



Universidad de San Carlos de Guatemala  
Facultad de Ingeniería  
Escuela de Estudios de Postgrado  
Maestría en Estadística Aplicada

**ANÁLISIS GEOESTADÍSTICO DE AUTOCORRELACIÓN ESPACIAL INCREMENTAL Y  
PUNTOS DE CALOR ENTRE LA UBICACIÓN DE LAS CÁMARAS EN LA VÍA PÚBLICA Y LA  
REDUCCIÓN DE ACTOS DELICTIVOS**

**Ing. Carlos Rafael Maldonado Estrada**

Asesorado por el Mtro. Ing. Byron Emmanuel Bobadilla Chin

Guatemala, enero de 2022



UNIVERSIDAD DE SAN CARLOS DE GUATEMALA



FACULTAD DE INGENIERÍA

**ANÁLISIS GEOESTADÍSTICO DE AUTOCORRELACIÓN ESPACIAL INCREMENTAL Y  
PUNTOS DE CALOR ENTRE LA UBICACIÓN DE LAS CÁMARAS EN LA VÍA PÚBLICA Y  
LA REDUCCIÓN DE ACTOS DELICTIVOS**

TRABAJO DE GRADUACIÓN

PRESENTADO A LA JUNTA DIRECTIVA DE LA  
FACULTAD DE INGENIERÍA  
POR

**ING. CARLOS RAFAEL MALDONADO ESTRADA**  
ASESORADO POR EL MTRO. ING. BYRON EMMANUEL BOBADILLA CHIN

AL CONFERÍRSELE EL TÍTULO DE

**MAESTRO EN ESTADÍSTICA APLICADA**

GUATEMALA, ENERO DE 2022



UNIVERSIDAD DE SAN CARLOS DE GUATEMALA  
FACULTAD DE INGENIERÍA



**NÓMINA DE JUNTA DIRECTIVA**

DECANA	Inga. Aurelia Anabela Cordova Estrada
VOCAL I	Ing. José Francisco Gómez Rivera
VOCAL II	Ing. Mario Renato Escobedo Martínez
VOCAL III	Ing. José Milton de León Bran
VOCAL IV	Br. Kevin Armando Cruz Lorente
VOCAL V	Br. Fernando José Paz González
SECRETARIO	Ing. Hugo Humberto Rivera Pérez.

**TRIBUNAL QUE PRACTICÓ EL EXAMEN GENERAL PRIVADO**

DECANA	Inga. Aurelia Anabela Cordova Estrada
EXAMINADOR	Mtro. Ing. Edgar Darío Alvarez Cotí
EXAMINADOR	Mtro. Ing. Edwin Adalberto Bracamonte Orozco
EXAMINADOR	Mtro. Lic. Adonai Navas García
SECRETARIO	Ing. Hugo Humberto Rivera Pérez



## **HONORABLE TRIBUNAL EXAMINADOR**

En cumplimiento con los preceptos que establece la ley de la Universidad de San Carlos de Guatemala, presento a su consideración mi trabajo de graduación titulado:

### **ANÁLISIS GEOESTADÍSTICO DE AUTOCORRELACIÓN ESPACIAL INCREMENTAL Y PUNTOS DE CALOR ENTRE LA UBICACIÓN DE LAS CÁMARAS EN LA VÍA PÚBLICA Y LA REDUCCIÓN DE ACTOS DELICTIVOS**

Tema que me fuera asignado por la Dirección de Escuela de Estudios de Postgrado con fecha 21 de enero de 2020.

**Ing. Carlos Rafael Maldonado Estrada**







Decanato  
Facultad de Ingeniería  
24189101- 24189102  
secretariadecanato@ingenieria.usac.edu.gt

LNG.DECANATO.OI.073.2022

La Decana de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer la aprobación por parte del Director de la Escuela de Estudios de Posgrado, al Trabajo de Graduación titulado: **ANÁLISIS GEOESTADÍSTICO DE AUTOCORRELACIÓN ESPACIAL INCREMENTAL Y PUNTOS DE CALOR ENTRE LA UBICACIÓN DE LAS CÁMARAS EN LA VÍA PÚBLICA Y LA REDUCCIÓN DE ACTOS DELICTIVOS**, presentado por: **Carlos Rafael Maldonado Estrada**, que pertenece al programa de Maestría en artes en Estadística aplicada después de haber culminado las revisiones previas bajo la responsabilidad de las instancias correspondientes, autoriza la impresión del mismo.

IMPRÍMASE:

  
Inga. Aurelia Anabela Cordova Estrada



Decana

Guatemala, enero de 2022

AACE/gaoc





**Guatemala, enero de 2022**

LNG.EEP.OI.073.2022

En mi calidad de Director de la Escuela de Estudios de Postgrado de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer el dictamen del asesor, verificar la aprobación del Coordinador de Maestría y la aprobación del Área de Lingüística al trabajo de graduación titulado:

**“ANÁLISIS GEOESTADÍSTICO DE AUTOCORRELACIÓN ESPACIAL INCREMENTAL Y PUNTOS DE CALOR ENTRE LA UBICACIÓN DE LAS CÁMARAS EN LA VÍA PÚBLICA Y LA REDUCCIÓN DE ACTOS DELICTIVOS”**

presentado por **Carlos Rafael Maldonado Estrada** correspondiente al programa de **Maestría en artes en Estadística aplicada** ; apruebo y autorizo el mismo.

Atentamente,

*“Id y Enseñad a Todos”*

  
**Mtro. Ing. Edgar Dario Álvarez Cotí**  
Director



**Escuela de Estudios de Postgrado  
Facultad de Ingeniería**





Guatemala 9 de junio 2021.

**M.A. Edgar Darío Álvarez Cotí**  
**Director**  
**Escuela de Estudios de Postgrado**  
**Presente**

**M.A. Ingeniero Álvarez Cotí:**

Por este medio informo que he revisado y aprobado el Informe Final del trabajo de graduación titulado **“ANÁLISIS GEOESTADÍSTICO DE AUTOCORRELACIÓN ESPACIAL INCREMENTAL Y PUNTOS DE CALOR ENTRE LA UBICACIÓN DE LAS CÁMARAS EN LA VÍA PÚBLICA Y LA REDUCCIÓN DE ACTOS DELICTIVOS”** del estudiante **Carlos Rafael Maldonado Estrada** quien se identifica con número de carné **201990479** del programa de Maestría en Estadística Aplicada.

Con base en la evaluación realizada hago constar que he evaluado la calidad, validez, pertinencia y coherencia de los resultados obtenidos en el trabajo presentado y según lo establecido en el *Normativo de Tesis y Trabajos de Graduación aprobado por Junta Directiva de la Facultad de Ingeniería Punto Sexto inciso 6.10 del Acta 04-2014 de sesión celebrada el 04 de febrero de 2014*. Por lo cual el trabajo evaluado cuenta con mi aprobación.

Agradeciendo su atención y deseándole éxitos en sus actividades profesionales me suscribo.

Atentamente,

**MSc. Ing. Edwin Adalberto Bracamonte Orozco**  
**Coordinador**  
**Maestría en Estadística Aplicada**  
**Escuela de Estudios de Postgrado**



Guatemala, 28 de agosto de 2020.

Mtro. Edgar Darío Álvarez Cotí  
Director de la Escuela de Estudios de Postgrado. FIUSAC.  
Presente.

Estimado Maestro Álvarez Cotí:

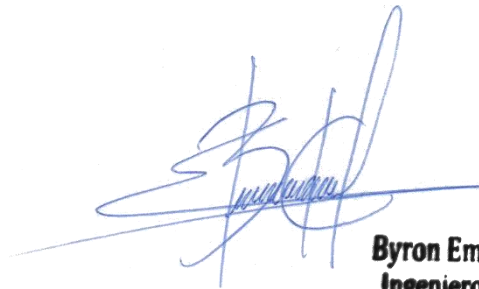
Es un gusto saludarle

Por medio de la presente hago de su conocimiento que Carlos Rafael Maldonado Estrada, estudiante de la Maestría en Estadística Aplicada, quien se identifica con carné número 201990479, me ha presentado el informe final de su trabajo de graduación titulado "Análisis Geoestadístico de Autocorrelación Espacial Incremental y Puntos de Calor Entre la Ubicación de las Cámaras en la Vía Pública y la Reducción de Actos Delictivos", el cual realizó bajo mi asesoría, brindada en forma Ad-Honorem

Luego de revisar el documento que contiene el informe del trabajo de investigación, manifiesto que le doy mi aprobación y considero que puede continuar con las gestiones correspondientes

Sin otro particular, me suscribo a sus respetables órdenes.

Atentamente,



Firma

**Byron Emmanuel Bobadilla Chin**  
**Ingeniero en Ciencias y Sistemas**  
**Colegiado No. 10,977**

Byron Emmanuel Bobadilla Chin  
Maestro en Tecnologías de la Información con  
Especialización en Base de Datos y Sistemas de Información





## **ACTO QUE DEDICO A:**

### **Mis padres**

Juan Carlos Maldonado y Miroslava Estrada. Por su apoyo y ejemplo constante. Gracias a su continuo acompañamiento, he alcanzado múltiples metas en mi vida profesional y personal, esta es una más que les dedico y agradezco infinitamente.

### **Mis amigos**

Personas que me han acompañado en mi vida y que me respaldan siempre que requiero de ellos y ellas, que me permitieron distracción sana y motivación para completar este proceso.



## **AGRADECIMIENTOS A:**

### **Mi asesor**

Ing. Byron Bobadilla, gracias por el tiempo que dedicó a revisar mis avances y a aportar su experiencia para encarrilarme en el camino adecuado para alcanzar los objetivos.

### **Mis catedráticos**

Por sus enseñanzas, sentaron las bases que me permitieron desarrollar mi conocimiento y lograron que adquiriera experiencia en las áreas que trataron.



## ÍNDICE GENERAL

ÍNDICE DE ILUSTRACIONES .....	V
GLOSARIO .....	VII
RESUMEN.....	IX
PLANTEAMIENTO DEL PROBLEMA.....	XI
OBJETIVOS.....	XV
RESUMEN DEL MARCO METODOLÓGICO .....	XVII
INTRODUCCIÓN .....	XXI
1. MARCO REFERENCIAL.....	1
1.1. Estudios previos .....	1
1.2. Marco contextual .....	4
2. MARCO TEÓRICO.....	7
2.1. Geoestadística.....	7
2.1.1. Autocorrelación espacial.....	7
2.1.1.1. Estadístico Global Moran's I .....	8
2.1.1.2. Autocorrelación espacial incremental .....	10
2.1.2. Variograma .....	10
2.1.3. Análisis de puntos de calor .....	11
2.1.4. Prueba de ajuste Kolmogorov-Smirnov .....	12
2.1.5. Diferencia de medias .....	13
2.2. Sistemas de información geográfica (SIG) .....	14
2.2.1. Imágenes Raster .....	15
2.2.2. Imágenes vectoriales.....	16
2.2.2.1. Punto .....	16

	2.2.2.2.	Línea.....	17
	2.2.2.3.	Polígono .....	17
	2.2.3.	Análisis geoespacial.....	18
	2.2.3.1.	Centroide .....	18
	2.2.3.2.	Diferencia de puntos.....	18
	2.2.3.3.	Buffer .....	18
2.3.		Términos jurídicos.....	19
	2.3.1.	Delito .....	20
3.		PRESENTACIÓN DE RESULTADOS.....	21
3.1.		Cálculo de coordenadas geoespaciales de las direcciones donde se realizaron los delito utilizando el API de Google.....	21
	3.1.1.	Limpieza datos y cálculo de coordenadas geoespaciales.....	21
	3.1.2.	Extracción de datos.....	22
	3.1.3.	Transformación de datos.....	22
3.2.		Modelo de puntos de calor optimizado y mapas de calor.....	23
	3.2.1.	Levantado de datos en GIS y limpieza.....	24
	3.2.2.	Análisis de puntos de calor optimizado .....	25
	3.2.3.	Mapa de calor.....	26
3.3.		Identificación del P-Value de las cámaras y análisis para establecer si hay algún patrón definido .....	27
4.		DISCUSIÓN DE RESULTADOS.....	33
4.1.		Análisis de generación de coordenadas geográficas de los actos delictivos.....	33
4.2.		Análisis de puntos de calor optimizado .....	35
4.3.		Interpretación del nivel de significancia de la ubicación de las cámaras .....	39

CONCLUSIONES ..... 43  
RECOMENDACIONES ..... 45  
REFERENCIAS ..... 47





# ÍNDICE DE ILUSTRACIONES

## FIGURAS

1.	Transformación de coordenadas geoespaciales en Z-scores y P-values mediante Getis-Ord $G_i^*$ .....	11
2.	Ejemplo de imagen raster. ....	15
3.	Imágenes vectoriales. ....	17
4.	Área generada para representar el buffer. ....	19
5.	Ejemplo de la estructura contenida en los archivos PDF de delitos.....	22
6.	Distribución geográfica de los delitos.....	24
7.	Conjunto de datos final.....	25
8.	Resultado del análisis de puntos de calor optimizado.....	26
9.	Mapa de calor de los delitos calculado sobre el análisis optimizado de puntos de calor.....	27
10.	Cámaras distribuidas geográficamente sobre mapa de calor. ....	28
11.	Histograma de comportamiento espacial de las cámaras, según su p-value .....	29
12.	Histograma de comportamiento espacial de los delitos, según su p-value.....	30
13.	Resultado de la transformación de direcciones.....	34
14.	Mapa de calor de significancia estadística $G_i^*$ .....	36
15.	Área de concentración de delitos en la Zona 1 de la capital .....	37
16.	Comportamiento delictivo Zonas 16, 17 y 24 .....	38

## TABLAS

I.	Las variables en estudio se describen a continuación: .....	XVIII
II.	Prueba de Kolmogorov-Smirnov del comportamiento espacial de delitos .....	30
III.	Prueba de Kolmogorov-Smirnov para el comportamiento delictivo en la ubicación de las cámaras .....	31
IV.	Comparación Mann-Whitney-Wilcoxon de poblaciones de cámaras y delitos.....	31

## GLOSARIO

<b><i>API</i></b>	Es una interfaz de programación de aplicaciones, es un medio por el cual dos aplicaciones pueden intercambiar información mediante un medio común.
<b><i>Data frame</i></b>	Conjunto de datos de dos dimensiones que puede contener columnas de distintos tipos.
<b><i>Optimized Hot Spot</i></b>	Herramienta que busca las distancias de los picos mediante autocorrelación espacial incremental.
<b><i>QGIS</i></b>	Herramienta de análisis espacial de licenciamiento libre.
<b><i>Shape</i></b>	El Shape es un formato de archivos de datos espaciales con extensión SHP.
<b><i>Spatial Join</i></b>	Une los atributos de una entidad con otra basada en la relación espacial.



## RESUMEN

El uso de cámaras en la vía pública con el fin de reducir las actividades delictivas es una práctica común en el área urbana, en este momento no se puede afirmar que las cámaras realmente tienen efecto sobre las actividades delictivas, por este motivo, se estudió este fenómeno para dar soporte a tal afirmación o por el contrario, negar dicho efecto.

Se debía realizar un proceso de transformación de direcciones escritas en lenguaje natural a coordenadas geoespaciales, ya que el proveedor de la información no contaba con dichos datos espaciales para el caso de las observaciones de delitos. Sobre el conjunto de datos de delitos ya georeferenciado se aplicó el análisis de puntos de calor optimizado para establecer el p-value del área de estudio, debido a que el resultado de este método son un conjunto de polígonos que describen dicho comportamiento y no cubren la totalidad del área de estudio, se procedió a realizar un mapa de calor.

Por último se debía determinar qué p-value correspondía a la ubicación de las cámaras, para este problema se utilizó un *Spatial Join* que permite agregar a los datos de las cámaras el p-valor del plano de calor según su posición. Para concluir con el objetivo de establecer si hay efecto o no en la ubicación de las cámaras, se debía contrastar el p-value asignado a la ubicación de las cámaras contra el comportamiento delictivo general en el espacio de estudio.

Debido a que los datos no se comportaban de forma normal se aplicó la prueba de Mann-Whitney obteniendo resultados significativos, concluyendo que las cámaras sí tienen efecto positivo sobre el comportamiento espacial de los

actos delictivos. La utilización de análisis espacial y geoestadístico es prácticamente nulo en el país, por lo que este tipo de estudios ayudan a fomentar su utilización y a proponer nuevas formas de abordar problemas.

## PLANTEAMIENTO DEL PROBLEMA

- Contexto general

En la ciudad de Guatemala, diariamente ocurren actos delictivos que son denunciados en el Ministerio Público y la Policía Nacional Civil, según el Instituto Nacional de Estadística, en el año 2017 la Policía Nacional Civil registró 1801 homicidios en el departamento de Guatemala de un total de 4410 a nivel nacional. El Ministerio Público es el encargado de recopilar datos de estos hechos y realizar las investigaciones necesarias para determinar qué ocurrió y quiénes son los responsables. El Ministerio Público, como parte de su investigación, solicita a la municipalidad capitalina las grabaciones de las cámaras de vigilancia, las cuales brindan un sustento importante a las investigaciones.

- Descripción del problema

La población en general considera que las cámaras de vigilancia tienen un efecto favorable en la reducción de actos delictivos, debido al peso de un registro de video en una investigación; por tanto, los delincuentes procuran evitar realizar sus actividades delictivas en áreas cubiertas por cámaras de vigilancia y por ende, se presenta una reducción en la cantidad de delitos cometidos cerca de las cámaras de vigilancia.

Se desconoce qué tan significativo es el efecto, si es que existe, de las cámaras de vigilancia en la cantidad de actos delictivos cometidos en las áreas

cubiertas por estas, por lo que se presentó la necesidad de determinar el nivel de correlación entre las cámaras y la reducción delincencial.

Por ser datos de tipo espacial, no se pueden utilizar los medios normales de correlación lineal, según la geoestadística, se debe aplicar la autocorrelación espacial incremental, en este caso, sobre las coordenadas de delitos contra una matriz distribuida en el área de estudio, este proceso produce un estadístico denominado Global Moran's I y distribuye valores de Z en toda el área de estudio; mediante un análisis de puntos de calor optimizado, se establece valores de z y p-values, los cuales indican qué tan posible es que ocurra un acto delictivo en cualquier coordenada dentro del área de estudio.

Para determinar qué tanto efecto tienen las cámaras sobre la delincuencia se realizó el análisis geoestadístico de autocorrelación y puntos de calor.

- Formulación del problema

Esto lleva a plantear la pregunta principal de este estudio: ¿Cuál es la diferencia entre las medias de p-value obtenido por el análisis de puntos calientes optimizados en la ubicación de las cámaras y el p-value medio de una muestra irrestricta aleatoria de puntos en el área de estudio?

- Preguntas auxiliares

- ¿Qué coordenadas geoespaciales corresponden a las direcciones utilizadas para identificar el sitio donde fue reportado un delito?
- ¿Cuál es el modelo de puntos calientes optimizado de los crímenes?



- ¿Cuál es el p-value que el modelo asigna a la ubicación de las cámaras?
- ¿Qué nivel de ajuste a la normal tiene la distribución de los p-values de la ubicación de las cámaras?
- Delimitación del problema

El estudio se limitó únicamente al municipio de Guatemala del departamento de Guatemala, en las coordenadas donde existan delitos denunciados ante el MP y que los datos estuvieran disponibles. Se abordó el estudio únicamente con los delitos tipificados como robo agravado, cohecho, homicidio y extorsión. Se evaluó los registros de enero de 2015 a enero de 2020 de historia de actos delictivos. No se disponía de las fechas en las que fueron instaladas las cámaras en su ubicación reportada, por lo que no fue posible realizar un análisis espacio temporal.



## **OBJETIVOS**

### **General**

Describir diferencias entre la media de p-value obtenido por el análisis de puntos calientes optimizados en la ubicación de las cámaras y el p-value medio de una muestra irrestricta aleatoria para determinar si la ubicación de las cámaras tiene una media diferente a la de la muestra del área de estudio y así determinar si estas pudieran afectar.

### **Específicos**

1. Establecer las coordenadas geoespaciales que corresponden a las direcciones utilizadas para identificar el sitio donde fue reportado un delito, por medio de un API que extrae los datos geográficos de google para georeferenciar el acto delictivo.
2. Establecer el modelo de puntos calientes optimizado de los crímenes, utilizando la herramienta GIS ArcGIS, para determinar un p-value y z-score de cualquier punto en el área de estudio.
3. Calcular el p-value que el modelo geoespacial asigna a la ubicación de las cámaras, para determinar si se comporta con un patrón definido, o si se ajusta a la normal mediante prueba de normalidad Kolmogorov-Smirnov.



## RESUMEN DEL MARCO METODOLÓGICO

A continuación se describe la metodología que se utilizó para completar y alcanzar los objetivos:

- Características del estudio

El enfoque del estudio propuesto es cuantitativo, ya que se utilizaron métodos geoestadísticos para sustentar los resultados obtenidos.

El alcance es correlacional, dado que se evaluó el efecto de las cámaras en la distribución geográfica de los hechos delictivos mediante autocorrelación espacial y variogramas.

El diseño adoptado fue no experimental, pues la información de las cámaras y delitos se analizaron en su estado original sin ninguna manipulación; analizando el comportamiento de los hechos delictivos en donde se ubican las cámaras en la vía pública.

- Unidades de análisis

La población en estudio fue la base de datos de las cámaras de seguridad registradas en el Ministerio Público y los hechos delictivos proporcionados por la misma institución, de la cual se trabajaron la totalidad de registros restantes luego de un proceso de limpieza de datos con direcciones erróneas o imposibles de establecer su ubicación espacial, representando estos el 90 %, 123,312 delitos en total.

- Variables

Tabla I. **Las variables en estudio se describen a continuación:**

<b>Variable</b>	<b>Definición teórica</b>	<b>Definición operativa</b>
Ubicación geoespacial de las cámaras de vigilancia	Coordenadas geoespaciales de la ubicación de las cámaras (WGS84)	Resultado de la transformación de la dirección registrada en coordenadas geoespaciales
Ubicación geoespacial de los hechos delictivos	Coordenadas geoespaciales de la ubicación del hecho delictivo (WGS84)	Resultado de la transformación de la dirección registrada en coordenadas geoespaciales

Fuente: elaboración propia.

- Fases del estudio

A continuación se describen las fases que se ejecutaron en el transcurso del proyecto.

- Fase 1. Revisión de literatura

Se obtuvieron antecedentes que guiaron la investigación, proporcionaron directivas y formas de proceder en escenarios similares al estudiado. Posteriormente se recopiló bibliografía para tener sustento en la labor realizada.

- Fase 2. Gestión o recolección de la información

Se gestionó información con el Ministerio Público, entidad que cuenta con los datos necesarios. Se solicitó un conjunto de datos que contiene la ubicación geoespacial de las cámaras además de un conjunto de datos con la ubicación de los hechos delictivos, es debido aclarar que solo se obtuvo la dirección, el MP no cuenta con información geoespacial para el caso de los registros de delitos.

- Fase 3. Limpieza y transformación de datos

Debido a que el conjunto de datos de los delitos no cuenta con la ubicación geoespacial de los mismos, se realizó un proceso de transformación, utilizando el API de Google, se realizó la conversión de direcciones a coordenadas geoespaciales, la conexión al API de Google se realizó con el lenguaje R.

- Fase 4. Análisis de información

Se aplicaron las técnicas descritas a la data, siendo estas autocorrelación espacial incremental y cálculo de puntos de calor optimizados, para obtener resultados y extraer conclusiones de los mismos. El análisis geoespacial se realizó con la herramienta ArcGIS y cálculos estadísticos de normalidad y análisis descriptivo con R.

- Fase 5. Presentación de resultados

Luego de completar los análisis geoestadísticos, se procedió a extraer conclusiones de los resultados obtenidos y realizar recomendaciones para estudios posteriores.

- Técnicas de análisis de información
  - Autocorrelación espacial incremental: al unir una cuadrícula con los puntos del conjunto de datos de delitos mediante un *spatial-join*, se puede calcular la autocorrelación espacial, mediante ésta se obtendrá el estadístico denominado Global Moran's I, asignando un valor z a cada cuadro de la cuadrícula, la autocorrelación espacial toma en cuenta la distancia. Estos valores z se utilizan para describir la probabilidad de que ocurran delitos en cada cuadro.
  - Análisis de puntos calientes: permite obtener la probabilidad de que ocurra un delito mediante valores z, toma en cuenta la aglomeración en el área de estudio.
  - Prueba de normalidad: se utilizará la prueba de Kolmogorov-Smirnov para determinar si la cantidad de hechos delictivos por cuadro se distribuye normalmente.
  - Diferencia de medias: la diferencia de medias entre la media de conteos delictivos de la ubicación de las cámaras y la media de conteos general indicaría si las medias pertenecen a la misma población, o son dos grupos diferentes.



## INTRODUCCIÓN

Las cámaras de circuito cerrado colocadas en la vía pública son utilizadas con el propósito de reducir la delincuencia en el área donde son instaladas, los estudios no han podido demostrar una correlación entre la instalación de cámaras de seguridad y la reducción de la delincuencia. Por ello se decidió abordar esta temática que es de suma importancia en un entorno como el de la ciudad de Guatemala, en donde se presentan altos índices de delincuencia, por lo que era prioritario establecer si las cámaras que se instalan en la vía pública brindan el resultado esperado.

Los datos utilizados en este estudio fueron proporcionados por el Ministerio Público. Los registros de las cámaras se obtuvieron en formato *Shape* y los datos de delitos en tablas con formato PDF. Por lo que se presentó la necesidad de realizar un proceso de extracción, otro problema era que dichos datos no se encontraban codificados geográficamente, eran simples direcciones desglosadas en avenida, calle y zona, por lo que se realizó un proceso de transformación y georeferenciación.

El análisis geoestadístico inició aplicando a la ubicación de los actos delictivos un proceso de autocorrelación denominado análisis de puntos de calor optimizado que se basa en el estudio de la cercanía y aglomeración de observaciones para establecer un estadístico denominado Getis-ord  $G_i^*$ , del cual se calcula p-values y z-score que se distribuyen en el área de las observaciones. El resultado son un conjunto de polígonos que no cubren la totalidad del plano de estudio. Debido a esto se realizó una superficie de variograma o mapa de

calor, la cual permite suavizar y calcular un valor estimado de p-values y z-score en el área no calculada por el análisis de puntos de calor optimizado.

Seguidamente se debía establecer el p-value que correspondía a las cámaras según su posición en el plano de calor, esto se logró utilizando la herramienta *Spatial Join*, tomando los atributos de las cámaras y agregando los atributos p-value y z-score de su posición.

Por último se hizo un contraste entre el comportamiento general del área de estudio según su significancia estadística y contrastando contra los valores asignados a las cámaras, esto mediante una prueba de Mann-Whitney ya que los datos no se comportaban normalmente. Se estableció que las cámaras tienen un efecto reductivo en la actividad delictiva.

En el capítulo 1 se presentan una serie de estudios que abordan el tema tratado, para obtener las pautas que se utilizaron de guía en el desarrollo de esta investigación. En el capítulo 2 se presenta el marco teórico que es el resultado de la investigación bibliográfica realizada para dar sustento a la investigación. En el capítulo 3 se presentan los resultados obtenidos del análisis realizado, describiendo el proceso. En el capítulo 4 se analizan los resultados obtenidos para interpretarlos y entenderlos. En el capítulo 5 se establecen las conclusiones obtenidas del análisis realizado. El capítulo 6 lista una serie de recomendaciones para futuros trabajos.

# 1. MARCO REFERENCIAL

## 1.1. Estudios previos

En el pasado se han realizado estudios sobre el tema, ya que es de pensamiento general que las cámaras en la vía pública reducen la delincuencia, pero esta afirmación no ha sido probada al 100 %, e incluso hay estudios que indican que no tiene efecto alguno, a continuación algunos de estos estudios que fueron utilizados como base para el desarrollo de este trabajo.

El efecto de las cámaras sobre los actos delictivos, según Ratcliffe, Taniguchi y Taylor (2009), representa una reducción del 13 % en actividades delictivas en general luego de implementar cámaras, estas métricas las obtuvieron mediante modelado lineal jerárquico y el cociente de desplazamiento de pesos, ellos realizaron pruebas subdividiendo los crímenes en dos categorías: crímenes serios (*Serious crime*) y crimen de desorden (*Disorder crime*), en la que concluyen que no hay ninguna correlación entre *serious crime* y la implementación de cámaras; pero si hay una correlación marcada entre *disorder crime* y la presencia de las cámaras de circuito cerrado, presentando una reducción en las mismas. Este artículo brindó una clasificación de los crímenes (*Serious crime* y *Disorder crime*) que fue utilizado como marco de referencia para la selección de los tipos de delito que fueron incluidos en este estudio.

Van Rompay, Vonk, Fransen (2009) han estudiado el efecto que tienen las cámaras sobre las personas, estas buscan la aprobación de los demás, y por tanto, cuando se encuentran frente a una cámara de circuito cerrado se sienten

obligados a presentar una actitud aprobable y correcta; la cámara tiene un efecto social sobre ellas como si se encontrasen frente a otra persona.

Este artículo brindó sustento para afirmar que las cámaras de circuito cerrado tienen un efecto positivo en la conducta de las personas y por tanto, reducen las actividades ilícitas en su ubicación. Para demostrar esto, realizaron un experimento con 80 personas, las cuales eran asignadas de manera aleatoria a una habitación con cámaras o sin ellas, para evaluar su forma de responder un cuestionario diseñado para determinar su comportamiento.

Piza, Caplan y Kennedy (2014) proponen que se debe evaluar detenidamente la ubicación de las cámaras, ya que se busca maximizar su poder de disuasión; con 117 unidades de análisis, se encontraron poco efecto en la utilización de cámaras para reducir el crimen, los autores manifestaron además, que en bares y sus alrededores se presenta una reducción en los niveles de crimen, siendo estadísticamente significativo en crímenes violentos y robos.

Piza, Caplan, y Kennedy (2014) utilizaron modelos de regresión de mínimos cuadrados para intentar simular la naturaleza de los crímenes en áreas con cámaras de circuito cerrado, primeramente evaluando si cumplían con las características de homocedasticidad y normalidad luego evaluando su nivel de ajuste con el coeficiente de determinación que para robos obtuvo  $r^2=0.206$ , para robos de auto obtuvo  $r^2=0.203$  y para robos con auto obtuvo  $r^2=0.203$ . Este artículo aportó antecedentes estadísticos de cómo se ha trabajado el problema.

Lim, Eck y Kim (2013) al igual que Ratcliffe *et. al.* (2009) proponen utilizar modelos lineales y el cociente de desplazamiento ponderado (*weighted displacement quotient* WDQ), que según los dos estudios permiten modelar de manera correcta la relación entre las cámaras y la reducción del crimen. Estos

modelos fueron un gran aporte para este estudio, brindando una guía de cómo analizar la correlación entre cámaras y delincuencia.

Dell'Olmo, Ricciardi y Sgalambro (2013), aplicaron un modelo de optimización de ubicación para cámaras de seguridad en intersecciones denominado modelo de ubicación de cobertura máxima multiperiodo (*Multiperiod Maximal Covering Location Model*) fue propuesto para reducir los accidentes de tránsito en Roma; a este estudio aportó un modelo de optimización bien descrito para cámaras de circuito cerrado utilizando Sistemas de Información Geográfica (SIG) que puede ser modificado y adaptado para optimizar la distribución de cámaras en la ciudad de Guatemala con el enfoque de reducción de actos delictivos.

Yaagoubi, El Yarmani, Kamel y Khemiri (2015) proponen un método de distribución de cámaras de vigilancia denominado *HybVOR*, intenta crear un diagrama *Voronoi* el cual describen a detalle y que proponen como un modelo óptimo para distribuir la menor cantidad de cámaras y maximizar el área de vigilancia. Este estudio presentó otra forma de abordar la distribución de cámaras de seguridad describiendo detalladamente su procedimiento.

Ways y Pearson (2018) en su estudio geoespacial de correlación entre los actos delictivos y la ubicación de las cámaras, utilizan WDQ, pero más importante para este estudio fue la utilización de correlación espacial incremental, y el análisis de puntos calientes optimizado que produce el estadístico *Global Moran's I*, que es utilizado para asignar un Z-score y un p-value a cualquier punto en el área estudiada. En este estudio proponen utilizar ArcGIS que es una herramienta GIS para realizar los cálculos y mapas, fue otro gran aporte para este estudio.

Gerell' (2016) mediante un estudio de puntos calientes en la ciudad de Malmö, en Suecia, concluye que no hay efecto significativo en la reducción de crímenes al implementar cámaras de vigilancia, pero sí se determinó que hubo un aumento en los reportes de asalto. Este estudio aportó más sustento a la utilización de puntos de calor para evaluar el efecto de las cámaras en la delincuencia.

Abdulqader (2006) realiza un extenso análisis, describe la utilización de los sistemas de información geográfica (SIG) en gran detalle, él también describe la utilización de variogramas en este tipo de análisis, el variograma fue un aporte importante para este estudio, ya que mide la dependencia espacial entre puntos. Abdulqader realizó su estudio con datos proporcionados por el Departamento de Policía de la ciudad de Ottawa (*Ottawa Police Services*).

Kamilaris y Ostermann (2018) presentan el futuro del análisis geoespacial para estudiar el comportamiento del crimen, en este caso no solo utiliza sistemas de información geográfica, sino amplía su estudio con la inclusión del internet de las cosas y propone nuevos métodos.

Con base en los antecedentes anteriormente citados, se contó con suficiente fundamento y lineamientos para llevar a cabo el estudio planteado, se dio seguimiento a las recomendaciones y experiencias que expusieron los autores para cumplir los objetivos de este estudio satisfactoriamente.

## **1.2. Marco contextual**

En la ciudad de Guatemala, diariamente ocurren actos delictivos que son denunciados en el Ministerio Público y la Policía Nacional Civil, según el Instituto Nacional de Estadística, en el año 2017 la Policía Nacional Civil registró 1801

homicidios en el departamento de Guatemala de un total de 4410 a nivel nacional. El Ministerio Público es el encargado de recopilar datos de estos hechos y realizar las investigaciones necesarias para determinar qué ocurrió y quiénes son los responsables. El Ministerio Público, como parte de su investigación, solicita a la municipalidad capitalina las grabaciones de las cámaras de vigilancia, las cuales brindan un sustento importante a las investigaciones.





## **2. MARCO TEÓRICO**

### **2.1. Geoestadística**

Es una rama de la estadística especialmente desarrollada para trabajar con datos espaciales, según Hengl (2009) “la geoestadística es un subconjunto de la estadística especializada en el análisis e interpretación de datos referenciados geográficamente” (p. 1). Según Journel (2009) indica que la geoestadística fue implantada por Kolmogorov y Wiener.

Hangl (2009) también propone tres objetivos que trata de satisfacer la geoestadística, indicando que son: estimación sobre modelo, predicciones o interpolación espacial, prueba de hipótesis.

Estas características o funcionalidades de la geoestadística son comunes en muchas de las otras ramas de la estadística, crear inferencias con base en un modelo, intentar predecir qué ocurrirá según las acciones que se realicen utilizando patrones en datos históricos como base y realizar pruebas de hipótesis para obtener un valor, rechazar o aceptar, según un planteamiento dado, pero en el caso de la geoestadística, lo que funciona como diferenciador y área de especialización es que se trabaja con datos georeferenciados, normalmente de dos dimensiones.

#### **2.1.1. Autocorrelación espacial**

Gelfand, Diggle, Fuentes y Guttorp (2010), también la describen como covarianza, la autocorrelación describe qué tan similares son los objetos

cercanos entre sí dependiendo de la distancia a la que se encuentren. Según Journel (2009), describe la covarianza mediante la siguiente ecuación:

$$C(h) = Cov\{Z(x), Z(x + h)\} \quad (\text{Ec. 1})$$

Donde:

C = es la autocorrelación espacial o función de covarianza,  
Z(x) y Z(x+h) = son conjuntos de variables aleatorias,  
H = representa un vector con cierta dirección y longitud.

Gelfand *et. al.* (2010) igualmente describen la autocorrelación como:

$$Cov(\gamma(s), \gamma(s + h)) = Cov(\gamma(0), \gamma(h)) = C(h) \quad (\text{Ec. 2})$$

Donde  $\gamma(s)$  y  $\gamma(s + h)$  son procesos gaussianos.

En conclusión, un valor estudiado comparado contra el espacio definido, podría no ser independiente de todos los puntos evaluados en el espacio. La autocorrelación espacial puede retornar valores positivos o negativos, si el valor es positivo indica que hay gran similitud entre el valor estudiado y el punto en el espacio, si el valor es negativo indica que no hay similitud.

### **2.1.1.1. Estadístico Global Moran's I**

Mitchell (2005) indica que el estadístico Global Moran's I es un valor que ayuda a medir la autocorrelación espacial, permite determinar si los valores estudiados están agrupados, dispersos o son aleatorios. Para interpretarlo

Mitchell plantea utilizar una hipótesis nula que indica que la ubicación del valor estudiado es aleatoria en el área de estudio.

El estadístico Global Moran's I es calculado mediante la ecuación:

$$I = \frac{n}{s_0} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{i,j} z_i z_j}{\sum_{i=1}^n z_i^2} \quad (\text{Ec. 3})$$

Donde:

$z_i$  = es la diferencia entre el valor y la media ( $x_i - \bar{X}$ ),

$w_{i,j}$  = es el peso espacial entre  $i$  y  $j$ ,

$n$  = es la cantidad de valores estudiados,

$s_0$  = es la sumatoria de todos los pesos espaciales.

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{i,j} \quad (\text{Ec. 4})$$

El valor de  $z_I$ -score es calculado mediante:

$$z_I = \frac{I - E[I]}{\sqrt{V[I]}} \quad (\text{Ec. 5})$$

Donde,  $E[I]$  está dado por:

$$E[I] = -1/(n - 1) \quad (\text{Ec. 6})$$

$V[I]$  está dado por:

$$V[I] = E[I^2] - E[I]^2 \quad (\text{Ec. 7})$$

$$E[I^2] = \frac{A-B}{C} \quad (\text{Ec. 8})$$

$$A = n[(n^2 - 3n + 3)S_1 - nS_2 + 3S_0^2] \quad (\text{Ec. 9})$$

$$B = D[(n^2 - n)S_1 - 2nS_2 + 6S_0^2] \quad (\text{Ec. 10})$$

$$C = (n - 1)(n - 2)(n - 3)S_0^2 \quad (\text{Ec. 11})$$

$$D = \frac{\sum_{i=1}^n z_i^4}{(\sum_{i=1}^n z_i^2)^2} \quad (\text{Ec. 12})$$

$$S_1 = \left(\frac{1}{2}\right) \sum_{i=1}^n \sum_{j=1}^n (w_{i,j} + w_{j,i})^2 \quad (\text{Ec. 13})$$

$$S_2 = \sum_{i=1}^n (\sum_{j=1}^n w_{i,j} + \sum_{j=1}^n w_{j,i})^2 \quad (\text{Ec. 14})$$

### 2.1.1.2. Autocorrelación espacial incremental

La autocorrelación espacial incremental describe cómo se comporta la autocorrelación conforme varía la distancia. La autocorrelación espacial incremental es descrita mediante variogramas.

#### 2.1.2. Variograma

Gelfand *et. al.* (2010) mencionan que el variograma o semivariograma es una herramienta que permite describir cómo una variable cambia en un área definida, utilizan la siguiente fórmula para representarlo:

$$\gamma(h) = \frac{1}{2} \text{var}(\gamma(s + h) - \gamma(s)) \quad (\text{Ec. 15})$$

Donde  $\gamma$  es un proceso estocástico espacial.  $s$  es la ubicación espacial,  $w$  es la probabilidad.

$$\gamma(s) = \gamma(s, w) \quad (\text{Ec. 16})$$

Y aplicado a autocorrelación:

$$\gamma(h) = C(0) - C(h) \quad (\text{Ec. 17})$$

### 2.1.3. Análisis de puntos de calor

Smith, Goodchild y Longley (2018) indican que las observaciones espaciales pueden ser estudiadas según cómo se aglomeran, esto se denomina análisis de puntos calientes.

Mitchell (2005) realiza el cálculo de puntos calientes mediante un estadístico denominado Getis-Ord  $G_i^*$ , el resultado es un conjunto de valores Z y p-values, mediante los cuales se puede determinar cómo se agrupan los puntos espacialmente.

Figura 1. **Transformación de coordenadas geoespaciales en Z-scores y P-values mediante Getis-Ord  $G_i^*$**



Fuente: ArcMap (2020). *Análisis de Puntos Calientes ( $G_i^*$  de Getis-Ord)*. Consultado el 15 de enero de 2022. Recuperado de <https://desktop.arcgis.com/es/arcmap/10.3/tools/spatial-statistics-toolbox/hot-spot-analysis.htm>.

El análisis de puntos de calor es descrito por la siguiente ecuación:

$$G_i^* = \frac{\sum_{j=1}^n w_{i,j} x_j - \bar{X} \sum_{j=1}^n w_{i,j}}{S \sqrt{\frac{[n \sum_{j=1}^n w_{i,j}^2 - (\sum_{j=1}^n w_{i,j})^2]}{n-1}}} \quad (\text{Ec. 18})$$

Donde:

$x_i$  = es el valor del punto estudiado,

$w_{i,j}$  = es el peso espacial entre  $i$  y  $j$ ,

$n$  = es el número total de elementos estudiados.

$\bar{X}$  está dada por:

$$\bar{x} = \frac{\sum_{j=1}^n x_j}{n} \quad (\text{Ec. 19})$$

$S$  está dada por:

$$S = \sqrt{\frac{\sum_{j=1}^n x_j^2}{n} - (\bar{x})^2} \quad (\text{Ec. 20})$$

El estadístico  $G_i^*$  ya es un valor de  $z$  por lo que no se requieren cálculos adicionales, entre mayor es el valor del estadístico, mayor es el punto caliente.

#### 2.1.4. Prueba de ajuste Kolmogorov-Smirnov

Siegel y Castellan (1998) indican que “La prueba de Kolmogorov-Smirnov (...) está interesada en el grado de acuerdo entre la distribución de un conjunto de valores muestreados y alguna distribución teórica específica” (p. 74). La prueba de ajuste a la normal de Kolmogorov-Smirnov es utilizada en conjuntos

de datos mayores a 31 elementos. La prueba Kolmogorov-Smirnov está dada por:

$$D = \max |F_o(X_i) - S_N(X_i)| \quad i = 1, 2, 3 \dots N \quad (\text{Ec. 21})$$

Donde  $F_o(X_i)$  representa un conjunto de frecuencias relativas acumuladas dictada por la distribución teórica  $H_o$  y  $S_N(X_i)$  representa un conjunto de frecuencias relativas acumuladas observadas.

### 2.1.5. Diferencia de medias

Walpole, Myers, Myers y Ye (2012), explican que para determinar si dos medias pertenecen a la misma población, se debe proceder de la siguiente manera:

$$\sigma_{\bar{X}_1 - \bar{X}_2} = \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \quad (\text{Ec. 22})$$

Donde:

$\sigma_1$  = es la desviación de la población 1,

$\sigma_2$  = es la desviación de la población 2,

$n_1$  = es la cantidad de elementos de la muestra 1,

$n_2$  = es la cantidad de elementos de la muestra 2.

El estadístico de prueba está dado por:

$$Z = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sigma_{\bar{X}_1 - \bar{X}_2}} \quad (\text{Ec. 23})$$

Donde:

$\bar{X}_1$  = es la media de la primera muestra,  
 $\bar{X}_2$  = es la media de la segunda muestra,  
 $\mu_1$  = es la media de la primera población,  
 $\mu_2$  = es la media de la segunda población.

El intervalo de confianza está dado por:

$$P\left(-z_{\frac{\alpha}{2}} < Z < z_{\frac{\alpha}{2}}\right) = 1 - \alpha \quad (\text{Ec. 24})$$

Donde  $z_{\frac{\alpha}{2}}$  es el valor de z teórico a dos colas,  $1 - \alpha$  es el nivel de confianza.

## 2.2. Sistemas de información geográfica (SIG)

Según Pucha-Cofrep (2018) los sistemas de información geográfica son herramientas de hardware y software para el análisis y almacenamiento de información geográfica facilitando la toma de decisiones y permitiendo una visualización amigable para el usuario.

Los SIG utilizan distintos tipos de imágenes para representar los datos espaciales almacenados en forma de tabla en bases de datos diseñadas para manejar coordenadas geoespaciales, estas bases de datos también brindan cálculos espaciales y facilitan el análisis.

Los SIG brindan la facilidad de realizar cálculos complejos mediante una interfaz amigable, a continuación, se describen algunas de las características principales que el lector debe conocer en pro del entendimiento de este estudio.

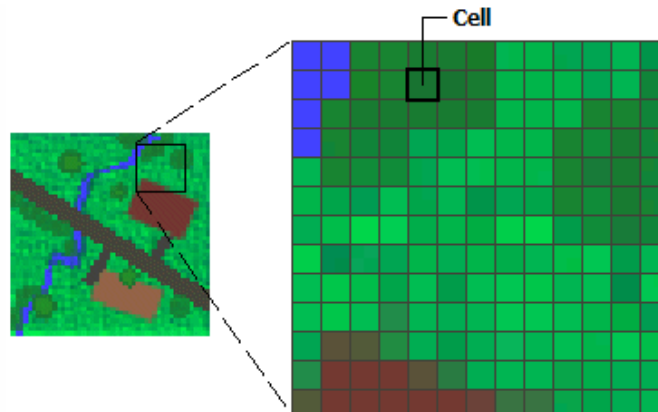


### 2.2.1. Imágenes Raster

Pucha-Cofrep (2008) indica que “una estructura raster está basada en una matriz de celdas representadas en filas y columnas, cada celda puede almacenar información sobre alguna variable (precipitación, temperatura, humedad relativa, radiación solar, reflectividad, entre otros)” (p. 9).

Las imágenes raster son generalmente imágenes satelitales y mapas de calor, las imágenes raster facilitan la visualización complementando a las imágenes vectoriales que se describen a continuación. En algunos casos de uso, las imágenes raster son más aptas que las imágenes vectoriales, por ejemplo en análisis de puntos calientes, distribuciones en planos y otros casos de uso que distribuyen en un área la variable a estudiar.

Figura 2. **Ejemplo de imagen ráster**



Fuente: ArcMap (2020) *¿Qué son los datos Ráster?*. Consultado el 15 de enero de 2022.  
Recuperado de <https://desktop.arcgis.com/es/arcmap/10.3/manage-data/raster-and-images/what-is-raster-data.htm>.

En la figura 2, se observa una imagen raster, y en este caso, las celdas almacenan un color, cada una posee su propio y único color, y al observarlas en el plano, se aprecia una imagen más compleja, pero estas celdas pueden representar muchas cosas aparte de color. Para entenderlas mejor, se pueden homologar a los píxeles.

### **2.2.2. Imágenes vectoriales**

Pucha-Cofrep (2008) indica que “el modelo de datos vectoriales está basado en el supuesto que la superficie terrestre está compuesta de objetos discretos como árboles, ríos, lagunas, entre otros. (...) Estas primitivas son de tres tipos: puntos, líneas y polígonos)” (p. 8).

Las imágenes vectoriales permiten distribuir objetos más complejos que una celda en un plano, estos objetos pueden tener más atributos que la celda, a continuación se describe cada uno.

#### **2.2.2.1. Punto**

Es la imagen vectorial más simple, representa un lugar específico en el espacio y puede poseer  $n$  atributos, por ejemplo, un punto puede representar una casa, a esta casa se le puede asignar un color, una dirección, un tipo, todos estos datos son descriptivos. Normalmente son un único registro en una base de datos espacial.

### 2.2.2.2. Línea

Una línea es un objeto compuesto por una serie de puntos, al igual que estos, puede poseer n atributos, por ejemplo, una línea en un plano puede representar un río, el río posee un nombre, una longitud, un caudal, entre otros.

### 2.2.2.3. Polígono

Es la imagen vectorial más compleja, representa una forma geométrica, está compuesto por una o varias líneas perimetrales que encierra un área o volumen, definiendo un objeto de 2 o 3 dimensiones, como las otras, esta puede incluir n atributos.

Figura 3. **Imágenes vectoriales**



Fuente: Obe y Hsu (2011). *Introducing the geometry data type*.

En la figura se pueden observar ejemplos de los distintos tipos de una imagen vectorial, las imágenes vectoriales facilitan los cálculos geoespaciales, y son más fáciles de manipular que las imágenes raster. Obe y Hsu (2011) indican “La totalidad del mapeo en 2D puede ser alcanzado con tres geometrías básicas: puntos, líneas y polígonos” (p. 6).

### **2.2.3. Análisis geoespacial**

Es el proceso por el cual se extrae información y conocimiento utilizando georeferenciación, algunos procedimientos geoespaciales básicos se listan a continuación:

#### **2.2.3.1. Centroide**

Según Obe y Hsu (2009) “se debería pensar sobre el centroide de una geometría como el centro de gravedad como si cada punto de la geometría tuviese igual masa, la única consideración es que el centroide puede no caer dentro de la geometría” (p. 103).

#### **2.2.3.2. Diferencia de puntos**

Los sistemas de información geográfica permiten la comparación de áreas y distancias entre objetos vectoriales, e incluso determinar si se sobreponen. La diferencia entre puntos permite determinar la distancia entre ellos. Obe y Hsu indican que hay dos formas de realizar estos cálculos, uno es con un modelo de esfera de radio 6,370,986 metros, con este modelo esférico se obtienen resultados más rápidamente pero los valores resultantes no son precisos. El segundo modelo es denominado esferoide terrestre y por su forma compleja, los cálculos son más lentos, pero su precisión es muy exacta.

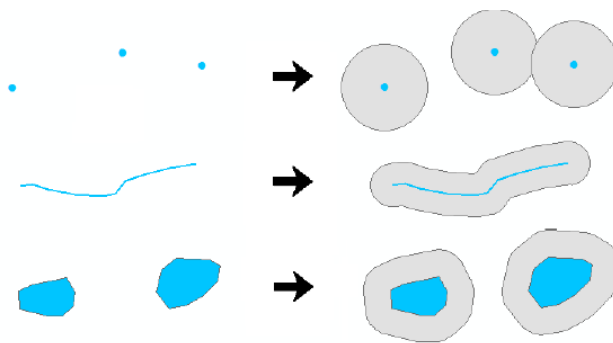
#### **2.2.3.3. Buffer**

Según Obe y Hsu (2009), “toma cualquier geometría y expande radialmente en  $r$  unidades, donde  $r$  se define en unidades del sistema de referencia espacial,

esta nueva geometría formada por la expansión es llamada zona de buffer o "corridor" (p. 30). Este tipo de cálculos geoespaciales permiten realizar análisis con respecto al área en el que tiene efecto algo. Por ejemplo, el campo de visión de una cámara.

Pucha-Cofrep (2008) ejemplifica el área generada para buffer con la siguiente imagen:

Figura 4. **Área generada para representar el buffer**



Fuente: Pucha-Cofrep (2008). *Buffer*.

En la figura 4 se visualiza la zona en la que el objeto tiene injerencia, el tamaño del radio utilizado para definir el área del buffer es arbitrario, y es establecido por el analista, lo que quiere decir que es un valor variable.

### 2.3. Términos jurídicos

Para un mejor entendimiento del contenido de este documento, se describe qué es delito, ya que son la fuente de datos utilizada para análisis geoespacial.

### **2.3.1. Delito**

Según Fontan (1998) indica que la escuela clásica lo define como “el delito no es un ente de hecho, sino un ente jurídico, una relación contradictoria entre el hacer del hombre y la ley” (p. 55). Fontan (1998) también expone que “en el delito se destaca el elemento intencional, haya ánimo de delinquir; se distingue también la culpa, siendo la pena inferior y casi siempre pecuniaria”(p. 48).

### **3. PRESENTACIÓN DE RESULTADOS**

#### **3.1 Cálculo de coordenadas geospaciales de las direcciones donde se realizaron los delito utilizando el API de Google**

La fuente de datos proporcionada por el Ministerio Público estaba compuesta por una serie de archivos formato PDF, dichos archivos debían ser procesados para extraer la data contenida en ellos, a continuación se describe dicho proceso:

##### **3.1.1. Limpieza datos y cálculo de coordenadas geospaciales**

Los datos necesarios para este trabajo fueron proporcionados por el Ministerio Público (MP) en cuatro archivos con extensión PDF para el registro de delitos y en un Shapefile para las cámaras. En el caso de los archivos de delitos, se debió realizar un proceso de extracción y transformación complejo, a continuación en la Figura 5 se presenta una captura de la fuente de datos:

Figura 5. Ejemplo de la estructura contenida en los archivos PDF de delitos



1

**REPORTE ESTADISTICO DEL MUNICIPIO DE GUATEMALA, PERSONAS AGRAVIADAS POR EL DELITO DE ROBO AGRAVADO, REGISTRADAS EN EL PERIODO COMPRENDIDO DEL 01/01/2015 AL 08/03/2020**

Municipio	Tipo Persona	Sexo	Calle	Avenida	Zona	Delito	Fecha	Personas
GUATEMALA	AGRAVIADO	MUJER	0	4	ZONA 1	ROBO AGRAVADO	02/01/2015 11:43	1
GUATEMALA	AGRAVIADO	HOMBRE	18	3	ZONA 1	ROBO AGRAVADO	02/01/2015 12:40	1
GUATEMALA	AGRAVIADO	HOMBRE	8	5	ZONA 1	ROBO AGRAVADO	02/01/2015 14:03	1
GUATEMALA	AGRAVIADO	HOMBRE	0	3	ZONA 1	ROBO AGRAVADO	02/01/2015 19:59	1
GUATEMALA	AGRAVIADO	HOMBRE	8	2 Y 3	ZONA 1	ROBO AGRAVADO	04/01/2015 8:11	1
GUATEMALA	AGRAVIADO	HOMBRE	19	9	ZONA 1	ROBO AGRAVADO	04/01/2015 12:28	1
GUATEMALA	AGRAVIADO	HOMBRE	12	6 Y 7	ZONA 1	ROBO AGRAVADO	04/01/2015 13:42	1
GUATEMALA	AGRAVIADO	HOMBRE	18	9	ZONA 1	ROBO AGRAVADO	04/01/2015 16:41	1
GUATEMALA	AGRAVIADO	HOMBRE	10	6	ZONA 1	ROBO AGRAVADO	04/01/2015 18:20	1

Fuente: elaboración propia, con datos obtenidos de Ministerio Pùblico (2020). *Personas agraviadas por delito de robo agravado.*

### 3.1.2. Extracción de datos

Para trabajar con esta fuente se desarrolló un script en R, lo primero que se debía lograr era extraer los datos de la fuente PDF, para lo cual se utilizó la librería *pdftools*, con la ayuda de esta librería, se cargó a un *data frame* la totalidad de registros contenidos en los 5 archivos. Luego, se debían depurar los registros que no eran de utilidad como títulos, encabezados e imágenes, para ello se desarrolló una función, la cual permitía realizar el proceso de depuración de registros. Con este proceso de extracción se logró obtener un *data frame* limpio y listo para continuar procesando.

### 3.1.3. Transformación de datos

El siguiente paso fue el proceso de transformar las direcciones en el *data frame* a coordenadas georeferenciadas. Para esta labor se utilizó la librería



*ggmap*, la cual permite la conexión a las APIs de Google, dicha herramienta brinda un servicio de conversión de direcciones escritas en lenguaje natural a coordenadas geoespaciales. Para poder utilizar este servicio, primeramente se debía convertir los campos de zona, calle, avenida y municipio en una dirección escrita en lenguaje natural. Mediante un script en R, se concatenaron y adaptaron lo más posible para alcanzar los mejores resultados y la precisión deseada.

Ya teniendo un conjunto de datos adecuado para la utilización de la API de Google, se debía obtener un token de acceso, ya que estos servicios son gratuitos para un número muy limitado de peticiones, las cuales quedaban cortas para el alto número de direcciones de delitos contenidos en el *data frame*. Para reducir costos se optó por aperturar una cuenta en Google Cloud Platform, en la cual se disponibiliza \$ 300.00 de prueba, para poder trabajar y aprender sobre los servicios de Google en la nube. Ya disponiendo del token, se procedió a utilizar la librería *ggmap*, mediante esta herramienta y el servicio de Google se georeferenciaron cerca del 90 % de las direcciones, este porcentaje representa un total de 123,312 delitos exitosamente georeferenciados, algunas direcciones fueron descartadas por estar almacenadas de manera inadecuada o eran imposibles de localizar.

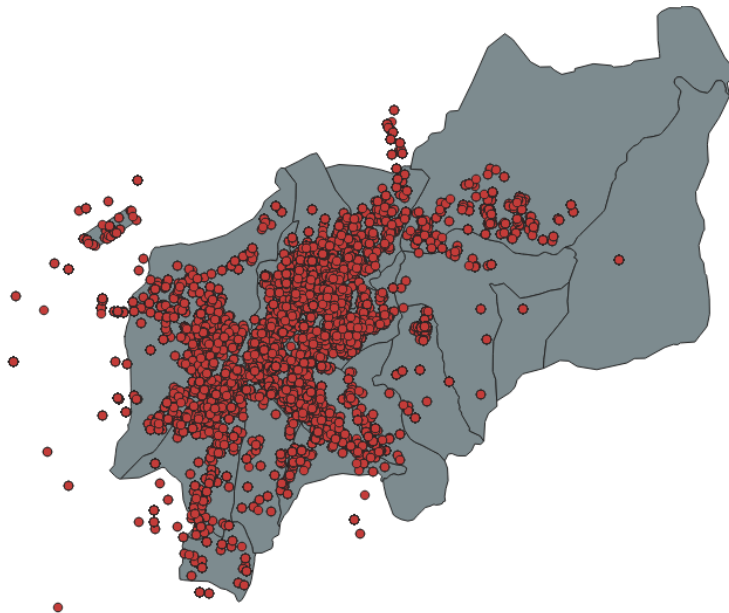
### **3.2. Modelo de puntos de calor optimizado y mapas de calor**

El proceso para análisis geoespacial con la tabla generada depende de una serie de transformaciones a nivel de sistema de información espacial, para posteriormente aplicar los modelos.

### 3.2.1. Levantado de datos en GIS y limpieza

Primeramente se realizó el levantado de los datos con la herramienta QGIS, estos se visualizaban de manera adecuada, algunos de los registros proporcionados por el Ministerio Público se referenciaron fuera de los límites de la ciudad capital, por tanto se encontraban fuera del alcance de este trabajo.

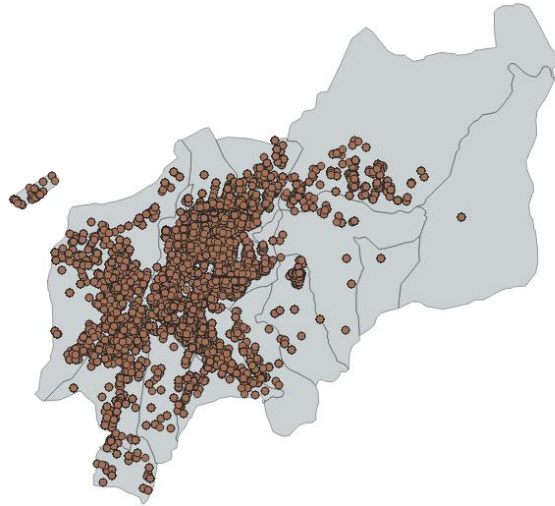
Figura 6. **Distribución geográfica de los delitos**



Fuente: elaboración propia, realizado en QGIS.

Mediante la función *Clip*, se realizó el corte de los delitos fuera de la ciudad, permitiendo generar un conjunto de datos limpio y dentro del alcance definido, este conjunto de datos nuevo es adecuado para realizar el análisis de puntos de calor optimizado.

Figura 7. **Conjunto de datos final**



Fuente: elaboración propia, realizado con QGIS.

### 3.2.2. **Análisis de puntos de calor optimizado**

Para el análisis de puntos de calor optimizado, se hicieron pruebas en la herramienta QGIS, utilizando un plugin especializado, este plugin es experimental, y por tanto se presentaron una serie de problemas con algunas dependencias, específicamente la librería *pysal* del lenguaje *Python*, que si bien se lograron instalar, no fue posible ejecutar el plugin de manera correcta debido a que esta librería no presentaba la clase *classFactory()*, siendo esta requerida por el plugin. Por este motivo se recurrió a la herramienta ArcGIS, la cual incorpora este análisis de manera nativa.

En ArcGIS se utilizó la herramienta *Optimized Hot Spot Analysis* localizado en *ArcToolBox* en el apartado estadístico *Spatial Statistics Tools*, en la librería de *Mapping Clusters*. Generando el correspondiente conjunto de datos que incluye

un Z-score y un P-value según la cercanía y cantidad de ocurrencias de los delitos.

Figura 8. **Resultado del análisis de puntos de calor optimizado**

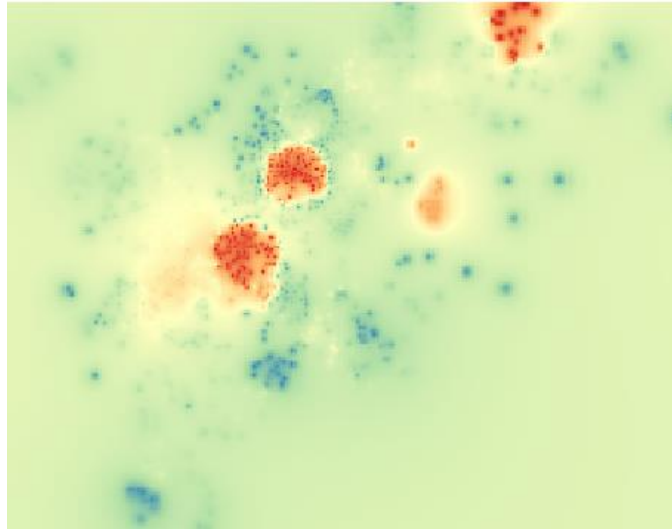


Fuente: elaboración propia, realizado con ArcGIS.

### 3.2.3. Mapa de calor

El conjunto de datos resultante del análisis de puntos de calor optimizado deja espacios vacíos que no permite establecer de manera adecuada el z-score y p-value para la ubicación de las cámaras, por tanto se debía realizar un proceso de estimación que permitiera completar las áreas vacías, en este caso se realizó un mapa de calor con la herramienta QGIS, utilizando interpolación, para este caso se utilizó *Grid Inverse Distance* de grado 2. El resultado de la interpolación presenta un área con valores estimados y se le aplicó escala de color para representar de mejor manera el comportamiento de los delitos según el p-value asignado.

Figura 9. **Mapa de calor de los delitos calculado sobre el análisis optimizado de puntos de calor**



Fuente: elaboración propia, realizado con QGIS.

### **3.3. Identificación del P-Value de las cámaras y análisis para establecer si hay algún patrón definido**

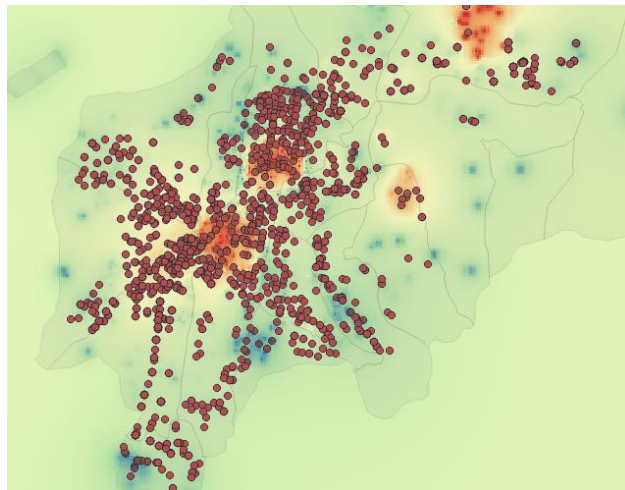
Los datos de las cámaras fueron proporcionados por el Ministerio Público en formato *Shape*, los *Shapes* son un conjunto de archivos que permiten el almacenamiento y manipulación de datos geospaciales. El Ministerio Público creó estos registros de manera manual, ubicando las cámaras una por una en su localización correspondiente.

Para establecer el P-Value de las cámaras, se utilizó como base el resultado del análisis de puntos de calor optimizado que se realizó sobre el *shape* de delitos. Para determinar el P-value de delito de una cámara, se hace la relación con base en su ubicación espacial, aplicando un *Spatial Join*, obteniendo como

resultado un conjunto de datos de las cámaras que incluye además los atributos del resultado del análisis optimizado de puntos de calor.

Mediante ArcGIS, se realizó el *Spatial Join* antes descrito. Continuando con el proceso se debía establecer si se presentaba diferencia estadística entre los puntos calientes y las cámaras, el análisis se realizó sobre los p-values del área estudiada y los p-values asignados por el *Spatial Join* a los puntos geográficos de las cámaras, estos p-value explican qué tan significativa estadísticamente es la cantidad de delitos que ocurren en cualquier posición del plano, a continuación se presenta una figura que describe gráficamente las cámaras sobre el mapa de calor de delitos.

Figura 10. **Cámaras distribuidas geográficamente sobre mapa de calor**

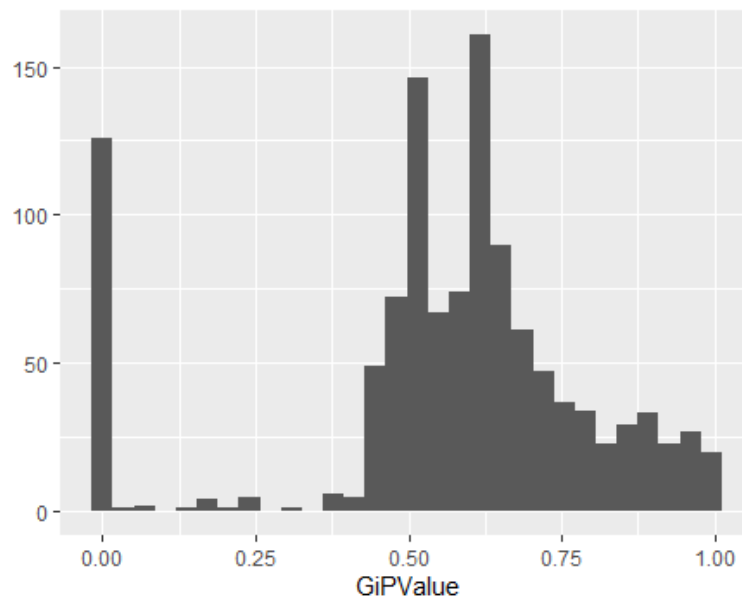


Fuente: elaboración propia, realizado con QGIS.

Para establecer si las cámaras realmente tienen efecto significativo sobre los actos delictivos, se debe realizar el análisis estadístico, se planteaba realizar una diferencia de medias, para lo cual, los datos deben comportarse de forma

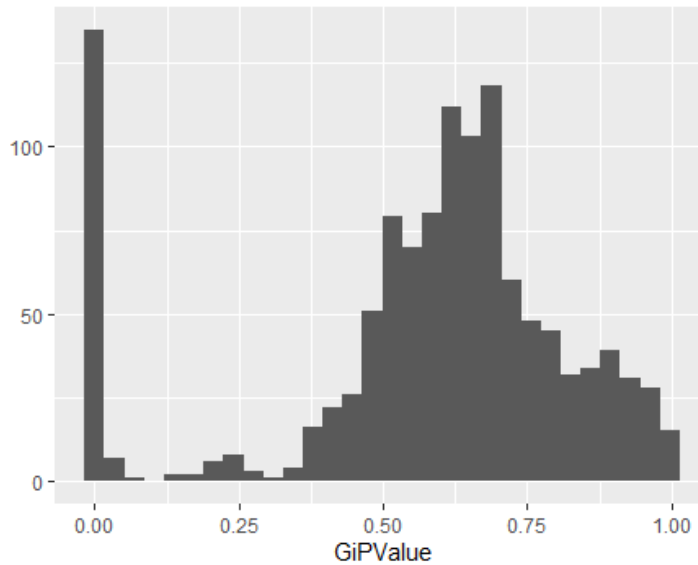
normal, de lo contrario, se deben buscar alternativas para realizar la diferenciación. Por ello, primeramente se analizaron los datos mediante un histograma del p-value asignados a las cámaras y el histograma de los p-values para los delitos.

Figura 11. **Histograma de comportamiento espacial de las cámaras, según su p-value**



Fuente: elaboración propia, realizado con R.

Figura 12. **Histograma de comportamiento espacial de los delitos, según su p-value**



Fuente: elaboración propia, realizado con R.

Para establecer de manera definitiva si los datos se comportan normalmente se aplicó la prueba de Kolmogorov Smirnov.

Tabla II. **Prueba de Kolmogorov-Smirnov del comportamiento espacial de delitos**

<b>Prueba de Kolmogorov-Smirnov</b>	
Datos	Delitos\$GiPValue
p-value	<2.2e-16

Fuente: elaboración propia.



Tabla III. **Prueba de Kolmogorov-Smirnov para el comportamiento delictivo en la ubicación de las cámaras**

<b>Prueba de Kolmogorov-Smirnov</b>	
Datos	Cámara\$GiPValue
p-value	<2.2e-16

Fuente: elaboración propia.

Según las pruebas, los P-value de las cámaras y los delitos no se comportan de forma normal, por tanto, para realizar la comparación entre poblaciones, se debe aplicar una técnica no paramétrica dedicada a este fin, en este caso se aplicó Mann-Whitney-Wilcoxon.

Tabla IV. **Comparación Mann-Whitney-Wilcoxon de poblaciones de cámaras y delitos**

<b>Prueba Mann-Whitney-Wilcoxon</b>	
Datos	Cámaras y Delitos
p-value	0.0001041

Fuente: elaboración propia.

Con base en la prueba Mann-Whitney, se rechaza la hipótesis nula, las poblaciones son significativamente distintas. Interpretándose como la calidez delictiva calculada mediante los puntos de calor optimizados para los delitos sobre el área total y transferida a la ubicación de las cámaras mediante el Spatial Join y posteriormente contrastando estas dos poblaciones (calidez de delitos según su ubicación y calidez de cámaras según su ubicación) utilizando la prueba Mann-Whitney , se establece que la ubicación de las cámaras se comporta

estadísticamente diferente al área delictiva en estudio y por tanto hay un efecto en su utilización en la vía pública.

## **4. DISCUSIÓN DE RESULTADOS**

### **4.1. Análisis de generación de coordenadas geográficas de los actos delictivos**

El proceso de limpieza de datos es fundamental para cualquier análisis, en este caso se presentaba la característica de que los datos debían ser transformados para ser utilizados, puesto que las direcciones en las que ocurren los delitos no son georeferenciadas, únicamente se almacena una dirección en lenguaje natural.

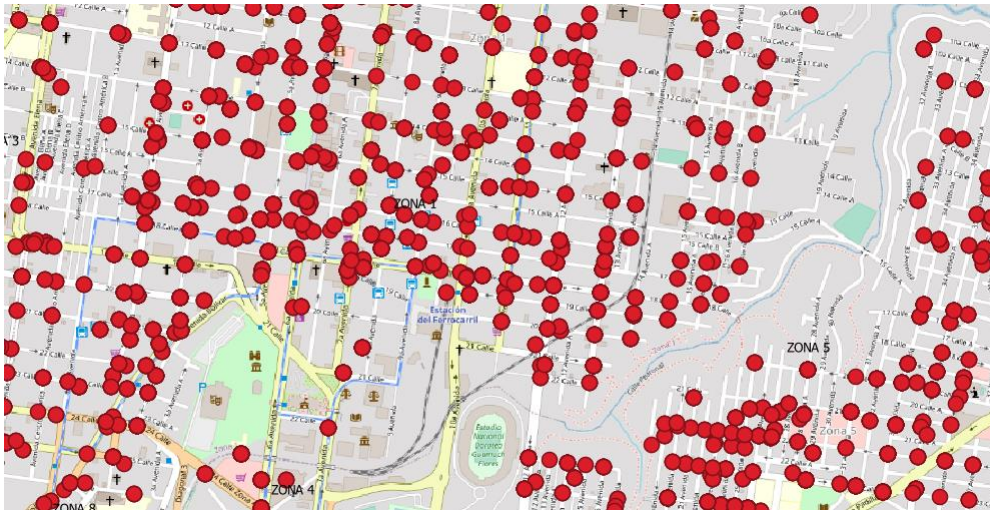
Adicionalmente, el Ministerio Público trasladó los datos en Pdf, formato que no es muy amigable para ser manipulado, por lo cual se agrega complejidad a la preparación y manipulación de los datos.

Esta información, al ser pública, debería ser accesible de manera sencilla, ya sea mediante la utilización de APIs o por medio de un portal web que proporcione descarga de datos en formato CSV o XLSX; los usuarios de la información ahorrarían tiempo en transformación si estos conjuntos de datos fueran accesible en estos formatos y tiempo de espera para la recepción.

Otro factor importante fue la conversión de las direcciones en coordenadas geográficas, en este caso Google brinda el servicio, el problema es el alto costo de la utilización del mismo que puede tener fuerte efecto en el presupuesto de este tipo de proyectos. El Ministerio Público como administrador de esta información y ente investigador, debería recolectar los datos geográficos en el

punto exacto de ocurrencia mediante herramientas como GPS, para poder realizar análisis más precisos.

Figura 13. Resultado de la transformación de direcciones



Fuente: elaboración propia, realizado con QGIS.

En la figura 14 se observa una captura del resultado de la transformación de direcciones a puntos georeferenciados. De esta imagen se puede observar que el resultado de la transformación es satisfactorio, los puntos se alinean con las calles y avenidas donde ocurrieron y es buena base para análisis.

Este conjunto de datos y el proceso de transformación podrían aportar un recurso valioso para el Ministerio Público ya que esta entidad realiza la geolocalización de manera manual, colocando punto por punto en su ubicación lo cual hace que sea complicado y lento obtener una base de datos como la utilizada en este estudio. Si se ejecutara este proceso en la totalidad de los datos que administra el Ministerio Público, se enriquecería su información y abriría las

puertas a la aplicación de técnicas geoestadísticas y análisis espacial, pudiendo ser herramientas de apoyo en investigación y predicción.

#### **4.2. Análisis de puntos de calor optimizado**

Para el análisis geoestadístico, se utilizó una solución de sistemas de información geográfica. Cuando se hizo el levantamiento de los datos en la aplicación SIG, se presentaban datos referenciados fuera del área de la ciudad capital, por tanto, fuera de alcance, por tanto se incluyó un proceso de limpieza de datos adicional a nivel de SIG.

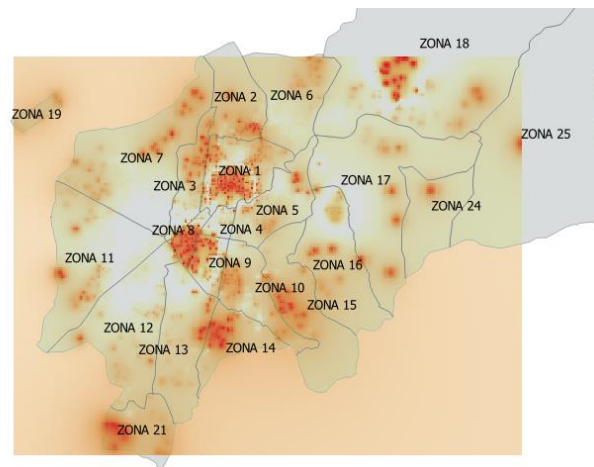
Este proceso de limpieza inició con importar el CSV con las coordenadas, luego se contrastó con el polígono de la ciudad capital, identificando delitos referenciados fuera del área de la ciudad, estos delitos fueron eliminados y se estableció en conjunto de datos definitivo para trabajar el análisis geoestadístico.

Para establecer cómo se comportan geográficamente los delitos, se utilizó el análisis de puntos de calor optimizado, el cual calcula el estadístico  $G_i^*$  de Getis-Ord, este estadístico describe la agrupación de las observaciones, estableciendo puntos calientes y puntos fríos, este mismo análisis da como resultado la conversión de  $G_i^*$  en valores de Z y también P-values. El resultado de este proceso retorna un conjunto de polígonos que incluyen dicho P-value y Z -Score, hacer análisis sobre un conjunto resultante de 1,231 polígonos es complejo y poco práctico.

Para continuar con el análisis, primeramente los polígonos del análisis de puntos de calor optimizado no cubren la totalidad del área de ocurrencia de observaciones y son demasiados para analizarlos uno por uno, debido a esto, se aplicó un proceso de interpolación conocido como variograma, obteniendo un

plano del comportamiento de los delitos y observando detalladamente los puntos calientes en la ciudad.

Figura 14. **Mapa de calor de significancia estadística Gi\***



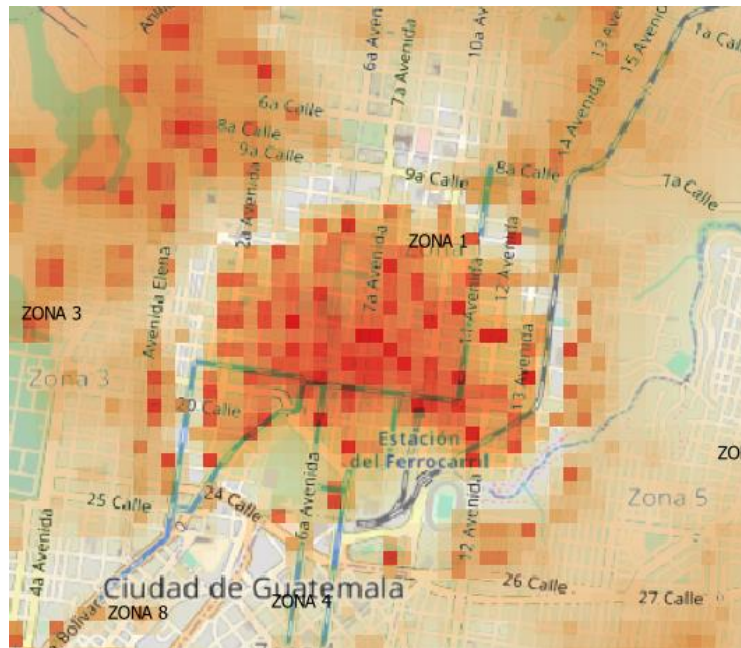
Fuente: elaboración propia, realizado con QGIS.

El comportamiento que describe el variograma destaca la zona 1, zona 8, zona 18, zona 14 y zona 21 como estadísticamente significativas, indicando en escala de rojos, qué tan importante es esa significancia, siendo los rojos claros poco significativos, mientras que los rojos fuertes altamente significativos, entre más alta la significancia, mayor es la cercanía entre las observaciones de los delitos, y por tanto, se puede interpretar que es un área de más alto riesgo si se presenta un rojo fuerte.

El mapa de calor puede utilizarse como instrumento de planificación de mejora de seguridad, tratando de reducir esos puntos rojos, e incluso como forma de comparación, si se aplica alguna estrategia de seguridad, se puede generar un mapa de calor un tiempo después para establecer si el tono de rojo se ha atenuado o reducido su área; dicho efecto significaría una mejora en seguridad,

de lo contrario si no cambia el tono o se amplía el área es que la estrategia no tiene efecto.

Figura 15. Área de concentración de delitos en la Zona 1 de la capital

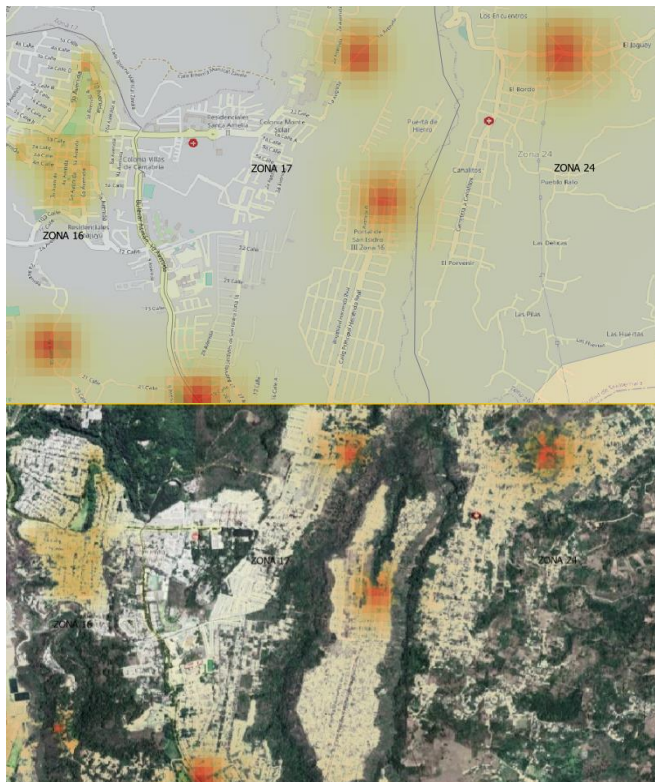


Fuente: elaboración propia, realizado con QGIS.

Según la Figura 17, se observa una circunferencia de alta concentración de delitos, dicha circunferencia tiene como límite norte la décima calle, límite oriente la 14 avenida, límite sur 21 calle y límite oeste primera avenida A todas de la zona 1; esta área de alta significancia está rodeada de un círculo concéntrico de baja significancia, y luego un comportamiento estable, surge la duda de si esto podría ser el territorio de alguna organización que se dedica a delinquir en esta área, ya que es una circunferencia casi perfecta, de hecho, este fenómeno se repite en el área de la zona 8, dicho comportamiento debe ser analizado de manera profunda

mediante nuevos estudios, ya que estos círculos son de área amplia y sumamente cálidos.

Figura 16. **Comportamiento delictivo zonas 16, 17 y 24**



Fuente: elaboración propia, realizado con QGIS.

La figura 17 presenta el comportamiento en un área geográfica relativamente poco delictiva, se observa que el comportamiento aquí es de focos marcados donde tienen lugar los actos delictivos, en la segunda parte de la imagen se visualiza la geografía escabrosa y boscosa que aísla el espacio poblado, esto da lugar a la posibilidad de estudiar si este aislamiento provocado por los numerosos barrancos y bosques que predominan estas zonas tiene algún efecto sobre los actos delictivos. Este comportamiento focal marcado podría ser



aprovechado para proponer proyectos de seguridad específicos para mitigar la calidez de dichos puntos.

El mapa de calor se ajusta únicamente al área que posee registros según el conjunto de datos proporcionado por el Ministerio Público, esa es la razón del porqué no se extiende dicho mapa a la totalidad del área de la ciudad, ya que en el espacio no cubierto de la zona 18 y zona 25 no presentaba ningún acto delictivo registrado allí, por tanto, el aplicativo SIG no generó información para esa área de la ciudad.

#### **4.3. Interpretación del nivel de significancia de la ubicación de las cámaras**

Para interpretar si la ubicación de las cámaras tiene un efecto significativo en la distribución geográfica de los actos delictivos, se debe establecer la significancia estadística del punto geográfico donde estas se localizan. En este caso, se aplicó un *Spatial Join* entre el conjunto de polígonos obtenidos del análisis optimizado de puntos de calor y la ubicación de las cámaras creando un nuevo conjunto de datos con la localización de las cámaras, P-Value y Z-score

Este nuevo conjunto de datos de las cámaras debía ser contrastado con los delitos para ver si provienen de poblaciones estadísticamente distintas, esto indicaría que la significancia de las cámaras es distinta que la población de puntos en general, y por tanto las cámaras tendrían efecto reductivo en la delincuencia.

Para contrastar dos poblaciones se aplicó una diferencia de medias, estableciendo como hipótesis nula que la media de las dos poblaciones fueron iguales, e hipótesis alternativa indicando que media de las poblaciones es

distinta. Antes de aplicar esta prueba, se debe asegurar que las poblaciones se comportan de manera normal.

En este estudio se aplicó la prueba de Kolmogorov-Smirnov debido a que las poblaciones son mayores a 31 observaciones, esto para establecer normalidad en ambos conjuntos de datos (delitos y cámaras), esta prueba establece como hipótesis nula que los datos se comportan de manera normal, por el contrario, la hipótesis alternativa indica que los datos no se comportan de forma normal. El resultado de ambas pruebas, tanto para cámaras como para delitos presentó un p-value cercano a cero, rechazando la hipótesis nula, estableciendo que los datos no se comportan de manera normal. Por tanto, no es posible realizar una diferencia de medias entre los dos conjuntos de datos. El comportamiento no normal es debido a que se está estudiando.

Debido a este problema, se decidió cambiar el enfoque hacia los métodos no paramétricos. Por ser únicamente dos poblaciones, se recurrió a la prueba de Mann-Whitney-Wilcoxon, la cual, por ser del grupo no paramétrico, permite realizar dicha comparación sin tener que asegurar la normalidad de los datos. Según dicha prueba, se rechaza la hipótesis nula, estableciendo que los dos grupos contrastados provienen de poblaciones distintas.

Esto se puede interpretar como un efecto estadísticamente significativo reflejado por la baja calidez de la ubicación de las cámaras comparado con los niveles de calor del área en general indican reducción en los crímenes en la ubicación de cámaras. Ratcliffe, J., Taniguchi, T. y Taylor, T. (2009) presentaron resultados de reducción de delitos por efecto de las cámaras en ciertos tipos de delitos tomados en cuenta en este estudio. La nube del variograma es la forma en que se describe la correlación en un espacio, según la cercanía y la

aglomeración de observaciones, por tanto una geografía puede tener áreas de alta correlación y áreas de baja correlación que se traducen en puntos calientes.

El análisis geoespacial es una disciplina que el Ministerio Público puede explotar de muchas maneras, el mapa de calor es un ejemplo claro de una herramienta que brinda gran cantidad de información y que puede ser utilizado como base en distintos proyectos de seguridad, aumento de presencia policial en puntos calientes, medición del efecto de dichos proyectos, etc.

La geoestadística puede brindar adicionalmente otras capacidades como predicción de eventos, con lo cual se podría lograr predecir en qué ubicación es más probable que ocurra un delito en determinado rango de tiempo, predecir el comportamiento de los puntos de calor en el futuro y planificar de mejor manera.



## CONCLUSIONES

1. Según la prueba de Mann-Whidney, se presenta diferencia estadística significativa entre la ubicación de las cámaras y el comportamiento de los delitos en el área de estudio.
2. Mediante la utilización del API de Google y R para la comunicación, se consiguió establecer las coordenadas espaciales de las direcciones de los actos delictivos.
3. Se calculó el modelo de puntos de calor optimizado con ayuda de ArcGIS y el mapa de calor mediante QGIS de los actos delictivos ocurridos en la ciudad de Guatemala estableciendo los p-value distribuidos en el área de estudio.
4. Según la prueba de Kolmogorov-Smirnov, se rechaza la hipótesis nula, los datos se comportan de manera normal.



## RECOMENDACIONES

1. Recomendar al Ministerio Público mejorar su metodología de levantado de datos, incluyendo coordenadas espaciales y direcciones más precisas.
2. Utilizar en estudios posteriores, datos georeferenciados de origen para obtener más precisión.
3. Proponer un estudio a bajo nivel, enfocado en cada tipo de delito, que podría dar más patrones de comportamiento para cada caso y enfocar acciones para su reducción.
4. Proponer un estudio que genere un modelo de ubicación geográfica de las cámaras, maximizando su efectividad.





## REFERENCIAS

1. Abdulqader, A. (2006). *Spatial Analysis of Criminal Incidents: Implementation of GIS and Spatial Statistics* (Tesis de maestría). Universidad de Carleton, Canadá.
2. Dell'Olmo, P., Ricciardi, N. y Sgalambro, A. (enero, 2013). A Multiperiod Maximal Covering Location Model for the optimal location of intersection safety cameras on an urban traffic network. *Procedia - Social and Behavioral Sciences*, 108(1), 106-117.
3. Fontan, C. (1998). *Derecho Penal Introducción y Parte General*. Buenos Aires, Argentina: Abeledo-Perrot.
4. Gelfand, A., Diggle, P., Fuentes, M. y Guttorp, P. (2010). *Handbook of Spatial Statistics*. Boston, Estados Unidos: CRC Press.
5. Gerell', M. (2016). *Hot Spot Policing With Actively Monitored CCTV Cameras: Does it Reduce Assaults in Public Places?* (Tesis de Maestría). Universidad del estado de Georgia, Estados Unidos.
6. Hengl, T. (2009). *A Practical Guide to Geostatistical Mapping*. Amsterdam, Holanda: European Communities.
7. Journel, A. (2009). *Fundamentals of Geostatistics in Five Lessons*. Washington, Estados Unidos: American Geophysical.

8. Kamilaris, A. y Ostermann, F. (julio, 2018). Geospatial Analysis and the Internet of Things. *International Journal of Geo-Information*, 7(7), 269-291.
9. Lim, H., Eck, J. y Kim, C. (2013). *The crime-reduction effects of open-street CCTV in South Korea* (Tesis de maestría). Universidad de Cincinnati, Estados Unidos.
10. Mitchell, A. (2005). *The ESRI Guide to GIS Analysis, Volume 2: Spatial Measurements and Statistics*. Nueva York, Estados Unidos: Esri Press.
11. Obe, R. y Hsu, L. (2009). *PostGIS in Action*. Estados Unidos: Manning Publications Co.
12. Piza, E., Caplan, J. y Kennedy, L. (mayo, 2014). *Analyzing the Influence of Micro-Level Factors on CCTV Camera Effect*. *Journal of Quantitative Criminology*, 30(2), 237-264.
13. Pucha-Cofrep, F., Et Al.(2018). *Fundamentals of GIS Applications with ArcGIS*. Murcia, España: Ediloja Cia. Ltda.
14. Ratcliffe, J., Taniguchi, T. y Taylor, T. (octubre, 2009). The Crime Reduction Effects of Public CCTV Cameras: A Multi-Method Spatial Approach. *Justice Quarterly*, 26(4), 746-770.
15. Siegel, S. y Castellan, J. (1998). *Estadística no Paramétrica Aplicada a las Ciencias de la Conducta*. México: Editorial Trillas.

16. Smith, M., Goodchild, M. y Longley, P. (2018). *Geospatial Analysis A Comprehensive Guide to Principles, Techniques and Software Tools*. Londres, Reino Unido: The Winchelsea Press. Recuperado de <https://spatialanalysisonline.com/HTML/index.html>.
17. Van Rompay, T., Vonk, D. y Fransen, M. (enero, 2009). The Eye of the Camera Effects of Security Cameras on Prosocial Behavior. *Environment and Behavior*, 41(1), 60-74.
18. Walpole, R., Myers, R., Myers, S. y Ye, K. (2012). *Probabilidad y Estadística para Ingeniería y Ciencias*. México: Pearson.
19. Ways, B. y Pearson, C. (2018). *Evaluating the effectiveness of CCTV in Baltimore, Maryland* (Tesis de maestría). Universidad de Maryland, Estados Unidos.
20. Yaagoubi, R., El Yarmani, M., Kamel, A. y Khemiri, W. (mayo, 2015). HybVOR: A Voronoi-Based 3D GIS Approach for Camera Surveillance Network Placement. *International Journal of Geo-Information*, 4(2), 754-782.