

Socioeconomic inequality and its association with traffic accidents in Great Santiago, Chile

Mauricio Iturrieta, BSc¹, Carola Blazquez, PhD¹ y Karen Sauer-Brand, PhD¹

¹Universidad Andres Bello, Chile, m.iturrieta@uandresbello.edu, cblazquez@unab.cl, k.sauerbrand@uandresbello.edu

Abstract- In the present study, we investigate the relationship between different dimensions that define socioeconomic inequality and the rate of traffic accidents that occurred in the 34 communes of Great Santiago, Chile in the 2015-2019 period. First, global regression models are employed to explore the associations between the variables, and consequently, spatial regression models (spatial lag models, spatial error models, and geographically weighted regression) were used. Results suggest that the rate of educational establishments present a strong association with the rates of traffic accidents, particularly in communes with high levels of poverty. Thus, the results may support authorities in the resource assignment for road safety by prioritizing those communes in Great Santiago with inhabitants of medium-low socioeconomic segments.

Keywords- Spatial econometry, regression models, traffic safety, inequity, Chile

Desigualdad socioeconómica y su asociación con accidentes de tránsito en el Gran Santiago, Chile

Mauricio Iturrieta, BSc¹, Carola Blazquez, PhD¹ y Karen Sauer-Brand, PhD¹

¹Universidad Andres Bello, Chile, m.iturrieta@uandresbello.edu, cblazquez@unab.cl, k.sauerbrand@uandresbello.edu

Resumen— En el presente estudio, se investiga la relación entre diferentes dimensiones que definen la desigualdad socioeconómica y la tasa de accidentes viales que ocurrieron en las 34 comunas del Gran Santiago, Chile entre los años 2015 y 2019. Para ello, primero, se usaron modelos de regresión globales para explorar las asociaciones entre las variables, y posteriormente se implementaron modelos de regresión espaciales (modelo de retraso espacial, modelo de error espacial y regresión ponderada geográficamente). Los resultados sugieren que la tasa de establecimientos educacionales presenta una fuerte asociación con la tasa de accidentes viales, particularmente en comunas con niveles más altos de pobreza. Por lo tanto, estos resultados pueden apoyar a las autoridades en la asignación de recursos para la seguridad vial privilegiando aquellas comunas del Gran Santiago con habitantes de segmentos socioeconómicos medios-bajos.

Palabras claves— Econometría espacial, modelos de regresión, seguridad vial, inequidad, Chile

I. INTRODUCCIÓN

Cada año mueren más 1.3 millones de personas en accidentes automovilísticos a nivel mundial y cerca de 50 millones resultan heridas cuya mayoría son niños y jóvenes entre 5 y 29 años principalmente del sexo masculino. Al año 2030, se espera que esta cifra se triplique llegando 3.6 millones de víctimas fatales anuales [1]. Los países en vías de desarrollo representan el 50% del tráfico vial en el mundo y a éstos se les asocia el 90% de las muertes por accidentes de tránsito [2]. La mayoría de los accidentes fatales en estos casos corresponden a usuarios vulnerables; peatones, ciclistas y motociclistas [3].

Según el Banco Mundial, los accidentes viales representan en promedio entre el 1% y el 3% del producto interno bruto (PIB) en países de medianos y puede llegar a un 5% en países de bajos recursos. Chile no es ajeno a esta cifra, en el año 2020, los accidentes viales significaron un 2,01% del PIB equivalentes a más de US\$ 5.485 millones de dólares [4].

Producto de la expansión urbana, las distancias y tiempos de viaje han ido aumentando, profundizando las condiciones de segregación socio espacial y de creciente desigualdad en términos de conectividad de los territorios. Asimismo, existe una importante población que no posee automóvil y que depende en gran medida del transporte público de baja calidad, en especial, en las zonas más alejadas. Específicamente, los usuarios del transporte público disponen de recursos limitados para su movilidad, por lo que deben aceptar un alto costo en tiempo para minimizar el gasto de su dinero en este ítem [5]. De lo anterior, se deduce que, con mayor frecuencia, los grupos de ingresos más bajos están desproporcionadamente expuestos a un mayor número de accidentes de tráfico fatales, pues por su ubicación geográfica deben recorrer distancias mayores [6, 7],

y al aumentar su exposición aumenta la accidentabilidad [8]. En cambio, en los segmentos socioeconómicos más altos, donde la tasa de propiedad de automóviles es mayor, se registran menor cantidad de accidentes viales [8].

Estudios que se han enfocado en investigar la asociación entre los factores socioeconómicos y los accidentes viales. Por ejemplo, [9] estudiaron la influencia de los factores socioeconómicos y demográficos en la ocurrencia de colisiones con peatones ocurridos en Tennessee entre el 2008 y 2012. Para ello, se incluyeron diferentes variables (tales como estado de pobreza, distribución por edades, disponibilidad de automóviles en el hogar y modo de transporte al trabajo) en un modelo binomial negativo para comprender la influencia de estas variables en los atropellos de peatones. En otro estudio, [10] identificaron que en España las condiciones económicas y la educación son factores explicativos relevantes de accidentes fatales y lesiones en las provincias de segmentos socioeconómicos más altos y que para reducir los riesgos de accidentes fatales y lesiones en países menos desarrollados, es imperativo invertir en infraestructura vial y aumentar la proporción de vías de alta capacidad. [8] concluyó que los riesgos de accidentes fatales aumentan con el kilometraje recorrido y la motorización durante los auge económicos y que tanto los accidentes fatales de tránsito como las conductas riesgosas en éste disminuyen al disminuir las tasas de desempleo. Respecto del mismo tema, [3] establecieron que la tasa de accidentes viales es directamente proporcional al PIB per cápita hasta cierto umbral y posteriormente disminuye, formando una U. Finalmente, [5] compararon el quintil de menores y de mayores ingresos en la ciudad de Santiago y se estableció que las personas más ricas realizan 1,2 veces más viajes a una velocidad promedio 1,6 veces mayor que las personas más pobres. Además, el uso de automóvil privado del último quintil es 5,3 veces mayor, y que este medio de transporte tiene una incidencia 6,8 veces mayor en los accidentes viales que usar el transporte público, caminar y andar en bicicleta.

Por lo tanto, es necesario asignar los recursos para la seguridad vial, privilegiando las necesidades de la población [7], confirmando la necesidad de incluir en el desarrollo y planificación vial futuro las tasas de mortalidad y accidentalidad vial de los espacios geográficos que habitan las personas de distintos segmentos socioeconómicos y sus condiciones geográficas [10].

Según la Comisión Nacional de Seguridad del Tránsito (CONASET), en el año 2019, hubo un total de 89.983 accidentes de tránsito en Chile, de los cuales 30.242 (33.6%) ocurrieron en la Región Metropolitana que incluye a la ciudad

de Santiago. En particular, las comunas de Santiago, Maipú, Puente Alto y San Bernardo de la ciudad de Santiago requieren de intervenciones urgentes por parte del Estado para aumentar sus niveles de desarrollo económico [11]. El objetivo del presente estudio es investigar la relación entre la desigualdad socioeconómica y los accidentes viales que ocurrieron en el Gran Santiago, Chile entre los años 2015 y 2019. Para ello, se utilizaron diferentes modelos de regresión espaciales y, además, se definieron seis dimensiones para la desigualdad socioeconómica: pobreza multidimensional, establecimientos educacionales, empresas, trabajadores, permisos de circulación y desempleo.

III. DATOS

La Tabla I muestra la definición para cada variable analizada en este estudio. La base de datos sobre los accidentes viales ocurridos en las 34 comunas que conforman el Gran Santiago fueron descargados de la página web de la CONASET¹. La información de la pobreza multidimensional, empresas y trabajadores por comuna en el Gran Santiago se adquirió de la Biblioteca Nacional del Congreso de Chile. Los establecimientos educacionales se obtuvieron del Ministerio de Educación². El Instituto Nacional de Estadística (INE) proveyó los datos sobre los permisos de circulación (vehículos registrados) por comuna en el Gran Santiago. Finalmente, la tasa de desempleo se descargó de la página web del IDE Observatorio de Ciudades UC³.

La Tabla II presenta los valores promedios para cada variable y por año del periodo estudiado. Esta tabla indica que la tasa de accidentes viales (TAV) presenta su valor más alto en el año 2017, similarmente a la tasa de trabajadores (TT) y la tasa de permisos de circulación (TPC). Mientras que las variables sobre la tasa de pobreza multidimensional (TPM) y la tasa de establecimientos educacionales (TEE) disminuyeron a través del periodo del estudio. La tasa de empresas (TE) y la tasa de desempleo (TD) han mostrado reducciones en el tiempo.

Fig. 1 muestra la distribución espacial de la TAV a nivel de comuna en el Gran Santiago por cada año del estudio. Estas figuras muestran que las comunas de Providencia y Cerrillos ubicadas hacia el centro de la ciudad poseen las tasas más altas de accidentabilidad en la mayoría de los años del estudio.

TABLA I
VARIABLES DEL ESTUDIO

Variable Dependiente	
Tasa de Accidentes Viales (TAV)	Accidentes cada 10.000 habitantes de la comuna en el año mencionado.
Variable Independiente	
Tasa de Pobreza Multidimensional (TPM)	Pobreza multidimensional cada 10.000 habitantes de la comuna en el año mencionado.
Tasa de Establecimientos Educacionales (TEE)	Cantidad de establecimientos educacionales cada 10.000 habitantes por comuna.
Tasa de Empresas (TE)	Cantidad de empresas cada 10.000 habitantes por comuna.
Tasa de Trabajadores (TT)	Cantidad de trabajadores cada 10.000 habitantes por comuna.
Tasa de Permisos de Circulación (TPC)	Cantidad de permisos de circulación (vehículos registrados) cada 10.000 habitantes en la comuna.
Tasa de Desempleo (TD)	Cantidad de personas sin trabajo por comuna cada 10.000 habitantes

TABLA II
PROMEDIO TOTAL DE LAS VARIABLES POR AÑO

Variable	Año				
	2015	2016	2017	2018	2019
TAV	1326,3	1536,2	1677,0	1485,4	1146,5
TPM	62305,3	61946,2	61964,8	59524,1	58007,0
TEE	747,3	730,1	725,3	684,3	661,2
TE	24469,2	24658,1	26311,8	26608,1	26217,0
TT	298420,0	297428	301677,1	290255,6	280717,6
TPC	102169,7	104840,0	109057,6	108900,9	106935,0
TD	21145,3	22542,9	22157,9	22766,6	23691,8

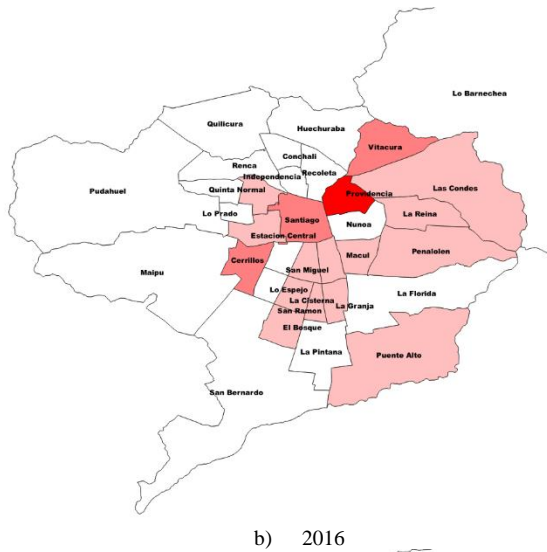


a) 2015

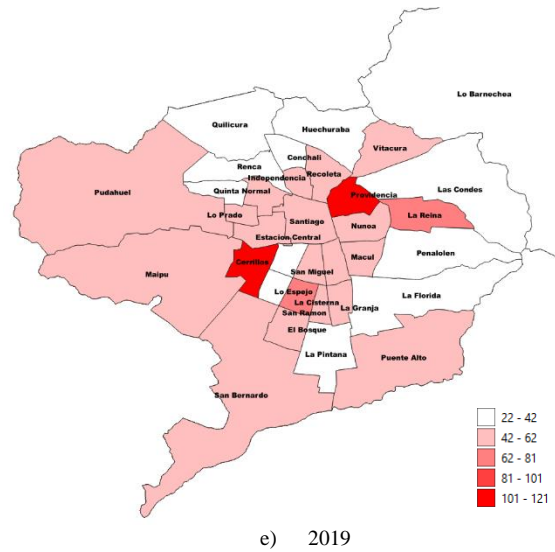
¹ <https://mapas-conaset.opendata.arcgis.com/>

² <https://www.ide.cl/index.php/instalaciones-y-edificaciones/item/1900-establecimientos-de-educacion-escolar>

³ <https://ideocuc-ocuc.hub.arcgis.com/datasets/185b4619bccf4441bb909443d67def06/about>




b) 2016

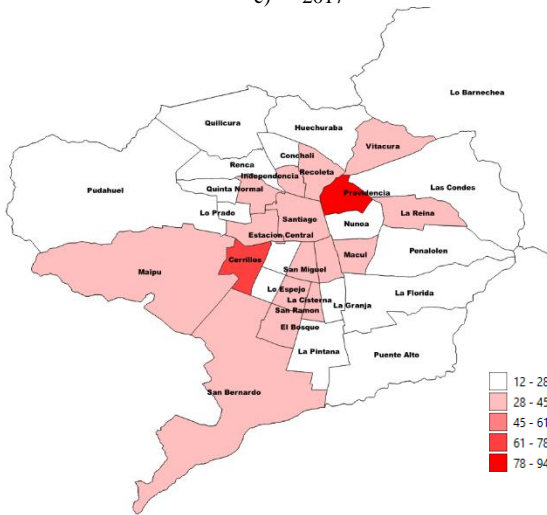


e) 2019

Fig. 1 Tasa de accidentes viales por año.



c) 2017



d) 2018

IV. METODOLOGÍA

En este estudio, primero, el análisis de regresión global se utilizó para explorar las relaciones entre variables explicativas y la variable dependiente minimizando la suma de los cuadrados de los residuales (OLS, por su sigla en inglés). OLS está definida por la expresión (1) [12, 13].

$$y_i = \beta_0 + x_i\beta + \varepsilon_i \quad (1)$$

donde y_i representa la estimación de la tasa de accidentes viales en la comuna i , x_i es el vector de variables independientes, β es el vector de coeficientes de regresión global, β_0 es el intercepto y ε_i es el error.

Posteriormente, se implementaron dos modelos de regresión espaciales: el modelo de retraso espacial (SLR) y el modelo de error espacial (SER). El SLR (por su sigla en inglés) asume la dependencia entre la variable dependiente y las variables independientes e incorpora dependencia espacial en el modelo de regresión con una variable dependiente del retraso espacial. SLR se calcula usando (2) [13].

$$y_i = \beta_0 + x_i\beta + \rho w_i y_i + \varepsilon_i \quad (2)$$

donde ρ es el parámetro de retardo espacial y w_i es el vector de pesos espaciales que relaciona las variables en la comuna i .

El SER (por su sigla en inglés) asume la dependencia espacial en el error del OLS y descompone este error de (1) en dos componentes: a) un término que indica el componente espacial del error ($\lambda w_i \xi_i$) y b) un término que satisface el supuesto de regresión normal (ε_i), como se muestra en (2) [13].

$$y_i = \beta_0 + x_i\beta + \lambda w_i \xi_i + \varepsilon_i \quad (3)$$

donde en la comuna i , ξ_i indica la componente espacial del error, w_i es el vector de pesos espaciales, λ representa el nivel

de correlación entre los componentes y ε_i es el término de error no correlacionado espacialmente.

A diferencia del OLS que asume que los parámetros estimados son constantes en el espacio, los parámetros varían espacialmente en la regresión ponderada geográficamente (GWR, por su sigla en inglés). GWR calcula los coeficientes de la regresión dependiendo de su ubicación geográfica y entrega información local sobre la relación entre la variable de interés y algún factor en un punto geográfico específico. GWR está expresado por (4) [14].

$$y_i = \beta_0(\mu_i, v_i) + \sum_{k=1}^n \beta_k(\mu_i, v_i)x_{ik} + \delta_i \quad (4)$$

donde los estimadores locales son representados por (μ_i, v_i) que es una matriz que representa la ubicación de la comuna i ; x_{ik} es la observación i de la variable k , $\beta_k(\mu_i, v_i)$ representa el coeficiente local para el predictor k en la comuna i en la ubicación (μ_i, v_i) . Nótese que se usaron los indicadores R^2 y AIC para evaluar el desempeño de cada modelo.

V. RESULTADOS

A. Modelo de Regresión Global

Primero, se realizó un análisis exploratorio con OLS para cada año del periodo estudiado, el cual entregó un coeficiente estimado para cada variable, como se muestra en la Tabla III. Esta tabla indica que la TEE tiene una asociación positiva fuerte con la TAV para todos los años, excepto para el año 2015. En segundo lugar, la TPC o vehículos registrados presenta la mayor relación con la TAV en el año 2017. La TE afectó significativamente en el año 2015, mientras que la tasa de trabajadores en el año 2017. De la misma manera, la TPM tiene la mayor influencia en la TAV durante el año 2017. Por último, la TD presenta la mayor asociación con la TAV en los años 2015 y 2016, pero con diferentes signos.

Tabla III
RESULTADOS DEL MODELO DE REGRESIÓN GLOBAL OLS

Variable	Año				
	2015	2016	2017	2018	2019
TPM	0,005	-0,001	0,052	0,000	-0,001
TEE	1,665	1,477	0,002	1,677	1,143
TE	0,023	0,020	-0,000	0,015	0,013
TT	0,000	0,000	0,019	0,000	0,000
TPC	0,000	0,003	1,036	0,001	0,001
TD	-0,031	0,036	-0,006	0,006	0,008

B. Modelos de Regresión Espaciales

A continuación, se implementó el modelo SLR cuyos resultados se muestran en la Tabla IV. Al igual que el modelo OLS, esta tabla indica la TEE tiene una asociación positiva fuerte con la TAV para todos los años, excepto para el año 2017. Nuevamente, la TPC presenta la mayor relación con la TAV en el año 2017. Durante el año 2017, la TPM presentó una relación positiva con la TAV diferencia a los otros años del estudio. La TE tuvo una baja considerable en la implicancia de la TAV a comparación de los otros años. En el 2017, se ven las principales alzas en la TAV por la TT y por TPC. Por último, la

TD en el año 2016 fue una gran influyente a comparación a los otros años en la TAV.

La Tabla V muestra los resultados con los modelos de regresión espacial SER para cada año del estudio. Los resultados presentados en esta tabla son bastante similares a los resultados de los modelos en las Tablas III y IV.

Fig. 2-7 muestran los resultados de los modelos GWR, los cuales entregan un coeficiente estimado promedio entre los años 2015 y 2019 para cada variable por comuna. Los coeficientes de la TPM mostrados en la Fig. 2 exhiben un signo negativo lo que resulta contra intuitivo ya que indicaría a mayor TPM menor es la TAV. Por lo tanto, en futura investigación, se estudiará con más detalle esta dimensión.

La Fig. 3 muestra que la comuna de Macul posee la mayor asociación entre la TEE y la TAV, seguidos por Lo Espejo, Maipú, Lo Prado y Lo Barnechea. Nótese que esta variable presenta los coeficientes más grandes que otras variables estudiadas. Por lo tanto, se debe estudiar en el futuro si los accidentes ocurridos en estas comunas involucran particularmente a escolares. Con respecto a la TE, las comunas con mayor impacto en la TAC son El Bosque, Cerrillos, Cerro Navia, Quinta Normal, Recoleta y Conchalí. En cambio, la variable TT tiene una incidencia positiva en la TAV en las comunas de Quilicura, Lo Espejo, Macul, Lo Barnechea y Las Condes. Las comunas de Providencia, Huechuraba, Renca, Cerrillos y Estación Central poseen los coeficientes más altos para la variable TPC, es decir, en estas comunas, existe un mayor impacto de los vehículos registrados en la TAV. Finalmente, los valores de los coeficientes estimados para la TD son similares a los valores de los coeficientes de la TE. Además, las comunas con coeficientes más altos son semejantes para estas dos variables.

Tabla IV
RESULTADOS DEL MODELO DE REGRESIÓN ESPACIAL SLR

Variable	Año				
	2015	2016	2017	2018	2019
TPM	0,004	-0,002	0,051	-0,001	-0,001
TEE	1,560	1,379	0,001	1,567	1,127
TE	0,027	0,024	-0,000	0,018	0,015
TT	0,000	0,000	0,022	0,000	0,000
TPC	0,000	0,003	0,949	0,001	0,001
TD	-0,034	0,030	-0,007	0,009	0,009

Tabla V
RESULTADOS DEL MODELO DE REGRESIÓN ESPACIAL SER

Variable	Año				
	2015	2016	2017	2018	2019
TPM	0,004	-0,000	0,058	0,000	-0,001
TEE	1,717	1,342	0,001	1,624	1,121
TE	0,023	0,013	-0,000	0,016	0,014
TT	0,000	0,001	0,023	0,000	0,000
TPC	-0,001	0,004	0,988	0,001	0,001
TD	-0,046	0,023	-0,006	0,009	0,008

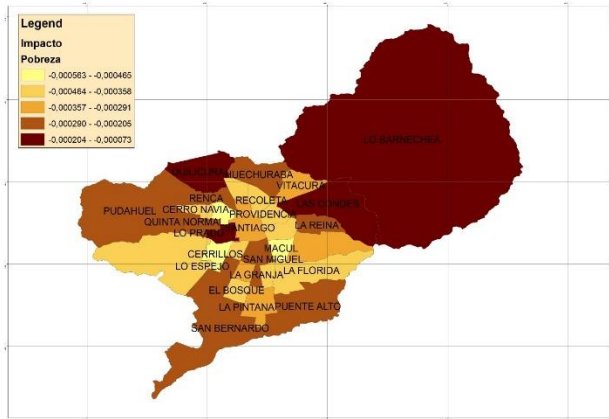


Fig. 2 Coeficientes promedio para la variable TPM usando GWR.




Fig. 5 Coeficientes promedio para la variable TT usando GWR.




Fig. 3 Coeficientes promedio para la variable TEE usando GWR.




Fig. 6 Coeficientes promedio para la variable TPC usando GWR.




Fig. 4 Coeficientes promedio para la variable TE usando GWR.




Fig. 7 Coeficientes promedio para la variable TD usando GWR.

C. Comparación entre los modelos de regresión

Las Tablas VI y VII muestran el desempeño de cada modelo de regresión usando R^2 y AIC, respectivamente. Estas tablas indican que el desempeño de los modelos empeora a través del tiempo ya que el R^2 disminuye desde valores sobre 0.70 en el 2015 a cercanos a 0.40 en el 2019. Similarmente, los valores de AIC tienden a subir desde el 2015 al 2019, confirmando nuevamente que los modelos presentan mejor desempeño en los años 2015 y 2016. Por lo tanto, se puede apreciar un mejor ajuste de las variables socioeconómicas con la TAV para los primeros años del estudio.

En promedio, el desempeño de los modelos GWR usando el indicador R^2 es superior a los otros modelos en tres de los cinco años del estudio. Sin embargo, el desempeño de los modelos SER presenta el menor valor del indicador AIC. Cabe destacar que, pese a que los modelos GWR tienen un desempeño inferior cuando se usa el indicador AIC, estos modelos tienen la ventaja de estimar coeficientes para las variables en cada comuna, como se mostró en las Fig. 2-7.

TABLA VI
VALORES DE R^2 PARA CADA MODELO DE REGRESIÓN

Regresión	Año				
	2015	2016	2017	2018	2019
OLS	0.72	0.71	0.68	0.54	0.38
SLR	0.75	0.73	0.70	0.56*	0.40*
SER	0.79*	0.73	0.69	0.54	0.38
GWR	0.72	0.74*	0.73*	0.54	0.40*

*Presentan el mejor desempeño para cada año

TABLA VII
VALORES DE AIC PARA CADA MODELO DE REGRESIÓN

Regresión	Año				
	2015	2016	2017	2018	2019
OLS	279.1	277.2	274.9	291.4	286.6
SLR	290.3	276.9*	275.6	292.0	287.7
SER	273.5*	277.1	274.2*	291.3*	286.5*
GWR	286.0	284.0	281.0	299.0	294.0

*Presentan el mejor desempeño para cada año

V. CONCLUSIONES

En este estudio, se utilizó econometría espacial para determinar la relación la desigualdad socioeconómica y la accidentabilidad vial en el Gran Santiago entre los años 2015 y 2019. Todos los modelos analizados indican que la tasa de establecimientos educacionales (TEE) tiene la mayor asociación positiva con la tasa de accidentes viales (TAV), en comparación con las otras dimensiones estudiadas. En otras palabras, la TEE es la variable que más inciden en la TAV y, consecuentemente, los estudiantes son los más expuestos a las externalidades del transporte. Además, se demuestra que la tasa de empresas (TE) y la tasa de desempleo (TD) repercutan en los

accidentes, afectando principalmente a las comunas que presentan altos niveles de pobreza.

Los resultados sugieren que los modelos de regresión espaciales GWR y SER presentan el mejor desempeño al usar los indicadores R^2 y AIC, respectivamente. El modelo GWR tiene la ventaja de estimar coeficientes por comuna. Con este modelo, se corroboran los resultados de los otros modelos ya que la TEE es la variable que más se relaciona con la TAV.

Futura investigación debería considerar un estudio más minucioso de la TAV y su alta asociación en el 2017 con la tasa de pobreza multidimensional (TPM), la tasa de trabajadores (TT) y la tasa de permisos de circulación (TPC). Similarmente, es necesario investigar la disminución del desempeño de los modelos en el tiempo, particularmente para el año 2019. En el futuro trabajo, se debería realizar un análisis espacial de los accidentes viales usando otras dimensiones que puedan medir la desigualdad socioeconómica tales como nivel de educación y movilidad de las personas en las comunas.

BIBLIOGRAFÍA

- [1] Organización Mundial de la Salud, OMS, "Traumatismos causados por el tránsito," 2021 [Online]. <https://www.who.int/es/news-room/factsheets/detail/road-traffic-injuries>
- [2] The Washington Post. "Roads Kill: The toll of traffic accidents is rising in poor countries," [Online]. https://www.washingtonpost.com/world/roads-kill-the-toll-of-traffic-accidents-are-rising-in-poor-countries/2014/01/12/b1065922-56d2-11e3-8304-caf30787c0a9_story.html
- [3] A. Hyder, and M. Peden, M, Inequality and road-traffic injuries: call for action," *The Lancet*, vol. 362, 9401, pp. 2034-20342003.
- [4] Comisión Nacional de Seguridad del Tránsito, CONASET, "Costo social de los siniestros de tránsito en Chile," 2021 [Online] <https://www.conaset.cl/wp-content/uploads/2021/05/Costos-accidentes-2020.pdf>
- [5] V. Iglesias, F. Giraldez, I. Tiznado-Aitken, and J. Muñoz, "How Uneven is the Urban Mobility Playing Field? Inequalities among Socioeconomic Groups in Santiago De Chile," *Transport Res Rec*, vol. 2673, no. 11, pp. 59-70, 2019.
- [6] G. Lucas, G. Mattioli, E. Verlinghieri, and A. Guzman, "Transport poverty and its adverse social consequences," *Proc. of the Institution of Civil Engineers - Transport*, vol. 169, no. 6, pp. 353-365, 2016.
- [7] A. Krüger, "Fatal connections- socioeconomic determinants of road accident risk and drunk driving in Sweden," *J Safety Res*, vol. 46, pp. 59-65, 2013.
- [8] A. Pirdavani, S. Daniels, K. Van Vlierden, K. Brijs, and B. Kochan, "Socioeconomic and sociodemographic inequalities and their association with road traffic injuries," *J Transp Health*, vol. 4, pp. 152-161, 2017.
- [9] D. Chimba, A. Musinguzi A, and E. Kidando, "Associating pedestrian crashes with demographic and socioeconomic factors," *Case studies on transport policy*, vol. 6, no. 1, pp. 11-16, 2018.
- [10] M. González, A. Ponce, and F. Sotos, "Interregional inequality and road accident rates in Spain," *Accident Anal Prev*, vol. 135, 105347, 2020.
- [11] S. Gajardo, "Índice De Prioridad Social De Comunas 2022," SEREMI. Ministerio de Desarrollo Social y Familia. 2022 [Online] https://www.desarrollosocialyfamilia.gob.cl/storage/docs/INDICE-DE-PRIORIDAD-SOCIAL-2022_V2.pdf
- [12] L. Anselin, and D. Arribas-Bel, "Spatial fixed effects and spatial dependence in a single cross-section," *Pap Reg Sci*, vol. 92, no. 1, pp. 3-17, 2013.
- [13] M. Ward, and K. Gleditsch, *Spatial regression models*, Sage Publications, 2018.
- [14] A. Fotheringham, and T. Oshan, "Geographically weighted regression and multicollinearity: dispelling the myth," *J Geogr Syst*, vol. 18, no. 4, pp. 303-329, 2016.