



**“Desastres Naturales y Bienestar Social: Una perspectiva
econométrica espacial aplicada en Latinoamérica”**

**TESIS PARA OPTAR AL GRADO DE
MAGÍSTER EN ANÁLISIS ECONÓMICO**

**Alumna: Vania Vargas Bello
Profesor Guía: Christian Belmar Castro**

Santiago, Agosto 2024

Desastres Naturales y Bienestar Social: Una perspectiva econométrica espacial aplicada en Latinoamérica

Vania Vargas Bello

Agosto 2024



Profesor guía: Christian Belmar C.

Tesis para optar por el grado de Magíster en Análisis Económico

DESASTRES NATURALES Y BIENESTAR SOCIAL: UNA PERSPECTIVA ECONÓMETRICA ESPACIAL APLICADA EN LATINOAMÉRICA

Autora: Vania Vargas Bello ¹

Profesor guía: Christian Belmar Castro ²

Resumen

Los desastres naturales se han desplegado como una amenaza creciente durante las últimas décadas. Junto con esto, la alta diversidad social y geográfica que caracteriza a la región de Latinoamérica y El Caribe, generan una problemática interesante a analizar. El presente trabajo busca estudiar el efecto de los desastres naturales sobre el bienestar social, específicamente analizando la existencia de dependencia geográfica en el impacto que estos han tenido sobre América Latina. Incorporando un enfoque econométrico espacial, es posible identificar la presencia de autocorrelación espacial en el efecto de dichas catástrofes entre países colindantes.

Mediante un análisis geográfico y estadístico en un período de estudio de cinco años, se comprueba la existencia de autocorrelación espacial positiva y significativa en el efecto de los desastres naturales, donde el impacto en un país en particular afecta también los niveles de bienestar social de los países más cercanos, el cual es medido a través del Índice de Desarrollo Humano y el PIB per cápita. Junto con esto, se logra observar que la autocorrelación espacial positiva identificada, indica que países con valores altos de bienestar social, están rodeados de países con valores altos de bienestar social, mientras que países con valores bajos de bienestar social, están rodeados también de países colindantes con niveles de bienestar social similares.

Este estudio busca contribuir, no solo a la literatura existente asociada a la econometría espacial, si no que también a su desarrollo y difusión. De esta manera, se ofrece una visión innovadora en el uso de datos georreferenciados y la utilización de herramientas econométricas espaciales, aportando en la divulgación de esta moderna área de estudio.

Palabras clave: *Desastres naturales, Bienestar social, Latinoamérica, Análisis espacial, Autocorrelación espacial*

¹vargasb@fen.uchile.cl, Departamento de Economía, Universidad de Chile

²cbelmarc@fen.uchile.cl, Departamento de Economía, Universidad de Chile

Índice

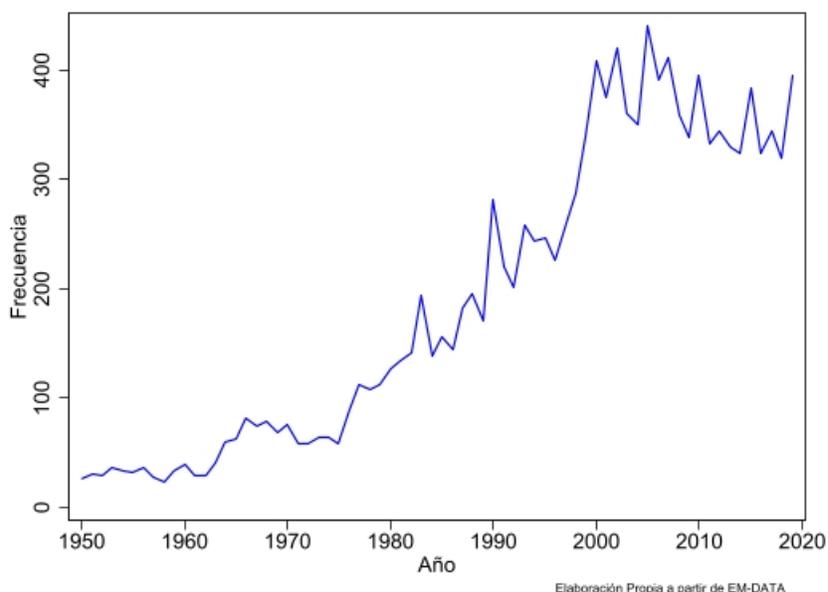
1. Introducción	3
2. Marco teórico	8
2.1. Revisión de Literatura	8
2.1.1. Enfoque tradicional	8
2.1.2. Enfoque espacial	11
2.2. Conceptos básicos	13
2.2.1. Econometría espacial	13
2.2.2. Autocorrelación Espacial	14
2.2.3. Matriz de pesos espaciales	15
3. Hechos estilizados	19
3.1. Análisis Exploratorio de datos espaciales	19
3.2. Índice de Moran	22
3.3. Test G de Getis & Ord	26
4. Estrategia de identificación	29
4.1. Datos	29
4.2. Elección del Modelo	30
5. Resultados	37
5.1. Autocorrelación espacial	37
5.2. Modelo de Error Espacial	40
5.3. Discusión	45
6. Conclusiones	47
7. Anexos	51
7.1. Anexo 1: Modelo de Durbin	51

1. Introducción

En las últimas décadas la ocurrencia de desastres naturales ha aumentado de forma alarmante alrededor del mundo. Fenómenos como inundaciones, terremotos, sequías, tormentas y huracanes han provocado una mayor preocupación por parte de las autoridades al momento de invertir en sistemas de alerta temprana. Junto con esto, atrae la atención de la población en cuanto a medidas de protección y la gestión de planes de acción ante alguna eventualidad de esta índole. Este aumento significativo podría explicarse debido al inminente cambio climático que afecta a la población a través de diversos factores como el aumento en la temperatura ambiental y la acumulación de gases de efecto invernadero en la atmósfera. Es más, la evidencia muestra que el “incremento de las emisiones de carbono generadas por el hombre en el mundo, ha provocado y provocará consecuencias perjudiciales para el planeta, entre las cuales destacan: aumento del nivel del mar, disminución de la disponibilidad de agua para consumo humano, mayor frecuencia e intensidad de desastres naturales (mega-sequías, inundaciones, incendios forestales)” ([Gino Sturla and Flores \(2017\)](#)), entre otras.

Sucesos como estos impactan no sólo en el crecimiento y capacidad de adaptación de un país, si no que también modifica la esfera del bienestar social de la población. Un desastre natural conlleva una serie de repercusiones en quienes residen en una región afectada, ya sea a nivel económico, cultural, educacional e incluso habitacional. La evidencia muestra que países menos desarrollados se encuentran en una posición más vulnerable a la hora de enfrentarse a un desastre natural, ya sea por la baja inversión en políticas preventivas o por la lenta recuperación posterior al desastre.

Figura 1.1: Frecuencia de desastres naturales entre 1950 y 2019



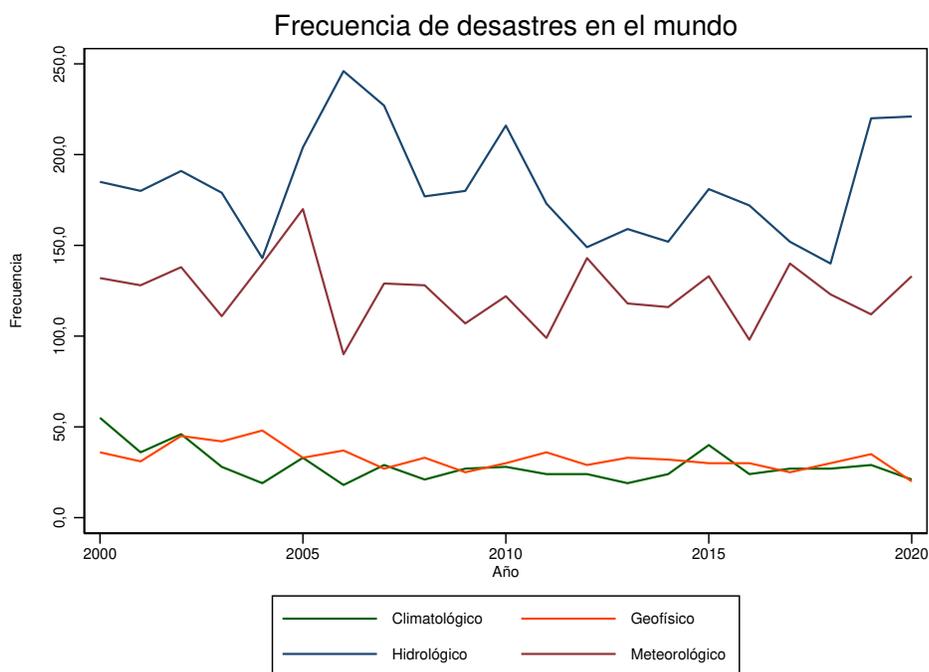
Fuente: Elaboración propia a partir de datos de EM-DATA

Latinoamérica y El Caribe, siendo un territorio caracterizado por una alta desigualdad socio-económica dentro de sus países, “es la segunda región más propensa a los desastres naturales en el mundo, con alrededor de 152 millones de personas afectadas a causa de 1.205 desastres entre el año 2000 y 2019” según la Oficina de Naciones Unidas para la Coordinación de Asuntos Humanitarios. Junto con esto y según el Banco Interamericano de Desarrollo, **la vulnerabilidad de riesgo de desastre no se distribuye de forma uniforme a través de la región**. Países territorialmente más expuestos al océano serán países que están bajo más riesgo, como por ejemplo Chile, Costa Rica y Panamá. Mientras que países más alejados de la costa están clasificados como menos riesgosos, por ejemplo, Bolivia, Paraguay y Ecuador. Este hecho, podría indicar que existe algún tipo de correlación en el impacto de estos desastres entre vecindades de países cercanas, viéndose afectadas de forma similar a nivel económico y social.

Junto con lo anterior, los datos muestran que los desastres más recurrentes no sólo en América Latina y El Caribe, sino que también en el mundo, son del tipo hidrológico y meteorológico, como los tsunamis, inundaciones, sequías y ciclones. En particular, según el registro del Centro de Investigación sobre Epidemiología de los Desastres (CRED), las inundaciones, entre el año 2000 y 2019, afectaron a aproximadamente 41 millones de habitantes en la región. Incluso, se observa que este es uno de los desastres naturales más costosos. En esta línea,

la Oficina para la Coordinación de Asuntos Humanitarios, menciona que los desastres hidrológicos son especialmente catastróficos, “debido a la extensión de los daños causados, como la pérdida de bienes físicos y ambientales. Principalmente pertenencias humanas, sistemas ecológicos, la producción en todos los sectores económicos, salud y la pérdida de vidas”.

Figura 1.2: Frecuencia según tipo de desastre en el mundo - 2000 al 2019



Fuente: Elaboración propia a partir de datos de EM-DATA

Dada la alta diversidad geográfica que presenta la región de Latinoamérica y El Caribe, se podría esperar que el efecto de los desastres naturales sean bastante diferente entre países. Junto con esto, el impacto que estos podrían provocar, también podría estar correlacionado con las consecuencias que conlleva en países cercanos. Por ejemplo, una catástrofe natural podría no sólo tener un efecto en el bienestar de Chile, sino que también en los niveles de bienestar de países colindantes como Argentina y Perú. En base a esto, este trabajo de investigación busca analizar si **¿Existe autocorrelación espacial en el impacto de los desastres naturales sobre el bienestar social?**

El análisis de autocorrelación espacial permitirá examinar las interdependencias generadas entre países, lo que será especialmente útil al momento de definir un patrón de impacto entorno al efecto de las catástrofes naturales. Por ejemplo, [OCHA \(2023\)](#) indica que el impacto

de terremotos e inundaciones depende de diversos elementos, entre ellos la ubicación geográfica, la cual determina en gran medida el impacto del desastre. Es por esto que, el análisis de autocorrelación podría ser una herramienta provechosa en el análisis, ya que muestra cómo “se distribuye el fenómeno en el espacio analizado y en qué grado los elementos locales pueden verse afectados por sus vecinos” (Siabato and Guzmán-Manrique (2019)). En base a esto, se esperaría observar que países más cercanos entre sí, tengan impactos similares al momento de enfrentarse a un desastre natural. Junto con esto y en base a la literatura existente, se prevería que países menos desarrollados sean colindantes de otros países de características similares y estos a su vez, se vean más afectados debido a su posición de vulnerabilidad. Finalmente se encuentra presencia de autocorrelación espacial positiva, donde el impacto de los desastres naturales dentro de un país, influye en el nivel de bienestar de los países vecinos.

La inclusión del elemento de autocorrelación espacial en el estudio del impacto de los desastres naturales sobre el bienestar social es de carácter exploratorio, siendo no sólo un aporte importante en la literatura existente, si no que también podría ser una herramienta fundamental para el desarrollo de políticas públicas que logren incentivar una mejor gestión del riesgo entre países. Además de proteger a la población de manera preventiva y posterior al desastre. Una mayor inversión en infraestructura adecuada, entrega de información y capacitación a la población, además de sistemas de alerta temprana, podrían impactar de forma positiva a las consecuencias que conlleva una catástrofe natural. Todo esto, con el objetivo de resguardar no sólo la seguridad física de los habitantes, sino que también asegurar un óptimo desarrollo cultural y económico que vele por el bienestar social.

Junto con lo anterior, la región de América Latina y el Caribe “ha sufrido incrementos notables de población en migraciones sostenidas desde 1950, donde se han configurado territorios expansivos que afectan y/o amenazan los ecosistemas y sobre todo se estructuran zonas de enormes y drásticas diferencias socio-económicas, al punto que se puede hablar de varias ciudades en cada metrópolis” (Galilea (2021)), lo que dificulta especialmente la gestión pública en cuanto a acciones concretas y preventivas. Es por esto que el desarrollo de investigaciones que analicen el efecto de estas catástrofes en esta región en particular, es fundamental para la toma de decisiones y construcción de políticas que protejan a la población.

El estudio se estructura de la siguiente manera, la sección uno recién descrita, relata la introducción de la investigación, la sección dos describe la construcción del marco teórico compuesto por la revisión de la literatura desde una perspectiva tradicional y una perspectiva espacial, además de la exploración de conceptos básicos asociados a la metodología técnica

aplicada en el estudio. La sección tres describe los hechos estilizados de la metodología a utilizar. La sección cuatro describe expone la estrategia de identificación y la elección del modelo. La sección cinco muestra los resultados obtenidos y la respectiva discusión de estos. Finalmente la sección seis describe las conclusiones obtenidas del estudio realizado.

2. Marco teórico

A continuación, se presenta el marco teórico de la investigación, el cual comienza con una revisión de literatura desde un enfoque tradicional, describiendo los estudios existentes acerca de los efectos de los desastres naturales sobre el bienestar social y crecimiento económico. Luego, se analiza la literatura existente desde una perspectiva espacial, dando cuenta del panorama actual en cuanto a técnicas econométricas espaciales. Todo esto se complementa con la revisión de conceptos básicos asociados al enfoque técnico aplicado en esta investigación.

2.1. Revisión de Literatura

El análisis del impacto de los desastres naturales lleva décadas de desarrollo. Diversos autores han investigado, en su mayoría, el impacto de este tipo de catástrofes sobre el crecimiento económico e incluso sobre el bienestar social en dinámicas de corto y largo plazo. En estos estudios, se identifican los desastres naturales como un factor que genera efectos directos e indirectos sobre el crecimiento económico y el bienestar social. Por ejemplo, [Cavallo et al. \(2020\)](#) examinan el impacto de los desastres naturales sobre el crecimiento económico a través de controles sintéticos en base a estudios comparativos. Aquí, los autores encuentran que sólo las catástrofes significativamente grandes tendrán un efecto negativo sobre el crecimiento económico, siendo estas relevantes sólo en el caso de que estén seguidas por alguna revolución política que interfiera en la organización industrial de un país. Al controlar por este tipo de política, ni los desastres más grandes tendrían un impacto significativo en el crecimiento económico de un país.

Si bien, como se menciona, este tipo de análisis se desarrolla ampliamente en la literatura, la mayoría de estos estudios se realizan desde una perspectiva econométrica tradicional y no desde un enfoque espacial. En este caso, se estudiará el impacto de los desastres naturales en el bienestar social en el corto plazo a través del PIB per cápita. Para esto, se hará uso de la econometría espacial, incluyendo componentes de carácter geográficos que permitirán considerar la localización de los países a analizar, siendo esta uno de los factores determinantes en el impacto de las catástrofes naturales.

2.1.1. Enfoque tradicional

El estudio de los impactos de los desastres naturales ha sido ampliamente estudiado en la literatura. Por lo general, la mayoría de las investigaciones utiliza metodologías tradicionales para estimar la magnitud de la catástrofe, ya sea desde una perspectiva económica o desde

una perspectiva social. Modelos como controles sintéticos, ARIMA y VAR, además del uso de datos de panel, son comúnmente utilizados en el desarrollo de este enfoque.

Como se mencionaba anteriormente, uno de los trabajos más influyentes se trata del desarrollado por [Cavallo et al. \(2020\)](#). En este, los autores analizan el impacto de los desastres naturales sobre el crecimiento económico a través de controles sintéticos. Mediante casos comparativos, encuentran que sólo las catástrofes de magnitud tendrán efecto en el crecimiento económico (de corto y plazo), siempre y cuando estas estén acompañadas de una revolución política importante que impacte en la organización industrial de un país. En ausencia de este shock político, ni los desastres más destructivos tendrían un efecto significativo en el crecimiento económico.

Por ejemplo, [Barrientos-Marín et al. \(2020\)](#), analizan el impacto del terremoto, tsunami y emergencia nuclear en Japón en 2011 en términos económicos. Al igual que [Cavallo et al. \(2020\)](#), los autores utilizan una metodología de control sintético, construyendo contrafactuales a partir de prefecturas que no fueron afectadas por este desastre natural. En base a esto, encuentran que el “costo económico del desastre en 2011 asciende a 2,5 billones de yenes, equivalente al 18 % del PIB sectorial de Japón” ([Barrientos-Marín et al. \(2020\)](#)) resultando en un significativo costo para el país, al menos en un corto plazo. Junto con esto, prefecturas que reciben mayores niveles de inversión, tienden a sufrir una expansión económica más acelerada que aquellas que reciben inversiones en menor magnitud en el largo plazo. Esto último, podría estar explicado a través de lo que señala la literatura, donde países más desarrollados como Japón, se encontrarían en una posición menos vulnerable a la hora de enfrentarse a un desastre natural.

En este mismo contexto, [González \(2021\)](#) presenta una síntesis de la evidencia empírica existente dedicada al análisis del impacto de los desastres naturales sobre el crecimiento económico. A través de la recopilación de 650 estimaciones en diversos estudios, el autor logra identificar que en promedio, las catástrofes tendrían un efecto combinado y negativo. Junto con esto, también señala que los países en desarrollo se ven más afectados que aquellos ya desarrollados.

[Panwar and Sen \(2019\)](#), estudian el efecto de los desastres naturales sobre el crecimiento económico de corto y largo plazo a través del Método Generalizado de Momentos (GMM). Los autores encuentran que el impacto de la catástrofe dependerá del tipo de desastre y de su intensidad, pero que de todas formas los resultados son compatibles con la literatura, de

modo que países en vías de desarrollo se ven significativamente más afectados que aquellos países desarrollados.

[Bănică et al. \(2020\)](#), realizan un estudio de análisis de datos, donde analizan las trayectorias de variables de interés específicas como, PIB per cápita, población, tasa de empleo y desempleo, además del Índice de Desarrollo Humano, antes y después de un desastre natural en particular. En el paper se centran en 5 desastres, el primero corresponde a un huracán ocurrido en el año 2005 en Estados Unidos, el segundo corresponde al terremoto de China del 2008, el tercero al terremoto de Haití el 2010, el cuarto al terremoto del 2010 ocurrido en Chile y finalmente al terremoto y posterior tsunami ocurrido en Japón el año 2011. De este análisis de trayectorias concluyen que los desastres naturales otorgan una “bendición disfrazada” a los países afectados. Esto quiere decir que se observa que los países toman estas experiencias para tomar medidas que mitiguen futuras catástrofes, generando el desarrollo de una mayor conciencia y aprendizaje. Se observa que el Índice de Desarrollo Humano aumenta luego del desastre en 4 de los 5 países analizados, siendo la excepción Haití, donde la gestión del desastre fue ineficiente debido principalmente a la limitante en el financiamiento y la inversión.

[Lee et al. \(2018\)](#) realizan un análisis del impacto económico de corto plazo de los desastres naturales en los Países Insulares del Pacífico. En este señalan que estos países son “muy vulnerables a catástrofes naturales destructivas, imprevisibles y frecuentes”, por lo que el estudio de estas sería fundamental para una planificación estratégica a niveles económicos y sociales. A través de la exploración de la intensidad de los desastres económicos y la distribución de los daños, los autores encuentran que las catástrofes más graves tienen un efecto significativo y negativo en el crecimiento económico reflejado en el deterioro de la balanza fiscal. Junto con esto, y mediante una metodología de regresión lineal y uso de datos de panel, los autores detectan que desastres más intensos, tendrán impactos aún más significativos sobre el crecimiento que aquellos de menor intensidad.

En el contexto Latinoamericano, [González et al. \(2020\)](#) estiman el efecto de los desastres naturales sobre el crecimiento económico para distritos de Argentina. Utilizando la luminosidad nocturna por distrito como proxy del crecimiento económico, encuentran que, al menos en el corto plazo, las catástrofes naturales reducen el crecimiento en un 0,53 % en el mismo año de ocurrencia. Lo anterior, es presentado mayormente por desastres del tipo geofísico e hidrológicos, siendo estos últimos los más comunes en la región de América Latina y El Caribe.

En esta misma línea, [López and Belmar \(2022\)](#), estudian el efecto de los desastres naturales sobre el crecimiento económico a través de Modelos VAR y Panel VAR Bayesianos. En este, analizan los efectos indirectos en el largo plazo, encontrando que “para países de altos ingresos la hipótesis de destrucción creativa tiene mayor peso, mientras que en el caso de los países de bajos ingresos la posibilidad de la trampa de pobreza sigue siendo una realidad” ([López and Belmar \(2022\)](#)). Lo anterior, hace referencia a que países de mayores ingresos enfrentarán los shocks negativos de desastres naturales de forma positiva en un largo plazo, resultando en un mayor crecimiento económico ya que sus posibilidades de financiamiento refuerzan y aceleran los niveles de inversión, lo cual es compatible con la literatura. Esto no ocurre en países de menores ingresos, donde al poseer un stock de recursos y capital más bajos, el enfrentar un desastre natural se torna más complejo y limitante, lo que finalmente conlleva a una lenta recuperación económica o incluso a la ausencia de esta.

En términos de bienestar, [Rodríguez-Oreggia et al. \(2012\)](#) analizan el impacto de los desastres naturales sobre el desarrollo humano y los niveles de pobreza en los municipios de México en el corto plazo. A través de la metodología de diferencias en diferencias, encuentran que los desastres naturales, especialmente las inundaciones y sequías, provocan efectos significativos y negativos en indicadores sociales como el índice de desarrollo humano y el nivel de incidencia en pobreza. “Los niveles de pobreza aumentaron entre un 1,5 % y un 3,7 %, según la medida considerada. Asimismo, para los municipios afectados, el efecto sobre el Índice de Desarrollo Humano fue similar a retroceder dos años en desarrollo humano durante el mismo periodo analizado” ([Rodríguez-Oreggia et al. \(2012\)](#)).

2.1.2. Enfoque espacial

El desarrollo de la econometría desde un enfoque espacial surge “con el objetivo de resolver los problemas que supone la presencia de efectos espaciales, tales como la heterogeneidad y dependencia espacial” ([Serrano et al. \(2002\)](#)). Además de esto, otorga una mayor importancia al factor espacial y no sólo al factor temporal que caracteriza la econometría tradicional.

El término de econometría espacial se le atribuye a Paelinck y Klaassen en la década de los setenta, quienes buscaban diferenciar la econometría tradicional de la econometría regional. A partir de este punto, autores como Cliff y Ord, Blommestein y Anselin, jugaron un rol fundamental en el crecimiento de este campo, siendo cada vez más significativa y utilizada a través de los años. Además de lo anterior, el desarrollo de nuevos softwares geoespaciales permitió una expansión importante en la evolución del análisis de datos espaciales.

Para la aplicación de la econometría espacial existen diversas herramientas que permiten el desarrollo del análisis de heterogeneidad y autocorrelación incorporando medidas de georreferenciación. Entre los estadísticos más populares se encuentran, el Índice de Moran, C de Geary y G de Getis & Ord. Junto con esto y luego del análisis de autocorrelación previo, es posible hacer la elección de un modelo econométrico espacial que más se ajuste a los datos, en base a los resultados obtenidos con los estadísticos descritos. Lo anterior, mediante estimadores de máxima verosimilitud o del método generalizado de momentos.

En cuanto al análisis literario desde una perspectiva espacial, dado que es un enfoque relativamente reciente, no son muchas las investigaciones que se dediquen de forma específica a analizar el impacto espacial de los desastres naturales en el bienestar. Sin embargo, [Saldaña-Zorrilla and Sandberg \(2009\)](#) plantean un modelo econométrico espacial que busca analizar los efectos de las catástrofes naturales en la migración de regiones vulnerables en México. En este, exponen que regiones que son más afectadas por desastres naturales, presentan un mayor grado de migración, lo que provocaría una caída significativa en los ingresos. Es importante destacar que estas regiones más afectadas, también tienden a presentar características socioeconómicas similares, donde residen individuos de menores niveles educativos y mayormente marginados del centro de la ciudad, fenómeno que logró capturar el modelo espacial.

[Sánchez-Peña \(2012\)](#), realiza un estudio de las limitaciones y alcances de los métodos espaciales enfocado en la pobreza urbana en México a través de tres metodologías, análisis de datos espaciales, modelos de regresión espacial autorregresivos y regresión geográficamente ponderada. Utilizando las metodologías mencionadas, la autora encuentra resultados compatibles, donde variables como menores niveles de escolaridad, trabajo informal y dependencia aumentan las brechas de pobreza urbana. Junto con esto, el análisis espacial muestra presencia de autocorrelación espacial, donde municipios vecinos situados en zonas periféricas de la ciudad presentan mayores niveles de pobreza.

Bajo esta misma línea, [Muñetón and Vanegas \(2014\)](#) analizan la pobreza como un fenómeno espacial en Colombia. Aquí, encuentran que a través del análisis exploratorio de datos espaciales es posible obtener que “municipios con un porcentaje de población en situación de pobreza por encima del promedio departamental, tienen vecinos que igualmente tienen un porcentaje de población en situación de pobreza por encima de la media del departamento” ([Muñetón and Vanegas \(2014\)](#)). Esto, indica la presencia de autocorrelación espacial, donde municipios vecinos tienden a concentrar un mayor nivel de pobreza, mostrando incluso una

posible dependencia geográfica.

[Aponte and Meisel \(2010\)](#), analizan la pobreza como un fenómeno espacial de “vecindario”. A través de herramientas econométricas espaciales (Índice de Moran), estudian la distribución de la pobreza en regiones de Colombia. Aquí, logran evidenciar que existen desigualdades regionales persistentes, donde espacios geográficos más pobres, tienden a perpetuar esta pobreza no sólo a través del tiempo, sino que también a través de regiones vecinas.

Como se logra notar, no existen estudios que desarrollen el impacto de corto plazo de los desastres naturales desde una perspectiva espacial a través del bienestar social a nivel Latinoamericano. Es por esto, que el desarrollo de esta investigación podría ser un aporte desde un punto de vista econométrico y social, otorgándole especial relevancia al nivel de concentración y dependencia geográfica y espacial entre regiones. Además de aportar desde la perspectiva de la innovación y la vanguardia, aplicando herramientas econométricas novedosas a problemáticas contingentes como la gestión de desastres naturales.

2.2. Conceptos básicos

2.2.1. Econometría espacial

El desarrollo de la econometría espacial a través de las décadas ha buscado incorporar el espacio en el análisis económico, factor que no es considerado por la econometría tradicional. [Anselin \(1988\)](#), quien ha sido una de las figuras más importantes en el área, define la econometría espacial como “la colección de técnicas que tratan las peculiaridades causadas por el espacio en el análisis estadístico de los modelos tradicionales de la ciencia regional”.

En base al desarrollo de los aspectos espaciales de la econometría, es que surgen dos conceptos fundamentales en el análisis de este tópico, la heterogeneidad espacial y la autocorrelación espacial. El primero “consiste en la variación de las relaciones en el espacio” [Serrano et al. \(2002\)](#), donde el efecto de algún fenómeno afectará de forma heterogénea a los espacios analizados. Mientras que la autocorrelación espacial, hace referencia a cómo el impacto de un fenómeno dependerá del impacto del mismo en el espacio contiguo. En el análisis de este estudio, se utilizará el concepto de autocorrelación espacial.

2.2.2. Autocorrelación Espacial

Según [Siabato and Guzmán-Manrique \(2019\)](#), “la autocorrelación mide el grado de asociación que una variable desarrolla a través de un espacio definido como marco geográfico y este a su vez estará delimitado por el problema que se quiere abordar”. Es decir, el análisis de la autocorrelación espacial permitirá evaluar la posible dependencia que podrían presentar las variables a estudiar, en este caso en particular, el Índice de Desarrollo Humano y PIB per cápita, entre países colindantes.

El término de autocorrelación espacial de alguna manera evidencia la primera Ley de la Geografía desarrollada por Waldo Tobler, la cual postula que “Todas las cosas están relacionadas, pero las cercanas están más relacionadas que las distantes”. De esta manera, este análisis permitirá evaluar si el impacto de los desastres naturales estará relacionado entre países vecinos.

Según [Anselin \(1988\)](#), la autocorrelación espacial aparece como consecuencia de la existencia de una relación funcional entre lo que ocurre en un punto determinado del espacio y lo que ocurre en otro lugar [Serrano et al. \(2002\)](#). En este contexto, permitirá analizar si el impacto de los desastres naturales tendrá un efecto dependiente entre países colindantes, es decir, la reacción provocada por una catástrofe en un país en particular podría extenderse hacia el resto de países vecinos, concentrando incluso los efectos negativos que podría traer esta.

Técnicamente, para medir el nivel y posible existencia de autocorrelación espacial en un territorio, existen una serie de índices como, el Índice de Moran, el C de Geary y G de Getis y Ord, entre otros. El más utilizado en la literatura, es el primero, el Índice de Moran, el cual permite identificar elementos espaciales en las variables a estudiar.

Formalmente, suponiendo que se busca estudiar el efecto sobre y_i en presencia de autocorrelación espacial en tres regiones (i, j y k), se tiene la siguiente relación,

$$y_i = \alpha_{ij}y_j + \alpha_{ik}y_k + \mu_i \quad (1)$$

$$y_j = \alpha_{ji}y_i + \alpha_{jk}y_k + \mu_j \quad (2)$$

$$y_k = \alpha_{ki}y_i + \alpha_{kj}y_j + \mu_k \quad (3)$$

donde

$$\mu_i, \mu_j, \mu_k \sim iid(0, \sigma^2) \quad (4)$$

Aquí, se logra observar que el valor de y_i , dependerá de lo ocurrido en k y este a su vez dependerá de lo ocurrido en j .

En términos matriciales, esta relación se puede representar como,

$$\begin{bmatrix} y_i \\ y_j \\ y_k \end{bmatrix} = \begin{bmatrix} 0 & \alpha_{ij} & \alpha_{ik} \\ \alpha_{ji} & 0 & \alpha_{jk} \\ \alpha_{ki} & \alpha_{kj} & 0 \end{bmatrix} \begin{bmatrix} y_i \\ y_j \\ y_k \end{bmatrix} + \begin{bmatrix} \mu_i \\ \mu_j \\ \mu_k \end{bmatrix} \quad (5)$$

$$y = \Gamma y + \mu \quad (6)$$

donde

$$\Gamma = \begin{bmatrix} 0 & \alpha_{ij} & \alpha_{ik} \\ \alpha_{ji} & 0 & \alpha_{jk} \\ \alpha_{ki} & \alpha_{kj} & 0 \end{bmatrix} \quad (7)$$

2.2.3. Matriz de pesos espaciales

El problema del sistema recién presentado es que contiene 3 observaciones y 6 parámetros, por lo que está sobreparametrizado y no se podrá estimar. Para poder dar solución a esta problemática, es importante imponer alguna restricción en la estructura de la matriz Γ , de modo que,

$$\Gamma = \rho W \quad (8)$$

donde

$$W = \begin{bmatrix} 0 & w_{ij} & w_{ik} \\ w_{ji} & 0 & w_{jk} \\ w_{ki} & w_{kj} & 0 \end{bmatrix} \quad (9)$$

y corresponde la matriz de pesos espaciales. Cada elemento que la compone captura la relación entre dos regiones o espacios geográficos, donde $w_{ij} = 1$ cuando i y j sean vecinos y $w_{ij} = 0$ cuando no lo sean. Cabe recalcar que el criterio de vecindad dependerá de la restricción impuesta por el investigador o investigadora, siendo por ejemplo, los n vecinos más cercanos o alguna restricción de distancia. Como se puede observar, la diagonal de la matriz está compuesta por ceros, ya que un espacio no puede ser vecino de sí mismo.

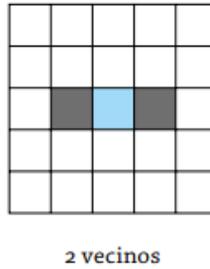
Criterios de contigüidad

Los criterios de contigüidad o criterios de vecindad, describen la relación de proximidad entre unidades espaciales, en este caso países. Son fundamentales para la construcción de la matriz

de pesos espaciales, ya que determinará que tipo de proximidad utilizará el modelo. [Anselin \(1988\)](#) y [Siabato and Guzmán-Manrique \(2019\)](#) describen los siguientes,

- Lineal

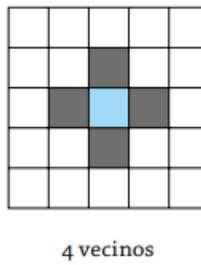
Figura 2.1: Criterio de contigüidad lineal



Fuente: Extraído de “La autocorrelación espacial y el desarrollo de la geografía cuantitativa”, [Siabato and Guzmán-Manrique \(2019\)](#)

- Torre

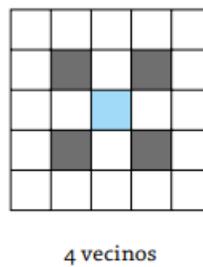
Figura 2.2: Criterio de contigüidad torre



Fuente: Extraído de “La autocorrelación espacial y el desarrollo de la geografía cuantitativa”, [Siabato and Guzmán-Manrique \(2019\)](#)

- Alfil

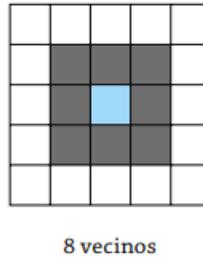
Figura 2.3: Criterio de contigüidad alfil



Fuente: Extraído de “La autocorrelación espacial y el desarrollo de la geografía cuantitativa”, [Siabato and Guzmán-Manrique \(2019\)](#)

- Reina

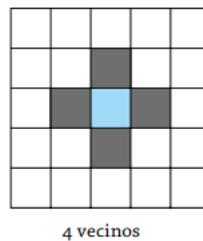
Figura 2.4: Criterio de contigüidad reina



Fuente: Extraído de “La autocorrelación espacial y el desarrollo de la geografía cuantitativa”, [Siabato and Guzmán-Manrique \(2019\)](#)

- Distancia

Figura 2.5: Criterio de contigüidad distancia



Fuente: Extraído de “La autocorrelación espacial y el desarrollo de la geografía cuantitativa”, [Siabato and Guzmán-Manrique \(2019\)](#)

En este caso se utilizará el criterio de distancia, específicamente los dos vecinos más cercanos. Lo anterior, se explica debido a que la distribución geográfica de los países en América Latina y el Caribe genera que la mayoría de los países colinden con máximo dos vecinos.

La matriz de pesos espaciales es protagonista en el análisis de autocorrelación espacial, ya que será la herramienta que permitirá estimar modelos econométricos espaciales en función de la distancia entre cada unidad. Con esta, es posible testear a través de diversas pruebas estadísticas, si la hipótesis propuesta presenta componentes espaciales.

3. Hechos estilizados

A continuación, se presentan los hechos estilizados asociados al análisis de elementos espaciales exploratorio, comenzando con la identificación gráfica de la posible autocorrelación espacial mediante un análisis exploratorio de datos espaciales. Con el objetivo de respaldar los datos obtenidos estadísticamente, se realizan dos test de autocorrelación espacial, el Índice de Moran y el Test de Getis & Ord.

3.1. Análisis Exploratorio de datos espaciales

Para comenzar un estudio desde una perspectiva espacial, es necesario realizar un análisis exploratorio de datos espaciales (AEDE). Este corresponde a un “conjunto de técnicas que permite detectar asociaciones espaciales, concentraciones locales y detección de datos anómalos (outliers)” (de Corso Sicilia et al. (2017)). El objetivo de comenzar por un AEDE es estudiar los datos de forma gráfica a través de mapas como una primera aproximación hacia la dependencia geográfica del tema de interés. Mediante un análisis gráfico, un AEDE es utilizado para identificar las propiedades de los datos con el fin de detectar posibles patrones y formular hipótesis en base a estos.

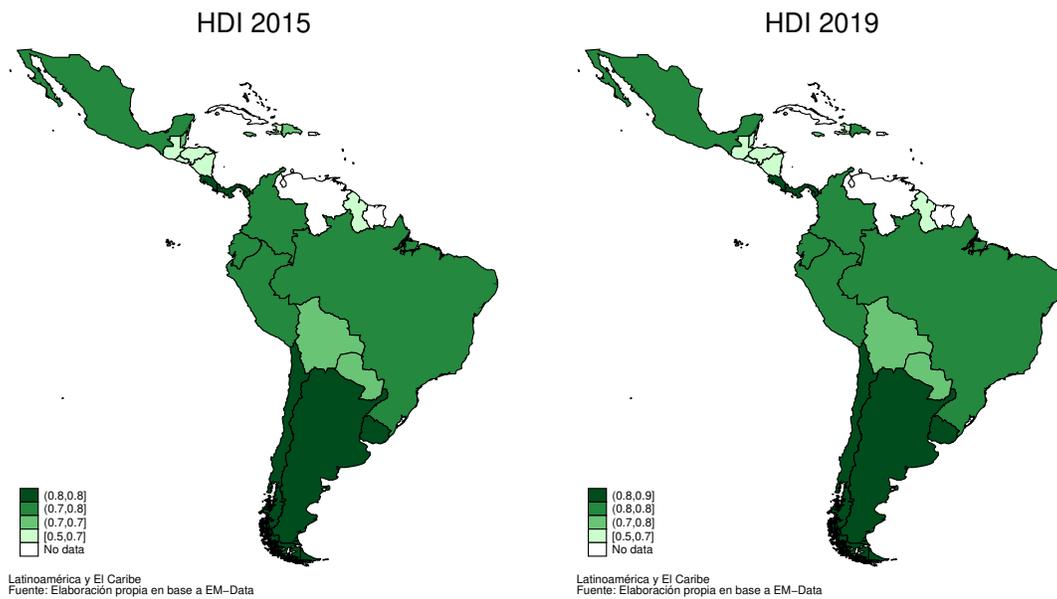
Es importante mencionar que, dado que el análisis exploratorio espacial es previo a la elección del modelo econométrico espacial, no se asume una relación asimétrica entre las variables a utilizar, si no que se analizan de forma independiente en el espacio. Mientras que en los modelos de econométricos en general, se asume que “existe una variable dependiente que es de especial interés y que existe un conjunto de variables explicativas que condicionan su comportamiento” (Herrera-Gómez (2015)).

Junto con lo anterior, es fundamental aclarar que un AEDE provee información gráfica de las variables a utilizar y cómo se distribuyen en el espacio, pero no por eso retratará una relación causal. Serrano et al. (2002), menciona que “si bien la observación de un mapa podría ofrecernos una idea intuitiva acerca de la posible correlación entre regiones vecinas, la información así obtenida, aunque útil, es subjetiva y altamente dependiente, entre otras cosas, del número de intervalos seleccionados para representar a la variable”. Es por esto que posterior a un análisis exploratorio de los datos, es fundamental que se implemente una metodología que permita obtener estimaciones posiblemente causales de la problemática.

En la práctica, para realizar un Análisis Exploratorio de Datos Espaciales es necesario contar

con datos que permitan crear un mapa base del territorio a analizar. Dado que la investigación se centra en la región de América Latina y el Caribe, se reúnen los datos de coordenadas de longitud y latitud de los países seleccionados que permitirán graficar el mapa de Latinoamérica y el Caribe. En base a esto, es posible analizar visualmente el comportamiento, de forma independiente, de las variables a utilizar. En este caso, se explorarán las variables de PIB per cápita, Índice de Desarrollo Humano y Frecuencia de desastres para los años 2015, 2016, 2017, 2018 y 2019.

Figura 3.1: Distribución de HDI 2015-2019

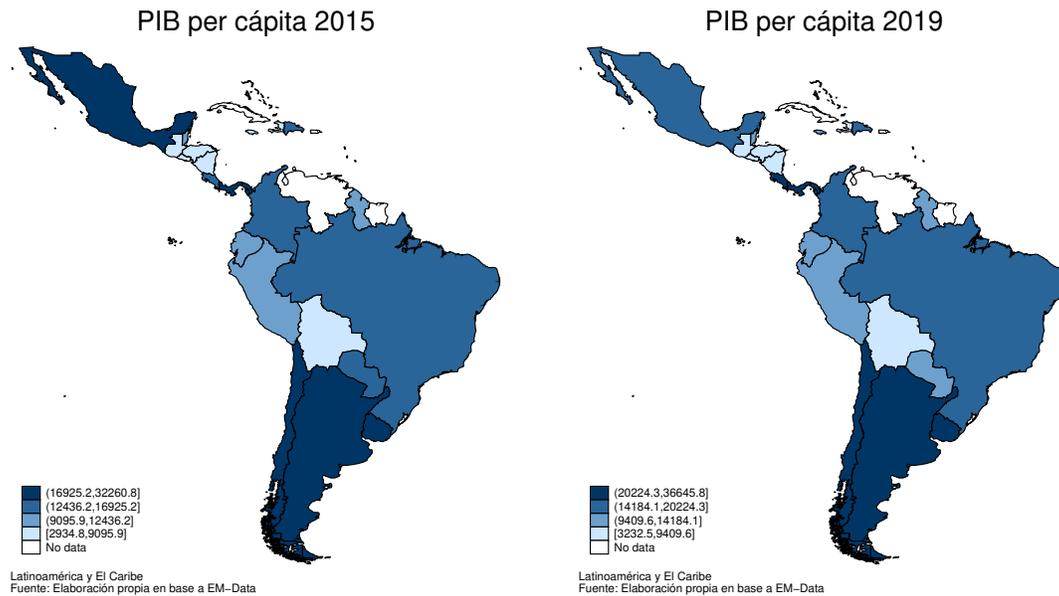


Fuente: Elaboración propia en base a EM-Data.

Como se puede observar, la Figura 3.1 muestra el Índice de Desarrollo Humano para 25 países de América Latina y el Caribe de forma geográfica distribuido por cuantiles. A mayor intensidad de color, mayor es el HDI del país, por lo que se logra inferir que Chile y Argentina poseen los índices más altos de la región, siendo estos vecinos colindantes. Lo mismo ocurre para Bolivia y Paraguay y Guatemala y Nicaragua, compartiendo índices de desarrollo más bajos pero similares entre vecinos.

Este hecho se repite para el año 2019, donde si bien en algunos países el Índice de Desarrollo Humano ha aumentado, sigue presentando un posible patrón de dependencia espacial entre los países anteriormente mencionados.

Figura 3.2: Distribución de PIB per cápita 2015-2019

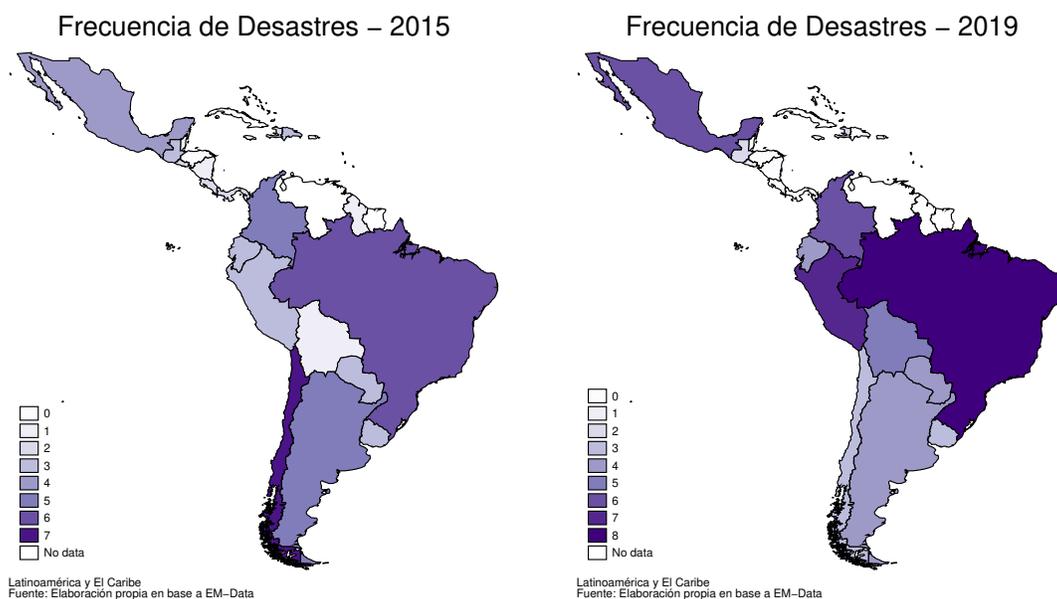


Fuente: Elaboración propia en base a EM-Data.

En la Figura 3.2, se observa la distribución de PIB per cápita por cuantiles en América Latina y el Caribe para el año 2015 y 2019. Como se logra ver, se repite el fenómeno descrito anteriormente pero en una menor magnitud. Esta vez por ejemplo, se da con países vecinos como Ecuador y Perú, Brasil y Paraguay y nuevamente para el par Chile, Argentina y Nicaragua, Guatemala, donde países que presentan menores niveles de PIB per cápita son colindantes a países con niveles de PIB per cápita similares. Lo mismo ocurre en el caso de países con valores de PIB per cápita mayores.

En la Figura 3.3, se logra observar la distribución de frecuencia de desastres para el año 2015 y 2019. Si bien aquí no se observa una posible autocorrelación espacial debido a que los desastres naturales son más bien shocks exógenos e impredecibles, la figura permite observar el aumento en la intensidad de la frecuencia. Un mayor número de desastres por país, es representado por un aumento en la intensidad del color, por lo que durante el año 2019 aumentó de forma considerable la frecuencia de desastres. Esto se observa especialmente en países como Brasil, México y Perú.

Figura 3.3: Distribución de Frecuencia de Desastres 2015-2019



Fuente: Elaboración propia en base a EM-Data.

El análisis exploratorio de datos espaciales, nos permite observar, como primera aproximación, la posible presencia de autocorrelación espacial, es decir, el impacto que el desastre natural tenga en Chile, puede depender también del impacto que el desastre tendrá en Argentina. En este caso, a través de las Figuras 3.1 y 4.2, se logra observar que las variables de Índice de Desarrollo Humano y PIB también tienen una distribución similar entre países vecinos.

Los resultados obtenidos del análisis exploratorio de datos espaciales muestran que las variables de Índice de Desarrollo Humano, PIB per cápita y frecuencia de desastres naturales, se distribuyen de manera similar entre países vecinos. Esto quiere decir que, por ejemplo, países con altos niveles de PIB per cápita, se rodean de países con niveles de PIB per cápita similares, lo que podría estar señalando la presencia de autocorrelación espacial.

Con el objetivo de respaldar los resultados obtenidos a partir del análisis gráfico desarrollado anteriormente, a continuación se presentan dos test de identificación de autocorrelación espacial global univariados.

3.2. Índice de Moran

Luego del análisis exploratorio de datos espaciales, el cual, como se observó anteriormente, indicaba una posible presencia de autocorrelación espacial, es necesario testear estadística-

mente dicho supuesto. Para esto, existen una serie de medidas que se pueden clasificar como globales o locales. Las locales, analizan la autocorrelación espacial en un subconjunto de datos, mientras que las medidas globales hacen uso de todo el conjunto de datos “con el fin de obtener un valor promedio para todo el espacio geográfico” (Herrera-Gómez (2015)).

Para el desarrollo de esta investigación, se hará uso del estadístico global más utilizado en la literatura, correspondiente el Índice de Moran. Matemáticamente, se puede expresar como

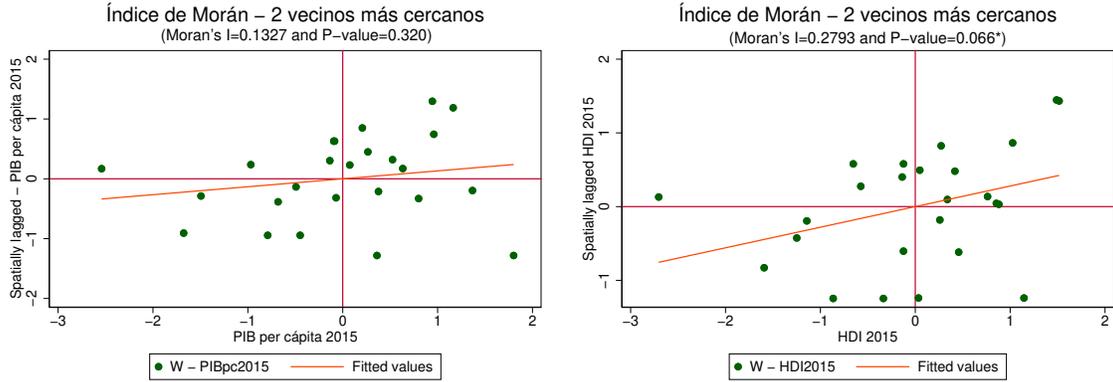
$$I = \frac{N}{\sum_i \sum_j W_{ij}} \frac{\sum_i \sum_j W_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_i (x_i - \bar{x})^2} \quad (10)$$

donde N corresponde al tamaño de la muestra, W_{ij} a la matriz de pesos espaciales definida anteriormente y x_i es el valor de x en la región i .

En este caso, se aplicará el Índice de Moran para analizar la existencia de autocorrelación espacial en las variables PIB per cápita e Índice de Desarrollo Humano (HDI) con el criterio de los dos vecinos más cercanos. Esto debido a que, como se mencionó anteriormente, la distribución geográfica que presenta la región de Latinoamérica y El Caribe, donde la mayoría de los países colindan con la frontera de máximo dos vecinos. Recordar también que el uso del Índice de Moran implica un análisis de las variables de forma independiente a través del espacio y no así una relación causal entre ellas.

En la Figura 3.4 se presenta el análisis gráfico y estadístico del Índice de Moran para el PIB per cápita y el Índice de Desarrollo Humano (HDI) para el año 2015. Como se puede observar, el gráfico se divide en cuatro cuadrantes respecto al valor promedio de la variable a estudiar, donde se distribuyen los puntos correspondientes a los países de la muestra (25). Junto con esto, en ambos gráficos se logra observar una autocorrelación positiva, siendo más pronunciada y significativa para el caso del HDI. Esto indica que países con valores altos de HDI, son colindantes con países con valores altos de HDI también. Lo mismo ocurre en caso de que los niveles de HDI sean más bajos, situación donde los países serán vecinos de quienes tengan un HDI bajo.

Figura 3.4: Índice de Moran - PIB per cápita y HDI - 2015

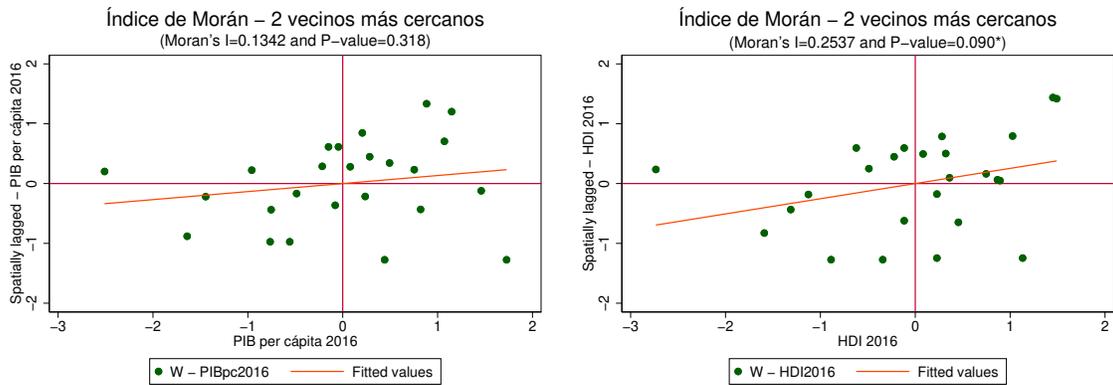


Fuente: Elaboración propia

Nota: En el eje x se encuentra el PIB per cápita/HDI y en el eje y el valor promedio de estas variables para los espacios estudiados. Los puntos representan cada país. Las cuatro divisiones del gráfico describen las cuatro posibles asociaciones entre países: AA - país de alto PIB/HDI colindante a otro de alto PIB/HDI, AB - país de alto PIB/HDI colindante a otro de bajo PIB/HDI, BB - país de bajo PIB/HDI colindante a otro de bajo PIB/HDI y BA - país de bajo PIB/HDI colindante a otro de alto PIB/HDI.

En la Figura 3.5, se realiza el mismo análisis pero esta vez para el año 2016. Como se logra observar, al igual que en el caso anterior, el análisis de autocorrelación para el PIB per cápita, si bien presenta autocorrelación positiva, esta no es estadísticamente significativa. Mientras que para el Índice de Desarrollo Humano, se encuentra una autocorrelación positiva y estadísticamente significativa.

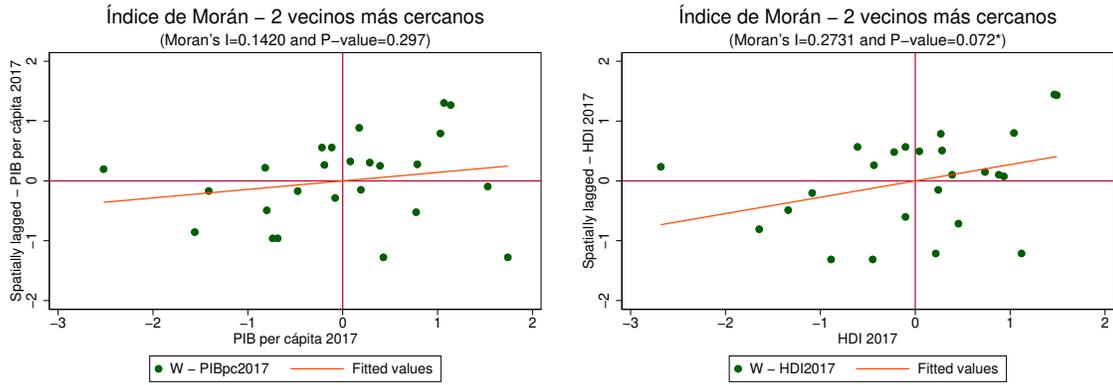
Figura 3.5: Índice de Moran - PIB per cápita y HDI - 2016



Fuente: Elaboración propia

Nota: En el eje x se encuentra el PIB per cápita/HDI y en el eje y el valor promedio de estas variables para los espacios estudiados. Los puntos representan cada país. Las cuatro divisiones del gráfico describen las cuatro posibles asociaciones entre países: AA - país de alto PIB/HDI colindante a otro de alto PIB/HDI, AB - país de alto PIB/HDI colindante a otro de bajo PIB/HDI, BB - país de bajo PIB/HDI colindante a otro de bajo PIB/HDI y BA - país de bajo PIB/HDI colindante a otro de alto PIB/HDI.

Figura 3.6: Índice de Moran - PIB per cápita y HDI - 2017

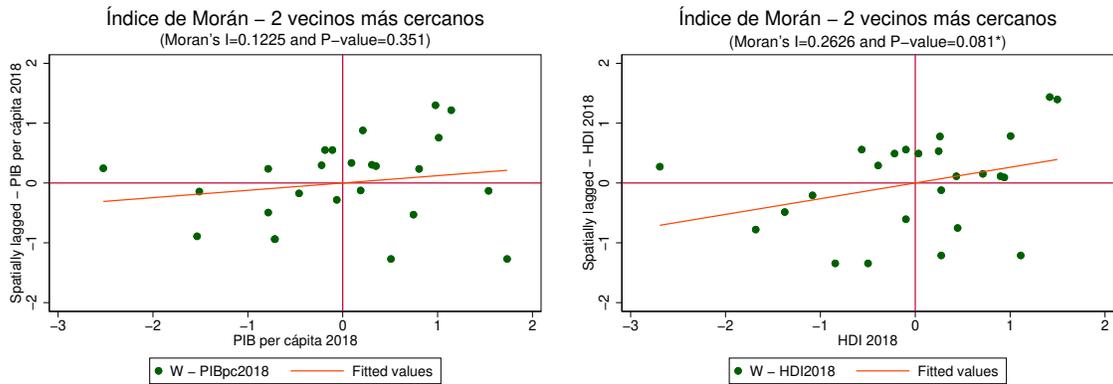


Fuente: Elaboración propia

Nota: En el eje x se encuentra el PIB per cápita/HDI y en el eje y el valor promedio de estas variables para los espacios estudiados. Los puntos representan cada país. Las cuatro divisiones del gráfico describen las cuatro posibles asociaciones entre países: AA - país de alto PIB/HDI colindante a otro de alto PIB/HDI, AB - país de alto PIB/HDI colindante a otro de bajo PIB/HDI, BB - país de bajo PIB/HDI colindante a otro de bajo PIB/HDI y BA - país de bajo PIB/HDI colindante a otro de alto PIB/HDI.

La situación recién descrita se repite para los años 2017, 2018 y 2019 (Figuras 3.6, 3.7 y 3.8), donde la variable de autocorrelación espacial es positiva y estadísticamente significativa para el caso del Índice de Desarrollo Humano. Esto indicaría que valores altos de HDI son vecinos de países con valores altos de HDI y países con valores bajos de HDI tienden a ser vecinos de otros países con valores bajos de HDI. Esta situación no se refleja en el análisis del PIB per cápita, ya que si bien gráficamente se logra observar una autocorrelación espacial positiva, esta no es estadísticamente significativa para ninguno de los años estudiados.

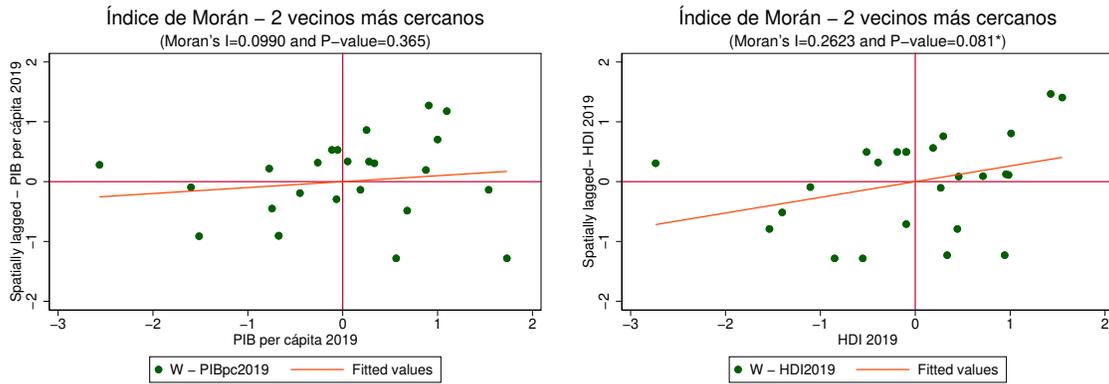
Figura 3.7: Índice de Moran - PIB per cápita y HDI - 2018



Fuente: Elaboración propia

Nota: En el eje x se encuentra el PIB per cápita/HDI y en el eje y el valor promedio de estas variables para los espacios estudiados. Los puntos representan cada país. Las cuatro divisiones del gráfico describen las cuatro posibles asociaciones entre países: AA - país de alto PIB/HDI colindante a otro de alto PIB/HDI, AB - país de alto PIB/HDI colindante a otro de bajo PIB/HDI, BB - país de bajo PIB/HDI colindante a otro de bajo PIB/HDI y BA - país de bajo PIB/HDI colindante a otro de alto PIB/HDI.

Figura 3.8: Índice de Moran - PIB per cápita y HDI - 2019



Fuente: Elaboración propia

Nota: En el eje x se encuentra el PIB per cápita/HDI y en el eje y el valor promedio de estas variables para los espacios estudiados. Los puntos representan cada país. Las cuatro divisiones del gráfico describen las cuatro posibles asociaciones entre países: AA - país de alto PIB/HDI colindante a otro de alto PIB/HDI, AB - país de alto PIB/HDI colindante a otro de bajo PIB/HDI, BB - país de bajo PIB/HDI colindante a otro de bajo PIB/HDI y BA - país de bajo PIB/HDI colindante a otro de alto PIB/HDI.

Es importante mencionar, que si bien el Índice de Moran indica la posible presencia de elementos espaciales en el análisis, este no es una medida definitiva de autocorrelación. Además, tampoco permite identificar qué elementos espaciales se deben incorporar en el modelo a estimar, si no que sirve como una aproximación a una posible presencia de dependencia espacial. Lo mismo en el caso del PIB per cápita, si bien se logra observar una tendencia positiva sin ser estadísticamente significativa, se analizará posteriormente esta relación a través de otros test estadísticos. De esta forma, se lograría confirmar o rechazar la existencia de autocorrelación espacial.

3.3. Test G de Getis & Ord

Adicionalmente al Índice de Moran, se emplea el test G de Getis & Ord funcionando como un complemento al análisis. Este, ayuda a identificar el grado en el que las unidades de análisis con valores altos (hotspots) o bajos (coldspots) se agrupan, es decir, priorizan la conformación de clústeres (Siabato and Guzmán-Manrique (2019)). Este, calcula la interacción espacial del valor de una variable particular en una zona con los valores de esa misma variable en zonas cercanas. A diferencia del I de Moran, solo identifica la autocorrelación espacial positiva, es

decir, donde las zonas tienen valores similares a sus vecinos, por lo que no puede detectar autocorrelación espacial negativa, donde las zonas tienen valores diferentes a sus vecinos (Bravo (2021))

El valor del estadístico G , se calcula con respecto a una distancia de búsqueda especificada en lugar de una distancia inversa como en el caso del I de Moran (Bravo (2021)):

$$G = \frac{\sum_{i=1}^n \sum_{j=1}^n W_{ij} X_i X_j}{\sum_{i=1}^n \sum_{j=1}^n X_i X_j}; i \neq j \quad (11)$$

donde X_i y X_j son los valores de los elementos i y j , W_{ij} es la matriz de pesos espaciales entre los elementos i y j .

Con respecto a la interpretación de este test, un valor z positivo indica que se agrupan valores altos (autocorrelación espacial positiva o hotspots), mientras que valores de z negativos indican la agrupación de valores bajos de las variables estudiadas (autocorrelación espacial negativa o coldspots).

Tabla 3.1: Resultados test Getis & Ord

Test - Getis-Ord	PIB per cápita		HDI	
	Statistic	p-value	Statistic	p-value
2015	-2.193**	0.028	-1.382	0.167
2016	-2.088**	0.037	-1.455	0.146
2017	-2.039**	0.041	-1.434	0.152
2018	-2.071**	0.038	-1.498	0.134
2019	-2.115**	0.034	-1.525	0.127

Fuente: Elaboración propia

Como se logra observar en la tabla 3.1, y a diferencia de lo indicado por el Índice de Moran, el análisis de PIB per cápita a través del test de Getis & Ord muestra la posible presencia de elementos espaciales para todos los años estudiados. Junto con esto, también se puede ver que los valores del test son negativos, lo que indica la agrupación de valores bajos entre países colindantes, es decir, países que presentan PIB per cápita bajos, tienden a estar rodeados de otros países con niveles de PIB per cápita similares (autocorrelación espacial positiva baja o

coldspots).

Como se mencionaba anteriormente, el Índice de Moran y el Test de Getis & Ord permiten identificar la posible presencia de patrones de autocorrelación espacial en las variables analizadas pero no necesariamente implican una relación causal entre ellas. Con los resultados encontrados, se logra inferir que podría existir un elemento espacial en las variables observadas, por lo que a continuación, se describirá el análisis multivariado y la elección del modelo identificado.

4. Estrategia de identificación

Para realizar un análisis desde una perspectiva espacial, es necesario seguir una serie de etapas que, en caso de que exista presencia de autocorrelación espacial, permitirán definir un modelo econométrico espacial que se ajuste a los datos encontrados. La primera etapa, consta de un análisis exploratorio de datos espaciales (descrito anteriormente), donde mediante mapas, se grafica la relación espacial que podría existir entre las variables estudiadas a través de los distintos espacios geográficos, que en este caso corresponden a países. Este análisis gráfico se complementa con el uso de diversos test estadísticos de análisis espacial univariante, en este caso, Índice de Moran y test de Getis & Ord.

Luego de observar la posible presencia de autocorrelación, se prosigue a la segunda etapa, la cual corresponde al testeo estadístico de autocorrelación espacial por medio del Índice de Moran desde una perspectiva multivariante, es decir, se aplica el test sobre el modelo a estimar incluyendo todas las variables del estudio, donde existe una variable dependiente y al menos una variable explicativa, además de una serie de test de Lagrange que serán explicados más adelante. Una vez ya analizados estos resultados, se elige el mejor modelo econométrico espacial a utilizar.

4.1. Datos

Para el análisis espacial del impacto de los desastres naturales se utilizará la base de datos EM-DATA, perteneciente al Centro de Investigación sobre la Epidemiología de los Desastres (CRED) de la Université Catholique de Louvain. En esta se registran catástrofes masivas a nivel mundial desde el año 1900 hasta la actualidad, las cuales se dividen en dos clasificaciones, desastres tecnológicos y naturales. Estos últimos se subdividen en geofísicos, meteorológicos, hidrológicos y climatológicos.

En esta investigación en particular, se hará uso únicamente de los desastres del tipo naturales, lo que permitirá diferenciar la localización de estos a nivel país, además del tipo de catástrofe. Esta base de datos también permitirá analizar la magnitud del desastre a través del número de afectados y número de fallecidos por evento.

Es importante mencionar que dado que los desastres son autoreportados por los países, es necesario que cumplan con alguno de los siguientes criterios para que estos realmente sean clasificados como desastres naturales:

- 10 o más personas fallecidas
- 100 o más personas afectadas, heridas o sin hogar.
- Declaración por parte del país del Estado de emergencia o petición de ayuda internacional.

Cabe destacar que en este caso no es posible incluir una variable que permita describir la distancia exacta que separa cada desastre, ya que no se cuenta con la localización exacta de cada uno de los desastres registrados por el Centro de Investigación sobre la Epidemiología de los Desastres (CRED).

Para la medición desde la perspectiva del bienestar social, se utilizarán el PIB per cápita y el Índice de Desarrollo Humano, extraído desde la base de datos del Programa de las Naciones Unidas. Este último, corresponde a una medida resumida de los logros medios en las dimensiones clave del desarrollo humano: una vida larga y saludable, tener conocimientos y un nivel de vida digno, lo cual permitirá capturar el efecto en esferas sociales de forma indirecta a través de variables como la educación, el ingreso per cápita y la esperanza de vida.

Por otro lado, se utilizarán variables de control como densidad poblacional, niveles de migración y tasa de mortalidad infantil para incluir una medida de salud. Es importante mencionar que la información de estas últimas variables se encuentra disponible en la base de datos de la Comisión Económica para América Latina y el Caribe (CEPAL).

4.2. Elección del Modelo

Luego del análisis exploratorio de datos espaciales y del análisis del Índice de Moran, donde se logra observar una posible presencia de autocorrelación espacial, el siguiente paso es detectar la estructura del modelo. Para esto, se utilizará un modelo básico de MCO, definido de la siguiente forma,

$$y = X\beta + \mu \quad (12)$$

$$\mu \sim (0, \sigma^2 I_n) \quad (13)$$

[Herrera-Gómez \(2015\)](#) indica que, en base al modelo básico descrito anteriormente, para la elección del modelo econométrico a utilizar es posible plantear dos hipótesis. La primera consiste en plantear la presencia de autocorrelación espacial en el término de error, de modo que,

$$y = X\beta + \mu \quad (14)$$

$$\mu = \rho W \mu + \epsilon \Rightarrow \mu = B^{-1} \epsilon \quad (15)$$

y

$$\epsilon \sim \mathcal{N}(0, \sigma^2 I_n) \quad (16)$$

con $B = [I - \rho W]$ y ϵ un vector de errores ([Herrera-Gómez \(2015\)](#)). En este caso, ρ corresponde al parámetro espacial autoregresivo que mide el nivel de autocorrelación y W corresponde a la matriz de pesos espaciales definida anteriormente. Este modelo es denominado Modelo de Error Espacial o SEM.

Es importante mencionar que si bien la identificación del modelo es en base a un modelo básico de MCO, la estimación de este tipo de modelos especiales no puede realizarse mediante MCO, debido a que se obtendrían estimaciones inconsistentes y/o ineficientes ([Anselin \(1988\)](#)). Es por esto que, existen dos formas de estimar un modelo espacial. La primera es mediante máxima verosimilitud (MV), mientras que la segunda es a través del método generalizado de momentos (GMM). Dado que suponemos que los errores se distribuyen de forma normal, se hará uso de la primera opción, la estimación por máxima verosimilitud. Entonces, asumiendo la distribución normal de los errores, la función de log-verosimilitud del SEM corresponde a,

$$L = -\frac{n}{2} \ln(2\pi\sigma^2) + \ln|B| - \frac{1}{2\sigma^2} [(y - X\beta)' \Omega(\rho)(y - X\beta)] \quad (17)$$

En base a lo planteado por [Herrera-Gómez \(2015\)](#), para un ρ dado, la optimización de la función de log-verosimilitud muestra que,

$$\beta_\rho = [X' \Omega(\rho) X]^{-1} X' \Omega(\rho) y \quad (18)$$

y

$$\sigma_\rho^2 = \frac{e' \Omega(\rho) e}{n} \quad (19)$$

donde $e = y - X\beta_\rho$ y $\Omega(\rho) = (I - \rho W)'(I - \rho W)$. Con esto, es posible obtener la función de log-verosimilitud concentrada,

$$L_c = -C + \ln|I - \rho W| - \frac{n}{2} \ln[e'\Omega(\rho)e] \quad (20)$$

Así, “se maximiza la log-verosimilitud concentrada hasta lograr convergencia y posteriormente con el valor $\hat{\rho}$ se obtienen los demás parámetros del modelo. Una vez logrado la convergencia de L_c , puede sustituirse en las expresiones previas” tal que,

$$\hat{\beta}_{\hat{\rho}} = [X'\Omega(\hat{\rho})X]^{-1}X'\Omega(\hat{\rho})y \quad (21)$$

y

$$\hat{\sigma}_{\hat{\rho}}^2 = \frac{1}{n}(e'\Omega(\hat{\rho})e) \quad (22)$$

Como segunda hipótesis, es posible “plantear un modelo con estructura espacial sustantiva (SLM), incorporando un rezago espacial de la variable dependiente como variable explicativa” (Herrera-Gómez (2015)), de modo que,

$$y = \lambda W_y + X\beta + \mu \quad (23)$$

y

$$\mu \sim \mathcal{N}(0, \sigma^2 I_n) \quad (24)$$

Siendo λ un parámetro espacial autoregresivo. Este modelo lleva como nombre, modelo con estructura espacial sustantiva o modelo de rezago espacial o SLM. Al igual que en el modelo SEM, al suponer que los errores se distribuyen de forma normal, es posible estimar el modelo a través de máxima verosimilitud, donde la función de log-verosimilitud corresponde a,

$$L = -\frac{n}{2} \ln(2\pi\sigma^2) + \ln|A| - \frac{1}{2\sigma^2} [(Ay - X\beta)'(Ay - X\beta)] \quad (25)$$

donde $A = I - \lambda W$.

Herrera-Gómez (2015) menciona la necesidad de imponer una restricción sobre el rango de valores que puede asumir λ con el objetivo de evitar que el espacio paramétrico de la función sea discontinuo o inestable. Con esto, “Ord (1981) propuso restringir los posibles valores del parámetro en un rango $\frac{1}{\tau_{mín}} < \lambda < \frac{1}{\tau_{máx}}$, donde $\tau_{mín}$ y $\tau_{máx}$ son los autovalores, mínimo y máximo, de la matriz W . Bajo una matriz espacial estandarizada por filas automáticamente se impone una restricción sobre el máximo autovalor tal que λ se encontrará restringido entre los valores $\frac{1}{\tau_{mín}} < \lambda < 1$.”.

Con la función de log-verosimilitud planteada y los parámetros establecidos, al igual que en el modelo SEM se calcula la función de log-verosimilitud concentrada, con lo que se obtienen los parámetros,

$$\beta_\lambda = [X'X]^{-1}X'y - \lambda[X'X]^{-1}X'y = \beta_{MCO} - \lambda\beta_{W_y, MCO} \quad (26)$$

y

$$\sigma_\lambda^2 = \frac{1}{n}[\mu_{MCO} - \lambda\mu_{W_y, MCO}]'[\mu_{MCO} - \lambda\mu_{W_y, MCO}] \quad (27)$$

siendo $\beta_{MCO} = [X'X]^{-1}X'y$, $\beta_{W_y, MCO} = [X'X]^{-1}X'W_y$, $\mu_{MCO} = y - X\beta_{MCO}$ y $\mu_{W_y, MCO} = W_y - X\beta_{W_y, MCO}$.

Dadas las opciones planteadas, es necesario utilizar estadísticos de dependencia espacial para la detección de la estructura espacial del modelo. Utilizando como hipótesis nula las ecuaciones (12) y (13) asociadas al modelo básico de MCO, el objetivo es “encontrar evidencia tal que permita mantener la hipótesis nula de no autocorrelación espacial, en caso contrario, se incorporarán elementos espaciales al modelo” (Herrera-Gómez (2015)).

Adicional al Índice de Moran univariado desarrollado en secciones anteriores, se aplica también el Índice de Moran multivariado sobre el modelo simple de MCO. Este permitirá descubrir la presencia de elementos espaciales en el modelo, pero no identifica qué modelo espacial específico es el más adecuado a los datos. Es por esto, que se complementa el análisis con un set de estadísticos de Multiplicadores de Lagrange “que resultan de la aplicación del principio de máxima verosimilitud. Estos tienen la ventaja de que la hipótesis alternativa se encuentra bien definida o restringida” (Herrera-Gómez (2015)), permitiendo identificar qué modelo espacial se ajusta mejor a los datos.

Dados los modelos descritos anteriormente, error espacial y rezago espacial, se plantean los contrastes de Multiplicadores de Lagrange (LM).

Herrera-Gómez (2015) menciona que el contraste LM para detectar autocorrelación espacial en el error establece las siguientes hipótesis,

$$\begin{aligned} H_0 &: \rho = 0 \\ H_1 &: \rho \neq 0 \end{aligned}$$

Siendo su fórmula

$$LM_{error} = \frac{1}{T_1} \left(\frac{\hat{\mu}'W\hat{\mu}}{\hat{\sigma}^2} \right)^2 \sim \chi_1^2 \quad (28)$$

donde $T_1 = [(W' + W)W]$, $\hat{\sigma}^2 = \frac{\mu'\hat{\mu}}{n}$ y $\hat{\mu}$ son los residuos.

Por otro lado, el contraste para la detección de dependencia sustantiva plantea las siguientes hipótesis (Herrera-Gómez (2015)),

$$\begin{aligned} H_0 &: \lambda = 0 \\ H_1 &: \lambda \neq 0 \end{aligned}$$

Siendo su fórmula

$$LM_{lag} = \frac{\left(\frac{\hat{\mu}'W_y}{\hat{\sigma}^2} \right)^2}{n\hat{J}_{\lambda\beta}} \sim \chi_1^2 \quad (29)$$

donde $\hat{J}_{\lambda\beta} = \frac{1}{n\hat{\sigma}^2} [(WX\hat{\beta})'M(WX\hat{\beta}) + T_1\hat{\sigma}^2]$, con $M = I - X(X'X)^{-1}X'$.

Herrera-Gómez (2015) menciona que los test recién descritos (LM_{error} y LM_{lag}) son sensibles a diversos tipos de errores de especificación. Por ejemplo “ LM_{error} detecta autocorrelación espacial debido a la presencia de un rezago espacial de la variable endógena (W_y), y lo mismo puede decirse del LM_{lag} , que brinda falsos positivos cuando el término de error contiene un rezago espacial (W_μ)”. Es por esto que Luc Anselin and Yoon (1996) plantean multiplicadores adicionales robustos a este tipo de errores de especificación, donde la versión robusta del test LM_{error} corresponde a,

$$LM_{error}^* = \frac{\left[\left(\frac{\hat{\mu}'W\hat{\mu}}{\hat{\sigma}^2} \right) - T_1(n\hat{J}_{\lambda\beta})^{-1} \left(\frac{\hat{\mu}'W_y}{\hat{\sigma}^2} \right) \right]^2}{T_1 - [T_1^2(n\hat{J}_{\lambda\beta})^{-1}]} \sim \chi_1^2 \quad (30)$$

Mientras que la versión robusta del contraste asociado al rezago corresponde a,

$$LM_{lag}^* = \frac{[\left(\frac{\hat{\mu}'W_y}{\hat{\sigma}^2}\right) - \left(\frac{\hat{\mu}'W\hat{\mu}}{\hat{\sigma}^2}\right)]^2}{n\hat{J}_{\lambda\beta} - T_1} \sim \chi_1^2 \quad (31)$$

Entonces, en base a lo recién planteado, para la identificación del modelo de error espacial (SEM), se utilizará el, el Multiplicador de Lagrange del error (LM_{error}) y el Multiplicador de Lagrange Robusto (LM_{error}^*). Mientras que para la identificación del modelo de rezago espacial, se usa el Multiplicador de Lagrange del rezago (LM_{lag}) y el multiplicador de Lagrange robusto del rezado (LM_{lag}^*). De este modo, que para que exista autocorrelación de algún tipo, es necesario rechazar la hipótesis nula planteada.

Como se había mencionado anteriormente, si bien el Índice de Moran puede indicar presencia de autocorrelación espacial, no entrega indicios sobre el modelo espacial que es necesario estimar. Es por esto que se utilizan los test de Multiplicador de Lagrange, de forma que a través de un análisis conjunto, sea posible elegir el modelo más adecuado.

En este caso, se utilizarán como variables independientes el PIB per cápita y el Índice de Desarrollo Humano, mientras que para medir la magnitud del desastre, se realizará a través del número de fallecidos y número de afectados por país durante un año en específico. De esta forma, se estimarán los siguientes cuatro modelos para los años 2015, 2016, 2017, 2018 y 2019,

$$\log PIB_{i,t} = \beta_0 + \beta_1 \log N Fallecidos_{i,t} + X_{i,t} \beta_2 + \mu_{i,t} \quad (32)$$

$$\log PIB_{i,t} = \beta_0 + \beta_1 \log N Afectados_{i,t} + X_{i,t} \beta_2 + \mu_{i,t} \quad (33)$$

$$\log HDI_{i,t} = \beta_0 + \beta_1 \log N Fallecidos_{i,t} + X_{i,t} \beta_2 + \mu_{i,t} \quad (34)$$

$$\log HDI_{i,t} = \beta_0 + \beta_1 \log N Afectados_{i,t} + X_{i,t} \beta_2 + \mu_{i,t} \quad (35)$$

Con los modelos recién descritos, se realizará una estimación lineal simple que permitirá, a través de los test ya mencionados, elegir el modelo econométrico espacial más adecuado para el desarrollo de la investigación.

5. Resultados

La siguiente sección, presenta los resultados de la estrategia de identificación definida anteriormente. Primero, se describen los resultados asociados al testeo estadístico del Índice de Moran multivariado, el cual comprueba la presencia de autocorrelación espacial y los contrastes de Lagrange, que permiten identificar qué modelo espacial se ajusta mejor a los datos utilizados. Con la elección del modelo realizada, se presentan los resultados ligados a la estimación correspondiente.

5.1. Autocorrelación espacial

A continuación, se describen los resultados por año del testeo estadístico descrito anteriormente en base al modelo básico de MCO, comenzando por la aplicación del Índice de Moran multivariado, el cual permitirá determinar la presencia de autocorrelación espacial, seguido de los test de Lagrange, los cuales posibilitan la identificación del modelo econométrico espacial que se ajusta mejor a los datos disponibles.

Tabla 5.1: Test Autocorrelación - 2015

Diagnostics - 2015	PIB per cápita				HDI			
	Fallecidos		Afectados		Fallecidos		Afectados	
Test	Statistic	p-value	Statistic	p-value	Statistic	p-value	Statistic	p-value
Spatial error:								
Moran's I	2.389**	0.017	2.364**	0.018	3.756***	0.000	3.766***	0.000
Lagrange Multiplier	4.078**	0.043	4.110**	0.043	10.947***	0.001	11.307***	0.001
Robust Lagrange Multiplier	5.313**	0.021	5.587**	0.018	5.806**	0.016	7.003***	0.008
Spatial Lag:								
Lagrange Multiplier	1.071	0.301	0.933	0.334	5.363**	0.021	1.736**	0.030
Robust Lagrange Multiplier	2.306	0.129	2.410	0.121	0.222	0.637	0.433	0.511

Fuente: Elaboración propia

En la Tabla 5.1, se logra observar que para el año 2015 el análisis hará distinción entre las variables de PIB per cápita y HDI. En el caso del PIB per cápita, se puede ver que este presenta un Índice de Moran estadísticamente significativo a diferencia de lo mostrado por el AEDE en la sección anterior. Esto indicaría la presencia de autocorrelación espacial, pero no entrega indicios de la estructura espacial a estimar. En el caso de los test de error espacial, también presenta valores estadísticamente significativos. Mientras que para los test de rezago espacial, no presenta valores estadísticamente significativos.

En el caso del Índice de Desarrollo Humano, se logra observar que este es significativo para prácticamente toda la estructura espacial del error analizada. Mientras que al testear el rezago espacial, sólo el multiplicador de Lagrange del rezago (LM_{lag}) resulta ser estadísticamente

significativo. Esto a simple vista parece ser un modelo de error espacial. Para asegurar esta elección, es necesario analizar todos los años a utilizar, los cuales se muestran a continuación,

Tabla 5.2: Test Autocorrelación - 2016

Diagnostics - 2016	PIB per cápita				HDI			
	Fallecidos		Afectados		Fallecidos		Afectados	
	Statistic	p-value	Statistic	p-value	Statistic	p-value	Statistic	p-value
Spatial error:								
Moran's I	1.812*	0.070	1.796*	0.072	3.092***	0.002	3.037***	0.002
Lagrange Multiplier	1.884	0.170	1.899	0.168	6.621***	0.009	6.424**	0.011
Robust Lagrange Multiplier	1.801	0.180	2.004	0.157	3.155*	0.076	3.392*	0.066
Spatial Lag:								
Lagrange Multiplier	0.611	0.434	0.451	0.502	3.467*	0.063	3.048*	0.081
Robust Lagrange Multiplier	0.529	0.467	0.556	0.456	0.001	0.976	0.016	0.900

Fuente: Elaboración propia

Para el año 2016 (Tabla 5.2), se logra observar una estructura bastante similar a la del año 2015, donde para la variable de PIB, el Índice de Moran sigue siendo significativo para ambos casos, número de fallecidos y número de afectados. Mientras que no logra rechazar las hipótesis nulas de los demás test. Esto indicaría que si bien hay presencia de elementos espaciales, no es claro qué modelo se ajusta mejor a los datos.

Para el caso del Índice de Desarrollo Humano, se observa una situación similar a la descrita para el año 2015. Existe significancia para los test de error espacial, pero no para todos los test de rezago espacial. Esto, reforzaría la idea de un modelo de error espacial por sobre un modelo de rezago espacial.

Tabla 5.3: Test Autocorrelación - 2017

Diagnostics - 2017	PIB per cápita				HDI			
	Fallecidos		Afectados		Fallecidos		Afectados	
	Statistic	p-value	Statistic	p-value	Statistic	p-value	Statistic	p-value
Spatial error:								
Moran's I	1.259	0.208	1.888*	0.059	2.169**	0.030	3.033***	0.002
Lagrange Multiplier	0.775	0.379	2.251	0.134	2.952*	0.086	6.578***	0.010
Robust Lagrange Multiplier	0.780	0.377	3.275*	0.070	0.688	0.407	3.704*	0.054
Spatial Lag:								
Lagrange Multiplier	0.251	0.616	0.492	0.483	2.408	0.121	3.050*	0.081
Robust Lagrange Multiplier	0.256	0.613	1.516	0.218	0.145	0.704	0.177	0.674

Fuente: Elaboración propia

Tabla 5.4: Test Autocorrelación - 2018

Diagnostics - 2018	PIB per cápita				HDI			
	Fallecidos		Afectados		Fallecidos		Afectados	
Test	Statistic	p-value	Statistic	p-value	Statistic	p-value	Statistic	p-value
Spatial error:								
Moran's I	1.433	0.152	1.058	0.290	2.767***	0.006	2.659***	0.008
Lagrange Multiplier	0.870	0.351	0.411	0.521	4.628**	0.031	4.561**	0.033
Robust Lagrange Multiplier	0.602	0.438	0.038	0.845	1.160	0.282	0.087	0.768
Spatial Lag:								
Lagrange Multiplier	0.375	0.540	0.722	0.395	3.708*	0.054	6.216**	0.013
Robust Lagrange Multiplier	0.107	0.743	0.349	0.555	0.239	0.625	1.742	0.187

Fuente: Elaboración propia

Los resultados descritos se repiten de forma similar para los años 2017, 2018 y 2019, donde el Índice de Moran en gran parte de los casos, sugiere la inclusión de elementos espaciales en la estimación. De esta misma manera, la variable de Índice de Desarrollo Humano presenta significancia en la mayoría de los test de error espacial analizados ($IdeMoran$, LM_{error} y LM_{error}^*), mientras que para los test de rezago espacial (LM_{lag} y LM_{lag}^*) la significancia es prácticamente inexistente. En el caso del PIB per cápita, los resultados apuntan a la misma dirección, donde si bien el Índice de Moran tiende a ser significativo, los test de error espacial son más significantes que los test de rezago espacial.

Tabla 5.5: Test Autocorrelación - 2019

Diagnostics - 2019	PIB per cápita				HDI			
	Fallecidos		Afectados		Fallecidos		Afectados	
Test	Statistic	p-value	Statistic	p-value	Statistic	p-value	Statistic	p-value
Spatial error:								
Moran's I	2.090**	0.037	2.052**	0.040	3.757***	0.000	3.824***	0.000
Lagrange Multiplier	2.574	0.109	2.386	0.122	10.031***	0.002	10.341***	0.001
Robust Lagrange Multiplier	5.463**	0.019	4.825**	0.028	7.354***	0.007	7.772***	0.005
Spatial Lag:								
Lagrange Multiplier	0.438	0.508	0.418	0.518	3.851**	0.050	3.813*	0.051
Robust Lagrange Multiplier	3.326*	0.068	2.857*	0.091	1.175	0.278	1.245	0.265

Fuente: Elaboración propia

Gracias al análisis descrito, se observa que existe presencia de elementos espaciales en el modelo a estimar. Debido a que los test de error espacial presentan resultados más significativos que los test de rezago espacial, el modelo econométrico espacial elegido corresponde al modelo de error espacial. Como se mencionó anteriormente, de forma matemática se define como,

$$y = X\beta + \mu \quad (36)$$

y

$$\mu = \rho W\mu + \epsilon \quad (37)$$

Dado que en este tipo de modelos el elemento espacial identificado está presente en los errores, la dependencia del error espacial puede reflejar la autocorrelación espacial en los errores de medición o en variables que de otro modo no son cruciales para el modelo (es decir, las variables ignoradas se propagan a través de las unidades espaciales de observación) (Morales-Oñate and Morales (2019)). Esto podría indicar que la detección de estructura espacial en el error puede ser causada por una omisión de variables relevantes y no por efectos espaciales en el error (Herrera-Gómez (2015)).

Es por esto que, si bien el modelo elegido en base a los resultados de los estadísticos desarrollados corresponde al modelo de error espacial, con el objetivo de verificar esta elección y cubrir la posibilidad de variables omitidas relevantes, también se analizaron los resultados del modelo de Durbin. Este modelo, además de incorporar dependencia sustantiva, también incorpora nuevas variables explicativas que pueden haberse omitido y tiene la siguiente estructura,

$$y = \lambda W_y + X\beta + WX_\gamma + \mu \quad (38)$$

Los resultados obtenidos del modelo de Durbin no mostraron resultados significativos en cuanto a presencia de autocorrelación espacial para todos los períodos (Anexo 1). La presencia de autocorrelación espacial se observa únicamente para el impacto del número de afectados sobre el Índice de Desarrollo Humano en los años 2018 y 2019. Es por esto que los resultados descritos en los test mencionados son correctos y el modelo que se ajusta mejor a los datos y al período de estudio corresponde al modelo de error espacial.

5.2. Modelo de Error Espacial

En base al análisis desarrollado en el apartado anterior, se llega a la conclusión de que el modelo elegido corresponde al Modelo de Error Espacial SEM. El problema, es que no es posible estimar un modelo de este tipo a través de mínimos cuadrados, ya que “la estimación sería inconsistente o ineficiente dependiendo del caso” (Anselin (1988)).

Como se mencionaba anteriormente, existen dos formas de estimar un modelo de este tipo. La primera es a través del modelo de máxima verosimilitud (MV) y la segunda es mediante el método generalizado de momentos (GMM). En el caso de la estimación por máxima verosimilitud, esta se podría utilizar sólo si los errores se distribuyen de forma normal. En el caso contrario, se hace uso del método generalizado de momentos. Para el análisis de esta investigación, los errores se distribuyen normal, por lo que se utilizará la estimación por máxima

verosimilitud.

A continuación, se presentan los resultados de las cuatro regresiones descritas anteriormente, pero esta vez estimadas por el modelo de máxima verosimilitud, para los años 2015, 2016, 2017, 2018 y 2019. Como se logra ver, en la Tabla 5.6 se observa la estimación del efecto de los desastres naturales, medido a través del número de afectados, sobre el Índice de Desarrollo humano y el PIB per cápita para los años de estudio. De aquí, se puede desprender un resultado significativo y positivo para el año 2015, donde la variación en un 1 % de los afectados aumenta el Índice de Desarrollo Humano en 0,461 % . Mientras que para los años siguientes este resultado no es estadísticamente significativo y además cambia la dirección del efecto.

Junto con esto, las variables explicativas adicionales muestran variados resultados. Con respecto a la mortalidad infantil, esta muestra resultados negativos y significativos para todo el período estudiado. Mientras que para el caso de la variable de migración, esta muestra resultados positivos y significativos para los dos primeros años, dejando de ser significativo para los años 2017, 2018, 2019. Finalmente, la variable que controla por densidad población, solo presenta resultados significativos para el año 2019, siendo este un efecto negativo sobre el Índice de Desarrollo Humano.

Si bien la estimación no presenta resultados significativos para la mayoría de los años, si define la presencia de autocorrelación espacial positiva a través del índice ρ , el cual resulta ser estadísticamente significativo para todos los años estudiados, confirmando la existencia de autocorrelación espacial en el modelo seleccionado.

Por otro lado, con respecto al modelo estimado utilizando como variable dependiente el PIB per cápita, se logra observar un efecto positivo y estadísticamente significativo, donde el aumento en un 1 % de los afectados, impacta positivamente en el PIB per cápita en un 3,6 % en promedio. Mientras que para los años siguientes no se observan resultados estadísticamente significativos, pero sí negativos para la mayoría de los años.

Con respecto a las variables explicativas utilizadas, se logra observar una situación similar al modelo utilizando el Índice de Desarrollo Humano como variable dependiente. La mortalidad infantil tiene un efecto negativo y significativo en el PIB per cápita para todos los años y la migración es positiva y significativa solo para los años 2015 y 2016. Mientras que la variable de densidad poblacional no es significativa para ninguno de los años.

Variables	HDI					PIB				
	2015	2016	2017	2018	2019	2015	2016	2017	2018	2019
Afectados	0.00461** (0.00226)	0.000435 (0.00184)	-0.00144 (0.00163)	-0.00203 (0.00204)	0.00110 (0.00274)	0.0360** (0.0163)	-0.0172 (0.0145)	-0.00708 (0.0131)	-0.0188 (0.0201)	0.0152 (0.0255)
Mortalidad infantil	-0.885*** (0.0857)	-0.885*** (0.102)	-0.891*** (0.105)	-0.906*** (0.112)	-0.925*** (0.116)	-3.997*** (0.624)	-3.303*** (0.831)	-3.802*** (0.854)	-3.738*** (0.960)	-4.135*** (1.084)
Migración	0.701*** (0.265)	0.687** (0.285)	0.275 (0.243)	-0.0594 (0.144)	0.178 (0.139)	5.235*** (1.951)	4.501** (2.210)	1.645 (1.874)	0.207 (1.078)	0.666 (1.163)
Densidad poblacional	-0.00065 (0.00062)	-0.00058 (0.00065)	-0.00089 (0.00068)	-0.00012 (0.00081)	-0.00014** (0.00066)	-0.000584 (0.000452)	-0.000388 (0.000525)	-0.000662 (0.000560)	-0.000530 (0.000652)	-0.00100 (0.000614)
Constante	-0.185*** (0.0366)	-0.150*** (0.0297)	-0.130*** (0.0344)	-0.115*** (0.0340)	-0.128*** (0.0338)	9.930*** (0.258)	10.21*** (0.198)	10.27*** (0.240)	10.31*** (0.206)	10.27*** (0.242)
ρ	0.664*** (0.0994)	0.599*** (0.126)	0.609*** (0.118)	0.597*** (0.139)	0.642*** (0.119)	0.653*** (0.124)	0.416** (0.202)	0.462*** (0.179)	0.287 (0.283)	0.520** (0.222)
σ^2	0.00169*** (0.000502)	0.00211*** (0.000629)	0.00230*** (0.000684)	0.00235*** (0.000706)	0.00228*** (0.000685)	0.0860*** (0.0261)	0.119*** (0.0351)	0.134*** (0.0396)	0.145*** (0.0423)	0.154*** (0.0476)
Observaciones	25	25	25	25	25	25	25	25	25	25

Standard errors in parantheses

***p<0.01, ** p<0.05, *p<0.1

Tabla 5.6: Modelo de Error Espacial - Afectados. Fuente: Elaboración propia

Al igual que en el análisis anterior, se confirma la presencia de autocorrelación espacial a través del coeficiente ρ para todos los años.

En la Tabla 5.7, se presentan los resultados del impacto de los desastres naturales, esta vez medido mediante el número de fallecidos, sobre el Índice de Desarrollo humano y el PIB per cápita.

Para el caso del Índice de Desarrollo Humano, como se logra observar, no se obtienen resultados estadísticamente significativos para ninguno de los años de estudio. Con respecto a las variables de control, se ve que la mortalidad infantil tiene un efecto significativo y negativo para todos los años, mientras que la migración es positiva y significativa para los años 2015 y 2016. Finalmente la variable de densidad población es negativa y significativa para los años 2015 y 2019.

Con respecto al efecto del número de fallecidos sobre el PIB per cápita, no se observa un impacto significativo para ninguno de los años analizados. En cuanto a las variables explicativas incluidas en el modelo, se puede ver que los efectos son similares a los observados en el modelo anterior, la mortalidad infantil presenta un efecto negativo y significativo para todo el período, la migración es significativa y positiva solo para el primer año y la densidad poblacional es significativa y negativa para el año 2015.

Si bien la estimación tampoco presenta resultados significativos en el efecto del número de fallecidos sobre el PIB per cápita, si define la presencia de autocorrelación espacial positiva a través del índice ρ , el cual resulta ser estadísticamente significativo para todos los años estudiados, confirmando la existencia de autocorrelación espacial en el modelo seleccionado.

En resumen, no se obtienen resultados estadísticamente significativos en el impacto del número de fallecidos y afectados sobre el PIB per cápita y el Índice de Desarrollo Humano, pero si se confirma la presencia de autocorrelación espacial en cada uno de los modelos y años analizados, confirmando la hipótesis inicial.

Variables	HDI					PIB				
	2015	2016	2017	2018	2019	2015	2016	2017	2018	2019
Fallecidos	0.00149 (0.00462)	0.00218 (0.00568)	-0.00500 (0.00457)	-0.00462 (0.00688)	0.00585 (0.00618)	0.0429 (0.0328)	0.0207 (0.0462)	-0.0272 (0.0377)	-0.0189 (0.0605)	0.0627 (0.0530)
Mortalidad infantil	-0.846*** (0.0929)	-0.903*** (0.118)	-0.868*** (0.111)	-0.903*** (0.123)	-0.935*** (0.107)	-3.754*** (0.675)	-3.880*** (0.963)	-3.644*** (0.919)	-3.952*** (1.042)	-4.196*** (0.943)
Migración	0.563*** (0.281)	0.654** (0.301)	0.399 (0.271)	-0.0387 (0.144)	0.147 (0.142)	4.146** (2.021)	3.749 (2.291)	2.294 (2.107)	0.455 (1.079)	0.369 (1.178)
Densidad poblacional	-0.000116* (0.00063)	-0.000636 (0.00067)	-0.000782 (0.00067)	-0.000115 (0.00081)	-0.000131** (0.00065)	-0.000880* (0.00048)	-0.000574 (0.00056)	-0.000584 (0.00056)	-0.000581 (0.00069)	-0.000878 (0.00058)
Constante	-0.143*** (0.0315)	-0.147*** (0.0289)	-0.136*** (0.0311)	-0.122*** (0.0352)	-0.133*** (0.0336)	10.17*** (0.218)	10.16*** (0.207)	10.23*** (0.216)	10.25*** (0.228)	10.24*** (0.238)
ρ	0.631*** (0.110)	0.605*** (0.125)	0.586*** (0.126)	0.611*** (0.131)	0.646*** (0.114)	0.599*** (0.143)	0.513*** (0.190)	0.426** (0.202)	0.388* (0.233)	0.521*** (0.185)
σ^2	0.00201*** (0.000597)	0.00210*** (0.000625)	0.00230*** (0.000683)	0.00238*** (0.000714)	0.00221*** (0.000662)	0.0995*** (0.0300)	0.120*** (0.0362)	0.135*** (0.0398)	0.146*** (0.0430)	0.148*** (0.0446)
Observaciones	25	25	25	25	25	25	25	25	25	25

Standard errors in parantheses

***p<0.01, ** p<0.05, *p<0.1

Tabla 5.7: Modelo de Error Espacial - Fallecidos. Fuente: Elaboración propia

5.3. Discusión

Como se pudo observar, los resultados obtenidos en cuanto a la presencia de autocorrelación espacial son efectivamente los esperados. Se confirma la existencia de dependencia espacial en el impacto de los desastres naturales entre países a través del Modelo de Error Espacial, describiendo una relación positiva y estadísticamente significativa. Esto indica que países colindantes se ven afectados de forma similar ante la ocurrencia de una catástrofe natural y esto a su vez impacta también en el nivel de bienestar social del país vecino.

Con respecto a la metodología aplicada, se utilizan datos de carácter transversal, donde el efecto de los desastres se mide a través de la magnitud de este en cuanto al número de fallecidos y afectados. Aquí, el impacto no presenta una dirección clara en el movimiento del efecto, ni tampoco significancia estadística, lo cual es contrario a lo esperado, ya que la evidencia muestra que países que residen en regiones más vulnerables como lo es Latinoamérica y El Caribe, tendrán un efecto negativo en el corto plazo en sus índices de bienestar social.

Lo anterior, podría explicarse debido a que el análisis realizado es de corte transversal, es decir, se examina el efecto a lo largo de un mismo año. Las variables que miden el bienestar social tales como el Índice de Desarrollo Humano y el PIB per cápita, tienden a ser variables económicas que muestran variaciones significativas en el largo plazo, por lo que es complejo encontrar efectos relevantes sobre estas cuando el período a analizar es de un año.

Cabe destacar que a lo largo de la investigación, se realizó un análisis de datos de panel, el cual tampoco presentó resultados significativos. Esto podría indicar que la construcción de la variable asociada a magnitud del desastre podría no ajustarse totalmente a los datos disponibles. Lo anterior, resulta ser una limitante, debido principalmente a que el registro de desastres naturales presentados por el Centro de Investigación sobre la Epidemiología de los Desastres (CRED) no posee la geolocalización exacta de todos los desastres reportados. Al utilizar datos específicos como la latitud y longitud del desastre, se podrían observar diversos efectos ligados a la ubicación exacta de cada catástrofe, generando una variable que logre plasmar de mejor manera la magnitud del desastre.

En cuanto a los resultados esperados, si bien desde una perspectiva tradicional los datos no mostraron resultados significativos para el efecto de los desastres naturales sobre el bienestar social, sí se comprobó la existencia de autocorrelación espacial en el modelo estimado. Esto permite indicar que el impacto que producen los desastres naturales a nivel país, efectiva-

mente impactan en cierta medida a los países colindantes.

El desarrollo de un análisis de esta índole es más bien exploratorio y podría traer consigo una serie de limitaciones que estén sesgando el resultado obtenido. Como se mencionaba anteriormente, la medición de la magnitud del desastre a través del número de fallecidos y afectados podría tener una implicancia importante, debido a que pueden existir muchos desastres pequeños que involucren a muchos individuos por país o también un desastre muy grande que afecte a la misma cantidad de personas. Sumado a lo anterior, la alta diversidad geográfica entre países y la estrechez en el número de observaciones, propia en este tipo de análisis, también podrían estar jugando un papel importante en los resultados alcanzados.

6. Conclusiones

El desarrollo de esta investigación buscaba estudiar el impacto de los desastres naturales sobre el bienestar social, específicamente el PIB per cápita y el Índice de Desarrollo Humano desde una perspectiva econométrica espacial en Latinoamérica. Junto con esto, se exploró la existencia de autocorrelación espacial entre países, que lograra identificar algún patrón donde el impacto del desastre natural ocurrido en un país en particular, también afectara a los países colindantes a este. Los resultados encontrados indican presencia de autocorrelación espacial, más fuerte identificada a través del Índice de Desarrollo Humano, donde países con niveles de HDI más altos, son colindantes de países con niveles de HDI similares.

En cuanto al impacto de los desastres naturales sobre las medidas de bienestar social, prácticamente no se encontraron resultados significativos, siendo esto contrario a la evidencia existente. La literatura indica que, en el corto plazo, los países se ven afectados de forma negativa ante los desastres naturales. Además, países en desarrollo, como los situados en la región de Latinoamérica y El Caribe, tienden a verse más afectados debido a su posición de vulnerabilidad previa.

El resultado de lo anterior podría explicarse debido a que el estudio utiliza datos transversales, es decir, analiza los impactos de los desastres naturales sobre el bienestar social en un mismo año. Variables como el Índice de Desarrollo Humano y el PIB per cápita, tienden a ser variables macroeconómicas de largo plazo, por lo que sería complejo observar el efecto estudiado de manera inmediata.

La utilización de datos a nivel de país resulta bastante útil para obtener una visión general del panorama, pero puede traer consigo limitaciones como el bajo número de observaciones. Esto también, podría provocar una desventaja al momento de analizar los datos de forma espacial, debido a las grandes distancias entre países. Una solución a esto sería trabajar los datos a nivel regional por países, pero sigue siendo complejo acceder a datos económicos y sociales con ese nivel de desagregación.

El análisis econométrico espacial juega un rol fundamental en la incorporación de elementos geolocalizados para el desarrollo de estudios económicos. Si bien es una metodología muy útil, su uso sigue siendo reciente en comparación al uso de un enfoque tradicional. Es por esto, que es fundamental la exploración de esta rama de la econometría, la cual permitiría obtener resultados importantes para la toma de decisiones y reconocer patrones de comportamiento

entre países que evidencien el impacto, no sólo de desastres naturales, si no que de otro tipo de fenómenos, ya sean sociales, culturales y económicos.

La investigación en el área de desastres naturales es fundamental para el reconocimiento de patrones de comportamiento y confrontación entre países. Con una mayor información disponible acerca de las posibles consecuencias e impactos que estos conllevan, es factible el desarrollo de políticas de prevención que tengan efectos significativos en la población y en los organismos encargados de gestionar el riesgo de catástrofe. De esta forma, se espera que la expansión de esta área de estudio logre contribuir de manera positiva en el desarrollo de nuevas tecnologías y medidas que velen por el bienestar social.

El estudio de los efectos de los desastres naturales es especialmente relevante en un país como Chile, el cual se caracteriza por ser una región altamente vulnerable a este tipo de catástrofes. Sequías, terremotos, precipitaciones, entre otros, son escenas recurrentes en nuestro país, siendo fundamental la gestión pública como herramienta preventiva. Para esto, es esencial conocer los territorios de forma particular, identificar los desastres más recurrentes y generar políticas que permitan enfrentar las contingencias de forma rápida y eficaz, disminuyendo el efecto social del impacto generado y atendiendo el bienestar de la población.

Es por esto, que es fundamental construir herramientas que permitan a las autoridades tomar decisiones y generar políticas transversales, en respuesta a las necesidades particulares de cada región. Es importante que la elaboración de lineamientos estratégicos que generen acciones concretas preventivas estén respaldadas por investigaciones desde diversas áreas de estudio. De esta manera, se esperaría aprender de situaciones pasadas, con el objetivo de enfrentar el desastre de la mejor manera.

Este estudio también tiene como objetivo contribuir al desarrollo y difusión de la econometría espacial, ofreciendo una visión innovadora en el uso de datos espaciales. La utilización de este tipo de técnicas econométricas podría permitir el desarrollo de políticas públicas que requieran de la identificación de regiones claves, incluso más allá de los desastres naturales, sino que también asociadas al mercado del trabajo, la educación, la salud, entre otras áreas.

Referencias

- Anselin, L. (1988). *Spatial Econometrics: Methods and Models*. (Studies in operational regional science).
- Aponte, L. A. G. and Meisel, A. (2010). Persistencia de las desigualdades regionales en Colombia: Un análisis espacial. (120).
- Barrientos-Marín, J., Ospina-Valencia, S., and Giraldo-Flórez, S. (2020). El costo económico de los desastres naturales: el caso del tsunami y la emergencia nuclear en Japón en 2011. *Lecturas de Economía*, pages 225 – 260.
- Bravo, P. (2021). Autocorrelación espacial - Índices para determinar su presencia en datos geográficos: Una breve revisión de la literatura. *Revista Científica de Ciencias Sociales y Humanas*.
- Bănică, A., Kourtit, K., and Nijkamp, P. (2020). Natural disasters as a development opportunity: a spatial economic resilience interpretation. *Review of Regional Research: Jahrbuch für Regionalwissenschaft*, 40(2):223–249.
- Cavallo, E., Galliani, S., Noy, I., and Pantano, J. (2020). *Catastrophic Natural Disasters and Economic Growth*. 95:1549–1561.
- de Corso Sicilia, G., Pinilla Rivera, M., and Gallego Navarro, J. (2017). Métodos gráficos de análisis exploratorio de datos espaciales con variables espacialmente distribuidas. *Cuadernos Latinoamericanos de Administración*.
- Galilea, S. (2021). Cambio climático y desastres socio-naturales. el caso del Área metropolitana de Santiago. *Instituto de Asuntos Públicos. Universidad de Chile*.
- Gino Sturla, Eugenio Figueroa, M. S. and Flores, J. (2017). Reducción de emisiones globales de carbono. refinar el cobre en Chile. *Serie de documentos de trabajo. Universidad de Chile*.
- González, F. I. (2021). Desastres naturales y crecimiento económico: una síntesis de la evidencia empírica. *Nóesis. Revista De Ciencias Sociales*, 31(61):155–173.
- González, F. I., Santos, M. E., and London, S. (2020). Desastres naturales y crecimiento económico: evidencia para distritos de Argentina.
- Herrera-Gómez, M. (2015). *Econometría espacial usando stata. breve guía aplicada para datos de corte transversal*. (13).

- Lee, D., Zhang, H., and Nguyen, C. (2018). The economic impact of natural disasters in pacific island countries: Adaptation and preparedness. 108:225 – 260.
- Luc Anselin, Anil K. Bera, R. F. and Yoon, M. J. (1996). Simple diagnostic tests for spatial dependence. *Regional Science and Urban Economics*.
- López, R. and Belmar, C. (2022). Desastres naturales y crecimiento. modelos var y panel var bayesianos aplicados al estudio de los efectos sobre las economías. *Universidad de Chile, Mimeo*.
- Morales-Oñate, V. and Morales, B. (2019). Innovación en ecuador: un enfoque espacial. pages 321–331.
- Muñetón, G. and Vanegas, J. (2014). Análisis espacial de la pobreza en antioquia, colombia. 21:29 – 47.
- OCHA (2023). Panorama de los desastres en américa latina y el caribe. *Oficina de Naciones Unidas para la Reducción del Riesgo de Desastres (UNDRR)*.
- Panwar, V. and Sen, S. (2019). Economic impact of natural disasters: An empirical re-examination. *Margin: The Journal of Applied Economic Research*, 13(1):109–139.
- Rodriguez-Oreggia, E., De La Fuente, A., De La Torre, R., and Moreno, H. (2012). Natural disasters, human development and poverty at the municipal level in mexico. *The Journal of Development Studies*, 49(3):442–455.
- Saldaña-Zorrilla, S. and Sandberg, K. (2009). Spatial econometric model of natural disaster impacts on human migration in vulnerable regions of mexico. *Journal compilation. Overseas Development Institute*, 33:591–607.
- Serrano, M., Vayá, R., and Valcarce, E. (2002). Econometría espacial: nuevas técnicas para el análisis regional. una aplicación a las regiones europeas. *Investigaciones Regionales - Journal of Regional Research*.
- Siabato, W. and 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.
- Sánchez-Peña, L. (2012). Alcances y límites de los métodos de análisis espacial para el estudio de la pobreza urbana. *Papeles de Población*.

7. Anexos

7.1. Anexo 1: Modelo de Durbin

Variables	HDI					PIB				
	2015	2016	2017	2018	2019	2015	2016	2017	2018	2019
Afectados	0.00345 (0.00323)	-0.00159 (0.00236)	-0.00256 (0.00262)	-0.00641*** (0.00187)	-0.00094*** (0.00367)	0.0270 (0.0209)	-0.0244 (0.0153)	-0.0118 (0.0174)	-0.0310** (0.0142)	0.0192 (0.0247)
W_x	-0.00872** (0.00401)	-0.000127 (0.00353)	-0.00302 (0.00352)	-0.00971*** (0.00261)	-0.000405*** (0.00464)	-0.0616** (0.0260)	0.00208 (0.0231)	-0.0162 (0.0232)	-0.0564*** (0.0199)	-0.0390 (0.0314)
Mortalidad infantil	-0.859*** (0.137)	-0.741*** (0.142)	-0.765*** (0.152)	-0.925*** (0.111)	-0.794*** (0.184)	-3.745*** (0.887)	-2.690*** (0.917)	-3.219*** (1.000)	-4.088*** (0.848)	-3.990*** (1.245)
Migración	1.118*** (0.417)	1.009** (0.394)	0.581* (0.340)	-0.317** (0.142)	0.174 (0.191)	6.792** (2.792)	5.347** (2.520)	2.683 (2.205)	-1.399 (1.080)	0.522 (1.287)
Densidad poblacional	-0.00052 (0.00094)	0.00051 (0.00086)	0.00048 (0.00091)	-0.000186** (0.00079)	-0.000231 (0.00096)	0.000157 (0.000614)	0.000116 (0.00055)	0.000945 (0.000605)	-0.00119** (0.000602)	-0.000416 (0.000647)
Constante	-0.00853 (0.0790)	-0.104* (0.0544)	-0.0775 (0.0628)	0.0669 (0.0479)	-0.0741 (0.0632)	8.048*** (1.444)	8.956*** (1.708)	9.175*** (1.776)	10.39*** (1.599)	9.095*** (1.744)
ρ	0.351*** (0.123)	0.225* (0.136)	0.224 (0.147)	0.250** (0.110)	0.284** (0.144)	0.246 (0.160)	0.119 (0.175)	0.108 (0.185)	0.0581 (0.164)	0.128 (0.185)
σ^2	0.00289*** (0.000825)	0.0034*** (0.00095)	0.00374*** (0.00106)	0.00196*** (0.00056)	0.00412*** (0.0012)	0.123*** (0.0349)	0.142*** (0.0402)	0.166*** (0.0470)	0.114*** (0.0323)	0.189*** (0.0535)
Observaciones	25	25	25	25	25	25	25	25	25	25

Standard errors in parantheses

***p<0.01, ** p<0.05, *p<0.1

Anexo 1.1: Modelo de Durbin - Afectados. Fuente: Elaboración propia

Variables	HDI					PIB				
	2015	2016	2017	2018	2019	2015	2016	2017	2018	2019
Fallecidos	0.00055 (0.00662)	-0.00559 (0.00653)	-0.0154** (0.0064)	-0.0161** (0.00787)	0.00555 (0.00870)	0.0281 (0.0420)	-0.0241 (0.0445)	-0.0861** (0.0423)	-0.0649 (0.0530)	0.0659 (0.0585)
W_x	-0.00566 (0.0114)	0.00239 (0.00959)	-0.0154* (0.00934)	-0.0250* (0.0149)	-0.00250 (0.00995)	-0.103 (0.0726)	-0.0303 (0.0647)	-0.121** (0.0617)	-0.163** (0.0899)	-0.0864 (0.0669)
Mortalidad infantil	-0.762*** (0.149)	-0.716*** (0.149)	-0.730*** (0.143)	-0.868*** (0.152)	-0.828*** (0.173)	-3.357*** (0.950)	-2.936*** (1.010)	-3.159*** (0.934)	-3.386*** (1.021)	-3.878*** (1.158)
Migración	0.791* (0.432)	1.045*** (0.395)	0.858** (0.337)	0.0297 (0.150)	0.111 (0.199)	4.650* (2.745)	5.185* (2.659)	4.173* (2.178)	0.393 (1.007)	0.103 (1.333)
Densidad poblacional	0.000276 (0.00087)	0.000581 (0.00084)	0.000602 (0.00083)	0.000256 (0.00086)	0.00013 (0.00097)	0.000977 (0.00055)	0.000765 (0.00056)	0.000134 (0.000545)	-0.000241 (0.000583)	-0.000161 (0.000647)
Constante	-0.0737 (0.0589)	-0.110** (0.0508)	-0.0953* (0.0529)	-0.0955* (0.0529)	-0.0903 (0.0573)	8.411*** (1.551)	8.928*** (1.683)	10.43*** (1.759)	11.30*** (2.100)	8.864*** (1.722)
ρ	0.300*** (0.131)	0.246* (0.134)	0.143 (0.143)	0.0756 (0.182)	0.274* (0.141)	0.183 (0.167)	0.116 (0.177)	-0.0112 (0.183)	-0.0970 (0.214)	0.138 (0.182)
σ^2	0.00354*** (0.00101)	0.00330*** (0.00094)	0.00314*** (0.000889)	0.00321*** (0.000909)	0.00410*** (0.00117)	0.143*** (0.0407)	0.153*** (0.0433)	0.138*** (0.0390)	0.146*** (0.0412)	0.185*** (0.0525)
Observaciones	25	25	25	25	25	25	25	25	25	25

Standard errors in parantheses

***p<0.01, ** p<0.05, *p<0.1

Anexo 1.2: Modelo de Durbin - Fallecidos. Fuente: Elaboración propia