

Identificación de Patrones y Zonas Críticas de Accidentes de Tránsito en Bucaramanga (2012–2023)

Ronald Martínez Bustos

Trabajo de Grado para Optar al Título de Matemático

Director

Fabio Humberto Sepúlveda Murillo
Ph.D. en Matemáticas

Universidad Industrial de Santander
Facultad de Ciencias
Escuela de Matemáticas
Programa de Matemáticas
Bucaramanga
2026

Dedicatoria y agradecimientos

A mis familiares, amigos y profesores, por su esfuerzo y por enseñarme que el estudiar vale la pena. A Fabio Humberto Sepúlveda, mi director, por su guía clara y paciente. A la Universidad Industrial de Santander, por el espacio para aprender y vivir. A quienes compartieron conmigo las horas de trabajo y las dudas. Y a los que estuvieron en el camino, aunque no aparezcan en estas páginas, especialmente a quien, como las profundidades del lago Nes, guarda silencio pero sostiene, y a quien haya hecho más ligero el trayecto.

Índice general

Introducción	12
1. Planteamiento del problema	15
2. Objetivos	17
2.1. Objetivo principal	17
2.1.1. Objetivos específicos	17
3. Marco teórico	18
3.1. Antecedentes de la investigación	18
3.1.1. Estudios sobre patrones temporales de accidentalidad	18
3.1.2. Estudios sobre patrones espaciales y clústeres de accidentes	19
3.1.3. Estudios sobre la participación de actores viales	20
3.1.4. Estudios en el contexto colombiano	20
3.2. Seguridad vial y accidentes de tránsito	21
3.2.1. Definición y clasificación de los accidentes de tránsito	21
3.2.2. Factores de riesgo	22
3.2.3. Impacto en salud pública y contexto urbano	23
3.2.4. Enfoques de análisis en seguridad vial	23
3.3. Medición de la siniestralidad vial	24
3.3.1. Frecuencia de accidentes de tránsito	24
3.3.2. Tasas de accidentalidad y normalización por población	24
3.3.3. Indicadores de gravedad del accidente	25
3.3.4. Limitaciones de las medidas tradicionales	25
3.4. Análisis temporal	26
3.4.1. Concepto de series de tiempo	26
3.4.2. Componentes: tendencia, estacionalidad y variabilidad	28
3.4.3. Teoría de la descomposición STL	29
3.4.4. Teoría de las series de tiempo interrumpidas (ITS)	32

3.4.5.	Patrones temporales en la siniestralidad vial	36
3.4.6.	Importancia del análisis temporal en la identificación de períodos críticos	37
3.4.7.	Análisis Prophet	37
3.5.	Fundamentos de análisis espacial	41
3.5.1.	Conceptos básicos de estadística espacial	41
3.5.2.	Dependencia y heterogeneidad espacial	42
3.5.3.	Unidades espaciales	42
3.5.4.	Representación cartográfica y mapas temáticos	43
3.5.5.	Relevancia del análisis espacial en seguridad vial	43
3.5.6.	Índice de Moran global	44
3.5.7.	Indicadores Locales de Asociación Espacial (LISA)	44
3.5.8.	Identificación de clústeres y zonas críticas	50
3.5.9.	Interpretación de patrones espaciales	50
3.6.	Análisis de la participación de actores viales	51
3.6.1.	Clasificación de actores viales	51
3.6.2.	Interacción entre actores en los accidentes de tránsito	51
3.6.3.	Vulnerabilidad de los actores viales	52
3.6.4.	Importancia del análisis modal en seguridad vial	53
4.	Marco metodológico	54
4.1.	Diseño de la investigación	54
4.2.	Fuente de datos	54
4.3.	Preparación y procesamiento de datos	55
4.3.1.	Limpieza y estandarización de la base de accidentes	55
4.3.2.	Estandarización de nombres de barrio (para integración espacial)	56
4.3.3.	Construcción de variables derivadas	56
4.3.4.	Agregación para análisis espacial por barrio	56
4.3.5.	Unión con datos de población y shapefile	57
4.3.6.	Cálculo de métricas derivadas (para mapas)	57
4.4.	Análisis temporal de los accidentes de tránsito	57
4.4.1.	Distribución por hora, día de la semana y mes	58
4.4.2.	Pruebas diagnósticas de la serie temporal	58

4.4.3.	Análisis de series de tiempo (agregación mensual)	60
4.4.4.	Modelo Prophet (análisis complementario de patrones temporales)	61
4.5.	Análisis espacial de la siniestralidad vial	63
4.5.1.	Cálculo de tasas y normalización	63
4.5.2.	Representación cartográfica	65
4.5.3.	Autocorrelación espacial (Índice de Moran global)	66
4.5.4.	Identificación de clusters (LISA)	68
4.6.	Análisis de la participación de actores viales	69
4.6.1.	Frecuencias y perfiles por gravedad	69
4.6.2.	Análisis de co-ocurrencia de vehículos	69
4.6.3.	Análisis temporal por tipo de vehículo (series mensuales)	70
4.7.	Herramientas computacionales	70
5.	Análisis y resultados	72
5.1.	Análisis descriptivo general	72
5.1.1.	Resumen estadístico general	72
5.1.2.	Distribución geográfica por comuna	72
5.1.3.	Tasas de involucramiento por comuna (estandarizadas por población)	74
5.2.	Análisis temporal de la siniestralidad vial	76
5.2.1.	Distribución por franja horaria	76
5.2.2.	Distribución por día de la semana	77
5.2.3.	Horas pico y densidad horaria	80
5.2.4.	Análisis Prophet	82
5.2.5.	Análisis de series de tiempo	86
5.2.6.	Reducción de accidentes en 2022–2023 y posibles efectos de la Ley 2251 de 2022	104
5.2.7.	Resumen del análisis temporal	105
5.3.	Análisis espacial de la siniestralidad	107
5.3.1.	Estadísticas generales de accidentalidad	107
5.3.2.	Análisis Espacial	108
5.3.3.	Autocorrelación espacial global: estadístico <i>I</i> de Moran	108
5.3.4.	Autocorrelación espacial local: indicadores LISA	109
5.3.5.	Distribución de barrios según categorías de accidentalidad	112

5.3.6.	Involucramiento por tipo de vehículo	113
5.3.7.	Análisis espacial: mapas temáticos	115
5.3.8.	Gráficos estadísticos complementarios	119
5.3.9.	Barrios con mayor frecuencia de accidentes	121
5.3.10.	Síntesis del análisis espacial	123
5.4.	Análisis modal	124
5.4.1.	Análisis de co-ocurrencia entre tipos de vehículos	124
5.4.2.	Involucramiento por gravedad del accidente	127
5.4.3.	Evolución temporal del involucramiento por tipo de vehículo	128
5.4.4.	Vehículos más involucrados por franja horaria y día de la semana	129
5.5.	Resultados del análisis de tasas estandarizadas por población	133
5.5.1.	Tasas de accidentalidad por comuna	134
5.5.2.	Tasas de accidentalidad por barrio	135
5.5.3.	Tasas de involucramiento por tipo de vehículo a nivel de comuna	137
5.5.4.	Análisis por cuadrantes de accidentalidad	138
5.5.5.	Análisis espacial de las tasas estandarizadas	142
5.5.6.	Resumen	148
6.	Conclusiones y recomendaciones	150
6.1.	Conclusiones según objetivos	150
6.2.	Recomendaciones	152
6.2.1.	Para las Autoridades de Tránsito	152
6.2.2.	Para la Planeación Urbana	153
6.2.3.	Para Futuras Investigaciones	153
	Referencias bibliográficas	159

Índice de figuras

5.1. Mapa de calor de tasas de involucramiento (por 1.000 hab)	75
5.2. Heatmap de accidentes por franja horaria y gravedad	77
5.3. Heatmap de accidentes por día de la semana y franja horaria	80
5.4. Distribución de densidad de accidentes por hora del día	82
5.5. Descomposición de componentes de Prophet	83
5.6. Funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) de la serie.	88
5.7. Descomposición STL de la serie mensual de accidentes	89
5.8. Patrón estacional de accidentes por año	91
5.9. Subseries mensuales (cada panel muestra un mes a lo largo de los años)	92
5.10. Distribución de accidentes por mes (rombo = media)	93
5.11. Mapa de calor de accidentalidad mensual por año	94
5.12. Evolución mensual del involucramiento por tipo de vehículo	96
5.13. Análisis de Series de Tiempo Interrumpidas	99
5.14. Mapa de clústeres LISA de accidentalidad vial en Bucaramanga (2012–2023)	110
5.15. Mapa de categorías de accidentalidad basado en el número total de accidentes por barrio	116
5.16. Mapa de accidentes con heridos	117
5.17. Porcentaje de accidentes en los que participaron motocicletas	118
5.18. Mapa de densidad de accidentes (frecuencia absoluta)	119
5.19. Top 10 barrios con mayor número de accidentes	120
5.20. Distribución porcentual de accidentes según tipo de vehículo involucrado	121
5.21. Mapa de calor de co-ocurrencia	126
5.22. Involucramiento de vehículos por gravedad del accidente	128
5.23. Involucramiento de vehículos por franja horaria	133
5.24. Clasificación de barrios por cuadrantes de priorización	140
5.25. Distribución de barrios, accidentes y población por cuadrante	141
5.26. Top 10 barrios por tasa en cada cuadrante	142
5.27. Mapa coroplético de la tasa anual de accidentalidad por barrio	144
5.28. Categorización de la accidentalidad por barrio a partir de la tasa estandarizada	146

5.29. Distribución espacial de los cuadrantes de priorización 147

Lista de tablas

3.1. Clasificación de unidades espaciales según el diagrama de Moran local	48
4.1. Variables utilizadas en el estudio, tipo y uso	55
4.2. Pruebas diagnósticas aplicadas a la serie temporal	59
5.1. Resumen estadístico general	72
5.2. Frecuencia absoluta de vehículos involucrados por comuna (principales comunas)	74
5.3. Distribución de accidentes por franja horaria	76
5.4. Distribución de accidentes por día de la semana	78
5.5. Top 10 horas con más accidentes	81
5.6. Efecto estimado del día de la semana sobre la accidentalidad diaria	85
5.7. Festivos nacionales con mayor impacto negativo sobre la accidentalidad diaria	86
5.8. Resumen de la descomposición STL	90
5.9. Estadísticas mensuales de accidentes (2012–2023)	95
5.10. Resumen del cambio estructural detectado (AMOC)	97
5.11. Diagnóstico de autocorrelación en el modelo ITS	98
5.12. Coeficientes del modelo ITS con corrección AR(1)	98
5.13. Evolución del total de vehículos involucrados en accidentes por año	101
5.14. Resumen estadístico temporal	106
5.15. Resumen general de accidentes por barrio	108
5.16. I de Moran global	108
5.17. Barrios clasificados como <i>hotspot</i> (High-High) en el análisis LISA	112
5.18. Distribución de barrios por categoría de accidentalidad	113
5.19. Frecuencia y porcentaje de accidentes según tipo de vehículo involucrado	114
5.20. Top 15 barrios con mayor número de accidentes	122
5.21. Matriz de co-ocurrencia entre tipos de vehículos (accidentes compartidos)	125
5.22. Frecuencia absoluta de vehículos involucrados por año	129
5.23. Vehículos más involucrados por franja horaria (extracto)	131

5.24. Vehículos más involucrados por día de la semana (extracto)	132
5.25. Top 8 comunas por tasa de accidentalidad (por 1.000 hab/año)	135
5.26. Top 20 barrios por tasa de accidentalidad (por 1.000 hab/año)	136
5.27. Top 10 comunas por tasa de motocicletas involucradas (por 1.000 hab)	137
5.28. Resumen de barrios por cuadrante	139
5.29. Distribución de barrios por categoría de accidentalidad (tasa estandarizada por 1.000 hab)	145
1. Fuentes de datos de accidentes de tránsito	160
2. Especificaciones del entorno de desarrollo	161

Lista de apéndices

1. Apéndice A: Base de datos
2. Apéndice B: Códigos de programación

Introducción

Los accidentes de tránsito constituyen un problema crítico de salud pública y seguridad vial a nivel mundial. Más allá de las estadísticas, estas cifras representan pérdidas humanas, sensación de inseguridad vial y una carga económica para los sistemas de salud. Según la Organización Mundial de la Salud (OMS, 2023), cada año fallecen aproximadamente 1.3 millones de personas por esta causa, y entre 20 y 50 millones sufren lesiones no mortales que, en muchos casos, dejan secuelas permanentes. Lo más alarmante es que los jóvenes de 5 a 29 años son el grupo más afectado en la mayoría de los países. En Colombia, el Instituto Nacional de Medicina Legal (INML, 2022) reportó 6.752 muertes por accidentes de tránsito en 2021, con una tasa de 13,1 por cada 100.000 habitantes. Esta magnitud evidencia la urgencia de comprender cómo se distribuyen los siniestros en el territorio para orientar acciones de prevención basadas en evidencia.

En el contexto específico de Bucaramanga, la situación no es menos compleja. El acelerado crecimiento del parque automotor, los problemas recurrentes de congestión vehicular y la convivencia forzada de distintos modos de transporte (buses, motocicletas, bicicletas y peatones) en espacios urbanos cada vez más limitados han convertido la seguridad vial en un tema prioritario. Un estudio de la Universidad Industrial de Santander estimó que la ciudad sufrió una pérdida económica de \$47.198 millones de pesos colombianos en 2023 solo por la muerte de 23 personas en accidentes de tránsito (Beltran, 2023). Durante el período 2012–2023 se registraron 39.193 accidentes, de los cuales el 48,4 % dejaron heridos y el 1,6 % fueron fatales. Estas cifras justifican la necesidad de analizar el fenómeno con detalle para identificar cuándo, dónde y qué actores viales se ven más involucrados.

A nivel internacional, se han desarrollado estudios que integran dimensiones espaciales y temporales para la identificación de patrones de siniestralidad. Por ejemplo, Anselin (1995) introdujo los Indicadores Locales de Asociación Espacial (LISA) para detectar clústeres de concentración de accidentes, metodología aplicada con éxito en ciudades como Teherán Effati et al. (2015) y Nueva York Thakali et al. (2015). En Colombia, existen investigaciones sobre accidentalidad en ciudades principales: Fox et al. (2015) analizaron la distribución espacial de las muertes de peatones en Cali, y en Castañeda-Millán y Eslava-Schmalbach (2024) estudiaron las tendencias de mortalidad en motocicleta a nivel nacional. Para

Bucaramanga, la Secretaria de Transito y Transporte (STTB, 2020) ha publicado informes descriptivos que identifican las comunas con mayor frecuencia de accidentes, pero sin aplicar técnicas de estadística espacial ni integrar el análisis temporal y modal de forma simultánea. En consecuencia, existe un vacío de conocimiento: son escasas las investigaciones que integren las dimensiones temporal, espacial y modal en ciudades intermedias colombianas como Bucaramanga. En particular, no se han explotado sistemáticamente herramientas como los Sistemas de Información Geográfica (SIG), el índice de Moran o los indicadores LISA para identificar clústeres de siniestralidad a nivel de barrio, ni se ha caracterizado la evolución temporal de la participación de distintos actores viales durante un período prolongado.

El presente trabajo tiene como propósito caracterizar la distribución de los accidentes de tránsito en Bucaramanga entre 2012 y 2023 desde tres dimensiones complementarias: (i) temporal, mediante el análisis de horas, días y meses de mayor ocurrencia; (ii) espacial, a través de la identificación de zonas críticas y patrones de agrupamiento por barrio; y (iii) modal, examinando la participación de motocicletas, automóviles, peatones y otros actores viales. El interés principal no es explicar causalmente los accidentes ni modelar factores de siniestralidad, sino identificar patrones de ocurrencia y zonas de concentración de siniestros que permitan orientar futuras intervenciones en seguridad vial.

Para llevar a cabo este propósito, el estudio se apoya en un conjunto de procedimientos estadísticos y de análisis de datos que, sin necesidad de recurrir a modelos causales complejos, permiten extraer información valiosa de los registros de accidentes. En primer lugar, se realiza una exploración descriptiva completa de las variables disponibles: frecuencias, porcentajes, distribuciones por hora, día, mes y año. Eso da una primera radiografía de lo que ha ocurrido en Bucaramanga durante más de una década. Adicionalmente, para entender la evolución temporal de la siniestralidad, se aplican técnicas que descomponen la serie de accidentes en sus componentes fundamentales: la tendencia de largo plazo, que indica si el número de accidentes ha aumentado, disminuido o se ha mantenido estable; la estacionalidad, que revela si hay ciertos meses o días de la semana donde sistemáticamente ocurren más siniestros; y el efecto de días especiales, como los festivos, que suelen modificar los patrones habituales de movilidad. Estos procedimientos, ampliamente utilizados en el análisis de fenómenos que cambian en el tiempo, permiten identificar con claridad cuáles son los momentos críticos en los que deberían intensificarse las campañas de prevención y los operativos de control.

En segundo lugar, el estudio incorpora un análisis espacial que va más allá de identificar

qué barrios tienen más accidentes: examina si estos se distribuyen al azar o tienden a agruparse en el territorio, detectando donde la concentración de siniestros es estadísticamente significativa. Todo ello se complementa con representaciones gráficas que facilitan la comprensión de los resultados. Finalmente, la información de todas las dimensiones se integra en un diagnóstico completo que señala patrones recurrentes (horas pico, días y meses más conflictivos), actores viales predominantes (motocicletas, automóviles, peatones, bicicletas) y barrios con altas tasas de accidentalidad ajustadas por población. De esta manera, el trabajo pretende ofrecer a las autoridades, planeadores urbanos y ciudadanía una herramienta sólida para diseñar estrategias de prevención más focalizadas y efectivas.

De todo lo anterior se desprende una necesidad clara: no basta con saber cuántos accidentes ocurren en Bucaramanga, sino que se requiere entender con precisión cuándo suceden, en qué lugares se concentran y qué tipos de vehículos o actores viales están involucrados con mayor frecuencia. La literatura revisada muestra que, aunque existen estudios descriptivos a nivel nacional y local, todavía es escaso el conocimiento integrado que articule las dimensiones temporal, espacial y modal de la siniestralidad en una ciudad intermedia como Bucaramanga durante un período prolongado. Sin esa visión de conjunto, las autoridades enfrentan serias dificultades para focalizar sus intervenciones y asignar recursos de manera eficiente.

En consecuencia, existe un vacío de conocimiento: son escasas las investigaciones que integren las dimensiones temporal, espacial y modal en ciudades intermedias colombianas como Bucaramanga. En particular, no se han explotado sistemáticamente herramientas como los Sistemas de Información Geográfica (SIG), el índice de Moran o los indicadores LISA para identificar clústeres de siniestralidad a nivel de barrio, ni se ha caracterizado la evolución temporal de la participación de distintos actores viales durante un período prolongado.

1 Planteamiento del problema

A nivel mundial, los accidentes de tránsito se encuentran entre las primeras causas de muerte y discapacidad, generando no solo pérdidas humanas, sino también graves afectaciones económicas y el colapso de los servicios de salud. La OMS (2023) señala que alrededor de 1.3 millones de personas mueren cada año a causa de estos siniestros, mientras que entre 20 y 50 millones resultan heridas, muchas de ellas con lesiones irreversibles. Resulta especialmente preocupante que el grupo etario más afectado sea el de los jóvenes de 5 a 29 años, lo que hace de la siniestralidad vial una amenaza para el desarrollo futuro de las sociedades. Además, la mortalidad se concentra desproporcionadamente en países de ingresos bajos y medios, donde ocurre más del 90 % de las muertes, debido a políticas de seguridad vial débiles y una infraestructura inadecuada. Colombia no es la excepción; según el Instituto Nacional de Medicina Legal se registran lo que equivale a una tasa de 13,1 por cada 100.000 habitantes, significativamente más alta que la de países con mejores indicadores en seguridad vial INML (2022). A ello se suman los altos costos económicos: estudios del Banco Mundial estiman que los siniestros viales representan entre el 1 % y el 3 % del Producto Interno Bruto anual de cada país World Bank (2017).

En el contexto de Bucaramanga, el parque automotor ha crecido aceleradamente en la última década, las vías se congestionan a diario y distintos modos de transporte buses, motocicletas, bicicletas y peatones compiten por un espacio urbano limitado, lo que genera condiciones propicias para los siniestros. Entre 2012 y 2023 se registraron 39.193 accidentes de tránsito en la ciudad. De ellos, 18.982 (48,4 %) dejaron personas heridas, 609 (1,6 %) fueron fatales y la proporción de accidentes ocurridos en horario nocturno alcanzó el 29,7 %. El impacto económico también es significativo: solo por la muerte de 23 personas en 2023, la ciudad sufrió una pérdida económica estimada en \$47.198 millones de pesos colombianos, lo que equivale al 0,05 % del Producto Interno Bruto departamental (Beltran, 2023).

Además, la composición de los accidentes ha cambiado notablemente. Las motocicletas, que en 2012 participaban en el 26,8 % de los siniestros, aumentaron su involucramiento al 46,8 % en 2023, mientras que los automóviles redujeron su participación del 39,5 % al 25,6 % en el mismo período. Este cambio en el perfil de los actores viales plantea nuevos retos para las políticas de prevención, pues los motociclistas son usuarios especialmente vulnerables.

A pesar de la magnitud de la problemática y de la existencia de registros históricos de accidentes, el conocimiento sobre cómo se distribuyen los siniestros dentro de Bucaramanga es todavía limitado. Las autoridades locales requieren información detallada para responder preguntas fundamentales: ¿cuándo ocurren los accidentes (dimensión temporal)? ¿dónde se concentran (dimensión espacial)? ¿qué actores viales participan con mayor frecuencia (dimensión modal)? Los estudios disponibles se centran en grandes ciudades como Bogotá o Medellín, y para Bucaramanga predominan los informes descriptivos que identifican las comunas con más accidentes, pero sin aplicar técnicas de estadística espacial ni integrar las tres dimensiones de manera simultánea STTB (2020).

En particular, no se han explotado herramientas como los sistemas SIG, el índice de Moran o los indicadores LISA para identificar clústeres de siniestralidad a nivel de barrio, ni se ha caracterizado la evolución temporal de la participación de los distintos actores viales durante un período prolongado. Este vacío de conocimiento tiene consecuencias prácticas: sin un diagnóstico territorial fino, las intervenciones de seguridad vial tienden a ser genéricas o mal focalizadas, lo que reduce su efectividad y desperdicia recursos escasos. La ausencia de análisis que articulen cuándo, dónde y con qué actores ocurren los accidentes impide diseñar estrategias adaptadas a cada zona y a cada tipo de usuario.

En consecuencia, resulta necesario analizar de manera conjunta las dimensiones temporal, espacial y modal de los accidentes de tránsito en Bucaramanga, con el fin de identificar patrones recurrentes, zonas críticas de siniestralidad y actores viales predominantes que contribuyan a una mejor comprensión del fenómeno. Por ello, este estudio se desarrolla alrededor de la siguiente pregunta de investigación: ¿Cuáles son los patrones espacio-temporales y modales de los accidentes de tránsito ocurridos en Bucaramanga entre 2012 y 2023, y cómo pueden estos patrones contribuir a la identificación de zonas críticas y actores viales predominantes para orientar futuras acciones de seguridad vial?

2 Objetivos

2.1. Objetivo principal

Caracterizar el fenómeno de los accidentes de tránsito en Bucaramanga durante el período 2012 - 2023, a partir de sus dimensiones temporales, espaciales y modales, con el fin de identificar patrones recurrentes, zonas críticas y actores viales predominantes que permitan orientar futuras intervenciones en seguridad vial.

2.1.1 *Objetivos específicos*

- Analizar la distribución de accidentes por horas, días y meses para detectar períodos de mayor riesgo.
- Analizar la distribución espacial de la tasa de siniestralidad vial por barrio y su asociación con la proximidad a puntos críticos identificados.
- Examinar la participación de motocicletas, vehículos particulares, peatones en los accidentes de tránsito y la interacción entre todos los actores viales recopilados en la base de datos.

3 Marco teórico

Los accidentes de tránsito han sido estudiados desde múltiples perspectivas, pero no todas ellas resultan pertinentes para una investigación que busca caracterizar patrones de ocurrencia más que explicar causas. A continuación, se revisan los antecedentes empíricos que resultan relevantes para este trabajo, organizados en seis bloques: antecedentes de investigación relacionados con este estudio, seguridad vial, medición de la siniestralidad vial, análisis temporales, fundamentos sobre análisis espacial y participación de actores viales.

3.1. Antecedentes de la investigación

3.1.1 *Estudios sobre patrones temporales de accidentalidad*

Una de las líneas de investigación más consolidadas es la que analiza cómo varía el número de accidentes en el tiempo. Desde mediados del siglo pasado, investigadores como Norden et al. (1956) documentaron que los siniestros viales no se distribuyen uniformemente a lo largo del día, la semana o el año, sino que presentan concentraciones sistemáticas en ciertas horas y días. Estudios posteriores profundizaron en estos patrones: Quddus (2008) demostraron que los conteos de accidentes suelen presentar autocorrelación temporal, es decir, que lo que ocurre un mes influye en lo que ocurre al siguiente, lo que obliga a utilizar métodos estadísticos que tengan en cuenta esa dependencia. En la misma línea, Razzaghi et al. (2013) mostraron que la descomposición de una serie temporal de accidentes en tendencia, estacionalidad y residuos permite identificar si el fenómeno tiene un comportamiento cíclico predecible o si responde más bien a fluctuaciones aleatorias.

En años recientes, el análisis temporal de la siniestralidad vial ha experimentado avances significativos impulsados por la disponibilidad de grandes volúmenes de datos y el desarrollo de nuevas técnicas computacionales. Kolivand et al. (2024) aplicaron modelos de series de tiempo interrumpidas comparativas (CITS) para evaluar el impacto de las restricciones por COVID-19 en la accidentalidad de autopistas interestatales, demostrando que estas medidas se asociaron con reducciones inmediatas y significativas en los siniestros con heridos leves y en aquellos que involucran un solo vehículo. Asimismo, Apichai Tongpradubetch (2024) utilizaron modelos SARIMA e ITS para analizar el impacto de la

COVID-19 en Tailandia, evidenciando que las medidas de confinamiento y cierre de lugares de entretenimiento redujeron significativamente los accidentes por exceso de velocidad y conducción bajo efectos del alcohol.

La evidencia reportada en estos trabajos sugiere que en contextos urbanos muy diversos, los accidentes tienden a concentrarse en las horas pico de movilidad (generalmente al mediodía y al atardecer), en los días viernes y sábados, y en ciertos meses del año que coinciden con temporadas de mayor actividad comercial o festividades. Sin embargo, la mayoría de estos estudios se han realizado en países de ingresos altos, y no necesariamente sus hallazgos son transferibles de manera directa a ciudades intermedias colombianas, donde la composición del parque automotor y los patrones de desplazamiento son muy distintos.

3.1.2 Estudios sobre patrones espaciales y clústeres de accidentes

Otra corriente importante es la que se ocupa de la dimensión geográfica de la siniestralidad. Generalmente se trabaja bajo el supuesto de que los accidentes no ocurren de manera aleatoria en el territorio, sino que tienden a agruparse en lugares específicos, conocidos como *hotspots* o puntos negros. Anselin (1995) propuso los indicadores LISA, una metodología que permite identificar clústeres estadísticamente significativos y distinguir entre zonas donde la alta accidentalidad se debe a factores locales de aquellas donde es simplemente un reflejo de la alta densidad de tránsito.

Diversos estudios han aplicado estas técnicas en diferentes latitudes. Por ejemplo, Effati et al. (2015) utilizaron el índice de Moran y el análisis LISA para identificar zonas críticas en la red vial de Irán, encontrando que los clústeres de alta siniestralidad no siempre coinciden con los sectores de mayor volumen vehicular, lo que sugiere la presencia de factores territoriales específicos. Por su parte, Thakali et al. (2015) combinaron métodos de densidad de kernel con estadística espacial en el estado de Nueva York, demostrando que la identificación de puntos negros mejora sustancialmente cuando se tiene en cuenta la dependencia espacial entre unidades vecinas.

En América Latina, Fox et al (2015) analizaron la distribución de las muertes de peatones en Cali, Colombia, y encontraron que estas se concentran en corredores viales de alta velocidad y en intersecciones sin semáforo, lo que evidencia que el análisis espacial puede revelar patrones que no son evidentes con simples recuentos de frecuencia. Estos antecedentes resultan especialmente valiosos para este trabajo, pues muestran que la metodología LISA y el índice de Moran son herramientas adecuadas para el estudio de la accidentalidad en ciudades de tamaño medio.

3.1.3 *Estudios sobre la participación de actores viales*

No todos los usuarios de la vía enfrentan el mismo nivel de exposición ni las mismas consecuencias cuando ocurre un accidente. La literatura ha puesto un énfasis creciente en los llamados *usuarios vulnerables*: peatones, ciclistas y motociclistas. Peden et al. (2004) documentaron que, a pesar de representar una fracción minoritaria de los viajes, estos grupos concentran más de la mitad de las muertes por tránsito a nivel mundial.

El caso de los motociclistas es particularmente relevante en países de ingresos medios, donde la motocicleta se ha convertido en el principal medio de transporte para amplios sectores de la población. Oluwaseun et al. (2019) analizaron la accidentalidad de motociclistas en Nigeria y concluyeron que su sobrerrepresentación en las estadísticas de víctimas fatales se explica por una combinación de menor protección física, mayor exposición al tráfico mixto y la frecuente circulación por vías de alta velocidad. En el contexto europeo, Yannis et al. (2017) confirmaron que el riesgo de muerte por kilómetro recorrido es entre 15 y 20 veces mayor para los motociclistas que para los ocupantes de automóviles.

Otro aspecto que ha sido menos explorado, pero que resulta fundamental para entender la dinámica de los siniestros, es la interacción entre distintos tipos de actores en un mismo accidente. Como señalan Elvik et al. (2009a), los accidentes multivehículo involucran procesos de co-participación que deben analizarse explícitamente para identificar las combinaciones de mayor riesgo. El análisis de co-ocurrencia (esto es, la frecuencia con que dos tipos de vehículos aparecen juntos en un mismo siniestro) se ha mostrado como una herramienta descriptiva muy útil en este sentido.

3.1.4 *Estudios en el contexto colombiano*

Colombia tiene una de las tasas de mortalidad por accidentes de tránsito más altas de América Latina. Según el Instituto Nacional de Medicina Legal INML (2022), en 2021 se registraron 6.752 muertes, con una tasa de 13,1 por cada 100.000 habitantes. Los motociclistas representaron el 55 % del total de fallecidos, lo que evidencia la magnitud del problema para este actor vial.

En cuanto a estudios específicos, Castañeda-Millán y Eslava-Schmalbach (2024) analizaron la evolución de la mortalidad en motocicleta en Colombia entre 2008 y 2021, encontrando una tendencia creciente en ciudades intermedias, precisamente donde la moto ha reemplazado a otros modos de transporte. Montenegro-Martínez et al. (2023) estudiaron la mortalidad de peatones y ciclistas en el país,

destacando que los patrones espaciales de estos grupos difieren sustancialmente de los de los ocupantes de vehículos motorizados.

Para Bucaramanga, la secretaría de tránsito ha publicado informes periódicos STTB (2020) que identifican las comunas con mayor número de accidentes (Centro, San Francisco y Cabecera del Llano) y señalan a las motocicletas como el vehículo más frecuentemente involucrado. Sin embargo, estos informes se basan exclusivamente en frecuencias absolutas y no aplican técnicas de estadística espacial para determinar si las concentraciones observadas son estadísticamente significativas, ni integran el análisis temporal con el modal. Tampoco se han explotado herramientas como los indicadores LISA o el índice de Moran a nivel de barrio en esta ciudad.

De esta manera, se configura un vacío de conocimiento: a pesar de los avances existentes en el ámbito internacional y nacional, no se identifican estudios que integren simultáneamente el análisis temporal, espacial y modal de los accidentes de tránsito en Bucaramanga durante un período prolongado de observación. Este trabajo busca contribuir a llenar esa laguna, proporcionando una caracterización integral que sirva de base para intervenciones más focalizadas.

3.2. Seguridad vial y accidentes de tránsito

3.2.1 Definición y clasificación de los accidentes de tránsito

Un accidente de tránsito se define como todo evento no deseado que ocurre en la vía pública e involucra al menos un vehículo en movimiento, causando daños materiales, lesiones o muerte Organización Mundial de la Salud (2018). Esta definición, adoptada por la mayoría de los sistemas de registro institucional, engloba una amplia variedad de eventos que difieren en severidad, modalidad de participación y contexto de ocurrencia.

En Colombia, el Código Nacional de Tránsito (Ley 769 de 2002) define el accidente de tránsito como «un evento generalmente involuntario, generado al menos por un vehículo en movimiento, que causa daños a personas y bienes involucrados en él e igualmente afecta la normal circulación de los vehículos que se movilizan por la vía o vías comprendidas en el lugar o dentro de la zona de influencia del hecho». Esta definición legal establece los criterios de registro que utiliza la Secretaría de Tránsito y que constituyen la fuente de datos del presente estudio.

La clasificación de los accidentes de tránsito puede realizarse según múltiples criterios. Por su tipo, se distinguen los choques, los atropellos, las volcaduras y los incendios. Por su gravedad, se clasifican en accidentes con solo daños materiales, con heridos y con víctimas fatales. Por su localización, se diferencian los ocurridos en intersecciones, en tramos rectos, en curvas y en zonas de trabajo. Cada uno de estos criterios ofrece información complementaria sobre los mecanismos causales y las posibilidades de intervención preventiva.

3.2.2 Factores de riesgo

La literatura identifica múltiples factores asociados a la ocurrencia de accidentes de tránsito, entre ellos factores humanos, vehiculares, ambientales e infraestructurales. No obstante, el presente estudio no busca analizar dichos factores de manera causal, sino caracterizar la distribución espacial, temporal y modal de los accidentes registrados en Bucaramanga.

Los factores humanos son los más frecuentemente citados en la literatura y comprenden la velocidad excesiva o inapropiada, la conducción bajo los efectos del alcohol o sustancias psicoactivas, la distracción al volante, el incumplimiento de normas de tránsito y la fatiga del conductor Elvik et al. (2009b). Estudios de reconstrucción de accidentes estiman que los factores humanos están presentes en más del 90 % de los siniestros como causa principal o contributiva Treat et al. (1979).

Los factores vehiculares incluyen el estado mecánico del vehículo (frenos, neumáticos, luces), la ausencia o deficiencia de sistemas de seguridad pasiva (cinturones, airbags, cascots) y las características de diseño que condicionan la visibilidad del conductor. La edad del parque automotor tiene una incidencia particular en países en desarrollo, donde una alta proporción de vehículos no cuenta con los equipamientos de seguridad estándar de los modelos recientes.

Los factores ambientales abarcan las condiciones de la infraestructura vial (señalización, demarcación, estado del pavimento, diseño geométrico), las condiciones climáticas (lluvia, niebla, intensidad luminosa) y el entorno urbano circundante (densidad de comercio, confluencia de flujos peatonales, presencia de instituciones educativas). Lord y Mannering (2010) destaca que el diseño de la infraestructura es el factor sobre el cual las políticas públicas tienen mayor capacidad de intervención a largo plazo, dado que los factores humanos son considerablemente más difíciles de modificar de forma sostenida.

3.2.3 Impacto en salud pública y contexto urbano

Los accidentes de tránsito representan uno de los principales problemas de salud pública a escala global. La carga de enfermedad asociada a los siniestros viales incluye no solo las muertes prematuras, sino también la morbilidad por lesiones fracturas, traumatismos craneoencefálicos, amputaciones y las consecuencias de largo plazo en términos de discapacidad, pérdida de productividad y costos de atención médica Peden et al. (2004).

Desde la perspectiva económica, el Banco Mundial estima que los accidentes de tránsito le cuestan a los países entre el 1 y el 3 % de su Producto Interno Bruto anual World Bank (2017). En Colombia, los estudios de carga de enfermedad ubican a los traumatismos por accidente de tránsito entre las primeras causas de Años de Vida Potencialmente Perdidos (AVPP) para la población económicamente activa.

En el contexto urbano específicamente, la accidentalidad vial se ve exacerbada por la alta densidad de tráfico, la mezcla de modos de transporte con velocidades heterogéneas, la concentración de actividades comerciales en corredores viales y las deficiencias de los sistemas de transporte público que inducen el uso masivo de motocicletas como modo de movilidad individual. Jacobs et al. (2000) señalan que la urbanización acelerada sin planificación vial adecuada genera entornos de alta peligrosidad que afectan de forma desproporcionada a los usuarios más vulnerables.

3.2.4 Enfoques de análisis en seguridad vial

Los estudios sobre seguridad vial han empleado diversas aproximaciones metodológicas que van desde el análisis descriptivo de frecuencias hasta la modelación causal de los determinantes del riesgo. Hauer (2015) distingue tres grandes enfoques: el enfoque descriptivo, orientado a caracterizar los patrones de ocurrencia de los accidentes; el enfoque predictivo, que busca estimar el nivel esperado de accidentalidad de una instalación vial a partir de sus características; y el enfoque evaluativo, que mide el efecto de intervenciones sobre el número de siniestros.

Entre los métodos cuantitativos más utilizados en la literatura se encuentran los modelos de regresión binomial negativa para datos de conteo, los modelos de regresión espacial, las series de tiempo y los métodos de kernel para la estimación de densidad espacial de accidentes. La elección del método apropiado depende de los objetivos del estudio, la naturaleza de los datos disponibles y las hipótesis sobre la estructura de dependencia temporal y espacial del fenómeno.

3.3. Medición de la siniestralidad vial

3.3.1 Frecuencia de accidentes de tránsito

La medida más básica de la siniestralidad vial es la frecuencia absoluta de accidentes, es decir, el número total de eventos registrados en un territorio y período de tiempo determinados. Esta medida, si bien es simple e intuitiva, tiene importantes limitaciones para la comparación entre unidades territoriales de distinto tamaño y para la evaluación del riesgo relativo al que están expuestos los usuarios de la vía Hauer (2015).

La frecuencia absoluta puede desagregarse según distintas dimensiones: tipo de accidente, gravedad, tipo de vehículo involucrado, franja horaria, día de la semana y unidad geográfica. Esta desagregación permite identificar los subgrupos de mayor concentración de siniestros y los momentos o lugares de mayor incidencia, constituyendo el primer nivel de análisis en cualquier estudio de accidentalidad.

Es importante señalar que los registros administrativos solo capturan los accidentes que llegan a conocimiento de las autoridades, lo que implica un subregistro sistemático de los siniestros de menor gravedad. Este problema se agudiza cuando cambios normativos modifican los procedimientos de reporte, como ocurrió en Colombia con la Ley 2251 de 2022.

3.3.2 Tasas de accidentalidad y normalización por población

Las tasas de accidentalidad relacionan el número de accidentes con una medida de exposición, permitiendo comparaciones estandarizadas entre unidades territoriales. La forma más común de estandarización es la tasa por habitantes, que expresa el número de accidentes (o de víctimas) por cada n habitantes de la unidad geográfica analizada:

$$\text{Tasa}_u = \frac{\text{Número de accidentes en la unidad } u}{\text{Población de la unidad } u} \times k \quad (3.1)$$

donde k es un factor de escala (generalmente 1.000, 10.000 o 100.000 habitantes), elegido en función de la magnitud de los valores resultantes.

Otras medidas de exposición incluyen la tasa por kilómetros de red vial, la tasa por vehículo-kilómetro recorrido y la tasa por número de viajes registrados. Estas medidas son preferibles desde

el punto de vista epidemiológico porque capturan mejor la exposición real al riesgo, pero requieren información sobre flujos de tráfico que no siempre está disponible a niveles de desagregación finos.

Hauer (2015) señala que la elección del denominador de la tasa introduce supuestos implícitos sobre la naturaleza del riesgo: una tasa por habitante mide la probabilidad de que un residente promedio se vea involucrado en un accidente, mientras que una tasa por vehículo-kilómetro mide el riesgo asociado al acto específico de circular. La tasa por habitante, aunque menos precisa como medida de exposición, es la más utilizada en estudios de salud pública porque refleja la carga que soporta la población residente en un territorio.

3.3.3 Indicadores de gravedad del accidente

La gravedad de los accidentes de tránsito constituye una dimensión fundamental del análisis de la siniestralidad, toda vez que accidentes de frecuencia similar pueden implicar consecuencias radicalmente diferentes en términos de pérdida de vidas y de carga sobre el sistema de salud. Los indicadores de gravedad más utilizados en la literatura son:

- **Tasa de mortalidad:** número de fallecidos por cada 100 accidentes o por cada 100.000 habitantes.
- **Tasa de lesionados:** número de heridos por cada 100 accidentes.
- **Índice de gravedad:** proporción de accidentes con víctimas (heridos o fallecidos) sobre el total de accidentes registrados.

Este último indicador el índice de gravedad resulta especialmente útil para comparar territorios o tipos de actores viales, pues resume en una sola cifra la proporción de siniestros que dejan secuelas humanas.

3.3.4 Limitaciones de las medidas tradicionales

A pesar de su amplio uso, las medidas tradicionales de accidentalidad adolecen de importantes limitaciones que deben tenerse en cuenta al interpretar los resultados. La primera y más relevante es el subregistro, es decir, la diferencia entre el número real de accidentes ocurridos y el número efectivamente capturado por los sistemas de registro institucional. Estudios de comparación entre registros policiales y registros hospitalarios estiman que el subregistro puede alcanzar entre el 30 y el 70 % para los accidentes con heridos leves, y prácticamente el 100 % para los siniestros con solo daños materiales que no son

reportados a las autoridades Amoros et al. (2006). En el caso colombiano, la promulgación de la Ley 2251 de 2022 introdujo un cambio estructural en los criterios de registro, generando una discontinuidad en las series temporales que debe ser reconocida explícitamente en cualquier análisis que utilice datos administrativos.

La segunda limitación es la heterogeneidad de la exposición: la población residente no es la única expuesta al riesgo en una unidad territorial, dado que las personas también se accidentan en lugares donde no residen. Los barrios de alta actividad comercial o con importantes flujos de paso tienden a presentar tasas por habitante elevadas porque el numerador incluye accidentes que involucran tanto a residentes como a personas de otros lugares. Esta sobrerrepresentación no implica necesariamente un mayor riesgo intrínseco para los residentes, sino que refleja la alta concentración de actividades y desplazamientos en ese territorio.

3.4. Análisis temporal

3.4.1 Concepto de series de tiempo

Formalmente, una serie de tiempo es una realización particular de un proceso estocástico $\{Y_t, t \in \mathcal{T}\}$, es decir, una familia de variables aleatorias indexadas por el tiempo y definidas sobre un mismo espacio de probabilidad (Box et al., 2015). Cuando el índice temporal $\mathcal{T}$ es discreto y equiespaciado como ocurre al agregar accidentes por día, mes o año, cada observación Y_t es una variable aleatoria con función de distribución propia, y la serie observada $\{y_1, y_2, \dots, y_T\}$ constituye una única trayectoria muestral de dicho proceso.

El rasgo distintivo de este tipo de datos frente a una muestra aleatoria simple es que las variables Y_t no son, en general, independientes ni idénticamente distribuidas: el valor en el instante t está estadísticamente relacionado con sus valores pasados. Esta dependencia se caracteriza mediante los dos primeros momentos del proceso:

$$\mu_t = \mathbb{E}[Y_t], \quad (3.2)$$

$$\gamma(t, s) = \text{Cov}(Y_t, Y_s) = \mathbb{E}[(Y_t - \mu_t)(Y_s - \mu_s)]. \quad (3.3)$$

Cuando μ_t es constante en t y $\gamma(t, s)$ depende únicamente de la distancia temporal $h = |t - s|$ de modo que puede escribirse $\gamma(h)$, se dice que el proceso es débilmente estacionario. La violación de esta propiedad es la regla, no la excepción, en fenómenos como la accidentalidad vial: la presencia de tendencia de largo plazo y de estacionalidad calendario implica precisamente que μ_t varía con t , lo que invalida los supuestos de independencia (y de estacionariedad) de los métodos estadísticos clásicos y exige el empleo de técnicas especializadas de análisis de series de tiempo.

Naturaleza de conteo y unidad de agregación

En el ámbito de la accidentalidad vial, la variable de interés es el número de accidentes o de víctimas agregado en intervalos regulares de tiempo, por lo que Y_t es una variable de conteo ($Y_t \in \mathbb{N}_0$) más que continua. Si se admite, como primera aproximación, que los accidentes ocurren según un proceso puntual localmente homogéneo con tasa λ , el conteo agregado en una ventana de longitud h , $Y_t^{(h)}$, satisface aproximadamente

$$\mathbb{E}[Y_t^{(h)}] \approx \lambda h, \quad \text{Var}(Y_t^{(h)}) \approx \lambda h, \quad (3.4)$$

de donde el coeficiente de variación decrece como

$$\frac{\text{DE}(Y_t^{(h)})}{\mathbb{E}[Y_t^{(h)}]} \approx \frac{1}{\sqrt{\lambda h}}. \quad (3.5)$$

La ecuación (3.5) formaliza el compromiso mencionado entre resolución temporal y estabilidad de las estimaciones: agregaciones cortas (por ejemplo, horarias) permiten detectar patrones de alta frecuencia, pero producen conteos con mayor variabilidad relativa; agregaciones largas (mensuales o anuales) estabilizan la serie reduciendo el coeficiente de variación a costa de enmascarar la variabilidad intra-período. La elección de la agregación mensual adoptada en este trabajo responde a este balance, priorizando la estabilidad necesaria para la identificación de tendencia y estacionalidad de largo plazo.

Modelo de descomposición

Sea $\{Y_t\}_{t=1}^T$ la serie de conteos mensuales de accidentes. Un modelo general de descomposición postula que Y_t puede expresarse como función de tres componentes latentes no observadas directamente:

$$Y_t = f(T_t, S_t, R_t), \quad (3.6)$$

donde T_t es la componente de tendencia (evolución suave de largo plazo), S_t la componente estacional (patrón periódico de período conocido s , con $S_{t+s} = S_t$ para todo t) y R_t el residuo irregular, que recoge la variabilidad no explicada por las dos componentes anteriores.

La función f admite dos especificaciones habituales, según si la amplitud de la estacionalidad es constante o proporcional al nivel de la serie:

$$\text{Aditiva:} \quad Y_t = T_t + S_t + R_t, \quad \sum_{j=1}^s S_j = 0, \quad (3.7)$$

$$\text{Multiplicativa:} \quad Y_t = T_t \cdot S_t \cdot R_t, \quad \frac{1}{s} \sum_{j=1}^s S_j = 1. \quad (3.8)$$

Las restricciones de normalización en (3.7) y (3.8) son necesarias para garantizar la identificabilidad del modelo: sin ellas, cualquier constante podría desplazarse arbitrariamente entre T_t y S_t sin alterar Y_t . En el caso aditivo se exige adicionalmente que el residuo tenga media nula, $\mathbb{E}[R_t] = 0$; en el multiplicativo, media unitaria, $\mathbb{E}[R_t] = 1$. Cuando la estacionalidad es proporcional al nivel, el modelo multiplicativo puede reconducirse al caso aditivo mediante una transformación logarítmica,

$$\log Y_t = \log T_t + \log S_t + \log R_t, \quad (3.9)$$

lo que permite emplear las mismas herramientas de estimación en ambos regímenes.

3.4.2 Componentes: tendencia, estacionalidad y variabilidad

La tendencia captura el movimiento de largo plazo de la serie, es decir, la dirección general de cambio a lo largo del período de observación. En el contexto de la accidentalidad vial, una tendencia decreciente puede reflejar el efecto acumulado de mejoras en infraestructura, cambios regulatorios o transformaciones en la composición del parque automotor. La tendencia puede ser estimada mediante regresión lineal, suavizamiento LOESS o descomposición STL Cleveland et al. (1990).

La estacionalidad representa la variación periódica que se repite con una frecuencia fija y predecible: ciclos anuales (variación mensual del número de accidentes), ciclos semanales (variación por

día de la semana) o ciclos diarios (variación por hora del día). La fuerza de la estacionalidad puede cuantificarse mediante la medida F_s , definida como:

$$F_s = 1 - \frac{\text{Var}(R_t)}{\text{Var}(S_t + R_t)} \quad (3.10)$$

Valores de F_s próximos a 1 indican que la componente estacional explica una fracción importante de la variabilidad total de la serie, mientras que valores próximos a 0 sugieren que la estacionalidad es débil o inexistente Hyndman y Athanasopoulos (2021).

La variabilidad irregular o residuo recoge las fluctuaciones de la serie que no son explicadas ni por la tendencia ni por la estacionalidad: perturbaciones aleatorias, efectos de eventos extraordinarios (catástrofes naturales, pandemias, huelgas) y errores de medición. El análisis del residuo permite verificar los supuestos del modelo en particular, la ausencia de autocorrelación y detectar observaciones atípicas que merecen una interpretación específica.

3.4.3 Teoría de la descomposición STL

STL (*Seasonal-Trend decomposition using Loess*) es un procedimiento no paramétrico para estimar las componentes T_t , S_t y R_t del modelo de descomposición (3.6), propuesto originalmente por Cleveland et al. (1990). A diferencia de los métodos clásicos de descomposición basados en medias móviles de ventana fija, STL estima tendencia y estacionalidad mediante regresión local ponderada (Loess), lo que le confiere dos propiedades relevantes para series de accidentalidad: (i) admite que la componente estacional cambie de forma gradual a lo largo del tiempo, en vez de asumirla fija, y (ii) es robusto ante observaciones atípicas mediante un esquema de ponderación iterativa.

Regresión local (Loess)

El bloque elemental de STL es el suavizador Loess. Dado un punto t_0 y una ventana de q vecinos más cercanos, Loess ajusta un polinomio de bajo grado (habitualmente $d = 1$, local-lineal) minimizando una suma de cuadrados ponderada:

$$\hat{\beta}(t_0) = \arg \min_{\beta_0, \beta_1} \sum_{i \in \mathcal{N}_q(t_0)} w_i(t_0) (y_i - \beta_0 - \beta_1(t_i - t_0))^2, \quad (3.11)$$

con pesos definidos por la función tricúbica sobre la distancia normalizada al vecino más lejano de la ventana, $\Delta_q(t_0) = \max_{i \in \mathcal{N}_q(t_0)} |t_i - t_0|$:

$$w_i(t_0) = \left(1 - \left| \frac{t_i - t_0}{\Delta_q(t_0)} \right| \right)_+^3, \quad (3.12)$$

donde $(\cdot)_+$ denota la parte positiva. El valor suavizado en t_0 es $\hat{g}(t_0) = \hat{\beta}_0(t_0)$. El parámetro q (*span*) controla el compromiso sesgo–varianza: valores grandes de q producen curvas más suaves (mayor sesgo, menor varianza); valores pequeños siguen más de cerca los datos (menor sesgo, mayor varianza).

Algoritmo: bucles interno y externo

STL descompone Y_t mediante dos bucles anidados de suavizado iterativo.

Bucle interno.

Para cada iteración $k = 1, \dots, n_{(i)}$, dadas las estimaciones actuales $T_t^{(k)}$ y $S_t^{(k)}$:

1. **Desestacionalización (*detrending*):** se calcula la serie sin tendencia,

$$Y_t - T_t^{(k)}. \quad (3.13)$$

2. **Suavizado por sub-series cíclicas:** la serie (3.13) se separa en s sub-series y cada sub-serie se suaviza con Loess de forma independiente usando un parámetro de ventana $n_{(s)}$, obteniendo una estimación preliminar $C_t^{(k+1)}$ extendida un período antes y después de la serie observada.
3. **Filtrado de paso bajo:** $C_t^{(k+1)}$ se pasa por un filtro de medias móviles de longitudes s , s y 3 (para eliminar posibles remanentes de tendencia que se filtraron a la componente estacional), seguido de un suavizado Loess con $d = 1$, obteniendo $L_t^{(k+1)}$.

4. **Estimación de la componente estacional:**

$$S_t^{(k+1)} = C_t^{(k+1)} - L_t^{(k+1)}. \quad (3.14)$$

5. **Desestacionalización de la serie original:**

$$Y_t - S_t^{(k+1)}. \quad (3.15)$$

6. **Suavizado de la tendencia:** la serie (3.15) se suaviza con Loess ($d = 1$) usando un parámetro de ventana $n_{(t)}$, obteniendo la tendencia actualizada $T_t^{(k+1)}$.

Los tres parámetros de ventana ($n_{(s)}$, $n_{(t)}$, y el de la etapa de paso bajo) determinan la suavidad relativa de cada componente y deben satisfacer restricciones de orden entre sí para garantizar la convergencia del algoritmo (Cleveland et al., 1990).

Bucle externo (robustez).

Tras converger el bucle interno, se calculan los residuos

$$R_t = Y_t - T_t - S_t, \quad (3.16)$$

y se define un peso de robustez decreciente en $|R_t|$ mediante la función bicuadrada de Tukey:

$$\rho_t = B\left(\frac{|R_t|}{6 \text{ mediana}(|R_t|)}\right), \quad B(u) = (1 - u^2)_+^2. \quad (3.17)$$

Estos pesos ρ_t se incorporan multiplicativamente en los suavizados Loess del siguiente bucle interno (ec. 3.11), de modo que observaciones con residuos grandes potenciales valores atípicos, como picos de accidentalidad asociados a eventos puntuales reciben menor influencia en la re-estimación de T_t y S_t . Este esquema se repite $n_{(o)}$ veces, típicamente entre 1 y 2 iteraciones externas, hasta estabilizar la descomposición.

Cuantificación de la fuerza de tendencia y estacionalidad

A partir de la descomposición aditiva final $Y_t = T_t + S_t + R_t$, Hyndman y Athanasopoulos (2021) proponen cuantificar la importancia relativa de cada componente comparando la varianza del residuo con la varianza de la componente más el residuo. Para la componente estacional:

$$F_S = \max\left(0, 1 - \frac{\text{Var}(R_t)}{\text{Var}(S_t + R_t)}\right), \quad (3.18)$$

y, análogamente, para la tendencia:

$$F_T = \max \left(0, 1 - \frac{\text{Var}(R_t)}{\text{Var}(T_t + R_t)} \right). \quad (3.19)$$

Ambos índices toman valores en $[0, 1]$. Un valor de F_S (o F_T) cercano a 1 indica que, al remover esa componente, la varianza residual se reduce drásticamente evidencia de una estacionalidad (o tendencia) fuerte y bien definida; un valor cercano a 0 indica que la componente aporta poca información adicional sobre el residuo puramente aleatorio. La interpretación se sustenta en que, si S_t (o T_t) fuese idénticamente nula, entonces $\text{Var}(S_t + R_t) = \text{Var}(R_t)$ y el índice correspondiente sería exactamente 0; en el extremo opuesto, si R_t tuviera varianza despreciable frente a $S_t + R_t$, el índice tendería a 1.

3.4.4 Teoría de las series de tiempo interrumpidas (ITS)

El diseño de series de tiempo interrumpidas (*Interrupted Time Series*, ITS) es un diseño cuasi-experimental utilizado para evaluar el efecto de una intervención o evento externo puntual sobre la trayectoria de una serie temporal, en ausencia de un grupo de control aleatorizado (Bernal et al., 2017). A diferencia de la descomposición STL que estima tendencia y estacionalidad como componentes suaves sin atribuir causalidad a un instante específico, ITS parte de una hipótesis explícita: existe un momento conocido t^* (el punto de interrupción) en el cual la estructura generadora de la serie cambia, y el objetivo es cuantificar la magnitud de ese cambio contrastando la trayectoria observada después de t^* con la trayectoria que la serie habría seguido de no haber ocurrido la intervención.

Especificación del modelo de regresión segmentada

Sea Y_t la serie observada (en este trabajo, el número mensual de accidentes) y t^* el instante de la intervención (marzo de 2020 para el inicio de las restricciones asociadas a la pandemia de COVID-19). Se define la variable indicadora de intervención

$$X_t = \mathbf{1}(t \geq t^*) = \begin{cases} 0, & t < t^* \\ 1, & t \geq t^* \end{cases} \quad (3.20)$$

y el tiempo transcurrido desde la intervención,

$$T_t = (t - t^*) \cdot X_t \geq 0, \quad (3.21)$$

que vale cero antes de t^* y crece linealmente después. El modelo de regresión segmentada, estándar en el análisis de ITS, se especifica como

$$Y_t = \beta_0 + \beta_1 t + \beta_2 X_t + \beta_3 T_t + \varepsilon_t, \quad (3.22)$$

donde cada coeficiente tiene una interpretación causal directa y es, en sí mismo, un parámetro de interés (no un subproducto del ajuste, como ocurre con los coeficientes de la expansión de Fourier en Prophet):

- β_0 : nivel de la serie en $t = 0$ (intercepto).
- β_1 : pendiente (tendencia) de la serie antes de la intervención.
- β_2 : cambio de nivel inmediatamente después de t^* el salto discontinuo en la serie atribuible a la intervención.
- β_3 : cambio de pendiente después de t^* cuánto se acelera o desacelera la tendencia respecto a β_1 .

La pendiente post-intervención resulta $\beta_1 + \beta_3$, y el valor contrafactual esperado en cualquier $t \geq t^*$ lo que la serie habría sido sin la intervención se obtiene evaluando el modelo con $X_t = 0$, $T_t = 0$ en ese mismo t :

$$\hat{Y}_t^{\text{contrafactual}} = \hat{\beta}_0 + \hat{\beta}_1 t. \quad (3.23)$$

El efecto absoluto de la intervención en un instante $t \geq t^*$ es entonces la diferencia entre el valor ajustado observado y su contrafactual, $\hat{Y}_t - \hat{Y}_t^{\text{contrafactual}} = \hat{\beta}_2 + \hat{\beta}_3 T_t$, y el efecto relativo se obtiene expresando esa diferencia como proporción del nivel contrafactual.

Supuestos del modelo

La validez causal de (3.22) descansa en cuatro supuestos, cuya verificación (o al menos discusión explícita) es condición necesaria para interpretar $\hat{\beta}_2$ y $\hat{\beta}_3$ como efectos atribuibles a la intervención y no a otros factores concurrentes:

1. **Correcta especificación de la forma funcional pre-intervención.** Se asume que, de no mediar la intervención, la serie habría continuado con la tendencia lineal $\beta_0 + \beta_1 t$. Si la tendencia real pre-intervención no es lineal (por ejemplo, si ya existía una desaceleración previa), el contrafactual (3.23) está mal especificado y $\hat{\beta}_2$ absorbe, además del efecto genuino, el sesgo de esa mala especificación. Este supuesto se contrasta visualmente inspeccionando el ajuste sobre el período pre-intervención y, formalmente, evaluando la significancia de términos polinómicos adicionales en t antes de t^* .
2. **Ausencia de eventos concurrentes** (*no hay otras interrupciones simultáneas*). El cambio observado en t^* debe ser atribuible únicamente a la intervención de interés. En el caso de la pandemia de COVID-19, este supuesto es razonablemente sólido dada la magnitud y sincronía del confinamiento; no obstante, se discute explícitamente en la sección de limitaciones la posible superposición con otros cambios normativos (Ley 2251 de 2022) como una segunda interrupción independiente, que se analiza por separado y no se atribuye al mismo punto de cambio.
3. **Número suficiente de observaciones a ambos lados de t^* .** La estimación de β_0, β_1 (pre) y de β_2, β_3 (post) requiere suficiente variabilidad temporal en cada segmento; la literatura metodológica recomienda un mínimo de 8 a 12 puntos por segmento para una estimación estable de la pendiente (Bernal et al., 2017). Con series mensuales de 12 años (144 observaciones) y un punto de corte en marzo de 2020, se dispone de aproximadamente 99 observaciones pre-intervención y 45 post-intervención, satisfaciendo este requisito mínimo.
4. **Independencia (o corrección) de los errores.** El supuesto clásico de mínimos cuadrados ordinarios (MCO), $\text{Cov}(\varepsilon_t, \varepsilon_{t-h}) = 0$ para $h \neq 0$, rara vez se cumple en series de tiempo: observaciones consecutivas suelen estar correlacionadas, lo que de ignorarse no sesga los coeficientes $\hat{\beta}$ pero sí subestima sus errores estándar, inflando artificialmente la significancia estadística de $\hat{\beta}_2$ y $\hat{\beta}_3$. Este es el supuesto más frecuentemente violado y el que motiva la corrección descrita a continuación.

Autocorrelación residual y corrección AR(1)

Para verificar el cuarto supuesto se inspeccionan los residuos $\hat{\varepsilon}_t = Y_t - \hat{Y}_t$ del ajuste por MCO de (3.22) mediante la prueba de **Durbin–Watson**,

$$d = \frac{\sum_{t=2}^T (\hat{\varepsilon}_t - \hat{\varepsilon}_{t-1})^2}{\sum_{t=1}^T \hat{\varepsilon}_t^2}, \quad d \in [0, 4], \quad (3.24)$$

donde valores de d próximos a 2 indican ausencia de autocorrelación de primer orden, mientras que valores cercanos a 0 señalan autocorrelación positiva el patrón típico en series mensuales de conteo con inercia temporal (meses çalmados.^o .agitados”que tienden a persistir).

Cuando se detecta autocorrelación significativa, se asume que el error sigue un proceso autorregresivo de primer orden,

$$\varepsilon_t = \phi \varepsilon_{t-1} + u_t, \quad u_t \sim \mathcal{N}(0, \sigma_u^2) \text{ i.i.d.}, \quad |\phi| < 1, \quad (3.25)$$

con ϕ el coeficiente de autocorrelación y u_t ruido blanco. Bajo este supuesto, la estimación por MCO deja de ser eficiente y se reemplaza por **mínimos cuadrados generalizados factibles** (procedimiento de Cochrane–Orcutt / Prais–Winsten). El procedimiento transforma el modelo original mediante una *cuasi-diferenciación*: para $t \geq 2$,

$$(Y_t - \hat{\phi} Y_{t-1}) = \beta_0(1 - \hat{\phi}) + \beta_1(t - \hat{\phi}(t-1)) + \beta_2(X_t - \hat{\phi} X_{t-1}) + \beta_3(T_t - \hat{\phi} T_{t-1}) + u_t, \quad (3.26)$$

donde $\hat{\phi}$ se estima iterativamente a partir de la autocorrelación de primer orden de los residuos del ajuste anterior, hasta la convergencia. La ecuación (3.26) se ajusta por MCO ordinario sobre las variables transformadas, obteniendo estimadores $\hat{\beta}$ idénticos en valor esperado a los de (3.22) pero con errores estándar correctamente calculados bajo el proceso (3.25) condición necesaria para que las pruebas de hipótesis sobre β_2 y β_3 (cambio de nivel y de pendiente) sean válidas.

Contraste de hipótesis

El efecto de la intervención se evalúa formalmente mediante pruebas t individuales sobre $\hat{\beta}_2$ y $\hat{\beta}_3$ (con los errores estándar corregidos por AR(1)):

$$H_0 : \beta_2 = 0 \quad (\text{sin cambio de nivel}) \quad \text{vs.} \quad H_1 : \beta_2 \neq 0, \quad (3.27)$$

$$H_0 : \beta_3 = 0 \quad (\text{sin cambio de pendiente}) \quad \text{vs.} \quad H_1 : \beta_3 \neq 0. \quad (3.28)$$

El rechazo de (3.27) con $\hat{\beta}_2 < 0$ constituye evidencia de una caída abrupta en el nivel de accidentalidad coincidente con el inicio de la pandemia; el signo y la significancia de $\hat{\beta}_3$ indican, adicionalmente, si la velocidad de recuperación (o de deterioro) posterior difiere de la tendencia pre-pandemia.

Condiciones de aplicación

En síntesis, la aplicación válida de ITS a la serie de accidentalidad de Bucaramanga requiere: (i) que t^* esté fijado *a priori* por conocimiento externo al análisis no elegido *ex post* por inspección visual de un quiebre, lo que constituiría un sesgo de selección; (ii) suficientes observaciones pre y post intervención (verificado en el punto 3 anterior); (iii) una forma funcional pre-intervención razonablemente lineal (verificable gráficamente); y (iv) corrección explícita de la autocorrelación residual mediante (3.25)–(3.26) antes de interpretar la significancia de $\hat{\beta}_2$ y $\hat{\beta}_3$. El instante $t^* =$ marzo de 2020 satisface la condición (i) por tratarse de una fecha determinada por la declaratoria oficial de emergencia sanitaria, externa a los datos de accidentalidad, y no derivada de un examen previo de la propia serie.

3.4.5 Patrones temporales en la siniestralidad vial

La literatura documenta varios patrones temporales recurrentes en la accidentalidad vial que han sido observados en contextos geográficos muy diferentes. En la escala intradía, la distribución horaria de los accidentes suele presentar picos en las franjas de mayor movilidad: la hora del mediodía y las primeras horas de la tarde, asociadas al tráfico de hora pico del almuerzo, y las horas del atardecer, vinculadas al retorno laboral. En la madrugada, aunque el volumen de accidentes disminuye, su severidad media es mayor debido a la mayor velocidad de circulación y al eventual consumo de alcohol.

En la escala semanal, el sábado y el viernes concentran típicamente la mayor accidentalidad, especialmente para los accidentes con heridos graves y fatales, fenómeno atribuido al incremento de la movilidad recreativa y nocturna. El domingo muestra frecuentemente los menores registros en términos absolutos, aunque con una mayor proporción de accidentes de alta severidad en las primeras horas de la madrugada. En la escala mensual y anual, los patrones son más heterogéneos y dependientes del contexto local: variables climáticas, calendarios escolares, festividades nacionales y ciclos económicos modulan la accidentalidad de formas que difieren significativamente entre países y ciudades Caliendo et al. (2007).

3.4.6 *Importancia del análisis temporal en la identificación de períodos críticos*

El análisis temporal de la accidentalidad vial aporta información estratégica para la planificación de las intervenciones preventivas. La identificación de los períodos de mayor riesgo horas, días y meses permite orientar la asignación de recursos de control y vigilancia hacia los momentos de mayor exposición, maximizando la eficiencia de las políticas de seguridad vial Ogden (1996).

Desde la perspectiva de la evaluación de políticas, los métodos de series de tiempo interrumpidas permiten distinguir entre los cambios en la accidentalidad atribuibles a intervenciones específicas (legislación de velocidad, campañas de alcohol al volante, mejoras de infraestructura) y los cambios asociados a tendencias preexistentes o factores exógenos Bernal et al. (2017). Esta capacidad de atribución causal es fundamental para la rendición de cuentas de los programas de seguridad vial y para la justificación de inversiones públicas.

La detección de puntos de cambio estructural en las series de tiempo momentos en que el nivel o la tendencia de la serie se modifican de forma abrupta y persistente permite identificar eventos de alto impacto sobre la movilidad urbana, como la pandemia COVID-19 en 2020 o cambios regulatorios significativos como la Ley 2251 de 2022 en Colombia, y estimar con precisión la magnitud de sus efectos sobre el número de accidentes registrados.

El análisis temporal permite identificar períodos de mayor concentración de siniestros y constituye una herramienta fundamental para orientar acciones preventivas y operativas en materia de seguridad vial.

3.4.7 *Análisis Prophet*

Prophet (Taylor, 2018) es un modelo aditivo generalizado (GAM) de naturaleza bayesiana, diseñado para series de tiempo de negocio con tendencia no lineal y estacionalidad múltiple. A diferencia de STL, que es un procedimiento puramente descriptivo de suavizado, Prophet especifica un modelo generativo completo con parámetros interpretables, lo que permite tanto la descomposición como la proyección hacia adelante. El modelo se define como

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t, \quad (3.29)$$

donde $g(t)$ es la componente de tendencia, $s(t)$ la componente de estacionalidad periódica, $h(t)$ el efecto de días festivos y eventos irregulares, y ε_t un término de error. La ecuación (3.29) es formalmente un caso particular del modelo de descomposición aditivo (3.7), en el que cada componente se sustituye por una función paramétrica explícita en lugar de una estimación no paramétrica por suavizado local.

Supuesto de aditividad

El primer supuesto estructural de Prophet es que las tres componentes se combinan de forma aditiva e independiente entre sí: el efecto de un festivo no depende del nivel de la tendencia, y la amplitud estacional no escala con el nivel de la serie. Este supuesto es razonable cuando la variabilidad estacional es de magnitud aproximadamente constante en el tiempo; en caso contrario cuando la amplitud estacional crece proporcionalmente al nivel de la serie, el propio modelo permite una especificación multiplicativa mediante

$$y(t) = g(t)[1 + s(t) + h(t)] + \varepsilon_t, \quad (3.30)$$

análoga a la transformación logarítmica discutida en (3.9). En este trabajo se adopta la forma aditiva (3.29) como configuración por defecto (`seasonality_mode = "additive"`).

Componente de tendencia: crecimiento lineal por tramos

La tendencia se modela como una función lineal a trozos (*piecewise linear*) con un conjunto de S puntos de cambio (*changepoints*) $\{s_1, \dots, s_S\} \subset [0, T]$, ubicados de forma uniforme sobre el rango histórico de la serie. Sea $\delta \in \mathbb{R}^S$ el vector de ajustes de tasa de crecimiento en cada punto de cambio, y defínase la matriz indicadora $A(t) \in \{0, 1\}^S$ con

$$a_j(t) = \mathbf{1}(t \geq s_j), \quad j = 1, \dots, S. \quad (3.31)$$

La tasa de crecimiento instantánea en t es entonces $k + A(t)^\top \delta$, donde k es la tasa de crecimiento base, y la tendencia se obtiene integrando dicha tasa con el ajuste de continuidad correspondiente en el intercepto:

$$g(t) = (k + A(t)^\top \delta) t + (m + A(t)^\top \gamma), \quad (3.32)$$

con m el intercepto base y $\gamma_j = -s_j \delta_j$ el término de corrección necesario en cada punto de cambio para que $g(t)$ sea continua (sin saltos) en $t = s_j$. La ecuación (3.32) es, por construcción, una función continua y lineal por tramos: fuera de los puntos de cambio, la pendiente es constante; en cada s_j , la pendiente se desplaza en δ_j .

Supuesto de dispersión de los cambios de tendencia.

Prophet asume, a priori, que la mayoría de los ajustes de pendiente son nulos o pequeños, y solo unos pocos puntos de cambio capturan variaciones estructurales genuinas. Esto se formaliza con un prior de Laplace sobre cada componente de δ :

$$\delta_j \sim \text{Laplace}(0, \tau), \quad j = 1, \dots, S, \quad (3.33)$$

donde τ es el hiperparámetro `changepoint_prior_scale`. Al ser el Laplace una distribución de colas pesadas y alta concentración en 0, este prior induce regularización tipo LASSO: la mayoría de los δ_j se contraen hacia cero (tendencia estable, sin quiebres artificiales), mientras que un número reducido de puntos de cambio puede tomar valores apreciables si los datos lo respaldan fuertemente. Un valor pequeño de τ (como $\tau = 0,05$, adoptado en este trabajo) impone un supuesto de tendencia subyacente relativamente rígida, penalizando cambios de pendiente frecuentes o de gran magnitud.

Componente estacional: series de Fourier

La estacionalidad periódica de período P se aproxima mediante una expansión truncada en series de Fourier:

$$s(t) = \sum_{n=1}^N \left[a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right], \quad (3.34)$$

donde N controla el número de armónicos y, por tanto, la flexibilidad de la curva estacional: valores mayores de N permiten capturar patrones más abruptos, a costa de mayor riesgo de sobreajuste. El supuesto implícito de (3.34) es que la estacionalidad es una función suave y periódica exacta se repite idénticamente cada P unidades de tiempo, sin cambios estructurales en su forma a lo largo de la historia de la serie (a diferencia de STL, donde la componente estacional puede evolucionar lentamente en el tiempo). Los coeficientes $\beta = (a_1, b_1, \dots, a_N, b_N)^\top$ reciben un prior normal, $\beta \sim \mathcal{N}(0, \sigma_\beta^2 I)$, que regulariza su magnitud y evita estacionalidades espurias.

Componente de festivos y eventos

Para un conjunto de L festivos o eventos, cada uno con su propia ventana de influencia $[l_i - w_i^-, l_i + w_i^+]$ alrededor de la fecha l_i , se define una matriz de regresores indicadores $Z(t) \in \{0, 1\}^L$ y un vector de efectos $\kappa \in \mathbb{R}^L$:

$$h(t) = Z(t)^\top \kappa, \quad \kappa_i \sim \mathcal{N}(0, \nu^2). \quad (3.35)$$

El supuesto aquí es que cada festivo tiene un efecto puntual, aditivo y fijo sobre el nivel de la serie idéntico cada año en que ocurre el festivo, sin interacción con la tendencia ni con la estacionalidad. Al incorporar el calendario oficial colombiano (`add_country_holidays('CO')`), se asume implícitamente que dicho calendario captura los eventos relevantes que modifican la movilidad y, con ella, la accidentalidad; festividades locales no incluidas en el calendario nacional quedarían absorbidas en el residuo ε_t .

Estructura del error y estimación

El término de error se asume ruido blanco gaussiano,

$$\varepsilon_t \sim \mathcal{N}(0, \sigma^2), \quad (3.36)$$

independiente entre observaciones y sin estructura autorregresiva explícita a diferencia de los modelos ARIMA o del ITS con corrección AR(1) empleado en este trabajo, Prophet no modela la dependencia serial residual. Dado que $g(t)$, $s(t)$ y $h(t)$ son lineales en sus parámetros condicional a las posiciones de los *changepoints*, y los priors (3.33)–(3.35) son conjugados o aproximadamente conjugados con la verosimilitud gaussiana (3.36), la estimación se realiza mediante inferencia bayesiana aproximada.

Síntesis de supuestos

La validez de Prophet como herramienta de análisis descansa sobre cinco supuestos que conviene enunciar explícitamente, dado su carácter exploratorio en este trabajo:

1. **Aditividad** de tendencia, estacionalidad y festivos (ec. 3.29), o su forma multiplicativa alternativa (ec. 3.30).

2. **Tendencia suave y poco cambiante**, con quiebres escasos y de magnitud regularizada por el prior de Laplace (ec. 3.33).
3. **Estacionalidad periódica exacta y estable**, representable con un número finito de armónicos de Fourier (ec. 3.34).
4. **Efectos de festivos puntuales, fijos y aditivos**, no condicionados al nivel de la serie (ec. 3.35).
5. **Error gaussiano sin autocorrelación residual** (ec. 3.36).

El quinto supuesto es, en el contexto de este estudio, el más restrictivo: la ruptura estructural asociada a la pandemia de COVID-19 (marzo de 2020) constituye precisamente un choque abrupto y persistente que el mecanismo de regularización de (3.33) diseñado para privilegiar tendencias suaves tiende a subestimar o a distribuir en varios *changepoints* cercanos en lugar de aislar como una única discontinuidad de nivel.

3.5. Fundamentos de análisis espacial

3.5.1 Conceptos básicos de estadística espacial

La estadística espacial es una rama de la estadística aplicada que se ocupa del análisis de datos cuya estructura de dependencia es función de la posición geográfica de las unidades de observación Cressie (1993). A diferencia de la estadística clásica, que asume la independencia de las observaciones, la estadística espacial reconoce explícitamente que las unidades cercanas en el espacio tienden a ser más similares entre sí que las unidades distantes, fenómeno conocido como autocorrelación espacial positiva o Primera Ley de la Geografía de (Tobler, 1970): «todo está relacionado con todo, pero las cosas cercanas están más relacionadas que las lejanas».

Los métodos de estadística espacial pueden clasificarse en tres grandes familias según el tipo de datos que analizan Bivand et al. (2008): (i) **geoestadística**, que trabaja con valores continuos de una variable medida en puntos del espacio (por ejemplo, concentración de contaminantes en estaciones de monitoreo); (ii) **estadística de datos de área**, que analiza variables agregadas en unidades espaciales discretas (barrios, comunas, municipios); y (iii) **análisis de patrones de puntos**, que estudia la distribución espacial de eventos individuales (localización de accidentes).

3.5.2 Dependencia y heterogeneidad espacial

La dependencia espacial se refiere a la existencia de correlación entre los valores de una variable en unidades geográficas contiguas o próximas. Esta dependencia puede ser positiva cuando los valores similares tienden a agruparse o negativa cuando valores altos se rodean de valores bajos y viceversa. La dependencia espacial positiva es el patrón más frecuente en datos socioeconómicos y epidemiológicos, y refleja la existencia de procesos de difusión, contagio o determinantes comunes en el territorio Anselin (1988).

La heterogeneidad espacial hace referencia a la variación sistemática de los parámetros de un proceso a través del espacio, es decir, a la inestabilidad de las relaciones entre variables a lo largo del territorio. Mientras que la dependencia espacial afecta la estructura de errores de los modelos (problema de autocorrelación), la heterogeneidad espacial afecta la especificación del modelo (problema de no estacionariedad). Anselin (1988) argumenta que ambos fenómenos son omnipresentes en datos geográficos y que ignorarlos conduce a estimaciones sesgadas e ineficientes.

En el contexto de la accidentalidad vial, la dependencia espacial refleja que los factores de riesgo densidad de tráfico, calidad de la infraestructura, velocidad de circulación no se distribuyen de forma aleatoria en el territorio, sino que tienden a concentrarse en zonas contiguas. La heterogeneidad espacial, por su parte, indica que el efecto de determinadas variables sobre la accidentalidad puede diferir entre zonas del territorio: el impacto de la densidad comercial puede ser mayor en el centro que en la periferia, por ejemplo.

3.5.3 Unidades espaciales

La elección de la unidad espacial de análisis tiene implicaciones profundas en los resultados del análisis estadístico, fenómeno conocido como el *Problema de la Unidad de Área Modificable* (MAUP, por sus siglas en inglés) Openshaw (1984). El MAUP establece que los resultados estadísticos obtenidos para datos de área dependen de la forma y el tamaño de las unidades utilizadas para la agregación: los mismos datos pueden producir resultados distintos e incluso contradictorios al ser analizados con diferentes sistemas de zonificación.

3.5.4 Representación cartográfica y mapas temáticos

Los mapas temáticos son representaciones gráficas del territorio que asocian a cada unidad espacial el valor de una variable cuantitativa o cualitativa, permitiendo visualizar la distribución geográfica de fenómenos de interés Slocum et al. (2009). En el análisis de accidentalidad vial, los mapas temáticos cumplen una función dual: por un lado, comunican los resultados a audiencias no especializadas de forma intuitiva; por otro lado, constituyen una herramienta exploratoria que permite detectar visualmente patrones de concentración que pueden guiar los análisis estadísticos más rigurosos.

Los principales tipos de mapas temáticos utilizados en estudios de accidentalidad son:

- **Mapas coropléticos:** cada unidad espacial se colorea en función del valor de la variable, utilizando una escala de color continua o discreta. Son adecuados para representar variables de tasa o proporción.
- **Mapas de densidad de kernel:** estiman la densidad espacial de eventos puntuales (accidentes individuales) mediante una función de suavizamiento, produciendo una superficie continua que facilita la identificación de zonas de alta concentración.
- **Mapas de clústeres LISA:** representan la clasificación de las unidades espaciales según el tipo de agrupamiento estadístico identificado por el análisis de autocorrelación local, diferenciando entre *hotspots* (High-High), *coldspots* (Low-Low) y outliers espaciales.

3.5.5 Relevancia del análisis espacial en seguridad vial

El análisis espacial aporta una dimensión adicional al diagnóstico de la accidentalidad que los métodos descriptivos no especializados no pueden capturar. En particular, la identificación de *hotspots* zonas de concentración estadísticamente significativa de accidentes permite focalizar las intervenciones preventivas en los territorios de mayor riesgo, maximizando el impacto de los recursos disponibles Moons et al. (2014).

La evidencia internacional indica que las intervenciones focalizadas en los *hotspots* de accidentalidad tienen un rendimiento significativamente mayor que las intervenciones distribuidas de forma uniforme en el territorio. Elvik (2008) estima que las acciones concentradas en los puntos negros de la red vial pueden reducir entre un 20 y un 40 % el número de accidentes en esas localizaciones, frente a reducciones de apenas el 5–10 % para intervenciones de carácter general. Esta lógica de focalización

territorial es el argumento central para la incorporación del análisis espacial en la planificación de la seguridad vial.

3.5.6 Índice de Moran global

El índice de Moran global, propuesto por (Moran, 1950), es el estadístico más empleado para evaluar la existencia de autocorrelación espacial en datos de área. El estadístico I se define como:

$$I = \frac{n}{\sum_i \sum_j w_{ij}} \cdot \frac{\sum_i \sum_j w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_i (x_i - \bar{x})^2} \quad (3.37)$$

donde n es el número de unidades espaciales, x_i es el valor de la variable en la unidad i , $\bar{x}$ es la media global y w_{ij} son los pesos espaciales que cuantifican la proximidad entre las unidades i y j .

Bajo la hipótesis nula de aleatoriedad espacial, el valor esperado del estadístico es $E[I] = -1/(n - 1)$, que tiende a cero cuando n es grande. Un valor positivo de I superior a $E[I]$ indica autocorrelación espacial positiva (los valores similares tienden a agruparse), mientras que un valor negativo inferior a $E[I]$ indica autocorrelación espacial negativa (los valores similares tienden a dispersarse).

La significancia estadística se evalúa mediante un test de permutación o de aleatorización, comparando el valor observado con la distribución empírica de I bajo la hipótesis nula Anselin (1995).

Los pesos espaciales w_{ij} pueden construirse de distintas formas: contigüidad de primer orden (reina o torre), k vecinos más cercanos, o funciones de distancia inversa. La elección de la estructura de pesos tiene implicaciones en los resultados del test.

3.5.7 Indicadores Locales de Asociación Espacial (LISA)

Si bien el índice de Moran global permite determinar si existe autocorrelación espacial en todo el conjunto de datos, no identifica dónde se localizan los agrupamientos o anomalías espaciales. Para superar esta limitación, Anselin (1995) propuso los Indicadores Locales de Asociación Espacial (LISA), que descomponen el estadístico global en contribuciones individuales para cada unidad espacial, permitiendo detectar conglomerados significativos y valores atípicos locales.

Definición formal

El estadístico de Moran local para la unidad espacial i se define como:

$$I_i = \frac{(x_i - \bar{x})}{m_2} \sum_{j=1}^n w_{ij}(x_j - \bar{x}) \quad (3.38)$$

donde:

- x_i : valor de la variable de interés en la unidad i (en este estudio, la tasa de accidentalidad por 1.000 habitantes en el barrio i).
- $\bar{x}$: media global de la variable.
- w_{ij} : peso espacial entre las unidades i y j , que cuantifica la proximidad geográfica (en este estudio, definido mediante los k vecinos más cercanos con $k = 5$, estandarizados por fila).
- $m_2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$: varianza empírica de la variable.
- n : número total de unidades espaciales.

El estadístico I_i mide la contribución de la unidad i y sus vecinos al patrón global de autocorrelación. Un valor $I_i > 0$ indica que la unidad i y sus vecinos tienen valores similares (ambos altos o ambos bajos), mientras que $I_i < 0$ indica que la unidad i y sus vecinos tienen valores disímiles (uno alto y el otro bajo).

Matriz de pesos espaciales

Todo estadístico de autocorrelación espacial global o local requiere especificar, de forma previa y explícita, una matriz de pesos espaciales $W \in \mathbb{R}^{n \times n}$, donde n es el número de unidades de análisis y cada entrada w_{ij} cuantifica el grado de vecindad o influencia espacial que la unidad j ejerce sobre la unidad i . Aunque la noción de vecindad es intuitiva en términos geográficos, su traducción a una estructura matemática requiere definir explícitamente tres elementos: el criterio de conectividad entre unidades, el esquema de ponderación de dichas conexiones, y la forma en que se manejan las unidades sin vecinos, cuando las hubiere.

Criterios de vecindad

Bivand y Wong (2018) distinguen tres familias principales de criterios para definir la vecindad entre unidades de área (*lattice data*):

- **Contigüidad** (tipo *reina* o *torre*): $w_{ij} = 1$ si los polígonos i y j comparten frontera (torre: solo lados; reina: lados o vértices), y 0 en caso contrario. Es sensible a la irregularidad geométrica: un polígono con fronteras artificiales o de forma alargada puede quedar sin vecinos directos, generando las llamadas observaciones *sin vecino* (*no-neighbour observations*), un problema que los propios autores señalan como recurrente y no trivial de resolver (Bivand & Wong, 2018, p. 4).
- **Distancia** (*distance-band* o *inverse distance weighting*, IDW): w_{ij} se define como una función decreciente de la distancia entre centroides, ya sea binaria (vecino si la distancia es menor a un umbral d) o continua ($w_{ij} \propto 1/d_{ij}$). Requiere fijar un umbral o una función de decaimiento en buena medida arbitraria, y produce un número de vecinos muy heterogéneo cuando la densidad geográfica de las unidades no es uniforme.
- **k vecinos más cercanos** (k -NN): $w_{ij} = 1$ si j se encuentra entre los k centroides más próximos a i . A diferencia de los dos criterios anteriores, garantiza por construcción que toda unidad tenga exactamente k vecinos, eliminando de raíz el problema de observaciones sin vecino. Como contrapartida, la relación de vecindad no es necesariamente simétrica (que j sea uno de los k vecinos más cercanos de i no garantiza que i lo sea de j), de modo que la matriz de contigüidad binaria resultante no es, en general, simétrica a diferencia de los pesos de contigüidad clásicos, que sí lo son por definición (Bivand & Wong, 2018).

Esquemas de ponderación

Definida una matriz de contigüidad binaria B bajo cualquiera de los criterios anteriores, existen dos esquemas principales para convertirla en pesos utilizables:

- **Binario** (estilo “B”): $w_{ij} = b_{ij}$, sin normalizar. S_0 es simplemente el número total de relaciones de vecindad.
- **Estandarizado por fila** (*row-standardization*, estilo “W”):

$$w_{ij} = \frac{b_{ij}}{\sum_{l=1}^n b_{il}}, \quad (3.39)$$

de modo que $\sum_j w_{ij} = 1$ para todo i . Bajo este esquema, el rezago espacial $(WY)_i = \sum_j w_{ij} Y_j$ se interpreta directamente como el promedio de Y entre los vecinos de i , lo que según documentan Bivand y Wong (2018) constituye la convención más extendida en la literatura de econometría espacial, incluyendo la implementación original de LISA de Anselin (1995), precisamente por dicha interpretación directa como promedio ponderado del entorno.

Del índice global al estadístico local (LISA)

El estadístico de Moran local o LISA, propuesto por Anselin (1995), descompone el índice global en contribuciones individuales por unidad:

$$I_i = \frac{(x_i - \bar{x})}{m_2} \sum_{j=1}^n w_{ij}(x_j - \bar{x}), \quad m_2 = \frac{\sum_i z_i^2}{n}, \quad (3.40)$$

que satisface $I = \sum_i I_i / S_0$: el índice global es, hasta un factor de escala, la suma de las contribuciones locales de cada unidad (Bivand & Wong, 2018). Las ecuaciones en (3.40) son válidas independientemente de si W es simétrica o no la formulación no requiere dicha propiedad, aunque en el caso asimétrico (propio de k -NN) la contribución de i al rezago de j no es, en general, igual a la de j sobre i .

Clasificación en cuadrantes del diagrama de Moran

Para una interpretación más detallada, el signo de I_i se combina con la posición relativa de x_i respecto a la media ($\bar{x}$) y el promedio ponderado de los vecinos ($\sum_j w_{ij} x_j$). Esta combinación permite clasificar cada unidad en uno de los cuatro cuadrantes del diagrama de Moran (Anselin, 1996):

Cuadro 3.1: Clasificación de unidades espaciales según el diagrama de Moran local

Categoría	Condición	Interpretación práctica en seguridad vial
High-High (HH)	$x_i > \bar{x}$ y $\sum_j w_{ij}x_j > \bar{x}$	Barrio con alta tasa de accidentalidad rodeado de barrios con alta tasa. Conglomerado de alto riesgo (<i>hotspot</i>). Requiere intervención territorial integral.
Low-Low (LL)	$x_i < \bar{x}$ y $\sum_j w_{ij}x_j < \bar{x}$	Barrio con baja tasa rodeado de barrios con baja tasa. Conglomerado de bajo riesgo (<i>coldspot</i>). Puede servir como referencia para identificar factores protectores.
High-Low (HL)	$x_i > \bar{x}$ y $\sum_j w_{ij}x_j < \bar{x}$	Barrio con alta tasa rodeado de barrios con baja tasa. <i>Outlier</i> positivo. Sugiere factores de riesgo locales que merecen estudio individualizado.
Low-High (LH)	$x_i < \bar{x}$ y $\sum_j w_{ij}x_j > \bar{x}$	Barrio con baja tasa rodeado de barrios con alta tasa. <i>Outlier</i> negativo. Indica posibles factores protectores locales que podrían replicarse en zonas vecinas.

Prueba de significancia y corrección por comparaciones múltiples

La significancia estadística de cada I_i se evalúa mediante un procedimiento de permutaciones aleatorias. Bajo la hipótesis nula de aleatoriedad espacial, los valores de x se permutan aleatoriamente entre las unidades, manteniendo fija la matriz de pesos espaciales. Para cada permutación se calcula un I_i simulado, generando una distribución empírica de referencia. El p -valor asociado a la unidad i se obtiene comparando el I_i observado con esta distribución.

Dado que el análisis LISA implica la realización de múltiples pruebas de hipótesis (una por cada unidad espacial), se recomienda controlar la tasa de falsos descubrimientos (FDR, por sus siglas en inglés) mediante el método de Benjamini-Hochberg (Benjamini & Hochberg, 1995). Este ajuste reduce la probabilidad de detectar clústeres espurios debido al azar. En este estudio, se consideraron como significativos aquellos barrios con un p -valor ajustado $< 0,05$.

Utilidad de LISA en el contexto del estudio

La aplicación de los indicadores LISA en el análisis de la accidentalidad vial ofrece múltiples ventajas prácticas:

1. **Identificación precisa de hotspots:** a diferencia de los enfoques basados únicamente en frecuencias absolutas, LISA permite distinguir entre barrios con alta accidentalidad por su tamaño poblacional (alta frecuencia pero tasa moderada) y aquellos donde la alta tasa es estadísticamente anómala en relación con su entorno. Esto permite focalizar las intervenciones en los verdaderos núcleos de riesgo.
2. **Detección de anomalías espaciales:** los casos HL y LH revelan barrios que se comportan de manera atípica respecto a sus vecinos. Por ejemplo, un barrio HL (alta tasa rodeado de bajas) podría esconder un punto negro localizado que no afecta a los barrios vecinos, lo que justifica un estudio detallado de sus características particulares.
3. **Planificación territorial integrada:** la identificación de clústeres HH (como el corredor centro-occidental de Bucaramanga, conformado por Puerta del Sol, Antonia Santos Sur, La Salle, Conucos y La Ceiba) permite diseñar estrategias de intervención que abarquen toda el área del clúster, abordando los factores territoriales compartidos en lugar de actuar sobre barrios aislados.
4. **Base para modelos explicativos:** los resultados de LISA pueden utilizarse como variable dependiente en modelos de regresión espacial (por ejemplo, regresión logística espacial) para identificar qué factores del entorno construido (densidad de intersecciones, usos del suelo, jerarquía vial) están asociados con la pertenencia a un *hotspot*.

Relación con el índice de Moran global

Es importante destacar que el análisis LISA no reemplaza al Moran global, sino que lo complementa. Mientras el Moran global responde a la pregunta ¿existe autocorrelación espacial en todo el terri-

torio?», los LISA responden a ¿dónde se localizan específicamente los agrupamientos o anomalías?».

3.5.8 *Identificación de clústeres y zonas críticas*

La identificación de clústeres espaciales de accidentalidad zonas donde la concentración de siniestros es estadísticamente significativa y espacialmente contigua constituye uno de los objetivos centrales de la aplicación del análisis espacial a la seguridad vial. Los clústeres de tipo High-High, denominados *hotspots* o puntos negros, señalan áreas donde el riesgo de accidente es simultáneamente elevado en el barrio y en su entorno inmediato, lo que sugiere la existencia de factores de riesgo de carácter territorial que trascienden los límites administrativos de una unidad individual Prasannakumar et al. (2011).

La identificación de *hotspots* mediante el análisis LISA tiene importantes implicaciones para la gestión de la seguridad vial: a diferencia de los enfoques basados únicamente en frecuencias absolutas que tienden a señalar los centros urbanos de mayor densidad como las zonas con mayor accidentalidad, el análisis de clústeres permite identificar zonas periféricas de menor tamaño pero con concentraciones de riesgo estadísticamente anómalas, que podrían pasar desapercibidas en un análisis descriptivo convencional.

Los *coldspots* (Low-Low) representan zonas de bajo riesgo estructural, cuya identificación es también relevante para entender los determinantes de la accidentalidad: los factores presentes en estas zonas (diseño vial, velocidades moderadas, menor flujo de motos) pueden servir de referencia para el diseño de intervenciones en las zonas de mayor riesgo.

3.5.9 *Interpretación de patrones espaciales*

La interpretación de los patrones espaciales identificados mediante el análisis LISA requiere un ejercicio de triangulación entre la evidencia estadística y el conocimiento del territorio. Un clúster High-High estadísticamente significativo no implica necesariamente la existencia de un factor de riesgo identificable; puede también reflejar la localización de una infraestructura de alta concentración vehicular (como un nodo de transporte público o una zona comercial de alto tráfico) que genera accidentalidad por razones puramente de exposición.

La convergencia entre distintos métodos de identificación de zonas críticas por ejemplo, entre el análisis LISA y el análisis de cuadrantes basado en la comparación de rankings por frecuencia y por tasa estandarizada aumenta la confiabilidad del diagnóstico territorial. Cuando varios métodos independientes

señalan las mismas zonas como críticas, la evidencia de concentración de riesgo es más robusta que cuando solo un método lo detecta Thakali et al. (2015).

3.6. Análisis de la participación de actores viales

3.6.1 Clasificación de actores viales

Los actores viales son todos los usuarios del espacio vial público: peatones, ciclistas, motociclistas, conductores de vehículos particulares, pasajeros de transporte público y conductores de vehículos de carga Organización Mundial de la Salud (2018). Esta diversidad de actores es característica del entorno urbano de los países en desarrollo, donde la vía pública es compartida por modos de transporte de muy distintas características físicas, velocidades y niveles de protección.

La clasificación más utilizada en los estudios de accidentalidad agrupa los actores en dos grandes categorías: los usuarios motorizados (conductores y pasajeros de vehículos de dos, tres y cuatro ruedas, y de transporte público y de carga) y los usuarios no motorizados o vulnerables (peatones y ciclistas). Esta distinción es relevante porque los usuarios vulnerables presentan una probabilidad de lesión grave o mortal significativamente mayor ante un impacto de igual energía, dada su menor masa corporal y la ausencia de carrocería protectora Peden et al. (2004).

En el contexto colombiano, y particularmente en ciudades intermedias como Bucaramanga, el crecimiento sostenido del parque de motocicletas ha generado una categoría intermedia de especial relevancia: los motociclistas comparten con los usuarios vulnerables la exposición física directa a los impactos, pero pertenecen al grupo motorizado en términos de velocidad de circulación y de capacidad de acceso a la red vial. Esta posición intermedia explica, en parte, su sobrerrepresentación en las estadísticas de víctimas graves y fatales Yannis et al. (2017).

3.6.2 Interacción entre actores en los accidentes de tránsito

Los accidentes de tránsito son, en su mayoría, eventos de interacción entre actores: el 70–80 % de los siniestros en entornos urbanos involucran a más de un tipo de usuario de la vía Elvik et al. (2009a). La naturaleza de estas interacciones, así como los pares de actores que se involucran con mayor frecuencia y las circunstancias en las que ocurren, aporta información relevante sobre las dinámicas de ocurrencia de los accidentes y sobre posibles estrategias de prevención vial.

El análisis de co-ocurrencia de actores viales, que examina la frecuencia con que dos tipos de vehículos o usuarios aparecen simultáneamente en el mismo siniestro, es una herramienta descriptiva útil para identificar las interacciones más frecuentes y más graves. La co-ocurrencia moto–automóvil, por ejemplo, es característica de los entornos urbanos con alta densidad de motocicletas, donde la interacción entre vehículos de distinta masa y velocidad genera siniestros de especial severidad para el motociclista.

Elvik et al. (2009b) señalan que las intervenciones orientadas a reducir los conflictos entre actores de distintas categorías mediante la separación física de los flujos (infraestructura segregada para ciclistas y motociclistas), la reducción de velocidades en zonas de mezcla modal o la formación específica en conducción defensiva han demostrado mayor efectividad que las medidas genéricas de control de velocidad, precisamente porque actúan sobre los mecanismos específicos de generación de los accidentes más graves.

3.6.3 Vulnerabilidad de los actores viales

El término vulnerabilidad diferencial alude a las diferencias que presentan los distintos actores viales tanto en la probabilidad de verse implicados en un accidente como en la gravedad de sus consecuencias. Esta vulnerabilidad surge de la combinación de tres factores: la exposición (los kilómetros que recorre cada actor en el sistema vial), la tasa de accidentalidad por unidad de exposición (número de accidentes por vehículo-kilómetro) y la severidad esperada (la probabilidad de sufrir una lesión grave o mortal una vez ocurrido el siniestro).

Peden et al. (2004) documentan que, a nivel mundial, los motociclistas presentan una tasa de mortalidad por kilómetro recorrido entre 15 y 20 veces mayor que los ocupantes de automóviles, y los peatones entre 5 y 10 veces mayor. Estas diferencias son aún más pronunciadas en países de ingresos medianos, donde la calidad de la infraestructura vial y los sistemas de seguridad de los vehículos son inferiores al estándar de los países de altos ingresos.

En el contexto colombiano, la expansión del uso de motocicletas como modo de transporte de trabajo mototaxismo, reparto de domicilios ha transformado el perfil de vulnerabilidad de este actor: los motociclistas colombianos están expuestos a mayores volúmenes de kilómetros recorridos, a menudo en condiciones de fatiga y con equipos de protección deficientes, lo que amplifica su sobrerepresentación en los registros de víctimas fatales INML (2022).

3.6.4 Importancia del análisis modal en seguridad vial

El análisis de la participación de los distintos actores viales en los accidentes denominado análisis modal en la literatura de seguridad vial es fundamental por varias razones. En primer lugar, permite identificar los grupos de actores que requieren intervenciones prioritarias en función de su nivel de vulnerabilidad relativa y de su peso en el total de víctimas. En segundo lugar, posibilita el diseño de intervenciones específicas y diferenciadas para cada tipo de actor, superando el enfoque genérico de las campañas de seguridad vial dirigidas a la población general.

En tercer lugar, el seguimiento de la participación de los distintos actores a lo largo del tiempo permite detectar cambios en el perfil de vulnerabilidad asociados a transformaciones en el sistema de movilidad urbana. El aumento sostenido de la participación de las motocicletas en la accidentalidad de Bucaramanga, documentado en el presente estudio, es un indicador de alerta que debe incorporarse en la planificación de la infraestructura vial y en las estrategias de educación y control de tránsito.

Finalmente, el análisis modal enriquece la interpretación de los patrones espaciales: la concentración de accidentes en determinadas zonas puede estar asociada no solo a factores de infraestructura, sino también a la predominancia de un tipo específico de actor vial como la alta densidad de motocicletas en las comunas Centro y San Francisco de Bucaramanga cuya gestión requiere estrategias diferenciadas de las empleadas para los accidentes en que predominan los vehículos de cuatro ruedas.

4 Marco metodológico

4.1. Diseño de la investigación

El presente estudio corresponde a una investigación cuantitativa de carácter descriptivo, con componentes de análisis espacial y temporal. Su objetivo es caracterizar el fenómeno de los accidentes de tránsito en Bucaramanga durante el período 2012–2023, abordándolo desde tres dimensiones principales: temporal, espacial y modal, con el propósito de identificar patrones recurrentes, zonas críticas y actores viales predominantes.

La unidad de análisis está constituida por los registros individuales de accidentes de tránsito ocurridos en Bucaramanga durante el período de estudio, los cuales fueron posteriormente agregados según las necesidades del análisis temporal, espacial y modal.

4.2. Fuente de datos

Los datos utilizados en esta investigación provienen de tres fuentes principales: dos archivos en formato CSV y un archivo shapefile. El primero de ellos contiene los registros de accidentes de tránsito ocurridos en Bucaramanga entre 2012 y 2023, sumando un total de 39.193 siniestros. El segundo archivo proporciona información poblacional desagregada por comuna y por barrio, necesaria para calcular tasas estandarizadas. El tercero es un shapefile con la cartografía oficial de los 219 barrios del municipio. Todos los archivos fueron suministrados por la Secretaría de Tránsito de Bucaramanga y el Departamento Administrativo Nacional de Estadística (DANE).

El Cuadro 4.1 resume las principales variables empleadas en el análisis, clasificadas según su tipo y el uso que se les da en cada una de las dimensiones del estudio (temporal, espacial, modal y de severidad).

Cada registro de accidente incluye información relacionada con la fecha y hora del siniestro, la ubicación geográfica (barrio y comuna), la gravedad del evento y los tipos de vehículos involucrados. Asimismo, se dispone de variables asociadas con las condiciones de iluminación y el contexto del accidente. Por otra parte, los datos poblacionales se encuentran desagregados por barrio y comuna, permitiendo el

Cuadro 4.1: Variables utilizadas en el estudio, tipo y uso

Variable	Tipo	Uso
FECHA	Fecha	Análisis temporal
HORA	Hora	Análisis temporal
BARRIO	Categórica	Análisis espacial
COMUNA	Categórica	Análisis espacial
GRAVEDAD	Categórica	Severidad
MOTO	Númerica	Análisis modal
AUTOMÓVIL	Númerica	Análisis modal
PEATÓN	Númerica	Análisis modal
BICICLETA	Númerica	Análisis modal
CAMIÓN	Númerica	Análisis modal
BUS	Númerica	Análisis modal
OTRO	Númerica	Análisis modal
ILUMINACIÓN	Categórica	Contexto (diurno/nocturno)

cálculo de tasas ajustadas por número de habitantes.

4.3. Preparación y procesamiento de datos

A continuación se describen las principales etapas de limpieza y transformación, integrando tanto el análisis descriptivo general como el procesamiento para mapas, análisis espaciales y temporales.

4.3.1 Limpieza y estandarización de la base de accidentes

1. **Conversión de tipos:** Las variables categóricas (año, mes, día, gravedad, barrio, comuna, propietario del vehículo, diurno/nocturno) se transformaron a factores para facilitar su tratamiento estadístico.
2. **Manejo de valores no disponibles:** En las variables BARRIO y COMUNA, los registros etiquetados como “NO DISPONIBLE” se reemplazaron por NA (valor perdido) y posteriormente se convirtieron nuevamente a factores. Esto permite excluir o tratar dichos casos en los análisis posteriores.
3. **Verificación de datos faltantes:** Se verificó la ausencia de valores perdidos en el resto de las variables, garantizando la integridad del conjunto de datos.

4.3.2 Estandarización de nombres de barrio (para integración espacial)

Para garantizar la correcta unión entre los datos tabulares y el shapefile, se aplicó un proceso de normalización de los nombres de barrio en ambas fuentes:

- Conversión a mayúsculas.
- Eliminación de espacios al inicio y final.
- Remoción de caracteres especiales (signos de puntuación, acentos) mediante expresiones regulares.
- Reemplazo de valores “NO DISPONIBLE” o vacíos por NA.

En el procesamiento para mapas, se definió una función que realiza estos pasos, filtra los registros con barrio desconocido y luego agrupa por barrio para calcular totales y métricas asociadas.

4.3.3 Construcción de variables derivadas

A partir de la fecha y la hora se enriqueció la base de datos con nuevas variables:

- FECHA convertida a formato `Date`.
- HORA transformada a `POSIXct` y extracción del número decimal de horas (`HORA_NUM`) para análisis continuos.
- Creación de la variable `DIA_SEMANA` a partir de la fecha, etiquetando los días de lunes a domingo.
- Discretización de la hora numérica en siete categorías (madrugada, mañana temprano, mañana, tarde temprano, tarde, noche temprano, noche).
- Para análisis de series temporales: extracción de año, mes y variable `año_mes` (primer día de cada mes usando `floor_date(FECHA, "month")`).

4.3.4 Agregación para análisis espacial por barrio

Se definió una función específica que, tras la limpieza, realiza:

1. Filtrado de registros válidos (eliminación de filas con barrio NA).
2. Conteo de accidentes y métricas asociadas agrupando por barrio:

- Total de accidentes.
- Número de accidentes con heridos, con muertos y solo daños.
- Frecuencia de involucramiento de peatones, motos, automóviles, bicicletas, camiones y buses (basado en si la columna correspondiente es mayor que cero).

El resultado es un data frame con 164 barrios que registraron al menos un accidente.

4.3.5 Unión con datos de población y shapefile

- Se importó el archivo de población (`poblacionbga.csv`), limpiando los formatos (eliminando comas de los números) y sumando la población por comuna o por barrio según el análisis.
- Se cargó el Shapefile `Barrios.shp` mediante `st_read()`. Se inspeccionaron los nombres de las columnas para identificar la que contiene el nombre del barrio (columna `NOMBRE`). Se creó una nueva variable `NOMBRE_LIMPIO` aplicando la misma estandarización.
- Los datos espaciales y tabulares fueron integrados mediante una unión basada en los nombres estandarizados de los barrios.
- Los barrios sin accidentes recibieron valores cero en las variables numéricas.

4.3.6 Cálculo de métricas derivadas (para mapas)

Posteriormente se calcularon:

- `tasa_gravedad`: porcentaje de accidentes con heridos o muertos respecto al total del barrio.
- `porcentaje_motos` y `porcentaje_peatones`: proporción de accidentes que involucran motocicletas o peatones.
- `categoria_riesgo`: clasificación cualitativa del nivel de accidentalidad según el número total de accidentes (Sin accidentes, Bajo 1-5, Medio 6-15, Alto 16-30, Muy alto >30).

4.4. Análisis temporal de los accidentes de tránsito

Se llevó a cabo un análisis descriptivo de la distribución temporal de los accidentes, complementado con técnicas de series de tiempo y el modelo Prophet como herramienta exploratoria (no central). A continuación se detallan todos los procedimientos realizados.

4.4.1 *Distribución por hora, día de la semana y mes*

- Se elaboraron tablas de frecuencia y gráficos de barras para la distribución por franja horaria (7 categorías) y por día de la semana.
- Se generaron mapas de calor cruzando franja horaria con día de la semana para identificar momentos críticos.
- Se identificaron las horas con mayor concentración de accidentes (horas pico) mediante un gráfico de densidad de la distribución horaria.
- Se construyó una matriz de frecuencias de vehículos involucrados por franja horaria y por día de la semana, destacando los tipos predominantes en cada período.

4.4.2 *Pruebas diagnósticas de la serie temporal*

Para caracterizar formalmente la estructura temporal de la serie mensual de accidentes, se aplicaron un conjunto de pruebas estadísticas que permiten verificar los supuestos subyacentes a los modelos empleados (STL, Prophet, ITS) y justificar las correcciones aplicadas, como la estructura autorregresiva AR(1) en el modelo de series de tiempo interrumpidas.

Prueba de estacionalidad mensual (Kruskal-Wallis)

Con el fin de evaluar si existen diferencias significativas en el número de accidentes entre los meses del año, se utilizó la prueba no paramétrica de Kruskal-Wallis (Kruskal & Wallis, 1952). Esta prueba es adecuada porque no asume normalidad en la distribución de los datos y compara las medianas de los 12 grupos mensuales. La hipótesis nula establece que todas las medianas son iguales; un p -valor inferior a 0.05 indicaría diferencias significativas entre meses.

Prueba de estacionariedad (ADF)

Para determinar si la serie es estacionaria, se aplicó la prueba aumentada de Dickey-Fuller (*Augmented Dickey-Fuller*, ADF) (Dickey & Fuller, 1979, 1981). La estacionariedad es un supuesto importante para ciertos modelos; su ausencia justifica el uso de modelos que incorporan tendencia o diferenciación. La hipótesis nula de la prueba ADF establece que la serie **no es estacionaria** (presencia de raíz unitaria). Un p -valor inferior a 0.05 indica que se rechaza la hipótesis nula y la serie es estacionaria.

Prueba de autocorrelación (Ljung-Box)

Para detectar la presencia de dependencia serial en la serie, se aplicó la prueba de Ljung-Box (Ljung & Box, 1978) sobre los primeros 12 rezagos. Esta prueba evalúa si los datos son independientes; un p -valor bajo indica autocorrelación significativa, lo que justifica el uso de modelos que incorporen estructura autorregresiva.

Análisis de autocorrelación (ACF y PACF)

Complementariamente, se calcularon las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) (Box et al., 2015) para los primeros 48 rezagos. Estas herramientas permiten identificar visualmente la estructura de dependencia temporal: la ACF revela patrones de tendencia y estacionalidad, mientras que la PACF ayuda a determinar el orden de los componentes autorregresivos (AR). Los gráficos resultantes se utilizan como diagnóstico para seleccionar el orden de corrección en modelos como ITS.

Resumen de la estrategia de análisis

El Cuadro 4.2 resume las pruebas aplicadas, su propósito y el criterio de decisión.

Cuadro 4.2: Pruebas diagnósticas aplicadas a la serie temporal

Prueba	Propósito	Criterio de significancia
Kruskal-Wallis (Kruskal & Wallis, 1952)	Evaluar diferencias estacionales entre meses	$p < 0,05$: diferencias significativas
ADF (Dickey & Fuller, 1979, 1981)	Evaluar estacionariedad de la serie	$p < 0,05$: serie estacionaria
Ljung-Box (Ljung & Box, 1978)	Detectar autocorrelación en la serie	$p < 0,05$: autocorrelación presente
ACF / PACF (Box et al., 2015)	Identificar estructura de dependencia temporal	Análisis visual de rezagos significativos

4.4.3 *Análisis de series de tiempo (agregación mensual)*

Se agregaron los accidentes a nivel mensual mediante la función `preparar_serie_mensual()` que realiza:

1. Extrae el año y el mes de la columna `FECHA` mediante `year()` y `month()` del paquete `lubridate`.
2. Crea una variable `año_mes` que representa el primer día de cada mes (usando `floor_date(FECHA, "month")`).
3. Agrupa por `año_mes` y calcula: total de accidentes por mes, número de accidentes con heridos, con muertos y solo daños.
4. Ordena cronológicamente el resultado.

El resultado es un data frame con una fila por mes. Luego, mediante la función `crear_ts()` se convierte la columna `total_accidentes` en un objeto `ts` con inicio en enero de 2012 y frecuencia 12 (mensual).

Descomposición STL

Se aplicó la descomposición STL (*Seasonal-Trend decomposition using Loess*) mediante la función `stl()` del paquete `base stats`, con el argumento `s.window = "periodic"` para extraer una componente estacional constante. Esta técnica descompone la serie en tres componentes:

- **Tendencia:** movimiento de largo plazo.
- **Estacional:** patrón que se repite cada año.
- **Residuo:** fluctuaciones irregulares no explicadas por las anteriores.

Se generaron dos visualizaciones de la descomposición. Además, se calcularon:

- La varianza de cada componente.
- La fuerza de la estacionalidad F_s y de la tendencia F_t , definidas como:

$$F_s = 1 - \frac{\text{Var}(R)}{\text{Var}(S + R)}, \quad F_t = 1 - \frac{\text{Var}(R)}{\text{Var}(T + R)}$$

donde T , S y R son tendencia, estacional y residuo respectivamente. Valores cercanos a 1 indican componentes fuertes.

Análisis detallado de la estacionalidad

Se desarrolló la función `analizar_estacionalidad()`, que produce múltiples visualizaciones y pruebas estadísticas:

1. **Gráfico de estacionalidad por año** (`ggseasonplot` del paquete `forecast`): muestra las trayectorias de cada año superpuestas, facilitando la comparación interanual del patrón mensual.
2. **Gráfico de subseries mensuales** (`ggsubseriesplot`): presenta los valores de cada mes por separado a lo largo de los años, con una línea horizontal que indica la media de ese mes.
3. **Boxplot por mes**: diagramas de caja que resumen la distribución de accidentes para cada mes, incluyendo la media (marcada con un rombo) y los valores atípicos.
4. **Heatmap año-mes**: mapa de calor que muestra la intensidad de accidentes en cada celda (año vs. mes), utilizando una escala de colores divergente.
5. **Gráfico polar (circular)**: representa el promedio mensual en un círculo, resaltando visualmente los meses con mayor accidentalidad.

Además de las visualizaciones, se calcularon estadísticas descriptivas por mes (media, mediana, desviación estándar, coeficiente de variación, mínimo y máximo), y se ordenaron los meses según su media para identificar los de mayor y menor accidentalidad. Para evaluar si existen diferencias significativas entre meses, se aplicó la prueba no paramétrica de Kruskal-Wallis, que contrasta la hipótesis nula de que las distribuciones de accidentes son iguales en todos los meses.

4.4.4 Modelo Prophet (análisis complementario de patrones temporales)

Aunque la descomposición STL ya provee una estimación de tendencia y estacionalidad, se incorporó adicionalmente el modelo Prophet por tres razones. Primero, STL no modela explícitamente el efecto de fechas específicas (festivos, puentes), mientras que Prophet permite aislar y cuantificar ese efecto mediante su componente $h(t)$, de directa relevancia para la seguridad vial. Segundo, Prophet ofrece una estimación paramétrica del efecto promedio por día de la semana, complementaria a la inspección visual de subseries que ofrece STL. Tercero, su mecanismo de detección de changepoints en la tendencia sirve como verificación cruzada, independiente del método, frente a los puntos de cambio estructural identificados con Binary Segmentation y AMOC. Cabe señalar que, dado que Prophet no modela explícitamente la autocorrelación residual y su regularización privilegia tendencias suaves (ver supuestos del modelo), se

emplea en este trabajo como herramienta exploratoria y complementaria, no como sustituto del modelo de Series de Tiempo Interrumpidas (ITS) utilizado para cuantificar con rigor el impacto de la pandemia de COVID-19.

A partir de esto se construyó una serie temporal diaria agregando los accidentes por día, siguiendo los pasos:

1. Importación del archivo CSV y conversión de FECHA a Date con `as.Date()` y formato "`%d/%m/%Y`".
2. Agregación por día.
3. Renombrado de columnas a `ds` (fecha) y `y` (conteo) según exige Prophet.
4. Ordenamiento cronológico.

Especificación del modelo

Prophet es un modelo aditivo: $y(t) = g(t) + s(t) + h(t) + \varepsilon_t$, donde $g(t)$ es tendencia, $s(t)$ estacionalidad, $h(t)$ efecto de festivos y ε_t error. Se configuró con:

- `daily.seasonality = FALSE` (datos diarios sin información intra-diaria).
- `weekly.seasonality = TRUE` (para capturar diferencias entre días de la semana).
- `yearly.seasonality = TRUE` (para patrones anuales).
- `changepoint.prior.scale = 0.05` (sensibilidad moderada a cambios estructurales).

Incorporación de días festivos

Se utilizó la función `add_country_holidays()` con el código '`CO`' (Colombia), añadiendo automáticamente los festivos oficiales colombianos.

Análisis de componentes y visualización

Se generaron dos gráficos principales:

1. **Componentes del modelo:** se muestra un panel con tendencia, estacionalidad semanal, anual y efectos de festivos.

2. **Pronóstico general:** se visualizan datos reales (puntos negros), ajuste y predicción futura (línea azul) con intervalos de confianza (sombra azul).

Análisis específicos

- **Impacto de días festivos:** a partir del componente `holidays` se identificaron los diez días festivos con mayor impacto absoluto en la accidentalidad y ordenando por valor absoluto.
- **Efecto del día de la semana:** se extrajo el componente `weekly`, se asoció a cada fecha su día de la semana con `wday()`, y se promedió el efecto por día, obteniendo el cambio relativo esperado para cada día de la semana.

4.5. Análisis espacial de la siniestralidad vial

El análisis espacial se desarrolló a partir de la agregación de los accidentes a unidades geográficas (barrios y comunas), permitiendo la construcción de indicadores espaciales y la integración con el shapefile de barrios. Se realizaron tanto análisis no espaciales (rankings, cuadrantes) como análisis con autocorrelación espacial.

4.5.1 Cálculo de tasas y normalización

Para comparar la siniestralidad entre unidades espaciales se calcularon tasas ajustadas por población.

Tasa anual por barrio (por 1.000 habitantes)

A partir de los datos de accidentes se agregó el total de siniestros por barrio durante todo el período. Con la población de cada barrio se calculó la tasa anual promedio por cada 1.000 habitantes:

$$\text{Tasa}_b = \frac{\text{Accidentes totales en barrio } b}{\text{Población del barrio } b} \times \frac{1.000}{\text{número de años}}$$

donde el número de años corresponde al período de estudio (12 años, 2012–2023). Esta estandarización permite comparar el riesgo entre barrios independientemente de su tamaño poblacional.

Nota: No existían datos del parque automotor por comuna y por eso utilizaron la población como denominador.

Tasa por comuna y tipo de vehículo

Para el análisis de tasas por tipo de vehículo a nivel de comuna:

1. Se agregaron los conteos de vehículos por comuna (sumando los involucrados en cada accidente).
2. Se importó el archivo de población (`poblacionbga.csv`), limpiando formatos y sumando la población por comuna.
3. Mediante unión izquierda se combinaron los datos de accidentes con la población correspondiente.
4. Para cada tipo de vehículo v y comuna c se calculó:

$$\text{Tasa}_{v,c} = \frac{\text{Número de vehículos tipo } v \text{ en comuna } c}{\text{Población de la comuna } c} \times \frac{1.000}{\text{número de años}}$$

Nota: la implementación actual en `calcular_tasas_vehiculos()` agrega los conteos de vehículos sobre todo el período (2012–2023) pero no divide entre el número de años, por lo que los valores reportados corresponden a una tasa acumulada de 12 años y no a una tasa anual; el script debe actualizarse para incluir esta división antes de reportar los resultados como “tasa anual”.

5. Se construyó una matriz de tasas (formato largo) y se visualizó con un mapa de calor.

Ranking de barrios y análisis de cuadrantes

Se generaron dos rankings de barrios:

- **Ranking por frecuencia absoluta:** orden descendente según el número total de accidentes.
- **Ranking por tasa estandarizada:** orden descendente según la tasa anual por 1.000 habitantes.

La diferencia entre ambos rankings permite identificar barrios cuya peligrosidad relativa aumenta o disminuye al ajustar por población.

Tomando como referencia las medianas de ambos rankings, se clasificaron los barrios en cuatro cuadrantes estratégicos:

Q1: Prioridad máxima Alta frecuencia y alta tasa (por encima de la mediana en ambos rankings).

Q2: Gran población Alta frecuencia pero baja tasa (población numerosa que diluye la tasa).

Q3: Población pequeña Baja frecuencia pero alta tasa (barrios pequeños con alto riesgo per cápita).

Q4: Bajo riesgo Baja frecuencia y baja tasa.

Para cada cuadrante se calcularon: número de barrios, total de accidentes, población total y tasa promedio. Estos resúmenes se exportaron a archivos CSV.

4.5.2 Representación cartográfica

Se generaron múltiples mapas temáticos y gráficos complementarios utilizando `ggplot2` en combinación con `geom_sf`.

Mapas temáticos (análisis exploratorio y de riesgo)

1. **Mapa de categorías de riesgo:** representa los barrios según la clasificación cualitativa (Sin accidentes, Bajo 1-5, Medio 6-15, Alto 16-30, Muy alto >30) con colores graduados.
2. **Mapa de accidentes con heridos:** escala de color continua que muestra la intensidad de accidentes con víctimas heridas.
3. **Mapa de porcentaje de accidentes con motos:** resalta los barrios donde las motocicletas tienen mayor protagonismo relativo.
4. **Mapa de densidad de accidentes:** visualiza el volumen total de accidentes por barrio mediante gradación de color.

Mapas derivados del análisis de tasas

- **Mapa de tasas continuo:** mapa coroplético que representa la tasa de accidentalidad por barrio con una escala de color continua (viridis), destacando valores extremos.
- **Mapa de categorías de tasa:** clasificación en seis categorías (tasa por 1.000 habitantes): Sin accidentes (tasa = 0), Muy bajo (<1), Bajo (1–3), Medio (3–6), Alto (6–10), Muy alto (>10). Cada categoría con color específico, generando tabla resumen con número de barrios, accidentes y población por categoría.
- **Mapa de cuadrantes de priorización:** barrios coloreados según el cuadrante (Q1–Q4), permitiendo visualizar espacialmente las zonas que requieren atención prioritaria.

- **Mapas por tipo de vehículo:** mapas individuales para motos, automóviles, peatones y bicicletas, mostrando tasa de involucramiento por cada 1.000 habitantes. Además, se creó un panel combinado con los cuatro mapas.
- **Mapa comparativo frecuencia vs. tasa:** panel de tres mapas: frecuencia absoluta, tasa estandarizada, y cambio en el ranking (diferencia entre ranking por frecuencia y ranking por tasa), categorizado en bajadas, subidas y sin cambio.

Gráficos no espaciales complementarios

1. **Comparación de rankings:** gráfico de dispersión que enfrenta el ranking por frecuencia contra el ranking por tasa, destacando los barrios que aparecen en ambos rankings y el caso emblemático de Río de Oro I (cambio más dramático).
2. **Top 20 barrios por tasa:** gráfico de barras horizontales con los barrios de mayor tasa, categorizados por nivel de riesgo (Extremo, Muy alto, Alto, Moderado).
3. **Caso Río de Oro vs. Centro:** gráfico de barras que muestra cómo cambia la posición en el ranking al pasar de frecuencia absoluta a tasa, evidenciando el sesgo poblacional.
4. **Heatmap de tasas por comuna:** mapa de calor que ordena las comunas de mayor a menor tasa, con el valor numérico sobre cada celda.
5. **Tasas de vehículos por comuna:** gráfico de barras agrupadas que muestra las tasas de involucramiento de motos, automóviles, peatones y bicicletas en las diez comunas con mayor tasa de motos.

4.5.3 Autocorrelación espacial (Índice de Moran global)

Construcción de la matriz de pesos espaciales

A partir de las coordenadas de los centroides de cada barrio, se construyó la matriz de vecindad utilizando el criterio de k vecinos más cercanos (k -NN, sección 3.5.7), mediante la función `knearneigh()` del paquete `spdep`, cuyo resultado se convirtió en un objeto `nb` y se estandarizó con pesos fila (estilo “W”) mediante `nb2listw()`.

Justificación del criterio de vecindad

La elección de k -NN, en lugar de contigüidad, responde directamente a la limitación de esta última señalada en la sección teórica: dada la heterogeneidad en tamaño y forma de los 219 polígonos del shapefile de barrios de Bucaramanga barrios pequeños o con fronteras irregulares en la periferia, un criterio de contigüidad simple habría generado con alta probabilidad varias observaciones sin vecino, para las cuales el rezago espacial $\sum_j w_{ij}y_j$ queda indeterminado y obliga a decisiones adicionales sobre el ajuste de n en el cálculo de la esperanza y la varianza de I . El criterio k -NN evita esta complicación por construcción.

Justificación de $k = 5$

El valor de k determina la escala espacial a la que se mide la autocorrelación: valores bajos capturan estructura muy local (sensible a ruido si algún vecino inmediato es atípico), mientras que valores altos aproximan W a un promedio de vecindario amplio que diluye patrones de agrupamiento fino. Se fijó $k = 5$ por tres razones:

1. Garantiza un número mínimo de vecinos suficiente para calcular un rezago espacial estable en todos los barrios, incluidos los de menor tamaño.
2. Se sitúa dentro del rango convencional ($k = 4$ a $k = 8$) reportado en aplicaciones comparables de LISA sobre unidades administrativas urbanas (Effati et al., 2015; Thakali et al., 2015).
3. Constituye un punto intermedio razonable entre capturar el entorno inmediato de cada barrio y evitar que W se aproxime en exceso a un promedio cuasi-global, lo que atenuaría artificialmente el estadístico de Moran.

I de Moran

El índice de Moran global mide el grado de autocorrelación espacial en todo el conjunto de datos. Se calculó con la función `moran.test()` sobre la variable `tasa_1k`, utilizando la matriz de pesos espaciales definida. Con respecto al estadístico I de Moran si es un valor positivo y significativo indica que barrios con tasas similares tienden a agruparse espacialmente; un valor negativo indica dispersión. La significancia se evaluó mediante un test de aleatorización.

4.5.4 Identificación de clusters (LISA)

Para identificar conglomerados locales se aplicó el estadístico de Moran local (LISA) mediante la función `localmoran()`. Este descompone el índice global en contribuciones por cada barrio, permitiendo clasificarlos según su valor y el de sus vecinos. Se estandarizó la variable `tasa_1k` (obteniendo `s_tasa`) y se calculó su rezago espacial `lag_s_tasa` como el promedio ponderado de los vecinos.

Con base en el signo de `s_tasa` y `lag_s_tasa`, y considerando un nivel de significancia del 5 % ($p\text{-valor} < 0.05$), se clasificaron los barrios en cinco categorías:

- **Hotspot (High-High):** barrio con alta tasa y vecinos con alta tasa (conglomerado de alto riesgo).
- **Coldspot (Low-Low):** barrio con baja tasa y vecinos con baja tasa (conglomerado de bajo riesgo).
- **Outlier (High-Low):** barrio con alta tasa rodeado de vecinos con baja tasa.
- **Outlier (Low-High):** barrio con baja tasa rodeado de vecinos con alta tasa.
- **No Significativo:** cuando el p-valor no alcanza el umbral de significancia.

Una vez obtenida la clasificación LISA, se filtraron los barrios pertenecientes a la categoría “Hotspot (High-High)” y se ordenaron de mayor a menor según su tasa de accidentalidad. Se seleccionaron los tres barrios con las tasas más altas dentro de este grupo para ser destacados en el mapa final.

Visualización de resultados LISA

Se generó un mapa temático utilizando `ggplot2` y `sf`, con:

- Capa base de todos los barrios coloreados según su clasificación LISA.
- Paleta de colores profesional: rojo intenso para hotspots, azul fuerte para coldspots, naranja y azul claro para outliers, y gris para áreas no significativas.
- Etiquetas inteligentes para los tres hotspots más críticos, mostrando el nombre del barrio sin superposición.
- Título, subtítulo y leyenda explicativa.

4.6. Análisis de la participación de actores viales

Se analizó la participación de los diferentes actores viales involucrados en los accidentes, incluyendo motociclistas, conductores de vehículos particulares, peatones, bicicletas, camiones y buses. Se examinó la frecuencia de participación y la interacción entre actores mediante análisis de co-ocurrencia.

4.6.1 Frecuencias y perfiles por gravedad

Para examinar la relación entre la severidad del accidente y los tipos de vehículos involucrados, se clasificaron los siniestros según la variable de gravedad, que distingue entre accidentes con solo daños materiales, con heridos y con víctimas fatales. Para cada una de estas tres categorías se contabilizó la frecuencia absoluta con que aparece cada tipo de vehículo (motocicleta, automóvil, peatón, bicicleta, camión, bus, etc.). Adicionalmente, se calcularon las proporciones relativas (porcentajes) que cada actor representa dentro de cada nivel de gravedad, lo que permite comparar si ciertos actores están sobrerrepresentados en los siniestros más graves. Los resultados se presentan en un gráfico de barras agrupadas, donde cada grupo corresponde a un nivel de gravedad y cada barra muestra la frecuencia (absoluta o relativa) de un tipo de vehículo, facilitando así la comparación del perfil de actores según la severidad del accidente.

4.6.2 Análisis de co-ocurrencia de vehículos

Se evaluó la tendencia de ciertos tipos de vehículos a aparecer juntos en un mismo accidente. Para ello:

1. Se creó una matriz binaria indicando presencia (1) o ausencia (0) de cada tipo de vehículo en cada accidente.
2. Multiplicando la matriz traspuesta por sí misma se obtuvo la matriz de co-ocurrencia, cuyas entradas representan el número de accidentes en los que dos tipos de vehículo participaron simultáneamente.
3. La diagonal se fijó en cero para centrar el análisis en las relaciones entre distintos tipos.
4. Esta matriz se visualizó mediante un mapa de calor.

4.6.3 *Análisis temporal por tipo de vehículo (series mensuales)*

Se definió una función que permite estudiar la evolución temporal del involucramiento de cada tipo de vehículo:

1. Se transforman los datos a formato largo, seleccionando las columnas que indican el número de vehículos de cada tipo involucrados en cada accidente (desde PEATON hasta OTRO).
2. Se filtran únicamente los registros con participación positiva ($\text{INVOLUCRADO} > 0$).
3. Se agrupa por mes y tipo de vehículo, contando el número total de involucramientos por mes para cada categoría.
4. Se genera un gráfico de líneas múltiples que muestra la evolución mensual de los cuatro tipos principales (motos, automóviles, peatones, bicicletas), junto con una curva suavizada (LOESS) para visualizar tendencias.

Este análisis permite detectar cambios en la composición del parque automotor involucrado en siniestros a lo largo del período de estudio.

4.7. Herramientas computacionales

Todos los análisis estadísticos se ejecutaron mediante el software R, versión 4.3.3 (R Core Team, 2024), se estableció el directorio de trabajo y se cargaron las librerías necesarias, los principales paquetes utilizados fueron:

- **tidyverse** (2.0.0): conjunto que incluye `ggplot2` (visualización), `dplyr` y `tidyr` (manipulación), `readr` (importación), `stringr` (limpieza de cadenas).
- **sf** (1.0-16): lectura, manipulación y escritura de datos espaciales en formato vectorial.
- **spdep** (1.3-1): para el cálculo de matrices de vecindad, índices de Moran global y local (LISA).
- **forecast** (8.21.1): funciones `ggseasonplot` y `ggsubseriesplot`.
- **changepoint** (2.2.4): detección de puntos de cambio.
- **prophet** (1.0): implementación del modelo de pronóstico de Facebook (dependencias `Rcpp` y `rstan`).

- **lubridate** (1.9.4): manejo de fechas.
- **reshape2** (1.4.5): para reestructurar matrices y data frames (función `melt()`).
- **viridis** (0.6.5): proporciona escalas de color perceptuales y amigables para daltónicos en los gráficos.
- **patchwork** (1.2.0): para la composición de múltiples gráficos en una misma figura.
- **ggrepel** (0.9.3): para añadir etiquetas sin superposición en mapas.
- **RColorBrewer** (1.1-3): paletas adicionales para mapas categóricos.
- **ggfortify** (0.4.16): para visualización de descomposiciones con `ggplot2`.

Los gráficos generados (mapas de calor, barras, mosaicos, densidades, mapas temáticos, series de tiempo, etc.) se exportaron en formato PNG con resolución de 300 dpi y se almacenaron en la carpeta `figuras` (creada automáticamente si no existía). Los resultados numéricos (resúmenes estadísticos, rankings, tablas de tasas, etc.) se exportaron a archivos CSV en la carpeta `resultados`. El shapefile enriquecido con todas las variables calculadas se guardó como `barrios_accidentes_analisis.shp`, listo para ser utilizado en sistemas SIG.

5 Análisis y resultados

5.1. Análisis descriptivo general

5.1.1 Resumen estadístico general

Durante el período 2012–2023 se registraron 39.193 siniestros viales en Bucaramanga, cerca de la mitad de esos eventos dejaron personas heridas, mientras que los desenlaces fatales constituyeron una fracción muy inferior. Respecto al momento de ocurrencia, casi tres de cada diez hechos se presentaron en horario nocturno, lo que revela un peso significativo de la noche en la dinámica de la siniestralidad. (Cuadro 5.1).

Este panorama indica que la carga de morbilidad se concentra en los siniestros con lesionados, al tiempo que la baja proporción de fatalidades no debe opacar su extrema gravedad, estas magnitudes permiten dimensionar el problema de la accidentalidad vial en la ciudad y constituyen el punto de partida para los análisis temporales, espaciales y modales desarrollados en las siguientes secciones.

Cuadro 5.1: Resumen estadístico general

Indicador	Frecuencia	Porcentaje (%)
Total de accidentes	39.193	100
Accidentes con heridos	18.982	46,02
Accidentes con muertos	609	1,6
Accidentes en horario nocturno	11.640	29,7

5.1.2 Distribución geográfica por comuna

La matriz de frecuencias absolutas por comuna (Cuadro 5.2) evidencia que la participación de vehículos en los accidentes de tránsito no se distribuye de manera homogénea entre las comunas de Bucaramanga. Las mayores frecuencias se concentran en sectores con alta dinámica urbana: Cabecera del Llano (C12), San Francisco (C03), Centro (C15), Provenza (C10) y La Concordia (C06), comunas que coinciden con los principales corredores comerciales y viales de la ciudad.

En todas las comunas analizadas, las motocicletas y los automóviles representan los tipos de vehículos con mayor participación en los siniestros, aunque con diferencias relativas entre sectores. Por ejemplo, San Francisco (C03) presenta los mayores registros de motocicletas involucradas (3.211), superando incluso a Cabecera del Llano (C12), que tiene una población mayor. Esto sugiere que San Francisco podría ser un punto de suma importancia para la circulación de motos, posiblemente por su configuración vial y su actividad comercial. En contraste, Cabecera del Llano (C12) concentra la mayor frecuencia de automóviles (4.626), lo que refleja su carácter de zona residencial y de oficinas con alta densidad de tráfico vehicular privado.

La participación de peatones muestra valores relevantes en comunas centrales como Centro (C15) con 514 peatones involucrados, seguido de San Francisco (C03) con 460 y La Concordia (C06) con 374. Estos datos sugieren una interacción más intensa entre movilidad vehicular y peatonal en estos sectores urbanos, donde confluyen flujos comerciales, institucionales y de transporte público. Por el contrario, la participación de bicicletas es baja en todas las comunas, con cifras que no superan los 88 registros, lo que indica que este modo de transporte tiene aún una presencia marginal en la siniestralidad vial de la ciudad.

Los resultados sugieren una concentración importante de la accidentalidad en sectores urbanos con alta circulación vehicular y fuerte actividad comercial, lo que evidencia diferencias espaciales en la composición modal de los accidentes entre comunas. Estos hallazgos son relevantes para orientar intervenciones diferenciadas por zona, pues las estrategias para reducir accidentes en San Francisco donde predominan las motos no necesariamente serían las mismas que en Cabecera del Llano, donde los automóviles son el actor principal.

Cuadro 5.2: Frecuencia absoluta de vehículos involucrados por comuna (principales comunas)

Tipo	C03	C12	C15	C10	C06	C13
AUTOMÓVIL	3.114	4.626	2.720	1.620	1.963	3.572
BICICLETA	82	88	58	43	59	74
BUS	244	280	179	186	140	207
BUSETA	217	257	256	42	122	182
CAMION	531	338	359	121	240	301
CAMIONETA	934	1.363	765	469	563	965
CAMPERO	226	579	249	155	165	377
MICRO	89	137	100	52	66	103
MOTO	3.211	2.801	2.359	1.197	1.785	2.593
PEATÓN	460	407	514	205	374	367
VOLQUETA	101	60	31	28	27	63

Nota: Las comunas corresponden a: C03 = San Francisco, C12 = Cabecera, C15 = Centro, C10 = Provenza, C06 = La Concordia, C13 = Oriental. Las cifras en negrita indican el valor máximo de cada tipo de vehículo entre las comunas mostradas.

5.1.3 Tasas de involucramiento por comuna (estandarizadas por población)

Para comparar la accidentalidad entre comunas controlando las diferencias poblacionales, se calcularon tasas por cada 1.000 habitantes para los principales tipos de vehículos. La Figura 5.1 presenta un mapa de calor de estas tasas.

El mapa de calor evidencia diferencias espaciales importantes en la intensidad relativa del involucramiento vehicular entre comunas. Las mayores tasas asociadas con motocicletas se concentran en comunas como San Francisco (C03), La concordia (C06) y Centro (C15), lo que sugiere una alta exposición y circulación de este tipo de vehículo en estas zonas, caracterizadas por una intensa actividad comercial y una alta densidad de flujo vehicular. En el caso de los automóviles, los valores más elevados se presentan principalmente en Cabecera del Llano (C12) y Centro (C15), lo que refleja el predominio del vehículo particular en sectores residenciales de alto poder adquisitivo y en el núcleo administrativo y comercial de la ciudad.

Es relevante destacar que la comuna 14 (Morrórico) presenta tasas bajas en todas las categorías de vehículos, lo que contrasta con la alta accidentalidad observada en las comunas centrales. Este patrón

sugiere que la siniestralidad no solo depende de factores poblacionales, sino también de la dinámica urbana, la configuración vial y los usos del suelo. Por ejemplo, la alta tasa de motos en San Francisco y Oriental podría estar asociada al uso de motocicletas como medio de transporte laboral (Filigrana, 2014), mientras que la alta tasa de automóviles en Cabecera del Llano refleja el carácter residencial y de oficinas de esa zona.




Figura 5.1: Mapa de calor de tasas de involucramiento (por 1.000 hab)

5.2. Análisis temporal de la siniestralidad vial

5.2.1 Distribución por franja horaria

El cuadro 5.3 presenta la distribución de accidentes según la franja horaria. Las horas de mayor siniestralidad son la tarde temprano (12–15h) con 7.646 accidentes (19.5 %), seguidas de la tarde (15–18h) con 7, 236 (18.5 %) y la mañana (9–12h) con 6, 910 (17.6 %). La madrugada (0–6h) y la noche (21–24h) presentan menos frecuencia de accidentalidad en general.

Cuadro 5.3: Distribución de accidentes por franja horaria

Franja horaria	Total	Con heridos	Con muertos	Solo daños	Porcentaje
Madrugada (0-6h)	2.718	1.467	131	1.120	6,93
Mañana temp. (6-9h)	5.775	3.035	69	2.671	14,74
Mañana (9-12h)	6.910	2.979	80	3.851	17,63
Tarde temp. (12-15h)	7.646	3.575	68	4.003	19,51
Tarde (15-18h)	7.236	3.210	90	3.936	18,46
Noche temp. (18-21h)	6.194	3.066	105	3.023	15,80
Noche (21-24h)	2.708	1.650	63	995	6,91

El mapa de calor de la Figura 5.2 cruza la franja horaria con la gravedad, destacando que los accidentes con muertos son más frecuentes en la madrugada y la noche.

Aunque la madrugada y la noche presentan una menor cantidad total de accidentes en comparación con otras franjas horarias, los accidentes fatales muestran una presencia relativamente más importante durante estos períodos. La distribución horaria evidencia una mayor concentración de accidentes durante las franjas de mayor actividad urbana y movilidad diaria, particularmente entre las 9:00 y las 18:00 horas. En contraste, aunque la madrugada y las horas nocturnas presentan menores frecuencias absolutas, los accidentes fatales muestran una participación relativamente más importante en estos períodos.




Figura 5.2: Heatmap de accidentes por franja horaria y gravedad

5.2.2 Distribución por día de la semana

La distribución semanal de los accidentes de tránsito en Bucaramanga evidencia un patrón claramente diferenciado entre los días laborales y el fin de semana. La Tabla 5.4 muestra que el sábado es el día con mayor frecuencia absoluta (6.460 accidentes, 16,5 % del total), seguido del viernes (5.969, 15,2 %) y el martes (5.829, 14,9 %). En el extremo opuesto, el domingo presenta la cifra más baja (4.137, 10,6 %), con una diferencia de más de 2.300 accidentes respecto al sábado.

Cuadro 5.4: Distribución de accidentes por día de la semana

Día	Total	Con heridos	Con muertos	Solo daños	Promedio hora	Porcentaje
Lunes	5.386	2.563	62	2.761	13,5	13,7
Martes	5.829	2.743	84	3.002	13,5	14,9
Miércoles	5.712	2.660	78	2.974	13,6	14,6
Jueves	5.700	2.674	68	2.958	13,5	14,5
Viernes	5.969	2.843	84	3.042	13,8	15,2
Sábado	6.460	3.175	123	3.162	13,8	16,5
Domingo	4.137	2.324	110	1.703	12,9	10,6

El patrón semanal revela una transición gradual desde los días laborales hacia el fin de semana. Entre martes y jueves, los valores son relativamente homogéneos, con frecuencias que oscilan entre 5.700 y 5.829 accidentes, lo que sugiere una dinámica de accidentalidad estable durante la semana laboral. El viernes marca un punto de inflexión: el incremento en la movilidad asociada al cierre de la semana laboral eleva la accidentalidad en casi 200 siniestros respecto al jueves, estableciendo el inicio del fin de semana como un período de mayor riesgo. El sábado consolida este patrón, alcanzando el máximo semanal con 6.460 accidentes, lo que refleja una movilidad intensa y diversificada a lo largo de todo el día.

El domingo presenta un comportamiento cualitativamente diferente, más allá de ser el día con menor número de accidentes, la hora promedio de ocurrencia es notablemente más temprana (12.9 h) en comparación con el resto de la semana (13.5–13.8 h), lo que sugiere que la movilidad dominical se concentra en las horas de la mañana y el mediodía, disminuyendo hacia la noche. También es relevante que, a pesar de tener el menor número absoluto de accidentes, el domingo registra 110 accidentes con víctimas fatales, solo 13 menos que el sábado (123), lo que indica que la severidad de los siniestros dominicales es proporcionalmente mayor. Esto podría estar asociado a la conducción en condiciones de menor congestión (y por tanto mayores velocidades) y a la posible presencia de alcohol en horarios nocturnos. (Cárdenas & Pérez, 2010)

El heatmap de la Figura 5.3 complementa este análisis al desagregar la distribución horaria dentro de cada día. Se observa que las franjas comprendidas entre el mediodía y la noche concentran las ma-

yores frecuencias en la mayoría de los días, destacándose especialmente los viernes y sábados en horas de la tarde y noche. Los días laborales (martes, miércoles, jueves) presentan un patrón relativamente homogéneo, con picos en la tarde temprano (12–15h) y la tarde (15–18h), coincidiendo con los horarios de mayor actividad comercial y desplazamientos laborales. El sábado, en cambio, muestra una distribución más extendida a lo largo del día, con altas frecuencias desde la mañana hasta la noche, y picos pronunciados en la tarde y noche temprana, lo que refleja la diversidad de actividades recreativas y comerciales propias del fin de semana. Un patrón interesante es el que se observa en la madrugada (0–6h) durante los fines de semana: aunque los números absolutos son bajos en comparación con las horas pico, la proporción relativa de accidentes en esta franja es mayor el sábado y el domingo que en los días laborales, lo que sugiere una mayor incidencia de conducción nocturna asociada a actividades de ocio; este hallazgo tiene implicaciones prácticas para los operativos de control de alcoholemia y velocidad, que deberían reforzarse en las noches de viernes y sábado.

Estos resultados indican que la seguridad vial en Bucaramanga no puede abordarse con estrategias uniformes a lo largo de la semana. Los patrones de accidentalidad responden a ritmos sociales y de movilidad claramente diferenciados: campañas de prevención y controles deben intensificarse los viernes y sábados, especialmente en horas de la tarde y noche, mientras que el domingo, aunque con menor volumen, requiere atención particular debido a la mayor severidad relativa de los siniestros.




Figura 5.3: Heatmap de accidentes por día de la semana y franja horaria

5.2.3 Horas pico y densidad horaria

El cuadro 5.5 muestra las 10 horas del día con mayor número de accidentes. La hora 12 (mediodía) encabeza la lista con 2.927 accidentes, seguida de las 18 (6 p.m.) con 2.597 y las 14 (2 p.m.) con 2.563.

Cuadro 5.5: Top 10 horas con más accidentes

Hora	Accidentes
12	2.927
18	2.597
14	2.563
11	2.508
15	2.490
16	2.487
17	2.375
10	2.270
19	2.177
13	2.119

La Figura 5.4 muestra la distribución de densidad de accidentes a lo largo del día, con una mayor concentración alrededor de las 12–14 h y una segunda concentración relativa alrededor de las 18 h, un aspecto destacable es el aumento progresivo de la densidad desde las primeras horas de la mañana: la curva asciende de forma sostenida desde las 6:00 h hasta alcanzar el pico del mediodía, lo que indica que el riesgo vial se incrementa de manera constante a medida que la ciudad despierta y se activa. En contraste, el descenso nocturno es más gradual, extendiéndose hasta altas horas de la madrugada, lo que sugiere que la movilidad nocturna, aunque menor en volumen, se distribuye a lo largo de un período más prolongado.




Figura 5.4: Distribución de densidad de accidentes por hora del día

5.2.4 *Análisis Prophet*

Resumen

El análisis de la serie diaria revela tres patrones temporales: una tendencia con caída en 2020 y recuperación parcial; un patrón semanal con sábado de mayor frecuencia y domingo de menor, pero más severo; y una reducción sistemática en días festivos como Viernes Santo y día de San José. A continuación se presentan estos patrones.

Componentes del modelo

La Figura 5.5 presenta los componentes estimados mediante Prophet para la serie diaria de accidentes entre 2012 y 2023. El eje vertical de cada panel representa el efecto aditivo del componente sobre el conteo diario de accidentes, el panel superior muestra la tendencia de largo plazo que refleja los cambios en el nivel medio de accidentalidad a lo largo de los doce años. Los paneles siguientes muestran el efecto aditivo de los días festivos nacionales, la estacionalidad semanal y la estacionalidad anual. Cada uno de estos componentes indica cuántos accidentes adicionales o menos (en promedio) se esperan en una fecha determinada debido a ese factor.




Figura 5.5: Descomposición de componentes de Prophet

La tendencia de largo plazo muestra una reducción progresiva del número esperado de accidentes a lo largo del período de estudio, particularmente a partir de 2019. Este comportamiento es consistente con la disminución observada previamente en las frecuencias anuales agregadas. La caída se acentúa en 2020, coincidiendo con las restricciones de movilidad por la pandemia de COVID-19, y aunque se observa una recuperación parcial en 2021 y 2022, el nivel de accidentalidad no alcanza los valores previos a 2019. Este patrón sugiere que, además del efecto coyuntural de la pandemia, puede haber factores estructurales (cambios en los hábitos de movilidad, mejoras en infraestructura, etc.) que han contribuido a una reducción sostenida de la siniestralidad.

El componente de días festivos revela que todos los festivos nacionales incluidos en el modelo tienen un efecto negativo sobre el número esperado de accidentes, es decir, reducen la accidentalidad. Los efectos más pronunciados corresponden al Día de San José, el Día de la Raza, la Independencia de Cartagena y el Viernes Santo. Esta reducción refleja la menor movilidad laboral y comercial durante estos días, lo que disminuye la exposición al riesgo vial.

La estacionalidad semanal muestra un patrón asimétrico. El sábado presenta el efecto positivo más alto, seguido del viernes. Los días laborales (lunes a jueves) presentan efectos cercanos a cero o ligeramente positivos, indicando una accidentalidad relativamente uniforme durante la semana laboral. El domingo, en contraste, muestra el efecto más negativo, consistente con la menor circulación vehicular dominical. La brecha entre el sábado y el domingo subraya que el riesgo de fin de semana se concentra en el sábado.

La estacionalidad anual revela fluctuaciones a lo largo del año, con valores positivos en ciertos meses (especialmente hacia finales del año) y valores negativos en otros. Aunque menos pronunciada que la estacionalidad semanal.

Efecto del día de la semana

El componente de estacionalidad semanal cuantifica cómo varía el número esperado de accidentes a lo largo de los días de la semana, en promedio durante todo el período. El cuadro 5.6 resume los valores estimados, expresados como desviación aditiva respecto del conteo promedio diario.

Cuadro 5.6: Efecto estimado del día de la semana sobre la accidentalidad diaria

Día	Efecto (accidentes/día)	Dirección
Sábado	+1,28	↑ Mayor accidentalidad
Viernes	+0,59	↑
Lunes	+0,24	↑
Martes	+0,23	↑
Jueves	+0,10	↑
Miércoles	+0,07	≈ Neutro
Domingo	-2,51	↓ Menor accidentalidad

El sábado es el día de mayor accidentalidad (+1,28 accidentes/día sobre el promedio), lo que indica que los sábados presentan una frecuencia esperada de accidentes superior al promedio semanal. El viernes ocupa el segundo lugar (+0,59), coherente con el desplazamiento masivo al cierre de la semana laboral. Los días entre semana (lunes a jueves) muestran efectos ligeramente positivos pero cercanos a cero, lo que indica una accidentalidad relativamente uniforme durante la semana laboral.

El resultado más destacado es el efecto marcadamente negativo del domingo (-2,51 accidentes/día), que representa la reducción más pronunciada de toda la semana y vemos que el domingo presenta la mayor reducción respecto al promedio semanal.

Impacto de los festivos nacionales

El modelo incorporó automáticamente el calendario de festivos oficiales de Colombia. El cuadro 5.7 muestra los festivos con mayor efecto reductor sobre la accidentalidad diaria. Todos ellos presentan efectos negativos, es decir, reducen el número esperado de accidentes, lo que es coherente con la menor movilidad laboral y comercial en esos días.

Cuadro 5.7: Festivos nacionales con mayor impacto negativo sobre la accidentalidad diaria

Fecha	Festivo	Efecto (accidentes/día)
2018-03-19	Día de San José	-6,80
2020-10-12	Día de la Raza	-6,35
2019-11-11	Independencia de Cartagena	-6,00
2013-03-29	Viernes Santo	-5,53
<i>(se repite en todos los años)</i>		

El Viernes Santo aparece sistemáticamente en todos los años con un efecto constante de $-5,53$ accidentes/día, lo que indica un patrón muy estable. El Día de San José (19 de marzo) registra el mayor impacto individual ($-6,80$ accidentes/día) en los años en que coincidió con día hábil (2012 y 2018). El Día de la Raza (12 de octubre) y la Independencia de Cartagena (11 de noviembre) presentan impactos intermedios, también solo en los años en que estas fechas cayeron en día hábil y, por tanto, generaron una reducción real de la movilidad laboral.

5.2.5 Análisis de series de tiempo

Resultados de las pruebas diagnósticas de la serie temporal

A continuación se presentan los resultados de las pruebas estadísticas aplicadas a la serie mensual de accidentes para caracterizar su estructura temporal. Los hallazgos permiten validar las decisiones metodológicas adoptadas en el análisis temporal.

Estacionalidad mensual (Kruskal-Wallis)

La prueba de Kruskal-Wallis arrojó un estadístico $\chi^2 = 11,408$ con 11 grados de libertad y un p -valor de 0,4097. Dado que este valor supera ampliamente el nivel de significancia convencional ($\alpha = 0,05$), no se rechaza la hipótesis nula. En consecuencia, no existe evidencia estadística suficiente para afirmar que los meses presentan diferencias significativas en el número de accidentes. Este hallazgo es consistente con la baja fuerza de estacionalidad ($F_s = 0,289$) obtenida en la descomposición STL y confirma que las variaciones mensuales observadas no responden a un patrón estacional consistente.

Tendencia general

Se ajustó un modelo de regresión lineal simple a la serie mensual para estimar la tendencia de largo plazo. La pendiente estimada fue $\hat{\beta}_1 = -0,05$ accidentes por mes, con un p -valor prácticamente nulo ($p \approx 0$). Este resultado indica una disminución promedio de aproximadamente 0.6 accidentes por año a lo largo del período 2012–2023. La alta significancia estadística confirma que la tendencia decreciente es real y no atribuible al azar, lo cual es coherente con la alta fuerza de tendencia ($F_t = 0,904$) reportada en la descomposición STL.

Estacionariedad (ADF)

La prueba ADF arrojó un p -valor de 0,4059, muy superior al umbral de 0,05. Por lo tanto, no se rechaza la hipótesis nula, lo que indica que la serie original no es estacionaria. Este comportamiento era esperado, dado que la serie presenta una tendencia de largo plazo y cambios estructurales significativos (como el asociado a la pandemia de COVID-19). La no estacionariedad justifica el uso de modelos que incorporan explícitamente la tendencia (STL, Prophet) o que corrigen la autocorrelación de los residuos (ITS con corrección AR(1)).

Autocorrelación (Ljung-Box)

La prueba de Ljung-Box sobre los primeros 12 rezagos arrojó un p -valor prácticamente nulo ($p \approx 0$), lo que permite rechazar la hipótesis nula con alta confianza. En consecuencia, la serie presenta autocorrelación significativa, confirmando que el número de accidentes en un mes está correlacionado con el de meses anteriores. Este resultado es consistente con la prueba de Durbin-Watson aplicada en el modelo ITS ($DW = 0,927$, $p < 0,001$) y justifica la inclusión de una estructura autorregresiva AR(1) en dicho modelo.

Análisis de autocorrelación (ACF y PACF)

La Figura 5.6 presenta las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) para los primeros 48 rezagos. La ACF muestra un decaimiento lento y positivo en los primeros rezagos (1, 2, 3, ...), lo que indica la presencia de una tendencia de largo plazo y autocorrelación positiva significativa. En el rezago 12 se observa un pico moderado, aunque de magnitud reducida, lo que sugiere una componente estacional anual débil nuevamente coherente con $F_s = 0,289$. Por su parte, la PACF presenta un corte abrupto después del rezago 1, indicando que la estructura autorregresiva de la serie es de orden bajo,

típicamente AR(1). Este hallazgo refuerza la decisión metodológica de aplicar una corrección AR(1) en el modelo ITS.




Figura 5.6: Funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) de la serie.

Estructura temporal de la serie

Con el propósito de identificar los principales patrones temporales de la accidentalidad en Bucaramanga, se analizó la serie mensual de accidentes correspondiente al período 2012–2023. Inicialmente, la serie fue descompuesta mediante el método STL (*Seasonal-Trend decomposition using Loess*), separando los componentes de tendencia, estacionalidad y residuales.

La Figura 5.7 presenta la descomposición completa, mientras que el Cuadro 5.8 resume la varianza asociada a cada componente y las medidas de fuerza propuestas por Hyndman y Athanasopoulos (2021). Los resultados muestran que la tendencia constituye el componente dominante de la serie, con una varianza de 5225.95, muy superior a la asociada a la estacionalidad (235.77). De forma consistente, la fuerza de la tendencia fue elevada ($F_t = 0,904$), mientras que la fuerza de la estacionalidad resultó relativamente baja ($F_s = 0,289$).

En términos generales, estos resultados indican que la dinámica temporal de la accidentalidad en Bucaramanga está explicada principalmente por cambios de largo plazo, mientras que los patrones esta-

cionales desempeñan un papel secundario.




Figura 5.7: Descomposición STL de la serie mensual de accidentes

Cuadro 5.8: Resumen de la descomposición STL

Componente	Varianza
Tendencia	5.225,95
Estacional	235,77
Residuos	585,24
Fuerza de la estacionalidad (F_s)	0,289 (DÉBIL)
Fuerza de la tendencia (F_t)	0,904 (FUERTE)

Tendencia y estacionalidad mensual

La tendencia estimada mediante STL evidencia una reducción progresiva del número mensual de accidentes a lo largo del período analizado, particularmente a partir de 2020. Esta disminución se observa claramente en el componente de tendencia de la Figura 5.7 y sugiere la existencia de cambios estructurales relevantes en la dinámica de la movilidad urbana.

Para explorar la posible presencia de patrones estacionales, se analizaron las distribuciones mensuales mediante diferentes representaciones gráficas. La Figura 5.8 muestra la evolución mensual por año, la Figura 5.9 presenta las subseries mensuales y la Figura 5.10 resume la distribución de accidentes para cada mes mediante diagramas de caja. Complementariamente, la Figura 5.11 muestra un mapa de calor que permite visualizar simultáneamente las variaciones mensuales y anuales.




Figura 5.8: Patrón estacional de accidentes por año




Figura 5.9: Subseries mensuales (cada panel muestra un mes a lo largo de los años)




Figura 5.10: Distribución de accidentes por mes (rombo = media)




Figura 5.11: Mapa de calor de accidentalidad mensual por año

Las estadísticas descriptivas por mes se presentan en el Cuadro 5.9. Los valores medios más altos corresponden a octubre (299.4 accidentes), diciembre (298.1) y marzo (289.5), mientras que junio (252.9), enero (257.4) y abril (260.3) registran las menores medias. La diferencia entre el mes de mayor y menor accidentalidad es de aproximadamente 46.5 accidentes mensuales, equivalente a una variación relativa cercana al 18 %.

No obstante, el test no paramétrico de Kruskal–Wallis no detectó diferencias estadísticamente significativas entre los meses ($p = 0,4097$), lo que indica que las fluctuaciones observadas no constituyen una estacionalidad fuerte. Este resultado es coherente con la baja fuerza estacional obtenida en la descomposición STL ($F_s = 0,289$).

Cuadro 5.9: Estadísticas mensuales de accidentes (2012–2023)

Mes	Media	Mediana	Desv. estándar	Mín.	Máx.	CV (%)
Oct	299,4	319,0	75,6	110	389	25,3
Dic	298,1	313,0	73,8	123	394	24,8
Mar	289,5	309,5	79,3	107	394	27,4
Sep	288,8	329,0	92,2	116	382	31,9
May	288,5	324,0	90,0	123	380	31,2
Nov	282,9	305,0	73,0	113	357	25,8
Feb	280,0	301,0	74,4	109	376	26,6
Ago	273,3	308,5	91,5	100	384	33,5
Jul	268,5	306,5	83,6	78	344	31,1
Abr	260,3	285,5	92,5	81	360	35,6
Ene	257,4	281,0	63,5	90	317	24,7
Jun	252,9	290,5	79,2	83	321	31,3

Adicionalmente, la evolución temporal del involucramiento de los principales actores viales se presenta en la Figura 5.12. Se observa una reducción generalizada en los niveles de participación de automóviles, motocicletas y peatones a partir de 2020, seguida de una recuperación parcial durante los años posteriores. Las motocicletas mantienen una participación destacada durante todo el período analizado, consolidándose como uno de los actores más frecuentemente involucrados en los siniestros viales.




Figura 5.12: Evolución mensual del involucramiento por tipo de vehículo

Detección de cambios estructurales

La marcada disminución observada en la serie después de 2020 motivó la búsqueda formal de posibles puntos de cambio estructural. Para ello se aplicaron los métodos AMOC (*At Most One Change*), Binary Segmentation y ventana deslizante.

Los resultados convergieron en identificar un cambio importante alrededor de febrero–marzo de 2020. En particular, el método AMOC detectó una ruptura estructural en febrero de 2020, resumida en el Cuadro 5.10. Antes del cambio, la serie presentaba una media de 323.0 accidentes por mes, mientras que posteriormente la media descendió a 175.4 accidentes mensuales, lo que representa una reducción absoluta de 147.5 accidentes por mes y una disminución relativa del 45.7 %.

La coincidencia temporal de esta ruptura con el inicio de las restricciones de movilidad asociadas a la pandemia de COVID-19 sugiere que dicho evento constituyó el principal factor responsable del cambio observado en la dinámica de la accidentalidad.

Cuadro 5.10: Resumen del cambio estructural detectado (AMOC)

Parámetro	Valor
Fecha del cambio	Febrero 2020
Media antes (ene 2012 – feb 2020)	323,0 accidentes/mes
Media después (mar 2020 – sep 2023)	175,4 accidentes/mes
Cambio absoluto	-147,5 accidentes/mes
Cambio relativo	-45,7 %

Análisis de Series de Tiempo Interrumpidas (ITS)

Con el fin de cuantificar formalmente el impacto de la pandemia sobre la accidentalidad vial, se empleó la metodología de Series de Tiempo Interrumpidas (*Interrupted Time Series*, ITS), considerando marzo de 2020 como punto de intervención.

El modelo utilizado se expresa como:

$$Y_t = \beta_0 + \beta_1 T_t + \beta_2 X_t + \beta_3 (T \cdot X)_t + \varepsilon_t \quad (5.1)$$

donde Y_t representa el número mensual de accidentes, T_t la tendencia temporal, X_t una variable indicadora de la intervención y $(T \cdot X)_t$ la interacción que permite estimar cambios en la pendiente posterior a la intervención.

Diagnóstico y corrección de autocorrelación

Previamente al ajuste del modelo se evaluó la autocorrelación de los residuos mediante la prueba de Durbin-Watson. El resultado ($DW = 0,927$; $p < 0,001$) evidenció autocorrelación positiva significativa, por lo que el modelo fue estimado mediante Mínimos Cuadrados Generalizados (GLS) incorporando una estructura autorregresiva AR(1). El parámetro estimado fue $\hat{\phi} = 0,533$ (Cuadro 5.11).

Cuadro 5.11: Diagnóstico de autocorrelación en el modelo ITS

Prueba	Resultado
Durbin-Watson (DW)	0,927
p -valor (autocorrelación)	$< 0,001$
Método de corrección	GLS con estructura AR(1)
Parámetro $\hat{\phi}$ (AR(1))	0,533

Resultados del modelo ITS

Los coeficientes estimados se presentan en el Cuadro 5.12. El intercepto ($\hat{\beta}_0 = 340,35$) representa el nivel inicial esperado de accidentalidad al comienzo de la serie.

La tendencia previa a la pandemia fue negativa pero no significativa ($\hat{\beta}_1 = -0,36$; $p = 0,134$), indicando que antes de 2020 la serie se mantenía relativamente estable. El hallazgo más importante corresponde al cambio inmediato de nivel asociado a la intervención ($\hat{\beta}_2 = -88,01$; $p < 0,001$), que evidencia una reducción abrupta y estadísticamente significativa en el número mensual de accidentes tras el inicio de las restricciones de movilidad.

Por su parte, el cambio de tendencia posterior a la intervención fue negativo ($\hat{\beta}_3 = -1,59$), aunque con evidencia estadística marginal ($p = 0,054$). Este resultado sugiere una posible prolongación del efecto reductor de la pandemia sobre la accidentalidad, aunque su interpretación debe realizarse con cautela.

Cuadro 5.12: Coeficientes del modelo ITS con corrección AR(1)

Parámetro	Estimación	Error estándar	t	p -valor
Intercepto ($\hat{\beta}_0$)	340,35	13,62	24,98	$< 0,001$
Tendencia pre ($\hat{\beta}_1$)	-0,36	0,24	-1,51	0,134
Cambio de nivel ($\hat{\beta}_2$)	-88,01	22,01	-4,00	$< 0,001$
Cambio de tendencia ($\hat{\beta}_3$)	-1,59	0,82	-1,94	0,054

Método: máxima verosimilitud (ML). Estructura AR(1), $\hat{\phi} = 0,533$.

$AIC = 1388,2$; $BIC = 1405,9$; error estándar residual = 37,6 accidentes/mes.

Análisis contrafactual

La Figura 5.13 presenta la serie observada, la trayectoria ajustada por el modelo GLS y la trayectoria contrafactual estimada bajo el supuesto de ausencia de intervención. La comparación entre ambas trayectorias muestra que los niveles observados permanecieron sistemáticamente por debajo de los valores esperados sin pandemia.

La divergencia persistente entre la serie observada y la trayectoria contrafactual indica que el impacto asociado a las restricciones de movilidad no se limitó a los meses iniciales de confinamiento, sino que modificó de forma sostenida el comportamiento de la accidentalidad durante los años posteriores. Aunque se observa una recuperación parcial después de 2020, los niveles registrados no retornan a los patrones históricos observados antes de la intervención.




Figura 5.13: Análisis de Series de Tiempo Interrumpidas

En síntesis, el análisis temporal muestra que la accidentalidad en Bucaramanga estuvo caracterizada por una tendencia de largo plazo dominante, una estacionalidad relativamente débil y una ruptura estructural significativa asociada al inicio de la pandemia de COVID-19. El modelo ITS confirma que este evento produjo una reducción inmediata y sustancial en la frecuencia mensual de accidentes, cuyos efectos persistieron durante los años posteriores.

Reducción de accidentes en 2022–2023 y posibles efectos de la Ley 2251 de 2022

La Figura 5.13 muestra que, después de la fuerte disminución observada durante el inicio de la pandemia en 2020, la accidentalidad registró una recuperación parcial durante 2021. Sin embargo, a partir de finales de 2022 y durante 2023 se observa una nueva reducción del número de accidentes reportados que no es explicada por el modelo ITS ajustado previamente. Mientras que la pandemia fue incorporada explícitamente como intervención en el modelo, esta disminución posterior sugiere la presencia de factores adicionales que afectan el comportamiento de la serie.

El Cuadro 5.13 resume la evolución anual del número de vehículos involucrados en accidentes. Entre 2012 y 2019 los valores permanecieron relativamente estables, oscilando entre 6.220 y 7.358 vehículos por año. En 2020 se produjo una reducción de 41,5 %, consistente con las restricciones de movilidad derivadas de la emergencia sanitaria. Posteriormente, en 2021 se observó una recuperación parcial (+24,5 %). No obstante, los registros volvieron a disminuir en 2022 (-13,9 %) y, de manera más pronunciada, en 2023.

Cuadro 5.13: Evolución del total de vehículos involucrados en accidentes por año

Año	Total vehículos involucrados	Variación (%)
2012	7.358	–
2013	6.955	-5,5
2014	6.439	-7,4
2015	6.370	-1,1
2016	6.308	-1,0
2017	6.375	+1,1
2018	6.391	+0,3
2019	6.220	-2,7
2020	3.638	-41,5
2021	4.528	+24,5
2022	3.900	-13,9
2023	1.613	-58,6

Nota: Los datos de 2023 corresponden únicamente a enero-septiembre (serie incompleta).

Cambios normativos en el registro de accidentes.

Una posible explicación de este comportamiento es la entrada en vigencia de la Ley 2251 de 2022, que modificó el procedimiento aplicable a los accidentes de tránsito con daños exclusivamente materiales. La normativa establece que, cuando no existan personas lesionadas, fallecidas o presunción de embriaguez, los conductores deben retirar inmediatamente los vehículos de la vía y gestionar el incidente mediante evidencia fotográfica o videográfica y el reporte ante las aseguradoras, sin requerir la presencia de las autoridades de tránsito.

Esta modificación reduce la participación directa de los organismos de tránsito en una proporción importante de los siniestros de baja gravedad, que históricamente constituyen una fracción significativa del total de accidentes registrados en las bases administrativas utilizadas en este estudio.

Posible efecto sobre la calidad del registro

Desde una perspectiva estadística, la Ley 2251 puede generar una discontinuidad en el sistema de información utilizado para construir la serie histórica. En particular, los accidentes que anteriormente eran documentados mediante informes oficiales podrían dejar de registrarse en las bases de datos de tránsito cuando son gestionados directamente entre las partes involucradas y sus aseguradoras. Por esta razón, la disminución observada durante 2022–2023 no necesariamente debe interpretarse como una reducción equivalente de la accidentalidad real. Una parte de la caída puede corresponder a una menor cobertura del sistema de registro, especialmente en los accidentes de solo daños materiales.

En consecuencia, los datos posteriores a 2022 deben analizarse con cautela, dado que la comparabilidad con los años anteriores podría verse afectada por cambios institucionales en los procedimientos de reporte y documentación de siniestros.

Implicaciones para el análisis.

La posible existencia de subregistro tiene varias implicaciones metodológicas. En primer lugar, las comparaciones temporales realizadas entre los períodos anteriores y posteriores a 2022 podrían sobreestimar la magnitud de la reducción de la accidentalidad.

En segundo lugar, los modelos estadísticos que utilicen el número de accidentes registrados como variable de resultado pueden reflejar simultáneamente cambios reales en la seguridad vial y cambios en los mecanismos de registro administrativo.

Por ello, futuras investigaciones deberían complementar la información proveniente de los organismos de tránsito con otras fuentes, tales como registros de aseguradoras, reclamaciones SOAT o bases hospitalarias, con el fin de estimar de manera más precisa la magnitud real de la accidentalidad de baja gravedad.

Consideración metodológica

Dado que la Ley 2251 comenzó a aplicarse durante el período final de la serie analizada y que los datos disponibles para 2023 corresponden únicamente al período enero–septiembre, no existe un

número suficiente de observaciones posteriores a la intervención para estimar de manera robusta un segundo modelo de Series de Tiempo Interrumpidas. En consecuencia, el presente estudio interpreta la reducción observada como evidencia compatible con un posible efecto de subregistro asociado al cambio normativo, pero no pretende establecer una relación causal definitiva entre la Ley 2251 de 2022 y la disminución observada en los registros de accidentes.

Resumen del análisis temporal

El análisis temporal de la accidentalidad en Bucaramanga permitió caracterizar los principales patrones de ocurrencia de los siniestros registrados entre el 1 de enero de 2012 y el 30 de septiembre de 2023. Durante este período se registraron 39.193 accidentes, con una hora promedio de ocurrencia de las 13:33 horas y una dispersión moderada alrededor de este valor. Los accidentes se concentran principalmente durante las horas de la tarde, especialmente entre las 12:00 y las 18:00 horas, siendo la franja de tarde temprana (12–15 h) la de mayor frecuencia. Asimismo, el sábado constituye el día de la semana con mayor número de siniestros registrados.

En cuanto a los actores viales involucrados, las motocicletas y los automóviles predominan ampliamente durante todo el período de estudio. Se observa además un incremento progresivo de la participación de las motocicletas en la accidentalidad, mientras que los accidentes fatales muestran una mayor representación relativa de motociclistas y peatones. Desde la perspectiva espacial, las comunas Cabecera del Llano, Centro y San Francisco concentran el mayor número de accidentes, mientras que las tasas estandarizadas revelan una incidencia particularmente elevada de motocicletas en comunas como San Francisco y Oriental.

Los análisis de series de tiempo evidencian que la accidentalidad presentó una dinámica relativamente estable hasta comienzos de 2020, momento en el cual se produjo una ruptura estructural asociada a la pandemia de COVID-19. Esta intervención generó una disminución abrupta en los registros de accidentes y modificó la trayectoria posterior de la serie. Aunque se observó una recuperación parcial durante los años siguientes, los niveles de accidentalidad no retornaron a los valores previos a la pandemia.

Adicionalmente, los resultados sugieren que la implementación de la Ley 2251 de 2022 pudo afectar la comparabilidad de los registros administrativos, particularmente en los accidentes con daños exclusivamente materiales, al modificar los procedimientos de reporte y atención de este tipo de eventos. Por

esta razón, las reducciones observadas durante 2022 y 2023 deben interpretarse con cautela, pues pueden reflejar simultáneamente cambios reales en la movilidad y cambios en los mecanismos de registro.

En conjunto, los resultados permiten concluir que la accidentalidad en Bucaramanga está dominada por patrones horarios y semanales claramente definidos, con una marcada concentración durante las horas de mayor movilidad y una participación creciente de las motocicletas. Asimismo, la pandemia de COVID-19 constituye el principal punto de cambio estructural identificado en la serie temporal, mientras que las modificaciones normativas recientes introducen posibles efectos de subregistro que deben ser considerados en futuros análisis y procesos de formulación de políticas públicas.

5.2.6 Reducción de accidentes en 2022–2023 y posibles efectos de la Ley 2251 de 2022

Cambios normativos en el registro de accidentes

Una posible explicación de este comportamiento es la entrada en vigencia de la Ley 2251 de 2022, que modificó el procedimiento aplicable a los accidentes de tránsito con daños exclusivamente materiales Congreso de la República de Colombia (2022). La normativa establece que, cuando no existan personas lesionadas, fallecidas o presunción de embriaguez, los conductores deben retirar inmediatamente los vehículos de la vía y gestionar el incidente mediante evidencia fotográfica o videográfica y el reporte ante las aseguradoras, sin requerir la presencia de las autoridades de tránsito.

Esta modificación reduce la participación directa de los organismos de tránsito en una proporción importante de los siniestros de baja gravedad, que históricamente constituyen una fracción significativa del total de accidentes registrados en las bases administrativas utilizadas en este estudio. Los aspectos clave de la normativa son:

- **Retiro inmediato del vehículo:** la norma obliga a despejar la calzada sin dilación; permanecer en el lugar puede acarrear multa por obstrucción de la vía.
- **Prescindencia de autoridad de tránsito:** los agentes no son convocados ni elaboran informes en choques simples.
- **Registro de evidencias:** fotos y videos suscriben la narrativa del accidente y sirven de soporte ante la aseguradora.

- **Conciliación entre partes:** se promueve el acuerdo directo en el lugar del hecho; las evidencias documentales se utilizan si no hay acuerdo.
- **Aplicación universal:** rige tanto para vehículos con seguro voluntario como para los que solo cuentan con SOAT.

El objetivo declarado de la ley es agilizar la movilidad y reducir la congestión derivada de accidentes menores, delegando a los conductores y sus aseguradoras la gestión administrativa de los siniestros de baja gravedad.

Efecto sobre la calidad del registro

Desde una perspectiva estadística, la Ley 2251 puede generar una discontinuidad en el sistema de información utilizado para construir la serie histórica. En particular, los accidentes que anteriormente eran documentados mediante informes oficiales podrían dejar de registrarse en las bases de datos de tránsito cuando son gestionados directamente entre las partes involucradas y sus aseguradoras.

Por esta razón, la disminución observada durante 2022–2023 no necesariamente debe interpretarse como una reducción equivalente de la accidentalidad real. Una parte de la caída puede corresponder a una menor cobertura del sistema de registro, especialmente en los accidentes de solo daños materiales.

En consecuencia, los datos posteriores a 2022 deben analizarse con cautela, dado que la comparabilidad con los años anteriores podría verse afectada por cambios institucionales en los procedimientos de reporte y documentación de siniestros.

5.2.7 Resumen del análisis temporal

El análisis temporal de la accidentalidad en Bucaramanga permitió caracterizar los principales patrones de ocurrencia de los siniestros registrados entre el 1 de enero de 2012 y el 30 de septiembre de 2023. Durante este período se registraron 39.193 accidentes, con una hora promedio de ocurrencia de las 13:33 horas y una dispersión moderada alrededor de este valor (Tabla 5.14). Los accidentes se concentran principalmente durante las horas de la tarde, especialmente entre las 12:00 y las 18:00 horas, siendo la franja de tarde temprana (12–15 h) la de mayor frecuencia. Asimismo, el sábado constituye el día de la semana con mayor número de siniestros registrados.

Cuadro 5.14: Resumen estadístico temporal

Indicador	Valor
Total de accidentes	39.193
Rango de fechas	2012-01-01 – 2023-09-30
Hora promedio	13.55
Hora mediana	13.75
Desviación estándar de la hora	5.20
Día con más accidentes	Sábado
Franja con más accidentes	Tarde temprano (12-15h)

En cuanto a los actores viales involucrados, las motocicletas y los automóviles predominan ampliamente durante todo el período de estudio. Se observa además un incremento progresivo de la participación de las motocicletas en la accidentalidad, mientras que los accidentes fatales muestran una mayor representación relativa de motociclistas y peatones. Desde la perspectiva espacial, las comunas Cabecera del Llano, Centro y San Francisco concentran el mayor número de accidentes, mientras que las tasas estandarizadas revelan una incidencia particularmente elevada de motocicletas en comunas como San Francisco y Oriental.

Los análisis de series de tiempo evidencian que la accidentalidad presentó una dinámica relativamente estable hasta comienzos de 2020, momento en el cual se produjo una ruptura estructural asociada a la pandemia de COVID-19. Esta intervención generó una disminución abrupta en los registros de accidentes y modificó la trayectoria posterior de la serie. Aunque se observó una recuperación parcial durante los años siguientes, los niveles de accidentalidad no retornaron a los valores previos a la pandemia.

Adicionalmente, los resultados sugieren que la implementación de la Ley 2251 de 2022 pudo afectar la comparabilidad de los registros administrativos, particularmente en los accidentes con daños exclusivamente materiales, al modificar los procedimientos de reporte y atención de este tipo de eventos. Por esta razón, las reducciones observadas durante 2022 y 2023 deben interpretarse con cautela, pues pueden reflejar simultáneamente cambios reales en la movilidad y cambios en los mecanismos de registro.

5.3. Análisis espacial de la siniestralidad

5.3.1 Estadísticas generales de accidentalidad

El análisis espacial se realizó sobre los 219 barrios que conforman el área urbana de Bucaramanga. Durante el período de estudio se registraron accidentes en 164 barrios, lo que representa el 70,8 % del total, evidenciando una amplia distribución territorial de la siniestralidad en la ciudad (Cuadro 5.15).

En total se contabilizaron 39.193 accidentes de tránsito, de los cuales 18,040 (46,02 %) involucraron personas lesionadas y 609 (1,6 %) ocasionaron víctimas fatales. Estos resultados muestran que cerca de la mitad de los siniestros registrados generaron consecuencias directas sobre la integridad física de los actores viales, mientras que una proporción menor, aunque socialmente relevante, correspondió a eventos con desenlace fatal.

El número promedio de accidentes por barrio fue de 170,2 durante todo el período analizado. Sin embargo, esta medida oculta una marcada heterogeneidad espacial. Mientras numerosos barrios registraron pocos eventos o incluso ausencia de accidentes, otros concentraron una proporción importante de la siniestralidad urbana. El caso más destacado es el barrio Centro, que acumuló 3.861 accidentes, convirtiéndose en el principal foco de accidentalidad de la ciudad.

Estos resultados preliminares sugieren que la distribución espacial de los accidentes no es homogénea entre los barrios de Bucaramanga. Por el contrario, existen zonas con una concentración significativamente mayor de siniestros, lo que justifica la aplicación de técnicas de análisis espacial para identificar patrones de agrupamiento, áreas críticas y posibles factores asociados a la variación territorial de la accidentalidad.

Cuadro 5.15: Resumen general de accidentes por barrio

Indicador	Valor	Porcentaje
Total de barrios analizados	219	–
Barrios con accidentes registrados	164	74,8 %
Total de accidentes	39.193	–
Accidentes con heridos	18.040	46,02 %
Accidentes con muertos	609	1,6 %
Promedio de accidentes por barrio	170.2	–
Máximo de accidentes en un barrio	3.861 (Centro)	–

5.3.2 *Análisis Espacial*

5.3.3 *Autocorrelación espacial global: estadístico I de Moran*

Con el fin de evaluar si la distribución espacial de las tasas de accidentalidad presenta un patrón de agrupamiento territorial, se calculó el estadístico global I de Moran. Los resultados se resumen en el Cuadro 5.16.

Cuadro 5.16: I de Moran global

Parámetro	Valor
I de Moran observado	0,1229
Esperanza bajo aleatoriedad	−0,0053
Varianza	0,0014
Desviación estándar (z)	3,3655
p -valor (hipótesis mayor)	0,0003

El valor observado del estadístico fue $I = 0,1229$, superior al esperado bajo la hipótesis nula de aleatoriedad espacial ($E[I] = -0,0053$). Asimismo, la prueba de significancia arrojó un valor $z = 3,37$ y un p -valor de 0,000382, evidenciando que la autocorrelación espacial positiva observada es estadísticamente significativa.

Estos resultados permiten rechazar la hipótesis nula de independencia espacial y concluir que las tasas de accidentalidad presentan una estructura espacial no aleatoria. En términos prácticos, los barrios con altas tasas de accidentalidad tienden a localizarse próximos a otros barrios con características similares, mientras que los barrios con bajas tasas también muestran una tendencia a agruparse espacialmente.

Aunque la magnitud del índice es relativamente moderada ($I = 0,1229$), este comportamiento es frecuente en estudios urbanos donde intervienen múltiples factores socioeconómicos, demográficos y de infraestructura vial que generan una considerable heterogeneidad local. En consecuencia, la evidencia obtenida indica la existencia de dependencia espacial en la accidentalidad de Bucaramanga y justifica la aplicación de técnicas de autocorrelación local para identificar la ubicación específica de los conglomerados espaciales de alta y baja accidentalidad.

5.3.4 Autocorrelación espacial local: indicadores LISA

Una vez confirmada la existencia de autocorrelación espacial global, se aplicó el análisis de indicadores LISA con el fin de identificar la localización específica de los conglomerados y anomalías espaciales de accidentalidad. Los resultados significativos ($p < 0,05$) se presentan en la Figura 5.14.




Figura 5.14: Mapa de clústeres LISA de accidentalidad vial en Bucaramanga (2012–2023)

El análisis reveló la presencia de un clúster High–High (*hotspot*) conformado principalmente por los barrios Puerta del Sol y La Salle, ubicados en el sector centro-oriental de la ciudad. Estos barrios presentan tasas de accidentalidad elevadas y se encuentran rodeados por barrios con tasas igualmente altas, configurando un núcleo espacial de siniestralidad vial significativamente superior al esperado bajo un patrón aleatorio.

La localización de este *hotspot* coincide con uno de los principales corredores de actividad económica y movilidad urbana de Bucaramanga. En esta zona convergen importantes ejes viales, actividades comerciales y altos flujos de tránsito vehicular, condiciones que favorecen una mayor exposición al ries-

go de siniestros viales. La identificación de este conglomerado constituye una evidencia espacial de que la accidentalidad no se distribuye uniformemente en el territorio, sino que se concentra en áreas específicas donde confluyen factores de infraestructura, movilidad y uso del suelo.

Adicionalmente, se identificó el barrio Antonia Santos Sur como un caso Low–High, es decir, un barrio con una tasa de accidentalidad relativamente baja rodeado por barrios con tasas elevadas. Este resultado sugiere la existencia de una anomalía espacial local que podría estar asociada a características particulares de la infraestructura vial, condiciones de movilidad o diferencias en la composición demográfica y funcional del sector. Este tipo de observaciones resulta especialmente útil para futuras investigaciones orientadas a identificar factores protectores frente a la siniestralidad vial.

Finalmente, la gran mayoría de los barrios no presentó asociaciones espaciales locales estadísticamente significativas, lo que indica que los patrones de concentración detectados se encuentran focalizados en áreas específicas del municipio. En conjunto, los resultados LISA complementan el análisis global de Moran y permiten delimitar territorialmente las zonas prioritarias para la implementación de estrategias de prevención, control y gestión de la seguridad vial.

Barrios críticos

El estadístico global sintetiza el comportamiento del conjunto, pero no permite identificar la localización específica de los agrupamientos espaciales. Para ello se calcularon los Indicadores Locales de Asociación Espacial (LISA), que permiten detectar conglomerados y valores atípicos espaciales mediante el estadístico I de Moran local. La 5.14 presenta los resultados significativos ($p < 0.05$).

Los resultados muestran la presencia de un clúster High–High (hotspot) localizado en el sector centro-oriental de Bucaramanga, donde barrios con altas tasas de accidentalidad se encuentran rodeados por otros barrios con tasas igualmente elevadas. Adicionalmente, se identificó un caso Low–High correspondiente al barrio Antonia Santos Sur, mientras que la mayoría de los barrios no presentó patrones espaciales locales significativos.

Con el fin de caracterizar el *hotspot* identificado mediante el análisis LISA, el Cuadro 5.17 presenta los barrios que conforman dicho conglomerado, junto con sus tasas estandarizadas y el número total de

accidentes registrados.

Cuadro 5.17: Barrios clasificados como *hotspot* (High-High) en el análisis LISA

Barrio	Tasa (acc./1 000 hab.)	Total accidentes
Puerta del Sol	656,7	616
Antonia Santos Sur	454,6	365
La Salle	280,2	276
Conucos	219,0	716
La Ceiba	77,9	255

El clúster está integrado por Puerta del Sol, Antonia Santos Sur, La Salle, Conucos y La Ceiba. Estos barrios se localizan de forma contigua, configurando una zona espacialmente concentrada de elevada siniestralidad vial. Puerta del Sol presenta la tasa más alta del conjunto (656,7 accidentes por cada 1.000 habitantes), seguido por Antonia Santos Sur (454,6) y La Salle (280,2). Por su parte, Conucos registra el mayor número absoluto de accidentes (716), lo que evidencia la coexistencia de altas tasas relativas y elevados volúmenes de siniestros en este sector de la ciudad.

La concentración espacial observada coincide con los resultados obtenidos previamente en el análisis descriptivo de tasas y frecuencias, reforzando la identificación de este sector como la principal zona crítica de accidentalidad vial en Bucaramanga. En consecuencia, estos barrios constituyen áreas prioritarias para la focalización de estrategias de prevención, control y gestión de la seguridad vial.

5.3.5 Distribución de barrios según categorías de accidentalidad

A partir del número total de accidentes, los barrios se clasificaron en cinco categorías. El Cuadro 5.18 presenta la distribución completa de los 219 barrios del municipio.

Cuadro 5.18: Distribución de barrios por categoría de accidentalidad

Categoría	N.º de barrios	Porcentaje
Muy alto (> 30)	86	39,3
Alto (16–30)	20	9,1
Medio (6–15)	22	10,0
Bajo (1–5)	27	12,3
Sin accidentes	64	29,2

Los resultados muestran una distribución marcadamente asimétrica. La categoría Muy alto agrupa a 86 barrios (39,3 %), lo que indica que una proporción importante del territorio urbano presenta niveles elevados de siniestralidad. En el extremo opuesto, 64 barrios (29,2 %) no registraron ningún accidente durante el período de estudio, lo que sugiere la existencia de zonas con condiciones que reducen la exposición al riesgo vial.

Las categorías intermedias Alto, Medio y Bajo agrupan en conjunto a 69 barrios (31,4 %), reflejando un gradiente territorial que requiere estrategias diferenciadas según la intensidad del problema. En conjunto, estos resultados indican que la accidentalidad en Bucaramanga no se distribuye de manera homogénea, sino que presenta una concentración significativa en un grupo relativamente reducido de barrios, lo que justifica la focalización de intervenciones en las zonas de mayor frecuencia de siniestros.

5.3.6 Involucramiento por tipo de vehículo

El análisis de los tipos de vehículos involucrados en los accidentes evidencia el papel predominante de los automóviles y las motocicletas en la siniestralidad vial de Bucaramanga. Como se observa en el Cuadro 5.19, los automóviles estuvieron presentes en 22.881 accidentes (61,4 % del total), mientras que las motocicletas participaron en 19.879 siniestros (53,3 %). Debido a que un mismo accidente puede involucrar más de un tipo de vehículo, los porcentajes reportados no son mutuamente excluyentes y, por tanto, no suman 100 %.

Cuadro 5.19: Frecuencia y porcentaje de accidentes según tipo de vehículo involucrado

Tipo de vehículo	Frecuencia	Porcentaje de accidentes*
Automóviles	2.881	61,4
Motocicletas	19.879	53,3
Peatones	3.582	9,6
Camiones	3.137	8,4
Buses	1.713	4,6
Bicicletas	653	1,8

* Porcentaje sobre el total de accidentes (39.193). La suma supera el 100 % debido a que un accidente puede involucrar varios tipos de vehículos.

Los peatones estuvieron involucrados en 3.582 accidentes (9,6 %), seguidos por los camiones con 3.137 casos (8,4 %) y los buses con 1.713 registros (4,6 %). Las bicicletas representan la menor participación relativa, con 653 accidentes (1,8 %). No obstante, aunque su frecuencia es reducida, este grupo corresponde a usuarios vulnerables de la vía, por lo que su relevancia desde la perspectiva de la seguridad vial trasciende su peso porcentual.

La elevada participación conjunta de automóviles y motocicletas refleja la composición del parque automotor y los patrones de movilidad predominantes en la ciudad. Particularmente, la alta frecuencia de motocicletas resulta consistente con la creciente importancia de este modo de transporte observada durante el período de estudio, así como con su reconocida vulnerabilidad frente a eventos de tránsito. La coexistencia de ambos actores en el espacio vial, como se evidenció en el análisis de co-ocurrencia, configura uno de los principales desafíos para la seguridad vial en Bucaramanga.

En términos generales, los resultados indican que la siniestralidad vial en Bucaramanga se encuentra fuertemente asociada a los vehículos motorizados, especialmente automóviles y motocicletas, los cuales concentran la mayor parte de los eventos registrados. Este patrón justifica que los análisis posteriores profundicen en la distribución espacial y temporal de estos actores viales, así como en su contribución a los accidentes con víctimas lesionadas y fatales, con el fin de orientar intervenciones diferenciadas según el tipo de actor predominante en cada zona y momento.

5.3.7 *Análisis espacial: mapas temáticos*

Con el propósito de complementar los análisis de autocorrelación espacial y caracterizar distintas dimensiones de la siniestralidad vial en Bucaramanga, se elaboraron mapas temáticos que representan la distribución territorial de la frecuencia de accidentes, la gravedad de los siniestros y la participación de motocicletas en los eventos registrados. Las Figuras 5.15 a 5.18 presentan los principales resultados.

La Figura 5.15 muestra la clasificación de los barrios según categorías de accidentalidad definidas a partir del número total de accidentes registrados durante el período de estudio. Se observa una amplia presencia de barrios clasificados en la categoría de accidentalidad muy alta, especialmente en el sector central y centro-oriental de la ciudad. En contraste, los barrios con niveles bajos de accidentalidad o sin accidentes registrados se localizan principalmente en zonas periféricas, lo que sugiere una asociación entre la intensidad de la actividad urbana y la concentración de siniestros viales.

La Figura 5.16 presenta la distribución espacial de los accidentes que ocasionaron personas heridas. El patrón observado es consistente con la distribución general de la accidentalidad, destacándose una concentración importante en los sectores centrales del municipio. Esto indica que las zonas con mayor frecuencia de accidentes también concentran una proporción significativa de los eventos con consecuencias lesivas para los usuarios de la vía, lo que refuerza la necesidad de intervenciones prioritarias en estas áreas.

Por su parte, la Figura 5.17 representa el porcentaje de accidentes en los que participaron motocicletas. A diferencia de los mapas anteriores, se observa una mayor heterogeneidad espacial, con variaciones importantes entre barrios. Este resultado sugiere que la exposición al riesgo asociado al uso de motocicletas no es uniforme en la ciudad y que existen sectores donde este actor vial tiene una participación particularmente elevada en la siniestralidad. La identificación de estas zonas resulta clave para diseñar campañas de prevención y controles focalizados en este tipo de vehículo.

La Figura 5.18 muestra la distribución espacial de la frecuencia absoluta de accidentes por barrio. El mapa confirma una marcada concentración de siniestros en la zona central de Bucaramanga, donde destacan barrios como Centro y sectores adyacentes. A medida que se avanza hacia las áreas periféricas, la

frecuencia de accidentes disminuye progresivamente, reflejando menores niveles de actividad vehicular y menor intensidad de interacción entre los diferentes actores viales.

En general, los mapas temáticos evidencian que la accidentalidad vial en Bucaramanga presenta una distribución espacial claramente desigual. Los sectores centrales concentran tanto la mayor cantidad de accidentes como una proporción importante de eventos con personas lesionadas, mientras que la participación de motocicletas muestra una distribución más heterogénea. Estos resultados complementan la evidencia obtenida mediante el análisis de autocorrelación espacial global y local, reforzando la existencia de patrones espaciales no aleatorios en la siniestralidad vial del municipio y proporcionando insumos para la focalización territorial de las políticas de seguridad vial.





Figura 5.15: Mapa de categorías de accidentalidad basado en el número total de accidentes por barrio






Figura 5.17: Porcentaje de accidentes en los que participaron motocicletas




Figura 5.18: Mapa de densidad de accidentes (frecuencia absoluta)

5.3.8 Gráficos estadísticos complementarios

Además de la cartografía temática, se elaboraron gráficos de barras que permiten sintetizar algunos de los patrones más relevantes identificados en el análisis espacial y descriptivo de la siniestralidad vial (Figuras 5.19 y 5.20).

La Figura 5.19 presenta los barrios con mayor número absoluto de accidentes registrados durante el período de estudio. Se observa una concentración marcada en el sector central de la ciudad, donde el barrio Centro registra una frecuencia sustancialmente superior al resto de barrios analizados. También destacan Cabecera del Llano, San Francisco, Provenza, La Concordia y Sotomayor, todos ellos carac-

terizados por una intensa actividad comercial, institucional o de servicios, así como por elevados flujos vehiculares y peatonales. Estos resultados son consistentes con los patrones identificados en los mapas de densidad y en los análisis espaciales previos, que evidenciaron una concentración de la accidentalidad en las zonas de mayor dinamismo urbano.

Por otra parte, la Figura 5.20 resume la participación de los distintos actores viales en los accidentes registrados. Los automóviles y las motocicletas son, con amplia diferencia, los tipos de vehículo más frecuentemente involucrados, apareciendo en más de la mitad de los siniestros reportados. En contraste, peatones, camiones, buses y bicicletas presentan participaciones considerablemente menores. La elevada presencia de motocicletas resulta especialmente relevante desde la perspectiva de la seguridad vial, ya que este grupo constituye uno de los usuarios más vulnerables del sistema de transporte y concentra una proporción importante de los eventos con consecuencias graves.

Los gráficos complementan la información cartográfica al evidenciar tanto la concentración territorial de la accidentalidad como el papel predominante que desempeñan automóviles y motocicletas en la ocurrencia de los siniestros de tránsito en Bucaramanga.




Figura 5.19: Top 10 barrios con mayor número de accidentes




Figura 5.20: Distribución porcentual de accidentes según tipo de vehículo involucrado

5.3.9 Barrios con mayor frecuencia de accidentes

El análisis de la frecuencia absoluta de accidentes permite identificar los sectores de la ciudad donde se concentra el mayor volumen de siniestros registrados durante el período 2012–2023. Como se observa en el Cuadro 5.20, el barrio Centro ocupa el primer lugar con 3,861 accidentes, cifra ampliamente superior a la registrada en los demás barrios del municipio. Le siguen Cabecera del Llano (2,412), San Francisco (1,974), Provenza (1,408) y La Concordia (1,376), consolidando un corredor urbano de alta actividad económica, comercial y de movilidad que concentra una proporción importante de la accidentalidad de Bucaramanga.

Cuadro 5.20: Top 15 barrios con mayor número de accidentes

Barrio	Total accidentes	Con heridos	Con muertos	Tasa de gravedad (%)
CENTRO	3.861	1.786	26	46,9
CABECERA DEL LLANO	2.412	760	14	32,1
SAN FRANCISCO	1.974	1.124	14	57,6
PROVENZA	1.408	628	13	45,5
LA CONCORDIA	1.376	699	22	52,4
SOTOMAYOR	1.272	463	8	37,0
RIO DE ORO I	1.136	514	45	49,2
ANTONIA SANTOS CENTRO	1.102	543	7	49,9
SAN ALONSO	1.002	477	11	48,7
ALARCON	886	469	9	53,9
MEJORAS PUBLICAS	829	344	6	42,2
COMUNEROS	821	525	11	65,3
RICAUORTE	819	369	17	47,1
DIAMANTE II	781	306	10	40,5

Aunque el número total de accidentes constituye un indicador fundamental de exposición al riesgo vial, la incorporación de variables de gravedad permite matizar la interpretación de estos resultados. En términos absolutos, el barrio Centro también registra el mayor número de accidentes con personas heridas (1.786), seguido por San Francisco (1.124) y Cabecera del Llano (760). Asimismo, algunos barrios presentan cifras relevantes de accidentes fatales, destacándose Río de Oro I con 45 eventos con víctimas mortales, valor superior al observado en barrios con mayor frecuencia total de accidentes, como Cabecera del Llano o San Francisco.

Mientras que Cabecera del Llano presenta una de las menores proporciones de accidentes con víctimas (32,1 %), otros sectores muestran niveles considerablemente más elevados. Destacan Comuneros (65,3 %), San Francisco (57,6 %), Alarcón (53,9 %) y La Concordia (52,4 %), donde más de la mitad de los accidentes registrados ocasionaron personas heridas o fallecidas. Estos resultados sugieren que la intensidad del problema no depende únicamente del número de siniestros, sino también de las consecuencias que estos generan sobre los usuarios de la vía.

Los resultados indican que los barrios con mayor frecuencia de accidentes corresponden principal-

mente a zonas de alta concentración de actividades urbanas y elevados flujos de movilidad. Sin embargo, la distribución de la gravedad no sigue exactamente el mismo patrón, evidenciando la necesidad de diferenciar entre áreas con alta ocurrencia de accidentes y áreas donde los siniestros presentan mayores consecuencias para la salud y la vida de la población. Esta distinción resulta crucial para la planificación de intervenciones, ya que las estrategias para reducir la frecuencia de accidentes pueden diferir de aquellas orientadas a disminuir su severidad.

5.3.10 Síntesis del análisis espacial

El análisis espacial realizado evidencia que la siniestralidad vial en Bucaramanga presenta una distribución territorial claramente heterogénea y no aleatoria. La prueba global de Moran confirmó la existencia de autocorrelación espacial positiva ($I = 0,123$, $p < 0,001$), indicando que los barrios con niveles elevados de accidentalidad tienden a agruparse espacialmente con otros barrios de características similares. Este resultado sugiere que la ocurrencia de accidentes está asociada a factores territoriales compartidos, tales como la estructura de la red vial, la intensidad de los flujos vehiculares, la concentración de actividades económicas y la configuración urbana de los diferentes sectores de la ciudad. En términos descriptivos, el 70,8 % de los barrios del municipio registraron al menos un accidente, con una fuerte concentración en el centro y en corredores principales, mientras que la periferia oriental y suroccidental presenta menor accidentalidad.

El análisis local mediante indicadores LISA permitió identificar un clúster *hotspot* conformado por los barrios Puerta del Sol, Antonia Santos Sur, La Salle, Conucos y La Ceiba, ubicados en la zona centro-occidental del municipio. La presencia simultánea de altas tasas de accidentalidad y dependencia espacial significativa confirma que estos barrios constituyen el principal núcleo territorial de riesgo vial en Bucaramanga. La consistencia entre los resultados del análisis LISA, los mapas temáticos y los rankings de frecuencia absoluta refuerza la robustez de este hallazgo y permite delimitar con precisión las áreas prioritarias para intervenciones de seguridad vial. Este patrón es coherente con la distribución descriptiva: el barrio Centro concentra el 10,4 % del total de accidentes, seguido por Cabecera del Llano y San Francisco, todos ubicados en la misma franja territorial de alta siniestralidad.

Dentro del clúster *hotspot*, Puerta del Sol se destaca como el barrio con la mayor tasa estandarizada de accidentalidad de toda la ciudad, superando en más del 40 % a la del segundo barrio del clúster y en

más de ocho veces a la media de los barrios clasificados como «Muy alto» en el análisis coroplético. Esta brecha señala la necesidad de intervenciones focalizadas y urgentes en este sector. Cabe destacar que cerca de la mitad de los accidentes registrados en la ciudad (46,02 %) dejaron personas heridas y el 1,6 % fueron fatales, lo que subraya la gravedad del fenómeno en estas zonas críticas.

Los análisis descriptivos mostraron además que la accidentalidad se concentra principalmente en barrios de alta actividad urbana y elevada movilidad. El Centro, Cabecera del Llano, San Francisco, Provenza y La Concordia registran los mayores volúmenes absolutos de accidentes, mientras que otros barrios presentan tasas de gravedad particularmente elevadas, evidenciando que la magnitud del problema no depende únicamente de la frecuencia de siniestros, sino también de sus consecuencias sobre la salud y la vida de los usuarios de la vía.

Finalmente, los resultados revelan el papel predominante de automóviles y motocicletas en la dinámica de la accidentalidad urbana. Ambos tipos de vehículo participan en más de la mitad de los siniestros registrados y muestran patrones espaciales diferenciados dentro del territorio municipal. La metodología LISA y el análisis de cuadrantes convergen en la identificación de las mismas zonas críticas, lo que otorga alta confiabilidad al diagnóstico territorial. La evidencia obtenida confirma la existencia de una marcada variación espacial de la accidentalidad vial entre barrios, lo que justifica la focalización de intervenciones diferenciadas por tipo de actor en las áreas priorizadas y refuerza la necesidad de enfoques de modelamiento espacial para identificar los factores asociados a estas diferencias territoriales.

5.4. Análisis modal

5.4.1 *Análisis de co-ocurrencia entre tipos de vehículos*

La matriz de co-ocurrencia (Cuadro 5.21) muestra el número de accidentes en los que dos tipos de vehículos participaron simultáneamente. La diagonal principal fue excluida del análisis porque representa coincidencias entre el mismo tipo de vehículo, mientras que el interés de esta sección se centra en las interacciones entre actores viales distintos.

Cuadro 5.21: Matriz de co-ocurrencia entre tipos de vehículos (accidentes compartidos)

	Pe	Au	Cp	Ct	Mi	Bu	Bs	Cm	Vo	Mo	Bi	Ot
PEATÓN	0	871	54	207	30	68	128	94	17	2480	23	42
AUTOMÓVIL	871	0	975	3040	328	734	805	1485	291	9826	234	317
CAMPERO	54	975	0	273	42	66	60	141	20	670	20	26
CAMIONETA	207	3040	273	0	97	185	220	404	52	2304	51	76
MICRO	30	328	42	97	0	23	37	39	2	197	5	6
BUSETA	68	734	66	185	23	0	71	70	14	368	20	21
BUS	128	805	60	220	37	71	0	81	10	392	22	18
CAMIÓN	94	1485	141	404	39	70	81	0	37	632	22	64
VOLQUETA	17	291	20	52	2	14	10	37	0	92	4	11
MOTO	2480	9826	670	2304	197	368	392	632	92	0	293	185
BICICLETA	23	234	20	51	5	20	22	22	4	293	0	9
OTRO	42	317	26	76	6	21	18	64	11	185	9	0

Nota: Pe = Peatón, Au = Automóvil, Cp = Campero, Ct = Camioneta, Mi = Micro, Bu = Buseta, Bs = Bus, Cm = Camión, Vo = Volqueta, Mo = Moto, Bi = Bicicleta, Ot = Otro. Las cifras en negrita indican los valores máximos de co-ocurrencia entre pares de vehículos distintos. La diagonal fue excluida del análisis.

Los resultados evidencian que la combinación MOTO–AUTOMÓVIL domina de manera abrumadora, con 9.826 accidentes compartidos, lo que representa más del triple que la segunda combinación más frecuente (AUTOMÓVIL–CAMIONETA, con 3.040). Esta cifra refleja la alta interacción entre estos dos actores en la siniestralidad vial de Bucaramanga, probablemente asociada a la coexistencia de motocicletas y automóviles en los mismos corredores viales y en horas de alta congestión. Le sigue la combinación MOTO–CAMIONETA (2.304), que evidencia que las motocicletas también interactúan frecuentemente con vehículos de mayor tamaño, lo que puede derivar en siniestros de mayor severidad para los motociclistas.

Un hallazgo particularmente relevante es la co-ocurrencia PEATÓN–MOTO (2.480 accidentes), que ocupa el quinto lugar en la matriz y supera a combinaciones como AUTOMÓVIL–BUS (805) o AUTOMÓVIL–CAMIÓN (1.485). Esta cifra sugiere escenarios de vulnerabilidad asociados con la coexistencia entre movilidad motorizada y peatonal en sectores urbanos de alta circulación, donde los peatones especialmente en el centro y en comunas como San Francisco se ven expuestos a colisiones con motoci-

cletas. En contraste, las bicicletas presentan una participación muy baja en todas las combinaciones (el valor máximo es 293 con MOTO), lo que indica que este modo de transporte tiene aún una presencia marginal en la dinámica de accidentalidad de la ciudad.

La Figura 5.21 permite visualizar claramente que las mayores intensidades de co-ocurrencia se concentran en las combinaciones que involucran motocicletas y automóviles, evidenciando el papel predominante de estos actores dentro de la dinámica de siniestralidad vial en Bucaramanga. El mapa de calor también revela un patrón en el que las combinaciones con vehículos pesados (camiones, buses, busetas) presentan valores intermedios, mientras que las interacciones con bicicletas y otros vehículos son consistentemente bajas.




Figura 5.21: Mapa de calor de co-ocurrencia

Estos resultados tienen implicaciones prácticas para la seguridad vial; la alta frecuencia de co-ocurrencia MOTO–AUTOMÓVIL sugiere que las intervenciones orientadas a reducir los conflictos entre estos dos actores como la separación de flujos, la adecuada señalización en intersecciones y campañas de conducción defensiva podrían tener un impacto significativo en la reducción de la siniestralidad global. Asimismo, la relevancia de la combinación PEATÓN–MOTO apunta a la necesidad de proteger a los peatones en zonas donde el tráfico de motos es intenso, mediante medidas como reductores de velocidad,

pasos peatonales elevados y mejor iluminación.

5.4.2 *Involucramiento por gravedad del accidente*

La Figura 5.22 muestra la participación de los distintos tipos de vehículos según la gravedad del accidente: solo daños, con heridos y con víctimas fatales. Este desglose permite identificar qué actores están sobrerrepresentados en los siniestros más graves, lo que resulta clave para orientar estrategias de prevención.

Como era de esperar, los automóviles y las motocicletas son los vehículos más frecuentes en las tres categorías, reflejando su predominio en el parque automotor, sin embargo, el análisis comparativo revela diferencias relevantes. En los accidentes con solo daños, los automóviles son claramente el actor predominante. En los accidentes con heridos las motocicletas aumentan su participación relativa, lo que indica que los siniestros que las involucran tienen mayor probabilidad de dejar lesionados.

El patrón más alarmante se observa en los accidentes con muertos; aquí, las motocicletas y los peatones presentan una sobrerrepresentación, reflejando la vulnerabilidad de quienes usan estos métodos de transporte. Los vehículos de carga y transporte público (camiones, buses, busetas) mantienen una participación relativamente estable en las tres categorías, mientras que las bicicletas tienen una presencia marginal en todas. Estos datos apuntan a la necesidad de implementar medidas específicas para proteger a motociclistas y peatones.




Figura 5.22: Involucramiento de vehículos por gravedad del accidente

5.4.3 Evolución temporal del involucramiento por tipo de vehículo

Se construyó una matriz de frecuencias absolutas que cruza el tipo de vehículo con el año del accidente (Cuadro 5.22). Se observa una tendencia decreciente en la mayoría de los tipos a partir de 2020, coincidiendo con el período asociado con las restricciones de movilidad por COVID-19, y un incremento posterior en 2021–2022. Las motocicletas y automóviles son los actores más frecuentes en todos los años.

Cuadro 5.22: Frecuencia absoluta de vehículos involucrados por año

Tipo	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023
AUTOMÓVIL	2.905	2.701	2.349	2.336	2.276	2.325	2.339	2.247	1.343	1.648	1.326	413
BICICLETA	49	42	47	39	60	70	88	85	74	59	50	23
BUS	168	197	219	199	190	171	183	206	95	106	85	31
BUSETA	225	179	155	152	172	193	162	165	69	85	79	26
CAMION	383	385	318	316	313	295	288	233	185	218	156	50
CAMIONETA	677	693	632	752	698	680	735	747	430	586	425	131
CAMPERO	293	278	265	247	257	210	211	169	101	149	98	25
MICRO	112	88	98	78	72	68	81	82	34	22	43	11
MOTO	1.975	1.864	1.839	1.950	1.966	2.123	2.214	2.065	1.288	1.534	1.352	755
OTRO	99	87	77	75	53	70	57	67	79	69	50	19
PEATÓN	371	344	371	359	387	411	415	378	223	211	215	128
VOLQUETA	100	96	68	66	62	30	29	26	21	23	21	1

La matriz de frecuencias relativas por año (Cuadro ??) permite apreciar cambios en la composición porcentual. Destaca el aumento sostenido de la participación de motocicletas, que pasan del 26.8 % en 2012 al 46.8 % en 2023, mientras que los automóviles disminuyen del 39.5 % al 25.6 % en el mismo período.

El análisis temporal evidencia cambios importantes en la composición modal de los accidentes de tránsito durante el período 2012–2023. Aunque las motocicletas y los automóviles representan los actores con mayor participación en todos los años analizados, se observa un incremento progresivo de la participación relativa de las motocicletas, mientras que los automóviles presentan una disminución sostenida. Asimismo, los registros muestran una reducción generalizada en las frecuencias durante 2020, seguida de un incremento posterior en 2021 y 2022, comportamiento que coincide temporalmente con el contexto de restricciones de movilidad asociado a la pandemia de COVID-19.

5.4.4 Vehículos más involucrados por franja horaria y día de la semana

Los Cuadros 5.23 y 5.24 muestran que los automóviles y las motocicletas representan los actores viales con mayor participación en todas las franjas horarias y días de la semana, con porcentajes que en conjunto oscilan entre el 65 % y el 75 % del total de vehículos involucrados, no obstante, se observan variaciones importantes en la composición modal de los accidentes según el momento del día y el día de

la semana.

Los peatones presentan una participación relativamente mayor durante la noche y la madrugada, duplicando su porcentaje en comparación con las horas diurnas, lo que refleja su mayor vulnerabilidad en condiciones de baja visibilidad y la menor densidad de tráfico en esos períodos. Por su parte, los buses y camiones concentran su presencia en horarios diurnos y laborales (mañana y tarde temprano), con una participación que disminuye drásticamente durante los fines de semana y alcanza sus valores más bajos los domingos, consistentemente con la reducción de la actividad comercial y de transporte de carga.

Asimismo, durante los fines de semana se registra un incremento moderado en la participación relativa de motocicletas, que pasan del 30 % en días laborables al 31,6 % los sábados y al 34,8 % los domingos. Este aumento sugiere un uso más recreativo y nocturno de las motocicletas durante el fin de semana, así como una mayor exposición en condiciones de menor control y mayor riesgo. Aunque el domingo es el día con menos accidentes en términos absolutos, la proporción de motocicletas y peatones es más alta, lo que apunta a siniestros potencialmente más graves debido a la mayor vulnerabilidad de estos actores y a la posible presencia de factores como el consumo de alcohol o el exceso de velocidad en vías menos congestionadas.

La Figura 5.23 complementa estos resultados al mostrar la evolución del involucramiento vehicular a lo largo del día; el gráfico de barras apiladas evidencia que, aunque automóviles y motocicletas dominan en todas las franjas, su participación relativa fluctúa: las motos alcanzan su punto más alto en la madrugada (32,9 %) y mantienen una presencia elevada durante la tarde y la noche (31 % en promedio), mientras que los automóviles son más predominantes en horas nocturnas (39 %–40 % entre las 21h y las 6h). La figura también permite visualizar el aumento de la participación de peatones en la madrugada y la noche, así como la mayor presencia de camiones y buses en las horas de mayor actividad comercial y laboral (9h–18h). Estas evidencias refuerzan la necesidad de diseñar estrategias de prevención diferenciadas según la franja horaria y el día de la semana, focalizando los controles de alcoholemia y velocidad en las noches de fin de semana, y los operativos de revisión técnica y de carga en horarios diurnos laborales.

Cuadro 5.23: Vehículos más involucrados por franja horaria (extracto)

Franja horaria	Tipo	Total	Porcentaje
Madrugada (0-6h)	AUTOMÓVIL	1.682	40,0
	MOTO	1.382	32,9
	CAMIONETA	338	8,0
Mañana temp. (6-9h)	AUTOMÓVIL	3.517	37,0
	MOTO	2.783	29,3
	CAMIONETA	1.069	11,3
Mañana (9-12h)	AUTOMÓVIL	3.965	34,9
	MOTO	3.471	30,5
	CAMIONETA	1.273	11,2
Tarde temp. (12-15h)	AUTOMÓVIL	4.462	35,0
	MOTO	3.956	31,0
	CAMIONETA	1.407	11,0
Tarde (15-18h)	AUTOMÓVIL	4.365	36,1
	MOTO	3.712	30,7
	CAMIONETA	1.312	10,8
Noche temp. (18-21h)	AUTOMÓVIL	3.843	37,4
	MOTO	3.127	30,4
	CAMIONETA	1.080	10,5
Noche (21-24h)	AUTOMÓVIL	1.677	39,0
	MOTO	1.328	30,9
	CAMIONETA	384	8,9

Cuadro 5.24: Vehículos más involucrados por día de la semana (extracto)

Día	Tipo	Total	Porcentaje
Lunes	AUTOMÓVIL	3.343	35,7
	MOTO	2.824	30,1
	CAMIONETA	1.030	11,0
Martes	AUTOMÓVIL	3.572	36,3
	MOTO	3.087	31,4
	CAMIONETA	1.100	11,2
Miércoles	AUTOMÓVIL	3.545	35,8
	MOTO	2.977	30,1
	CAMIONETA	1.054	10,7
Jueves	AUTOMÓVIL	3.465	35,4
	MOTO	2.975	30,4
	CAMIONETA	1.069	10,9
Viernes	AUTOMÓVIL	3.672	36,1
	MOTO	3.130	30,8
	CAMIONETA	1.131	11,1
Sábado	AUTOMÓVIL	4.026	36,3
	MOTO	3.508	31,6
	CAMIONETA	1.203	10,8
Domingo	AUTOMÓVIL	2.585	37,1
	MOTO	2.424	34,8
	CAMIONETA	599	8,6




Figura 5.23: Involucramiento de vehículos por franja horaria

5.5. Resultados del análisis de tasas estandarizadas por población

En esta sección se presentan los resultados obtenidos al estandarizar las cifras de accidentalidad por población, lo que permite comparar la intensidad relativa del problema entre distintas zonas geográficas, independientemente de su tamaño demográfico. Se analizan tasas a nivel de comuna y barrio, así como tasas de involucramiento por tipo de vehículo.

Aunque el análisis espacial presentado en la sección anterior permitió identificar patrones de agrupamiento espacial y zonas críticas mediante el índice de Moran y los indicadores locales LISA, dichos métodos responden principalmente a la pregunta de si la accidentalidad presenta una distribución espacial aleatoria o si existen conglomerados territoriales significativos. En contraste, el análisis de tasas estandarizadas desarrollado en esta sección tiene como propósito cuantificar la magnitud relativa de la accidentalidad en cada territorio, ajustando por el tamaño de la población. De esta manera, ambos enfoques son complementarios: mientras LISA identifica dónde existen agrupamientos espaciales significativos,

las tasas estandarizadas permiten evaluar la intensidad relativa del problema y comparar territorios con diferentes tamaños poblacionales.

5.5.1 Tasas de accidentalidad por comuna

Con el fin de comparar la intensidad relativa de la accidentalidad entre comunas, se calcularon tasas anuales promedio por cada 1.000 habitantes. Los resultados muestran diferencias importantes que no son evidentes al considerar únicamente el número absoluto de accidentes. El Cuadro 5.25 presenta las diez comunas con las mayores tasas de accidentalidad.

La comuna 15 (Centro) registra la mayor tasa de la ciudad, con 11,4 accidentes por cada 1.000 habitantes al año, valor que supera ampliamente al de la segunda comuna clasificada (Corregimiento 1, con 3,8). Esta diferencia refleja la elevada concentración de siniestros en el centro urbano, donde convergen una intensa actividad comercial y de servicios, altos flujos vehiculares y peatonales, y una población residente relativamente reducida. Como consecuencia, al estandarizar los accidentes por población, la incidencia relativa resulta considerablemente mayor que en el resto de las comunas.

En los siguientes lugares se ubican La Concordia (3,4), San Francisco (3,3) y Cabecera del Llano (2,6). Aunque estas comunas también presentan un elevado número de accidentes, sus poblaciones son mayores que la del Centro, lo que reduce las tasas de accidentalidad respecto a esta última. Estos resultados son coherentes con el análisis espacial presentado en la sección anterior, donde dichas comunas forman parte de la franja urbana con mayor concentración de siniestros y donde se localizaron los principales clústeres de accidentalidad.

Por el contrario, comunas con poblaciones más numerosas, como Oriental (134.676 habitantes), presentan tasas relativamente bajas (1,2 accidentes por cada 1.000 habitantes al año), lo que evidencia que una elevada frecuencia absoluta de accidentes no necesariamente implica un mayor riesgo relativo para la población residente. En consecuencia, el uso de tasas estandarizadas permite identificar con mayor precisión los territorios donde la accidentalidad representa un problema proporcionalmente más severo.

Cuadro 5.25: Top 8 comunas por tasa de accidentalidad (por 1.000 hab/año)

Comuna	Tasa anual	Total accidentes	Población promedio
15. CENTRO	11,4	4.405	12.476
06. LA CONCORDIA	3,4	3.180	29.962
03. SAN FRANCISCO	3,3	5.287	51.781
12. CABECERA DEL LLANO	2,6	6.415	80.984
09. LA PEDREGOSA	2,3	1.188	16.513
04. OCCIDENTAL	1,9	2.143	37.339
05. GARCIA ROVIRA	1,3	1.517	38.339
13. ORIENTAL	1,2	5.093	134.676

5.5.2 Tasas de accidentalidad por barrio

Las tasas estandarizadas por barrio permiten identificar territorios donde la accidentalidad representa un riesgo proporcionalmente elevado para la población residente, independientemente del número absoluto de siniestros. Para este análisis se calcularon tasas anuales promedio por cada 1.000 habitantes en los 164 barrios con información poblacional disponible. El Cuadro 5.26 presenta los veinte barrios con las mayores tasas de accidentalidad.

El barrio Río de Oro I registra la mayor tasa de la ciudad, con 34,8 accidentes por cada 1.000 habitantes al año, seguido por Puerta del Sol (21,2), Antonia Santos Sur (14,7), La Pedregosa (14,4) y Centro (14,1). Estas diferencias muestran que la intensidad de la accidentalidad varía considerablemente entre barrios y que la frecuencia absoluta de accidentes no siempre coincide con el mayor riesgo relativo.

Un aspecto relevante es que varios de los barrios con las tasas más elevadas poseen poblaciones relativamente pequeñas. En consecuencia, un número moderado de accidentes puede traducirse en tasas muy altas al estandarizar por población. Este comportamiento se observa, por ejemplo, en Río de Oro I, con 1.136 accidentes y una población de 1.053 habitantes, así como en Puerta del Sol (616 accidentes, 938 habitantes) y Antonia Santos Sur (365 accidentes, 803 habitantes). Estos resultados ilustran la importancia de interpretar conjuntamente las tasas y las frecuencias absolutas para evitar conclusiones basadas únicamente en el volumen de accidentes.

En contraste, el barrio Centro, aunque registra el mayor número absoluto de accidentes de toda la

ciudad (3.861), ocupa la quinta posición en el ranking de tasas. Este resultado indica que su elevada frecuencia está asociada, en parte, a una población residente considerablemente mayor que la de otros barrios con tasas más altas. De manera similar, barrios como Bosconia y Los Cedros aparecen entre los veinte primeros debido a que sus reducidas poblaciones amplifican el valor de la tasa, aun cuando el número absoluto de accidentes es relativamente bajo.

Estos resultados evidencian que las tasas estandarizadas aportan una perspectiva complementaria al análisis basado en frecuencias absolutas. Mientras este último identifica los sectores donde ocurre el mayor número de siniestros, las tasas permiten reconocer aquellos territorios donde la accidentalidad representa una mayor carga relativa para la población residente, proporcionando un criterio adicional para la priorización de intervenciones en seguridad vial.

Cuadro 5.26: Top 20 barrios por tasa de accidentalidad (por 1.000 hab/año)

Barrio	Comuna	Tasa	Accidentes	Población
RÍO DE ORO I	04. OCCIDENTAL	34,8	1.136	1.053
PUERTA DEL SOL	12. CABECERA DEL LLANO	21,2	616	938
ANTONIA SANTOS SUR	09. LA PEDREGOSA	14,7	365	803
LA PEDREGOSA	09. LA PEDREGOSA	14,4	273	613
CENTRO	15. CENTRO	14,1	3.861	8.816
LA SALLE	06. LA CONCORDIA	9,0	276	985
RICAUURTE	06. LA CONCORDIA	8,6	819	3.059
NORTE BAJO	03. SAN FRANCISCO	8,5	397	1.505
ALARCON	03. SAN FRANCISCO	8,5	886	3.374
CONUCOS	12. CABECERA DEL LLANO	7,1	716	3.270
BOSCONIA	02. NORORIENTAL	6,0	21	194
ASTURIAS	09. LA PEDREGOSA	5,9	196	1.065
LA CONCORDIA	06. LA CONCORDIA	4,9	1.376	9.037
GARCIA ROVIRA	15. CENTRO	4,8	544	3.660
LOS CEDROS	12. CABECERA DEL LLANO	4,8	3	210

Cuadro 5.26 – Continuación

Barrio	Comuna	Tasa	Accidentes	Población
SAN RAFAEL	03. SAN FRANCISCO	4,8	318	2.158
QUINTADANIA	13. ORIENTAL	4,5	176	1.256
LOS GUAYACANES	16. LAGOS DEL CACIQUE	4,4	17	350
VILLA MARIA I	01. NORTE	4,2	3	238
LA AURORA	13. ORIENTAL	4,1	716	5.590

5.5.3 Tasas de involucramiento por tipo de vehículo a nivel de comuna

Con el fin de comparar la intensidad relativa del involucramiento de distintos tipos de vehículos entre comunas, se calcularon tasas estandarizadas por cada 1.000 habitantes. El Cuadro 5.27 presenta las diez comunas con mayor tasa de motocicletas involucradas, junto con su población total.

Cuadro 5.27: Top 10 comunas por tasa de motocicletas involucradas (por 1.000 hab)

Comuna	Tasa de motos	Población total
15. CENTRO	222,0	12.476
03. SAN FRANCISCO	72,6	51.781
06. LA CONCORDIA	70,5	29.962
CORREG. 1	60,1	782
09. LA PEDREGOSA	43,8	16.513
12. CABECERA DEL LLANO	39,5	80.984
04. OCCIDENTAL	36,9	37.339
05. GARCIA ROVIRA	33,9	38.339
13. ORIENTAL	21,9	134.676
CORREG. 3	21,7	1472

Los resultados revelan una marcada heterogeneidad territorial en la incidencia de motocicletas en los accidentes de tránsito. La comuna 15 (Centro) presenta una tasa de 222,0 motos involucradas por cada 1.000 habitantes, un valor que supera en más de tres veces al de la segunda comuna (San Francisco, 72,6) y en más de diez veces al de comunas como Oriental (21,9). Esta diferencia tan pronunciada refleja la combinación de dos factores en el Centro: por un lado, su reducida población residente, que eleva el denominador de la tasa, y por otro, su intensa actividad comercial, institucional y de servicios, que atrae un flujo masivo de motocicletas durante todo el día, incrementando la exposición y el número de siniestros

que las involucran.

San Francisco (72,6) y La Concordia (70,5) ocupan el segundo y tercer lugar, con tasas que, aunque muy inferiores a la del Centro, duplican a las de comunas como Cabecera del Llano (39,5) u Occidental (36,9). Estas diferencias sugieren que la presencia de motocicletas en la siniestralidad está asociada no solo al volumen de tráfico, sino también a la configuración vial y a los patrones de movilidad particulares de cada comuna. Por ejemplo, San Francisco es una zona con alta densidad de comercio y servicios, donde las motocicletas son frecuentemente utilizadas para labores de mensajería, domicilios y transporte informal, lo que incrementa su exposición en las vías.

Llama la atención la presencia de los corregimientos 1 y 3 en la lista, con tasas de 60,1 y 21,7 respectivamente. Aunque estos sectores tienen poblaciones reducidas (782 y 1.472 habitantes), las tasas elevadas indican que, en términos relativos, la incidencia de motocicletas en accidentes es considerable. Esto podría deberse a la existencia de vías principales que atraviesan estos sectores y que conectan con otras zonas de la ciudad, generando un tránsito de paso que no se refleja en la población residente.

En el extremo opuesto, comunas con alta población como Oriental (134.676 habitantes) presentan tasas relativamente bajas (21,9), lo que sugiere que, a pesar del volumen de accidentes, la incidencia per cápita de motocicletas en siniestros es menor. Esto podría estar asociado a una menor densidad de actividades comerciales o a un parque automotor con una composición diferente a la de las comunas centrales.

Estos resultados complementan los hallazgos del análisis espacial y modal presentados anteriormente, al evidenciar que la participación de motocicletas en la siniestralidad no es uniforme en el territorio, sino que se concentra en comunas con alta actividad urbana, elevados flujos de tránsito y, en algunos casos, poblaciones reducidas que magnifican las tasas relativas. La identificación de estas zonas resulta clave para diseñar campañas de prevención, controles de velocidad y uso de casco, así como intervenciones en infraestructura vial adaptadas a las características particulares de cada comuna.

5.5.4 Análisis por cuadrantes de accidentalidad

A partir de los valores de frecuencia absoluta y tasa estandarizada, se clasificaron los barrios en cuatro cuadrantes tomando como punto de corte la mediana de cada indicador (mediana frecuencia =

84 accidentes, mediana tasa = 8,7 accidentes por 1.000 hab/año). Esta clasificación permite priorizar intervenciones según la combinación de ambos indicadores. El Cuadro 5.28 resume las características de cada cuadrante.

Cuadro 5.28: Resumen de barrios por cuadrante

Cuadrante	N.º barrios	Total accidentes	Población total	Tasa promedio*
Q1: Prioridad máxima (alta frecuencia + alta tasa)	64	30.753	353.499	10,8
Q2: Alta frecuencia – baja tasa	18	5.629	294.304	1,9
Q3: Baja frecuencia – alta tasa	18	260	17.494	1,5
Q4: Baja accidentalidad (baja frecuencia + baja tasa)	64	740	144.298	0,5

* Tasa promedio simple de los barrios del cuadrante (por 1.000 hab/año).

Q1: Prioridad máxima

Agrupar 64 barrios que concentran 30.753 accidentes (82,5 % del total) en una población de 353.499 habitantes. Son zonas que requieren atención prioritaria por su alta siniestralidad tanto absoluta como relativa. Entre ellos se encuentran Río de Oro I, Puerta del Sol, Antonia Santos Sur, La Pedregosa, Centro, La Salle, Ricaurte, Norte Bajo, Alarcón y Conucos, entre otros.

Q2: Alta frecuencia – baja tasa

Incluye 18 barrios con muchos accidentes pero poblaciones grandes, lo que modera su tasa. Ejemplos de este grupo son San Alonso, Real de Minas, El Tejar, Mutis, Álvarez, Café Madrid, entre otros. En estos barrios, la frecuencia absoluta es elevada, pero la tasa per cápita es relativamente baja debido a sus grandes poblaciones.

Q3: Baja frecuencia – alta tasa

Agrupar 18 barrios pequeños (población total 17.494 hab.) con pocos accidentes pero tasas elevadas, lo que revela una vulnerabilidad oculta. Destacan Bosconia, Los Cedros, Los Guayacanes, Villa María I, Omega I, entre otros. Estos barrios, aunque tienen pocos accidentes en términos absolutos, presentan tasas que indican un alto riesgo relativo para sus residentes.

Q4: Baja accidentalidad

Incluye 64 barrios con baja frecuencia y baja tasa. Ejemplos de este grupo son Buenos Aires, Manuela Beltrán, Granjas de Provenza, Brisas del Mutis, María Paz, entre otros. Estos barrios presentan tanto bajos volúmenes absolutos como bajas tasas per cápita, lo que sugiere condiciones de movilidad más seguras.

Visualización de los cuadrantes

La Figura 5.24 muestra la distribución de los barrios en los cuatro cuadrantes, con los más destacados etiquetados. Las líneas sólidas representan las medianas de frecuencia y tasa.

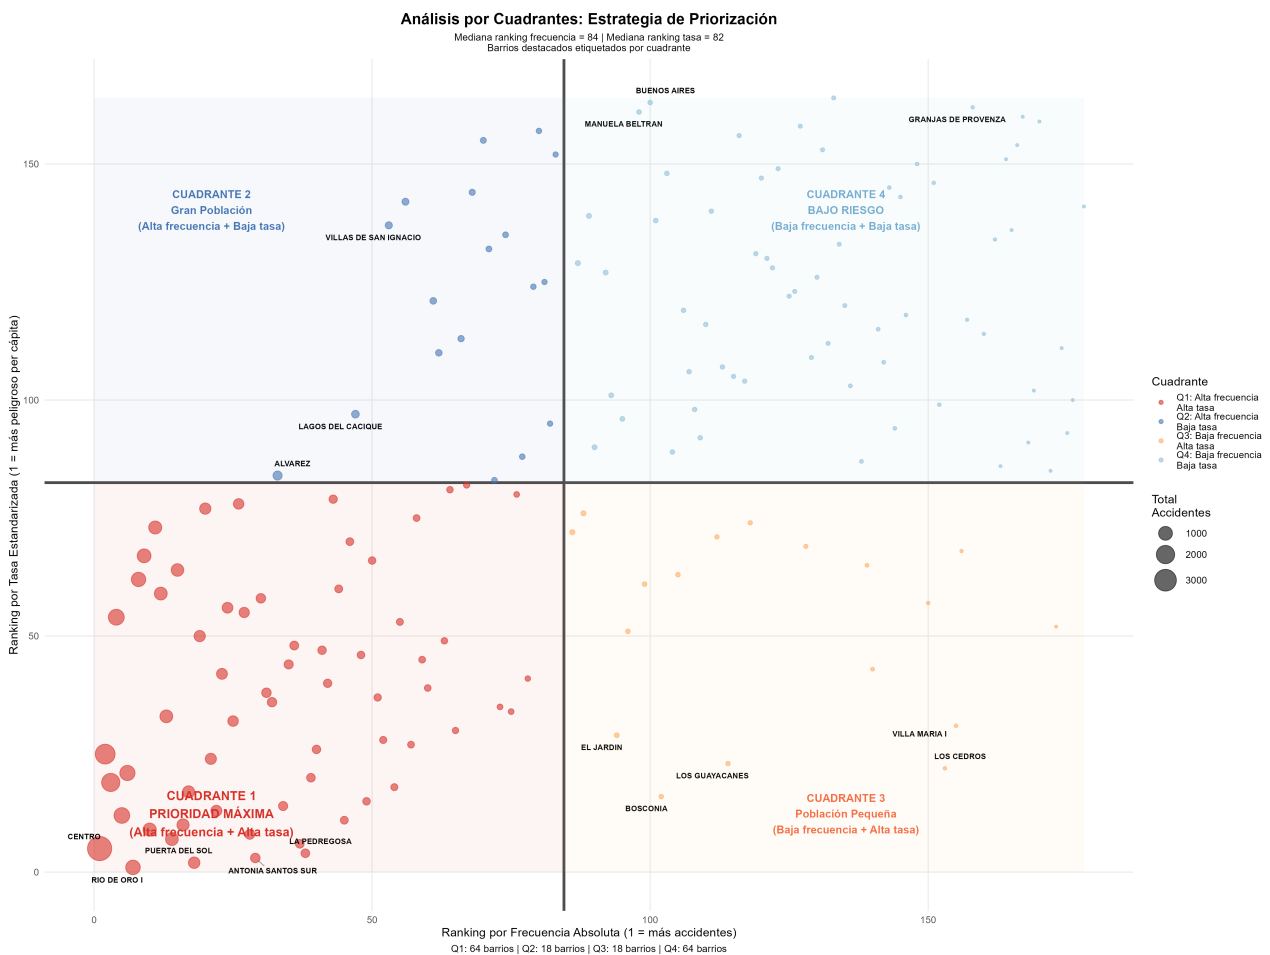


Figura 5.24: Clasificación de barrios por cuadrantes de priorización

La Figura 5.25 presenta un resumen en barras del número de barrios, accidentes y población por cuadrante.




Figura 5.25: Distribución de barrios, accidentes y población por cuadrante

La Figura 5.26 compara los diez barrios con mayor tasa dentro de cada cuadrante.




Figura 5.26: Top 10 barrios por tasa en cada cuadrante

5.5.5 Análisis espacial de las tasas estandarizadas

Los análisis anteriores permiten cuantificar la accidentalidad por barrio, pero su interpretación gana profundidad al proyectarlos sobre el territorio. Para ello se construyeron cuatro mapas temáticos a partir del shapefile oficial de barrios de Bucaramanga (219 polígonos), combinado con las tasas calculadas en las subsecciones precedentes.

Los resultados obtenidos complementan los hallazgos del análisis LISA, ya que mientras este permitió identificar conglomerados espaciales significativos, las tasas estandarizadas permitieron dimensionar la magnitud relativa de la accidentalidad en cada barrio y comuna.

Distribución coroplética de la tasa de accidentalidad

La Figura 5.27 presenta el mapa coroplético de la tasa anual promedio de accidentalidad por cada 1.000 habitantes. La escala de color permite identificar rápidamente los barrios de mayor accidentalidad: las manchas de color más intenso se concentran en la franja centro-occidental de la ciudad, correspondiente a los barrios Río de Oro I, Puerta del Sol, Antonia Santos Sur y La Pedregosa, así como en el núcleo central (barrio Centro). La periferia sur y suroriental presenta tonos fríos, coherente con los bajos conteos de accidentes en esas zonas residenciales.




Figura 5.27: Mapa coroplético de la tasa anual de accidentalidad por barrio

Categorización espacial de la accidentalidad

Con el fin de simplificar la lectura del mapa anterior, los barrios se clasificaron en seis categorías de accidentalidad según umbrales de tasa establecidos a partir de la distribución empírica de las tasas observadas en los 164 barrios con datos válidos de población y accidentalidad. El Cuadro 5.29 resume la distribución resultante y la Figura 5.28 la muestra cartográficamente.

Cuadro 5.29: Distribución de barrios por categoría de accidentalidad (tasa estandarizada por 1.000 hab)

Categoría	N.º barrios	% barrios	Accidentes	% accidentes
Sin accidentes	70	32,0	0	0,0
Muy bajo (<1)	60	27,4	3.740	10,1
Bajo (1–3)	63	28,8	16.102	43,4
Medio (3–6)	14	6,4	6.854	18,5
Alto (6–10)	6	2,7	3.115	8,4
Muy alto (>10)	6	2,7	7.387	19,9

Destaca que apenas 12 barrios (5,5 % del total) concentran el 28,3 % de todos los accidentes y corresponden a las categorías «Alto» y «Muy alto». El 60,8 % de los barrios tiene una tasa inferior a 3 accidentes por 1.000 habitantes al año o no registra siniestros, lo que evidencia una distribución espacial de accidentalidad marcadamente asimétrica.




Figura 5.28: Categorización de la accidentalidad por barrio a partir de la tasa estandarizada

Mapa de cuadrantes de priorización

La Figura 5.29 traslada la clasificación por cuadrantes al plano geográfico. Los barrios en rojo corresponden al cuadrante Q1 (prioridad máxima: alta frecuencia y alta tasa); los azules al Q2 (alta frecuencia pero tasa moderada por su gran población); los naranjas al Q3 (baja frecuencia pero tasa elevada por su pequeña población); y los azul claro al Q4 (baja accidentalidad en ambas dimensiones).




Figura 5.29: Distribución espacial de los cuadrantes de priorización

La observación del mapa revela un patrón geográfico claro: los barrios Q1 forman un corredor continuo que abarca el centro histórico, la ladera occidental y los ejes viales principales de las comunas 3, 6, 9, 12 y 15. Los barrios Q3, en cambio, se distribuyen de manera dispersa en zonas de borde urbano con pequeñas poblaciones, donde un accidente puntual genera tasas per cápita elevadas. La distribución Q2 y Q4 se localiza principalmente en la periferia sur y oriente, donde grandes conjuntos residenciales moderan la tasa a pesar de contar con decenas de accidentes anuales.

5.5.6 *Resumen*

El conjunto de análisis presentado en esta sección permite extraer las siguientes conclusiones sobre la distribución espacial de la accidentalidad en Bucaramanga durante el período 2012–2023:

1. **La estandarización por población es imprescindible.** La tasa por 1.000 habitantes permite identificar barrios con alta intensidad relativa que no son evidentes al observar solo las frecuencias absolutas. Río de Oro I, Puerta del Sol y Antonia Santos Sur presentan las tasas más altas de la ciudad, muy por encima de barrios con mayor volumen de accidentes como Centro o Cabecera del Llano.
2. **Un núcleo reducido de barrios concentra la mayor parte de los siniestros.** Los 60 barrios del cuadrante Q1 (prioridad máxima) reúnen el 94,5 % de los accidentes con datos de población disponibles. Este grupo incluye tanto barrios céntricos de alta densidad como zonas residenciales de baja densidad pero con tasas per cápita extremas.
3. **La distribución espacial de la accidentalidad es asimétrica y geográficamente concentrada.** Solo 12 barrios (5,5 %) pertenecen a las categorías de accidentalidad «Alto» o «Muy alto» (tasa > 6 por 1.000 hab/año), pero concentran el 28,3 % de todos los accidentes. Geográficamente se ubican en un corredor continuo que cruza el centro y la ladera occidental de la ciudad.
4. **Los barrios Q3 revelan vulnerabilidad periférica oculta.** 15 barrios de borde urbano, con población total inferior a 10.000 habitantes en conjunto, presentan tasas elevadas a pesar de sus bajos números absolutos. Intervenciones pequeñas en estos territorios podrían tener un impacto relativo muy significativo.
5. **Las motocicletas dominan en todas las escalas territoriales.** Su participación creció del 26,8 % en 2012 al 46,8 % en 2023. La comuna 15 (Centro) registra una tasa acumulada de 222 motocicletas involucradas por cada 1.000 habitantes durante el período 2012–2023, más de tres veces superior a la siguiente (San Francisco, 72,6). Este patrón es consistente tanto en el análisis comunal como en el barrial.
6. **El cambio estructural de 2020 no afecta la jerarquía espacial de la accidentalidad.** A pesar de la caída del 45,7 % en el volumen mensual de accidentes asociada a la pandemia COVID-19, los barrios de mayor accidentalidad relativa mantienen sus posiciones en el ranking de tasa

estandarizada, lo que sugiere que los factores estructurales de accidentalidad (infraestructura, flujo vehicular, densidad de usos del suelo) prevalecen sobre las reducciones coyunturales de movilidad.

6 Conclusiones y recomendaciones

6.1. Conclusiones según objetivos

1. **Caracterización descriptiva general de la accidentalidad.** El análisis de los registros de accidentes ocurridos en Bucaramanga entre 2012 y 2023 revela un fenómeno de gran magnitud y profundas implicaciones para la seguridad vial de la ciudad. La mayoría de los barrios del municipio registraron al menos un siniestro durante el período, aunque la distribución es marcadamente desigual: un pequeño grupo de barrios concentra una proporción desproporcionada del total de accidentes, encabezado por el Centro, seguido de Cabecera del Llano y San Francisco. Los automóviles y las motocicletas emergen como los actores viales predominantes, presentes en la mayoría de los siniestros, y su interacción conjunta constituye la combinación más frecuente en accidentes múltiples, superando ampliamente a cualquier otra.
2. **Identificación de patrones temporales de la siniestralidad.** La ocurrencia de accidentes sigue ritmos temporales claramente definidos que se manifiestan en distintas escalas. A lo largo del día, la accidentalidad se concentra en las horas centrales de la jornada, con picos al mediodía y al atardecer. En la escala semanal, el sábado emerge como el día de mayor frecuencia, aunque los siniestros más graves tienden a concentrarse en la madrugada y el domingo. En el ámbito mensual, aunque se observan variaciones entre meses, estas no son estadísticamente significativas, lo que indica que la estacionalidad anual es débil. En contraste, la tendencia de largo plazo es fuerte y estable durante los años previos a 2020.
3. **Estimación del impacto de eventos exógenos sobre la serie temporal.** La serie temporal de accidentes se vio afectada por dos perturbaciones externas de distinta naturaleza. La pandemia de COVID-19 produjo una caída abrupta y significativa en el número mensual de accidentes, efecto que se mantuvo en el tiempo y que impidió que la accidentalidad retornara a los niveles previos. Adicionalmente, la modificación de los procedimientos de registro de siniestros de baja gravedad introdujo un sesgo de subregistro que afecta la comparabilidad de los datos recientes, lo que obliga a interpretar con cautela las cifras posteriores a la entrada en vigor de la nueva normativa.
4. **Caracterización de los componentes temporales mediante modelación complementaria.** El

modelo de descomposición temporal permitió precisar los patrones semanales y anuales de la accidentalidad. El sábado se consolida como el día de mayor actividad, mientras que el domingo presenta la menor frecuencia, con una diferencia considerable entre ambos. Los días festivos nacionales reducen sistemáticamente el número esperado de accidentes, siendo los más relevantes aquellos que implican una disminución significativa de la movilidad laboral y comercial, como la Semana Santa y las festividades de noviembre y octubre.

5. **Análisis de la distribución espacial de la accidentalidad.** La distribución geográfica de los accidentes no responde a un patrón aleatorio. Existe una tendencia clara al agrupamiento espacial: los barrios con alta accidentalidad tienden a concentrarse en áreas contiguas, lo que evidencia la presencia de factores territoriales compartidos. El análisis local identificó un núcleo crítico en la zona centro-occidental de la ciudad, conformado por barrios con tasas excepcionalmente altas, que se sitúa como el principal foco de atención para las políticas de seguridad vial. La convergencia de distintas metodologías otorga solidez a este diagnóstico.
6. **Evaluación de la distribución espacial mediante tasas estandarizadas.** La estandarización por población modifica sustancialmente la percepción del riesgo territorial. Barrios que no destacan por su volumen absoluto de accidentes emergen como los de mayor intensidad relativa una vez ajustados por su población, lo que revela situaciones de alta vulnerabilidad que la frecuencia absoluta oculta. El análisis por cuadrantes permitió distinguir entre zonas de prioridad máxima, donde confluyen alta frecuencia y alta tasa, y zonas de vulnerabilidad periférica, donde poblaciones reducidas enfrentan riesgos relativos elevados. Una proporción muy reducida de barrios, perteneciente a las categorías más altas de riesgo, concentra una parte importante del total de siniestros.
7. **Análisis de la participación de actores viales.** La composición modal de los accidentes ha experimentado una transformación profunda durante el período de estudio. Las motocicletas han aumentado su participación de manera sostenida, consolidándose como el actor vial de mayor crecimiento relativo, mientras que los automóviles han perdido peso en la siniestralidad. Este crecimiento se concentra espacialmente en las mismas zonas identificadas como críticas por el análisis espacial. En los accidentes más graves, motociclistas y peatones presentan una sobrerrepresentación que evidencia su especial vulnerabilidad, y la interacción entre ambos actores, aunque menos frecuente en términos absolutos, resulta particularmente letal.

6.2. Recomendaciones

6.2.1 Para las Autoridades de Tránsito

1. **Focalizar los operativos de control en los períodos y zonas de mayor riesgo identificados.** Los resultados muestran que los sábados entre las 12:00 y las 18:00 h concentran los picos más altos de accidentalidad. Se recomienda reforzar los operativos de control de velocidad, alcoholemia y uso de casco en estas franjas, especialmente en los ejes viales de las comunas Centro (C15), San Francisco (C03), La Concordia (C06) y Cabecera del Llano (C12).
2. **Implementar intervenciones prioritarias en el clúster *hotspot* centro-occidental.** Los cinco barrios identificados como *hotspots* estadísticamente significativos (Puerta del Sol, Antonia Santos Sur, La Salle, Conucos y La Ceiba) requieren intervenciones urgentes y focalizadas: auditorías de seguridad vial de la infraestructura, revisión de velocidades máximas permitidas, mejoramiento de señalización y demarcación, e instalación o optimización de dispositivos de control semafórico.
3. **Adoptar el indicador de tasa estandarizada como criterio complementario de priorización.** La frecuencia absoluta de accidentes no es suficiente para identificar las zonas de mayor riesgo real. Se recomienda que la Secretaría de Tránsito incorpore las tasas por habitante en sus informes periódicos de accidentalidad, lo que permitiría visibilizar barrios como Río de Oro I que no aparecen en los primeros puestos del ranking absoluto pero presentan un riesgo per cápita extremo.
4. **Diseñar estrategias diferenciadas para el control de motocicletas.** Dada la sobrerrepresentación creciente de las motocicletas en los siniestros (46.8 % en 2023) y su mayor vulnerabilidad en los accidentes fatales, se recomienda intensificar la verificación del uso del casco y demás elementos de protección, así como el control del estado técnico-mecánico de estos vehículos. Los operativos en las comunas de mayor tasa de involucramiento de motos (Centro, San Francisco y La Concordia) deberían ser prioritarios.
5. **Considerar el impacto del subregistro en la evaluación de políticas.** La Ley 2251 de 2022 generó una discontinuidad en los registros administrativos que dificulta la comparabilidad temporal de las cifras de accidentalidad. Se recomienda explorar fuentes complementarias de registro (reportes de aseguradoras, datos SOAT, atenciones de urgencias) para estimar el volumen real de siniestros de baja gravedad y evaluar el impacto efectivo de las políticas de seguridad vial implementadas desde 2022.

6.2.2 *Para la Planeación Urbana*

1. **Integrar los *hotspots* de accidentalidad en los instrumentos de planeación territorial.** Los resultados del análisis LISA y del análisis de cuadrantes deberían incorporarse al Plan de Ordenamiento Territorial (POT) de Bucaramanga como insumo para la identificación de zonas de intervención prioritaria en materia de infraestructura vial. El corredor continuo de barrios Q1 que abarca las comunas 3, 6, 9, 12 y 15 debería ser objeto de planes específicos de mejoramiento vial.
2. **Atender la vulnerabilidad periférica revelada por los barrios del cuadrante Q3.** Los 29 barrios de borde urbano con baja frecuencia absoluta pero alta tasa per cápita (cuadrante Q3) representan zonas donde la infraestructura vial es típicamente más precaria y donde la ausencia de señalización o la deficiencia geométrica de las vías puede generar accidentes de alta severidad relativa. Se recomienda incluir estos territorios en los programas de mejoramiento de infraestructura vial periférica.
3. **Planificar la infraestructura considerando la expansión del parque de motocicletas.** El crecimiento sostenido de la participación de motocicletas en la movilidad urbana de Bucaramanga exige adaptar la infraestructura vial a esta realidad: diseño de carriles segregados o zonas de avanzada para motos en intersecciones, revisión de los radios de curvatura en vías de alta velocidad y mejoramiento del estado del pavimento en los corredores de mayor tráfico de dos ruedas.
4. **Fortalecer la seguridad peatonal en las zonas de mayor co-ocurrencia MOTO-PEATÓN.** La interacción moto-peatón es la de mayor gravedad relativa en términos de víctimas fatales. Se recomienda revisar las condiciones de los cruces peatonales, ampliar la red de andenes en las comunas de alta accidentalidad peatonal (San Francisco con 514 peatones involucrados, La Concordia con 374) e implementar medidas de calmado de tráfico en zonas de alta densidad de peatones.

6.2.3 *Para Futuras Investigaciones*

1. **Incorporar variables explicativas en los modelos espaciales.** El presente estudio identificó los patrones de distribución espacial de la accidentalidad, pero no modeló sus determinantes. Futuras investigaciones podrían estimar modelos de regresión espacial (regresión ponderada geográficamente, modelos de rezago espacial) que relacionen las tasas de accidentalidad con variables del entorno construido: densidad de intersecciones, jerarquía vial, usos del suelo, densidad comercial

y características de la red de transporte público.

2. **Ampliar el análisis temporal con fuentes de datos complementarias.** El subregistro introducido por la Ley 2251 de 2022 limita la continuidad de la serie histórica en los años más recientes. Se recomienda explorar la fusión de los registros de la Secretaría de Tránsito con datos de reportes de aseguradoras, atenciones hospitalarias de urgencias por trauma vial y registros del SOAT, con el fin de construir una estimación más completa del volumen real de siniestros.
3. **Desarrollar un segundo modelo ITS para evaluar el efecto de la Ley 2251.** El período de observación post-Ley 2251 disponible (segundo semestre de 2022 y enero–septiembre de 2023) es insuficiente para ajustar un modelo ITS robusto que aísle el efecto normativo del efecto pandémico residual. A medida que se acumulen más observaciones post-intervención, se recomienda estimar un modelo de doble intervención que cuantifique de forma independiente ambos efectos.
4. **Explorar el análisis de accidentalidad a escala de segmento vial.** El presente estudio utilizó el barrio como unidad espacial básica. La disponibilidad de datos georreferenciados a nivel de punto de accidente permitiría realizar análisis de densidad de kernel y detección de puntos negros a escala de segmento vial o intersección, con mayor precisión para la toma de decisiones de ingeniería vial.
5. **Analizar el perfil de riesgo de los motociclistas con mayor desagregación.** El crecimiento del parque de motocicletas como modo de transporte de trabajo (mototaxismo, domicilios) en Bucaramanga justifica un estudio específico sobre este actor: análisis de las franjas horarias, corredores y condiciones de iluminación en que los motociclistas son víctimas, estimación de tasas de mortalidad por kilómetro recorrido y evaluación del impacto de campañas específicas de uso de casco y conducción defensiva.
6. **Replicar la metodología en otras ciudades intermedias colombianas.** Los patrones identificados en Bucaramanga (predominio de motos, concentración espacial en zonas céntricas, impacto diferencial de festivos) son consistentes con los reportados en ciudades como Cúcuta, Pereira y Manizales. Un estudio comparativo que aplique la misma metodología en varias ciudades intermedias colombianas permitiría identificar patrones estructurales de alcance nacional y formular recomendaciones de política pública de mayor escala.

Referencias bibliográficas

- Amoros, E., Martin, J.-L., & Laumon, B. (2006). Under-reporting of road crash casualties in France. *Accident Analysis & Prevention*, 38(4), 627-635. <https://doi.org/10.1016/j.aap.2005.11.006>
- Anselin, L. (1988). *Spatial Econometrics: Methods and Models*. Kluwer Academic Publishers. <https://doi.org/10.1007/978-94-015-7799-1>
- Anselin, L. (1995). Local Indicators of Spatial Association—LISA. *Geographical Analysis*, 27(2), 93-115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Anselin, L. (1996). The Moran scatterplot as an ESDA tool to assess local instability in spatial association (M. M. Fischer, H. J. Scholten & D. Unwin, Eds.). *Spatial Analytical Perspectives on GIS*, 111-125.
- Apichai Tongpradubetch, K. K. (2024). Impact of COVID-19 on road crashes in Thailand. *Traffic Injury Prevention*. <https://doi.org/10.1016/j.iatssr.2024.04.001>
- Beltran, P. J. C., Karen. (2023). Valoración del costo social de accidentes de tránsito fatales en Bucaramanga [Se estimó una pérdida de \$47.198.062.272 COP por la muerte de 23 personas en 2023]. Repositorio Noesis UIS. <https://noesis.uis.edu.co/items/f56d318c-95a9-4b4b-99e1-ff61c8d8804f>
- Benjamini, Y., & Hochberg, Y. (1995). Controlling the false discovery rate: a practical and powerful approach to multiple testing. *Journal of the Royal Statistical Society: Series B*, 57(1), 289-300. <https://doi.org/10.1111/j.2517-6161.1995.tb02031.x>
- Bernal, J. L., Cummins, S., & Gasparrini, A. (2017). Interrupted time series regression for the evaluation of public health interventions: a tutorial. *International Journal of Epidemiology*, 46(1), 348-355. <https://doi.org/10.1093/ije/dyw098>
- Bivand, R. S., Pebesma, E., & Gómez-Rubio, V. (2008). *Applied Spatial Data Analysis with R*. Springer. <https://doi.org/10.1007/978-0-387-78171-6>
- Bivand, R. S., & Wong, D. W. S. (2018). Comparing implementations of global and local indicators of spatial association. *TEST*, 27(4), 716-748. <https://doi.org/10.1007/s11749-018-0599-x>
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control* (5th). John Wiley & Sons.

- Caliendo, C., Guida, M., & Parisi, A. (2007). A crash-prediction model for multilane roads. *Accident Analysis & Prevention*, 39(4), 657-670. <https://doi.org/10.1016/j.aap.2006.10.012>
- Castañeda-Millán, G., & Eslava-Schmalbach, J. (2024). Tendencias en la mortalidad por accidentes de tránsito en motocicleta en Colombia, 2008–2021. *Revista Panamericana de Salud Pública*, 48, e44. <https://doi.org/10.26633/RPSP.2024.44>
- Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. (1990). STL: A Seasonal-Trend Decomposition Procedure Based on Loess. *Journal of Official Statistics*, 6(1), 3-73.
- Congreso de la República de Colombia. (2022). Ley 2251 de 2022: Por medio de la cual se modifica la Ley 769 de 2002 y la Ley 2161 de 2021 en lo relacionado con el procedimiento para accidentes de tránsito con solo daños. <https://www.suin-juriscol.gov.co/viewDocument.asp?ruta=Leyes/30044283>
- Cressie, N. A. (1993). *Statistics for Spatial Data*. John Wiley & Sons. <https://doi.org/10.1002/9781119115151>
- Cárdenas, F. A., & Pérez, A. F. (2010). Niveles de alcohol en sangre y riesgo de accidentalidad vial: revisión sistemática de la literatura. *Revista Colombiana de Anestesiología*, 38(4). http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0034-74502010000500018
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*, 74(366), 427-431. <https://doi.org/10.1080/01621459.1979.10482531>
- Dickey, D. A., & Fuller, W. A. (1981). Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. *Econometrica*, 49(4), 1057-1072. <https://doi.org/10.2307/1912517>
- Effati, M., Thill, J.-C., & Shabani, S. (2015). Geospatial and machine learning techniques for wicked social science problems: analysis of crash severity on a regional road network. *Applied Geography*, 61, 99-111. <https://doi.org/10.1016/j.apgeog.2015.04.008>
- Elvik, R. (2008). The predictive validity of empirical Bayes estimates of road safety. *Accident Analysis & Prevention*, 40(6), 1964-1969. <https://doi.org/10.1016/j.aap.2008.08.001>
- Elvik, R., Høye, A., Vaa, T., & Sørensen, M. (2009a). *The Handbook of Road Safety Measures* (2nd) [Véase especialmente el cap. 1 sobre el enfoque sistémico de la seguridad vial y la interacción entre actores]. Emerald Group Publishing.
- Elvik, R., Høye, A., Vaa, T., & Sørensen, M. (2009b). *The Handbook of Road Safety Measures* (2nd). Emerald Group Publishing.

- Filigrana, M. H. (2014). Condiciones de salud y trabajo de los mototaxistas en Palmira, Colombia. *Revista Colombiana de Salud Ocupacional*. https://revistas.unilibre.edu.co/index.php/rc_salud_ocupa/article/view/4820
- Fox et al, S. M. L. L. S. J. R. D. A. B., Lindsay. (2015). Spatiotemporal approaches to analyzing pedestrian fatalities: the case of Cali, Colombia. *Traffic Injury Prevention*, 16(6). <https://doi.org/10.1080/15389588.2014.976336>
- Hauer, E. (2015). *The Art of Regression Modeling in Road Safety*. Springer. <https://doi.org/10.1007/978-3-319-12828-3>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3rd) [Disponible en línea: <https://otexts.com/fpp3/>]. OTexts. <https://otexts.com/fpp3/>
- INML. (2022). *Forensis 2021: Datos para la Vida* (inf. téc.). Instituto Nacional de Medicina Legal y Ciencias Forenses. Bogotá, Colombia. <https://www.medicinalegal.gov.co/documents/20143/738831/Forensis+2021.pdf>
- Jacobs, G., Thomas, A., & Astrop, A. (2000). *Estimating Global Road Fatalities* [TRL Report 445]. Transport Research Laboratory.
- Kolivand, P., Saberian, P., Arabloo, J., Behzadifar, M., Karimi, F., Rajaie, S., Moradipour, M., Parvari, A., & Azari, S. (2024). Impact of COVID-19 pandemic on road traffic injuries in Iran: An interrupted time-series analysis [Análisis de series de tiempo interrumpidas para evaluar el impacto de la pandemia de COVID-19 en las lesiones por accidentes de tránsito en Irán]. *PLoS ONE*, 19(6), e0305081. <https://doi.org/10.1371/journal.pone.0305081>
- Kruskal, W. H., & Wallis, W. A. (1952). Use of Ranks in One-Criterion Variance Analysis. *Journal of the American Statistical Association*, 47(260), 583-621. <https://doi.org/10.1080/01621459.1952.10483441>
- Ljung, G. M., & Box, G. E. P. (1978). On a Measure of Lack of Fit in Time Series Models. *Biometrika*, 65(2), 297-303. <https://doi.org/10.1093/biomet/65.2.297>
- Lord, D., & Mannering, F. (2010). The statistical analysis of crash-frequency data: A review and assessment of methodological alternatives. *Transportation Research Part A: Policy and Practice*, 44(5), 291-305. <https://doi.org/10.1016/j.tra.2010.02.001>
- Montenegro-Martínez, G., Agudelo-Cifuentes, M.-C., & Muñoz-Rodríguez, D.-I. (2023). Mortality due to traffic accidents in Colombia: profiles of pedestrians and cyclists, 1998–2019. *F1000Research*, 12, 360. <https://doi.org/10.12688/f1000research.131431.2>

- Moons, E., Brijs, T., & Wets, G. (2014). Detecting local traffic safety problems at the level of road sections. *Expert Systems with Applications*, 41(18), 8247-8253. <https://doi.org/10.1016/j.eswa.2014.07.036>
- Moran, P. A. (1950). Notes on continuous stochastic phenomena. *Biometrika*, 37(1/2), 17-23. <https://doi.org/10.2307/2332142>
- Norden, M., Orlansky, J., & Jacobs, H. (1956). Application of statistical quality-control techniques to analysis of highway-accident data. *Highway Research Board Bulletin*, 117, 17-31.
- Ogden, K. W. (1996). Safer Roads: A Guide to Road Safety Engineering. *Avebury Technical*.
- Oluwaseun, A., Adekunle, S., & Oladele, S. (2019). Characteristics of motorcycle road traffic crashes in a Nigerian metropolitan city: a five-year retrospective study. *African Journal of Emergency Medicine*, 9(2), 67-71. <https://doi.org/10.1016/j.afjem.2019.01.010>
- OMS. (2023). *Global Status Report on Road Safety 2023* (inf. téc.) (Disponible en: <https://www.who.int/publications/i/item/9789240086517>). World Health Organization. Geneva, Switzerland. <https://www.who.int/publications/i/item/9789240086517>
- Openshaw, S. (1984). The Modifiable Areal Unit Problem. *Concepts and Techniques in Modern Geography*, 38.
- Organización Mundial de la Salud. (2018). *Global Status Report on Road Safety 2018* (inf. téc.) (Disponible en: <https://www.who.int/publications/i/item/9789241565684>). World Health Organization. Geneva, Switzerland. <https://www.who.int/publications/i/item/9789241565684>
- Peden, M., Scurfield, R., Sleet, D., Mohan, D., Hyder, A. A., Jarawan, E., & Mathers, C. (Eds.). (2004). *World Report on Road Traffic Injury Prevention*. World Health Organization. <https://www.who.int/publications/i/item/world-report-on-road-traffic-injury-prevention>
- Prasannakumar, V., Vijith, H., Charutha, R., & Geetha, N. (2011). Spatio-temporal clustering of road accidents: GIS based analysis and assessment. *Procedia – Social and Behavioral Sciences*, 21, 317-325. <https://doi.org/10.1016/j.sbspro.2011.07.020>
- Quddus, M. A. (2008). Time series count data models: an empirical application to traffic accidents. *Accident Analysis & Prevention*, 40(5), 1732-1741. <https://doi.org/10.1016/j.aap.2008.06.011>
- R Core Team. (2024). *R: A Language and Environment for Statistical Computing* [Versión utilizada para el análisis de datos]. Ver. 4.3.3. Vienna, Austria, R Foundation for Statistical Computing. <https://www.R-project.org/>

- Razzaghi, A., Bahrampour, A., Baneshi, M. R., & Zolala, F. (2013). Assessment of trend and seasonality in road accident data: an Iranian case study. *International Journal of Health Policy and Management*, 1(1), 51-55. <https://doi.org/10.15171/ijhpm.2013.08>
- Slocum, T. A., McMaster, R. B., Kessler, F. C., & Howard, H. H. (2009). *Thematic Cartography and Geovisualization* (3rd). Pearson Prentice Hall.
- STTB. (2020). *Informe de Accidentalidad Vial en Bucaramanga 2019–2020* (inf. téc.). Alcaldía de Bucaramanga. Bucaramanga, Colombia.
- Taylor, L. B., Sean. (2018). Forecasting at Scale. *The American Statistician*, 72(1), 37-45. <https://doi.org/10.1080/00031305.2017.1380080>
- Thakali, L., Kwon, T. J., & Fu, L. (2015). Identification of crash hotspots using kernel density estimation and kriging methods: a comparison. *Journal of Modern Transportation*, 23(2), 93-106. <https://doi.org/10.1007/s40534-015-0068-0>
- Tobler, W. R. (1970). A computer movie simulating urban growth in the Detroit region. *Economic Geography*, 46(Supplement), 234-240. <https://doi.org/10.2307/143141>
- Treat, J. R., Tumbas, N., McDonald, S., Shinar, D., Hume, R., Mayer, R., Stansifer, R., & Castellan, N. (1979). *Tri-Level Study of the Causes of Traffic Accidents: Final Report* (inf. téc. N.º DOT HS-805 085). Institute for Research in Public Safety, Indiana University. Bloomington, Indiana.
- World Bank. (2017). *The High Toll of Traffic Injuries: Unacceptable and Preventable* (inf. téc.). World Bank Group. Washington, D.C. <https://openknowledge.worldbank.org/handle/10986/29129>
- Yannis, G., Laiou, A., Papantoniou, P., & Christoforou, C. (2017). Impact of texting on the safety of young drivers [Incluye análisis comparativo del riesgo diferencial por tipo de actor vial en siete países europeos]. *Advances in Transportation Studies*, 42, 25-36.

Apéndices

Apéndice A: Base de datos

Fuentes de Información

Datos de Accidentes

Cuadro 1: Fuentes de datos de accidentes de tránsito

Fuente	Período	Variables Principales
Secretaría de Tránsito de Bucaramanga	2012-2023	Fecha, hora, ubicación, tipo de accidente, vehículos involucrados, gravedad
Observatorio Vial de Santander	2015-2023	Coordenadas geográficas, características de la vía
Policía Nacional - SIMIT	2012-2023	Lesionados, fallecidos, conductores implicados

Fuentes de datos

- **Datos abiertos de población (Gobierno de Colombia):** Proyecciones desagregadas por barrio, comuna, sexo y grupo etario.
[Portal de Datos Abiertos de Colombia](#)
- **Proyección de población municipal (Alcaldía de Bucaramanga):** Datos desagregados por barrios y comunas.
[Sitio oficial de la Alcaldía de Bucaramanga](#)

Apéndice B: Códigos de programación

Entorno Computacional

Especificaciones Técnicas

Cuadro 2: Especificaciones del entorno de desarrollo

Componente	Especificación
Sistema Operativo	Windows 11 pro
Procesador	Intel(R) Core(TM) i5-10210U
Memoria RAM	20 GB DDR4
R Version	4.3.2 (2023-10-31)
RStudio Version	2023.12.1+402

Código para reproducibilidad

El proyecto completo está disponible en GitHub: [repositorio del estudio](#).