Universidad Nacional de Colombia

Facultad de Ingeniería

Departamento de Ingeniería Eléctrica y Electrónica

Toma de Decisión Basada en Datos GIS de Ciudad para Planificación de Electrolineras de Carga Rápida en Bogotá

Documento Técnico

Luis Felipe Diaz Corzo

Bogotá, Colombia

Índice

1. Objetivos **3**
1.1. Objetivo General . . . 3
1.2. Objetivos Específicos . . . 3

2. Estado del Arte Planificación Urbana con GIS **4**
2.1. Modelos de Análisis Teórico . . . 4
2.1.1. Enfoques Principales del Análisis GIS . . . 4
2.1.2. Metodología de desarrollo del modelo . . . 4
2.1.3. Condiciones de la información para Análisis GIS . . . 5
2.1.4. Funciones específicas que debe realizar el modelo . . . 5
2.1.5. Análisis de Movilidad . . . 5
2.1.6. Desarollo Urbano . . . 5
2.2. Planificación de Servicios Públicos de Ciudad . . . 6
2.2.1. Servicios Energéticos . . . 7
2.3. Planificación de Estaciones de Servicio Vehiculares . . . 8
2.4. Planificación de Estaciones de Carga de Vehículos Eléctricos . . . 8
2.4.1. Criterios para Toma de Decisiones . . . 8
2.4.2. Normativa Aplicable . . . 10
2.4.3. Herramientas y Métodos . . . 10
2.5. Resumen de datos utilizados en la literatura . . . 10

3. Modelos de Toma de Decisiones Usados en la Literatura **11**
3.1. Modelo *Analytical Hierarchical Process (AHP)* . . . 12
3.1.1. La estructura jerárquica . . . 12
3.1.2. Procedimiento . . . 12
3.1.3. Metodología . . . 13
3.1.4. Verificación de Consistencia . . . 13
3.2. Modelo *Technique for Order Preference by Similarity to Ideal Solution* (TOPSIS) . . . 15
3.2.1. Solución Ideal . . . 15
3.2.2. Metodología . . . 15
3.3. Spatial Multi-criteria Decision Making (SMCDM) . . . 17
3.3.1. Elementos que lo conforman . . . 17

4. Herramientas Disponibles para el Tratamiento de Datos en Python **18**
4.1. Introducción a *PySAL* . . . 18
4.1.1. Modelos de Regresión de Vecinos *Neighbors Regressor* . . . 19
4.1.2. DBSCAN . . . 19

5. Metodología Propuesta **20**

6. Manejo de los Datos **20**
6.1. Fuentes de Información . . . 20
6.1.1. Infraestructura de Datos Espaciales para el Distrito Capital (IDECA) . . . 21
6.1.2. OpenStreetMap . . . 21
6.1.3. Electromaps . . . 22
6.1.4. Google Maps . . . 22
6.2. Presentación de los Datos Usados . . . 22
6.3. Preprocesamiento de las Variables . . . 23
6.4. Aplicación Método AHP . . . 25
6.5. Diseño, Entrenamiento y Validación del Modelo de Regresión . . . 26

7. Resultados Obtenidos **27**
7.1. Casos de Uso a Implementar 27
7.1.1. Caso de Uso 1: Expansión del 50 % de la Infraestructura de Carga Rápida Existente . . 27
7.1.2. Caso de Uso 2: Predicción del Despliegue de Estaciones de Carga Rápida para 2026 Basado en Proyecciones de Política Pública Nacional 29
7.1.3. Caso de Uso 3: Predicción del Despliegue de Estaciones de Carga Rápida para 2030 Basado en Proyecciones de Política Pública Nacional 30
7.2. Discusión Final de los Casos de Uso 31

8. Conclusiones **32**

1. Objetivos

1.1. Objetivo General

Desarrollar un modelo de toma de decisiones a futuro para la planificación espacial de estaciones de carga rápida destinadas a vehículos eléctricos particulares en Bogotá, involucrando a partes interesadas y empleando sistemas de información geográfica (GIS) y técnicas de *Machine Learning* orientadas a la predicción y optimización en el dominio espacial.

1.2. Objetivos Específicos

1. Identificar la variables, metodologías y herramientas que se han utilizado en la literatura para la planificación de servicios públicos de ciudad, y en especifico, para estaciones de carga para vehículos eléctricos.

2. Obtener y analizar la información georreferenciada a partir de la alianza con la Infraestructura de Datos Espaciales de Bogotá (IDECA).

3. Desarrollar un modelo de predicción y optimización para determinar las ubicaciones futuras predilectas de estaciones de carga vehiculares para el público particular.

4. Establecer comunicación con partes interesadas para realimentar el resultado del modelo, usando el modelo decisorio *Analytical Hierarchical Process* (AHP).

2. Estado del Arte Planificación Urbana con GIS

2.1. Modelos de Análisis Teórico

Se hizo una revisión del Estado del Arte teniendo en cuenta el artículo de Yeh [1], donde se presenta un resumen completo del *background* teórico que tiene el Análisis de de Datos GIS. Por esta razón, sumado a que es un trabajo ampliamente citado, se consideró relevante dicha investigación para este proyecto. A pesar de que el artículo es del año 1999, la fecha de publicación no se consideró relevante para tener un contexto teórico. Sin embargo, a la hora de entrar a revisar herramientas tecnológicas sí lo será. Por otra parte, el autor toma como ejemplo el caso de uso de Planeamiento Urbano, aunque dicha teoría se puede aplicar en cualquier otro contexto.

2.1.1. Enfoques Principales del Análisis GIS

En primer lugar, el autor indica que hay tres usos principales de los GIS:

- **Administración general:** Manejo de datos en general.
- **Control de desarrollo:** Mapeo y visualización de la información para ejercer un control.
- **Planeamiento:** Análisis espacial/modelado para tomar decisiones.

Ahora bien, cada uno de estos usos debe ser abordado a partir de tres funciones; Descripción de la información a estudiar, Predicción a partir de la información que se tiene para tomar decisiones que se acomoden al futuro, y Prescripción de las decisiones a implementar [1].

Tabla 1: Nivel de aplicación (%) de las tres funcionalidades según el tipo de uso de los GIS [1].

Uso	Descripción	Predicción	Prescripción
Administración general	75 %	15 %	10 %
Control de desarrollo	70 %	20 %	10 %
Planeamiento	33.3 %	33.3 %	33.3 %

Siendo el de *Análisis espacial/modelado* al que va enfocado este trabajo, bien sea el caso de uso de Planificación Urbana o Movilidad. Por lo que teniendo en cuenta la Tabla 1, para este estudio se deben dedicar los mismos esfuerzos a cada una de las tres funciones. Es decir, realizar una correcta interpretación de los datos, junto con un modelo predictivo acorde que permita llegar a la toma de decisiones.

2.1.2. Metodología de desarrollo del modelo

Se propone un proceso de desarrollo cíclico de 8 pasos, es decir, en caso de no obtener los resultados esperados se retorna al paso 1. Es importante aclarar que durante cualquier paso el proceso se puede nutrir de nutre de nueva información GIS o datos no-espaciales [1].

1. Determinación de objetivos.
2. Descripción de inventario de datos.
3. Análisis de la situación existente .
4. Modelado teórico.
5. Desarrollo técnico.
6. Selección de decisiones.
7. Implementación.
8. Evaluación y retroalimentación.

2.1.3. Condiciones de la información para Análisis GIS

Para el *Análisis espacial/modelado*, se deben usar datos que tengan las siguientes características:

- Ser información vectorizada con **alta resolución**. Esta última característica es particularmente relevante para la planificación local en ciudades.
- Proceder de diferentes fuentes y temáticas. Entre más variables se tengan en cuenta se pueden tomar mejores decisiones.
- Ser predecible.

2.1.4. Funciones específicas que debe realizar el modelo

En la Sección 2.1 (Tabla 1) se habló de las tres funciones generales que debe tener el análisis, aquí se muestran las acciones específicas que se deben realizar.

- Realizar la proyección futura.
- Simular escenarios distintos y obtener realimentación.
- Uso de mapas/información de idoneidad territorial, con el fin de tener marcos de referencia.
- Correlacionar información espacial con no-espacial. Hay datos sin información geográfica que pueden enriquecer el análisis, permitiendo obtener mejores conclusiones.
- Usar distintas técnicas, modelos y fuentes de información.

2.1.5. Análisis de Movilidad

Aunque el autor [1] se enfoca en el Planeamiento Urbano, nombra dos formas de abordar el estudio de Transporte a partir de GIS.

1. Análisis de red, que incluye:
    - Tráfico.
    - Ruta más corta.
    - Áreas de servicio.
    - Accesibilidad.
2. Selección de ruta, que considera:
    - Menor costo.
    - Menor distancia.
    - Menor tiempo de viaje.

2.1.6. Desarollo Urbano

En el libro *GIS in Sustainable Urban Planning and Management: A Global Perspective* [2] se muestra un Análisis GIS de Desarrollo Sostenible que se realizó en Ciudad de Guatemala. Allí utilizan tres tipos de variables en el análisis de datos.

- **Variables de uso del suelo:** Para expresar la intensidad de la edificación y la relación entre la superficie del terreno y la superficie de espacio libre.
- **Variables de vivienda:** Para expresar el porcentaje de superficie edificable destinado a cada tipo de vivienda (pisos de 50, 75 o 100 m^2), servicios y la presencia de aparcamiento subterráneo.
- **Variables económicas:** Para expresar las preocupaciones monetarias del desarrollo inmobiliario, incluyendo variables como costos de construcción, precios de venta y rentabilidad esperada. Tambien se consideran tendencias de consumo de los compradores.

2.2. Planificación de Servicios Públicos de Ciudad

El trabajo [3] realiza una revisión exhaustiva de 126 artículos académicos relacionados con la simulación de escenarios para iniciativas de desarrollo urbano, poniendo especial atención en el uso combinado de los Sistemas de Información Geográfica *GIS*. Sobre esos trabajos se analizaron tendencias de investigación y la utilidad práctica de diferentes enfoques para simular cambios en el uso del suelo urbano. Con el objetivo de evaluar tanto la evolución de estas metodologías como su efectividad para modelar dinámicas espaciales urbanas bajo distintos escenarios.

Frente a los escenarios de estudio que se realizaron en esas 126 investigaciones, el artículo condensa la información obtenida en la Figura 1. Allí se observa como el interés de los estudio se centra principalmente en las ciudades más grandes y densamente pobladas. Donde se tienen en cuenta factores sociales relacionados a los habitantes. Urbanos de infraestructura y desarrollo. Ambientales que tienen en cuenta el cambio climático, los recursos disponibles, desarrollo sostenible y rural. Y escenarios politico-económicos relacionados con el bienestar y progreso económico.

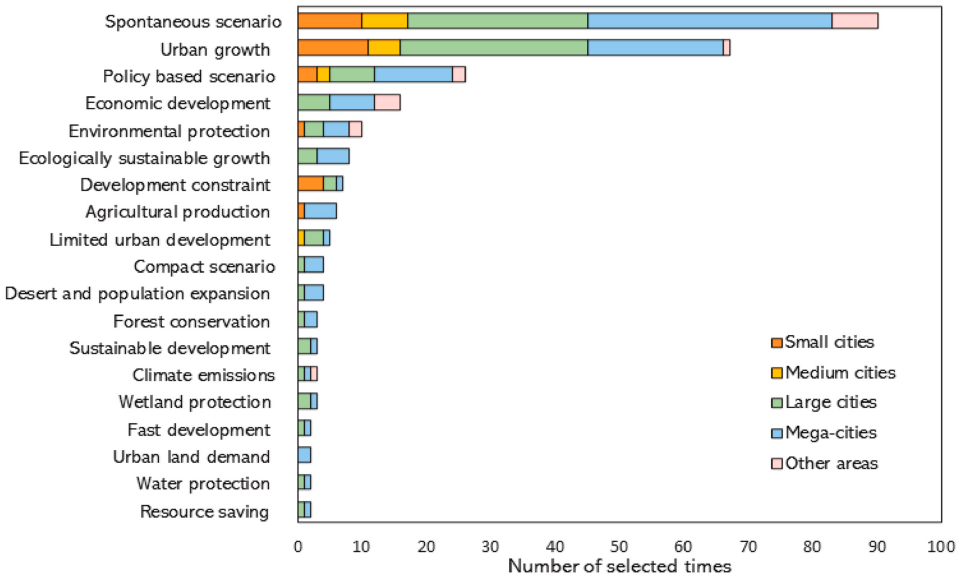


Figura 1: Escenarios de estudio GIS teniendo en cuenta su caso de uso y área de estudio [3].

Frente a las metodologías usadas, en la Figura 2 se muestra un histograma de que reúne los modelos empleados por los 126 estudios.

Se observa el mayor uso de modelos genéricos y ampliamente conocidos como el de autómatas celulares *CA* y su mejora el *CA-Markov* que combina la capacidad espacial de los autómatas celulares con las cadenas de *Markov*. En estos modelos el espacio se divide en celdas, cada una de las cuales cambia de estado en función de reglas locales y del estado de sus celdas vecinas, simulando dinámicas complejas como la expansión urbana.

También se observa la presencia de modelos con atributos de estudio personalizados, como el *SLEUTH* (*Slope, Land cover, Exclusion, Urbanization, Transportation, and Hillshade*).

Aunque en menor medida, hubo uso de modelos basados en inteligencia artificial, como los modelos *CLUE/CLUE-S* (*Conversion of Land Use and its Effects at Small regional extent*), *LCM* (*Land Change*

Modeler), *FLUS* (*Future Land Use Simulation*). Los cuales son modelos espaciales dinámicos (si se tienen datos variantes en el tiempo) que combinan técnicas estadísticas con métodos de inteligencia artificial como ANN's y perceptrones multicapa (*MLP*) [3].

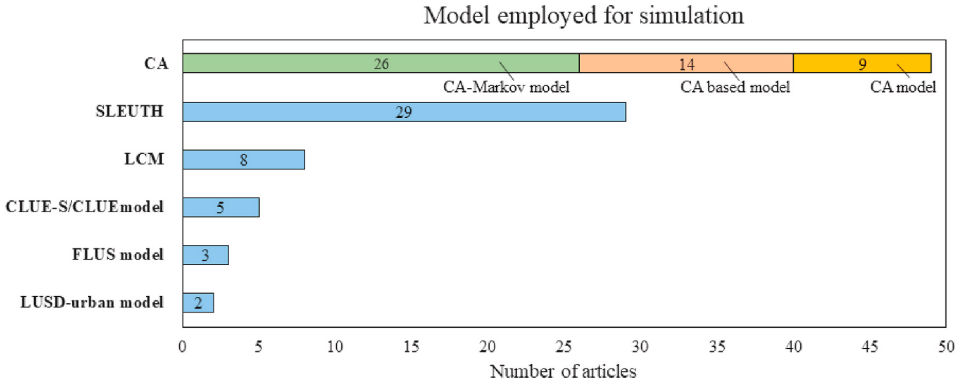


Figura 2: Metodologías de estudio GIS encontradas en la literatura [3].

Teniendo en cuenta la revisión reciente del trabajo [4], sobre los métodos de decisión AHP y TOPSIS ampliamente citados en la literatura, se plantea un resumen como estado del arte de dichas metodologías.

2.2.1. Servicios Energéticos

Este crecimiento urbano intensifica los desafíos energéticos: demanda creciente, agotamiento de recursos no renovables, inestabilidad de precios, infraestructura limitada y vulnerabilidad ante el cambio climático. Se destaca la relevancia de la forma urbana, el transporte, la infraestructura energética, las edificaciones, y las redes inteligentes en el desempeño energético de las ciudades. Mediante acciones como la eficiencia energética en edificios, integración de energías renovables, mejora del microclima urbano, y densificación con uso mixto del suelo, las ciudades pueden romper con modelos de desarrollo intensivos en energía.

La integración de la planificación energética dentro de la planificación urbana es crucial, particularmente bajo el paradigma de las ciudades inteligentes, que apuestan por el uso intensivo de tecnologías como IA, Teledetección, GIS, IoT, y redes eléctricas inteligentes. Estas tecnologías permiten optimizar el consumo energético, integrar energía renovables y reducir emisiones contaminantes.

En el estudio, a través de un análisis bibliográfico y una revisión de alcance de 9320 artículos (1992–2023) se identifican tres fases evolutivas en la investigación: primero, un énfasis inicial en tecnología y transporte (entre 1992 y 2008). Segundo, un avance tecnológico sin enfoque socioeconómico (entre 2008 y 2017). Y tercero, una integración tecnológica con consideraciones socio-ecológicas (entre 2018 y 2023) [5]. Asimismo, destacan cinco dimensiones clave de convergencia entre ciudades inteligentes y planificación energética urbana:

1. Uso de energía en edificios,
2. Integración del diseño urbano,
3. Transporte y movilidad,
4. Modernización de redes eléctricas,
5. Políticas y marcos regulatorios.

El estudio concluye, que para que las ciudades inteligentes sean sostenibles, inclusivas y resilientes, es necesaria una visión integrada que trascienda la dimensión técnica y abarque aspectos sociales, ambientales y normativos.

2.3. Planificación de Estaciones de Servicio Vehiculares

La ubicación estratégica de estaciones de gasolina es un problema complejo que requiere integrar múltiples criterios técnicos, económicos y regulatorios. Teniendo en cuenta el trabajo de *Zhu J, et al.(2024)*, el estudio de esta problemática se centra principalmente en tres enfoques metodológicos: el análisis espacial mediante Sistemas de Información Geográfica (GIS), los modelos predictivos de tráfico y demanda, y los modelos de optimización multiobjetivo. Estos enfoques se integran con las restricciones y directrices derivadas de la planificación espacial territorial, particularmente en contextos regulados como el de China [6], para el caso particular de ese trabajo.

Primero, la información GIS se emplea para evaluar la idoneidad geoespacial de los sitios candidatos, permitiendo analizar variables como densidad poblacional, flujo vehicular, uso del suelo y distribución de estaciones existentes. Esta herramienta es esencial para delimitar zonas restringidas y permisibles según normativas de planificación urbana, como líneas de protección ecológica, áreas patrimoniales, tierras agrícolas permanentes y corredores viales.

Segundo, los modelos de predicción de demanda y tráfico utilizan técnicas como la estimación de densidad por núcleo *KDE* y cálculos de isócronas para cuantificar la cobertura de servicio actual y potencial. Estos modelos se alimentan de datos demográficos como estructuras viales clasificadas por jerarquía y tiempos de desplazamiento vehicular.

Tercero, la optimización multiobjetivo aborda la selección de ubicaciones mediante funciones que maximizan la cobertura de demanda, minimizan la redundancia entre estaciones y maximizan la cobertura espacial. En el estudio de caso aplicado a la ciudad de Lishui, China, se empleó un algoritmo genético para resolver el modelo. Este algoritmo optimiza simultáneamente:

- La cobertura de demanda de combustible, ponderada por densidad poblacional, densidad vial y capacidad actual de servicio.
- La cobertura espacial total de estaciones sobre la malla urbana.
- La superposición de radios de cobertura entre estaciones.

La planificación territorial se incorpora mediante un sistema de criterios dividido en restricciones obligatorias de infraestructura como control de planificación, normas de construcción, seguridad y condiciones naturales. Y requisitos orientadores (población, tráfico, estado oferta-demanda). Los pesos de cada factor se determinaron utilizando el Proceso Analítico Jerárquico *AHP*), y las zonas candidatas se definieron a partir de restricciones cuantitativas (radio mínimo, densidad máxima, área útil).

Este enfoque integrado demostró resultados superiores frente a métodos tradicionales, logrando tasas de cobertura de demanda mayores al 90 %, con redundancia reducida a aproximadamente un 30 %. Además, garantiza la coherencia con planes reguladores, mejora la sostenibilidad ambiental y permite una implementación adaptativa en diferentes contextos urbanos [6].

2.4. Planificación de Estaciones de Carga de Vehículos Eléctricos

2.4.1. Criterios para Toma de Decisiones

Con el objetivo de conocer que datos se podrían utilizar para el objetivo de este trabajo, se realiza una investigación en la literatura sobre los criterios de decisión para la planificación de estaciones de carga públicas para vehículos eléctricos. Teniendo en cuenta el estudio de *Soczówka et al. (2024)* [7], se encontraron los siguientes criterios para diferentes factores de todo tipo:

1. **Determinantes espaciales:** Consideran la proximidad a puntos clave como estaciones de servicio, centros comerciales, parqueaderos, parques, vías principales y estaciones de carga existentes. Además, se incluyen variables como la densidad poblacional y los patrones de uso del suelo para identificar las zonas de mayor potencial.

2. **Factores sociales:** Involucran el análisis de variables demográficas y socioeconómicas como edad, nivel de ingresos, tipo de vivienda y hábitos de consumo, que afectan la adopción de vehículos eléctricos y, por ende, la demanda de estaciones de carga.

3. **Patrones de movilidad:** Se analizan los flujos de tráfico, las rutas habituales de los usuarios, los tiempos y lugares de detención, y la frecuencia de carga. Estos patrones permiten ubicar estaciones en zonas estratégicas para viajes urbanos y de larga distancia.

4. **Condiciones de la red eléctrica:** Es necesario evaluar la capacidad de la red de distribución, las pérdidas energéticas, las posibles sobrecargas y los costos asociados a las adecuaciones necesarias para conectar nuevas estaciones de carga.

5. **Impacto ambiental:** Se prioriza el uso de energías renovables y la integración con sistemas de generación distribuida, como la energía solar, para reducir la huella de carbono y minimizar la dependencia de fuentes contaminantes.

6. **Aspectos económicos:** Incluyen el análisis de costos de instalación, operación y mantenimiento, así como el tiempo de desplazamiento y espera del usuario. Los modelos de optimización buscan equilibrar la inversión con la eficiencia y el retorno económico.

7. **Aspectos regulatorios:** Es fundamental cumplir con normativas locales, nacionales e internacionales sobre infraestructura de carga, asegurando la compatibilidad con políticas públicas y regulaciones energéticas.

8. **Tipología de cargadores:** La planificación debe considerar diferentes tipos de cargadores (domiciliarios, públicos lentos, semi-rápidos y rápidos) para atender diversas necesidades de carga, optimizando la cobertura y el uso eficiente de la infraestructura.

Este trabajo presenta un estado del arte completo frente a los criterios a tener en cuenta. Los cuales se observan presentes en otros trabajos enfocados al desarrollo de estrategias de planificación para casos de uso en específico como *Nalin et al. (2024)* [8]. Donde utiliza la densidad poblacional, las ubicaciones de parqueaderos, las estaciones de carga existentes, las paradas de autobús y las estaciones de tren actualmente en operación, todo ello a partir de información de acceso público. Además, se incorporaron los tramos planificados de líneas de tranvía, lo que permite anticipar futuros polos de movilidad. Complementariamente, se integraron datos extraídos de *OpenStreetMap* correspondientes a la ubicación de hospitales, universidades y los principales centros comerciales, así como información sobre museos, teatros y galerías recopilada desde bases de datos abiertas. Esta combinación de criterios busca asegurar una cobertura eficiente y estratégica de la infraestructura de carga, considerando tanto la demanda actual como las proyecciones de crecimiento y transformación urbana.

Otro ejemplo es la el trabajo de *Kazempour et al. (2025)* [9]. El cual plantea los conceptos de factores de selección y de exclusión.

Frente a los factores de selección, se incluyó la instalación de cargadores en zonas cercanas a residencias, evitando concentrar las estaciones en un mismo sector y promoviendo su distribución estratégica respecto a los puntos de carga ya existentes. La densidad poblacional es un factor clave, ya que en las áreas densamente habitadas los residentes suelen carecer de parqueaderos privados y, por tanto, dependen de la infraestructura pública de carga. También se consideran las características demográficas, privilegiando zonas con mayor proporción de población joven, dado su mayor interés en la adopción de vehículos eléctricos. Desde un enfoque ambiental, se priorizan las áreas con altos niveles de contaminación del aire y ruido, donde el fomento de la movilidad eléctrica puede contribuir a mitigar estos problemas. Por último, se incluyen aspectos topográficos, limitando la instalación de cargadores a zonas planas o con pendientes inferiores al 10 %, para facilitar el acceso y garantizar la eficiencia operativa.

Por otro lado, se definieron criterios de exclusión que buscan evitar ubicaciones inadecuadas o de alto riesgo. Se excluyen las vías con límites de velocidad superiores a $30mph$, dado que estas representan un entorno poco seguro para la carga en vía pública. También se descartan las vías de carácter no residencial, enfocando la instalación en entornos habitacionales para fomentar la carga domiciliaria. Adicionalmente, se evita ubicar puntos de carga en zonas con alta atracción de viajes y largas duraciones de parqueo, como áreas comerciales o de servicios públicos, ya que estos espacios son más adecuados para la carga de destino o de largo plazo. Las

áreas con pendientes superiores al 10 % son eliminadas de la planificación por razones de seguridad y eficiencia energética.

2.4.2. Normativa Aplicable

Con la idea de contextualizar el proyecto y poder orientar el análisis, se cita la norma IEC 61851-1. El cual estandariza los requisitos generales de funcionamiento y operaciones de las estaciones de carga eléctricas. Allí se definen unos niveles de carga (ver Tabla 2). De esta forma, se definió que el proyecto se enfocará en estaciones de carga semi-rápida, rápida y ultra-rápida. Teniendo en cuenta que los datos a usar serán de infraestructura pública y el proyecto se desarrollará en conjunto con un organismo del Distrito Capital de Bogotá.

Tabla 2: Niveles de carga de vehículos eléctricos según IEC 61851-1.

Tipo de carga	**Voltaje (V)**	**Lugar de toma**	**Potencia máx. (kW)**	**Tiempo de carga (h)**
Nivel I (carga lenta)	120.0 US (CA)	Hogar	1.90	4.0–11.0
	230.0 EU (CA)	Hogar	7.40	11.0–36.0
Nivel II (semi-rápida)	240.0 US (CA)	Privado/público	19.20	2.0–6.0
	400.0 EU (CA)	Privado/público	43.0	2.0–3.0
Nivel III (rápida)	208.0–600.0 (CC)	Público	50.0–350.0	0.160–0.50
Nivel IV (ultra-rápida)	$\geq$ 800.0 (CC)	Público	$>$ 400.0	Repostaje gas

2.4.3. Herramientas y Métodos

En general, en este apartado los estudios consultados difieren bastante a pesar de tener *datasets* similares. Cada trabajo propone un modelo de procesamiento de los datos acorde a los objetivos de su análisis GIS. A partir de lo investigado, se evidencia en todos los casos la presencia de datos geoespaciales con múltiples capas de información. También se observa el uso de pesos que permitan amplificar/disminuir la influencia de las variables que más/menos se alineen a los objetivos del análisis.

En el trabajo de *Soczówka et al. (2024)* [7] se utiliza una malla de análisis hexagonal, donde se calcula el *potencial* de hexágono según la presencia de los criterios decisorios en ese espacio al superponer las capas sobre el territorio. Dicho *potencial* es influenciado por el de sus hexágonos vecinos y de esta forma se crea una malla con los potenciales de todo el terreno a estudiar.

En el trabajo de *Nalin et al. (2024)* [8] se realiza un análisis de superposición de capas. Donde se define una malla de evaluación (espacio donde se ubicarán y estudiaran las diferentes capas) acorde al tamaño de la Bologna. Allí es importante resaltar el normalizado de 0-1 que se le aplica a todas las capas, con el objetivo de que se traten de la misma manera las capas al superponerse. Ahora bien, posteriormente se definen unos pesos para cada criterio acorde a su importancia en el resultado esperado. Sin embargo, no brindan información acerca de la obtención de dichos pesos.

Sin embargo, en el trabajo de *Kazempour et al. (2025)* [9] se plantea el uso de modelos teóricos para toma de decisiones. Específicamente, el método *Analytic Hierarchy Process* (AHP). Con el cual obtiene unos pesos acorde a la importancia subjetiva que le quiera dar a cada criterio a la hora de realizar al análisis de capas superpuestas. Un estudio similar al anterior, hecho por *Zafar et al. (2025)* [9] plantea un problema de máxima cobertura (MCLP). El objetivo es seleccionar un número limitado de estaciones de carga de modo que se cubra la mayor cantidad posible de demanda dentro de un radio máximo de servicio (por ejemplo 5 km). Lo anterior a partir de la herramienta $QGIS$ para cargar mapas reales (bloques censales y carreteras), calcular los centroides de las zonas de demanda y realizar un $spatialjoin$ (juntar los datos demográficos y de tráfico a los centroides correspondientes). De esta forma se logran determinar las distancias entre cada punto de demanda y cada estación candidata (usando distancia euclidiana).

2.5. Resumen de datos utilizados en la literatura

En la Tabla 3 se muestra un resumen de los datos utilizados por trabajos similares.

Tabla 3: Datos utilizados en la literatura.

No.	Categoría	Criterio	Descripción	Refs.
1	Demografía	Densidad poblacional	Garantiza la presencia de estaciones de carga donde se concentren las personas.	[3, 6–10]
2		Edad	Donde los individuos más jóvenes son más propables a adquirir vehiculos eléctricos.	[7, 9, 11, 12]
3		Género	Donde las mujeres son más susceptibles a adquirir vehículos eléctricos.	[7, 11, 13, 14]
4		Nivel de educación	Donde un nivel de educación más alto se relaciona a la compra de vehículos eléctricos.	[7, 11, 13]
5		Ingresos	Donde mayores ingresos son proporcionales a la intención de compra de vehículos eléctricos.	[7, 11, 13]
6		Longitud de los trayectos	Donde menores distancias de viaje diarias generan más probabilidad de compra de vehículos eléctricos.	[7, 13, 14]
7		Población que posea vehículos	Es proporcional a la intención de compra de vehículos eléctricos.	[7, 14]
8		Personas solteras	Las cuales tienen una mayor tendencia a la compra de vehículos eléctricos.	[7, 14]
9	Infraestructura existente de ciudad	Estaciones de carga vehiculares	Para maximizar su cobertura se deben ubicar alejadas de las existentes.	[5, 8, 9, 11, 12, 14]
10		Estaciones de gasolina	Servicios públicos de ciudad como indicio de la presencia de vehiculos.	[3, 7]
11		Estaciones de transporte público		[3, 7, 8]
12		Parqueaderos vehiculares		[3, 7–9]
13		Hospitales		[3, 7–9]
14		Universidades		[3, 7–9]
15		Museos, teatros, galerías, etc.		[3, 7–9]
16		Centros comerciales		[3, 7–9]
17		Zonas residenciales	Garantiza la presencia de estaciones de carga en zonas residenciales.	[3, 7, 9]
18	Ambiente	Calidad del aire	Se priorizaría el uso de vehículos eléctricos en áreas con peor calidad de aire.	[3, 5, 7, 9, 11]
19		Contaminación auditiva	El uso de vehículos eléctricos contribuye a disminuir la contaminación auditiva.	[3, 7, 9, 11]
20		Pendiente del terreno	Como requerimiento de construcción se deben ubicar las estaciones de carga en zonas planas (pendiente $<10\,\%$).	[3, 6, 9]
21	Transporte	Velocidad y densidad vehicular en la vía	Baja si se quieren ubicar estaciones de carga residenciales y alta para públicas.	[5–7, 9, 10]
22		Malla vial	Información de la infraestructura vial de la ciudad.	[7, 9, 10]
23	Economía	Costo del terreno	Ubicar los proyectos de estaciones de carga en sitios con menor costo por m^2 permite optimizar la inversión.	[7]
24		Costos de construcción y operación	Permiten optimizar el desempeño en el tiempo de la estación de carga.	[5, 7, 11, 14]
25	Características técnicas	Número de conectores por estación de carga	Indica capacidad de uso en paralelo.	[7, 14]
26		Capacidad de potencia por estación de carga	Indica capacidad máxima de servicio.	[5, 7, 14]
27		Capacidad y uso de la red eléctrica	Para optimizar el proceso de transporte de la energía a las estaciones de carga.	[3, 7]
28		Sitios permitidos de instalación	Información requerida para la ubicación de los proyectos de estaciones de carga.	[3, 6, 7]

3. Modelos de Toma de Decisiones Usados en la Literatura

Teniendo en cuenta la revisión reciente del trabajo [4], sobre los métodos de decisión AHP y TOPSIS ampliamente citados en la literatura, se plantea un resumen como estado del arte de dichas metodologías.

3.1. Modelo *Analytical Hierarchical Process (AHP)*

El Proceso Analítico Jerárquico (AHP) se ha consolidado como una metodología destacada en la toma de decisiones, especialmente en situaciones que involucran múltiples criterios y alternativas. Ofrece un enfoque estructurado y completo para evaluar problemas complejos de decisión, desglosándolos en una pirámide de criterios y subcriterios. Este método integra juicios subjetivos con datos objetivos. Usando la variante que propuso *Saaty* en 1980. El PAJ descompone un problema complejo de decisión multi-criterio en una estructura jerárquica lineal que conecta los objetivos, factores y alternativas del contexto de decisión. Los criterios del problema pueden ser cualitativos o cuantitativos, lo cual es una gran ventaja en casos donde los criterios no siempre tienen una unidad de medida. El enfoque PAJ emplea comparaciones por pares, en las que cada elemento de las capas inferiores se compara con los elementos inmediatamente superiores. El resultado puede utilizarse para comparar el rendimiento de cada opción, guiando al responsable de la toma de decisiones hacia la opción más adecuada y, al mismo tiempo, proporcionando información valiosa sobre las demás. El AHP dota al problema de una estructura jerárquica, lo que permite escalarlo para abordar dificultades complejas en la toma de decisiones grupales, así como problemas individuales básicos. Además, puede ampliarse o modificarse fácilmente. El AHP es una estrategia sencilla y directa que se basa en la capacidad intuitiva del responsable de la toma de decisiones para comparar las partes del problema. El AHP también puede clasificarse como un modelo compensatorio, ya que permite alcanzar acuerdos entre criterios, lo que puede ser beneficioso en situaciones que involucren partes interesadas.

Como recomendación de la investigación de *Saaty*, el número de criterios debería limitarse a siete para evitar inconsistencias y criterios similares que se contradigan.

3.1.1. La estructura jerárquica

El AHP aborda la resolución de problemas al descomponerlos en una jerarquía. De forma que se interconecta el objetivo, los criterios y las alternativas. Esta estructura sirve como diagrama de flujo guía y proporciona un enfoque a los responsables de la toma de decisiones. Los niveles son:

- Nivel 1: El nivel superior define el objetivo o meta principal del problema que el responsable de la toma de decisiones busca resolver.
- Nivel 2: El nivel intermedio define los criterios con los que se evaluará el rendimiento de nuestras soluciones.
- Nivel 3: El nivel inferior define las posibles alternativas como soluciones al problema.

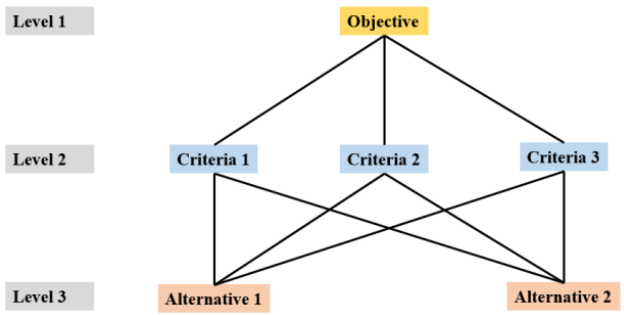


Figura 3: Niveles jerárquicos del método AHP (obtenido de [4]).

3.1.2. Procedimiento

El procedimiento para abordar un problema mediante AHP puede generalizarse en cuatro etapas básicas:

- Identificación de los elementos de decisión: Se estudia el planteamiento del problema para definir el objetivo e identificar los diversos elementos relevantes para dicho objetivo.
- Formación de la jerarquía: Los responsables de la toma de decisiones disponen todos los elementos del problema en la estructura jerárquica lineal de la Figura 3.
- Formación de matrices de comparación por pares: El procedimiento matemático comienza con la determinación de las preferencias entre todos los criterios, que son alcanzadas por los responsables de la toma de decisiones mediante la construcción de un conjunto de matrices de comparación por pares. Para las comparaciones por pares se utiliza una escala denominada escala de Saaty, que proporciona un valor numérico especificado en un intervalo determinado que indica la preferencia o el nivel de importancia entre dos criterios.
- Obtención de ponderaciones: La normalización de las matrices de comparación por pares debe realizarse hasta la suma de uno. La puntuación normalizada obtenida de las comparaciones se utiliza para calcular la ponderación. Existen varios métodos matemáticos para calcular la ponderación. A esto le siguen comprobaciones de consistencia. Las puntuaciones finales de cada alternativa se calculan sumando el producto de su puntuación respecto a cada criterio y su ponderación.

3.1.3. Metodología

La metodología para abordar un problema se proporciona a continuación basada en los trabajos de investigación de *Saaty* en 1980 y 1990.

En primer lugar, la fórmula para determinar el número de juicios J, que deben realizarse en una comparación por pares completa es:

$$J = \frac{n(n-1)}{2} \tag{1}$$

n: número de criterios.

Para obtener los puntajes, se define una matriz de comparación. Los elementos de la matriz representan los valores relativos de los criterios proporcionados por las partes interesadas.

Definamos una matriz de comparación por pares A de orden $n \times n$ como:

$$A = \begin{bmatrix} 1 & a_{12} & \cdots & a_{1n} \\ a_{21} & 1 & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & 1 \end{bmatrix} = \begin{bmatrix} 1 & a_{12} & \cdots & a_{1n} \\ 1/a_{12} & 1 & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 1/a_{1n} & 1/a_{2n} & \cdots & 1 \end{bmatrix} \tag{2}$$

donde a_{ij} representa los puntajes obtenidos por comparación.

Los elementos diagonales en la matriz A se comparan entre sí, de ahí que $a_{ii} = 1$, para $i = j$ y $i, j = 1, 2, \ldots, n$.

Los elementos de la matriz son positivos y recíprocos.

$$a_{ij} = \frac{1}{a_{ji}}, \quad \text{y} \quad a_{ij} = \frac{a_{ik}}{a_{jk}} \tag{3}$$

La obtención de los elementos de puntuación se realiza mediante la *escala de Saaty*. Donde un valor numérico entre 1–9 puede asignarse a cada comparación. La escala de Saaty se describe en detalle en la Tabla 4.

El AHP comúnmente usa dos técnicas para determinar los pesos finales: el método del autovector y el método de la media geométrica.

3.1.4. Verificación de Consistencia

Con un gran número de alternativas, se vuelve cada vez más difícil evitar inconsistencias entre la importancias asignada a los criterios. Sin embargo, cada problema puede ser procesado bajo una verificación de

Tabla 4: Escala de Saaty

Intensidad de Importancia	**Definición**	**Significado**
1	Igual	Igual importancia entre ambos elementos
3	Débil	Un elemento es ligeramente más importante
5	Claro	Un elemento es claramente más importante
7	Fuerte	Un elemento tiene un fuerte grado de importancia
9	Muy fuerte	Un elemento posee la máxima importancia posible en comparación
2,4,6,8	Valores intermedios	Valores intermedios para mayor precisión
1/1, 1/2, 1/3, . . . , 1/9	Recíprocos	Valores recíprocos de los anteriores

consistencia. Dichas inconsistencias pueden ocurrir por múltiples razones; como falta de juicio de los tomadores de decisiones, falta de información disponible o problemas dentro de la construcción del modelo.

Para monitorear la consistencia, se calcula un *índice de consistencia* (CI), para verificar inconsistencias en la matriz de decisión, mediante la fórmula:

$$CI = \frac{\text{(Valor propio principal – tamaño de la matriz)}}{\text{tamaño de la matriz – 1}} \tag{4}$$

o bien,

$$CI = \frac{\lambda_{\max} - n}{n - 1} \tag{5}$$

donde $\lambda_{\max}$ es el valor propio máximo de la matriz y n es el orden de la matriz.

A continuación, el índice de consistencia se compara con el *índice aleatorio* (RI), el cual corresponde a una matriz recíproca positiva generada aleatoriamente. Una propiedad del RI es que puede tener cualquier orden posible, aunque se debe tomar el RI del mismo orden que la matriz para los cálculos posteriores. Los valores de RI para matrices de hasta orden 10 se muestran en la Tabla 5.

Tabla 5: Valores del índice aleatorio (RI)

Orden	**RI**
1	0
2	0
3	0.58
4	0.90
5	1.12
6	1.24
7	1.32
8	1.41
9	1.45
10	1.49

Luego, se calcula la *razón de consistencia* (CR). La relación entre el índice de consistencia y el índice aleatorio da el valor de CR, el cual no se ve afectado por el tamaño de la matriz:

$$CR = \frac{CI}{RI} \tag{6}$$

Generalmente, cuando $CR < 0{,}1$, la matriz de comparación se considera consistente y, por lo tanto, se pueden obtener conclusiones confiables. Cuando $CR > 0{,}1$, la matriz de comparación incorpora muchas inconsistencias y puede llevar a conclusiones erróneas. Idealmente, la matriz se considera totalmente consistente cuando se cumple que $CR = 0$ o que $\lambda_{\max} = n$.

3.2. Modelo *Technique for Order Preference by Similarity to Ideal Solution* (TOPSIS)

La técnica para el orden de preferencia por similitud con la solución ideal (TOPSIS) se ha convertido en una metodología dominante en el campo de MADM (*Multi-Attribute Decision Making*). Originalmente propuesto por Hwang y Yoon en 1981, TOPSIS ha cultivado eminencia por su capacidad para evaluar y clasificar sistemáticamente alternativas. Al comparar con otras alternativas en el espacio de decisión que pueden tener múltiples dimensiones, la solución más adecuada debe estar posicionada geométricamente de forma que tenga la menor distancia posible respecto a un concepto teórico de la mejor solución, mientras que la mayor distancia es la peor solución. La distancia euclidiana se utiliza comúnmente para evaluar la proximidad relativa de las alternativas a la solución ideal, ya que es suficiente y requiere recursos computacionales mínimos.

El método TOPSIS selecciona la alternativa más adecuada en un problema multicriterio identificando aquella que se encuentra más cerca de la solución ideal (mejores valores posibles de cada criterio) y más lejos de la solución no ideal (peores valores posibles). Su principal ventaja radica en que es simple, intuitivo, fácilmente programable y mantiene un número fijo de pasos independientemente del número de criterios, lo que lo hace práctico y eficiente. Además, en estudios comparativos ha mostrado menos inversión de rangos que otros métodos como AHP y ELECTRE. Sin embargo, presenta limitaciones: asume que la utilidad de los criterios varía de manera monotónica, ignora las correlaciones entre criterios al calcular las distancias euclidianas, y no considera la consistencia de los juicios del tomador de decisiones, aspectos que pueden afectar la validez de los resultados en problemas complejos.

3.2.1. Solución Ideal

Una solución teórica al propósito del problema, que actúa como la mejor o más perfecta solución al objetivo, se conoce como *solución ideal* (también llamada solución óptima). Los criterios pueden dividirse según si el desempeño de la alternativa en dicho criterio es efectivamente beneficioso o desfavorable.

La categoría de criterios de beneficio, también conocida como criterios de ganancia, incluye aquellos en los que mejorar el desempeño de una alternativa también aumenta las ventajas. La categoría de criterios de costo, en cambio, incluye factores en los que mejorar el desempeño de una alternativa reduce las ventajas.

Como resultado, el valor de todos los criterios de beneficio sería el más alto para un desempeño óptimo, mientras que el valor de todos los criterios de costo sería el más bajo. Esto genera una situación utópica en la que se alcanza perfectamente el objetivo de la decisión.

La metodología TOPSIS se fundamenta en la escuela de métodos de compromiso. Debido a que la solución ideal es teórica y poco probable en el mundo real, los enfoques de compromiso buscan seleccionar la alternativa más efectiva aceptando una solución intermedia. TOPSIS selecciona la alternativa geométricamente más cercana a la solución óptima basada en la teoría.

3.2.2. Metodología

La metodología para aplicar el modelo TOPSIS se describe a continuación. Se ha dividido en una serie de pasos.

1. El procedimiento comienza con la construcción de la matriz de decisión, con un número total de alternativas denotado por m y un número total de criterios denotado por n. El orden de la matriz de decisión será $m \times n$.

$$X = \begin{array}{c|cccc} & C_1 & C_2 & \dots & C_n \\ \hline A_1 & x_{11} & x_{12} & \dots & x_{1n} \\ A_2 & x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ A_m & x_{m1} & x_{m2} & \dots & x_{mn} \end{array}$$

donde las alternativas están denotadas por $A_1, A_2, \dots, A_m$ y los criterios por $C_1, C_2, \dots, C_n$. x_{ij} es el elemento de la matriz que representa la evaluación que el tomador de decisiones asigna a la alternativa A_i, con $i = 1, 2, \dots, m$ respecto al criterio C_j para $j = 1, 2, \dots, n$, siendo $x_{ij} \in \mathbb{R}$.

Los pesos de los criterios se determinan por el tomador de decisiones en un vector. Sea el vector de pesos:

$$w = (w_1, w_2, \dots, w_n), \quad w_j \in \mathbb{R},$$

y la suma total de los pesos es igual a uno:

$$\sum_{j=1}^{n} w_j = 1.$$

2. Los criterios pueden tener diferentes unidades de medida. Para poder evaluarlos de manera homogénea es necesario normalizarlos. La fórmula para normalizar la matriz de decisión se expresa como:

$$r_{ij} = \frac{x_{ij}}{\sum_{i=1}^{m} x_{ij}^2}, \quad i = 1, \dots, m;\ j = 1, \dots, n$$

donde R es la matriz normalizada con los elementos r_{ij}.

3. La matriz de decisión normalizada ponderada se obtiene multiplicando cada valor normalizado por el peso correspondiente del criterio, es decir:

$$v_{ij} = w_j \cdot r_{ij}, \quad i = 1, \dots, m;\ j = 1, \dots, n$$

Sea V la matriz normalizada ponderada:

$$V = (v_{ij}) = \begin{bmatrix} w_1 n_{11} & w_2 n_{12} & \dots & w_n n_{1n} \\ w_1 n_{21} & w_2 n_{22} & \dots & w_n n_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_1 n_{m1} & w_2 n_{m2} & \dots & w_n n_{mn} \end{bmatrix}$$

4. La mejor solución se denomina *solución ideal positiva* (PIS) y la peor solución se denomina *solución ideal negativa* (NIS). Sea A^+ la PIS y A^- la NIS, entonces:

$$A^+ = \{v_1^+, v_2^+, \dots, v_n^+\} = \left\{ \left(\max_i v_{ij} \mid j \in I \right), \left(\min_i v_{ij} \mid j \in J \right) \right\}$$

$$A^- = \{v_1^-, v_2^-, \dots, v_n^-\} = \left\{ \left(\min_i v_{ij} \mid j \in I \right), \left(\max_i v_{ij} \mid j \in J \right) \right\}$$

donde I está asociado a criterios de beneficio y J a criterios de costo, con $i = 1, \dots, m$ y $j = 1, \dots, n$.

5. La distancia geométrica entre cada alternativa y la PIS y NIS se calcula como:

$$d_i^+ = \left(\sum_{j=1}^{n} (v_{ij} - v_j^+)^p \right)^{1/p}, \quad i = 1, \ldots, m$$

$$d_i^- = \left(\sum_{j=1}^{n} (v_{ij} - v_j^-)^p \right)^{1/p}, \quad i = 1, \ldots, m$$

   En particular:

   - Para $p = 1$ se usa la distancia Manhattan.
   - Para $p = 2$ la distancia Euclidiana.
   - Para $p = n$ la distancia de Tchebycheff.

6. La cercanía relativa de cada alternativa a la solución ideal positiva se determina mediante el coeficiente de cercanía:

$$R_i = \frac{d_i^-}{d_i^+ + d_i^-}, \quad i = 1, \ldots, m$$

   Cuanto mayor sea R_i, más cercana está la alternativa A_i a la solución ideal.

7. El paso final consiste en asignar un ranking global a las alternativas. La clasificación se realiza con base en el valor del coeficiente de cercanía R_i, siguiendo un orden decreciente. Cuanto mayor sea el valor de R_i de una alternativa, mejor será su posición en el ranking.

   Así, la alternativa cuyo R_i esté más próximo a 1 se considera la más adecuada para el problema de decisión.

3.3. Spatial Multi-criteria Decision Making (SMCDM)

Antes de entender el SMCDM, es importante saber qué es el análisis multi-criterio generalmente se define como una herramienta de ayuda a la decisión y una herramienta matemática que permite comparar diferentes alternativas o escenarios según muchos criterios. Con el fin de guiar al tomador de decisiones hacia una elección rigurosa.

Ahora bien, al relacionarlo al los datos geográficos se tienen alternativas espaciales que constan de al menos dos factores: acción (qué hacer) y ubicación (dónde hacerlo). La componente espacial puede ser explícita o implícita (cuando hay una implicación espacial asociada a la implementación de una alternativa). El conjunto de alternativas puede ser discreto (un número limitado y predefinido, modelado por primitivas espaciales como punto, línea, polígono, o representados como rasters) o continuo (un número alto o infinito, definido por restricciones) [15].

3.3.1. Elementos que lo conforman

En un modelo SMCDM se tienen los siguientes elementos:

1. **Criterios de Evaluación Espaciales:** Están asociados con entidades geográficas y relaciones entre ellas, y pueden representarse en forma de mapas. Se distingue entre una capa de mapa simple (datos espaciales reales) y un mapa de criterio, que modela las preferencias subjetivas del decisor sobre un concepto particular. Diferentes personas pueden asignar valores distintos a la misma unidad cartográfica en un mapa de criterio [15]. En nuestro caso de estudio son las variables de los

datos IDECA a los que tengamos acceso, y consideremos relevantes para el trabajo. Para lo cual nos podríamos apoyar en Marcos de Referencia para territorios idóneos, como la Ley Colombiana de Ordenamiento Territorial [16].

2. **Restricciones:** Representan restricciones naturales o artificiales sobre las alternativas potenciales. A menudo se usan en pasos de pre-análisis para dividir las alternativas en .ªceptables.º ïnaceptables". Una alternativa es aceptable si su rendimiento en uno o varios criterios supera un mínimo o no excede un máximo. Métodos como el conjuntivo o el disyuntivo pueden modelar restricciones, donde, por ejemplo, con el conjuntivo, se exige que la alternativa cumpla o supere un nivel mínimo en todos los criterios relevantes para ser aceptable [15]. Para este proyecto las restricciones pueden surgir de límites numéricos concretos que recomienden Organismos Internaciones (ver Sección **??**).

3. **Cuantificación y Estandarización:** La evaluación de alternativas puede ser cuantitativa o cualitativa. Muchos métodos requieren evaluaciones cuantitativas o que los criterios estén expresados en una escala similar. La cuantificación implica asignar valores numéricos a datos cualitativos (por ejemplo, usando una escala Likert). La estandarización permite reescalar las evaluaciones, a menudo entre 0 y 1, para hacer comparaciones entre y dentro de los criterios [15].

4. **Pesos de los Criterios:** La importancia relativa de los criterios se expresa generalmente mediante números llamados pesos. Estos pesos influyen significativamente en la elección final. Existen diversas técnicas para asignar pesos, desde arreglos simples hasta métodos más complejos como el Proceso Analítico Jerárquico (AHP) [15]. En nuestro caso, se pueden utilizar estas alternativas matemáticas que brinda el autor para la selección de los pesos. Aunque pueden orientarse acorde a los objetivos del proyecto o si en algún momento entra alguna parte interesada (relevancia de unas variables sobre otras).

5. **Estructura de Preferencia y Reglas de Decisión:** Ya cuando se tengan los pesos de los criterios definidos, aparecerán muchas alternativas (sobretodo si se desean simular varios escenarios). Para compararlas globalmente, se agregan las evaluaciones parciales utilizando una regla de decisión o procedimiento de agregación. Las reacciones posibles al comparar dos alternativas pueden ser preferencia, indiferencia o imposibilidad de comparar (incomparabilidad). Las reglas de decisión para alternativas discretas suelen basarse en funciones de utilidad (buscando maximizar una función agregada, a menudo aditiva) o en relaciones de superación (construyendo una relación binaria 'a es al menos tan buena como b'. Los métodos continuos, en cambio, definen el conjunto de alternativas viables implícitamente a través de funciones objetivo y restricciones, a menudo utilizando programación matemática multiobjetivo [15]. Al realizar el desarrollo en Python, para nuestro trabajo sería conveniente utilizar el método continuo con programación multiobjetivo.

4. Herramientas Disponibles para el Tratamiento de Datos en Python

4.1. Introducción a *PySAL*

En el contexto actual de la ciencia de datos geográfica, los avances en el manejo de grandes volúmenes de información, la proliferación de nuevas fuentes de datos (como redes sociales y sensores), y el desarrollo de técnicas computacionales más potentes han transformado la forma en que se estudian los fenómenos espaciales. La geografía, entendida como el estudio de los patrones y estructuras espaciales de los procesos sociales, físicos y de comportamiento individual, se beneficia de manera significativa de estas innovaciones.

En este marco surge **PySAL** (Python Spatial Analysis Library) [17], una librería de código abierto escrita en *Python*, diseñada específicamente para el análisis espacial. PySAL ofrece un conjunto integral de herramientas que permiten abordar problemas clásicos y contemporáneos de la geografía cuantitativa, proporcionando desde operaciones básicas de análisis de vecindad y autocorrelación espacial, hasta métodos avanzados de econometría espacial, simulación y análisis de redes.

El objetivo de PySAL es proporcionar una infraestructura robusta, reproducible y extensible que facilite a investigadores, analistas y profesionales explorar datos espaciales, detectar patrones, modelar relaciones y extraer conclusiones relevantes sobre fenómenos geográficos. Al integrarse de manera natural con el ecosistema

científico de Python (`numpy`, *pandas*, *geopandas*, *matplotlib*, entre otros), PySAL se convierte en un componente esencial de la ciencia de datos aplicada a problemas geográficos.

Dentro de esta librería se utilizarán dependencias relacionadas al análisis de datos geoespaciales a partir de puntos. Dado que la mayoría de los *datasets* utilizados están georreferenciados con este formato, y el tipo de solución que se busca es encontrar localizaciones óptimas con la mayor precisión posible. Dichas dependencias se relacionan a:

4.1.1. Modelos de Regresión de Vecinos *Neighbors Regressor*

Los *NeighborsRegressor* de *scikit-learn* son modelos de regresión no paramétrico basado en los k vecinos más cercanos a partir de un radio r, cuyo principio consiste en estimar el valor de una nueva observación a partir de los valores objetivo de sus vecinos en el conjunto de entrenamiento. Dado un conjunto $\{(x_i, y_i)\}_{i=1}^{N}$, para un punto nuevo x se identifican los k vecinos más cercanos $x_{(1)}, \ldots, x_{(k)}$ con respuestas $y_{(1)}, \ldots, y_{(k)}$. La predicción puede hacerse con pesos uniformes,

$$\hat{y}(x) = \frac{1}{k} \sum_{j=1}^{k} y_{(j)},$$

o con pesos inversamente proporcionales a la distancia,

$$\hat{y}(x) = \frac{\sum_{j=1}^{k} w_j \, y_{(j)}}{\sum_{j=1}^{k} w_j}, \quad \text{donde } w_j = \frac{1}{d(x, x_{(j)}) + \varepsilon}.$$

Las distancias más comunes son la Euclidiana ($p = 2$),

$$d(x, x_i) = \sqrt{\sum_{j=1}^{n} (x_j - x_{i,j})^2},$$

y la Manhattan ($p = 1$),

$$d(x, x_i) = \sum_{j=1}^{n} |x_j - x_{i,j}|.$$

También es posible calcular la distancia *Haversine* si se quiere tener en cuenta la curvatura de la tierra a causa de su forma esférica, lo cual puede ser crítico al analizar áreas grandes donde dicho efecto sea considerable.

El enfoque de los *Neighbors Regressor* es intuitivo, fácilmente programable e idóneo para relaciones no lineales, aunque presenta limitaciones en conjuntos de gran tamaño o alta dimensionalidad debido al *curse of dimensionality*, y requiere normalización de los datos para un desempeño adecuado.

Existen dos variantes que se utilizarán en este proyecto, el *K-Neighbors Regressor* y el *Radius Neighbors Regressor*. Los cuales tienen el mismo fundamento explicado anteriormente, pero el primero permite fijar el número mínimo de vecinos k para agrupar vecinos y encontrar puntos *core*. Mientras que el segundo permite fijar el radio mínimo r para agrupar los vecinos.

4.1.2. DBSCAN

El *Density-Based Spatial Clustering of Applications with Noise* es un algoritmo de aprendizaje no supervisado ampliamente utilizado para la detección de clusters basados en densidad. Su objetivo es encontrar regiones de alta densidad separadas por regiones de baja densidad, lo que permite descubrir clusters de forma arbitraria y detectar puntos atípicos (*outliers*).

DBSCAN se basa en dos parámetros principales:

- ε (*eps*): radio de vecindad que define el entorno de un punto.
- $MinPts$: número mínimo de puntos requerido en la vecindad ε para considerar un punto como *núcleo*.

En una aplicación, se tiene un conjunto de datos $D = \{x_1, x_2, \ldots, x_n\}$ en $\mathbb{R}^d$, donde se definen:

1. **Vecindad ε de un punto**:
$$N_\varepsilon(x_i) = \{x_j \in D \mid d(x_i, x_j) \leq \varepsilon\}$$
donde $d(\cdot, \cdot)$ es una métrica de distancia, típicamente Euclidiana.
2. **Punto núcleo (core point)**:
$$|N_\varepsilon(x_i)| \geq MinPts$$
Un punto núcleo tiene suficientes vecinos en su entorno ε.
3. **Punto alcanzable por densidad (density-reachable)**: Un punto x_j es alcanzable por densidad desde x_i si existe una cadena de puntos $x_i \to x_{p_1} \to \cdots \to x_j$ tal que cada punto es un núcleo y los pares consecutivos cumplen
$$x_{p_{k+1}} \in N_\varepsilon(x_{p_k}).$$
4. **Punto frontera (border point)**: No cumple la condición de núcleo, pero está dentro de la vecindad ε de un núcleo.
5. **Ruido (noise)**: Puntos que no son núcleos ni fronteras.

Luego, se aplica el algoritmo de forma que se sigue el siguiente proceso; primero para cada punto no visitado, se calcula su vecindad ε. Si el punto es un núcleo, se crea un nuevo cluster y se añaden recursivamente todos los puntos alcanzables por densidad. Por último, si el punto no es un núcleo y no está en la vecindad de ningún núcleo, se marca como ruido.

5. Metodología Propuesta

La metodología propuesta en este trabajo comprende seis etapas principales: formulación de objetivos, adquisición de datos, preprocesamiento, aplicación del AHP, desarrollo del modelo de aprendizaje automático y validación de resultados (véase Figura 4).

En primer lugar, los objetivos del proyecto se definieron de acuerdo con el déficit de EVFCS en Bogotá. En segundo lugar, la adquisición de datos se llevó a cabo en colaboración con IDECA. Con base en la Tabla 3 y en los conjuntos de datos identificados como relevantes según la revisión bibliográfica sobre planificación de EVFCS, IDECA proporcionó para este trabajo las variables listadas en la Tabla 7. Estas variables seleccionadas se enfocan en infraestructura pública con alta afluencia y disponibilidad, excluyendo principalmente zonas residenciales y dinámicas de carga lenta. En tercer lugar, el preprocesamiento de datos incluyó cuatro pasos principales: filtrado de datos útiles, codificación de atributos cualitativos, normalización y balanceo de los conjuntos de datos según su tamaño respectivo. Todos estos pasos se realizaron utilizando Python como herramienta principal, específicamente la Python Spatial Analysis Library (PySAL), que incluye varias bibliotecas de ciencia de datos como GeoPandas, NumPy, scikit-learn, Matplotlib y SciPy. Su guía oficial [17] se empleó como soporte técnico de programación. Por un lado, se aplicó teoría sobre la gestión de conjuntos de datos desbalanceados. Se utilizó un método de balanceo sensible al peso. De esta manera, es posible balancear los conjuntos de datos de acuerdo con su tamaño respectivo.

6. Manejo de los Datos

6.1. Fuentes de Información

A continuación se listan se listan y describen las fuentes de información utilizadas, y los *datasets* que se obtuvieron de cada una.

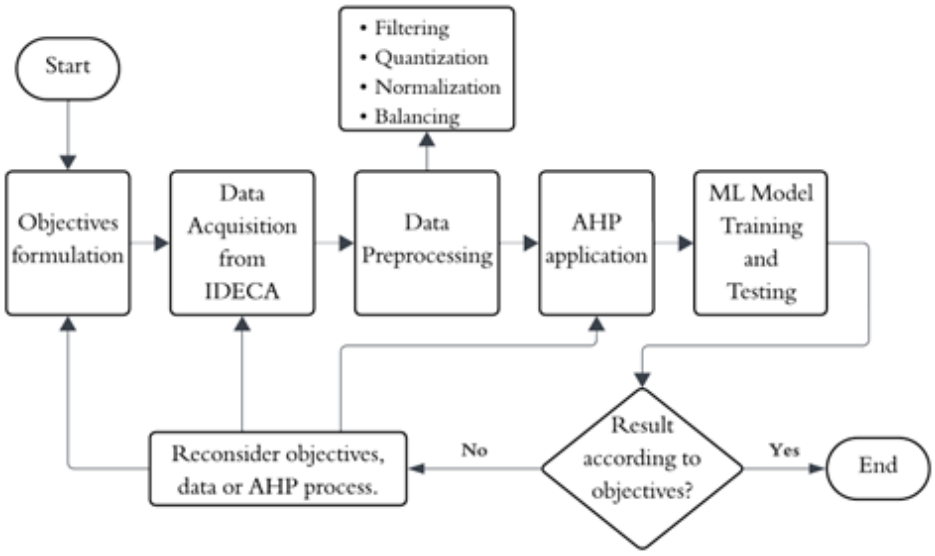


Figura 4: Metodología a aplicar.

6.1.1. Infraestructura de Datos Espaciales para el Distrito Capital (IDECA)

La Infraestructura de Datos Espaciales de Bogotá (IDECA), se define como una iniciativa del gobierno distrital, que busca desarrollar el descubrimiento, acceso, interoperabilidad y reutilización de la información geoespacial, mediante el trabajo colaborativo y articulado entre productores y consumidores de información. Esta entidad contiene y regula el conjunto de datos, estándares, políticas, tecnologías y acuerdos institucionales, que de forma integrada y sostenida, facilitan la producción, disponibilidad y acceso a la información geográfica del Distrito Capital, con el fin de apoyar su desarrollo social, económico y ambiental.

Esta iniciativa fue construida a partir de 5 pilares. (1) Crear una comunidad entre productores y usuarios de datos y servicios espaciales. (2) Establecer políticas y estándares como reglas de juego que regulan el descubrimiento, acceso, interoperabilidad y disposición de la información geográfica. (3) Control de datos que posean atributos de localización como representaciones de elementos del territorio distrital. (4) Uso de herramientas informáticas disponibles para apoyar la producción, administración y canales que posibilitan el flujo y el intercambio de los datos. (5) Buscar el fortalecimiento institucional a partir del establecimiento de alianzas interinstitucionales, ambientes colaborativos, desarrollos en investigación, transferencia de conocimientos y tecnologías, divulgación de procesos y definición de servicios.

Este último factor fue el que posibilitó el trabajo en conjunto de este proyecto con IDECA y obtener los siguientes datos:

- Encuesta de movilidad de Bogotá 2023.
- Servicios públicos de ciudad (centros comerciales, museos, industria, comercio, etc.).
- Capacidad energética disponible por zonas.
- Valor comercial del terreno por m2.
- Infraestructura disponible de estaciones de servicio vehicular (incluyendo parqueaderos, talleres, gasolineras y servitecas).
- Calidad del aire en la ciudad.

6.1.2. OpenStreetMap

OpenStreetMap (*OSM*) es un proyecto colaborativo que construye un mapa mundial libre y editable, elaborado con aportes de voluntarios que recolectan datos mediante GPS, imágenes satelitales, cartografía

libre o trabajo de campo. Permite importar y trabajar a través de API's con distintas capas referentes a la infraestructura. De forma que se pueden analizar redes de transporte, construcciones, comunidades y modelados ambientales a partir de GIS.

En este proyecto se obtuvo de OSM la red vial vehicular de Bogotá, para estudiar los nodos de transporte más frecuentes a partir de una matriz de origen-destino de usuarios. Si bien IDECA provee la malla vial de la ciudad georreferenciada (probablemente con una mayor definición y exactitud frente a la realidad), se optó por usar la versión de OSM. Esto se debió a que OSM se basa en una distribución de nodos para establecer la distribución longitudinal de las vías, donde cada nodo cuenta con un identificador y su respectiva ubicación geográfica. Y a partir de este formato es que se pueden trazar caminos a partir de la matriz origen-destino. Mientras que el mapa de IDECA únicamente se basa en la geometría lineal de las vías por tramos, con la que no se puede trabajar directamente en el análisis de rutas.

6.1.3. Electromaps

Servicio web que brinda una capa de visualización de las estaciones de carga en el mundo. A través de alianzas con miles de operadores de estaciones de carga, permite a los usuarios buscar por ubicación (dirección urbana), disponibilidad, velocidad de carga, cantidad y tipo de conectores y calificaciones de otros usuarios entre más de 430.000 estaciones de carga.

En el contexto de este trabajo, la información obtenida de Electromaps por estación de carga se resume en:

- Capacidad de potencia total (kW).
- Número de conectores.
- Tipo/velocidad de carga (lenta, rápida, semi-rápida y ultra-rápida).
- Dirección urbana.

A pesar de no brindar la información en un formato georreferenciado, para este trabajo se obtuvieron manualmente los parámetros eléctricos de las estaciones presentes en Bogotá junto con su respectiva dirección urbana normalizada. Luego cada dirección se contrastó con Google Maps para obtener su respectiva longitud y latitud, formato de ubicación que permite el trabajo en Python.

6.1.4. Google Maps

Servicio de cartografía digital de acceso libre ampliamente conocido. Desarrollado por Google, permite visualizar mapas interactivos del mundo con diversas funcionalidades de navegación, geolocalización y análisis espacial. Desde su lanzamiento en 2005, se ha convertido en una de las herramientas más utilizadas a nivel global para la planificación de rutas, exploración geográfica y localización de sitios de interés.

Provee una interfaz web que ofrece vistas en diferentes formatos mapa base, satélite, relieve y vista de calle. Permitiendo a los usuarios buscar direcciones, estimar tiempos de viaje en distintos modos de transporte y conocer información actualizada sobre el tráfico, negocios locales y puntos de referencia.

En este proyecto se utilizó para obtener la longitud y latitud de las estaciones de carga a partir de la dirección urbana obtenida de Electromaps y para referenciar la ubicación de coordenadas de interés.

6.2. Presentación de los Datos Usados

En la Tabla 6 se presentan los datos que se pudieron obtener para la ciudad de Bogotá a partir de la revisión de la Tabla 3, y que ingresan al modelo de regresión. En la columna de *tamaño* está la cantidad de muestras de cada atributo. Allí es posible observar el evidente desbalance que se planea solucionar. Por otra parte se lista la referencia geográfica con la que cada uno está definido. Dado que el modelo de regresión solo acepta entradas referenciadas a coordenadas puntuales, para la variables definidas en áreas se calcula el centroide y este es el que se ingresa al modelo.

Tabla 6: Presentación de las variables utilizadas.

No.	Atributo	Tamaño	Georreferencia
1	Potencia electrolineras existentes	30	Coordenadas lat/lon.
2	Cantidad de conectores electrolineras existentes	30	Coordenadas lat/lon.
3	Tipo de carga electrolineras existentes	30	Coordenadas lat/lon.
4	Nodos vehiculares más transitados	22293	Coordenadas lat/lon.
5	Capacidad libre de potencia de las subestaciones de la ciudad	31	Coordenadas lat/lon.
6	Uso del suelo por lote	1054695	Geometría lotes de la ciudad.
7	Valor comercial del terreno por m^2 en las manzanas de la ciudad	44043	Geometría manzanas de la ciudad.
8	Concentración de PM-2.5	479	Coordenadas lat/lon.
9	Áreas no permitidas para construcción	44	Geometría de las áreas.

6.3. Preprocesamiento de las Variables

Con el objetivo de adecuar los datos para su ingreso al modelo de regresión, se hizo un preprocesamiento. Allí se clasificaron los valores posibles de cada atributo según la relevancia o no que tengan frente a la planificación de nuevas electrolineras (variables de inclusión o exclusión). Luego las clases se codificaron y normalizaron numéricamente a un valor entre 0 y 1. Finalmente, para combatir el desbalance entre los tamaños de las clases, se utilizó un algoritmo de asignación de pesos basado en el trabajo ampliamente citado de [18]. Donde a las clases con más datos se les asigna un peso menor, mientras que a las que tiene menos datos se les da un peso mayor. Matemáticamente está dada por la Ecuación 7.

$$w_j = \frac{n}{k \cdot n_j} \tag{7}$$

donde:

- w_j: peso asignado a la clase j.
- n: número total de muestras en el conjunto de datos.
- k: número total de clases.
- n_j: número de muestras pertenecientes a la clase j.

En la Tabla 7 se presenta un resumen del preprocesamiento explicado anteriormente para cada dataset. La información de *Nodos vehiculares más transitados* no se obtuvo de las Fuentes de Información nombradas en la sección anterior, sino que se procesó a partir de la matriz de viajes que provee la Encuesta de Movilidad 2023 de Bogotá. La cual indica origen, destino, frecuencia y características de los desplazamientos que realizan los habitantes encuestados, incluyendo su información demográfica. La matriz se encuentra referenciada a las *Zonas de Análisis de Transporte (ZAT)*, por lo que se trabaja con el centroide de cada una de ellas (dada la restricción del formato de entrada al modelo de regresión).

Frente a la información demográfica se utiliza la edad, sexo, nivel de educación máximo alcanzado y estrato de los encuestados. En la Tabla 8 se muestra la codificación empelada para las clases identificadas de cada atributo, teniendo en cuenta la susceptibilidad a la adquisición de vehículos eléctricos revisada en la Tabla 3 del estado del arte. Ya teniendo cuantizados estos valores cualitativos, se procede a calcular un *puntaje* a partir de la suma del valor numérico que tenga cada atributo para cada persona encuestada.

Lo siguiente fue el análisis de los nodos de transporte más frecuentes a partir de trazar el camino más rápido (en tiempo) entre los puntos de origen y destino del viaje de cada encuestado. Esto se realizó utilizando la librería de Python *OSMX* para obtener la red de nodos viales de Bogotá y *NetworkX* para el análisis de la red, que se basó en encontrar el camino más rápido teniendo en cuenta datos de velocidad vial promedio entre tramos (imformación propia de las librerías gracias a la API de *OpenStreetMap*. Para cada par origen-destino resulta un arreglo que contiene los nodos que conforman dicha ruta.

Por último, se relaciona el puntaje de las variables demográficas con el estudio de los nodos más frecuentes. De forma que se reúnen los nodos repetidos de todos los viajes y se suma su puntaje. Permitiendo estudiar cada nodo teniendo en cuenta su repetición en las rutas trazadas y la relevancia que tenga frente a las características demográficas de los habitantes que lo transiten.

Tabla 7: Preprocesamiento de las variables utilizadas.

No.	Atributo	Tipo	Valores posibles	Codificación	Peso	Observaciones
1	Potencia electrolineras existentes	Exclusión	3 - 600 kW	0 - 1	4154.35	Normalizado con escala lineal.
2	Cantidad de conectores electrolineras existentes	Exclusión	1 - 9	0 - 1		Normalizado con escala lineal.
3	Tipo de carga electrolineras existentes	Exclusión	Lenta	1		Clasificación dada según los objetivos del proyecto
4		Exclusión	Semirápida	0		
5		Exclusión	Rápida	0		
6		Exclusión	Ultrarápida	0		
7	Nodos vehiculares más transitados*	Inclusión	0 - 188.1	0 - 1	5.59056	Puntaje otorgado a cada nodo según el perfil y cantidad de las personas que lo transitan. El detalle de su cálculo se encuentra en la Tabla 8.
8	Uso del suelo de los lotes de la ciudad	Exclusión	Residencial	0	0.118167	Cada clase se declara como de inclusión o de exclusión según los objetivos del proyecto y la revisión del estado del arte.
9		Inclusión	Industrial	1		
10		Inclusión	Comercial	1		
11		Inclusión	Transporte	1		
12		Exclusión	Almacenamiento	0		
13		Inclusión	Educación	1		
14		Inclusión	Institucional	1		
15		Exclusión	Religioso	0		
16		Exclusión	Hostales	0		
17		Inclusión	Recreación	1		
18		Inclusión	Salud	1		
19		Exclusión	Otros	0		
20	Capacidad libre de potencia de las subestaciones de la ciudad	Inclusión	11.25 - 62.21 MVA	0 - 1	4020.34	Normalizado con escala lineal.
21	Valor comercial del terreno por m^2 en las manzanas de la ciudad	Inclusión	0 - 30.940.000 COP	0 - 1	2.82974	Normalizado con escala lineal.
22	Concentración de PM-2.5 en la ciudad	Inclusión	10.70 - 20.65 $\mu g/m^3$	0 - 1	260.189	Normalizado con escala lineal.
23	Áreas no permitidas para construcción	Exclusión	-	0	2832.51	Todas las áreas se clasifican y condifican como 0 dado que el dato únicamente contiene su georeferencia.

*: Datos no obtenidos directamente de las Fuentes de Información ya mencionadas, se obtuvieron a partir del procesamiento de otros datos.

Tabla 8: Codificación de variables demográficas Encuesta de Movilidad 2023.

No.	Atributo	Valores posibles	Codificación	Observaciones
1	Edad	0 - 17 años	0	La población más susceptible a adquisición de EV está entre 18 y 40 años [9, 12, 14].
2		18 - 40 años	1	
3		41 - 100 años	0	
4	Sexo	Hombre	0	La población de mujeres es más susceptible a adquisición de EV [13, 14].
5		Mujer	1	
6		Intersexual	0.5	
7	Estrato	0 - 6	0 - 1	Normalización con escala lineal. La preferencia por EV es proporcional al estrato socioeconómico. [7, 13, 14].
8	Nivel máximo de educación alcanzado	Hasta técnico/tecnólogo	0	Mayores niveles de educación tienen mayor preferencia a EV [12].
9		Universitario y superior	1	
10	Frecuencia del viaje	Nunca	0	Se le dará prioridad a los viajes que se realicen con mayor frecuencia.
11		Esporádicamente	0.25	
12		Algunas veces al mes	0.5	
13		Varias veces a la semana	0.75	
14		Todos los días	1	

6.4. Aplicación Método AHP

Habiendo definido algunos pesos para cada atributo en la última sección, se desarrolló una encuesta basada en el método AHP con el fin de recopilar la opinión de los stakeholders y refinar los pesos de los datos de entrada del modelo de regresión. Estos stakeholders hacen parte del Grupo de Investigación EM&D del Departamento de Ingeniería Eléctrica y Electrónica de la Universidad Nacional de Colombia. Sin embargo, no solo participaron respondientes del ámbito académico, sino también ingenieros del sector industrial y profesionales vinculados al sector energético institucional (empresas de consultoría energética, entidades gubernamentales u organismos regulatorios), como se muestra en la Figura 5. La encuesta compartida a estos stakeholders empleó la Escala de Saaty para clasificar las variables mediante comparaciones por pares. Dado que existen 8 atributos, en la encuesta se solicitaron 28 juicios por pares para construir la matriz de comparación del AHP. Se evaluó la validación de la condición de consistencia $CI < 0{,}1$. Por lo tanto, de 16 respuestas, se descartaron 6 debido a que su CI no cumplía con dicha condición. Finalmente, se obtuvieron $\lambda_{max} = 9{,}015$ y $CI = 0{,}093$.

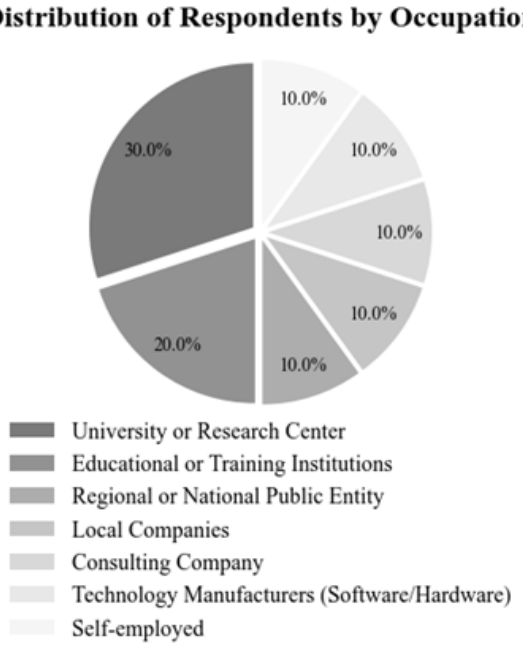


Figura 5: Ocupación de las partes interesadas encuestadas.

Después de procesar todas las respuestas, se calcula la matriz AHP que condensa la opinión de todos los stakeholders (ver Ecuación 8).

$$A_G = \begin{bmatrix} 1 & 2{,}33 & 2{,}21 & 2{,}49 & 3{,}08 & 1{,}92 & 2{,}69 & 2{,}35 \\ 0{,}43 & 1 & 3{,}81 & 2{,}41 & 3{,}18 & 2{,}76 & 3{,}53 & 2{,}53 \\ 0{,}45 & 0{,}26 & 1 & 4{,}07 & 3{,}24 & 2{,}14 & 3{,}74 & 2{,}67 \\ 0{,}40 & 0{,}41 & 0{,}25 & 1 & 2{,}47 & 2{,}09 & 2{,}74 & 3{,}41 \\ 0{,}32 & 0{,}31 & 0{,}31 & 0{,}40 & 1 & 2{,}21 & 2{,}54 & 2{,}33 \\ 0{,}52 & 0{,}36 & 0{,}47 & 0{,}48 & 0{,}45 & 1 & 2{,}33 & 2{,}90 \\ 0{,}37 & 0{,}28 & 0{,}27 & 0{,}37 & 0{,}39 & 0{,}43 & 1 & 2{,}81 \\ 0{,}43 & 0{,}39 & 0{,}37 & 0{,}29 & 0{,}43 & 0{,}34 & 0{,}36 & 1 \end{bmatrix} \tag{8}$$

Posteriormente, se calculó su vector propio y los pesos para cada variable resultaron como se muestra en la Tabla 9. Los stakeholders encuestados otorgaron la mayor prioridad a las capacidades técnicas de las EVFCS, directamente relacionadas con el uso por parte del usuario, como la capacidad de potencia, el número de conectores y la velocidad de carga. Posteriormente, se priorizaron los factores asociados a la infraestructura existente y a la accesibilidad, incluyendo la capacidad eléctrica de la red y las condiciones de tráfico de vehículos y habitantes. Por último, el menor peso se asignó al valor económico del suelo para la instalación de una EVCS y a la posible contribución a la descontaminación en zonas con alta concentración de PM-2.5. Nótese que el grupo con la mayor calificación tiene un peso AHP 2.3 veces mayor que el segundo grupo y 4.6 veces mayor que el tercer grupo, en promedio. Los pesos definitivos que se aplicarán a cada variable corresponden al producto entre los pesos de la Tabla 7 y los de la Tabla 9.

Tabla 9: Pesos AHP de cada atributo acorde a partes interesadas.

Criterio	**Peso AHP**
Potencia de las estaciones de carga EV	0.23
Número de conectores en las estaciones de carga EV	0.22
Velocidad de carga de las estaciones de carga EV	0.17
Proximidad a los nodos vehiculares más transitados	0.11
Capacidad de potencia disponible en la zona	0.08
Proximidad a lugares con alto flujo de personas	0.08
Valor comercial del sitio de instalación	0.05
Contribución a la descontaminación del aire	0.04

6.5. Diseño, Entrenamiento y Validación del Modelo de Regresión

El modelo seleccionado fue el de *Radius Neighbors Regressor (RNRM)*. Después de preparar todos los datos en la sección anterior, estos se integraron en un conjunto de datos que actúa como la entrada adecuada para el RNRM. Formando un *dataset* de entrenamiento de 1,121,666 datos. Como el RNRM solo admite geometrías de tipo *Point* como entrada. Por esta razón, este conjunto de datos contiene información espacial puntual de todos los atributos, además de una columna relacionada con la puntuación de cada muestra según su influencia de inclusión o exclusión en la planificación de estaciones de carga rápida, donde se incluyen los pesos por desbalance y los pesos AHP. Ambos funcionan como entradas X y Y para el entrenamiento del modelo, donde la variable de optimización directa es el valor de ponderación, aunque su georreferenciación será la salida de interés.

Los parámetros del RNRM se configuraron para ponderar la contribución de cada vecino de manera inversamente proporcional a su distancia desde el punto de consulta, utilizando la distancia Manhattan como métrica. Esta distancia mide qué tan separados están dos puntos sumando las diferencias absolutas a lo largo de cada eje de coordenadas, lo que permite emular desplazamientos urbanos a través de manzanas, aunque sin estar relacionada con la red vial real de la ciudad.

Para realizar predicciones con el modelo entrenado, se plantea una *malla de evaluación* en un espacio 2D georreferenciado que abarque la ciudad de Bogotá, con una resolución de 100 metros (por el momento dado el alto consumo computacional). Esto se realiza con el objetivo de establecer una entrada compuesta de datos

semi-aleatorios, que permitan al modelo predecir las ubicaciones óptimas luego de su entrenamiento. Dado que en este caso se quiere llegar a ubicaciones objetivo no conocidas, a partir de ubicaciones conocidas con cierta ponderación según la influencia de cada atributo frente al uso de estaciones de carga rápida para vehículos eléctricos.

Finalmente, el RNRM fue entrenado y evaluado. Las métricas de validación obtenidas fueron:

$$\text{MSE} = 3{,}03 \times 10^{-3}, \quad \text{RMSE} = 1{,}79 \times 10^{-3}, \quad \text{MAE} = 1{,}46 \times 10^{-5}, \quad R^2 = 0{,}949.$$

Todas ellas se encuentran normalizadas entre 0 y 1. De este modo, con un modelo validado y aprobado, sus predicciones se presentan en las siguientes secciones.

7. Resultados Obtenidos

Ahora bien, antes de juntar todos los datos y hacer la regresión definitiva, se realiza una regresión individual para cada atributo. Con la idea de observar como se distribuye cada variable y encontrar tendencias que permitan obtener conclusiones posteriores a la regresión final. Las regresiones individuales se muestran en la Figura 6. Allí se aprecia como ya se ajustó cada atributo a su respectivo peso (según su tamaño y desbalance) y se procesó según si es una variable de inclusión o exclusión. Para los atributos referentes a las electrolineras existentes en la ciudad, las zonas de interés representan donde *no* se concentran las existentes, es decir, regiones objetivo donde se pueden ubicar las nuevas estaciones de carga. En la regresión de nodos se muestran las zonas donde el flujo de transporte de la población objetivo se concentra (según las variables de la Tabla 8). En el estudio del suelo objetivo se le da una mayor ponderación (colores más oscuros) a las ubicaciones con infraestructura que indique concentración de personas (según Tabla7). La capacidad energética libre se halló a partir de la carga y capacidad total de las subestaciones georreferenciadas, en consecuencia las zonas más oscuras indican mayor capacidad disponible. Para el costo del terreno se tomó el mayor costo con menor puntuación, gracias a su característica de variable de exclusión, mientras que la concentración de PM-2.5 al ser de inclusión toma mayores concentraciones con mayor puntuación.

7.1. Casos de Uso a Implementar

Con el fin de evaluar las estimaciones realizadas por el modelo en tres escenarios distintos, se plantean tres casos de uso.

7.1.1. Caso de Uso 1: Expansión del 50 % de la Infraestructura de Carga Rápida Existente

Este primer caso de uso se propuso como un escenario de baja masificación, en comparación con los otros dos casos que se presentan más adelante. El caso considera únicamente el número de estaciones de carga rápida existentes y sugiere un crecimiento del 50 % en la infraestructura. La Figura 7 ilustra la predicción del modelo.

Con el objetivo de comparar y analizar los resultados obtenidos, se tiene en cuenta la regresión espacial para cada atributo mostrado en la Figura 6. Esto permite observar el comportamiento espacial individual de cada variable en la ciudad y evaluar su influencia específica en la salida del modelo. Las tonalidades oscuras indican mayores concentraciones que las tonalidades claras. Las barras laterales indican el peso final de cada una (el peso de balanceo por tamaño multiplicado por el peso AHP).

Considerando las Figuras 6 y 7, es posible analizar la estimación obtenida. Las predicciones del modelo muestran un claro predominio de variables relacionadas con déficits de infraestructura y demanda de movilidad. Los factores más influyentes son los déficits de potencia, conectores y carga veloz de las estaciones existentes, seguidos por los nodos de movilidad de la población objetivo, los cuales en conjunto guían la ubicación de nuevas estaciones hacia las zonas con mayores necesidades de carga no satisfechas y con mejor accesibilidad.

La capacidad de la red eléctrica y el uso del suelo presentan una influencia moderada, actuando principalmente como restricciones de viabilidad técnica. En contraste, el costo del suelo y la concentración de PM-2.5 tienen un efecto mínimo o nulo en la distribución de las 15 estaciones propuestas, lo que sugiere que en esta etapa inicial de despliegue, el modelo prioriza la eficiencia operativa por encima de consideraciones económicas o ambientales. De este modo, es coherente con los pesos AHP de la Tabla 9.

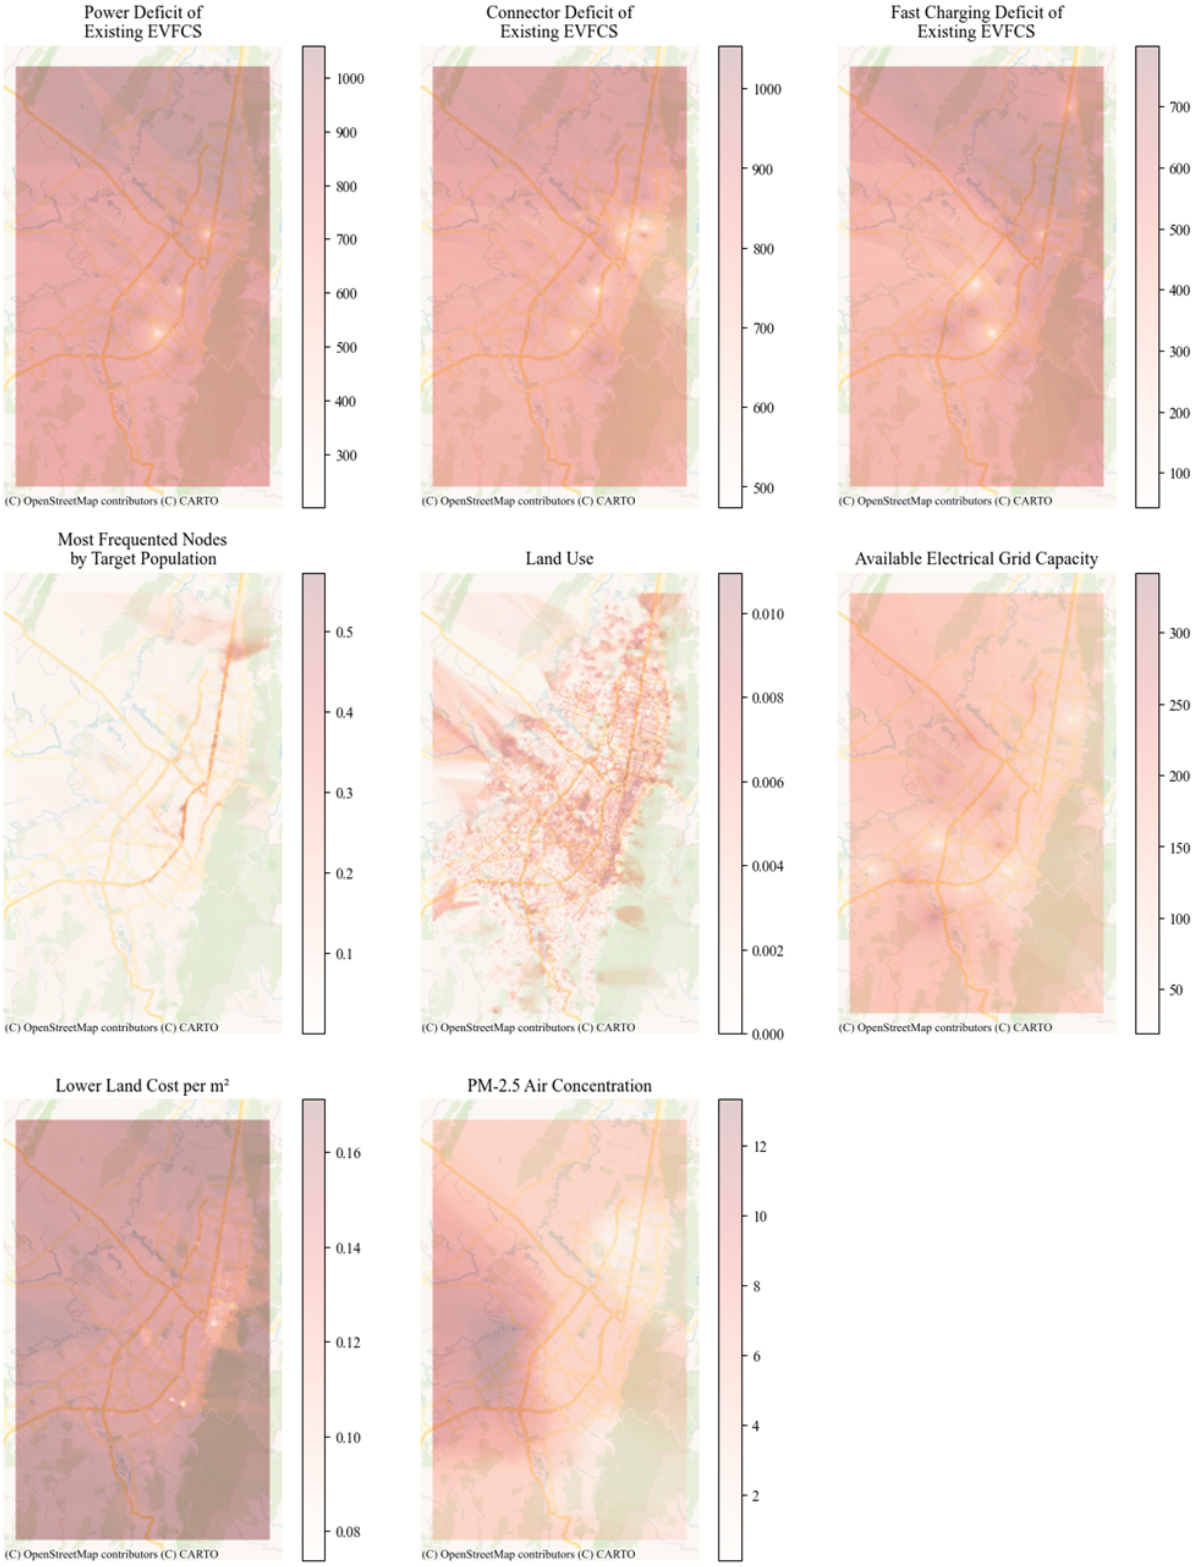


Figura 6: Regresión individual de cada uno de los atributos propuestos para el estudio. Las zonas de interés de cada tributo se muestran en colores más oscuros.



Figura 7: Estimación del modelo para el caso de uso 1.

7.1.2. Caso de Uso 2: Predicción del Despliegue de Estaciones de Carga Rápida para 2026 Basado en Proyecciones de Política Pública Nacional

El segundo escenario de caso consideró las recomendaciones emitidas por la UPME en 2019 respecto a la planificación de infraestructura para vehículos eléctricos, institución responsable de la planeación energética y lineamientos regulatorios de Colombia. Se recomendó que existiera una estación de carga rápida por cada 117 vehículos eléctricos [19]. Informes recientes indican que Bogotá cuenta con aproximadamente 14,100 vehículos eléctricos, lo que, según dichas proyecciones de política nacional, requeriría alrededor de 120 de dichas estaciones para 2026. Dado que la ciudad actualmente opera solo 30, serían necesarias 90 adicionales.

Utilizando el modelo RNRM diseñado y entrenado en este trabajo, se predijeron las ubicaciones óptimas para estas 90 nuevas estaciones de carga como un escenario de masificación media (véase Figura 8). Comparando las distribuciones de la Figura 6 y el patrón espacial de estas 90 EVFCS propuestas, tal como en el caso de uso 1, es posible notar que la distribución se expande significativamente más allá de las áreas núcleo iniciales, indicando una transición de un despliegue correctivo hacia una densificación de red.

El modelo continúa respondiendo fuertemente a los déficits de potencia y conectores, pero la mayor dispersión sugiere una influencia creciente de los patrones de movilidad y de la disponibilidad de suelo como factores determinantes. Ahora las estaciones aparecen a lo largo de corredores secundarios y zonas periféricas, reflejando un intento de mejorar la cobertura territorial y la accesibilidad en lugar de atender únicamente deficiencias localizadas. El efecto de la capacidad de la red eléctrica se vuelve más evidente, orientando las instalaciones hacia áreas con infraestructura factible. Mientras tanto, el costo del suelo y la concentración de PM-2.5 comienzan a desempeñar un papel ligeramente mayor, aunque todavía secundario. En conjunto, esta etapa consolida una red de carga más conectada y resiliente.



Figura 8: Estimación del modelo para el caso de uso 2.

7.1.3. Caso de Uso 3: Predicción del Despliegue de Estaciones de Carga Rápida para 2030 Basado en Proyecciones de Política Pública Nacional

El tercer caso corresponde a un escenario de alta masificación, alineado con la agenda de política considerada en el caso de estudio 2. En este escenario se requieren 236 estaciones de carga para vehículos eléctricos, lo que implica que deben desplegarse 206 estaciones adicionales. Dado que este escenario apunta a una red de carga de alta densidad, el parámetro de radio del modelo RNRM se redujo a la mitad para permitir agrupamientos dentro de áreas urbanas más pequeñas.

La distribución espacial de las estaciones propuestas (véase Figura 9) muestra una marcada dispersión hacia zonas periféricas y suburbanas, indicando un cambio claro respecto a la concentración previa en el núcleo urbano. El modelo ahora prioriza la cobertura territorial y la equidad en accesibilidad, expandiendo la red a lo largo de corredores secundarios y barrios externos que anteriormente estaban subatendidos. Este patrón refleja una influencia más equilibrada entre disponibilidad de suelo, capacidad de la red eléctrica y conectividad de movilidad, permitiendo que la infraestructura cubra una mayor porción del área metropolitana.

Aunque las variables relacionadas con déficits existentes siguen siendo influyentes, su predominio disminuye a medida que el modelo se enfoca en la expansión espacial y la redundancia dentro de la red de carga. En conjunto, esta etapa representa una fase de despliegue madura, orientada hacia la robustez, la inclusividad y una cobertura espacial integral, más que a la optimización localizada.



Figura 9: Estimación del modelo para el caso de uso 3.

7.2. Discusión Final de los Casos de Uso

Para evaluar el impacto del despliegue propuesto de estaciones de carga rápida en los tres casos de estudio, se realizó un análisis comparativo del cambio de consumo energético del petróleo hacia la electricidad, empleando datos promedio de vehículos eléctricos, vehículos a gasolina, estaciones de carga eléctrica y estaciones de servicio en Bogotá.

En primer lugar, se efectuó una comparación de emisiones de CO_2. Considerando que (1) la capacidad promedio de batería es de 34 kWh (según fabricantes), (2) la autonomía promedio de los vehículos vendidos en Colombia es de 204 km, (3) la distancia promedio recorrida por día es de 15.4 km, es posible afirmar que una estación de carga rápida de 50 kWh estará ocupada efectivamente 6 horas por día atendiendo 117 vehículos eléctricos [19]. En consecuencia, la energía eléctrica total requerida E_{req} para suplir las 90 estaciones propuestas del caso de estudio 2 se calcula en la Ec. (9).

$$E_{\text{req}} = 50\,\text{kW}_{\text{EVFCS}} \cdot 6\,\text{h/day} \cdot 90\,\text{EVFCS} = 27\,\text{MWh/day} \tag{9}$$

Para obtener las emisiones indirectas de CO_2 provenientes de la generación eléctrica en Colombia, se emplea el factor nacional de emisiones dado también en [19], igual a 0.112 ton CO_2/MWh. En la Ec. (10) se estiman las emisiones equivalentes totales de la energía eléctrica requerida para abastecer las 90 nuevas estaciones.

$$\text{Em}_{\text{CO}_2-\text{ele}} = 27\,\text{MWh/day} \cdot 0{,}112\,\text{ton}\,\text{CO}_2/\text{MWh} = 3{,}024\,\text{ton}\,\text{CO}_2/\text{day} \tag{10}$$

Por otro lado, para calcular las emisiones de CO_2 del combustible equivalente —que las estaciones propuestas buscan reemplazar en el mismo caso de estudio—, considerando: (1) la misma distancia recorrida al

día, (2) 10,530 vehículos atendidos por día (117 vehículos por 90 estaciones), (3) un consumo promedio de 0.08 L/km para vehículos a gasolina, y (4) un factor de emisión del petróleo de 2.45 kg CO_2/L, es posible estimar las emisiones equivalentes mostradas en la Ec. (11).

$$\mathrm{Em}_{\mathrm{CO_2-oil}} = 15{,}4\,\mathrm{km/car} \cdot 0{,}08\,\mathrm{L/km} \cdot 10530\,\mathrm{car/day} \cdot 2{,}45\,\mathrm{kg\,CO_2/L} = 31{,}784\,\mathrm{ton\,CO_2/day} \tag{11}$$

En segundo lugar, se realizó un análisis económico. Suponiendo un costo promedio por kWh en una estación de carga rápida de 1,690 COP, el costo total que pagarían los usuarios para recargar sus vehículos eléctricos en las 90 estaciones propuestas se calcula en la Ec. (12).

$$C_{\mathrm{ele}} = 27\,\mathrm{MWh/day} \cdot 1,690\,\mathrm{COP/kWh} = 45{,}630{,}000\,\mathrm{COP/day} \approx 12{,}072\,\mathrm{USD/day} \tag{12}$$

De forma similar, asumiendo un costo de combustible de 17,300 COP/gal, el costo del suministro equivalente de gasolina para el mismo caso se estima en la Ec. (13).

$$\begin{aligned} C_{\mathrm{oil}} &= 15{,}4\,\mathrm{km/car} \cdot 0{,}08\,\mathrm{L/km} \cdot 10530\,\mathrm{car/day} \cdot\ 17{,}300\,\mathrm{COP/gal} \cdot \frac{1}{0{,}264\,\mathrm{gal/L}} \\ &= 59{,}250{,}102\,\mathrm{COP/day} \approx 15{,}675\,\mathrm{USD/day} \end{aligned} \tag{13}$$

Los resultados indican que las emisiones totales de CO_2 se reducen en promedio por un factor de 10.5 con las estaciones propuestas, alcanzando una disminución de 10,497.4 toneladas de CO_2 al año. Además, en el caso proyectado para 2026, se lograría una reducción del 23 % en el costo diario que los usuarios pagan por transporte, si optan por reemplazar los vehículos a gasolina por vehículos eléctricos y realizar sus recargas en las estaciones propuestas.

Dado que ambos análisis son lineales, el mismo comportamiento corresponde a los casos de estudio 1 y 3, de baja y alta masificación respectivamente. Los valores calculados para los tres casos se presentan en la Tabla 10. Allí es posible observar cómo la reducción de la huella de carbono y los beneficios económicos crecen linealmente con la penetración de infraestructura de carga rápida.

En tercer lugar, al observar los tres casos, se nota que las ubicaciones predichas tienden a concentrarse en el centro y el norte de la ciudad, de acuerdo con la influencia de cada atributo y su peso asignado, tal como se explicó previamente. Sin embargo, surgen dos efectos importantes. Por un lado, desde el punto de vista técnico, estas ubicaciones se concentran en zonas con baja disponibilidad de capacidad eléctrica (véase Figura 6). Actualmente, Bogotá presenta problemas de distribución eléctrica en las zonas central y norte debido a la falta de nuevos proyectos de expansión en transmisión. Por otro lado, el impacto positivo ambiental es menor porque las estaciones predichas no se ubican en las áreas con peor calidad del aire. No obstante, esto se debe al peso asignado al criterio ambiental en el AHP definido por los actores consultados.

Tabla 10: Resumen de la discusión de los casos de estudio

Factor	**Unidad**	**Caso 1**	**Caso 2**	**Caso 3**
$\mathrm{Em}_{\mathrm{CO_2-ele}}$	Ton CO_2/día	0.50	3.02	6.92
$\mathrm{Em}_{\mathrm{CO_2-oil}}$	Ton CO_2/día	5.29	31.78	72.75
C_{ele}	USD	2,001	12,072	27,484
C_{oil}	USD	2,598	15,675	35,688

8. Conclusiones

El enfoque de toma de decisiones propuesto fortalece el proceso de planificación al incorporar criterios basados en expertos mediante AHP, permitiendo una selección optimizada y objetiva de ubicaciones adecuadas para estaciones de carga rápida que se ajustan a las condiciones urbanas reales y al criterio de los actores involucrados en la movilidad eléctrica. Además, la metodología se estableció como un procedimiento cíclico que integra retroalimentación de varios factores. Primero, la revisión del estado del arte permitió identificar qué datos debían seleccionarse o descartarse a lo largo del proceso de desarrollo. Segundo, el AHP permitió considerar las opiniones de los actores al priorizar los conjuntos de datos seleccionados. Tercero, las métricas de validación del RNRM hicieron posible calificar las predicciones refinadas por los dos procedimientos anteriores.

A lo largo de los tres casos de uso desarrollados, el modelo RNRM demuestra una evolución progresiva en el despliegue espacial de EVFCS, pasando de un refuerzo localizado a una expansión a escala de red. Esto ocurre principalmente debido al radio de clúster del RNRM, que define la distancia mínima de evaluación para las predicciones y debe ajustarse según la densidad de predicción deseada. En este estudio, dicho radio se restringió a la distancia requerida entre EVFCS según las políticas públicas [**?**].

En el escenario de baja masificación, el modelo prioriza claramente las zonas con mayores déficits de infraestructura, particularmente en disponibilidad de potencia y conectores, generando un patrón concentrado alrededor del núcleo urbano existente. Esta etapa enfatiza la eficiencia operativa y atiende brechas inmediatas de demanda.

En el escenario intermedio, la red comienza a extenderse a lo largo de corredores secundarios y zonas de transición, equilibrando la cobertura de demanda con la viabilidad técnica. La influencia de la capacidad de la red eléctrica y del uso del suelo se vuelve más evidente, indicando que el modelo optimiza el despliegue más allá de la corrección de déficits y considerando factores más amplios de accesibilidad y conectividad.

En el escenario de alta masificación, la distribución espacial se dispersa ampliamente hacia zonas periféricas y suburbanas, reflejando una fase de despliegue madura. Aquí, el modelo busca equidad territorial y redundancia, garantizando una cobertura robusta en toda el área metropolitana. La importancia relativa de los variables asociadas a déficits disminuye, mientras que la disponibilidad de suelo, la conectividad de movilidad y la factibilidad de la red adquieren mayor relevancia en la determinación de nuevas ubicaciones. Estos cambios en importancia relativa pueden afectar los pesos establecidos utilizados para balancear los conjuntos de datos y refinarlos mediante AHP. En este caso final, el radio de clúster del RNRM desempeña un papel clave en la determinación de las ubicaciones óptimas debido a la capacidad del modelo para ajustar su salida según la densidad de predicción objetivo.

El despliegue propuesto de infraestructura muestra impactos positivos para Bogotá. Aunque las estaciones no mejoran directamente la calidad del aire porque no se localizan en las zonas más contaminadas, las emisiones de CO_2 disminuyen en un 10 %. Desde una perspectiva económica, los costos de transporte pueden reducirse en un 23 %. Se espera que esta reducción aumente en el futuro cercano, dado que los precios de la gasolina tienden a incrementar mientras que los costos de la electricidad podrían disminuir debido a las políticas de transición energética y a la penetración de generación renovable.

Los resultados indican que los análisis basados en GIS combinados con modelos de toma de decisiones guiados por políticas públicas conducen a resultados óptimos sostenibles, objetivos y alineados con las políticas. Sin embargo, la implementación real de las estaciones propuestas debe considerar requerimientos técnicos y de instalación detallados. Como se mencionó, las estaciones predichas tienden a concentrarse en las zonas central y norte de la ciudad, donde existen déficits de capacidad eléctrica. Además, se espera que el uso de estaciones alcance su máximo durante horas pico de tráfico o carga. Por lo tanto, la implementación debe considerar el impacto sobre el sistema eléctrico de Bogotá para garantizar seguridad y confiabilidad en la red. El trabajo futuro se centrará en estas consideraciones de instalación.

Referencias

[1] A. G. Yeh, "Urban planning and gis," *Geographical information systems*, vol. 2, no. 877-888, p. 1, 1999.

[2] M. van Maarseveen, J. Martinez, and J. Flacke, Eds., *GIS in Sustainable Urban Planning and Management: A Global Perspective*. Boca Raton: Routledge, 2023.

[3] R. Wang, Y. Murayama, and T. Morimoto, "Scenario simulation studies of urban development using remote sensing and gis: review," *Remote Sensing Applications: Society and Environment*, vol. 22, p. 100474, 2021. [Online]. Available: https://www.sciencedirect.com/science/article/pii/S2352938521000100

[4] S. Chaube, S. Pant, A. Kumar, S. Uniyal, M. K. Singh, K. Kotecha, and A. Kumar, "An overview of multi-criteria decision analysis and the applications of ahp and topsis methods," *International Journal of Mathematical, Engineering and Management Sciences*, vol. 9, no. 3, p. 581, 2024.

[5] S. Esfandi, S. Tayebi, J. Byrne, J. Taminiau, G. Giyahchi, and S. A. Alavi, "Smart cities and urban energy planning: An advanced review of promises and challenges," *Smart Cities*, vol. 7, no. 1, pp. 414–444, 2024. [Online]. Available: https://www.mdpi.com/2624-6511/7/1/16

[6] J. Zhu, M. Zhu, L. Chen, L. Luo, W. Wang, X. Zhu, and Y. Sun, "Multi-objective optimization of urban gas station site selection under territorial spatial planning constraints," *ISPRS International Journal of Geo-Information*, vol. 13, no. 11, 2024. [Online]. Available: https://www.mdpi.com/2220-9964/13/11/375

[7] P. Soczówka, M. Lasota, P. Franke, and R. Żochowska, "Method of determining new locations for electric vehicle charging stations using gis tools," *Energies*, vol. 17, no. 18, 2024. [Online]. Available: https://www.mdpi.com/1996-1073/17/18/4546

[8] A. Nalin, A. Simone, L. Bellinato, V. Vignali, and C. Lantieri, "Gis-based analysis to locate electric vehicle charging stations in an urban environment: a case study in bologna, italy," *Transportation Research Procedia*, vol. 90, pp. 424–431, 2025, vSI: TIS ROMA 2024. [Online]. Available: https://www.sciencedirect.com/science/article/pii/S2352146525006349

[9] M. Kazempour, H. Sabboubeh, K. Pirouz Moftakhari, R. Najafi, and G. Fusco, "GIS-based geospatial analysis for identifying optimal locations of residential on-street electric vehicle charging points in Birmingham, UK," *Sustainable Cities and Society*, vol. 120, p. 105988, 2025. [Online]. Available: https://www.sciencedirect.com/science/article/pii/S2210670724008126

[10] U. Zafar, I. S. Bayram, and S. Bayhan, "A gis-based optimal facility location framework for fast electric vehicle charging stations," in *A GIS-based Optimal Facility Location Framework for Fast Electric Vehicle Charging Stations*, 04 2021.

[11] M. A. Schvartz, L. V. Avila, W. Leal Filho, L. Neves Canha, J. C. M. Siluk, T. A. B. C. d. Barros, L. Felipe Dias Lopes, and E. R. Steinhorst Kraetzig, "Analysis of the factors influencing the purchase of electric vehicles in brazil," *Sustainability*, vol. 16, no. 22, 2024. [Online]. Available: https://www.mdpi.com/2071-1050/16/22/9957

[12] A. Rahman, I. W. K. Suryawan, S. Suhardono, V. V. Nguyen, and C.-H. Lee, "Determinants of electric vehicle adoption in urban and peri-urban areas," *Energy for Sustainable Development*, vol. 85, p. 101664, 2025. [Online]. Available: https://www.sciencedirect.com/science/article/pii/S0973082625000146

[13] Y. Chen, W. Cao, and K. Wang, "Purchase intention of new energy vehicles: a comprehensive analysis considering total cost of ownership and personality traits," *Transportation Research Part F: Traffic Psychology and Behaviour*, vol. 114, pp. 701–720, 2025. [Online]. Available: https://www.sciencedirect.com/science/article/pii/S1369847825002335

[14] K. Tissayakorn, "Consumers' decisions to purchase electric vehicles in bangkok, thailand," *Case Studies on Transport Policy*, vol. 21, p. 101536, 2025. [Online]. Available: https://www.sciencedirect.com/science/article/pii/S2213624X25001737

[15] S. Chakhar and V. Mousseau, "Spatial multicriteria decision making," *Encyclopedia of GIS*, vol. 10, pp. 978–0, 2008.

[16] República de Colombia, "Por el cual se reglamentan las disposiciones referentes al ordenamiento del territorio municipal y distrital y a los planes de ordenamiento territorial," Decreto No. 879 de 1998, Publicado en el Diario Oficial No. 43.300, Presidencia de la República de Colombia; Ministerio de Desarrollo Económico, may 1998, nota: Los datos publicados tienen propósitos exclusivamente informativos. El Departamento Administrativo de la Función Pública no se hace responsable de la vigencia de la presente norma. Nos encontramos en un proceso permanente de actualización de los contenidos. [1, 53].

[17] S. J. Rey, D. Arribas-Bel, and L. J. Wolf, *Geographic Data Science with Python*, 1st ed. New York: Chapman & Hall/CRC, 2023.

[18] G. King and L. Zeng, "Logistic regression in rare events data," *Political Analysis*, vol. 9, 09 2002.

[19] UPME, "Establecer recomendaciones en materia de infraestructura de recarga para la movilidad eléctrica en colombia para los diferentes segmentos: buses, motos, taxis, brt, cu sumatoria," Unidad de Planeación Minero-Energética (UPME), Bogotá, Colombia, Reporte técnico, 2019.