



Autocorrelación geoespacial departamental del COVID-19 asociado con enfermedades de comorbilidad: Perú 2020-2021

Departmental geospatial autocorrelation of COVID-19 associated with comorbid diseases:
Peru 2020-2021

Luis A. Rubio Jácobo^{1*}, Enrique Ipanaqué Centeno¹, María T. Rojas García¹,

^a Departamento Académico de Estadística, Universidad Nacional de Trujillo, Av. Juan Pablo II s/n, Ciudad Universitaria, Trujillo, Perú

Resumen

El objetivo de investigación fue analizar la autocorrelación geoespacial departamental del COVID-19 asociado a comorbilidades como diabetes, hipertensión y neumonía en el Perú durante el periodo 2020-2021. La población estuvo constituida por los departamentos del Perú. El estudio es de tipo cuantitativo, descriptivo y de corte transversal. Se aplicó el Índice de Moran Local Bidimensional para identificar patrones espaciales en la distribución de los casos, teniendo en cuenta la matriz de continuidad Reyna de orden 1. Los resultados mostraron que no existió una autocorrelación geoespacial significativa entre los casos de COVID-19 y las comorbilidades, lo que indica una distribución aleatoria. Sin embargo, mediante el Índice de Moran bivalente, se identificaron clústeres espaciales de enfermedades asociadas al COVID-19 en varias regiones; en 2020, se halló un clúster significativo en los departamentos de Loreto, Pucallpa, Madre de Dios y Ayacucho, relacionado con los casos de COVID-19 e hipertensión, y otro en Ancash y Tumbes para COVID-19 y neumonía. En 2021, se formaron tres clústeres vinculados con la relación entre COVID-19 e hipertensión, en Loreto, Pucallpa y Madre de Dios; Ayacucho y Callao; e Ica. Asimismo, en los departamentos de Ica, Apurímac y Tumbes se identificó un clúster relacionado con COVID-19 y neumonía.

Palabras claves: Autocorrelación espacial, casos positivos de COVID-19, enfermedades asociadas, Índice de Moran, clústeres geoespaciales

Abstract

The research objective was to analyze the departmental geospatial autocorrelation of COVID-19 associated with comorbidities such as diabetes, hypertension, and pneumonia in Peru during the period 2020-2021. The population consisted of the departments of Peru. The study is quantitative, descriptive, and cross-sectional. The Two-Dimensional Local Moran Index was applied to identify spatial patterns in the distribution of cases, taking into account the Reyna continuity matrix of order 1. The results showed that there was no significant geospatial autocorrelation between COVID-19 cases and comorbidities, indicating a random distribution. However, using the bivariate Moran Index, spatial clusters of diseases associated with COVID-19 were identified in several regions; In 2020, a significant cluster was found in the departments of Loreto, Pucallpa, Madre de Dios and Ayacucho, related to cases of COVID-19 and hypertension, and another in Ancash and Tumbes for COVID-19 and pneumonia. In 2021, three clusters linked to the relationship between COVID-19 and hypertension were formed, in Loreto, Pucallpa and Madre de Dios; Ayacucho and Callao; and Ica. Likewise, in the departments of Ica, Apurímac and Tumbes, a cluster related to COVID-19 and pneumonia was identified.

Keywords: Spatial autocorrelation, positive cases of COVID-19, associated diseases, Moran Index, geospatial clusters

1. Introducción

Los primeros casos de COVID-19 (del inglés, Coronavirus Disease-2019) se confirmaron en diciembre de 2019 en la ciudad de Wuhan, provincia de Hubei de China, como un brote de neumonía de causa desconocida. El virus SARS-CoV-2, que fue identificado oficialmente el 7 de enero del 2020 por autoridades sanitarias en la provincia sur-central china de Hubei, y declarado como causante de una irrupción de casos de neumonía que se habían detectado en la región desde el mes anterior, principalmente en la ciudad de Wuhan, provocó a nivel mundial una enorme crisis global sin precedentes. En septiembre de 2020, 186 de los 193 Estados miembros de la ONU han confirmado casos de esta infección, y 177 de ellos han registrado muertes directamente relacionadas con este nuevo coronavirus, llamado después COVID-19 (Gutiérrez et al., 2021).

El virus se propagó rápidamente hacia otros países del mundo, donde a mediados de enero del 2020 se identificaron pacientes en otros países de Asia (Indonesia, Japón Tailandia y Corea del Sur) y desde la última semana de enero en varios de Europa (Francia, Alemania, España, Reino Unido e Italia). Al igual que en los casos anteriores, el virus llegó a América con viajeros internacionales, al parecer, el primer caso se confirmó en Estados Unidos (EEUU) el 19 de enero de 2020 en el estado de Washington (Holshue et al., 2020). Ante la acelerada dispersión del virus en varios países de prácticamente todos los continentes del mundo, la Organización Mundial de la Salud [OMS] declaró el 30 de enero al brote de SARS-CoV-2 como una emergencia de salud de importancia mundial (OMS, 2020a; European Centre for Disease Prevention and Control [ECDC], 2020). A su vez, el nuevo coronavirus apareció en América Latina casi un mes después, el 26 de febrero se confirmó el primer caso en Sao Paulo, Brasil, mientras que en México apareció el 28 de febrero en la Ciudad de México. En ambos casos se trató de personas que habían estado recientemente en Italia. Ante este panorama, la OMS declaró oficialmente la existencia de una pandemia de COVID-19, el 11 de marzo de 2020 (OMS, 2020a).

El impacto que ha tenido el COVID-19 sigue siendo preocupante, ya que sus consecuencias son verdaderamente globales y multifacéticas, al menos desde que quedó claro que, a diferencia de lo que ocurrió en anteriores eventos pandémicos, como el caso del brote del SARS-CoV entre 2002-2004, esta vez no se puede detener la propagación del virus, debido a la rápida expansión en los países vecinos y, desde finales de enero de 2020, también a Europa y los Estados Unidos. La Organización Mundial de la Salud (OMS) declaró el día 30 de enero una “emergencia de salud pública de interés internacional”, y el 11 de marzo de 2020 elevó el COVID-19 a rango de pandemia (Gutiérrez et al., 2021; Mejía, et al (2022).

Desde diciembre de 2019, la enfermedad por coronavirus 2019, ha representado un desafío para los gobiernos del mundo una vez que exigía un balance entre estrategias e infraestructuras de control epidemiológico, garantía de bienestar económico, así como para la administración de servicios de salud rutinarios (Prinja & Pandav 2020). Para detener los contagios, los gobiernos del mundo adoptaron una amplia gama de medidas, así como, ante la ausencia de procedimientos médicos probados de una vacuna para eliminar el virus, se optó por imponer restricciones a la movilidad de las personas, tanto en su entorno inmediato (confinamiento domiciliario) como en su desplazamiento geográfico (viajes nacionales e internacionales). Así, el 22 de enero Corea del Sur anunció la suspensión temporal de la entrada de turistas en todo su territorio; el gobierno italiano, por su parte, determinó el aislamiento total del país, además de imponer medidas más estrictas, como la prohibición de viajes. España decretó el Estado de Alarma, por lo que se confinó a la población, en tanto que los trabajadores no imprescindibles dejaron de laborar o lo hicieron desde sus hogares, además de que los colegios, institutos y universidades cerraron (Carrión et al., 2020). En América, Perú y Chile pasan a estado de emergencia y cierran sus fronteras el 15 de marzo (OMS, 2020a).

A pesar de estas medidas, y otras que se tomaron en los diferentes países, el número de contagios aumentó en todo el mundo, aunque a diferentes ritmos, lo que llevó a la OMS a declarar el COVID-19

como pandemia global el 11 de marzo (OMS, 2020a). El rápido crecimiento de los contagios ha llevado a un elevado número de casos acumulados en varios países. Por ejemplo, hasta el 31 de julio, se ha tenido un total de 4'495,014 en EE. UU; 288,522 en España; 186,573 en Francia; 247,158 en Italia; 2'610,102 en Brasil; 407,492 en Perú; 353,536 en Chile y 454,322 en México. Al parecer, los países donde hubo un menor número, fue donde se adoptaron medidas de control rápidas y estrictas, como China y Corea del Sur, donde se tuvieron hasta la misma fecha un total de 87,489 y 14,305 personas afectadas, respectivamente (ECDC, 2020).

En el Perú el paciente cero o primer caso con COVID-19 fue detectado el 6 de marzo de 2020 y desde entonces el virus continuó su propagación y ante el inminente contagio de la población, el gobierno instauró políticas sanitarias similares a las tomadas por el gobierno chino. Así, se establecieron medidas de cuarentena y distanciamiento social, la adquisición de nuevas camas y equipos de cuidados intensivos, así como, la contratación y la redistribución de los profesionales capacitados en medicina intensiva. Sin embargo, cualquier estrategia aplicada en otro país para contrarrestar la pandemia debe adecuarse a nuestra realidad, pues pareciera que la cuarentena por sí sola no fue suficiente para prevenir la propagación y el impacto socioeconómico de la enfermedad fue preocupante, dado que nuestra situación sanitaria difiere mucho con la de países desarrollados (Córdoba & Rossani, 2020)

La COVID-19 se transmite por contacto directo e indirecto (fómites) con gotas contaminadas o por aerosoles, siendo esta última vía la principal y más difícil de contener; por otro lado, los factores ambientales como el material particulado (PM), con efectos adversos para la salud humana, favorecen el contagio por aerosoles y el aumento de mortalidad por COVID-19. El material particulado, clasificado en PM10 y PM2.5 de acuerdo con su diámetro aerodinámico, sirve de protector y transporte; el que induce daños en los neumocitos y sobreexpresión de la enzima convertidora de angiotensina la cual facilita el ingreso del coronavirus. Factores sociodemográficos como la densidad poblacional, el número de centros de salud, la edad, la preexistencia de comorbilidades, entre otros, también inciden en la morbimortalidad por COVID-19 (Chaudhry et al., 2020).

La autocorrelación espacial es un procedimiento intrínsecamente geográfico que nos puede decir mucho acerca del comportamiento de la información georreferenciada a diferentes escalas, en particular el tipo de asociación existente entre unidades espaciales vecinas. No obstante, a pesar de su creciente importancia en el marco del análisis exploratorio de datos espaciales, su utilización es reducida en trabajos geográficos que continúan recurriendo a los coeficientes tradicionales de correlación y a la estadística descriptiva. La relevancia de la autocorrelación espacial en el estudio geográfico y las características socioeconómicas y ambientales propias de la Geografía tienden a mostrar cierto grado de similitud, ya que a menos que existan factores de ruptura o de discontinuidad muy marcados, la situación normalmente esperable sería la de cierta homogeneidad espacial. En general se acepta que existe autocorrelación espacial (AE) siempre que haya una variación espacial sistemática en los valores de una variable a través de un mapa, es decir un patrón en el comportamiento de la variable según la ubicación geográfica del dato. Si los valores altos de una localización están asociados con valores altos en los vecinos, la autocorrelación espacial es positiva siendo la situación opuesta la de autocorrelación espacial negativa (Cepeda & Velázquez, 2005; Celemin, 2009)

Los sistemas de información geográfica, junto con métodos de estadística espacio-temporal, son herramientas efectivas para el análisis de variables espaciales, especialmente aquellas que afectan a áreas cercanas. Utilizando el método de autocorrelación espacial de Moran y tecnologías de dispositivos móviles, se analizan fenómenos de expansión y concentración en tiempo real, siguiendo un modelo estadístico-matemático que simula la movilidad de variables en diferentes zonas. Este enfoque permite identificar patrones espaciales en tiempo real (Rivera, 2014).

Modelos epidemiológicos de autocorrelación espacial han sido utilizados para comprender las rutas de propagación de enfermedades, buscando aglomerados entre factores ambientales y sociodemográficos, para implementar medidas de mitigación del riesgo de contagio, especialmente en

las zonas más comprometidas. Esta investigación estableció la existencia de autocorrelación espacial entre los casos de COVID-19 y la concentración de PM10 y PM2.5, y determinó el mejor modelo predictivo de ML en Bogotá (Colombia). Se concluyó que, mediante técnicas de autocorrelación espacial, se verificó la asociación positiva entre los casos de COVID-19 y la concentración de PM10 en el suroccidente de Bogotá (Vílchez & Díaz, 2021).

Murillo et al. (2020) analizaron los cambios en la Densidad de Recursos Humanos en Salud (DRHS) a nivel regional y provincial en el Perú, utilizando la base de datos INFORHUS del Ministerio de Salud. Para calcular la DRHS, se consideró el personal de salud registrado en INFORHUS y la población afiliada al Seguro Integral de Salud (SIS), excluyendo a los fallecidos o diagnosticados con COVID-19 durante el periodo de estudio (abril a agosto de 2020). Los resultados mostraron un incremento de la DRHS a nivel nacional del 5.1%, con 15 de las 25 regiones experimentando aumentos que variaron entre 0.2% y 12.3%. Sin embargo, se observó una disminución del personal fijo y un aumento del personal temporal. En el resto de las regiones, la DRHS disminuyó entre -0.7% y -7.7%. Se concluyó que, aunque hubo un aumento a nivel nacional, este no fue equitativo entre regiones, lo que indica la necesidad de fortalecer la distribución de recursos humanos en salud, especialmente en áreas más desfavorecidas.

Como se evidencia en los antecedentes presentados, es muy importante evaluar la distribución espacial de los casos positivos de COVID-19 asociados a las enfermedades de comorbilidad como son la diabetes, hipertensión y neumonía, a escala nacional y regional, porque permitirá la toma de decisiones gubernamentales de manera correcta. En el Perú son escasos los estudios acerca de la autocorrelación geoespacial de los casos de COVID-19 asociados a las enfermedades de comorbilidad, ya que es una realidad latente y que necesitan ser estudiados a profundidad. Como docentes e investigadores de la Universidad Nacional de Trujillo, estamos siempre a la vanguardia de esta problemática de salud y dar algunos aportes para la implementación de políticas relacionados con los casos positivos de COVID-19.

Esta investigación se justifica por la necesidad de comprender la distribución geoespacial del COVID-19 en relación con enfermedades de comorbilidad, como diabetes, hipertensión y neumonía, en los departamentos del Perú durante el periodo 2020-2021. Utilizando la técnica de autocorrelación espacial con software libre, se buscó identificar patrones geoespaciales que revelaran asociaciones importantes. El objetivo fue analizar la autocorrelación geoespacial departamental del COVID-19 asociado con diabetes, hipertensión y neumonía, e identificar los clústeres espaciales correspondientes en el Perú durante el periodo 2020-2021.

2. Metodología

Objeto de estudio y diseño de investigación

La investigación tuvo como objeto de estudio la autocorrelación espacial departamental de los casos positivos de COVID-19 asociados a casos de diabetes, hipertensión y neumonía en el Perú.

Diseño de investigación

El diseño de esta investigación es descriptivo correlacional y de corte transversal, con un enfoque cuantitativo. El propósito principal es identificar y analizar la relación geoespacial entre los casos positivos de COVID-19 y las comorbilidades de diabetes, hipertensión y neumonía en los departamentos del Perú durante el periodo 2020-2021.

Población

La población estuvo constituida por los 24 departamentos del Perú y la Provincia Constitucional del Callao cuya información fue obtenida en los boletines informativos de bienestar del Ministerio de salud reportados en su sala situacional.

Análisis de datos

Para el análisis estadístico se utilizó el Índice de Moran bidimensional con enfoque global y local que determinó la presencia de autocorrelación espacial positiva o negativa, así como la detección de patrones espaciales de los departamentos del Perú, en función al número de casos confirmados positivos de COVID-19, y los casos de diabetes, hipertensión y neumonía. Para realizar el análisis espacial se utilizaron los softwares libres GeoDa 1.7 y QGIS versión 3.24, junto con los respectivos archivos cartográficos en formato “shapefile” a escala departamental para los límites del Perú. Se empleó el criterio Reyna, con enlace de vecindad contigua de orden 1 según el método de Reyna. El mapa cartográfico del Perú por departamentos y su enlace de vecindad contigua de orden 1 según el criterio Reyna, se presenta en la figura 1.

Variables en estudio

La variable principal del estudio fue el número de casos positivos de COVID-19 totalizados por departamento, considerando también las variables de comorbilidad como son el número de casos de diabetes, hipertensión y neumonía.

Consideraciones éticas

La investigación se realizó en base a datos públicos proporcionados por el Ministerio de Salud del Perú. Estos datos fueron utilizados de manera responsable, respetando la privacidad de los individuos y sin incluir información personal que permita la identificación de los pacientes. El manejo de los datos se realizó de acuerdo con principios éticos, asegurando transparencia y el uso adecuado de la información durante todo el estudio.

3. Resultados

Figura 1

El mapa cartográfico de la Región del Perú por departamentos y su enlace de vecindad contigua de orden 1, según el criterio Reyna.

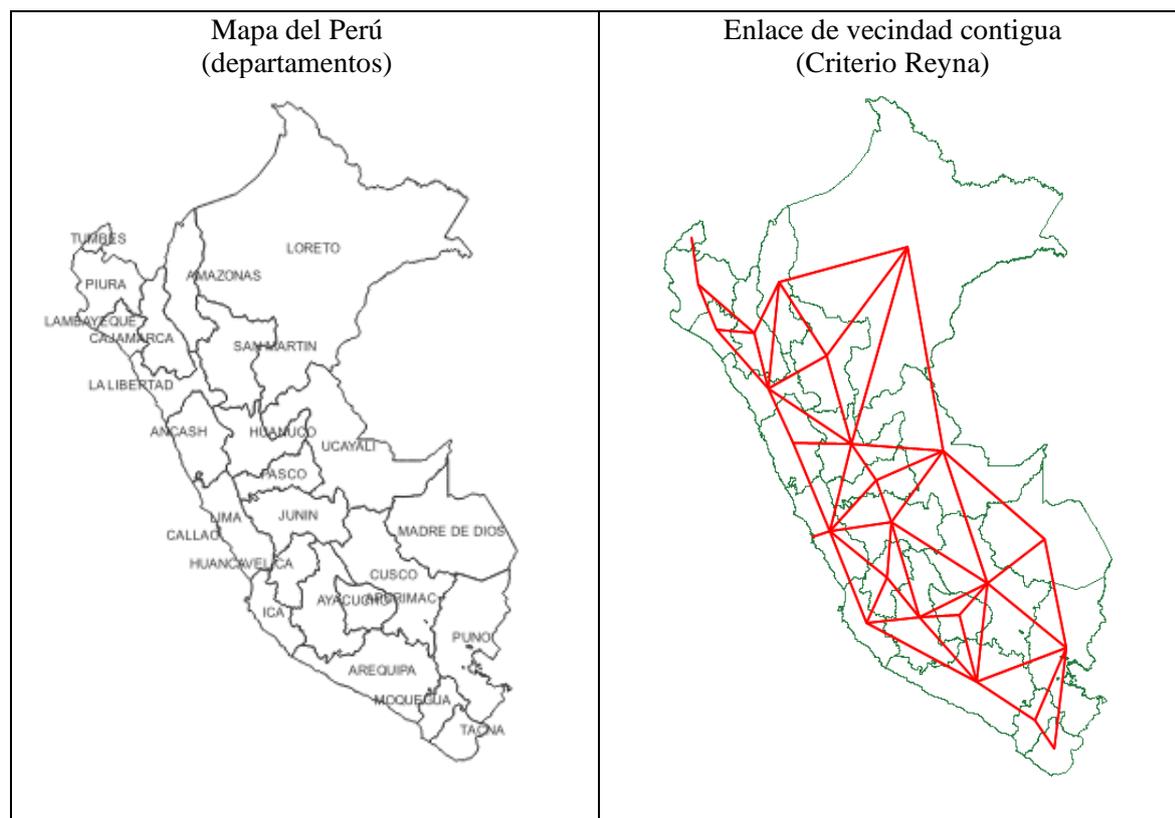


Figura 2

Índice I de Moran bidimensional y mapa de clústeres (LISA) para casos positivos de COVID-19 por departamentos del Perú, periodo 2020-2021

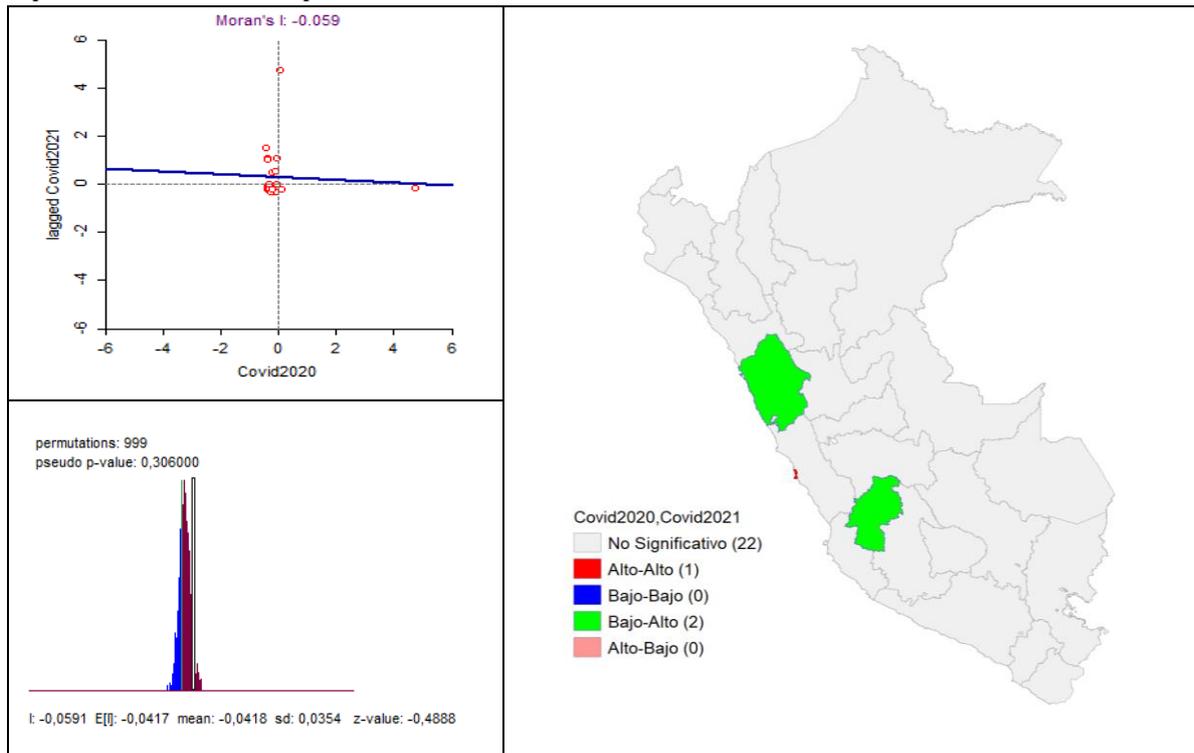


Figura 3

Índice I de Moran bidimensional y mapa de clústeres (LISA) para casos de DIABETES por departamentos del Perú, periodo 2020-2021

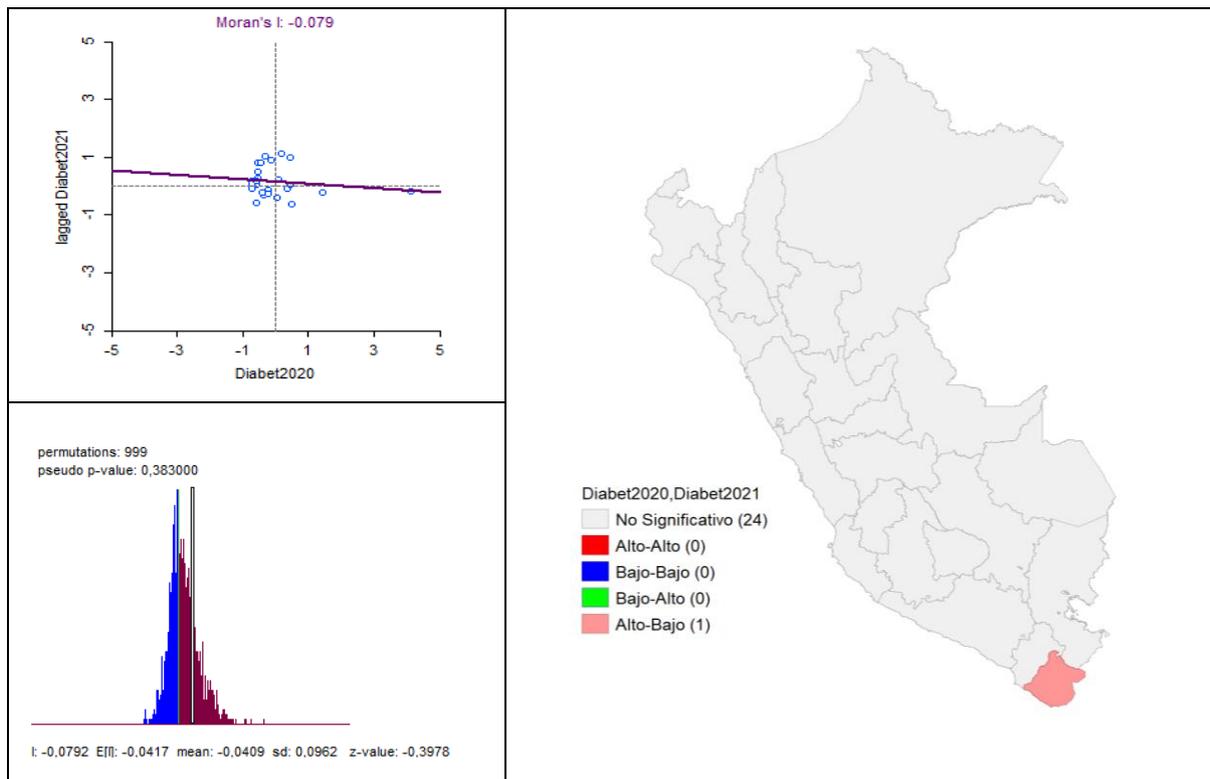


Figura 4

Índice I de Moran bidimensional y mapa de clústeres (LISA) para casos de HIPERTENSIÓN por departamentos del Perú, periodo 2020-2021

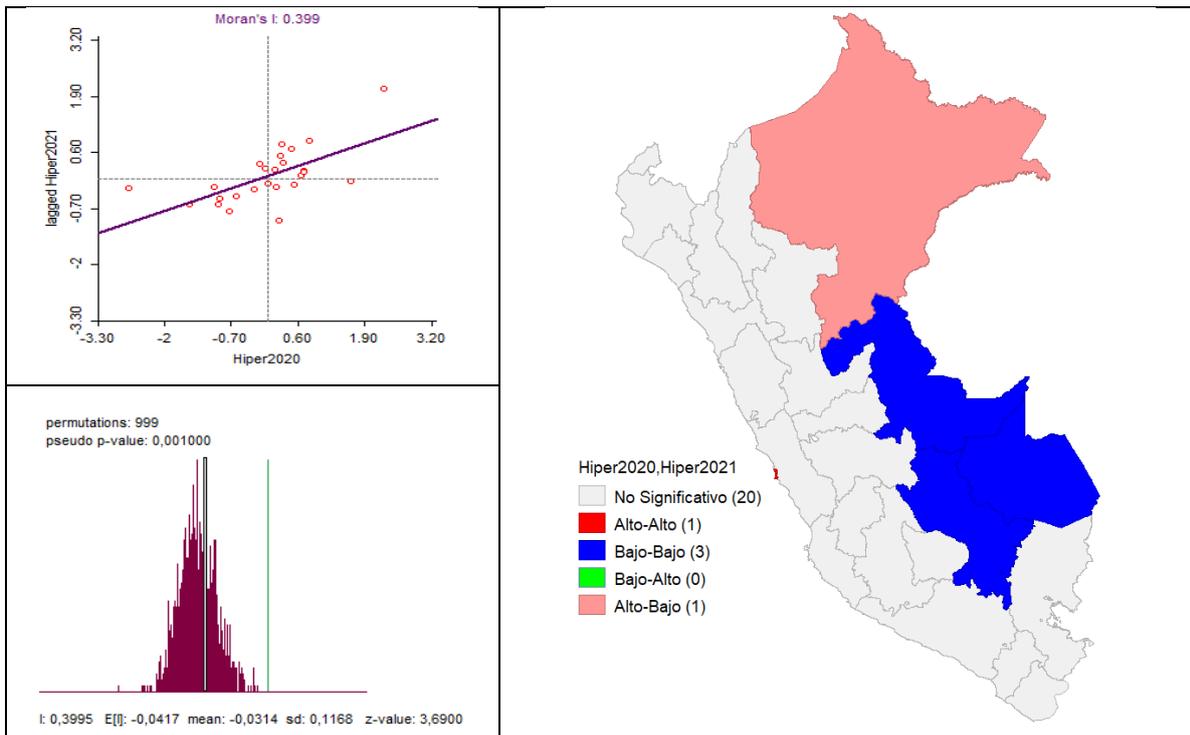
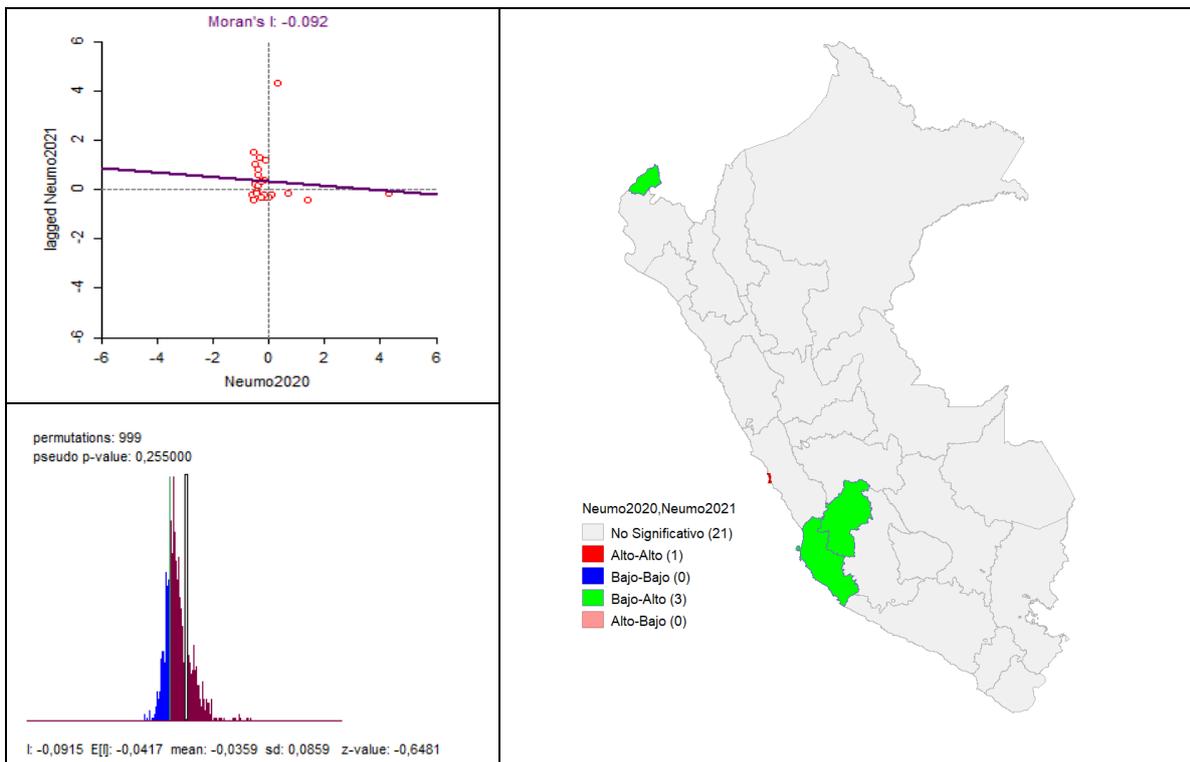


Figura 5

Índice I de Moran bidimensional y mapa de clústeres (LISA) para casos de NEUMONÍA por departamentos del Perú, periodo 2020-2021



En la figura 2, 3, 4 y 5 se presenta el gráfico de dispersión espacial bidimensional de Moran, así como su respectivo índice (Índice de Moran Bidimensional) que nos permite evaluar el tipo de autocorrelación espacial que existe en los casos positivos de COVID-19, casos de diabetes, casos de hipertensos y casos de neumonía, comparados en los años 2020 y 2021. Asimismo, nos presenta la prueba Z la cual a través del pseudo p-valor, concluiremos acerca de la existencia de un patrón de los casos a nivel departamental. En estas figuras se muestra el mapa de clústeres (LISA) la que nos permite identificar algún patrón de comportamiento por parte de los casos estudiados.

La figura 2 presenta este análisis de correlación espacial comparativo bidimensional para la variable número de casos positivos de COVID-19 para los años 2020 y 2021. La figura 3, lo hace para la variable número de casos de diabetes también para los años 2020 y 2021; la figura 4 presenta el análisis para la variable número de casos de hipertensión y en la figura 5, se analiza la variable número de casos de neumonía para este mismo periodo de tiempo.

La figura 6, se presenta el índice de Moran Bidimensional de los casos positivos de COVID-19 en relación a los casos de diabetes, hipertensión y neumonía para los años 2020 y 2021. En la figura 7, se muestra los clústeres espaciales (LISA) de los casos positivos de COVID-19 correlacionado con las comorbilidades por departamentos del Perú, constituidos a través de la evaluación del Índice de Moran Local Bidimensional.

Figura 6

Índice de Moran bidimensional de los casos positivos de COVID-19 en relación a casos de diabetes, hipertensión y neumonía. Año 2021 y 2022

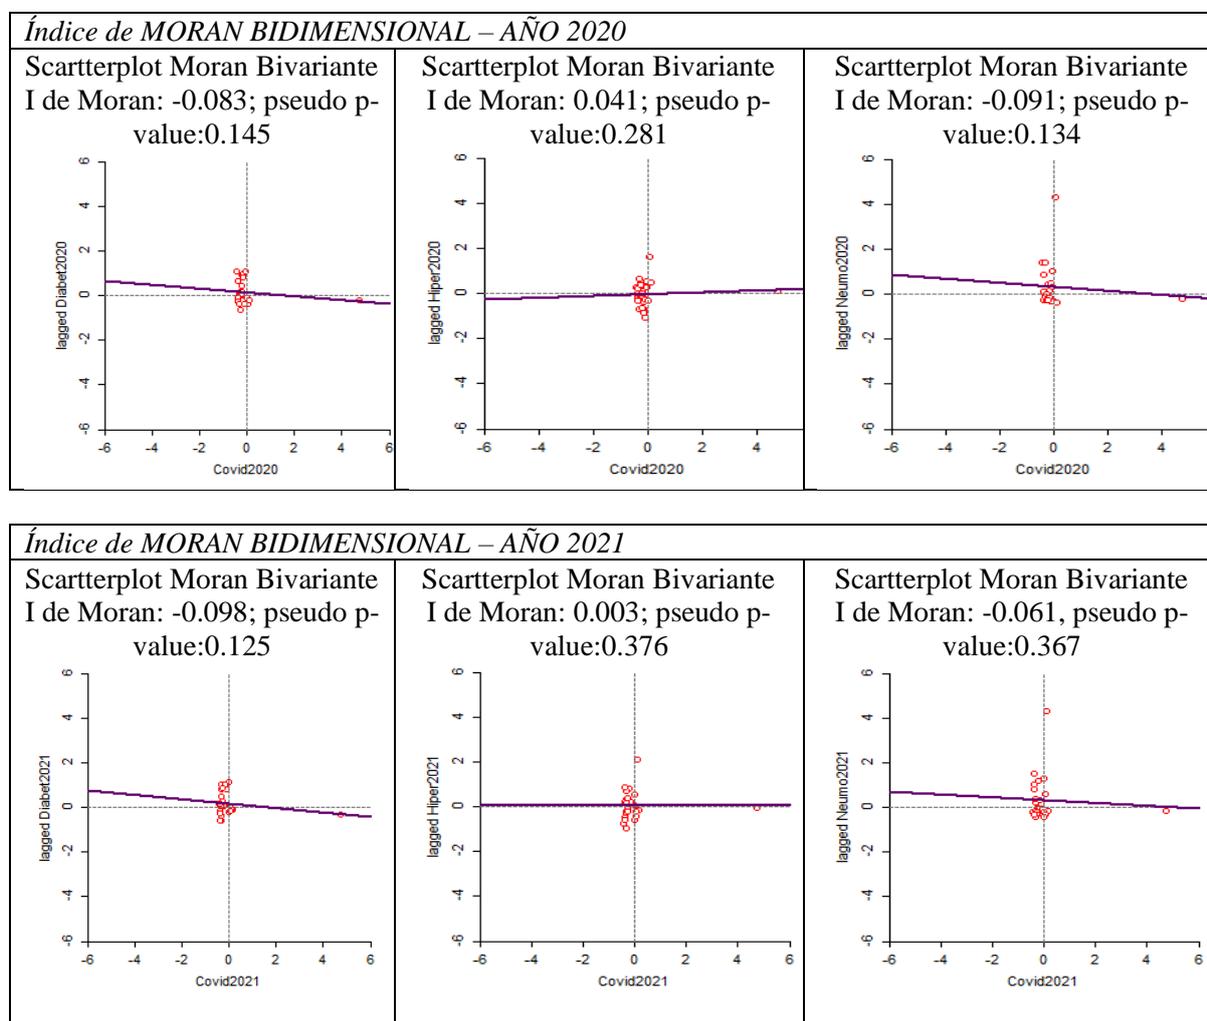
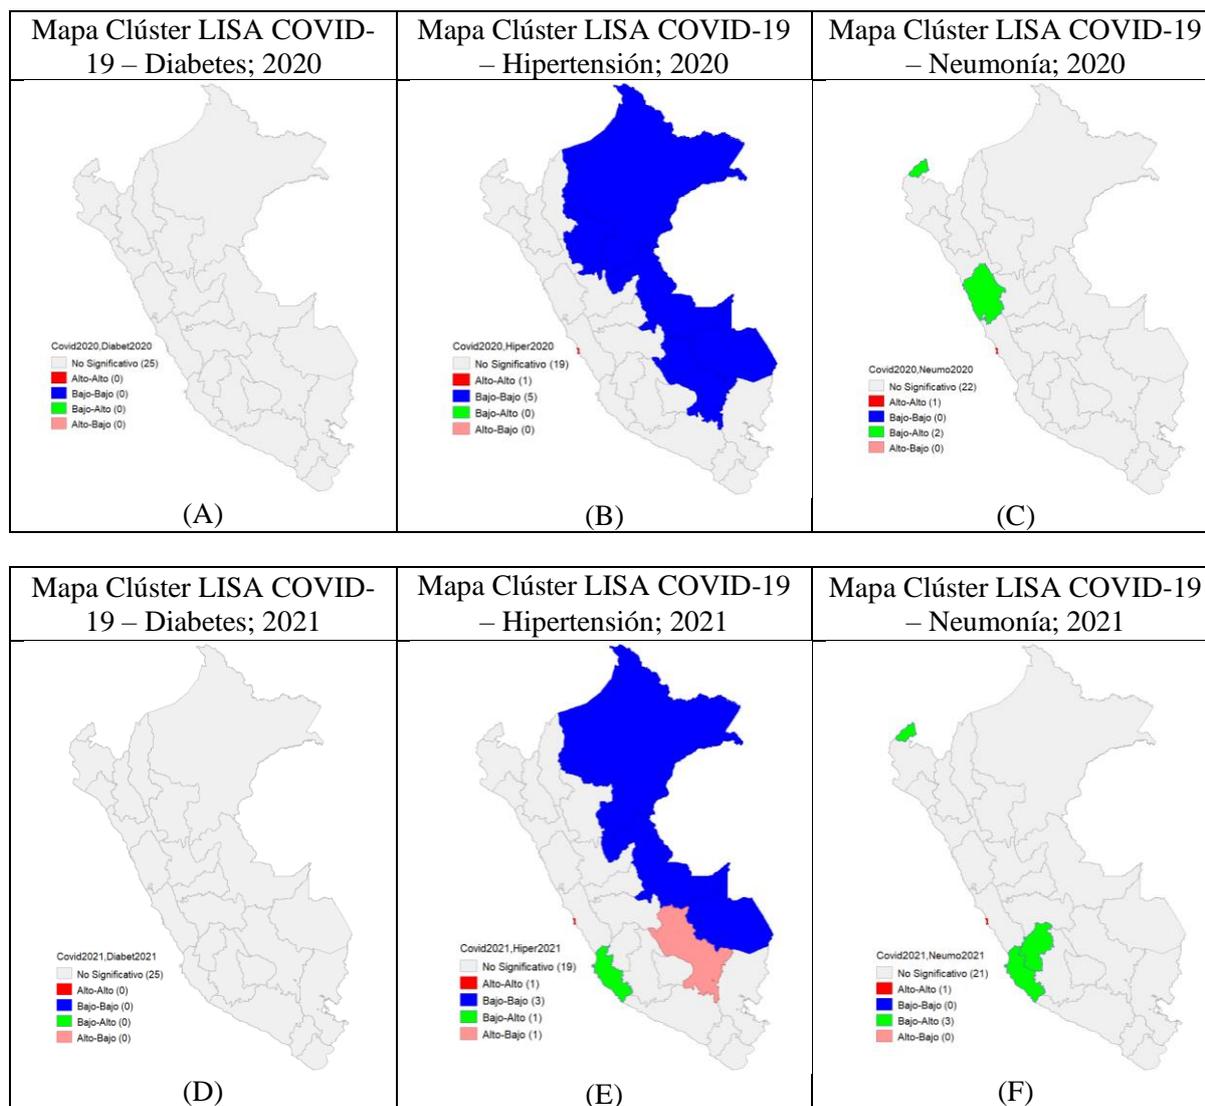


Figura 7

Mapa de clúster (LISA) de los casos positivos de COVID 19 en relación a casos de diabetes, hipertensión y neumonía. Año 2021 y 2022

**4. Discusión**

El objetivo general de nuestra investigación fue analizar el tipo de autocorrelación geoespacial de los casos positivos de COVID-19 asociados a los casos de diabetes, hipertensión y neumonía en el Perú. Es un estudio de tipo exploratorio, descriptivo y de corte transversal, donde la variable fundamental del estudio son los casos positivos de COVID-19 totalizados por departamento. Debemos mencionar que la información fue recolectada de fuentes secundarias como son los Boletines Epidemiológicos del Minsa, luego fueron procesadas en los softwares libres GeoDa 1.20 y QGIS Ver 3.14, para la obtención de los diagramas espaciales y los valores del Índice de Moran Local Bidimensional.

Evaluando los resultados de la figura 2, los casos positivos de COVID-19 del año 2020 y los casos positivos del año 2021 por departamentos, presentan una autocorrelación espacial negativa muy débil (IM: -0.059) mediante el índice de Moran Local Bidimensional, considerando una matriz de continuidad tipo Reyna de orden 1. En este caso como el índice de Moran Local está cercano a cero,

por lo que podemos concluir que no hay una autocorrelación espacial de los casos positivos de COVID-19 en los dos años de estudio por departamento, es decir, presentan un patrón espacial disperso; es decir, que los casos positivos de COVID-19 se distribuyen en forma aleatoria en los departamentos, cuyo resultado es validado con la prueba Z en la cual se obtuvo un pseudo valor- $p=0.306$. Así mismo, hay 22 departamentos que presentan correlación espacial no significativa, dos departamentos se correlacionan espacialmente con un bajo número de casos de COVID-19 en el año 2020 con un alto número alto de casos de COVID-19 en el año 2021. Solamente la provincia Constitucional del Callao se correlaciona espacialmente los casos de COVID-19 del año 2020 y 2021

Respecto a la evaluación de los casos de diabetes en los años 2020 y 2021, no presentan una correlación espacial positiva cuyo valor resultó ser $IM = -0.079$, el cual también se corrobora con la prueba Z que resultó ser no significativa (Aceptar H_0 que los casos de diabetes se distribuyen en los departamentos del Perú, de manera aleatoria). Esto también se corrobora con el mapa de clúster (LISA), donde 24 de ellos presentan una correlación no significativa.

Al evaluar los resultados de la figura 4, el índice de Moran $IM=0.399$ obtenido respecto a la evaluación de los casos de hipertensión de los años 2020 y 2021 si presentan correlación espacial, cuyo resultado se valida con la prueba Z donde el valor del pseudo valor- $p=0.001$, lo cual significa que estos casos de hipertensión si presentan un patrón espacial. Su mapa de clúster (LISA) también así lo demuestra, donde, el número de casos de hipertensión alto en el departamento de Loreto en el año 2020 se correlaciona con los ocurridos en el año 2021. Lo mismo ocurre con los departamentos de Pucallpa, Madre de Dios y Ayacucho, que presentan cantidades bajas de casos de hipertensión, tanto en los años 2020 y 2021.

Con respecto a la evaluación de los casos de neumonía en los departamentos del Perú en los años 2020 y 2021 no presentan autocorrelación espacial ya que el índice de Moran tuvo como valor $IM=-0.092$, validándose con el pseudo valor- $p=0.255$ de la prueba Z. Al describir la distribución espacial de los casos de neumonía en los años 2020 y 2021, 21 departamentos presentan autocorrelación espacial no significativa y los departamentos Ica y Huancavelica tienen un patrón de comportamiento constituyendo un clúster. Así mismo, Tumbes es otro departamento que presenta este tipo de patrón, es decir, casos bajos de neumonía en el 2020 y casos altos de neumonía en el 2021.

Otro aspecto importante en esta investigación es conocer la distribución espacio-temporal de los casos positivos de COVID-19 con las comorbilidades, para ello consideramos la evaluación de la autocorrelación espacial bidimensional con los casos de diabetes, hipertensión y neumonía. El Índice de Moran bidimensional, considerando la matriz de contigüidad tipo Reyna de orden 1, para el año 2020 considerando el número de casos positivos de COVID-19 y el número de casos de diabetes se obtuvo un Índice de Moran bidimensional de $IM=-0.089$, con el número de casos de hipertensión un Índice de Moran de $IM=0.041$ y con el número de casos de neumonía un Índice de Moran $IM=-0.091$, que fueron verificados con la Prueba Z resultando no significativa la autocorrelación espacial con valores pseudo valores- $p=(0.145, 0.281, 0.134)$, concluyéndose que presentan un comportamiento aleatorio.

Considerando los casos positivos de COVID-19 con los casos de diabetes, casos de hipertensión y casos de neumonía, en el año 2021, se obtuvo un Índice de Moran ($IM=-0.098, 0.003, -0.061$), que se salieron no significativos mediante la prueba Z con valores pseudo valor- p (0.125, 0.376, 0.367) mayores a 0.05, concluyéndose que no existe autocorrelación espacial, concluyéndose que presentan un patrón aleatorio.

Al desarrollar el objetivo 4, en la identificación de clústeres espaciales de COVID-19 asociados a diabetes, hipertensión y neumonía por departamentos en el Perú, periodo 2020-2021, se utilizó el Índice de Moran Local obteniéndose los mapas clúster LISA que se encuentran en la figura 7 para cada año en estudio. Observamos en la figura 7-A, no hay un clúster significativo, se puede observar en la figura 7-B un clúster significativo formado por los departamentos Loreto, Pucallpa, Madre de Dios y Ayacucho con respecto a las variables casos COVID-19 e hipertensión para el año 2020, ubicándose en

el cuadrante III de la asociación espacial (Bajo-Bajo) de Moran. También se observa otro clúster en la figura 7-C, formado por los departamentos Ancash y Tumbes con respecto a las variables casos positivos de COVID-19 y casos de Neumonía para el año 2020, ubicándose en el cuadrante II de la asociación espacial (Bajo-Alto) de Moran.

Co respecto al año 2021 en la figura 7-D no observamos ningún patrón significativo, en la figura 7-C si observamos 03 clúster, el primero constituido por los departamentos Loreto, Pucallpa y Madre de Dios; el otro clúster constituido por Ayacucho y la Provincia Constitucional del Callao, y el tercer clúster por el departamento de Ica. El primer clúster se ubica en el cuadrante III, el segundo clúster en el cuadrante IV y el tercer clúster en el cuadrante II. Estos clústeres se constituyeron teniendo en cuenta las variables casos positivos de COVID-19 y casos de Hipertensión. Finalmente, en la figura 7-E, se aprecia un solo clúster constituido por los departamentos Ica, Apurímac y Tumbes con respecto a las variables casos de COVID-19 y casos de Neumonía, ubicándose en el cuadrante II (Bajo-Alto) en el diagrama espacial de Moran.

5. Conclusiones

En la presente investigación para evaluar la autocorrelación geoespacial departamental se ha obtenido el Índice de Moran Local Bidimensional, teniendo en cuenta la matriz de continuidad tipo Reyna de orden 1, y en base a esto indicadores se concluye que no hay autocorrelación geoespacial departamental de los casos de COVID-19, de los casos de Hipertensión y casos de Neumonía en el año 2021 respecto al año 2020, indicando que los patrones de estos casos son aleatorios a nivel geoespacial. Así mismo, al aplicar el Índice de Moran Bivariante entre los casos positivos de COVID-19 y cada comorbilidad (diabetes, hipertensión y neumonía), tampoco se encontró autocorrelación geoespacial significativa.

En la identificación de clústeres espaciales de COVID-19 asociados a diabetes, hipertensión y neumonía por departamentos en el Perú, se utilizó el Índice de Moran Local obteniéndose los mapas clúster LISA. En el año 2020, se identificó un clúster significativo formado por los departamentos Loreto, Pucallpa, Madre de Dios y Ayacucho con respecto a las variables casos COVID-19 e hipertensión, ubicándose en el cuadrante III de la asociación espacial (Bajo-Bajo) de Moran. Otro clúster formado por los departamentos Ancash y Tumbes con respecto a las variables casos positivos de COVID-19 y casos de Neumonía ubicándose en el cuadrante II de la asociación espacial (Bajo-Alto) de Moran. Con respecto al año 2021 y en referencia a las variables casos positivos COVID-19 y casos de Hipertensión observamos 03 clúster, el primero constituido por los departamentos Loreto, Pucallpa y Madre de Dios; el segundo constituido por Ayacucho y la Provincia Constitucional del Callao, y el tercero por Ica. Finalmente, respecto a los casos de COVID-19 y casos de Neumonía, se aprecia un solo clúster constituido por los departamentos Ica, Apurímac y Tumbes, ubicándose en el cuadrante II (Bajo-Alto) en el diagrama espacial de Moran.

Finalmente, se recomienda realizar nuevas investigaciones incorporando variables adicionales, como la infraestructura de salud y los recursos humanos disponibles en cada departamento. Además, sería útil aplicar otros índices de autocorrelación espacial, como el índice C de Geary y el índice G de Getis y Ord, para ampliar el análisis y evaluar otras características de la distribución espacial.

Por último, dado que los datos georreferenciados de la pandemia tienen también un componente temporal, se recomienda realizar investigaciones orientadas a estimar modelos predictivos con un enfoque espacio-temporal, lo que podría mejorar la precisión de las predicciones sobre la evolución de la pandemia y las comorbilidades asociadas. En tal sentido, se recomienda evaluar los aspectos teórico-prácticos de estas metodologías, a fin de mejorar las herramientas utilizadas en el análisis geoespacial de enfermedades y comorbilidades.

6. Referencias

- Carrión, R., Carrasco, C., & Serrano, J. (2020). *Impacto social y económico de las medidas de confinamiento en Europa durante la pandemia de COVID-19*. *Revista Europea de Economía y Sociedad*, 29(3), 45–67.
- Celemín, M. (2009). *Uso de herramientas estadísticas para el análisis de datos espaciales en Geografía*. Universidad Nacional Autónoma de México.
- Cepeda, A., Velázquez, F. (2005). *Introducción a la autocorrelación espacial en Geografía*. *Revista de Estudios Geográficos*, 45(1), 1–15.
- Chaudhry, R., Dranitsaris, G., Mubashir, T., Bartoszko, J., & Riazi, S. (2020). *A country-level analysis measuring the impact of government actions, country preparedness, and socioeconomic factors on COVID-19 mortality and related health outcomes*. *EClinicalMedicine*, 25, 100464. <https://doi.org/10.1016/j.eclinm.2020.100464>
- Córdoba, J., Rossani, M. (2020). *Impacto del COVID-19 en la infraestructura sanitaria en América Latina: Retos y desafíos*. *Revista Panamericana de Salud Pública*, 44, e63. <https://doi.org/10.26633/RPSP.2020.63>
- European Centre for Disease Prevention and Control (ECDC). (2020). *COVID-19 situation updates worldwide*. Recuperado de <https://www.ecdc.europa.eu/en/covid-19-pandemic>
- Gutiérrez, M., Herrera, L., & Kemmer, J. (2021). *El impacto del COVID-19 en la salud pública global*. *Revista Internacional de Salud y Epidemiología*, 35(2), 98–112.
- Holshue, M. L., DeBolt, C., Lindquist, S., Lofy, K. H., Wiesman, J., Bruce, H., ... & Diaz, G. (2020). *First case of 2019 novel coronavirus in the United States*. *New England Journal of Medicine*, 382, 929-936. <https://doi.org/10.1056/NEJMoa2001191>
- Mejía, A., Hurtado, P., Rendón, L. (2020). *Respuestas sanitarias frente a la pandemia en América Latina: Análisis del primer semestre de la COVID-19*. *Revista de Salud Pública*, 22(1), 45–67.
- Murillo, L., Salas, A., Vargas, E., Quispe, R. (2020). *Cambios en la densidad de recursos humanos en salud durante la epidemia de COVID-19 en el Perú*. *Revista Peruana de Salud Pública*, 37(2), e124.
- Organización Mundial de la Salud (OMS). (2020a). *Declaración sobre la pandemia de COVID-19*. Recuperado el 4 de enero de 2025, de <https://www.who.int/news/item/11-03-2020-who-declares-covid-19-pandemic>
- Prinja, S., Pandav, C. S. (2020). *COVID-19: Global challenges and India's response*. *Journal of Public Health Policy*, 41(2), 185-196. <https://doi.org/10.1057/s41271-020-00221-y>
- Rivera, Y. (2014). *Análisis espacio-temporal del COVID-19 utilizando autocorrelación espacial y tecnologías móviles*. *Revista de Estadística Espacial y Geografía*, 12(4), 76–89.
- Vílchez, C., Díaz, M. (2021). *Asociación entre factores ambientales y casos de COVID-19: Un enfoque de autocorrelación espacial en Bogotá, Colombia*. *Revista Colombiana de Geografía*, 30(2), 54–70.