

# Distribución espacial del Índice de Rezago Social en los municipios de México

Spatial distribution of the Social Backwardness Index in the municipalities of Mexico

Roberto Carlos Rodríguez-Soto<sup>1</sup>

<sup>1</sup>Universidad de Guanajuato, México  
rc.rodriguezoto@ugto.mx<sup>1</sup>

## Resumen

El presente trabajo pretende describir la distribución espacial del Índice de Rezago Social (IRS), medida proporcionada por el Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL) para los 2469 municipios de México durante el año 2020. Haciendo uso de herramientas propias del campo de la econometría espacial y de la metodología *LISA* propuesta por Luc Anselin (1995) se concluye que en México la pobreza, entendida a través de IRS, no sigue una distribución aleatoria, sino que esta tiende a concentrarse en *focos de pobreza*: A través de un análisis estadístico detallado se mostró que el IRS sigue una autocorrelación espacial positiva (Índice de Moran de 0.687, significativo a un *pseudo* p-valor  $\leq 0,001$ ). El mismo análisis permitió la identificación de 411 *clusters* de rezago social de alta intensidad (AA) y 7 *islas de pobreza* (AB), ambos casos significativos a un *pseudo* p-valor  $\leq 0,05$ .

**Palabras clave:** Índice de Rezago Social; análisis espacial; pobreza; autocorrelación espacial; *clustering*

## Introducción

El uso y la inclusión de modelos espaciales dentro de la econometría *mainstream* es una tendencia que ha visto un importante crecimiento durante los últimos años, debido en buena parte al crecimiento en el volumen de datos geo-referenciados disponibles y al desarrollo de tecnología amigable que permite manipular estos datos a través de los sistemas de información geográfica. De igual manera, otro cambio importante que ha intensificado el interés por la perspectiva espacial es el cambio en los enfoques teóricos dentro del *mainstream economics*, enfoques que han transferido el interés sobre el comportamiento por separado de los agentes hacia la comprensión de la interacción entre los agentes (Anselin 2010).

Los modelos espaciales se caracterizan por prestar atención a la localización de las observaciones y por caracterizar la interacción entre las mismas. De manera formal, los modelos espaciales “expresan interacción espacial al incluir variables observadas en otras localizaciones dentro de la especificación de la regresión” (Anselin 2021). Estos modelos se han desarrollado principalmente dentro de la rama de la econometría conocida como econometría espacial. La econometría espacial es definida como el “subconjunto de métodos econométricos que se ocupa de los aspectos espaciales presentes en observaciones transversales y espaciotemporales” (Anselin 2006).

El énfasis sobre los aspectos espaciales cobra relevancia cuando se busca establecer posibles relaciones de asociación entre variables de interés que cuentan con información geo-referenciada (dependencia espacial), especialmente cuando dichas variables están relacionadas con problemáticas sociales y económicas como es el caso de la pobreza. El interés por el estudio del aspecto espacial de la pobreza también se ha mostrado en crecimiento, muestra de ello se puede encontrar por parte de la academia (Ver trabajos de Partridge y Rickman 2006; Treviño 2016), pero también por parte de organismos públicos dentro de la esfera política, destacando para México el caso del Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL).

El CONEVAL es un organismo público descentralizado de la Administración Pública Federal que durante más de dos décadas se ha encargado de recabar información acerca de la situación de la pobreza en México, esto con la finalidad de mejorar la toma de decisiones en la materia al coordinar de manera conjunta la evaluación de las políticas y los programas de desarrollo social.

Uno de los indicadores que el CONEVAL presenta de manera periódica, en quinquenios, que se encuentra estrechamente relacionado con la caracterización de la situación de la pobreza en México es el Índice de

Rezago Social (IRS). Este índice es una medida que proporciona el resumen agregado de cuatro carencias sociales de la medición de la pobreza del CONEVAL: (1) rezago educativo, (2) acceso a los servicios de salud, (3) acceso a los servicios básicos en la vivienda y (4) la calidad y espacios en la vivienda; para las diferentes desagregaciones geográficas: entidades federativas, municipios y localidades (CONEVAL 2014). Existen dos tipos de IRS, global y longitudinal; el primero busca identificar las áreas territoriales que podrían considerarse prioritarias, en materia de desarrollo social en un momento determinado en el tiempo; el segundo pretende identificar las áreas con alto o muy alto rezago social persistente en el tiempo, es decir, este último permite hacer comparaciones en el tiempo a partir del cambio puntual en el índice.

Como se menciona con anterioridad, gracias a la desagregación geográfica con la que cuenta el índice, es posible identificar las áreas territoriales prioritarias en materia de desarrollo social para la política pública en un momento determinado en el tiempo y con ello caracterizar la distribución de la pobreza en México, entendida a través del rezago social. No obstante, esta desagregación no sólo permite la identificación de la distribución, sino que, en complemento con las técnicas proporcionadas por la econometría espacial, vuelve posible evaluar el rol que juega el componente espacial dentro de la misma distribución del rezago social en México. En otras palabras, a través de los modelos espaciales es posible determinar el papel que juega la geografía dentro de la distribución del rezago social y el tipo de relación guarda con dicha variable, además de ofrecer otras herramientas para medir la intensidad de dicho rezago en determinadas áreas geográficas.

El presente trabajo pretende determinar la distribución geográfica del IRS en los municipios de México para el año 2020 (último año en que CONEVAL hace públicas las estimaciones del IRS para cada uno de los municipios de México), así como identificar el tipo y el grado de asociación espacial entre los municipios, con la finalidad de identificar focos de pobreza que requieran de una atención prioritaria efectiva por parte de los organismos públicos correspondientes.

Para realizar las estimaciones que dictaminarán dichos focos de pobreza se empleará *GeoDa*<sup>1</sup>, un software de código abierto creado por Luc Anselin, un reconocido científico social y geógrafo, conocido ampliamente por ser uno de los principales desarrolladores del campo de la econometría espacial. *GeoDa* es una herramienta amigable y por ello muy utilizada para realizar análisis espaciales. A través de su interfaz permite a los investigadores y analistas explorar patrones espaciales, visualizar datos geo-referenciados y realizar análisis de asociación espacial, también llamado análisis de autocorrelación espacial. La metodología empleada por este software para las estimaciones será discutida en la siguiente sección del trabajo.

## Metodología

La metodología empleada por *GeoDa* para las estimaciones de asociación o dependencia espacial se basa en el enfoque *Local Indicators of Spatial Association (LISA)*, propuesto por primera vez por Luc Anselin en 1995 (*Geographical Analysis Vol. 27*, p. 93-115); esta metodología nos permitirá identificar, además de la distribución espacial del rezago social, dos elementos clave para nuestro trabajo: la magnitud y la intensidad del componente espacial dentro de la variable de interés, siendo en este caso el IRS. La magnitud será entendida como el grado de asociación que guarda la variable de interés en relación a su ubicación geográfica (respecto a la posición de sus vecinos), mientras que la intensidad será entendida a través del grado de significancia estadística local de la variable (de igual manera, en relación a sus vecinos). Más adelante se desarrollarán con mayor detalle los supuestos e implicaciones que guardan ambas características.

Antes de continuar con la metodología para la estimación de la relación espacial y determinar la magnitud e intensidad de dicha relación debemos establecer el grado de relación espacial a través de un indicador de similitud geográfica; es decir, debemos especificar qué significa que un municipio sea *vecino* de otro municipio. A continuación, se desarrollará la metodología para especificar dicha relación.

### Especificación de la interacción espacial

El componente espacial es incorporado dentro de un modelo de regresión al incluir observaciones de variables que se encuentran en otras ubicaciones a través de lo que llamamos una variable rezagada

---

<sup>1</sup> Ver sitio oficial dentro del *CSDS* de la Universidad de Chicago: <https://spatial.uchicago.edu/geoda>

espacialmente, que no es más que el promedio de los valores observados en las localizaciones aledañas a una determinada unidad espacial; pero antes de incluir esta variable es necesario especificar la interacción espacial a través de otra variable que determine lo que implica que una observación sea *vecina* de otra y el peso que tendrá el que dos unidades espaciales sean contiguas.

Las medidas tradicionales empleadas para determinar el grado de asociación espacial (Moran 1948; Geary 1954) estaban basadas en la noción de contigüidad binaria entre unidades espaciales. De acuerdo con este enfoque, la noción de lo que implica que un municipio sea *vecino* de otro estará dada por valores de 0 y 1. Antes es importante aclarar que la definición de contigüidad asume la existencia de un mapa, cuyos bordes pueden ser identificados (cada unidad espacial es entendida como un polígono), a partir de los cuales es posible determinar la existencia o no de contigüidad (Anselin 1988). Podemos denotar la relación entre dos unidades espaciales a través de  $w_{ij}$ , que expresa una relación de vecindad entre las localizaciones  $i$  y  $j$ ; es decir,  $w_{ij}$  representará los pesos espaciales y tomará un valor de 1 cuando exista contigüidad (frontera común entre las unidades espaciales) y de 0 cuando no la haya. Esta definición de contigüidad por frontera común se denomina *queen-based* o de tipo reina, donde cualquier municipio que guarde una frontera común directa con otro municipio será considerado *vecino*.

Los pesos espaciales estarán contenidos dentro de una *matriz de pesos* (también llamada matriz de contigüidad),  $W$ , de tamaño  $n \cdot n$ , siendo  $n$  el número total de observaciones. La matriz de pesos que emplearemos se encontrará estandarizada por filas, lo cual implica que la suma de los pesos será igual a 1, al ser estos promediados. Por convención, cada unidad espacial no puede ser considerada vecina de sí misma, por lo que la diagonal de la matriz de pesos estará conformada por valores iguales a 0.

Ya que nuestro modelo bivariado de regresión pretende identificar la asociación entre el rezago espacial del IRS, es decir, el promedio del rezago social de los vecinos ( $Wx$ ) y el valor de cada observación ( $x$ ) sobre la distribución del IRS ( $y$ ), la especificación de nuestro modelo será la siguiente:

$$y = \beta x + \theta Wx + e$$

La especificación de la variable rezagada espacialmente permitirá la construcción de la medida que caracterizará la magnitud del componente espacial: El índice de Moran. A continuación, se desarrollará la construcción de dicho índice y sus interpretaciones.

### Índice de Moran, Diagrama de dispersión de Moran y *Clusters*

Una vez definida la matriz de pesos y la variable rezagada es posible estimar el grado de asociación o autocorrelación espacial; para ello, se emplea la medida estándar dentro del campo de la econometría espacial: el Índice de Moran, que fue primeramente introducido por Moran (1948) y popularizado por los trabajos de Cliff y Ord (1973) sobre autocorrelación espacial.

El índice de Moran se encuentra definido de la siguiente forma

$$I = \frac{n \sum_i \sum_j w_{ij} z_i \cdot z_j}{S_0 \sum_i z_i^2}$$

Donde  $w_{ij}$  representa los elementos de la matriz de pesos espaciales (matriz de contigüidad),  $S_0 = \sum_i \sum_j w_{ij}$  y  $z_i = x_i - \bar{x}$ , donde  $\bar{x}$  está definida como la media de la variable  $x$ ; es decir,  $z$  representa las desviaciones respecto a la media, en nuestro caso, para el IRS. El número de observaciones está dado por  $n$ .

Cuando trabajamos con una matriz de pesos estandarizada por filas, como es nuestro caso, la suma de todos los pesos,  $S_0$ , es igual al número de observaciones,  $n$ . Como resultado, el Índice de Moran se simplifica:

$$I = \frac{\sum_i \sum_j w_{ij} z_i \cdot z_j}{\sum_i z_i^2}$$

El Índice de Moran, como lo hemos presentado, se conoce como el Índice de Moran Global, que puede tomar valores entre -1 y 1. A partir de éste índice podemos construir otro que refleje los componentes individuales dentro de la suma doble que corresponden a cada  $i$ -ésima observación; este índice se conoce como Índice de Moran Local, mismo que cobrará relevancia dentro de la inferencia estadística a la hora de definir la intensidad de los focos de pobreza más adelante. Por ahora, simplemente definiremos el índice local:

$$I_i = \frac{\sum_j w_{ij} z_i z_j}{\sum_i z_i^2}$$

Una asociación espacial positiva (Índice de Moran > 1) indica que valores similares (ya sean estos altos o bajos) tienden ubicarse de manera contigua; es decir, la distribución del rezago no es aleatoria, sino que, en promedio, municipios con niveles de rezago similar tienden a ser próximos geográficamente. La asociación espacial negativa (Índice de Moran < 1), por otro lado, indica que, en promedio, municipios con características distintas tienden a estar cerca unos de otros; en otras palabras, valores altos de rezago social tienden a estar rodeados de valores bajos, y lo mismo ocurre en sentido opuesto.

Con un poco de examinación podremos notar que el Índice de Moran no es más que la pendiente estimada de la regresión espacial,  $\sum_j w_{ij} z_j$  en  $z_i$ , ya que en una regresión lineal bivariada por mínimos cuadrados,  $y = \alpha + \beta x$ , el estimador  $\beta$  es igual a

$$\frac{\sum_i (x_i \cdot y_i)}{\sum_i x_i^2}$$

Por lo anterior, es posible representar dicho índice en combinación con las observaciones espaciales a través de un diagrama de dispersión, donde el papel de  $y$  es tomado por el rezago espacial  $\sum_j w_{ij} z_j$ ; dicho diagrama se conoce popularmente como Diagrama de Moran y es una potente herramienta para clasificar la asociación espacial en dos categorías: aglomeraciones espaciales (*clusters*) y casos atípicos (Para más detalles ver Anselin 2019b). Cada cuadrante dentro del diagrama representa un tipo de autocorrelación espacial. A continuación, se presenta un diagrama que resume lo que implica que una observación se ubique dentro de cada uno de dichos cuadrantes.

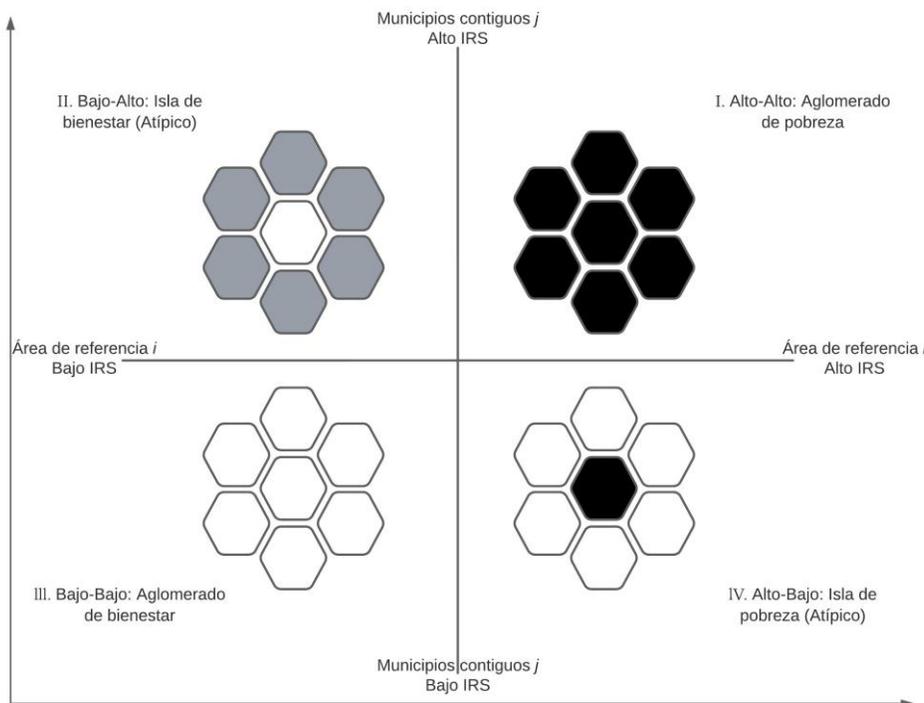


Figura 1. Interpretación del Diagrama de Moran. Elaboración propia en base a Anselin (1995), siguiendo el diagrama propuesto por Treviño (2016).

Las observaciones ubicadas dentro de los cuadrantes I y III corresponden a las aglomeraciones espaciales (*clusters*), donde el primero representa aquellos casos donde un municipio con alto IRS está rodeado de otros municipios con un IRS alto (AA) y el segundo representa el caso donde un municipio con un IRS bajo está rodeado por otros municipios con un IRS bajo (BB). Las observaciones ubicadas dentro de los cuadrantes II y IV corresponden a casos atípicos, donde el primero representa el caso en que un municipio con un IRS bajo se encuentra rodeado por municipios con un IRS alto (BA) y el segundo representa aquellos casos donde un municipio con un IRS alto se encuentra rodeado por municipios con un IRS bajo (AB).

La anterior clasificación por *clusters* y atípicos nos permite identificar los focos de pobreza como aquellos *clusters* o aglomeraciones espaciales del tipo AA, es decir, dentro del cuadrante I. En caso de existir una asociación espacial positiva, esperaremos que un importante número de observaciones se encuentre dentro de este sector. Ahora, determinar la magnitud de la relación espacial (sea esta positiva o negativa) no implica que en mayor medida todas aquellas observaciones sean significativas desde un punto de vista estadístico. Es por ello que será necesario establecer la intensidad o significancia de dichas aglomeraciones. Para ello, partiendo del Índice de Moran Local, es posible llevar a cabo un análisis a través del método de permutación condicional (Anselin 1995). Dicho método permitirá la estimación de un *pseudo* p-valor para cada localización en la muestra. Es importante señalar que este mecanismo combinado con la información del Diagrama de Moran permitirá clasificar la significancia de las unidades espaciales a través de la misma clasificación presentada con anterioridad para los *clusters* y atípicos. En otras palabras, podremos determinar cuáles de los *clusters* AA y BB, así como de los atípicos AB y BA, pueden ser considerados como estadísticamente significativos. Además, podemos representar la información generada de las permutaciones a través de un mapa, donde nos enfocaremos especialmente en aquellos *clusters* del tipo AA que sean considerados relevantes estadísticamente, al tratarse de focos de pobreza (aglomerados de pobreza).

Ya que hemos concluido con las principales notas sobre metodología que será empleada por *GeoDa* para las estimaciones, es momento de que se presenten los principales resultados y hallazgos dentro de la caracterización espacial del IRS para los municipios de México en 2020.

## Resultados

### Distribución Espacial y Resultados de la Regresión

A través de un mapa podemos apreciar la distribución del IRS por quintiles para cada uno de los 2469 municipios que conforman la muestra<sup>2</sup> (ver Figura 2); a simple vista podemos notar que de manera general las regiones Sur, Occidente y Noroeste (especialmente aquellos municipios que se ubican dentro la Sierra-Madre Occidental) parecen concentrar la mayor parte de los municipios con un Índice de Rezago Social alto o muy alto. Mientras que, por otra parte, las regiones Centro, Centro-Norte y Norte (especialmente aquellos municipios que comparten frontera con Estados Unidos) parecen concentrar el mayor número de municipios con un Índice de Rezago Social bajo o muy bajo. Lo anterior genera indicios sobre la posible presencia de una relación espacial positiva sobre la distribución del IRS a nivel municipal; es decir, este primer acercamiento sugiere que la pobreza en México podría no estar distribuida de forma aleatoria, sino que esta pareciera tender a concentrarse en algunos espacios geográficos determinados (formación de *clusters*).

Para determinar la existencia de dicha relación se calculó el Índice de Moran Global, los resultados serán presentados a continuación.

El Índice de Moran Global ( $I$ ), obtenido al emplear una matriz de contigüidad de tipo reina para evaluar el grado de autocorrelación entre el IRS y su rezago espacial para cada uno de los 2469 municipios de México, rechaza la hipótesis nula de aleatoriedad al mostrar una asociación espacial positiva (adicionalmente se calculó un *pseudo* p-valor  $\leq 0,001$  al realizar 999 permutaciones ante la hipótesis nula de aleatoriedad, con lo cual queda completamente descartada).

El Índice global indica que la pobreza se encuentra espacialmente aglomerada en el país, y en un alto grado de concentración, al contar con un valor positivo igual a  $I = 0.687$  (como puede apreciarse en la Figura 3).

Considerando el alto grado de concentración encontrado, las implicaciones que esto guarda son las siguientes: En México la distribución espacial de la pobreza, entendida a través del IRS, sigue en promedio un patrón del tipo AA, es decir, municipios con un IRS alto tienden a ser contiguos a otros municipios con un IRS alto, lo cual implica una focalización de la pobreza (formación de aglomerados o *clusters* de pobreza); así mismo, podemos agregar que esta distribución también tiende a seguir un patrón del tipo BB, donde municipios con un IRS bajo se encontrarán, en promedio, de manera contigua a otros municipios con un IRS bajo (formación de aglomerados o *clusters* de bienestar).

---

<sup>2</sup> Consultar datos en: [IRS 2020 - anexos \(coneval.org.mx\)](https://coneval.org.mx)

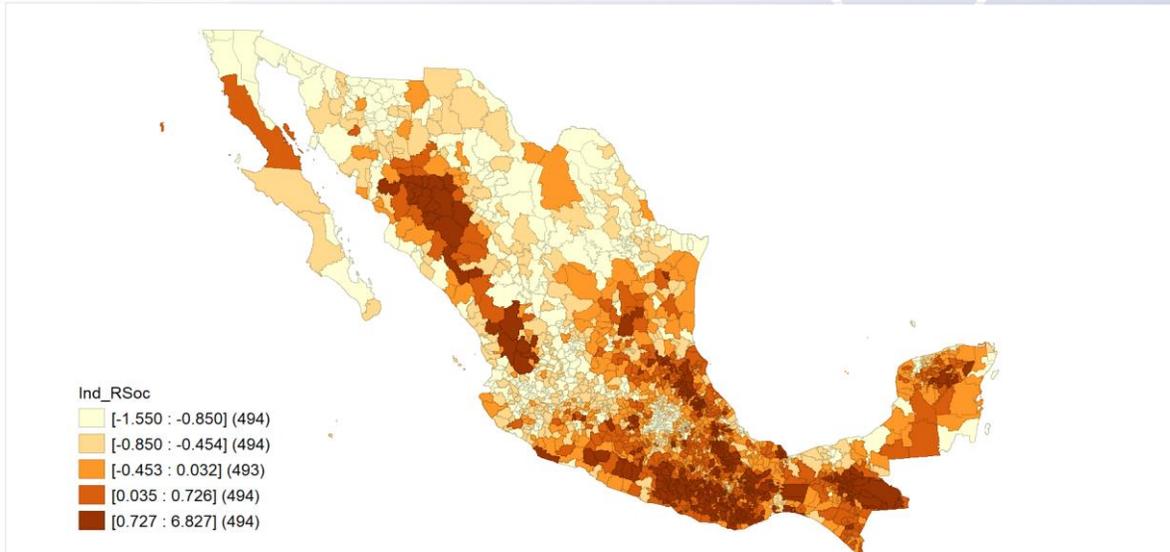


Figura 2. Distribución espacial del IRS en 2020. Elaboración propia con datos del CONEVAL haciendo uso de GeoDa.

El grueso de las observaciones espaciales de la muestra se encontrará, pues, dentro de los cuadrantes I y III, dentro de nuestro Diagrama de Moran, como puede apreciarse en la Figura 3.

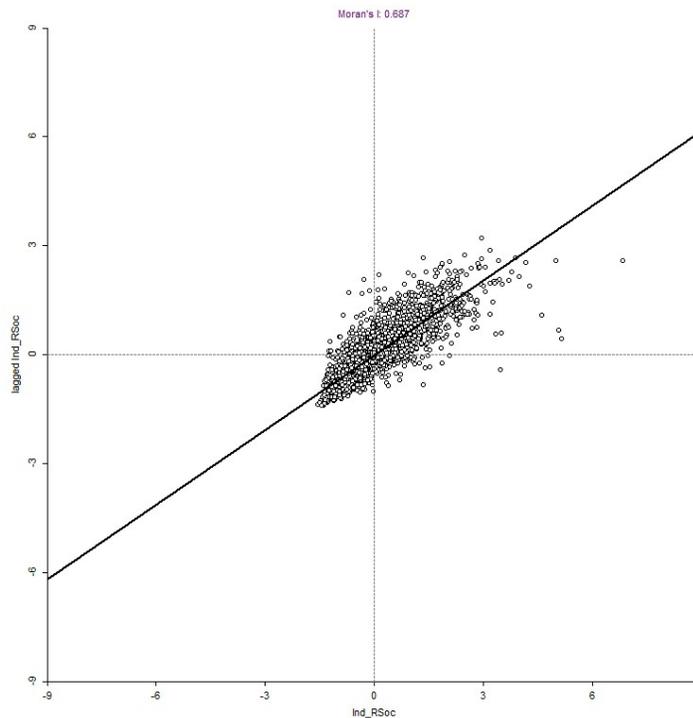


Figura 3. Diagrama de Moran. Elaboración propia con datos del CONEVAL haciendo uso de GeoDa.

Si bien después de nuestras estimaciones hemos descartado de manera global que el IRS siga una distribución aleatoria en México, aún debemos diagnosticar cuales son los focos de pobreza *prioritarios* para su atención, así como descartar *outliers* o datos atípicos que no sean significativos; lo último se vuelve

especialmente relevante cuando los atípicos se ubican dentro del cuadrante IV, pues esto implica una concentración de pobreza dentro de entornos de bienestar. Al examinar literatura previa, Quillian (2012) señalaba que “la separación espacial de los ricos y los pobres produce un desajuste espacial entre la demanda de empleos y los solicitantes de empleo, lo que contribuye al alto desempleo en los barrios más pobres”, de igual manera comentaba que la concentración de *desventajas* en algunos vecindarios “es uno de los predictores más duraderos de altas tasas de delitos violentos”, razones por las cuales vale la pena examinar aquellos atípicos donde se presentan *islas de pobreza*.

Para llevar a cabo el diagnóstico, se realizarán 999 permutaciones por el método de permutación condicional propuesto por Anselin (1995), mismas que determinarán aquellos *clusters* con un mayor grado de significancia estadística a un p-valor  $\leq 0,05$ .

### Significancia (*Clustering*)

En la Figura 4 podemos apreciar la distribución espacial de los *clusters* de pobreza más significativos (focos de pobreza que requieren de una atención prioritaria), así como aquellos *clusters* o aglomerados del bienestar (pertenecientes en su mayoría a la región Norte, aledaña a la Frontera con Estados Unidos, y a los estados pertenecientes a la región Centro y Centro-Norte; destaca el caso de Yucatán y Tabasco, dentro de la región Sur).

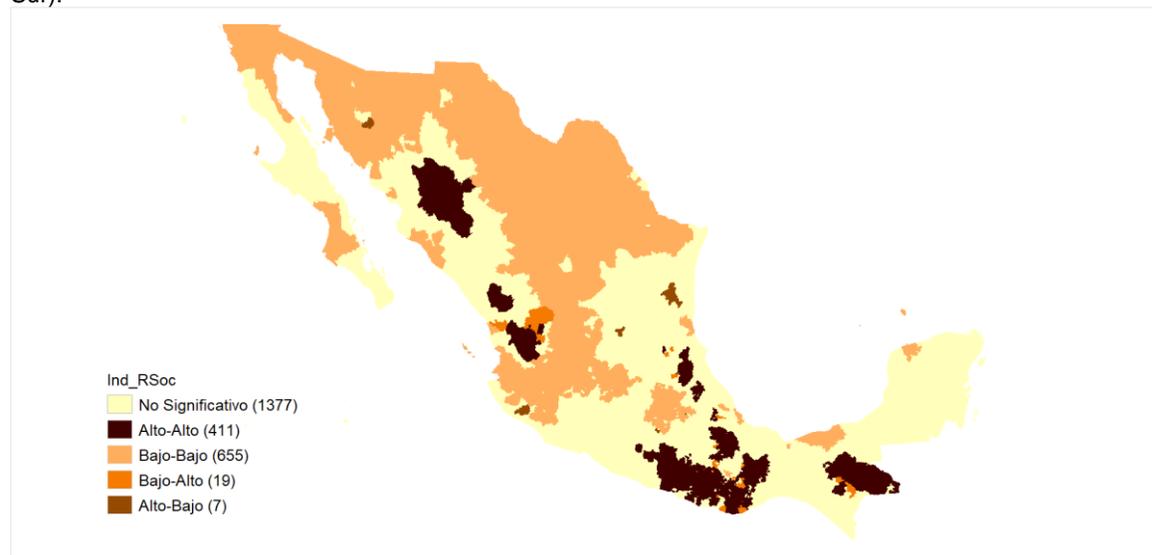


Figura 4. Mapa de significancia Elaboración propia con datos del CONEVAL haciendo uso de GeoDa.

En marrón oscuro y salmón: *Clusters* del tipo AA y BB, respectivamente. En naranja y marrón claro: Atípicos del tipo BA y AB, respectivamente. El resto de las observaciones (1377) resultaron no significativas.

Los principales *focos de pobreza* identificados se ubican dentro de la región Sur y Centro-Sur del país, siendo estos municipios en su mayoría pertenecientes a los estados de Oaxaca, Chiapas y Guerrero para la región Sur y a los estados de Puebla y Veracruz de Ignacio de la Llave para aquellos pertenecientes a la región Centro-Sur.

Otra importante concentración de *focos de pobreza* se da dentro de las regiones Centro-Occidente y Noroeste del país, particularmente en los estados de Jalisco y Nayarit, pertenecientes a la primera, y en los estados de Sinaloa, Durango y Chihuahua, para la segunda.

Finalmente, dentro de la región aledaña al Golfo-Norte, el estado de Hidalgo y el norte del estado de Veracruz presentan otra significativa concentración de pobreza. Es importante destacar que ambos estados comparten frontera común y es alrededor de esta frontera donde se concentra precisamente la pobreza para ambos

casos; destacan los municipios de Huejutla de Reyes, Huehuetla, Xochiatipan (Hidalgo), Ixmiquilpan, Ixcatepec, Ixmiquilpan de Madero y Benito Juárez (Veracruz), por mencionar algunos.

El diagnóstico permitió además la identificación de siete municipios atípicos de carácter AB (islas de pobreza), mismos que se señalan a continuación: En la región Centro y Centro-Norte del país, se identificaron los municipios de La Magdalena de Tlaltelulco (Tlaxcala) Armadillo de los Infante (San Luis Potosí) Coatetelco y Xoxocotla (ambos pertenecientes a Morelos) y Cuautitlán de García Barragán (Jalisco); mientras que en la región Norte se identificaron los municipios de San Miguel de Horcasitas y Casas (pertenecientes a los estados de Sonora y Tamaulipas, respectivamente).

A manera de cierre, se presentará a continuación una serie de conclusiones a las que se llegan a través del uso de la metodología *LISA* (Anselin 1995) para describir la distribución espacial del rezago social en México.

## Conclusiones

Las principales aportaciones que ofrece el presente trabajo son las siguientes:

- De manera global se concluye que la distribución de la pobreza en México, entendida a través del Índice de Rezago Social (IRS), no sigue un patrón aleatorio, ya que fue posible identificar autocorrelación espacial de carácter positivo. Estos resultados son consistentes con los mostrados por Treviño (2016), quien rechazaba la hipótesis nula de distribución aleatoria y a su vez concluía que la pobreza en México sigue un patrón de aglomeración.
- Los anteriores resultados implican que, en promedio, en México aquellos municipios que cuentan un Índice de Rezago Social alto se encontrarán rodeados por otros municipios igualmente rezagados; en otras palabras, se confirma la presencia de *focos de pobreza*.
- El Índice de Moran (0.687), además de confirmar la presencia de *clusters* de pobreza, en combinación con el método de permutación condicional propuesto por Anselin (1995) permitió la identificación de 411 *clusters* de pobreza de alta intensidad y de 7 *islas de pobreza* (ambos casos fueron significativos a un *pseudo* p-valor  $\leq 0,05$ ).
- La mayor parte de los municipios que presentan un alto rezago social se ubican dentro de las regiones Sur, Golfo-Norte, Occidente y Noroeste de la República Mexicana.
- Examinar la magnitud e intensidad de la asociación espacial entre el IRS y su rezago espacial permite identificar *focos de pobreza* que requieren de una atención prioritaria; la metodología propuesta puede tener un impacto significativo dentro de organismos públicos encargados de áreas como el Desarrollo Económico, Social y Humano, ya que permite, mediante la desagregación geográfica de variables socioeconómicas, identificar aquellos municipios que requieren en mayor o menor medida de su atención, así como posibles aglomeraciones de municipios con características similares y datos atípicos.

Adicionalmente, se enlistan algunas consideraciones respecto a los resultados obtenidos:

- Si bien la metodología empleada nos permite un mejor entendimiento de manera global sobre la asociación espacial de la pobreza y generar una jerarquización sobre los municipios que requieren de una atención prioritaria, es importante señalar que esta metodología no es más que una aproximación espacial hacia una problemática que requiere, además, de "ajustes regionales basados en la historia, cultura y economía comunes" (Treviño 2016).
- Como Treviño (2016) también señala, las regiones y los municipios comparten por lo general características naturales similares, factores sociales y otras experiencias en común. El análisis de *clustering* presentado durante la elaboración de resultados muestra un gran número de focos de pobreza (411); esta medida efectivamente es bastante útil para identificar las principales aglomeraciones de pobreza y dictaminar su atención prioritaria; sin embargo, esta medida no incorpora otros factores relevantes como son las características naturales, comunes en un gran número de municipios de México. El problema con esta omisión es que puede generar una situación donde se ignore o excluya a municipios contiguos a un conglomerado de alta intensidad, aún cuando compartan un gran número de características similares y requieran de igual atención.
- Para ejemplificar de mejor manera el punto anterior se incluye un caso de revisión: Chihuahua, estado perteneciente a la región Noroeste de la República cuenta con una de las mayores concentraciones de rezago social dentro de su territorio, particularmente dentro de la llamada Sierra Tarahumara. Los municipios miembros de este espacio territorial cuentan con características naturales similares al estar ubicadas dentro de los puntos más altos y de más difícil acceso dentro de la Sierra-Madre Occidental; de igual manera, los municipios pertenecientes a este territorio

comparten factores sociales comunes como es el origen étnico, ya que dentro de este espacio la mayor parte de la población indígena es de origen Rarámuri (Tarahumara).

A pesar de que 23 municipios integran la región tarahumara, sólo 13 son identificados dentro del *cluster* de mayor intensidad de pobreza (ver Figura 5). Siguiendo la lógica de nuestra metodología, los últimos serían vistos como aquellos que requieren ser atendidos con prioridad; sin embargo, se está dejando fuera de la atención a otros 10 municipios pertenecientes a la misma región y con los que comparten las características muy similares. Por lo anterior, además de realizar el análisis espacial preliminar correspondiente, será “necesario visitar la región y verificar lo que pasa ahí para ver si la inclusión/exclusión de los municipios tiene sustento local” (Treviño 2016).

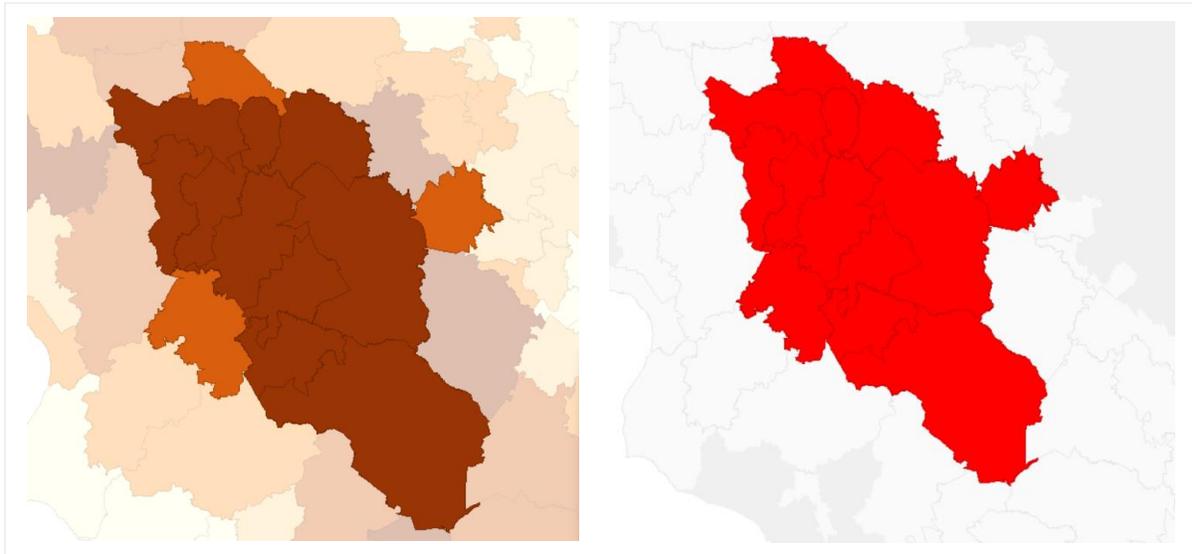


Figura 5. Comparativa entre el IRS real y el clúster identificado como estadísticamente significativo para la misma zona (Chihuahua). Elaboración propia con datos del CONEVAL haciendo uso de GeoDa.

Podemos notar que alrededor del área señalada dentro del *foco de pobreza* de alta intensidad (resaltado en colores más claros a la izquierda y en rojo a la derecha) se ubican municipios con un Índice de Rezago Social igualmente alto (áreas más oscuras, en tonos opacos a la izquierda); sin embargo, el análisis de *clustering* únicamente incluye a 13 municipios y descarta el resto de los municipios aledaños a éste al considerarlos como no significativos (en gris).

El presente trabajo presenta, a través del uso de metodologías y herramientas digitales (*GeoDa*) propias del campo de la econometría espacial y de los estudios regionales, conclusiones relevantes sobre la distribución y concentración de la pobreza en México. De igual manera, se espera que la metodología propuesta en este trabajo pueda ser útil para determinar un orden o jerarquía espacial de atención con el cual se pueda concentrar la atención de las autoridades a través de programas sociales con perspectiva territorial.

No obstante, se extiende la invitación a futuras investigaciones que aborden el tema desde la perspectiva espacial a complementar sus metodologías con un análisis regional cualitativo que incluya dentro de sí una revisión histórica, cultural y comunitaria sobre las características de la población objetivo con la finalidad de no cometer la exclusión injustificada de municipios que requieran de atención por parte de las autoridades competentes y con ello disminuir el número de personas en condición de pobreza que no pueden gozar del acceso a los beneficios de los programas sociales y atender así de manera efectiva el resto de las problemáticas sociales que giran entorno a la pobreza.

## Bibliografía/Referencias

- Anselin, L. (1995). Local Indicators of Spatial Association-LISA. *Geographical Analysis*, 27(2), 93-115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Anselin, L. (2006). Spatial econometrics. In Mills, T. and Patterson, K., editors, Palgrave Handbook of Econometrics: Volume 1, Econometric Theory, pages 901–969. Palgrave Macmillan, Basingstoke.
- Anselin, L. (1988). Spatial Econometrics: Methods and models. En *Studies in operational regional science*. Springer Nature (Netherlands). <https://doi.org/10.1007/978-94-015-7799-1>
- Anselin, L. (2021). Spatial models in econometric research. *ResearchGate*. <https://doi.org/10.13140/RG.2.2.26447.20641>
- Anselin, L. (2019b). The Moran Scatterplot as an ESDA tool to assess local instability in spatial association. En *Routledge eBooks* (pp. 111-126). <https://doi.org/10.1201/9780203739051-8>
- Anselin, L. (2010). Thirty years of spatial Econometrics. *Papers in Regional Science*, 89(1), 3-25. <https://doi.org/10.1111/j.1435-5957.2010.00279.x>
- Consejo Nacional de Evaluación de la Política de Desarrollo Social [CONEVAL]. (2014). *Metodología para la medición multidimensional de la pobreza en México* (segunda edición).
- Getis, A. (1995c). *Cliff, A.D. and Ord, J.K. 1973: Spatial Autocorrelation. London: Pion.* <https://www.semanticscholar.org/paper/Cliff%2C-A.D.-and-Ord%2C-J.K.-1973%3A-Spatial-London%3A-Getis/4521d0130d62dc4cd04bb379da1b36533716ed4b#:~:text=In%201973%2C%20Pio>

n%20published%20A.D.%20Cliff%20and%20J.K.,have%20an%20enormous%20impact  
%20on%20geographical%20data%20analysts.

Instituto Nacional de los Pueblos Indígenas [INPI] & Instituto Nacional de Lenguas Indígenas.

(s. f.). *Tarahumaras – Etnografía*. Atlas de los Pueblos Indígenas de México.

<https://atlas.inpi.gob.mx/tarahumaras-etnografia/>

Moran, P. A. P. (1948). The interpretation of statistical maps. *Journal of the royal statistical society series b-methodological*, 10(2), 243-251. <https://doi.org/10.1111/j.2517-6161.1948.tb00012.x>

Partridge, M. D., & Rickman, D. S. (2006). *The geography of American poverty: Is there a need for place-based policies?*. WE Upjohn Institute.

Quillian, L. (2012). Segregation and poverty concentration. *American Sociological Review*, 77(3), 354-379. <https://doi.org/10.1177/0003122412447793>

Treviño, A. C. J. (2016). Mapa y jerarquía espacial de la pobreza en México. Un nuevo procedimiento para identificar el patrón espacial de los problemas sociales. *Trimestre Económico*, 83(332), 679. <https://doi.org/10.20430/ete.v83i332.236>