

Análisis espacial del delito

Por Luc Anselin, Jacqueline Cohen, David Cook, Wilpen Gorr, y George Tita.

Justicia penal 2000, volumen 4: medición y análisis del delito y la justicia.

El nuevo siglo trae consigo un creciente interés en los lugares donde ocurren los delitos. Este interés abarca tanto la teoría, desde la perspectiva de comprender la etiología del delito, como la práctica, desde el punto de vista de desarrollar intervenciones efectivas de justicia penal para reducir el crimen. No intentamos ofrecer un tratamiento exhaustivo del considerable cuerpo de investigación teórica y empírica sobre los lugares y el delito, sino que nos centramos en las cuestiones metodológicas en los análisis estadísticos espaciales de los datos del crimen. Se presta especial atención a algunos métodos prácticos y accesibles de análisis exploratorio de datos que, posiblemente, deberían ser el punto de partida de cualquier análisis empírico de la relación entre los lugares y el delito.

Muchas de las capacidades para apoyar la cartografía computarizada y los análisis estadísticos espaciales surgieron recientemente, durante la década de 1990. La promesa de utilizar datos y análisis espaciales para el control del delito aún debe ser demostrada y depende de la naturaleza de la relación entre el delito y el lugar. Si las características espaciales actúan como factores desencadenantes para el delito, ya sea debido a las personas que se encuentran allí o a las instalaciones ubicadas en esos lugares, entonces las intervenciones diseñadas para modificar a esas personas y actividades podrían afectar el delito. Por otro lado, si la distribución espacial del crimen es esencialmente aleatoria, entonces, focalizarse en lugares específicos, probablemente no sea una estrategia efectiva de control del delito. Desentrañar la relación entre lugar y crimen requiere métodos analíticos que sean los más adecuados para aislar los impactos del lugar en el delito.

A medida que nos acercamos a finales del siglo XX, el interés por los lugares donde ocurren los delitos continúa creciendo. La identificación de puntos calientes del crimen (Sherman, Gartin y Buerger, 1989) fue quizás un hito al volver a enfocar la atención en las características espaciales/locativas del delito. Este interés abarca tanto la teoría, desde la perspectiva de entender la etiología del crimen, como la práctica, desde el punto de vista de desarrollar intervenciones efectivas de justicia penal para reducir el crimen. Las preocupaciones teóricas se centran en cómo el lugar podría ser un factor en el delito, ya sea influyendo o modelando los tipos y niveles de comportamiento criminal de las personas que frecuentan un área, o atrayendo a un área a personas que ya comparten inclinaciones criminales similares. Estas preocupaciones teóricas, que se abordan hábilmente en una literatura publicada en crecimiento sobre la criminología del lugar, solo se mencionan brevemente en este documento. En su lugar, nos enfocamos en los métodos analíticos más adecuados para aislar el impacto del lugar en el delito.

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Los avances tecnológicos, principalmente en las capacidades de la computadora, son fundamentales para los avances recientes en los métodos disponibles para analizar los datos de criminalidad basados en el lugar. La aparición de aplicaciones de mapeo por computadora y sistemas de información geográfica (SIG) es crucial para poder medir y representar las relaciones espaciales en los datos. Quizás las herramientas analíticas más poderosas que emergen de las tecnologías SIG son (1) capacidades de agregación espacial flexibles para facilitar la medición de la criminalidad basada en el lugar y (2) matrices de contigüidad simples para representar las relaciones de vecindad entre diferentes unidades de área. Además de estos avances analíticos, los sistemas de gestión de registros policiales por computadora y los sistemas de despacho asistidos por computadora (CAD) de llamadas de ciudadanos a la policía hacen posible cuantificar sistemáticamente los diferentes niveles de actividad criminal en diferentes lugares dentro de una ciudad.

El documento que sigue comienza con una breve visión general de algunos enlaces conceptuales entre el lugar y el delito. No intentamos hacer un tratamiento exhaustivo del considerable cuerpo de investigación teórica y empírica sobre este tema. Nuestra intención es simplemente proporcionar un contexto ilustrativo para el enfoque principal del documento: análisis estadísticos espaciales de datos del delito con énfasis especial en preocupaciones pragmáticas sobre cómo se implementan mejor estos análisis. El texto guía a los lectores a través de una variedad de preocupaciones metodológicas relacionadas con el análisis de datos espaciales y de espacio/tiempo. Quizás el servicio más valioso es dirigir a los analistas hacia partes relevantes de una creciente literatura de investigación, con muchas fuentes publicadas recientemente. Se abordan cuestiones complejas, no para advertir a los analistas que se abstengan por completo, sino para fomentar el ejercicio de la debida cautela en la realización e interpretación de los análisis empíricos. Se presta especial atención a algunos métodos prácticos y accesibles de análisis exploratorio de datos que, probablemente, deberían ser el punto de partida de cualquier análisis empírico de la relación entre lugar y delito.

Crimen y Lugar

En esta sección, revisamos brevemente algunos desarrollos teóricos y empíricos en la investigación sobre el crimen y el lugar. Estos se remontan al trabajo de los primeros ecologistas sociales en Francia durante mediados del siglo XIX, pasando por la tradición sociológica que surgió de la Escuela de Chicago a principios del siglo XX, y finalmente al reciente resurgimiento de esta tradición en estudios ecológicos contemporáneos sobre el crimen. La perspectiva de la ecología social evolucionó hacia teorías de crimen más específicamente enfocadas en el lugar, particularmente la teoría de las actividades rutinarias. Las actividades rutinarias que reúnen a posibles delincuentes y oportunidades criminales son especialmente efectivas para explicar el papel del lugar en la promoción o inhibición del crimen.

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Los lugares donde ocurren los delitos resultantes a menudo toman la forma de instalaciones: lugares que las personas frecuentan con un propósito específico, que resultan atractivos para los delincuentes o propicios para la comisión de delitos. Las instalaciones podrían ofrecer una abundancia de oportunidades criminales (por ejemplo, un entorno rico en objetivos para robos o propiedades abandonadas o desprotegidas que podrían usarse para actividades ilícitas como el tráfico de drogas). O bien, podrían ser sitios de comportamientos lícitos asociados con un aumento del riesgo de crimen (por ejemplo, el consumo excesivo de alcohol en multitudes donde los conflictos pueden convertirse fácilmente en violencia). La relación entre tipos específicos de instalaciones y los puntos calientes de crímenes observados es una pregunta importante, y estos lugares de crímenes crónicos son particularmente adecuados para investigaciones empíricas adicionales sobre las características criminogénicas distintivas asociadas con el lugar.

Teorías de la ecología social del crimen

Los primeros ecologistas sociales

Invariablemente, los artículos de investigación que se centran en la concentración del crimen en distintos tipos de comunidades citan el trabajo de los primeros ecologistas sociales franceses Guerry [1833a] 1984, [1833b] 1974) y Quetelet (1833, 1842). Al igual que en los estudios clásicos de Durkheim sobre el suicidio ([1897] 1966) y el crimen ([1901] 1950) una mitad de siglo después, Guerry y Quetelet estaban interesados en explicar las diferencias en los niveles de crimen en las comunidades en términos de las distintas condiciones sociales de las poblaciones residentes. Es admirable ver el nivel de sofisticación analítica que muestran en sus primeros mapas de tasas de crimen, suicidio, alcoholismo, estructura de edad de la población, estructura familiar, niveles educativos y diversidad poblacional en los "Departamentos" franceses del siglo XIX (es decir, áreas geopolíticas análogas a los Estados o provincias contemporáneos). Estos trabajos históricos se encuentran entre los ejemplos más antiguos de un tipo de investigación social empírica que forma parte de la tradición de los estudios ecológicos del crimen, es decir, estudios en los que las unidades de análisis son agregados poblacionales definidos espacialmente.

El siguiente auge de la investigación ecológica sobre el crimen fue a principios del siglo XX. Más que cualquier otro cuerpo académico de trabajo, la Escuela de Chicago de principios de la década de 1920 es responsable de la aparición de estudios ecológicos en la investigación sociológica (por ejemplo, Park, Burgess y McKenzie, 1925). La Escuela de Chicago representa un paradigma sociológico que fomenta una síntesis de métodos cualitativos y cuantitativos. Aunque muchos la consideran aturística y principalmente empírica, es difícil negar su importancia en los desarrollos teóricos en estudios comunitarios y criminología. Como escribe Abbott (1997, 1152):

La Escuela de Chicago pensaba —y piensa— que no se puede entender la vida social sin comprender la disposición de los actores sociales particulares en

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

tiempos y lugares sociales particulares... Ningún hecho social tiene sentido si se abstrae de su contexto en el espacio social (y, a menudo, geográfico) y en el tiempo social. Los hechos sociales son hechos ubicados.

Los datos originales de la Escuela de Chicago eran registros obtenidos del Tribunal de Menores del Condado de Cook (Illinois), la Corte de Menores y la cárcel. Estos incluían medidas demográficas básicas como la edad y el sexo de cada delincuente, junto con la dirección de su domicilio. El siguiente pasaje de Bursik y Grasmick (1993, 31) describe el procedimiento utilizado por Shaw y sus colegas para mapear estos datos:

La dirección residencial de cada individuo... se trazó (¡a mano!) en un mapa base de la ciudad de Chicago (véase Shaw et al. 1929:24) [sic] para una descripción completa del proceso y luego se copió en mapas de contorno de Chicago mediante un reflector y una mesa de vidrio. ... Las tasas de delincuencia (definidas en términos del número de niños referidos al tribunal de menores) se calcularon luego en función de los distritos censales, las áreas comunitarias oficiales de Chicago y áreas de una milla cuadrada de la ciudad, que era su definición operativa más común del vecindario.

Confundiendo únicamente en “la inspección visual... y pruebas estadísticas rudimentarias” (Bursik y Grasmick, 1993) de la distribución espacial resultante de los delincuentes, Shaw y McKay (1942) obtuvieron sus hallazgos fundamentales sobre la estabilidad de la delincuencia a lo largo del tiempo en ciertos vecindarios y la relación negativa entre el crimen y la distancia de los distritos comerciales centrales. De estas observaciones nació la teoría de la desorganización social del crimen.

Otro trabajo importante sobre crimen y lugar que surge de la Escuela de Chicago original incluye el censo de bandas callejeras urbanas de Thrasher (1927). Al mapear las ubicaciones donde se formaban las bandas, Thrasher encontró el “territorio de las bandas” en las áreas “intersticiales” de Chicago, y no en zonas que pudieran etiquetarse fácilmente como “comerciales” o “residenciales”. Las bandas se forman donde “los mejores distritos residenciales retroceden ante la invasión del comercio y la industria” (p. 23). Comprensiblemente, Thrasher no emprendió lo que en ese entonces era una tarea formidable de catalogar todas las características que distinguen el “territorio de las bandas” de las áreas no vinculadas a bandas. Con la llegada de las computadoras y, quizás más importante, la accesibilidad de los datos censales informatizados, esta tarea es mucho más manejable hoy en día.

La “nueva” Escuela de Chicago

Una sesión plenaria destacada en la reunión anual de 1996 de la Sociedad Americana de Criminología, celebrada en Chicago, abordó la pregunta, “¿Qué futuro para la Escuela de Chicago?”. A medida que un panel distinguido de antiguos estudiantes y mentores de la Escuela de Chicago discutía sobre el pasado, presente y futuro de los estudios ecológicos al

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

estilo de Chicago, quedó claro que actualmente estamos en medio de un resurgimiento de la Escuela de Chicago. En las últimas dos décadas, varios estudios excelentes han resucitado y avanzado las tradiciones metodológicas y teóricas de la Escuela de Chicago original. Aunque no estén relacionados causalmente, los recientes avances en técnicas de mapeo informatizado y análisis espacial ampliamente accesibles han acompañado el resurgimiento en popularidad de las explicaciones ecológicas del crimen. Las nuevas capacidades de los sistemas de información geográfica (GIS), que permiten mediciones flexibles en varios niveles de agregación espacial, han facilitado muchos de los análisis recientes de las características ecológicas del crimen.

Por ejemplo, basándose en su capacidad para mapear la ubicación de homicidios, agregarlos a distritos censales y luego examinar la distribución de homicidios de bandas controlando la “desorganización social”, Curry y Spergel (1988) encontraron que el crimen está correlacionado con la pobreza y la falta de control social, pero que la violencia (por ejemplo, homicidios) está correlacionada con su medida de desorganización social. Tita, Engberg y Cohen (1999) presentan otro estudio ecológico contemporáneo de bandas. Descubren que las áreas en las que se forman las bandas tienen bajos niveles de control social informal y comparten características asociadas con la “clase baja”. Además, una vez que se toma en cuenta la composición racial, su medida de desorganización social no predice la ubicación de las bandas. Las bandas se forman en vecindarios de alta criminalidad, pero la llegada de bandas a un área no altera los niveles locales de criminalidad. La excepción notable es un aumento significativo en los disparos tras la formación de bandas en un área (Tita 1999).

Un excelente ejemplo de la combinación de medidas espaciales cuantitativas con estudios cualitativos observacionales es el estudio ecológico de la prostitución callejera en Nueva York realizado por Bernard Cohen (1980). Cohen descubrió que la prostitución callejera abarca todos los niveles de ingresos a través de los vecindarios y distritos censales de Manhattan. Sin embargo, notó similitudes importantes en las fachadas de los bloques y las esquinas de las calles frecuentadas por prostitutas y clientes. Usando mapas dibujados a mano, Cohen identificó “puntos calientes” de actividad de prostitución. Basándose en la observación participante, registró y cuantificó la cantidad de desviación en las áreas de estudio, así como la edad, raza y género de los residentes cercanos. Extrapoló la estructura familiar a partir de los datos de los distritos censales.

Las áreas con una alta incidencia de prostitución se destacaban por la ausencia de niños pequeños y mujeres jóvenes. No es sorprendente que los hogares en estas áreas fueran mucho más propensos a estar formados por adultos solteros y compañeros de cuarto no relacionados. Cohen también observó varias características importantes del entorno construido que potenciaban el crimen, como calles anchas (para permitir un flujo de tráfico discreto de clientes por la zona), los tipos de establecimientos comerciales en el área (para atraer al público “adecuado”) y la proximidad espacial de callejones oscuros, parques o terrenos vacíos (para proporcionar lugares donde llevar a cabo actos sexuales). Aunque no se reconoce ampliamente como tal, el libro de Cohen (1980), *Deviant Street Networks*, puede ser uno de los primeros estudios empíricos en documentar la intersección espacial y temporal de los

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

“delincuentes motivados” y las propiedades del lugar que facilitan el crimen, como lo propone la teoría de las actividades rutinarias (Cohen y Felson 1979).

El trabajo de Bernard Cohen subraya la importancia de especificar la unidad de análisis adecuada en los estudios ecológicos. Al examinar la presencia de prostitutas callejeras en función de diversas medidas socioeconómicas agregadas a nivel de vecindarios o distritos censales, hubo pocas diferencias entre las áreas con prostitución y aquellas sin ella. Solo cuando Cohen examinó la variación dentro de los distritos censales surgieron diferencias importantes. Las capacidades modernas de GIS, combinadas con datos puntuales sobre las ubicaciones de delitos individuales, hacen factible obtener rutinariamente medidas de variables de crimen en estos niveles de agregación no tradicionales y más pequeños.

Las teorías basadas en el lugar buscan explicaciones de las acciones individuales en las características generales de la estructura social en la que está inmerso un individuo. Estas teorías se encuentran dentro de la tradición teórica de la ecología social, pero son más específicas en cuanto a los mecanismos mediante los cuales el contexto estructural se traduce en acción individual. Las principales perspectivas teóricas derivan de la teoría de las actividades rutinarias (Cohen y Felson 1979) y de la teoría de la elección racional (Cornish y Clarke 1986). En ambos casos, la distribución del crimen se determina por la intersección en el tiempo y el espacio de objetivos adecuados y delincuentes motivados. Esta intersección espacial y temporal se define por la organización de ciertos tipos de actividades en lugares específicos, que van desde entornos altamente estructurados como el trabajo y la escuela, hasta entornos menos estructurados como el hogar y los lugares de ocio.

Actividades rutinarias

La teoría de las actividades rutinarias fue introducida por primera vez en Cohen y Felson (1979), más tarde refinada en Felson (1986, 1994) y extendida a la teoría del patrón del crimen en Brantingham y Brantingham (1993). El lugar es central en esta perspectiva, sirviendo como el punto donde los delincuentes motivados se encuentran con objetivos deseables en ausencia de elementos que supriman el crimen (que incluyen guardianes, manejadores íntimos [Felson 1986] y administradores de lugares [Eck 1994]). Esta convergencia de oportunidades delictivas en el espacio y el tiempo se facilita por diversas características situacionales, tanto de tipo físico como social, que proporcionan un contexto o entorno que es más o menos propicio para el crimen (Clarke 1992).

El lugar puede facilitar (o inhibir) el crimen de dos maneras. Primero, las características físicas o construidas de un lugar pueden disminuir las capacidades de control social de diversos suprimidores del crimen. Este tipo de preocupaciones motiva el interés en el diseño de “espacios defendibles” (Jeffrey 1971; Newman 1972). Por ejemplo, el estudio de Newman sobre viviendas públicas sugiere que los edificios de gran altura aumentan la densidad de población, pero dado que los residentes viven en vertical, están físicamente alejados de las actividades de monitoreo en los espacios públicos, especialmente en los de nivel de calle.

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Estas condiciones dejan a este tipo de viviendas con relativamente pocos administradores de lugar que monitorearán y controlarán el comportamiento público y limitan seriamente los niveles de control social informal ejercido sobre todas las formas de comportamiento disruptivo, desde incivildades menores hasta actividades ilícitas más serias. Roncek y Francik (1981) encontraron niveles elevados de crimen en y cerca de viviendas públicas, incluso después de incluir controles sobre la composición de la población residente en diversas características. Esto respalda un papel criminógeno de la propia instalación, independiente de los tipos de personas que se encuentran allí.

En segundo lugar, además de las características físicas, el crimen en los lugares aparentemente está influenciado por las actividades rutinarias que ocurren en ellos. El crimen no se distribuye de manera uniforme o aleatoria en el espacio. En cambio, los lugares con ciertos tipos de instalaciones experimentan niveles más altos de crimen que otros. En algunos casos, los crímenes parecen estar elevados en entornos ricos en objetivos, como los robos en tiendas de conveniencia abiertas las 24 horas, los robos de autos en grandes estacionamientos o los asaltos a compradores en áreas comerciales muy frecuentadas (por ejemplo, Engstad 1975; Duffala 1976; Brantingham y Brantingham 1982). En otros casos, actividades específicas como el consumo de alcohol parecen contribuir a niveles más altos de violencia (Roncek y Bell 1981; Roncek y Pravatiner 1989; Roncek y Maier 1991; Homel y Clark 1995; Block y Block 1995). Algunos lugares parecen ser propensos a niveles más altos de crimen debido a los tipos de personas que atraen y repelen. Por ejemplo, los lugares con edificios abandonados o viviendas en mal estado con propietarios ausentes son atractivos para los traficantes de drogas ilícitas que buscan lugares donde establecer puntos de venta estables sin temor a quejarse de los propietarios o vecinos (Eck 1994).

Puntos calientes de crimen

La concentración del crimen en lugares identificables se señaló en Brantingham y Brantingham (1982). Estos puntos calientes de crimen son ejemplos clave del valor potencial del lugar en el análisis del crimen. Sherman, Gartin y Buerger (1989) publicaron uno de los primeros estudios en cuantificar lo que muchos estudios cualitativos habían sugerido: que el crimen en una ciudad se concentra en relativamente pocas áreas pequeñas. El estudio encontró que el 3.3 por ciento de las direcciones de calles e intersecciones en Minneapolis generaban el 50.4 por ciento de todas las llamadas de servicio de policía despachadas. Patrones similares surgieron en otras ciudades (Pierce, Spaar y Briggs 1988; Sherman 1992; y Weisburd y Green 1994). Aunque a menudo motivados por preocupaciones prácticas sobre qué intervenciones son efectivas para reducir el crimen, estos resultados también sirven para enfocar agudamente la teoría del crimen en el desarrollo de explicaciones satisfactorias sobre las relaciones aparentemente fuertes entre el crimen y el lugar.

Los estudios sobre crimen que examinan la distribución espacial del crimen demuestran claramente que ciertos usos de la tierra y características de la población están asociadas con

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

puntos calientes de crimen. Roncek y Maier (1991) encontraron una relación positiva entre los niveles de crimen y el número de tabernas y bares en los bloques de la ciudad de Cleveland. La influencia de los bares en el crimen se incrementó cuando estos se encontraban en áreas con más anonimato y menor vigilancia. Cinco de los diez puntos calientes identificados en Sherman, Gartin y Buerger (1989) incluían bares. Cohen, Gorr y Olligschlaeger (1993) encontraron que los puntos calientes de drogas tendían a ubicarse en áreas con bares problemáticos, establecimientos comerciales en mal estado o áreas con pobreza y baja cohesión familiar, medida por hogares encabezados por mujeres.

Skogan y Maxfield (1981) informaron que las condiciones ambientales como edificios abandonados, incivildades públicas como peleas y otros asaltos menores, jóvenes desordenados, ventanas rotas u otras formas de vandalismo, consumo público de drogas o alcohol, prostitución, merodeo, ruidos, basura y comportamientos obscenos aumentan el miedo de la comunidad al crimen. Las “ventanas rotas” y otras señales públicas de desorden también pueden contribuir al aumento de crímenes más graves, ya que estos signos visibles de desorden urbano indican que una comunidad ha perdido su capacidad de ejercer control social, lo que a su vez fomenta y perpetúa el crimen (Wilson y Kelling 1982; Greenberg, Rohe y Williams 1985). Por otro lado, las estrategias de aplicación de la ley enérgicas, dirigidas a diversas formas de desorden público y violaciones menores, pueden inhibir los crímenes más graves al establecer señales visibles de una comunidad vigilante y autoprottegida (Boydstrun 1975; Wilson y Boland 1978; Pate et al. 1985; Sherman 1986; Sampson y Cohen 1988; Kelling y Coles 1996). Esto sugiere que los puntos calientes de crimen pueden surgir primero como concentraciones de crímenes “menores” que luego se intensifican a crímenes más graves.

La contribución causal de los puntos calientes al crimen depende de si los niveles elevados de crimen observados en estos lugares son sistemáticos (regulares y predecibles) y no simplemente ocurrencias aleatorias. Si los puntos calientes son aleatorios y pueden ocurrir en cualquier lugar, entonces el crimen en estos lugares no depende de características distintivas observadas en los puntos calientes; en este caso, los esfuerzos de reducción de crimen que se centran en estas características probablemente fracasarán. Por lo tanto, la identificación cuidadosa de los puntos calientes y análisis metodológicamente sólidos para establecer si tienen vínculos significativos con el crimen son cruciales.

Herramientas de Análisis de Datos Espaciales

La concentración espacial del crimen en puntos calientes lleva de forma natural a su representación en mapas de crimen. Los mapas de incidentes del crimen permiten identificar rápidamente la ubicación geográfica de los puntos calientes de crimen, pero por sí solos aportan poco a la comprensión de por qué el crimen está concentrado en ciertos lugares. Un aspecto crucial de las técnicas de reconocimiento de patrones, como el análisis de puntos calientes, es determinar hasta qué punto los patrones en el mapa reflejan “verdaderas”

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

concentraciones o casos atípicos y si son espurios. Como es bien sabido, la interpretación visual simple del mapa es inadecuada en este sentido porque la mente humana está condicionada a encontrar significado e identificar patrones y concentraciones, incluso cuando los datos representados pueden ser puramente aleatorios. El uso de principios cartográficos sólidos por sí solo no garantiza que se obtenga una interpretación adecuada (Rheingans y Landreth 1995; Gahegan y O'Brien 1997; MacEachren y Kraak 1997). Lo que se necesita es una estructuración cuidadosa de la estrategia de visualización, complementada con información cuantitativa (Cleveland 1993).

Representación de Puntos Calientes

La representación de puntos calientes de crimen se refiere a identificar áreas específicas con una alta concentración de incidentes delictivos. Estos lugares, donde el crimen persiste en niveles elevados durante periodos prolongados, pueden compararse con el pequeño porcentaje de delincuentes crónicos que son responsables de una gran parte del crimen. Sin embargo, hasta la fecha, se conoce poco sobre el ciclo de vida real de estos puntos calientes. Sherman (1995) y Spelman (1995) fueron pioneros en aplicar características de las carreras criminales de los delincuentes para describir el ciclo de vida de los puntos calientes. Identificaron procesos como la iniciación, el crecimiento, la consolidación o escalada de la gravedad del crimen, la persistencia, el declive, el desplazamiento y la terminación. Además, estos estudios comenzaron a explorar empíricamente la validez de esta caracterización, buscando evidencia de la persistencia del crimen en ciertos lugares a lo largo del tiempo.

Los puntos calientes de crimen comparten características clave como la existencia de una frontera y la presencia de eventos delictivos dentro de ella (por ejemplo, llamadas al 911 o informes de delitos). Una forma sencilla de identificar estos puntos es dividir una jurisdicción en un conjunto fijo de fronteras (por ejemplo, celdas de cuadrícula, grupos de bloques censales u otros tipos de divisiones) y desarrollar un conjunto de reglas basadas en valores umbral. Sherman y Weisburd (1995) definieron de manera objetiva los puntos calientes considerando la ubicación, el intervalo de tiempo, los tipos de crimen y el número de eventos.

Supongamos que los límites son celdas de una cuadrícula de tamaño fijo y origen. Entonces, una regla para la iniciación de puntos calientes en cualquier celda de la cuadrícula podría ser la siguiente: Si la celda no era un punto caliente en el período de tiempo anterior, pero el número de crímenes de un tipo designado ahora supera un valor umbral específico, entonces la celda se convierte en un punto caliente durante el período actual. Una base de reglas incorporará estados de ciclo de vida, intervalos de tiempo, conteos de crímenes umbral y cambios en los conteos de crímenes. Gorr, Olligschlaeger y Szczypula (1998) están diseñando tal base de reglas para explorar empíricamente los números, las duraciones, las probabilidades de ramificación, las mezclas de crímenes y las concentraciones de puntos calientes.

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

La elección de los límites—fijos o ad hoc—es de particular interés al representar los puntos calientes. Los límites fijos (por ejemplo, áreas censales, distritos policiales o celdas de cuadrícula uniformes) tienen la ventaja de dar lugar a los datos de series temporales/espaciales comúnmente utilizados para la información sobre delitos y modelado espacial. Su desventaja es que los puntos calientes pueden cruzar los límites fijos o variar en tamaño. Un ejemplo de agrupamiento ad hoc de datos de puntos de delito observados son las elipses creadas en el software STAC (Análisis Espacial y Temporal del Crimen) (Block 1994). Tales límites tienen la ventaja de ofrecer tamaños y formas ajustados específicamente a los puntos calientes individuales. Sin embargo, no generan una colección consistente de datos de series temporales y espaciales sobre delitos y actividades de aplicación de la ley. Como modeladores, preferimos límites fijos.

Los puntos calientes son, por definición, pequeños en área. Utilizando la inspección visual de mapas de puntos y conteos umbral para delitos "duros" y "blandos", Sherman y Weisburd (1995) identificaron puntos calientes en Minneapolis, Minnesota, de no más de un bloque lineal de calle—un área en la que un oficial de policía puede ver y ser visto fácilmente. Los momentos de mayor actividad eran entre las 7:00 p.m. y las 3:00 a.m. Para los mercados de drogas en Jersey City, Nueva Jersey, los puntos calientes se definieron por intersecciones y los cuatro bloques de calle conectados, y los momentos de mayor actividad eran de mediodía a medianoche (Weisburd y Green 1994). Esta escala puede ser demasiado pequeña para la mayoría de los fines prácticos. Por ejemplo, los puntos calientes pueden moverse distancias cortas en períodos de tiempo cortos (por ejemplo, desplazamiento a lugares cercanos en respuesta a actividades de aplicación de la ley). Las áreas de puntos calientes de unos pocos bloques de tamaño o incluso más grandes pueden adaptarse mejor a tales movimientos esporádicos a corto plazo dentro de lo que esencialmente es el mismo espacio de actividad.

La presencia de variaciones en los efectos estimados de los modelos derivados de las diferencias en las unidades de área seleccionadas para el análisis se conoce como el problema de la unidad de área modificable (MAUP, por sus siglas en inglés) en geografía (Holt et al. 1996). Las estimaciones de parámetros que varían ampliamente pueden resultar de reagrupar datos por unidades de área de diferentes tamaños. Por ejemplo, Gehlke y Biehl (1934) encontraron que los coeficientes de correlación tendían a aumentar con el nivel de agregación de las áreas censales. Fotheringham y Wong (1991) descubrieron que los cambios en las estimaciones de parámetros de modelos de regresión lineal múltiple eran complejos e impredecibles al cambiar la escala en la que se recopilaban y agregaban los datos. Aunque es importante en teoría, el MAUP probablemente sea de menor preocupación en los análisis de puntos calientes, porque el tamaño a menudo está dictado por la necesidad de representar los puntos calientes de delitos para fines de aplicación de la ley, y esta función restringe el rango de tamaños relevantes.

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Modelos y análisis de puntos calientes

Comprender la relación entre lugar y crimen requiere conocer la dinámica del desarrollo de puntos calientes a lo largo del espacio y el tiempo, prestando especial atención a las formas en que las instalaciones y la utilización de un lugar contribuyen a la conducta delictiva. Este tipo de conocimiento se puede derivar de la combinación de teoría con investigación empírica exploratoria y confirmatoria. Existen varios tipos de modelos y análisis espaciales apropiados para los puntos calientes. Como paso previo a los modelos causales reales, estos incluyen modelos descriptivos y modelos predictivos.

Modelos descriptivos

El ciclo de vida de los puntos calientes incluye varias etapas de desarrollo, la duración del tiempo pasado en cada etapa y las probabilidades de ramificación de las transiciones entre las etapas. Una mejor comprensión de los puntos calientes requiere datos de espacio y tiempo sobre delitos y sus covariables para una muestra de ciudades. Estos datos deben incluir una base de reglas consistente para clasificar áreas fijas en puntos no calientes y puntos calientes en diferentes etapas de desarrollo. Entonces, los analistas tendrán una mejor base para distinguir fenómenos estocásticos aleatorios, como la regresión a la media (algunos puntos calientes se desvanecen por sí mismos), de la sistematización del endurecimiento de los puntos calientes de delitos menores hacia delitos más graves.

Modelos predictivos

Después de la descripción, el siguiente paso para comprender los puntos calientes es construir modelos predictivos exitosos. Por ejemplo, la hipótesis de las "ventanas rotas" postula que una variedad de delitos menores (por ejemplo, vandalismo y disturbios del orden público) sirven como indicadores anticipados de delitos graves como agresiones y robos. Los modelos de indicadores anticipados requieren datos multivariados que incluyan la variable dependiente (por ejemplo, número de robos por mes) junto con variables de indicadores anticipados que se retrasan uno o más períodos de tiempo (por ejemplo, número de llamadas al 911 relacionadas con pandillas o drogas de meses anteriores). Los retrasos también pueden ser espaciales, como un total simple o un promedio ponderado de llamadas al 911 en ubicaciones contiguas (cercanas) de meses anteriores.

El modelo de Vector Autoregression (VAR) es un modelo común de series temporales para estimar y probar indicadores anticipados. Los investigadores han utilizado modelos VAR de manera extensiva para modelado aplicado y pronóstico desde el trabajo de Sims (1980). Estos son modelos multivariados simples en los que una variable se explica por sus propios valores pasados y los valores pasados de todas las demás variables (indicadores anticipados) en el sistema (Holden 1995). El modelo de Bayesian Vector Autoregression (BVAR) es una forma restringida de VAR.

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Introducido por Litterman (1980, 1986), el BVAR se basa en estimaciones de priors de Bayes para superar problemas de colinealidad y grados de libertad que típicamente surgen en la aplicación de modelos autorregresivos vectoriales. Doan, Litterman y Sims (1984) introdujeron los llamados priors de Minnesota para el BVAR. LeSage y Pan (1995) introdujeron la contigüidad espacial para especificar más detalladamente los priors en estudios regionales. Los modelos BVAR han tenido éxito en el análisis de series temporales y modelos de pronóstico para datos regionales, especialmente en análisis exploratorios de las especificaciones de modelos con retrasos en el tiempo y el espacio adecuados (LeSage 1989, 1990; LeSage y Pan 1995).

Granger y Newbold (1977, 224–226) introdujeron reglas y pruebas para una forma débil de prueba de causalidad basada en VAR y en relación con el conjunto de información limitado de variables utilizadas. Ahora conocida como "causalidad de Granger", el Factor A "causa Granger" B si el retraso A es un predictor significativo de B, pero el retraso B no es un predictor significativo de A. Enders (1995, 315) presenta una prueba F estándar para determinar la causalidad de Granger.

Análisis de exploración de datos espaciales

Recientemente, el conjunto de métodos para estructurar la visualización de datos espaciales se ha denominado análisis exploratorio de datos espaciales, o ESDA. Según lo definido por Anselin (1994, 1998, 1999a), ESDA es un conjunto de técnicas para describir y visualizar distribuciones espaciales; identificar ubicaciones atípicas o valores atípicos espaciales; descubrir patrones de asociación espacial, agrupamientos o puntos calientes; y sugerir regímenes espaciales u otras formas de heterogeneidad espacial (cambio en la estructura o en la asociación a través del espacio). Como tal, el ESDA forma un subconjunto del análisis exploratorio de datos o EDA (Tukey 1977), pero con un enfoque explícito en las características distintivas de los datos geográficos (Anselin 1989). En esta sección, describimos cómo los principios del ESDA son relevantes en el análisis de patrones espaciales en el crimen. Específicamente, comenzamos revisando el concepto de autocorrelación espacial y cómo se puede aplicar tanto a datos puntuales (por ejemplo, ubicación de robos) como a datos de área (por ejemplo, número de homicidios o tasa de homicidios por tramo censal). Luego, presentamos algunos enfoques recientemente desarrollados que se enfocan en los “indicadores locales de asociación espacial” (o LISA) y discutimos cómo estos pueden usarse para detectar puntos calientes y valores atípicos espaciales. Finalmente, revisamos la integración de estas técnicas en un entorno de computación interactivo.

El interés en la cuantificación de patrones en mapas ha llevado a un gran número de estadísticas espaciales y otros resúmenes de mapas, revisados en los tratamientos clásicos de autocorrelación espacial por Cliff y Ord (1973, 1981). De manera similar, la detección de agrupamientos y valores atípicos en mapas es una preocupación importante en la

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

epidemiología y las estadísticas médicas, y existe una gran cantidad de literatura dedicada al tema (por ejemplo, como se revisa en Marshall 1991). Formalmente, la presencia o ausencia de patrón se indica mediante el concepto de autocorrelación espacial, o la coincidencia de similitud en el valor con similitud en la ubicación. En otras palabras, cuando los valores altos en un lugar tienden a asociarse con valores altos en ubicaciones cercanas, o los valores bajos con valores bajos en los vecinos, se dice que ocurre una autocorrelación espacial positiva o un agrupamiento espacial. En contraste, cuando los valores altos en una ubicación están rodeados de valores bajos cercanos, o viceversa, se presenta una autocorrelación espacial negativa en forma de valores atípicos espaciales. El punto de referencia en el análisis de la autocorrelación espacial es la aleatoriedad espacial, o la falta de estructura alguna. Por ejemplo, bajo la aleatoriedad espacial, la disposición particular de los delitos en un mapa dado sería tan probable como cualquier otra disposición, y cualquier agrupamiento de valores altos o bajos en un área particular sería totalmente espurio.

Análisis de patrones de puntos

La evaluación formal de la presencia y extensión de la autocorrelación espacial depende del tipo de datos que se consideren. La situación más sencilla es cuando solo se conoce la ubicación de un fenómeno dado (por ejemplo, las direcciones de las calles donde ocurrieron robos). En esta situación, el interés principal radica en evaluar si estas ubicaciones, representadas como puntos en un mapa, están dispersas al azar en el espacio, o si, por el contrario, muestran patrones sistemáticos en forma de agrupamientos (más puntos se encuentran sistemáticamente más cerca entre sí de lo que sería en un caso puramente aleatorio) o dispersión (más puntos están sistemáticamente más separados entre sí que bajo la aleatoriedad). El análisis de patrones de puntos se ocupa de detectar cuándo se producen desviaciones “significativas” de la aleatoriedad espacial.

Método de conteo de cuadrículas. La construcción de pruebas para los patrones de puntos puede abordarse de diferentes maneras. Una técnica popular que se puede realizar fácilmente en un entorno SIG es el método de conteo de cuadrículas, en el que se superpone una cuadrícula cuadrada a los puntos. Se cuenta el número de puntos en cada celda de la cuadrícula y se compara con el “número esperado” bajo la aleatoriedad espacial mediante una prueba de chi-cuadrado de bondad de ajuste. Aunque es intuitivo y se implementa fácilmente, este enfoque presenta varios problemas conceptuales, como la arbitrariedad en la elección del tamaño de la celda de la cuadrícula y la posibilidad de correlación entre los conteos en celdas cercanas (autocorrelación espacial).

Estimación de kernel. Una extensión natural del enfoque de cuadrícula es la estimación de kernel, en la que se obtiene una estimación suave de la intensidad del proceso de puntos mediante una ventana móvil sobre los datos. En otras palabras, el número de puntos dentro de la ventana móvil (a veces transformado para mejorar la interpretación y visualización) se toma como un indicador de la intensidad del evento en esa ubicación (por ejemplo, cuántos

Texto original:


<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

robos por milla cuadrada). En lugar de los puntos mismos, esta medida de intensidad puede visualizarse en un mapa y evaluarse en busca de desviaciones sistemáticas de la aleatoriedad. Una implementación particular de esta técnica consiste en trazar muchos círculos superpuestos de tamaños variables y evaluar la medida en que pueden estar presentes “agrupamientos”. Por ejemplo, esto se implementa en la “máquina de análisis geográfico” de Openshaw y asociados (Openshaw et al. 1987, 1988; para una revisión reciente, ver Openshaw y Alvanides 1999).

La estimación de kernel o suavizado de kernel es un método para examinar las tendencias globales a gran escala en los datos puntuales. El objetivo de la estimación de kernel es estimar cómo varían los niveles de eventos de manera continua en un área de estudio basada en un patrón de puntos observado para una muestra de puntos (Bailey y Gatrell 1995; Williamson et al. 1998). La estimación de kernel crea un mapa suave de valores utilizando datos espaciales. El mapa suavizado aparece como un histograma espacial, con el nivel en cada ubicación del mapa reflejando la intensidad del patrón de puntos en el área circundante.

En la estimación de kernel, una función tridimensional móvil (k_1) de un radio o “ancho de banda” dado visita cada celda de una cuadrícula fina que se ha superpuesto en la región de estudio o área. A medida que el kernel visita cada celda, se miden las distancias desde el centro de la celda de la cuadrícula (s_1) a cada observación (s_i) que se encuentra dentro del ancho de banda (t_1). Cada distancia contribuye al nivel de intensidad de esa celda de la cuadrícula, dando mayor peso a las observaciones que se encuentran más cerca del centro de la celda (ver el gráfico 1).

Exhibit 1. Kernel estimation



La elección de un ancho de banda adecuado es crucial al aplicar la estimación de kernel a los datos de puntos y puede ser una debilidad significativa si se selecciona arbitrariamente (ver Silverman 1986). El ancho de banda es importante porque determina la cantidad de suavizado aplicada al patrón de puntos. En general, un ancho de banda grande dará como resultado una mayor cantidad de suavizado, produciendo un mapa fluido con bajos niveles de intensidad.

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Un ancho de banda menor da lugar a menos suavizado, produciendo un mapa irregular con variaciones locales en los niveles de intensidad. Idealmente, el ancho de banda debería representar la distancia real entre los puntos en la distribución. Sin embargo, no existe una regla estricta para determinar el ancho de banda.

La estimación de kernel se ha aplicado en diversos campos, particularmente en la epidemiología. En las aplicaciones epidemiológicas, una distribución de puntos discretos, cada uno representando la incidencia de una enfermedad en la población, se transforma en un mapa de superficie continua suavizada que indica el riesgo de enfermedad (ver Sabel 1998). Al transformar los patrones de puntos espaciales de incidentes criminales en una imagen suave, la estimación de kernel puede ser igualmente efectiva para visualizar áreas de actividad y riesgo delictivo.

La estimación de kernel ofrece varios beneficios prácticos en el análisis espacial del crimen. El primer beneficio es la accesibilidad. La estimación de kernel permite a los analistas simplificar visualmente y examinar patrones complejos de puntos de incidentes criminales. La mayor accesibilidad de los datos puntuales sobre incidentes criminales puede fácilmente llevar a una sobrecarga de datos (Block 1998). Mostrar incluso cantidades modestas de datos de puntos en un mapa puede volverse rápidamente confuso e informativo. La estimación de kernel no disminuye la importancia de los datos espaciales basados en puntos. En cambio, una imagen suave captura y muestra los puntos calientes y potenciales puntos calientes como áreas de alta densidad. Estas áreas de alta densidad pueden luego verificarse examinando el nivel de significancia estadística de las áreas calientes estimadas para determinar la probabilidad de observar niveles tan altos si los incidentes están distribuidos aleatoriamente en el espacio y el tiempo.

La estimación de kernel también permite una mayor flexibilidad en la definición de los límites de las áreas calientes y en el análisis de las áreas de puntos calientes. Las áreas de puntos calientes a menudo se ven influenciadas por límites naturales que dividen las zonas de población, como barrancos y autopistas. Estos límites hacen que las áreas tengan formas irregulares. Además, las concentraciones de delitos a menudo cruzan áreas de patrullaje y jurisdicciones policiales en lugar de estar confinadas a límites administrativos predefinidos. Por lo tanto, siempre que la distribución del crimen no sea uniforme, los contornos que definen las áreas de puntos calientes probablemente no serán los círculos o elipses bien comportados requeridos en algunos métodos de agrupamiento de delitos (por ejemplo, el método STAC en Block 1998). La estimación de kernel permite límites flexibles y la representación de la intensidad de los incidentes criminales a lo largo de toda una región.

Finalmente, la estimación de kernel puede ser importante en el análisis de patrones de incidentes a lo largo del tiempo. Las imágenes de densidad se pueden comparar en períodos de tiempo consecutivos o correspondientes (por ejemplo, el mismo mes o comparaciones de año a la fecha en años sucesivos). Esto proporciona un contexto para interpretar cambios a corto plazo en relación con tendencias a largo plazo y patrones estacionales. Los mapas

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

suavizados por kernel también revelan el contexto espacial más amplio de los cambios a lo largo del tiempo.

Estadísticas de distancia

Otras técnicas de patrones de puntos se basan en la distancia entre los puntos, ya sea entre cada punto y su vecino más cercano (estadísticas de vecino más cercano) o entre todos los puntos (estadísticas de segundo orden). La lógica subyacente es que, cuando los eventos están agrupados en el espacio, las distancias interpuntuales pequeñas deberían ser más prevalentes que bajo la aleatoriedad espacial. Se han propuesto numerosos tipos de estadísticas de vecino más cercano en la literatura. Sus propiedades se derivan o se aproximan analíticamente o, más interesante aún, se basan en un enfoque computacional. Este último consiste en simular la ubicación del mismo número de puntos que en el conjunto de datos (por ejemplo, el total de robos en un año determinado) asignando ubicaciones aleatoriamente, imitando así la hipótesis nula de aleatoriedad espacial. Para cada uno de los patrones simulados, se puede calcular el valor de la estadística (o estadísticas), lo que proporciona una distribución de referencia con la que se puede comparar la estadística del patrón observado. Esto ofrece una forma intuitiva y muy visual de evaluar el grado de no aleatoriedad en un patrón de puntos. Por ejemplo, esto se puede aplicar a la función de distribución acumulada empírica para las distancias de los vecinos más cercanos de cada punto, o a todas las distancias entre los puntos.

Las estadísticas de vecinos más cercanos se han extendido para probar la existencia de agrupamientos en el espacio y el tiempo. Por ejemplo, la estadística de Knox (Knox 1964) consiste en contar cuántos pares de eventos están más cercanos en espacio y tiempo de lo que se esperaría bajo la aleatoriedad. Aunque inicialmente se desarrolló para detectar agrupamientos de incidencia de enfermedades, la aplicación de estos métodos a la actividad criminal es directa.

Las técnicas discutidas hasta ahora abordan los llamados niveles "generales" de agrupamiento (o, autocorrelación espacial global) en el sentido de evaluar el grado en el que se puede rechazar la aleatoriedad espacial. En muchos casos, es interesante localizar "dónde" podrían estar presentes los agrupamientos. Por ejemplo, se podría querer saber si los centros de los agrupamientos se encuentran cerca de ubicaciones de instalaciones que inducen delitos, como licorerías o tiendas de conveniencia abiertas las 24 horas. Estas pruebas se denominan "pruebas enfocadas" (Besag y Newell 1991) y relacionan el número de puntos en una celda (o los conteos de eventos) con la distancia desde una "fuente putativa". Nuevamente, el principio general subyacente a estas pruebas es que las desviaciones de la aleatoriedad espacial resultarían en una frecuencia más alta de puntos cerca de la fuente putativa.

Procesamiento de puntos espaciales

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Las pruebas para patrones de puntos o agrupamientos de eventos se implementan en una serie de paquetes de software, varios de los cuales están disponibles comercialmente o como freeware/shareware. La mayoría de estos paquetes también se pueden integrar fácilmente en un entorno de SIG. Por ejemplo, las estadísticas de vecino más cercano y la función K se incluyen en el complemento S+SpatialStats del paquete estadístico S-Plus (MathSoft 1996), que se puede integrar con el SIG ArcView a través del enlace S+ArcView (Bao et al., próximamente).

Infomap (Bailey y Gatrell 1995) contiene varios métodos de conteo de cuadrantes, así como estadísticas de vecino más cercano y de segundo orden, junto con un conjunto de funciones básicas de mapeo. Una amplia gama de estadísticas de agrupamiento y escaneo también se incluye en Stat! (BioMedware 1994), que, aunque se desarrolló con eventos de salud en mente, se puede aplicar fácilmente a estadísticas de delitos. Un enfoque específico en la detección de patrones en las ubicaciones de incidentes delictivos se implementa en el paquete CrimeStat. Esta herramienta de software, desarrollada con el apoyo del Instituto Nacional de Justicia, se puede vincular a una variedad de software GIS comerciales y formatos de datos espaciales (Levine 1999).

Análisis del área

Hasta ahora, la discusión sobre la autocorrelación espacial se ha centrado en situaciones donde los datos se presentan en forma de puntos, y su ubicación es el principal foco de interés. Un entorno igualmente importante es aquel en el que los datos se recopilan para unidades areales o "regiones", como los conteos o tasas de homicidios por condado o tramo censal. Se han desarrollado una gran cantidad de pruebas de autocorrelación espacial para evaluar en qué medida la disposición espacial de los valores en un mapa muestra desviaciones de una hipótesis nula de aleatoriedad espacial, tal como se revisa en Cliff y Ord (1973, 1981), Upton y Fingleton (1985), y Griffith (1987), entre otros.

Un concepto fundamental en el análisis de la autocorrelación espacial para datos areales es la matriz de pesos espaciales. Esta es una matriz cuadrada de dimensión igual al número de observaciones, con cada fila y columna correspondiente a una observación. Típicamente, un elemento w_{ij} de la matriz de pesos W es distinto de cero si las ubicaciones i y j son vecinas, y cero en caso contrario (por convención, los elementos diagonales w_{ii} son cero). Se puede utilizar una amplia gama de criterios para definir vecinos, como la contigüidad binaria (frontera común) o bandas de distancia (ubicaciones dentro de una distancia dada entre sí), o incluso una "distancia social" general.

La matriz de pesos espaciales se utiliza para formalizar una noción de similitud locacional y es fundamental para cada estadística de prueba. En la práctica, los pesos espaciales se derivan típicamente de los archivos de límites o los datos de coordenadas en un sistema de información geográfica (véase Can 1996).

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Desde un punto de vista más técnico, casi todas las pruebas para la “autocorrelación espacial global” pueden expresarse como un caso especial de una estadística de producto cruzado general o “gamma” (Hubert 1985, 1987; Hubert, Golledge y Costanzo 1981). Esta estadística consiste en una suma de productos cruzados entre dos conjuntos de términos, uno relacionado con la similitud de valor entre dos observaciones, y el otro con su similitud en la ubicación, o, $G = \sum_i \sum_j a_{ij} \cdot w_{ij}$. En esta expresión, el término a_{ij} corresponde a la similitud de valor, como un producto cruzado $x_i \cdot x_j$ o una diferencia al cuadrado $(x_i - x_j)^2$, mientras que w_{ij} son elementos en una matriz de pesos espaciales. La inferencia para esta clase general de estadísticas se basa en permutación. Específicamente, se construye una distribución de referencia que simula la aleatoriedad espacial al reorganizar arbitrariamente los valores observados en un mapa dado sobre las ubicaciones disponibles y volver a calcular la estadística para cada uno de estos arreglos aleatorios.

Estadísticas clásicas

Las estadísticas de prueba clásicas para la autocorrelación espacial son la estadística de conteo de uniones, el I de Moran y el c de Geary (Cliff y Ord 1973). La estadística de conteo de uniones es apropiada cuando los datos son binarios, por ejemplo, la presencia (codificada como B para negro) o ausencia (codificada como W para blanco) de incendios intencionales por manzana de la ciudad. El número de veces que las unidades espaciales vecinas también tienen B en común se llama conteo de uniones BB. Las pruebas se basan en la medida en que el número observado de uniones BB (o WW, BW) es compatible con una hipótesis nula de aleatoriedad espacial. De manera similar, cuando los datos son variables medidas en una escala continua (como tasas de criminalidad o conteos de homicidios), las estadísticas de I de Moran y c de Geary miden la desviación de la aleatoriedad espacial. El I de Moran es un coeficiente de producto cruzado similar al coeficiente de correlación de Pearson y se escala para que sea menor que uno en valor absoluto. Los valores positivos del I de Moran indican autocorrelación espacial positiva (agrupamiento), mientras que los valores negativos sugieren valores atípicos espaciales. En contraste con el I de Moran, el coeficiente c de Geary se basa en desviaciones al cuadrado. Los valores de c de Geary menores que uno indican autocorrelación espacial positiva, mientras que los valores mayores que uno sugieren autocorrelación espacial negativa. Se han propuesto ajustes al I de Moran para tener en cuenta la inestabilidad de la varianza en las tasas en la literatura epidemiológica, por ejemplo, la estadística Ipop de Oden (1995). Las extensiones del I de Moran a un entorno multivariante se describen en Wartenberg (1985).

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Diagrama de dispersión de Moran

Cuando se utilizan variables en forma estandarizada (es decir, su media es cero y la desviación estándar es uno), el grado de autocorrelación espacial en un conjunto de datos se puede visualizar fácilmente mediante un diagrama de dispersión espacial, denominado diagrama de dispersión de Moran en Anselin (1995, 1996). El diagrama de dispersión de Moran se centra en la media y muestra el valor de una variable (z_j) en el eje horizontal frente a su rezago espacial (Wz_j , o $\sum_j w_{ij} z_j$; es decir, un promedio ponderado de los valores vecinos) en el eje vertical. Los cuatro cuadrantes en el diagrama de dispersión corresponden a ubicaciones donde los valores altos están rodeados de valores altos en la parte superior derecha (un z_j por encima de la media con un Wz_j por encima de la media), o valores bajos rodeados de valores bajos en la parte inferior izquierda, ambos indicando autocorrelación espacial positiva. Los otros dos cuadrantes corresponden a autocorrelación espacial negativa, o valores altos rodeados de valores bajos (alto z_j , bajo Wz_j) y valores bajos rodeados de valores altos (bajo z_j , alto Wz_j). La pendiente de la línea de regresión lineal a través del diagrama de dispersión de Moran es el coeficiente I de Moran. Además, un mapa que muestre las ubicaciones que corresponden a los cuatro cuadrantes proporciona una vista general de los patrones en los datos. Por lo tanto, este dispositivo proporciona un medio intuitivo para visualizar el grado de autocorrelación espacial, no solo en un contexto transversal tradicional, sino también a través de variables y a lo largo del tiempo (Anselin 1998). Ejemplos recientes de la aplicación de estos conceptos en estudios de homicidios se pueden encontrar en Sampson, Morenoff y Earls (1999) y Cohen y Tita (1999).

Estadísticas basadas en la distancia

Una perspectiva alternativa sobre la autocorrelación espacial para datos disponibles en ubicaciones discretas (puntos, áreas) es considerar estos como puntos de muestreo para una superficie continua subyacente en un enfoque geoestadístico. Por ejemplo, las estadísticas de criminalidad por comisaría se usarían para estimar una superficie continua de criminalidad para toda la ciudad. El interés principal en este paradigma radica en la interpolación espacial, o kriging. La medida de la autocorrelación espacial se toma como una función de la diferencia al cuadrado entre los valores de cada par de observaciones en comparación con la distancia que los separa. Formalmente, esto se realiza en un variograma (o, más precisamente, un semi-variograma). Una visualización del variograma consiste en un diagrama de dispersión de las diferencias al cuadrado organizadas por banda de distancia, posiblemente con un diagrama de caja para cada banda de distancia: un gráfico de nube de variograma o un diagrama de caja de variograma (ver Cressie 1993; Haslett et al. 1991). Otra visualización se enfoca en cada rezago de distancia por separado, en un diagrama de dispersión espacialmente rezagado (Cressie 1984). La media o mediana en el gráfico de nube de variograma para cada banda de distancia sugiere un patrón general para el cambio en la autocorrelación espacial con la distancia, y un enfoque en los valores atípicos indica pares de

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

observaciones que pueden influir indebidamente en esta tendencia central (ver también Majure y Cressie 1997; Anselin 1998, 1999a).

Indicadores locales de asociación espacial—estadísticas LISA

Las medidas de autocorrelación espacial revisadas hasta ahora son generales, o globales, en el sentido de que el patrón general en los datos se resume en una única estadística. Paraleleando las pruebas focalizadas de análisis de patrones de puntos, los indicadores locales de asociación espacial (LISA) proporcionan una medida de la extensión en que la disposición de los valores alrededor de una ubicación específica se desvía de la aleatoriedad espacial. Estrechamente relacionado con las pruebas focalizadas, las estadísticas G_i y G_i^* de Getis y Ord (1992; Ord y Getis 1995) miden la extensión en que la concentración de valores altos o bajos dentro de una banda de distancia dada alrededor de una ubicación se desvía de la aleatoriedad espacial. Estas estadísticas están diseñadas para encontrar grupos de valores altos o bajos. Pueden aplicarse a cada ubicación por turno o utilizando bandas de distancia crecientes alejadas de una ubicación dada. Un marco general para LISA se describe en Anselin (1995), donde se derivan formas locales para varias estadísticas globales, como las estadísticas locales de Moran y Geary. La estadística local de Moran está estrechamente relacionada con el diagrama de dispersión de Moran e indica la presencia de grupos locales o valores atípicos espaciales locales. Las estadísticas LISA se prestan bien a la visualización mediante un SIG, por ejemplo, en mapas simbólicos que muestran las ubicaciones con estadísticas locales significativas. Además, cuando se combinan con un diagrama de dispersión de Moran, las ubicaciones con Moran local significativo pueden clasificarse en términos del tipo de asociación que representan.

Estimación de la autocorrelación espacial

Las rutinas para probar la autocorrelación espacial se encuentran en una amplia gama de software tanto de propósito específico como comercial. Una lista extensa se encuentra en el sitio web de AI-GEOSTAT (<http://curie.ei.jrc.it:80/software>). Otras revisiones recientes se pueden encontrar en Legendre (1993) y Levine (1996). La mayoría de estas implementaciones de software son especializadas y contienen una o unas pocas estadísticas. Los tratamientos más completos son el complemento S+SpatialStats para el sistema estadístico S-Plus (MathSoft 1996) y el paquete SpaceStat™ (Anselin 1992). Este último es el único sistema hasta la fecha que contiene tanto estadísticas espaciales globales como locales. Está integrado con el GIS ArcView a través de una extensión, que, entre otras cosas, permite la visualización de mapas de dispersión de Moran y de ubicaciones con LISA significativa.

Las implementaciones computacionales modernas del análisis exploratorio de datos se basan en el paradigma de ventanas dinámicamente vinculadas, en el que el usuario interactúa con

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

diferentes “vistas” de los datos en la pantalla de una computadora. Las vistas típicamente consisten en gráficos estadísticos estándar como histogramas, diagramas de caja y diagramas de dispersión, pero cada vez incluyen más un mapa. El enlace dinámico consiste en permitir que un analista que usa un dispositivo apuntador (ratón) establezca conexiones entre puntos de datos en diferentes gráficos, resalte (pinte) subconjuntos de los datos y rote, corte y proyecte datos de alta dimensión (para una revisión reciente, ver Buja, Cook y Swayne 1996). Los datos geográficos pueden incluirse fácilmente en este marco cuando se visualizan como puntos x , y en un diagrama de dispersión estándar. Un marco más extenso que también incluye mapas coropléticos se propuso originalmente en el software Spider de Haslett, Unwin y asociados (Haslett, Wills y Unwin 1990; Haslett et al. 1991; Unwin 1996; Unwin et al. 1996).

Los esfuerzos recientes en este sentido también incorporan estadísticas espacialmente explícitas, como un gráfico de nube de variogramas o un diagrama de caja, un diagrama de dispersión de Moran y mapas de LISA en un visualizador de asociación espacial (Anselin 1998).

Un ejemplo práctico de un vínculo entre un GIS y diversas herramientas de análisis exploratorio de datos está representado por el trabajo de Symanzik y colegas (1998, 1999). Aquí, se obtiene una forma de integración de software entre el GIS ArcView y los paquetes de software EDA XGobi (Buja, Cook y Swayne 1996) y XploRe (Härdle, Klinkle y Turlach 1995). Este vínculo se basa en datos puntuales y permite la selección en un gráfico de nube de variogramas. Cada una de las herramientas de exploración puede usarse de forma aislada o vinculada con la otra. Siempre que los datos estén representados por puntos, se pueden obtener visualizaciones poderosas, incluyendo dinámicas espacio-temporales y conexiones multivariadas complejas. Por ejemplo, este método puede usarse para rastrear la ubicación y frecuencia de un tipo específico de crimen a lo largo del espacio y el tiempo, así como para sugerir correlatos potencialmente útiles. Un enfoque similar se toma en la implementación de ventanas dinámicamente vinculadas en la extensión DynESDA para ArcView (Anselin y Smirnov 1998). Aquí, una vista en ArcView se complementa con una serie de gráficos estadísticos, incluyendo histogramas, diagramas de caja, diagramas de dispersión y diagramas de dispersión de Moran, todos vinculados dinámicamente. Usando técnicas de selección y vinculación, se puede evaluar y visualizar tanto la asociación multivariada como la espacial entre varias variables. Una aplicación reciente de esta técnica al estudio de la difusión espacial de homicidios es la de Messner y colegas (1999).

Modelo Espacial

Las técnicas de análisis exploratorio revisadas en la sección anterior son extremadamente útiles para evaluar la existencia y ubicación de patrones locales no aleatorios en los datos espaciales. Sin embargo, también están limitadas por la falta de mecanismos para “explicar” los patrones observados. EDA y ESDA son exploratorios por naturaleza. “Sugieren”

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

asociaciones potenciales entre variables y generan hipótesis, pero la prueba formal de estas hipótesis se deja para el análisis confirmatorio, que generalmente se realiza mediante el modelado de regresión multivariada (Anselin y Getis 1992).

En el contexto específico de la justicia penal, el análisis de regresión juega un papel crucial en los intentos de explicar las causas de la actividad criminal (por ejemplo, Land, McCall y Cohen 1990; Kposowa y Breault 1993; DeFronzo y Hannon 1998). Hasta hace poco, el papel del espacio (y el espacio-tiempo) no se reconocía explícitamente en la metodología utilizada en estos estudios, pero es central en varios aspectos. Por ejemplo, es bien sabido que los delitos urbanos, como el robo y el allanamiento de morada, así como la mayoría de las categorías de delitos violentos, tienden a concentrarse espacialmente en áreas urbanas de bajos ingresos que tienen proporciones relativamente altas de personas desempleadas y minorías raciales. Esta concentración espacial tiende a resultar en autocorrelación espacial, lo cual va en contra de la suposición usual de independencia en el análisis de regresión. Además, los esfuerzos de aplicación de la ley (Chambliss 1994) y la actividad de las pandillas (Cohen et al. 1998) varían espacialmente, sugiriendo fuertemente la necesidad de una perspectiva espacial explícita (Roncek 1993) y la consideración de la heterogeneidad espacial (cambio estructural espacial). Una perspectiva espacial se motiva aún más por los hallazgos de diferencias espaciales a gran escala para diversos delitos (por ejemplo, urbanos, suburbanos y rurales, como se informa en los Informes Uniformes de Crimen del Federal Bureau of Investigation, así como en la Encuesta Nacional de Victimización del Crimen semestral del Bureau of Justice Statistics). Esto, a su vez, ha impulsado la búsqueda de mecanismos espaciales como la proximidad y la difusión para explicar estos fenómenos (Tolnay, Deane y Beck 1996; Morenoff y Sampson 1997; Sampson, Morenoff y Earls 1999).

El desafío de los efectos espaciales

En la mayoría de estos estudios, el análisis de regresión emplea datos de unidades transversales, como distritos censales o condados. Como se reconoce cada vez más, en este caso, se deben utilizar métodos especializados de análisis de regresión espacial (econometría espacial) para evitar resultados potencialmente sesgados e inferencias erróneas (Anselin 1988; Anselin y Bera 1998). Esto se debe a la presencia de efectos espaciales, que consisten en dependencia espacial y heterogeneidad espacial, los cuales violan los supuestos básicos subyacentes al análisis de regresión clásico. Los estadísticos han sido conscientes durante mucho tiempo de los problemas asociados con el análisis de datos espaciales (geográficos), pero las técnicas estadísticas espaciales no se difundieron en la práctica empírica de las ciencias sociales convencionales hasta recientemente (para una revisión, véase Anselin 1999b).

La motivación para la incorporación explícita de los efectos espaciales en los modelos de regresión que explican la actividad criminal es doble. Por un lado, los datos de criminalidad y de aplicación de la ley están fácilmente geocodificados, pero la escala espacial de

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

observación no siempre coincide con la escala espacial del proceso en estudio. Por ejemplo, la ocurrencia de ciertos tipos de delitos, como el tráfico de drogas ilícitas, puede explicarse mediante variables socioeconómicas y datos de uso del suelo recopilados a nivel de manzana. Sin embargo, si la zona de tráfico de drogas ilícitas para un grupo dado abarca varias manzanas, los datos de varias unidades de observación estarán correlacionados. De manera similar, si las variables no modeladas, como el “capital social” o el “sentido de comunidad”, se extienden a través de múltiples unidades de observación, se producirá una correlación espacial de estos “errores”. Por lo tanto, la preocupación por tener en cuenta la presencia de autocorrelación espacial en un modelo de regresión se debe al hecho de que el análisis se basa en datos espaciales para los cuales la unidad de observación es en gran parte arbitraria (como las unidades administrativas). La metodología se enfoca en garantizar que las estimaciones e inferencias del análisis de regresión (ya sea para modelos espaciales o no espaciales) sean correctas en presencia de autocorrelación espacial.

Por otro lado, gran parte del trabajo teórico reciente en sociología urbana, economía y criminología ha enfatizado conceptos relacionados con la “interacción” de los agentes, como la imitación, normas sociales, efectos de vecindario, difusión y otros efectos de grupos de pares. Estas teorías se centran en cuestiones de cómo las interacciones individuales pueden dar lugar a comportamientos colectivos emergentes y patrones agregados (por ejemplo, Brock y Durlauf 1995; Akerlof 1997; Durlauf 1994; Borjas 1995; Glaeser, Sacerdote y Scheinkman 1996). En este contexto, la necesidad de un modelo espacial explícito se impulsa por preocupaciones teóricas y el interés radica en una especificación correcta de la forma y el alcance de la interacción y la estimación de su fuerza.

Técnicas estadísticas espaciales

Las dos motivaciones diferentes para considerar los efectos espaciales en los modelos de regresión conducen a métodos para manejar la dependencia espacial como una molestia (problemas de datos) frente a la dependencia espacial sustantiva (impulsada por la teoría) (Anselin 1989). Formalmente, esto da lugar a técnicas para modelar la dependencia espacial en los términos de error del modelo de regresión o para transformar las variables en el modelo para eliminar la correlación espacial (filtrado espacial), frente a métodos para añadir explícitamente una variable de interacción espacial como uno de los regresores en el modelo. Lo común a todos los enfoques metodológicos es la necesidad de expresar rigurosamente la noción de “efectos de vecindad”, que se basa en el concepto de una matriz de pesos espaciales, discutido anteriormente. Una variable espacialmente explícita toma la forma de un “rezago espacial” o variable dependiente rezagada espacialmente, que consiste en un promedio ponderado de los valores vecinos. Más precisamente, el rezago espacial de una variable dependiente en la ubicación i , y_i , sería $S_j w_{ij} y_j$, donde la suma ponderada es sobre esos “vecinos” y que tienen un valor distinto de cero para el elemento w_{ij} en la matriz de pesos (o, en general, el peso es w_{ij}). Para fines prácticos, los elementos de la matriz de pesos

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

espaciales suelen ser estandarizados por fila, lo que facilita la interpretación y comparación entre modelos (para detalles técnicos, véase Anselin 1988, próximo; Anselin y Bera 1998).

Una especificación típica de una ecuación de regresión lineal que expresa interacción espacial sustantiva (o autocorrelación espacial) es el modelo regresivo mixto, autoregresivo espacial, o modelo de rezago espacial. Este incluye, además del conjunto habitual de regresores (por ejemplo, x_i , la parte regresiva), una variable dependiente rezagada espacialmente $S_j w_{ij} y_j$, (la parte autoregresiva espacial), con un coeficiente autoregresivo espacial r . La inclusión de un término de rezago espacial es similar a un término autoregresivo temporal en el análisis de series temporales, aunque hay varias diferencias importantes que requieren una metodología especializada para la estimación y la prueba.

La interpretación del modelo de rezago espacial se ilustra mejor con un ejemplo simple. Supongamos que estuviéramos interesados en explicar la tasa de criminalidad mediante las variables socioeconómicas habituales, así como por una medida de intervención policial, y asumamos que los datos se recopilan a nivel de distrito censal. El rezago espacial capturará la tasa de criminalidad promedio de los distritos vecinos. Esta medida de “criminalidad potencial” es una manera de formalizar la interacción espacial en el modelo. Por lo tanto, la significancia y el valor del coeficiente autoregresivo tienen una interpretación directa como una indicación de la fuerza de la interacción espacial. En nuestro ejemplo, la estimación de r sugeriría hasta qué punto la tasa de criminalidad en cada distrito censal está “explicada” por el promedio de los vecinos.

Existen dos posibles trampas en esta interpretación. En primer lugar, el rezago espacial no “explica” nada (de manera similar a un rezago temporal en series temporales), sino que es un proxy de la simultaneidad en todo el sistema. Esto se ve mejor de manera formal, pero para simplificar, se puede pensar en él como un multiplicador espacial. Después de transformar el modelo a forma reducida, de modo que solo queden variables “exógenas” en el lado derecho de la ecuación, se concluye que el valor de y en cada ubicación (por ejemplo, la tasa de criminalidad) depende no solo de las variables explicativas de esa ubicación (los x_i), sino también de estas variables en todas las otras ubicaciones, ajustadas adecuadamente para reflejar el efecto de la atenuación por distancia. En nuestro ejemplo, la presencia de un multiplicador espacial implica que un cambio en la intervención policial en una ubicación (distrito censal) no solo afecta la tasa de criminalidad en esa ubicación, sino también en todas las demás ubicaciones del sistema (debidamente atenuadas), de ahí la noción de un multiplicador.

El segundo problema se debe al uso de entidades agregadas, como distritos censales o condados, como unidades de observación. La interpretación del término autoregresivo como una indicación de “interacción” entre unidades puede llevar fácilmente a una “falacia ecológica”. Esto se debe al hecho de que estas unidades no son agentes sociales en sí mismas, sino solo agregados (promedios) de unidades de comportamiento individual. Inferir comportamientos individuales a partir de relaciones observadas a nivel agregado solo puede llevarse a cabo bajo un estricto conjunto de supuestos (imponiendo esencialmente una

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

homogeneidad extrema), lo cual es claramente injustificado en el contexto actual (para una discusión extensa, véase King 1997). Una interpretación alternativa es que el modelo de rezago espacial permite filtrar el efecto potencialmente confuso de la autocorrelación espacial en la variable en cuestión. La principal motivación para esto es obtener la inferencia correcta sobre los coeficientes de las otras covariables en el modelo (los β). Por ejemplo, la autocorrelación espacial de tipo rezago puede resultar de un desajuste entre la extensión espacial de la actividad criminal y el distrito censal como la unidad espacial de observación.

Desde el punto de vista de la estimación, el problema con este modelo es que el término de rezago espacial contiene las variables dependientes de las observaciones vecinas, las cuales, a su vez, contienen el rezago espacial de sus vecinos, y así sucesivamente, lo que lleva a la simultaneidad (el efecto multiplicador espacial mencionado anteriormente). Esta simultaneidad da lugar a una correlación no nula entre el rezago espacial y el término de error, lo que viola un supuesto estándar de la regresión. En consecuencia, la estimación de mínimos cuadrados ordinarios (OLS) dará lugar a estimaciones inconsistentes (y sesgadas), y la inferencia basada en este método será errónea. En lugar de OLS, deben emplearse métodos de estimación especializados que tengan en cuenta correctamente la simultaneidad espacial en el modelo. Estos métodos se basan ya sea en el principio de máxima verosimilitud (ML), o en la aplicación de estimación de variable instrumental (IV) en un enfoque de mínimos cuadrados en dos etapas.

A diferencia del modelo de rezago, existen varias formas de incorporar la autocorrelación espacial en la estructura del término de error del modelo de regresión. Los modelos más comúnmente utilizados se basan en procesos espaciales, como el proceso autoregresivo espacial (SAR) o el proceso de media móvil espacial (SMA), en paralelo a la convención de series temporales. La forma particular del proceso da lugar a una estructura de covarianza no diagonal para los errores, con el valor y signo de los elementos fuera de la diagonal que corresponden a la “correlación espacial” (es decir, la correlación entre los términos de error en dos ubicaciones diferentes).

Un aspecto interesante de esta estructura de correlación es el rango de interacción que implica. En un proceso SAR, cada término de error está correlacionado con todos los demás términos de error, pero la magnitud de la correlación sigue un efecto de atenuación por distancia. En otras palabras, la interacción implicada es global, como en el multiplicador espacial del modelo de rezago espacial. En contraste, el proceso SMA da lugar a una interacción local, en la que solo los vecinos de primer y segundo orden tienen una correlación no nula. Dado que esto se refiere a los términos de error en un modelo, o los efectos “ignorados” o “no medibles”, las dos especificaciones también tienen diferentes implicaciones políticas. Por ejemplo, si existiera un efecto “de vecindario” no medible en nuestro modelo de criminalidad, la especificación SAR implicaría que un cambio en este efecto en una ubicación afecta a todas las ubicaciones del sistema, mientras que en una especificación SMA, este cambio solo afectaría a los vecinos inmediatos. Sin embargo, más precisamente, estos errores de medición solo afectan la precisión de las estimaciones y, “en promedio”, su impacto es cero en la criminalidad predicha, a diferencia del multiplicador

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

espacial en el modelo de rezago, en el que los choques relacionados con el regresor (X) se transmiten a todo el sistema.

En el espacio, las varianzas de los errores también son heterocedásticas, lo cual no es el caso en el dominio temporal (véase Anselin y Bera 1998). La heterocedasticidad es inducida por el proceso espacial y complicará las pruebas de especificación (es decir, distinguir la “verdadera” heterocedasticidad de la inducida por un proceso espacial). Esta es una distinción importante entre los procesos de error espacial y su estructura de covarianza y su contraparte en series temporales.

Un enfoque alternativo para manejar los procesos espaciales es especificar la magnitud de la covarianza de error espacial como una función de la distancia que separa los pares de observaciones. Este enfoque de “representación directa” se inspira en la modelación geostatística y se adapta bien a la predicción espacial (o interpolación). A diferencia de los modelos de procesos espaciales, no hay heterocedasticidad inducida. Sin embargo, para que el enfoque de representación directa dé lugar a una covarianza válida (por ejemplo, para evitar varianzas negativas), deben cumplirse varias suposiciones restrictivas (véase, por ejemplo, Cressie 1993; Anselin próximo).

La estimación de modelos de error espacial se encuentra dentro de la categoría genérica de modelos de regresión con varianza de error no esférica. Técnicamente, se aplicará una forma de mínimos cuadrados generalizados, aunque, a diferencia del dominio temporal, no hay un procedimiento de estimación simple de dos pasos. En su lugar, se debe seguir un enfoque explícito de máxima verosimilitud o una técnica de momentos generalizados. En estos métodos, el coeficiente del modelo espacial se considera un “parámetro molesto” en el sentido de que mejora la precisión de las estimaciones de los regresores (b), pero en sí mismo es de poco interés.

En comparación con la dependencia espacial, los efectos espaciales en forma de heterogeneidad espacial pueden manejarse de manera bastante directa con modelos econométricos estándar. La heterocedasticidad resultante, los coeficientes variables o la inestabilidad estructural son distintos solo en el sentido de que la especificación de la heterogeneidad se realiza en términos de diferencias espaciales o regionales (por ejemplo, tasas de criminalidad diferentes en el centro de la ciudad en comparación con los suburbios). Sin embargo, dado que la heterogeneidad espacial a menudo ocurre junto con la dependencia espacial (o los dos son observacionalmente equivalentes), es necesaria una consideración explícita de la dependencia espacial en las aplicaciones empíricas. Ejemplos de técnicas que abordan la heterogeneidad espacial incluyen el análisis espacial de varianza (Sokal et al. 1993), coeficientes espacialmente variables como una forma de modelado lineal jerárquico en el método de expansión espacial (Jones y Casetti 1992; Casetti 1997), coeficientes de regresión localmente diferentes en el filtro adaptativo espacial (Foster y Gorr 1986; Gorr y Olligschlaeger 1994), regresión ponderada geográficamente (Brunsdon, Fotheringham y Charlton 1996; McMillen y McDonald 1997) y la corrección de valores atípicos espaciales mediante técnicas bayesianas (LeSage 1997, 1999).

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

Cuando se disponen de observaciones de una sección transversal en diferentes momentos de tiempo, en forma de datos de panel, es posible modelar combinaciones complejas de heterogeneidad y dependencia espacial. Por ejemplo, se pueden especificar diferentes coeficientes de modelo para diferentes subregiones y/o diferentes períodos de tiempo; los coeficientes autoregresivos espaciales pueden variar con el tiempo, etc. Los métodos apropiados para abordar estos modelos incluyen regresiones aparentemente no relacionadas, componentes de error y enfoques bayesianos, en conjunto con una dependencia de rezago espacial o de error espacial. Se ofrecen resúmenes de los problemas metodológicos en Anselin (1988, cap. 10; 1990b, 1999b) y LeSage (1995).

En la práctica, el aspecto más importante de la modelización espacial puede ser la prueba de especificación. De hecho, incluso si el descubrimiento de alguna forma de interacción espacial no es de interés principal, ignorar el rezago espacial o la dependencia de error espacial cuando están presentes crea una especificación incorrecta del modelo. De los dos efectos espaciales, ignorar la dependencia de rezago es la infracción más grave, ya que, como un problema de variable omitida, resulta en estimaciones sesgadas e inconsistentes para todos los coeficientes del modelo; y la inferencia derivada de estas estimaciones es defectuosa.

Cuando se ignora la dependencia de error espacial, el estimador de OLS sigue siendo insesgado, aunque ya no es el más eficiente. Además, las estimaciones de los errores estándar de los coeficientes de OLS estarán sesgadas y, en consecuencia, las pruebas t y las medidas de ajuste serán engañosas.

Estimación de modelos espaciales

Las pruebas de la presencia de posibles efectos espaciales se complican por varios factores. Primero, como se mencionó anteriormente, los procesos espaciales generan errores heterocedásticos, lo que dificulta distinguir la heterocedasticidad real de la inducida por los procesos espaciales. Lo contrario también es cierto; por lo tanto, las pruebas contra la dependencia espacial serán sensibles a la presencia de heterocedasticidad y podrían señalar la alternativa incorrecta. En segundo lugar, las especificaciones de rezago espacial y error espacial están estrechamente relacionadas, de modo que las pruebas contra una forma de dependencia también tendrán poder contra la otra forma, complicando de nuevo la búsqueda de especificación. En tercer lugar, todas las pruebas de efectos espaciales se basan en propiedades de grandes muestras (asimptóticas) y su desempeño en conjuntos de datos pequeños puede ser cuestionable.

A pesar de estos problemas, hay una serie de pautas prácticas que se pueden seguir en aplicaciones empíricas. El enfoque de prueba más sencillo es utilizar las pruebas de multiplicador de Lagrange basadas en los residuos de una regresión de MCO (Mínimos Cuadrados Ordinarios). Existen pruebas separadas para una alternativa de rezago espacial y una de error espacial, y hay una regla general que orienta al investigador en la dirección correcta (la prueba más significativa sugiere la alternativa adecuada). Otras pruebas con alta

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.

potencia se basan en la aplicación del índice de Moran a los residuos de la regresión, que es una prueba de especificación válida contra una amplia gama de alternativas y aplicable en varias especificaciones econométricas (Anselin y Kelejian 1997; Kelejian y Robinson 1998, 1999; Kelejian y Prucha 1999b; Pinkse 1999).

Los métodos econométricos espaciales no se incorporan rutinariamente en los paquetes de software comerciales. Por lo tanto, varios autores han desarrollado “trucos” para realizar estimaciones y pruebas de especificación utilizando macro o facilidades de script en software de computación estadística. Ejemplos de esto son rutinas en Limdep, Gauss, Shazam y S-Plus en Anselin y Hudak (1992), y estimación de máxima verosimilitud en SAS (Griffith 1993), Matlab (Pace y Barry 1998) o R (Bivand 1999). La estimación de modelos de error espacial está incluida en el complemento S+SpatialStats para el software S-Plus (MathSoft 1996), pero la única suite de rutinas completa para manejar tanto la prueba de especificación como la estimación se encuentra en SpaceStat (Anselin 1992).

Conclusión

Al acercarnos al final del siglo XX, el análisis espacial del crimen sigue estando en las primeras etapas de desarrollo. Muchas de las capacidades para apoyar el mapeo informatizado y el análisis estadístico espacial emergieron solo recientemente durante los años 90. La promesa de utilizar datos y análisis espaciales para el control del crimen aún está por demostrarse, y su utilidad depende de la naturaleza de la relación entre el crimen y el lugar. Si las características espaciales actúan como factores activadores del crimen, ya sea por las personas o las instalaciones ubicadas en esos lugares, entonces las intervenciones diseñadas para alterar a esas personas y actividades podrían afectar el crimen. Alternativamente, si la distribución espacial del crimen es esencialmente aleatoria, entonces enfocarse en lugares específicos probablemente no sea una estrategia efectiva para el control del crimen.

La investigación destinada a esclarecer la naturaleza de la relación entre lugar y crimen es crucial y se está volviendo cada vez más factible a medida que proliferan las capacidades de datos espaciales. Una de las primeras prioridades es la investigación sobre la naturaleza de los puntos calientes de crimen, especialmente el curso de vida típico (o “carrera” criminal) de las áreas con alta concentración de crimen, para determinar si los niveles inusualmente altos persisten durante algún tiempo. Si bien los análisis espaciales siguen siendo una herramienta prometedora, la etapa temprana de la investigación sobre la relación entre crimen y lugar es motivo de precaución. Se necesita considerable más investigación antes de considerar la ubicación como un objetivo primario para los esfuerzos de control del crimen. Tanto la investigación básica en ciencias sociales como la investigación aplicada bien diseñada sobre intervenciones policiales específicas serán de valor.

Texto original:

<https://www.ojp.gov/ncjrs/virtual-library/abstracts/criminal-justice-2000-volume-4-measurement-and-analysis-crime-and> // Traducido y adaptado al español por Violeta Misenti.