



Pontificia Universidad Católica Del Ecuador

Facultad de Derecho y Sociedad

Carrera de Ingeniería Geográfica y Planificación territorial

Título:

**Implementación de Inteligencia Artificial (IA) en el procesamiento de imágenes
satelitales**

Disertación previa a la obtención del título de Ingeniería en Ciencias Geográficas y
Planificación Territorial

Autor: Fausto Fabricio Muñoz Galarza

Tutor: Ph.D. Monserrath Mejía Salazar

Quito - 2025

Índice De Contenidos

Capítulo 1 Introducción	7
1.1. Antecedentes	7
1.2. Justificación	9
1.3. Planteamiento del Problema	10
1.4. Pregunta de Investigación	12
1.5. Objetivos	12
1.5.1. Objetivo General	12
1.5.2. Objetivos Específicos	12
Capítulo 2 Marco Teórico	13
2.1. Marco Conceptual	18
Capítulo 3 Marco Metodológico	21
3.1. Enfoque Cualitativo	21
3.2. Enfoque Cuantitativo	22
3.4. Algoritmos de Aprendizaje Automático	27
3.4.1. Inducción al Aprendizaje Automático para procesar Imágenes Satelitales	27
3.4.2. Tipos de Aprendizaje Automático en el Procesamiento de Imágenes Satelitales	32
3.4.3. Principales Algoritmos de Aprendizaje en el Procesamiento e Imágenes Satelitales	36
3.4.4. Procedimientos Sofisticados Usados en el Procesamiento de Imágenes Satelitales a través del Aprendizaje Automático	41
3.4.5. Implementación y Evaluación de Modelos de Aprendizaje Automático en el Procesamiento de Imágenes Satelitales	43
3.5. Mecanización del Procesamiento de Imágenes Satelitales con Inteligencia Artificial	48

<i>3.5.1. Inicio de la Mecanización en el Procesamiento de Imágenes Satelitales</i>	48
<i>3.5.2. Elaboración de Imágenes Satelitales con Algoritmos de Inteligencia Artificial</i>	51
<i>3.5.3. Técnicas Avanzadas de IA en el Análisis de Imágenes Satelitales</i>	52
<i>3.5.4. Impacto de la IA en la Planificación Territorial Mediante Imágenes Satelitales</i>	55
Capítulo 4 Presentación de Resultados	60
Presentación de Resultados Cuantitativos	60
Presentación de Resultados Cualitativos Anexo 1	82
Conclusiones	84
Recomendaciones	85
Referencias	86
Anexo 1	91

Índice De Ilustraciones

Ilustración 1. <i>Creación de puntos</i>	60
Ilustración 2. <i>Combinación de bandas</i>	61
Ilustración 3. <i>Clasificación de puntos</i>	62
Ilustración 4. <i>Creación de firmas espectrales</i>	63
Ilustración 5. <i>Algoritmo máxima verosimilitud</i>	64
Ilustración 6. <i>Resultado de la clasificación de máxima verosimilitud</i>	64
Ilustración 7. <i>Filtro mayoritario</i>	65
Ilustración 8. <i>Resultado filtro mayoritario</i>	65
Ilustración 9. <i>Conversión</i>	66
Ilustración 10. <i>Resultados de la conversión</i>	66
Ilustración 11. <i>Resultado final de la clasificación</i>	67
Ilustración 12. <i>Creación de puntos con IA</i>	69
Ilustración 13. <i>Instalación de paquetes numpy, scikit-learn, matplotlib, shapely y scipy</i>	70
Ilustración 14. <i>Instalación de librerías</i>	71
Ilustración 15. <i>Conectar rutas de archivos</i>	71
Ilustración 16. <i>Estimación de índices</i>	72
Ilustración 17. <i>Carga de los puntos de entrenamiento</i>	73
Ilustración 18. <i>Extracción de muestras aleatorias</i>	73
Ilustración 19. <i>Creación del modelo Random Forest</i>	74
Ilustración 20. <i>Creación del archivo .tiff</i>	74
Ilustración 21. <i>Instalación de paquetes de conversión</i>	75
Ilustración 22. <i>Exportación de raster</i>	76
Ilustración 23. <i>Creación de archivo shape</i>	76
Ilustración 24. <i>Creación de matriz de confusión</i>	77
Ilustración 25. <i>Resultados de matriz de confusión gráfica</i>	77

Ilustración 26. <i>Importancia de las bandas</i>	79
Ilustración 27. <i>Resultado final de la clasificación con IA</i>	79

Índice De Tablas

Tabla 1. <i>Operativización de la investigación</i>	26
Tabla 2. <i>Coordenadas</i>	60
Tabla 3. <i>Tabla de tiempo por cada procedimiento con método tradicional de clasificación supervisada</i>	68
Tabla 4. <i>Tabla de tiempo por cada procedimiento con método de aprendizaje automático de clasificación supervisada</i>	80

Capítulo 1 Introducción

1.1. Antecedentes

La incorporación de la inteligencia artificial en el análisis de imágenes satelitales ha permitido resolver algunas de las limitaciones que, durante años, acompañaron la elaboración de mapas y estudios espaciales. En la India, por ejemplo, un equipo liderado por Gangopadhyay et al. (2020) empleó redes neuronales convolucionales para clasificar imágenes y detectar patrones en el uso del suelo. Lo que antes era una tarea manual, sujeta a errores humanos y poco eficiente ante grandes volúmenes de datos, fue automatizado parcialmente con esta tecnología. Utilizando imágenes del programa Landsat así, lograron reducir en un tercio el tiempo de procesamiento, al tiempo que disminuyeron los errores de clasificación. Sin embargo, no todo fue perfecto ya que, las zonas con datos de baja calidad presentaron dificultades técnicas importantes. Aun así, el estudio dejó claro que la inteligencia artificial puede ser clave para mejorar procesos que antes dependían de enfoques tradicionales.

Un caso similar ocurrió en Brasil, Silva et al. (2019) aplicaron algoritmos de aprendizaje profundo para identificar focos de deforestación en la Amazonía. Frente a una problemática urgente como la pérdida acelerada de cobertura forestal, el uso de redes neuronales profundas permitió detectar patrones con una precisión del 85%. Además, los tiempos requeridos para producir mapas se redujeron en un 40%. Eso sí, los investigadores advirtieron que la calidad y disponibilidad de los datos seguía siendo una condición crítica para lograr buenos resultados, y que contar con bases más sólidas mejoraría significativamente los diagnósticos.

En Bangladesh, Ahmed y Rahman (2021) enfrentaron una situación distinta, el riesgo constante de inundaciones. Su propuesta se centró en anticipar estos eventos mediante modelos de inteligencia artificial que combinaron datos climáticos, históricos y satelitales. El

sistema que desarrollaron logró predecir con mayor exactitud las zonas de alto riesgo, con un margen de error 20% menor que el de métodos previos. Sin embargo, no fue sencillo, la dificultad para integrar fuentes de datos distintas y las limitaciones técnicas en algunas regiones del país marcaron los límites del experimento. Aun así, el potencial quedó en evidencia.

En España, Martínez y Pérez (2022) utilizaron técnicas de aprendizaje automático para monitorear transformaciones en la costa andaluza. Lo complicado de producir imágenes de alta resolución en tiempo real significa un reto demandante. Asimismo, el sistema diseñado logró una precisión del 90% en cuanto a detectar las variaciones dadas en el terreno. Por ende, se facilitó la gestión del litoral, principalmente lo que tenía que ver con fenómenos erosivos y la presión proveniente de actividad humana. Dichos autores aclararon que integrar datos de origen local tenía la capacidad de potenciar mucho más los análisis y convertirlos en significativos.

Por otro lado, en Estados Unidos, Johnson et al. (2018) ofrecieron una solución para poder mapear el tráfico en la ciudad de Chicago. Para ello, incorporaron información de sensores, cámaras y celulares, lo que facilitó la creación de mapas al momento con una precisión alta: un 95% de eficiencia en predecir flujos vehiculares. No obstante, el sistema no fue del todo funcional; por ejemplo, en zonas con menor cantidad de datos los resultados fueron reducidos. Esto expuso la importancia de endurecer los sistemas de recolección de información en zonas con menos monitoreo.

Por consiguiente, dichos casos demuestran cómo la inteligencia artificial está cambiando la visión en que se produce aprendizaje espacial. El desarrollo está a la vista, al igual que los procedimientos ágiles en conjunto con la precisión mejorada y muchas actividades han puesto de lado la dependencia de la participación humana. Sin embargo, continúan existiendo obstáculos, tal es el caso de la calidad limitada de los datos disponibles,

lo complicado de incorporar varias fuentes y la demanda de infraestructura con tecnología apropiada. Aunque existen dichos obstáculos, la capacidad de estos recursos para abarcar temas ambientales, sociales y urbanos va en aumento, señalando el inicio de una nueva era debido a la manera en que se ejecuta y se usa la información territorial.

1.2. Justificación

La presente investigación aborda el interés por aplicar herramientas de IA en los distintos procesos geográficos, en particular en la actualidad. Ya que, la disponibilidad de imágenes satelitales y el avance de algoritmos inteligentes abren paso a innovadoras posibilidades para mejorar la gestión del espacio geográfico. De esta manera, se ha podido observar las limitaciones de los métodos convencionales en el procesamiento de imágenes, en cuanto al tiempo solicitado como la precisión. Esta motivación se suma a la necesidad de actualizar los procesos de análisis espacial, por ende, el impulso de examinar cómo puede mejorar la eficiencia del procesamiento de imágenes satelitales con la ayuda de la inteligencia artificial (IA).

De esta manera, una de las contribuciones más relevantes que se espera de este estudio es brindar una comparación práctica y fundamentada entre los métodos tradicionales y los basados en IA. Esta relación evaluará desde la calidad de resultados visuales hasta los indicadores clave como el tiempo de procesamiento, costos de implementación y a necesidad de la intervención humana en los diversos procesos. La meta es desarrollar conocimiento técnico aplicado para que sea de utilidad tanto en entidades públicas como instituciones de planificación territorial. Además, de investigadores y profesionales que trabajan con teledetección y sistemas de información geográfica.

Esta investigación va dirigida a quienes trabajan en el campo de la geografía y confrontan obstáculos en la categorización del uso y la cobertura del suelo, el monitoreo ambiental y la toma de decisiones territoriales basada en datos. Al comparar los resultados de

una clasificación supervisada convencional (usando el método de máxima verosimilitud en ArcGIS) con los de una clasificación basada en inteligencia artificial (usando Random Forest en Python), se visualiza el potencial de la automatización, sin embargo, se dan a relucir las limitaciones que pueden aparecer cuando no se cuenta con la capacitación, los recursos o el tiempo suficientes para mejorar los modelos.

Adicional, el estudio aborda una dificultad mayor al utilizar imágenes satelitales que necesitan analizar vastas cantidades de datos en tiempo reducido y que deben garantizar la pertinencia y la utilidad de los resultados. De este modo, la utilización de la IA es una solución real al deseo de procesar eficientemente, en especial cuando se trata de contextos en los cuales el análisis gráfico deber ser continuo y veloz.

1.3.Planteamiento del Problema

Por mucho tiempo procesar imágenes satelitales ha representado una variedad de complicaciones técnicas y metodológicas. Al comienzo, realizar mapas era un trabajo meramente manual. Por consiguiente, esta perspectiva tradicionalista significaba procesos largos, costo excesivo de la operatividad y el error potencial de la parte humana. Al transcurrir los años la inclusión de recursos como los sistemas de información geográfica (SIG) y la teledetección brindaron un desarrollo importante. No obstante, dichos métodos reflejaron limitaciones visibles, en especial lo que concierne a la gestión de una cantidad vasta de datos y el juicio personal de los expertos. Así, este escenario representaba la necesidad de actualizar mapas y la habilidad de respuesta frente a fenómenos dinámicos como el desarrollo urbano o las catástrofes naturales (Longley et al., 2015; Goodchild, 2018).

Un obstáculo continuo ha sido la inclusión de datos heterogéneos como las divergencias en cuanto a resolución, formato o proyección de imágenes satelitales, información LIDAR o cartografía histórica. Esto dificulta la homogeneidad en análisis territoriales lo que se convierte en zonas geográficamente inestables, en las cuales se necesita

más precisión y una actualización permanente. Adicional, cuando se hace referencia a fenómenos naturales como inundaciones o deforestación, los procesos habituales no han alcanzado respuestas eficientes. Más aún, por la limitada cantidad de recursos capaces de procesar datos simultáneos y con una buena exactitud (Li et al., 2017; Aubretch et al., 2019; Asner et al., 2020).

Al usar técnicas convencionales para el análisis de imágenes satelitales igualmente se ha demostrado que existen falencias latentes. Las perspectivas generales apoyadas en reglas o en la segmentación supervisada requieren mucha injerencia humana. Esto produce resultados que dependen del conocimiento previo del analista y minimiza la persistencia entre estudios. De igual modo, trabajar con imágenes de máxima resolución demanda herramientas computacionales importantes y una buena inversión de tiempo. Esto limita la aplicación que tiene a gran magnitud, por otra parte, es necesario mencionar la dificultad en la detección de variaciones discretas o patrones difíciles en áreas con disparidad geográfica o cambios continuos (Mather y Koch, 2021; Pham et al., 2018).

Este escenario ha dado un vuelco radical gracias a la inteligencia artificial, ya que permite integrar modelos como las redes neuronales convolucionales que han permitido categorizar imágenes con mucha más precisión y velocidad, siendo capaz de identificar cambios en el uso del suelo. Modelos más complicados como ConvLSTM, unen análisis espacial y temporal, lo que los convierte en funcionales para prever fenómenos como inundaciones. Estas mejoras se han encargado de reducir tiempo, costos y han proporcionado procesos de actualización constante, además, de optimizar la toma de decisiones en campos como la planificación territorial (Zhang et al., 2018; Wang et al., 2020; Gangopadhyay et al., 2020).

Los beneficios se hacen constar en los algoritmos de IA, ya que conceden la ejecución de análisis en tiempo récord, inclusive cuando se trata de una vasta cantidad de

datos. Adicional, suprime la variabilidad proveniente de la comprensión humana, lo que favorece la calidad en los productos cartográficos. En estudios dirigidos a la vigilancia ambiental se ha conseguido minimizar los tiempos de análisis en un 40%, lo que refleja una ventaja importante para tomar decisiones adecuadas por parte de organizaciones y autoridades. Sin embargo, se hace evidente que la aplicación de dichas tecnologías necesita infraestructura apropiada y gente capacitada, lo que implica un reto en la mayoría de países en desarrollo (Silva et al., 2019).

1.4.Pregunta de Investigación

¿Cómo puede la inteligencia artificial mejorar la eficiencia en el procesamiento de imágenes satelitales?

1.5.Objetivos

1.5.1. Objetivo General

Analizar procesos aplicando IA para mejorar la eficiencia en el procesamiento de imágenes satelitales.

1.5.2. Objetivos Específicos

O.E.1. Describir los algoritmos de aprendizaje automático que pueden mejorar la interpretación de imágenes satelitales.

O.E.2. Implementar inteligencia artificial en la automatización del procesamiento de imágenes satelitales para verificar su eficiencia.

Capítulo 2 Marco Teórico

La Inteligencia Artificial Usada en el Deep Learning

La puesta en escena del aprendizaje profundo fue producto de los investigadores LeCun, Bengio y Hinton desde 2015, se centra en usar redes neuronales de varias capas para tratar problemas complicados, por ejemplo, la categorización de imágenes o la detección de patrones de una vasta cantidad de datos. En el campo de la cartografía digital se concreta por medio de la aplicación de redes neuronales convolucionales (CNN), las cuales permiten analizar automáticamente datos espaciales a gran magnitud. Debido a estos sistemas, se ha conseguido perfeccionar la precisión y la eficacia en la realización de mapas fundamentados en imágenes satelitales y otras bases geoespaciales. La respuesta basada en inteligencia artificial concede la automatización de varias actividades, lo que conlleva una disminución de tiempos en el proceso y en los costos asociados. Adicional, se aumenta la fiabilidad de los productos cartográficos, asegurando un desarrollo importante en la explicación y la tipificación del territorio (Hinton et al., 2006; LeCun et al., 2015; Bengio, 2012).

Teoría del Aprendizaje Automático

Se describe como una ramificación de la inteligencia artificial que posibilita que un sistema informático aprenda y avance automáticamente partiendo de la experiencia, no necesita programación explícita para cada tarea (Samuel, 1959, citado en Kouatchou et al., 2023). Según la instrucción brindada por la NASA instaurada a teledetección, el aprendizaje automático “usa técnicas de la estadística, matemática e informática para realizar programas de computación que aprendan de los datos para prever una salida” (Kouatchou, Carballo-Vega, Spradlin y Li, 2023). Dicha teoría se fundamenta en un pipeline que abarca: definición del problema, recolección y preprocesamiento de datos, selección de características, diseño y entrenamiento del modelo, ajuste de parámetros y finalmente la predicción. En el contexto geoespacial, los pasos se aplican directamente al procesamiento de imágenes satelitales, en la

cual el aprendizaje automático permite sacar información compleja, mejorar la automatización de actividades y producir modelos predictivos fiables en conjunto con escalables basados en datos reales (Kouatchou et al., 2023).

Clasificación Supervisada

Es un proceso importante en el análisis de imágenes satelitales ya que parte de un grupo predefinido de clases de interés. Por ejemplo, tipos de cobertura de suelo y usa modelos conocidos como las muestras de verdad terreno para adiestrar al algoritmo. Por ende, en la clasificación supervisada el analista brinda categorías previamente rotuladas para conducir la clasificación. En cuanto al aprendizaje automático se entrena un modelo estadístico usando datos de entrada cuyos resultados correctos son conocidos, de manera que el modelo aprenda la conexión entre las propiedades descriptivas (bandas espectrales, índices, etc.) y la clase objetivo.

Después del entrenamiento, el modelo puede otorgar etiquetas de clase a nuevos datos de imagen basado en lo aprendido. Este enfoque ha mostrado ser de vital importancia para la interpretación de imágenes de teledetección, permitiendo mapear con fiabilidad categorías temáticas (vegetación, agua, suelo urbano, etc.) con la condición de que se cuente con un grupo de entrenamiento representativo y un proceso arduo de validación de la clasificación a través de matrices de confusión e índices como el coeficiente Kappa. En definitiva, la clasificación supervisada fusiona conocimiento previo (datos de preparación) y métodos estadísticos de aprendizaje para alcanzar predicciones precisas en imágenes satelitales, así, se convierte en un componente importante de la GeoAI (inteligencia artificial geoespacial).

Redes Neuronales Convolucionales (CNN) para el Procesamiento de Imágenes

El esquema y la organización de las redes convolucionales se le asigna a LeCun, el responsable del progreso de esta arquitectura con el fin de identificar patrones en imágenes a

través de una sucesión de filtros que son capaces de obtener información importante en varias etapas del análisis. Dicha jerarquía de procesamiento ha evidenciado ser de suma utilidad en el tratamiento de imágenes geoespaciales. Su habilidad para reconocer, categorizar y sacar datos relevantes de las imágenes ha admitido que se potencialicen los procesos de elaboración cartográfica. Por consiguiente, la implementación de CNN en el entorno territorial aumenta la precisión de mapas generados y favorece a su continua actualización. Por lo tanto, esta propuesta posee una ejecución directa y adecuada en el progreso del análisis del espacio a través de inteligencia artificial (LeCun et al., 2015).

Algoritmo Random Forest

Más conocido como árboles de decisión es un algoritmo de aprendizaje automático supervisado de conjunto que erige varios árboles de decisión y une sus resultados para beneficiar la precisión de la clasificación. Cada árbol se instruye con una muestra aleatoria de los datos y elige por una clase; la clasificación final se decide por mayoría de votos (es decir, la moda de las predicciones de todos los árboles). Este enfoque usa las fortalezas de varios modelos frágiles para generar un modelo fuerte. Una de sus ventajas es la facilidad de interpretación, la habilidad para manejar grandes cantidades de datos y robustez frente a valores fuera de lo normal y ruido. Adicional, brinda estimaciones internas del error y de la importancia de las variables predictoras.

Geomática: Integración Tecnológica en el Análisis Espacial

A partir de la propuesta de Burrough y McDonnell, la geomática se percibe como una perspectiva integral que emplea múltiples tecnologías como los sistemas de información geográfica (SIG) para la recaudación y la evaluación de datos espaciales. Actualmente, este enfoque está conformado por un sustento firme para crear soluciones cartográficas que incluyan mejores técnicas de inteligencia artificial. La utilización de herramientas analíticas y fuentes de datos varios ha posibilitado la construcción de adaptabilidad y consistencia en la

cartografía con capacidad para responder a problemas geográficos complicados. Adicional, al incluir algoritmos automáticos de procesamiento, se consigue un avance significativo en cuanto a calidad y velocidad del análisis espacial se refiere (Burrough y McDonnell, 1998).

Bandas en Imágenes Satelitales

Las imágenes sacadas a partir de satélites tienen información estructurada en diferentes bandas espectrales. Cada banda está vinculada a un nivel específico del espectro electromagnético. Estas incorporan el espectro visible, las de infrarrojo y las térmicas. De esta manera, se detectan y relucen varias propiedades del terreno y la atmósfera. De acuerdo con Jensen y Lillesand, la combinación adecuada de dichas bandas aumenta la habilidad que tienen los algoritmos para identificar patrones complejos. Por ende, es importante cuando se usan modelos de aprendizaje automático para ordenar imágenes. Por consiguiente, el análisis multibanda se transforma en un recurso sencillo para el avance de cartografías específicas y precisas porque otorga al algoritmo una perspectiva amplia y fragmentada del área observada (Jensen, 2007; Lillesand et al., 2014).

Análisis espacial automático

Uno de los aportes más importantes es hacer el análisis espacial de forma automática con ayuda de la inteligencia artificial en el campo cartográfico. Expertos como Goodchild han indicado el cambio de los flujos en trabajos convencionales gracias al uso de algoritmos para actividades como la categorización automatizada o la identificación de variantes en la cobertura del suelo. Actualmente, la mayoría de las actividades que anteriormente necesitaban una participación humana permanente pueden ser realizadas de manera independiente, con una minimización del tiempo y una mejora en la calidad de los resultados. Este modelo mejora la eficacia permitiendo una mejor actualización en tiempo real de los mapas, algo significativo en entornos en los cuales los datos deben mostrar dinámicas

territoriales fluctuantes como el monitoreo ambiental o la gestión de recursos (Michael Goodchild, 2007).

Aplicación del Big Data en la Geografía

La entrada del Big Data en la geografía ha cambiado de manera reflexiva la forma en que se explican los fenómenos espaciales. Especialistas como Batty (2013) han fundamentado que la disposición de recursos apropiados de vastas cantidades de datos puede transformarse en una fuente preciada de entendimiento sobre el territorio. El análisis a gran escala de datos geoespaciales apoyado por algoritmos de inteligencia artificial, concede identificar patrones imperceptibles a modelos tradicionales. Adicional, favorece la producción de representaciones cartográficas dinámicas y ajustadas a las variantes reales del entorno. La teoría del Big Data, habla de un momento decisivo en la manera en que se perciben los mapas y en su propósito dentro del procesamiento de planificación territorial (Batty, 2013).

La Teoría de la Teledetección

La teledetección es la técnica de obtener información minuciosa sobre objetos o zonas geográficas sin importar el contacto físico directo, ayudándose de sensores remotos que captan datos desde plataformas situadas a una distancia moderada, como satélites o aeronaves. En el campo de las imágenes satelitales, dichos sensores almacenan datos en varias longitudes de onda, esto favorece el análisis del uso del suelo, la entrega de los recursos naturales o el reconocimiento de fenómenos ambientales a gran magnitud (Campbell, 2011; Schowengerdt, 2007).

En cuanto a la teoría, la teledetección se cimienta en el principio de que cada estilo de superficie transmite radiación de modo particular, esto va según sus características físicas y químicas. Esta peculiaridad espectral es capaz de producir productos cartográficos temáticos,

así como mapas de cobertura terrestre o registros de áreas afectadas por sucesos extremos. Al mismo tiempo se ve mejorado el avance tecnológico en los sistemas de sensores y la integración de inteligencia artificial para analizar vastas cantidades de datos. Debido a esto, es factible hacer un monitoreo con más precisión y eficacia de las modificaciones que pasan en el territorio con el paso del tiempo (Lu et al., 2014).

2.1. Marco Conceptual

Inteligencia Artificial (IA)

Es la habilidad de los sistemas de computación para imitar procesos cognitivos humanos, así como el aprendizaje, analizar información y solventar problemas. En el campo de la cartografía digital, su empleo ha sido innovador porque da acceso a grandes cantidades de información geoespacial como imágenes que vienen de satélites que ocupan automatización que acelera la creación de mapas, potencia la precisión de análisis y minimiza los tiempos de operación. Según con las investigaciones de Hinton, Bengio y LeCun (2012), el aprendizaje profundo como extensión de la IA, ha establecido un precedente en las ciencias espaciales favoreciendo una interpretación más detallada de las secuencias espaciales que se originan de datos visuales complicados (Hinton, Bengio y LeCun, 2012; Russell y Norvig, 2016).

Geomática

Une varias disciplinas que reúnen herramientas y técnicas dirigidas al tratamiento de información geográfica. Va desde la recolección y almacenamiento de datos espaciales hasta su análisis e interpretación cartográfica. También se encarga de brindar el soporte técnico para entender y procesar la realidad territorial. La inteligencia artificial ha permitido que se automaticen los procesos cartográficos y todo sea más acelerado (Burrough y McDonnell, 1998).

Sistema de Información Geográfica (SIG)

Son plataformas que gestionan datos espaciales incorporando mapas, imágenes satelitales y otros recursos de información. Su utilización en conjunto con la inteligencia artificial en estos sistemas provoca el incremento de capacidad, lo que se traduce como automatización de actividades que consisten en categorizar imágenes o prever dinámicas territoriales. La unión entre SIG e IA mejora los procesos de planificación y gestión del espacio geográfico (Goodchild, 2007).

Big Data

Gestiona y analiza un grupo de datos grande y complejo, su utilización concede examinar vastos archivos de información geoespacial incorporando imágenes satelitales y datos de sensores remotos. En conjunto con la IA facilitan la detección automática de patrones, prevé análisis y permite comprender de forma rápida y profunda el territorio (Batty, 2013).

Cartografía Automática

Incluye tecnologías que reducen la participación humana en la creación de mapas. Con el uso de la IA se aceleran procesos interpretativos de imágenes satelitales o la identificación de variantes en el uso del suelo. Todo esto permite tener herramientas potentes para la planificación urbana y la gestión ambiental (Goodchild, 2007).

Teledetección

Permite obtener información del entorno terrestre usando sensores que captan la energía reflejada o producida en varias longitudes del espectro electromagnético. Accede a datos extensos y continuos en tiempo real, esto favorece al análisis geográfico a gran magnitud y ayuda a la planificación territorial (Campbell, 2011; Lillesand et al., 2014).

Imagen Satelital

Es una exhibición minuciosa del planeta que se obtiene a través de sensores montados en satélites, dichas imágenes están hechas por diversas bandas espectrales, esto deja de lado paisaje como vegetación, agua o zonas urbanizadas (Jensen, 2007; Lillesand et al., 2014).

Fotointerpretación

Es un proceso encargado de analizar zonas o satélites para identificar elementos que se encuentran en la superficie terrestre. Gracias a ello se detectan cambios en el uso del suelo o fenómenos ambientales (Lillesand et al., 2014; Schowengerdt, 2007).

Evaluación de Eficiencia

Analiza procesos productivos desde el punto de vista de mejora de recursos como tiempo, dinero o capacidad computacional con el fin de expandir resultados. A través del IA se toma en cuenta la velocidad de procesamiento, rendimiento de las unidades de hardware usadas (CPU, GPU, memoria) y la correlación entre costo de operación y la cantidad de datos procesados (Farrell, 1957; Charnes, Cooper, y Rhodes, 1978).

Capítulo 3 Marco Metodológico

La metodología de esta investigación se basó en un enfoque mixto usando métodos cuantitativos y cualitativos. En el ámbito cualitativo se usó la entrevista realizada a técnicos en inteligencia artificial (IA) y en procesamiento de imágenes satelitales para obtener la información necesaria sobre la aplicación de dichos procesos aplicando IA. Por otro lado, en la parte cuantitativa se recopilaron y analizaron ejemplos de proyectos existentes sobre el procesamiento de imágenes satelitales con IA para la toma de decisiones.

Para la aplicación de técnicas de procesamiento de imágenes satelitales con métodos tradicionales (ArcGis) en conjunto con métodos de inteligencia artificial como Random Forest, se tomó la decisión de realizar una categorización supervisada de una imagen satelital en la cual se pueda diferenciar al menos cuatro categorías principales que fueron: cuerpos de agua, suelo urbano, suelo agrícola y forestal.

3.1. Enfoque Cualitativo

Este enfoque se usa para explorar experiencias y percepciones de profesionales en el procesamiento de imágenes satelitales. El instrumento utilizado fue un cuestionario con preguntas semiestructuradas. Se plantearon 5 entrevistas.

Pasos en el Enfoque Cualitativo

- Selección de los participantes: Técnicos con experiencia en proyectos de procesamiento de imágenes satelitales. Poseen conocimientos prácticos acerca del uso de la IA para la interpretación de datos geoespaciales. Se seleccionaron en especial a aquellos que han trabajado en la optimización de tiempos de procesamiento, minimización del uso de recursos computacionales y tareas automáticas.
- Diseño de la entrevista: Se estructuraron entrevistas para abordar el impacto de la IA en el procesamiento de imágenes satelitales. Se formularon preguntas sobre las

- tecnologías usadas (aprendizaje automático), los obstáculos en su implementación y los beneficios observados. Adicional, se incorporaron preguntas específicas sobre:
- Minimización de tiempos de procesamiento en comparación con métodos convencionales.
 - Escalabilidad y capacidad de generalización del modelo en diferentes tipos de imágenes satelitales.
 - Impacto en la toma de decisiones derivado de la mejora en eficiencia del procesamiento.
- **Análisis de datos cualitativos:** Las entrevistas se transcribieron y analizaron a través de un proceso de codificación temática. Se distinguieron patrones en las respuestas que muestran como la IA ha mejorado la eficiencia en la automatización del procesamiento de imágenes satelitales. Así, se analizaron aspectos como:
 - Factores clave que aportan a la reducción de costos operativos.
 - Percepciones de los expertos sobre la efectividad y confiabilidad de la IA en estos procesos.
 - Comparaciones cualitativas entre el rendimiento de la IA y los métodos convencionales (fotointerpretación manual, clasificación supervisada).

3.2. Enfoque Cuantitativo

Se usaron datos cuantitativos sobre los tiempos acerca de los tiempos en los procesos y costos en la interpretación de imágenes satelitales usando herramientas de IA en comparación con métodos tradicionales. Adicional, se utilizaron métricas de automatización como la reducción en los tiempos de ejecución de tareas y la cantidad de datos procesados automáticamente.

Pasos en el enfoque Cuantitativo

- **Recolección de datos secundarios:** Se recopilaron estudios y casos de proyectos anteriores que han implementado IA en el procesamiento de imágenes satelitales, en los cuales se han notificado tiempos de procesos, costos de implementación u operación, reducción de etapas manuales en el flujo del trabajo. Estos datos fueron analizados para obtener una perspectiva general de la eficacia de la IA en el contexto de la interpretación de imágenes satelitales.
- **Análisis comparativo:** se realizó una comparativa de los resultados obtenidos en proyectos con IA frente a aquellos que han utilizado métodos tradicionales. Se analizaron indicadores clave como:
 - Tiempo promedio de procesamiento por imagen
 - Costo computacional (uso de CPU, GPU y almacenamiento)
 - Cantidad de imágenes procesadas en un periodo determinado.
 - Nivel de automatización alcanzado en comparación con procesos manuales.
- **Estudio de caso:** Se seleccionó una imagen satelital de una zona donde se pueda diferenciar con mayor facilidad las cuatro categorías a identificar por medio de una clasificación supervisada. La cual se efectuó de manera convencional por medio del software ArcGis con herramientas de análisis espacial usando el algoritmo de máxima verosimilitud. Mientras tanto que, para realizar la misma clasificación supervisada utilizando inteligencia artificial, se empleó la aplicación web de Jupyter notebook para que a través de lenguaje Python se pueda crear un modelo con el algoritmo Random Forest y se haga la clasificación de manera más precisa.

Para entrenar a ambos modelos se usaron 700 puntos distribuidos entre las cuatro clases a estudiar. Estos puntos fueron creados en un shape para poder

identificar las diferentes firmas espectrales de cada clase y facilitar así los procesos para la clasificación de estas.

Se decidió identificar cuatro categorías para el presente estudio, las cuales fueron: cuerpos de agua, urbano, bosque y agrícola. La elección de estas cuatro categorías es gracias a su relevancia territorial y funcional en la gestión y planificación territorial. Debido a esto, la imagen satelital escogida abarca áreas en las cuales se localizan los diferentes usos del suelo que fueron clasificados.

- Cuerpos de agua: Se escogieron por su valor estratégico en la planificación ambiental y el monitoreo de recursos hídricos. Lagos como: San Pablo o Cuicocha que son visibles en la imagen usada forman parte de ecosistemas delicados.
- Urbano: Representa los asentamientos humanos y su expansión, en el caso de regiones como la Sierra ecuatoriana, el monitoreo del desarrollo urbano es útil para planificar infraestructuras, controlar la ocupación del suelo y mitigar riesgos ambientales.
- Agrícola: Es una cobertura dominante en la mayoría del Ecuador interandino y su inclusión permite evaluar la relación entre actividad productiva y transformación territorial.
- Forestal: Comprende bosques nativos como vegetación secundaria, que cumplen funciones ecosistémicas clave como la regulación hídrica, la captura de carbono y la conservación de biodiversidad.

Técnicas de recolección de datos

- Primera fase: Entrevistas semiestructuradas a expertos y técnicos (método cualitativo)
- Segunda fase: Recopilación y análisis de datos secundarios de estudios de caso, informes de proyectos y otros estudios que hayan usado IA en el procesamiento de imágenes satelitales (método cuantitativo)

Instrumentos de recolección de datos

- Entrevista semiestructurada: Se desarrolló un cuestionario sobre la experiencia de los participantes en el uso de IA para el procesamiento de imágenes.
- Revisión documental: Se revisaron proyectos, artículos académicos, informes de empresas de tecnología y casos de estudio relacionados con el uso de IA en el procesamiento de imágenes satelitales.

Análisis de datos

- Análisis cualitativo: Los datos cualitativos obtenidos en las entrevistas se analizaron mediante técnicas de codificación temáticas, permitiendo identificar patrones y temas comunes en las respuestas.
- Análisis cuantitativo: Se realizó el análisis mediante estadísticas descriptivas, usando programas como Excel, para comparar la eficiencia del procesamiento de imágenes satelitales antes y después de la implementación de IA. Se calcularon promedios y porcentajes de mejora en cuanto a los tiempos de procesamiento y costos.

Tabla 1.*Operativización De La Investigación*

Variables		Indicadores	
Eficiencia en el procesamiento de imágenes satelitales	Tiempo promedio de procesamiento por imagen (segundos/minutos)	Cantidad de imágenes procesadas por unidad de tiempo	
Capacidad de Automatización	Número de tareas automatizadas respecto a los procesos manuales anteriores.	Reducción de la intervención humana en el procesamiento de imágenes.	
Escalabilidad y adaptabilidad del modelo	Capacidad del sistema para procesar grandes volúmenes de datos sin pérdida de rendimiento.	Compatibilidad con diferentes tipos de imágenes satelitales.	Facilidad para transferir el modelo a nuevas áreas geográficas sin reentrenamiento extenso.
Costo-Beneficio de la implementación de IA	Comparación del costo total de implementación con métodos tradicionales (\$ dólares)	Costos operativos en almacenamiento y procesamiento en la nube o servidores locales (\$ dólares)	Reducción de costos laborales al minimizar tareas manuales (\$ dólares)
Integración y Compatibilidad con Sistemas SIG	Facilidad de integración del modelo de IA con herramientas SIG utilizadas en planificación territorial	Compatibilidad con formatos de datos espaciales estándar	
Confiabilidad y Robustez del Modelo	Capacidad del modelo para manejar imágenes con ruido o baja calidad	Sensibilidad del modelo a variaciones en condiciones ambientales (cambios estacionales, nubosidad, etc.)	

3.4. Algoritmos de Aprendizaje Automático

3.4.1. Inducción al Aprendizaje Automático para procesar Imágenes Satelitales

3.4.1.1. Aprendizaje Automático

El machine learning o aprendizaje automático es un área de la inteligencia artificial en la que el aprendizaje de datos y la optimización del rendimiento de los sistemas informáticos no necesitan ser programados para cada actividad. Esto se da gracias a la creación de modelos que precisan patrones elaborados y facilitan deducir comportamientos al ser expuestos a una cantidad de información extensa. De esta forma, la decisión o ejecución de las predicciones está apoyada en antecedentes. (Russell y Norvig. 2016).

En cuanto a la planificación territorial se debe automatizar el análisis de datos espaciales, que son: imágenes satelitales, mapas digitales o bases georreferenciadas. Reemplazando el procesamiento manual y secuencial que requiere de un control centrado para cada distribución y que gasta mucho tiempo. Debido a esto, el aprendizaje automático brinda innovación y eficacia para examinar información territorial, adhiriéndose a entornos que tienen problemas geográficos profundos.

Por consiguiente, la habilidad de superarse consiste en reconocer al aprendizaje automático de otras técnicas computacionales antiguas. Esto se da mediante el ajuste interior de sus directrices así, los algoritmos aprenden constantemente de las falencias y adaptan sus resultados dependiendo de la cantidad de información que tengan. De esta manera, es de gran utilidad para procesar imágenes satelitales, donde la inestabilidad natural del territorio, cambios estacionales, crecimiento urbano, fenómenos ambientales requieren herramientas que sean flexibles y adaptables en tiempo real (Hinton, Osindero y Teh, 2006).

En la ejecución geográfica, el aprendizaje automático usualmente sirve para clasificar coberturas de suelo, detectar modificaciones en el paisaje o anticipar sucesos como la

deforestación o el crecimiento urbano, obligaciones que en el pasado estaban condicionadas por procesos demorosos como la fotointerpretación manual. Por consiguiente, la competencia que tiene este avance tecnológico no recae expresamente en su habilidad para gestionar grandes cantidades de información, más bien reside en su experiencia para moderar el enfoque personal y mejorar la facultad para tomar decisiones en cuanto a territorio se refiere. (Burrough y McDonnell, 1998; Goodchild, 2007).

Es así, que para entender el significado esencial del aprendizaje automático es en gran medida para quienes ocupan inteligencia artificial como para expertos en geografía y planificación territorial que poseen herramientas actualizadas para observar, interpretar y modificar el territorio con mayor exactitud y rapidez. En esta situación, el aprendizaje automático es un progreso tecnológico y una oportunidad para replantear enfoques tradicionales en los que se lleva a cabo el análisis espacial y la gestión de recursos territoriales.

3.4.1.2. Cronología y progreso del Aprendizaje Automático y sus Algoritmos

La historia del aprendizaje automático (AA) se integra como una rama importante de la inteligencia artificial (IA). Oficialmente su origen se da en la década de 1950, con el interés de retratar el razonamiento humano en máquinas. En el ensayo de Alan Turing “Computing Machinery and Intelligence”, se preguntaba si las máquinas podrían tener la capacidad de pensar y razonar, empezando así, un debate filosófico y técnico que sentó precedentes de lo que es el campo de la inteligencia artificial.

Frank Rosenblatt configuró el prototipo llamado “el perceptrón” que es una red neuronal artificial funcional. Este modelo inicial demostró que las máquinas tenían la capacidad de aprender basándose en un proceso de formación a partir de datos. No obstante, las previsiones fueron más allá de lo real en cuanto a la técnica de la época. La privación de habilidad de cómputo y de algoritmos robustos generó incredulidad, desencadenando lo que

se conoce como el primer “invierno de la IA” en los años 70, distinguido por una reducción del financiamiento y del interés académico (Russell y norvig, 2016).

El resurgimiento del aprendizaje automático se dio en la década de 1980, cuando los avances matemáticos y la mejora en los recursos informáticos permitieron el desarrollo de algoritmos más refinados, como las máquinas de soporte vectorial (SVM), los árboles de decisión y los métodos bayesianos. Estas técnicas presentaron la oportunidad de trabajar con datos no lineales y conjuntos de adiestramiento más intrincados, lo que facilitó su aplicación en contextos prácticos, entre ellos el análisis de datos espaciales, a pesar de que aún era de forma emergente.

Fue en la década del 2000 cuando el AA empezó a propagarse significativamente, motivado por tres criterios clave: el rápido crecimiento de datos disponibles (Big Data), la rebaja y el incremento de la capacidad de procesamiento (especialmente gracias a las GPU), y la difusión de bibliotecas y entornos de programación de código abierto como TensorFlow, Keras o Scikit-learn. Lo que facilitó el ingreso a herramientas que en el pasado eran sólo para formación específica, permitiendo el acceso a profesionales de diversas áreas para que incorporaran estas tecnologías en sus estudios (Batty, 2013; Dávila Sguerra, 2023).

Uno de los sucesos que causó más revuelo fue el apogeo de las redes neuronales profundas (Deep Neuronal Networks), particularmente las redes neuronales convolucionales (CNN), que cambiaron la forma de analizar imágenes. LeCun, Bengio y Hinton (2015) expresaron su habilidad en agrupación de patrones espaciales elaborados, sobrepasando técnicas convencionales. Dichos avances hicieron que el AA se transformara en un elemento clave para analizar de manera automatizada las imágenes satelitales, autorizando el procesamiento de millones de píxeles en segundos e identificando modificaciones en la superficie de la tierra con una eficiencia superior.

En geografía, este aumento se ha traducido como un cambio del arquetipo convencional. Anteriormente, los estudios del territorio provenientes de imágenes necesitaban procesos extensos de fotointerpretación manual y un conocimiento profesional para cada zona. En la actualidad, debido a los algoritmos preparados con grandes extensiones de datos, es factible automatizar actividades como la segmentación del uso del suelo, el estudio multitemporal o la identificación de patrones de crecimiento urbano. Esto ha incrementado el trabajo del ingeniero geógrafo, convirtiendo la ejecución de procesos manuales a creador y traductor de sistemas inteligentes implementados en el territorio (López y Castro, 2021).

Hoy en día, los algoritmos de aprendizaje automático son implementados en sistemas de monitoreo ambiental, planificación territorial, prevención de desastres naturales, análisis de deforestación, agricultura de precisión, entre otras implementaciones que necesitan un entendimiento desarrollado del área geográfica. Antes se ocupaba mucho tiempo de investigación, en la actualidad pueden ser minutos con un límite de inexactitud pasable para alternativas adecuadamente respaldadas.

3.4.1.3. Inteligencia Artificial en el Aprendizaje Automático

Gracias a la inteligencia artificial (IA), el aprendizaje automático (machine learning) es una figura clave para representar un grupo de procedimientos que autorizan a los sistemas informáticos aumentar su rendimiento en tareas específicas mediante los conocimientos previos, sin necesitar una programación determinada. De esta forma, la habilidad de aprendizaje es lo que convierte a la IA en un instrumento flexible en varios entornos como los del análisis de territorios y la geografía aplicada.

El AA es necesario ya que a través de extensas cantidades de información se pueden extraer modelos elaborados. Adicional, se pueden integrar nuevos factores para tomar resoluciones con base a datos reales. Por ello se toma en cuenta la conexión entre la

inteligencia artificial general y sus ramificaciones útiles. Gracias a esto, los sistemas pueden aprender a clasificar, predecir, reconocer objetos o comportamientos, e incluso detectar anomalías en datos variados y dinámicos (Russell y Norvig, 2016).

El análisis de imágenes satelitales y el aprendizaje automático son prácticos al momento de comprender datos de teledetección de forma ágil y con menos manipulación por parte del ser humano. Esto no solo reduce costos y tiempo, sino también mejora la capacidad de analizar fenómenos geográficos complejos, como el cambio en el uso del suelo, la expansión urbana o la degradación del medio ambiente (López y Castro, 2021). En la antigüedad, estos análisis dependían mucho de la interpretación manual, lo que era tedioso. En la actualidad, la automatización ofrece un aprendizaje automático que representa un grave avance frente a todo lo convencional.

Otra ventaja, es la ayuda que ofrecen los modelos de aprendizaje automático en plataformas de análisis espacial, que ofrecen anticipar eventos territoriales como inundaciones, deslizamientos o deforestación. Esto facilita la toma de decisiones más informadas para la planificación territorial. Gracias a ello, la gestión de los recursos naturales es más sostenible lo que conlleva a una respuesta antes riesgos naturales de manera más oportuna (Ahmed y Rahman, 2021; Ramírez y Medina, 2022).

Así, el aprendizaje automático no sólo sirve para hacer únicamente predicciones. También permite crear procesos que se adaptan constantemente a nuevas condiciones del entorno o a la llegada de nuevos datos satelitales. Esto hace que la información territorial se pueda actualizar con frecuencia, algo esencial para el monitoreo ambiental, la gestión del riesgo o la planificación del desarrollo urbano y rural (González y Cáceres, 2020). En resumen, esta tecnología no solo cambia la forma en que se procesan los datos geoespaciales, sino también los tiempos, las escalas y las prioridades que se usan para analizar el territorio.

3.4.2. Tipos de Aprendizaje Automático en el Procesamiento de Imágenes Satelitales

3.4.2.1. Aprendizaje Supervisado

El aprendizaje supervisado es una de las técnicas más usadas dentro del aprendizaje automático, sobre todo cuando se trata de procesar imágenes satelitales. Dicha técnica funciona bien en situaciones donde se tienen datos etiquetados, es decir, información ya clasificada y se busca que el modelo reconozca patrones similares en nuevos datos. Básicamente, se entrena al sistema con un conjunto de datos donde cada elemento tiene una etiqueta o respuesta asociada, para que el modelo aprenda a relacionar lo que entra con el resultado esperado. Después, ese mismo modelo puede clasificar datos nuevos que no han sido etiquetados antes (Russell y Norvig, 2016).

En la geografía aplicada, el aprendizaje supervisado ayuda a distinguir varias categorías dentro de imágenes satelitales, como: cuerpos de agua, áreas urbanas, zonas agrícolas o bosques. Esto se logra porque el sistema se basa en firmas espectrales conocidas para cada tipo de suelo. Esta forma de trabajar resulta útil para proyectos de planificación territorial que necesitan mapas temáticos actualizados y confiables para la toma de decisiones acertadas. Por ejemplo, utilizando técnicas como la regresión logística, máquinas de soporte vectorial (SVM) o los árboles de decisión, los algoritmos pueden clasificar cada píxel de una imagen en una categoría específica, teniendo en cuenta su información espectral y espacial (Cheng y Liu, 2020).

La gran contribución del aprendizaje supervisado consiste en reducir considerablemente el tiempo para categorizar imágenes. En entornos en los cuales es importante actuar ágilmente, como en el caso del desarrollo urbano, el deterioro de ecosistemas o la supervisión agrícola, permitiendo que el proceso decisorio se dé oportunamente gestionando información exponencial. Más aún, cuando estos algoritmos se incorporan con sistemas de información geográfica (SIG), su función se incrementa

permitiendo el estudio espacial y la formación de mapas temáticos con la finalidad de gestionar el territorio (Goodchild, 2007; Ramírez y Medina, 2022).

No obstante, existen obstáculos para que el aprendizaje supervisado sirva apropiadamente, por ello, es importante tener bases de datos rotuladas. La excelencia del conjunto de datos de entrenamiento incide de forma directa en la exactitud de los resultados obtenidos. En contextos donde la información es insuficiente o existe varianza geográfica, el prototipo puede experimentar complicaciones para generalizar adecuadamente. Esto conlleva a realizar ajustes regularmente y validar resultados para afianzar el análisis del territorio (LeCun, Bengio, y Hinton, 2015).

Para concluir, el aprendizaje supervisado es un recurso importante para automatizar la categorización de imágenes satelitales en el estudio geoespacial. Su empleo en la planificación territorial ha ido en aumento, gracias a la identificación de estándares elaborados en cantidades exuberantes de información. Lo cual ha otorgado a los expertos un sustento sólido para afrontar los obstáculos en la gestión del suelo y ambiental, además, del crecimiento urbano.

3.4.2.2. Aprendizaje no Guiado

El aprendizaje no supervisado es un método del aprendizaje automático y es usado cuando no hay datos rotulados. Esta técnica no inicia con los datos que ya están categorizados, por el contrario, se dirige a encontrar secuencias omitidas, estructuras internas o grupos dentro de una serie de datos. Es decir, el algoritmo estudia la información sin tener indicaciones anteriores e intenta reconocer conexiones por sí solo. Esta característica lo transforma en un recurso indispensable en entornos donde la información es poca o no existe, generalmente sucede en áreas geoespaciales con una complejidad considerable (Russell y Norvig, 2016).

Las imágenes satelitales que usan el aprendizaje no supervisado facilitan reunir píxeles con características espectrales semejantes, sin requerir previamente la clase a la que pertenecen. Así, puede generar clases homogéneas que no necesariamente se alinean con etiquetas tradicionales como “urbano” o “forestal”. Esta metodología resulta muy útil en los trabajos exploratorios o cuando se busca detectar áreas que presentan características inusuales. Técnica como el algoritmo k-means o clustering jerárquico se han utilizado con éxito en estudios sobre el uso del suelo, la cobertura vegetal o la delimitación de unidades geomorfológicas (Burrough y McDonell, 1998; Mather y Koch, 2011).

Su utilidad se vuelve aún más evidente en regiones remotas de difícil acceso, donde no hay cartografía actualizada ni datos históricos confiables. En esos casos, el aprendizaje no supervisado puede ofrecer una primera visión general del territorio permitiendo generar mapas temáticos iniciales que luego pueden ser ajustados con métodos supervisados o a través de la fotointerpretación. Al automatizar esta etapa exploratoria, se ahorra tiempo y se facilita una toma de decisiones más ágil, algo crucial en tareas de planificación territorial, ordenamiento ecológico o gestión de riesgos naturales (Goodchild, 2007; García y Pérez, 2004).

En consecuencia, este sistema posee algunas barreras por no considerar con rotulados preliminares, los tipos que produce el modelo no manifiestan siempre un significado en la parte práctica. Por ello, es sumamente importante que el evaluador actúe para que descifre adecuadamente los resultados y otorgarles un sentido en el contexto geográfico. También, existe la posibilidad de que los resultados puedan variar según las normas con los que se programe el algoritmo o el nivel de similitud de los datos, lo que demanda un entendimiento firme de la zona de estudio previniendo errores en la decodificación.

Pese a los obstáculos, el aprendizaje no supervisado continúa representando un recurso poderoso en la estructuración de una vasta cantidad de información espacial. Su

destreza para trabajar con datos multiespectrales y que no se manifiesten a simple vista, lo convierte en una herramienta de gran valor en las fases iniciales del análisis territorial. Posibilita distinguir secuencias generales que posteriormente pueden ser depuradas a través de otros métodos más precisos.

3.4.2.3. Retroalimentación en el Aprendizaje

El aprendizaje dado por retroalimentación es un método del aprendizaje automático que se fundamenta en tomar decisiones partiendo de experiencias. Contrario al aprendizaje supervisado y el no supervisado, opera a través de una progresión de prueba y error. En esta técnica, una entidad participa en un entorno tomando decisiones y recibiendo retroalimentación que puede ser positiva o negativa. Esto brinda la posibilidad de readecuar su comportamiento con el fin de potenciar las retribuciones a largo plazo (Sutton y Barto, 2018).

En el campo del procesamiento de imágenes satelitales, este método aún está desarrollándose, con una posibilidad de mejora en el futuro. Se centra específicamente en condiciones donde la mecanización debe guiar decisiones de patrones complejos, como optimizar el desplazamiento de trabajo para categorizar imágenes o elegir qué zonas supervisar de forma permanente. En particular, el sistema podría aprender a escoger los algoritmos que quiera aplicar, el orden y los criterios, en función de las propiedades espectrales de una imagen o de las modificaciones en el contexto geográfico (Zhang et al., 2018).

La utilidad del aprendizaje por refuerzo radica en su habilidad de adaptación a contextos cambiantes. Esto es especialmente útil para imágenes satelitales en áreas afectadas por fenómenos dinámicos (inundaciones, deforestación, expansión urbana). Debido a la flexibilidad, el modelo serviría para vigilar en tiempo real el territorio, estudiando cada

nuevo conjunto de datos receptado y adaptando sus tácticas de forma automática (LeCun et al., 2015; Russell y Norvig, 2016).

Considerando el enfoque de la geografía, este estudio podría simplificar la toma de decisiones cuando se unen sistemas información geográfica (SIG). Las aplicaciones podrían adquirir conocimientos gradualmente acerca de cuáles indicadores o fuentes de datos son más competentes para diversas regiones. Así, en la Amazonía, el sistema podría identificar que las bandas del infrarrojo cercano funcionan mejor para distinguir coberturas vegetales densas, mientras que en áreas urbanas podría priorizar otras combinaciones espectrales.

No obstante, hay obstáculos como el tiempo que requiere entrenar al agente y la dificultad de diseñar entornos realistas donde pueda aprender sin cometer errores graves desde el principio. Además, se necesita una gran cantidad de simulaciones para obtener resultados confiables, lo que implica contar con mucha capacidad computacional (Mather y Koch, 2011).

A pesar de estas limitaciones, el aprendizaje por refuerzo se perfila como una herramienta valiosa en el largo plazo para crear sistemas inteligentes aplicados a la gestión territorial, especialmente en lugares donde la dinámica espacial exige respuestas rápidas, flexibles y sostenibles.

3.4.3. Principales Algoritmos de Aprendizaje en el Procesamiento e Imágenes Satelitales

3.4.3.1. Algoritmos de Clasificación

Los algoritmos de clasificación son una herramienta clave cuando se trata de procesar imágenes satelitales. Su función principal es asignar clases o etiquetas específicas a cada píxel o grupos de píxeles, en base a sus características espectrales. Gracias a esto es posible identificar distintas coberturas del suelo y usos del territorio, como zonas urbanas, áreas agrícolas, cuerpos de agua o vegetación. Desde una mirada territorial, esta capacidad para

dividir el espacio geográfico en categorías temáticas resulta muy útil para el diagnóstico, el monitoreo y la toma de decisiones a distintas escalas.

Uno de los enfoques estadísticos más clásicos utilizados en la clasificación supervisada es la regresión logística. Básicamente, este modelo calcula la probabilidad de que una observación, como un píxel, pertenezca a una determinada clase, usando un conjunto de variables independientes. Es especialmente útil cuando se trabaja con clasificaciones binarias, por ejemplo, para diferenciar entre áreas urbanas y no urbanas o entre zonas inundadas y secas. Su mayor ventaja es que no requiere tanta capacidad computacional y es bastante fácil de interpretar. Sin embargo, presenta limitaciones cuando se trata de clasificar múltiples clases o fenómenos más complejos, que suelen aparecer en paisajes con alta diversidad o transiciones. Por eso, se suele usar en contextos donde los datos están bien definidos o hay poca variabilidad espectral (Mather y Koch, 2011).

Por otro lado, las máquinas de Soporte Vectorial (SVM, por sus siglas en inglés) representan un enfoque más avanzado. Este tipo de algoritmo busca establecer un hiperplano que separe de forma óptima las distintas clases, tratando de maximizar la distancia entre los puntos más cercanos a ese límite. Una de sus fortalezas es que funciona muy bien incluso con pocos datos y en contextos donde las clases no pueden separarse fácilmente de forma lineal. En el análisis territorial, las SVM han sido bastante útiles para trabajar con imágenes satelitales de alta resolución, sobre todo cuando se intenta clasificar zonas urbanas fragmentadas, vegetación diversa o áreas con variaciones espectrales. Además, son bastante resistentes al ruido y a la heterogeneidad del paisaje (Pham et al., 2018).

Aunque estos dos algoritmos tienen enfoques distintos y niveles de complejidad diferentes, ambos forman partes del conjunto de técnicas que se usan hoy en día para el análisis automatizado de imágenes satelitales con apoyo de inteligencia artificial. De hecho, es común que se combinen con otros métodos, como las redes neuronales, para construir

modelos híbridos que beneficien la eficacia y la habilidad de adaptación a territorios con propiedades diferentes.

3.4.3.2. Algoritmos de Clustering

Estos algoritmos son parte del aprendizaje no supervisado y se utilizan para encontrar secuencias dentro de un conjunto de datos amplio, sin la necesidad de contar con rotulados anteriores. Esta propiedad es esencial en el procesamiento de imágenes satelitales, ya que en la mayoría de ocasiones se trata con territorios desconocidos o poca información. En estas circunstancias no es aconsejable preparar un modelo supervisado, por lo cual las técnicas de agrupación se convierten en una opción factible.

El fin de estos algoritmos es simple pero importante: ordenar datos con propiedades espectrales semejantes en grupos uniformes. Una de las técnicas más conocidas es el algoritmo k-means, que reúne los datos en un número establecido de clústeres. Sirve para indagar que los componentes dentro de un mismo conjunto estén lo más próximos entre sí. En cuanto a las imágenes satelitales, se otorgan píxeles con cantidades espectrales homólogas a una misma clase, lo que ayuda a fraccionar cuerpos de agua, zonas agrícolas o áreas deforestadas cuando no hay datos de campo. Su simplicidad y rapidez de procesamiento convierten a k-means en algo extremadamentepreciado en etapas exploratorias o investigaciones regionales a gran magnitud. Sin embargo, al requerir una definición previa del número de clústeres y asumir que todos los grupos tienen forma esférica y tamaño similar, puede generar clasificaciones imprecisas en paisajes complejos (Lilesand et al., 2014).

Un procedimiento bastante usado en el análisis de datos espaciales es la organización jerárquica. Este método no obliga a que se defina de antemano la cantidad de grupos que se desean formar, lo cual es beneficioso cuando se desarrolla con imágenes de regiones donde la ocupación del suelo no es homogénea, más bien indica cambios progresivos o un orden más

complicado como patrones ecológicos. Lo llamativo de este método es que posibilita la construcción de un árbol denominado dendrograma que indica la relación que tienen los datos en diversos rangos, lo que sirve en investigaciones territoriales donde se busca mostrar zonas mixtas o unidades paisajísticas. En este aspecto, su habilidad para exponer relaciones espaciales más imperceptibles brinda un cimiento más productivo para tomar decisiones significativas en la planificación (Jensen, 2007).

La técnica k-means y este método son importantes para generar un primer acercamiento o categorización inicial de los datos. Partiendo de aquí, se puede refinar el estudio a través del trabajo de campo o también conciliando los algoritmos supervisados. En las operaciones que integren inteligencia artificial, estos conjuntos además de servir para categorizar, son útiles para detectar secuencias ocultas en los datos. En ocasiones, estos esquemas no serían visibles con técnicas convencionales, por ello, se transforman en un precedente importante para adiestrar modelos más complejos.

En cuanto a planificación territorial, la relevancia radica en contextos donde hay poca información a disposición. De esta forma, asisten a ejecutar un estudio más eficaz del espacio, minimizando tiempo y recursos. Por esta razón, al momento de unirse con los sistemas de información geográfica, favorecen en la generación de capas temáticas que sirven para gestionar, ordenar y monitorear. Esto se torna relevante en regiones que se están transformando a una velocidad abismal, donde los métodos tradicionales de análisis sencillamente no consiguen captar todos los sucesos que pasan en tiempo real.

3.4.3.3.Principios y Funciones de las Redes Neuronales Artificiales en la IA

Las redes neuronales artificiales (RNA), han evolucionado para convertirse en una parte fundamental dentro del área de la inteligencia artificial y más cuando es acerca del procesamiento de datos complicados, como las imágenes que vienen de satélites. Estas redes están inspiradas en cómo funciona el cerebro humano, aunque claro, de forma simplificada.

Así, las RNA están compuestas por capas de nodos llamadas “neuronas” artificiales que se conectan entre sí y permiten que la información pase, se transforme y se procese gracias a un sistema de pesos y funciones de activación (LeCun, Bengio y Hinton, 2015).

Lo interesante es que, en el análisis de imágenes satelitales, estas redes permiten detectar patrones complejos sin necesidad de que el analista programe reglas específicas. Esto es clave en geografía, ya que interpretar el territorio implica analizar muchas variables al mismo tiempo: bandas espectrales, diferencias espaciales, cambios en las condiciones ambientales, entre otros. Frente a este nivel de complejidad, las RNA se destacan por superar muchas de las limitaciones que tienen los métodos de clasificación más tradicionales.

Una red neuronal, en su forma más simple, está compuesta por tres capas: una capa de entrada (por donde ingresan los datos), una o varias capas ocultas (donde ocurre todo el procesamiento interno) y una capa de salida (donde se obtiene el resultado). En el caso de las imágenes satelitales, cada píxel aporta los valores numéricos que entran como datos, los cuales van pasando por las capas hasta que se logra, por ejemplo, clasificar o un tipo de cobertura del suelo o identificar zonas específicas del territorio. Este enfoque ha demostrado ser realmente eficaz en tareas como detectar la deforestación, identificar cuerpos de agua, mapear zonas urbanas o monitorear cultivos (Sarmiento, 2021).

Una de las cosas más destacables de la RNA es que aprenden solas. Bueno, no exactamente solas, pero sí tienen la capacidad de ajustar sus parámetros internos mientras se entrenan con ejemplos representativos del territorio. A esto se le llama retropropagación del error (backpropagation), y básicamente permite mejorar sus predicciones. Este proceso es fundamental cuando se trabaja con paisajes muy diversos, porque hace que la red se adapte a distintas realidades geográficas o espectrales (Hinton, Osindero y Teh, 2006).

Desde el punto de vista de la planificación territorial, estas redes ofrecen una ventaja enorme: permiten automatizar buena parte del análisis espacial. Esto quiere decir que es

posible generar mapas más actualizados y detallados sin depender tanto del análisis manual, lo que agiliza mucho la toma de decisiones. En proyectos de ordenamiento del suelo o monitoreo ambiental, por ejemplo, las RNA pueden procesar imágenes satelitales de forma rápida y eficaz, lo que ayuda a trabajar con datos objetivos y actualizados (García y Pérez, 2004).

Dicho esto, las RNA contienen algunos obstáculos, para empezar, necesitan ser entrenadas con bases amplias y representativas, lo que no siempre es fácil de conseguir. Además, su entrenamiento puede requerir mucha capacidad computacional. Otro punto crítico es que, muchas veces, no resulta claro cómo llegaron a ciertas conclusiones. A esto se le denomina “caja negra” y es capaz de originar inquietudes en entornos donde la claridad del análisis es relevante.

A pesar de ello, las redes neuronales artificiales se ubican como los recursos más favorables para el análisis automatizado del territorio. Su facultad de aprender y adecuarse las hace colaboradoras importantes al momento de trabajar con imágenes satelitales en regiones activas, otorgando un diagnóstico, una gestión y una planificación geográfica excelentes.

3.4.4. Procedimientos Sofisticados Usados en el Procesamiento de Imágenes Satelitales a través del Aprendizaje Automático

3.4.4.1. Aprendizaje Profundo y Redes Neuronales Profundas

El Deep learning o aprendizaje profundo es una derivación del aprendizaje automático que se ha transformado totalmente en los años más recientes en cuanto a su forma de trabajar con imágenes satelitales. En comparación con los puntos de vista primarios, este procedimiento se fundamenta en redes neuronales profundas (DNN, por sus siglas en inglés) que están conformadas por niveles subyacentes, que dejan que los datos transcurran por diferentes fases, cada una recoge y optimiza la información, lo que da como resultado una

demostración más precisa y formada. Debido a eso, estas redes alcanzan a identificar secuencias muy complicadas y no continuas, que muchas veces otros métodos más sencillos no consiguen lograr (LeCun, Bengio y Hinton, 2015).

Cuando se trata de imágenes satelitales, las redes neuronales profundas se han convertido en una herramienta esencial. Han demostrado ser sumamente eficaces para automatizar tareas como clasificar tipos de cobertura del suelo, identificar cambios en el territorio o incluso predecir de eventos ambientales. Todo esto trabajando con grandes cantidades de datos multiespectrales, que vienen de satelitales como Landsat o Sentinel, los cuales recopilan información en muchas bandas diferentes del espectro, aportando una perspectiva minuciosa del territorio (Jensen, 2007).

Lo que realmente diferencia al Deep learning de otros enfoques es su capacidad de aprender por sí mismo. En lugar de que un experto tenga que definir a mano qué aspectos de una imagen son importantes para clasificarla como: colores, texturas o formas específicas, estas redes aprenden solas las características que son más útiles para distinguir entre clases. Este tipo de automatización es particularmente útil en regiones con mucha complejidad ambiental o donde las coberturas del suelo se mezclan de forma difusa, lo que haría muy difícil aplicar métodos tradicionales (Ramírez y Medina, 2022).

Uno de los modelos más conocidos dentro de este campo es el de las redes neuronales convolucionales profundas (CNN profundas). Estas han sido muy utilizadas en el monitoreo ambiental, análisis de cambios en el paisaje y apoyo a la planificación territorial. Su gran fortaleza está en detectar variaciones muy sutiles en la superficie terrestre, como la expansión urbana o el avance de la agricultura hacia nuevas zonas. Todo esto se traduce en información valiosa para quienes toman decisiones sobre el uso del suelo y las políticas ambientales (Gangopadhyay et al., 2020; Silva et al., 2019).

Desde una perspectiva geográfica, el Deep learning también ha traído consigo avances importantes en la elaboración de mapas temáticos de forma automatizada. Gracias a esta tecnología, hoy es posible generar actualizaciones cartográficas mucho más frecuentes y precisas que las que se obtenían con métodos clásicos. Esto constituyó una urgencia para muchas autoridades locales y organismos de planificación, que poseen recursos actualizados para realizar controles a problemáticas como: la deforestación, la ocupación de zonas de riesgo o el deterioro de ecosistemas frágiles (Ahmed y Rahman, 2021).

No obstante, aplicar redes neuronales profundas no está libre de obstáculos, como lo son el requerir enormes cantidades de datos que ya están catalogados para adiestrarlos adecuadamente, de forma usual esto no es tan simple de alcanzar. También se requiere de una infraestructura computacional bastante potente, lo cual puede ser una barrera para muchos equipos de investigación. Además, uno de los puntos más discutidos es lo complicado que puede resultar interpretar cómo llegan estas redes a conclusiones. Esa falta de transparencia ha hecho que crezca el interés por desarrollar técnicas que permitan entender mejor lo que sucede dentro de estos modelos (Wang, Li y Zang, 2020).

Con todo y estas limitaciones, el aprendizaje profundo se perfila como una de las herramientas más prometedoras para el análisis geoespacial del futuro. Su capacidad para adaptarse, aprender y detectar lo que otras técnicas no pueden ver, la convierte en una aliada necesaria para afrontar los obstáculos que plantea el análisis del territorio en contextos cada vez más dinámicos y complejos.

3.4.5. Implementación y Evaluación de Modelos de Aprendizaje Automático en el Procesamiento de Imágenes Satelitales

3.4.5.1. Procesos de Entrenamiento y Validación de Modelos

Cuando se trabaja con imágenes satelitales y se aplican técnicas de inteligencia artificial, una de las fases más críticas es sin duda el entrenamiento y validación de modelo.

Esta etapa no es solo un paso técnico más, sino que determina en gran medida si el algoritmo va a funcionar de manera confiable cuando se aplique a situaciones reales. En términos simples, se trata de enseñar al modelo a identificar patrones y estructuras dentro de los datos que suelen ser imágenes multiespectrales o hiperespectrales, para poder llevar a cabo tareas como clasificar coberturas del suelo, segmentar regiones o detectar cambios importantes en el paisaje (LeCun, Bengio y Hinton, 2015).

El entrenamiento implica alimentar al modelo con un conjunto de datos que ya ha sido etiquetado previamente. Es decir, que la muestra de imágenes que ya han sido clasificadas, ya sea por especialistas o a partir de mapas existentes que sirven de referencia. A medida que se expone a estos datos, el modelo va ajustando sus parámetros internos (como los pesos de sus neuronas) para ir detallando su capacidad de predecir correctamente. Este proceso es repetitivo y se va ajustando gracias a funciones que miden errores, combinadas con algoritmos de retroprogramación, especialmente cuando se trabaja con redes neuronales profundas (Hinton et al., 2006).

Dicho esto, entrenar el modelo no es suficiente. Para saber si realmente aprendió y no sólo memorizó los datos, se utiliza un segundo conjunto de imágenes: el conjunto de validación. Este nuevo lote de datos nunca fue visto por el modelo durante el entrenamiento, y sirve justamente para corroborar si lo que aprendió puede generalizarse. Es decir, si el modelo también funciona con imágenes nuevas. De no ser así, es muy probable que se encuentre frente a un caso de (overfitting), donde el modelo se ajustó demasiado a los datos originales y no es útil más allá de ellos.

Cuando se trata de imágenes satelitales, la selección del conjunto de datos cobra aún más relevancia. No basta con tener muchas imágenes, es necesario que estas reflejen distintas realidades geográficas, temporales y climáticas. Si se busca aplicar el modelo a grandes regiones como suele ocurrir en estudios de ordenamiento territorial, esta diversidad

en los datos es crucial. Una técnica que suele emplearse para mejorar la validación cruzada k -folds es dividir los datos en varios grupos para ir entrenando y validando el modelo de forma más equilibrada (Russell y Norvig, 2016).

Por otro lado, investigaciones recientes han comenzado a destacar lo importante que es incluir imágenes provenientes de distintas fuentes satelitales (como Sentinel-2, Landsat-8 o WorldView). Esta combinación de fuentes no solo enriquece el modelo, sino que también lo vuelve más robusto y versátil. Así, se vuelve más útil para distintas aplicaciones, incluso aquellas que puedan surgir con nuevas misiones satelitales o escenarios geográficos distintos (Dávila Sguerra, 2023).

En resumen, entrenar y validar correctamente un modelo de IA es mucho más que una formalidad. Es una parte esencial del proceso que garantiza que los resultados tengan valor científico, que el procesamiento sea eficiente y que las salidas sean realmente útiles para quienes toman decisiones en temas como la planificación del territorio. Sin una base sólida en esta etapa, cualquier análisis posterior pierde fuerza y confiabilidad.

3.4.5.2. Métricas y Evaluación del Rendimiento de los Algoritmos

Después de entrenar y validar un modelo de aprendizaje automático, el paso siguiente y no menos importante es evaluar cómo se comporta ese modelo, y para eso se necesita contar con métricas que realmente reflejen su desempeño. Estas métricas no solo sirven para comparar diferentes algoritmos, sino que también ofrecen una mirada más precisa sobre cómo el modelo reacciona ante nuevos datos. En el caso de las imágenes satelitales, la evaluación va más allá del plano técnico, ya que está estrechamente ligada a necesidades reales del territorio, como entender cómo se está usando el suelo, planificar zonas urbanas o detectar cambios ambientales que puedan ser críticos.

En trabajos aplicados donde se analiza qué tan eficiente es el procesamiento, suele prestarse atención a variables como el tiempo que tarda el modelo en ejecutar sus tareas, el nivel de automatización que logra y cuántos recursos computacionales consume. Estos aspectos están muy relacionados con la posibilidad de implementar modelos de IA a gran escala, sobre todo cuando se habla de territorios amplios. A diferencia de otros campos en los que lo más importante es cuán preciso es el resultado, en este tipo de estudios el foco suele estar en qué tan útil, replicable y oportuno es lo que el modelo entrega (Charnes, Cooper y Rhodes, 1978).

Una de las métricas más comunes es el tiempo promedio que tarda en procesar una imagen. Esto ayuda a entender si el modelo realmente aporta una mejora respecto a métodos manuales o más tradicionales. Otra métrica interesante es el porcentaje de tareas que el modelo logra automatizar dentro de todo el flujo de trabajo. Cuanto mayor sea este valor, menor es la intervención humana, lo cual representa una ganancia en términos de tiempo, esfuerzo y recursos. También se analizan cuestiones técnicas como el consumo de memoria RAM o la carga que el modelo genera sobre el CPU mientras se ejecuta, especialmente si se piensa usar en infraestructuras con capacidad limitada.

Otro punto clave a considerar es la escalabilidad. Es decir, cuántas imágenes puede procesar el modelo a la vez sin que su rendimiento se vea afectado. Esto es fundamental cuando se trabaja con grandes volúmenes de datos o con regiones que se actualizan constantemente. Además, conviene verificar qué tan robusto es el modelo ante imágenes que no están en condiciones ideales, como aquellas que presentan inferencias atmosféricas o baja calidad. Esto permite anticipar cómo responderá el algoritmo en condiciones reales, que casi nunca son perfectas (Farrell, 1957).

Por último, comparar lo que el modelo basado en IA logra con respecto a métodos tradicionales como la interpretación manual de imágenes o la clasificación hecha por

expertos es clave para saber si realmente vale la pena implementarlo. En este tipo de comparaciones no solo importa qué tan rápido trabaja el modelo, sino también si sus resultados pueden reproducirse, si permiten ahorrar recursos, y si el producto final es útil para quienes toman decisiones sobre el territorio. En definitiva, integrar estas métricas ofrece una mirada más completa sobre la eficacia del modelo y facilita su uso dentro de proyectos de planificación o gestión espacial.

3.4.5.3.Optimización de Modelos

La optimización de modelos en el aprendizaje automático es una etapa clave para mejorar tanto el rendimiento como la eficiencia de algoritmos. No implica únicamente ejecutar el modelo para que funcione, más bien se trata de alcanzar que lo haga de un modo más efectivo, en esencia cuando se afronta con datos elaborados como los que se obtienen de las imágenes satelitales. En investigaciones de planificación territorial o monitoreo ambiental, donde los factores geográficos se modifican y vinculan continuamente, disponer de un modelo que esté correctamente limitado puede señalar una enorme distinción.

Una de las rutas principales que conducen a la optimización es la adaptación de hiperparámetros, que son cifras no aprendidas a lo largo del entrenamiento, más bien se precisan con anterioridad, como el índice de aprendizaje, el número de capas escondidas o el tamaño del lote de datos (batch size). Pese a que se muestren aspectos técnicos, poseen un efecto inmediato en la habilidad del modelo para adquirir conocimiento de manera eficiente. Para hallar una buena combinación, se deben utilizar procedimientos como la validación cruzada, la búsqueda exhaustiva (grid search) o algoritmos más avanzados como la optimización bayesiana, Todo esto depende de la complejidad del prototipo y de los recursos que estén a la mano (Russell y Norvig, 2016).

Adicionalmente, de la adecuación de hiperparámetros, existe la reducción de dimensionalidad. Las imágenes satelitales, en especial las multiespectrales o hiperespectrales

albergan decenas o cientos de bandas. Esto produce datos en cantidades exponenciales. Minimizar esta dificultad, manteniendo la información importante colabora para que el prototipo trabaje con más rapidez y se centre en lo más esencial. De esta manera, las herramientas como el Análisis de Componentes Principales (PCA) o los autoencoders desempeñan esta función de forma impecable (Mather y Koch, 2011).

No obstante, optimizar consiste no sólo en trabajar el prototipo en sí, sino que se debe pensar en todo el escenario. Empezando por escoger aplicaciones de tratamiento en la nube o contextos simultáneos que agilicen el tiempo, para que sean automáticas las tareas como limpiar datos o la división anterior de los mismos. Hacer uso de bibliotecas como TensorFlow o PyTorch, que han sido concebidas para extraer al máximo el beneficio del hardware, puede influir de manera determinante en la eficacia integral del sistema.

En resumen, la optimización se transforma en una acción integradora que se dirige desde resoluciones técnicas muy específicas hasta tácticas más generales que unen el avance computacional con las metas territoriales de la investigación. En cuanto al procesamiento de imágenes satelitales, esta perspectiva completa no solo progresa la exactitud del prototipo, adicional concede que sus resultados sean más prácticos, disponibles e implementables en entornos prácticos.

3.5. Mecanización del Procesamiento de Imágenes Satelitales con Inteligencia Artificial

3.5.1. Inicio de la Mecanización en el Procesamiento de Imágenes Satelitales

3.5.1.1. Mecanización a través de la IA

La mecanización promovida por la inteligencia artificial ha innovado el procesamiento de imágenes satelitales. Actualmente, a través de algoritmos desarrollados, es factible tratar grandes cantidades de información geoespacial casi sin influencia humana.

Gracias a esto, han aumentado notablemente los procedimientos y perfeccionado su exactitud, simplificando el acceso a grandes áreas de manera simultánea. Lo que antes exigía horas de análisis manual ahora puede resolverse en minutos, con la capacidad de detectar patrones complejos en diversos entornos: desde selvas tropicales hasta regiones áridas (Goodchild, 2018; LeCun et al., 2015).

La IA en la Geografía y la Planificación Territorial

- Optimización en la toma de decisiones

La diferencia en tiempos de respuesta es notable. Tareas que antes requerían semanas ahora se completan en horas gracias a modelos como U-Net, que analizan imágenes de Sentinel-2 para detectar fenómenos como la deforestación en la Amazonía ecuatoriana (Ramírez y Medina, 2022). Así, el Ministerio del Ambiente en Ecuador es un ejemplo que ya cuenta con un sistema de alertas casi inmediatas ante cualquier cambio en la cobertura de la vegetación. Lo cual, permite actuar rápido frente a la tala ilegal.

- Menor subjetividad y mayor precisión

El uso del suelo es una variable crítica territorial. Hoy, las redes neuronales convolucionales (CNN) permiten eliminar la carga subjetiva en la interpretación técnica y mejorar la objetividad en la toma de decisiones. Estas redes alcanzan tasas de éxito superiores al 90% al diferenciar zonas urbanas de rurales con gran exactitud (Zhang et al., 2018). En ciudades como Quito, estas herramientas han sido importantes para detectar asentamientos irregulares en zonas de riesgo, lo que representa un avance significativo para la seguridad urbana (Jones y Smith, 2019).

- Cobertura en áreas extensas

Una de las ventajas más destacables es la capacidad para analizar territorios extensos y diversos como los de Ecuador, en las regiones: costa, sierra y Amazonía. Así se tiene el

proyecto Amazonía 4.0, que ha logrado mapear más de 500.000 hectáreas usando modelos de aprendizaje profundo y sensores multiespectrales (Silva et al., 2019).

- Compatibilidad con herramientas actuales

Un gran punto a favor es contar con la existencia de las extensiones de IA compatibles con un software ampliamente utilizado como QGIS o ArcGIS. Esto facilita su adaptabilidad tanto en universidades como en instituciones públicas sin necesidad de grandes inversiones ni capacitación extra (Gangopadhyay et al., 2020).

3.5.1.2. Progresión de las Técnicas de Procesamiento hacia la Integración de IA

El empleo de imágenes satelitales en los campos de la geografía y la planificación territorial ha experimentado una transformación significativa con la introducción de la inteligencia artificial (IA) especialmente en sus procesos de análisis e interpretación. Los enfoques han sido variados, desde los que son meramente visuales hasta las representaciones mecanizadas que están fundamentadas en enfoques de aprendizaje automático.

En el transcurso de los años 70 y 80, el estudio de imágenes satelitales estaba sujeto especialmente al análisis visual, en donde expertos en geografía y teledetección debían actuar además de descifrar de forma manual secuencias y componentes existentes en las imágenes (Campbell, 2011). Dichos métodos eran extenuantes en cuanto a tiempo se refiere y necesitaban un grado de entendimiento profesional. Esto ocasionaba que exista un vínculo muy fuerte hacia la participación directa de la humanidad para generar resultados confiables.

Así, el desarrollo de las ciencias de la computación consintió que nazcan métodos digitales para procesar imágenes satelitales, incluyendo técnicas como la categorización supervisada y no supervisada (Lillesand et al., 2014). Pese a que estos recursos significaban una mejoría relevante, todavía se necesitaba mucha contribución social.

Con la aparición de la inteligencia artificial, se consiguió mecanizar la mayoría de análisis de imágenes. El aprendizaje automático, brinda la posibilidad de reconocer mecánicamente elementos y secuencias en imágenes desde datos anteriormente analizados, esto favorece la identificación de modificaciones y la categorización de la cubierta terrestre (LeCun et al., 2015).

En esta situación, las redes neuronales convolucionales (CNN), una versión del aprendizaje profundo, han surgido como uno de los métodos más eficientes. Las CNN son aptas para instruirse en esquemas jerárquicos que les permiten reconocer secuencias concretas en imágenes satelitales (Hinton et al., 2006).

3.5.2. Elaboración de Imágenes Satelitales con Algoritmos de Inteligencia Artificial

3.5.2.1. Agrupación de Métodos Supervisados Implementados en el Análisis Territorial

En el análisis de territorios a través de imágenes satelitales, los algoritmos supervisados son extensamente usados en el aprendizaje automático. Su eje principal es instruir prototipos con datos anteriormente rotulados, logrando después reconocer secuencias y segmentar datos nuevos no rotulados, tales como clases de vegetación, cuerpos de agua o tipos de uso de suelo.

El procedimiento empieza con el reconocimiento de las cualidades importantes del conjunto de datos que serán ocupadas en la categorización, como la reflectancia espectral, la textura o la forma (Cheng y Liu, 2020). Después, se designa rótulos a los datos de adiestramiento, así se tiene a los píxeles agrupados como: “bosque”, “área urbana” o “cultivo” (Lillesand et al., 2014).

Dicha información rotulada es útil para adiestrar al prototipo, el cual se instruye identificando conexiones entre propiedades y grupos (LeCun et al., 2015). Para evaluar su

desempeño, se hace uso de un grupo de validación, y si es indispensable, se adecúan los criterios del prototipo para incrementar su exactitud (Ahmed y Rahman, 2021).

Un enfoque diferente en el interior de los métodos supervisados es la división, que comprende en distribuir una imagen en regiones similares según características comunes. Esta técnica permite identificar áreas específicas de interés, como construcciones, redes viales o masas de vegetación (Romón Jacob, 2021).

El procedimiento es similar al de la clasificación: se determinan primero las características relevantes, se etiquetan segmentos representativos de la imagen y luego se entrena el modelo para que reconozca patrones similares en imágenes nuevas (Bengio, 2012). Posteriormente, se valida su rendimiento y se ajustan los parámetros según los resultados obtenidos (Ahmed y Rahman, 2021).

3.5.3. Técnicas Avanzadas de IA en el Análisis de Imágenes Satelitales

3.5.3.1. Redes Neuronales Profundas: Aplicaciones Geográficas Específicas

Las redes neuronales profundas (DNN, por sus siglas en inglés) representan una herramienta avanzada de aprendizaje automático con gran potencial en el análisis de imágenes satelitales, gracias a su capacidad para detectar patrones complejos en grandes volúmenes de datos. Dichas redes comprenden varias capas de nodos intervinculados, que convierten paulatinamente los datos de ingreso.

- (CNN) Redes neuronales convolucionales

En esencia son eficientes para identificar secuencias en imágenes bidimensionales, lo que las convierte en apropiadas para actividades como el reconocimiento de elementos, el reconocimiento de alteraciones y la categorización de la utilización del suelo (LeCun et al., 2015).

- (RNN) Redes neuronales recurrentes

Dado que su capacidad para examinar datos lineales es funcional, son usadas especialmente en el estudio de series temporales, como el seguimiento de cambios en la vegetación o la proyección de fenómenos como inundaciones (Sutskever et al., 2024).

Estas dos estructuras brindan una gran exactitud y versatilidad, porque se pueden adaptar de acuerdo con el funcionamiento de la complejidad del prototipo (cantidad de capas). Sin embargo, existen obstáculos como la demanda de volúmenes de datos rotulados extensos para su instrucción y la complicación para analizar sus decisiones, esto puede intervenir en la toma honesta de conclusiones (Lu et al., 2014).

Aplicaciones Geográficas Específicas

- Tipificación de la cobertura terrestre: Funciona para reconocer varias clases de cobertura como, cuerpos de agua, áreas forestales o zonas agrícolas (Cheng y Liu, 2020).
- Monitoreo de variaciones: Sirve para reconocer cambios como la deforestación, crecimiento urbano o desarrollo de la frontera agrícola (Lu et al., 2024).
- Reconocimiento de objetos: Capaz de identificar estructuras como edificios o caminos en entornos urbanos y rurales (Romón Jacob, 2021).
- Predicción de inundaciones: Mediante el análisis temporal de imágenes, se pueden anticipar eventos hidrológicos en áreas vulnerables (Ahmed y Rahman, 2021).

3.5.3.2. Análisis Multiespectral y Temporal con Inteligencia Artificial

El análisis multiespectral y temporal ha ganado fuerza gracias a la aplicación de la inteligencia artificial. Esto ha permitido mejorar notablemente la forma en que se interpretan los datos obtenidos por satélites. De esta forma, las imágenes captadas incluyen bandas que abarcan desde el espectro visible hasta el infrarrojo, cada una con una función específica. Por

ejemplo, algunas bandas resaltan la vegetación, otras la humedad o la presencia de agua. Este tipo de imágenes provienen de misiones como Landsat o Sentinel (Jensen, 2007; Lillesand et al., 2014).

Al utilizar este tipo de datos, es posible obtener una representación más clara del uso del suelo. Desde hace décadas, se ha recurrido a índices como el NDVI para observar la vegetación. Sin embargo, los avances actuales permiten algo mucho más sofisticado. En lugar de depender de combinaciones fijas de bandas, los algoritmos de inteligencia artificial pueden procesarlas todas al mismo tiempo. Gracias al aprendizaje automático, se identifican patrones complejos que una persona probablemente no notaría a simple vista. Esto conduce a resultados completos y de alto grado de confiabilidad (Sarmiento, 2021; Dávila Sguerra, 2023).

Otro aspecto clave es el análisis temporal que consiste en comparar imágenes de distintos momentos y permite ver cómo ha cambiado un territorio con el paso del tiempo. Esta capacidad se potencia cuando se dispone de archivos históricos amplios, como los del programa Landsat, que existen desde 1976. Usando esta información, los modelos con IA pueden detectar procesos como la expansión urbana, la pérdida de vegetación o incluso la transformación progresiva de ciertos ecosistemas (Lu et al., 2014; Asner et al., 2020).

Al combinar tanto el análisis temporal como el espectral, se obtiene una herramienta muy potente. Así, modelos como las redes neuronales recurrentes o las arquitecturas ConvLSTM pueden capturar tanto el componente espacial como el cambio en el tiempo. Estos modelos aprenden a partir de datos de distintos sensores, lo que los hace útiles incluso en regiones donde las condiciones son difíciles de prever.

Estas herramientas no solo se quedan en lo técnico. Tienen aplicaciones prácticas en la planificación territorial. Permiten observar cómo cambia una zona agrícola, medir el crecimiento de una ciudad o evaluar el daño después de incendios o inundaciones. También

ayudan a tomar decisiones más informadas al generar mapas detallados y actualizados, Por lo tanto, en caso de emergencia, la respuesta puede ser más rápida y precisa gracias a los sistemas automatizados. (Silva et al., 2019; Ramírez y Medina, 2022).

De este modo, el uso de la inteligencia artificial transforma el análisis multiespectral y temporal haciéndolo comprensible para el ser humano con respecto a los cambios territoriales. Es capaz de brindar un punto de vista general al combinar el “que” (información espectral) y el “cuando” (información temporal), lo que favorece a la gestión territorial otorgando información continua y en tiempo real. (Mather y Koch, 2011; González y Cáceres, 2020).

Además, esta tecnología permite generar alertas tempranas. Algo impensable con los métodos tradicionales. Al reducir el tiempo que toma analizar y procesar la información, se optimizan los recursos destinados a monitorear el territorio. Así, gobiernos locales y entidades ambientales pueden trabajar de forma más estratégica.

Finalmente, esta evolución tecnológica también beneficia la integración con sistemas de información geográfica. Al contar con datos precisos y actualizados en todo momento, se facilita una planificación más sensible a los cambios. La cartografía se vuelve dinámica y más ajustada a las necesidades reales de cada región. Gracias a los avances en algoritmos y la disponibilidad creciente de imágenes satelitales de alta resolución, la gestión territorial está entrando en una nueva etapa.

3.5.4. Impacto de la IA en la Planificación Territorial Mediante Imágenes Satelitales

3.5.4.1. Ventajas de la Inteligencia Artificial en Decisiones Sustentadas por Datos

Geoespaciales

La incorporación de la inteligencia artificial al análisis de imágenes satelitales ha marcado un antes y un después en la planificación territorial. En el pasado, los métodos

tradicionales se basaban en mapas estáticos y en la observación directa, lo que limitaba la posibilidad de reaccionar con rapidez frente a los cambios del entorno. Ahora, gracias a herramientas automatizadas impulsadas por la IA, es posible procesar grandes volúmenes de información geoespacial casi en tiempo real. Esta capacidad acelera los tiempos de respuesta y mejora sustancialmente la calidad de las decisiones que deben tomarse en el ámbito territorial (Goodchild, 2007; Batty, 2013).

Una de las principales fortalezas de la IA es su habilidad para detectar patrones espaciales complejos que muchas veces pasan desapercibidos con técnicas convencionales. Dicha cualidad es una pauta para vigilar sucesos tales como: la ausencia de vegetación, el deterioro del suelo o el desarrollo de las ciudades encima de zonas naturales. Las brigadas que están a cargo de la organización requieren disponer de información fiable y reciente para prever eventuales riesgos y proponer soluciones adecuadas (Zhang et al., 2018; Ramírez y Medina, 2022).

Adicional, dicha tecnología facilita mezclar diversas clases de datos como: registros históricos, variables sociales o económicas, e imágenes comprendidas iniciando desde el espacio en el interior de un único enfoque analítico. Esto le brinda a la jurisdicción la oportunidad de generar prototipos que representan panoramas a futuro además de explicar lo que está pasando. Por ende, es posible contrastar políticas, analizar sus efectos y escoger la solución ideal basada en demostración concisa y reproducible (García y Pérez, 2024; Aubrecht et al., 2019).

Otra contribución destacable de la inteligencia artificial es la exactitud con la que se reproducen mapas temáticos. Debido a la utilización de redes neuronales y tácticas de categorización desarrollada, es capaz de identificar hasta las modificaciones más insignificantes en el paisaje. Esta exhaustividad es imprescindible para diseñar infraestructura, implementar reglamentos del territorio o cuidar zonas ecológicas

susceptibles. En los años más recientes, el aprendizaje profundo ha sintetizado la labor de reconocer anomalías mínimas pero relevantes, anteriormente esto necesitaba demasiado tiempo y medios (Silva et al., 2019; Lillesand et al., 2014).

Por otra parte, los prototipos sustentados en IA son capaces de prever lo que puede llegar a suceder, además, de examinar lo sucedido. Al ser instruidos con datos satelitales históricos y factores ambientales, son capaces de anticipar el efecto territorial de algunos eventos climáticos o visualizar el desarrollo urbano. Esta clase de pronóstico simboliza una ganancia evidente para la supervisión de la contingencia. Facilitando intervenir antes de que una problemática se transforme en una crisis (Lu et al., 2014; LeCun et al., 2015).

En definitiva, lo que en verdad modifica la dinámica es que la inteligencia artificial convierte a las imágenes satelitales es un recurso táctico. No se reduce únicamente a ver el territorio, más bien comprenderlo, preverlo y administrarlo de forma óptima. Para los expertos en planificación, esto se reduce a captar decisiones de forma más rápida, precisa y fundamentada. Se descarta la perspectiva reactiva, limitada y lenta, para proseguir hacia una organización previsible, que se fundamenta en datos precisos y en un enfoque sostenible de desarrollo territorial.

3.5.4.2.Limitaciones Técnicas en los Procesos Territoriales

A pesar de que la incorporación de la inteligencia artificial en el tratamiento de imágenes satelitales ha avanzado notablemente, la habilidad de resolver y la eficiencia han representado algunos problemas técnicos desde la perspectiva de la planificación territorial. Dichos obstáculos son de origen tecnológico, de la divergencia en los contextos y estructuras que impactan la aplicación y la ampliabilidad de las alternativas de IA en diversas regiones geográficas (Goodchild, 2007; Longley et al., 2015).

Uno de los mayores desafíos es la accesibilidad sin conocimiento y la excelencia cambiante de los datos geospaciales, específicamente en el Sur Global, en la cual el acceso a imágenes satelitales de alta resolución o datos históricos fiables es reducido (Asner et al., 2020; Aubrecht et al., 2019). Lo mencionado es probable que dirija a los prototipos de IA a que generen resultados inconclusos o sesgados cuando no poseen un grupo de datos fuerte, afectando la exactitud de los estudios territoriales y dificultando los procesos de organización. Dicha problemática se empeora en territorios con una variedad importante causas ecológicas, sociales y económicas que no resultan sencillas al ser simuladas de forma masiva.

De igual forma, el vínculo de las herramientas tecnológicas desarrolladas representa un obstáculo extra. Para adiestrar y emplear algoritmos de aprendizaje profundo, específicamente los referidos que usan datos multitemporales o multispectrales, se necesita un almacenamiento de procesamiento significativo, que abarca GPU avanzadas, alto rendimiento de memoria e ingreso sólido a internet. No obstante, la mayoría de autoridades locales o instituciones de administración territorial no disponen de estas herramientas a causa de restricciones presupuestarias o ausencia de conocimiento técnico (Charnes et al., 1978; Ramírez y Medina, 2022).

Desde un enfoque funcional, asimismo se presenta el problema de incorporar los resultados de la IA en esquemas ya existentes de planificación territorial, que frecuentemente están obligados a estar en procesos administrativos y bases legales. Esta inflexibilidad puede entorpecer la integración de datos interactivos hechos por IA, al igual que la confianza de los que toman decisiones en procesos automáticos que son capaces de carecer de transparencia en sus resultados (Batty, 2013; Russell y Norvig, 2016). Por ende, se requiere una participación más activa e integrada y el avance de habilidades para solventar este desfase entre el progreso técnico y la formación organizacional.

Otro aspecto crucial es la habilidad reducida de universalización de los prototipos de IA a causa de las diferencias en la cobertura del suelo, los factores climáticos y los esquemas culturales entre regiones. Esto conlleva que los prototipos instruidos en una ubicación son capaces de no ser eficientes en otra sin modificaciones relevantes o capacitación adicional, lo que necesita tiempo, datos y conocimientos extra (LeCun et al., 2015; Jensen, 2007).

En conclusión, partiendo de un punto de vista del territorio, el nivel de operación de los prototipos de IA conlleva un reto. Pese a que estos algoritmos son capaces de analizar rápidamente información a nivel mundial, la mayoría de decisiones de organización necesitan detalles determinados y susceptibles al entorno local, como: zonificación del uso del suelo, conectividad rural o conservación del ambiente. La ausencia de adaptación a estos mecanismos geográficos delimitados tendría la capacidad de indefinir brechas de desigualdad presentes o excluir a los requerimientos locales cruciales. Por ende, es importante sincronizar de mejor manera el conocimiento que se tiene de la zona con el diseño del algoritmo para afianzar que la IA potencie las capacidades técnicas, incentive la planificación inclusiva y susceptible a las realidades espaciales y sociales.

Capítulo 4 Presentación de Resultados

Para la aplicación de ambos métodos se eligió usar una imagen satelital extraída de la página web del servicio meteorológico de los Estado Unidos, llamado EarthExplorer.

La resolución de la imagen seleccionada es de 30 metros por píxel y data del 30 de agosto de 2024. Esta fue descargada del satélite Landsat 8, colección 2, nivel 2 con las siguientes coordenadas:

Tabla 2.

Coordenadas

Esquina superior izquierda latitud	1°02'40.63''N
Esquina superior izquierda longitud	79°32'15.97''W
Esquina superior derecha latitud	1°02'34.76''N
Esquina superior derecha longitud	77°29'35.52''W
Esquina inferior izquierda latitud	1°03'09.94''S
Esquina inferior izquierda longitud	79°32'15.97''W
Esquina inferior derecha latitud	1°03'04.03''S
Esquina inferior derecha longitud	77°29'35.48''W

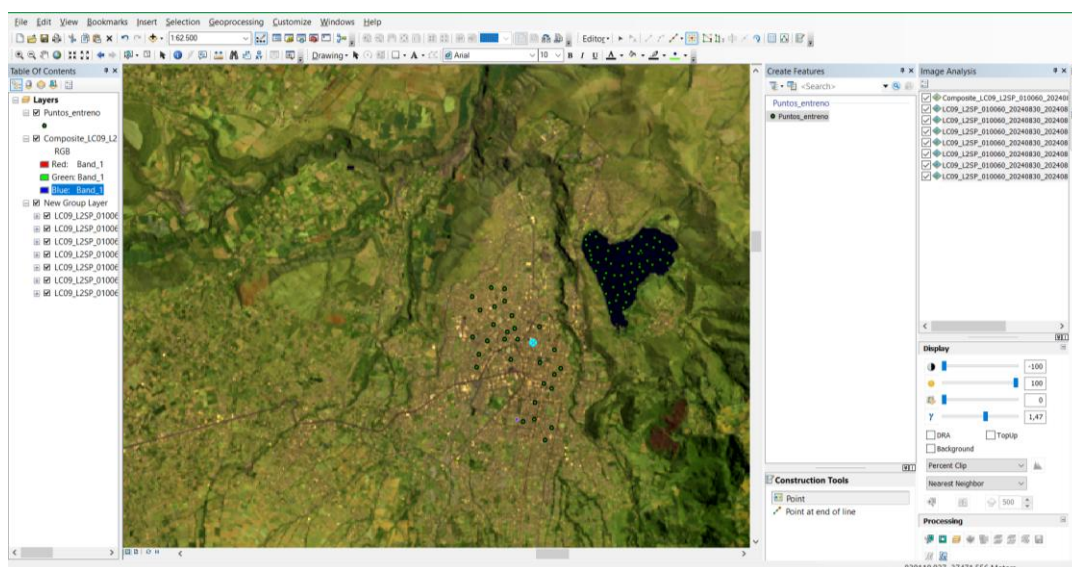
Presentación de Resultados Cuantitativos

Clasificación supervisada con métodos tradicionales (ARCGIS)

1. Creación de puntos

Ilustración 1.

Creación de puntos

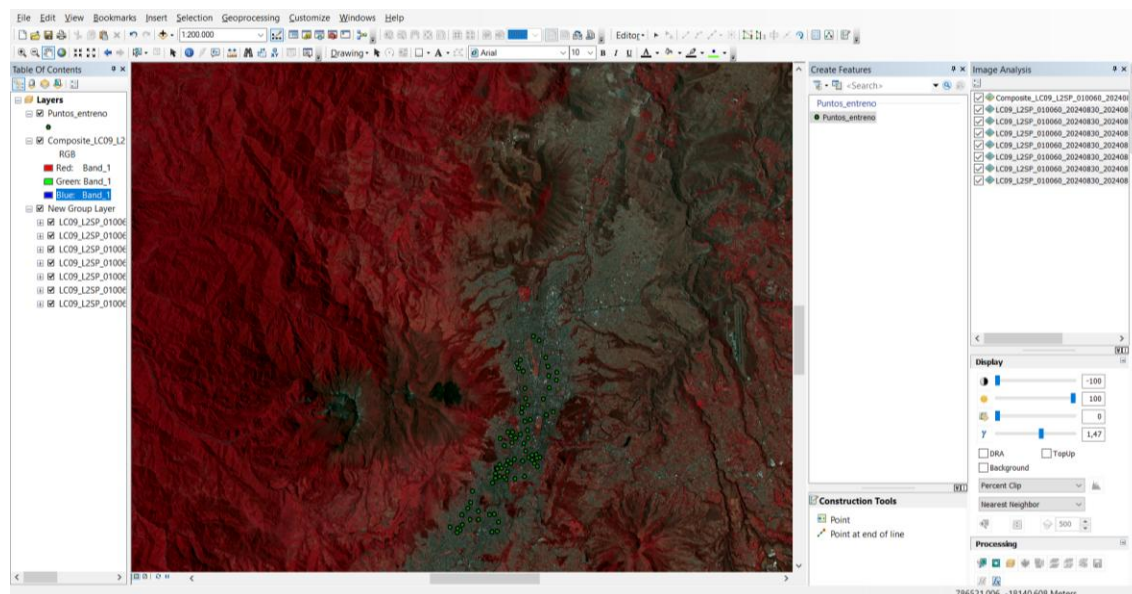


Se procede a crear un shape de puntos en el cual se identifica cada categoría que se va a categorizar en el procesamiento de la imagen satelital. Estos puntos ayudan a que se pueda iniciar con el entrenamiento de los modelos para la clasificación supervisada usando IA, de igual forma con el entrenamiento para la clasificación supervisada usando métodos tradicionales en ARCGIS.

2. Combinación de bandas

Ilustración 2.

Combinación de bandas



Se utilizaron varias combinaciones de bandas Landsat para poder identificar de mejor manera las clases elegidas.

Combinación de bandas 5,4,3. Esta combinación ayudó a identificar de mejor manera las zonas forestales y cuerpos de agua.

Combinación 6,5,2. Esta combinación ayudó a identificar zonas de uso agrícola.

Combinación 7,6,4. Esta combinación ayudó a identificar las zonas urbanas dentro de la imagen.

3. Clasificación de puntos

Ilustración 3.

Clasificación de puntos

ID	Shape *	M	Clases
1	Point	1	Cuerpos de Agua
2	Point	1	Cuerpos de Agua
3	Point	1	Cuerpos de Agua
4	Point	1	Cuerpos de Agua
5	Point	1	Cuerpos de Agua
6	Point	1	Cuerpos de Agua
7	Point	1	Cuerpos de Agua
8	Point	1	Cuerpos de Agua
9	Point	1	Cuerpos de Agua
10	Point	1	Cuerpos de Agua
11	Point	1	Cuerpos de Agua

ID	Shape *	M	Clases
186	Point	2	Urbano
187	Point	2	Urbano
188	Point	2	Urbano
189	Point	2	Urbano
190	Point	2	Urbano
191	Point	2	Urbano
192	Point	2	Urbano
193	Point	2	Urbano
194	Point	2	Urbano

ID	Shape *	M	Clases
330	Point	3	Bosque
331	Point	3	Bosque
332	Point	3	Bosque
333	Point	3	Bosque
334	Point	3	Bosque
335	Point	3	Bosque
336	Point	3	Bosque
337	Point	3	Bosque
338	Point	3	Bosque
339	Point	3	Bosque
340	Point	3	Bosque

ID	Shape *	M	Clases
507	Point	4	Agrícola
508	Point	4	Agrícola
509	Point	4	Agrícola
510	Point	4	Agrícola
511	Point	4	Agrícola
512	Point	4	Agrícola
513	Point	4	Agrícola
514	Point	4	Agrícola
515	Point	4	Agrícola

Aquí se puede observar la tabla de atributos del shape de puntos con sus respectivos números de cada categoría, para posteriormente realizar el análisis de las firmas espectrales.

1= Cuerpos de Agua con 184 puntos de entreno

2= Urbano con 152 puntos de entreno

3= Bosque con 177 puntos de entreno

4= Agrícola con 187 puntos de entreno

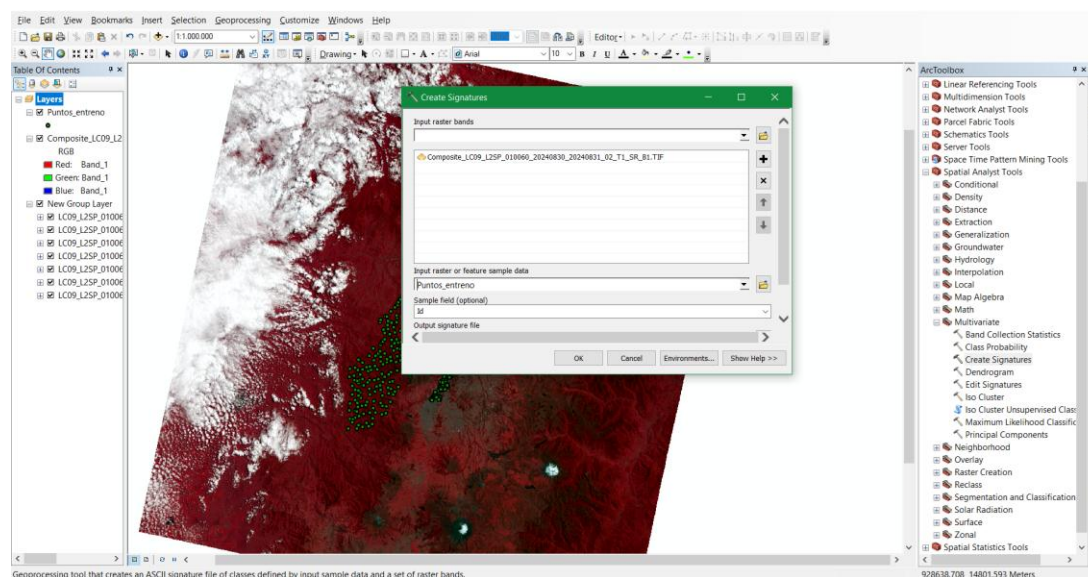
Total 700 puntos de entrenamiento usados en ambos métodos

Estos puntos fueron seleccionados estratégicamente para poder identificar las diferentes categorías de estudio y su distribución visualmente clara dentro de la imagen satelital.

4. Creación de firmas espectrales

Ilustración 4.

Creación de firmas espectrales

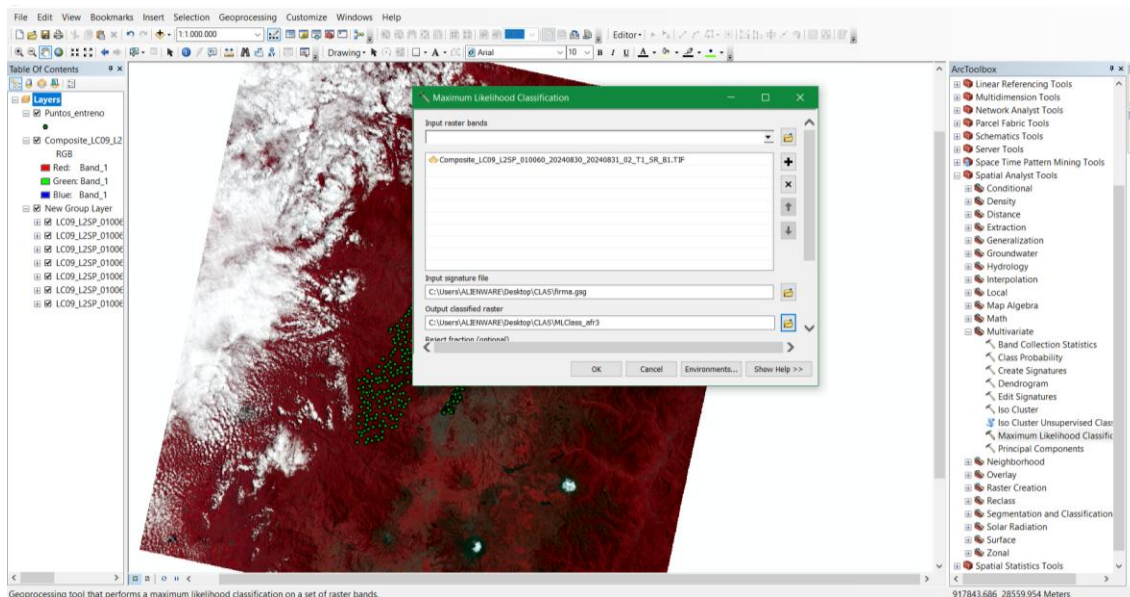


Se inició con el procesamiento utilizando los puntos establecidos para crear las firmas espectrales insertando la composición de bandas y el shape de los puntos de entreno en la herramienta de “Create Signatures” en ARCGIS.

5. Algoritmo máxima verosimilitud

Ilustración 5.

Algoritmo máxima verosimilitud

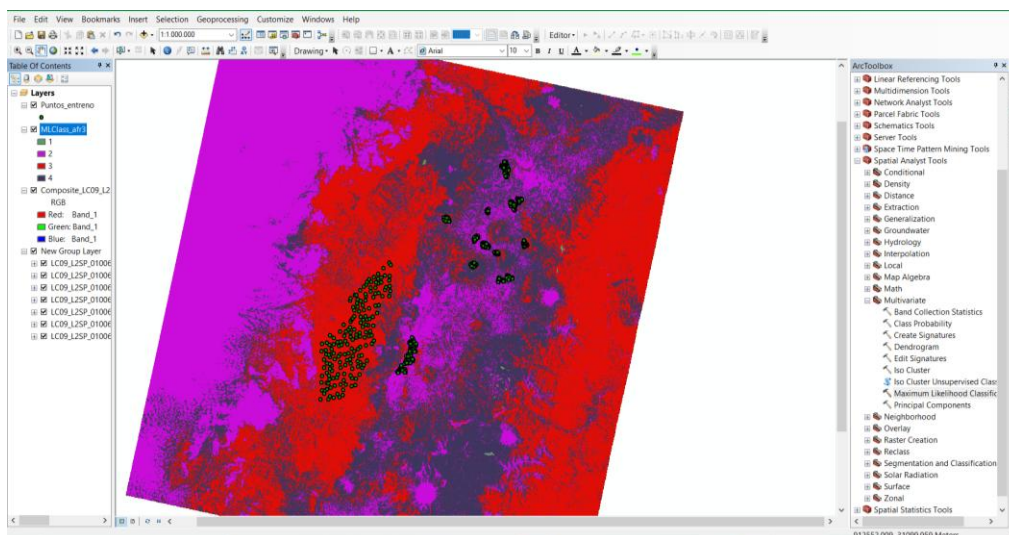


Con la ayuda del Spatial Analyst Tools se creó la clasificación de máxima verosimilitud o también llamado “máximo likelihood classification”, insertando en dicha herramienta la composición de bandas y las firmas previamente creadas.

6. Resultado de la clasificación de máxima verosimilitud

Ilustración 6.

Resultado de la clasificación de máxima verosimilitud

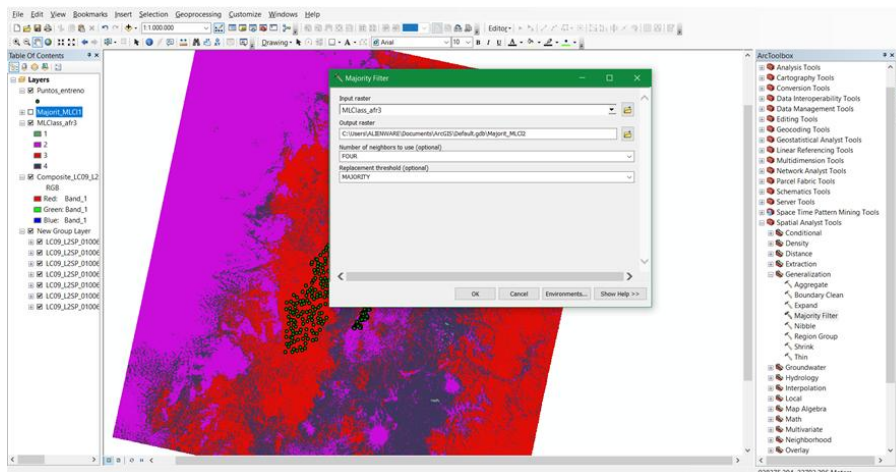


Aquí se puede observar el resultado de la clasificación con la herramienta de máxima verosimilitud en formato raster.

7. Filtro mayoritario

Ilustración 7.

Filtro mayoritario

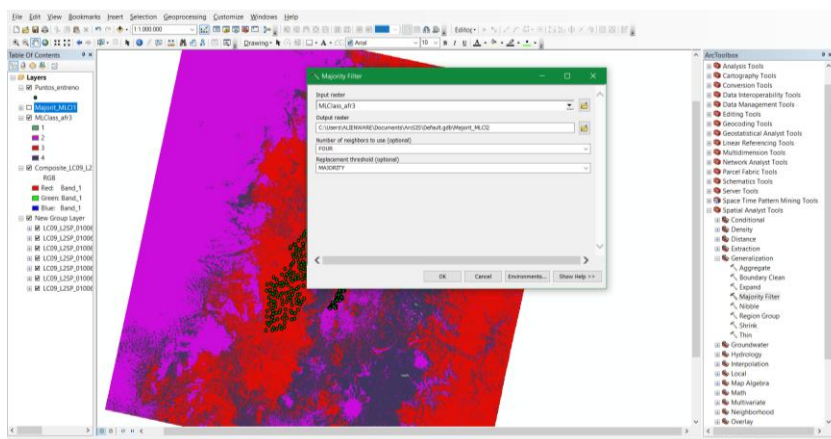


El siguiente paso una vez obtenida la clasificación con el algoritmo de máxima verosimilitud es crear el filtro mayoritario con la herramienta “Majority filter” para mejorar la apariencia y la coherencia espacial de los píxeles en el resultado.

8. Resultado filtro mayoritario

Ilustración 8.

Resultado filtro mayoritario




Aquí se puede observar una mejora visual en la clasificación realizada con el uso de la herramienta “majority filter”.

9. Conversión

Ilustración 9.

Conversión

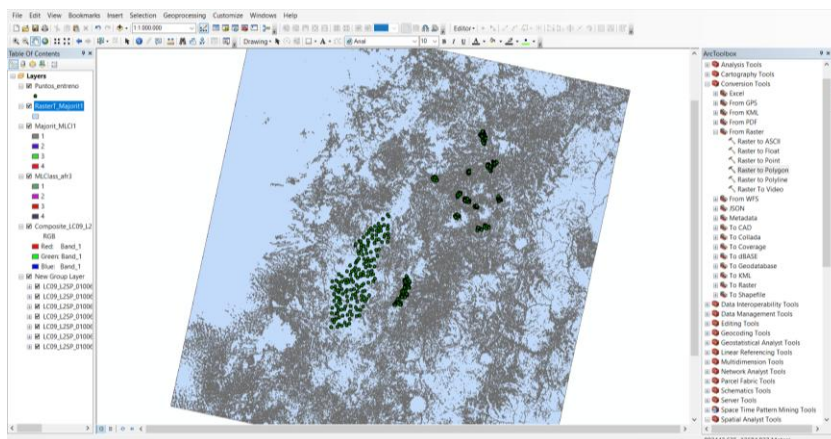


Ahora se realiza la transformación del formato raster a un formato de polígonos que permitirá identificar de mejor manera las categorías clasificadas y se obtiene una mejor representación de estas. Para eso se utiliza la herramienta de conversión tools llamada “Raster to polygon”.

10. Resultados de la conversión

Ilustración 10.

Resultado de la conversión




Este es el resultado después de transformar el raster en un shape de polígonos con la clasificación de cada categoría.

11. Resultado final de la clasificación

Ilustración 11.

Resultado final de la clasificación



La clasificación de colores de cada categoría es la siguiente:

■ Cuerpos de Agua ■ Urbano ■ Bosque ■ Agrícola

Por último, se obtiene la imagen satelital con su respectiva clasificación supervisada de manera tradicional identificando claramente sus cuatro categorías bien definidas.

Se puede observar que la clasificación realizada posee una segmentación clara y coherente de las diferentes categorías seleccionadas, lo cual verifica el correcto funcionamiento del algoritmo. Sin embargo, existe un error visible en la clasificación de zonas urbanas, ya que se puede evidenciar una confusión de la clasificación en las zonas cubiertas por nubes, esto puede deberse a la similitud de las firmas espectrales entre ambas coberturas en algunas bandas utilizadas (Ver tabla 2).

Tabla 3.

Tabla de tiempo por cada procedimiento con método tradicional de clasificación supervisada

Procedimientos	Tiempo (segundos)
Creación de puntos	723
Combinación de bandas	544
Clasificación de puntos	42
Creación de firmas espectrales	77
Algoritmo máxima verosimilitud	54
Resultado clasificación máxima verosimilitud	6
Filtro mayoritario	35
Resultado filtro mayoritario	8
Conversión	27
Resultado de la conversión	15
Resultado final de la clasificación	94
Tiempo Total	1625 (27,08 minutos)

En la tabla se puede identificar el tiempo empleado en cada proceso para la clasificación supervisada con métodos tradicionales, es decir, con el software ARCGIS utilizando el algoritmo de máxima verosimilitud. El tiempo total que se obtuvo de realizar todo el proceso de clasificación fue de 27,08 minutos.

El procedimiento de la creación de puntos de entrenamiento tomó un tiempo total de 12 minutos con 5 segundos, el cual, representa al 45% del tiempo total de todo el flujo de trabajo.

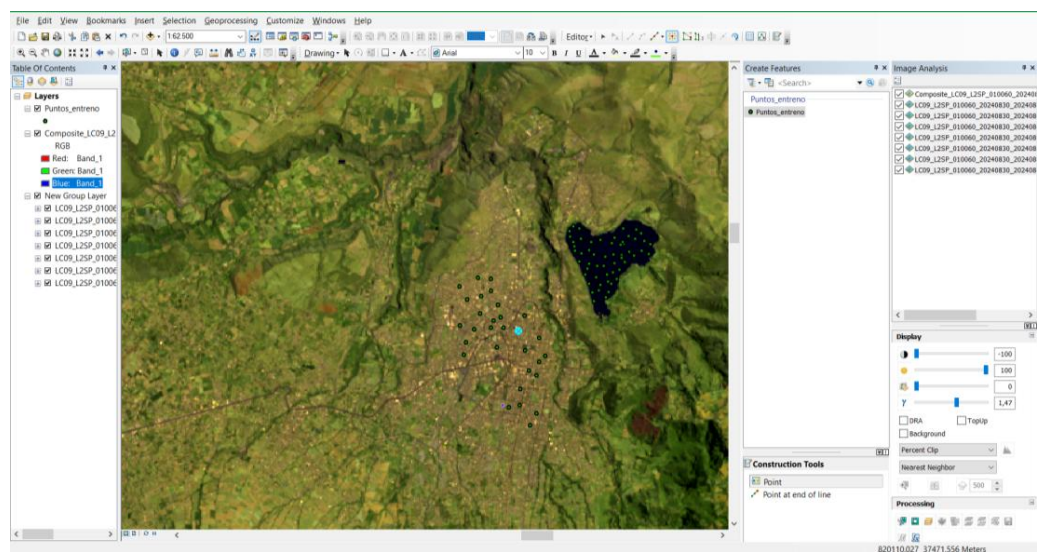
Este análisis demuestra que el método tradicional toma un poco más de tiempo y que consta con menos procedimientos que el aprendizaje automático, ya que este comprende cuatro procesos extra destinados a la instalación de herramientas para el correcto funcionamiento del modelo, sin embargo, el método es eficiente en términos de tiempo y facilidad de manejo para los técnicos con poco conocimiento en programación.

Clasificación Supervisada con Método de Aprendizaje Automático (IA)

1. Creación de puntos

Ilustración 12.

Creación de puntos IA



Se procedió a crear un shape de puntos donde identifiquemos cada categoría que se va a clasificar en el procesamiento de la imagen satelital. Estos puntos ayudan a iniciar con el entrenamiento de los modelos para la clasificación supervisada utilizando IA y de igual manera con el entrenamiento para la clasificación supervisada usando métodos tradicionales en ARCGIS.

2. Instalación de paquetes

Ilustración 13.

Instalación de paquetes numpy, scikit-learn, matplotlib, shapely y scipy

```
In [1]: pip install rasterio geopandas numpy scikit-learn matplotlib pandas

Defaulting to user installation because normal site-packages is not writeable
Requirement already satisfied: rasterio in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (1.4.3)
Requirement already satisfied: geopandas in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (1.1.0)
Requirement already satisfied: numpy in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (1.24.3)
Requirement already satisfied: scikit-learn in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (1.7.0)
Requirement already satisfied: matplotlib in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (3.6.3)
Requirement already satisfied: pandas in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (2.0.2)
Requirement already satisfied: affine in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from rasterio) (2.4.0)
Requirement already satisfied: attrs in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from rasterio) (23.1.0)
Requirement already satisfied: certifi in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from rasterio) (2024.2.2)
Requirement already satisfied: click>=4.0 in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from rasterio) (8.1.7)
Requirement already satisfied: cligj>=0.5 in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from rasterio) (0.7.2)
Requirement already satisfied: click-plugins in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from rasterio) (1.1.1)
Requirement already satisfied: pyparsing in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from rasterio) (3.0.9)
Requirement already satisfied: pyogrio>=0.7.2 in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from geopandas) (0.11.0)
Requirement already satisfied: packaging in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from geopandas) (23.2)
Requirement already satisfied: pyproj>=3.5.0 in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from geopandas) (3.7.1)
Requirement already satisfied: shapely>=2.0.0 in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from geopandas) (2.1.1)
Requirement already satisfied: scipy>=1.8.0 in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from scikit-learn) (1.9.3)
Requirement already satisfied: joblib>=1.2.0 in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from scikit-learn) (1.5.1)
Requirement already satisfied: threadpoolctl>=3.1.0 in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from scikit-learn) (3.6.0)
Requirement already satisfied: contourpy>=1.0.1 in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from matplotlib) (1.2.0)
Requirement already satisfied: cycler>=0.10 in c:\program files\arcgis\pro\bin
```

Con la ayuda de Jupyter notebook y el lenguaje python se procedió a instalar los paquetes necesarios para el procesamiento, ploteo, generación de imágenes y posterior conversión de shapes.

3. Instalación de librerías

Ilustración 14.

Instalación de librerías

```
In [*]: import rasterio
import numpy as np
import geopandas as gpd
from rasterio.plot import show
from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import train_test_split
import matplotlib.pyplot as plt
```

El siguiente paso fue instalar las librerías que ayudaron a utilizar los elementos necesarios para continuar con el procesamiento.

4. Conectar rutas de archivos

Ilustración 15.

Conectar rutas de archivos

```
: # Paso 1: Definir las rutas de las bandas
ruta_base = r'C:\Users\disco\Documents\TESIS\FABRI'

# Nombres de las bandas a usar
bandas = ['SR_B2', 'SR_B3', 'SR_B4', 'SR_B5', 'SR_B6', 'SR_B7']
rutas = [f'{ruta_base}\\LC09_L2SP_010060_20240830_20240831_02_T1_{b}.TIF' for b in bandas]

# Leer bandas y apilar
stacked = []
for path in rutas:
    with rasterio.open(path) as src:
        stacked.append(src.read(1))
        perfil = src.profile # Usamos una de las bandas como perfil base
        transform = src.transform

imagen = np.stack(stacked) # shape = (6, filas, columnas)
```

Posteriormente se definió la ruta donde se encuentran los archivos que se usaron para el procesamiento, se llama a la información (a las bandas que se van a usar en el modelo) y se las aplica para poder trabajar imágenes.

5. Estimación de índices

Ilustración 16.*Estimación de índices*

```

In [4]: # Asignar bandas por índice
B2 = imagen[0] # Azul
B3 = imagen[1] # Verde
B4 = imagen[2] # Rojo
B5 = imagen[3] # NIR
B6 = imagen[4] # SWIR1

# NDVI: Vegetación
ndvi = (B5 - B4) / (B5 + B4)

# NDWI: Agua
ndwi = (B3 - B5) / (B3 + B5)

# NDBI: Urbano
ndbi = (B6 - B5) / (B6 + B5)

# Agregar índices como nuevas bandas
imagen = np.concatenate((imagen, ndvi[np.newaxis, :, :], ndwi[np.newaxis, :, :],

```

```

C:\Users\mlopezr\AppData\Local\Temp\ipykernel_5420\2855834732.py:9: RuntimeWarning: divide by zero encountered in divide
  ndvi = (B5 - B4) / (B5 + B4)
C:\Users\mlopezr\AppData\Local\Temp\ipykernel_5420\2855834732.py:9: RuntimeWarning: invalid value encountered in divide
  ndvi = (B5 - B4) / (B5 + B4)
C:\Users\mlopezr\AppData\Local\Temp\ipykernel_5420\2855834732.py:12: RuntimeWarning: divide by zero encountered in divide
  ndwi = (B3 - B5) / (B3 + B5)
C:\Users\mlopezr\AppData\Local\Temp\ipykernel_5420\2855834732.py:12: RuntimeWarning: invalid value encountered in divide
  ndwi = (B3 - B5) / (B3 + B5)
C:\Users\mlopezr\AppData\Local\Temp\ipykernel_5420\2855834732.py:15: RuntimeWarning: divide by zero encountered in divide
  ndbi = (B6 - B5) / (B6 + B5)
C:\Users\mlopezr\AppData\Local\Temp\ipykernel_5420\2855834732.py:15: RuntimeWarning: invalid value encountered in divide
  ndbi = (B6 - B5) / (B6 + B5)

```

Se incorpora la estimación de índices para mejorar la precisión del modelo y así poder calcular métricas que derivan de las bandas de la imagen satelital, como por ejemplo el índice de vegetación de diferencia normalizada (NDVI).

6. Carga de los puntos de entrenamiento

Ilustración 17.

Carga de los puntos de entrenamiento

```
In [5]: # Paso 3: Cargar Los puntos de entrenamiento
# Asegúrate de tener un archivo tipo .shp o .geojson con puntos y una columna 'c'
muestras = gpd.read_file(f'{ruta_base}\\muestras_poli.shp') # Asegúrate de que
muestras = muestras.to_crs(perfil['crs']) # Asegurar CRS compatible
```

Aquí se procede a cargar los puntos del shape de muestreo generados para entrenar al modelo que se usará para clasificar las categorías.

7. Extracción de muestras aleatorias

Ilustración 18.

Extracción de muestras aleatorias

```
In [6]: # Paso 4: Extraer muestras
import geopandas as gpd
from shapely.geometry import Point
import random

def generar_puntos_aleatorios_en_poligono(poligono, n):
    puntos = []
    minx, miny, maxx, maxy = poligono.bounds
    while len(puntos) < n:
        x = random.uniform(minx, maxx)
        y = random.uniform(miny, maxy)
        punto = Point(x, y)
        if poligono.contains(punto):
            puntos.append(punto)
    return puntos

# Cargar el shapefile de polígonos
gdf_poligonos = gpd.read_file("muestras_poli.shp")

# Generar puntos aleatorios
n_puntos_por_poligono = 5
puntos_lista = []
clases_lista = []

for _, row in gdf_poligonos.iterrows():
    puntos = generar_puntos_aleatorios_en_poligono(row.geometry, n_puntos_por_po
    puntos_lista.extend(puntos)
    clases_lista.extend([row['Clase']] * len(puntos))

# Crear nuevo GeoDataFrame de puntos
gdf_puntos = gpd.GeoDataFrame({'geometry': puntos_lista, 'Clase': clases_lista},

# Guardar si deseas revisar en QGIS
gdf_puntos.to_file("muestras_aleatorias.shp")
```

Se procede a extraer muestras aleatorias para ayudar al modelo a distinguir las diferentes categorías de estudio.

8. Creación del modelo Random Forest

Ilustración 19.

Creación del modelo Random Forest

```
In [6]: from sklearn.preprocessing import LabelEncoder # ✓ <--- esto es lo que faltaba
le = LabelEncoder()
y_encoded = le.fit_transform(y)

# Entrenar modelo
X_train, X_test, y_train, y_test = train_test_split(X, y_encoded, test_size=0.2,
clf = RandomForestClassifier(n_estimators=100, random_state=42)
clf.fit(X_train, y_train)

print("Precisión:", clf.score(X_test, y_test))
print("Clases codificadas:", dict(zip(le.classes_, le.transform(le.classes_))))
```

Precisión: 0.5555555555555556
Clases codificadas: {'Agricola': 0, 'Agua': 1, 'Bosque': 2, 'Urbano': 3}

Posteriormente se genera el modelo del algoritmo a usar que es Random Forest.

9. Creación de archivo .tiff

Ilustración 20.

Creación de archivo.tiff

```
In [12]: rows, cols = imagen.shape[1], imagen.shape[2]
img_pixels = imagen.reshape(imagen.shape[0], -1).T
predicted = clf.predict(img_pixels)
clasificado = predicted.reshape(rows, cols)

# Guardar resultado
perfil.update(dtype=rasterio.uint8, count=1)

with rasterio.open(f'{ruta_base}\\clasificacion_RF.tif', 'w', **perfil) as dst:
    dst.write(clasificado.astype(rasterio.uint8), 1)
print("✓ Clasificación exportada como 'clasificacion_RF.tif'")
✓ Clasificación exportada como 'clasificacion_RF.tif'
```

Se genera el archivo .tiff con la clasificación ejecutada con el algoritmo de Random Forest.

10. Instalación de paquetes de conversión

Ilustración 21.

Instalación de paquetes de conversión

```
In [9]: pip install rasterio geopandas shapely scipy
Defaulting to user installation because normal site-packages is not writeable
Requirement already satisfied: rasterio in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (1.4.3)
Requirement already satisfied: geopandas in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (1.1.0)
Requirement already satisfied: shapely in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (2.1.1)
Requirement already satisfied: scipy in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (1.9.3)
Requirement already satisfied: affine in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from rasterio) (2.4.0)
Requirement already satisfied: attrs in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from rasterio) (23.1.0)
Requirement already satisfied: certifi in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from rasterio) (2024.2.2)
Requirement already satisfied: click>=4.0 in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from rasterio) (8.1.7)
Requirement already satisfied: cligj>=0.5 in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from rasterio) (0.7.2)
Requirement already satisfied: numpy>=1.24 in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from rasterio) (1.24.3)
Requirement already satisfied: click-plugins in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from rasterio) (1.1.1)
Requirement already satisfied: pyparsing in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from rasterio) (3.0.9)
Requirement already satisfied: pyogrio>=0.7.2 in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from geopandas) (0.11.0)
Requirement already satisfied: packaging in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from geopandas) (23.2)
Requirement already satisfied: pandas>=2.0.0 in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from geopandas) (2.0.2)
Requirement already satisfied: pyproj>=3.5.0 in c:\users\mlopezr\appdata\roaming\python\python311\site-packages (from geopandas) (3.7.1)
Requirement already satisfied: colorama in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from click>=4.0->rasterio) (0.4.6)
Requirement already satisfied: python-dateutil>=2.8.2 in c:\program files\arcgis\pro\bin\python\envs\arcgispro-py3\lib\site-packages (from pandas>=2.0.0->geopandas) (2.8.2)
```

Una vez que se obtiene el resultado en raster se procede a instalar los diferentes paquetes para poder convertir de raster a shape.

11. Exportación de raster

Ilustración 22.

Exportación de raster

```
In [10]: import rasterio
from rasterio.features import shapes
import geopandas as gpd
import numpy as np
from shapely.geometry import shape
```

Seguido de esto se instalan las librerías necesarias para exportar de raster a shape.

12. Creación de archivo shape

Ilustración 23.

Creación de archivo shape

```
In [*]: # Leer el raster clasificado
with rasterio.open('C:/Users/mlopezr/Documents/MUNICIPIO_DMQ/FABRI/clasificacion
imagen = src.read(1) # Capa clasificada
transform = src.transform
crs = src.crs

# Extraer polígonos
mask = imagen != src.nodata if src.nodata is not None else np.ones_like(imagen,

shapes_gen = shapes(imagen, mask=mask, transform=transform)

# Convertir a GeoDataFrame
records = []
for geom, value in shapes_gen:
    records.append({'geometry': shape(geom), 'clase': int(value)})

gdf = gpd.GeoDataFrame(records, crs=crs)

# (Opcional) Asignar nombres de clase
diccionario_clases = {
    0: 'Agricola',
    1: 'Agua',
    2: 'Bosque',
    3: 'Urbano'
}
gdf['clase_nombre'] = gdf['clase'].map(diccionario_clases)

# Guardar como shapefile
salida = 'C:/Users/mlopezr/Documents/MUNICIPIO_DMQ/FABRI/clasificacion_poligonos
gdf.to_file(salida)

print(f"✅ Shapefile exportado: {salida}")
```

Aquí se genera el shape con las distintas categorías definidas.

13. Creación de matriz de confusión

Ilustración 24.

Creación de matriz de confusión

```
In [13]: clf.feature_importances_

Out[13]: array([0.23831979, 0.13865696, 0.12932108, 0.23223582, 0.13135735,
              0.13010901])

In [14]: from sklearn.metrics import classification_report, confusion_matrix

y_pred = clf.predict(X_test)

print("\n📊 Matriz de confusión:")
print(confusion_matrix(y_test, y_pred))

print("\n📋 Reporte de clasificación:")
print(classification_report(y_test, y_pred, target_names=le.classes_))

# Importancia de Las variables
import matplotlib.pyplot as plt

importancias = clf.feature_importances_
plt.figure(figsize=(10,5))
plt.bar(range(len(importancias)), importancias)
plt.xticks(range(len(importancias)), ['B2','B3','B4','B5','B6','B7','NDVI','NDWI'])
plt.title("📊 Importancia de las Bandas/Índices en el Modelo")
plt.ylabel("Importancia")
plt.xlabel("Banda o Índice")
plt.grid(True)
plt.show()
```

Se genera una matriz de confusión y una gráfica para determinar la fiabilidad del modelo e importancia de las bandas de la imagen satelital en el procesamiento.

14. Resultados de la matriz de confusión y gráfica

Ilustración 25.

Resultados de la matriz de confusión gráfica

```
📊 Matriz de confusión:
[[1 0 0 2]
 [0 0 0 0]
 [0 1 0 0]
 [1 0 0 4]]

📋 Reporte de clasificación:
              precision    recall  f1-score   support

   Agrícola      0.50      0.33      0.40         3
     Agua       0.00      0.00      0.00         0
    Bosque      0.00      0.00      0.00         1
    Urbano      0.67      0.80      0.73         5

 accuracy              0.56         9
 macro avg              0.29      0.28      0.28         9
 weighted avg           0.54      0.56      0.54         9
```

La matriz de confusión ayuda a evaluar el rendimiento del modelo de la clasificación supervisada que se realizó en función de su capacidad para emparejar correctamente las categorías de estudio.

El reporte de la clasificación indica que la categoría “Urbano” es la categoría mejor clasificada con un f1-score de 0,73, lo que significa que el modelo pudo identificar correctamente la mayoría de las muestras urbanas ingresadas en él.

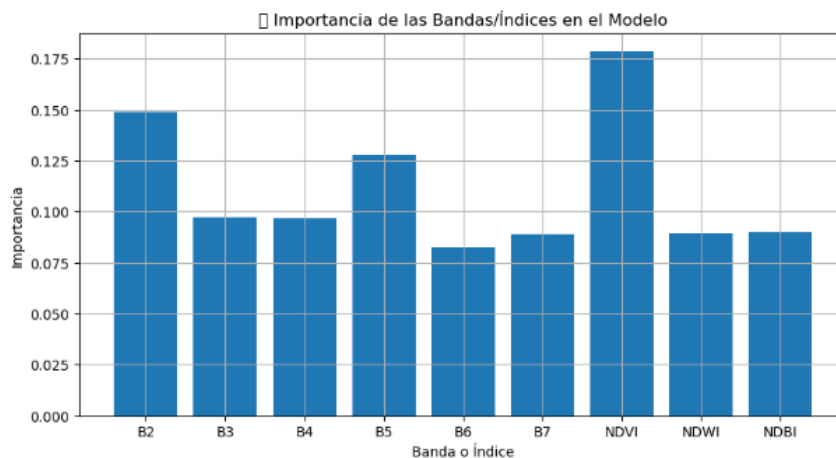
Mientras que la categoría “Agrícola” tuvo un f1-score de 0,40 lo cual es un valor moderado de clasificación, esto se traduce a que el modelo no pudo identificar todas las áreas agrícolas correctamente.

Así, las categorías “Bosque” y “Agua” no fueron identificadas ni clasificadas correctamente, esto puede deberse a que la cantidad de puntos creados para entrenar el modelo no fue suficiente para poder identificar estas clases o puede ser resultado de que ambas coberturas poseen espectros similares en la imagen satelital.

En conclusión, este análisis indica que la cantidad de puntos de entrenamiento creados no fueron suficientes en algunas categorías y que para mejorar la clasificación y la identificación general de cada categoría se debe poseer más tiempo para entrenar el modelo con mayor cantidad de puntos, mayor cantidad de categorías y una alta y variada cantidad de imágenes satelitales de diferentes zonas donde se pueda visualizar ampliamente las categorías elegidas para el estudio.

Ilustración 26.

Importancia de las bandas

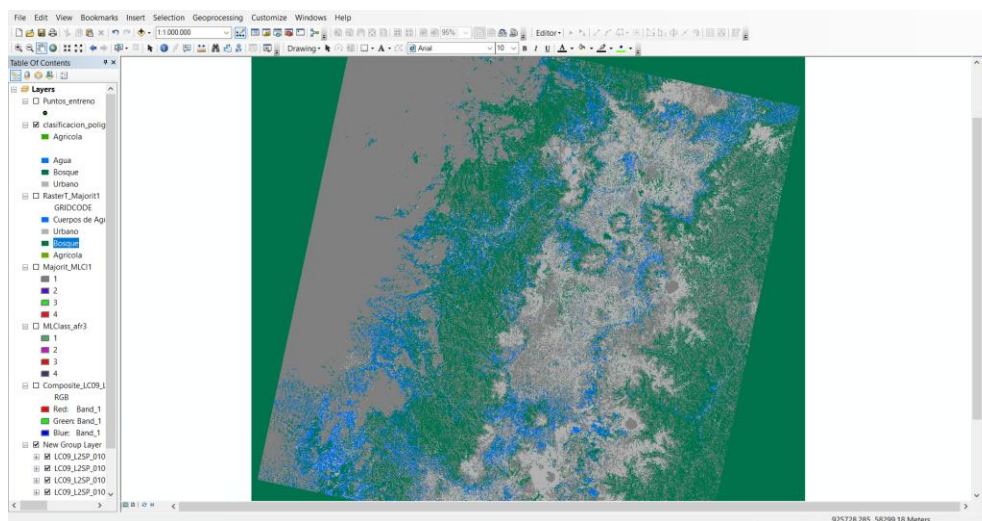


La gráfica indica que el NDVI fue decisivo en el modelo al momento de identificar las diversas clases debido a su alta capacidad para distinguir zonas con vegetación. De igual manera la importancia de la B2 y la B5 pueden ser resultado de su sensibilidad para identificar las diferentes coberturas como suelos desnudos, zonas forestales y agrícolas.

15. Resultado final de la clasificación

Ilustración 27.

Resultado final de la clasificación con IA



■ Cuerpos de Agua ■ Urbano ■ Bosque ■ Agrícola

Finalmente, la imagen arrojó la clasificación supervisada hecha con aprendizaje automático que permitió evidenciar las falencias y aciertos que señaló el reporte de clasificación y la gráfica de la importancia de las bandas.

Se puede observar en la clasificación obtenida, una segmentación de las coberturas que no refleja acertadamente las categorías reales seleccionadas para el estudio y esto produce mucho ruido visual en la imagen. También existe una sobreestimación de la clase de “agua” que se puede diferenciar en toda la imagen.

Tabla 4.

Tabla de tiempo por cada procedimiento con método de aprendizaje automático de clasificación supervisada

Procedimientos	Tiempo (segundos)
Creación de puntos	723
Instalación de paquetes	19
Instalación de librerías	3
Conectar rutas de archivos	9
Estimación de índices	4
Carga de los puntos de entrenamiento	5
Extracción de muestras aleatorias	3
Creación de modelo Random Forest	4
Creación de archivo .tiff	188
Instalación de paquetes de conversión	5
Exportación de raster	3
Creación de archivo shp	232
Creación de matriz de confusión	8
Resultados de la matriz de confusión y gráfica	43
Resultado final de la clasificación	112
Tiempo Total	1361 (23 minutos)

En la tabla se puede evidenciar los tiempos de los procesamientos que se realizaron para obtener la clasificación supervisada usando el método de aprendizaje automático con el algoritmo de Random Forest. De igual manera que en el método tradicional, se puede identificar que el proceso que más tiempo demanda es el de la creación de los puntos para el entrenamiento del modelo, representando más del 50% del tiempo total de todo el flujo de trabajo.

La mayoría de los procesos que implican programación son rápidos y sencillos con el suficiente conocimiento de lenguaje Python, mientras que los procesos que más consumen tiempo después de los puntos de entrenamiento con los procesos de creación de los diferentes archivos.

Pese a que este método posee más procedimientos que el método tradicional, consume menos tiempo que la clasificación realizada con máxima verosimilitud.

De igual manera se debe tomar en cuenta que pese a que este método fue más rápido, no fue más eficiente que el método tradicional al momento de clasificar las categorías de la imagen satelital, por ende, para mejorar la clasificación supervisada con este método tomaría mucho más tiempo el crear mayor cantidad de puntos de entrenamiento para el modelo y también entrenarla con varias imágenes satelitales de diferentes zonas, lo cual pone en desventaja este método en términos de tiempo por lo menos al empezar a implementar y entrenar el modelo.

Análisis de Resultados Cuantitativos

Se realizaron dos métodos de clasificación supervisada de imágenes satelitales: tradicional (usando ARCGIS) con el algoritmo de máxima verosimilitud, en contraposición con aprendizaje automático (usando Random Forest) en Python. Así se tiene que el modelo tradicional alcanzó una segmentación clara y coherente de las categorías (agua, urbano, bosque y agrícola), pese a que se presentaron errores en zonas urbanas cubiertas por nubes. En cambio, en el aprendizaje automático, el desempeño fue desigual ya que la categoría “urbano” tuvo buena precisión (f1-score de 0,73), mientras que “agrícola” fue moderada (0,40) y “bosque” y “agua” resultaron mal clasificados, produciendo ruido visual y sobreestimación. En cuanto al análisis del tiempo se demostró que si bien el método de IA fue más rápido (23 minutos frente a 27), la creación de puntos de entrenamiento consumió el mayor tiempo en ambos casos.

Interpretación de Resultados Cuantitativos

Los resultados demuestran que a pesar de que el método de aprendizaje automático puede llegar a ser más veloz en términos de operatividad, su efectividad depende en gran medida de una adecuada cantidad y calidad de datos de entrenamiento. El bajo desempeño en algunas categorías revela la necesidad de una mayor inversión en la preparación del modelo, especialmente en la recolección de puntos y la diversidad de imágenes. Por otra parte, el método tradicional, aunque un poco más lento y con menor automatización, brinda resultados más estables y precisos para técnicos con menor experiencia en programación. En este contexto, se sugiere considerar el equilibrio entre precisión y tiempo según recursos disponibles y los objetivos del análisis.

Presentación de Resultados Cualitativos

Anexo 1.

Las entrevistas realizadas a los profesionales con experiencia en el uso de inteligencia artificial (IA) en el procesamiento de imágenes satelitales muestran una adopción creciente y diversa de estas tecnologías en contextos como monitoreo ambiental, planificación territorial, gestión de riesgos y salud pública. Todos los entrevistados han usado plataformas como Google Earth Engine, Python con bibliotecas de machine learning (scikit-learn, TensorFlow, xgboost), y herramientas SIG como QGIS y ArcGIS. Las tareas más automatizadas incluyen la clasificación de coberturas, detección de objetos, identificación de focos de calor y predicción de eventos como incendios o brotes epidemiológicos. La mayoría coincide en que la IA ha reducido significativamente los tiempos de procesamiento (hasta un 70%) y ha mejorado la eficiencia operativa, aunque aún requiere supervisión experta y datos de entrenamiento de calidad.

Análisis de Resultados Cualitativos

El análisis de las respuestas demuestra una percepción compartida sobre los beneficios de la IA, especialmente en la automatización de tareas repetitivas, la mejora en la detección de patrones espaciales complejos y la compatibilidad con plataformas SIG. Sin embargo, se identifican obstáculos comunes, como la escasez de datasets etiquetados en contextos de Latinoamérica, la sensibilidad de los modelos a la calidad de las imágenes (nubosidad, resolución) y la necesidad de personal capacitado para el diseño y validación de modelos. Aunque algunos profesionales han trabajado con modelos preconfigurados en software comercial, otros han desarrollado soluciones personalizadas, lo que refleja distintos niveles de profundidad técnica. La IA no ha suprimido la necesidad de intervención humana todavía, pero ha transformado su rol hacia tareas más estratégicas y analíticas.

Interpretación de Resultados Cualitativos

Los resultados sugieren que la inteligencia artificial está consolidándose como una herramienta clave en el procesamiento de imágenes satelitales, con un impacto tangible en la eficiencia, precisión y escalabilidad de los análisis geoespaciales. A pesar de que no reemplaza en su totalidad los métodos tradicionales, su integración está redefiniendo el perfil del profesional geoespacial, que ahora debe combinar conocimientos técnicos con habilidades en ciencia de datos. La IA permite abordar problemáticas territoriales con mayor rapidez y profundidad, pero su efectividad depende de la calidad de los datos, la contextualización local y la supervisión experta. En este sentido, la IA no sustituye la experiencia humana, sino que la potencia, abriendo nuevas posibilidades para la planificación territorial basada en evidencia.

Conclusiones

- 1) La comparativa entre los métodos tradicionales y aquellos basados en inteligencia artificial permitieron evaluar cómo la IA mejora la eficiencia en el procesamiento de imágenes satelitales. Se evidenció que el uso de la IA por más veloz que sea requiere datos de entrenamiento más robustos para alcanzar precisión, lo que indica que la eficiencia se cumple si se equilibran aspectos como la rapidez y la calidad. Por otra parte, hay coincidencias en la idea de que la IA ha reducido tiempos de procesamiento. Aumentando así la eficacia operativa en tareas clave como la clasificación y predicción geoespacial.
- 2) Se describieron detalladamente los algoritmos de aprendizaje automático utilizados, como Random Forest, y su comparación con algoritmos tradicionales como máxima verosimilitud. Los resultados demostraron las ventajas y limitaciones del aprendizaje automático que tuvo mayor precisión en clases urbanas, pero deficiencias en clases como bosque y agua. Por otro lado, los profesionales entrevistados mencionaron el uso de varias bibliotecas, lo que evidencia una aprobación técnica de los algoritmos en distintos contextos.
- 3) Se implementó la IA en el procesamiento de imágenes satelitales y se comprobó su eficiencia. Los resultados muestran que a pesar de que el proceso con IA requiere una preparación más compleja, el tiempo de ejecución fue menor que con el método tradicional. Además, en los testimonios se destacó como la automatización ha transformado las labores técnicas, permitiendo mayor rapidez en la toma de decisiones territoriales, aun cuando sigue siendo necesaria la supervisión humana.

Recomendaciones

- 1) Fortalecer los procesos de recolección y curación de datos de entrenamiento para modelos de inteligencia artificial, asegurando una mayor diversidad y calidad de las imágenes satelitales. Esto permitirá mejorar la precisión en todas las categorías geoespaciales y maximizar la eficiencia que la IA puede ofrecer en los análisis territoriales.
- 2) Capacitar a los profesionales del área geoespacial en el uso y comprensión de algoritmos de aprendizaje automático, promoviendo el dominio de herramientas como Python, scikit-learn y TensorFlow. Esta formación permitirá aprovechar al máximo las capacidades de la IA y adaptarla a las necesidades locales mediante soluciones personalizadas.
- 3) Implementar estrategias mixtas que combinen la velocidad de la IA con la estabilidad de los métodos tradicionales, dependiendo del contexto y los recursos disponibles. Se sugiere utilizar IA en tareas repetitivas y de gran volumen, pero mantener la supervisión humana en etapas clave para asegurar la calidad y contextualización de los resultados.

Referencias

- Ahmed, F., & Rahman, S. (2021). Uso de modelos de IA para predecir inundaciones y mapear riesgos en Bangladesh. *International Journal of Geospatial Analysis*, 14(3), 112-127.
- Asner, G. P., Llacayo, W., Tupayachi, R., & Luna, E. R. (2020). Elevated rates of deforestation and degradation in lowland and Andean Amazonia. *Environmental Research Letters*, 15(3), 025003.
- Aubrecht, C., Özceylan, D., Steinnocher, K., & Freire, S. (2019). Multi-source geospatial data integration for urban vulnerability mapping. *ISPRS International Journal of Geo-Information*, 8(2), 73-85.
- Batty, M. (2013). *Big Data, smart cities and city planning. Dialogues in Human Geography*, 3(3), 274-279.
- Bengio, Y. (2012). Practical recommendations for gradient-based training of deep architectures. *Neural Networks: Tricks of the Trade*, 2, 437-478.
- Burrough, P. A., & McDonnell, R. A. (1998). *Principles of geographical information systems*. Oxford University Press.
- Campbell, J. B. (2011). *Introduction to remote sensing* (5th ed.). The Guilford Press.
- Charnes, A., Cooper, W. W., & Rhodes, E. (1978). Measuring the efficiency of decision-making units. *European Journal of Operational Research*, 2(6), 429-444.
- Cheng, X., & Liu, Y. (2020). Satellite image processing using deep learning algorithms for land cover classification: A review of applications. *Remote Sensing Technology Journal*, 15(3), 150-165.

- Dávila Sguerra, M. (2023). Algoritmos para el procesamiento de imágenes utilizando satélites del programa Copernicus de la Unión Europea. *MappingGIS*.
- Farrell, M. J. (1957). The measurement of productive efficiency. *Journal of the Royal Statistical Society: Series A (General)*, 120(3), 253-290.
- García, J., & Pérez, L. (2004). El empleo de los SIG y la teledetección en planificación territorial. En *Aportaciones al XI Congreso de Métodos Cuantitativos, SIG y Teledetección* (pp. 123–135). Universidad de Murcia.
- Gangopadhyay, S., Bhattacharya, A., & Pal, S. (2020). Aplicación de redes neuronales convolucionales para la clasificación del uso del suelo en la India. *International Journal of Remote Sensing*, 41(9), 3352-3371.
- Gómez, A., & Martínez, R. (1984). La teledetección y la ordenación del territorio. *ResearchGate*.
- González, M., & Cáceres, P. (2020). Sistema de procesamiento digital de imágenes satelitales para cálculo de áreas de interés. *ResearchGate*.
- Gonzalez-Roglich, M., & Mendoza, E. (s. f.). Introducción a la teledetección. *NASA Applied Sciences*.
- Goodchild, M. F. (2007). Citizens as sensors: The world of volunteered geography. *GeoJournal*, 69(4), 211-221.
- Goodchild, M. F. (2018). GIScience, geography, form, and process. *Annals of the American Association of Geographers*, 108(5), 1234-1246.
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast-learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527-1554.

- Jensen, J. R. (2007). *Remote sensing of the environment: An earth resource perspective* (2nd ed.). Prentice Hall.
- Jones, T., & Smith, H. (2019). Automated satellite image processing for urban planning using machine learning. *International Journal of Geospatial Applications*, 12(2), 78-85.
- Johnson, K., Miller, A., & Thompson, L. (2018). Implementación de IA en la cartografía del tráfico urbano en Chicago. *Transportation Research Journal*, 12(5), 214-229.
- Kouatchou, J., Caraballo-Vega, J. A., Spradlin, C., & Li, J. (2023). Fundamentos del aprendizaje automático para las ciencias de la Tierra. NASA Applied Remote Sensing Training Program (ARSET).
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Li, W., Guo, Q., & El-Ghazawi, T. (2017). A comparative study of parallel computing approaches for remote sensing image processing. *IEEE Transactions on Geoscience and Remote Sensing*, 55(3), 1883-1895.
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2014). *Remote sensing and image interpretation* (7th ed.). Wiley.
- Longley, P. A., Goodchild, M. F., Maguire, D. J., & Rhind, D. W. (2015). *Geographic information systems and science* (4th ed.). John Wiley & Sons.
- Lu, D., Mausel, P., Brondizio, E., & Moran, E. (2014). Change detection techniques. *International Journal of Remote Sensing*, 25(12), 2365-2401.
- Martínez, J., & Pérez, L. (2022). Inteligencia artificial en la detección de cambios en zonas costeras de Andalucía. *European Journal of Geospatial Science*, 17(1), 55-69.

- Mather, P. M., & Koch, M. (2011). *Computer processing of remotely sensed images: An introduction* (4th ed.). Wiley-Blackwell.
- Mendoza, E. (2017). Introducción a la teledetección. *CESAR / ESA*.
- Michael, G. (2007). The future of GIS and spatial analysis. *Transactions in GIS*, 11(1), 3-9.
- Mundocartogeo. (2006). *Teledetección: Nociones y aplicaciones*. Mundocartogeo.
- Navarro-Cerrillo, R. M., Varo-Martínez, M. Á., Ariza-Salamanca, A. J., & Rodríguez Galiano, V. (2024). Técnicas de clasificación de imágenes de satélite en ciencias forestales (Capítulo 6). Material didáctico del Máster Geoforest, Universidad de Córdoba (ES).
- Pham, H., Bui, D. T., Pradhan, B., & Revhaug, I. (2018). Landslide susceptibility assessment using Random Forest algorithm and remote sensing data. *Geoscience Frontiers*, 9(5), 1585-1593.
- Ramírez, G., & Medina, E. (2022). Procesamiento de imágenes satelitales mediante redes neuronales profundas para el mapeo de cambios en el uso de suelo en las zonas rurales de Ecuador. *Geospatial Analysis Journal*, 9(1), 123-134.
- Romón Jacob, I. (2021). Clasificación de imágenes espaciales mediante visión artificial. *Trabajo de Fin de Grado*, Universidad Politécnica de Madrid.
- Russell, S., & Norvig, P. (2016). *Artificial intelligence: A modern approach* (3rd ed.). Pearson Education.
- Sarmiento, V. (2021). Inteligencia artificial aplicada al estudio de imágenes satelitales. *Tecnología Investigación y Academia*, 8(1), 113–121.
- Schowengerdt, R. A. (2007). *Remote sensing: Models and methods for image processing* (3rd ed.). Academic Press.

Shafri, H. (2022). Métodos de inteligencia artificial (IA) para aplicaciones en teledetección.

Fedepalma.

Silva, R., Souza, M., & Andrade, C. (2019). Optimización de la cartografía de deforestación en la Amazonía mediante aprendizaje profundo. *Revista de Ciencias Ambientales*, 28(2), 125-139.

Valero Medina, J. A., & Alzate Atehortúa, B. E. (2019). Comparación de las técnicas máxima verosimilitud, máquinas de soporte vectorial y bosques aleatorios en clasificación de imágenes satelitales. *Tecnura*, 23(59), 13–26.

Wang, L., Li, Z., & Zhang, J. (2020). Processing satellite images using AI models for land cover classification. *Remote Sensing of Environment*, 240, 111710.

Zhang, Y., Li, H., & Wang, F. (2018). Aplicación de redes neuronales profundas en la interpretación de imágenes satelitales para planificación territorial. *Journal of Applied Remote Sensing*, 12(1), 046002.

Anexo 1

Entrevista previa a la obtención del Título de Ingeniero Geógrafo en Planificación Territorial

“Uso de Inteligencia Artificial en el Procesamiento de Imágenes Satelitales”

Nombre: Belén Zambrano

Edad: 28

Título de pregrado: Ingeniería Ambiental

Título de postgrado (Si aplica):

Lugar de trabajo: PROCALCULO PROSIS SAS

Esta entrevista tiene como objetivo conocer la experiencia de profesionales que han incorporado herramientas de inteligencia artificial (IA) en el procesamiento de imágenes satelitales. Se busca identificar beneficios, desafíos, aplicaciones prácticas y perspectivas sobre el uso actual y futuro de la IA en este campo.

Preguntas

1. ¿Cuánto tiempo lleva utilizando herramientas de inteligencia artificial para el procesamiento de imágenes satelitales y qué tecnologías o plataformas ha empleado en ese tiempo?

Llevo aproximadamente 3 años incorporando herramientas de inteligencia artificial (IA) en el procesamiento de imágenes satelitales. Comencé durante mi trabajo de titulación, en el que apliqué modelos de deep learning para detectar residuos sólidos a partir de imágenes de alta resolución, y desde entonces he continuado en el ámbito profesional aplicando IA para análisis agrícolas, catastro rural, monitoreo ambiental y detección de cambios. Las tecnologías que he utilizado incluyen bibliotecas como TensorFlow, PyTorch y Scikit-learn, además de herramientas geoespaciales como Google Earth Engine, ArcGIS Pro, QGIS y plataformas de visualización satelital como Planet Explorer y las API de LuxCarta y Omeo Space.

2. Desde su experiencia, ¿qué beneficios y limitaciones ha identificado al implementar IA en este campo?

Uno de los mayores beneficios ha sido la capacidad de procesar grandes volúmenes de datos en menos tiempo y con una mayor consistencia, especialmente en tareas repetitivas como la clasificación o segmentación de coberturas.

Como limitaciones, destacaría la necesidad de contar con datasets etiquetados de calidad para entrenar los modelos y eso en LATAM casi no hay por nuestras condiciones climáticas.

3. ¿Cómo describiría el impacto de la IA en cuanto al tiempo requerido para el procesamiento, en comparación con los métodos tradicionales?

El impacto ha sido significativo. Mientras que los métodos tradicionales requerían procesos manuales extensos y revisiones por parte de varios especialistas, la IA ha permitido automatizar fases del flujo de trabajo, reduciendo tiempos hasta en un 60- 70% en algunos proyectos, especialmente en clasificación de uso de suelo o identificación de coberturas agrícolas.

4. ¿Qué tareas específicas del procesamiento de imágenes considera que han sido automatizadas con mayor éxito gracias a la IA? ¿Qué tanto ha disminuido su intervención humana durante procesos como la clasificación supervisada?

Las tareas más exitosamente automatizadas han sido la detección de objetos, clasificación de coberturas y segmentación semántica. En procesos como la clasificación supervisada, la intervención humana se ha reducido principalmente a la validación y ajuste fino de los resultados, más que a la clasificación misma.

5. ¿Ha aplicado modelos de IA en distintos tipos de imágenes satelitales (como Landsat, Sentinel o Copernicus) y regiones geográficas? ¿Qué tan fácil ha sido adaptar esos modelos a nuevos contextos?

Sí, he trabajado con imágenes de Landsat, Sentinel-2, PlanetScope y también con imágenes submétricas comerciales. He aplicado modelos en distintas regiones de Ecuador, tanto rurales como periurbanas.

6. ¿El uso de IA ha representado una reducción en los costos operativos o en el uso de recursos como hardware, software o personal especializado?

Sí, en algunos casos hemos podido reducir el tiempo operativo del personal técnico y evitar la contratación de horas adicionales de análisis. Si bien al inicio se requiere inversión en capacitación y procesamiento (a veces en la nube), los modelos una vez entrenados permiten una ejecución más eficiente.

7. ¿Qué tan compatibles han sido los resultados obtenidos mediante IA con las plataformas de Sistemas de Información Geográfica (SIG) que utiliza?

Muy compatibles. Los outputs generados por IA, como mapas de clasificación raster o vectores de segmentación, pueden ser integrados fácilmente en plataformas SIG. En mi experiencia, tanto ArcGIS como QGIS permiten trabajar con estos productos y realizar análisis espaciales complementarios que se requiera.

8. En términos de análisis espacial, ¿considera que la calidad de los productos generados mediante IA es adecuada?

Sí, siempre y cuando el modelo esté bien entrenado y se utilice una validación rigurosa que tengan precisión de al menos un %90 en adelante.

9. ¿Cómo ha respondido la IA ante imágenes con baja calidad, presencia de nubosidad u otras condiciones desfavorables?

Lo que sé es que algunos modelos pueden ser entrenados para reconocer y filtrar estas áreas problemáticas, aunque con menor precisión que en condiciones óptimas. También se podría usar un dataset con imágenes radar, pero sería más trabajoso de etiquetar, limpiar las imágenes etc.

10. ¿Considera que la inteligencia artificial es solo una herramienta complementaria a los métodos tradicionales o cree que eventualmente los reemplazará en el procesamiento de imágenes satelitales?

Considero que, por ahora, la IA es una herramienta complementaria super potente, pero no sustituye del todo la experticia humana. Sin embargo, a medida que los modelos mejoran y se vuelven más accesibles, es probable que muchas tareas rutinarias sean completamente automatizadas. El rol del especialista evolucionará hacia el diseño, supervisión y validación de estos modelos, más que a la ejecución manual de los análisis.

Agradecemos su participación y el tiempo dedicado a responder estas preguntas. Su experiencia es valiosa para comprender el impacto y las posibilidades que ofrece la inteligencia artificial en el procesamiento de imágenes satelitales, así como para orientar futuras investigaciones y aplicaciones en el campo.

Entrevista previa a la obtención del Título de Ingeniero Geógrafo en Planificación Territorial

“Uso de Inteligencia Artificial en el Procesamiento de Imágenes Satelitales”

Nombre: Diego Reyes

Edad: 31

Título de pregrado: Ing. Geógrafo y del Medio Ambiente

Título de postgrado (Si aplica): Mgtr. Gestión de Riesgos de Desastres

Lugar de trabajo: secretaria de Hábitat de Ordenamiento Territorial del DMQ

Esta entrevista tiene como objetivo conocer la experiencia de profesionales que han incorporado herramientas de inteligencia artificial (IA) en el procesamiento de imágenes satelitales. Se busca identificar beneficios, desafíos, aplicaciones prácticas y perspectivas sobre el uso actual y futuro de la IA en este campo.

Preguntas

1. ¿Cuánto tiempo lleva utilizando herramientas de inteligencia artificial para el procesamiento de imágenes satelitales y qué tecnologías o plataformas ha empleado en ese tiempo?

Un año de forma particular, específicamente en el uso de herramientas incorporadas en los programas, ejemplo en el software ENVI; mas no en el desarrollo y diseño de dichas herramientas, a pesar de que ocupo para otros procesos de analítica de datos.

2. Desde su experiencia, ¿qué beneficios y limitaciones ha identificado al implementar IA en este campo?

Beneficios, la reducción de tiempos en la identificación de patrones. En el contexto de desarrollo, la creación de herramientas personalizadas.

Limitaciones, los bancos de datos para el desarrollo de dichos modelos y el tiempo de desarrollo invertido en la construcción de modelos particulares.

3. ¿Cómo describiría el impacto de la IA en cuanto al tiempo requerido para el procesamiento, en comparación con los métodos tradicionales?

Existe una mejora en la optimización en función a objetivos específicos de búsqueda, sin embargo, esto no significa que sea autónomo, ya que se requiere de personal capacitado que supervise el resultado y evalúe los parámetros para obtener resultados alineados al objetivo del análisis.

4. ¿Qué tareas específicas del procesamiento de imágenes considera que han sido automatizadas con mayor éxito gracias a la IA? ¿Qué tanto ha disminuido su intervención humana durante procesos como la clasificación supervisada? Identificación de áreas de verdes, edificaciones, derrames de petróleo.
5. ¿Ha aplicado modelos de IA en distintos tipos de imágenes satelitales (como Landsat, Sentinel o Copernicus) y regiones geográficas? ¿Qué tan fácil ha sido adaptar esos modelos a nuevos contextos?
Sentinel, resulta ligeramente sencillo, ya que se parte de un entorno asistido provisto por las licencias comerciales que incorporan dichos modelos.
6. ¿El uso de IA ha representado una reducción en los costos operativos o en el uso de recursos como hardware, software o personal especializado?
No, necesariamente, ya que demanda de recursos compatibles que garanticen la operatividad y la comprensión.
7. ¿Qué tan compatibles han sido los resultados obtenidos mediante IA con las plataformas de Sistemas de Información Geográfica (SIG) que utiliza? Depende, desde el punto de la metodología de uso, los SIG pueden incorporar dichas herramientas, mas es probable que se requiera de una segunda aplicación o entorno para procesar y su resultado sea llevado al entorno SIG.
8. En términos de análisis espacial, ¿considera que la calidad de los productos generados mediante IA es adecuada?
Todo depende del grado de conocimiento sobre el algoritmo, los datos, el método y el propósito, ya que el procesamiento lo puede ejecutar, si existe las garantías del caso, los resultados son precisos.
9. ¿Cómo ha respondido la IA ante imágenes con baja calidad, presencia de nubosidad u otras condiciones desfavorables?
No, lo he analizado detenidamente dado que se enmascara dichas áreas.
10. ¿Considera que la inteligencia artificial es solo una herramienta complementaria a los métodos tradicionales o cree que eventualmente los reemplazará en el procesamiento de imágenes satelitales?
Ya es una herramienta complementaria, probablemente el flujo de trabajo tradicional sea reducido, sin embargo, siempre demandara de una supervisión para la configuración de parámetros, tratamiento de los insumos e interpretación de resultados, a pesar de que los resultados entregados gocen de aceptación por los desarrolladores, siempre será necesario la intervención de un especialista que respalde el resultado.

Agradecemos su participación y el tiempo dedicado a responder estas preguntas. Su experiencia es valiosa para comprender el impacto y las posibilidades que ofrece la inteligencia artificial en el procesamiento de imágenes satelitales, así como para orientar futuras investigaciones y aplicaciones en el campo.

**Entrevista previa a la obtención del Título de Ingeniero Geógrafo en
Planificación Territorial**

“Uso de Inteligencia Artificial en el Procesamiento de Imágenes Satelitales”

Nombre: María Gabriela López Revelo

Edad: 29

Título de pregrado: Ingeniería Geográfica en Gestión Ambiental

Título de postgrado (Si aplica): Magíster en Sistemas de la Información, Mención Data Science

Lugar de trabajo: Secretaría de Salud – Municipio del DMQ

Esta entrevista tiene como objetivo conocer la experiencia de profesionales que han incorporado herramientas de inteligencia artificial (IA) en el procesamiento de imágenes satelitales. Se busca identificar beneficios, desafíos, aplicaciones prácticas y perspectivas sobre el uso actual y futuro de la IA en este campo.

Preguntas

1. ¿Cuánto tiempo lleva utilizando herramientas de inteligencia artificial para el procesamiento de imágenes satelitales y qué tecnologías o plataformas ha empleado en ese tiempo?

Llevo aproximadamente 3 años incorporando técnicas de inteligencia artificial en el procesamiento de imágenes satelitales, principalmente durante mi trabajo en la Secretaría de Salud y en el Instituto de Investigación Geológico y Energético. He utilizado plataformas como Google Earth Engine, MaxEnt, y herramientas de machine learning disponibles en QGIS y Python (principalmente con scikit-learn y TensorFlow para modelos específicos).

2. Desde su experiencia, ¿qué beneficios y limitaciones ha identificado al implementar IA en este campo?

Uno de los principales beneficios es la automatización de tareas repetitivas, la reducción del tiempo de procesamiento y la capacidad de identificar patrones complejos que no siempre son evidentes visualmente. Sin embargo, también he enfrentado limitaciones, como la necesidad de procesar grandes volúmenes de datos multitemporales y la sensibilidad de algunos modelos a la calidad y resolución de las imágenes.

3. ¿Cómo describiría el impacto de la IA en cuanto al tiempo requerido para el procesamiento, en comparación con los métodos tradicionales?

El impacto ha sido muy positivo. Por ejemplo, al trabajar con predicciones de incendios forestales mediante la implementación del modelo MaxEnt permitió obtener aproximaciones de posibles ocurrencias de este tipo de eventos en el DMQ, mientras que con métodos tradicionales tomaría semanas. En general, los tiempos se reducen considerablemente, especialmente en etapas como clasificación o predicción espacial.

4. ¿Qué tareas específicas del procesamiento de imágenes considera que han sido automatizadas con mayor éxito gracias a la IA? ¿Qué tanto ha disminuido su intervención humana durante procesos como la clasificación supervisada?

La clasificación de coberturas y la detección de patrones espaciales en imágenes multiespectrales se han automatizado con gran éxito. Un ejemplo es la aplicación realizada en temas de vigilancia epidemiológica. En el caso del *Aedes aegypti* (mosquito del dengue), los algoritmos identificaron áreas de riesgo basándose en variables ambientales sin necesidad de una interpretación manual continua. En este sentido, la intervención humana ha disminuido especialmente en la validación y ajuste de parámetros, aunque sigue siendo fundamental para supervisión y ajustes contextuales.

5. ¿Ha aplicado modelos de IA en distintos tipos de imágenes satelitales (como Landsat, Sentinel o Copernicus) y regiones geográficas? ¿Qué tan fácil ha sido adaptar esos modelos a nuevos contextos?

Sí, he trabajado con imágenes de Sentinel-2 y Landsat en zonas urbanas y rurales del Ecuador, pero sobre todo del DMQ. Adaptar modelos a nuevas regiones requiere ajustes en las variables de entrada, especialmente cuando cambian las condiciones ecológicas o climáticas, pero herramientas como Google Earth Engine facilitan mucho ese proceso.

6. ¿El uso de IA ha representado una reducción en los costos operativos o en el uso de recursos como hardware, software o personal especializado?

Definitivamente sí. Al utilizar plataformas en la nube como Google Earth Engine o al automatizar procesos con scripts en R o en Python, se ha reducido el uso de hardware local costoso. Además, aunque se requiere personal capacitado en IA, una vez implementado el modelo, el mantenimiento y ejecución pueden ser mucho más eficientes.

7. ¿Qué tan compatibles han sido los resultados obtenidos mediante IA con las plataformas de Sistemas de Información Geográfica (SIG) que utiliza?

Los resultados son altamente compatibles. Generalmente se exportan en formatos como GeoTIFF o shapefiles, lo cual permite su uso directo en QGIS o ArcGIS para análisis espacial, mapeo temático o validaciones de campo.

8. En términos de análisis espacial, ¿considera que la calidad de los productos generados mediante IA es adecuada?

Sí, especialmente cuando se cuenta con datos de entrenamiento sólidos, variados y bien georreferenciados. En análisis como la clasificación de cobertura o la predicción de distribución de vectores, los resultados han sido suficientemente precisos para la toma de decisiones en salud pública, vigilancia epidemiológica o gestión de riesgos.

9. ¿Cómo ha respondido la IA ante imágenes con baja calidad, presencia de nubosidad u otras condiciones desfavorables?

La nubosidad sigue siendo una limitación importante, sobre todo con imágenes ópticas. Sin embargo, con técnicas de preprocesamiento o el uso de datos multitemporales, se puede mitigar ese impacto. En modelos robustos, como los usados con Sentinel-2 en estudios epidemiológicos, se logró minimizar el sesgo por nubosidad usando múltiples fechas.

10. ¿Considera que la inteligencia artificial es solo una herramienta complementaria a los métodos tradicionales o cree que eventualmente los reemplazará en el procesamiento de imágenes satelitales?

Creo que actualmente la IA es una herramienta complementaria muy poderosa, pero no sustituye completamente la interpretación experta, especialmente en contextos complejos o con datos limitados. Sin embargo, con la evolución de los modelos y el acceso a más datos de calidad, es probable que la IA adquiera un rol predominante en tareas rutinarias y de análisis masivo, dejando al ser humano el rol de supervisión y toma de decisiones.

Agradecemos su participación y el tiempo dedicado a responder estas preguntas. Su experiencia es valiosa para comprender el impacto y las posibilidades que ofrece la inteligencia artificial en el procesamiento de imágenes satelitales, así como para orientar futuras investigaciones y aplicaciones en el campo.

Entrevista previa a la obtención del Título de Ingeniero Geógrafo en Planificación Territorial

“Uso de Inteligencia Artificial en el Procesamiento de Imágenes Satelitales”

Nombre: Nicholas Oña

Edad: 29

Título de pregrado: Ingeniería Geográfica **Título**

de postgrado (Si aplica): Ciencia de Datos **Lugar de**

trabajo: Instituto Geográfico Militar

Esta entrevista tiene como objetivo conocer la experiencia de profesionales que han incorporado herramientas de inteligencia artificial (IA) en el procesamiento de imágenes satelitales. Se busca identificar beneficios, desafíos, aplicaciones prácticas y perspectivas sobre el uso actual y futuro de la IA en este campo.

Preguntas

1. ¿Cuánto tiempo lleva utilizando herramientas de inteligencia artificial para el procesamiento de imágenes satelitales y qué tecnologías o plataformas ha empleado en ese tiempo?

Llevo aproximadamente 3 años incorporando herramientas de inteligencia artificial en el procesamiento de imágenes satelitales, con un enfoque más intensivo durante los últimos dos años gracias a mi formación en Ciencia de Datos. He trabajado principalmente con plataformas como Google Earth Engine, QGIS con complementos de machine learning, y lenguajes como Python con bibliotecas especializadas (por ejemplo, scikit-learn, xgboost, y tensorflow en contextos experimentales). Además, he utilizado modelos de aprendizaje supervisado y no supervisado para clasificación de cobertura de suelo, detección de focos de calor e identificación de áreas afectadas por procesos naturales como movimientos en masa o incendios forestales.

2. Desde su experiencia, ¿qué beneficios y limitaciones ha identificado al implementar IA en este campo?

Entre los principales beneficios, destaco la capacidad de procesar grandes volúmenes de datos con rapidez, generar clasificaciones más consistentes, y automatizar tareas repetitivas, como la clasificación supervisada. Además, la

IA ha permitido mejorar la detección de patrones espaciales complejos que resultaban difíciles de identificar con métodos tradicionales.

Sin embargo, también he observado limitaciones. Una de ellas es la dependencia de datos de entrenamiento de buena calidad, que puede ser difícil de obtener para ciertas zonas. Otra limitación importante es la necesidad de una curva de aprendizaje técnica para dominar el uso de algoritmos y plataformas, lo cual puede excluir a profesionales sin formación en programación o ciencia de datos.

3. ¿Cómo describiría el impacto de la IA en cuanto al tiempo requerido para el procesamiento, en comparación con los métodos tradicionales?

El impacto ha sido muy positivo en cuanto a la eficiencia temporal. Tareas que antes requerían horas o incluso días, como la clasificación de coberturas en zonas amplias, ahora pueden completarse en cuestión de minutos o pocas horas con IA, especialmente utilizando procesamiento en la nube (como en Google Earth Engine). Esto ha permitido aumentar la frecuencia de actualización de productos geoespaciales y responder de forma más oportuna a eventos como incendios o brotes epidemiológicos.

4. ¿Qué tareas específicas del procesamiento de imágenes considera que han sido automatizadas con mayor éxito gracias a la IA? ¿Qué tanto ha disminuido su intervención humana durante procesos como la clasificación supervisada?

La clasificación supervisada de coberturas de suelo, la detección de cambios temporales y la identificación de anomalías (como focos de calor o áreas deforestadas) son tareas que han sido altamente automatizadas con IA. El uso de algoritmos como Random Forest, Support Vector Machines y redes neuronales ha permitido una reducción significativa de la intervención manual, aunque todavía es necesario realizar ajustes, validación y entrenamiento del modelo con conocimiento experto. En mi experiencia, la intervención humana ha disminuido entre un 40% y 60% en ciertas tareas específicas.

5. ¿Ha aplicado modelos de IA en distintos tipos de imágenes satelitales (como Landsat, Sentinel o Copernicus) y regiones geográficas? ¿Qué tan fácil ha sido adaptar esos modelos a nuevos contextos?

Sí, he trabajado principalmente con imágenes de Landsat 8, Sentinel-2 y, en algunos casos, datos de MODIS y VIIRS para análisis temporales o de incendios. Adaptar los modelos a nuevos contextos requiere ajustar los parámetros del modelo y, sobre todo, reentrenar con muestras locales, ya que la reflectancia o respuesta espectral puede variar según la región, el tipo de cobertura o la época del año. Sin embargo, con herramientas como GEE, este proceso se ha hecho mucho más accesible y reproducible.

6. ¿El uso de IA ha representado una reducción en los costos operativos o en el uso de recursos como hardware, software o personal especializado?

Sí. El uso de plataformas como Google Earth Engine, que operan en la nube y de forma gratuita para uso académico y gubernamental, ha permitido reducir considerablemente el uso de hardware local potente. Además, al automatizar tareas repetitivas, se reduce el tiempo de dedicación del personal técnico. Sin embargo, aún se requiere formación especializada para diseñar y validar los modelos, por lo que no necesariamente se prescinde de personal, sino que sus roles evolucionan hacia tareas más analíticas y estratégicas.

7. ¿Qué tan compatibles han sido los resultados obtenidos mediante IA con las plataformas de Sistemas de Información Geográfica (SIG) que utiliza?

Los resultados han sido altamente compatibles, sobre todo cuando se generan productos en formatos estándar como GeoTIFF o shapefiles. Los modelos aplicados en GEE o Python pueden exportar directamente a estos formatos, lo que permite integrarlos sin problemas en plataformas como QGIS o ArcGIS para análisis adicionales, validación o difusión. Incluso se pueden automatizar flujos de trabajo para actualizar mapas en dashboards o story maps.

8. En términos de análisis espacial, ¿considera que la calidad de los productos generados mediante IA es adecuada?

Sí, en general, la calidad es muy buena, especialmente cuando se dispone de datos de entrenamiento adecuados y se seleccionan las variables espectrales

o índices adecuados (como NDVI, NBR, NDWI). En análisis que he realizado, los productos generados con IA han alcanzado precisiones superiores al 85% y han permitido una mejor comprensión espacial de fenómenos como la expansión urbana o la degradación del territorio.

9. ¿Cómo ha respondido la IA ante imágenes con baja calidad, presencia de nubosidad u otras condiciones desfavorables?

Este sigue siendo un reto importante. Si bien algunos algoritmos pueden manejar ruido o datos faltantes, la nubosidad intensa y las sombras siguen afectando la precisión del modelo. Para mitigar este problema, suelo utilizar composites temporales (medianas o percentiles) o aplicar máscaras de nubes antes de entrenar el modelo. En contextos tropicales como el Ecuador, donde la nubosidad es frecuente, estas estrategias son claves para obtener productos confiables.

10. ¿Considera que la inteligencia artificial es solo una herramienta complementaria a los métodos tradicionales o cree que eventualmente los reemplazará en el procesamiento de imágenes satelitales?

Actualmente, considero que la IA es una herramienta complementaria, pero con un potencial creciente para reemplazar tareas tradicionales que son repetitivas y propensas a error humano. Sin embargo, la experiencia del analista geoespacial sigue siendo fundamental para diseñar, validar y contextualizar los modelos. A futuro, es probable que la IA asuma un rol central, pero siempre bajo la supervisión de especialistas que puedan interpretar y traducir los resultados a decisiones prácticas y políticas públicas.

Agradecemos su participación y el tiempo dedicado a responder estas preguntas. Su experiencia es valiosa para comprender el impacto y las posibilidades que ofrece la inteligencia artificial en el procesamiento de imágenes satelitales, así como para orientar futuras investigaciones y aplicaciones en el campo.

**Entrevista previa a la obtención del Título de Ingeniero Geógrafo en Planificación
Territorial**

“Uso de Inteligencia Artificial en el Procesamiento de Imágenes Satelitales”

Nombre: Mauricio Viera

Edad: 29

Título de pregrado: Ingeniería Geográfica y del Medio Ambiente

Título de postgrado (Si aplica):

Lugar de trabajo: Secretaría de Hábitat y Ordenamiento Territorial – Dirección
Metropolitana de Ordenamiento Territorial

Esta entrevista tiene como objetivo conocer la experiencia de profesionales que han incorporado herramientas de inteligencia artificial (IA) en el procesamiento de imágenes satelitales. Se busca identificar beneficios, desafíos, aplicaciones prácticas y perspectivas sobre el uso actual y futuro de la IA en este campo.

Preguntas

1. ¿Cuánto tiempo lleva utilizando herramientas de inteligencia artificial para el procesamiento de imágenes satelitales y qué tecnologías o plataformas ha empleado en ese tiempo?

Aproximadamente un año, principalmente utilizo la librería de “pytorch” y “geotorch” a través de un entorno específico creado a partir de “Anaconda” para la aplicación de inteligencia artificial para segmentación de imágenes, todo es ejecutado mediante cualquier IDLE disponible.

2. Desde su experiencia, ¿qué beneficios y limitaciones ha identificado al implementar IA en este campo?

En cuanto al beneficio, he podido comprobar un mejor resultado en cuanto a las métricas obtenidas en el tema clasificación o segmentación de imágenes mediante el uso de distintas arquitecturas de redes neuronales, comparado con algoritmos de “machine learning”. También destaco la facilidad para realizar una búsqueda de hiperparámetros y la versatilidad de librerías enfocadas en datos geoespaciales.

3. ¿Cómo describiría el impacto de la IA en cuanto al tiempo requerido para el procesamiento, en comparación con los métodos tradicionales?

Como mencioné en el anterior apartado, he obtenido mayor fluidez en cuanto a la búsqueda de hiperparámetros y selección de arquitecturas idóneas para resolver el problema de clasificación de imágenes en cuanto a clases de interés. Por ejemplo, me toma aproximadamente unas 4 horas encontrar una arquitectura con sus respectivos hiperparámetros idóneos para resolver una problemática, y cabe mencionar, que son datos geoespaciales con una gran resolución espacial. En cambio, mediante el uso de algoritmos de machine learning, me toma el doble de tiempo, ejecutar una búsqueda y las métricas obtenidas son inferiores.

4. ¿Qué tareas específicas del procesamiento de imágenes considera que han sido automatizadas con mayor éxito gracias a la IA? ¿Qué tanto ha disminuido su intervención humana durante procesos como la clasificación supervisada?

En la experiencia de aplicación de este tipo de herramientas, he constatado que la segmentación de imágenes y la detección de objetos han obtenido un enorme avance y al alcance de todos. Por ejemplo, para mi tesis de pregrado, que estaba enfocada en la detección de enfermedades de las palmas africanas, hace 6 años aproximadamente, aún eran un poco inestables estas tareas mencionadas, además de que mayormente se distribuían a través de software comercial. Es importante aclarar, que desde entonces ya se había mermado la participación humana en el ámbito que menciono, por ejemplo, se

desarrollaba un conteo automático de palmas, a manera de censo, para poder identificar plantas enfermas y poder acudir a verificarlas en campo, tarea que tomaba bastante tiempo a los palmicultores, al realizarlo de manera manual.

5. ¿Ha aplicado modelos de IA en distintos tipos de imágenes satelitales (como Landsat, Sentinel o Copernicus) y regiones geográficas? ¿Qué tan fácil ha sido adaptar esos modelos a nuevos contextos?

Principalmente he aplicado modelos de machine learning e IA a imágenes Sentinel, de manera que, he podido crear funciones que permitan su preprocesamiento previo, de manera automática, a través de los metadatos, para la posterior aplicación de clasificaciones supervisadas o no supervisadas. Se me ha hecho un proceso bastante accesible y sin dificultad alguna, por otro lado, al manejar este tipo de algoritmos en ortofotos, es donde mayor complicación he tenido, por la gran resolución espacial de este tipo de datos.

6. ¿El uso de IA ha representado una reducción en los costos operativos o en el uso de recursos como hardware, software o personal especializado?

En ese apartado, mantengo una compostura neutral, ya que, por ejemplo, en mis tareas actuales, se necesitan recursos de hardware mucho más específicos y costosos en el mercado, para poder procesar grandes cantidades de datos geoespaciales de gran resolución espacial. En cuanto, a software me parece que es posible obtener modelos sin la necesidad de utilizar software comercial, el cual es bastante costoso para las instituciones. Pero en cuanto al personal, al tener que elaborar el código y realizar las distintas pruebas y selección de modelos, me parece que si es necesario un profesional, que pueda llevar a cabo estas tareas; mientras que, al entender el personal necesario, para realizar tareas que pueden ser reemplazadas por una clasificación de imágenes, me parece que en parte se podrían reducir esfuerzos y cantidad de personal, pero siempre es importante la validación de técnicos

especializados en cartografía temática, en cuanto a tareas de topología, aplicación de modelos semánticos, reglas de ajuste cartográfico específicas, por lo que, para mí, es aún necesaria la validación técnica por parte de humanos por así decirlo.

7. ¿Qué tan compatibles han sido los resultados obtenidos mediante IA con las plataformas de Sistemas de Información Geográfica (SIG) que utiliza?

Por el momento he logrado que los resultados obtenidos, puedan ser manipulados a partir de software GIS sin problema, desconozco si existen casos en los que no se pueda realizar una integración de resultados.

8. En términos de análisis espacial, ¿considera que la calidad de los productos generados mediante IA es adecuada?

Considero que más que la aplicación de la IA, los resultados obtendrán una buena calidad, dependiendo de los datos utilizados, y del “feature engineering” elaborado.

9. ¿Cómo ha respondido la IA ante imágenes con baja calidad, presencia de nubosidad u otras condiciones desfavorables?

Por el momento, no he tenido que realizar consideraciones especiales de los casos descritos, al tener insumos de gran resolución espacial, zonas sin nubosidad, entre otros. He podido apreciar que se pueden aplicar arquitecturas de tipo GAN para la generación de datos o mejora de resoluciones espaciales, pero en cuanto a la factibilidad para aplicarlas a casos que se necesite la mayor precisión espacial, espectral y temporal, me faltaría la experiencia para poder dar un criterio propio. Me gustaría trabajar en este tema en algún momento.

10. ¿Considera que la inteligencia artificial es solo una herramienta complementaria a los métodos tradicionales o cree que eventualmente los reemplazará en el procesamiento de imágenes satelitales?

Considero que es posible comenzar a reemplazar el uso de software comercial, para aplicar modelos adecuados a la necesidad de cada caso, por lo que se podría invertir en la

generación de datos idóneos para estas tareas y obtener buenos resultados, sin la necesidad de pagar por aplicaciones comerciales de gran valor.

Agradecemos su participación y el tiempo dedicado a responder estas preguntas. Su experiencia es valiosa para comprender el impacto y las posibilidades que ofrece la inteligencia artificial en el procesamiento de imágenes satelitales, así como para orientar futuras investigaciones y aplicaciones en el campo.