

EXPLORACIÓN DE PATRONES ESPACIALES DE LA PRIMERA OLA DE COVID-19 EN SANTIAGO DE CHILE: UN ENFOQUE DE AUTOCORRELACIÓN ESPACIAL.

EXPLORATION OF SPATIAL PATTERNS OF THE FIRST WAVE OF COVID-19 IN SANTIAGO, CHILE: AN APPROACH TO SPATIAL AUTOCORRELATION.

Manuel Fuenzalida¹

ABSTRACT

A quantitative research study is conducted to explain the spatial distribution of the frequency of active COVID-19 cases (SARS-CoV-2) among residents within the Metropolitan Area of Santiago, organized into square kilometer urban quadrants, during the first wave (May-August 2020). Spatial autocorrelation analysis is performed, including Moran's I and LISA Cluster. The results show that the autocorrelations are positive, moderate to strong, across all four months of interest. Additionally, five spatial clusters are identified, where changes in the "High-High" and "Low-Low" groups suggest that complex dynamics may be influencing the transmission of the virus. These clusters predominantly occupy the central area of the Metropolitan Area of Santiago (AMS) for the "High-High" group and the periphery for the "Low-Low" group.

Keywords: COVID-19; Geography of Health; spatial autocorrelation.

RESUMEN

Se desarrolla una investigación de carácter cuantitativo que intenta explicar la distribución espacial de la frecuencia de casos activos por COVID-19 (SARS CoV-2) de las personas residentes al interior del Área Metropolitana de Santiago, contenidas en cuadrante por kilómetro cuadrado urbano, durante la primera ola (mayo-agosto 2020). Se ejecuta el análisis de autocorrelación espacial; I de Moran; Clúster LISA. Los resultados han permitido observar que las autocorrelaciones son en los cuatro meses de interés positivas, moderada a fuerte. También se identifican 5 clúster espaciales, en donde los cambios en los grupos "Alto-Alto" y "Bajo-Bajo" indican que puede haber dinámicas complejas en la transmisión del virus. Estos clústeres preferentemente ocupan el centro del AMS para el grupo "Alto-Alto" y la periferia para el grupo "Bajo-Bajo".

Palabras clave: COVID-19; geografía de la salud; autocorrelación espacial.

¹ Departamento de Geografía, Universidad Alberto Hurtado. Almirante Barroso 10, Santiago, Chile

1. INTRODUCCIÓN

La pandemia por COVID-19, producida por el coronavirus SARS CoV-2 fue un fenómeno global sin precedentes que puso de relieve no solo los desafíos sanitarios, sino también la importancia de comprender las dinámicas espaciales que subyacen a su propagación (Suárez Lastra et al., 2021). La revisión del estado del arte reporta que la distribución de los casos de COVID-19 no es homogénea; en cambio, se caracteriza por patrones complejos que pueden estar influenciados por una variedad de factores sociales, económicos y ambientales (Gutiérrez-Hernández y García, 2020; Aranguiz, 2021; Cuartas et al., 2023; Delgado Viñas, 2023).

Como bien describe Patel et al. (2020), las personas de nivel socioeconómico bajo (NSB) presentan una serie de factores que aumentan su exposición al COVID-19. En primer lugar, las personas económicamente desfavorecidas tienen más probabilidades de vivir en viviendas con hacinamiento, en donde existen más dificultades para el cumplimiento del distanciamiento social. En segundo lugar, las personas de bajos ingresos a menudo están empleadas en ocupaciones que no brindan oportunidades para trabajar desde casa. En tercer lugar, los que pertenecen a grupos de NSB tienen más probabilidades de tener condiciones de trabajo e ingresos inestables, condiciones exacerbadas por las respuestas al COVID-19 y sus consecuencias. En cuarto lugar, las personas de NSB se presentan a los servicios de salud en una etapa más avanzada de la enfermedad, lo que da como resultado peores resultados de salud. Finalmente, existe evidencia emergente de que la hipertensión y la diabetes son factores de riesgo de muerte por COVID-19 (Guam et al. 2020).

El estudio de la propagación del COVID-19 a través de un lente espacial no solo contribuye al campo de la Geografía de la Salud, sino que también promueve una comprensión más profunda de las interacciones entre salud pública y factores socioeconómicos, enfatizando la necesidad de estrategias integradas que aborden estas complejidades en futuras pandemias (Sánchez et al., 2022).

En este contexto, el análisis de autocorrelación espacial se presenta como una herramienta esencial para investigar cómo los casos de COVID-

19 están relacionados entre sí en distintos lugares o espacios (Santana et al., 2020).

El concepto de autocorrelación espacial se refiere a la dependencia de los valores de una variable en un espacio geográfico. En el caso de COVID-19, la autocorrelación puede indicar si la ocurrencia de casos en un área está relacionada con la ocurrencia de casos en áreas vecinas. Esta relación es crucial para entender las dinámicas de transmisión del virus y cómo factores como la densidad poblacional, el acceso a servicios de salud y las intervenciones de salud pública influyen en la propagación del virus (Escolano-Utrilla & Salvador-Oliván, 2022).

El análisis de autocorrelación espacial se puede llevar a cabo mediante diversas metodologías, entre las cuales destacan el Índice de Moran y el análisis de clústeres. El Índice de Moran es una medida que evalúa si los valores de una variable, en este caso, la incidencia de COVID-19, están distribuidos de manera aleatoria o si, por el contrario, presentan patrones espaciales significativos (Chamizo-García et al., 2024). Un valor positivo del Índice de Moran sugiere que los casos tienden a agruparse, mientras que un valor negativo indica dispersión. Este tipo de análisis puede ayudar a identificar "puntos calientes" de transmisión, lo cual es crucial para orientar recursos y estrategias de intervención.

Además del Índice de Moran, el análisis de clústeres proporciona una forma de identificar agrupamientos de casos en áreas específicas. A través de métodos como el análisis de clústeres de alta y baja carga (Siabato & Guzmán-Manrique, 2019), es posible determinar no solo dónde se concentran los casos, sino también qué factores pueden estar contribuyendo a esas concentraciones. Estos enfoques permiten a los investigadores no solo mapear la distribución de los casos, sino también examinar cómo factores contextuales pueden estar influyendo en la propagación del virus.

De esta forma, los resultados del análisis de autocorrelación espacial han demostrado ser relevantes en diversas investigaciones sobre COVID-19. Por ejemplo, estudios han encontrado que áreas con mayor densidad poblacional y menor acceso a servicios de salud presentan una mayor concentración de casos (Cerón Vargas et al., 2022). Estos hallazgos resaltan la importancia de

integrar enfoques espaciales en la planificación de políticas de salud pública, especialmente en un contexto de crisis sanitaria.

Sumado a la relevancia para la gestión de una pandemia, el análisis de autocorrelación espacial también puede ofrecer perspectivas sobre las desigualdades sociales que afectan la salud. La distribución desigual de los casos de COVID-19 refleja no solo la biología del virus, sino también las condiciones socioeconómicas y el acceso a recursos que varían significativamente entre diferentes comunidades o territorios (Leveau & Bastos, 2022). Al comprender estas desigualdades, los responsables de la formulación de políticas pueden diseñar intervenciones más efectivas que aborden las necesidades específicas de las comunidades más afectadas.

En términos técnicos, la estructura espacial del medio circundante a una observación o dato individual, puede ser descrita por la técnica de la autocorrelación espacial. Ésta, entendida como el cálculo de concentración espacial, ha ocupado un papel preponderante, basándose en el legado de Tobler, el cual sugiere que los valores cercanos están más relacionados y se parecen más que los valores que están alejados. Básicamente, en un análisis de autocorrelación espacial ya no se intenta medir la correlación entre dos variables diferentes en un mismo espacio, sino la correlación que una misma variable tiene en diferentes unidades espaciales contiguas. Por lo tanto, un análisis de autocorrelación espacial demuestra utilidad para descubrir cómo influye la componente espacial en el comportamiento correspondiente a la distribución espacial de la variable analizada (Buzai, 2006). Debido a estos argumentos, el análisis de autocorrelación se utiliza principalmente para estudiar de qué forma se produce la propagación de un fenómeno a través de diferentes unidades espaciales y si este comportamiento se adecua a algún modelo de difusión establecido o bien para estudiar la segregación espacial de alguna característica (Cárdena et al., 2023). Cuando la autocorrelación espacial es alta, los valores adyacentes de una variable muestran una relación significativa entre sí. Por el contrario, cuando la autocorrelación espacial es baja o prácticamente nula, los valores de la variable se distribuyen de manera aleatoria en el espacio.

Un ejemplo para entender el método de búsqueda de la autocorrelación se ilustra en la figura 1.

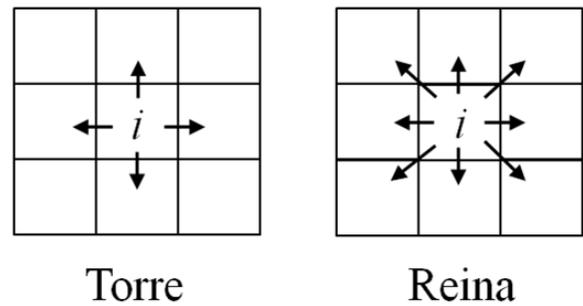


Figura 1. Método de búsqueda para la técnica de autocorrelación espacial. Fuente: Elaboración propia

2. MATERIALES Y MÉTODOS

2.1. Área de estudio

El Área Metropolitana de Santiago (AMS), es una conurbación que comprende 44 comunas dentro de la Región Metropolitana. Su localización absoluta es 33°30' Sur y 70°40'Oeste. En ella reside 1/3 de la población nacional (aprox. 6,9 millones de habitantes). Ver Figura 2.

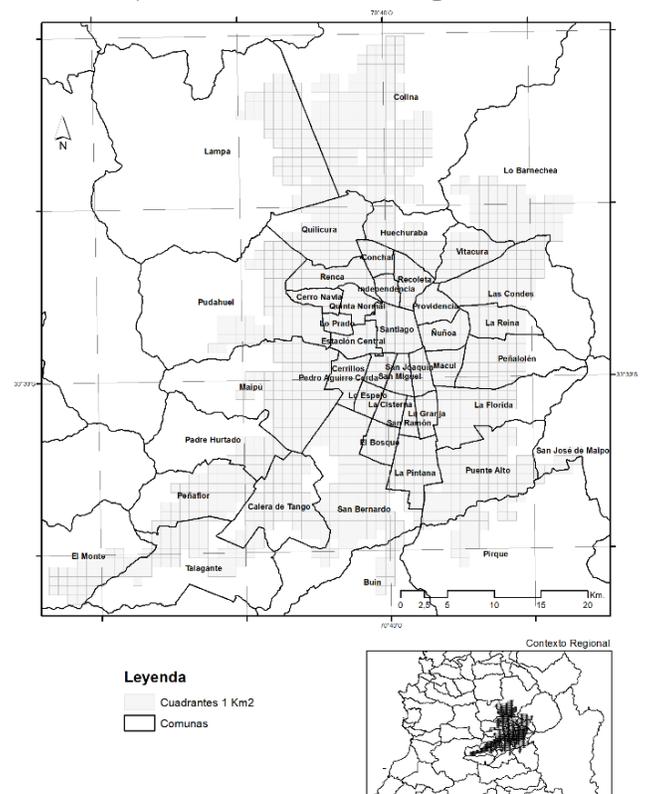


Figura 2. Área de estudio. Fuente: Elaboración propia

2.2. Fuente de información

La frecuencia de casos activos por COVID-19 (notificados con PCR positivo y casos probables) en cuadrante por kilómetro cuadrado urbano, fueron obtenidos desde la Unidad de Gestión Territorial del Departamento de Gestión de Riesgos en Emergencias y Desastres del Ministerio de Salud. Se puede acceder a la información a partir de la web <https://degreyd.minsal.cl/>

Se seleccionaron los meses de mayo a agosto de 2020, dado que corresponden a la primera gran ola de la pandemia, que tuvo su foco principal en el AMS (Chomali et al., 2021; Oppenheimer-Lewin et al., 2022). Dado que el conteo de casos por cuadrante es de 1 a 14 días, se utilizaron las fechas 14 y 28 de cada mes para construir el valor total de casos activos por COVID-19.

2.3. La técnica

La metodología se basa en la técnica de autocorrelación espacial. Con ella se hará el análisis espacial entre los cuadrantes por kilómetro cuadrado, de tipo reina, para una contigüidad espacial de primer orden. Se utilizan 1.359 unidades espaciales, con un mínimo de dos (en los bordes del área de estudio) y un máximo de 8 vecinos. La autocorrelación espacial se define como:

$$I = \frac{n \sum_i \sum_j w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{(\sum_i \sum_j w_{ij}) \sum (x_i - \bar{x})^2}$$

Donde n son las unidades espaciales del área de estudio, x_i es el valor de la variable en la localización central, x_j es el valor de la variable en las otras localizaciones vecinas, y w representa una medida de ponderación aplicada a la comparación entre las localizaciones $i-j$. Si $i-j$ son contiguas en el espacio toma valor 1 y si no valor 0. El valor w siempre será 1 por el hecho de estar trabajando con unidades espaciales con la misma forma y el mismo tamaño.

El resultado numérico de la autocorrelación varía entre -1 y 1. Esto nos puede entregar tres resultados interpretables: la autocorrelación positiva, cuando el valor resultante es >0 ; autocorrelación negativa, cuando el valor resultante es <0 ; y nula autocorrelación, cuando el valor resultante es $=0$ (Lucero & Celemín, 2008). Se utilizará el software GeoDa 1.14.

3. RESULTADOS

3.1 Estadísticos básicos

Los estadísticos básicos de la frecuencia de casos activos por COVID-19 por kilómetro cuadrado, para cada mes de interés se pueden examinar en la tabla 1. La distribución territorial de casos activos según mes de interés, se puede observar en la figura 3.

Tabla 1. Estadísticos básicos. Fuente: Elaboración propia

Estadístico	Mes			
	Mayo	Junio	Julio	Agosto
N	1.359	1.359	1.359	1.359
Min	0	0	0	0
Max	459	384	195	104
Media	29,7	47,8	23,2	10,7
Med	7,0	10,0	5,0	2,0
Desvest	46,1	67,7	32,9	15,6
Coef Var	1,5	1,4	1,4	1,4
Q1	0,0	1,0	0,0	0,0
Q3	44,0	81,0	37,0	16,0
IQR	44,0	80,0	37,0	16,0

Considerando que el área de estudio se encuentra compuesta por 1.359 cuadrantes, el valor mínimo es 0 en todos los meses, lo que sugiere que hay cuadrantes que no reportan actividad o eventos en cada uno de esos meses. En relación a los valores máximos, mayo tiene el valor máximo más alto (459), seguido por junio (384). Julio y agosto tienen máximos significativamente más bajos (195 y 104, respectivamente), lo que indica una disminución en los valores máximos de casos activos por COVID-19 a lo largo de los meses.

Respecto a la media, es más alta en junio (47.8), lo que indica que fue un mes de mayor actividad en comparación con los otros meses. La media disminuye significativamente en julio (23.2) y agosto (10.7). La mediana sigue una tendencia similar a la media, siendo más alta en junio (10.0) y disminuyendo en julio (5.0) y agosto (2.0). Esto sugiere que el centro de los datos también se desplaza hacia valores más bajos en los meses posteriores.

La desviación estándar es más alta en junio (67.7), lo que indica mayor variabilidad en los datos de ese mes. Disminuye en los meses posteriores, especialmente en agosto (15.6), lo que sugiere que los datos se concentran más cerca de la media. El coeficiente de variación es relativamente constante (alrededor de 1.4 a 1.5) en todos los meses, indicando que la variabilidad es alta en comparación con la media, lo que refuerza la idea de que hay datos dispersos o extremos.

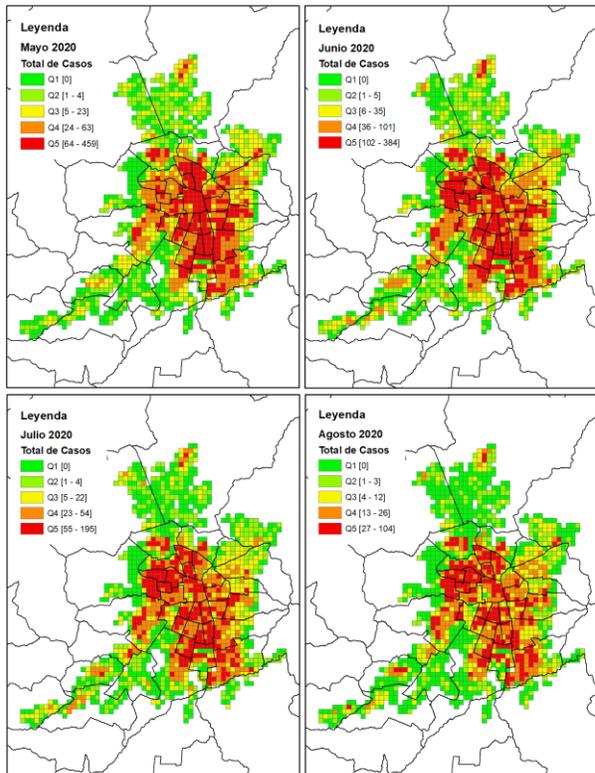


Figura 3. Distribución territorial de casos activos según mes de interés, año 2020. Fuente: Elaboración propia

Los cuartiles muestran que, en junio, la distribución es más amplia, con un rango intercuartílico (IQR) de 80.0, lo que indica mayor dispersión entre los cuartiles. En contraste, el IQR disminuye en los meses posteriores, siendo 16.0 en agosto.

En relación a las tendencias temporales, podemos concluir que hay una clara disminución en los valores máximos, la media y la mediana a medida que avanzan los meses de mayo a agosto. Esto refleja el comportamiento de la primera ola. La variabilidad de los datos es mayor en junio, lo que podría significar que hubo picos de casos activos

por COVID-19. Además, es posible afirmar que existe una estabilidad en la variabilidad relativa, ya que, a pesar de la disminución en las medias y la variabilidad absoluta, la relación de la variabilidad respecto a la media se mantiene constante..

3.2 Índices de Morán

Se puede identificar que las autocorrelaciones son en los cuatro meses de interés positivas, lo que significa que áreas cercanas tienden a tener valores similares a casos activos por COVID-19. Para el mes de mayo es de 0,641. Para el mes de junio es 0,630. Para el mes de julio es 0,602. Para el mes de agosto es 0.536 (ver figura 4).

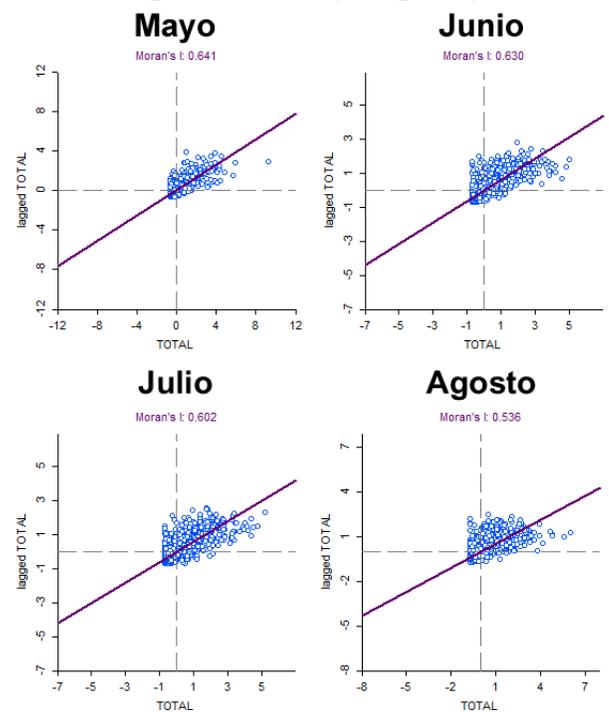


Figura 4. Índice de Moran según mes de interés, año 2020. Fuente: Elaboración propia

Tomando estos valores, se indica una autocorrelación positiva moderada a fuerte. Esto significa que hay una tendencia significativa para que los valores de la variable en áreas cercanas sean similares entre sí. En el contexto de los casos activos por COVID-19, esto sugiere que los cuadrantes por kilómetro cuadrado con alta presencia de casos activos tienden a estar cerca de otros cuadrantes con altos niveles de COVID-19.

Esto es un indicativo de que la variable analizada tiene una distribución espacial significativa, lo que

merece atención y análisis más profundos para entender mejor las causas y consecuencias de este patrón, lo cual habilita a realizar la identificación de clústeres.

3.3 Distribución territorial de los clúster LISA

Los resultados de los diversos clúster LISA, según mes de interés, para el año 2020 se pueden observar en la figura 5. Se espacializan cinco grupos diferentes. El primero de ellos corresponde al No significativo, que se interpreta como cuadrantes donde no se observa autocorrelación significativa. El segundo es Alto-Alto: Cuadrantes con alta concentración de casos vecinos. El tercero es Bajo-Bajo: Cuadrantes con baja concentración de casos vecinos. El cuarto es Bajo-Alto: Cuadrantes con baja concentración de casos vecinos y alta concentración en áreas adyacentes. El quinto corresponde a Alto-Bajo: Cuadrantes con alta concentración de casos vecinos y baja concentración en áreas adyacentes.

En relación al análisis mensual, del clúster no significativo, hay una tendencia general al aumento en el número de cuadrantes no significativos desde junio (553) a agosto (650), lo que indica que, a medida que avanza el tiempo, hay más áreas que no presentan un patrón claro de transmisión.

El clúster Alto-Alto, muestra un aumento en junio (294) y luego una disminución en julio (287) y agosto (266). El pico en junio podría sugerir un aumento en los casos activos durante ese mes, seguido de un descenso, lo que podría reflejar el éxito de intervenciones de salud pública o cambios en el comportamiento social (cuarentenas y distanciamiento social).

El clúster Bajo-Bajo, se mantiene relativamente constante, aunque se observa una ligera disminución desde mayo (476) hasta agosto (411). Esto podría indicar que la actividad del virus está comenzando a llegar a más zonas (aunque no necesariamente con alta concentración), lo cual es un indicio de que el contagio se está extendiendo.

El clúster Bajo-Alto, experimenta un aumento en este grupo desde 26 en mayo a un máximo de 40 en julio, y luego una disminución a 29 en agosto. Esto sugiere que algunas áreas con pocos casos están experimentando aumentos en casos en áreas adyacentes.

El clúster Alto-Bajo, es el más pequeño en número y muestra un ligero aumento a lo largo de los meses, de 1 en mayo a 3 en agosto. Aunque los números son bajos, su existencia podría indicar que hay áreas donde la concentración de casos es alta, pero que están rodeadas de áreas con pocos casos.

La tendencia general muestra que, a medida que avanza el tiempo, hay un aumento en la cantidad de cuadrantes que no presentan patrones significativos, lo que podría reflejar una dispersión de casos o una estabilización en algunas áreas.

Los cambios en los grupos "Alto-Alto" y "Bajo-Bajo" indican que puede haber dinámicas complejas en la transmisión del virus. Las áreas que experimentan alta concentración de casos pueden estar influenciadas por factores socioeconómicos o demográficos.

La variación en la cantidad de cuadrantes en cada categoría a lo largo de los meses sugiere que las intervenciones de salud pública estarían teniendo un impacto en la distribución de los casos, y sería importante evaluar cuáles fueron más efectivas.

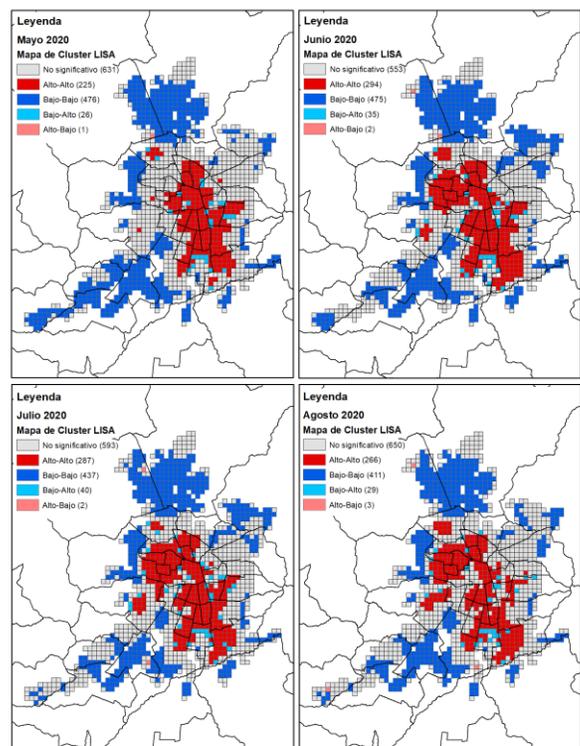


Figura 5. Clúster LISA según mes de interés, año 2020. Fuente: Elaboración propia

Sería útil realizar un análisis más profundo de las características de los cuadrantes en cada categoría, especialmente en los "Alto-Alto" y "Bajo-Bajo", para entender mejor las dinámicas subyacentes. Estos clúster preferentemente ocupan el centro del AMS para el grupo "Alto-Alto" y la periferia para el grupo "Bajo-Bajo".

Aquí las comunas de San Miguel, Independencia, La Granja, Lo Prado, San Ramón, Quinta Normal, La Cisterna, Pedro Aguirre Cerda, Cerro Navia, San Joaquín, El Bosque, Santiago, Conchalí, Lo Espejo, Macul, Estación Central, Recoleta, Renca, La Florida y Puente Alto, tienen de una mayor proporción de cuadrantes en el grupo "Alto-Alto".

Las comunas de Calera De Tango, Lampa, Colina, Lo Barnechea, San José De Maipo, Pirque, Buin y Talagante tienen de una mayor proporción de cuadrantes en el grupo "Bajo-Bajo".

Esta información cobra relevancia debido a que, según Orellana & Arenas (2024), las comunas con un Índice de Calidad de Vida Urbana (ICVU) clasificado como "bajo" o "medio bajo" formaron parte de una mayor proporción de cuadrantes en el clúster "Alto-Alto". Este hallazgo es significativo, ya que el ICVU se calcula a partir de un conjunto de variables distribuidas en seis dimensiones: Condiciones laborales, Ambiente de negocios, Condiciones socioculturales, Conectividad y movilidad, Salud y medio ambiente, y Vivienda y entorno, las cuales son procesadas estadísticamente mediante la técnica de Análisis de Componentes Principales (ACP).

4. DISCUSIÓN Y CONCLUSIONES

La relación entre la geografía de la salud y la pandemia de COVID-19, causada por el coronavirus SARS-CoV-2, presenta como principal evidencia que su distribución espacial ha demostrado ser heterogénea a nivel global, nacional e incluso local (Martellucci et al., 2020). Algunas regiones o países experimentaron brotes tempranos y severos, mientras que otros, inicialmente, lograron mantener los contagios contenidos (Han et al., 2021). Las grandes ciudades y las áreas densamente pobladas fueron, en general, los primeros puntos de concentración del virus. Esto se debió a varios factores, como la proximidad física entre individuos, el transporte

público, las actividades comerciales y la interacción social (Cordes & Castro, 2020).

Las zonas con mayores índices de pobreza y desigualdad social experimentaron un mayor impacto debido a las condiciones precarias de salud, la falta de acceso a servicios médicos adecuados, la alta prevalencia de comorbilidades como la diabetes o la hipertensión, y la dificultad para aplicar medidas preventivas como el confinamiento (Fuenzalida & Trebilcock, 2021; Morales Peña et al., 2024).

El concepto de autocorrelación espacial es fundamental en la Geografía de la Salud. Se refiere a la dependencia de los valores de una variable en un contexto geográfico. En el caso de COVID-19, este análisis permite entender si la ocurrencia de casos en un área está relacionada con la de áreas adyacentes. Siguiendo las recomendaciones de Sandar et al. (2023), cuando es posible identificar una fuerte autocorrelación espacial del patrón "Alto-Alto", esto debería respaldar a las partes interesadas y a los responsables de las políticas en sus esfuerzos por prevenir, controlar, monitorear y evaluar los determinantes multidimensionales de la pandemia de COVID-19.

De esta forma, el análisis de las dinámicas espaciales de la propagación del COVID-19 ofrece información valiosa para la planificación y ejecución de intervenciones en salud pública. En particular, se destaca la importancia de integrar factores socioeconómicos en estos análisis, ya que ello es fundamental para diseñar estrategias que no solo sean efectivas desde el punto de vista de la salud, sino también equitativas desde una perspectiva social. Sin embargo, este aspecto no ha podido ser abordado en el presente estudio, dado que la información espacial disponible se limita a los casos activos totales, lo que impide establecer relaciones con variables como la edad, el género, el nivel socioeconómico, entre otras.

No obstante, el empleo de la técnica de autocorrelación espacial, por medio del Índice de Moran y el análisis de clústeres, permitió identificar y mapear la distribución de casos de COVID-19 en función del territorio, lo que relevó patrones no evidentes a través de análisis estadísticos convencionales (Thammaboribal et al., 2024).

Como ventaja inicial, el Índice de Moran proporciona una medida de la correlación entre los

valores de una variable en diferentes ubicaciones. Un valor positivo indica que los casos tienden a estar más agrupados de lo esperado, mientras que un valor negativo sugiere dispersión. Este análisis es esencial para identificar áreas que requieren atención prioritaria (Pranzo et al., 2023).

Los resultados obtenidos de los Índices de Morán revelan una autocorrelación positiva significativa en los cuatro meses de análisis, con valores que varían de 0,641 en mayo a 0,536 en agosto. Estos valores indican una autocorrelación moderada a fuerte, lo que implica que los casos activos por COVID-19 tienden a agruparse espacialmente, es decir, las áreas cercanas entre sí muestran una alta similitud en la cantidad de casos activos. Este patrón de distribución sugiere que la propagación del virus no ocurre de manera aleatoria, sino que está influenciada por factores espaciales, lo que resalta la importancia de abordar el fenómeno desde una perspectiva geoespacial.

En términos más específicos, los valores más altos de autocorrelación observados en los meses de mayo y junio podrían reflejar una propagación inicial más concentrada del virus en áreas específicas. A medida que avanzan los meses, la disminución progresiva de la autocorrelación en los cuadrantes estudiados, podría indicar que la propagación del COVID-19 se ha diversificado y dispersado más en el espacio, lo que podría ser el resultado de la implementación de políticas públicas, cambios en el comportamiento social o una mayor movilidad de las personas. Sin embargo, incluso en agosto, los valores de autocorrelación siguen siendo lo suficientemente altos como para sugerir que ciertos clústeres de casos siguen concentrados en áreas específicas, lo cual plantea un desafío para el control de la pandemia en esas regiones.

Como aporte al estudio de las distribuciones espaciales, el análisis de clústeres complementa el Índice de Moran al identificar grupos significativos de unidades espaciales. Este enfoque ayuda a visualizar cómo se agrupan los casos en el espacio y a comprender las razones subyacentes a estas concentraciones.

En particular, la variación observada en los grupos "Alto-Alto" y "Bajo-Bajo" sugiere que las dinámicas de transmisión del COVID-19 son complejas y probablemente están influidas por una combinación de factores espaciales, socioeconómicos y

demográficos. Las áreas de "Alto-Alto", que se caracterizan por una alta concentración de casos activos, podrían estar reflejando la presencia de vulnerabilidades sociales y estructurales, tales como alta densidad poblacional, menor acceso a servicios de salud, o mayores dificultades para cumplir con medidas de aislamiento o distanciamiento social. Estas zonas, generalmente ubicadas en el centro del Área Metropolitana de Santiago (AMS), pueden estar experimentando una transmisión más sostenida debido a una interacción continua entre estos factores.

Por otro lado, las áreas clasificadas en el grupo "Bajo-Bajo", que se encuentran principalmente en la periferia del AMS, muestran una menor proporción de cuadrantes con alta concentración de casos. Esto podría sugerir que las comunas periféricas, aunque menos densamente pobladas, han tenido una propagación más contenida, posiblemente debido a un menor contacto social, pero también puede reflejar factores de acceso limitado a servicios de salud y respuesta a la pandemia en estas áreas. En este sentido, el estudio de las características específicas de cada zona podría proporcionar una perspectiva útil para entender mejor la distribución de los casos en función de las características socioeconómicas y demográficas locales.

Tanto el Índice de Moran como el análisis de clústeres, son cruciales para el diseño de estrategias de intervención en salud pública, permitiendo una respuesta más dirigida a la propagación de los virus en una futura pandemia (Seamon et al., 2024).

Los hallazgos sobre la propagación del COVID-19 resaltan la importancia de considerar las dinámicas espaciales y los factores socioeconómicos en la planificación de salud pública. La autocorrelación espacial revela que las comunidades de bajo nivel socioeconómico no solo son más vulnerables a la infección, sino que también tienden a experimentar peores resultados de salud debido a su acceso limitado a recursos y servicios (Khedmati Morasae et al., 2024).

La pandemia ha puesto de relieve desigualdades existentes que podrían tener efectos a largo plazo en la salud de las comunidades vulnerables. Abordar estas desigualdades es esencial para la preparación ante futuras crisis sanitarias.

La evidencia obtenida sugiere que las respuestas a la pandemia deben ser adaptativas y sensibles a las realidades locales. El fortalecimiento de los sistemas de salud y el mantenimiento de la prestación de servicios esenciales durante la respuesta a emergencias sanitarias es fundamental para la detección y el diagnóstico tempranos, el tratamiento oportuno y el control eficaz de las pandemias (Lal et al., 2022).

A modo de conclusión, la pandemia de COVID-19 ha resaltado la necesidad de abordar la salud pública desde una perspectiva integral que considere las dinámicas espaciales y socioeconómicas. El análisis de autocorrelación espacial es una herramienta valiosa que puede informar políticas y prácticas en salud pública, permitiendo una respuesta más eficaz ante futuras pandemias. La identificación y atención de las desigualdades estructurales deben ser una prioridad en la planificación de salud pública para garantizar una respuesta equitativa y efectiva.

5. BIBLIOGRAFÍA

- Aranguiz, P. (2021). Análisis de la medición del empeoramiento de la calidad de aire en la Región Metropolitana y su posible relación con el aumento de casos de covid-19. *Revista Geográfica De Chile Terra Australis*, 57(1), 53–74. <https://doi.org/10.23854/07199562.2021571.Aranguiz53>
- Buzai, G. & Baxendale, C. (2006). *Análisis socioespacial con sistemas de información geográfica*. Buenos Aires, Argentina. Lugar editorial.
- Cárdenas, J., Gómez, J., Maturana, F. y Fuenzalida, M. (2023). "Distribución espacial de las hospitalizaciones por enfermedad isquémica del corazón en Chile 2002-2020". *Salud Pública de México*. <https://doi.org/10.21149/14575>.
- Cerón Vargas, J. A., Reyes Hernández, M. S., Muñoz Alonso, F., & Gutiérrez Pozos, J. A. (2022). Análisis espacial comparativo 2021-2022 de la pandemia por covid-19 y sus efectos en la pobreza en México. *Contaduría y administración*, 67(4), 279-302.
- Cordes, J., & Castro, M. C. (2020). Spatial analysis of COVID-19 clusters and contextual factors in New York City. *Spatial and spatio-temporal epidemiology*, 34, 100355.
- Cuartas, D. E., Arango-Londoño, D., Guzmán-Escarria, G., Muñoz, E., Caicedo, D., Ortega, D., ... & Méndez, F. (2023). Análisis espacio-temporal del SARS-coV-2 en Cali, Colombia. *Revista de Salud Pública*, 22, 138-143.
- Chamizo-García, H. A., Romero-Zúñiga, J. J., Ubieta, S. A., & Quirós-Arias, L. (2024). Patrones geoespaciales de la morbilidad por covid-19 en Costa Rica: marzo 2020 a mayo 2022. *Revista de Biología Tropical*, 72(1).
- Chomali, M., Guell, M., Hervé, B., Angulo, M., Huerta, C., Gutiérrez, C., & Blamey, R. (2021). Impacto de la primera ola pandémica de COVID-19 en el personal de salud en un hospital privado. *Revista Médica Clínica Las Condes*, 32(1), 90-104.
- Delgado Viñas, C. (2023). Los efectos de la pandemia COVID-19 en los espacios rurales: Cantabria (España) como estudio de caso. *Ería*, 43(2), 153–202. <https://doi.org/10.17811/er.43.2023.153-202>
- Escolano-Utrilla, S., & Salvador-Oliván, J. A. (2022). Regularidad global y variabilidad local de los patrones espacio temporales de la COVID 19 en Aragón (España). *Boletín de la Asociación de Geógrafos Españoles*, (93).
- Fuenzalida, M., & Trebilcock, M. (2021). COVID-19 y las desigualdades territoriales al interior de Áreas Metropolitanas de Valparaíso, Santiago y Concepción, Chile. Escenario 2021. *Persona Y Sociedad*, 35(1), 41,56. <https://doi.org/10.53689/pys.v35i1.336>
- Guan W., Liang W., Zhao Y., Liang H., Chen Z., Li Y. (2020). Comorbidity and its impact on 1590 patients with covid-19 in China: a nationwide analysis. *Eur Respir J.*, Mar 26;55(5).
- Gutiérrez-Hernández, O., & García, L.V. (2020). ¿Influyen tiempo y clima en la distribución del nuevo coronavirus (SARS CoV-2)? Una revisión desde una perspectiva biogeográfica. *Investigaciones Geográficas*, (73), 31-55. <https://doi.org/10.14198/INGEO2020.GHVG>

- Han, Y., Yang, L., Jia, K., Li, J., Feng, S., Chen, W., ... & Pereira, P. (2021). Spatial distribution characteristics of the COVID-19 pandemic in Beijing and its relationship with environmental factors. *Science of the Total Environment*, 761, 144257.
- Khedmati Morasae, E., Derbyshire, D. W., Amini, P., & Ebrahimi, T. (2024). Social determinants of spatial inequalities in COVID-19 outcomes across England: a multiscale geographically weighted regression analysis. *SSM-Population Health*, 25.
- Lal, A., Ashworth, H. C., Dada, S., Hoemeke, L., & Tambo, E. (2022). Optimizing pandemic preparedness and response through health information systems: lessons learned from Ebola to COVID-19. *Disaster medicine and public health preparedness*, 16(1), 333-340.
- Leveau, C. M., & Bastos, L. S. (2022). Desigualdades socioespaciales de la mortalidad por COVID-19 en tres olas de propagación: un análisis intraurbano en Argentina. *Cadernos de Saúde Pública*, 38, e00163921.
- Martellucci, C. A., Sah, R., Rabaan, A. A., Dhama, K., Casalone, C., Arteaga-Livias, K., ... & Rodriguez-Morales, A. J. (2020). Changes in the spatial distribution of COVID-19 incidence in Italy using GIS-based maps. *Annals of Clinical Microbiology and Antimicrobials*, 19, 1-4.
- Morales Peña, F., Mesina, I., & Peralta, C. (2024). Propuesta de rediseño de las ciudades post COVID 19 en el ámbito Laboral. *Revista Geográfica De Chile Terra Australis*, 60(1). <https://doi.org/10.23854/07199562.2024601.moral.es>
- Oppenheimer-Lewin, D., Ortega-Palavecinos, M., & Núñez-Cortés, R. (2022). Resiliencia en las personas mayores durante la primera ola pandémica de la COVID-19 en Chile: una perspectiva desde los determinantes sociales de la salud. *Revista Española de Geriátría y Gerontología*, 57(5), 264-268.
- Orellana, A., & Arenas, F. (2024). La expresión de la desigualdad a escala metropolitana: el caso del Área Metropolitana de Santiago de Chile. *Revista de Geografía Norte Grande*, 89:1-22.
- Patel, J.A., Nielsen, F. y Badiani, A. et al. (2020). Poverty, inequality and COVID-19: the forgotten vulnerable. *Public Health*, 183: 110-111.
- Pranzo, A. M. R., Dai Prà, E., & Besana, A. (2023). Epidemiological geography at work: An exploratory review about the overall findings of spatial analysis applied to the study of CoViD-19 propagation along the first pandemic year. *GeoJournal*, 88(1), 1103-1125.
- Sandar, E., Laohasiriwong, W., & Sornlorm, K. (2023). Spatial autocorrelation and heterogeneity of demographic and healthcare factors in the five waves of COVID-19 epidemic in Thailand. *Geospatial Health*, 18(1).
- Sánchez, A., Contreras, A., Corrales, J. C., & de la Fe, C. (2022). En el principio fue la zoonosis: One Health para combatir esta y futuras pandemias. Informe SESPAS 2022. *Gaceta Sanitaria*, 36, S61-S67.
- Santana, M. V., Santa Castañeda, G., Carillo, C. S., Carrillo, R. S., & Alcántara, R. O. (2020). COVID-19 en México: Asociación espacial de cara a la fase tres. *Hygeia: Revista Brasileira de Geografia Médica e da Saúde*, (Especial), 36.
- Seamon, E., Ridenhour, B. J., Miller, C. R., & Johnson-Leung, J. (2024). Spatial Modeling of Sociodemographic Risk for COVID-19 Mortality. *medRxiv*, 2023-07.
- Siabato, W., & Guzmán-Manrique, J. (2019). La autocorrelación espacial y el desarrollo de la geografía cuantitativa. *Cuadernos de Geografía: Revista Colombiana de Geografía*, 28(1), 1-22.
- Suárez Lastra, M., Valdés González, C. M., Galindo Pérez, M. C., Salvador Guzmán, L. E., Ruiz-Rivera, N., Alcántara-Ayala, I., ... & Garnica-Peña, R. (2021). Índice de vulnerabilidad ante el COVID-19 en México. *Investigaciones geográficas*, (104).
- Thammaboribal, P., Tripathi, N. K., Junpha, J., Lipilert, S., & Wongpituk, K. (2024). Examining the Correlation between COVID-19 Prevalence and Patient Behaviors, Healthcare, and Socioeconomic Determinants: A Geospatial Analysis of ASEAN Countries. *International Journal of Geoinformatics*, 20(3), 95-112.