

Automatización en la detección de potenciales linderos: integración de algoritmos de IA y fusión de imágenes

Automation in the detection of potential boundaries: integration of AI algorithms and image fusion

Ing. Javier Damián León Ruiz  ¹, **Esp. Diego Andrés Bedoya Peña**  ¹
MSc. Martha Patricia Valbuena Gaona  ²

¹ Sociedad Latinoamericana en Percepción Remota y Sistemas de Información Espacial (SELPER), Capítulo Estudiantil Colombia, Bogotá D.C., Colombia.

² Procalcuto Prosis S.A.S, Gerente de Investigación y Desarrollo, Bogotá D.C, Colombia.

Correspondencia: info@selper.org.co

Recibido: 01 julio 2025. Aceptado: 18 noviembre 2025. Publicado: 08 enero 2026.

Cómo citar: J. D. León Ruiz, D. A. Bedoya Peña, and M. P. Valbuena Gaona, "Automatización en la detección de potenciales linderos: integración de algoritmos de IA y fusión de imágenes", *RCTA*, vol. 1, n.º 47, pp. 169-176, ene. 2026.

Recuperado de <https://ojs.unipamplona.edu.co/index.php/rcta/article/view/4310>

Esta obra está bajo una licencia internacional
 Creative Commons Atribución-NoComercial 4.0.



Resumen: La desactualización catastral en Colombia constituye una barrera estructural para la implementación de la Reforma Rural Integral (RRI). Esta investigación valida una metodología para la extracción automática de linderos visibles mediante la fusión de imágenes de radar de apertura sintética (SAR) y ópticas, empleando técnicas de inteligencia artificial. Se evaluaron comparativamente los enfoques de aprendizaje automático y aprendizaje profundo, contrastando el modelo fundacional Segment Anything Model (SAM) con un detector de bordes reentrenado (VGG13_bn). Los resultados cuantitativos indican que, si bien SAM presenta un mayor nivel de segmentación, el modelo VGG13_bn alcanzó un F1-score de 0.405 y una exactitud de 0.888, configurándose como la alternativa más equilibrada y viable desde el punto de vista operativo. El trabajo aporta un flujo metodológico reproducible que puede apoyar procesos de modernización catastral en contextos de alta complejidad territorial.

Palabras clave: catastro multipropósito, detección de bordes, fusión de imágenes, aprendizaje profundo, límites arcifinios.

Abstract: Outdated cadastral information in Colombia constitutes a structural barrier to the implementation of the Comprehensive Rural Reform (CRR). This research validates a methodology for the automatic extraction of visible boundaries through the fusion of synthetic aperture radar (SAR) and optical imagery, employing artificial intelligence techniques. Machine learning and deep learning approaches were comparatively evaluated, contrasting the foundational Segment Anything Model (SAM) with a retrained edge detector (VGG13_bn). Quantitative results indicate that, while SAM exhibits a higher level of segmentation, the VGG13_bn model achieved an F1-score of 0.405 and an accuracy of 0.888, emerging as the most balanced and operationally viable alternative. This work

provides a reproducible methodological workflow that can support cadastral modernization processes in territorially complex contexts.

Keywords: multipurpose cadastre, edge detection, image fusion, deep learning, arcifinious boundaries.

1. INTRODUCCIÓN

La inseguridad jurídica en la tenencia de la tierra, agravada por una masiva desactualización catastral, representa una barrera estructural para la consolidación de la paz y la implementación de políticas de desarrollo como la Reforma Rural Integral (RRI) en Colombia. Las metodologías tradicionales de levantamiento predial, aunque precisas, son logísticamente inviables para la escala y urgencia que demanda el país, siendo intensivas en tiempo, recursos y susceptibles al error humano [1]. En este contexto, la automatización de la extracción de potenciales linderos prediales mediante teledetección se ha consolidado como un campo de investigación de vital importancia para la modernización del catastro.

El uso de imágenes ópticas, aunque efectivo, se ve severamente restringido por la persistente cobertura nubosa en vastas regiones del territorio nacional. Por ello, el Radar de Apertura Sintética (SAR) emerge como una tecnología estratégica, gracias a su capacidad de adquirir imágenes de alta resolución independientemente de las condiciones atmosféricas o de iluminación [2]. A pesar de esta ventaja operativa, las imágenes SAR presentan desafíos técnicos significativos, principalmente el ruido speckle, un artefacto granular inherente a la señal que degrada la calidad de la imagen, y las distorsiones geométricas (ej. layover, shadow) causadas por la interacción del haz del radar con el relieve topográfico [3]. La corrección de estos fenómenos es un prerequisito indispensable para cualquier análisis fiable.

En el ámbito técnico reciente, el estado del arte presenta avances contrastantes. Por un lado, Fetai et al. [4] validaron la superioridad de las redes convolucionales profundas para la detección de linderos visibles, pero su enfoque depende de imágenes ópticas de vehículos aéreos (UAV), inviables para coberturas nacionales masivas. Por otro lado, en el dominio del radar, estudios como el de Carstairs et al. [5] documentan que, en bandas de longitud de onda corta (como la Banda X), la penetración en el dosel es limitada y la señal sufre decorrelación en zonas de topografía compleja; si bien este hallazgo se dio en el contexto de

degradación forestal, sugiere dificultades inherentes para la definición de bordes prediales bajo vegetación. Para mitigar estas limitaciones, la literatura más actual sugiere la fusión de sensores; Irfan et al. [6] demostraron recientemente que la fusión multimodal (SAR-Óptico) mejora significativamente la clasificación de uso del suelo (Land Cover), aprovechando la textura del radar y la espectralidad óptica. Paralelamente, la irrupción de Modelos Fundacionales como el Segment Anything Model (SAM) [7] ha abierto nuevas posibilidades, aunque existe un vacío técnico respecto a su viabilidad operativa frente a redes ligeras reentrenadas para tareas catastrales en un país como Colombia.

Para superar estos desafíos, este estudio propone y valida una metodología integral que aplica Inteligencia Artificial (IA), específicamente enfoques de Aprendizaje Profundo (DL) [8], para automatizar la extracción de potenciales linderos visibles. El núcleo de la metodología reside en la fusión de imágenes SAR de alta resolución y datos ópticos, combinando la información estructural del radar con la información espectral de la imagen óptica para crear un producto fusionado de mayor interpretabilidad. Este enfoque no solo aborda los problemas técnicos del SAR, sino que sienta una base metodológica robusta para futuras aplicaciones catastrales.

Para el desarrollo y validación de esta propuesta, se seleccionó el municipio de Vistahermosa (Meta) como área de estudio. Este territorio, priorizado en el marco del Acuerdo de Paz de 2016, representa un microcosmos de los desafíos catastrales del país. Un factor determinante para su elección fue la disponibilidad de un conjunto de datos de referencia de alta calidad, correspondientes a los linderos levantados en campo mediante la metodología Fit-For-Purpose (FFP) en 2018, lo cual fue crucial para la validación cuantitativa de los modelos de IA desarrollados. Este artículo detalla el flujo de trabajo completo, desde el preprocesamiento de datos hasta el análisis comparativo de los modelos, y concluye con una discusión sobre la viabilidad práctica de la solución en el contexto colombiano.

2. METODOLOGÍA

La investigación siguió un diseño cuantitativo-experimental, el flujo de trabajo comprende adquisición de datos, preprocesamiento, fusión de imágenes, entrenamiento de modelos de aprendizaje profundo y evaluación cuantitativa.

2.1. Área de Estudio e Insumos de Datos

El área de estudio se focalizó en las veredas Costa Rica, y Terciales, en el municipio de Vistahermosa (Meta), Colombia. Esta zona fue seleccionada estratégicamente por dos razones principales: (1) su relevancia en el contexto del posconflicto, siendo un territorio priorizado para la implementación del catastro multipropósito, y (2) la disponibilidad de un conjunto de datos de validación de alta calidad, correspondientes a los linderos levantados en campo durante el piloto de la metodología Fit-For-Purpose (FFP) en 2018.

Los datos primarios utilizados fueron dos tipos de imágenes satelitales adquiridas en fechas cercanas para asegurar la consistencia temporal:

- Imagen SAR: Una imagen de la constelación Capella Space (Banda X, 50 cm de resolución espacial), adquirida el 24 de septiembre de 2023. Su muy alta resolución fue clave para el discernimiento de detalles estructurales finos.
- Imagen Óptica: Una imagen multiespectral de PlanetScope (3 m de resolución espacial), del 30 de septiembre de 2023, esencial para el análisis de coberturas y la creación de un producto fusionado.

2.2. Preprocesamiento y Fusión de Datos

El flujo metodológico inició con un preprocesamiento riguroso para mitigar los artefactos inherentes a las imágenes SAR y estandarizar los datos para el análisis.

2.2.1 Reducción del Ruido Speckle

Para abordar el ruido granular característico de las imágenes SAR, se evaluaron ocho filtros espaciales. Se seleccionó el filtro IDAN (Intensity-Driven Adaptive-Neighborhood), implementado en el software SNAP, debido a que su algoritmo de vecindad adaptativa demostró el mejor equilibrio entre la supresión de ruido y la preservación de bordes y características lineales finas, cruciales para la posterior detección de linderos [9].

2.2.2 Corrección Geométrica y Orto-rectificación

Las distorsiones geométricas inherentes al SAR, causadas por el relieve, fueron corregidas mediante la generación de un Modelo Digital de Elevación (DEM). Se empleó la técnica de radargrametría sobre el par estéreo de imágenes SAR en el software ENVI SARscape para derivar un DEM de alta resolución. Este DEM fue posteriormente utilizado para la ortorrectificación precisa de la imagen SAR, asegurando su correcta correspondencia geométrica con el terreno y otros sistemas de coordenadas [10].

2.2.3 Fusión de imágenes SAR-Óptico

Con el fin de maximizar la información extraible, se generó un producto de datos fusionados. Se aplicó una fusión basada en el modelo de color HSI (Tono, Saturación, Intensidad), una técnica que permite integrar el detalle estructural de una imagen de alta resolución (SAR) con la información cromática de una imagen multiespectral de menor resolución (óptica). El componente de Intensidad (I) de la imagen óptica (transformada a HSI) fue reemplazado por la imagen SAR, y el resultado fue reconvertido a RGB. Este proceso, fundamentado en trabajos como los de Schmitt & Zhu [11], produce una imagen híbrida que mejora significativamente la interpretabilidad visual.

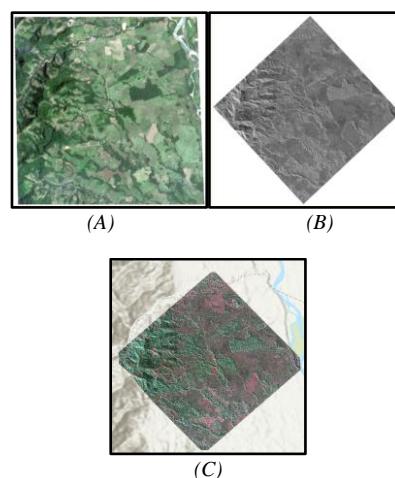


Fig. 1. Fusión sinérgica de datos. (A) Imagen óptica PlanetScope, (B) Imagen SAR Capella Space, y (C) Imagen resultante de la fusión HSI.

Fuente: Elaboración propia.

2.3. Modelos de inteligencia artificial

Se evaluaron y compararon dos paradigmas principales de IA para la generación de candidatos a linderos:

2.3.1 Aprendizaje Automático (ML)

Se implementó el algoritmo de clustering no supervisado Segment Mean Shift a través de las herramientas de segmentación de ArcGIS Pro. Este método fue elegido por su robustez teórica para delinear formas irregulares sin necesidad de predefinir el número de clústeres [12]. Aunque se realizaron pruebas con este enfoque, los resultados cualitativos mostraron una segmentación de coberturas con bordes demasiado gruesos e imprecisos, por lo que se descartó para un análisis cuantitativo profundo en favor de los métodos de DL.

2.3.2 Aprendizaje Profundo (DL)

Se exploraron dos enfoques de vanguardia:

- Land Parcel Extraction (VGG13_bn): Se abordó el problema como una tarea de detección de bordes supervisada. Se re-entrenó un modelo pre-entrenado BDCN (Bi-Directional Cascade Network) [13] con un backbone VGG13_bn [14]. Los datos de entrenamiento se generaron creando un buffer de 0.5 metros alrededor de los linderos de referencia, convirtiendo los vectores en una máscara binaria. Este valor fue seleccionado como un compromiso para asegurar una representación suficiente del borde a nivel de píxel sin introducir ruido de las coberturas adyacentes, el conjunto total (1573 etiquetas) se particionó de la siguiente manera: 70% entrenamiento, 15% validación y 15% prueba.

El modelo de detección de linderos visibles se abordó como un problema de detección de bordes mediante el reentrenamiento de una red convolucional profunda pre entrenada, siguiendo el flujo de trabajo de Deep Learning Edge Detection implementado por ESRI.

Se empleó una Bi-Directional Cascade Network (BDCN) como arquitectura base para detección perceptual de bordes, utilizando VGG13 con normalización por lotes (VGG13_bn) como backbone, la arquitectura está compuesta por trece capas convolucionales organizadas en cinco bloques jerárquicos, cada uno seguido de capas de normalización por lotes y funciones de activación ReLU.

Los hiperparámetros empleados fueron:

- Función de pérdida: Binary Cross-Entropy Loss (BDCE)
- Optimizador: Adam
- Tasa de Aprendizaje: 1×10^{-4}
- Tamaño del lote: 8

Y fue ejecutado dentro de un equipo portátil con las siguientes características:

- CPU: Core i7 13620H 2,4 GHz
- GPU: NVIDIA GeForce RTX 4060 8 Gb (VRAM)
- Memoria: 24 GB (RAM)
- Framework: PyTorch (Integrado en ArcGIS Pro Deep Learning Framework)
- Software: ArcGIS Pro 3.4.0 / Arcpy 3.6

- Segment Anything Model (SAM): Se aplicó el modelo fundacional de Meta AI en su modo automático. Este modelo, gracias a su arquitectura basada en Transformers y su pre-entrenamiento masivo, realiza una segmentación de tipo zero-shot de todos los objetos identificables en la imagen, sin requerir entrenamiento específico para este proyecto [7].

2.4. Evaluación de Resultados

La calidad de los linderos potenciales extraídos se evaluó mediante un análisis cuantitativo de exactitud posicional, comisión y omisión. Para ello, se generó un buffer de tolerancia de 1.04 metros alrededor de los linderos de referencia (FFP), un umbral definido con base en los estándares normativos del IGAC para cartografía catastral a la escala de trabajo [17]. Se cuantificó la longitud de los candidatos a linderos extraídos que cayeron dentro de este buffer (Verdaderos Positivos), así como aquellos que quedaron fuera (Falsos Positivos o errores de comisión) y los linderos de referencia que no fueron detectados (Falsos Negativos o errores de omisión).

3. RESULTADOS Y DISCUSIÓN

3.1. Métricas de Evaluación

Para cuantificar el desempeño de los modelos desde una perspectiva integral, se emplearon dos métricas complementarias. En primera instancia, se calculó la Exactitud (Accuracy), la cual mide la proporción global de aciertos del modelo respecto al total de píxeles de la imagen, indicando su estabilidad general:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Donde:

TP: Verdaderos Positivos.

TN: Verdaderos Negativos.

FP: Falsos Positivos.

FN: Falsos Negativos.

Adicionalmente, se incorporó el F1-Score. Dado que la detección de linderos implica un desbalance de clases (donde los posibles linderos ocupan una porción mínima de la imagen frente al fondo), esta métrica permite evaluar el equilibrio específico entre la Precisión (P) y la Sensibilidad (R) en la delimitación de los vectores lineales:

$$F1 = 2 \cdot \frac{(P \cdot R)}{P + R} \quad (2)$$

Donde P es la precisión predictiva y R es la tasa de verdaderos positivos (Recall).

La interpretación conjunta de ambos valores permite validar tanto la capacidad del modelo para generalizar el entorno como su desempeño en la tarea específica de extracción de potenciales linderos.

3.2. Comparación de Modelos de IA

La fase experimental se diseñó para contrastar de manera sistemática los enfoques de Aprendizaje Automático (ML) y Aprendizaje Profundo (DL).

3.2.1 Desempeño y descarte del enfoque de machine learning

Los algoritmos de ML no supervisado, con Segment Mean Shift como su representante más robusto, fueron evaluados sobre el sinergismo. Como se observa en la Fig. 2, el resultado es una segmentación de coberturas en forma de un mosaico de polígonos irregulares. Aunque se logra una diferenciación de las grandes masas de uso del suelo, los bordes generados son gruesos, geométricamente imprecisos y presentan numerosas discontinuidades, lo que los hace inadecuados para la extracción de vectores de linderos a una escala catastral. La baja calidad de esta salida, sumada al considerable esfuerzo computacional que requeriría su posprocesamiento, justificó el descarte de este paradigma y la concentración de los esfuerzos en los métodos de DL (42% contenido dentro del Buffer de exactitud)



Fig. 2. Potenciales Linderos Segment Mean Shift.

Fuente: Elaboración propia.

Los modelos de DL produjeron resultados cualitativamente superiores y conceptualmente distintos.

- **Enfoque Land Parcel Extraction (VGG13_bn) - Sinergismo:** El modelo VGG13_bn (Land Parcel Extraction), entrenado para la detección específica de bordes, alcanzó su rendimiento óptimo tras 10 épocas de entrenamiento, logrando un F1-Score de 0.405, una Accuracy de 0.888 y una pérdida de validación (valid_loss) de 4.941e9. Aunque el valor del F1-Score puede parecer modesto, es un resultado significativo en el contexto de la compleja tarea de detección de bordes en imágenes SAR. La evaluación cualitativa (Fig. 3) es más reveladora: el modelo produce vectores lineales delgados que se alinean correctamente con caminos y divisiones de parcelas, representando una salida directa y mucho más útil para el propósito catastral que la generada por los métodos de ML (84% contenido dentro del Buffer de exactitud)



Fig. 3. Potenciales Linderos Land Parcel Extraction.

Fuente: Elaboración propia.

- **Enfoque Segment Anything Model (SAM):** SAM produjo segmentación más detallada y precisa de todos los modelos probados, no solo delineó los linderos principales, sino que también identificó variaciones de cobertura dentro de los mismos predios, demostrando una sensibilidad contextual buena (67% contenido dentro del Buffer de exactitud)



*Fig. 4. Potenciales Linderos SAM.
 Fuente: Elaboración propia.*

Su evaluación se dio respecto a la información de referencia levantada en campo, para esto se generó un buffer de tolerancia de 1,04 m alrededor de los linderos obtenidos mediante la metodología FFP, de acuerdo con la exactitud posicional establecida para el insumo cartográfico en la Resolución IGAC 471 de 2020 [15], considerándose como verdaderos positivos aquellos linderos extraídos dentro del buffer y falsos positivos aquellos se encuentran fuera.

3.3. Discusión de Resultados e Implicaciones

3.3.1 *El Dilema entre la Precisión Teórica y la Viabilidad Práctica*

Estudios previos han demostrado que la extracción de límites catastrales constituye un problema altamente desafiante debido al carácter lineal y delgado de los objetos de interés, así como al fuerte desbalance entre clases Fetai et al [16]; la comparación entre SAM y VGG13_bn expone un dilema central para la aplicación de la IA en contextos institucionales. SAM, con su precisión superior, se establece como el benchmark técnico. Sin embargo, su costo computacional (más de 7 horas de procesamiento en hardware especializado para el área de estudio) lo convierte en una herramienta académicamente valiosa pero operativamente inviable para la producción masiva.

En contraste, el modelo VGG13_bn, aunque con un F1-Score inferior, emerge como la solución pragmática y escalable. Su capacidad para ejecutarse en hardware convencional en tiempos razonables y la posibilidad de ajustar su entrenamiento a necesidades regionales específicas lo convierten en el enfoque más equilibrado y recomendable para una implementación inmediata en el marco del catastro multipropósito. Este hallazgo subraya que, en la ingeniería aplicada, la "mejor" solución no es siempre la más precisa, sino la más eficiente y sostenible.

Otros estudios de la temática como el de Zhang et al. [17] reportan resultados de precisión del 88%,

recall del 75% y F1-score del 81% empleando U-Net con backbone ResNet34 para la detección de límites prediales a partir de imágenes Satelitales; si bien estos valores son superiores a los obtenidos en el presente estudio, es importante señalar que dicho enfoque se basa en un esquema de segmentación semántica densa y en conjunto de datos con condiciones espectrales más homogéneas, lo que tiende a favorecer métricas globales más altas.

Por su parte, Fetai et al. [16] evaluaron un modelo convolucional para la revisión de límites catastrales visibles, reportando valores de F1-score entre 0.55 y 0.60 y precisiones de hasta 0.71, dependiendo de la complejidad geométrica y fragmentación de las parcelas analizadas. Estos autores destacan que la variabilidad espacial y la similitud textural entre linderos y coberturas adyacentes influyen significativamente en el desempeño de los modelos, lo cual es consistente con los patrones de error observados en este trabajo.

De manera similar, en un estudio enfocado en imágenes UAV, Fetai et al. [16] obtuvieron precisión de 0.75, recall de 0.65 y F1-score de 0.70 utilizando redes totalmente convolucionales para la detección de linderos visibles. Aunque estas métricas superan las alcanzadas por el modelo VGG13_bn en el presente caso de estudio, debe considerarse que las imágenes UAV presentan resoluciones espaciales significativamente más altas y menor interferencia de ruido radar, lo que facilita la detección de bordes continuos.

En este contexto, el F1-score de 0.405 y la exactitud de 0.888 obtenidos en el presente estudio se sitúan dentro del rango reportado en la literatura para tareas de detección de linderos en escenarios complejos, especialmente cuando se emplean imágenes SAR y productos fusionados SAR–óptico. Estos resultados refuerzan la idea de que, en aplicaciones catastrales operativas, métricas intermedias pueden considerarse aceptables cuando el objetivo es generar candidatos a linderos físicos que apoyen procesos de validación en campo, más que producir delimitaciones jurídicas definitivas.

3.3.2 *Limitaciones de la Metodología:*

Un análisis crítico de los resultados del modelo VGG13_bn revela patrones de error sistemáticos. Los errores de omisión (falsos negativos) se concentran en áreas de sombra de radar y sobre linderos definidos por vegetación baja cuya textura es muy similar a la de los pastos circundantes. Los errores de comisión (falsos positivos) tienden a

aparecer en zonas de alta textura, como lechos de ríos secos o patrones de drenaje, que el modelo confunde con estructuras lineales. Estos hallazgos sugieren que futuras mejoras deberían enfocarse en incorporar información adicional, como datos polarimétricos o de DEM, para ayudar al modelo a desambiguar estas situaciones complejas.

4. CONCLUSIONES

Este estudio desarrolló y validó una metodología integral para la extracción automática de linderos visibles mediante la fusión de imágenes SAR y ópticas. Los resultados experimentales permiten establecer tres conclusiones técnicas fundamentales: Primero, se demostró la superioridad del Aprendizaje Profundo (DL) sobre los métodos de Machine Learning tradicionales para esta tarea específica. Mientras que algoritmos como Segment Mean Shift generaron segmentaciones discontinuas, las redes neuronales lograron abstraer la geometría lineal de los linderos. Específicamente, el modelo VGG13_bn se consolidó como la solución más equilibrada, alcanzando una Exactitud (Accuracy) de 0.888, lo que lo hace viable operativamente frente a modelos fundacionales como SAM, cuyo costo computacional limita su escalabilidad en entornos de recursos restringidos.

Segundo, la estrategia de fusión de imágenes resultó determinante. Se comprobó que la integración de la información estructural del radar con la riqueza espectral óptica mitiga las deficiencias individuales de cada sensor. Esta complementariedad permitió al modelo identificar linderos en condiciones donde los sensores ópticos pasivos suelen fallar debido a la nubosidad, validando el uso de datos SAR como un insumo crítico para el catastro en zonas tropicales.

El estudio identificó limitaciones y restricciones técnicas importantes. Se observó que la Banda X del radar presenta una penetración limitada en zonas de vegetación arbórea densa, lo que genera interrupciones en la continuidad de los bordes detectados. Asimismo, se reportaron errores de comisión (falsos positivos) asociados a patrones de drenaje seco que el modelo confunde con linderos físicos. Estas limitaciones sugieren que, para una implementación productiva, se requiere la integración futura de bandas de mayor longitud de onda (como la Banda L) o datos LiDAR.

Finalmente, este trabajo aporta un flujo de trabajo replicable que transita desde la teoría hacia una prueba de concepto funcional. Si bien no reemplaza la validación jurídica en campo, la herramienta

constituye un insumo técnico capaz de optimizar los tiempos de barrido predial, contribuyendo tecnológicamente a los objetivos de actualización catastral y formalización de la propiedad rural en Colombia.

5. RECOMENDACIONES

A partir de los hallazgos, se proponen las siguientes líneas de trabajo:

- Realizar una validación de campo rigurosa en diversos ecosistemas colombianos para cuantificar la exactitud posicional del modelo VGG13_bn y evaluar su capacidad de generalización.
- Investigar el uso de datos SAR en bandas de mayor longitud de onda (ej. banda L), que ofrecen una mejor penetración del dosel arbóreo, para mejorar la precisión en áreas de vegetación densa.
- Integración con Datos Jurídicos: Desarrollar flujos de trabajo híbridos que utilicen la cartografía catastral existente como una entrada para guiar o ajustar los modelos de IA, buscando cerrar la brecha entre el lindero físico y el jurídico.

RECONOCIMIENTO

Este proyecto fue adelantado en el marco del proyecto 1047 de MinCiencias, que buscaba ejecutar propuestas orientadas a fortalecer el catastro multipropósito a través de la vinculación de jóvenes investigadores e innovadores.

REFERENCIAS

- [1] C. Lemmen, J. Zevenbergen, M. Lengoiboni, K. Deininger y T. Burns, “First experiences with high resolution imagery based adjudication approach for Social Tenure Domain Model in Ethiopia”, en Proceedings of the FIG–World Bank Conference, 2009.
- [2] J. A. Richards, *Remote Sensing with Imaging Radar*. Berlin, Germany: Springer, 2009.
- [3] C. Oliver and S. Quegan, *Understanding Synthetic Aperture Radar Images*. Raleigh, NC, USA: SciTech Publishing, 2004.
- [4] B. Fetai, M. Račić, and A. Lisec, “Deep learning for detection of visible land boundaries from UAV imagery,” *Remote Sens.*, vol. 13, no. 11, art. 2077, Jun. 2021, doi: 10.3390/rs13112077.
- [5] H. Carstairs et al., “An effective method for InSAR mapping of tropical forest degradation in hilly areas,” *Remote Sens.*, vol. 14, no. 3, art. 452, Feb. 2022, doi: 10.3390/rs14030452.

- [6] A. Irfan, Y. Li, X. E, and G. Sun, “Land use and land cover classification with deep learning-based fusion of SAR and optical data,” *Remote Sens.*, vol. 17, no. 7, art. 1298, Mar. 2025, doi: 10.3390/rs17071298.
- [7] A. Kirillov et al., “Segment anything,” in *Proc. IEEE/CVF Int. Conf. Comput. Vis. (ICCV)*, 2023, pp. 4015–4026, doi: 10.1109/ICCV51070.2023.00370.
- [8] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015.
- [9] G. Vasile, E. Trouvé, J.-S. Lee, and V. Buzuloiu, “Intensity-driven adaptive-neighborhood technique for polarimetric and interferometric SAR parameters estimation,” *IEEE Trans. Geosci. Remote Sens.*, vol. 44, no. 6, pp. 1609–1621, Jun. 2006.
- [10] D. Small and A. Schubert, *Guide to ASAR Geocoding. RSL-ASAR-GC-AD*, Tech. Rep., Univ. of Zurich, 2008.
- [11] M. Schmitt and X. X. Zhu, “Data fusion and remote sensing: An ever-growing relationship,” *IEEE Geosci. Remote Sens. Mag.*, vol. 4, no. 2, pp. 6–23, Jun. 2016.
- [12] D. Comaniciu and P. Meer, “Mean shift: A robust approach toward feature space analysis,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 5, pp. 603–619, May 2002.
- [13] J. He, S. Zhang, M. Yang, Y. Shan, and T. Huang, “Bi-Directional Cascade Network for Perceptual Edge Detection,” in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2019, pp. 3828–3837.
- [14] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv:1409.1556*, 2014.
- [15] Instituto Geográfico Agustín Codazzi, Resolución n.º 471 de 2020, “Por la cual se establecen los lineamientos para la formación, actualización y conservación catastral con enfoque multipropósito en Colombia,” May 11, 2020. [Online]. Available: <https://www.igac.gov.co/transparencia-y-acceso-a-la-informacion-publica/normograma/resolucion-no-471-de-2020>
- [16] B. Fetai, M. Račić y A. Lisec, “Revising cadastral data on land boundaries using deep learning”, *ISPRS International Journal of Geo-Information*, vol. 11, n.º 5, p. 298, 2022. [En línea]. Disponible en: <https://doi.org/10.3390/ijgi11050298>
- [17] Y. Zhang, H. Liu, J. Wang, and X. Chen, “Detecting cadastral boundaries from satellite images using a U-Net model,” *Remote Sens.*, vol. 17, no. 4, art. 742, 2025.

ANEXOS

Apéndice A: mapas detallados de la extracción de potenciales linderos

A continuación, se presentan los mapas generados para cada una de las metodologías evaluadas.

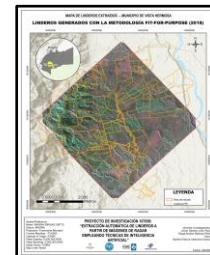


Fig. A.1. Mapa de los linderos de referencia levantados en campo mediante la metodología Fit-For-Purpose (FFP) en el año 2018. **Fuente:** Elaboración propia.

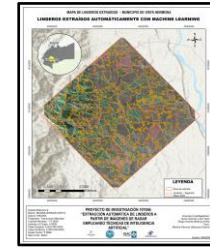


Fig. A.2. Mapa de los potenciales linderos lineales extraídos con el algoritmo de Aprendizaje Automático Segment Mean Shift. **Fuente:** Elaboración propia.

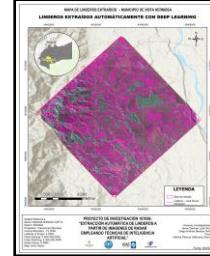


Fig. A.3. Mapa de los potenciales linderos lineales extraídos con el modelo de Aprendizaje Profundo Land Parcel Extraction (VGG13_bn). **Fuente:** Elaboración propia.

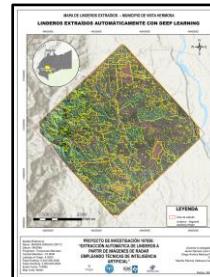


Fig. A.4. Mapa de los potenciales linderos lineales extraídos con el modelo de Aprendizaje Profundo Segment Anything Model (SAM). **Fuente:** Elaboración propia.