

UNIVERSIDAD DE EL SALVADOR
FACULTAD DE CIENCIAS NATURALES Y MATEMÁTICA
ESCUELA DE MATEMÁTICA



Universidad de El Salvador
Hacia la libertad por la cultura

**“DISTRIBUCIÓN REGIONAL DE LA VIOLENCIA EN EL SALVADOR Y
SUS DETERMINANTES”**

PRESENTADO POR:

NADIA JAHAYRA CARRANZA

PARA OPTAR AL GRADO DE:

LICENCIADA EN ESTADÍSTICA

ASESORES:

DR. CARLOS ALBERTO CARCACH

M.Sc. ROLANDO LEMUS

CIUDAD UNIVERSITARIA, SAN SALVADOR, 13 DE JUNIO DE 2006.

UNIVERSIDAD DE EL SALVADOR

Dra. María Isabel Rodríguez
RECTORA

Ing. Joaquín Orlando Machuca
VICERRECTOR ACADEMICO

Dra. Carmen Rodríguez de Rivas
VICERRECTORA ADMINISTRATIVA

Lcda. Alicia Margarita Rivas de Recinos
SECRETARIA GENERAL

FACULTAD DE CIENCIAS NATURALES Y MATEMÁTICA

M.Sc. José Héctor Elías Rivas
DECANO

M.Sc. Francisco Antonio Chicas.
VICEDECANO

Lic. Victor Manuel Duran Belloso
SECRETARIO

ESCUELA DE MATEMATICA

Lic. Mauricio Hernán Lovo Córdova
DIRECTOR

Lic. Héctor Douglas Molina
SECRETARIO

UNIVERSIDAD DE EL SALVADOR
FACULTAD DE CIENCIAS NATURALES Y MATEMÁTICA
ESCUELA DE MATEMÁTICA

TRABAJO DE GRADUACIÓN

**“DISTRIBUCIÓN REGIONAL DE LA VIOLENCIA EN EL SALVADOR Y SUS
DETERMINANTES”**

PRESENTADO POR:

NADIA JAHAYRA CARRANZA

APROBADO POR:

LIC. MAURICIO HERNÁN LOVO CÓRDOVA
COORDINADOR

DR. CARLOS ALBERTO CARCACH
ASESOR

M.Sc. ROLANDO LEMUS
ASESOR ADJUNTO

AGRADECIMIENTOS

Los ideales son como las estrellas: no alcanzarás a tocarlas, pero puedes escogerlas como tus guías y seguirías para alcanzar tu destino. Schurz

Agradezco a Dios y a la Santísima Virgen María por guiarme hasta la culminación de esta meta. Gracias a mis abuelos paternos, Ramón y Elba, a mi tía Isabel y a mi prima Marlene por su apoyo durante toda mi carrera. Gracias, Dr. Carlos Carcach por dedicarme su tiempo y transmitirme su conocimiento. Gracias al M.Sc. Rolando Lemus y demás profesores del departamento de estadística por la formación académica que me dieron.

Gracias a todos aquellos que directa o indirectamente colaboraron en esta investigación. Muchas gracias, amigos y amigas que me acompañaron y animaron en todo este proceso.

Sinceramente,

Nadia Jahayra.

Índice de Contenido

1. Resumen	1
2. Introducción	2
3. Fundamento Teórico	
3.1. Diferencias Regionales en Tasas de Criminalidad	4
3.2. Teoría General del Estrés	6
3.3. Transformación Económica	9
3.4. El Modelado Estadístico de Tasas de Criminalidad	12
3.4.1. Modelos Lineales Generalizados	14
3.4.2. Distribución Binomial Negativa	16
3.5. Pruebas de Exceso de Dispersión	19
3.6. Diagnóstico del Modelo	20
3.6.1. Fuentes de Mala Especificación	23
3.6.2. Pruebas de Mala Especificación	24
3.6.3. Pruebas Clásicas de Mala Especificación	25
4. Objetivos	33
5. Hipótesis	34
6. Metodología	36
7. Discusión y Análisis de Resultados	54

8. Conclusiones y Recomendaciones	58
9. Bibliografía	60
<i>Índice de Tablas</i>	<i>vi</i>
<i>Índice de figuras</i>	<i>vii</i>

Índice de Tablas

Tabla 5.1	Operacionalización de hipótesis	34
Tabla 6.1	Definición de variables y estadísticos de resumen.	37
Tabla 6.2	Coefficientes de Regresión de Poisson	39
Tabla 6.3	Coefficientes de Regresión binomial negativa	45
Tabla 6.4	Resultados de la prueba Breusch-Pagan-Godfrey	46
Tabla 6.5	Teoría General del Estrés. Coeficientes de Regresión de Poisson con factor de corrección.	48

Índice de Figuras

Figura 3.1	Teoría General del Estrés sobre Diferencias en las Comunidades en Tasas de Criminalidad	8
Figura 3.2	Patrones en las gráficas de residuales.	22
Figura 6.1	Gráfico de Residuales y valores predichos. Regresión de Poisson.	42
Figura 6.2	Gráfico de residuales contra variables regresoras. Regresión de Poisson	43
Figura 6.3	Gráfico de Residuales y valores predichos. Regresión de Poisson con factor de corrección.	49
Figura 6.3	Gráfico de Residuales y valores predichos sin valores extremos. Regresión de Poisson con factor de corrección.	49
Figura 6.2	Gráfico de residuales contra variables regresoras. Regresión de Poisson con factor de corrección	50

1. Resumen

El objetivo de este trabajo consiste en identificar los factores económicos y sociales que inciden en la variación del número de homicidios entre los municipios de El Salvador, y cuantificar su impacto, usando un Modelo Lineal Generalizado basado en la distribución de Poisson. El estudio utiliza datos a nivel municipal sobre el número de homicidios registrados por la Policía Nacional Civil durante el año 2002, datos de la Encuesta de Hogares y Propósitos Múltiples del período 2001-2004, y del Censo de Población y Vivienda de 1992.

Estos datos son usados para investigar una serie de hipótesis relacionadas con una teoría de la distribución geográfica de violencia conocida como Teoría General del Estrés la cual fue propuesta por Agnew (1999), y un enfoque basado en el rol que cambios económicos y sociales derivados de la urbanización juegan en la configuración espacial de la violencia (Carcach, 2001).

Los resultados obtenidos dan soporte a una explicación de diferencias en los niveles de homicidios entre municipios a partir de las consecuencias sociales y económicas de procesos acelerados de urbanización los cuales provocan ambientes dentro de los que los residentes en situación de desventaja relativa con respecto a sus congéneres tienden sentir malestar por su propia realidad, llevándolos a experimentar frustración, lo que a su vez conduce al desarrollo de respuestas violentas.

2. Introducción

La distribución geográfica de la violencia se ha convertido en una de las áreas de mayor atención en la literatura especializada. La literatura indica que la incidencia de actos violentos y los factores asociados a los mismos tienden a mostrar patrones de concentración geográfica bien definidos. (Carcach, 2000a).

Este Trabajo de Graduación contiene los resultados de un estudio estadístico de la violencia en El Salvador, mediante el análisis de su forma más grave, el homicidio, dentro del marco de la teoría del “estrés” social, complementado con un enfoque basado en el rol que cambios económicos y sociales derivados de la urbanización juegan en la configuración espacial de la violencia (Carcach, 2001).

El estrés definido como una tensión provocada por situaciones agobiantes que originan reacciones psicósomáticas o trastornos psicológicos a veces graves¹ es visto en este estudio como una fuente de criminalidad basada en la Teoría General del Estrés.

De acuerdo con la Teoría General del Estrés (*General Strain Theory GST, Agnew1999*), diferencias entre comunidades en niveles de criminalidad son el resultado de diferencias en niveles de estrés social y económico, y en factores tales como pobreza, urbanización, densidad y familias desintegradas; los cuales median la relación entre estrés y niveles de criminalidad. En particular, comunidades con niveles altos de criminalidad tienden a seleccionar y a retener individuos estresados, lo que a su vez produce más estrés y fomenta respuestas criminales ante el mismo.

Comunidades con criminalidad elevada tienden a presentar indicadores débiles en términos de factores tales como; ingreso, pobreza, desempleo, bienestar social, ocupación, desigualdad, propiedad y calidad de la vivienda. Privación económica, en realidad, es quizás la característica más distintiva del alto crimen en las comunidades. (Land, McCall y Cohen 1990; Sampson, Raudenbush y Earls 1997).

¹ Real Academia Española, 2006.

Criminólogos han ofrecido varias explicaciones para el hecho que el alto crimen en las comunidades se debe a la pobreza, densidad y alto grado de hacinamiento urbano, así como a problemas familiares. La explicación dominante se deriva de Shaw y Mckay (1942) en su "Teoría de Desorganización Social", y particularmente de las reinterpretaciones y extensiones a la misma en años recientes. (Bursik 1988; Bursik and Grasmik 1993, 1995; Elliott et al. 1996; Kornhauser 1978; Sampson 1995; Sampson y Groves 1989; Sampson and Wilson 1995).

Los datos usados en este estudio provienen del registro de homicidios de la Policía Nacional Civil (PNC), para cada uno de los 262 municipios del país, durante el año 2002. Las tasas de homicidios se calcularon en base a datos sobre población por municipio, según el Censo de Población y Vivienda conducido por la Dirección General de Estadística y Censos (DIGESTYC) en 1992. Datos sobre indicadores de los distintos factores asociados con la violencia a nivel municipal provienen de las siguientes fuentes: Fondo de Inversión Social para el Desarrollo Local (FISDL), Censo de Población y Vivienda de El Salvador 1992 (DIGESTYC) y de la Encuesta de Hogares de Propósitos Múltiples (EHPM) (DIGESTYC, 2001 a 2004).

Los resultados indican que de acuerdo a la Teoría General del Estrés y al enfoque complementario adaptado de Carcach (2001), en los municipios de El Salvador, el número de homicidios está relacionado con cambios en la estructura económica a raíz de los procesos de urbanización acelerada que han tenido lugar en años recientes, diferencias de ingresos, pobreza, y principalmente a la estructura demográfica, es decir, a la composición de la población por edades, principalmente en aquellas regiones donde la población joven es mayor que la población adulta.

Los indicadores más influyentes en el número de homicidios son: la proporción de jóvenes respecto a adultos mayores dentro de un municipio y el nivel de pobreza. Se aprecia un aumento del diez por ciento en la incidencia de homicidios ante un aumento del 167% en la razón de jóvenes a adultos mayores dentro de un municipio; por otro lado, el número de homicidios tiende a disminuir en un 290 por ciento en aquellos municipios clasificados con pobreza extrema severa en relación a los que están clasificados con pobreza extrema baja por cada aumento unitario porcentual del nivel de pobreza, expresando así, que a medida un

municipio es más pobre, menos homicidios suceden; lo cual se opone a la hipótesis de que la pobreza es un indicador de tasas altas de homicidios.

El documento contiene 9 secciones, incluyendo el resumen y esta introducción. La tercera sección revisa la literatura sobre diferencias regionales en tasas de criminalidad y el modelado estadístico de las mismas. La cuarta sección detalla los objetivos de la investigación propuesta. La quinta sección presenta las hipótesis de la investigación. La sección seis describe la metodología realizada en la investigación. La séptima sección presenta la discusión y análisis de resultados de la investigación. La sección ocho nos plantea las conclusiones y recomendaciones y la novena sección presenta la bibliografía consultada.

3. Fundamento Teórico

3.1. *Diferencias Regionales en Tasas de Criminalidad*

Ha habido mucha investigación reciente sobre los determinantes de las diferencias en tasas de crimen en regiones o lugares geográficos. En adelante, nos referiremos a estas regiones como comunidades, es decir entidades geográficas delimitadas; en nuestro caso una comunidad será un municipio.

Ya sea medido por su incidencia o por su prevalencia², hay lugares más propensos a una criminalidad alta y a presentar indicadores económicos débiles en términos de ingreso, pobreza, desempleo, bienestar social, ocupación, desigualdad y calidad de vivienda. Privación económica, en realidad, es quizás la característica más distintiva de las comunidades con alta criminalidad. Mucha de la investigación coincide en que altos niveles de criminalidad tienen lugar en áreas con alta densidad poblacional, altas tasas de hacinamiento y movimientos poblacionales intensos.

Criminólogos han ofrecido varias explicaciones para el hecho que la alta criminalidad en las comunidades se debe a la pobreza, densidad y alto grado de hacinamiento urbano e incidencia de problemas familiares. La explicación dominante se deriva de Shaw y Mckay (1942) en su "Teoría de Desorganización Social", y particularmente de las reinterpretaciones y extensiones a la misma en años recientes. (Bursik 1988; Bursik and Grasmik 1993, 1995; Elliott et al. 1996; Kornhauser 1978; Sampson 1995; Sampson y Groves 1989; Sampson and Wilson 1995).

Varios estudios sugieren que los factores mencionados anteriormente contribuyen a debilitar la capacidad de las comunidades para proveerse de los mecanismos que les permitan controlar los niveles locales de criminalidad. Los efectos de estos factores sobre las tasas de

² Incidencia: Número de casos ocurridos.

Prevalencia: Proporción de personas que son víctimas de violencia con respecto al total de la población en estudio. (Adaptación del Diccionario de la Lengua Española, 2006)

criminalidad son mediados por características propias de los individuos y de su medio ambiente social (por ejemplo familia, escuela, trabajo).

El estatus económico de los residentes es el factor que más contribuye a discriminar entre comunidades con niveles altos y niveles bajos de criminalidad. La Teoría General del "Estrés" (Agnew, 1999) argumenta que en comunidades desaventajadas existen altos niveles de criminalidad porque los residentes experimentan dificultades grandes para alcanzar sus metas económicas. Esta obstrucción de metas les crea frustración con la situación económica propia y les conduce a desarrollar actividades ilegales para generar ingresos, a la agresión, y al uso de drogas. Residir en una comunidad *en desventaja* incrementa la probabilidad de tensión económica, especialmente entre residentes de comunidades con altas disparidades en ingresos.

Cuando la desigualdad económica es alta, la gente se compara a sí misma con otros a quienes perciben como más aventajados, deciden que ellos quieren y merecen lo que otros tienen, y se dan cuenta que no pueden alcanzarlo a través de medios legítimos, lo que resulta en tasas altas de criminalidad.

Individuos en comunidades desaventajadas pasan por innumerables problemas, incluyendo falta de recursos financieros, desempleo, o empleo en condiciones adversas (salarios bajos, trabajos esporádicos, bajos niveles de seguridad e higiene laboral y prestaciones laborales inadecuadas o inexistentes). Estas comunidades tienen bajos niveles de apoyo social entre sus miembros (Agnew, 1999) y tal falta de apoyo social es magnificado por niveles incrementados de problemas familiares (Thoits, 1982). Datos reportados en Hagan y McCarthy (1997) sugieren que las diferencias en los niveles de apoyo social entre comunidades tienen un efecto importante sobre la habilidad de los residentes para manejar el estrés, y que tales diferencias están vinculadas a diferencias en las tasas de criminalidad.

3.2. *Teoría General del Estrés*

Según Agnew (1999) el estrés es una fuente principal de motivación criminal. Su teoría explica diferencias en criminalidad entre comunidades por las diferencias en niveles de estrés y en los factores que condicionan el efecto que éstos tienen sobre el crimen. En particular, comunidades con alta criminalidad tienden a seleccionar y a retener individuos estresados, lo que produce estrés y fomenta respuestas criminales ante el mismo.

El *estatus* económico es el factor que más diferencia a comunidades con alta criminalidad de aquellas con baja criminalidad. La Teoría General del Estrés (*GST, General Strain Theory*) establece que es lógico que comunidades económicamente necesitadas estén más expuestas a grados altos de criminalidad porque sus residentes tienen más dificultad en alcanzar sus metas económicas que aquellos que residen en áreas con mejor situación económica. (Agnew 1992, Agnew et. al 1996, Wilson 1996).

GST muestra que existen características de las comunidades que están asociadas con tasas más altas de criminalidad, las cuales tienen que ver con la tensión entre sus residentes y las reacciones de ellos ante dichas tensiones en varias formas:

1. Individuos estresados, especialmente aquellos experimentando tensión económica tienden a moverse dentro de comunidades necesitadas porque no tienen los recursos para vivir en otros lugares y porque los residentes de las comunidades son menos capaces para resistir su migración. (Reiss 1993).
2. Comunidades con baja motivación entre sus residentes son más probables a causar bloqueo de metas – el primer tipo de estrés en *GST*. En particular, tales comunidades llevan a los individuos a colocar un fuerte énfasis sobre ciertas metas y hace más difícil para los individuos alcanzar estas metas a través de medios legítimos. Tres metas son enfatizadas: dinero, estatus/respeto, el deseo de ser tratado en una manera justa o no discriminatoria.
3. Privación relativa. En particular, estas y otras ciertas características de las comunidades influyen si los individuos se comparan a sí mismos con las ventajas

de otros, deciden que quieren y desean lo que otros tienen, y reconocen que no pueden tener lo que estos otros tienen a través de medios legítimos.

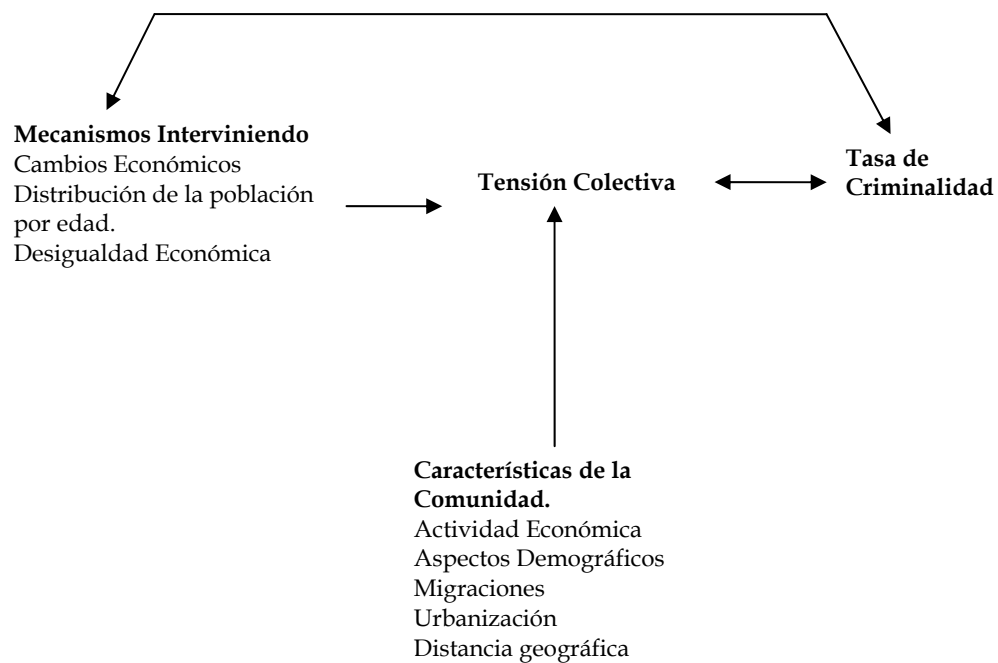
4. Comunidades con altos niveles de tensión social y económica debido a pobreza y a problemas familiares contribuyen a crear ambientes que conducen a que sus residentes valoren medios negativos para alcanzar sus metas.
5. Obstrucción de metas, privación relativa y exposición a estímulos adversos incrementan la probabilidad que los residentes de las comunidades experimenten emociones negativas tales como cólera y frustración. Niveles agregados de cólera/frustración deberían tener un efecto directo sobre tasas de criminalidad y *en parte* deberían mediar el efecto de las características de la comunidad sobre tasas de criminalidad.
6. Estas comunidades no solamente producen individuos enojados/frustrados sino que crean ambientes en los que tales individuos interactúan con otros. Esto a su vez incrementa el nivel colectivo de tensión/cólera que lleva a respuestas criminales ante tales tensiones.
7. Finalmente, tasas de criminalidad en las comunidades tiene un efecto directo e indirecto sobre el estrés. Victimización criminal, de hecho, es uno de los tipos más serios de estrés al cual los individuos están sujetos, y los datos sugieren que es una fuente principal de crimen subsiguiente (Dawkins 1997). Comunidades necesitadas generan estrés y crimen, mientras que el crimen contribuye a más deterioro en la comunidad y a más estrés.

La explicación de *GST* contribuye a la literatura sobre comunidades y crimen en tres formas principales. Primero, integra mucha teoría e investigación previa tratando sobre estrés y tasas de crimen en las comunidades. Segundo, extiende la teoría anterior por el señalamiento para varias variables nuevas al nivel de la comunidad que podrían influenciar el crimen, especialmente interviniendo y condicionando variables. Tercero, ofrece una nueva interpretación sobre el efecto de variables a nivel de comunidades sobre crimen.

Muchos datos indican que variables como privación económica, movilidad, desintegración familiar y signos de deterioro social y físico³ ejercen un gran efecto sobre tasas de crimen en las comunidades. Los mecanismos por los cuales estas variables afectan las tasas de crimen, sin embargo, son mucho menos claros. GST argumenta que estas variables no solamente reducen el control social, sino que también incrementan el estrés.

La Figura 3.1 muestra la explicación de *GST*. En dicha figura primero se describe como las características de las comunidades causan tensión y luego describe como dichas características condicionan el efecto de estrés sobre el crimen. Estas representan la parte central y más original de la explicación de *GST*.

Figura 3.1. Teoría General del Estrés sobre Diferencias en las Comunidades en Tasas de Criminalidad.



³ Por ejemplo, graffiti en paredes y edificios, ebrios y vagos rondando en las calles, viviendas en mala condición, vecinos escandalosos, basura en las calles, etc.

Éxito Económico

Estatus económico es el factor que más distingue a comunidades con alta criminalidad de aquellas con baja criminalidad. Primero, comunidades económicamente desaventajadas pueden contribuir a la obstrucción de metas de sus residentes por generar ambientes dentro de los cuales las personas ponen gran énfasis sobre el dinero. La necesidad propia de los individuos es además elevada por la privación que impregna a la comunidad –incluyendo la falta de recreo, compras, salud y otras facilidades.

Segundo, comunidades necesitadas no solamente alientan un fuerte énfasis sobre el dinero, sino también limitan la habilidad de los residentes para alcanzar sus metas económicas a través de medios legítimos. En particular, individuos en comunidades necesitadas tienen menos acceso a trabajos estables y bien pagados, -trabajos en el sector primario en particular.

Los problemas encarados por los residentes de los barrios deprimidos de una ciudad, en ocasiones, crean una multitud de problemas adicionales que sirven para reducir además el acceso de éstos a oportunidades legítimas para la realización de sus metas. Estos problemas no sólo crean estrés económico para los adultos sino además para los adolescentes.

GST, entonces, puede fácilmente explicar la fuerte asociación entre privación económica al nivel de la comunidad y crimen: Residir en una comunidad necesitada incrementa la probabilidad de estrés económico.

3.3. Transformación económica.

El nivel de desarrollo social y económico de una región es reflejada en su grado de urbanización, la diversidad de su base económica, la importancia relativa de la actividad económica orientada a servicios en el conjunto de la economía regional, el crecimiento y movilidad de la población y la calidad de su infraestructura. (Carcach, 2000a). Atributos de los municipios, su desarrollo y características de sus residentes juegan un rol importante en una localidad determinada. (Carcach, 2000c)

Estructura Industrial

La composición industrial de una economía local ha sido asociada con la incidencia de crimen. Regiones con industrias empleando grandes números de trabajadores no calificados son a menudo consideradas a estar en riesgo (Donnermeyer 1994).

Esas regiones tienden a atraer trabajadores con bajos niveles de educación y pocas oportunidades de éxito económico. Además, las economías de esas regiones son a menudo más vulnerables que aquellas de áreas con estructuras industriales más diversificadas, lo que hace más probable que atraviesen por períodos frecuentes de prosperidad y decaimiento. Esto pudiera tener un impacto sobre estabilidad residencial mediante movilidad laboral y también contribuir a la pobreza. (Carcach, 2000a).

En ciertas investigaciones, disminución en empleo agrícola ha mostrado estar asociado con incrementos en tasas de crimen violento y contra la propiedad. (Carcach 2000a, 2000b). Por otro lado, aumentos en la actividad de la manufactura se correlaciona negativamente con incrementos en tasas de criminalidad.

Industrias terciarias, tal como comercio de ventas al por mayor y al por menor, servicios y finanzas, seguros y bienes raíces, pudieran estar asociadas con incrementos en las tasa de criminalidad. Esas industrias requieren clientes para visitar lugares específicos para comprar bienes y servicios. Tales lugares normalmente se concentran en zonas de negocios o grandes centros comerciales creando oportunidades para el crimen en un número de formas. La población actual en riesgo en esas áreas de negocios pudiera fluctuar ampliamente durante diferentes tiempos del día o días de la semana, lo cual hace que las tasas de crimen sean indicadores menos precisos de la prevalencia del crimen.

Condiciones Económicas.

Condiciones económicas representan ingresos disponibles en el sector legal y son medidos por indicadores regionales del bienestar, crecimiento y apoyo público tal como ingreso familiar, ingreso per cápita, tasa de desempleo, crecimiento del empleo, nivel de pobreza y desigualdad del ingreso.

Bajos niveles de criminalidad no están necesariamente asociados con mejoramiento en las condiciones económicas. Si las disparidades entre una región permanecen grandes, mejoramientos en salud e ingreso, pudieran animar a los grupos menos privilegiados para cometer crímenes contra los grupos más acaudalados. (Glaeser and Sacerdote, 1999). Crecimiento económico podría contribuir a una reducción en crimen si este reduce el desempleo y la desigualdad social, y mejora las oportunidades de los miembros de una comunidad. (Mosser and Shrader, 1998). Rápido crecimiento económico además pudiera afectar negativamente a las regiones, particularmente cuando tienen poco tiempo para adaptarse a las nuevas condiciones. Esto pudiera causar inmigración masiva, y pudiera incrementar el tamaño de las poblaciones transitorias, debilitando la capacidad local para desarrollar redes y proporcionar control social. (Bursik and Grasmick, 1993).

El rol que la dependencia del bienestar social pudiera tener sobre el crimen es complejo. Por un lado, teniendo acceso a asistencia de bienestar social se esperaría que se reduzca la necesidad de los individuos a dedicarse a actividades criminales para satisfacer sus necesidades básicas. Por el otro lado, dependencia del bienestar social pudiera tener un efecto estimulador sobre el crimen si en cambio este contribuye a crear una cultura que fomente los problemas sociales. (Jarrel and Howsen, 1990).

Demográficos

Género y edad han sido identificados entre los factores que afectan el crimen regional. Investigadores en Criminología sugieren que las regiones con altas concentraciones de hombres jóvenes experimentarían tasas de crimen más altas que las regiones donde este grupo no hace una contribución significativa al total de la población. (Gottfredson, 1981).

Tamaño y accesibilidad a servicios.

Tamaño y localización influyen el desarrollo regional ya que amplios conjuntos de oportunidades económicas se acumulan en ciertos lugares por virtud de su tamaño y su acceso a economías más grandes. (Ghelfi & Parker, 1997). Esas dos dimensiones son relacionadas con el conjunto más amplio de procesos locales generando desventaja socioeconómica,

estabilidad residencial, cantidad y calidad de redes en la comunidad y capital social local. (Carcach 2000c).

3.4. *El Modelado Estadístico de Tasas de Criminalidad.*

Con el propósito de explicar la variación observada en tasas de criminalidad, necesitamos fundamentar nuestro modelo estadístico en una distribución de probabilidad que nos permita obtener un buen ajuste a los datos.

La metodología estadística que permite explicar las variaciones en las tasas de criminalidad se basa en el supuesto de que el número de homicidios en una región determinada y en un momento en el tiempo sigue una distribución de Poisson.

Definamos la variable aleatoria Y_i para representar el evento que un residente de la región i , seleccionado al azar, sea víctima de violencia. Suponiendo que estos eventos ocurren de manera independiente, la variable Y sigue una función de distribución de Bernoulli con una función de distribución de probabilidad dada por

$$\Pr(Y = k) = p^k (1 - p)^{1-k} = p^k q^{1-k} \quad k = \{0, 1\}, \quad (3.1)$$

donde p es la probabilidad de que una persona sea víctima de homicidio y $q = 1 - p$ representa la probabilidad de no ser víctima de homicidio.

Si n homicidios ocurren aleatoriamente en una población de N miembros, esto es cada elemento de dicha población está expuesto al mismo riesgo de victimización, entonces la distribución del número de víctimas está dada por una distribución Binomial con función de distribución de probabilidad dada por

$$\Pr(Y = k) = \binom{n}{k} p^k q^{n-k} \quad k = 0, 1, 2, \dots, n \quad (3.2)$$

donde la variable aleatoria Y denota el número de homicidios registrados u ocurridos.

Si la probabilidad p es pequeña y el tamaño de la población es grande, entonces podemos aproximar la distribución del número de víctimas por una distribución de Poisson con función de distribución de probabilidad

$$\Pr[Y = y] = \frac{e^{-\lambda} \lambda^y}{y!} \quad y = 0, 1, 2, \dots \quad (3.3)$$

Para esta distribución $E(Y) = V(Y) = \lambda$, $\lambda > 0$. Esta distribución tiene un parámetro único λ , el parámetro de intensidad igual a Np .

La igualdad de la media y la varianza se refiere a menudo como la propiedad de igual dispersión (*equidispersión*) de la distribución de Poisson. Esta propiedad es frecuentemente violada por datos reales, los cuales exhiben variación que excede lo predicho por el modelo de Poisson, un fenómeno conocido como *exceso de dispersión* ya que la varianza sobrepasa la media.

Exceso de dispersión puede ocurrir porque los datos exhiben dependencia, como por ejemplo cuando estos provienen de muestras de conglomerados o en el caso de eventos que ocurren dentro de entidades espaciales o en el tiempo, los cuales por naturaleza son correlacionados. En nuestro caso, otra razón para que el exceso de dispersión aparezca es el hecho que los homicidios son de naturaleza diferente, una parte de ellos son causa de la violencia delincuencia (hechos motivados económicamente o los delitos contra el patrimonio) y los otros son producto de violencia social (venganzas, intolerancias, violencia intrafamiliar, alcoholismo, drogadicción y rencillas entre pandillas). Exceso de dispersión puede aparecer también debido al hecho de que se registren homicidios en municipios con poblaciones relativamente pequeñas.

3.4.1. Modelos Lineales Generalizados

En El Salvador, la tasa de homicidio varía entre regiones geográficas y el propósito de esta investigación es poder explicar dicha variación. La literatura indica que problemas tales como bajos ingresos, pobreza, desempleo, falta de acceso a bienestar social, desigualdad, alta densidad poblacional y altas tasas de hacinamiento explican parte de la variación en tasas de homicidio.

Para alcanzar este propósito es adecuado usar la metodología de los Modelos Lineales Generalizados (MLG). Un MLG está constituido por tres componentes. El primero, conocido como el componente aleatorio, corresponde al modelo de probabilidad o mecanismo aleatorio que genera los datos. El segundo es conocido como el componente sistemático y corresponde a una función lineal de variables asociadas a variaciones de tipo sistemático en la media de la distribución de la variable dependiente, según el modelo del componente aleatorio. El tercer componente se conoce como la función de enlace y corresponde a un mapeo del componente sistemático sobre una transformación del parámetro natural del modelo probabilístico especificado en el componente aleatorio sobre el componente sistemático.

Los modelos seleccionados para el componente aleatorio de un MLG corresponden generalmente a distribuciones que pertenecen a la familia exponencial de distribuciones. Se dice que una distribución de probabilidad pertenece a la familia exponencial si su función de distribución de probabilidad posee la forma siguiente (Everitt, 2002):

$$f(x) = \exp\{a(\theta)b(x) + c(\theta) + d(x)\}, \quad (3.4)$$

donde, θ es un parámetro, conocido como el parámetro natural de la distribución, y a, b, c, d son funciones conocidas. La familia exponencial incluye a las distribuciones normal, gamma, binomial y Poisson. Por ejemplo, la distribución de Poisson puede ser escrita de la manera siguiente:

$$f(x) = \exp\left\{(\ln \lambda)x - \lambda - \sum_{i=1}^n \ln(x_i)\right\}, \quad (3.5)$$

donde $a(\theta) = \ln \lambda$, $b(x) = x$, $c(\theta) = -\lambda$, y $d(x) = \sum_{i=1}^n \ln(x_i)$.

La derivación de la función de enlace requiere trabajar con la función de verosimilitud asociada a una muestra. Asumimos que la variable aleatoria escalar y_i , dado un vector de regresores, \mathbf{x}_i , y un vector de parámetros, $\boldsymbol{\beta}$, está distribuida con densidad $f(y_i / \mathbf{x}_i, \boldsymbol{\beta})$. El criterio de máxima verosimilitud elige como estimador de $\boldsymbol{\beta}$ a aquel valor que maximiza una función de la probabilidad conjunta de los valores de y en la muestra, y_1, \dots, y_n . Dicha función, vista como una función de los parámetros, condicional en los datos, es llamada la *función de verosimilitud*, denotada como

$$L(\boldsymbol{\beta}) = \prod_{i=1}^n f(y_i / \mathbf{x}_i, \boldsymbol{\beta}) \quad (3.6)$$

En el caso de una distribución de Poisson, la función de verosimilitud asociada es

$$L(\boldsymbol{\beta}) = \prod_{i=1}^n \frac{e^{-\lambda} \lambda^{y_i}}{y_i!} \quad (3.7)$$

Tomando el logaritmo natural de la función de verosimilitud y reemplazando $\ln \lambda$ con $\mathbf{x}_i' \boldsymbol{\beta}$ se obtiene la función de enlace deseada:

$$\mathcal{L}(\boldsymbol{\beta}) = \ln L(\boldsymbol{\beta}) = \sum_{i=1}^n \ln f(y_i / \mathbf{x}_i, \boldsymbol{\beta}) \quad (3.8)$$

$$\mathcal{L}(\boldsymbol{\beta}) = \sum_{i=1}^n \{y_i \mathbf{x}_i' \boldsymbol{\beta} - \exp(\mathbf{x}_i' \boldsymbol{\beta}) - \ln y_i!\} \quad (3.9)$$

En el caso que nos interesa, el MLG queda definido por

$$\ln(\lambda) = \mathbf{x}_i' \boldsymbol{\beta} \quad (3.10)$$

Esto define el Modelo Lineal Generalizado con componente aleatorio Poisson y función de enlace log, el cual también es conocido como regresión de Poisson.

Estas k ecuaciones son no lineales en las $\boldsymbol{\beta}$ desconocidas, y no hay solución analítica para $\hat{\boldsymbol{\beta}}$. Métodos iterativos, normalmente métodos gradientes tal como Newton-Raphson, son necesarios para calcular $\hat{\boldsymbol{\beta}}$.

El modelo de Poisson es restrictivo en el supuesto de que la media es igual a la variancia. En situaciones prácticas es frecuente encontrar que la variancia de los datos excede a la variancia dicha en el modelo de Poisson. Ese problema puede surgir debido a factores tales como:

1. La población expuesta al riesgo es pequeña.
2. El número homicidios en una comunidad es pequeño.
3. Los factores incluidos en la parte sistemática del modelo pueden mostrar patrones específicos de variación para diferentes grupos de la población o tipos de homicidios (Heterogeneidad).
4. Los eventos no son independientes.

Una manera de lidiar con el problema de exceso de dispersión es usando un modelo de probabilidad que tome en cuenta la asimetría y picudez de la distribución de la variable de interés en los datos. Uno de tales modelos es el de la distribución Binomial Negativa.

3.4.2. Distribución Binomial Negativa

El modelo estándar de conteos con exceso de dispersión es el de la distribución Binomial Negativa. Existen varias formas en las que esta distribución puede surgir, siendo la más común que los datos son Poisson, pero hay una heterogeneidad individual gamma distribuida reflejando el hecho que la media no está perfectamente observada. Una derivación alternativa

de la binomial negativa supone una forma particular de dependencia para los procesos estocásticos subyacentes, según la cual el acontecimiento de un evento afecta la probabilidad de otros acontecimientos.

Una variable aleatoria X tiene una distribución binomial negativa con parámetros $\alpha \geq 0$ y $\theta \geq 0$, escrita $X \sim \text{Negbin}(\alpha, \theta)$, si la función de probabilidad está dada por¹⁴

$$P(X = k) = \frac{\Gamma(\alpha + k)}{\Gamma(\alpha)\Gamma(k + 1)} \left(\frac{1}{1 + \theta}\right)^\alpha \left(\frac{\theta}{1 + \theta}\right)^k, \quad k = 0, 1, 2, \dots \quad (3.11)$$

donde $\Gamma(\cdot)$ denota la función gamma⁵².

La media y varianza están dadas por

$$E(X) = \alpha\theta \quad (3.12)$$

y

$$\text{Var}(X) = \alpha\theta(1 + \theta). \quad (3.13)$$

Para α fijo, dicha distribución tiene la forma de un modelo lineal generalizado con función de enlace

$$\eta = \log\left(\frac{\theta}{1 + \theta}\right). \quad (3.14)$$

Dado $\theta \geq 0$, la varianza de la distribución binomial negativa generalmente sobrepasa su media (“exceso de dispersión”). El exceso de dispersión desaparece para $\theta \rightarrow 0$.

⁴ Definida en función de la distribución gama. Puede demostrarse que la forma más común, esto es,

$$\Pr(Y = k) = \binom{r + k - 1}{r - 1} p^r (1 - p)^k$$

conduce a (3.11). Ver final de Capítulo.

⁵ La función gama denotada con Γ , se define como $\Gamma(p) = \int_0^\infty x^{p-1} e^{-x} dx$, definida para $p > 0$. Para más detalle sobre la distribución gama ver referencia 2 al final del capítulo.

La distribución binomial negativa posee varias parametrizaciones. El primer paso para usar la distribución binomial negativa en un análisis de regresión, es convertir el modelo dentro de una parametrización de la media, es decir

$$\lambda = \alpha\theta \quad (3.15)$$

donde λ es el valor esperado. Existen dos formas simples de hacer esto.

1. $\alpha = \lambda / \theta$. En este caso, la función de varianza toma la forma

$$\text{Var}(X) = \lambda (1 + \theta)$$

De aquí, la varianza es una función lineal de la media. Este modelo es llamado “Negbin I” (Cameron and Trivedi, 1986).

2. $\theta = \lambda / \alpha$. En este caso, la función de varianza toma la forma

$$\text{Var}(X) = \lambda + \alpha^{-1} \lambda^2$$

Una distribución binomial con función de varianza cuadrática. Este modelo es llamado “Negbin II”

Las funciones de probabilidad asociadas con los dos modelos son las siguientes:

$$\text{Negbin I: } P(X = k) = \frac{\Gamma(\lambda/\theta + k)}{\Gamma(\alpha/\theta)\Gamma(k+1)} \left(\frac{1}{1+\theta}\right)^{\lambda/\theta} \left(\frac{\theta}{1+\theta}\right)^k \quad (3.16)$$

y

$$\text{Negbin II: } P(X = k) = \frac{\Gamma(\alpha + k)}{\Gamma(\alpha)\Gamma(k+1)} \left(\frac{\alpha}{\alpha + \lambda}\right)^\alpha \left(\frac{\lambda}{\alpha + \lambda}\right)^k \quad (3.17)$$

Aunque esos dos tipos son las parametrizaciones más ampliamente utilizadas en la práctica, otras son posibles⁶.

Para resumir, la principal ventaja de la distribución binomial negativa sobre la distribución de Poisson es que el parámetro adicional introduce flexibilidad substancial en la modelación de la función de varianza, y así heterocedasticidad. En particular, introduce exceso de dispersión, una forma más general de heterocedasticidad que la igualdad de la media-varianza supuesta por la distribución de Poisson.

3.5. Pruebas de Exceso de Dispersión.

Los datos están con exceso de dispersión si la varianza condicional sobrepasa la media condicional. Un indicio de la magnitud de exceso de dispersión o déficit de dispersión puede ser obtenido simplemente por la comparación de la media y la varianza muestral de la variable de conteo independiente. Posterior a la regresión de Poisson decrece en algo la varianza condicional de la variable dependiente. El promedio de la media condicional será incambiable, sin embargo, ya que el promedio de las medias ajustadas es igual a la media muestral. Esto resulta porque los residuales de Poisson suman cero si un término constante es incluido. Si la varianza muestral es menos que la media muestral, los datos necesariamente están aún con más déficit de dispersión una vez los regresores son incluidos. Si la varianza muestral es más que dos veces la media muestral, entonces los datos están probables a permanecer con exceso de dispersión después de la inclusión de regresores.

Para realizar pruebas de exceso de dispersión se estima uno de los modelos de la función binomial negativa (Negbin I o Negbin II) junto con el modelo de Poisson; debido a que el modelo de Poisson es el caso especial de la binomial negativa con $\alpha = 0$, la hipótesis nula $H_0: \alpha = 0$ puede ser probada contra la alternativa $\alpha > 0$ usando los métodos de pruebas de hipótesis ya conocidas. Una prueba LR (Razón de verosimilitudes –LR por sus siglas en

⁶ Por ejemplo, dado $\alpha = \sigma^2 \lambda^{-k}$ y $\theta = \sigma^2 \lambda^k$. Como antes, $E(X) = \lambda$. Substituyendo α y θ en 3.13 se tiene $\text{Var}(X) = \lambda(1 + \sigma^2 \lambda^k)$. Así, para $k = 0$ esta parametrización reduce la distribución binomial negativa con función de varianza lineal, mientras que para $k = 1$, la función de varianza cuadrática es obtenida. Winkelmann y Zimmermann (1995) se refieren a este modelo como “Negbin k ”.

inglés) usa -2 veces la diferencia en la log – verosimilitud ajustada de los dos modelos. Alternativamente una prueba de Wald puede llevarse a cabo, usando el estadístico t presentado para el α estimado en el modelo binomial negativo.

Más allá del rechazo o no rechazo de la hipótesis nula de igual dispersión, el interés pudiera descansar en la interpretación de la magnitud de las salidas de igual dispersión. Estimaciones de α para la función de varianza Negbin I $(1 + \alpha)\lambda_i$ son fácilmente interpretadas, con baja dispersión si $\alpha < 0$, exceso de dispersión modesta cuando, es decir, $0 < \alpha < 1$, y exceso de dispersión considerable si, es decir $\alpha > 1$. Para la función de varianza Negbin II $\lambda_i + \alpha\lambda_i^2$ déficit de dispersión además ocurre si $\alpha < 0$. Para la interpretación de la magnitud de exceso de dispersión de la función de varianza Negbin II, es útil rescribir la función de varianza como $(1 + \alpha\lambda_i)\lambda_i$. Entonces valores de exceso de dispersión considerable surgen si, es decir, $\alpha\lambda_i > 1$, porque entonces el multiplicador $1 + \alpha\lambda_i > 2$. Así un valor de α igual a 0.5 indicaría exceso de dispersión modesta si la variable dependiente toma en su mayor parte valores de 0,1 y 2, sino habría exceso de dispersión grande si conteos de 10 ó más fueron a menudo observados.

Frecuentemente los datos de conteo están con exceso de dispersión en lugar que con falta de dispersión, y pruebas para salidas de igual dispersión son normalmente llamadas pruebas de exceso de dispersión. Observe que el modelo binomial negativo puede solamente acomodar exceso de dispersión.

3.6. Diagnóstico del Modelo.

El diagnóstico del modelo se refiere a la verificación que el modelo es especificado correctamente y que proporciona un buen ajuste a los valores observados de la variable dependiente. Además, esta actividad busca determinar qué tan bueno es el modelo para predecir el comportamiento de la tasa de homicidios en el futuro.

El modelo de regresión de Poisson se basa en los supuestos siguientes:

Supuesto 1.

$$y_i/x_i \sim \text{Poisson}(x'_i;\beta)$$

Donde y_i/x_i significa la distribución condicional de y_i dado la realización x_i .

Supuesto 2.

$$\lambda(x_i;\beta) = \exp(x'_i;\beta) \quad i = 1, \dots, n$$

Supuesto 3.

$(y_i/x_i), i = 1, \dots, n$ están idénticamente distribuidos.

Se debe tener en cuenta que, en situaciones prácticas, la validez de estos supuestos puede ser cuestionable, y se deben hacer análisis para examinar la adecuación del modelo que se haya desarrollado en forma tentativa.

Los residuales definidos como la diferencia entre el valor observado para la tasa de homicidios en un municipio y el valor de la tasa que se obtiene directamente del modelo, constituye la materia prima para evaluar la especificación y ajuste del modelo.

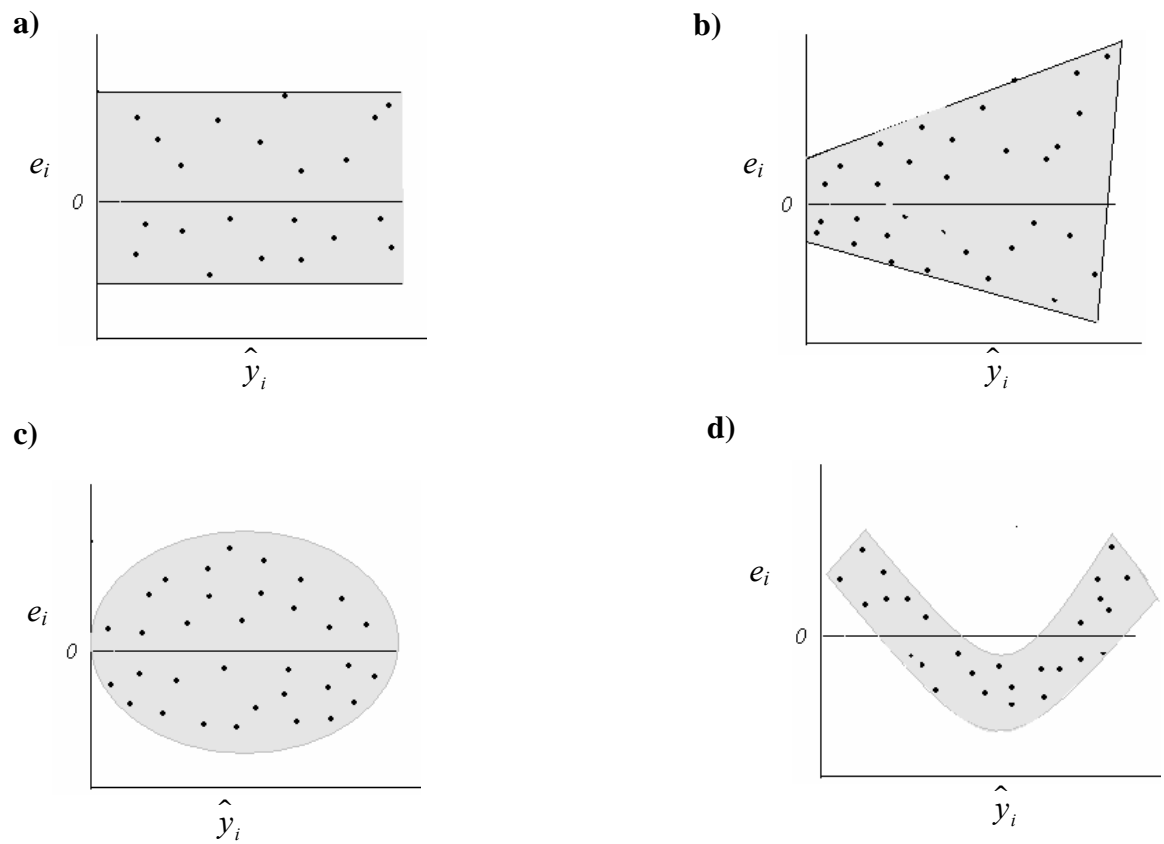
El análisis gráfico de residuales es una forma muy efectiva investigar la adecuación del ajuste de un modelo de regresión, y para comprobar las premisas básicas. Con frecuencia se aconseja graficar tanto los residuales originales como uno o más de los residuales escalados.

Es útil una gráfica de los residuales e_i (o los residuales escalados d_i, r_i o t_i) en función de los valores ajustados correspondientes \hat{y}_i para detectar tipos frecuentes de inadecuaciones del modelo⁷. Si esta gráfica se parece a la de la Figura 3.2a que indica que los residuales se pueden encerrar en una banda horizontal, entonces no hay defectos obvios del modelo. Las

⁷ Se deben graficar los residuales en función de los valores ajustados \hat{y}_i , y no los valores observados y_i , porque las e_i y las \hat{y}_i no están correlacionadas, mientras que las e_i y las y_i suelen estar correlacionadas.

gráficas de e_i en función de \hat{y}_i que se parezcan a cualquiera de los patrones de las partes b a d son síntomas de deficiencias de modelo.

Figura 3.2. Patrones en las gráficas de residuales.



3.6.1. Fuentes de mala especificación

Una “mala especificación” es una violación de alguna de las tres suposiciones de la especificación del modelo de regresión de Poisson. Tipos específicos de mala especificación podrían afectar no solo una suposición, sino dos o tres a la vez.

La relación cercana entre regresión, función varianza y distribución es una característica particular del modelo de regresión de Poisson. Bajo la suposición de Poisson, la igualdad de la media condicional y la varianza condicional, supone la pérdida de un grado de libertad comparado, por ejemplo con el modelo lineal normal. Así una violación de la función varianza supone siempre una violación de la suposición distribucional. La violación que ha obtenido la mayor atención es “exceso de dispersión”, una situación donde la varianza sobrepasa la media condicional sobre covariables.

3.6.1.1. Función de la media.

Recordar que la función de la media de la regresión de Poisson está especificada como

$$E(y_i/x_i) = \lambda_i = \exp(x_i'\beta)$$

donde x es un vector de covariables individuales.

La función de la media está mal especificada, si para x_i arbitraria, allí no existe β tal que $\lambda_i = f(x_i; \beta_0)$. Posibles fuentes de mala especificación incluyen:

- Variables explicativas son omitidas, y estas variables omitidas no son independiente de x .
- El predictor no es lineal en β .
- Variables explicativas entran al predictor por alguna transformación $f(x)$, en lugar de hacerlo linealmente.
- La función está mal especificada. Por ejemplo la verdadera función de la media podría ser lineal en lugar de hacerlo log-lineal.

3.6.1.2. *Heterogeneidad no observada.*

Esta situación se presenta si las variables explicativas no explican la cantidad completa de heterogeneidad individual. Esta situación puede ser interpretada como un defecto de la función de la media.

La heterogeneidad no observada en el modelo de regresión de Poisson causa “exceso de dispersión”; es decir que la varianza de la población es más grande que su media y la población no puede estar distribuida como una Poisson.

3.6.1.3. *Procesos dependientes.*

La distribución de Poisson es apropiada si los eventos suceden completamente aleatorios sobre el tiempo. El modelo de Poisson es mal especificado si el proceso que genera los eventos no está perdiendo la memoria, esto es cuando la probabilidad de un acontecimiento entre t y $t+h$ depende sobre el proceso pasado.

3.6.2. *Pruebas de mala especificación.*

Dado que muchas de las “malas especificaciones” listadas en la sección anterior conducen a una violación de la suposición de igualdad en la media y varianza condicional, la función de varianza proporciona un punto de partida natural para pruebas de mala especificación. Frecuentemente uno tiene una alternativa específica en mente que tiene en cuenta una función de varianza más general y, al mismo tiempo, anida la función de varianza Poisson a través de una restricción paramétrica. En esta situación, las tres pruebas clásicas, la razón de verosimilitud, la prueba de Wald y la de multiplicadores de Lagrange pueden ser usadas.

3.6.3. Pruebas clásicas de especificación

Examinando un modelo Poisson contra un modelo paramétrico más general es sencillo si aquel es contenido en el último a través de una restricción paramétrica. Los dos modelos se dice que están “anidados”. Ejemplos para restricciones son:

1. Poisson versus binomial negativa: $H_0: \sigma_u^2 = 0$.
2. Restricciones lineales sobre coeficientes de regresión: $H_0: R\beta = q$.
3. Restricciones no lineales sobre coeficientes de regresión: $H_0: R(\beta) = q$.

Se supone que la estimación es por el método de máxima verosimilitud. Pruebas para la validez de H_0 pueden ser basados sobre alguno de los tres principios siguientes:

1. Prueba de razón de verosimilitudes.
2. Prueba de Wald.
3. Prueba de multiplicadores de Lagrange.

Estas son pruebas asintóticas. Sus propiedades de muestras pequeñas (tamaño y potencia) son generalmente desconocidas. Asintóticamente, todas las tres pruebas son equivalentes. Las pruebas son direccionales, implicando que si la hipótesis nula es rechazada, hay una alternativa definida.

Prueba de Razón de Verosimilitudes.

Dado $\hat{\ell}_r$ que indica el valor de la función log-verosimilitud evaluada en la estimación de máxima verosimilitud restringida. (por ejemplo el modelo Poisson, y $\hat{\ell}_u$ el valor de la función log-verosimilitud evaluada en la estimación de máxima verosimilitud no restringida (por ejemplo, el modelo binomial negativo), y dado k que indica el número de restricciones ($k=1$ en un prueba del modelo de Poisson contra el modelo binomial negativo). Entonces bajo H_0 (si la restricción es correcta):

$$LR = -2(\hat{\ell}_r - \hat{\ell}_u) \sim \chi_{(k)}^2 \quad (3.18)$$

donde $\chi^2_{(k)}$ es una distribución chi-cuadrado con k grados de libertad. La prueba es basada sobre la diferencia de los dos valores de log-verosimilitudes, o equivalente, el log de una razón de verosimilitud, de aquí su nombre.

Si la restricción es disipada, el valor de la función log-verosimilitud (evaluada en las estimaciones máxima verosimilitud) debe incrementar. Si el incremento es “grande”, donde grande es definido como alguna prueba estadística que sobrepasa el valor crítico $\chi^2_{\alpha,k}$, la hipótesis nula es rechazada.

Prueba de Wald.

El punto de partida para la prueba de Wald es la distribución asintótica del estimador máxima verosimilitud en el modelo sin restricciones. En comparación a la prueba de verosimilitudes, la estimación de un modelo único es suficiente:

$$\hat{\theta} \sim^{\text{app}} N(\theta_0, \hat{Var}(\hat{\theta}))$$

donde $\hat{\theta}$ consiste de los coeficientes estimados de la regresión más algunos parámetros adicionales, tal como $\hat{\sigma}_u^2$. Para alguna combinación lineal de el vector de parámetro $R\hat{\theta} - q$ se sigue que

$$R\hat{\theta} - q \sim^{\text{app}} N(R\theta_0 - q, R\hat{Var}(\hat{\theta})R')$$

Bajo H_0 : $R\theta_0 - q = 0$ y por lo tanto

$$W = (R\hat{\theta} - q)[R\hat{Var}(\hat{\theta})R']^{-1} (R\hat{\theta} - q) \quad (3.19)$$

tiene una distribución chi-cuadrado con grados de libertad igual al número de restricciones si la hipótesis nula es verdadera. Si el número de restricciones es uno, el estadístico se simplifica al cuadrado del estadístico “ t ”. Dividiendo W en (3.19) por los grados de libertad produce un estadístico “ F ”. Las comillas indican que, bajo la estimación máxima verosimilitud, aplican

resultados asintóticos, visto que la distribución t y la distribución F son distribuciones de muestras finitas.

Prueba de Multiplicadores de Lagrange.

En lugar de calcular ambos modelos y llevar a cabo una prueba de máxima verosimilitud, o calcular el modelo alternativo únicamente y llevar a cabo una prueba de Wald, la prueba de multiplicadores de Lagrange (LM) evita completamente el cálculo del modelo alternativo. Esta prueba es además conocida como la prueba de “puntaje” (*score test*). En este contexto, el vector de puntaje es el vector de primeras derivadas (o gradientes) de la función de log-verosimilitud con respecto a los parámetros.

Dado $\ln L_u$ es la función de log-verosimilitud del modelo no restringido. Entonces, $\hat{\theta}_u$ soluciona las condiciones de primer orden

$$\frac{\partial \ln L}{\partial \theta} \Big|_{\theta_u} = \frac{\partial \ell}{\partial \theta} \Big|_{\theta_u} = 0 \quad (3.20)$$

Alternativamente, podríamos evaluar el vector de puntajes del modelo no restringido en el estimador máxima verosimilitud $\hat{\theta}_r$ obtenido bajo el modelo restringido.

$$\frac{\partial \ell}{\partial \theta} \Big|_{\theta_r} \neq 0 \quad (3.21)$$

A menos que la restricción sea verdadera, esta expresión es diferente de cero. Por lo tanto, la restricción es rechazada si el puntaje (3.21) está “lejos” de cero. Si la hipótesis nula es verdadera (i.e., $\hat{\theta}_r = \theta_0$), el vector de puntajes tiene una distribución normal asintótica con media cero y matriz de varianza covarianza igual a la matriz de información de Fisher. Por lo tanto, una prueba puede ser basada sobre la forma cuadrática

$$\text{LM} = \left(\frac{\partial \ell}{\partial \theta} \right)_{\hat{\theta}_r}' \left[I(\hat{\theta}_r) \right]^{-1} \left(\frac{\partial \ell}{\partial \theta} \right)_{\hat{\theta}_r} \quad (3.22)$$

El cual tiene una distribución chi –cuadrado con grados de libertad igual al número de restricciones bajo la hipótesis nula. (La varianza del puntaje puede ser estimada por las tres formas comunes).

Prueba de la Matriz de Información.

La prueba de la matriz de información (White, 1982) es basada sobre la muestra análoga de la identidad

$$E\left(\frac{\partial \ell}{\partial \theta} \frac{\partial \ell}{\partial \theta'}\right) = -E\left(\frac{\partial^2 \ell}{\partial \theta \partial \theta'}\right)$$

La cual puede ser rescrita como

$$E\left(\frac{\partial \ell}{\partial \theta} \frac{\partial \ell}{\partial \theta'}\right) + \left(\frac{\partial^2 \ell}{\partial \theta \partial \theta'}\right) = 0$$

En el contexto de modelos de datos de conteo con heterogeneidad no observada, este ha sido observado por Lee (1986), de un resultado originalmente debido a Chesher (1984) sobre la igualdad potencial entre pruebas de la matriz de información y pruebas de puntaje de multiplicadores de Lagrange aplicados también al modelo de regresión de Poisson.

3.6.3.1. Pruebas de Bondad de Ajuste.

En comparación a modelación continua, datos discretos permiten calcular probabilidades de resultados sencillos después que el modelo ha sido estimado. Para modelos de datos de conteo, la mayoría de la literatura aplicada ha ignorado la posibilidad de emplear las predicciones para evaluar la bondad de ajuste.

Gilbert (1979) considera el modelo Poisson y mide el ajuste del modelo por la proporción de las predicciones correctas en la muestra. El sugiere para predecir el conteo para i individual (con atributos dados x_i) ya sea por su valor modal o por el entero más cercano a su valor

esperado. Este procedimiento, básicamente se apoya sobre la bondad de ajuste de la función de la media.

Un procedimiento relacionado está basado sobre el estadístico de Pearson

$$P = \sum_{i=1}^n \frac{(y_i - \hat{\lambda}_i)^2}{\hat{\lambda}_i} \quad (3.23)$$

Si el modelo de Poisson está correctamente especificado, $\hat{E}(y_i - \lambda_i)^2 / \lambda_i = 1$, y así, $E[\sum_{i=1}^n (y_i - \lambda_i)^2 / \lambda_i] = n$. En la práctica, P es comparado a $(n - k)$ en orden para ajustar la pérdida de grados de libertad debido a la estimación de λ_i . $P \neq n - k$ indica una “mala especificación” de la media condicional o la suposición distribucional.

Una alternativa estadística de bondad de ajuste es la “deviance”

$$D = \sum_{i=1}^n \left\{ y_i \ln \left(\frac{y_i}{\hat{\lambda}_i} \right) - (y_i - \hat{\lambda}_i) \right\} \quad (3.24)$$

(McCullagh y Nelder, 1989). Para el modelo exponencial de Poisson con intercepto incluido, la suma sobre el segundo término sobre la derecha es cero, así que podemos escribir

$$D = \sum_{i=1}^n y_i \ln \left(\frac{y_i}{\hat{\lambda}_i} \right)$$

(donde $y_i \ln y_i = 0$ para $y_i = 0$). La “deviance” mide la diferencia entre la máxima verosimilitud alcanzable y el log-verosimilitud alcanzable por el modelo bajo examen. La “deviance” tiene una distribución aproximada chi-cuadrado con $n - k$ grados de libertad.

Cameron y Windmeijer (1996) discuten el uso de medidas de pseudos R cuadrado para determinar la bondad de ajuste dentro de las clases de modelos de regresión de datos de conteo.

La medida preferida identificada por Cameron y Windmeijer es una basada sobre los residuales de la deviance. Para el modelo de regresión de Poisson, este es dado por

$$R^2 = \frac{\sum_{i=1}^n y_i \log\left(\frac{\hat{\lambda}_i}{y}\right)}{\sum_{i=1}^n y_i \log\left(\frac{y_i}{y}\right)} \quad (3.25)$$

Ellos listan propiedades deseables de medidas de pseudos R cuadrado:

1. $0 \leq R^2 \leq 1$
2. R^2 no decrece cuando los regresores son agregados
3. R^2 basado sobre suma de residuales coincide con R^2 basados sobre sumas de cuadrados explicados.
4. Existe una correspondencia entre R^2 y una prueba de significancia sobre todas las pendientes de los parámetros o sobre el incremento de las pendientes de los parámetros.

Notas:

$$\begin{aligned} {}^1 \Pr(Y = k) &= \binom{r+k-1}{r-1} p^r (1-p)^k \\ &= \frac{(r+k-1)!}{(r-1)!((r+k-1)-(r-1))!} p^r (1-p)^k = \frac{(r+k-1)!}{k!(r-1)!} p^r (1-p)^k = \frac{\Gamma(r+k)}{\Gamma(k+1)\Gamma(r)} p^r (1-p)^k \end{aligned}$$

Haciendo $r = \alpha$ y $p = \frac{\alpha}{\lambda + \alpha}$, se tiene

$$\begin{aligned} \Pr(Y = k) &= \frac{\Gamma(\alpha+k)}{\Gamma(k+1)\Gamma(\alpha)} \left(\frac{\alpha}{\lambda+\alpha}\right)^\alpha \left(1 - \frac{\alpha}{\lambda+\alpha}\right)^k = \frac{\Gamma(\alpha+k)}{\Gamma(k+1)\Gamma(\alpha)} \left(\frac{\alpha}{\lambda+\alpha}\right)^\alpha \frac{\lambda^k}{(\lambda+\alpha)^k} \\ &= \frac{\Gamma(\alpha+k)}{\Gamma(k+1)\Gamma(\alpha)} \frac{1}{\left(\frac{\lambda+\alpha}{\alpha}\right)^\alpha} \frac{\lambda^k}{(\lambda+\alpha)^k} = \frac{\Gamma(\alpha+k)}{\Gamma(k+1)\Gamma(\alpha)} \frac{1}{\left(1 + \frac{\lambda}{\alpha}\right)^\alpha} \frac{\lambda^k}{(\lambda+\alpha)^k} \end{aligned}$$

Haciendo $\theta = \frac{\lambda}{\alpha}$, se tiene:

$$\begin{aligned} \Pr(Y = k) &= \frac{\Gamma(\alpha+k)}{\Gamma(\alpha)\Gamma(k+1)} \frac{1}{(1+\theta)^\alpha} \frac{\lambda^k}{(\lambda+\alpha)^k} = \frac{\Gamma(\alpha+k)}{\Gamma(\alpha)\Gamma(k+1)} \frac{1}{(1+\theta)^\alpha} \frac{\lambda^k}{(\lambda+\alpha)^k} \frac{\alpha^k}{\alpha^k} \\ &= \frac{\Gamma(\alpha+k)}{\Gamma(\alpha)\Gamma(k+1)} \frac{1}{(1+\theta)^\alpha} \frac{\frac{\lambda^k}{\alpha^k}}{\frac{(\lambda+\alpha)^k}{\alpha^k}} = \frac{\Gamma(\alpha+k)}{\Gamma(\alpha)\Gamma(k+1)} \frac{1}{(1+\theta)^\alpha} \frac{\left(\frac{\lambda}{\alpha}\right)^k}{\left(1 + \frac{\lambda}{\alpha}\right)^k} \\ &= \frac{\Gamma(\alpha+k)}{\Gamma(\alpha)\Gamma(k+1)} \frac{1}{(1+\theta)^\alpha} \frac{\theta^k}{(1+\theta)^k} \\ &= \frac{\Gamma(\alpha+k)}{\Gamma(\alpha)\Gamma(k+1)} \left(\frac{1}{1+\theta}\right)^\alpha \left(\frac{\theta}{1+\theta}\right)^k \end{aligned}$$

²La función gama denotada con Γ , se define como

$$\Gamma(p) = \int_0^\infty x^{p-1} e^{-x} dx, \text{ definida para } p > 0. \quad (1)$$

Integrando lo anterior por partes, haciendo $e^{-x} dx = dv$ y $x^{p-1} = u$, se obtiene

$$\Gamma(p) = (p-1) \Gamma(p-1). \quad (2)$$

Así se ha demostrado que la función gama sigue una importante relación recursiva. Supóngase que p es un entero positivo, dejamos $p = n$. Entonces, aplicando la ecuación (2) repetidamente, se obtiene

$$\Gamma(n) = (n-1) \Gamma(n-1)$$

$$= (n - 1) (n - 2) \Gamma(n - 2) = \dots$$

$$= (n - 1) (n - 2) \dots \Gamma(1).$$

Sin embargo, $\Gamma(1) = \int_0^{\infty} e^{-x} dx = 1$, por tanto, tenemos

$$\Gamma(n) = (n - 1)! \quad (3)$$

(si n es un entero positivo). (Luego se puede considerar que la función gama es una generalización de la función factorial).

Con la ayuda de la función gama, ahora se puede presentar la distribución gama de probabilidades:

Definición. Una variable aleatoria θ tiene una distribución de probabilidades gama si su función de densidad está dada por

$$f(\theta) = \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} e^{-\theta\beta}, \quad \theta > 0$$

$$= 0 \text{ para cualquier otro valor.} \quad (4)$$

Esta distribución depende de los dos parámetros, α y β de los cuales necesitamos $\alpha > 0, \beta > 0$.

Propiedades de la distribución gama

- Si $\alpha = 1$ la ecuación (4) se transforma en $f(\theta) = \beta e^{-\theta\beta}$. Luego, la distribución exponencial es un caso especial de la distribución gama.
- En la mayoría de nuestras aplicaciones, el parámetro α será un *entero* positivo. En este caso, existe una relación interesante entre la función de distribución acumulada de la distribución gama y la distribución de Poisson.
- Si θ tiene una distribución gama dada por la ecuación (4), tenemos $E(\theta) = \alpha / \beta$ y $V(\theta) = \alpha / \beta^2$.

4. Objetivos

General:

- Usando un Modelo Lineal Generalizado (MLG), identificar los factores económicos y sociales que afectan la variación geográfica en tasa de homicidios para los municipios de El Salvador.

Específicos:

1. Cuantificar el efecto del nivel de pobreza sobre la tasa de homicidios.
2. Cuantificar el efecto del desempleo sobre la tasa de homicidios.
3. Cuantificar el efecto de la composición demográfica sobre la tasa de homicidios.
4. Cuantificar el efecto de los ingresos económicos sobre la tasa de homicidios.
5. Evaluar la dirección que tales factores tienen sobre el número de homicidios en las diferentes regiones geográficas del país.
6. Evaluar la capacidad predictiva del modelo estimado.

5. Hipótesis

- Cuanto más alto sean el nivel de desigualdad socioeconómica y el nivel de pobreza, tanto más alta es la tasa de homicidio de un municipio.
- Cuanto mayor es el grado de aislamiento geográfico de un municipio, tanto más alta es su tasa de homicidio.
- Cambios en la estructura económica y social de los municipios afectan las tasas de homicidios.

5.1. Operacionalización de hipótesis

La operacionalización de las hipótesis consiste en tomar dichas suposiciones y expresarlas en términos de variables, las cuales algunas veces no podemos medir directamente por lo que nos valemos de indicadores que permitan medir el comportamiento del problema, así como los elementos asociados a él. La Tabla 5.1 presenta la operacionalización de las hipótesis planteadas anteriormente.

Tabla 5.1.

Operacionalización de hipótesis.

Variable dependiente			
Variable	Conceptualización	Indicador	Unidad de Medida
Homicidio	Hecho de privar de la vida a una persona, procediendo con voluntad y malicia. (PNUD, 2002)	Tasa de Homicidios	Tasa por 10,000 habitantes

Nota: La variable independiente es la misma para todas las hipótesis planteadas.

Variables Independientes				
Hipótesis	Variable	Conceptualización	Indicador	Unidad de Medida
Cuanto más altos sean el nivel de desigualdad socioeconómica y el nivel de pobreza, tanto más alta es la tasa de homicidio de un municipio.	Desigualdad Socio-económica	Distribución desigual de oportunidades y recursos dentro de una sociedad homogénea.	Ingresos por remesas.	\$ USA
			Personas que trabajan en el sector agropecuario, terciario e informal.	Tasa de trabajadores por sector.
			Hogares con alto ingreso familiar respecto a hogares con bajo ingresos. Decil 8/ Decil 2.	Razón
			Personas desempleadas	Tasa de desempleo
	Pobreza	Nivel de ingresos por debajo del cual no es posible, desde el punto de vista económico, garantizar una dieta mínima adecuada en términos nutricionales, así como en requerimientos no alimentarios esenciales (ONU).	Nivel de pobreza	Ordinal 1:Extrema baja 2:Extrema moderada 3:Extrema Alta 4: Extrema Severa
Cuanto mayor es el grado de aislamiento geográfico de una comunidad, más alta es su tasa de homicidio.	Aislamiento Geográfico	Distancia que existe entre un lugar y una ciudad de referencia, entendida esta última como un centro poblado urbano de importancia.	Kilómetros entre un municipio y su cabecera.	Cantidad de Kilómetros

6. Metodología

Unidades de Análisis.

La unidad de análisis fue el municipio. En total, se contó con los 262 municipios de los 14 departamentos de El Salvador, agrupados en cinco regiones geográficas.

Datos.

El número de homicidios ocurridos durante el año 2002 fue proporcionado por la Unidad de Estadísticas de la Policía Nacional Civil (PNC).

Los datos de población, indicadores económicos y sociales fueron tomados del *IV* Censo de Población y *V* de Vivienda de El Salvador del año 1992, Encuesta de Hogares y Propósitos Múltiples de los años 2001 al 2004 y del Fondo de Inversión Social para el Desarrollo Local (FISDL).

Medidas

La tasa de homicidio (por 10,000 habitantes) del año 2002 fue calculada a partir de los datos de homicidio del mismo año y de la proyección de la población para el 2002.

La estructura industrial de la población fue medida utilizando tasas de trabajadores en los sectores agropecuario, informal y terciario y sus cambios entre los años 2001-2003. Las tasas y los cambios relativos fueron calculadas a partir de los datos de la EHPM de los años 2001-2003.

Desempleo ha sido utilizado como una medida de desventaja socioeconómica al igual que su cambio entre los mismos años. Otra medida utilizada fue la razón de ingreso familiar alto con respecto a ingresos bajos y el cambio en ingresos por remesas. La pobreza fue medida por la clasificación hecha para los municipios de acuerdo al mapa de pobreza 2005.

Como una medida del aislamiento geográfico de las comunidades se usó la distancia en kilómetros que hay desde la cabecera de un departamento hasta los municipios del mismo. La distancia fue tomada de fuentes bibliográficas.

Como características demográficas de la población se utilizó la proporción de jóvenes con respecto a adultos mayores y la razón de habitantes por zona rural con relación a la zona urbana. Para el cálculo de tales índices se tomaron como fuente los datos del Censo de 1992.

Definiciones y estadísticos de resumen para las variables se presentan en la Tabla 6.1.

Tabla 6.1.

Definición de variables y estadísticos de resumen.

Variable	Definición	Media	Desviación Estándar
HOMICIDI	Número de homicidios. 2002	7.725191	18.85864
T_AGROP	Tasa de trabajadores en el sector agropecuario. Año 2001	15.61069	12.88325
T_TERCI	Tasa de trabajadores en el sector terciario. Año 2001	27.34351	19.92044
T_INFOR	Tasa de trabajadores en el sector informal. Año 2001	54.44275	37.80119
T_DESEMP	Tasa de desempleo. Año 2001	3.064885	2.216186
D_AGR	Cambio en la tasa de trabajadores agropecuario. 2001-2003	-2.687023	15.28382
D_TER	Cambio en la tasa de trabajadores terciario. 2001-2003	-1.09542	21.45856
D_INF	Cambio en la tasa de trabajadores informal. 2001-2003	-6.458015	39.94637
D_DES	Cambio en la tasa de desempleo. 2001-2003	-1.10687	3.185821
D_INGPER	Cambio en el Ingreso per cápita mensual. 1992-2004	480.4275	257.4871
D_REME	Cambio en hogares que reciben remesas. 2001-2004	-10.43893	34.76448
RINGFA	Razón por nivel de ingreso familiar alto/bajo. 2001-2004	5.2938	1.5785
POB_EXBA	Pobreza Extrema Baja (Categoría de Referencia). 2001-2004	.3053435	.4614342
POB_EXMO	Pobreza Extrema Moderada. 2001-2004	.3129771	.4645926
POB_EXAL	Pobreza Extrema Alta. 2001-2004	.259542	.4392223
POB_EXSE	Pobreza Extrema Severa. 2001-2004	.1221374	.3280711
JOV_MAY	Proporción de jóvenes respecto a adultos mayores. 1992	2.950382	.2175707
RUR_URBA	Razón por habitantes en zona rural/urbana. 1992	3.652672	4.3149
DIS_CAB	Distancia desde la cabecera hasta un municipio.	26.4580	20.6860

6.1. Especificación y Estimación del Modelo.

Se denotó a Y_i como el vector de regresados, el cual se refiere al evento que representa el número de homicidios registrados por la policía en un municipio determinado ($i = 1, 2, \dots, n$). Se asume que las Y_i están independientemente distribuidas como una variable aleatoria de Poisson con media λ .

La matriz de regresores linealmente independientes se denotó como X_i , las cuales fueron las características de los municipios antes mencionadas. Finalmente, β_k ($k = 0, 1, 2, \dots, 20$) representa el vector de parámetros del modelo a estimar.

Modelando el logaritmo de la media como una función de las variables es la forma normal para contar la variación en tasas de crimen.

El modelo de regresión de Poisson usado en este estudio tuvo el número de homicidios registrados por la policía dentro de un municipio como la variable respuesta. El modelo con los efectos principales adopta la forma siguiente:

$$\begin{aligned} \ln(\text{HOMICIDI}) = & \beta_0 + \beta_1 T_AGROP + \beta_2 T_TERCI + \beta_3 T_INFOR + \beta_4 T_DESEMP + \beta_5 D_AGR + \beta_6 D_TER + \\ & \beta_7 D_INF + \beta_8 D_DES + \beta_9 D_REME + \beta_{10} POB_EXMO + \beta_{11} POB_EXAL + \beta_{12} POB_EXSE + \\ & \beta_{13} RINGFA + \beta_{14} JOV_MAY + \beta_{15} RUR_URBA + \beta_{16} DIS_CAB \end{aligned} \quad (6.1)$$

La Tabla 6.2 muestra los resultados de la aplicación del modelo utilizando regresión de Poisson para los municipios de El Salvador.

Tabla 6.2.

Teoría General del Estrés. Coeficientes de Regresión de Poisson

homicidi	Coef.	Std. Err.	z	P>z	[95% Conf. Interval]	exp
dis_cab	-0.0275	0.0020	-13.67	0	-0.0314 -0.0235	0.9729
rur_urba	-0.0214	0.0066	-3.23	0.001	-0.0344 -0.0084	0.9788
dic_rurb	0.0018	0.0002	7.42	0	0.0014 0.0023	1.0018
pob_exmo	-0.6165	0.0958	-6.44	0	-0.8043 -0.4287	0.5398
pob_exal	-1.2908	0.1064	-12.14	0	-1.4993 -1.0824	0.2750
pob_exse	-1.8295	0.1921	-9.52	0	-2.2061 -1.4530	0.1605
rurb_pem	-0.0534	0.0172	-3.1	0.002	-0.0872 -0.0197	0.9480
t_agrop	0.0191	0.0055	3.47	0.001	0.0083 0.0299	1.0193
t_terci	0.0343	0.0033	10.52	0	0.0279 0.0407	1.0349
t_inform	-0.0155	0.0027	-5.73	0	-0.0209 -0.0102	0.9846
t_desemp	-0.0464	0.0189	-2.46	0.014	-0.0833 -0.0094	0.9547
d_ter	0.0061	0.0022	2.73	0.006	0.0017 0.0105	1.0061
d_inf	-0.0061	0.0024	-2.52	0.012	-0.0108 -0.0013	0.9939
d_des	-0.0398	0.0124	-3.22	0.001	-0.0641 -0.0156	0.9609
rurb_din	0.0009	0.0006	1.62	0.105	-0.0002 0.0020	1.0009
d_reme	0.0103	0.0012	8.63	0	0.0080 0.0127	1.0104
ringfa	0.0063	0.0255	0.25	0.806	-0.0438 0.0563	1.0063
jov_may	0.1054	0.0149	7.06	0	0.0762 0.1347	1.1112
_cons	2.3057	0.1788	12.89	0	1.9552 2.6562	10.0313

Number of obs = 262
 LR chi2(18) = 2445.88
 Prob > chi2 = 0.0000
 Log likelihood = -1599.9237
 Pseudo R2 = 0.4332

Goodness-of-fit chi2 = 2539.091
 Prob > chi2(243) = 0.0000

Uno de los supuestos de la regresión de Poisson que es violado más frecuentemente es el de la igualdad de la media y la varianza. La violación de este supuesto trae como consecuencia déficit o exceso de dispersión; sin embargo, es más común que los datos estén con exceso de dispersión. Para comprobar este supuesto es útil observar el gráfico de residuales contra los valores ajustados así como también es conveniente realizar alguna prueba estadística bajo la hipótesis de igual dispersión.

6.2. *Chequeo informal usando residuales.*

Ningún análisis puede ser considerado completo sin inspeccionar los residuales graficados contra alguna función de los valores ajustados.

Para modelos Normales podemos expresar la variable dependiente en la forma

$$y = \hat{\mu} + (y - \hat{\mu}),$$

i.e. dato = valor ajustado + residual. Los residuales pueden ser usados para explorar la adecuación del ajuste de un modelo, en cuanto a la elección de la función de varianza, función de enlace y términos en el predictor lineal. Para modelos lineales generalizados necesitamos una definición extendida de residuales, aplicable a todas las distribuciones que pudieran reemplazar la Normal. Se han definido tres formas de residuales generalizados: residual de Pearson, Anscombe y Deviance. (McCullagh y Nelder, 1989). En tales definiciones se utiliza la forma teórica, suponiendo μ en lugar de $\hat{\mu}$.

Dichos residuales se definen como:

$$r_P = \frac{y - \mu}{\sqrt{V(\mu)}}, \quad (6.1)$$

$$r_A = \frac{3/2(y^{2/3} - \mu^{2/3})}{\mu^{1/6}} \quad y \quad (6.2)$$

$$r_D = \text{sign}(y - \mu) \{2(y \log(y/\mu) - y + \mu)\}^{1/2} \quad (6.3)$$

donde

r_P : Residual de Pearson


r_A = Residual de Anscombe y

r_D : Residual de la Deviance

Estos dos últimos son definiciones propias para la distribución de Poisson. En nuestro caso utilizaremos la definición del residual de la deviance.

Los residuales de la deviance son recomendados graficarlos ya sea contra $x'\beta$ o contra los valores ajustados. El patrón nulo de este gráfico es una distribución de residuales para $\hat{\mu}$ variando con media cero y rango constante. Desviaciones sistemáticas típicas son: (i) La apariencia de una curvatura en la media y (ii) un cambio sistemático de rango con valores ajustados.

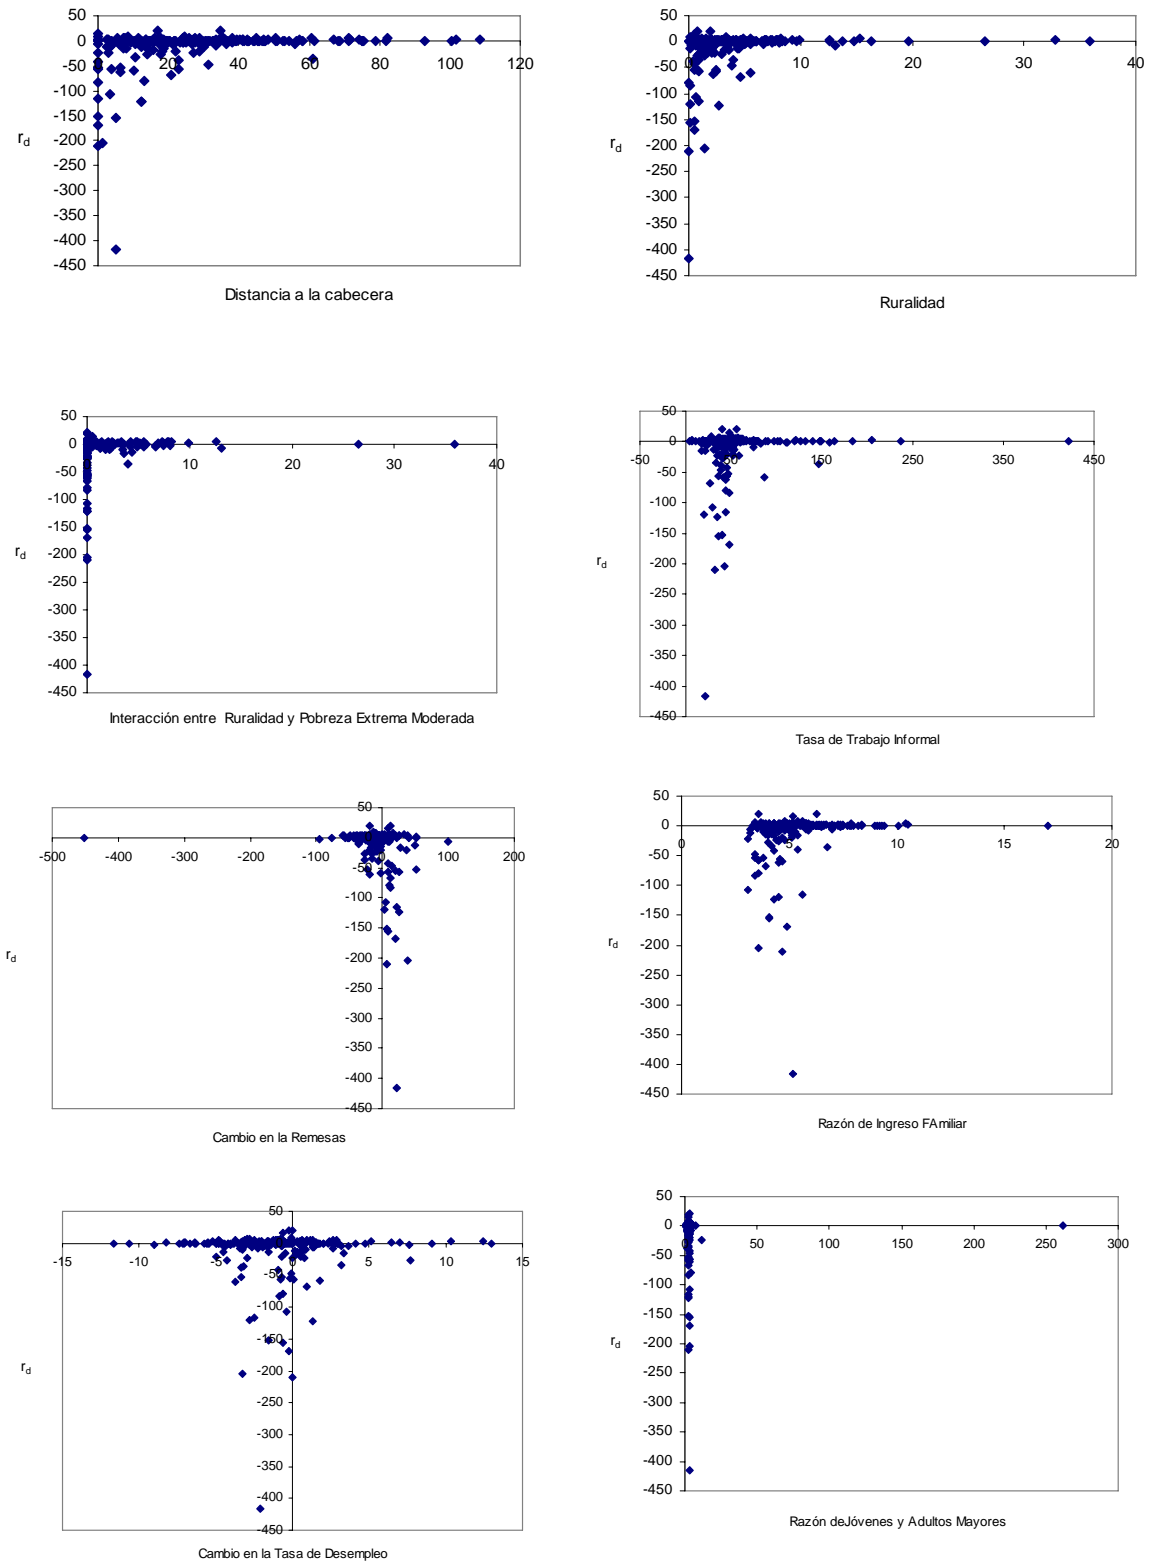
La Figura 6.1 muestra la tendencia que siguen los datos al graficar los residuales contra los valores predichos. Se observa que no hay un rango de variación constante alrededor de la media y que los datos tienden a dispersarse a medida se alejan del eje y .

Figura 6.1. Gráficas de residuales y valores predichos. Regresión de Poisson

Un segundo gráfico informal para el chequeo es graficar los residuales contra una variable explicativa en el predictor lineal. El patrón nulo es el mismo. De nuevo, la apariencia de una tendencia sistemática pudiera ser la elección equivocada de la función de enlace o la escala de la variable explicativa, o señalar que un término cuadrático debe ser introducido.

Para evaluar si las variables entran al modelo en forma lineal, como se ha supuesto, se grafican los residuales contra cada variable para examinar si existe alguna tendencia no lineal entre ellas. (Figura 6.2)

Los gráficos mostrados no presentan algún tipo de relación cuadrática o cúbica por ejemplo entre las variables regresoras y la variable regresada. Lo que si es notable es que los errores no se distribuyen con varianza constante y que existen algunos puntos extremos.

Figura 6.2. Gráficos de residuales contra variables regresoras. Regresión de Poisson.

6.3. Pruebas de Exceso de Dispersión

De la Tabla 6.1, podemos observar que los datos están con exceso de dispersión antes de la inclusión de regresores, con razón varianza – media de $355.648 / 7.7251 = 46.04$. La única pregunta es si este exceso de dispersión desaparece sobre la inclusión de regresores.

Consideremos primero pruebas de Poisson contra Negbin I a un nivel de significancia al 1%. Dado los resultados en la Tabla 6.2 y 6.3 la prueba estadística LR (Likelihood Ratio) es $2(1599.9237 - 677.8210) = 922.1026$, la cual excede el 1% del valor crítico de $\chi^2_{0.98}(1) = 5.41$. El estadístico de la prueba de Wald de la Tabla 6.3 es $1.2731 / 0.1394 = 9.13$, el cual excede el valor crítico del 1% de $z_{.99} = 2.33$. Por lo tanto ambas pruebas rechazan fuertemente la hipótesis nula de Poisson, indicando la presencia de exceso de dispersión. Claramente algún control es necesario para exceso de dispersión.

Tabla 6.3.

Teoría General del Estrés. Coeficientes de Regresión Binomial Negativa

homicidi	Coef.	Std. Err.	z	P>z	[95% Conf.	Interval]	exp
dis_cab	-0.0169	0.0057	-2.96	0.0030	-0.0281	-0.0057	0.9832
rur_urba	-0.0215	0.0220	-0.98	0.3280	-0.0646	0.0216	0.9787
dic_rurb	0.0012	0.0008	1.56	0.1180	-0.0003	0.0027	1.0012
pob_exmo	-0.8459	0.3007	-2.81	0.0050	-1.4353	-0.2565	0.4292
pob_exal	-1.4347	0.2910	-4.93	0.0000	-2.0051	-0.8644	0.2382
pob_exse	-1.9582	0.4085	-4.79	0.0000	-2.7588	-1.1577	0.1411
rurb_pem	-0.0181	0.0489	-0.37	0.7120	-0.1140	0.0778	0.9821
t_agrop	0.0448	0.0194	2.31	0.0210	0.0068	0.0827	1.0458
t_terci	0.0344	0.0120	2.88	0.0040	0.0110	0.0579	1.0350
t_inform	-0.0254	0.0095	-2.67	0.0080	-0.0441	-0.0068	0.9749
t_desemp	-0.0784	0.0598	-1.31	0.1900	-0.1957	0.0389	0.9246
d_ter	0.0024	0.0079	0.3	0.7610	-0.0130	0.0178	1.0024
d_inf	-0.0076	0.0065	-1.17	0.2440	-0.0204	0.0052	0.9924
d_des	-0.0411	0.0380	-1.08	0.2790	-0.1157	0.0334	0.9597
rurb_din	0.0006	0.0009	0.61	0.5440	-0.0012	0.0024	1.0006
d_reme	0.0109	0.0041	2.69	0.0070	0.0030	0.0189	1.0110
ringfa	0.0208	0.0764	0.27	0.7850	-0.1290	0.1707	1.0211
jov_may	0.3059	0.1317	2.32	0.0200	0.0477	0.5641	1.3578
_cons	1.7920	0.7346	2.44	0.0150	0.3522	3.2319	6.0016
/lnalpha	0.2415	0.1095			0.0269	0.4561	1.2731
alpha	1.2731	0.1394			1.0272	1.5778	

Number of obs = 262
 LR chi2(18) = 154.65
 Prob > chi2 = 0.0000
 Log likelihood = -677.82107
 Pseudo R2 = 0.1024

Likelihood-ratio test of alpha=0: chibar2(01) = 1844.21
 Prob>=chibar2 = 0.000

6.4. Prueba de Breusch-Pagan-Godfrey para Homocedasticidad en los errores.

La prueba de Breusch-Pagan-Godfrey (BPG) supone una hipótesis alternativa en el cual la varianza de los errores de la regresión es proporcional a una combinación lineal de regresores.

El algoritmo para hacer esta prueba es el siguiente:

1. Estimar el modelo y obtener los residuales
2. Obtener la estimación de Máxima Verosimilitud de varianza $\hat{\sigma}^2 = \frac{SSE}{n}$, donde SSE es la suma de los errores cuadrados y n el número de observaciones.
3. Construir $p_i = \frac{\hat{\mu}_i^2}{\hat{\sigma}_i^2}$, donde $\hat{\mu}_i^2 = (y_i - \hat{y}_i)^2$
4. Estimar la regresión con p_i como variable dependiente.
5. Obtener el SSR para la regresión 4 de arriba y definir $\Theta = \frac{1}{2}(SSR) \sim \chi_{m-1}^2$, donde SSR es la suma de cuadrados de la regresión.
6. Probar la hipótesis nula de homocedasticidad usando una variable aleatoria distribuida como Chi-cuadrado

Los resultados de esta prueba se presentan a continuación:

H_0 : Los errores son homocedásticos.

H_a : Los errores no son homocedásticos.

Tabla 6.4.

Resultados de la prueba Breusch-Pagan-Godfrey

Suma errores cuadrados (SSE)	Varianza ($\sigma^2 = SSE/262$)	Suma de Cuadrados de la regresión $\sum_{i=1}^{262} (\hat{p}_i - \bar{p})^2$	$\Theta = 1/2(SSR)$
65690.37	250.73	3186.3729	1593.1865

$$\Theta > \chi_{0.05, 21-1}^2$$

1593.1865 > 10.85 Por lo tanto, no se acepta la hipótesis nula de homocedasticidad.

Dado que los errores no se distribuyen con varianza constante, posiblemente debido al exceso de dispersión, se hace necesario establecer algún tipo de control para corregir este problema. Una solución sería modelar la varianza como una función distinta a la media, que es la que asume la distribución de Poisson por el supuesto de igualdad entre la media y la varianza. Entre varias alternativas, podemos usar la función de varianza definida en la sección anterior, es decir,

$$\hat{\sigma}^2 = \frac{SSE}{n} \tag{6.4}$$

Los parámetros estimados se calcularán ahora usando la función de varianza definida en (6.4). De este modo, al hacer la regresión de Poisson utilizaremos un factor de corrección para exceso de dispersión; esto lo haremos dividiendo cada una de las variables independientes y la dependiente entre la desviación estándar de (6.4).

Los resultados de esta regresión se presentan en la Tabla 6.5.

Tabla 6.5.

Teoría General del Estrés. Coeficientes de Regresión Poisson con factor de corrección.


homicidi	Coef.	Std. Err.	z	P>z	[95% Conf. Interval]	exp
dis_cab_d	-0.4349	0.1266	-3.44	0.0010	-0.6829 -0.1868	0.6473
rur_urba_d	-0.3392	0.4180	-0.81	0.4170	-1.1585 0.4801	0.7123
dic_rurb_d	0.0292	0.0157	1.86	0.0620	-0.0015 0.0600	1.0297
pob_exmo_d	-9.7590	6.0338	-1.62	0.1060	-21.5851 2.0671	0.0001
pob_exal_d	-20.4337	6.6990	-3.05	0.0020	-33.5635 -7.3039	0.0000
pob_exse_d	-28.9614	12.1009	-2.39	0.0170	-52.6787 -5.2442	0.0000
rurb_pem_d	-0.8455	1.0847	-0.78	0.4360	-2.9716 1.2805	0.4293
t_agrop_d	0.3029	0.3470	0.87	0.3830	-0.3772 0.9830	1.3538
t_terci_d	0.5437	0.2057	2.64	0.0080	0.1406 0.9469	1.7224
t_inform_d	-0.2461	0.1709	-1.44	0.1500	-0.5812 0.0889	0.7818
t_desemp_d	-0.7340	1.1879	-0.62	0.5370	-3.0622 1.5942	0.4800
d_ter_d	0.0970	0.1412	0.69	0.4920	-0.1798 0.3737	1.1018
d_inf_d	-0.0964	0.1524	-0.63	0.5270	-0.3952 0.2023	0.9081
d_des_d	-0.6308	0.7790	-0.81	0.4180	-2.1576 0.8961	0.5322
rurb_din_d	0.0144	0.0354	0.41	0.6840	-0.0550 0.0838	1.0145
d_reme_d	0.1638	0.0755	2.17	0.0300	0.0158 0.3118	1.1780
ringfa_d	0.0991	1.6074	0.06	0.9510	-3.0513 3.2495	1.1042
jov_may_d	1.6688	0.9404	1.77	0.0760	-0.1744 3.5120	5.3058
_cons	-0.4562	0.7116	-0.64	0.5210	-1.8509 0.9385	0.6337

Number of obs = 262
 LR chi2(18) = 154.51
 Prob > chi2 = 0.0000
 Log likelihood = -196.52271
 Pseudo R2 = 0.2822

Goodness-of-fit chi2 = 160.3974
 Prob > chi2(243) = 1.0000

Al utilizar el factor de corrección para el exceso de dispersión esperamos que se haya resuelto en cierta medida dicho problema. Para ver si esto sucede graficamos los valores residuales contra los predichos por el modelo actual. (Figura 6.3)

Figura 6.3. Gráfico de residuales y valores predichos.
Regresión de Poisson con factor de corrección



Para que tengamos una mejor idea de la distribución de los residuales contra los valores ajustados, dejaremos fuera los valores extremos. Estos valores corresponden a los municipios de Santa Ana, San Salvador, Soyapango y San Miguel. Al hacer esto (Figura 6.4) observamos como no existe una tendencia bien definida entre los datos y que éstos ya no están tan dispersos como en la Figura 6.1.

Nuevamente graficamos los residuales contra los variables independientes para ver si estos presentan alguna relación no lineal (Figura 6.5). A simple vista pareciera que tampoco hay evidencias de relaciones no cuadráticas o cúbicas entre las variables.

Figura 6.4. Gráfico de residuales y valores predichos sin valores extremos.
Regresión de Poisson con factor de corrección.


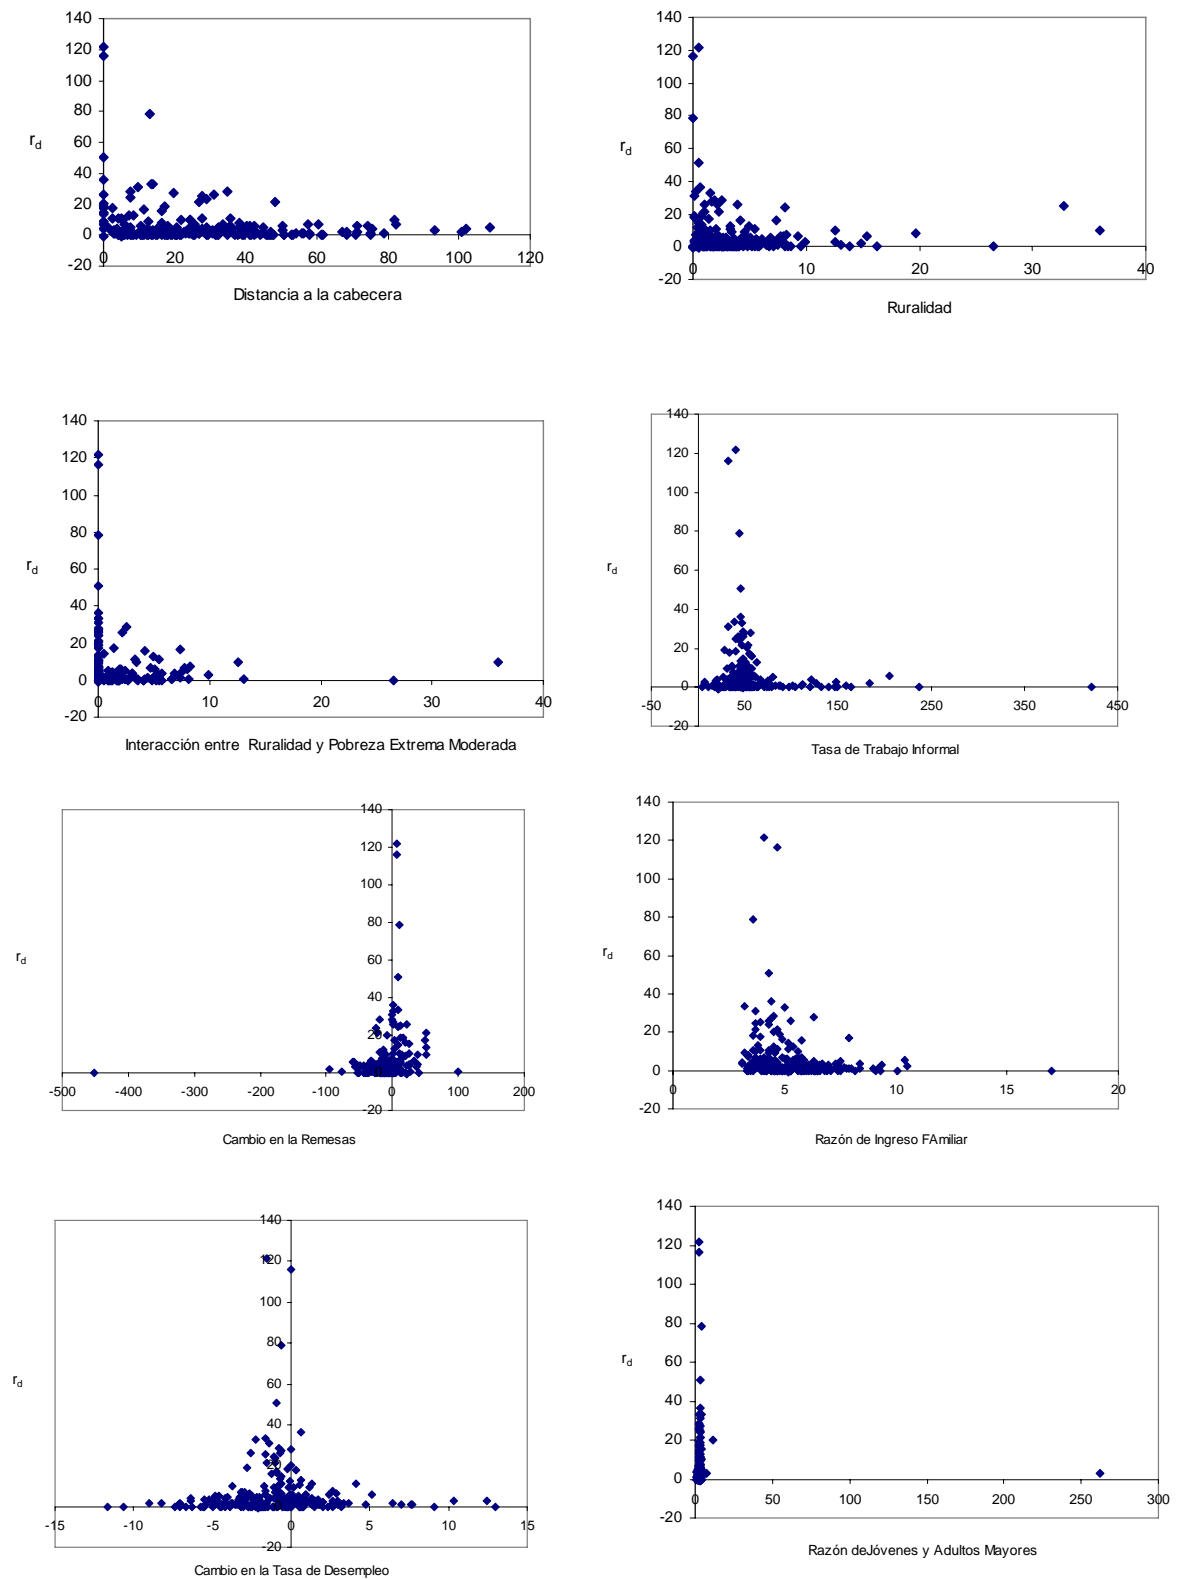


Figura 6.5. Gráficos de residuales contra variables regresoras. Regresión de Poisson con factor de corrección.



6.5. Prueba de significación de los coeficientes de regresión.

Estamos interesados en realizar pruebas de hipótesis que nos permiten decir si nuestras variables explicativas tienen un efecto sobre la variable respuesta; esto es,

$$H_0 : \beta = 0$$

$$H_A : \beta \neq 0$$

Las estimaciones de máxima verosimilitud se distribuyen aproximadamente normales para muestras grandes, lo cual, significa que para muestras “grandes”

$$\hat{\beta} \approx N(\beta, \sigma_p^2)$$

Así que podemos usar esto para construir intervalos de confianza para los parámetros y para pruebas de hipótesis.

Para un intervalo de confianza estimado al $(1-\alpha)100\%$ de β :

$$\hat{\beta} \pm z_{\alpha/2} ASE$$

donde ASE son los errores estándar de $\hat{\beta}$.

De este modo podemos realizar las pruebas de hipótesis y construir los intervalos de confianza para nuestros parámetros estimados.

Frecuentemente para pruebas de hipótesis también se utiliza el valor de la probabilidad (p -valor), el cual es comparado con el nivel de significancia y, si este es más pequeño, entonces el resultado es significativo. Esto es, si la hipótesis nula es rechazada a un nivel de $\alpha = 0.05$, el p valor reportado debería ser menor que 0.05.

De los datos de la Tabla 6.5 podemos obtener los p -valores y a partir de allí evaluar la significancia de las variables regresoras.

Bajo la hipótesis nula $H_0 = \beta_i = 0$ contra $H_A = \beta_i \neq 0$, a un nivel de significancia del 5% no resultaron ser significativas las siguientes variables: indicador de ruralidad, pobreza extrema moderada, interacción entre ruralidad y pobreza extrema moderada, tasa de trabajadores agropecuario, tasa de trabajo informal, tasa de desempleo, tasa de cambio en los sectores de trabajo y en desempleo, interacción entre ruralidad y cambio en empleo informal y el indicador de disparidad de ingreso familiar.

6.6. Bondad de Ajuste

El proceso de ajustar un modelo a los datos podría ser considerado como una forma de reemplazar un conjunto de valores y por un conjunto de valores ajustados $\hat{\mu}$ derivados de un modelo suponiendo normalmente un número relativamente pequeño de parámetros. En general las μ s no igualarán las y s exactamente, y la pregunta entonces surge que tan diferentes son, porque mientras una diferencia pequeña podría ser tolerable una gran diferencia no lo es. Medidas de discrepancia o bondad de ajuste pudieran ser encontradas en varias formas, pero estaremos primeramente relacionados con aquella formada de el logaritmo de una razón de verosimilitudes, a ser llamada la deviance.

La forma de la deviance para la distribución de Poisson está dada por

$$D(y; \hat{\mu}) = 2 \sum \left\{ y \log(y / \hat{\mu}) - (y - \hat{\mu}) \right\}$$

donde $D(y; \hat{\mu})$ es conocida como la deviance para el modelo actual y es una función de los datos solamente. El segundo término en la expresión es a menudo omitido por brevedad. Dado que el modelo ajustado incluye un término constante, o intercepto, la suma sobre las unidades del segundo término son idénticamente cero, justificando su omisión. (Nelder y Wedderburn, 1972).

Después de ajustar una variedad de modelos de Poisson para los datos de homicidios y corregir un poco el problema de exceso de dispersión, el modelo que presentamos tiene una deviance de 160.3974 y según el R^2 ajusta un 28% de los datos. (Tabla 6.5).

7. Discusión y Análisis de Resultados

Durante el año 2002, la Policía Nacional Civil reportó un total de 2,024 casos de homicidios, lo que representa una tasa de 24 homicidios por cada cien mil habitantes. Comparada con los dos años anteriores (2000 y 2001), en las cuales se tuvieron tasas de homicidios de 34.5 y 31.1 por cien mil habitantes respectivamente, se reflejó un descenso en este tipo de delito, sin embargo, éste recuperó su tendencia al alza en los años siguientes, principalmente en el 2,004 cuando fueron asesinadas 2,767 personas, lo que da una tasa de 40.9⁸ homicidios por cien mil habitantes. Dicha cifra ha sido la más alta registrada en los últimos nueve años.

Si se encuentra un conjunto de variables que puedan explicar el número de homicidios con una precisión razonable y cuya medición se pueda obtener de registros, o de una manera fácil. Esto favorecería la predicción de homicidios y sería de utilidad para tratar de enfocarnos en aquellos puntos en los cuales se deben reforzar programas sociales y económicos a modo que se puedan bajar los índices delincuenciales. Sin embargo, este fenómeno es complejo, pero en la medida de lo posible, hemos tratado de estudiar lo que afecta el número de homicidios en El Salvador, desde el marco de la Teoría del Estrés y del enfoque basado en cambios económicos y sociales.

En el intento de lograr este objetivo y después de haber seleccionado las variables que miden pobreza, desventaja económica, cambios estructurales, aislamiento geográfico y composición demográfica; y luego de haber ensayado una gran cantidad de modelos de regresión, encontramos que nuestro modelo final explica en un 28% (Pseudo R²) la variación del número de homicidios en El Salvador.

Cambios en la estructura industrial

Se había supuesto que cambios económicos podrían disminuir la habilidad de las comunidades para desarrollar mecanismos de control social formal e informal, lo cual podría incrementar el

⁸La población estimada para dicho año fue de 6, 757,407.704.

crimen. (Carcach, 2000a) y que además, cambios en la estructura económica aumentan el número de homicidios en una región determinada. Los resultados de la regresión de Poisson muestran que en efecto, los cambios económicos contribuyen a la variación en el número de homicidios.

La tasa de trabajadores en el sector terciario es una variable que afecta positivamente el número de homicidios ya que industrias terciarias, tal como comercio al por menor, servicios y finanzas, bienes raíces pudieran ser asociadas con altas tasas de criminalidad debido a que esas industrias necesitan clientes para visitar lugares específicos para comprar bienes y servicios y tales lugares generalmente se concentran en distritos de negocios o en centros comerciales creando oportunidades para el crimen en varias formas. (Carcach, 2000a). Nuestros resultados muestran que un aumento del uno por ciento en la tasa de trabajadores en el sector terciario supone un aumento del 54% en el número de homicidios.

Condiciones económicas.

Condiciones económicas afectan el nivel de homogeneidad social y económica de una región así como las condiciones actuales de la economía regional. Disparidades entre ingresos en una comunidad genera desventaja entre los residentes de estas, lo cual podría conducir a generar estrés por no alcanzar a satisfacer necesidades básicas y no poder garantizar bienestar a sus familias. Lo anterior podría generar que tales individuos se valgan de medios ilegales para poder obtener ingresos que lo lleven a satisfacer estas necesidades.

Los indicadores utilizados para medir condiciones económicas (cambios en ingresos por remesas y el índice usado para medir la relación de ingreso familiar) muestran que aumentos en dichas variables hace que el número esperado de homicidios aumente. Sin embargo el indicador de ingreso familiar no resultó ser significativo al nivel del 5%. El efecto en remesas refleja el hecho que a medida un municipio tiene un ingreso mayor por dinero proveniente del exterior, más homicidios sucederán. A medida este factor de cambio aumenta en una unidad porcentual, el número de homicidios lo hará en un 16%. Una explicación a este hecho es que las disparidades entre ingresos generan desventajas entre individuos, lo cual lleva a los más desaventajados a proveerse de los mecanismos necesarios para poder solventar dicha

disparidad; el problema surge cuando esos mecanismos no están dentro de un marco legal y esto hace que áreas con grandes concentraciones de personas desaventajadas se vean involucradas en hechos delictivos que terminan en homicidios.

Acceso a servicios

Algunos autores suponen que la pobreza y la falta de acceso a servicios básicos hacen que una comunidad sea más vulnerable a hechos delictivos que terminen en homicidios. Sin embargo, en este caso la pobreza medida a partir del nivel de pobreza no es un factor asociado positivamente al alto número de homicidios en los municipios.

Municipios clasificados con pobreza extrema alta y severa son aquellos en los que no es frecuente que se cometan homicidios. ($e^{-20.4337} = 1.34\text{E-}09$ y $e^{-28.9614} = 2.6437\text{E-}13$ respectivamente). Estos resultados nos estarían indicando que a medida un municipio es más pobre, menos homicidios ocurren.

Demográficos

Se ha supuesto que cambios en la estructura demográfica de la población suelen provocar cambios en las tasas de homicidios. La razón de jóvenes respecto a los adultos mayores que viven en una misma área geográfica aumenta el número de homicidios. Un aumento del 1% en dicha razón hace que los homicidios aumenten en un 167%, lo cual nos estaría indicando que mientras más gente entre los 15 y 24 años hay con respecto a adultos que exceden de 60 años, mayor es el nivel de criminalidad que existe.

Aunque el índice de ruralidad no resultó ser significativo en el modelo corregido por exceso de dispersión, vale la pena mencionar que es un factor que hace que el número de homicidios disminuya grandemente. Por cada aumento porcentual en el índice de ruralidad hay un decaimiento de un 34% en el número de homicidios; dicho resultado nos está indicando que si tenemos más personas viviendo en las zonas rurales en relación a los que viven en la ciudad, menos homicidios se cometerán.

Aislamiento Geográfico

La distancia que hay desde un municipio hasta su cabecera departamental hace que el número de homicidios disminuya en un 43 por ciento por cada kilómetro que este se aleje de la cabecera, entendiéndose que mientras más distancia exista entre ellos menor será el número de homicidios que allí se cometerán. Este resultado nos está indicando que el fenómeno en estudio es más característico de áreas más modernas o urbanas.

8. Conclusiones y Recomendaciones

Los resultados indican que en los municipios de El Salvador, la tasa de homicidio es relacionada con factores tales como pobreza, aislamiento geográfico, composición demográfica del municipio y condiciones económicas.

La pobreza medida a través del indicador de pobreza que clasifica a los municipios en un determinado nivel no ejerce un efecto positivo sobre el aumento de homicidios, es decir que nuestra hipótesis de que ésta es un factor que eleva el número de homicidios no es aceptada, ya que los resultados indican que al contrario, esta hace que el número esperado de homicidios disminuya a medida se aumente en dicha escala.

Los resultados de la variable que tomamos para medir el aislamiento geográfico nos hace pensar que el elevado número de homicidios es propio de áreas más urbanas que de áreas rurales, esto debido a que había una tendencia a disminuir el número de homicidios a medida los municipios se encuentran más distantes de sus respectivas cabeceras, tomando en cuenta que la cabecera de un municipio es el centro más urbano del departamento.

La tasa de trabajo en el sector terciario tiene un efecto significativo y proporcional sobre el número de homicidios. Esa relación existente nos lleva a aceptar la hipótesis que cambios en la estructura económica afectan en el mismo sentido el número de homicidios en El Salvador.

Cambios en la estructura demográfica de la población es relacionada con aumentos en el número de homicidios. El efecto que indicador de residentes jóvenes/adultos mayores nos lleva a concluir que a medida hay más personas entre 15 y 24 años con relación a adultos mayores (personas con 60 años y más), más homicidios sucederán. Significa entonces que municipios con más jóvenes están propensos a tener más delitos que terminan en homicidios debido a que hay más competencia por espacios físicos, por riñas entre pandillas, ventas y uso de drogas, etc. que aquellos municipios en donde la proporción de adultos es mayor.

El resultado obtenido en el indicador de cambio en remesas que utilizamos para medir un poco la desigualdad económica nos hace aceptar la hipótesis que a medida hay más desventaja económica, hay más hechos violentos, y esto de acuerdo a la Teoría del Estrés se debe a que la

persona que no tiene los mismos beneficios que otros se sienten más frustrada, enojada y tensionada y que puede responder ante cualquier situación con una actitud violenta.

Nuestros resultados deben ser considerados solamente como un indicio acerca de cuáles son los factores que influyen en distribución geográfica de la violencia en El Salvador, medida a través de los homicidios. Investigaciones más extensas deberían considerar factores sociales que hoy en día hacen que el número de homicidios sea alarmante, por ejemplo, el fenómeno de las pandillas y todo lo que ella involucra.

Lograr obtener fuentes confiables de información así como acceso a grandes bases de datos ayudaría grandemente a poder extender investigaciones en donde se estudien sucesos regionales en los que no se debe generalizar, por lo que es necesario contar con observaciones individuales para cada unidad de análisis, en nuestro caso, el municipio.

9. Bibliografía

Abraira, V. y Pérez de Vargas A. (1996). Métodos Multivariantes en Bioestadística. Ed. Centro de Estudios Ramón Areces. www.hrc.es/bioest/estadis_21.html. Consulta 22 de Abril de 2004.

Agnew, Robert. (1999). A General Strain Theory of Community Differences in Crime Rates. Vol. 36 No 2, Mayo de 1999. *Journal of Research in Crime and Delinquency*. California. Estados Unidos de América.

Cameron, A. Colin y Trivedi, Pravin K. (1998). Regression Analysis of Count Data. Cambridge University Press. Reino Unido.

Carcach, Carlos. Regional Variation in Crime. (2001). Australian Institute of Criminology. Canberra.

Carcach, C. 2000a. “Regional Development and Crime”. *Trends and Issues in Crime and Criminal Justice, No 160*. Australian Institute of Criminology. Canberra.

Carcach, C. 2000b. “Size, Accessibility and Crime in Regional Australia”. *Trends and Issues in Crime and Criminal Justice, No 175*. Australian Institute of Criminology. Canberra.

Carcach, C. 2000c. “Economic Transformation y Regional Crime”. *Trends and Issues in Crime and Criminal Justice, No 209*. Australian Institute of Criminology. Canberra.

Everitt, B.S. 2002, “The Cambridge Dictionary of Statistics”. Cambridge University Press. Reino Unido.

McCullag, Peter y Nelder, John A. (1989). Generalized Linear Models. 2a edición. *Monographs on Statistics and Applied Probability 37*. Estados Unidos.

Giles, David E. A (2002). On the Futility of Testing the Error Term Assumptions in Spurious Regressions. Universidad de Victoria, B. C. Canadá.

Programa de las Naciones Unidas para el Desarrollo (PNUD). (2002). Indicadores sobre Violencia en El Salvador. 1ª edición. Autor. San Salvador. El Salvador.

Real Academia Española. (2006). Diccionario de la Lengua Española. Vigésima Segunda Edición. www.rae.es. Consulta: 29 de mayo de 2006.

Weatherburn, Don y Lind, Bronwyn. (2001). *Delinquent – Prone Communities*. Cambridge University Press. Reino Unido.