

Evaluación De Técnicas SIG En La Estimación De Cambios De Cobertura Y Salud De La Vegetación De Purificación Tolima.

Yulian Leonardo González Larrarte

Universidad de Manizales
Facultad de Ciencias e Ingeniería
Maestría en Tecnologías de la Información Geográfica
Manizales, 2024

Evaluación De Técnicas SIG En La Estimación De Cambios De Cobertura Y Salud De La Vegetación De Purificación Tolima.

Yulian Leonardo González Larrarte

Propuesta de trabajo de grado presentado como requisito parcial para optar al título de Magíster en Tecnologías de la Información Geográfica

Director (a):

PhD en Ingeniería - Automática. Manuel Alejandro Tamayo Monsalve

Línea de Investigación:

Universidad de Manizales
Facultad de Ciencias e Ingeniería
Maestría en Tecnologías de la Información Geográfica
Manizales, 2024

Tabla de Contenido

Tabla de Contenido	3
Ilustraciones	5
Tablas	7
1 Resumen	9
2 Abstract	10
3 Introducción	11
4 Planteamiento del problema de investigación	14
4.1 Descripción del área problemática	14
4.2 Formulación del problema	16
5 Justificación	17
6 Antecedentes	18
7 Objetivos	29
7.1 Objetivo general	29
7.2 Objetivos específicos.....	29
8 Referente Contextual	30
9 Referente teórico	32
9.1 Importancia de los árboles:.....	32
9.2 Proteger la biodiversidad:	32
9.3 Crecimiento Poblacional:	33
9.4 Índices de Vegetación:	34
9.5 Fotogrametría y Teledetección:	34
9.6 Técnicas de Aprendizaje Profundo:.....	35
9.7 Sistemas de Información Geográfica (SIG):.....	35
9.8 Análisis Multitemporal y Comparativo:	36
9.9 Red GNSS:	36
10 Hipótesis de investigación	40
10.1 Base Tecnológica y Fundamentos Científicos:	40
10.2 Impacto del Cambio Climático:.....	40
10.3 Utilidad Práctica y Aplicaciones Futuras:.....	41
10.4 Conclusión Hipotética:.....	41
11 Metodología	43
11.1 Planeación de Vuelo.....	44
11.2 Reconocimiento del área	44
11.3 Marcación de puntos de control terrestre	45

11.4	Método de posicionamiento relativo estático	47
11.5	Cálculo del GSD y la cobertura del terreno	48
11.6	Captura de imágenes	49
11.7	Procesamiento y ajuste Fotogramétrico	50
11.8	Clasificación supervisada	53
11.8.1	Máxima verosimilitud	54
11.8.2	Evaluación de la exactitud en la clasificación de imágenes.....	55
11.9	Estimación de la salud de la vegetación.....	56
11.10	Implementación del modelo Tree Detection.....	57
	Ilustración 10 <i>Parámetros del modelo</i>	58
12	Resultados	61
12.1	Resultado del objetivo específico N°1	62
12.2	Resultado del objetivo específico N°2.....	68
12.3	Resultado del objetivo específico N°3.....	73
12.4	Resultado del objetivo específico N°4.....	83
13	Conclusiones	88
14	Referencias Bibliográficas	90

Ilustraciones

Ilustración 1 <i>Mapa conceptual</i>	43
Ilustración 2 <i>Ubicación de puntos de control</i>	46
Ilustración 3 <i>Marcación de dianas</i>	46
Ilustración 4 <i>Parámetros de vuelo en programa DJI PILOT 2</i>	50
Ilustración 5 <i>Ubicación y cobertura de fotografías</i>	51
Ilustración 6 <i>Ajuste de puntos de control</i>	52
Ilustración 7 <i>ModelBuilder Clasificación Supervisada</i>	55
Ilustración 8 <i>Matriz de Confusión Clasificación 2018</i>	56
Ilustración 9 <i>Matriz de Confusión Clasificación 2023</i>	56
Ilustración 10 <i>Parámetros del modelo</i>	58
Ilustración 11 <i>ModelBuilder modelo Tree Detection</i>	59
Ilustración 12 <i>Método padding</i>	60
Ilustración 13 <i>Clasificación Supervisada Imagen 2018</i>	65
Ilustración 14 <i>Clasificación Supervisada Imagen 2023</i>	66
Ilustración 15 <i>Estadísticas Clasificación Supervisada Imagen 2018</i>	66
Ilustración 16 <i>Estadísticas Clasificación Supervisada Imagen 2023</i>	67
Ilustración 17 <i>Creación de Urbanizaciones Entrada al municipio por Saldaña</i>	70
Ilustración 18 <i>Ampliación de Urbanizaciones Barrio Ospina Pérez sector 1</i>	70
Ilustración 19 <i>Aumento de zonas boscosas Barrio Ospina Pérez sector 2</i>	71
Ilustración 20 <i>Aumento de zonas boscosas sector Planta de Tratamiento de Agua Residual</i>	71
Ilustración 21 <i>Construcción de vías en pavimento urbanización el Triunfo</i>	72
Ilustración 22 <i>Construcción de vías en pavimento urbanización Villa del Carmen</i>	72

Ilustración 23 <i>Resultado VARI</i>	73
Ilustración 24 <i>Resultado Índice NDVI</i>	74
Ilustración 25 <i>Resultado NVDER</i>	75
Ilustración 26 <i>Resultado ARVI</i>	76
Ilustración 27 <i>Resultado OSAVI</i>	77
Ilustración 28 <i>Resultado GNDVI</i>	78
Ilustración 29 <i>Resultado ReCI</i>	79
Ilustración 30 <i>Resultado VARI</i>	80
Ilustración 31 <i>Imágenes de resultados índices VARI y NVDI</i>	82
Ilustración 32 <i>Resultado del modelo</i>	85
Ilustración 33 <i>Resultado de modelo Tree Detection</i>	86
Ilustración 34 <i>Identificación de especies arboreas</i>	86
Ilustración 35 <i>Salud de las especies arboreas</i>	87

Tablas

Tabla 1 <i>Parámetros Geodésicos</i>	38
Tabla 2 <i>Resultados y Productos de la investigación</i>	61
Tabla 3 <i>Descripción de estructuración de base de datos geográfica</i>	63
Tabla 4 <i>Tabla de puntos de apoyo 2018</i>	63
Tabla 5 <i>Tabla de puntos de apoyo 2023</i>	64
Tabla 6 <i>Tabla de puntos de apoyo</i>	65
Tabla 7 <i>Resultados de clasificación Supervisada Imagen 2018</i>	67
Tabla 8 <i>Resultados de clasificación Supervisada Imagen 2023</i>	67
Tabla 9 <i>Comparativo de las coberturas periodo 2018 a 2023</i>	69
Tabla 10 <i>Estadísticas Individuales de las 8 Bandas</i>	80
Tabla 11 <i>Matriz de Covarianza VARI - NDVI</i>	81
Tabla 12 <i>Matriz de Correlación VARI - NDVI</i>	81
Tabla 13 <i>Resultado Salud de los Árboles Purificación 2023</i>	86

1 Resumen

El presente estudio presenta diversas técnicas de Sistemas de Información Geográfica (SIG) para evaluar la salud de la vegetación en el área urbana del municipio de Purificación, Tolima. Se emplean dos tipos de drones: uno equipado con sensor RGB y otro con sensor multiespectral. Se utiliza el índice VARI como método funcional alternativo, validando sus resultados con los índices NDVI, NVDER, ARVI, OSAVI y GNDVI. Se realiza un análisis multitemporal entre 2018 y 2023, llevando a cabo clasificaciones supervisadas y examinando los cambios en la cobertura vegetal. Se incorpora una aplicación de inteligencia artificial para la automatización de tareas complejas mediante el aprendizaje profundo. Las técnicas de Deep Learning en el análisis de imágenes permiten una mayor automatización y precisión en la identificación y clasificación de especies vegetales, teniendo un impacto significativo en la planificación y toma de decisiones para la conservación de la vegetación, así como en el seguimiento de su distribución y salud a lo largo del tiempo.

Palabras Claves: Herramientas SIG, Dispositivos Aerotransportados, Ortomosaico, Análisis Multitemporal, Aprendizaje Profundo, Índices de Vegetación.

2 Abstract

The present study presents various Geographic Information Systems (GIS) techniques to evaluate the health of the vegetation in the urban area of the municipality of Purificación, Tolima. Two types of drones are used: one equipped with an RGB sensor and another with a multispectral sensor. The VARI index is used as an alternative functional method, validating its results with the NDVI, NVDER, ARVI, OSAVI and GNDVI indices. A multi-temporal analysis is performed between 2018 and 2023, carrying out supervised classifications and examining changes in vegetation cover. An artificial intelligence application is incorporated to automate complex tasks through deep learning. Deep Learning techniques in image analysis allow greater automation and precision in the identification and classification of plant species, having a significant impact on planning and decision-making for the conservation of vegetation, as well as in monitoring its distribution and health over time.

Keywords: GIS Tools, Airborne Devices, Orthomosaic, Multitemporal Analysis, Deep Learning, Vegetation Indices.

3 Introducción

El cambio climático es una realidad inminente en el mundo y en nuestro país, las temperaturas han aumentado considerablemente en los últimos años. En el departamento del Tolima encontramos una gran variedad de microclimas asociados a sus características geográficas, caso tal sus municipios del oriente sufren oleadas de calor cada vez más fuertes.

El municipio de Purificación se encuentra situado al suroriente del departamento del Tolima, es un municipio prospero en temas de pesca y cultivos de arroz, su temperatura promedio es de 33°C, siendo uno de los más calientes del departamento, razón por la cual es objeto de estudio de este trabajo, queriendo detectar la vegetación arbórea existente y determinar su salud.

El estudio detallado de la cobertura vegetal, empleando tecnologías avanzadas como los drones, se ha convertido en un componente indispensable para la gestión ambiental moderna (Smith & Turner, 2020). Este proyecto se centra en analizar de forma multitemporal la vegetación en Purificación, Tolima, mediante el uso de dos modelos de drones: el Mavic 3 y el Mavic 3 Multiespectral, ambos equipados con sensores comparables. Se busca evaluar la efectividad de índices de vegetación reconocidos, como el VARI y el NDVI, en la monitorización de la salud vegetal y la dinámica de cambios en la cobertura vegetal a lo largo del tiempo (López & Hernández, 2019).

La aplicación del método padding en el procesamiento de imágenes, agregando pixeles con valor igual a cero a los bordes de la imagen original para preservar la

calidad de los datos de las imágenes capturadas, Además, la correlación entre los índices NDVI y VARI, analizada a nivel de píxeles, proporciona una base sólida para discutir la precisión y similitudes en los resultados obtenidos por ambos drones, respaldada por visualizaciones gráficas que destacan estas semejanzas (Johnson & Martínez, 2019).

Las nuevas herramientas mejoran el soporte de los flujos de trabajo de machine Learning y Deep Learning con datos geospaciales. desde el etiquetado y la preparación de datos hasta el entrenamiento de los modelos, su despliegue para la interpretación y resultado final, (MathWorks, 2023). Es en este punto donde se necesita su aplicación en este trabajo de grado, aplicando el entrenamiento del modelo de detección de vegetación y entregando un etiquetado de árboles con alta precisión para luego ser tratado con el índice de vegetación.

Este estudio no solo es pertinente para los gestores ambientales y municipales, quienes podrían beneficiarse directamente de los hallazgos para mejorar la gestión de recursos, sino también para el campo académico, donde se proveen bases para futuras investigaciones. Al establecer que un índice como el VARI obtenido de cámaras RGB puede ser tan efectivo como los índices obtenidos de drones multiespectrales, se sugiere la posibilidad de utilizar tecnologías más accesibles sin comprometer la integridad de la información ambiental crucial (Davis & Thompson, 2021).

Desde la toma de las imágenes en los años 2018, 2023 y 2024 con un dispositivo aerotransportado, se inicia un proceso en el cual intervienen varias técnicas implementadas en Sistemas de Información Geográfica como lo son; el análisis

multitemporal, la clasificación supervisada, la utilización de modelos de aprendizaje profundo y la aplicación de los índices de vegetación. Obteniendo resultados concretos y dando herramientas para la supervisión de la vegetación desde la practicidad.

4 Planteamiento del problema de investigación

El cambio climático y las actividades humanas están afectando significativamente los ecosistemas forestales alrededor del mundo, haciendo imprescindible el monitoreo preciso y continuo de la cobertura vegetal (FAO, 2013). En este contexto, el municipio de Purificación en Tolima presenta una diversidad de coberturas vegetales que varían desde bosques densos hasta áreas de cultivo intensivo, las cuales necesitan ser monitoreadas con precisión para gestionar adecuadamente estos recursos naturales. A pesar de los avances tecnológicos, aún persisten desafíos significativos en la clasificación y el monitoreo temporal de la vegetación utilizando imágenes satelitales y de drones, especialmente cuando se trata de la identificación y evaluación de la salud de especies arbóreas específicas.

El uso de drones equipados con cámaras multiespectrales ha probado ser una herramienta eficiente en la teledetección, pero la integración de técnicas de Deep Learning para el reconocimiento específico de especies y la evaluación de su estado sanitario aún no se ha explorado completamente en contextos locales como el de Purificación. La capacidad de distinguir entre especies arbóreas y determinar su salud puede permitir intervenciones más precisas y oportunas en términos de conservación y manejo del territorio. (LIFE4FIR, 2021)

4.1 Descripción del área problemática

El municipio de Purificación, situado en el departamento del Tolima, Colombia, se caracteriza por una diversidad topográfica significativa que influye directamente en sus desafíos ambientales y sociales (Martínez & Rojas, 2018). Esta región exhibe un

rango de elevaciones que va desde zonas llanas en las partes bajas cerca del río Magdalena hasta áreas montañosas que forman parte de la cordillera Central en los límites más altos del municipio. Esta variación topográfica presenta retos particulares para la planificación del uso del suelo y la gestión de recursos naturales.

Las zonas montañosas, por ejemplo, son susceptibles a la erosión debido a las inclinaciones pronunciadas y a menudo enfrentan riesgos de deslizamientos de tierra, especialmente durante las temporadas de lluvia intensa (García & López, 2020). Estos fenómenos naturales no solo amenazan la infraestructura física, sino también las actividades agrícolas, que son el sustento principal de muchas comunidades locales.

En contraste, las áreas llanas cercanas al río Magdalena están más expuestas a inundaciones, un problema exacerbado por la deforestación y los cambios en los patrones de uso del suelo (Torres & Molina, 2019). Estos eventos de inundación pueden contaminar los recursos hídricos y reducir la calidad y disponibilidad de agua para consumo humano y riego, afectando así la productividad agrícola y la seguridad alimentaria.

En el municipio de Purificación departamento del Tolima, los veranos son cortos, tórridos, bochornosos y mayormente nublados y los inviernos son cortos, calurosos, opresivos, mojados y nublados. Durante el transcurso del año, la temperatura generalmente varía de 24 °C a 37 °C y rara vez baja a menos de 23 °C según análisis estadístico de informes climatológicos históricos por hora y reconstrucciones de modelos del 1 de enero de 1980 al 31 de diciembre de 2016. (Spark, Weather, 2018)

Desde la óptica de la ingeniería, es crucial abordar estos desafíos mediante la implementación de técnicas avanzadas de mapeo y modelado. Utilización de herramientas como los sistemas de información geográfica (SIG) y la teledetección, se pueden crear modelos detallados del terreno que ayuden a predecir y mitigar los riesgos naturales (Pérez & Quintana, 2021). Además, estas tecnologías permiten monitorear los cambios en la cobertura vegetal y la erosión del suelo, fundamentales para planificar intervenciones que promuevan la resiliencia ambiental y la adaptación al cambio climático.

El entendimiento detallado de la topografía de Purificación y la aplicación de tecnologías geoespaciales son, por lo tanto, indispensables para la planificación efectiva del territorio y la gestión de sus recursos naturales, garantizando el desarrollo sostenible y la protección del entorno y sus habitantes (Ortega & Gutiérrez, 2022).

4.2 Formulación del problema

¿Qué ventajas presenta el uso de drones, índices de vegetación y técnicas de aprendizaje profundo para la estimación de los cambios de cobertura y la salud de la vegetación en el municipio de Purificación Tolima?

5 Justificación

Este estudio se justifica por la problemática del cambio de cobertura vegetal en el municipio de Purificación Tolima, dando una alternativa para avanzar en la precisión del monitoreo ambiental mediante la integración de tecnologías de punta, como el Deep Learning y la teledetección, para abordar los desafíos actuales en la conservación de la biodiversidad y la gestión de los recursos naturales. La teledetección, a través del uso de drones, ofrece una perspectiva detallada y actualizada de grandes áreas de difícil acceso, proporcionando datos valiosos para la gestión ambiental (Li & Roy, 2017). Sin embargo, la aplicación de técnicas de Deep Learning puede llevar estos análisis a un nuevo nivel, permitiendo una clasificación más detallada y apoyado en la utilización de los índices de vegetación lograrla la evaluación de la salud de las especies arbóreas, lo cual es crucial para la toma de decisiones en la conservación y el manejo sostenible de los bosques (García et al., 2019).

Además, este estudio proporcionará una comparativa entre el uso de drones de bajo y alto costo, evalúa si los avances tecnológicos más accesibles pueden igualar la precisión de equipos más costosos. Esto no solo tiene implicaciones prácticas para las comunidades locales y los gestores del territorio, sino también para el campo académico y científico, fomenta un enfoque más inclusivo y accesible para la investigación ambiental.

6 Antecedentes

El desarrollo de nuevas tecnologías de la información Geográfica ha dado un gran impulso al cuidado y conservación del medio ambiente, determina nuevas formas de captura, con más nivel de precisión, como lo son los Ortofotomosaicos.

Gran parte del desarrollo de las tecnologías de vuelos no tripulados con mayor aceptación y/o investigaciones es en los países europeos, resaltando así el país de España, que tienen gran interacción con el desarrollo de estudios con imágenes aerotransportadas no tripuladas, contempla los sistemas de información geográficas como un campo de múltiples aplicaciones para los análisis de la vegetación.

La fotogrametría es la ciencia y tecnología de obtener medidas precisas a partir de fotografías, tiene una amplia gama de aplicaciones en diversos campos, como lo son topografía y cartografía, ingeniería civil y construcción, arquitectura y preservación del patrimonio, agricultura de precisión, geología y exploración de recursos naturales, medio ambiente y gestión de recursos naturales, arquitectura y diseño urbano, (Pix4D SA, 2024).

La fotogrametría puede definirse como una técnica que une las matemáticas, la fotografía y la óptica para determinar las propiedades geométricas de los objetos, a través del solapamiento de imágenes basadas en principios trigonométricos. Esta disciplina, surgida en 1840, ha evolucionado con el tiempo adaptándose a las nuevas tecnologías y su uso se ha extendido a diferentes ramas del saber, entre las que destacan la geografía y la topografía. (Ruiz, Gallego, & Peña, 2015)

El desarrollo de la tecnología de vehículos aéreos no tripulados en la última década ha sido vertiginoso, (Acosta, McClung , Jiménez , & García, 2018). No solamente en el campo de la geodesia hablando específicamente de la rama de la fotogrametría, si no, que existen diversas maneras para apoyar miles de soluciones efectivas, y así impactar positivamente el desarrollo de la comunidad.

Ahora bien, en Colombia, Riaño-Edgar (2018) en su trabajo de investigación, realiza una metodología para el diseño de un vuelo fotogramétrico con vehículos UAV'S o no tripulados, la fotogrametría en principio se realizaba partiendo de vuelo tripulados, pero encuentra una gran alternativa para realizar vuelos fotogramétricos con UAV's, en la cual determina una secuencia lógica y ofrece parámetros que van en función del tipo de terreno en donde se vaya a realizar la toma. asimismo, determinar las especificaciones técnicas que se requieran, es importante señalar que el autor concluye que para terrenos con pendientes fuertes se hace necesario realizar vuelos en forma perpendicular a la pendiente del terreno, esto con el fin de reducir las líneas de vuelo.

El fenómeno de la expansión urbana es cada vez más frecuente en el mundo lo que afecta directamente a los bosques por la extracción de materia prima y a la desaparición de vegetación o zonas verdes dentro de los cascos urbanos de los municipios (Forero Mendoza, 2022). Por medio del análisis de imágenes satelitales se puede concluir en cifras, durante el primer trimestre del año 2021 se deforestaron 45.500 ha, mientras que durante el mismo periodo del 2022 la cifra fue de 50.400 ha. Frente al segundo trimestre, que corresponde a la primera temporada de lluvias en el país, en el 2021, 1.580 ha fueron deforestadas, mientras que en 2022 la cifra ascendió a 2.060. Meta, Caquetá, Guaviare, Putumayo, Norte de Santander y Antioquia son los

seis departamentos más afectados (Ministerio de Ambiente y Desarrollo Sostenible, 2022).

(Garcia, 2012), en su publicación de la revista Fedesarrollo, argumenta la importancia para la vida humana de los bosques, los cuales contienen cerca del 90% de la biodiversidad terrestre, y que por procesos de deforestación como la expansión de la frontera agropecuaria, especialmente la ganadería extensiva, siembra de cultivos ilícitos, tala ilegal, minería e infraestructura, incendios forestales y presión por el crecimiento poblacional han cambiado el uso del suelo para satisfacer bienes como frutos, papel, madera, insumos para medicinas o cosméticos, entre otros, degradando procesos como la purificación del aire y del agua dulce, la regulación del clima regional y local, la extinción de la flora y la fauna nativa, temas que terminan siendo trascendentales para las generaciones futuras.

(Ruiz, Cardenas, & Baquero, 2011), en su artículo en la revista de la academia colombiana de ciencias exactas, físicas y naturales, realizan un análisis de la pérdida de coberturas en esta región por medio de 29 pares de imágenes LANDSAT TM y ETM+, para cinco categorías de coberturas de la tierra: agua, praderas naturales, agroecosistemas, arena y afloramiento rocoso, arrojándole como resultado 12.200 km² de bosque deforestado entre los años 1986 a 2000 años, teniendo un promedio anual de 852 km², arrojando una tasa anual de deforestación de 0,23%. En otras palabras, aproximadamente entre estos años, se deforestó el 2,8% de la Amazonia colombiana siendo el occidente de los departamentos de Putumayo y Caquetá y el suroccidente del Meta las áreas con más porcentaje de afectación.

(García Romero, 2013), en su publicación habla de las principales causas de la deforestación en Colombia, estando en primer lugar la expansión de la frontera agropecuaria, especialmente para ganadería extensiva, siembra de cultivos ilícitos, tala ilegal, minería e infraestructura, incendios forestales y presión por el crecimiento poblacional. Todo esto genera una presión en el gobierno y dando creación a la política forestal en Colombia, la cual está plasmada en el Consejo Nacional de Política Económica y Social – CONPES – 2834 de 1996 y de ella se desprende el Plan Nacional de Desarrollo Forestal (actualizado en 2010) y sus programas asociados, que tiene como objetivo principal lograr el uso sostenible de los bosques, con el fin de conservarlos, consolidar la incorporación del sector forestal en la economía nacional y contribuir al mejoramiento de la calidad de vida de la población.

(Tiria Forero, Bonilla Castillo, & Bonilla Castillo, 2018), en su artículo de la revista Cuadernos de Geografía, describe la transformación de la cobertura vegetal en la margen de la vía La Tagua – Puerto Leguizamo en el municipio de Putumayo Colombia, vía construida por el interés de extracción de materia prima de la selva Amazónica como especies maderables y pieles de animales silvestres durante la guerra binacional entre Perú y Colombia, con la llegada de los campesinos de los Andes, empezó la tala y la quema del bosque para la siembra de cultivos y pastos y esta vía se convirtió en el columna vertebral de la deforestación.

(Garciglia, 2014), en su publicación de la revista de divulgación de la Universidad Michoacana de San Nicolás de Hidalgo, habla sobre los motivos de la tala indiscriminada, los cuales están relacionados con el dinero o la necesidad de los comuneros de mantener sus familias, esto se deriva en una insaciable necesidad de

producir productos de pulpa de papel y madera al mercado mundial, pero no toda la deforestación es consecuencia de la intencionalidad. Alguna es causa de factores humanos y naturales como los incendios forestales y el pastoreo intensivo, que puede inhibir el crecimiento de los árboles.

En Costa Rica se encuentran procesos de deforestación equivalentes a 820 km²/año, siendo extremadamente alto. (Rosero & Palloni, 1998), hablan de la relación del fenómeno del crecimiento poblacional y la deforestación, realizando modelos de regresión se estimó que el uso de la leña en los hogares causa un efecto significativo a la deforestación caso contrario el nivel de pobreza en la zona si incrementa las probabilidades de deforestación, por cada 1% de incremento en la población el riesgo de deforestación aumenta en 0.03%.

Los estudios multitemporales son los más utilizados para evaluar los cambios de cobertura, caso puntual (Salas, Barboza, & Oliva, 2016), en su publicación de la revista INDES, utilizaron imágenes satelitales Landsat del sensor TM y OLI, realizando procesos de clasificación supervisada identificaron siete clases de coberturas en el distrito de la Florida, bosques, pastos y cultivos, arbustales y herbazales, zona pantanosa, cuerpos de agua, zona urbana y áreas quemadas, los cuales permitieron realizar el análisis por teledetección entre los años 1987 y 2000, encontrando una alta deforestación de 232.20 ha/año, con una reducción de 18.65% del área de bosque, por el contrario para el periodo 2000 – 2013, se encontró una baja deforestación de 19.52 ha/año de área total de bosque.

Ya se dio un repaso por las principales fuentes de la pérdida boscosa, ahora se revisan los efectos que trae este fenómeno al planeta, uno de los principales lo

menciona (Masera, Ordoñez, & Dirzo, 1992), en su publicación en la Revista Ciencia, las emisiones de carbono generadas por causa de la acelerada deforestación de la selva mexicana, se han aumentado en un 20% debido a este fenómeno antrópico. Al perder bosque se pierde la absorción de dichas emisiones.

La deforestación tiene todos los efectos negativos para el planeta. El impacto más alto es la desaparición del hábitat de cientos de millones de especies. 70% de los animales y plantas habitan los bosques de la tierra y muchos no pueden sobrevivir a este fenómeno que destruye su medio ambiente.

Como se puede evidenciar las causas en el proceso de deforestación de las regiones están identificadas desde hace muchos años, diferentes organismos se han sensibilizado con el problema actual y se han creado caminos para minimizar y reparar el daño causado al medio ambiente, en el libro Emergencia Climática Prospectiva 2030 de (Castro Niño & Robayo Galvis, 2020), habla sobre la emergencia climática, es sin lugar a duda el mayor desafío de nuestra era. Utilizando modelos climáticos y tendencias actuales establecieron una proyección sobre cómo podrían empeorar los impactos del cambio climático para el año 2030 si no se toman medidas significativas para reducir las emisiones de gases de efecto invernadero, afectando sectores como la agricultura, la salud, la seguridad alimentaria, la migración, la biodiversidad y los recursos hídricos, dicho desafío está respaldado por políticas estatales como los bienes públicos globales como mecanismo de defensa colectiva, y la creación de convenios internacionales para la preservación de especies arbóreas amenazadas.

(Poveda & Mesa, 1995) en su artículo de la revista de la universidad Nacional, menciona la relación que existe entre la deforestación y la disminución en los

regímenes de lluvia, demostrando eventos similares en Panamá, Costa de Marfil, La India y China, realiza un estudio de la precipitación concluyo que la precipitación de origen dentro de la cuenca del Amazonas era del orden del 50%, en el año 1975, jugando un papel fundamental a la hora de generar su propia lluvia, en el año 1990 por causa de la deforestación se muestra una reducción entre el 20% al 30% de esta precipitación, genera cambios importantes en la variables hidrológicas y el incremento en la duración de la temporada de bajas lluvias. Ocasiona cambios a nivel local, como lo son reducción de la evotranspiración, disminución en la longitud de rugosidad superficial, perdida de la materia orgánica y su fauna, compactación debida a prácticas agrícolas y sobrepastoreo y la erosión del suelo. Cambios a nivel regional, como el incremento de la temperatura superficial y del suelo y la reducción en la humedad de la capa limite atmosférica, disminución en los caudales y la escorrentía, por último, cambios a nivel global, al perturbar fuertemente el transporte de calor a los trópicos hacia mayores latitudes.

(Burga, 2016), en su trabajo de grado muestra la relación directa entre la perdida de la biomasa aérea y la deforestación, conociendo que la biomasa es un depósito importante de los gases de efecto invernadero que contribuye al almacenamiento de carbono en el suelo a través de la acumulación de la materia orgánica. Al realizar la cuantificación de la deforestación, se encontró la relación en el periodo evaluado en los distritos del alto amazonas, analizando que el incremento está influenciado por la constante presión y depredación antrópica del aumento de nuevos distritos.

(Pabon Caicedo, 2003), muestra en su publicación de la revista Cuadernos de Geografía de la universidad Nacional, que el aumento de la temperatura traería un

desplazamiento hacia mayores alturas de los cinturones bioclimáticos, Cultivos muy sensibles a la temperatura ambiental tendrían que desplazarse, o al menos sus rendimientos sufrirían variaciones apreciables. Otra manifestación del cambio climático que podría afectar a Colombia es el incremento del nivel del mar. Ese podría traer consecuencias de gran magnitud en las zonas costeras e insulares.

(Costa Posada, 2007), en su publicación de la revista Ingeniería también habla sobre el cambio climático, el cual es un fenómeno plenamente aceptado por científicos y políticos y la demora en el alcance de este consenso requiere del concurso de todos: científicos, tomadores de decisión, sector privado y comunidad en general para recuperar el tiempo perdido.

Una reflexión sobre el papel climático que tiene Colombia, no solo en el clima regional sino en el clima global, la da (Poveda Jaramillo, 2011). En su artículo evidencia las cifras que ilustran el problema del cambio ambiental global, las cuales demuestran un incremento exponencial de las emisiones de dióxido de carbono, igualmente del crecimiento de la población del planeta tierra, con las consecuentes presiones de agua, alimento, vestuario, albergue y energía que eso demanda. Detrás de la deforestación hay una racionalidad económica. La relación entre la deforestación y el aumento o la disminución de lluvia, depende de la escala, la lluvia necesita de tres ingredientes para su formación: condiciones termodinámicas de la atmosfera, vapor de agua debido a la evapotranspiración del bosque y partículas de aerosoles como polvo, hollín, o partículas resultado de incendios, e inclusive compuestos volátiles orgánicos que emitan las plantas. Los bosques actúan como una de las ruedas volantes del clima global, transportando agua y generando nubes, afectando la circulación atmosférica en

corrientes y hemisferios y almacenando sustanciales reservas de biomasa y carbón al suelo. Por lo tanto, la reducción de la deforestación y degradación del bosque tropical debe ser una prioridad y una oportunidad para mitigar los efectos del cambio climático.

La aplicación de Tecnologías de la información geográfica ha llevado al humano a experimentar en nuevos campos como lo es el uso de la inteligencia artificial, con el fin de generar procesos cada vez más eficientes y precisos, una de las más interesantes es el uso del Deep Learning.

El Deep Learning es un subconjunto de machine Learning, que es básicamente una red neuronal con tres o más capas. Estas redes neuronales intentan emular el comportamiento del cerebro humano, aunque lejos de igualar su capacidad, pero le permiten "aprender" a partir de grandes cantidades de datos. Aunque una red neuronal con una sola capa ya puede realizar predicciones aproximadas, las capas ocultas adicionales ayudan a optimizar y refinar la precisión, (IBM, 2015).

La Inteligencia Artificial (IA) se utiliza para automatizar el procesamiento de datos geoespaciales y la resolución de problemas espaciales. El aprendizaje automático o machine Learning (ML) – un subconjunto de la IA-, utiliza algoritmos y técnicas basadas en datos que entrenan la computadora para encontrar patrones. Deep Learning (DL) es otra rama de la IA que utiliza estructuras de códigos muy acopladas llamadas redes neuronales, que imitan el funcionamiento del cerebro humano para resolver problemas de forma flexible. La IA se está aplicando con éxito para recopilar, gestionar y analizar datos geoespaciales con el fin de predecir resultados. Los analistas geoespaciales trabajan con IA para automatizar el procesamiento de la información y ampliar su conocimiento (ESRI, 2021)

Diversas técnicas de Deep Learning han sido usadas para proponer soluciones a problemas reales para hacer un sistema más preciso y eficiente, como lo son Redes neuronales convolucionales, Redes neuronales recurrentes y Redes neuronales generativas adversarias, estas técnicas pueden ser utilizadas en prácticamente cualquier dominio, como es el caso del uso de conjuntos de datos Trash-Net para la clasificación y detección de objetos, (Arda Aral, Recep Keskin, Kaya, & Hacıömeroğlu, 2018).

Otro caso es el de (Vo, Son, Vo, & Le, 2019). En su estudio desarrolla un modelo de red neuronal profunda para la clasificación de basura llamado DNN-TC, que es una mejora del modelo ResNext para mejorar el rendimiento predictivo. Finalmente, los experimentos se llevan a cabo para comparar el rendimiento de DNN-TC y los métodos de última generación para la clasificación de basura en el conjunto de datos de basura VN, así como en el conjunto de datos de Trashnet para mostrar la efectividad del modelo propuesto. Los resultados experimentales indican que DNN-TC produce un 94 % y un 98 % en términos de precisión para los conjuntos de datos Trashnet y VN-trash respectivamente y, por lo tanto, supera a los métodos más avanzados para la clasificación de basura en ambos conjuntos de datos experimentales.

El uso de tecnologías de teledetección y fotogrametría para la monitorización de la cobertura vegetal ha revolucionado tanto la gestión ambiental como la evaluación ecológica. Los índices de vegetación como el NDVI y el VARI son herramientas efectivas para evaluar la salud y la biomasa vegetal, y su aplicación ha sido extensamente documentada en literatura (Pettorelli et al., 2005; Bannari et al., 1995). El avance en drones y técnicas como la fotogrametría ha permitido obtener datos más

precisos y evitar errores comunes en el procesamiento de la información (Smith et al., 2020; Whitehead y Hugenholtz, 2014).

El aumento en la accesibilidad de los drones ha facilitado la realización de estudios multitemporales, los cuales son cruciales para entender las dinámicas de cambio en la cobertura vegetal. En el contexto de Tolima, estudios han reportado una pérdida boscosa significativa, donde las principales fuentes incluyen la deforestación para agricultura y la explotación maderera (Gómez y Martínez, 2018; Hernández et al., 2016). La evaluación precisa de estos cambios es vital para la implementación de políticas de conservación efectivas.

Herramientas analíticas avanzadas como ArcGIS Pro y Agisoft Metashape se utilizan para procesar estos datos, con modelos que incluyen la detección de árboles y la clasificación supervisada de imágenes. Estas técnicas se complementan con el análisis de precisión mediante matrices de confusión (Congalton, 1991; Foody, 2002). Además, el desarrollo de algoritmos de Deep Learning aplicados a la teledetección está emergiendo como una potente solución para identificar patrones y cambios en la cobertura vegetal de maneras que antes no eran posibles (Kerkech et al., 2018).

La aplicación de estas tecnologías y métodos en Tolima no solo es relevante sino necesaria, dado el rápido cambio en la cobertura vegetal que esta región ha experimentado en las últimas décadas. Según Torres y García (2019), la cobertura forestal de Tolima ha visto una reducción de aproximadamente 12% en los últimos 20 años, un dato alarmante que subraya la necesidad de tecnología precisa y eficaz en la monitorización ambiental.

7 Objetivos

7.1 Objetivo general

Evaluar el uso de drones con sensores RGB y Multiespectrales, índices de vegetación como el VARI y el NDVI y Deep Learning, para la estimación multitemporal de la cobertura y salud de la vegetación para orientar decisiones de manejo ambiental en el municipio de purificación Tolima.

7.2 Objetivos específicos

- Toma de Imágenes con dispositivo aerotransportado, aplicación de Clasificación Supervisada y Geoprocesamientos: Utilizar clasificación supervisada de imágenes y ejecutar geoprocesamientos avanzados para analizar los datos obtenidos, identificando zonas con cambios significativos en la cobertura vegetal durante el periodo estudiado.
- Implementar técnicas de fotointerpretación y análisis multitemporal para determinar la distribución espacial de zonas ambientales y forestales de interés, capturando y procesando información geográfica crítica.
- Procesamiento y estimación de la Salud de la vegetación por medio del Índice de vegetación (VARI) y su comparación con los índices NDVI, NVDER, ARVI, OSAVI y GNDVI.
- Ejecutar un modelo de detección de árboles basado en técnicas de aprendizaje profundo para mejorar la precisión y eficacia de la identificación de especies arbóreas y su estado de salud.

8 Referente Contextual

El municipio de Purificación, ubicado en el departamento del Tolima, Colombia, enfrenta desafíos significativos relacionados con la gestión y conservación de su cobertura vegetal. Estos desafíos son exacerbados por cambios en el uso del suelo y la expansión urbana y agrícola, que a menudo resultan en la pérdida de biodiversidad y alteraciones en los ecosistemas locales. En respuesta a estos problemas, la teledetección y el análisis geoespacial emergen como herramientas cruciales para el monitoreo ambiental y la gestión de recursos naturales.

El uso de drones equipados con sensores RGB y multiespectrales ha revolucionado la capacidad de recopilar datos detallados y actualizados de áreas extensas, permitiendo estudios comparativos multitemporales que son esenciales para evaluar la dinámica de la cobertura vegetal (Turner et al., 2015). Los índices de vegetación como el NDVI (Índice de Vegetación de Diferencia Normalizada) y el VARI (Índice de Vegetación de Atmósfera Visible) son ampliamente utilizados para evaluar la salud y la biomasa vegetal desde una perspectiva remota, proporcionando indicadores efectivos del estado y la productividad de la vegetación (Pettorelli et al., 2005).

La integración de técnicas de fotointerpretación y análisis geoespacial facilita la identificación y clasificación de cambios en la cobertura vegetal, mientras que el desarrollo y la implementación de modelos de clasificación supervisada en plataformas como ArcGIS Pro permiten una evaluación precisa de estos cambios (Congalton & Green, 2009). Además, los avances en el aprendizaje profundo y la inteligencia artificial ofrecen nuevas oportunidades para mejorar la detección y clasificación de especies

arbóreas, contribuyendo significativamente a los esfuerzos de conservación y manejo sostenible (Zhu et al., 2017).

El análisis multitemporal y la comparación de índices de vegetación, utiliza datos capturados en diferentes momentos (2018, 2023, y 2024), proporcionan una base sólida para entender los patrones y tendencias en la salud de la vegetación, permitiendo a los investigadores y gestores locales tomar decisiones informadas y basadas en evidencia para la protección y restauración de ecosistemas críticos (Herold et al., 2012).

Este enfoque integral no solo mejora la comprensión de la dinámica ambiental en Purificación, sino que también establece un marco para futuras investigaciones y aplicaciones prácticas en el campo de la teledetección y análisis ambiental, apoyando así la sostenibilidad a largo plazo de los recursos naturales en la región.

9 Referente teórico

Este marco teórico proporciona una base sólida para entender cómo se abordará el estudio comparativo entre NDVI y VARI en el contexto del monitoreo de la cobertura vegetal utilizando drones en Purificación, Tolima, integrando diversas disciplinas y tecnologías en el análisis.

9.1 Importancia de los árboles:

Los árboles son los encargados de regular el ciclo del agua, recogiendo y almacenándola, ayudando a evitar las inundaciones, protegiendo los suelos ayudando a controlar la erosión, evitando derrumbes y deslizamientos. Son el hábitat de miles de especies de plantas, aves, mamíferos, reptiles y anfibios. Son la fuente de muchos recursos, nos proveen de madera, medicinas, alimentos, fibra, materiales de construcción entre otros bienes. Son territorio de vida para las comunidades que los habitan, cuyas prácticas tradicionales de manejo, pueden contribuir a la conservación de nuestros bosques y selvas. Contribuyendo a regular el clima porque reducen los efectos del cambio climático producidos por el hombre (Sostenible, 2023).

9.2 Proteger la biodiversidad:

El cambio climático está provocando la pérdida de hábitats naturales, la alteración de los ciclos de reproducción y migración de muchas especies, y la extinción de muchas otras. Al reducir las emisiones de gases de efecto invernadero y fomentar prácticas más sostenibles, podemos ayudar a proteger la biodiversidad y asegurar un futuro para todas las especies del planeta.

9.3 Crecimiento Poblacional:

El crecimiento poblacional es un tema complejo y multifacético que ha sido objeto de estudio y preocupación durante muchos años. Aunque la tasa de crecimiento poblacional en la región ha disminuido en las últimas décadas, sigue siendo una de las tasas más altas del mundo, y esto ha generado una serie de impactos ambientales y sociales.

En general, el crecimiento poblacional se ha visto impulsado por varios factores, entre ellos el acceso a mejores servicios de salud y el aumento de la esperanza de vida, así como por la migración de personas desde otras partes de Colombia y de otros países. Estos factores, combinados con el creciente interés en la explotación de los recursos naturales de la región, han llevado a la creación de nuevas ciudades y la expansión de las ya existentes, lo que ha tenido importantes implicaciones para el medio ambiente.

El aumento de la población ha llevado a la deforestación de vastas extensiones de bosque para dar paso a la agricultura, la ganadería, y esto ha tenido graves consecuencias para la biodiversidad y el clima. Además, el aumento de la población ha generado mayores demandas de agua y energía, lo que ha llevado a la construcción de presas y otros proyectos de infraestructura que han tenido un impacto negativo en los ecosistemas y las comunidades locales.

Los efectos de la deforestación por la actividad petrolera son menores con respecto al efecto posterior de la colonización agrícola. El crecimiento poblacional en la región, impulsado inicialmente por la migración interna y posteriormente por una tasa de

natalidad elevada, desencadenó un proceso generalizado de deforestación en favor de actividades agrícolas ineficientes con la consecuente pérdida de bosque (Carr, Suter y Barbieri 2005). La deforestación puede intensificarse con un incremento de población, especialmente en naciones en vías de desarrollo, donde lo usual es que no existan incentivos económicos por integrar avances tecnológicos en la práctica agrícola y eficiencia productiva o inversiones para la preservación del recurso natural. (Jarrín, Tapia Carrillo, & Zamora, 2017).

9.4 Índices de Vegetación:

Los índices NDVI y VARI proporcionan medidas cruciales para evaluar la salud y cobertura vegetal, basados en la diferencia de reflectancia entre las bandas del infrarrojo cercano y rojo para el NDVI y bandas visibles para el VARI. En particular, el NDVI es altamente efectivo para identificar la biomasa vegetal (Pettorelli et al., 2005), mientras que el VARI es útil en áreas donde los sensores no captan el infrarrojo cercano (Gitelson et al., 2002). En el contexto de Purificación, Tolima, estos índices permitirán monitorizar los efectos de prácticas agrícolas y cambios ambientales sobre la vegetación.

9.5 Fotogrametría y Teledetección:

Esta técnica implica el uso de drones para obtener datos precisos y actualizados de la topografía y la cobertura terrestre, lo que es fundamental para el monitoreo ambiental. Las imágenes de drones permiten la creación de ortofotos y modelos digitales del terreno, que son esenciales para evaluar cambios en la cobertura vegetal y

detectar prácticas agrícolas no sostenibles (Anderson & Gaston, 2013). Las tecnologías de teledetección aplicadas en este estudio proporcionarán datos multitemporales que son críticos para evaluar la dinámica de la vegetación en el área de estudio.

9.6 Técnicas de Aprendizaje Profundo:

El aprendizaje profundo se aplica en este caso para analizar imágenes de drones, proporcionando una detección más precisa de características específicas como tipos de vegetación o estados de salud vegetal. Los modelos de redes neuronales convolucionales (CNN) son particularmente útiles para clasificar la cobertura del suelo y detectar enfermedades en las plantas a partir de imágenes de alta resolución (LeCun et al., 2015). Este enfoque será vital para identificar áreas de intervención urgente y para mejorar la gestión de los recursos naturales.

9.7 Sistemas de Información Geográfica (SIG):

Los SIG permiten la manipulación, análisis y visualización de datos geoespaciales. En este estudio, se usarán para integrar y analizar datos de diferentes fuentes, incluyendo imágenes de drones y mediciones de campo. ArcGIS Pro, en particular, ofrece herramientas avanzadas para modelar y analizar la distribución espacial y temporal de la vegetación, facilitando así la toma de decisiones informadas sobre la conservación (Longley et al., 2015).

9.8 Análisis Multitemporal y Comparativo:

Este análisis implica comparar imágenes de diferentes periodos de tiempo para observar la evolución de la cobertura vegetal. Esta técnica es crucial para identificar tendencias de deforestación o regeneración y para evaluar la efectividad de las políticas de gestión ambiental (Coppin et al., 2004). Los datos recopilados en 2018, 2023, y 2024 permitirán realizar un estudio detallado sobre los efectos a largo plazo de las intervenciones humanas y naturales en la vegetación de Purificación.

9.9 Red GNSS:

Basados en puntos de control y utilizando un marco de referencia global, los sistemas de referencia geodésica, también conocidos como sistemas globales de referencia, son esenciales para la georreferenciación que produce coordenadas curvilíneas como latitud y longitud. El más conocido globalmente es el WGS (World Geodetic System), desarrollado inicialmente por el Departamento de Defensa de los Estados Unidos. Este sistema ha evolucionado a través de diversas versiones: desde WGS60 hasta el actualmente usado WGS84. Estos datums son geocéntricos y fueron creados inicialmente con propósitos militares. Debido a esto, la IAG (International Association of Geodesy) promovió una versión civil, el GRS (Geodetic Reference System), que comenzó con el GRS67 y culminó con el GRS80, alineándose con el WGS84. Por tal motivo, es común referirse al elipsoide de referencia como WGS84, aunque en la práctica civil es más adecuado referirse a él como GRS80 (González Larrarte, 2021).

El IERS (International Earth Rotation and Reference Systems Service) fue establecido en 1987 por la Unión Astronómica Internacional y la Unión Internacional de Geodesia y Geofísica. Este organismo se encarga de mantener y proporcionar los sistemas convencionales de referencia a través de cooperación internacional, y es responsable de generar información precisa y periódica sobre la orientación terrestre. Conecta el ICRF (International Celestial Reference Frame) con el ITRF (International Terrestrial Reference Frame), garantizando técnicas de alta confiabilidad para la geodesia. Los sistemas convencionales de referencia incluyen el ICRS (International Celestial Reference System) y el ICRF, creando a partir de estos el ITRS (International Terrestrial Reference System), esencial para determinar la orientación del eje de rotación terrestre en el espacio (González Larrarte, 2021).

El ITRS se define con origen en el centro de masa de la Tierra, considerando océanos y atmósfera, y se realiza mediante estimaciones de las coordenadas y velocidades de un conjunto de estaciones observadas por técnicas como VLBI, LLR, GPS, SLR y DORIS, conocido como el Marco de Referencia Terrestre Internacional (González Larrarte, 2021).

El SIRGAS (Sistema de Referencia Geocéntrico para las Américas) es un proyecto que surgió como respuesta a la necesidad de un sistema de referencia más regional frente al global ITRF. SIRGAS proporciona un Datum geocéntrico a través de redes geodésicas nacionales de cada país, apoyado por un Datum vertical que incluye la altura elipsoidal y física, siendo esencial para precisión geodésica en el continente (González Larrarte, 2021).

En Colombia, el Magna Sirgas actúa como el marco geocéntrico nacional de referencia, con el IGAC (Instituto Geográfico Agustín Codazzi) encargado de su determinación, establecimiento y mantenimiento. Esta entidad también produce la cartografía oficial, el catastro nacional de la propiedad inmueble, y coordina la Infraestructura Colombiana de Datos Espaciales (ICDE) (IGAC, 2024).

En el contexto de los sistemas de referencia geodésica discutidos anteriormente, es esencial considerar los parámetros específicos que definen estos sistemas. A continuación, se presenta una tabla detallada que resume los parámetros geodésicos clave utilizados en nuestros análisis. Esta tabla proporciona una visión clara de las especificaciones técnicas que fundamentan el proceso de georreferenciación y su aplicación en diferentes contextos geográficos.

Tabla 1 *Parámetros Geodésicos*
Sistema de Coordenadas

CTM12

Proyección	Transversa de Mercator
Datum	WGS-84
Elipsoide	GRS-80
Geoide	Geocol 2004
Latitud	04° N
Longitud	73° W
Falso Este	5.000.000.00
Falso Norte	2.000.000.00
Factor de Escala	0.9992

Unidades

Metros

Fuente: IGAC

Por medio del Modelo Gravitacional Terrestre GEOCOL 2004 se han calculado las alturas referidas al Nivel Medio del Mar de la Red GNSS, este modelo se ha aplicado porque se ha adaptado mejor a las alturas ortométricas.

10 Hipótesis de investigación

El uso combinado de drones con sensor RGB, índices de vegetación visible como el VARI y técnicas de aprendizaje profundo como el Tree Detection, permiten estimar de manera efectiva y detallada la salud de la vegetación y sus cambios a través del tiempo.

10.1 Base Tecnológica y Fundamentos Científicos:

Sensores RGB y Multiespectral: Los sensores RGB son excelentes para captar imágenes en el espectro visible, lo que nos ayuda en la identificación básica y visual de la vegetación. Por otro lado, los sensores multiespectrales ofrecen una visión más profunda, captando información en el infrarrojo cercano que es crucial para evaluar la salud vegetal a través de índices como el NDVI, que mide la biomasa viva, y el VARI, que ajusta por la iluminación y los efectos atmosféricos en el espectro visible.

10.2 Impacto del Cambio Climático:

Incidencia sobre la Vegetación: El aumento de temperaturas y los cambios en los patrones de lluvias, ambos síntomas del cambio climático, afectan significativamente la salud de la vegetación. Nuestra investigación explorará cómo los índices NDVI y VARI pueden captar estos efectos, lo cual es crucial para identificar zonas de riesgo o vulnerabilidad.

Gestión Ambiental: Demostrar esta hipótesis subrayaría la importancia de seleccionar índices de vegetación apropiados para la gestión de recursos naturales y la

planificación territorial, optimizando las políticas de conservación y las intervenciones ambientales.

10.3 Utilidad Práctica y Aplicaciones Futuras:

Análisis Multitemporal: Comparando imágenes de distintos años, como las de 2018 y 2023, se puede identificar cómo ha evolucionado la cobertura vegetal y cómo la expansión urbana o las prácticas agrícolas intensivas están influyendo en esta dinámica.

Detección de Árboles y Clasificación Supervisada: El uso de técnicas avanzadas como el aprendizaje profundo para la detección de árboles y la clasificación supervisada de imágenes enriquece nuestra capacidad de análisis, permitiéndonos tomar medidas más informadas contra la deforestación y degradación ambiental.

Índices de vegetación: Con ayuda de los índices de vegetación se puede determinar las especies enfermas por distintos factores dentro del municipio para dar oportuna atención y priorizar zonas con baja densidad de árboles.

10.4 Conclusión Hipotética:

Si se valida la hipótesis, se aportaría evidencia sólida sobre cómo el índice de vegetación VARI pueden ser herramienta crucial para monitorear la salud de la vegetación y su respuesta al cambio climático. Esta información sería fundamental para orientar las decisiones de manejo ambiental y conservación en Purificación, Tolima y

otras áreas similares, estableciendo una base para futuras investigaciones y políticas de gestión de recursos naturales y adaptación al cambio climático.

11 Metodología

Para el desarrollo del siguiente flujo de trabajo se hace una combinación del uso de herramientas especializadas en Tecnologías de Información Geográfica y el uso de sensores pasivos (cámaras RGB Y multiespectrales), desde la planeación, captura y procesamiento de los vuelos fotogramétricos, pasando por una clasificación supervisada y realizado un estudio multitemporal, para evaluar los cambios de la cobertura y con este resultado estimar la salud de la misma por medio de diferentes índices de vegetación, optimizando el resultado con un modelo de aprendizaje profundo. Como se puede ver en el siguiente mapa conceptual.

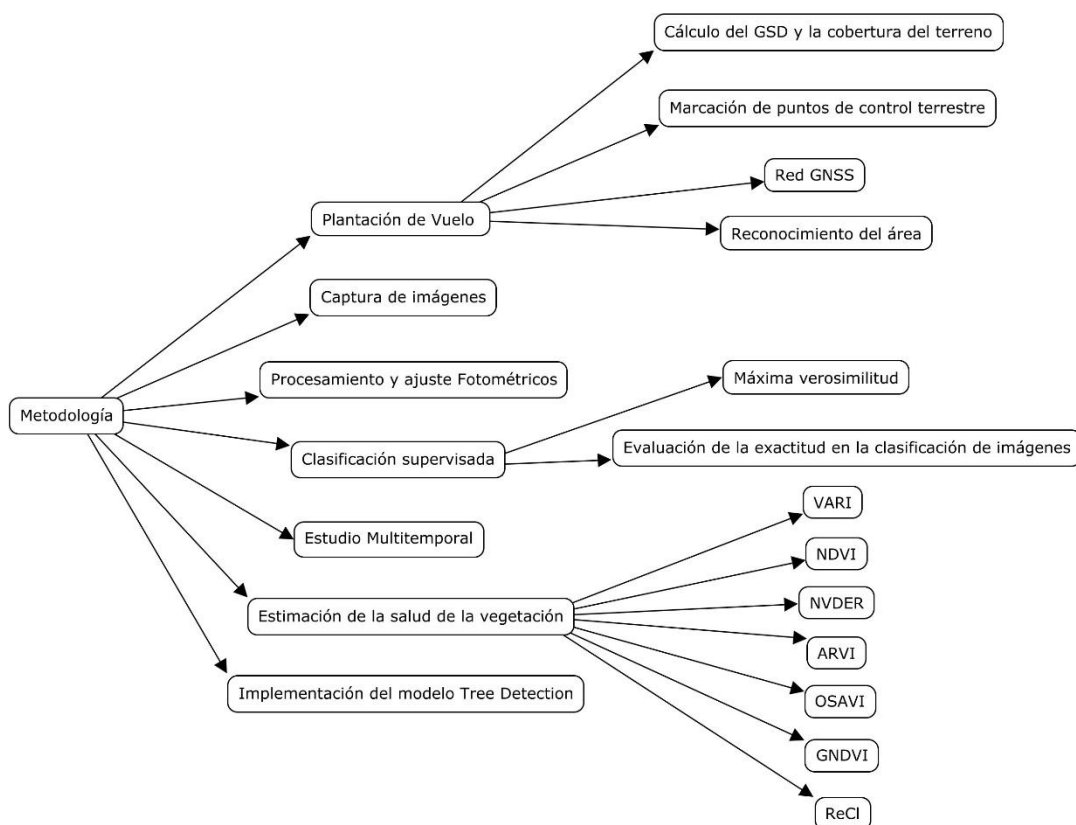


Ilustración 1 Mapa conceptual

Fuente: Elaboración propia

11.1 Planeación de Vuelo

En la fase inicial del proyecto de cartografía enfocado en el municipio de Purificación, se establece un polígono o área de interés que guía todo el proceso de planeación. Esta delimitación es crucial para estimar los recursos necesarios tales como costos, personal, tiempo de ejecución, así como el material y equipo requerido (Instituto Geográfico Nacional, 2018).

Posteriormente, se procede con la configuración en el software de vuelo, introduciendo los valores necesarios para garantizar la captura de imágenes precisas y fiables. Según Hsu (2019), operar el dron a una altitud aproximada de 120 metros ofrece un equilibrio óptimo entre el tiempo de vuelo y la resolución de imagen, siendo esta la altitud estándar para la mayoría de los vuelos cartográficos.

Los pasos seguidos durante la ejecución del vuelo incluyen:

- Reconocimiento del área
- Marcación de puntos de control
- Red GNSS
- Levantamiento Topográfico de puntos de control
- Cálculo del GSD y la cobertura del terreno
- Planeación de vuelo y captura de imágenes

11.2 Reconocimiento del área

El casco urbano de Purificación presenta una topografía mayormente plana, extendiéndose sobre 288 hectáreas. Limita al norte, este y oeste con cultivos de arroz,

y al sur con el Río Magdalena. La ventana operativa para los vuelos se extiende desde las 6:15 a las 6:30 AM para la salida del sol, y desde las 6:12 a las 6:20 PM para su puesta, proporcionando amplias oportunidades para realizar las operaciones aéreas en condiciones de luz adecuadas.

11.3 Marcación de puntos de control terrestre

La estrategia de distribución de puntos de control terrestre se diseñó para asegurar una cobertura adecuada en cada cuadrícula de vuelo. Se estableció un solapamiento longitudinal del 80% y un lateral del 70%, configurando tres líneas de vuelo consecutivas que garantizan la correcta alineación de las imágenes capturadas. En total, se generaron 15 puntos de control, tomados con tecnología RTK.

Cada imagen capturada está vinculada a valores de posición y orientación, registrados simultáneamente por sistemas GPS e inercial, información que se utiliza en las etapas posteriores de procesamiento para asegurar la precisión y veracidad de los datos recopilados.

La uniformidad en la distribución de los puntos de control asegura una cobertura integral tanto en los extremos como en el centro del área de interés, facilitando un procesamiento posterior eficiente y detallado.

La distribución de los puntos de control se realizó de manera uniforme, asegurando una cobertura completa tanto en los extremos como en el centro del polígono. A continuación, se presenta una imagen que ilustra esta distribución:



Ilustración 2 Ubicación de puntos de control
Fuente: Elaboración propia

Para facilitar la identificación precisa desde el aire y minimizar errores, se utilizaron dianas con un patrón central claramente distinguible. Cada diana medía 0.50 metros por 0.50 metros. A continuación, se muestra una imagen que ilustra esta marcación:




Ilustración 3 Marcación de dianas
Fuente: Elaboración propia

Durante la ejecución de este proyecto se llevaron a cabo dos vuelos de captura de imágenes. En el primer vuelo, realizado en el año 2018, se utilizaron un total de 2632 imágenes captadas con el dron Mavic 1. Para el segundo vuelo, en el año 2023, se empleó el dron Mavic 3 RTK Enterprise, con el cual se obtuvieron 3685 imágenes.

11.4 Método de posicionamiento relativo estático

Para la etapa del Postproceso de la información que se obtuvo en campo se posicionó un (1) punto base el día 29 de abril de 2023, este punto nos da una máscara libre sobre el horizonte que cumple con las especificaciones técnicas para un posicionamiento estático, lo cual garantizó una señal de rastreo con el equipo en campo que cumple con una distancia de 69 kilómetros de vectorización. Este punto base se fijó con relación a la estación Base GPS Permanente **"IGAC - IBAG"** del Instituto geográfico Agustín Codazzi perteneciente a la red MAGNA ECO, y 127 kilómetros de vectorización. Este punto base se fijó con relación a la estación Base GPS Permanente **"IGAC - BOGA"** del Instituto geográfico Agustín Codazzi perteneciente a la red MAGNA ECO.

Para el posicionamiento del punto base se utilizó un equipo 1 Equipo GNSS marca Leica 530, L1-L2 (doble frecuencia), los datos de la sesión del 29 de abril, tiempo de captura cada 2 segundos, máscara de elevación de 10° y el tiempo de posicionamiento del punto corresponde alrededor de 6 horas 52 minutos, en configuración estática, verificando que existan las menores obstrucciones tanto de elementos físicos, como electromagnéticos.

11.5 Cálculo del GSD y la cobertura del terreno

En algunos programas este cálculo es automático de acuerdo a la altura de vuelo y el tipo de cámara con la que se cuenta, pero realizamos el procedimiento manual para no solo conocer el GSD sino los metros que va a cubrir nuestra imagen en el terreno y compararla con la dada en el programa.

El dron utilizado es el Mavic 3 RTK Enterprise con modelo de cámara FC300X de 3.61 mm de distancia focal.

- F= Distancia focal de la cámara= 3.61 mm
- Sw= Ancho de sensor de la cámara= 13.20 mm
- Tamaño de Pixel en sensor= 0.00156 mm x 0.00156 mm
- Altura de Vuelo (Variable)= 120 m
- Ancho de la imagen en pixeles= 5472
- Alto de la imagen en pixeles= 3648
- Distancia focal= 3.61 mm

Al modificar la altura de vuelo se modifica el tamaño de la resolución de la imagen.

$$GSD = \frac{Sw * H * 100}{(8.8 * 5472)}$$

$$GSD = \frac{13.20 * 120 * 100}{(8.8 * 5472)}$$

$$GSD = 3.289 \text{ cm}$$

Para determinar el ancho de la imagen en el terreno (D_w) aplicamos la siguiente formula

$$D_w = \frac{GSD * imH}{100}$$

$$D_w = \frac{3.289 * 5472}{100}$$

$$D_w = 180 \text{ m}$$

Para determinar el alto de la imagen en el terreno (D_H) aplicamos la siguiente formula

$$D_H = \frac{GSD * imH}{100}$$

$$D_H = \frac{3.289 * 3648}{100}$$

$$D_H = 120 \text{ m}$$

11.6 Captura de imágenes

Para poder tener claridad en los tiempos y números de vuelos se obtuvo la delimitación del área de interés de los datos abiertos, siendo esta la delimitación del casco urbano del municipio de Purificación Tolima.

Como el área es de gran tamaño se realizaron subdivisiones de los polígonos de vuelo para poder cubrir la zona de estudio, siempre procurando no dejar áreas sin cubrimiento. Dando como resultado 10 vuelos.

Generando un archivo KMZ con el área del polígono a volar realizamos la distribución en el software DJI PILOT 2.

Se tuvieron en cuenta los diferentes obstáculos como las torres de comunicación ubicadas al sur del casco urbano, y factores climáticos como la niebla que es un factor meteorológico constante en el municipio.

Una vez se ajustaron todos los parámetros de vuelo se procedió a realizar las misiones y el monitoreo del vuelo usando la vista MapView, la cual nos muestra en tiempo real las fotografías tomadas.



Ilustración 4 *Parámetros de vuelo en programa DJI PILOT 2*
Fuente: DJI PILOT 2

11.7 Procesamiento y ajuste Fotogramétrico

El procesamiento se realizó con el software Agisoft, realizando todos los pasos para su producto final, los cuales son:

- Orientación de fotos: proceso en el cual el programa toma las coordenadas dadas por el GPS del dron y las organiza en un plano.




Ilustración 5 *Ubicación y cobertura de fotografías*

Fuente: Agisoft Metashape

- Generación de nube de puntos densa: Siendo el primer producto resultante del proceso se compone por posicionar los puntos tridimensionalmente, este paso se le aplican calidades medias al no tener aun la corrección de los puntos de control.
- Generación de Malla: Es la creación de una superficie arbitraria dando un modelo a los objetos, con una interpolación alta.
- Ajuste con puntos de control: Siendo el paso más complejo y de gran importancia para la determinar la calidad del ajuste, identificando los marcadores en cada una de las fotografías tomadas con el mayo de los cuidados



Ilustración 6 *Ajuste de puntos de control*

Fuente: Agisoft Metashape

- Generación de nube de puntos densa 2: Después de realizar el ajuste a las cámaras tomadas se procede nuevamente a generar la nube de puntos densa, pero en esta ocasión ajustado a los puntos de control.
- Generación del modelo digital de Elevaciones (DEM): Este modelo nos muestra las elevaciones sobre el nivel del mar de todas las superficies reflectantes como vegetación alta y edificaciones.
- Clasificación de nube de puntos densa: Por la cantidad de puntos que se generaron se hace necesario dar una clasificación, en la que se le insertan los parámetros; de ángulo máximo: lo que se refiere a que los objetos de 0° a 15° , sean catalogados como terreno. Distancia máxima: tomando como rango de 0 a 1 metro de altura sean catalogados como terreno y tamaño de la célula: es el

rango de búsqueda que tiene para hacer la clasificación. (INSTITUTO GEOGRAFICO NACIONAL, 2018)

- Generación del modelo digital del terreno (DTM): Al realizar la clasificación de la superficie obtenemos un filtrado de los puntos terrestres, anulando vegetación alta y edificaciones.
- Generación de Ortofotomosaico: Como producto adicional encontramos el Ortofotomosaico escalado y georreferenciado como apoyo fundamental en la generación del mapa de riesgos.

11.8 Clasificación supervisada

(Willington, Nolasco, & Bocco, 2013) en su informe para el congreso argentino de Agroinformatica describe “Los datos terrestres de uso y cobertura del suelo están entre los más importantes y universalmente utilizados en el ámbito de la gestión sostenible de recursos y en estudios de indicadores ambientales y de cambio climático, proveyendo información medioambiental clave para muchas aplicaciones científicas.”

El objetivo de la clasificación es asignar cada celda del área de estudio a una clase conocida (clasificación supervisada) o a un clúster (clasificación no supervisada). En ambos casos, la entrada a la clasificación es un archivo de firma que contiene las estadísticas multivariantes de cada clase o clúster. El resultado de cada clasificación es un mapa que divide el área de estudio en clases conocidas, que corresponden a muestras de entrenamiento, o clases que ocurren de forma natural, que corresponden a clústeres definidos por el clustering. La clasificación de ubicaciones en clases que

ocurren de forma natural que corresponden a clústeres también se conoce como estratificación. (ESRI, 2022).

11.8.1 Máxima verosimilitud

El método utilizado es el de máxima verosimilitud o probabilidad más alta, el cual calcula para cada clase la probabilidad de que la celda pertenezca a esa clase según sus valores de atributo.

Las celdas de una clase rara vez son homogéneas. Este es especialmente el caso de las muestras de entrenamiento que se toman para una clasificación supervisada. Si las maderas duras en la sombra, por ejemplo, tienen una firma de reflectancia similar a las coníferas a pleno sol, ambos tipos de árboles terminarán en la misma clase. (ESRI, 2022)

Para la optimización de los procesos se creó un ModelBuilder el cual es un lenguaje de programación visual para crear flujos de trabajo de geoprocésamiento. Los modelos de geoprocésamiento automatizan y documentan los procesos de análisis espacial y de administración de datos. (ESRI, 2021)

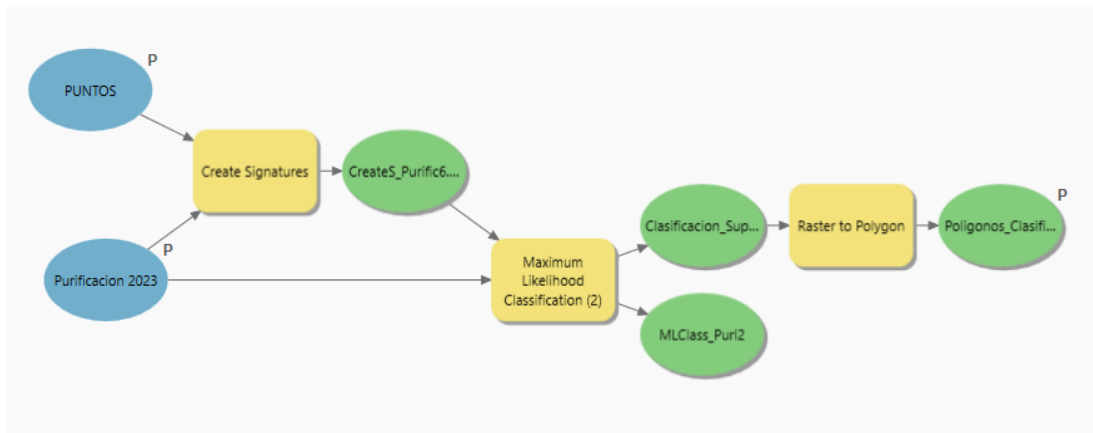


Ilustración 7 *ModelBuilder Clasificación Supervisada*
Fuente: ArcGIS Pro

11.8.2 Evaluación de la exactitud en la clasificación de imágenes

La evaluación de la exactitud es importante en cualquier proyecto de clasificación. Compara la imagen clasificada con otra fuente de datos que se considera exacta o con datos de realidad del terreno. La realidad del terreno se puede recopilar en el campo; sin embargo, si se hace así el proceso es lento y caro. Los datos reales del terreno también pueden derivar de la interpretación de imágenes en alta resolución, de imágenes clasificadas con anterioridad o de capas de datos SIG. (ESRI, 2022)

la forma común de evaluar la precisión de un mapa clasificado es mediante la creación de puntos aleatorios en los datos reales del terreno y comparándolos con los datos clasificados mediante una matriz de confusión. Sin embargo, este proceso puede involucrar la comparación de resultados de diferentes métodos de clasificación o sitios de formación. Para adaptarse a diversos flujos de trabajo, se utilizan tres herramientas de geoprocésamiento: Crear puntos de evaluación de exactitud, Actualizar puntos de evaluación de exactitud y Calcular matriz de confusión.

Después de realizar la validación en las dos imágenes y obtener un resultado superior al 90% se convierten las superficies ráster a entidades con la ayuda de herramientas de geo proceso y poder calcular sus áreas.

OBJECTID *	ClassValue	C_1	C_2	C_3	C_4	Total	U_Accuracy	Kappa
1	C_1	10	0	0	0	10	1	0
2	C_2	1	1	8	0	10	0.1	0
3	C_3	0	0	9	1	10	0.9	0
4	C_4	0	0	0	13	13	1	0
5	Total	11	1	17	14	43	0	0
6	P_Accuracy	0.909091	1	0.529412	0.928571	0	0.767442	0
7	Kappa	0	0	0	0	0	0	0.687727

Ilustración 8 *Matriz de Confusión Clasificación 2018*
Fuente: ArcGIS Pro

OBJECTID *	ClassValue	C_1	C_2	C_3	C_4	Total	U_Accuracy	Kappa
1	C_1	12	0	0	0	12	1	0
2	C_2	0	4	6	0	10	0.4	0
3	C_3	0	0	10	0	10	1	0
4	C_4	0	0	1	9	10	0.9	0
5	Total	12	4	17	9	42	0	0
6	P_Accuracy	1	1	0.588235	1	0	0.833333	0
7	Kappa	0	0	0	0	0	0	0.777273

Ilustración 9 *Matriz de Confusión Clasificación 2023*
Fuente: ArcGIS Pro

11.9 Estimación de la salud de la vegetación

Normalmente, se usaría los valores de reflectancia en ambas bandas de longitud de onda, la visible y la de infrarrojo cercano (NIR), para estimar la salud de la vegetación, como con el Índice de vegetación con diferencia normalizada (NDVI), pero para esta investigación se utilizó una imagen multibanda con tres bandas, todas en el

espectro electromagnético visible, por lo que se usa el índice de resistencia atmosféricamente visible (VARI) en su lugar.

Los índices de vegetación son un parámetro importante del análisis del desarrollo de los cultivos. Entre las numerosas ventajas de los índices de vegetación en la teledetección están la precisión de los datos y el control a kilómetros de distancia, los cuales son los principales impulsores de la adopción de esta práctica tecnológica (Sergieieva, 2022).

La gran ventaja de la metodología utilizada con dron es la alta resolución espacial que alcanzamos con estos dispositivos aerotransportados no tripulados, otro factor determinante son los bajos costos de operación que esto conlleva y su efectividad.

Los índices utilizados en esta investigación fueron; el Índice de Resistencia Atmosférica Visible (VARI), el Índice de Vegetación Resistente a la Atmosférica (ARVI), el índice de vegetación con diferencia normalizada (NDVI), el Índice de Vegetación Normalizado Diferencial de Empalme y Rotación (NVDER), el Índice de Vegetación Ajustado al Suelo Optimizado (OSAVI), el Índice de Diferencia Normalizada Verde (GNDVI) y El índice de Clorofila de Borde Rojo (ReCI), los cuales fueron capturados con un dron multiespectral.

11.10 Implementación del modelo Tree Detection

Este modelo de aprendizaje profundo se utiliza para detectar árboles en imágenes aéreas o de drones de alta resolución. La detección de árboles se puede utilizar para aplicaciones como la gestión de la vegetación, la silvicultura, la

planificación urbana, etc. Este modelo de aprendizaje profundo se basa en DeepForest y ha sido entrenado con datos de la Red Nacional de Observatorios Ecológicos. (ESRI, 2022)

Las redes neuronales convolucionales han demostrado ser muy buenas cuando se trata de reconocer objetos en una imagen. Tienen una arquitectura diferente que permite aprovechar cada parte de una imagen. En una arquitectura normal tenemos que convertir una imagen de tres dimensiones (alto x ancho x profundidad) a una imagen de una sola dimensión, esto trae algunos problemas, necesitamos muchos nodos para representar una imagen pequeña $(64 \times 64 \times 3) = (12,288)$ lo cual aumenta el tiempo de aprendizaje de una red neuronal. Con las redes neuronales convolucionales no tenemos que realizar esta tarea y podemos usar imágenes de grandes dimensiones como $(1024 \times 1024 \times 3)$ sin que la red sea lenta. (Rodriguez, 2018)

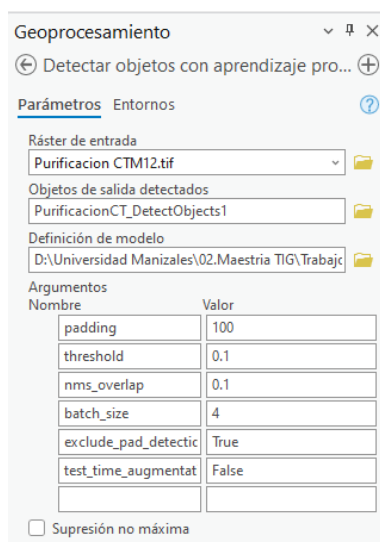


Ilustración 10 *Parámetros del modelo*

Fuente: ArcGIS Pro

Para la optimización de los procesos se creó un ModelBuilder el cual es un lenguaje de programación visual para crear flujos de trabajo de geoprocresamiento. Los modelos de geoprocresamiento automatizan y documentan los procesos de análisis espacial y de administración de datos. (ESRI, 2021)

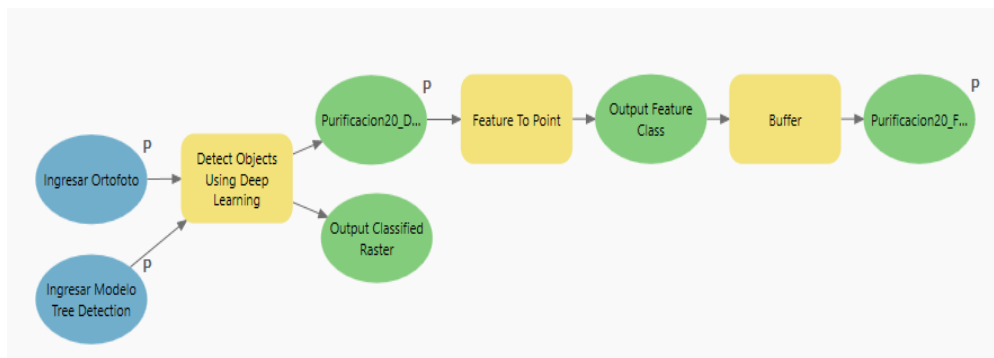


Ilustración 11 *ModelBuilder modelo Tree Detection*
Fuente: ArcGIS Pro

Al realizar la convolución de imágenes en el modelado de redes neuronales convolucionales, esencialmente está reduciendo los datos, y los píxeles del borde de la imagen se usan mucho menos durante el análisis, en comparación con los píxeles internos. De forma predeterminada, el parámetro padding es 0, pero un parámetro padding de 100 significa que se agrega un límite adicional de píxeles a los bordes exteriores de la imagen, todos con un valor de 0. Con ello se reduce la pérdida de información por los píxeles de borde válidos y la contracción.

0	0	0	0	0	0	0	0
0	3	4	6	5	1	3	0
0	5	3	2	4	3	2	0
0	5	4	3	3	2	6	0
0	1	1	2	5	3	4	0
0	2	3	3	4	1	2	0
0	3	3	2	4	2	4	0
0	0	0	0	0	0	0	0

Ilustración 12 Método *padding*
Fuente: Vicente Rodríguez

El argumento `threshold` es el umbral de confianza: ¿cuánta confianza es aceptable para etiquetar un objeto como árbol? Es la comparación entre un umbral y los valores de los píxeles de la imagen en escala de grises.

Máx. ratio de superposición (también se muestra en los argumentos de Python como `nms_overlap`) controla cuánto se puede intersectar una entidad. El parámetro aparece dos veces debido a los argumentos especificados en el archivo. `emd`, pero no siempre se agrega. Un número inferior de este argumento especificaría que los objetos no se pueden superponer por considerarse entidades individuales.

El parámetro `batch_size` define el número de muestras a utilizar al realizar el entrenamiento de la red en cada iteración de entrenamiento. Por ejemplo, si dispone de 1.000 muestras de formación (chips de imagen) y un tamaño de lote de 100, las primeras 100 muestras de entrenamiento realizarán el entrenamiento de la red neuronal. En la siguiente iteración se utilizarán las siguientes 100 muestras, y así sucesivamente. Según la memoria que tenga disponible su equipo, puede aumentar este parámetro, aunque el entrenamiento debería realizarse únicamente en lotes de cuadrados perfectos. Por ejemplo, podría utilizar un lote de 4, 9, 16, etc.

12 Resultados

Los resultados de la presente investigación se fundamentan en productos de origen cartográfico, obtenidos a partir de análisis geoespacial realizado con herramientas de sistemas de información geográfica propuesto en el componente metodológico, tablas y gráficos estadísticos que determinan el comportamiento de las variables, identificación espacio-temporal en la dinámica territorial por tendencias de uso del suelo y salidas cartográficas, que sirvan como soporte en la toma de decisiones orientadas a la planificación futura.

Tabla 2 Resultados y Productos de la investigación

Ítem	Actividades	Resultados / productos esperados	Indicador	Beneficiario
10.1	Toma de Imágenes con dispositivo aerotransportado, aplicación de Clasificación Supervisada y Geoprocesamientos: Utilizar clasificación supervisada de imágenes y ejecutar geoprocesamientos avanzados para analizar los datos obtenidos, identificando zonas con cambios significativos en la cobertura vegetal durante el periodo estudiado.	Capa de Información vectorial donde evidencia la correlación de las variables.	Dos (2) mapas temáticos a escala 1:5000 producto del procesamiento geoespacial de los datos de fuentes primarias y secundarias que ilustra el comportamiento del fenómeno estudiado.	Profesionales interesados en el estudio de las dinámicas territoriales del municipio de purificación y la administración municipal a cargo de la secretaria de planeación municipal.
10.2	Implementar técnicas de fotointerpretación y análisis multitemporal para determinar la distribución espacial de zonas ambientales y forestales de interés,	Bases de datos geográficas con los datos vectoriales y ráster usados y generados a partir de la investigación. Cartografía temática de coberturas a escala 1:5000 de	Dos (2) bases de datos geográficas. Dos (2) mapas temáticos de	Profesionales interesados en el estudio de las dinámicas territoriales del municipio de

	capturando y procesando información geográfica crítica.	los 2 periodos de tiempo objeto de estudio.	coberturas a escala 1:5000 de la zona de estudio.	purificación y la administración municipal a cargo de la secretaría de planeación municipal.
10.3	Procesamiento y estimación de la Salud de la vegetación por medio del Índice de vegetación (VARI) y su comparación con los índices NDVI, NVDER, ARVI, OSAVI y GNDVI.	Capa temática con la identificación de la salud de los árboles.	Un (1) mapa temático a escala 1:5000 de la zona de estudio.	Profesionales interesados en el estudio de las dinámicas territoriales del municipio de purificación y la administración municipal a cargo de la secretaría de planeación municipal.
10.4	Ejecutar un modelo de detección de árboles basado en técnicas de aprendizaje profundo para mejorar la precisión y eficacia de la identificación de especies arbóreas y su estado de salud.	Capa temática con la identificación de los arboles	Un (1) mapa temático con la identificación de los árboles del municipio de Purificación.	Profesionales interesados en el estudio de las dinámicas territoriales del municipio de purificación y la administración municipal a cargo de la secretaría de planeación municipal.

Fuente: Elaboración propia

12.1 Resultado del objetivo específico N°1

La estructura de la base de datos geográfica se basa en la representación geométrica, los atributos, los dominios y las relaciones, siguiendo los catálogos de

objetos geográficos oficiales. Estos catálogos están estandarizados por el Instituto Geográfico “Agustín Codazzi”, la Oficina de Planeación Municipal de Purificación. Los demás componentes cartográficos son resultados de estudios adicionales.

Tabla 3 Descripción de estructuración de base de datos geográfica

Temática	Nombre de la Capa	Escala	Temporalidad	Fuente
Coberturas	Coberturas	1:5000	2018-2023	Autor
Catastro_Urbano	U_Manzana	1:5000	2018	Instituto Geográfico
	U_Terreno	1:5000	2018	
	U_Construccion	1:5000	2018	Agustín Codazzi
	U_Vias	1:5000	2018	
Cartografía Básica	Drenaje_Sencillo	1:5000	2018	Instituto Geográfico
	Drenaje_Doble	1:5000	2018	Agustín Codazzi
Zona de Estudio	Poligono_Municipio	1:5000	2018	Autor
Análisis de Resultados	Coberturas_2018	1:5000	2018	Autor
	Coberturas_2023	1:5000	2023	Autor
	Multiespectral_2024	1:5000	2024	Autor

Fuente: Elaboración propia

En la toma de la de imagen aerotransportada con sensor RGB del municipio de Purificación Tolima en el año 2018 se obtuvo un Ortofotomosaico con resolución espacial de 4.57 cm/pix y un GSD de 3.289 cm, con 15 puntos de control generando el siguiente ajuste.

Tabla 4 Tabla de puntos de apoyo 2018

Nombre	Error X (cm)	Error Y (cm)	Error Z (cm)	Total (cm)	Imagen (pix)
PC1	-0.00365631	-0.263147	-0.061171	0.270188	0.035 (17)
PC2	-0.884977	0.623949	0.180498	1.09776	0.010 (6)
PC3	2.81735	0.325293	-0.126712	2.8389	0.011 (14)
PC4	1.41637	-0.902595	0.101077	1.68256	0.017 (16)
PC5	2.36666	-5.75679	-0.568478	6.25019	0.011 (22)
PC6	3.32947	-5.22096	-0.569558	6.21838	0.026 (22)
PC7	-0.385356	-2.00118	-0.347507	2.06736	0.016 (30)

PC8	-5.44625	-2.58677	0.414052	6.04355	0.007 (21)
PC9	-8.22542	0.221894	-0.250391	8.23222	0.018 (25)
PC10	-1.4922	2.72659	-0.14053	3.11139	0.022 (16)
PC11	0.148251	4.1071	0.105755	4.11114	0.014 (23)
PC12	1.88633	6.4703	-0.0367642	6.73976	0.016 (15)
PC13	-3.55053	6.88333	0.99792	7.80912	0.022 (16)
PC14	-5.28461	-8.81145	0.553333	10.2896	0.019 (29)
PC15	13.6217	4.38251	-0.143487	14.31	0.022 (22)
Total	4.87696	4.34296	0.401659	6.54273	0.019

Fuente: Agisoft Metashape

En la toma de la de imagen aerotransportada con sensor RGB del municipio de Purificación Tolima en el año 2023 se obtuvo un Ortofotomosaico con resolución espacial de 3.78 cm/pix y un GSD de 3.289 cm, con 14 puntos de control generando el siguiente ajuste.

Tabla 5 *Tabla de puntos de apoyo 2023*

Nombre	Error en X (cm)	Error en Y (cm)	Error en Z (cm)	Total (cm)	Imagen (pix)
PC1	0.223124	-0.156203	-0.000079292	0.272367	0.228 (24)
PC2	-0.670852	0.020998	0.0079601	0.671228	0.351 (24)
PC3	0.501848	-0.0252882	0.003198	0.502494	0.278 (24)
PC4	-0.0715502	-0.107741	-0.0150828	0.130212	0.283 (24)
PC6	1.56913	1.85204	-0.0907527	2.42909	0.471 (29)
PC7	-0.420642	0.93964	0.0908778	1.0335	0.300 (27)
PC8	0.353079	1.46125	-0.0465701	1.50402	0.384 (23)
PC9	-0.558598	-0.0666531	-0.0212022	0.56296	0.249 (28)
PC10	1.22646	1.09868	0.0379636	1.64704	0.345 (30)
PC11	-1.86161	-2.7865	-0.108897	3.35291	0.643 (25)
PC12	-0.45297	-1.30274	-0.0471258	1.38005	0.333 (24)
PC13	-2.21323	1.35241	0.158455	2.59856	0.708 (17)
PC14	-2.34993	-2.94562	-0.114136	3.76986	0.706 (27)
PC15	4.72573	0.665723	0.145389	4.7746	0.962 (23)
Total	1.72711	1.41692	0.0820313	2.23546	0.484

Fuente: Agisoft Metashape

En la toma de la de imagen aerotransportada con sensor Multiespectral del municipio de Purificación Tolima en el año 2024 se obtuvo un Ortofotomosaico con

resolución espacial de 3.46 cm/pix y un GSD de 3.289 cm, con corrección RTK amarrada a un punto de control conocido.

Tabla 6 *Tabla de puntos de apoyo*

Error en X (cm)	Error en Y (cm)	Error en Z (cm)	Error en XY (cm)	Error combinado (cm)
0.825521	0.547597	2.73054	0.990629	2.90469

Fuente: Agisoft Metashape

Con la información obtenida de los vuelos se procedió a realizar el geoprocesamiento de las capas ráster realizando la clasificación supervisada por el método de máxima verosimilitud o probabilidad más alta, el cual calcula para cada clase la probabilidad de que la celda pertenezca a esa clase según sus valores de atributo.

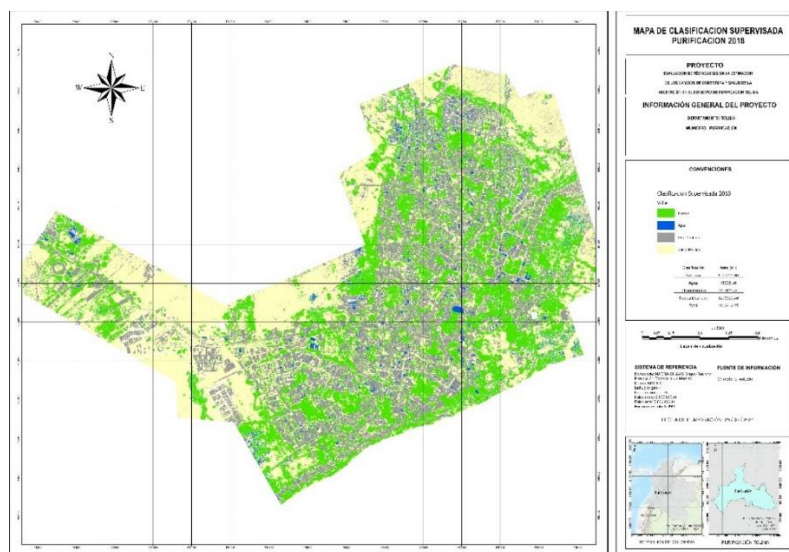


Ilustración 13 *Clasificación Supervisada Imagen 2018*
Fuente: ArcGIS Pro

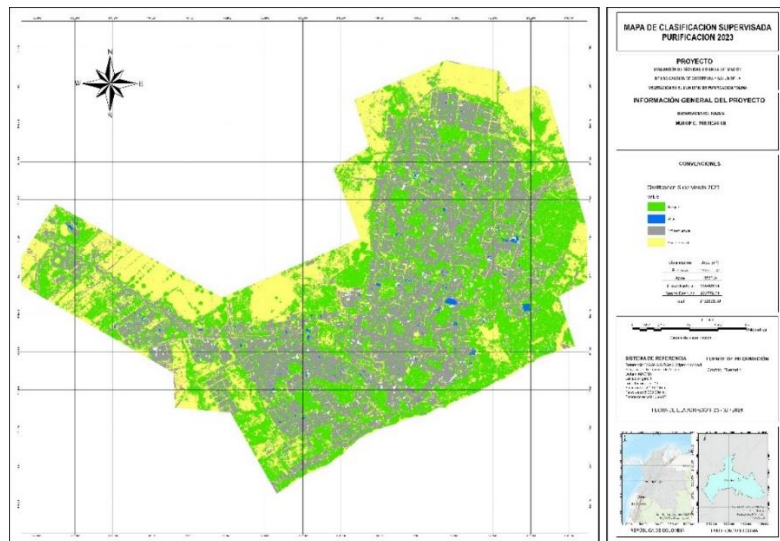




Ilustración 14 Clasificación Supervisada Imagen 2023
 Fuente: ArcGIS Pro



Color	Value	Label
■	1	Boscoso
■	2	Agua
■	3	Infraestructura
■	4	Suelo Desnudo

Ilustración 15 Estadísticas Clasificación Supervisada Imagen 2018
 Fuente: ArcGIS Pro



Color	Value	Label
■	1	Boscoso
■	2	Agua
■	3	Infraestructura
■	4	Suelo Desnudo

Ilustración 16 Estadísticas Clasificación Supervisada Imagen 2023
Fuente: ArcGIS Pro

Con la información generada de las capas ráster se procede a vectorizar los polígonos para tener datos de áreas más precisas con la herramienta ráster a polígono del ArcGIS Pro, arrojando los siguientes resultados.

Tabla 7 Resultados de clasificación Supervisada Imagen 2018

Clasificación	Área (m ²)
Boscosa	1073755.36
Agua	18025.36
Infraestructura	741022.08
Suelos Desnudo	1270029.46
Total	3102832.27

Fuente: ArcGIS Pro

Tabla 8 Resultados de clasificación Supervisada Imagen 2023

Clasificación	Área (m ²)
Boscosa	1206000.41
Agua	18582.24

Infraestructura	955469.64
Suelos Desnudo	922776.01
Total	3102828.30

Fuente: ArcGIS Pro

12.2 Resultado del objetivo específico N°2

Generalmente los estudios del cambio de uso del suelo forestal evalúan la velocidad de la deforestación/reforestación, determinan su extensión geográfica y entienden cuáles son las causas sociales y económicas de los cambios, en las escalas global, regional y local (Ruiz, Savé, & Herrera, 2013)

Por medio del uso de las imágenes tomadas en los años 2018 y 2023, en una serie de 5 años, con resolución espacial de 8 centímetros, cuyo nivel de procesamiento incluyen correcciones geométricas y topográficas.

Se seleccionaron áreas representativas de cada cobertura del suelo para obtener su valor espectral, clasificando píxeles que representan los patrones de los tipos de cobertura del suelo y que se identificaron en campo expuesto en las tablas 4 y 5, de la clasificación supervisada.

El proceso seguido consistió en tres pasos principales:

1. Selección y edición: Se identificaron y editaron píxeles similares y representativos de las áreas de entrenamiento, asignándoles una firma espectral específica y calculando su estadístico.

2. Evaluación de las categorías o firmas espectrales: Una vez definidas las firmas espectrales, se evaluó la viabilidad de las categorías para su clasificación.

3. Clasificación de la imagen satelital: Se utilizó un algoritmo de clasificación supervisada de tipo paramétrico. Se trabajó con un 69% de confiabilidad en la

clasificación de la imagen correspondiente al año 2018 y con un 78% de confiabilidad en la clasificación de la imagen correspondiente al año 2023 según las matrices de confusión.

Para los periodos evaluados, los resultados evidencian cambios de coberturas, en el aumento de la zona Boscosa del 10.96% dada por la maduración de las especies arbóreas, un aumento en las zonas de agua que se debe ignorar puesto que la clasificación supervisada no logro diferenciar los cuerpos de agua en especial piscinas de los techos metálicos azules, un aumento en la infraestructura del 22.44% dado a las construcciones de vías y edificaciones en el casco urbano y una disminución en los suelos desnudos del 37.63% el cual se da paralelo a las construcciones nuevas.

Tabla 9 Comparativo de las coberturas periodo 2018 a 2023

Municipio de Purificación				Municipio de Purificación				Indicador en (m ²)	%
Temática: Coberturas				Temática: Coberturas					
Año 2018				Año 2023					
Código	Nivel	Área (m ²)	%	Código	Nivel	Área (m ²)	%		
1	Boscosa	1073755.36	34.61	1	Boscosa	1206000.41	38.87	4.26	10.96
2	Agua	18025.36	0.58	2	Agua	18582.24	0.6	0.02	3.33
3	Infraestructura	741022.08	23.88	3	Infraestructura	955469.64	30.79	6.91	22.44
4	Suelos Desnudo	1270029.46	40.93	4	Suelos Desnudo	922776.01	29.74	-11.19	-37.63
Total		3102832.27	100	Total		3102828.30	100		

Fuente: Elaboración propia

Según los datos arrojados por el estudio se puede observar que el aumento en la infraestructura ha determinado la disminución de suelos desnudos en el municipio encontrando expansiones en el barrio Ospina Pérez sector 1, Barrio Modelo y creación de nuevas urbanizaciones en la entrada del municipio llegando por Saldaña.



Ortofotomosaico 2018



Ortofotomosaico 2023

Ilustración 17 *Creación de Urbanizaciones Entrada al municipio por Saldaña*
Fuente: ArcGIS Pro



Ortofotomosaico 2018




Ortofotomosaico 2023

Ilustración 18 *Ampliación de Urbanizaciones Barrio Ospina Pérez sector 1*
Fuente: ArcGIS Pro

por otro lado, se evidencia el aumento de zonas boscosas en diferentes zonas y el aumento de la frondosidad de las especies arbóreas en los barrios barrio Ospina Pérez sector 2 y sector de la planta de tratamiento de agua residual.



Ortofotomosaico 2018



Ortofotomosaico 2023

Ilustración 19 *Aumento de zonas boscosas Barrio Ospina Pérez sector 2*
Fuente: ArcGIS Pro



Ortofotomosaico 2018




Ortofotomosaico 2023

Ilustración 20 *Aumento de zonas boscosas sector Planta de Tratamiento de Agua Residual*
Fuente: ArcGIS Pro

Otro factor que contribuye a la disminución de suelos desnudos es la construcción de vías en pavimento en la urbanización el Triunfo, urbanización Villa del Carmen y demás pavimentaciones que se adelantaron durante este periodo.



Ortofotomosaico 2018



Ortofotomosaico 2023

Ilustración 21 *Construcción de vías en pavimento urbanización el Triunfo*
Fuente: ArcGIS Pro



Ortofotomosaico 2018



Ortofotomosaico 2023

Ilustración 22 *Construcción de vías en pavimento urbanización Villa del Carmen*
Fuente: ArcGIS Pro

12.3 Resultado del objetivo específico N°3

El índice de resistencia atmosféricamente visible (VARI) es perfecto para imágenes RGB o en color, ya que trabaja con todo el segmento visible del espectro electromagnético (que comprende las bandas de color rojo, verde y azul). Su tarea específica es realzar la vegetación bajo un fuerte impacto atmosférico al tiempo que suaviza las variaciones de iluminación. Gracias a la baja sensibilidad al impacto atmosférico, el error del índice VARI para la monitorización de la vegetación en condiciones de diferente espesor atmosférico es inferior al 10%. (Sergieieva, 2022).

$$\text{VARI} = (\text{GREEN} - \text{RED}) / (\text{GREEN} + \text{RED} - \text{BLUE})$$




Ilustración 23 *Resultado VARI*
Fuente: Agisoft Metashape

El tercer vuelo realizado en el año 2024 se realizó con un dron Mavic 3 Multiespectral el cual utiliza los valores de reflectancia en ambas bandas de longitud de onda, la visible y la del infrarrojo cercano (NIR), para estimar la salud de la vegetación, como con el índice de vegetación con diferencia normalizada (NDVI).

El NDVI se calcula a partir de las mediciones de la reflectancia de la luz infrarroja cercana y la luz roja, y se utiliza para estimar la cantidad de clorofila en la vegetación. (Sergieieva, 2022)

$$\text{NDVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED})$$




Ilustración 24 Resultado Índice NDVI
Fuente: Agisoft Metashape

El Índice de Vegetación Normalizado Diferencial de Empalme y Rotación (NVDER) es una métrica utilizada en la teledetección para monitorear y evaluar la salud y el vigor de la vegetación en un área determinada. Es una versión mejorada del Índice de Vegetación Normalizado (NDVI), que es una medida estándar en teledetección para evaluar la cantidad y la salud de la vegetación en un área. (Sergieieva, 2022)

El NVDER, es una mejora del NDVI que incorpora ajustes para corregir problemas relacionados con el solapamiento de imágenes (empalme) y el efecto de la rotación del sensor y esto ayuda a proporcionar mediciones más precisas y confiables de la salud de la vegetación en entornos de teledetección. (Sergieieva, 2022)

$$\text{NVDER} = (\text{NIR} - \text{REDEGE}) / (\text{REDEGE} + \text{NIR})$$




Ilustración 25 Resultado NVDER

Fuente: ArcGIS Pro

El Índice de Vegetación Resistente a la Atmosfera (ARVI) Se trata del primer índice de vegetación relativamente insensible a los factores atmosféricos (por ejemplo, aerosoles). Como muestra la fórmula, Kaufman y Tanré corrigieron el NDVI para mitigar los efectos de la dispersión atmosférica duplicando las mediciones del espectro rojo y añadiendo longitudes de onda azules (Sergieieva, 2022)

$$ARVI = (NIR - (2 * RED) + BLUE) / (NIR + (2 * RED) + BLUE)$$

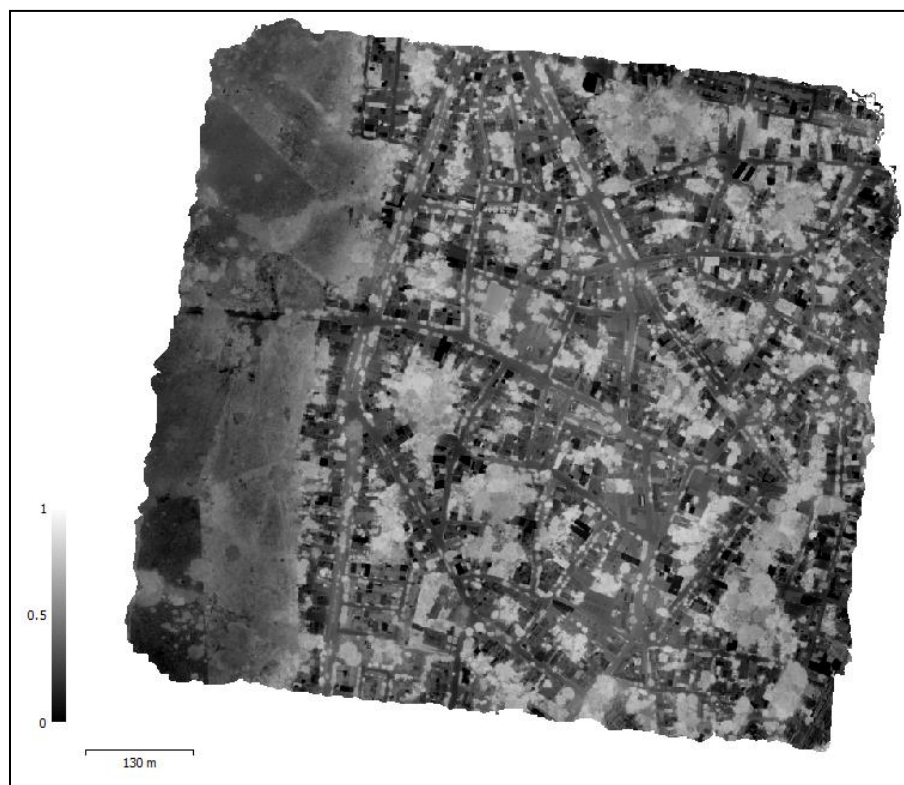


Ilustración 26 *Resultado ARVI*
Fuente: Agisoft Metashape

El Índice de Vegetación Ajustado al Suelo Optimizado (OSAVI) también utiliza la reflectancia en el espectro del infrarrojo cercano y del rojo. La diferencia entre los dos índices es que el OSAVI tiene en cuenta el valor estándar del factor de ajuste del fondo del dosel (0,16). (Sergieieva, 2022)

$$\text{OSAVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED} + 0.16)$$




Ilustración 27 *Resultado OSAVI*
Fuente: Agisoft Metashape

El Índice de Diferencia Normalizada Verde (GNDVI), es una modificación del NDVI que también utiliza el infrarrojo cercano, pero sustituye el verde visible por el rojo visible (540 a 570 nm). (Sergieieva, 2022)

$$\text{GNDVI} = (\text{NIR} - \text{GREEN}) / (\text{NDVI} + \text{GREEN})$$




Ilustración 28 *Resultado GNDVI*
Fuente: Agisoft Metashape

El índice de Clorofila de Borde Rojo (ReCI), responde al contenido de clorofila en las hojas que se nutre de nitrógeno. El ReCI muestra la actividad fotosintética de la vegetación, dado que el contenido de clorofila depende directamente del nivel de nitrógeno en las plantas, responsable de su “verdor”, este índice de vegetación ayuda a detectar las zonas con follaje amarillo o descolorido. (Sergieieva, 2022)

$$\text{ReCI} = (\text{NIR} / \text{RED}) - 1$$



Ilustración 29 *Resultado ReCI*
Fuente: Agisoft Metashape

La gran variedad de índices que podemos calcular con un sensor multiespectral permite establecer diferencias detalladas en los procesos de la salud de la vegetación, como podemos evidenciar es mucho más fácil evidenciar la vegetación sana por el color verde oscuro en los índices (NDVI-NVDER), pero en el índice VARI podemos apreciar resultados muy parecidos dando por entendido que los valores con más luminosidad pertenecen a las especies con mejor salud sin confundir los demás elementos de la imagen como vías destapadas o techos en zinc.

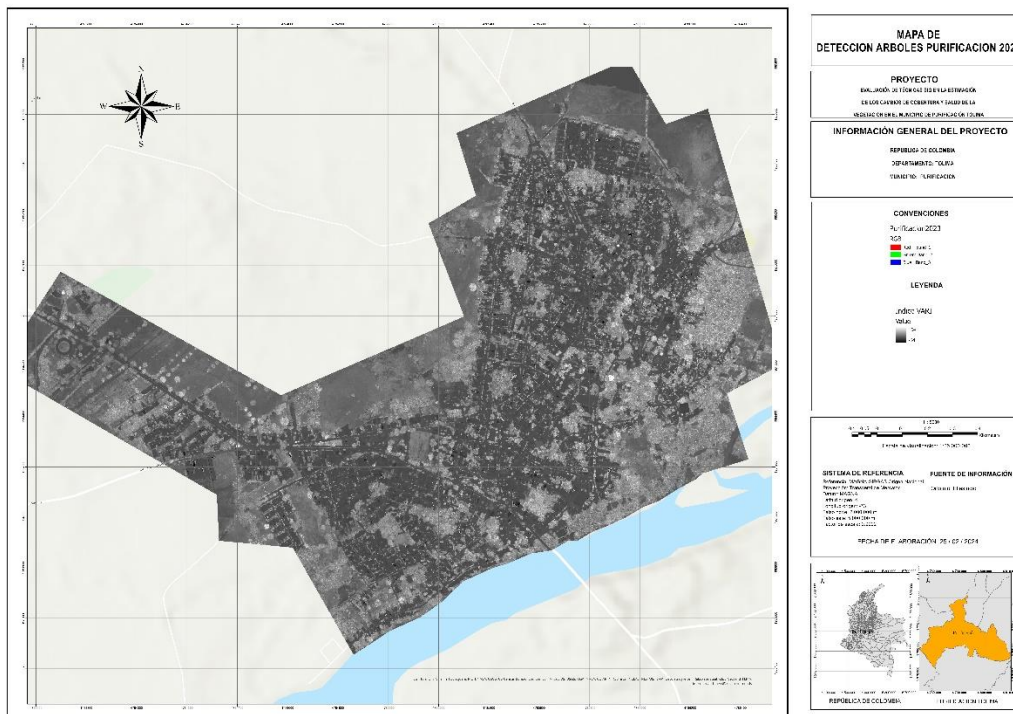


Ilustración 30 Resultado VARI
Fuente: ArcGIS Pro

“Si los valores de NDVI están cerca de 1.0, se espera que la vegetación sea saludable, pero para valores cercanos a 0.0, el mapa muestra suelo desnudo o vegetación estresada” (Pino, 2019). Los valores de 1.0 a 0.0, son los mismos valores que se utilizan para analizar todos los índices mencionados anteriormente, enfocándonos en las diferencias entre en el índice VARI y el NDVI, se establecieron estadísticas individuales, la matriz de covarianza y la matriz de correlación, arrojando los siguientes resultados.

Tabla 10 Estadísticas Individuales de las 8 Bandas

Layer	MIN	MAX	MEAN	STD
1	0.00	255	111.6383	97.74
2	0.00	255	111.6383	97.74
3	0.00	255	111.6383	97.74
4	0.00	255	205.9356	100.52

5	0.00	255	139.2806	113.72
6	0.00	255	139.2806	113.72
7	0.00	255	139.2806	113.72
8	0.00	255	205.9356	100.52

Fuente: Elaboración propia

Tabla 11 Matriz de Covarianza VARI - NDVI

Layer	1	2	3	4	5	6	7	8
1	9552.93397	9552.93397	9552.93397	-7033.95529	7378.78042	7378.78042	7378.78042	-7033.95529
2	9552.93397	9552.93397	9552.93397	-7033.95529	7378.78042	7378.78042	7378.78042	-7033.95529
3	9552.93397	9552.93397	9552.93397	-7033.95529	7378.78042	7378.78042	7378.78042	-7033.95529
4	-7033.95529	-7033.95529	-7033.95529	10104.10443	-5677.7021	-5677.7021	-5677.7021	10104.10443
5	7378.78042	7378.78042	7378.78042	-5677.7021	12931.16411	12931.16411	12931.16411	-5677.7021
6	7378.78042	7378.78042	7378.78042	-5677.7021	12931.16411	12931.16411	12931.16411	-5677.7021
7	7378.78042	7378.78042	7378.78042	-5677.7021	12931.16411	12931.16411	12931.16411	-5677.7021
8	-7033.95529	-7033.95529	-7033.95529	10104.10443	-5677.7021	-5677.7021	-5677.7021	10104.10443

Fuente: Elaboración propia

Tabla 12 Matriz de Correlación VARI - NDVI


Layer	1	2	3	4	5	6	7	8
1	1.00000	1.00000	1.00000	-0.71595	0.66389	0.66389	0.66389	-0.71595
2	1.00000	1.00000	1.00000	-0.71595	0.66389	0.66389	0.66389	-0.71595
3	1.00000	1.00000	1.00000	-0.71595	0.66389	0.66389	0.66389	-0.71595
4	-0.71595	-0.71595	-0.71595	1.00000	-0.49671	-0.49671	-0.49671	1.00000
5	0.66389	0.66389	0.66389	-0.49671	1.00000	1.00000	1.00000	-0.49671
6	0.66389	0.66389	0.66389	-0.49671	1.00000	1.00000	1.00000	-0.49671
7	0.66389	0.66389	0.66389	-0.49671	1.00000	1.00000	1.00000	-0.49671
8	-0.71595	-0.71595	-0.71595	1.00000	-0.49671	-0.49671	-0.49671	1.00000

Fuente: Elaboración propia


El comportamiento o relación que exista entre las variables y entendiendo que la covarianza es el coeficiente simple de la correlación lineal, la matriz de correlación nos explica cómo se encuentran relacionadas cada una de las variables con otra variable, su diagonal siempre contendrá el valor de 1. Si tiene un valor de 0, nos indicara que no tiene ninguna relación con esa variable por lo menos no lineal; es decir, pueda que tenga una relación cuadrática o de otro grado.

Visto desde este modo en la matriz de correlación se observa una muy alta relación entre todas las variables, llegando a 1 en un gran porcentaje.

La estimación de la salud de la vegetación obtenida con los dos índices de comparación VARI y NDVI alcanzo buenos niveles de confianza estadísticamente y visualmente se logra identificar la vegetación que no se encuentra en buen estado de salud.



Índice VARI



Índice NDVI

Ilustración 31 *Imágenes de resultados índices VARI y NDVI*
Fuente: ArcGIS Pro

En la ilustración anterior, el índice vari en una escala de grises deja apreciar un alto índice de luminosidad en la vegetación sana y tonos más oscuros en especies enfermas. “*VARI fue diseñado para introducir una corrección atmosférica y es un buen índice para estimar la fracción de vegetación del rango visible del espectro. Este índice se puede utilizar para analizar los cultivos en todas las etapas de crecimiento*”. (ADSU, 2022)

Se muestra en escala de grises por su mejor interpretación apoyados de la imagen en color natural.

La imagen del índice NDVI es una imagen en el color habitual que se muestra dicho índice y nos muestra en color verde oscuro las especies más sanas y en color amarillo las especies enfermas.

El NDVI es el más común de varios índices de vegetación derivados de observaciones en imágenes de percepción remota. Se basa en la relación entre la cantidad de luz reflejada (reflectancia) por la superficie terrestre en dos regiones del espectro electromagnético, luz roja e infrarroja (infrarrojo cercano). Valores bajos de luz reflejada en el color rojo, combinados con alta reflexión en el infrarrojo, indican una mayor actividad fotosintética o cantidad y densidad de plantas verdes, (INEGI, 2023).

Analizando las diferencias entre las dos imágenes podemos llegar a conclusiones muy similares de la salud de la vegetación y obtener resultados óptimos con un sensor RGB más económico que un sensor multiespectral.

Por esta razón es importante que al utilizar el índice VARI se tenga una preselección de las especies arbóreas para su identificación, lo cual lo realizamos con el siguiente modelo.

12.4 Resultado del objetivo específico N°4

Si bien el proceso de identificación de especies se facilita con los índices de vegetación, aun es un proceso dispendioso en grandes áreas de terreno, como alternativa se plantea la utilización de la inteligencia artificial con modelos de aprendizaje profundo para su pronta detección.

La identificación rápida y precisa de las especies forestales es fundamental para apoyar su gestión sostenible, combatir la tala ilegal y, en última instancia, conservarlas. Tradicionalmente, la identificación anatómica de especies forestales es un proceso manual que requiere de un humano experto con un alto nivel de conocimiento para observar y diferenciar ciertas estructuras anatómicas presentes en una muestra de madera, (Arias Aguilar, 2018).

El Deep Learning o aprendizaje profundo, es una técnica de aprendizaje automático perteneciente al campo de la inteligencia artificial (IA), en específico al subcampo del Machine Learning o aprendizaje automático. Los algoritmos de Deep Learning se caracterizan por el uso de arquitecturas jerárquicas capaces de aprender abstracciones de alto nivel. Estas arquitecturas están formadas por capas de unidades de procesamiento apiladas, y se denominan redes neuronales artificiales dado que su funcionamiento trata de emular el de las células del sistema nervioso de los seres vivos. (Peña, 2020)

Tree Detection es un modelo de aprendizaje profundo se utiliza para detectar árboles en imágenes aéreas o drones de alta resolución. La detección de árboles se puede utilizar para aplicaciones como gestión de la vegetación, silvicultura, planificación urbana, etc. Se pueden utilizar imágenes aéreas y de drones de alta resolución para la detección de árboles debido a su alta cobertura espacio-temporal. (ESRI, 2021)

Al correr el modelo pre entrenado de ESRI en el Ortofotomosaico se encontró una buena precisión de los valores al reconocer una gran cantidad de árboles dentro de la imagen creando muestras de entrenamiento representativas de diferentes árboles, estas entidades son leídas por el modelo de aprendizaje profundo en un formato

especifico llamado chips de imagen. Los chips son pequeños bloques de imagen cortados de la imagen origen, esta digitalización de muestras de entrenamiento puede llevar mucho tiempo, pero merece la pena disponer de una gran cantidad de ejemplos.



Ilustración 32 *Resultado del modelo*
Fuente: ArcGIS Pro

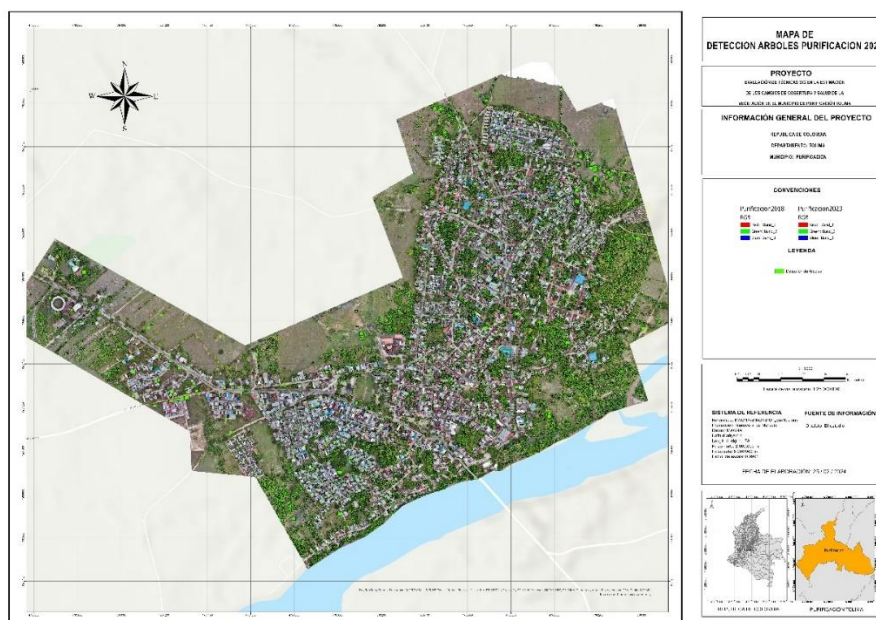


Ilustración 33 *Resultado de modelo Tree Detection*
Fuente: ArcGIS Pro

Con el resultado de la imagen anterior se hace mucho más fácil la identificación de las especies arbóreas y la determinación de su salud es un proceso más selectivo.

Para la extracción del VARI en las especies arbóreas se utilizan los recortes del modelo de aprendizaje profundo transformando los polígonos a puntos y creando una zona de influencia se tomó como distancia 3 metros como se puede evidenciar en la siguiente imagen.




Ilustración 34 *Identificación de especies arbóreas*
Fuente: ArcGIS Pro

Dando una clasificación a las etiquetas se establecieron las siguientes clases:
 Necesita Inspección, Salud en declive, Moderado y Saludable.

Tabla 13 *Resultado Salud de los Árboles Purificación 2023*

Municipio de Purificación
Temática: Salud de los arboles

Salud	No de Arboles	%
Necesita Inspección	10255	18.71
Salud en Declive	13391	24.43
Moderado	20265	36.97
Saludable	10902	19.89
Total	54813	100

Fuente: Elaboración propia

Como se puede evidenciar los resultados en la anterior tabla, el porcentaje de especies arbóreas que necesitan inspección es del 18.71% y los que se encuentran en declive 24.43% dando como resultado 43.14% de las especies con afectaciones y un 56.86% saludable o moderado, lo que significa que casi la mitad de las especies deberían ser tratadas para mejorar su salud y poder contar con un mejor ecosistema, mejorando la calidad de vida de los habitantes del casco urbano.

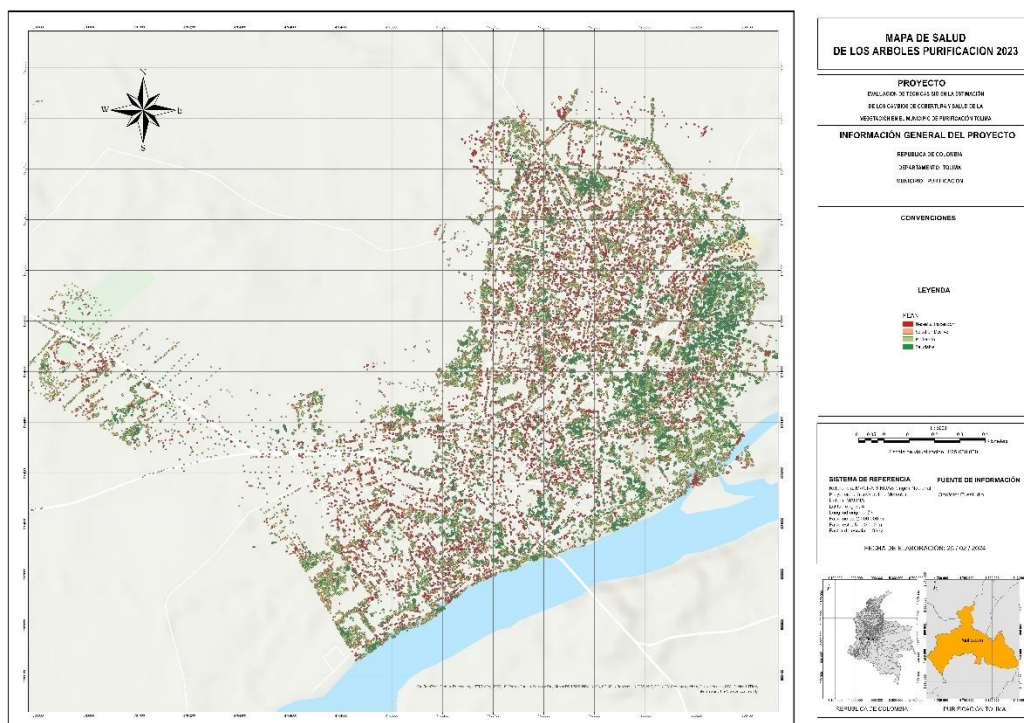


Ilustración 35 Salud de las especies arbóreas
Fuente: ArcGIS Pro

13 Conclusiones

El análisis multitemporal entre el periodo 2018 a 2023 en el casco urbano del municipio de Purificación Tolima, el porcentaje de bosque aumento en un 10.96%, su infraestructura aumento un 22.44% y el suelo desnudo disminuyo en un 37.63%, valores muy ajustados a la realidad por las dinámicas dadas en el municipio con respecto a su expansión.

En la zona de estudio, los mayores impactos que se observan sobre el paisaje son el avance en la construcción de urbanizaciones, perdiendo suelos desnudos. Aunque el bosque aumento esto se debe a la maduración de las especies por el paso de los años, pero se encuentran zonas muy pobres de vegetación boscosa, en los barrios de la periferia del casco urbano.

El comportamiento o relación entre las variables de las imágenes del índice VARI y el índice NDVI visto desde la matriz de correlación es muy alto, llegando a 1 en toda su diagonal, lo que demuestra la efectividad del índice VARI con su sensor RGB a la hora de determinar la salud de la vegetación.

Por medio de la implementación del modelo Tree Detection de Deep Learning se reconocieron 54 813 especies arbóreas en el área urbana del municipio de purificación de las cuales según el índice de vegetación VARI, el porcentaje de especies arbóreas que necesitan inspección es del 18.71% y los que se encuentran en declive 24.43% dando como resultado 43.14% de las especies con afectaciones y un 56.86% saludable o moderado, lo que significa que casi la mitad de las especies deberían ser tratadas para mejorar su salud y poder contar con un mejor ecosistema, mejorando la calidad de vida de los habitantes del casco urbano.

Según la distribución espacial en el mapa, los puntos de color rojo son las especies que necesitan inspección y son las zonas con más deterioro en la salud que se relacionan con las más pobladas de manera urbana, como los barrios Ospina Pérez sector 1, Barrio Plaza de Ferias, Urb. Santa Isabel, Urb. Villa de las Palmas, Barrio Caicedo y Flores y Barrio Los Cámbulos y los barrios con mejor salud en su vegetación los cuales son simbolizados por los puntos de color verde son el Barrio Camilo Torres, Barrio El Plan, Barrio El Puerto, Barrio Modelo y Barrio Santa Barbara.

14 Referencias Bibliográficas

ADSU. (10 de 12 de 2022). Herramientas de Análisis. Colombia.

Amazónica, G. (10 de Julio de 2020). *Guía Amazónica*. Obtenido de https://www.gaiaamazonas.org/noticias/2020-07-10_territorios-indigenas-y-areas-protectidas-de-la-amazonia-perdieron-menos-del-1-de-sus-areas-de-bosque-en-treinta-anos/#:~:text=Los%20Territorios%20Ind%C3%ADgenas%2C%20que%20en,d%C3%A9cadas%2C%20es%20decir%20

Amnistía Internacional. (01 de 01 de 2023). *Amnistía Internacional*.

Obtenido de https://www.amnesty.org/es/what-we-do/climate-change/?utm_source=google&utm_medium=cpc&gclid=Cj0KCQiA54KfBhCKARIsAJzSrdrs0jilAmM_6CISKIUeM_DpxSY5S_rqT-SnQZX7YKqTZ9IXZO9e96waAsiLEALw_wcB

Anderson, K., & Gastón, K. J. (2013). Lightweight unmanned aerial vehicles will revolutionize spatial ecology. *Frontiers in Ecology and the Environment*, 11(3), 138-146.

Anderson, K., & Gastón, K. J. (2013). Lightweight unmanned aerial vehicles will revolutionize spatial ecology. *Frontiers in Ecology and the Environment*, 11(3), 138-146.

Andrade, G. (2012). Selvas sin ley. Conflicto, drogas y globalización de la deforestación de Colombia. *Colombia. Guerra sociedad y medio ambiente*, 160-161.

Arda Aral, R., Recep Keskin, S., Kaya, M., & Hacıömeroğlu, M. (2018). Classification of TrashNet Dataset Based on Deep Learning Models. *IEEE XPLORE*.

Arias Aguilar, D. (2018). Aprendizaje profundo para la identificación de especies forestales basado en imágenes macroscópicas. *Biodiversity Information Science and Standards*.

Bannari, A., Morin, D., Bonn, F., & Huete, A. R. (1995). A review of vegetation indices. *Remote Sensing Reviews*, 13(1-2), 95-120.

BBC. (15 de Julio de 2021). *BBC NEWS MUNDO*. Obtenido de <https://www.bbc.com/mundo/noticias-57820472#:~:text=Los%20investigadores%20dicen%20que%20el,meses%20m%C3%A1s%20calurosos%20del%20a%C3%B1o>.

Burga, M. R. (2016). Incremento de la deforestación y sus consecuencias en la pérdida de biomasa en los bosques de la provincia Alto Amazonas del departamento de Loreto, 2000-2014. *Universidad Científica del Perú*, 64-67.

Castro Niño, N., & Robayo Galvis, W. (2020). *Emergencia Climática: Prospectiva 2030*. Bogotá: Heinrich Böll Stiftung.

Ceccon, E., & Miramontes, O. (1999). Mecanismos y actores sociales de la deforestación en la Amazonia Brasileña. *INTERCIENCIA*, 112-119.

Cepal y Patrimonio Natural. (2013). *Amazonia posible y sostenible*. Bogotá.

CEPAL. (12 de mayo de 2015). *Naciones Unidas*. Obtenido de <https://www.cepal.org/es/notas/amazonia-posible-y-sostenible>

Clark, J. et al. (2019). Evaluación de la eficacia de los UAVs en el monitoreo ambiental. *Journal of Environmental Management*, 240, 120-130.

co, C. (12 de 2022). *COLOMBIA co*. Obtenido de <https://www.colombia.co/pais-colombia/geografia-y-medio-ambiente/region->

amazonica/#:~:text=En%20el%20amazonas%20colombiano%20se,fluviales%20caracter%20C3%ADsticos%20de%20la%20regi%C3%B3n.

Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35-46.

Congalton, R. G., & Green, K. (2009). *Assessing the accuracy of remotely sensed data: Principles and practices* (2nd ed.). CRC Press.

Coppin, P., Jonckheere, I., Nackaerts, K., Muys, B., & Lambin, E. (2004). Digital change detection methods in ecosystem monitoring: a review

Costa Posada, C. (2007). La adaptación al cambio climático en Colombia. *Revista de ingeniería*, 74-80.

Del Cairo, J. R. (04 de diciembre de 2017). *PID AMAZONÍA*. Obtenido de <https://pidamazonia.com/content/leyes-normas-y-regulaciones-ambientales-en-colombia>

Díaz, R., & Miranda, J. (2012). *Áreas Naturales Protegidas en el Perú: Efectos sobre la Deforestación y su relación con el Bienestar de la Población Amazónica*. Lima, Perú: Instituto de Estudios Peruanos IEP.

Erasso, C., & Vélez, M. A. (2020). ¿Los cultivos de coca causan deforestación en Colombia? *CESED*, 1-14.

ESRI. (2021). *ESRI Colombia*. Obtenido de ESRI Colombia: <https://sig.esri.co/arcgisblog/inteligencia-artificial/>

ESRI. (24 de agosto de 2022). *ARCGIS*. Obtenido de <https://www.arcgis.com/home/item.html?id=4af356858b1044908d9204f8b79ced99>

Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185-201.

Franco Vivas, J., García Quimbaya, I., Parra Lasso, D. N., Mestanza Ríos, I., & Moreno Palma, A. L. (2020). Informe Región Amazónica. *Informe Observatorio Regional*, 26-28.

García Romero, H. (2013). Deforestación en Colombia. *El Desafío del Desarrollo Sustentable en América Latina*, 123-142.

García, H. (2012). *Deforestación en Colombia: retos y perspectivas*. Bogotá: Fedesarrollo.

García, J., & López, M. (2020). Impacto de la erosión en zonas montañosas de Colombia. Universidad Nacional de Colombia.

García, M., Moreno, A., & Neira, E. (2019). Deep Learning Techniques for the Analysis of Remote Sensing Data. *Remote Sensing Applications: Society and Environment*, 15, 100-112.

Garciglia, R. S. (2014). Deforestación. *Revista de divulgación de la Universidad Michoacana de San Nicolás de Hidalgo*, 31-32.

Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (2002). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 82(1), 127-143.

Gómez, D. y Martínez, F. (2018). Teledetección y su aplicación en el estudio de la cobertura vegetal de Tolima. *Revista Colombiana de Geografía*, 27(2), 112-127.

González Larrarte, Y. L. (2021). *Determinación de las diferencias en el dimensionamiento de los proyectos viales producto de la correcta utilización del único origen nacional de coordenadas en Colombia: estudio de caso*. Bogotá DC.

GREENPEACE. (21 de octubre de 2022). *GREENPEACE*. Obtenido de <https://www.greenpeace.org/colombia/blog/issues/climayenergia/por-que-nos-tiene-que-importar-muchisimo-el-cambio-climatico-y-que-hay-que-hacer-para-que-no-avance/?gclid=CjwKCAiAioifBhAXEiwApzCztp32sAJvXh1ad4toUAjO7WhvFf5MbjA9nEoKVaji3aRWh9W9CDqXoBoCNOgQAv>

Hernández, P. J., Graham, C. H., Master, L. L., & Albert, D. L. (2016). The effect of sample size and species characteristics on performance of different species distribution modeling methods. *Ecography*, 29(5), 773-785.

Herold, M., Liu, X., & Clarke, K. C. (2012). Spatial metrics and image texture for mapping urban land use. *Photogrammetric Engineering & Remote Sensing*, 78(8), 839-852.

Hsu, A. (2019). *Manual de vuelo de drones*. California.

Ibagué, U. d. (29 de septiembre de 2020). *Universidad de Ibagué*. Obtenido de Universidad de Ibagué: <https://www.unibague.edu.co/noticias-institucionales/3003-cambio-climatico-en-el-tolima-adaptacion-y-oportunidad#:~:text=%22La%20temperatura%20aumentar%C3%ADa%20en%20el,10%20%25%22%2C%20describi%C3%B3%20Pab%C3%B3n>.

IBM. (01 de 2023). *IBM*. Obtenido de <https://www.ibm.com/es-es/topics/deep-learning>

IBM. (15 de agosto de 2015). *IBM*. Obtenido de IBM:

<https://www.ibm.com/es-es/topics/deep-learning#:~:text=el%20siguiente%20paso-,%C2%BFQu%C3%A9%20es%20Deep%20Learning%3F,de%20grandes%20cantidades%20de%20datos.>

IGAC. (31 de 01 de 2024). *IGAC*. Obtenido de [https://www.igac.gov.co/el-](https://www.igac.gov.co/el-igac)

[igac](https://www.igac.gov.co/el-igac)

INEGI. (10 de 2023). *INEGI*. Obtenido de

<https://www.inegi.org.mx/investigacion/ndvi/>

INSTITUTO GEOGRAFICO NACIONAL. (2018). *Obtención de productos cartográficos generados a partir de imágenes RPA escala 1:1000*. Lima, Perú.

Jarrín, P. S., Tapia Carrillo, L., & Zamora, G. (2017). Demografía y transformación territorial: medio siglo de. *EUTOPIA*, 93.

Jones IV, G. P., & Vaughan, R. A. (2010). Remote sensing of vegetation: Principles, techniques, and applications. Oxford University Press.

Kerkech, M., Hafiane, A., & Canals, R. (2018). Deep learning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Remote Sensing*, 10(10), 1520.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.

LEY 2 (Corte Constitucional 27 de enero de 1959).

Li, X., & Roy, D. P. (2017). Designed Features for Aerial Image Classification with Convolutional Neural Networks. *IEEE Transactions on Geoscience and Remote Sensing*, 55(5), 2713-2722. DOI:10.1109/TGRS.2016.2645610

Li, X., & Roy, D. P. (2017). The use of Landsat data for sustainable forest management. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(5), 1980-1993.

Longley, P. A., Goodchild, M. F., Maguire, D. J., & Rhind, D. W. (2015). *Geographic Information Systems and Science*. John Wiley & Sons.

Ma, L., Liu, Y., & Zhang, X. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166-177.

Manríquez Zapata, H. M. (2019). Especies forestales afectadas en incendios ocurridos en Amazonas: Un análisis de la información fiscal de los casos de Chachapoyas y Luya. *SciELO Analytics*, 974.

Marapi, R. (2013). La deforestación de los bosques: un proceso indetenible. *La Revista Agraria*, 6-7.

Martínez, S., & Rojas, E. (2018). *Geografía y desafíos del Tolima*. Editorial Académica Española.

Martino, D. (2007). Deforestación en la Amazonía: principales factores de presión y perspectivas. *Revista del Sur*, 18-19.

Masera, O., Ordoñez, M. d., & Dirzo, R. (1992). Emisiones de carbono a partir de la deforestación en México. *Ciencia*, 151-153.

Mallorquín Tovar, A. R., & Moreno Carvajal, M. A. (2022). *Deforestación y minería ilegal "Una mirada a los mecanismos dirigidos a la protección del medio ambiente en Colombia, a partir de la expedición de la sentencia T-622 de 2016"*. Bogotá D.C.: Universidad la Gran Colombia.

Meisel, A., Bonilla, L., & Sánchez, A. (octubre de 2013). *Banco de la República Colombia*. Obtenido de https://www.banrep.gov.co/sites/default/files/publicaciones/archivos/dtser_193.pdf

Ministerio de Ambiente y Desarrollo Sostenible. (7 de septiembre de 2022). *Ministerio de Ambiente y Desarrollo Sostenible*. Obtenido de Ministerio de Ambiente y Desarrollo Sostenible: <https://www.minambiente.gov.co/uncategorized/en-colombia-se-han-deforestado-mas-de-tres-millones-de-hectareas-de-bosque-en-las-ultimas-dos-decadas/#:~:text=Meta%2C%20Caquet%C3%A1%2C%20Guaviare%2C%20Putumayo,los%20seis%20departamentos%20m%C3%A1s%20afectado>

Nieves, F. A., & Ruiz, J. E. (2021). Procesos de deforestación asociados a la minería legal en la Amazonía colombiana. *Revista Ontare*, 9.

Ortega, B., & Gutiérrez, D. (2022). Tecnologías geoespaciales en la planificación del uso del suelo. Editorial Universidad del Tolima.

Pabón Caicedo, J. D. (2003). El cambio climático global y su manifestación en Colombia. *Cuadernos de Geografía: Revista Colombiana de Geografía*, 111-119.

Pérez, F., & Quintana, R. (2021). Aplicaciones de teledetección en la gestión de riesgos naturales. Ediciones GeoPlaneta.

Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J. M., Tucker, C. J., & Stenseth, N. C. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9), 503-510.

Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J. M., Tucker, C. J., & Stenseth, N. C. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9), 503-510.

Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J.-M., Tucker, C. J., & Stenseth, N. C. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9), 503-510.

Pino, E. (2019). Los drones una herramienta para una agricultura eficiente: un futuro de alta tecnología. *IDESIA*, 75-84.

Poveda González, R. E. (2015). *Análisis multitemporal de la expansión urbanística del municipio de La Calera, Cundinamarca, Colombia*. Bogotá DC: Universidad Militar Nueva Granada.

Poveda Jaramillo, G. (2011). El papel de la Amazonía en el clima global y continental: impactos del cambio climático y la deforestación. *Escuela de Geociencias y Medio Ambiente*.

Poveda, G., & Mesa, O. (1995). Efectos hidrológicos de la deforestación. *Universidad Nacional*, 97-98-99.

RAISG. (2021). *MAPBIOMAS*. Obtenido de <https://amazonia.mapbiomas.org/>

Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., & Prabhat, (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195-204.

Revelo Luna, D., Mejía Manzano, J., Montoya Bonilla, B., & Hoyos García, J. (2020). Análisis de los índices de vegetación NDVI, GNDVI y NDRE para la caracterización del cultivo de café (*Coffea arabica*). *SciELO*.

Rodríguez, J. A., & Silva, M. (2021). Impacto de las prácticas agrícolas en la pérdida de cobertura vegetal en Tolima. *Journal of Environmental Management*, 280, 111-123.

Rodríguez, V. (17 de noviembre de 2018). *Vicente Rodríguez*. Obtenido de <https://vincentblog.xyz/posts/redes-neuronales-convolucionales>

Rosero, L. B., & Palloni, A. (1998). Población y deforestación en Costa Rica. *Centro Centroamericano de Población*, 131-150.

Ruiz, J., Cardenas, W., & Baquero, C. (2011). Deforestación y dinámica del bosque secundario en la Amazonia Colombiana 1986-2000. *SCIELO*, 9-10-11.

Salas, R. L., Barboza, E. C., & Oliva, M. C. (2016). Dinámica multitemporal de índices de deforestación en el distrito de Florida, departamento de Amazonas, Perú. *INDES Revista De Investigación Para El Desarrollo Sustentable*, 18-27.

Sánchez, Y., & Carvajal, J. (19 de 07 de 2019). Análisis normativo y jurídico de la deforestación en la selva amazónica colombiana: un paraíso perdido. Cúcuta, Colombia: Ediciones Universidad Simón Bolívar.

Sergieieva, K. (18 de febrero de 2022). *EOS Data Analytics*. Obtenido de <https://eos.com/es/blog/indices-de-vegetacion/>

SIAT-AC. (noviembre de 2022). *SIAT-AC*. Obtenido de <https://siatac.co/la-amazonia-colombiana/>

Smith, B., & Hugenholtz, P. (2020). UAVs for environmental monitoring: Applications and implications. *Remote Sensing*, 12(10), 1636.

Sostenible, M. d. (05 de 01 de 2023). *Ministerio de Ambiente y Desarrollo Sostenible*. Obtenido de <https://archivo.minambiente.gov.co/index.php/redd/importancia-de-los-bosques#:~:text=Por%20Qu%C3%A9%20los%20Bosques%20de%20Colombia%20So>

n%20Tan%20Importantes&text=Regulan%20el%20ciclo%20del%20agua,%2C%20mam%C3%ADferos%2C%20reptiles%20y%20anfibios.

Tiria Forero, L. N., Bonilla Castillo, J. S., & Bonilla Castillo, C. A. (2018). Transformación de las coberturas vegetales y uso del suelo en la llanura amazónica colombiana: el caso de Puerto Leguizamo, Putumayo (Colombia). *Cuadernos de Geografía*, 298-299.

Torrado, S. (09 de febrero de 2022). *El País*. Obtenido de <https://elpais.com/clima-y-medio-ambiente/2022-02-09/arde-la-amazonia-colombiana.html#:~:text=Los%20bosques%20naturales%20cubren%20cerca,de%20C%20aquet%C3%A1%2C%20Meta%20y%20Guaviare>.

Torres, A., & Molina, J. (2019). Inundaciones y gestión del riesgo en el río Magdalena. *Revista de Investigaciones Ambientales*, 11(2), 34-50.

Torres, J., & García, L. (2019). Dinámicas de cambio en la cobertura vegetal de Tolima: Un estudio de 20 años. *Ciencia y Tecnología Ambiental*, 15(1), 22-35.

Turner, D., Lucieer, A., & Wallace, L. (2015). Direct georeferencing of ultrahigh-resolution UAV imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 54(5), 2738-2745.

Turner, W., Spector, S., Gardiner, N., Fladeland, M., Sterling, E., & Steininger, M. (2015). Remote sensing for biodiversity science and conservation. *Trends in Ecology & Evolution*, 20(6), 306-314.

Valenzuela, S., & Sanabria, C. P. (05 de junio de 2022). *El Tiempo*. Obtenido de <https://www.eltiempo.com/vida/amazonia-deforestacion-mineria-agricultura-y-cultivos-ilicitos-577536>

Vargas, Á. M. (2015). *Fotogrametría de Bajo Vuelo por medio de Sistemas Aéreo no Tripulado para Modelación 3D en Área de Riesgo Geológico, Urb. Villa España, Bayamón*. Puerto Rico.

Vo, A., Son, L., Vo, M., & Le, T. (2019). A Novel Framework for Trash Classification Using Deep Transfer Learning. *IEEE XPLORE*.

Wallace, L., Lucieer, A., Watson, C., & Turner,

Willington, E., Nolasco, M., & Bocco, M. (2013). *Clasificación supervisada de suelos de uso agrícola en la Córdoba, Argentina*.

Zhu, X. X., Tuia, D., Mou, L., Xia, G. S., Zhang, L., Xu, F., & Fraundorfer, F. (2017).

Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4), 8-36.