

# **ANÁLISIS ECOLÓGICO DE LA DELINCUENCIA EN LA CIUDAD DE BARCELONA**

**Autor:** Héctor Sánchez Delgado

**Tutor:** Josep Cid Moliné

**Co-tutor:** Daniel Montolio Estivill

26/05/2017

Proyecto de 4º Curso, Grado en Criminología



Universitat Autònoma de Barcelona

## **AGRADECIMIENTOS**

Gracias al presente proyecto he podido aprender nuevos métodos de análisis del delito, a desarrollar un estudio de una mayor envergadura que los habituales y me ha permitido focalizar esfuerzos en una temática que realmente me interesa.

Para poder llevarlo a cabo ha sido necesaria la colaboración de un gran número de personas:

En primer lugar agradecer a Josep Cid por ejercer de tutor de mi proyecto, aconsejarme y ofrecerme su ayuda en todo aquello que he necesitado.

En segunda instancia, agradecer su participación a Daniel Montolio, por ofrecerme su ayuda y los datos sin los cuales no podría haber realizado el trabajo.

En tercer lugar quisiera dar las gracias al profesor Weisburd, a Cesar San Juan y a Joel Martí por una útil discusión y dar su experta opinión sobre las unidades en que se debiera explicar la variable dependiente de delitos.

Finalmente, a todas aquellas personas que me han apoyado en este tiempo, que me han motivado y han hecho todo lo posible para echarme una mano.

# Índice

Resumen / <i>Abstract</i> .....	3
1. Introducción .....	4
2. Marco teórico .....	5
2.1. Teoría de la Desorganización Social (TDS) .....	6
2.2. Teoría de la Eficacia Colectiva (TEF) .....	7
2.3. Teoría de las Actividades Rutinarias (TAR) .....	7
2.4. Hipótesis .....	9
3. Metodología .....	9
3.1. Recogida de datos .....	9
3.1.1. Variable dependiente .....	11
3.1.2. Variables independientes .....	11
3.2. Localización del estudio .....	13
3.3. Unidades de análisis .....	14
3.4. Métodos de análisis .....	17
4. Análisis .....	22
4.1. Regresión de Poisson .....	22
4.2. Regresión de Binomial Negativa .....	23
4.3. Comparativa entre modelos .....	24
4.4. Análisis geográfico .....	24
5. Resultados .....	25
5.1. Teoría de la Eficacia Colectiva .....	27
5.1.1. Regresión de Poisson .....	27
5.1.2. Regresión de Binomial Negativa .....	28
5.1.3. Comparativa entre modelos .....	29
5.1.4. Gráficos de las predicciones de los modelos .....	30

5.1.5. Mapas de la distribución espacial .....	31
5.2. Teoría de la Desorganización Social .....	33
5.2.1. Regresión de Poisson .....	33
5.2.2. Regresión de Binomial Negativa .....	36
5.2.3. Comparativa entre modelos .....	40
5.2.4. Gráficos de las predicciones del modelo .....	41
5.2.5. Mapas de la distribución espacial .....	43
5.3. Teoría de las Actividades Rutinarias .....	45
5.3.1. Regresión de Poisson .....	45
5.3.2. Regresión de Binomial Negativa .....	47
5.3.3. Comparativa entre modelos .....	51
5.3.4. Gráficos de las predicciones del modelo .....	52
5.3.5. Mapas de distribución espacial .....	53
6. Conclusiones y discusión .....	56
6.1. Discusión .....	56
6.2. Limitaciones .....	57
6.3. Implicaciones .....	57
6.4. Futuras investigaciones .....	59
Referencias .....	61
Apéndice .....	65

## **Resumen/*Abstract***

En este trabajo se plantea estudiar empíricamente si la variabilidad en el número de delitos a nivel de sección censal en la ciudad de Barcelona puede ser explicada por algunas variables de tipo social, atendiendo a las diferentes teorías ecológicas consideradas. Para ello, se utiliza un método actual para el análisis de datos de recuento como es la regresión de Poisson y el de la Binomial Negativa. Además, también se realiza un análisis geográfico mediante QGIS y sus correspondientes paquetes. La importancia de este trabajo reside en el conocimiento de aquellas variables que predicen mejor el número de delitos, es decir, que si actuamos sobre ellas en el sentido en el que las encontramos, podremos prevenir o reducir las incidencias delictivas. Las conclusiones a las que llegamos nos pueden ayudar a diseñar políticas criminales adecuadas para las necesidades de Barcelona y, así, poder mejorar la ciudad. Por ejemplo, hemos visto que la teoría más explicativa es la de la Desorganización Social, resaltando el Índice de Simpson de heterogeneidad cultural como elemento novedoso y útil en la criminología española actual.

**Palabras clave:** Teorías Ecológicas, concentración delictiva, Barcelona, estadística.

In this project we will try to study empirically if the variation in the number of crimes in the census sections of Barcelona can be explained by some social variables related to the theories named before. For that purpose, we will use the count method of Poisson Regression and the Binomial Negative. In addition, QGIS will be used to analyse geographically the data. The importance of this work resides in the knowledge of which variables are better predictors of the number of crimes, which means that if we act on them, we could prevent or reduce the criminal conduct. The conclusions of the project can help to design appropriate criminal politics for the necessities of Barcelona and could improve the city. For example, we have found that the most explicative theory is the one of the Social Disorganization, with a huge importance of the Simpson Index of cultural heterogeneity as an innovative and helpful variable in the actual Spanish criminology.

**Key words:** Ecological Theories, criminal concentration, Barcelona, statistics.

# 1. Introducción

El origen de la criminología, a mediados del siglo XIX, se debe a la necesidad de la sociedad de encontrar elementos capaces de reducir la delincuencia, mediante la prevención y el tratamiento. Tal y como exponen Garrido, Stangeland y Redondo (2006), la criminología es aquella ciencia que estudia el comportamiento delictivo y la reacción social ante dicho comportamiento. Según Cid y Larrauri (2001), los criminólogos usan teorías del delito, distintos estudios e investigaciones, para las tareas relativas al ámbito.

Desde las primeras teorías denominadas *clásicas*, que explican la actividad delictiva mediante la valoración de costes y beneficios para decidir si delinquir o no de forma racional, hasta el desarrollo de corrientes más modernas, se han ido estableciendo distintas corrientes que han planteado diferentes modelos para explicar el delito. Una de ellas incluye las *Teorías Ecológicas* que, según Garrido et al. (2006), nacieron en 1892. Éstas se focalizan en aportar a la criminología la investigación de la influencia del *ambiente* de un lugar en el que las personas conviven con el delito (Cid y Larrauri, 2001).

En el presente proyecto se pretende llevar a cabo un estudio sobre las posibles diferencias en las concentraciones delictuales en las diferentes unidades de estudio de la ciudad de Barcelona y conocer qué elementos explican estas diferencias, si es que existen. Explicando los motivos por los que se selecciona la sección censal como unidad de análisis, comparándola con los distritos.

En cuanto a la metodología utilizada, se tendrá en cuenta la estadística como base del trabajo. El procurar que la criminología consiga resultados fiables y sea considerada como ciencia requiere, como condición *sine qua non*, que se rija por el método científico, lo que incluye el uso de instrumentos estadísticos en la investigación cuantitativa.

Mediante distintos análisis estadísticos se tratará de investigar las posibles correlaciones entre el número de delitos por unidad ecológica y los indicadores que las diferentes teorías criminológicas proponen para ver si realmente estos indicadores son explicativos, cuáles lo son en mayor medida, y comprobar la adecuación de las teorías consideradas a la realidad que nos ocupa.

Además, también trataremos de analizar la delincuencia con un método de gran utilidad que en la actualidad se encuentra en auge como es el análisis de datos geográficos. Tal y como comentan Vázquez y Soto (2013), así podremos analizar la distribución geográfica de las distintas variables, observar dónde se concentran y analizar el delito en base a aspectos sociodemográficos, urbanísticos, de movilidad poblacional o problemas sociales.

Posteriormente, se tratará de interpretar los resultados obtenidos y comprobar si las teorías criminológicas analizadas se corroboran y si hay alguna variable que destaque como especialmente indicada para el análisis del delito a nivel ecológico en la ciudad de Barcelona.

## 2. Marco teórico

Las *Teorías Ecológicas* del delito fueron ideadas por la *Escuela de Chicago*. Tal y como bien resumen Azpurúa (2005) y (Sampson, 2012), con Escuela de Chicago se hace referencia a unos trabajos de investigación en ciencias sociales llevados a cabo por profesores y estudiantes de distintas universidades entre las que destaca la Universidad de Chicago, con su máximo esplendor entre 1915 y 1940, tales como Ernest Burgess, Edwin Sutherland o Herbert Blumer. El origen de las Teorías Ecológicas se encuentra en dicha escuela y, según Garrido et al. (2006), nacieron en 1892 con la creación de su Departamento de Sociología y la publicación de “*La Ciudad*”. Las teorías tienen originariamente como autores principales a Robert Park y Ernest Burgess (Universidad de Chicago).

Las Teorías Ecológicas son aquéllas que aportan a la criminología el examen de la influencia del ambiente en el que las personas habitan sobre el fenómeno de la delincuencia. La hipótesis de estas teorías es que, con independencia de la clase de personas que viven en un lugar, existen formas de organización humana que producen más delincuencia que otras (Cid y Larrauri, 2001). Estas organizaciones humanas se producen en lugares desorganizados, con mucha movilidad poblacional (y por lo tanto poco control informal) o con una gran heterogeneidad cultural, cosa que hace más difícil para los habitantes de estos lugares alcanzar unos valores que vayan encaminados a realizar actos no desviados o convencionales (Cid y Larrauri, 2001).

Como comentan Newburn (2013), Garrido et al. (2006), Cano (2006) y Cid y Larrauri (2001), la hipótesis principal de esta teoría fue postulada por Ernest Burgess y explica que las ciudades Norteamericanas del momento (finales del siglo XIX y principios del siglo XX) tendían a ordenarse formando círculos concéntricos. La Zona Central de este entramado estaba ocupada en la mayoría de ciudades del momento por el centro de negocios y la industria. Las personas con menos recursos ocupaban la siguiente zona, que correspondía a la Zona de Transición y que estaba ubicada alrededor de este centro de la ciudad. A medida que los sucesivos círculos se iban alejando del centro, las zonas iban siendo más acomodadas y habitadas por grupos de individuos más favorecidos económicamente. Es por ello que el último círculo estaba formado esencialmente por barrios residenciales, ocupados por la clase media y alta. A partir de esta distribución urbana ideal, las personas menos acomodadas, por norma general los inmigrantes acabados de llegar al país, tendían a ocupar estas zonas más desfavorecidas de la ciudad, actuando en la Zona de Transición.

Dentro de las Teorías Ecológicas se incluyen diferentes teorías que consideraremos a continuación.

## **2.1. Teoría de la Desorganización Social (TDS)**

Esta teoría explica que, a nivel ecológico, la delincuencia se concentra en aquellos lugares con un cierto grado de deterioro físico, alta movilidad poblacional, pobreza, heterogeneidad cultural y desorganización social. En esta tesitura se dificulta la cohesión social, disminuyen las posibilidades de control y se expone más a los jóvenes a valores desviados (Cid y Larrauri, 2001).

Según Shaw y McKay (1942), los barrios con una alta desorganización social, lo son a pesar de que la población vaya y venga de forma constante. Es decir, mantienen sus características independientemente de su población. Además, la población de dichos barrios tiene una menor capacidad de organizarse para gestionar conflictos.

Según Salinas y Fuentes (2016), Shaw y McKay consideraron que había distintos elementos que dificultaban la organización social de un lugar: bajo estatus socioeconómico,

heterogeneidad cultural o alta movilidad poblacional.

Cuando se dificulta la interacción y comunicación entre vecinos y hay una cohesión menor, es más sencillo que aumente la tasa delictiva y que disminuya el control. Además, habrá una nula capacidad de actuación conjunta ante problemas sociales que involucren a toda la población, como la delincuencia.

Para Cid y Larrauri (2001), el primer trabajo empírico en relacionar la desorganización social y el delito, fue el de Shaw y McKay (1942), donde se llevó a cabo un estudio en la ciudad de Chicago que demostró que en aquellas áreas centrales, que a su vez eran las más desorganizadas, también existían más casos de delitos juveniles.

## **2.2. Teoría de la Eficacia Colectiva (TEF)**

A continuación, consideramos la Teoría de la Eficacia Colectiva. Para Sampson et al. (1997), la eficacia colectiva se define en base a la cohesión social junto a la predisposición a actuar o intervenir en beneficio del bien común. Los autores consideran este elemento como esencial para la reducción de la delincuencia. Además, también se tiene en cuenta el control informal que se ejerce sobre los residentes de la zona a la hora de actuar, como principio para prevenir el delito.

Álvarez (2015) observó que en aquéllos lugares en los que había una mayor implicación del vecindario, se reducía el delito, por esa doble vertiente de mayor preocupación por el barrio y un aumento del control social informal.

Browning (2002) explica que la cohesión social promueve la capacidad de una comunidad para “monitorizar” y controlar en las situaciones sociales con potencial criminógeno. Se puede considerar que aquellas comunidades que son capaces de regular el delito local también son aquéllas con un alto nivel de eficacia colectiva.

## **2.3. Teoría de las Actividades Rutinarias (TAR)**

Según Cohen y Felson (1979), Cid y Larrauri (2001), Felson y Clark (1998) y Osgood, Wilson, O'malley, Bachman y Johnston (1996), la *Teoría de las actividades rutinarias*

explica que los cambios en las actividades cotidianas afectan a la tasa delictiva cuando confluyen tres elementos:

- 1) Infractor motivado.
- 2) Objeto deseado.
- 3) Ausencia de vigilancia.

Esta teoría explica que ciertos espacios pueden congregar una mayor tasa delictiva debido a que coinciden en espacio y tiempo los tres aspectos mencionados. Aunque inicialmente se creó como explicación para los delitos predatórios en E.E.U.U. después de la Segunda Guerra Mundial, posteriormente se ha desarrollado como una teoría que concibe los delitos como *actividades rutinarias*.

La Teoría de las Actividades Rutinarias tiene en especial consideración las oportunidades de delinquir, como condición necesaria para su explicación. Es decir, parte de la premisa de que sin oportunidades, no se produciría el delito y de que las condiciones ambientales son tan importantes como las individuales (Salinas y Fuentes, 2016).

Al igual que en las teorías clásicas del delito, el delincuente es considerado un ser racional, que en base a la evaluación de costes y beneficios, decide si delinquir o no por la situación en la que se encuentra y las formas de organización social que pueden facilitar la comisión del delito.

En un estudio de Álvarez (2015), mediante entrevistas a agentes de policía del barrio de Contruces (Gijón) se destaca como principal resultado la existencia de relación entre la actitud de implicación del vecindario y el delito. Encontró que en aquellos lugares en los que existen lo que el autor denomina como “guardianes” (vecinos implicados por la mejora del barrio) la delincuencia disminuye. Es decir, el aumento del control social informal hace que aumente la presencia de vigilancia y disminuya la delincuencia.

Otro estudio con resultados interesantes es el de Sánchez y Fuentes (2015), en el cual se analiza el robo de vehículos en la Ciudad de México mediante una regresión lineal múltiple. Los resultados fueron que hubo algunas variables que influían en esta tipología delictiva:

1. Uso de suelo destinado a comercio y servicios.
2. Nivel bajo de estudios y escolarización.
3. Alta densidad poblacional.

## 2.4. Hipótesis

Las hipótesis planteadas son las que se presuponen de las tres teorías criminológicas que he propuesto: Teoría de las Actividades Rutinarias, Teoría de la Desorganización Social y Teoría de la Eficacia Colectiva. Por ello, pretendo comprobar si sus hipótesis son adecuadas en el contexto de la ciudad de Barcelona y si se pueden corroborar a partir de los datos de los que dispongo y que explicaré en apartados posteriores. Estas hipótesis son:

**H1)** A mayor desorganización social, mayor concentración delictual.

**H2)** A menor eficacia colectiva, mayor concentración delictiva.

**H3)** A mayor concentración de delincuentes motivados, mayor concentración delictiva.

**H4)** A mayor cantidad de objetos deseados, mayor concentración delictiva.

**H5)** A menor vigilancia, mayor concentración de la delincuencia.

## 3. Metodología

### 3.1. Recogida de datos

Los datos de la variable dependiente son aquéllos que hacen referencia a los delitos cometidos en la ciudad de Barcelona. Su obtención ha podido ser gracias al profesor Daniel Montolio (UB) que ha dado acceso a los datos de los Mossos d'Esquadra necesarios para el análisis. Corresponden a Barcelona en el año 2014, que es el último año del que se tiene la totalidad de los datos a fecha de hoy. Las variables independientes se refieren a los indicadores de las distintas teorías y son las que aparecen en la tabla, encontrando entre paréntesis el nombre de la variable en el programa estadístico:

	<b>Elemento</b>	<b>Indicador (variable)</b>	<b>Año</b>
<b>Teoría de la Eficacia Colectiva</b>	Eficacia Colectiva	Participación electoral (Electoral).	2015
<b>Teoría de las Actividades Rutinarias</b>	Infractor motivado	Tasa de paro (Paro) y porcentaje de población sin estudios (Estudios).	2014 ambos.
	Objeto deseado	Porcentaje de superficie del lugar dedicado al comercio, a la hostelería y al turismo (Superficie) y densidad de población (Densidad).	2014 en la superficie, 2015 en Densidad.
	Ausencia de Vigilancia	Número de comisarías de Mossos y de Guardia Urbana (Comisarías).	2016
<b>Teoría de la Desorganización Social</b>	Heterogeneidad cultural	Número de extranjeros, comunitarios y nacionales: índice de Simpson (Simpson).	2011
	Deterioro físico	Incidentes de degradación del espacio público por cada 1000 habitantes (Degradación).	2012
	Pobreza	Número de coches y motos por cada 1000 habitantes (Coches_motos) e índice de renta familiar (Renta),.	2014 ambos.
<b>Otra</b>	Alta movilidad poblacional	Evolución de la población (Evolución_población) y número de contratos de alquiler (Alquiler).	2014-16 ambos.
	Variable a tener en cuenta en análisis “count”	Número de habitantes (Población).	2015

**Figura 1:** tabla-resumen de las distintas variables independientes, la teoría a la que pertenecen y los años de los que se han obtenido los datos.

### **3.1.1. Variable dependiente**

La variable dependiente considerada en el trabajo es la del número de delitos, una variable contadora y que se puede obtener por sección censal. En ella encontramos que cada fila se refiere a una sección censal de Barcelona y se indica el total de delitos por tipología específica y general. Es decir, encontramos la clasificación en unas tipologías delictivas más generales como puede ser delitos contra las personas y, dentro de ésta, las tipologías de homicidio o lesiones imprudentes, entre otras.

Finalmente se agregaron todas las tipologías en una única variable de delitos que incluía todas ellas y que sería la que se usaría en el análisis final.

### **3.1.2. Variables independientes**

En primer lugar, se ha considerado la *participación electoral* como indicador de Eficacia Colectiva y la variable que se ha usado es el porcentaje de participación electoral en las elecciones autonómicas del año 2015. El uso de esta variable se justifica en el estudio de la ciudad de Chicago de Weisburd, Groff y Yang (2012). Fuente: página web del Ayuntamiento de Barcelona, dentro del informe sobre las elecciones a las que me refiero.

En cuanto a la Teoría de las actividades Rutinarias en su vertiente del *infractor motivado*, he escogido la tasa de paro y el porcentaje de personas sin estudios obligatorios. En el caso del paro se entiende que cuando una persona carece de recursos puede optar por la vía delictiva para obtener aquello que no puede obtener por la vía lícita, lo que lo convierte en un infractor motivado. En cuanto al nivel de estudios, algunos trabajos como el de Machin, Marie y Vujic (2011) explican que a largo plazo el hecho de invertir en educación es realmente útil para reducir el delito. De hecho, tal y como explican Salinas y Fuentes (2016), muchos estudios empíricos sugieren que altas tasas de paro y bajos niveles de educación, entre otras, son variables asociadas a la delincuencia y a la variable concreta de infractor motivado. Además, también se considera la pobreza como elemento de motivación, aunque se ha considerado como elemento de Desorganización Social. Fuente: Departamento de Estadística del Ayuntamiento de Barcelona, por sección censal en el caso del nivel de estudios y por barrio en el caso de la tasa de paro.

El segundo elemento de la TAR es la **presencia de objeto deseado**, que se ha traducido en el porcentaje de superficie destinado a comercio, hostelería y comercio, además de la densidad de población (población total/superficie total). La idea es que ambas variables explicarían una mayor concentración de personas y de objetos tanto los que llevan consigo(tales como móviles, relojes o joyas) como los expuestos en comercios o establecimientos abiertos al público. Fuente: Departamento de Estadística del Ayuntamiento de Barcelona.

El tercer elemento de la TAR es la **ausencia de vigilancia**, que se ha interpretado en base a la presencia o no de comisarías de policía, tanto de Mossos d'Esquadra como de Guardia Urbana. La elaboración de la variable ha sido propia y se ha llevado a cabo localizando todas ellas e identificando su posición mediante el programa QGIS. Curiosamente, la mayoría de las secciones censales carecen de comisaría ya que hay exactamente dos por distrito, pero una de ellas tiene las dos correspondientes a su distrito.

Finalmente, la Teoría de la Desorganización social, se ha representado mediante la heterogeneidad cultural, el deterioro físico, la alta movilidad poblacional y la pobreza.

La **heterogeneidad cultural** se mide con el Índice de Simpson<sup>1</sup>, que será explicado en detalle más adelante pero que se construyó en base a los datos por sección censal del número de nacionales, extranjeros comunitarios y extranjeros extra-comunitarios que se encuentran en Barcelona. Fuente: Servicio de Datos Abiertos del Ayuntamiento de Barcelona.

Como indicador del **deterioro físico**, se utiliza el número de incidentes de degradación del espacio público por cada mil habitantes. Fuente: Anuario Estadístico de la Ciudad de Barcelona 2008 – 2012, por distrito.

Como indicadores de **pobreza** introducimos el número de coches y motos por cada 1000 habitantes y el índice de renta familiar. La idea es que a mayor número de coches y motos, mayor capacidad adquisitiva. En el caso de la renta familiar, ya directamente se infiere que

---

<sup>1</sup> Indicador de biodiversidad poblacional que en nuestro caso será usado según el origen de los ciudadanos de cada sección censal. Sus valores se encuentran entre 0 y 1, siendo 0 una homogeneidad total de la población y 1 una mayor heterogeneidad de origen de ésta.

a mayor renta, mayor capacidad adquisitiva. Según Ciafardini (2006, citado en Juárez y Navarrete 2007, pg. 3) la pobreza no es sinónimo de delincuencia, pero si se cronifica puede llevar a la marginalidad y la adopción del delito como forma de vida. Según Wilson (1987), aquéllas zonas con una mayor concentración de pobreza, son aquéllas en las que existe un nivel de desocupación y de dependencia del bienestar social muy elevados. Además, son zonas en las que no existe una transmisión de valores culturales fuertes ligados a las instituciones sociales comunitarias de gestión de recursos y donde no existe un control social del grupo que sancione las conductas antisociales del lugar. Fuente: Departamento de Estadística del Ayuntamiento de Barcelona, por sección censal en el caso del número de coches y de motos, por barrio en el caso del índice de renta familiar.

El último elemento de esta teoría es la **movilidad poblacional** se escogió la evolución de la población y el número de contratos de alquiler como indicadores. Si la evolución poblacional es negativa y además es una variación importante, podremos decir que existe una movilidad poblacional elevada. Además, en aquellos lugares en que haya mayor número de contratos de alquiler, serán aquéllos en que la población sea menos estable y haya una mayor movilidad. Donnangelo (2012) afirma que el hecho de que los habitantes de una zona no se conozcan entre sí (debido a la alta densidad y movilidad) debilita el compromiso y apego con la comunidad, y la supervisión y vigilancia directa de unos sobre otros. Fuente: Departamento de Estadística del Ayuntamiento de Barcelona, por sección censal.

Como último indicador encontramos el **número de habitantes**, que no se encuentra dentro de ninguna teoría pero su presencia se debe que la variable dependiente de delitos es de tipo recuento. Si estuviéramos tratando de investigar en tasas de victimización, por ejemplo, deberíamos usar la ratio poblacional, pero como nos interesa la concentración delictiva debemos usar como variable independiente el número de habitantes y tener en cuenta el tamaño de la población del lugar. Fuente: Departamento de Estadística del Ayuntamiento de Barcelona, por sección censal.

### **3.2. Localización del estudio**

En términos generales, las Teorías Ecológicas se han aplicado en ciudades estadounidenses

por lo que sería interesante intentar aplicar dichas teorías a Barcelona. Se ha elegido esta ciudad por tener un tamaño suficientemente grande, por su cercanía geográfica y por la mayor accesibilidad a datos que nos supone. Aunque ya se han realizado otros estudios sobre la delincuencia en la ciudad como puede ser el de Garrido, Stangeland y Redondo (2006) en el cual se llevó a cabo, entre otros, un mapa ecológico de la ciudad de Barcelona, el presente trabajo es novedoso porque aporta una nueva perspectiva a este tipo de estudios.

Otros artículos delincuenciales que toman como referencia Barcelona son el de Pérez (2012) o el de Valera y Guàrdia (2014). En el primer caso se llevó a cabo un estudio observacional sistemático de cuatro meses para entender si existía relación entre la inseguridad y el espacio público. En segunda instancia, Valera y Guàrdia se refieren al miedo al delito como uno de los problemas más importantes de Barcelona, inclusive en aquellas zonas con unas tasas delictivas inferiores. Un total de 570 personas fueron encuestadas sobre sus experiencias previas, su nivel de seguridad personal o la identidad de pertenencia a la comunidad.

### **3.3. Unidades de análisis**

A la hora de llevar a cabo el estudio, debemos escoger qué unidad de análisis usar. Por tanto, tenemos que escoger una de las tres divisiones que existen: barrio, distrito y sección censal.

En base a las Teorías Ecológicas, se debería escoger la unidad de análisis menor para llevar a cabo un trabajo más exhaustivo y que pueda representar en mayor medida la realidad. Esto apuntaría hacia las secciones censales como unidad de estudio. En este sentido, en diferentes estudios como el de Groff, Weisburd y Yang (2010) se ha evidenciado una variabilidad significativa intra-barrio a nivel de delitos que no sería tenida en cuenta si se tomasen los barrios como unidades de estudio, por lo que se debe realizar el estudio a un nivel más "micro". Por ello, las unidades de estudio deben ser menores que los barrios y en este trabajo se han escogido las secciones censales. Existe, sin embargo, un nivel todavía inferior y más "micro" que es el de segmento de calle, pero no se ha podido llevar a cabo ya que los datos de que se disponía son a nivel de la sección censal. Incluso algunas de las variables explicativas se tenían sólo a nivel de distrito o de barrio. En estos casos se ha

extrapolado el valor de la variable a todas las secciones censales del mismo distrito (o barrio, respectivamente).

Finalmente, destacar que se han descartado trece de las secciones censales de la base de datos del total de 1069 por no coincidir algunos datos en las bases de datos oficiales como las del Ayuntamiento de Barcelona y la de delitos de los Mossos d'Esquadra. Esto se podría deber a que la sección censal es una división del territorio que va variando con el tiempo ya que depende de la población que las habita. Por lo tanto, si hay movimientos poblacionales en el territorio, también habrá modificaciones en la estructura de las secciones.

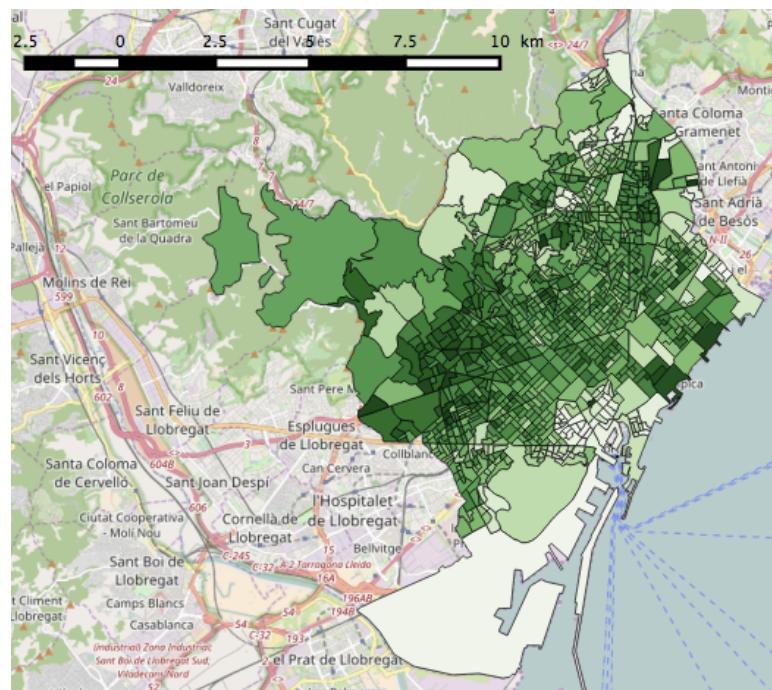
Para comprobar la idoneidad de usar un nivel de análisis inferior se han calculado las correlaciones bivariadas entre las variables independientes y el número de delitos a nivel de sección censal y de distrito para comprobar cuál era mejor:

Variable	Correlaciones con la variable Número de Delitos por Sección Censal		Correlaciones con la variable Número de Delitos por Distrito	
	P. valor	Correlación	P. valor	Correlación
Participación electoral	0,1860	-0,04069	0,1383	-0,503
% población sin estudios obligatorios	0,0000 ***	-0,1604	0,9867	0,006061
Tasa de paro	0,0050 ***	-0,08617	0,3848	0,3091
% superficie destinada a turismo, hostelería y comercio.	0,0000 ***	0,1588	0,0032 **	0,8268
Densidad poblacional	0,2232	-0,03748	0,1739	0,4667
Número de comisarías de policía	0,8432	-0,006087	0,2441	0,4062
Población	0,0000 ***	0,1575	0,0655	0,5727
Índice de Simpson	0,0000 ***	0,262	0,0133 *	0,7455
Incidentes degradación	0,7850	0,008397	0,7261	0,1273
Coches/motos	0,0492	-0,06048	0,1173	-0,5273
Renta familiar	0,0000 ***	0,1514	0,5796	-0,2
Evolución población	0,4308	0,02425	0,0816	0,5758
Evolución contratos de alquiler	0,0978	0,05092	0,5334	0,2242
Tasa de emigración	0,0000 ***	0,2007	0,0376 *	0,6606

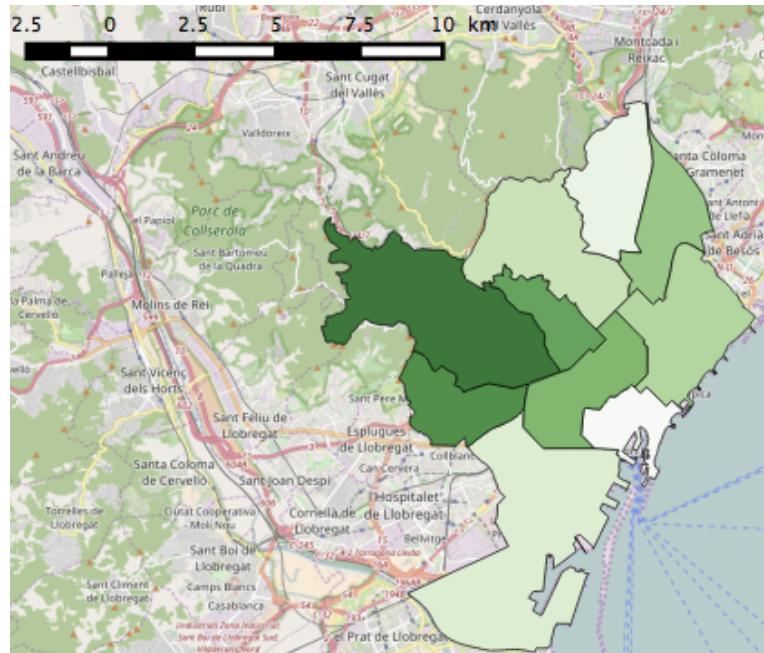
**Figura 2:** tabla de correlaciones bivariadas de *Spearman* entre la variable dependiente Delitos y cada una de las variables independientes.

Se puede ver que mientras que a nivel de sección censal siete de las variables están correlacionadas significativamente con el número de delitos en la ciudad de Barcelona, a nivel de distrito sólo tres de las variables lo están. Por ello se puede afirmar que es mejor realizar un análisis micro ya que las mismas variables a un nivel más general no funcionan del mismo modo.

Otro ejemplo es la comparativa de la representación gráfica del porcentaje de participación electoral. Aquí observamos que no se puede apreciar la concentración de las menores tasas y, en consecuencia, una menor eficacia colectiva, de la misma forma en ambos mapas.



**Figura 3:** mapa sobre el porcentaje de participación electoral en las elecciones autonómicas de 2015 por sección censal.



**Figura 4:** mapa sobre el porcentaje de participación electoral en las elecciones autonómicas de 2015 por distrito.

### 3.4. Métodos de análisis

Los métodos estadísticos que se han usado para el proyecto son de diversa índole.

1. **Las variables independientes:** En primer lugar, dos de las variables independientes consideradas se han construido mediante ciertos cálculos a partir de la información disponible.

1.1. Variable "Simpson": Se ha considerado el Índice de Simpson como indicador para medir la diversidad o heterogeneidad poblacional a partir de la tipología de origen. Se define como la probabilidad de que dos individuos escogidos al azar de una sección censal pertenezcan a distinta tipología de origen.

El *Índice de Simpson* fue introducido por Edward H. Simpson para medir el nivel de concentración de individuos cuando éstos se clasifican en distintos tipos (Simpson, 1949). Tiene su mayor uso en las ciencias naturales, sobretodo en biología, para cuantificar la abundancia o diversidad de especies en un entorno

determinado. Por su lado, He y Hu (2005) llevaron a cabo un estudio para conocer cómo de eficiente era el índice, concluyendo que es un parámetro realmente útil y cuyo uso es adecuado. También se utiliza en Economía, ámbito en el que se conoce por el nombre de Índice de Herfindahl o de Herfindahl-Hirschman.

Como es una probabilidad, los valores del índice se expresan por números entre 0 y 1. Su interpretación es: cuanto más próximo a 1, mayor heterogeneidad de origen, y cuanto más próximo a 0, mayor homogeneidad de origen, es decir, mayor dominancia de uno de los orígenes (Cámara y Díaz, 2013). La fórmula es la siguiente:

Donde S es el número de tipologías de orígenes diferentes (luego S=3), N es el número total de habitantes y  $n_i$  es el número de individuos del origen i.

$$D = 1 - \frac{\sum_{i=1}^S n_i (n_i - 1)}{N (N - 1)}$$

1.2. Variable Evolución de la población: Como indicador de la variabilidad en la evolución de la población de las secciones censales entre los años 2014 y 2016, que podría ser, a priori, una variable explicativa del número de delitos, se calcula el **Coeficiente de Variación**, para cada sección censal, del número de habitantes en los tres años consecutivos considerados.

Este coeficiente es una medida de variabilidad de una distribución de frecuencias (Everitt, 1998) que mide la dispersión de unos datos relativa a su media y permite comparar la variabilidad de datos que se encuentran expresados en diferentes unidades o en diferentes escalas de magnitud.

Se suele expresar en porcentaje multiplicando por 100 y se calcula así:

$$CV = \frac{s}{\bar{x}}$$

donde  $s$  indica la desviación estándar de los valores de población en los tres años (en cada sección censal), y  $\bar{x}$  su media. Cuanto mayor sea el resultado, mayor variabilidad, es decir, más fluctuación en la población de la sección censal en los tres años considerados relativa a su media.

2. **La variable dependiente:** La variable "Delitos", que es la variable dependiente del modelo que consideraremos, es de tipo *recuento* ya que refleja el número de ocurrencias de un delito en las secciones censales de Barcelona, a lo largo de un período concreto de tiempo (el año 2014). Podríamos haber considerado la variable "Delitos" no como variable de recuento sino como tasa de delitos (nº de delitos dividido por el tamaño de la población, usualmente expresada como delitos por cada 100,000 habitantes) y haber realizado un análisis de regresión OLS (Ordinary Least Squares). Por diferentes razones, esta opción está desaconsejada cuando en muchas de las unidades de estudio se produce un número pequeño de delitos como es nuestro caso, y es preferible considerar la variable como recuento, que es lo que se ha hecho. Algunas de estas razones son:

1. Tratándose en su mayoría de delitos contra la propiedad, muchas veces perpetrados por personas que no residen en la sección censal donde delinquen, en muchos casos siendo también las víctimas no residentes, no tiene sentido dividir el número de delitos por el número de habitantes en la sección censal.
2. Cuando el número de delitos es pequeño, no podemos esperar una distribución de los errores de las tasas de delitos que sea simétrica ni normal: como el menor valor posible para el número de delitos es 0, la distribución de los errores será tanto más sesgada y discreta cuanto más se acerquen las tasas de delitos a 0. Esto es, a medida que la población disminuye, se observaría una tasa delictiva de 0 en más y más unidades, lo que provocaría un sesgo en las estimaciones de los coeficientes del modelo de regresión.

Por lo anterior, en nuestro estudio usaremos como variable explicada el nº de delitos (variable de recuento) en cada unidad censal, no la tasa delictiva.

3. **El modelo de regresión de Poisson:** Buscaremos un modelo predictivo para el nº de delitos en Barcelona por sección censal, a partir de las variables explicativas consideradas para cada una de las tres Teorías Ecológicas, evitando la colinealidad de las variables dentro de cada modelo. Para ello, aplicaremos el modelo de regresión de Poisson, que es el modelo de regresión adecuado para las variables de recuento. A veces, cuando se tiene variables de tipo recuento, una opción es transformarlas usando la función logaritmo y analizarlas, una vez transformadas, usando OLS. Esto resulta problemático porque: el logaritmo de 0 no está definido (es  $-\infty$ ), por lo que si hay valores de recuento que sean 0, obtendremos valores faltantes. La suposición de normalidad del logaritmo de la variable recuento del modelo OLS no tiene por qué cumplirse. En nuestro caso, en particular, no se cumple. Esto lo hemos podido comprobar mediante el test de Shapiro-Wilk para el logaritmo de delitos. Su hipótesis nula hace referencia a que la muestra proviene de una población distribuida normalmente. Si el p.valor es menor que 0,05 diremos que se rechaza esta opción y diremos que no hay normalidad.

Por ello se ha desestimado esta posibilidad y se utiliza, en su lugar, la **regresión de Poisson** para el nº de delitos. Un ejemplo del uso de la Regresión de Poisson es el del artículo de Osgood, Wilson, O'malley, Bachman y Johnston (1996), donde se llevó a cabo un estudio sobre el número de llamadas a la policía y su concentración en la ciudad de Minneapolis, para conocer la naturaleza criminógena de los lugares llamados *hot spots*.

La principal hipótesis de la **Regresión de Poisson** es la igualdad entre la media y la varianza (equi-dispersión). Comprobaremos que esta hipótesis no se cumple con nuestros datos (hay sobre-dispersión). La sobre-dispersión está presente, generalmente, en todos los análisis de datos sobre delitos porque no podemos esperar que la regresión de Poisson explique toda la variabilidad en el número de delitos y las diferencias entre

las predicciones y las observaciones serán mayores de lo que serían si las variables regresoras explicasen toda esta variabilidad. Además, la varianza de los residuos también es mayor que la media (sobre-dispersión) si la suposición de independencia entre los delitos individuales cometidos no es aceptable.

4. **El modelo de regresión de la Binomial Negativa:** Debido a la sobre-dispersión, en segunda instancia se usará el modelo de regresión de la *Binomial Negativa*, que es un modelo alternativo al de la regresión de Poisson para una variable de tipo recuento cuando hay sobre-dispersión, es decir, cuando los datos presentan mucha más variabilidad de la que puede representarse con el modelo de Poisson. En realidad, es una generalización del modelo de Poisson, con el mismo tipo de estructura, pero en el que hay un parámetro extra que permite incorporar la sobre-dispersión en el modelo, lo que nos permitirá realizar una comparativa de ambos modelos. Si no se tuviese en cuenta la sobre-dispersión y se usase el modelo de Poisson, los errores estarían infraestimados, lo que llevaría a una sobre-estimación de la significación de los parámetros. Por ello, los intervalos de confianza para los parámetros del modelo de la Binomial Negativa son de menor longitud (por tanto, mejores) que los correspondientes al modelo de Poisson.

Estos dos modelos (así como el de la regresión *quasi-poisson*, que no se usará pero que es otra alternativa a la regresión de la Binomial Negativa cuando hay sobre-dispersión en la regresión de Poisson), y también los procedimientos estadísticos necesarios para trabajar con ellos, se encuentran implementados en la mayoría de paquetes estadísticos (SAS, SPSS,...). En el trabajo se utiliza R<sup>2</sup> y algunos de sus paquetes. Una explicación más detallada de los dos modelos se puede encontrar en el Apéndice.

En el caso del modelo de regresión de la Binomial Negativa, encontramos un artículo de Fergusson y Horwood (2000) que analiza la posible relación entre el abuso del

---

<sup>2</sup> R es un entorno de software libre para la computación y gráficos estadísticos que se puede obtener a través de la página del proyecto *Comprehensive R Archive Network (CRAN)* <http://cran.t-project.org>

alcohol y la delincuencia. Mediante la regresión de la Binomial Negativa, se examinó a jóvenes de entre 15 y 21 años de Nueva Zelanda y se encontró que el aumento del abuso de alcohol estaba directamente relacionado con los delitos violentos y contra la propiedad. Así, podemos ver que la Regresión de la Binomial Negativa ya se ha aplicado con éxito a diversos artículos criminológicos.

5. **El análisis geográfico:** Finalmente, se ha llevado a cabo un análisis geográfico de los delitos en Barcelona con una representación mediante una gama de colores que indiquen la distribución espacial, tanto del número de delitos, como de otras variables independientes como puede ser el Índice de Simpson. Este método ha sido usado en gran cantidad de artículos científicos como en el de Sánchez y Fuentes (2016), que representaron mediante un mapa el número de robos de vehículos en la Ciudad de México.

## 4. Análisis

En primer lugar es necesario reconocer la posible colinealidad entre variables independientes, ya que su presencia entre las variables predictoras de un modelo de regresión es una violación de las hipótesis del modelo y representa un problema frecuente en ciencias sociales. Si las variables predictoras se encuentran en combinación lineal entre ellas (es decir, no son independientes), su influencia sobre el elemento a explicar (en este caso, los delitos) no puede distinguirse al superponerse unas con otras (González, 1998). Por ello, consideraremos diferentes modelos pero en cada uno de ellos se partirá de una variable independiente y se irán añadiendo otras correspondientes a la misma Teoría Ecológica considerada (*stepwise*), siempre que no haya colinealidad entre ellas.

### 4.1. Regresión de Poisson

En primer lugar creamos el modelo base, con solo *intercept*, es decir, sin variables regresoras, y calculamos una estimación de Alpha (parámetro de sobredispersión) para conocer hasta qué punto podemos confiar en los resultados de este modelo de regresión (si hay sobredispersión, el modelo no es correcto). También obtenemos tanto el AIC (Criterio

de Información de Akaike sobre la calidad relativa del modelo estadístico para un conjunto de datos) como la *Residual Deviance* (desviación del modelo respecto del modelo "ideal" que contiene tantos parámetros como casos) para cada una de las variables que conformen la teoría que analicemos. Estos valores nos los proporciona la salida del correspondiente comando de R.

Aquellas variables con un AIC y una *Residual Deviance* menores, serán las que mejor expliquen el número de delitos. De entre éstas, escogeremos aquéllas que no estén correlacionadas para evitar la co-linealidad, y las añadiremos al modelo del mismo modo: escogiendo la combinación que presente valores de AIC y *Residual Deviance* menores. Además, el p-valor correspondiente a la estimación del parámetro de la variable ha de ser menor que 0,05 para que la introducción de esa variable suponga una mejora significativa para el modelo.

A continuación calculamos la pseudo-R<sup>2</sup>, que es una medida de ajuste del modelo a los datos, y hacemos el Test de la ji-cuadrado para ver si es significativamente mayor que 0. Si es así querrá decir que la variable que nos ocupe influye en la respuesta de número de delitos y su valor nos indicará en qué porcentaje es capaz de explicar la variabilidad en el número de delitos. Del mismo modo que anteriormente, realizamos un Test ji-cuadrado que permita conocer si las variables que vayamos añadiendo al modelo lo mejoran significativamente.

Un problema que nos podemos encontrar con el Modelo de Regresión de Poisson es que haya sobre-dispersión, como ya hemos comentado, y que entonces se infra-estime los errores de los parámetros con lo que salen muchas mas significaciones de las que deberían.

## 4.2. Regresión Binomial Negativa

En primer lugar creamos el modelo base, con solo *intercept*, sin variables regresoras, del mismo modo que en la Regresión de Poisson. Luego vamos añadiendo variables de una en una, *stepwise*, siempre escogiendo aquéllas que llevan a un mejor modelo y evitando la colinealidad.

Para hacer la elección de las variables a ir introduciendo en el modelo, se observan los

valores del parámetro de sobre-dispersión Alpha, el AIC y la *Residual Deviance* de cada uno de los modelos considerados, escogiendo siempre el mejor modelo.

Sucesivamente realizaremos tests del tipo LRT (Likelihood Ratio Test) para ver si al introducir una nueva variable en el modelo, éste mejora significativamente. Si el p.valor da pequeño ( $< 0,05$ ), podremos decir que la variable representa una contribución significativa en la predicción de la variable respuesta de número de delitos.

### 4.3. Comparativa entre modelos

Compararemos los modelos en cada teoría que hayamos seleccionado como “mejores” usando la Regresión de Poisson, con los “mejores” obtenidos con la Regresión de la Binomial Negativa mediante un test de la ji-cuadrado. Si el p.valor es menor que 0,05, podremos decir que uno de los dos modelos es mejor que el otro, concretamente, el modelo de la Binomial Negativa será mejor ya que su *Residual Deviance* será inferior.

A continuación, realizaremos unos gráficos de comparación de residuos para comprobar de forma más visual que efectivamente el modelo que se considera mejor lo es. Los gráficos son box-plots para los residuos con los dos modelos: el de Poisson y el de la BN. El mejor modelo tendrá menores residuos.

Finalmente, elaboraremos distintos gráficos que nos muestren, por un lado, la relación de algunas de las variables del modelo con la predicción para el número de delitos de forma individual y, por otra, junto con otra variable. De este modo veremos de forma gráfica la evolución de la predicción para el número de delitos que da el modelo en función de la variable independiente.

### 4.4. Análisis geográfico

Para conocer cómo se distribuyen espacialmente el número de delitos y las mejores variables independientes de los modelos seleccionados, realizamos mapas geográficos con QGIS<sup>3</sup>. Para ello, debido a que carecemos de las coordenadas geográficas concretas de

---

<sup>3</sup> QGIS es un sistema de información geográfica de código libre que permite la construcción de mapas y manejo de datos de diversa índole como Shapefile o Arcinfo.

cada uno de los delitos, debemos realizar un mapa donde cada sección censal sea una unidad y se le asigne un color dentro de una escala de colores. No se indica la leyenda de colores en cada mapa por haber muchos colores diferentes, pero siempre un tono más oscuro indica un valor más elevado de la variable respuesta.

En primer lugar debemos obtener una capa que corresponda a las secciones censales de Barcelona, para poder unirla por propiedades a una hoja de Excel que presente una columna común a la capa de secciones y que contenga la cantidad de delitos asociada a cada una de las secciones censales. De este modo, podremos acceder al apartado de propiedades del QGIS y realizar una representación categorizada de la variable.

## 5. Resultados

En primer lugar explicaremos los elementos básicos de interpretación de las tablas que se irán mostrando a continuación para los diferentes modelos de regresión que construiremos.

La **significación estadística** de los parámetros estimados del modelo se denota mediante asteriscos, siguiendo la nomenclatura habitual:

- \* significación al 5%
- \*\* significación al 1%
- \*\*\* significación al 1 por mil.

El **AIC (Akaike Information Criterion)** ofrece una estimación relativa de la información perdida cuando se usa un modelo concreto para representar un proceso que genera los datos. Cuanto menor, mejor es el modelo. Su definición es:

$$AIC = -2 \times \text{log-likelihood} + 2 \times n^{\circ} \text{ parámetros},$$

siendo log-likelihood el logaritmo de la verosimilitud (*likelihood*) del modelo, que es la probabilidad de observar los datos que realmente hemos observado, con el modelo. Interesa que el valor del **AIC** sea pequeño, por lo que vemos que el término que suma es un término

de penalización por complejidad (nº de parámetros) del modelo. En igualdad de condiciones, el modelo más simple es mejor (principio de la navaja de Ockam).

En la regresión OLS, la correlación múltiple al cuadrado  $R^2$  es una medida de la proporción de la variación en la variable respuesta que es explicada o debida a los regresores. En la regresión de Poisson, no existe una analogía directa de esta medida. Sin embargo, todos los modelos estimados mediante el método EML (Estimación de la Máxima Verosimilitud), como el de Poisson, nos permiten obtener la **Residual deviance**, que es una medida de desajuste del modelo. Concretamente, es una medida de desviación del modelo respecto de uno que ajuste perfectamente los datos (un modelo que tuviese tantos parámetros como casos, que son las secciones censales, con lo que predeciría los valores del número de delitos para cada sección censal perfectamente). La **Residual deviance** se irá reduciendo a medida que se vayan añadiendo predictores al modelo, siempre que los regresores tengan algún tipo de efecto sobre la variable predicha. La *Residual deviance* permite calcular una medida **Pseudo-R2** para evaluar lo bien que el modelo se ajusta a los datos, ya que representa la reducción proporcional en la *Residual deviance* debida a la inclusión de los predictores del modelo. Para calcularla debemos restar de uno el cociente entre la Residual Deviance del modelo seleccionado y la Residual Deviance del modelo con el que comparamos. Por ejemplo, si queremos calcular la Pseudo-R2 del modelo que incluye las variables regresoras Superficie, Densidad y Paro, cuya Residual Deviance se denota por `modelo.1$deviance`, en relación al modelo sin variables (con sólo *intercept*), cuya Residual deviance se denota por `modelo.0$deviance`, sería:

$$\begin{aligned} \text{Pseudo.R2} = \\ 1 - (\text{modelo.1$deviance}/\text{modelo.0$deviance}) \end{aligned}$$

Finalmente, tendremos en cuenta el valor **Alpha** como medida de sobre-dispersión, que se calcula dividiendo la **Residual deviance** entre sus grados de libertad. Cuanto menor sea, menor sobre-dispersión habrá.

## 5.1. Teoría de la Eficacia Colectiva

### 5.1.1. Regresión de Poisson

	<b>Modelo base</b>	<b>Modelo 1</b>
	<i>Intercept</i>	Intercept + Electoral
Estimación <i>Intercept</i>	5,05129 ***	8,2267717 ***
Estimación 1a variable		-0,0419488 ***
Residual Deviance	302.582	284.155
AIC	309.140	290.714,1
Pseudo-R2		0,061
Alpha	286,2653	269,0861

**Figura 5:** tabla-resumen de los resultados de la Regresión de Poisson para la Teoría de la Eficacia Colectiva.

Vemos que todos los parámetros son significativos al 1 por mil. Esto se puede deber a la sobre-dispersión que se comentaba anteriormente, que aumenta la significación. Se puede realizar un Test de Dispersión, mediante la función *dispersiontest* del paquete *AER* de *R*. Si el p.valor es menor que 0,05, entonces diremos que existe sobre-dispersión con una significación del 5%. En este caso, como el p.valor es de 0,0003112, así que podemos decir que sí que existe sobre-dispersión.

### 5.1.2. Regresión de la Binomial Negativa

	Modelo base	Modelo 1
	<i>Intercept</i>	<i>Intercept</i> + Electoral
Estimación <i>Intercept</i>	5,05128 ***	7,916659 ***
Estimación la variable		0,037859 ***
<i>Residual Deviance</i>	1240	1230,7
AIC	12.796	12.715
Alpha	0,8523	0,8580

**Figura 6:** tabla-resumen de los resultados de la Regresión de la Binomial Negativa para la Teoría de la Eficacia Colectiva.

Al igual que la anterior tabla, vemos que la significación de todos los parámetros es del 1 por mil, pero a diferencia del modelo de Regresión de Poisson, tanto la ***Residual deviance*** como el ***AIC*** son mucho menores, lo que refleja que el modelo se ajusta mejor a la realidad. Cuando analizamos ***Alpha***, vemos que es muy menor a lo encontrado en la Regresión de Poisson, lo que significa que se ha solucionado el problema de la sobre-dispersión, ya que el modelo ahora lo tiene en cuenta.

Mediante el comando de ***drop1*** de R, pretendemos conocer si la contribución de la variable que se ha añadido al modelo es significativa. Si el correspondiente p.valor es menor que 0,05 consideraremos que así es. En este caso el p.valor es < 2.2e-16, por lo que la contribución sí que es significativa.

Finalmente, observamos los intervalos de confianza para los parámetros del modelo, que contendrán al verdadero valor del parámetro (desconocido) con una confianza del 95%. En particular, con una probabilidad de equivocarnos del 5%, podemos decir que el *intercept* es >7 o que el parámetro (coeficiente) de la variable Electoral es negativo, por ejemplo.

	Estimación del parámetro	2,5%	97,5%
(Intercept)	7,91665864	7,27780065	8,5736509
Electoral	-0,03785941	-0,04634033	-0,0295644

**Figura 7:** tabla-resumen de la estimación de los parámetros del modelo de la Regresión de la Binomial Negativa de intervalos de confianza (al 95%).

**MODELO PREDICTIVO PARA LA TEORIA EFICIACIA COLECTIVA  
(MODELO DE REGRESIÓN DE LA BINOMIAL NEGATIVA)**  
 $\log(\lambda^{\wedge}) = 7,91665864 - 0,03785941 \times \text{Electoral}$

donde  $\lambda^{\wedge}$  es la predicción del número de delitos.

Aplicación: si tuviésemos una sección censal para la que la participación electoral fuese del 90% , por ejemplo, ¿cuál es la predicción que nos da el modelo?

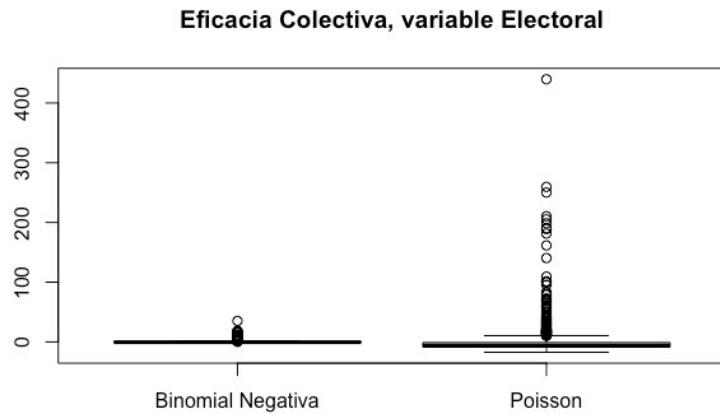
$$\text{Log}(\lambda^{\wedge}) = 7,916659 - 0,037859 * 90 = 7,916659 - 3,40731 = 4,509349$$

**Luego la predicción para el nº de delitos =  $\lambda^{\wedge} = \exp(4,509349) = 90,86$ .**

Por lo tanto, para un sección censal con un 90% de participación electoral, la predicción del número de delitos que nos da el modelo sería de entre 90 y 91 delitos.

### 5.1.3. Comparativa entre modelos

Para comparar ambos modelos de regresión, el de Poisson y el de la Binomial Negativa, es interesante realizar un *boxplot* que nos permita comparar sus residuos y así poder ver cuál es el modelo más ajustado a la realidad. Como los residuos son las diferencias entre los valores observados para la variable dependiente, y los valores predichos, cuanto menores son, mejor es el modelo.



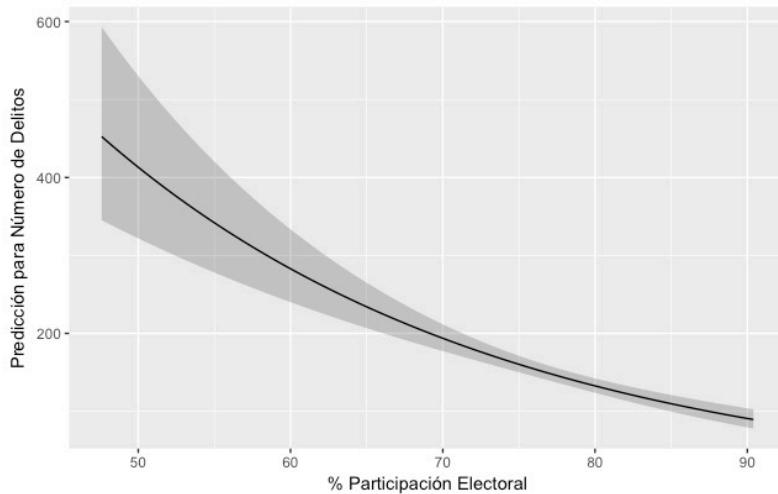
**Figura 8:** boxplot comparativo entre los residuos de los modelos de Regresión de Poisson y de la Binomial Negativa.

Claramente la Regresión de la Binomial Negativa muestra unos residuos menores y por ello debemos considerarla como una mejor alternativa a la de Poisson.

Mediante un test ji-cuadrado comparamos ambos modelos a través de la comparación de sus Residual Deviances. Si el p-valor es menor que 0,05 podremos decir que el que tiene la menor Residual Deviance es mejor que el otro. En este caso, el que tiene menor Residual Deviance es el de la Binomial Negativa, y el p-valor es menor que 0.05, por lo que este modelo es significativamente mejor.

#### 5.1.4. Gráficos de las predicciones del modelo

Finalmente, podemos ver cómo evoluciona la predicción que da el modelo para el número de delitos en función de la participación Electoral. La predicción es la línea continua de color negro. La banda alrededor de ella muestra el error de la predicción.

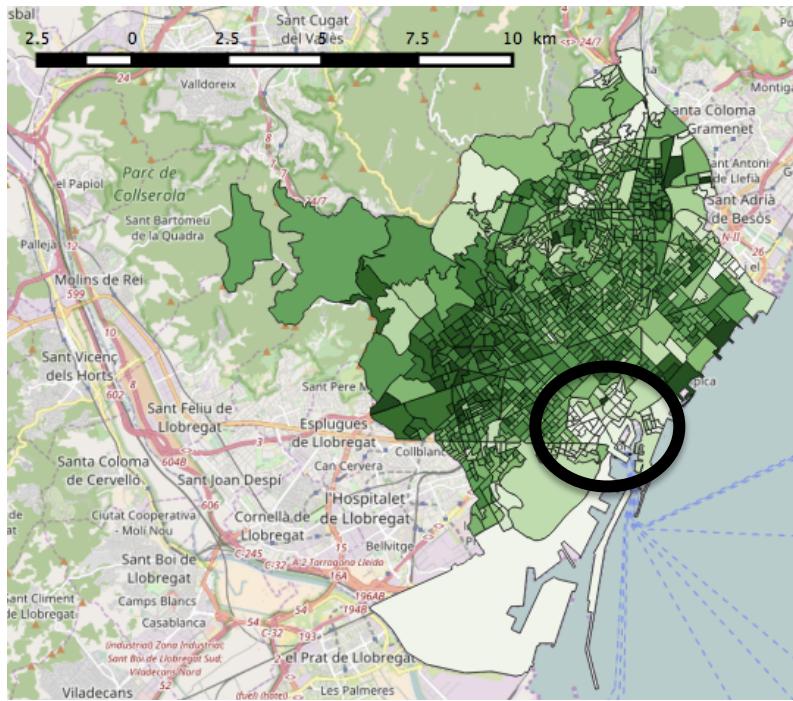


**Figura 9:** gráfico de la evolución de la predicción para el número de delitos en función del porcentaje de participación electoral.

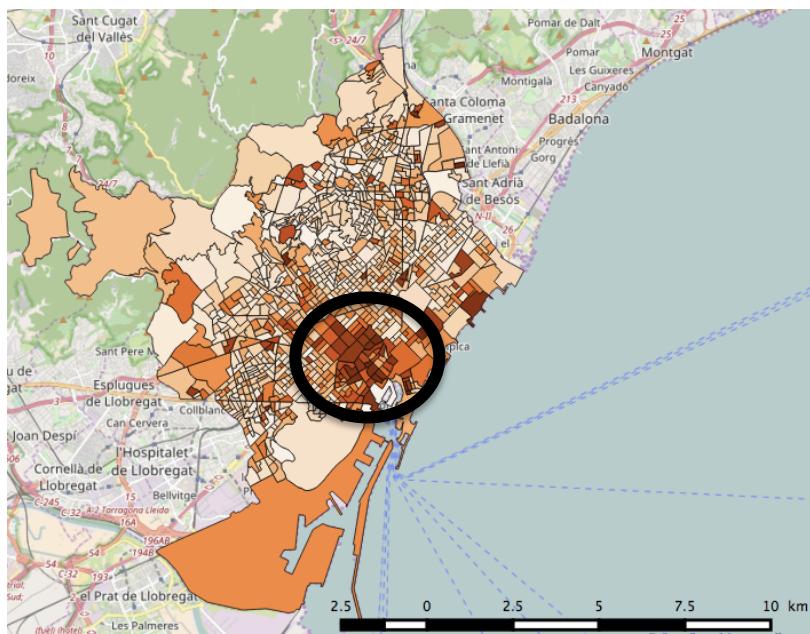
Vemos que a medida que la participación electoral aumenta, la predicción para el número de delitos disminuye. Por lo tanto, podemos afirmar que en este aspecto el modelo es congruente con la Teoría de la Eficacia Colectiva, que explica que a mayor participación electoral mayor cohesión social e implicación de la comunidad en los aspectos comunes, lo que reduce la delincuencia. Por otro lado, es interesante destacar que el modelo que hemos encontrado tiene mayor precisión en la predicción a medida que aumenta la participación electoral, mientras que si la participación electoral es baja, el error en la predicción del número de delitos es mayor.

### 5.1.5. Mapas de distribución espacial

Finalmente, realizamos un mapa con la distribución de la participación electoral por secciones censales, siendo aquellas secciones censales más oscuras las que presentan una mayor participación electoral y un mapa del número de delitos, donde también la mayor intensidad de color denota un mayor número de delitos.



**Figura 10:** Distribución del porcentaje de participación electoral por sección censal.



**Figura 11:** distribución del número de delitos por sección censal.

Comparando ambos veremos que en la zona central, donde se concentra la mayor cantidad de delitos, también se observa una menor participación electoral, mientras que toda la parte periférica, que destaca por la poca presencia delictiva, también coincide con la que presenta una tasa de participación electoral mayor.

## 5.2. Teoría de la Desorganización Social

### 5.2.1. Regresión de Poisson

Consideraremos tres modelos finales para esta teoría, partiendo de las variables Degradación, Emigración o Simpson (añadiendo todas las variables no correlacionadas con ellas que se pueda, en cada caso).

1. MODELO A (Degradación + Coches\_motos + Evolucion\_poblacion):

	Modelo base	Modelo 1	Modelo 2	Modelo 3
	<i>Intercept</i>	<i>Intercept + Degradación</i>	<i>Intercept + Degradación + Coches_motos</i>	<i>Intercept + Degradación + Coches_motos + Evolucion_poblacion</i>
Estimación <i>Intercept</i>	5,05129 ***	4,6562168 ***	4,362 ***	4,395 ***
Estimación 1ª variable		0,0329621 ***	0,03399 ***	0,03421 ***
Estimación 2ª variable			0,000515 ***	0,000519 ***
Estimación 3ª variable				-0,029430 ***
<i>Residual Deviance</i>	302.582	238.418	231.124	230.954
AIC	309.140	244.977	237.686	237.517
Pseudo-R2		0,2120	0,23616	0,2367
Alpha	286,2653	225,7748	219,0753	219,1215

**Figura 12:** tabla-resumen de los resultados de la Regresión de Poisson para la Teoría de la Desorganización Social. Modelo A.

Vemos que la significación de todos los parámetros de los tres modelos considerados es del 1 por mil. Esto se puede deber a la sobre-dispersión. Llevamos a cabo el test de sobre-dispersión y vemos que en cada caso existe dicha sobre-dispersión ( $p$ -valor < 0,05). Los  $p$ -valores de este test son los siguientes, para los modelos con 1, 2 o 3 variables:

- Degradación: 0,002545
- Degradación + Coches\_motos: 0,002456

- Degradación + Coches\_motos + Evolucion\_poblacion: 0,002581

## 2. MODELO B (Emigración + Degradación + Alquiler):

	<b>Modelo base</b>	<b>Modelo 1</b>	<b>Modelo 2</b>	<b>Modelo 3</b>
	<i>Intercept</i>	<i>Intercept</i> + Emigración	<i>Intercept</i> + Emigración + Degradación	<i>Intercept</i> + Emigración + Degradación + Alquiler
Estimación Intercept	5,05129 ***	2,914867 ***	3,9178542 ***	3,8279339 ***
Estimación 1ª variable		0,05905 ***	0,0229441 ***	0,0226083 ***
Estimación 2ª variable			0,0256605 ***	0,0259037 ***
Estimación 3ª variable				0,007248 ***
Residual Deviance	302.582	260.804	234.998	234.460
AIC	309.140	267.363	241.559	241.023
Pseudo-R2		0,138072	0,223359	0,2251375
Alpha	286,2653	246,74	222,7467	222,4476

**Figura 13:** tabla-resumen de los resultados de la Regresión de Poisson para la Teoría de la Desorganización Social. Modelo B.

Llevamos a cabo el test de sobre-dispersión y vemos que en cada conjunto de variables hay sobre-dispersión. Los p-valores son:

- Emigración: 0,001495
- Emigración + Degradación: 0,003397
- Emigración + Degradación + Alquiler: 0,003518

### 3. MODELO C (Simpson + Renta):

	<b>Modelo base</b>	<b>Modelo 1</b>	<b>Modelo 2</b>
	<i>Intercept</i>	<i>Intercept + Simpson</i>	<i>Intercept + Simpson + Renta</i>
Estimación <i>Intercept</i>	5,05129 ***	3,44928 ***	2,75400 ***
Estimación 1ª variable		5,12045 ***	5,46200 ***
Estimación 2ª variable			0,005814 ***
Residual Deviance	302.582	231.647	222.520
AIC	309.140	238.206	229.081
Pseudo-R2		0,2344325	0,2645974
Alpha	286,2653	219,3629	210,9193

**Figura 14:** tabla-resumen de los resultados de la Regresión de Poisson para la Teoría de la Desorganización Social. Modelo C.

Llevamos a cabo el test de sobre-dispersión y vemos que en cada caso existe sobre-dispersión, ya que los p-valores son:

- Simpson: 1,057e-05
- Simpson + Renta: 7,038e-07

## 5.2.2. Regresión de la Binomial Negativa

En este caso, sólo dos de los modelos anteriores aparecen como significativos:

1. MODELO B' (Emigración + Degradación + Alquiler):

	<b>Modelo base</b>	<b>Modelo 1</b>	<b>Modelo 2</b>	<b>Modelo 3</b>
	<i>Intercept</i>	<i>Intercept + Degradación</i>	<i>Intercept + Degradación + Emigración</i>	<i>Intercept + Degradación + Emigración + Alquiler</i>
Estimación <i>Intercept</i>	5,05129 ***	4,67847 ***	3,955501 ***	3,807983 ***
Estimación 1ª variable		0,03095 ***	0,02415 ***	0,024085 ***
Estimación 2ª variable			0,02237 ***	0,02289 ***
Estimación 3ª variable				0,009477 *
<i>Residual Deviance</i>	1240,1	1.214,3	1.212,3	1.211,7
AIC	12.796	12.559	12.591	12.538
Alpha	1,173	1,1492	1,1490	1,1496

**Figura 15:** tabla-resumen de los resultados de la Regresión de la Binomial Negativa para la Teoría de la Desorganización Social. Modelo B'.

En este caso en concreto, vemos que la variable *Alquiler* presenta una significación menor que las encontradas hasta el momento y, además, no mejora la capacidad explicación del modelo en gran medida. Vemos que la mejor variable del modelo es la de incidentes de degradación, mientras que las otras mejoran el modelo sin que sea algo realmente notorio.

Mediante el comando *drop1* de R, realizamos los tests para ver si hay contribución significativa de las variables que se han ido añadiendo al modelo. Los p-valores son:

- Degradación: < 2,2e-16
- Degradación + Emigración: 6,83e-06

- Degradación + Emigración + Alquiler: 0,02434

Lo que indica que *Alquiler*, como ya hemos comentado, tiene una significación un tanto escasa.

Las estimaciones de los parámetros y los correspondientes intervalos de confianza (con el 95% de confianza) son:

	Estimación del parámetro	2,5%	97,5%
(Intercept)	3,807982871	3,441709251	4,16568197
Degradoación	0,024084841	0,018406484	0,02993597
Emigración	0,022890325	0,012720054	0,03337947
Alquiler	0,009477411	0,001171465	0,01855958

**Figura 16:** tabla-resumen de la estimación de los parámetros del modelo B' e intervalos de confianza (al 95%).

### MODELO PREDICTIVO PARA LA TEORIA DESORGANIZACION SOCIAL (MODELO DE REGRESIÓN DE LA BINOMIAL NEGATIVA)

#### MODELO B'

$$\log(\lambda^{\wedge}) = 3,807982871 + 0,024084841 \times \text{Degradoación} + 0,022890325 \times \text{Emigración} + 0,009477411 \times \text{Alquiler}$$

donde  $\lambda^{\wedge}$  es la predicción del número de delitos.

Por ejemplo, si tenemos una sección censal con 58 incidentes de degradación del espacio público por cada 1000 habitantes, una tasa de emigración del 5% y 10 contratos de alquiler, la predicción que da este modelo para el número de delitos se calculará así:

$$\begin{aligned} \log(\lambda^{\wedge}) &= 3,807982871 + 0,024084841 * 58 + 0,022890325 * 5 + \\ &0,009477411 * 10 = 6,444194009 \end{aligned}$$

Luego la predicción para el nº de delitos en esa sección censal con este modelo será =  $\lambda^{\wedge} = \exp(6,444194009)$ = aprox. 629 delitos.

## 2. MODELO C' (Simpson + Renta)

	Modelo base	Modelo 1	Modelo 2
	<i>Intercept</i>	<i>Intercept + Simpson</i>	<i>Intercept + Simpson + Renta</i>
Estimación <i>Intercept</i>	5,05129 ***	3,70849 ***	3,2698317 ***
Estimación 1ª variable		4,28395 ***	4,23699 ***
Estimación 2ª variable			0,00447 ***
<i>Residual Deviance</i>	1240,1	1206,1	1202,5
AIC	12.796	12.479	12.444
Alpha	1,173	1,1421	1,1398

**Figura 17:** tabla-resumen de los resultados de la Regresión de Binomial Negativa para la Teoría de la Desorganización Social.

De nuevo, podemos comprobar que tanto el AIC como la Residual Deviance son menores que en el caso de la Regresión de Poisson. Además, también podemos comprobar mediante Alpha que el problema de la sobre-dispersión se ha solventado.

Como elementos a destacar encontramos lo mismo que hemos visto en la Regresión de Poisson: Simpson por sí sola es muy explicativa y el índice de renta a pesar de que mejore el modelo lo hace de manera muy menor.

Del mismo modo que en los casos anteriores, realizamos el test de sobre-dispersión con la función *drop1* de R, y obtenemos unos p-valores menores que 0,05:

- Simpson: < 2,2e-16

- Simpson + Renta: 9,16e-10

Las estimaciones de los parámetros y los intervalos de confianza con este modelo:

	<b>Estimación de parámetros</b>	<b>2,5%</b>	<b>97,5%</b>
(Intercept)	3,269831738	3,074284016	3,466956254
Simpson	4,236990822	3,786289965	4,694676285
Renta	0,004472843	0,003004089	0,005978963

**Figura 18:** tabla-resumen de la estimación de los parámetros del modelo C' e intervalos de confianza (al 95%).

Siendo el modelo:

**MODELO PREDICTIVO PARA LA TEORIA DESORGANIZACION SOCIAL  
(MODELO DE REGRESIÓN DE LA BINOMIAL NEGATIVA)  
MODELO C'**

$$\log(\lambda^{\wedge}) = 3,269831738 + 4,236990822 \times \text{Simpson} + 0,004472843 \times \text{Renta}$$

Para una sección censal cuyo Índice de Simpson sea de 0,6 y la renta de 66, el número de delitos predicho por el modelo se obtiene a partir de:

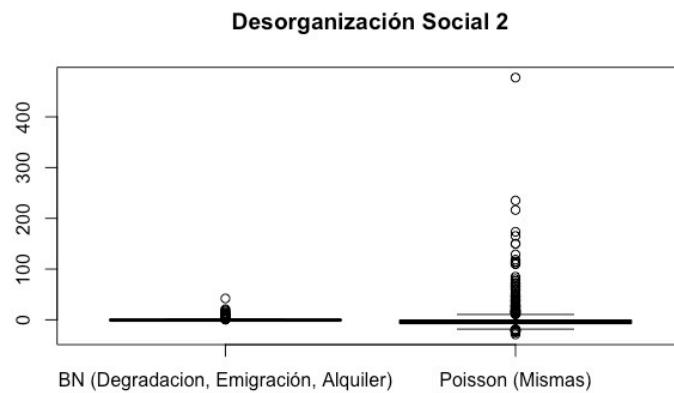
$$\begin{aligned} \log(\lambda^{\wedge}) &= 3,269831738 + 4,236990822 * 0,6 + 0,004472843 * 66 = \\ &= 6,10723366 \end{aligned}$$

**A este dato, hay que realizar la exponencial para poder obtener la predicción para el número de delitos que da el modelo**

$$= \lambda^{\wedge} = \exp(6,10723366) = \text{aprox. 449 delitos.}$$

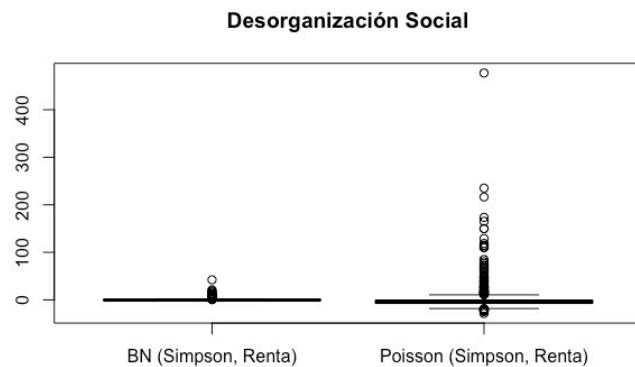
### 5.2.3. Comparativa entre modelos

#### 1. Modelos B-B':



**Figura 19:** *boxplot* comparativo entre los residuos de los modelos B de Regresión de Poisson y B' de la Binomial Negativa.

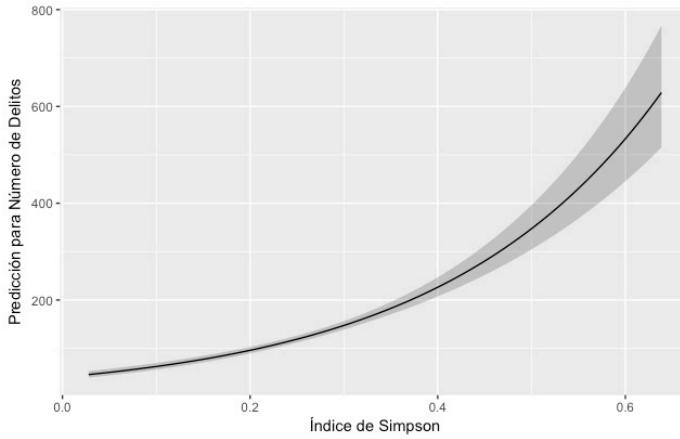
#### 2. Modelos C-C':



**Figura 20:** *boxplot* comparativo entre los residuos de los modelos C de Regresión de Poisson y C' de la Binomial Negativa.

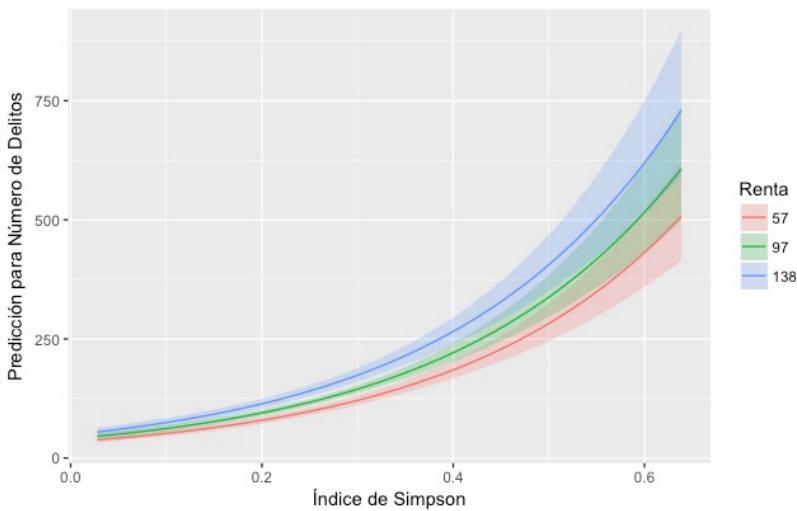
Vemos que ambos casos el modelo de la Regresión de la Binomial Negativa nos da menores residuos y por ello este modelo es mejor que el de la Poisson.

#### 5.2.4. Gráficos de las predicciones del modelo



**Figura 21:** gráfico de la evolución de la predicción para el número de delitos en función del Índice de Simpson. Modelo C'-1.

En este gráfico podemos ver que a medida que aumenta el índice de Simpson, es decir, a medida que aumenta la heterogeneidad cultural, también aumenta la predicción para el número de delitos. Además, también hay que destacar que el modelo presenta unos errores menores en la predicción cuánto menor sea el índice.



**Figura 22:** gráfico de la evolución de la predicción para el número de delitos en función del Índice de Simpson y el índice de renta familiar. Modelo C' final.

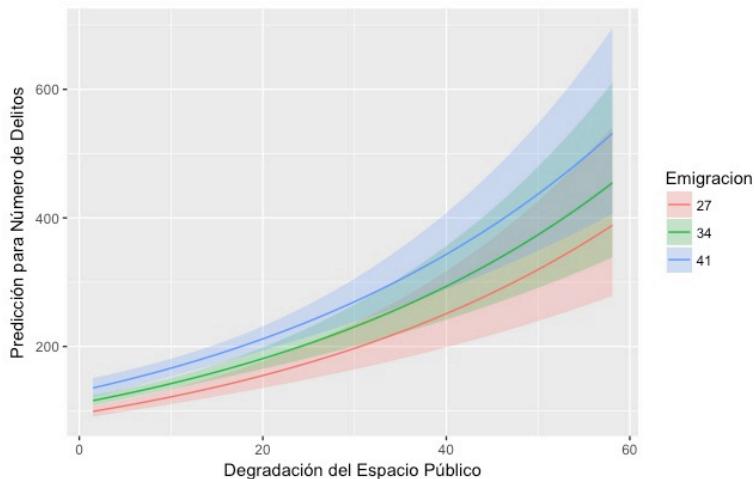
Si realizamos el mismo gráfico anterior pero añadiendo la variable de renta, vemos que además, la predicción para el número de delitos aumenta más en aquellas secciones censales donde la renta familiar es superior. Aunque la variable *Renta* es cuantitativa

continua, se ha discretizado a 3 valores: media-desviación, media, media + desviación, y se ha hecho una gráfica de la predicción para el número de delitos en función del índice de Simpson, para cada valor de la variable *Renta* discretizada (en diferentes colores en el gráfico).



**Figura 23:** gráfico de la evolución de la predicción para el número de delitos en función del número de incidentes de degradación del espacio público por cada 1000 habitantes. Modelo B'-1.

En este gráfico vemos que a mayor número de incidentes de degradación del espacio público, es decir, a mayor deterioro físico del lugar, mayor es la predicción para el número de delitos que nos da el modelo. Igual que en el caso del índice de Simpson, a mayor número de incidentes de degradación del espacio público, mayores errores en la predicción del modelo.



**Figura 24:** gráfico de la evolución de la predicción para el número de delitos en función del número de incidentes de degradación del espacio público por cada 1000 habitantes y la Tasa de Emigración. Modelo B'-2.

Si añadimos al modelo la variable Emigración, es decir, mayor movilidad poblacional, vemos que en aquellas secciones censales con una mayor tasa de emigración, también presentan una predicción más alta para el número de delitos.

### 5.2.5. Mapas de distribución espacial

Finalmente, vamos a observar la distribución espacial de la mejor variable del modelo: Índice de Simpson (mapa superior). La variable de número de incidentes de degradación del espacio público no tiene sentido representarla debido a que los datos se obtuvieron por distrito y no por sección censal. Ahora comparamos con el mapa de delitos (mapa inferior).

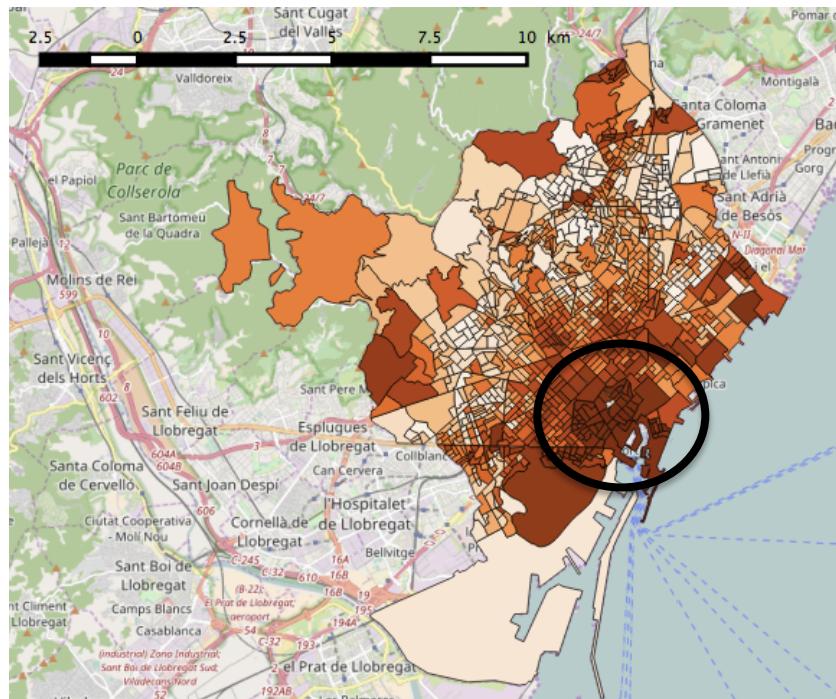
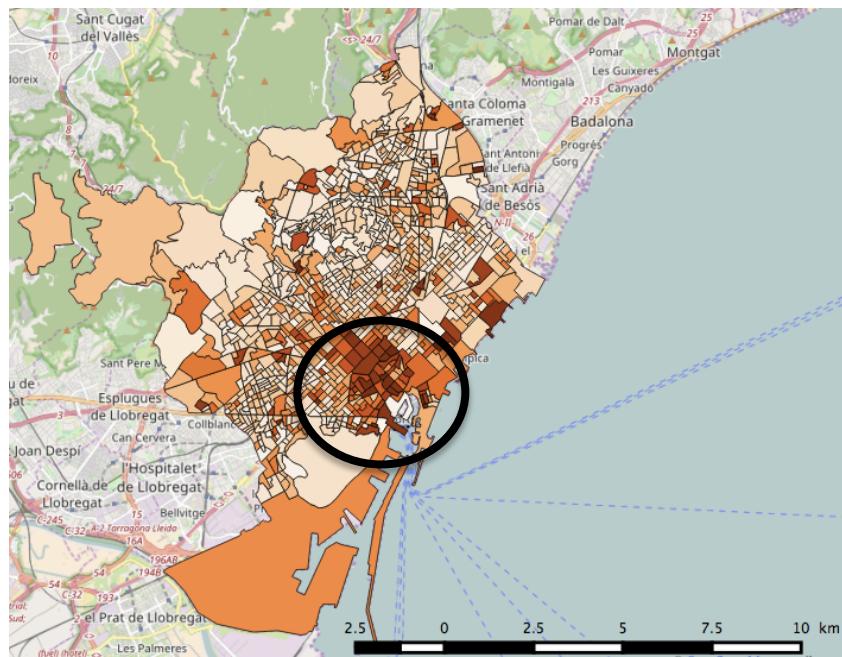


Figura 25: distribución del Índice de Simpson por sección censal.



**Figura 26:** distribución del número de delitos por sección censal.

Si comparamos los dos mapas, que representa el Índice de Simpson, vemos claramente que aquellas secciones censales con una mayor heterogeneidad cultural, también son aquéllas en las que se concentran una mayor cantidad de delitos.

## 5.3. Teoría de las Actividades Rutinarias

### 5.3.1. Regresión de Poisson

Consideraremos dos modelos finales para esta teoría, partiendo de las variables Superficie o Estudios.

1. MODELO A (Superficie + Densidad + Paro):

	Modelo base	Modelo 1	Modelo 2	Modelo 3
	<i>Intercept</i>	<i>Intercept</i> + Superficie	<i>Intercept</i> + Superficie+ Densidad	<i>Intercept</i> + Superficie + Densidad + Paro
Estimación <i>Intercept</i>	5,05129 ***	4,5360905 ***	4,676 ***	4,783 ***
Estimación 1 <sup>a</sup> variable		0,0617 ***	0,060450 ***	0,06056 ***
Estimación 2 <sup>a</sup> variable			-0,000318 ***	-0,00031 ***
Estimación 3 <sup>a</sup> variable				-0,01145 ***
<i>Residual Deviance</i>	302.582	268.192	267.470	267.331
AIC	309.140	274.751	274.031	273.894
Pseudo-R2		0,1136	0,1160	0,1165
Alpha	286,2653	253,9696	253,5261	253,6344

**Figura 27:** tabla-resumen de los resultados de la Regresión de Poisson para la Teoría de las Actividades Rutinarias. Modelo A.

Llevamos a cabo el test de sobre-dispersión y vemos que en cada caso existe dicha sobre-dispersión, ya que los p-valores son:

- Superficie: 0,0001942
- Superficie + Densidad: 0,0002775
- Superficie + Densidad + Paro: 0,0002964

## 2. MODELO B (Estudios + Población + Comisarías):

	<b>Modelo base</b>	<b>Modelo 1</b>	<b>Modelo 2</b>	<b>Modelo 3</b>
	<i>Intercept</i>	<i>Intercept</i> + Estudios	<i>Intercept</i> + Estudios + Población	<i>Intercept</i> + Estudios + Población + Comisarias
Estimación <i>Intercept</i>	5,05129 ***	5,434663 ***	4,586 ***	4,588 ***
Estimación 1 <sup>a</sup> variable		-0,058050 ***	-0,05694 ***	-0,05694 ***
Estimación 2 <sup>a</sup> variable			0,000544 ***	0,00054 ***
Estimación 3 <sup>a</sup> variable				-0,11410 ***
<i>Residual Deviance</i>	302.582	295.153	288.324	288.282
AIC	309.140	301.713	295.885	294.845
Pseudo-R2		0,02455	0,04712	0,047263
Alpha	286,2653	279,5012	273,2926	273,5119

**Figura 28:** tabla-resumen de los resultados de la Regresión de Poisson para la Teoría de las Actividades Rutinarias. Modelo B.

Los p-valores de los tests de sobredispersión son:

- Estudios: 0,0001233
- Estudios + Población: 0,0003941
- Estudios + Población + Comisarías: 0,0003907

### 5.3.2. Regresión de Binomial Negativa

1. MODELO A' (Superficie):

	<b>Modelo base</b>	<b>Modelo 1</b>
	<i>Intercept</i>	<i>Intercept</i> + Superficie
Estimación <i>Intercept</i>	5,05128	4,38883 ***
Estimación la variable		0,0796 ***
<i>Residual Deviance</i>	1240	1.219,6
AIC	12.796	12.613
Alpha	0,8523	0,8658

**Figura 29:** tabla-resumen de los resultados de la Regresión de la Binomial Negativa para la Teoría de las Actividades Rutinarias. Modelo A'.

Una vez más, podemos comprobar que tanto el **AIC** como la **Residual deviance** son menores que en el caso de usar un modelo de regresión de la Poisson, y el problema de la sobre-dispersión se ha solventado (**Alpha** pequeña).

Vemos que en el modelo de la Binomial Negativa no aparecen las variables Densidad ni Paro. Esto se debe a que la Regresión de Poisson infra-estima los errores y algunas variables aparecen como significativas cuando realmente no lo son, problema que queda corregido al usar el modelo de la Binomial Negativa.

De nuevo usamos la función *drop1* de R para ver si la adición de la variable Superficie al modelo sin ninguna variable (sólo *intercept*) nos da una mejora estadísticamente significativa, como en efecto sucede, ya que el p-valor del test es:

- Superficie: < 2,2e-16

En la siguiente tabla tenemos las estimaciones de los parámetros del modelo y los intervalos de confianza correspondientes (con un 95% de nivel de confianza):

	<b>Estimaciones de parámetros</b>	<b>2,5%</b>	<b>97,5%</b>
(Intercept)	4,38882796	4,27846455	4,49965459
Superficie	0,07960167	0,06691332	0,09279425

**Figura 30:** tabla-resumen de la estimación de los parámetros del modelo A' de intervalos de confianza (al 95%).

**MODELO PREDICTIVO PARA LA TEORIA ACTIVIDADES RUTINARIAS  
(MODELO DE REGRESIÓN DE LA BINOMIAL NEGATIVA)  
MODELO A'**  
 $\log(\lambda^*) = 4,38882796 + 0,07960167 \times \text{Superficie}$

Por ejemplo, si la superficie destinada a comercio, hostelería y turismo de una sección censal fuera del 15%, la predicción para el número de delitos se obtendría haciendo primero:

$$\text{Log}(\lambda^*) = 4,38882796 + 0,07960167 * 15 = 5,58285301, \text{ y luego}$$

**La predicción para el número de delitos que da el modelo es:**

$$= \lambda^* = \exp(5,58285301) = \text{entre } 265 \text{ y } 266 \text{ delitos.}$$

## 2. MODELO B' (Estudios + Población):

	<b>Modelo base</b>	<b>Modelo 1</b>	<b>Modelo 2</b>
	<i>Intercept</i>	<i>Intercept</i> + Estudios	<i>Intercept</i> + Estudios + Población
Estimación <i>Intercept</i>	5,05128	5,439523 ***	4,778 ***
Estimación la variable		-0,058796 ***	-0,05519 ***
Estimación 2 <sup>a</sup> variable			0,00041 ***
<i>Residual Deviance</i>	1240	1.234,9	1232,1
AIC	12.796	12.753	12.730
Alpha	0,8523	0,8551	0,8562

**Figura 31:** tabla-resumen de los resultados de la Regresión de la Binomial Negativa para la Teoría de las Actividades Rutinarias. Modelo B'.

De nuevo vemos que la variable comisarías se descarta en este modelo por lo mismo que en el caso anterior. También podemos ver que la variable Población mejora el modelo pero no en gran medida. De nuevo realizamos los test con la función *drop1* de R y vemos que los p-valores muy pequeños indican que tanto la variable Estudios añadida al modelo sin variables, como la variable Población añadida al modelo con la variable Estudios, mejoran significativamente el modelo y no deben ser eliminadas del modelo final. P-valores:

- Estudios: 1,222e-11
- Estudios + Población: 1,014e-10

Observamos las estimaciones de los parámetros y sus correspondientes intervalos de confianza:

	<b>Estimación de parámetros</b>	<b>2,5%</b>	<b>97,5%</b>
(Intercept)	4,7784890660	4,486801312	5,0678712018
Estudios	-0,0551920193	-0,071094065	-0,0389192698
Población	0,0004119375	0,000248489	0,0005805921

**Figura 32:** tabla-resumen de la estimación de los parámetros del modelo B' e intervalos de confianza (al 95%).

### MODELO PREDICTIVO PARA LA TEORIA ACTIVIDADES RUTINARIAS (MODELO DE REGRESIÓN DE LA BINOMIAL NEGATIVA)

#### MODELO B'

$$\log(\lambda^*) = 4,7784890660 - 0,0551920193 \times \text{Estudios} \\ + 0,0004119375 \times \text{Población}$$

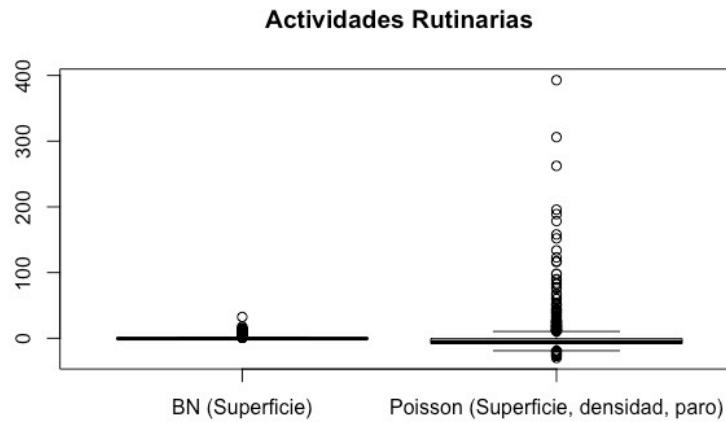
Por ejemplo, cuando la población sea de 2000 personas en una sección censal y el porcentaje de personas sin estudios obligatorios sea del 10%, en primer lugar, se calcula:

$$\begin{aligned} \text{Log}(\lambda^*) &= 4,7784890660 - 0,0551920193 * 10 \\ &+ 0,0004119375 * 2000 = 3,402693873, \end{aligned}$$

**Luego la predicción para el número de delitos =  $\exp(3,402693873)$ = aprox. 30 delitos.**

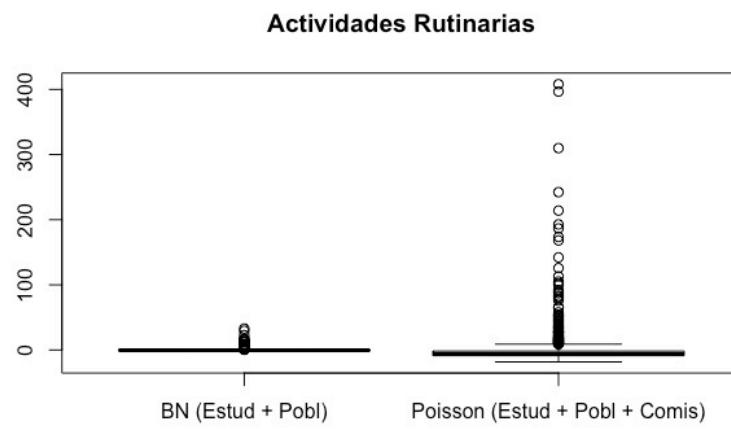
### 5.3.3. Comparativa de modelos

MODELOS A-A':



**Figura 33:** boxplot comparativo entre los residuos de los modelos A de Regresión de Poisson y A' de la Binomial Negativa.

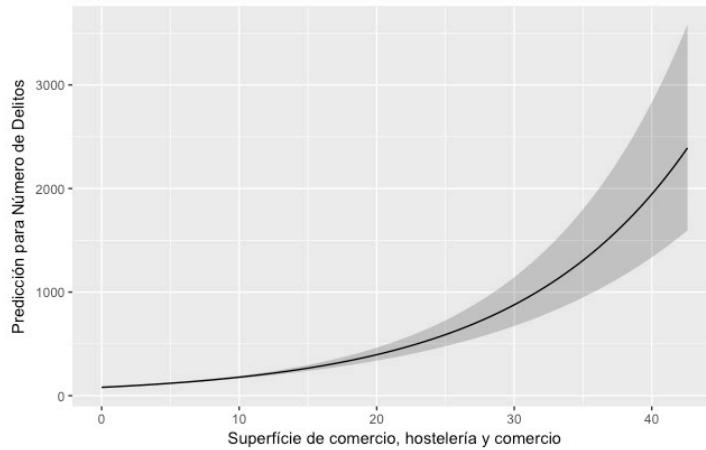
MODELOS B-B':



**Figura 34:** boxplot comparativo entre los residuos de los modelos B de Regresión de Poisson y B' de la Binomial Negativa.

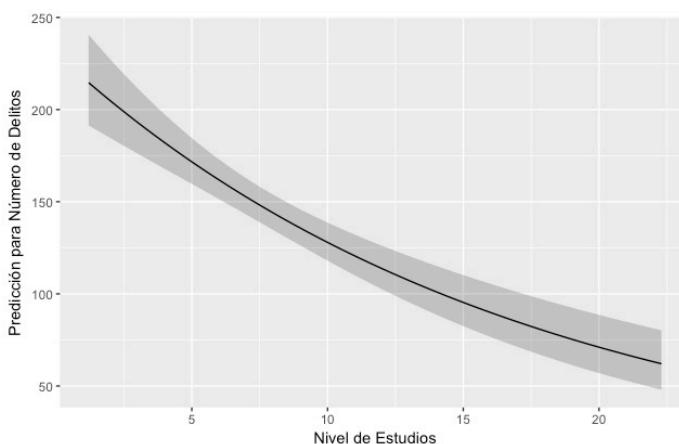
Vemos que ambos casos el modelo de la Regresión Binomial Negativa tiene menores residuos y por ello debemos considerarlo como una mejor alternativa al modelo de regresión de Poisson.

#### 5.3.4. Gráficos de las predicciones del modelo.



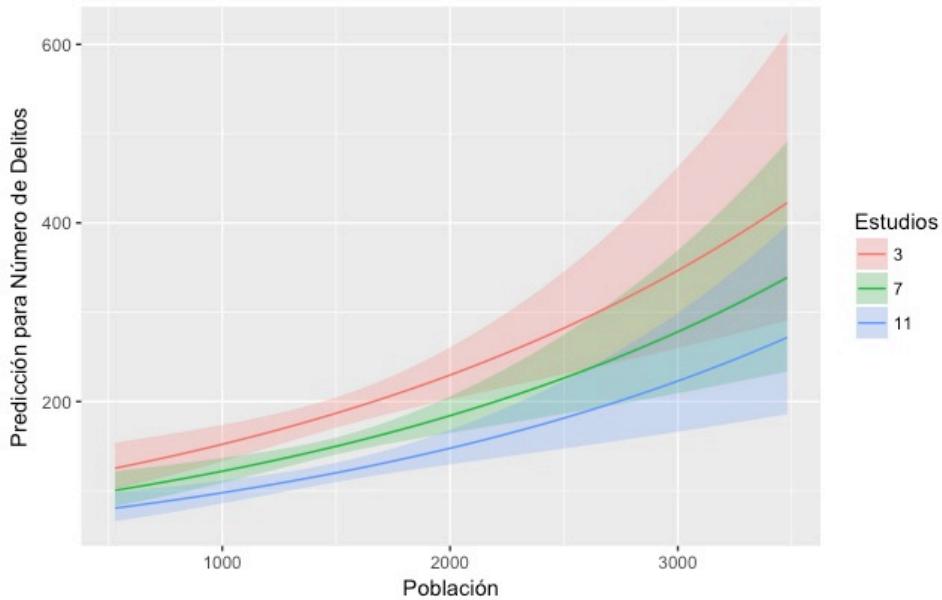
**Figura 35:** gráfico de la evolución de la predicción para el número de delitos en función del porcentaje de superficie destinada al uso de comercio, hostelería y turismo. Modelo A'.

En este gráfico vemos que a mayor porcentaje de superficie destinado a comercio, hostelería y turismo, es decir, a mayores cantidades de objetos deseados, mayor es la predicción que da el modelo para el número de delitos. Podemos observar también que a medida que aumenta el porcentaje de superficie, también el modelo aumenta en su error en la predicción.



**Figura 36:** gráfico de la evolución de la predicción para el número de delitos en relación al nivel de estudios. Modelo B'-1.

En este caso vemos que a mayor cantidad de personas sin estudios obligatorios, es decir, a mayor cantidad de infractores motivados, menor es la predicción para el número de delitos. Podemos observar también que a diferencia de otros casos anteriores, en éste el error se mantiene estable a lo largo de todo el gráfico con sólo alguna pequeña variación.

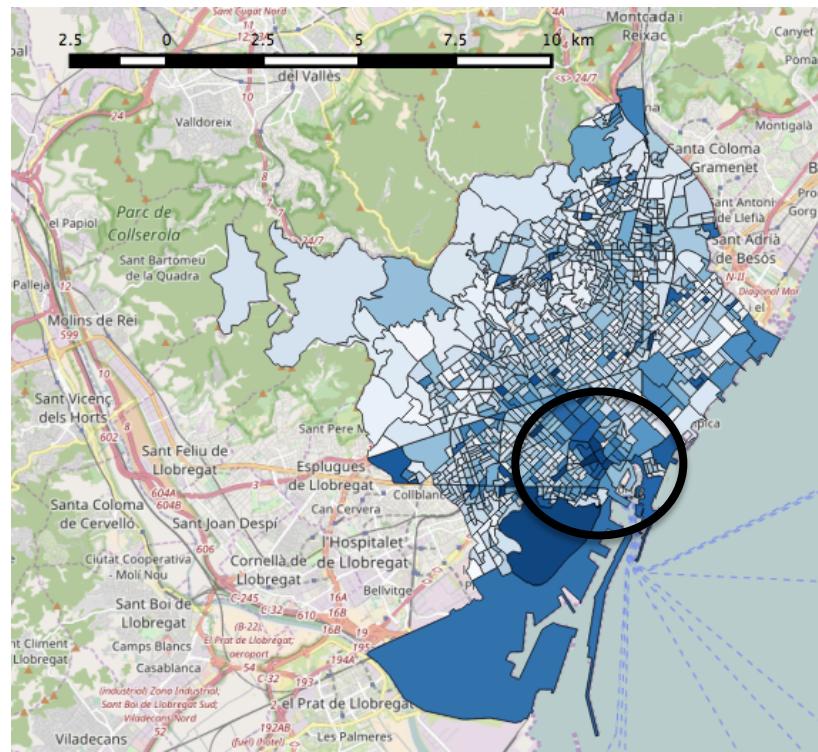


**Figura 37:** gráfico de la evolución de la predicción para el número de delitos en función del número de habitantes y el nivel de estudios. Modelo B' final.

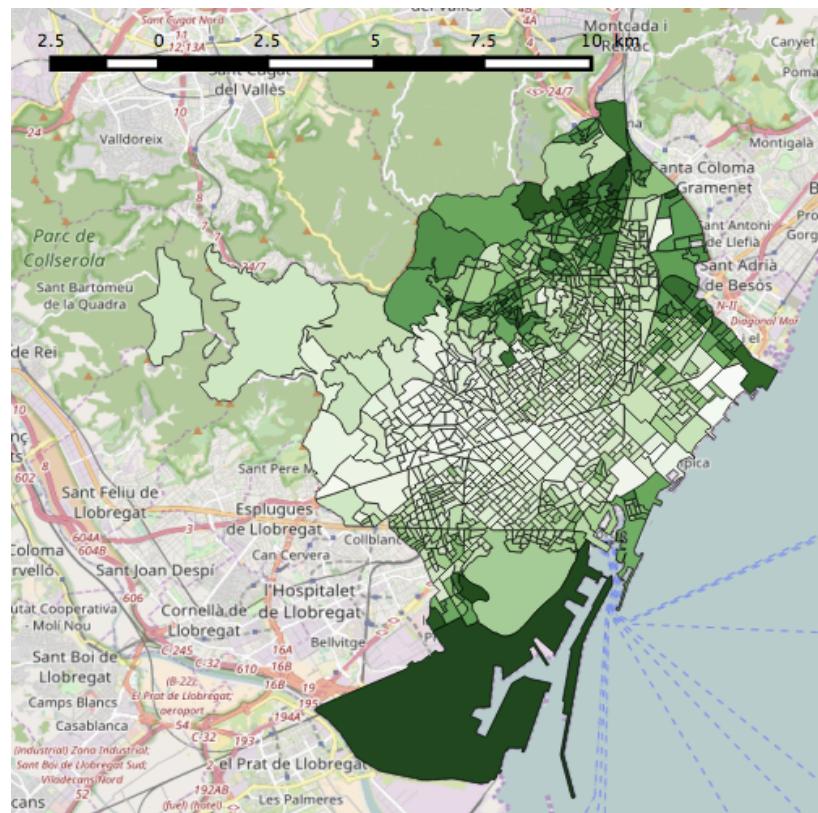
Vemos en este último gráfico que a mayor cantidad de número de habitantes, mayor es la predicción para el número de delitos. Además, cuando el porcentaje de personas sin estudios obligatorios es bajo, mayor es esa predicción. La variable *Estudios*, que es cuantitativa continua se ha discretizado para que tome 3 valores y poder hacer el gráfico de evolución de la predicción del número de delitos con el modelo en función de la *Población*, según los *Estudios*. Se han tomado 3 valores que son: media-desviación, media, y media+desviación. Las correspondientes gráficas aparecen en diferentes colores.

### 5.3.5. Mapas de distribución espacial

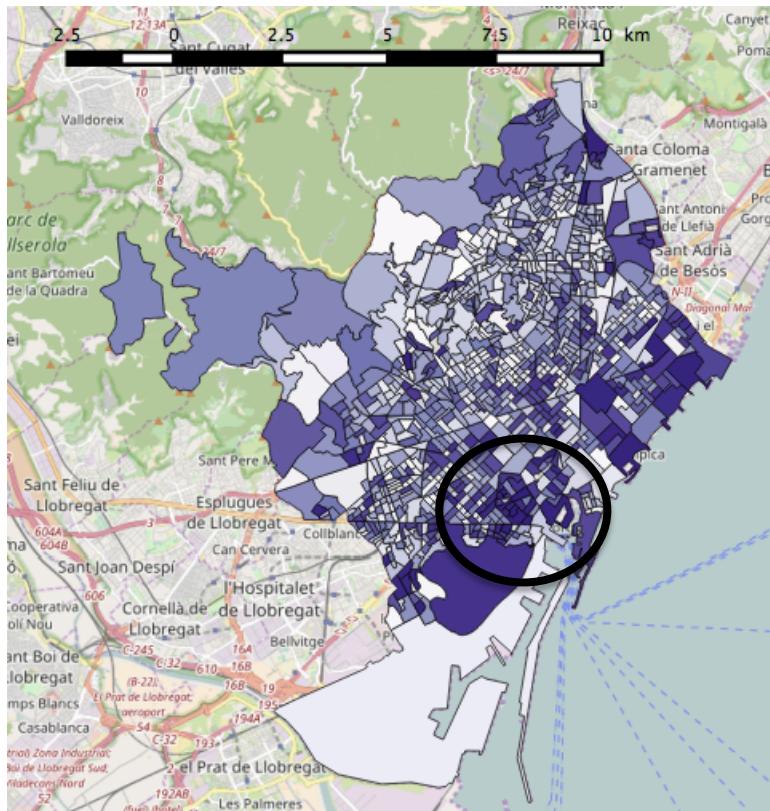
Finalmente, observaremos de forma visual la relación entre las variables de superficie destinada al comercio, hostelería y turismo (azul), el nivel de estudios (verde) y el número de habitantes (morado) con el número de delitos (último mapa, de color marrón):



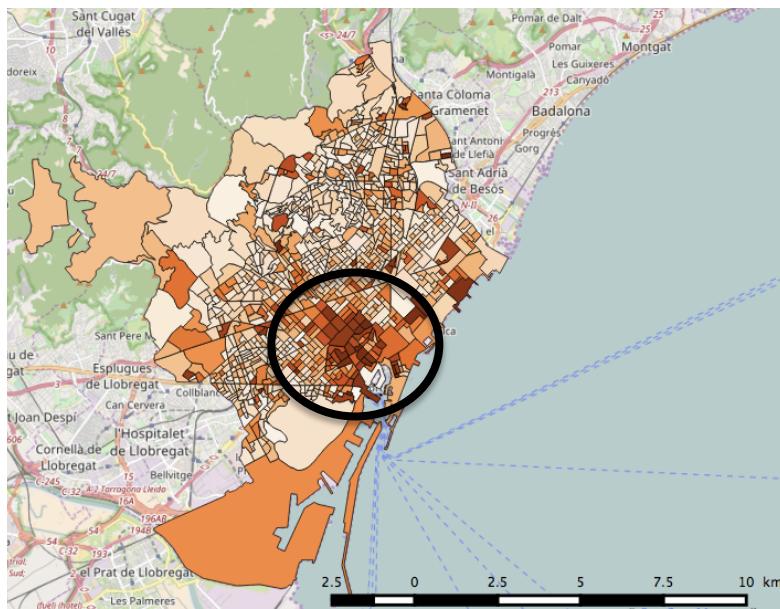
**Figura 38:** distribución del porcentaje de superficie destinada a comercio, hostelería y turismo.



**Figura 39:** distribución del nivel de estudios.



**Figura 40:** distribución del número de habitantes.



**Figura 41:** distribución del número de delitos.

Vemos que aquélla zona con una mayor tasa de superficie destinada a comercio, hostelería y turismo (azul más oscuro) coincide en gran medida con la concentración delictiva. No así en el caso porcentaje de personas sin estudios, donde la zona de concentración delictiva se vería en aquellas zonas con una tasa menor. Finalmente,

vemos que la zona de concentración delictiva también coincide con una de las zonas más pobladas (más oscuras), a pesar de que haya otros *hot spots* poblacionales.

## 6. Conclusiones y discusión

### 6.1. Discusión

Finalmente, después de todo el análisis llevado a cabo, se ha visto que el modelo de Regresión de la Binomial Negativa se ajusta mejor a la realidad que el de Poisson, que es el adecuado, en principio, para tratar con datos de tipo recuento, por lo que en casos de sobre-dispersión de los datos es una buena alternativa.

Además, después de testar las cinco hipótesis que se habían planteado se puede estar razonablemente satisfecho.

H1) Las variables que han demostrado que funcionan en el modelo de la Teoría de Desorganización social son la tasa de emigración (movilidad poblacional), número de incidentes de degradación del espacio público (deterioro físico), Índice de Simpson (heterogeneidad cultural) y índice de renta familiar (pobreza).

Se ha comprobado que a mayor movilidad poblacional o mayor deterioro físico o mayor heterogeneidad cultural o menor la pobreza, mayor es la predicción para el número de delitos. A diferencia de lo que se presuponía en las teorías, parece ser que los delitos se concentran en zonas con rentas más elevadas, hecho que tiene sentido cuando nos fijamos en que se cometan en una zona de mucho comercio y actividad económica, ya que la mayoría de ellos son delitos contra la propiedad (el 89,12%).

H2) Tal y como explica la Teoría de la Eficacia colectiva, la participación electoral está relacionada con la delincuencia y además en el sentido que la propia teoría comenta. A mayor participación electoral, menor número de delitos.

H3) En cuanto a la motivación para delinquir, se ha encontrado que el porcentaje de personas sin estudios obligatorios está relacionado con este hecho. Pero contrariamente a la hipótesis, vemos que a mayor porcentaje de personas en esta situación, menor es la

predicción para el número de delitos.

H4) En referencia a la presencia de objeto deseado, se ha encontrado que el porcentaje de superficie destinada al comercio, hostelería y turismo está directamente relacionado con una mayor predicción para el número de delitos.

H5) Esta última hipótesis no ha podido ser testada de forma satisfactoria debido a que se consideró el número de comisarías en Barcelona y hay un número insuficiente de datos como para conseguir una significación estadística aceptable.

## 6.2. Limitaciones

1. Los datos que se obtuvieron no siempre pudieron ser por sección censal, sino que algunos tuvieron que ser por unidades de análisis mayores.
2. En algunos de los datos no hubo coincidencia en diversas secciones censales, por lo que se tuvieron que eliminar, aunque fueron una minoría.
3. Además, no todos los datos son del mismo año de los datos de delitos. Algunos no se pudieron obtener del 2014, aunque sí de años próximos.
4. La variable de *Comisarías* no ha sido de gran utilidad debido a la pequeña cantidad de ellas. El número es tan reducido que no se puede comprobar su influencia.

## 6.3. Implicaciones

Hemos podido comprobar que la **participación electoral** es un buen predictor para el número de delitos. En el sentido de que a mayor participación electoral, menor es la predicción para el número de delitos. Por ello se debería promover la preocupación ciudadana por la comunidad. Por ejemplo, una forma es haciendo más palpable la atención al ciudadano y escuchando realmente sus sugerencias, articulando mecanismos para que éstos puedan dar su opinión y sea tomada en cuenta.

Además, a mayor **tasa de emigración** y **mayor número de incidentes de degradación del**

**espacio público**, mayor es la predicción para el número de delitos. Esto ocurre cuando la movilidad poblacional es alta y la degradación del lugar es evidente. De hecho, que haya mucha movilidad poblacional puede deberse a un deterioro físico de la sección censal. Por ello, deberían repararse aquellos daños producidos por los incivismos, para que no se produzca el efecto *Broken Windows*. También se podrían llevar a cabo campañas de concienciación para que se produzcan menos desperfectos y reducir el número de incidentes.

En aquellas secciones censales en las que el **Índice de Simpson** es elevado, también existe una predicción mayor para el número de delitos. Pero este índice es más alto, también encontramos que es en aquellas secciones con más **renta**, que es donde hay una mayor predicción para el número de delitos. Esto se puede deber a que hay una parte importante de la población en Barcelona que es extranjera y que son víctimas de delitos. Es decir, los delincuentes no pertenecen a las secciones censales donde cometen los delitos, sino que se desplazan, por lo que donde se cometen más delitos, también son aquéllos con mayor heterogeneidad cultural. Podemos inferir que los extranjeros sufren más la delincuencia en su conjunto. Además, en aquellos lugares donde hay una mayor heterogeneidad cultural, si la renta es más elevada, también hay más delitos. Se entiende desde la perspectiva de que la mayoría de delitos son contra la propiedad y se concentran en esas zonas por el mayor nivel económico de la sección censal donde actúan. En estos casos simplemente se debería mejorar la distribución de control policial y se deberían proteger esas zonas mediante otras medidas de seguridad tales como cámaras de video-vigilancia. Cuando predigamos una cantidad elevada de delitos debido a estos dos elementos, deberemos tener en cuenta estos aspectos además de otras políticas criminales.

Por otro lado, a mayor **superficie destinada a comercio, hostelería y turismo**, también la predicción es mayor para el número de delitos. En el mismo sentido que en el caso anterior, en estos lugares se concentra una mayor cantidad de bienes y de dinero, por lo que el objeto deseado es más frecuente y al ser la mayoría de los delitos contra la propiedad, se concentran en estas zonas. Para solventar este problema se debería distribuir el turismo y los comercios de forma más equitativa para evitar concentrarlos todos en unas zonas muy concretas. Para ello se puede potenciar la visita y el tránsito de monumentos, de parques,..

de otras secciones censales que también tienen su encanto pero a las que no se les da tanto reconocimiento.

Finalmente, vemos que a mayor cantidad de **población** la predicción para los delitos es mayor pero, además, en aquellas secciones censales en las que esta población es más elevada, cuando existía una tasa menor de **población sin estudios obligatorios**, la predicción para los delitos era más elevada. De nuevo, a una mayor concentración de población, mayor concentración de bienes. Además, en aquéllos lugares donde hay una mayor población y una menor proporción de personas sin estudios el delito es mayor. Esto se puede deber a que aquellas personas con un nivel de estudios superior, también son aquéllas con un nivel económico mejor. Por ello, en las secciones censales que presenten un mayor número de habitantes, se debería establecer una distribución diferente de las comisarías de policía, más allá de dos por distrito. Además, se deberían aumentar el sentimiento de comunidad y la participación grupal para aumentar el control social informal.

## 6.4. Futuras investigaciones

- 1) Hacer un estudio similar pero longitudinal, es decir, para una serie temporal de diversos años. De esta manera, se podrá estudiar la evolución temporal de la delincuencia en la ciudad y estudiar las secciones censales en cuanto a su relación con los "hot spots" y ver las que aumentan, disminuyen o se mantienen estables en el tiempo en cuanto al número de delitos.
- 2) Hacer un estudio a nivel más "micro" todavía (segmentos de calles) si se dispone de datos para ello.
- 3) Recopilar más variables que puedan ser predictoras del número de delitos e incorporarlas a los modelos considerados, siempre que no se introduzca colinealidad, para ver si éstos mejoran.

- 4) Se podría hacer un estudio específico para diferentes tipos de delito, que aquí se han tenido en cuenta conjuntamente, considerando el número total de delitos en cada sección censal.
- 5) Se podría considerar de manera aislada aquéllas secciones censales con mayor número de delitos ("hot-spots") y hacer un estudio más profundo de sus causas.

**Número total de palabras: 12.478.**

## Referencias

- Álvarez, F. (2015). Un test de la teoría de las actividades rutinarias. ¿guardianes capaces o eficacia colectiva?. *Revista de Derecho de la UNED*, 16, 65 - 80.
- Azpurúa, F. (2005). La escuela de Chicago: sus aportes para la investigación de las ciencias sociales. *Sapiens: revista universitaria de investigación*, 6(2), 25-36.
- Browning, C. (2002). The Span of Collective Efficacy: Extending Social Disorganization Theory to Partner Violence. *Journal of Marriage and Family*, 64, 833-850.
- Cámara, R., & del Diaz F. (2013). Muestreo en transecto de formaciones vegetales de fanerófitos y Caméfitos (I): Fundamentos metodológicos. *Estudios geográficos*, 74(274), 67-88.
- Cid, J., y Larrauri, E. (2001). *Teorías criminológicas*. Barcelona: Editorial Bosch.
- Cohen, L. E. y Felson, M. (1979). Social change and crime rate trends: A routine activity approach. *American sociological review*, 44 (4), 588-608.
- Donnangelo, J. (2012). Estructura comunitaria y delito: la heterogeneidad territorial del control social. *Revista del Departamento de ciencias sociales de la Universidad de la República*: volumen VII, pg. 311 – 320.
- Everitt, B. (1998). *The Cambridge Dictionary of Statistics*. Cambridge, UK New York: Cambridge University Press.
- Felson, M.; R. Clarke (1998), Opportunity makes the thief. Practical theory for crime prevention, Police Research Series, Paper 98, Home Office, Policing and Reducing Crime Unit, London.
- Fergusson, D. M., & Horwood, L. J. (2000). Alcohol abuse and crime: a fixed-effects regression analysis. *Addiction*, 95(10), 1525-1536.

Garrido, V., Stangeland, P., Redondo, S. (2006). *Principios de Criminología* (3<sup>a</sup> ed.). Valencia: Tirant Lo Blanch.

González, E. L. (1998). Tratamiento de la colinealidad en regresión múltiple. *Psicothema, 10*(2), 491-507.

Groff, E. R., Weisburd, D., & Yang, S. M. (2010). Is it important to examine crime trends at a local “micro” level?: a longitudinal analysis of street to street variability in crime trajectories. *Journal of Quantitative Criminology, 26*(1), 7-32.

He, F., & Hu, X. S. (2005). Hubbell's fundamental biodiversity parameter and the Simpson diversity index. *Ecology Letters, 8*(4), 386-390.

Juárez, H. Navarrete, J.L. (2007). *Delitos contra la propiedad: pobreza, inequidad y exclusión*. Bahía Blanca. Recuperado el 20 de Octubre de 2014, des de <http://www.aaep.org.ar/anales/works/works2007/juarez.pdf>

Machin, S., Marie, O., & Vujić, S. (2011). The crime reducing effect of education. *The Economic Journal, 121*(552), 463-484.

Newburn, T. (2013). *Criminology* (2<sup>a</sup> ed.). Oxon/New York: Routledge.

Osgood, D. W., Wilson, J. K., O'malley, P. M., Bachman, J. G., & Johnston, L. D. (1996). Routine activities and individual deviant behavior. *American Sociological Review, 63*5-655.

Pérez, F. (2012). Diferencias entre los usuarios de seisparques públicos en Barcelona según el nivel de seguridad percibida en el barrio. *Athenea digital, 12*(1), 55-66.

Salinas, O. A., Fuentes, C. M. (2016). El robo de vehículos y su relación espacial con el contexto sociodemográfico en tres delegaciones centrales de la Ciudad de México (2010). *Investigaciones geográficas, (89)*, 107-120.

Sampson, R. (2012). *Great American City: Chicago and the enduring neighborhood effect*. Chicago: The university of Chicago Press.

Sampson, R.J., Raudenbush, S.W., Earls, F. (1997). Neighbourhoods and Violent Crime: A multilevel Study of Collective Efficacy. *Revista Science*, volumen 277, pg. 918 – 924.

Sánchez. A., & Fuentes , C. M. (2016). El robo de vehículos y su relación espacial con el contexto sociodemográfico en tres delegaciones centrales de la Ciudad de México (2010). *Investigaciones geográficas*, (89), 107-120.

Shaw, C., y McKay, H. (1942). Juvenile delinquency and urban areas. *American sociological review*, 35 (2), 407- 408.

Simpson, E.H (1949). Measurement of diversity. *Nature*, 163 (4148), 668.

Valera, S., & Guàrdia, J. (2014). Perceived insecurity and fear of crime in a city with low-crime rates. *Journal of environmental psychology*, 38, 195-205.

Vázquez, C., Soto U, C. (2013). El análisis geográfico del delito y los mapas de la delincuencia. *Revista de Derecho Penal y Criminología*, (9), 419 – 488.

Wilson, W. J. (1987), *The Truly Disadvantaged: The Inner-City, the Underclass, and Public Policy*. Chicago, University of Chicago Press.

Weisburd, D; Groff, E; Yang, S. (2012). *The criminology of place: street segments and our understanding of the crime problem*. Oxford: Oxford University Press.

## APÉNDICE: los modelos de regresión de Poisson y de la Binomial Negativa.

Tanto el modelo de regresión de Poisson como el de la Binomial Negativa, pertenecen a la familia de modelos conocidos como **Modelos Lineales Generalizados (GLM)**, que generalizan la regresión OLS (Ordinary Least Squares) a la consideración de diferentes tipos de estructuras en los errores y en la variable dependiente.

Para la regresión OLS, se considera que la estructura de los **errores** (diferencias entre los valores observados de la variable dependiente y las correspondientes estimaciones dadas por el modelo) cumple:

1. normalidad condicional: para cada valor de las variables independientes, también llamadas **regresores** o **predictores**, los errores se distribuyen según una Normal,
2. homocedasticidad: varianza constante,
3. independencia.

Los datos de tipo recuento suelen violar las dos primeras condiciones: a) la distribución condicionada de los errores no se aproxima bien por una Normal, y b) la varianza no se mantiene constante sino que se incrementa con el valor de las variables predictoras.

Los modelos GLM presentan dos mejoras importantes frente a los modelos OLS:

- permiten usar transformaciones de la variable respuesta, lo que puede linearizar una potencial relación no lineal entre ella y los predictores (en el caso de la regresión de Poisson, la transformación que se usa (*link function*) es el logaritmo natural, **log**),
- son flexibles con respecto a la estructura asumida en los errores. En el caso de la regresión de Poisson, en vez de distribución Normal (caso OLS), se supone que los errores tienen una distribución condicional que es de **Poisson**. Tanto la media como la varianza de la Poisson coinciden con su parámetro  $\lambda$ , así que para especificar esta distribución sólo necesitamos un parámetro (en vez de los dos que utiliza la Normal). A menudo sucede que la suposición de que media=varianza en datos de recuento es

acertada, pues es habitual que la varianza se incremente con la media.

La regresión de Poisson es un GLM con distribución de los errores **Poisson** y link función = **log**. Además, en vez de estimar los parámetros mediante el método de OLS, se usa el método **MLE** (*maximum likelihood estimation*, estimación de la máxima verosimilitud). Las estimaciones de los parámetros obtenidas por el método MLE son las que con más verosimilitud (probabilidad) habrán producido los datos que realmente hemos observado. El modelo es:

$$\log(\lambda) = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_p X_p, \quad (1)$$

o bien

$$\lambda = \exp(b_0 + b_1 X_1 + b_2 X_2 + \dots + b_p X_p), \quad (2)$$

y si  $D=n^o$  de delitos en una sección censal, se asume que

$$P(D=d) = e^{-\lambda} \lambda^d / d! \quad (3)$$

donde  $\lambda$  se obtiene de (2) dando los valores específicos de una sección censal a los p regresores  $X_1, X_2, \dots, X_p$ . Es decir,  $D$  tiene distribución de Poisson de parámetro  $\lambda$ .

$b_0$  es el "intercept" u ordenada en el origen,  $b_1$  es el coeficiente de regresión de  $X_1, \dots$

A diferencia de lo que sucede con la regresión OLS, la predicción que se obtiene directamente del modelo NO es de la variable dependiente sino de su **logaritmo natural**. Para obtener las predicciones para la variable respuesta hemos de hacer la transformada inversa, es decir, la **exponencial**. De esta manera, si la variable predictora  $X_1$  se incrementa en una unidad mientras que las otras permanecen igual, entonces  $\log(\lambda)$  se incrementará en  $b_1$  unidades, lo que implica que la predicción para la variable respuesta se **multiplica por  $e^{b_1}$** .

El modelo de Poisson no considera que haya heterogeneidad entre los individuos (casos): supone que todos los individuos con los mismos valores de las variables regresores  $X_1, \dots, X_p$ , digamos  $x_1^i, x_2^i, \dots, x_p^i$ , tendrán un valor de la variable explicada ( $N^o$  de Delitos)

modelado por una distribución de Poisson con **el mismo parámetro** (media):

$$\lambda_i = \exp(b_0 + b_1 x_1^i + b_2 x_2^i + \dots + b_p x_p^i)$$

es decir, se asume que éste es el parámetro de la distribución de Poisson que modela el nº de delitos para una sección censal en la que los predictores toman los valores del caso i,  $X_1=x_1^i, \dots, X_p=x_p^i$ . Como predicción para esta sección censal se da la media de la Poisson, que es el valor  $\lambda_i$ , así que todas las secciones censales con los mismos valores de los regresores tendrían la misma predicción con este modelo. Aunque esa es la predicción, los valores observados para las diferentes secciones censales con los mismos valores de las variables regresores NO son todos iguales. Las diferencias entre los valores observados y la predicción  $\lambda_i$  deberían quedar explicadas por el modelo, es decir, porque los valores observados deberían seguir una distribución de Poisson de parámetro  $\lambda_i$ .

El modelo de la Binomial Negativa aborda el problema de la sobre-dispersión asumiendo que hay una cierta variabilidad no explicada entre las unidades que tienen la misma predicción, lo que lleva a una mayor varianza que la esperada por la distribución de Poisson, en la distribución de las observaciones, pero que no tiene efecto en su media. Es decir, los valores observados presentan más variabilidad que si realmente siguiesen la distribución Poisson de parámetro  $\lambda_i$ .

El modelo de regresión de la Binomial Negativa permite que las observaciones de las secciones censales con los mismos valores de los regresores sean modeladas por distribuciones de Poisson CON DIFERENTES PARÁMETROS (medias)!. Se sigue utilizando la distribución de Poisson pero cada sección censal puede representarse por una distribución de Poisson con un parámetro diferente. Las variaciones entre los parámetros para las distribuciones de Poisson de las secciones censales con los mismos valores de los regresores se suponen modeladas por una distribución de probabilidad: la distribución Gamma. Es decir, se supone que la esperanza del número de delitos cuando los regresores toman los valores del caso i es, a su vez, una variable aleatoria que se distribuye según una Gamma de media  $\lambda_i$  y parámetro de escala constante =  $\theta$ . Por tanto, la función de error es

una mixtura de dos distribuciones de probabilidad diferentes: la Poisson y la Gamma.

Entonces, el modelo de regresión de la Binomial Negativa se representa por las ecuaciones (1), (2) y (3)':

$$P(D=d) = \left( \Gamma(d+\theta) \theta^d \lambda^d \right) / (d! \Gamma(\theta) (\theta+\lambda)^{\theta+d}) \quad (3)'$$

donde  $\Gamma$  es la función Gamma de Euler (una versión continua del factorial):

$$\Gamma(x) = \int_0^\infty e^{-z} z^{x-1} dz \text{ (si } x \text{ es un natural, } \Gamma(x)=(x-1)!\text{)},$$

y  $\theta > 0$  es el parámetro de escala<sup>4</sup>. Resulta que según este modelo,

$$\text{la esperanza es } E(D) = \lambda \text{ y la varianza es } V(D) = \lambda + \alpha \lambda^2,$$

siendo  $\alpha = 1/\theta$  el parámetro de forma de la distribución Gamma. Vemos que la varianza de D en este modelo crece mucho más rápidamente con la media  $\lambda$  que en el modelo de Poisson (en el que la varianza = la media =  $\lambda$ ).

$\alpha$  representa la sobre-dispersión en el modelo BN. En el caso límite  $\alpha \rightarrow 0$  ( $\theta \rightarrow \infty$ ), no hay sobre-dispersión y el modelo de regresión BN se reduce al de Poisson estándar. Siempre  $\alpha > 0$ , así que este modelo se aplica cuando hay sobre-dispersión, y cuanto mayor sea  $\alpha$  (menor sea  $\theta$ ), mayor será la sobre-dispersión.

La interpretación de los coeficientes de regresión en la BN es igual que en el modelo de Poisson.

<sup>4</sup> Si X es una variable Binomial Negativa de parámetros p y r, que corresponde a contar el número de fracasos para conseguir r éxitos, si la probabilidad de éxito en cada intento es p, entonces,

$$P(X=k) = \Gamma(r+k) p^r (1-p)^k / (k! \Gamma(r)).$$

Por (3)' vemos que D es una Binomial Negativa de parámetros  $p=\theta/(\theta+\lambda)$  y  $r=\theta$ , siendo  $\theta$  el parámetro de escala que se estima a partir de los datos, y  $\lambda$  el valor obtenida por (2) a partir de los valores concretos de las variables regresoras (formalmente, porque  $\theta$  puede no ser un natural, mientras que r tiene que serlo).