Identificación de patrones socioeconómicos en Medellín a partir de imágenes satelitales

Estudiante: Mariana Ceballos Betancur
Escuela de Ciencias Aplicadas e Ingeniería

Director: Juan David Martínez Vargas
Escuela de Ciencias Aplicadas e Ingeniería
jdmartinev@eafit.edu.co
Senior (Minciencias)
Asistente (EAFIT)

Co-Directora: María Constanza Torres
Universidad Nacional de Colombia
Ingeniera electrónica
mctorresm@unal.edu.co

Palabras clave: *"Patrones Socioeconómicos", "Redes Neuronales", "Transformers" "Aprendizaje Automático", "Imágenes Satelitales"*

Identificación de patrones socioeconómicos en Medellín a partir de imágenes satelitales

Resumen

Este estudio se centra en la integración de herramientas de ciencia de datos en el campo de las ciencias sociales para analizar la distribución de la población y su impacto en las condiciones socioeconómicas de las ciudades. La investigación se enfoca en Medellín, utilizando imágenes satelitales para examinar su distribución socioeconómica.

Primero, se llevó a cabo una fase de preprocesamiento en la que se mejoró la calidad visual de las imágenes mediante la ecualización del histograma. A continuación, se implementó un modelo basado en redes neuronales con arquitectura de transformers para identificar patrones territoriales.

El objetivo principal de este enfoque es detectar patrones relacionados con la distribución de la población y la topografía de Medellín, proporcionando una herramienta valiosa para la toma de decisiones en políticas públicas. Esto permite a los responsables políticos identificar características clave que faciliten el desarrollo de políticas destinadas a mejorar las condiciones socioeconómicas de la ciudad. Este trabajo no solo ofrece una metodología innovadora para el análisis espacial y sociodemográfico, sino que también subraya la importancia de la colaboración interdisciplinaria entre las ciencias sociales y la ciencia de datos.

1. Introducción

La identificación de patrones socioeconómicos es fundamental para las comunidades, ya que permite anticiparse a posibles cambios demográficos y formular políticas públicas que aseguren la sostenibilidad del entorno sin agravar las brechas socioeconómicas. Además, proporciona una comprensión clara y completa de los procesos de urbanización y de cómo el territorio y la topografía influyen en estos patrones. Los patrones socioeconómicos incluyen la distribución de la riqueza, el acceso a servicios públicos, la educación, la salud y la movilidad, entre otros factores. Estos patrones pueden influir en la cohesión social, el desarrollo económico y la calidad de vida de los habitantes.

Es por esto que, la utilización de técnicas de aprendizaje automático, en comparación con las técnicas tradicionales, se convierte en una herramienta valiosa para monitorear estas dinámicas sociales y facilitar la toma de decisiones para abordar las problemáticas derivadas de los cambios demográficos (Wang, y otros, 2018). La teledetección, a través de imágenes satelitales, permite obtener datos precisos y actualizados sobre la distribución y las características del territorio, lo cual es esencial para un análisis socioeconómico efectivo. Esta metodología es menos costosa y más eficiente que los métodos tradicionales de recolección de datos, como los censos, que a menudo son costosos y se realizan con poca frecuencia.

Medellín ha experimentado significativas transformaciones demográficas en los últimos años, impulsadas en gran parte por un aumento del turismo, que creció un 42% en el primer semestre de 2023 (Gobernación de Antioquia, 2023). Estos cambios han afectado las dinámicas sociales tanto de Medellín como del Valle de Aburrá. Como resultado, el área metropolitana ha enfrentado consecuencias como el desplazamiento de residentes locales hacia la periferia y un aumento en los costos de vida, fenómeno conocido como gentrificación. Esto ha llevado a que el proceso de urbanización adopte patrones y consecuencias diferentes (Concejo de Medellín, 2023).

Identificar patrones socioeconómicos en Medellín es crucial para la toma de decisiones y la creación de políticas públicas que consideren aspectos no evaluados previamente. Este estudio propone evaluar la influencia de la topografía y la distribución de la población en el territorio en

aspectos socioeconómicos, mediante el análisis de imágenes satelitales que capturen dichos efectos y relaciones entre la sociedad y el territorio. La aplicación de técnicas de aprendizaje automático permitirá realizar un análisis integral y mucho más efectivo comparado con las técnicas tradicionales. Por ejemplo, en Colombia, el Censo Nacional de Población y Vivienda, realizado por el Departamento Administrativo Nacional de Estadística (DANE), presentó los resultados más recientes en 2018 y, antes de ese estudio, el censo más reciente era de 2005. Esto indica que el seguimiento de las condiciones socioeconómicas no se actualiza periódicamente (DANE, 2018).

Una de las limitaciones de esta propuesta es que, aunque las imágenes se capturan con mayor frecuencia, esa frecuencia no es fija ni está definida. Además, las imágenes satelitales varían en resolución espacial, lo que puede limitar la capacidad de detectar detalles finos. Los satélites de alta resolución son costosos y las imágenes de baja resolución pueden no capturar detalles necesarios para ciertos análisis. Para abordar esta restricción en el manejo de las imágenes satelitales, se implementó una librería de Python de código abierto que facilita la gestión de estas imágenes. Además, es necesario tener un conocimiento previo sobre las características de los sistemas de información geográfica para asegurar que el manejo de los datos sea adecuado y que las imágenes obtenidas sean pertinentes y coherentes con el objetivo de este proyecto.

2. Planteamiento del Problema

Como se mencionó anteriormente, es relevante y pertinente realizar el análisis de los patrones socioeconómicos debido a que permite prever cambios demográficos y desarrollar políticas públicas efectivas. En Medellín, los recientes cambios demográficos, impulsados por el incremento del turismo y la gentrificación, han llevado a que surjan desafíos que afectan tanto la cohesión social como la igualdad en el acceso a servicios. Sin embargo, la ausencia de datos actualizados y detallados dificulta una comprensión completa de estas dinámicas.

Aunque existen imágenes satelitales y técnicas avanzadas disponibles, los métodos tradicionales de recolección de datos, como los censos, tienen limitaciones importantes. Estos métodos suelen ser costosos y se realizan con poca frecuencia, lo que da lugar a una falta de información actualizada sobre las condiciones socioeconómicas en Medellín.

La brecha en el conocimiento radica en la falta de un análisis integral y actualizado de cómo la topografía y la distribución de la población influyen en los patrones socioeconómicos en Medellín. La utilización de técnicas de aprendizaje automático y redes neuronales para analizar imágenes satelitales representa una oportunidad para superar estas limitaciones. Estas técnicas pueden proporcionar un análisis más detallado, permitiendo una mejor comprensión de los patrones socioeconómicos y facilitando la toma de decisiones informadas. Al mismo tiempo, responde a las exigencias del mundo actual, donde las dinámicas sociales están cambiando rápidamente, lo que hace que algunas metodologías tradicionales puedan volverse obsoletas debido a la falta de coherencia con los cambios en la distribución de la población en el territorio.

3. Objetivos

3.1 Objetivo general.

Identificar patrones socioeconómicos a partir del análisis de imágenes satelitales por medio un modelo de redes neuronales.

3.2 Objetivos específicos

- Recopilar y procesar las imágenes satelitales de Medellín que cuenten con una buena resolución para garantizar mayor precisión.
- Explicar la relación de la distribución de la población, las condiciones topográficas y las condiciones socioeconómicas en la ciudad de Medellín
- Implementar un modelo con redes neuronales para comprobar lo propuesto anteriormente.
- Realizar una validación externa de los resultados utilizando datos socioeconómicos de la Alcaldía de Medellín para contrastar los resultados del modelo.

4. Marco teórico y Estado del arte

La urbanización se caracteriza por ser un proceso que lleva a la concentración de la población y de ciertas actividades económicas en las ciudades causando que experimenten cambios

demográficos y económicos, en donde el papel gubernamental cobra relevancia en el momento de llevar a cabo la toma de decisiones de las políticas públicas (Bottino, 2009). Este fenómeno se caracteriza por el aumento de la proporción de población urbana en comparación con la rural, manifestándose de diversas maneras y grados (Centro de Investigación sobre Dinámica Social, 2007). En el año 2018 más del 50% de la población vivía en zonas urbanas y se esperaba que esta tendencia continuara incrementando (United Nations, 2018), lo cual se traduce en un reto para los países y las entidades gubernamentales con respecto a la forma en la que deciden abordar este tipo de dinámicas sociales que son parte clave en todo lo que concerniente al desarrollo sostenible de los países y la comunidad internacional.

Estas dinámicas sociales que surgen a partir de la urbanización han llevado a que sea un centro de estudio, debido a que, aunque contribuye positivamente al desarrollo económico y social, también presenta desafíos significativos. Entre estos desafíos se encuentran la gestión de recursos naturales, la contaminación ambiental y la exclusión de grupos sociales de las ciudades, lo cual puede resultar en desigualdades sociales que son prioritarias en las agendas gubernamentales (Abitbol & Marton, 2020).

Para la identificación de los patrones socioeconómicos, se consideran estos patrones como representaciones abstractas de elementos del mundo físico. Estos patrones se manifiestan a través de regularidades en una serie de observaciones conectadas en el tiempo o el espacio, sirviendo como modelos para entender y predecir comportamientos (Valdes Avila & Baquero Vanegas, 2019). Adicionalmente, los patrones espaciales están vinculados a la forma urbana, definida por la disposición de calles, manzanas y edificaciones. Esta configuración origina ciertas geometrías que permiten analizar la morfología y tamaño de los elementos urbanos, proporcionando un marco para interpretar la estructura y dinámica de las ciudades (Vaca Proaño, Lopez Rueda, Llorca Vega, & Ferreras Cid, 2023).

Además de los retos mencionados, surge la necesidad de hacerle seguimiento a este tipo de procesos de manera efectiva, en donde a partir de la recolección de ciertos datos se logren identificar las transformaciones sociales que está experimentando una ciudad. Una de las alternativas adecua a este tipo de casos es la teledetección, comprendida como técnica de

adquisición de datos de la superficie terrestre mediante sensores instalados en plataformas espaciales (Instituto Geográfico Nacional, 2020). La teledetección permite tener una visión amplia y completa sobre las transformaciones sociales que se pretenden analizar utilizando redes neuronales como un método que permite recuperar información socioeconómica asociada a cada zona de las imágenes satelitales con las que se alimenta dicha red (Abitbol & Marton, 2020).

Inicialmente, se consideraba que el proceso de aprendizaje de las redes neuronales estaba asociado a la intensidad de las conexiones sinápticas entre las neuronas en dónde dicha relación fue conocida posteriormente como la regla de Hebb (Morel, 2000). Esta regla proporciona una base teórica para entender el funcionamiento de las redes neuronales, modeladas según el funcionamiento real de las neuronas. Sin embargo, en el campo de la inteligencia artificial, las redes neuronales se perciben como modelos computacionales compuestos por nodos o neuronas interconectadas. Estas neuronas son entendidas como unidades lógicas funcionales (Wu & Feng, 2017).

En este caso de estudio, se busca emplear datos no estructurados y no lineales, donde las redes neuronales desempeñan un papel crucial. Estas redes pueden abordar eficazmente la representación de cartografías no lineales mediante técnicas de aprendizaje automático, superando las limitaciones de modelos lineales. Las redes neuronales han sido ampliamente utilizadas en diversos contextos complejos como el procesamiento de señales, diagnósticos médicos, optimización de procesos, análisis de imágenes, entre otros (Sun, Liang, & Cui, 2021).

Ahora bien, en el contexto de redes neuronales, existen diversas arquitecturas en donde se encuentran los *Transformers* que fueron diseñados inicialmente para el procesamiento de lenguaje natural, sin embargo, en la actualidad es una herramienta de uso general en diferentes casos de uso o problemas que se pretendan solucionar, así como las imágenes, sonido, aprendizaje reforzado y otros casos en los que los datos de ingreso son de diversos tipos (de la Torre, 2023).

Por otra parte, también están los Vision Transformers (ViT), que representan la implementación de esta arquitectura en problemas de visión por computadora, como la clasificación de imágenes, detección de objetos y segmentación semántica, entre otros. En este

contexto, uno de los aspectos fundamentales es la manipulación de los datos de entrada, lo que implica la adaptación del tokenizador para procesar las imágenes que se desean analizar. Una estrategia propuesta para abordar esto consiste en dividir la imagen en segmentos más pequeños con las mismas dimensiones, permitiendo que la red neuronal reciba cada segmento de manera secuencial (de la Torre, 2023).

A continuación, se representa gráficamente el flujo de *Vision Transformer* en donde el aprendizaje por transferencia ha permitido reutilizar elementos de las redes neuronales convolucionales previamente entrenadas en nuevos modelos (Dosovitskiy, y otros, 2023).

Figura 1. Arquitectura Vision Transformers

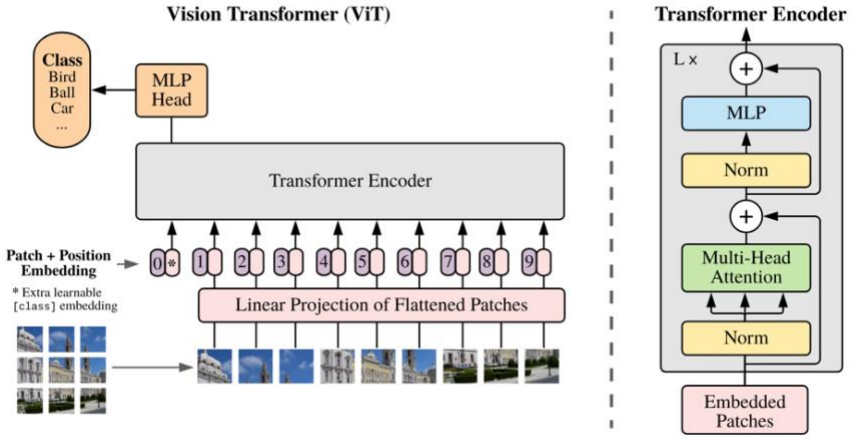

Fuente: Tomado de "AN IMAGE IS WORTH 16X16 WORDS: TRANSFORMERS FOR IMAGE RECOGNITION AT SCALE" (Dosovitskiy, y otros, 2023)

La implementación de este tipo de arquitectura presenta algunas ventajas con respecto a otras, debido a que se logra la reducción en el tiempo de procesamiento, así como el uso de menos recursos computacionales para el entrenamiento de los modelos (Dosovitskiy, y otros, 2023).

En ese orden de ideas, como se mencionó anteriormente, la urbanización es un reto para las sociedades modernas en donde surge la necesidad de hacerle seguimiento a este tipo de dinámicas para realizar una toma de decisiones pertinente a cada uno de los contextos involucrados, de manera que los métodos convencionales dejan de ser efectivos para la

recopilación y procesamiento de los datos que hacen referencia a las imágenes obtenidas por teledetección, en donde se propone utilizar estos datos como la entrada de las redes neuronales con la intención de recuperar la información socioeconómica que se encuentra asociada a una zona específica (Abitbol & Karsai, 2020).

Es así como se ha identificado que existe una relación entre las características socioeconómicas de las personas y el uso de la tierra, lo cual es fundamental incluir esta variable en el momento en el que se quieran identificar patrones socioeconómicos en un territorio y para ello deberán considerarse algunos aspectos como los principales generadores de dichas dinámicas, como lo es el lugar de trabajo, ubicación de centros educativos, zonas comerciales e instalaciones recreativas (Mirmoghtadaee, 2011). Identificar este tipo de grupos en diferentes ciudades, permite dimensionar el impacto que tienen ciertas características relativas a las dinámicas del desarrollo económico y social en el ámbito urbano, del medio ambiente y la sostenibilidad (Dos Santos, y otros, 2023).

Ahora bien, las imágenes satelitales son una fuente de información que permite identificar algunas de las características socioeconómicas, comerciales, entre otras; que de manera conjunta se logran percibir correlaciones entre algunos patrones visuales de las imágenes y los contextos sociales. Para este tipo de estudios relacionados con el análisis de patrones visuales se han utilizado principalmente redes neuronales convolucionales (CNN por sus siglas en inglés) y regresiones de soporte vectorial (SVR), debido a que son técnicas que se asemejan a la percepción humana (Wang, y otros, 2018). Al mismo tiempo, Abitbol & Karsai (2020) entrenaron un modelo de CNN con la intención de predecir de manera precisa el estado socioeconómico en cada una de las imágenes capturadas y que fueron utilizadas para entrenar el modelo.

El análisis de las imágenes satelitales no solo es relevante en un momento específico en el tiempo para obtener ciertas conclusiones sociodemográficas, sino que también permite monitorear cambios ambientales, gestionar desastres y planificar áreas urbanas de manera eficiente; en donde usualmente estos cambios en el territorio se encuentran asociadas a las actividades antropogénicas que hacen referencia a todo aquello que surge de la interacción de los seres humanos en un espacio determinado (Gomez, White, & Wulder, 2016).

El Segment Anything Model (SAM), desarrollado por Meta AI, es un avance significativo en la visión por computadora, utilizando Vision Transformers (ViT). Estos transformadores han revolucionado el procesamiento de imágenes al aplicar la arquitectura de Transformers, inicialmente diseñada para el procesamiento del lenguaje natural, al ámbito visual (Kirillov, y otros, 2023). SAM emplea un Vision Transformer (ViT-H/16) preentrenado con MAE, adaptado para procesar entradas de alta resolución. Este ViT utiliza atención en ventanas de 14×14 y cuatro bloques de atención global distribuidos uniformemente, produciendo un embebido de la imagen 16 veces más pequeño que la original (Zhang, y otros, 2023b). Esta arquitectura se basa en mecanismos de atención que permiten al modelo enfocarse en diferentes partes de una imagen para comprender mejor su contenido, logrando una generalización excepcional en diversos conjuntos de datos de imágenes sin necesidad de entrenamiento adicional para objetos desconocidos (Prado Osco, y otros, 2023).

La robustez de SAM en la segmentación se debe a su capacidad para identificar y atender características relevantes en la imagen a través de múltiples capas de atención, capturando detalles finos y patrones complejos. Esta capacidad es especialmente valiosa en el análisis de imágenes satelitales, donde los objetos pueden variar considerablemente en escala y apariencia (Kirillov, y otros, 2023). La flexibilidad de los Vision Transformers permite a SAM adaptarse a diversas tareas de segmentación sin modificaciones significativas en su arquitectura, facilitando su aplicación en distintos contextos de visión por computadora (Zhang, y otros, 2023b). Por ejemplo, en el análisis sociodemográfico a partir de imágenes satelitales, SAM puede identificar y segmentar áreas urbanas, agrícolas y naturales, proporcionando información precisa para estudios demográficos, planificación urbana y monitoreo ambiental (Prado Osco, y otros, 2023). Esta integración de técnicas avanzadas de aprendizaje automático con el análisis geoespacial tiene el potencial de mejorar la gestión y comprensión de las ciudades, contribuyendo a un desarrollo urbano más equitativo y sostenible (Kirillov, y otros, 2023).

Es por esto que, la pertinencia del presente proyecto se encuentra relacionado con la efectividad que tiene el uso de imágenes satelitales combinadas con técnicas de aprendizaje automático como las redes neuronales, debido a que la toma de decisiones para abordar

problemáticas sociales con la desigualdad en los ingresos, oportunidades y pobreza que se pueden asociar a la distribución en el territorio, requiere una descripción, un seguimiento constante y efectivo que permita tomar decisiones para la construcción de políticas urbanas que comprendan y contengan el estado real de las condiciones de sus habitantes (Abitbol & Karsai, 2020).

5. Metodología

La metodología que se implementará en este proyecto será *Cross Industry Standard Process for Data Mining (CRISP – DM)*, la cual hace referencia a un modelo que permite desarrollar los diferentes proyectos que se encuentran relacionados con la minería de datos (Galán, 2015). Esta metodología permite identificar las fases del proyecto, así como las tareas correspondientes que deben ejecutarse para lograr el cumplimiento del este, por otro lado, como modelo de proceso ofrece una ruta simplificada del ciclo de vida de los datos dentro de los proyectos relacionados a la minería de datos (IBM, 2021).

Figura 2. Ciclo de la Metodología CRISP - DM

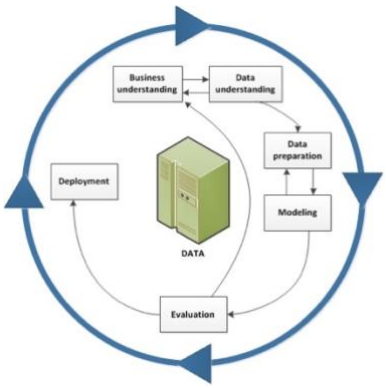

Fuente: Tomado de IBM, 2021

5.1 Entendimiento de los datos

Para esta aplicación se utilizará una imagen satelital como entrada para el modelo pre-entrenado, en donde se utilizó *leafmap* el cual es un paquete de Python que permite realizar un análisis geoespacial a partir de mapas interactivos de código abierto, de modo que esto permite cerrar una brecha con respecto al acceso a dicha información pues diversos softwares de análisis

geoespacial no son de uso libre (Wu Q. , 2021). Este paquete se utilizó para la generación de los datos de entrada que son de tipo no estructurado y que requirió ciertos criterios para la obtención de la imagen satelital de la ciudad de Medellín que se especificarán a continuación,

- **Origen de datos:** Imagen satelital generada con *leafmap* que utiliza mapas de *OpenStreetMap,* una plataforma que está construida por una comunidad de cartógrafos que aportan y mantienen los datos sobre diferentes estructuras y características que componen los mapas alrededor del mundo y puede ser utilizado de manera gratuita (OpenStreetMap, 2022).

- **Tipo de archivo:** En este trabajo se utilizan datos no estructurados. Estos datos no se presentan en un formato tradicional de filas y columnas, sino que están compuestos por unidades estructurales de nivel superior que forman una estructura más compleja y cohesiva (Gomez & Conesa, 2016). El formato implementado es el *Tagged Image File Format (TIFF,* por sus siglas en inglés*),* conocido por su estructura basada en etiquetas que permite almacenar imágenes rasterizadas. Este formato se destaca por su flexibilidad y adaptabilidad, ya que puede manejar imágenes codificadas de alta calidad. Por lo tanto, las imágenes almacenadas en TIFF son de alta resolución y son compatibles con diversos paquetes y software geoespaciales (Federal Agencies Digital Guidelines Iniciative, 2009).

- **Alcaldía de Medellín:** con la finalidad de realizar una comparación entre los resultados del modelo y las zonas geoeconómicas actuales de la ciudad de Medellín, se procedió a la utilización de un archivo brindado por la Alcaldía, en dónde se representan las áreas o espacios geográficos dentro del perímetro urbano, definidos a partir de Zonas Homogéneas Físicas (ZHF) que tienen valores unitarios similares o con diferencias insignificantes en cuanto a su precio, de acuerdo con las condiciones del mercado inmobiliario (Alcaldía de Medellín, 2023).

  La segmentación de las zonas geoeconómicas se encontraba en diferentes formatos para su uso público, en este caso se utilizó el formato '*ShapeFile',* de modo que se pudiera contrastar el resultado del modelo obtenido con la realidad de la ciudad de Medellín. La construcción de esta segmentación se actualiza anualmente e implica visitas de campo para

validar cada zona en las que se realiza un muestreo aproximadamente entre el 1% y el 15% para realizar la construcción de variables estadísticas para generar las conclusiones respectivas por cada zona (Alcaldía de Medellín, 2023). Este es un proceso que toma tiempo e implica validaciones manuales, por lo cual, la implementación de herramientas de aprendizaje automático se vuelve relevante en este contexto, dada la importancia de conocer las transformaciones en el territorio para la toma de decisiones a nivel gubernamental.

- ***Bounding Box (bbox)*:** se define el cuadro delimitador, el cual corresponde a un sistema de coordenadas rectangulares que establece el área geográfica en los mapas que se pretende utilizar (LocationIQ, 2022). En este caso, el cuadro delimitador se configuró de manera que incluyera la cobertura de Medellín, así como su centro,

$$bbox = [-75.6309, 6.1914, -75.5375, 6.2889]$$

$$centro = [6.25184, -75.56359]$$

- **Información de Georreferenciación:** a partir de la imagen definida con las características previamente mencionadas, se obtiene la información geográfica de la imagen para realizar una transformación geográfica con respecto al sistema de coordenadas que se requieren para la aplicación de este trabajo. Por lo tanto, se utiliza la librería para el manejo de imágenes ráster = *rasterio,* la cual permite obtener la información actual para poder realizar la reproyección de la imagen al tipo de coordenadas que se van a contrastar con demás datos.

Por otro lado, la imagen generada cuenta con las siguientes propiedades,

Figura 3. Propiedades de la Imagen Generada

Propiedad	***Resultado***
Ancho	*17.412 metros por pixel*
Altura	*18.284 metros por pixel*
Cantidad de Bandas	*1*
Tipo de Dato	*'uint8'*
Sistema de referencia de Coordenadas	*EPSG: 3857*
Resolución Espacial	*0.597 x 0.597 metros por píxel*

Fuente: Elaboración propia con base en la información obtenida con la biblioteca 'rasterio'.

El tipo de dato *'uint8'*, hace referencia a una representación de un entero sin signo de 8 bits, el cuál puede tomar valores en un rango de 0 a 255, comúnmente utilizado para la representación de pixeles en imágenes en escala de grises y en las bandas RGB, cada valor del píxel se relaciona con los diferentes niveles de intensidad o color del mismo (MathWorks, 2024).

Por otro lado, los sistemas de información geográfica se comprenden como herramientas que facilitan el almacenamiento, la consulta, la manipulación y la representación de datos espaciales. Para este caso se obtiene el sistema de coordenadas 'EPSG = 3857' que corresponde a una proyección *WGS 84 Web Mercator* y hace referencia a un sistema de coordenadas proyectado ampliamente utilizado en mapas web debido a su compatibilidad y eficiencia (de la Fuente, 2020).

5.2 Preparación de los datos

La preparación de los datos es uno de los aspectos claves en los proyectos de ciencia de datos y usualmente es la etapa que toma más tiempo, en la cual se estima que aproximadamente se destina entre el 50% y 70% del tiempo general del proyecto (IBM, 2021). Teniendo en cuenta la alta resolución de la imagen generada, se requiere hacer la partición de la imagen inicial en cuatro (4) submuestras, por lo tanto, se procede con la generación de las *bounding boxes* y de los vértices para posteriormente generar la imagen con cada una de las características establecidas previamente,

- Definición de los vértices de las submuestras,

$$x_{min}, y_{min}, X_{max}, y_{max} = bbox$$
$$x_{mid} = (x_{min} + x_{max})/2$$
$$y_{mid} = (y_{min} + y_{max})/2$$

- Definición de las *bounding boxes* de las submuestras,

$$bbox_1 = x_{min}, y_{mid}, X_{mid}, y_{max}$$
$$bbox_2 = x_{mid}, y_{mid}, X_{max}, y_{max}$$
$$bbox_3 = x_{min}, y_{min}, X_{mid}, y_{mid}$$
$$bbox_4 = x_{mid}, y_{min}, X_{max}, y_{mid}$$

A partir de la definición de las coordenadas de cada una de las submuestras se procede a la generación de las imágenes por medio del paquete de *samgeo* (Segment-geospatial, 2024), en donde se implementan cada una de las bounding boxes previamente definidas para finalmente obtener las submuestras mostradas a continuación,

Figura 4. Submuestras generadas

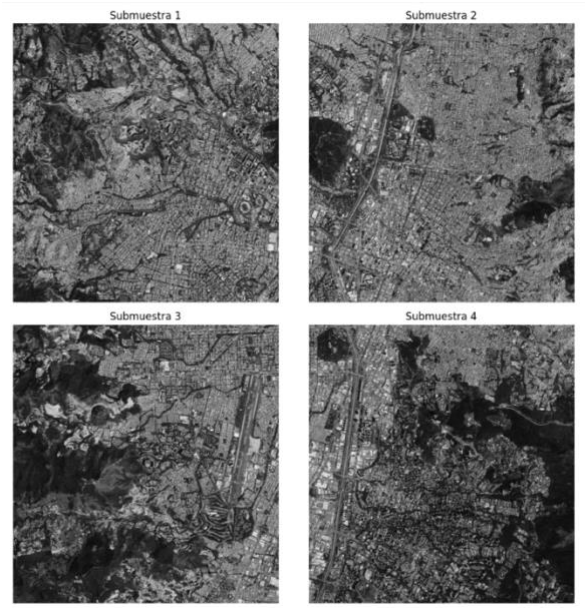

Fuente: Elaboración propia con base en las imágenes generadas con 'samgeo'

El procesamiento de las imágenes aumenta la capacidad de analizar las imágenes donde se adquiere más información para resolver problemas específicos. Esta etapa se basa en destacar o realzar elementos o características de la imagen que sean relevantes (Bustamante, 2014). De manera que, esta etapa se convierte en un aspecto relevante antes de realizar la implementación de los diferentes algoritmos de ciencia de datos, debido a que en la medida en la que se va mejorando el input que se le entregará a dichos algoritmos, se espera que a la vez los resultados sean acertados en su respuesta, así como una mejor interpretabilidad de los mismos.

Para este proyecto se planteó el procesamiento de la imagen por medio del ajuste de la intensidad de los colores de cada uno de los pixeles, lo cual se hace a partir del histograma que representa la distribución de las intensidades (Taquía, 2017).

5.3 Ecualización del histograma

El principal objetivo de la ecualización del histograma es ampliar el rango dinámico de los niveles de gris para resaltar el contraste visual de la imagen (Depaoli, Fernandez, & Diaz, 2005). Es decir, lo que se quiere lograr por medio de esta ecualización es obtener un histograma con una distribución más amplia entre el rango (0, 255) que compone el tipo de dato que se está utilizando en el proyecto.

5.4 Modelo Implementado

Una vez realizada la ecualización del histograma de la imagen satelital, se realizó el siguiente paso a paso para aplicar un modelo preentrenado a las cuatro (4) submuestras,

Figura 5. Flujo de la generación de las máscaras

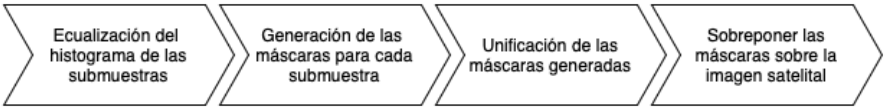

Fuente: Elaboración propia

Para la segmentación propuesta en la ciudad de Medellín, se propuso la aplicación del modelo SAM con la intención de revisar la segmentación realizada por el modelo. Para desarrollar esta etapa se definieron los siguientes parámetros,

Figura 6. Parámetros

Nombre del Parámetro	***Parámetro Inicial***
Model_type	*vit_h'*

Nombre del Parámetro	***Parámetros Finales***
Checkpoint	*"sam_vit_h_4b8939.pth"*
Model_type	*vit_h'*
Erosion_kernel	*(5, 5)*
Mask_multiplier	*100*

Fuente: Elaboración propia

Los parámetros que se implementaron tienen las siguientes características (Segment-geospatial, 2024),

a) *Checkpoint:* teniendo en cuenta que es un modelo preentrenado, por medio de este parámetro se le entrega la ruta en donde se encuentra alojado el modelo para ser implementado.
b) *Model_type:* corresponde al tipo de modelo, que en este caso corresponde al *Vision Transformer.*
c) *Erosion_kernel:* por medio de este parámetro se realiza la identificación de los bordes que componen la imagen para la generación de las máscaras y recibe una tupla como se mostró en la *Figura 8.*
d) *Mask_multiplier:* permite controlar la intensidad de la segmentación para que sea más general o específica entre las imágenes que recibe el modelo. El rango en este parámetro es el siguiente: [0, 255]. Entre menor sea el valor, hará que la segmentación sea más general.

Dentro de los parámetros mencionados anteriormente, se puede resaltar el impacto de *erosion_kernel* y *mask_multiplier,* debido a que estos son parámetros de *fine tunning* para mejorar la calidad de la segmentación generada. Debe tenerse presente que el de *fine tunning* es un proceso mediante el cual se adapta un modelo preentrenado para realizar ciertas tareas o simplemente implementarlo, también hace parte de la técnica más amplia del aprendizaje por transferencia: que hace referencia a la práctica de aprovechar los conocimientos que un modelo existente ya ha aprendido como punto de partida para aprender nuevas tareas (Bergmann, 2024).

Una vez fue importado el modelo, se realizó la generación de las máscaras de segmentación para cada una de las submuestras previamente mencionadas para finalmente realizar la unificación de las máscaras que ya se revisará en el posprocesamiento.

5.5 Posprocesamiento

Es habitual que los modelos que utilizan imágenes como entrada necesiten un paso adicional después de su implementación para refinar los resultados. En este estudio, se combinaron las máscaras generadas por el modelo para cada submuestra de la imagen original. Este paso es crucial para asegurar una integración coherente y precisa de las diferentes partes segmentadas. Una vez combinadas las máscaras, se realizó una superposición de estas sobre la imagen satelital generada inicialmente. Esta superposición permite visualizar claramente las áreas segmentadas dentro del contexto completo de la imagen, facilitando así un análisis más detallado y preciso de los patrones y características identificadas en el territorio estudiado.

6. Resultados

En esta sección se presentan los hallazgos derivados de la implementación del modelo SAMGeo para la segmentación de imágenes satelitales de la ciudad de Medellín. Los resultados obtenidos son fundamentales para comprender la distribución espacial y socioeconómica de la población, así como para evaluar el impacto de la topografía en estos aspectos.

Inicialmente, se expone el proceso de generación y preparación de las imágenes satelitales, incluyendo la subdivisión de la imagen original en cuatro submuestras y su posterior procesamiento mediante técnicas de ecualización de histograma para mejorar la calidad visual y la precisión del análisis. Seguidamente, se describen los resultados de la segmentación obtenidos a partir del modelo SAMGeo, destacando la precisión y efectividad del modelo en la identificación de patrones espaciales.

Además, se presenta una comparación visual entre las imágenes originales y las segmentadas, así como un análisis de los histogramas de las imágenes antes y después de la ecualización, lo que permite una evaluación exhaustiva de la mejora en la calidad de las imágenes y la precisión de la segmentación. Finalmente, se discuten las implicaciones de estos resultados en el contexto de la planificación urbana y la formulación de políticas públicas, subrayando la importancia de utilizar técnicas avanzadas de inteligencia artificial y procesamiento de imágenes en el análisis de datos geoespaciales.

6.1 Ecualización de la Imagen

En la preparación de los datos se implementó la ecualización de la imagen y a continuación se muestra el histograma de la imagen original contrastada con el histograma ecualizado,

Figura 7. Histograma de las imágenes

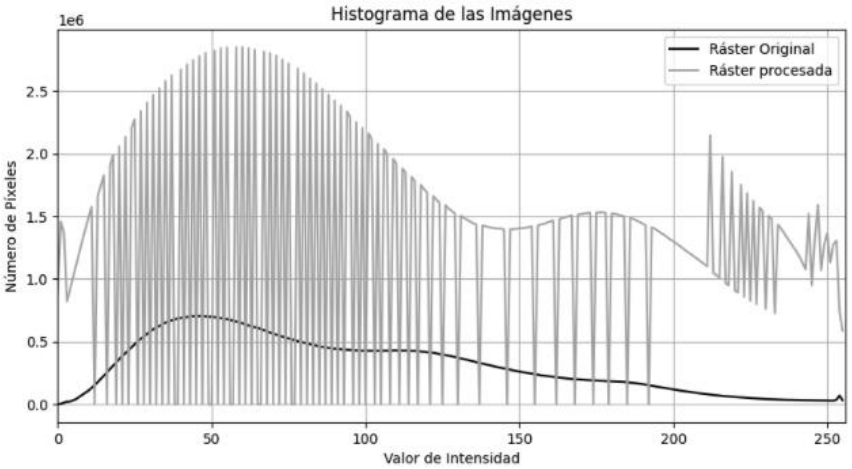

Fuente: Elaboración propia

Con respecto al histograma, se puede observar una ampliación del rango dinámico en su distribución. Ahora bien, a continuación, se muestra las imágenes que resultan a partir de este procesamiento realizado con respecto al histograma,

Figura 8. Submuestras con el histograma ecualizado

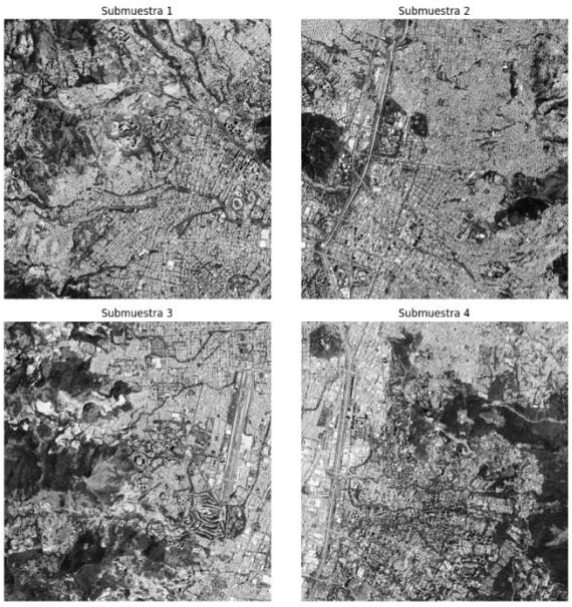

Fuente: Elaboración propia

Considerando la función de la ecualización del histograma se puede apreciar que esta técnica acentúa las diferencias entre áreas claras y oscuras, mejorando notablemente la percepción visual. Este proceso es útil para identificar características geográficas y urbanas, resalta detalles que podrían no verse en la imagen original.

Al comparar la imagen original con la ecualizada, se observa una clara mejora en la calidad visual. La ecualización del histograma permite que los contrastes dentro de la imagen sean más marcados, lo que facilita la interpretación de los datos. Esta mejora en la claridad visual puede ser crucial para el análisis y la toma de decisiones, ya que proporciona una mejor comprensión de las características presentes en la imagen, como la topografía del terreno y la distribución de áreas

urbanas. En resumen, la ecualización del histograma no solo mejora la apariencia de la imagen, sino que también aumenta su utilidad para el análisis geoespacial y urbano.

Figura 9. Contraste de imagen original versus la imagen ecualizada

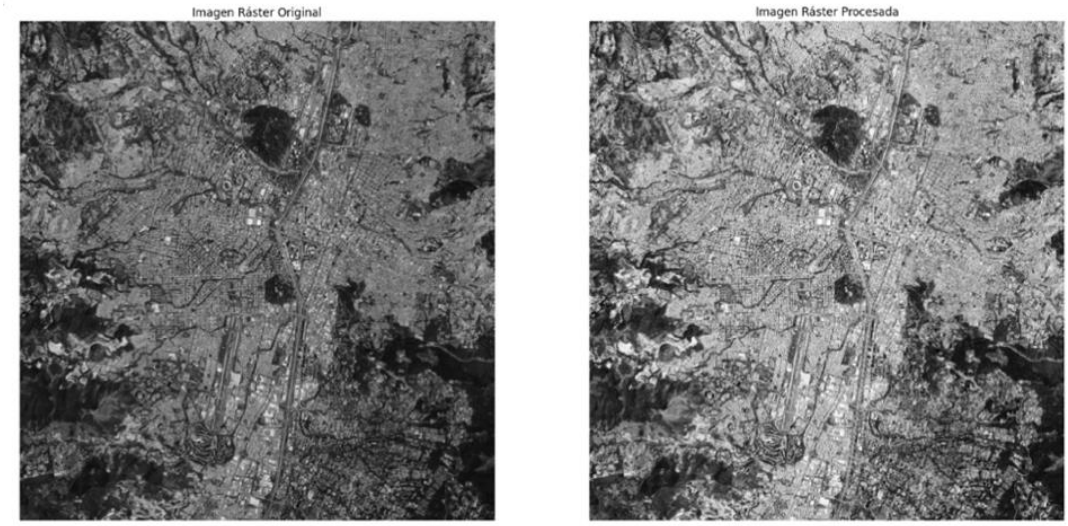

Fuente: Elaboración propia

6.2 Resultados del Modelo

En relación con la selección de parámetros, se realizó una segmentación inicial que reveló ciertas limitaciones en la configuración del modelo. Los parámetros originalmente definidos no lograban una segmentación adecuada, ya que capturaban únicamente puntos muy específicos del mapa. Este comportamiento sugiere que los parámetros no eran suficientemente amplios o precisos para identificar de manera efectiva las regiones de interés.

A continuación, se muestra esta segmentación inicial, donde se pueden observar las áreas específicas que fueron capturadas y cómo esto refleja la necesidad de ajustar los parámetros para mejorar la calidad de la segmentación.

Figura 10. Máscara generada con el modelo inicial

Fuente: Elaboración propia

Como se mencionó previamente, los parámetros iniciales estaban produciendo segmentaciones demasiado específicas que no se ajustaban al objetivo del proyecto. Por esta razón, se realizaron ajustes utilizando los parámetros previamente descritos. Seguidamente, se presenta el resultado obtenido con los parámetros ajustados y se compara con la información proporcionada por la Alcaldía. En esta comparación, se utiliza como base la imagen generada y se superpone el *'ShapeFile'* generado tanto por el modelo como por el ente territorial,

Figura 11. Segmentación Obtenida vs. Segmentación Alcaldía

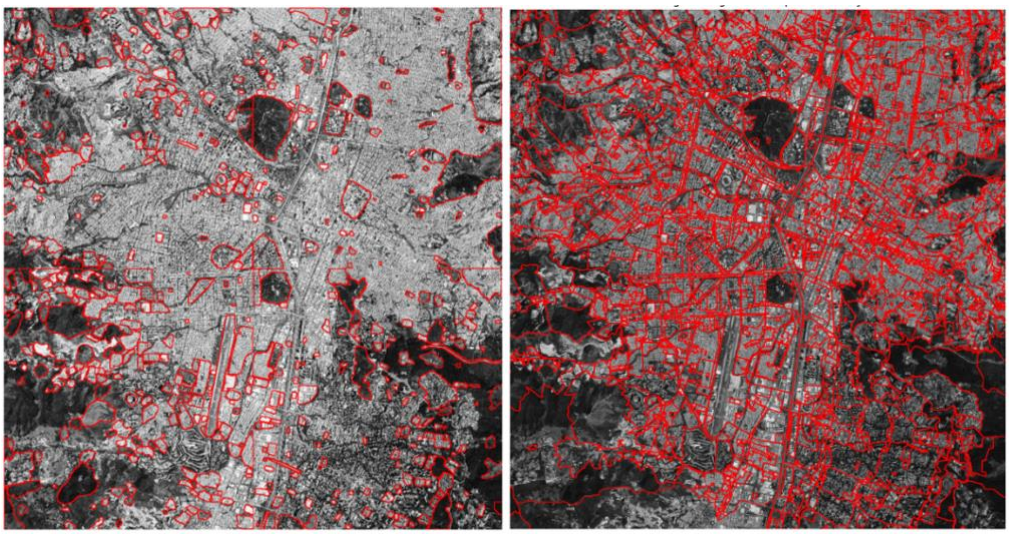

Fuente: Elaboración propia con base en los resultados del modelo (izquierda) y los datos de la Alcaldía (derecha) (Alcaldía de Medellín, 2023).

Se puede observar en la segmentación obtenida del modelo, hay varias zonas que no fueron segmentadas en comparación con la segmentación realizada por la Alcaldía, a pesar de los ajustes de parámetros realizados. Sin embargo, es importante destacar que algunas de las áreas segmentadas por el modelo presentan una notable similitud con la segmentación proporcionada por el ente territorial. A continuación, se presenta un análisis detallado de estos resultados y su relación con diferentes condiciones socioeconómicas de la ciudad.

Figura 12. Comparación de Resultados

Ubicación	***Resultado del Modelo***	***Segmentación Alcaldía***
Parque Natural Cerro El Volador & Universidad de Antioquia		
Aeropuerto Olaya Herrera		

Universidad Pontificia Bolivariana & Cerro Nutibara	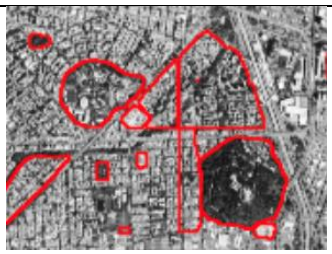	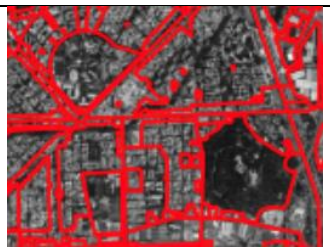
Estadio de Fútbol Atanasio Girardot	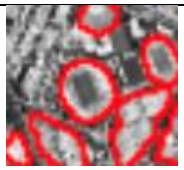	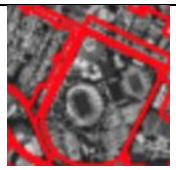
Comuna 1 & Comuna 3 (Sector Nororiental)	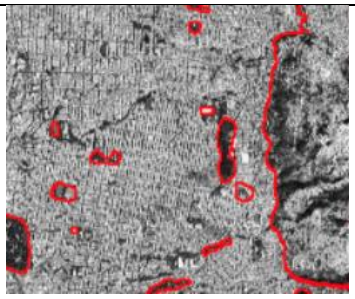	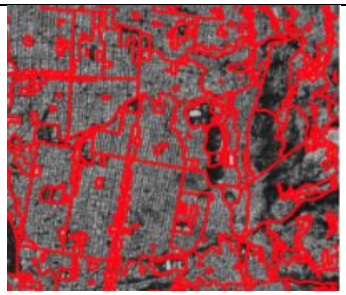

Fuente: Elaboración propia

6.3 Análisis de los Resultados del Modelo

- **Universidades:** La segmentación de una universidad por el modelo subraya la importancia de las instituciones educativas en la configuración de las dinámicas urbanas y socioeconómicas. Las universidades atraen a una gran población estudiantil y de personal académico, lo que genera una demanda considerable de servicios de vivienda, alimentación, transporte y entretenimiento. Además, las áreas alrededor de las universidades tienden a beneficiarse de un ambiente diverso, y pueden convertirse en centros de innovación y desarrollo económico. La presencia de una universidad también puede elevar el perfil socioeconómico de la zona, atrayendo inversiones y mejorando las infraestructuras locales.

- **Aeropuerto:** Esta segmentación es relevante, ya que el aeropuerto es una infraestructura crítica que tiene un impacto considerable en la economía local. Las áreas cercanas a los aeropuertos suelen experimentar un desarrollo significativo debido a la demanda de servicios relacionados con el transporte aéreo, como hoteles, restaurantes y centros

comerciales. Este desarrollo puede llevar a un aumento en los precios de la propiedad y a cambios en la composición demográfica, creando tanto oportunidades como desafíos para las comunidades locales.

- **Cerros:** Estos cerros no solo son características topográficas prominentes, sino que también influyen en las dinámicas socioeconómicas de las áreas circundantes. Por ejemplo, los cerros a menudo demarcan límites naturales que afectan la distribución de la población y el desarrollo urbano. En muchas ciudades, las zonas elevadas pueden estar asociadas con áreas de menor densidad poblacional debido a la dificultad de construcción y acceso. Sin embargo, en algunos casos, estas áreas también pueden albergar comunidades con menores recursos, afectadas por el difícil acceso a servicios y oportunidades.

- **Sector Nororiental:** en esta parte del mapa se puede identificar que al ser una zona homogénea no está segmentando de manera pertinente debido a que no se evidencia un patrón predominante y el modelo no lo segmenta. Partiendo de la información socioeconómica

Al comparar los resultados del modelo con la segmentación de la Alcaldía de Medellín, se observa que, aunque el modelo no segmentó todas las áreas, en las zonas que sí segmentó, hay una notable coincidencia con la segmentación oficial. Esta coincidencia sugiere que, a pesar de las limitaciones del modelo, su capacidad para identificar áreas clave es prometedora. La segmentación precisa de áreas como los cerros, el aeropuerto y la universidad, indica que el modelo puede capturar características socioeconómicas importantes que son relevantes para el análisis urbano y la planificación.

Aunque el modelo de segmentación presenta ciertas limitaciones, sus resultados son valiosos para entender las dinámicas socioeconómicas de Medellín. La segmentación de áreas significativas como los cerros, el aeropuerto y una universidad demuestra que el modelo es una herramienta útil para el análisis y la toma de decisiones en la planificación urbana y la gestión de recursos. La integración de técnicas de aprendizaje automático con el análisis geoespacial tiene el potencial de mejorar la comprensión y gestión de las ciudades, contribuyendo así a un desarrollo urbano más equitativo y sostenible. La falta de segmentación precisa en algunas zonas destaca la

necesidad de ajustar y mejorar el modelo para capturar de manera más efectiva las diversas realidades socioeconómicas de la ciudad.

7. Conclusiones

Por último, el avance de las tecnologías de análisis de datos y procesamiento de imágenes ha permitido nuevas formas de estudiar y entender las dinámicas urbanas y socioeconómicas en las ciudades. La utilización de modelos avanzados de aprendizaje automático, como el Segment Anything Model (SAM), ofrece un enfoque innovador para la segmentación y análisis de imágenes satelitales que se puede extrapolar al área de las ciencias sociales. A través de la recopilación, procesamiento y análisis de imágenes satelitales, se buscó proporcionar una segmentación que permitiera identificar patrones claves dentro de la distribución de la población de tal forma que facilitara la planificación urbana y la toma de decisiones por parte de las entidades gubernamentales locales. De manera más específica y abordando los objetivos del presente estudio se llega a lo siguiente,

- Recopilación y Procesamiento de Imágenes Satelitales: en esta etapa se identificó que las imágenes satelitales cuentan con diversas restricciones con respecto a su acceso y manejo, sin embargo, gracias a la implementación de librerías abiertas de Python como *leafmap*, fue posible la generación de la imagen satelital de Medellín. Posteriormente el uso de técnicas de preprocesamiento, como la ecualización del histograma, mejoró la calidad visual de las imágenes y facilitó la identificación de características geográficas y urbanas. Esto demuestra la importancia de una preparación exhaustiva de las imágenes para la obtención de una segmentación contextual que se asemeje a las condiciones reales de la población. Lo anterior, lleva a que el manejo de imágenes en ciencia de datos requiera un preprocesamiento y también posprocesamiento alineado con las necesidades de cada proyecto en cuestión. De tal modo que, se pueda obtener valor agregado en el resultado y los hallazgos del proyecto.

- Identificación de Patrones Socioeconómicos: El objetivo principal de este estudio fue identificar patrones socioeconómicos en Medellín utilizando un modelo de redes

neuronales aplicado al análisis de imágenes satelitales. Los resultados indican que, aunque el modelo presentó limitaciones en la segmentación de todas las áreas de la ciudad, logró identificar zonas clave como los cerros, el aeropuerto y universidades, reflejando patrones socioeconómicos significativos dentro de la distribución de la población que representan actividades económicas y sociales claves en el desarrollo de la sociedad.

- Implementación y Validación del Modelo: Estas segmentaciones reflejan las dinámicas urbanas y socioeconómicas, evidenciando el potencial de la arquitectura de *Vision Transformer* para el análisis geoespacial. La validación externa de los resultados, utilizando datos socioeconómicos de la Alcaldía de Medellín, mostró una notable coincidencia en ciertas áreas, lo que valida la pertinencia del modelo con respecto a la posible sugerencia de las políticas públicas para la toma de decisiones acertadas y coherentes con las necesidades de la población.

- Desafíos y Futuras Mejoras: Aunque el modelo presentó ciertos desafíos, como la segmentación precisa de todas las áreas y la necesidad de ajustes en los parámetros, los resultados obtenidos son prometedores. Las áreas que no fueron bien segmentadas, especialmente en la zona nororiental de Medellín, indican la necesidad de mejorar el modelo para capturar de manera más efectiva las diversas realidades socioeconómicas de la ciudad. Las zonas de estratos socioeconómicos bajos que no fueron bien segmentadas destacan la importancia de adaptar el modelo a las características específicas de cada área urbana. Con respecto a los trabajos futuros, se identificó que este proyecto permite realizar análisis de series de tiempo en donde las imágenes se utilicen como insumo para evaluar las transformaciones topográficas en el territorio que pueden responder a algunos fenómenos medioambientales. Lo cuál también estaría enfocado en brindar herramientas para la definición de políticas públicas no solo económicas y sociales, sino también políticas medioambientales que le apunten a un desarrollo integral.

En resumen, este estudio ha demostrado que el uso de redes neuronales para el análisis de imágenes satelitales puede ser una herramienta valiosa para identificar patrones socioeconómicos y apoyar la planificación urbana en Medellín. Aunque se requiere un mayor refinamiento del

modelo, los resultados obtenidos son una base sólida para futuras investigaciones y aplicaciones en el campo del análisis geoespacial que puedan sugerir.

Repositorio *GitHub*

En el siguiente link podrán acceder al código implementado para la elaboración de este proyecto: ProyectoImágenesSatelitalesMedellín

Referencias Bibliográficas

Gobernación de Antioquia. (08 de Septiembre de 2023). *Los turistas extranjeros potenciaron el turismo en Antioquia en el primer semestre de 2023*. Obtenido de Website Gobernación de Antioquia: https://antioquia.gov.co/prensa/historico-de-prensa-2/19280-los-turistas-extranjeros-potenciaron-el-turismo-en-antioquia-en-el-primer-semestre-de-2023

Concejo de Medellín. (21 de Abril de 2023). *La gentrificación y la turistificación desplazan ciudadanos de Medellín*. Obtenido de Website Concejo de Medellín: https://www.concejodemedellin.gov.co/es/La%20gentrificación%20y%20la%20turistificación%20desplazan%20ciudadanos%20de%20Medellín?language_content_entity=es

Bottino , R. (2009). La ciudad y la urbanización. *Centro de Documentación Histórica del Río de la Plata*, 1-14.

Centro de Investigación sobre Dinámica Social. (2007). *Ciudad, espacio y población: el proceso de urbanización en Colombia.* Bogotá: UNFPA.

Yahoo Finance. (20 de March de 2023). *The global board games market is expected to grow at a CAGR of 13.27% from 2022 to 2028*. Obtenido de Yahoo Finance: https://finance.yahoo.com/news/global-board-games-market-expected-153000943.html?guccounter=1&guce_referrer=aHR0cHM6Ly93d3cuZ29vZ2xlLmNvbS8&guce_referrer_sig=AQAAAC--ySB096DV0siYAEAoF3Q-jlwRPDb7oN7kHq5V3CSK_VgFE5jh-wO_uhprIr_D02bLqq48RssYo4n5owHXaSu9-sUOS

United Nations. (16 de May de 2018). *Department of Economic and Social Affairs*. Obtenido de 2018 Revision of World Urbanization Prospects: https://www.un.org/en/desa/2018-revision-world-urbanization-prospects#:~:text=Today%2C%20the%20most%20urbanized%20regions,Asia%20is%20now%20approximating%2050%25.

Instituto Geográfico Nacional. (2020). Teledetección. *Centro Nacional de Información Geográfica*, 6.

Wu, Y.-c., & Feng, J.-w. (2017). Development and Application of Artificial Neural Network. *Springer*, 12.

Morel, B. (2000). Biologically plausible learning rules for neural networks and quantum computing. *Elsevier*, 921-926.

Guresen, E., & Kayakutlu, G. (2010). Definition of artificial neural networks with comparison to other networks. *Procedia Computer Science*, 426-433.

Galán, V. (Octubre de 2015). *APLICACIÓN DE LA METODOLOGÍA CRISP-DM A UN PROYECTO DE MINERÍA DE DATOS EN EL ENTORNO UNIVERSITARIO.* Obtenido de Universidad Carlos III de Madrid: https://e-archivo.uc3m.es/bitstream/handle/10016/22198/PFC_Victor_Galan_Cortina.pdf

IBM. (17 de Agosto de 2021). *Conceptos básicos de ayuda de CRISP-DM*. Obtenido de IBM: https://www.ibm.com/docs/es/spss-modeler/saas?topic=dm-crisp-help-overview

QGIS. (2023). *Un Sistema de Información Geográfica libre y de Código Abierto*. Obtenido de QGIS: https://qgis.org/es/site/

Sun, L., Liang, F., & Cui, W. (2021). Artificial Neural Network and Its Application Research Progress in Chemical Process. *Asian Journal of Research in Computer Science*, 177-185.

Abitbol, J. L., & Karsai, M. (2020). Socioeconomic correlations of urban patterns inferred from aerial images: interpreting activation maps of Convolutional Neural Networks. *arXiv*, 19.

Mirmoghtadaee, M. (2011). The relationship between land use, socio-economic characteristics of inhabitants and travel demand in new towns - a case of study of Hashtgerd New Town (Iran). *International Journal of Urban Sustainable Development*, 39-62.

Dos Santos, G. F., Vives, A., Fuentes, M., de Sousa, J. F., Sancho, A., Useche, A. F., . . . Diez-Roux, A. V. (2023). Socioeconomic Urban Environment in Latin America: Towards a Typology of Cities. *Sustainability*, 1-16.

Wang, W., Yang, S., He, Z., Wang, M., Zhang, J., & Zhang, W. (2018). Urban Perception of Commercial Activeness from Satellite Images and Streetscapes. *International World Wide Web Conference Committee*, 647-654.

DANE. (2018). *Resultados Censo Nacional de Población y Vivienda 2018*. Obtenido de DANE: https://www.dane.gov.co/index.php/estadisticas-por-tema/demografia-y-poblacion/censo-nacional-de-poblacion-y-vivenda-2018

Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., . . . Houlsby, N. (2023). AN IMAGE IS WORTH 16X16 WORDS: TRANSFORMERS FOR IMAGE RECOGNITION AT SCALE. *arXiv*, 22.

de la Torre, J. (2023). Transformadores: Fundamentos Teóricos y Aplciaciones. *ArXiv*, 36.

Wu, Q. (2021). Leafmap: A Python package for interactive mapping and geospatial analysis with minimal coding in a Jupyter environment. *The Journal of Open Source Software*, 4.

LocationIQ. (2022). *Cuadro Delimitador*. Obtenido de LocationIQ: https://es.locationiq.com/glossary/bounding-box

OpenStreetMap. (27 de Marzo de 2022). *OpenStreetMap provides map data for thousands of websites, mobile apps, and hardware devices*. Obtenido de OpenStreetMap: https://www.openstreetmap.org/about

Gomez, J. L., & Conesa, J. (2016). Introducción al big data. Catalunya, España.

Federal Agencies Digital Guidelines Iniciative. (10 de Febrero de 2009). *Guidelines for TIFF Metadata Recommended Elements and Format*. Obtenido de Federal Agencies Digital Guidelines Iniciative: https://www.digitizationguidelines.gov/guidelines/TIFF_Metadata_Final.pdf

MathWorks. (2024). *MathWorks*. Obtenido de Imágenes de 8 y 16 bits: https://es.mathworks.com/help/matlab/creating_plots/working-with-8-bit-and-16-bit-images.html

de la Fuente, C. (2020). Guía práctica para la publicación de Datos Espaciales. España.

Segment-geospatial. (2024). *Segment-geospatial*. Obtenido de Welcome to samgeo: https://samgeo.gishub.org

Bustamante, S.-H. Y. (Marzo de 2014). ALGORITMOS DE PROCESAMIENTO DE IMAGEN APLICADOS A LA DETECCIÓN DE FIGURAS GEOMETRICAS Y SUS PROPIEDADES ESPACIALES. Valparaíso, Chile. Obtenido de http://opac.pucv.cl/pucv_txt/txt-4500/UCE4968_01.pdf

Taquía, J. A. (2017). El procesamiento de imágenes y su potencial aplicación en empresas con estrategia digital. *Dialnet*, 20.

Depaoli, R., Fernandez, L. A., & Diaz, D. (2005). *Optimización de la ecualización del histograma en el procesamiento de imágenes digitales.* Obtenido de Universidad Nacional de La Matanza: http://sedici.unlp.edu.ar/bitstream/handle/10915/21082/51.pdf?sequence=1

Prado Osco, L., Wu, Q., Lopes de Lemos, E., Nunes Gonçalves, W., Marques Ramos, A. P., Li, J., & Marcato Junior, J. (2023). The Segment Anything Model (SAM) for remote sensing applications: From zero to one shot. *Elsevier*, 18.

Gomez, C., White, J. C., & Wulder, M. A. (2016). Optical remotely sensed time series data for land cover classification: A review. *Elsevier*, 55-72.

Bergmann, D. (15 de Marzo de 2024). *What is fine-tuning?* Obtenido de IBM: https://www.ibm.com/topics/fine-tuning

Alcaldía de Medellín. (01 de Diciembre de 2023). *Zonas Geoeconómicas -ZGE-*. Obtenido de GeoMedellín: https://www.medellin.gov.co/geomedellin/datosAbiertos/1041

Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., . . . Girshick, R. (2023). Segment Anything. *arXiv*, 1-30.

Zhang, C., Puspitasari, F. D., Zheng, S., Li, C., Quiao, Y., Kang, T., . . . Hong, C. S. (2023b). A Survey on Segment Anything Model (SAM): Vision Foundation Model Meets Prompt Engineering. *ResearchGate*, 1-20.

Valdes Avila, L. S., & Baquero Vanegas, J. M. (16 de junio de 2019). Deep Learning aplicado a imágenes satelitales como herramienta de detección de viviendas sin servicio de energía en el caserío Media Luna-Uribia-Guajira. *Deep Learning aplicado a imágenes satelitales como herramienta de detección de viviendas sin servicio de energía en el caserío Media Luna-Uribia-Guajira*. Bogotá, Cundinamarca, Colombia: Repositorio Institucional Universidad Distrital Francisco José de Caldas.

Vaca Proaño, V. G., Lopez Rueda, C. P., Llorca Vega, N. A., & Ferreras Cid, E. (2023). PATRONES SOCIALES Y ESPACIALES: ESTUDIO COMPARATIVO ENTRE DOS ESPACIOS PÚBLICOS EN LA CIUDAD DE QUITO, ECUADOR. *Revista Urbano N° 47*, 96-106.