

Potencial de la inteligencia artificial en teledetección para el desarrollo sostenible y la gestión ambiental

Haydemar Núñez¹, Andrés Calderón³, Nicolás Díaz¹, Rocío Sierra², David Vásquez¹

¹Departamento de Ingeniería de Sistemas y Computación, Facultad de Ingeniería, Universidad de los Andes.

²Departamento de Ingeniería Química y Alimentos, Facultad de Ingeniería, Universidad de los Andes

³Department of Computer Science, University of California

1. Introducción

La teledetección ha emergido como una valiosa herramienta para la observación y comprensión de nuestro entorno terrestre a través de la captura de datos con sensores remotos. Debido a la complejidad de los procesos relacionados con esta tecnología, en los últimos años se han venido utilizando técnicas de inteligencia artificial (IA) para el análisis e interpretación de imágenes satelitales, con el fin de facilitar la generación de mapas de cobertura y uso de la tierra.

La combinación de teledetección e inteligencia artificial mejora nuestra comprensión de los cambios ambientales a escala global, regional y local, y apoya las acciones favorables al desarrollo sostenible y la gestión efectiva de recursos naturales. Utilizando imágenes satelitales y técnicas avanzadas de aprendizaje automático (*machine learning*), es posible facilitar la planificación urbana sostenible, el seguimiento de la deforestación y la desertificación, la detección de desastres naturales, la evaluación de la calidad del aire y del agua, entre otros usos, proporcionando así información crucial para la implementación efectiva de políticas respetuosas con el medio ambiente.

En este trabajo se presentan dos aplicaciones que apuntan en esta dirección. La primera, está relacionada con el uso de la biomasa residual para la estimación de potencial energético¹. En la búsqueda de soluciones energéticas sostenibles, la valorización de residuos post cosecha emerge como una estrategia clave². En la búsqueda de soluciones energéticas sostenibles, la

¹ El objetivo de desarrollo sostenible 7 (ODS 7, “Energía asequible y no contaminante”) está dirigido a garantizar el acceso a una energía asequible, fiable, sostenible y moderna para todos. Dentro de las metas específicas del ODS 7 se incluye el incremento en el uso de energías renovables, siendo la biomasa una fuente que puede ser utilizada para este propósito.

² En Colombia, según el IDEAM (2021), la mayor fuente de contaminación ambiental por emisión de gases de efecto invernadero (GEI) proviene de la actividad agrícola y pecuaria.

valorización de residuos postcosecha emerge como una estrategia clave. En muchos sectores agropecuarios, una cantidad significativa de biomasa residual, que de otra manera podría ser descartada o quemada de manera no controlada, representa un recurso hasta ahora mayormente desperdiciado. Transformar estos residuos en fuentes de energía renovable no solo ofrece una alternativa a los combustibles fósiles, sino que también refuerza la capacidad de las comunidades para enfrentar desafíos ambientales y económicos³.

La segunda aplicación está dirigida a apoyar la monitorización del crecimiento periférico de ciudades⁴. La expansión urbana descontrolada puede llevar a problemas como la congestión, la falta de vivienda adecuada, la contaminación ambiental y la segregación social. Se busca entonces apoyar un desarrollo urbano planificado y sostenible que incluya la construcción ordenada de infraestructuras y servicios básicos, la disponibilidad de viviendas seguras y asequibles, la protección del patrimonio cultural y natural, y la mejora de la calidad de vida en las urbes y sus alrededores. En este contexto, es fundamental contar con herramientas de seguimiento que permitan a los planificadores y autoridades urbanas tomar decisiones informadas basadas en datos actualizados, identificar áreas de mejora y diseñar políticas que promuevan un progreso ciudadano más equitativo, resiliente y sostenible a largo plazo.

La sección 2 del artículo está dedicada a la explicación de varios conceptos básicos sobre la teledetección e imágenes satelitales. Luego, en la sección 3, se presentan aplicaciones actuales de la IA en diferentes sectores relacionados. En la sección 4 se describe en detalle la herramienta para la estimación de potencial energético a partir de la biomasa residual en municipios de Colombia, mientras que en la sección 5 se hace lo propio con la de monitorización para el crecimiento periférico de ciudades. Para finalizar, se ofrecen reflexiones finales sobre los resultados y tópicos abordados en este trabajo.

2. Algunos conceptos sobre teledetección

³ Esta propuesta se construyó dentro del contexto de una iniciativa de la Universidad de los Andes, la Universidad de Chile y la GIZ de Alemania para generar recomendaciones para impulsar la reactivación económica de territorios vulnerables a través de la elaboración y divulgación de mapas interactivos de potencial energético solar y de biomasa. Específicamente, la construcción de los mapas interactivos se enfoca en municipios PDET seleccionados mediante la ponderación de indicadores como el rendimiento de cultivos, la irradiación solar, la informalidad laboral, la cobertura energética y de acueducto, entre otros.

⁴ El objetivo de desarrollo sostenible 11 (ODS 11: “Ciudades y comunidades sostenibles”) tiene como meta hacer que las ciudades y los asentamientos humanos sean inclusivos, seguros, resilientes y sostenibles.

La teledetección es la práctica de obtener información sobre las superficies terrestres y acuáticas de la Tierra mediante imágenes adquiridas desde una perspectiva aérea, utilizando radiación en una o más regiones del espectro electromagnético, reflejada o emitida por la superficie terrestre (Campbell, 2023). Es una herramienta muy útil para la gestión del territorio, ya que posibilita el análisis espacial de la cobertura terrestre para, por ejemplo, determinar cambios en la dinámica de la población, identificar patrones de actividades económicas, evaluar ecológicamente la naturaleza, gestionar recursos hídricos y hacer seguimiento a la deforestación (Chuvieco, 2016; Lillesand et al., 2015).

2.1. Las imágenes satelitales y sus características.

Los satélites, a través de sensores, recopilan datos en forma de imágenes que contienen información sobre la reflectancia de la luz (Campbell, 2023; Chuvieco, 2016; Lillesand et al., 2015). Estas imágenes, por lo general, tienen múltiples bandas que representan distintas longitudes de onda desde las porciones ultravioleta hasta las visibles e infrarrojas del espectro electromagnético.

Las imágenes satelitales poseen diversas características clave. La resolución espacial determina la capacidad de distinguir objetos pequeños en una imagen (expresada en metros por píxel), mientras que la resolución espectral indica la habilidad para captar diferentes longitudes de onda del espectro electromagnético. La resolución temporal refleja la frecuencia con la que un satélite puede adquirir imágenes de una zona específica. Además, los satélites de observación terrestre ofrecen cobertura global, permitiendo la captura de imágenes desde cualquier parte del mundo. Algunos satélites también utilizan información multisensorial, empleando múltiples sensores para capturar datos en diferentes espectros y resoluciones.

2.2. La misión Copernicus.

La misión Copernicus⁵ es un programa de observación de la Tierra liderado por la Unión Europea (UE) y desarrollado en colaboración con la Agencia Espacial Europea (ESA). El programa tiene como objetivo proporcionar una fuente continua de información precisa y actualizada sobre el estado del planeta. Consta de una constelación de satélites, llamados

⁵ <https://www.copernicus.eu/es/sobre-copernicus>. Fecha de acceso: 4 de julio de 2024.

Satélites de Monitoreo Ambiental (Sentinel), y una serie de servicios operativos que utilizan los datos recopilados por estos satélites. Los Sentinel están diseñados específicamente para recopilar información sobre la Tierra en una amplia gama de aspectos, como la atmósfera, los océanos y los ecosistemas terrestres.

Los satélites Sentinel, que son lanzados con diferentes capacidades y funciones, procesan y distribuyen datos de forma gratuita, fomentando así el acceso abierto a la información para fines científicos y comerciales. Entre estos está Sentinel 1, que utiliza radar de apertura sintética para obtener imágenes de la Tierra cada seis días independientemente de las condiciones meteorológicas, con una resolución espacial de cinco metros. Su dominio de medición abarca la topografía del paisaje, humedad del suelo, vegetación. Otro es Sentinel-2, que captura imágenes multispectrales con una resolución espacial de 10 metros para las bandas espectrales visibles e infrarrojas cercanas y una resolución de 20 metros para las bandas infrarrojas de onda corta, con una capacidad de revisita de 10 días. Esta multispectralidad brinda una visión integral y detallada de la superficie terrestre que permite analizar la salud de la vegetación, monitorear cambios en el uso del suelo, evaluar la calidad del agua y realizar diversas aplicaciones relacionadas con la gestión del medio ambiente y la agricultura

3. Inteligencia artificial sobre imágenes satelitales

El avance vertiginoso de la inteligencia artificial ha potenciado radicalmente la capacidad de procesamiento y extracción de información a partir de diversos datos complejos, ofreciendo posibilidades sin precedentes en una amplia gama de aplicaciones. En particular, la integración de la IA con la teledetección está abriendo nuevas vías para respaldar el desarrollo sostenible en múltiples sectores al permitir analizar, de manera eficiente y precisa, grandes cantidades de datos recopilados por satélites (Janga et al., 2023; Jeon, 2023; Li et al., 2018; Miller et al. 2024; Thapa et al., 2023). Esta capacidad de procesamiento sobre imágenes satelitales puede ser utilizada para prever cambios ambientales y evaluar el progreso hacia metas específicas de los Objetivos de Desarrollo Sostenible (ODS), proporcionando a gobiernos y organizaciones herramientas para la toma de decisiones informadas (Burke et al. 2021; Holloway et al. 2018; Ferreira et al. 2020; Persello et al. 2022). Potenciar esta capacidad ayuda a comprender y mitigar los impactos en el entorno natural,

promoviendo prácticas sostenibles que contribuyan a un avance equitativo y resiliente a largo plazo.

Por ejemplo, la conjunción de estas dos tecnologías ha posibilitado diversas aplicaciones para el sector agrícola, entre las que se pueden citar: seguimiento dinámico de los cultivos, predicción de la productividad agrícola, segmentación y clasificación de cultivos, así como la detección de enfermedades y estrés en las plantaciones (Benos et al., 2021; Teixeira et al., 2023). Además, ha facilitado una gestión óptima de la distribución de los cultivos y el aprovechamiento del suelo, entre otros usos posibles. Especialmente en la detección y monitoreo de áreas de cultivo, una tarea crítica para la gestión agrícola sostenible y la seguridad alimentaria a nivel global, las técnicas de IA han revelado un gran potencial al posibilitar la automatización de la identificación de plantaciones mediante el análisis de imágenes satelitales (Jung et al. 2021).

En el sector energético, la combinación de IA y teledetección puede apoyar en la planificación e implementación de proyectos relacionados con el uso de energías renovables (Lindahl et al. 2023; Paletta et al. 2023). En particular, ofrece posibilidades para desarrollar modelos para la estimación de biomasa residual, como residuos agrícolas o forestales, así como para identificar cambios en la distribución y cantidad de biomasa a lo largo del tiempo. Estos modelos ayudan a identificar áreas con alto potencial para la producción de biomasa y planificar estrategias de recolección y uso de manera eficiente con el fin de generar energías alternativas (Carrijo et al. 2021; Liu et al. 2024; Senocak y Guner, 2022).

En el ámbito urbano, la integración de estas dos tecnologías promete revolucionar la forma en que se diseñan, gestionan y optimizan las ciudades (Li et al. 2023). Al aprovechar técnicas de IA junto con métodos de teledetección, se tiene entonces la capacidad de detectar y rastrear cambios en el uso del suelo, como la expansión urbana, la conversión de áreas verdes o el desarrollo de infraestructuras (Kim et al. 2024; Veneri et al. 2022). Este conocimiento puede ser utilizado entonces para la construcción de herramientas para la gestión ambiental y la evaluación del impacto de actividades humanas, promoviendo así un desarrollo urbano más sostenible y resiliente (Wu et al. 2024). Además, hace posible la identificación y clasificación de elementos urbanos como edificios, carreteras, parques y cuerpos de agua, lo cual contribuiría a la evaluación de infraestructuras existentes y a la planificación de nuevas construcciones.

4. Estimación del potencial energético a partir de la biomasa residual en municipios PDET

En Colombia, los Programas de Desarrollo con Enfoque Territorial (PDET) son establecidos con el objetivo de estabilizar y transformar las zonas del territorio más afectadas por la violencia y pobreza, beneficiando 170 municipios de 19 departamentos, que constituyen el 36% del territorio nacional y el 24% de la población rural del país⁶. Teniendo en cuenta la alta proporción de población agrícola en los territorios PDET, se presenta una oportunidad para apoyar el desarrollo de estos municipios mediante la implementación de proyectos energéticos sustentables consistentes en el aprovechamiento de la biomasa residual generada después de la cosecha, lo cual, al mismo tiempo, puede contribuir a la transición energética del país mediante el aprovechamiento de residuos orgánicos⁷.

En este contexto, la propuesta se centró en la construcción de un atlas de biomasa que ofrezca información correspondiente a la generación de residuos postcosecha con enfoque en los territorios PDET, incluyendo estimaciones del potencial energético generado a partir de su aprovechamiento⁸. Como se muestra en la Figura 1, el atlas se basa en una metodología que combina técnicas de machine learning con imágenes satelitales y datos históricos de producción agrícola para la construcción de modelos de identificación de plantaciones y predicción de rendimiento de cultivos con base en el área sembrada. Estos modelos se integraron en una aplicación web que permite al usuario final interactuar con un mapa y

⁶ Agencia de Renovación del Territorio. (2021). PDET en cifras. Obtenido de https://www.renovacionterritorio.gov.co/especiales/especial_pdet/

⁷ En el contexto del potencial del país para el aprovechamiento de residuos, en un estudio realizado por el Centro de Innovación y Desarrollo Tecnológico del Sector Eléctrico (CIDET) para identificar los distintos tipos de biomasa residual disponibles para la generación de biogás, se encontró que el país posee un potencial teórico energético de 149.436TJ/año de biomasa residual agrícola, pecuaria, agroindustrial y urbana. Este potencial técnico corresponde al 26% de la demanda nacional de gas natural con respecto a datos del Balance Energético Colombiano (CIDET, 2019)

⁸ La Unidad de Planeación Minero-Energética (UPME) construyó un atlas del potencial energético de la biomasa residual proveniente de ocho cultivos promisorios, tres actividades pecuarias y dieciocho municipios como fuente de residuos sólidos urbanos en plazas de mercado, además de los generados por las podas en áreas urbanas. La información sobre áreas sembradas, ubicación de los cultivos, rendimientos y cantidades de residuos generados se obtuvo del Anuario Estadístico del Sector Agropecuario del año 2006 y de los gremios del sector como Cenipalma, Cenicaña, Cima, Cenicafé, Fedearroz, entre otros. La cantidad de biomasa residual se calculó a partir de los factores de generación de residuo, utilizando los valores promedio de la caracterización fisicoquímica de cada tipo de biomasa residual. <https://www1.upme.gov.co/siame/Paginas/atlas-del-potencial-energetico-de-la-biomasa.aspx>.

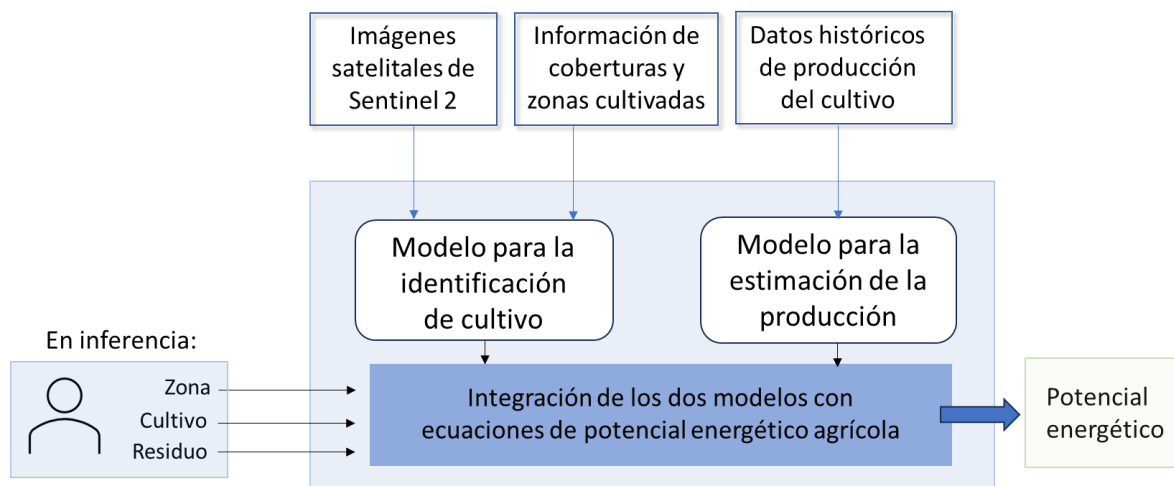


Figura 1. Metodología para la construcción del atlas de biomasa.

obtener estimaciones del potencial energético para zonas dentro de municipios PDET seleccionados.

El proceso de selección de municipios para este estudio se basó en dos criterios principales: la clasificación como PDET y la exclusión de zonas protegidas. Se emplearon 11 indicadores socioeconómicos y físicos para comparar y seleccionar los municipios: cobertura de acueducto, cobertura de energía eléctrica, rendimiento de cultivos, tasa de deserción estudiantil, índice de informalidad, casos positivos de COVID-19, casos de muertes por COVID-19, biomasa sobre el suelo, índice de vegetación NDVI, porcentaje de nubosidad e irradiación solar⁹. El método utilizado fue un proceso multicriterio con lógica difusa que permitió generar un índice de potencialidad por municipio, destacando valores promedio para los departamentos de Putumayo (0.38), Cesar (0.373) y Bolívar (0.363). Finalmente, tras considerar factores como la extensión de área cultivada y áreas protegidas, se seleccionaron como zonas de estudio los 21 municipios PDET de los departamentos de Bolívar y Cesar.

Para la prueba de concepto se trabajó con palma de aceite, pero la metodología es aplicable a cualquier tipo de cultivo. A continuación, se explican los pasos seguidos para la

⁹ Los índices socioeconómicos fueron tomados de fuentes oficiales como Terridata (<https://terridata.dnp.gov.co/>), UPME (<https://www1.upme.gov.co/>) y Portal de Datos Abiertos de Colombia (<https://www.datos.gov.co/>). Los físicos fueron recolectados a través de portales como Copernicus Global Land Service.

construcción de estos dos modelos y se presenta una visión general de la aplicación desarrollada.

4.1. Construcción del modelo de identificación de cultivos.

A través del portal de datos abiertos de Copernicus se realizó la descarga de las imágenes de Sentinel-2 que cubren los municipios seleccionados de los departamentos Del Cesar y Bolívar, empleando para ello información de coordenadas y rango de fechas (años 2018 y 2020). Para la identificación de áreas de cultivos de palma de aceite se utilizó el Mapa de Coberturas de la Tierra, desarrollado por el Instituto de Hidrología, Meteorología y Estudios Ambientales¹⁰. También se utilizaron polígonos suministrados por el Instituto Geográfico Agustín Codazzi (IGAC) sobre la zona de estudio. Además, fueron construidos polígonos asociados a otras coberturas para las siguientes cuatro clases: suelo desnudo, naturaleza, ciudad (zona urbana) y cuerpos de agua. A tal efecto, se utilizó la herramienta de creación de polígonos provista por el programa QGIS¹¹.

Para poder aplicar los algoritmos de aprendizaje es necesario obtener una representación estructurada a partir de las imágenes satelitales. Esta representación es una matriz o tabla de dos dimensiones, en la cual cada banda representará un atributo (columna) y cada pixel será una fila (registro), caracterizada por los valores de las diferentes bandas. Además, será necesario atribuir a cada pixel su clase (tipo de cobertura), que será una columna adicional. Para transformar los valores de bandas de los polígonos a un formato tabular se construyó un script en el lenguaje de programación Python con apoyo de la librería GDAL¹², el cual extrae la información de cada píxel en cada una de las bandas.

Una vez obtenida la tabla (conjunto de datos para el aprendizaje) se realizaron los pasos de limpieza e ingeniería de características. El primero consistió en la eliminación de registros duplicados, nulos y con valores en cero para alguna de las bandas. En el segundo, se

¹⁰ El mapa contiene la clasificación de más de 130 clases diferentes de coberturas, entre las que se describen y caracterizan territorios como centros urbanos, zonas industriales, zonas mineras, territorios agrícolas, áreas con pastos para ganadería, áreas de bosques, llanuras, pantanos y cuerpos de agua. Dentro de las clases de cobertura disponibles, se tienen algunas específicas para diversos cultivos presentes en el país, en particular, existe una clase dedicada a la palma de aceite. Fue realizado en 2018 y puede ser accedido desde: <https://visualizador.ideam.gov.co/geonetwork/srv/spa/catalog.search#/metadata/285c4d0a-6924-42c6-b4d4-6aef2c1aceb5>

¹¹ <https://www.qgis.org/es/site/>

¹² <https://gdal.org/index.html>

añadieron dos capas adicionales (variables) relacionadas con un modelo digital de elevación (DEM) de la zona de estudio y la pendiente (SLOPE), que representa la tasa de cambio de elevación para cada celda del modelo digital de elevación. Para esta tarea se descargó el ALOS PALSAR DEM, recurso cartográfico disponible dentro de los productos del satélite ALOS¹³. Por último, se hizo un análisis de la firma espectral de todas las coberturas. Con base en el comportamiento observado se decidió aplicar un filtro para depurar las anomalías al interior de cada una de las clases.

El modelado se hizo XGBoost¹⁴, el cual es un algoritmo de aprendizaje basado en una combinación de clasificadores. Se realizó una búsqueda de hiperparámetros con un conjunto de validación (20% de los datos) sobre las métricas de desempeño sensibilidad o *recall*, la precisión y el F1-Score, calculadas para cada una de las clases y para el desempeño general de los modelos¹⁵. En general, se observó una exactitud promedio por encima de 0.9. La Figura 2 muestra las clasificaciones hechas por el modelo sobre una zona no utilizada durante el aprendizaje.

4.2. Construcción del modelo de predicción de rendimiento agrícola.

Para la construcción del modelo se utilizaron datos pertenecientes a las Evaluaciones Agropecuarias (EVA) realizadas por la Unidad de Planificación Rural Agropecuaria (UPRA) para el periodo 2006-2021¹⁶. Este conjunto de datos contiene 271801 registros y 17 columnas, entre las que se encuentra información sobre el área sembrada, área cosechada,

¹³ El Satélite Avanzado de Observación Terrestre (ALOS), también conocido como DAICHI, fue una misión satelital japonesa que operó de 2006 a 2011. Llevaba tres instrumentos, incluido el radar de apertura sintética de banda L tipo Phased Array (PALSAR), que se utilizó para obtener observaciones detalladas de la superficie de la Tierra, de día y de noche, en cualquier condición meteorológica. Los datos PALSAR podrían adquirirse en múltiples modos, con diferentes polarizaciones, resoluciones, anchos de franja y ángulos fuera del nadir lo que lo constituía como una herramienta adecuada para la generación de modelos digitales de elevación. PALSAR se utilizó para una variedad de aplicaciones, incluida la cartografía, la observación precisa de la cobertura del suelo a escala regional, el monitoreo de desastres y el estudio de recursos. Fue una herramienta valiosa para científicos e investigadores, y sus datos siguen utilizándose para diversos fines en la actualidad. (<https://asf.alaska.edu/data-sets/sar-data-sets/alos-palsar/alos-palsar-about/>)

¹⁴ <https://xgboost.readthedocs.io/en/stable/>

¹⁵ *Recall*: representa la proporción de datos de la clase que se clasificaron correctamente. Precisión: indica cuantos datos clasificados como de una clase realmente pertenecen a esta. F1-score: proporciona la media geométrica de estas dos medidas.

¹⁶ <https://upra.gov.co/es-co/Paginas/eva.aspx>



Figura 2. Clasificaciones realizadas por el modelo XGBoost. La segunda imagen muestra delimitadas las plantaciones de palma de aceite para la primera imagen. En la tercera se puede observar las zonas, en verde oscuro, que el modelo identifica como plantaciones de palma de aceite.

producción y rendimiento por municipio, cultivo y periodo. El conjunto de datos fue filtrado para obtener información del cultivo de palma de aceite y se obtuvieron 1796 registros separados en 21 departamentos, con los dos departamentos de interés entre los tres primeros con mayor número de registros. A nivel de municipio, el conjunto contiene información del cultivo de palma de aceite para 23 municipios del Cesar y para 18 municipios del Bolívar.

Se decidió realizar el entrenamiento de un único modelo con regresión lineal (Gerón, 2022), con una variable descriptora (el área sembrada) y una variable objetivo (la producción), evitando separar los datos de acuerdo con variables temporales como el año y el periodo, y variables espaciales como el municipio. En ese sentido, se construyó un conjunto de entrenamiento con el 80% de los ejemplos (1436 registros) y un conjunto de pruebas con el 20% restante (360 registros). Para evaluar el modelo se utilizaron métricas como el coeficiente de determinación o R^2 y la raíz del error cuadrático medio (RMSE), obteniendo valores de 0.87 para el primero y 7293.25 para el segundo.

3.3. Atlas de biomasa

La vista general de la herramienta desarrollada muestra un mapa interactivo en el que se pueden observar los puntos clasificados utilizando el modelo XGBoost. Dentro de la grilla, el usuario puede dibujar un polígono y obtener información general como la latitud, longitud y ubicación, así como información histórica de producción para el municipio al que pertenece la zona seleccionada (Figura 3). Adicionalmente, se utiliza la resolución de píxel de la imagen

para estimar el área del cultivo en la zona, obteniendo el número de píxeles de palma dentro del polígono y transformando el valor resultante a hectáreas. Con este valor se realiza el estimado de la producción con el modelo de regresión. Para la estimación del potencial se utilizan ecuaciones de potencial energético para la palma de aceite (Onochie et al. 2015), que permiten el cálculo de energía dependiendo del tipo de residuo.

The interface is divided into two main sections: a data entry form on the left and a satellite map on the right.

Form Section:

- PRODUCCIÓN / GENERACIÓN:**
 - Ubicación:**
 - CULTIVO: Palma de aceite
 - UBICACIÓN: Agustín Codazzi, Cesar
 - LATITUD: 9.88°
 - LONGITUD: -73.39°
 - Variables estimadas:**
 - ÁREA: 205 ha
 - PRODUCCIÓN: 466.06t
 - Potencial energético:**

<input type="checkbox"/>	Tipo de residuo	Porcentaje de masa [%]	Humedad [%]
<input type="checkbox"/>	Racimo vacío	20.00	29.00
<input checked="" type="checkbox"/>	Fibra	13.00	14.00
<input checked="" type="checkbox"/>	Cáscara	6.00	6.00

ESTIMAR GENERACIÓN

POTENCIA: 382.392 MWh

Map Section: A satellite map showing a large area of land with a green polygon highlighting a specific cultivation zone. Labels on the map include 'Sitarara' and 'Sabanas de Cúcuta'.

Figura 3. Vista general de la interfaz de la aplicación desarrollada.

4. Identificación del crecimiento periférico de ciudades

El catastro es un registro público que documenta las propiedades y características físicas de los bienes inmuebles dentro de un área geográfica específica. Es crucial mantenerlo actualizado porque proporciona información precisa y detallada sobre la propiedad y el uso del suelo, facilitando la gestión adecuada de recursos, como agua y energía, la integración de áreas verdes y espacios públicos, y la provisión de servicios básicos de manera equitativa. Además, ayuda a prevenir conflictos relacionados con la tenencia de la tierra y apoya la gestión de riesgos asociados con desastres naturales, promoviendo así ciudades más resilientes y sostenibles en el largo plazo.

Los procesos de actualización catastral se componen en gran parte por trabajos manuales que se tornan costosos, debido al tiempo de revisión que toma buscar los cambios temporales en la cobertura del suelo para áreas muy extensas como lo son las principales ciudades. Una vía

para apoyar este proceso es a través del desarrollo de herramientas que faciliten la identificación de cambios en la cobertura de las ciudades, permitiendo a los tomadores de decisiones implementar acciones de manera oportuna, con base en analítica espacial del crecimiento de zonas urbanas.

El objetivo principal de este trabajo fue desarrollar una aplicación para facilitar la detección de cambios en la cobertura urbana y uso del suelo. Este proceso se llevó a cabo mediante el análisis de imágenes de radar multitemporales proporcionadas por Sentinel 1, aprovechando técnicas de aprendizaje profundo (*deep learning*). Como se muestra en la Figura 4, la herramienta se basa en una red neuronal convolucional (CNN) que permite segmentar imágenes de radar asociadas a tres períodos consecutivos (T1, T2 y T3) para detectar cambios en la cobertura a través del tiempo, utilizando para su implementación tecnologías de nube.

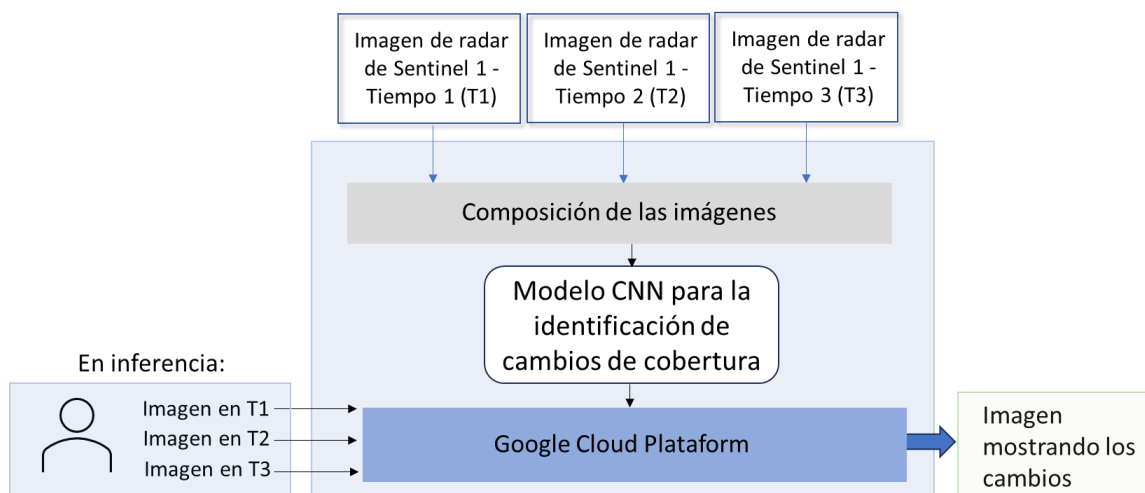


Figura 4. Diagrama general de la herramienta de detección de cambios en zonas urbanas.

5.1. Construcción del modelo de identificación de cambios de cobertura

La metodología utilizada en este trabajo se basa en la propuesta realizada por Gruenhagen y Juergens (2022). Este estudio utilizó imágenes de radar de Sentinel-1 para analizar cambios en la cobertura del suelo, como la demolición y construcción de edificios. Para visualizar la dinámica espacial en la cobertura terrestre se asignan las imágenes ordenadas cronológicamente (T1, T2 y T3) a los tres colores primarios rojo, verde y azul y se superponen en una imagen utilizando la mezcla aditiva de colores. Los cambios en la ocupación del suelo entre los tres puntos temporales se revelan en el color mixto respectivo de los colores primarios implicados (ver Figura 5). Si se construyen o derriban edificios, estos

cambios de la cubierta terrestre se muestran en el color correspondiente al período de tiempo, lo que permite un registro muy preciso del cambio de la cubierta terrestre. Las zonas en las que no se producen cambios en la ocupación del suelo se muestran en tonos blancos o grises.

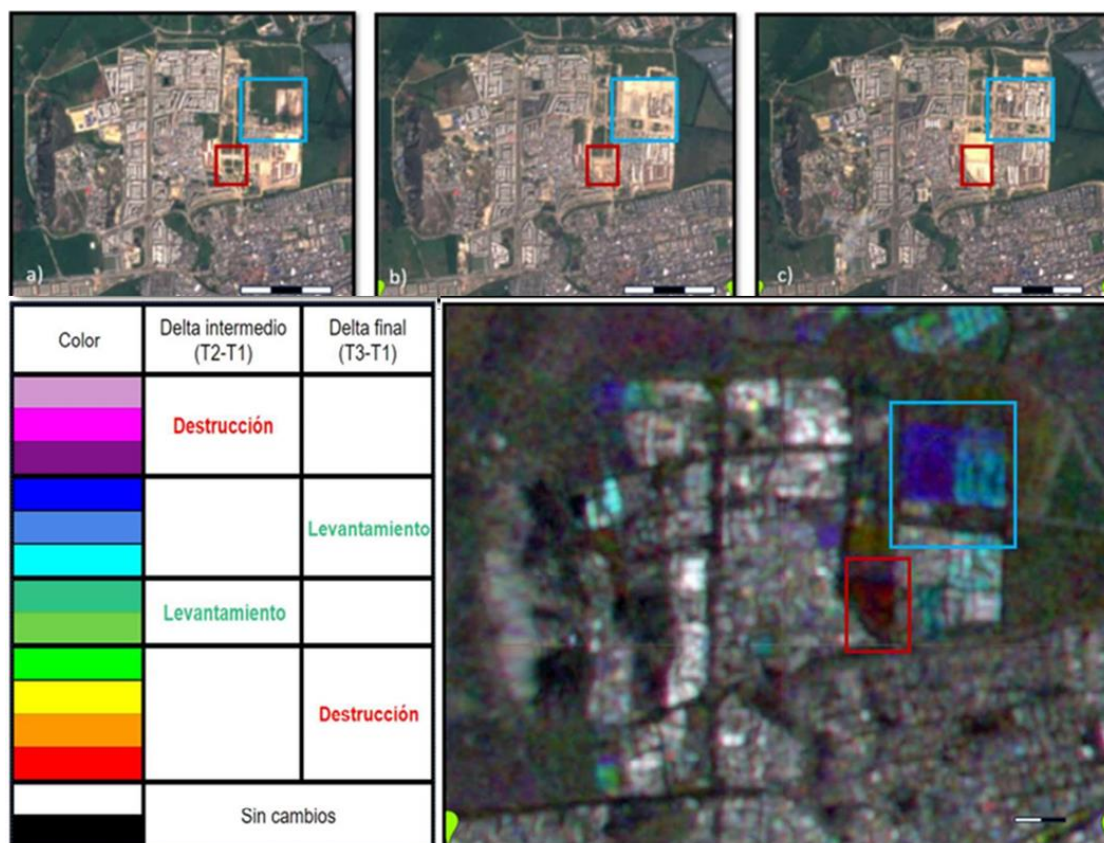


Figura 5. Se presentan imágenes ópticas correspondientes a Soacha en T1 (a) T2 (b) y T3 (c), así como la composición final de tres canales representando los cambios en una escala de color RGB. Se observa que la composición es fiel a los cambios de los nuevos conjuntos residenciales construidos en la zona noroccidental. (T1 corresponde a los primeros tres meses del 2019, T2 y T3 a 2020 y 2021, respectivamente). Al lado izquierdo se presenta la leyenda de la creación de la imagen multitemporal, con su interpretación.

Para construir el conjunto de aprendizaje se descargaron imágenes de Sentinel 1 para los períodos 2019, 2020 y 2021, sobre las ciudades que fueron seleccionadas para el estudio (Barranquilla, Cali y Santiago de Chile) durante los tres primeros meses para cada T. Esto se realiza con el objetivo de tener un promedio que represente la textura real de uso del suelo y no registros momentáneos como lo pueden ser contenedores en zonas de desembarque marítimo o parqueaderos de vehículo, entre otros. Posteriormente, se construyeron polígonos de las zonas que comprenden la categoría de cambios del uso del suelo en la imagen

multitemporal utilizando la herramienta de edición de Google Earth Engine¹⁷ (GEE) Por último, las imágenes se dividieron en *patches* de 512x512 píxeles, con sus respectivas máscaras (anotaciones) realizadas manualmente con GEE, obteniendo un total de 161, de los cuales el 12% se destinó para validación. El test se diseñó en dos fases, la primera sobre un conjunto de 13 *patches* correspondientes a Santa Marta y Cartagena, los cuales tienen las anotaciones manuales correspondientes. Posteriormente, para la segunda fase, se realizaron 20 inferencias sobre todo Bogotá sin anotaciones manuales y solo visuales, comparadas con la construcción de la imagen de radar multitemporal de los años 2019, 2020 y 2021.

Para el modelado se utilizó una arquitectura tipo U-net, la cual es una red neuronal convolucional diseñada para tareas de segmentación semántica de imágenes¹⁸. Se caracteriza por una estructura codificador-decodificador en forma de "U", de ahí su nombre. Se destaca por su capacidad para realizar una segmentación precisa de imágenes que captura tanto información detallada como contextual a diferentes escalas. Para realzar sus capacidades, se substituyó el codificador por la implementación VGG16¹⁹ de la librería Keras²⁰. Luego, se realizó el entrenamiento con muestras de validación y búsqueda de hiperparámetros que permitieron ajustar la red al conjunto de datos. La plataforma utilizada para la construcción y validación del modelo fue Vertex AI²¹, de Google Cloud. La exactitud, así como la pérdida (*loss*) sobre los conjuntos de entrenamiento y la validación, fueron las métricas de referencia para el ajuste de la red. Con base en el conjunto de validación se obtuvo un promedio de la exactitud (*accuracy*) de 0.92%.

La Figura 6 muestra nuevas inferencias del modelo sobre Bogotá, la ciudad de mayor población y crecimiento urbano en Colombia. La inferencia sobre Bogotá muestra una buena diferenciación con respecto a las zonas urbanas que mantienen colores blancos y grises,

¹⁷ <https://earthengine.google.com/>

¹⁸ La segmentación semántica de imágenes es una técnica en el campo de la visión por computadora que consiste en asignar a cada píxel de una imagen una etiqueta que identifique el objeto al que pertenece.

¹⁹ VGG16 es una red neuronal convolucional propuesta por K. Simonyan y A. Zisserman, de la Universidad de Oxford, y adquirió notoriedad al ganar el Desafío de Reconocimiento Visual a Gran Escala de ImageNet (ILSVRC) en 2014. El modelo alcanzó una precisión del 92,7% en ImageNet, que es una de las puntuaciones más altas logradas. Supone una mejora respecto a los modelos anteriores al proponer núcleos de convolución más pequeños (3x3) en las capas de convolución de lo que se había hecho anteriormente

²⁰ <https://keras.io/>

²¹ Vertex AI es una plataforma que permite a los usuarios entrenar, implementar y administrar modelos de machine learning (ML). Ofrece una gama de herramientas y servicios para ayudar a los usuarios a crear, entrenar y desplegar modelos de ML de forma rápida y eficiente

correspondientes a coberturas permanentes a lo largo del periodo de estudio. Por el contrario, la máscara resultante, que identifica cambios en la imagen de radar, deja al descubierto las zonas donde hay presencia de destrucción y construcción de nueva infraestructura, ya sea vial, residencial o industrial.



Figura 6. Inferencia de prueba sobre una imagen multitemporal del 2019-2020-2021 en Bogotá. Datos que no fueron incluidos en el entrenamiento. a) corresponde a la predicción del modelo, b) corresponde a la imagen de radar multitemporal, y c) corresponde a la superposición de las imágenes.

5.1. Implementación de la aplicación

El prototipo de la aplicación se realizó sobre Google Earth Engine, en el módulo de desarrollo de aplicaciones, el cual está diseñado y orientado al despliegue rápido y sencillo de soluciones de prototipado. Este le permite al usuario final la selección de la zona de estudio, visualización de todos los datos que componen la imagen multitemporal de cambios, y cálculo del resultado de la segmentación de la zona donde se desean evidenciar el uso de suelo (Figura 7).

6. Comentarios finales

Una estrategia para apoyar el desarrollo de zonas vulnerables es la implementación de proyectos sustentables con base en el aprovechamiento energético de la biomasa residual generada por la cosecha. El atlas de biomasa residual agrícola abre caminos en este sentido, al ser una herramienta que permite hacer una estimación del potencial energético para una zona y tipo de cultivo. El aprovechamiento de este recurso promueve la producción de energía limpia y renovable, lo cual no solo contribuye a la seguridad energética local, sino que también reduce las emisiones de gases de efecto invernadero y fomenta prácticas agrícolas más eficientes y amigables con el ambiente. Así, se establece un modelo para un

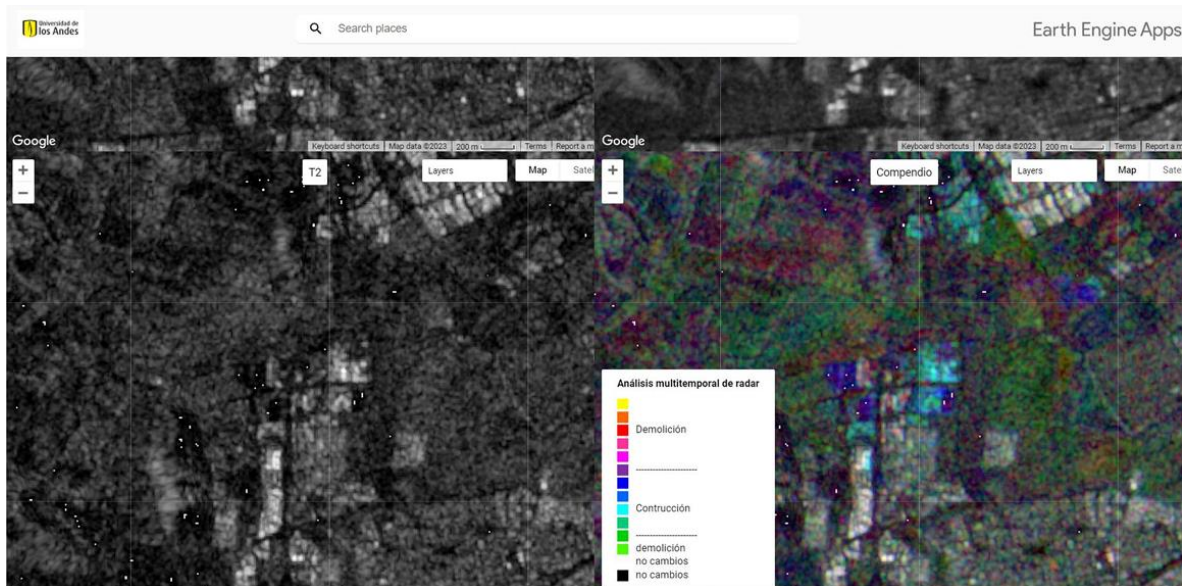


Figura 7. Multi mapa para la visualización de resultados y selección de datos a segmentar. A través de esta interfaz el usuario visualizar los resultados de la segmentación y la mascará binaria de los cambios de uso del suelo en la zona de estudio.

desarrollo rural sustentable que equilibra las necesidades económicas con la conservación del entorno natural.

Por su parte, la herramienta para la detección de cambios de cobertura en zonas urbanas representa un aporte significativo para lograr una expansión sostenible en este ámbito. Al identificar de manera precisa y oportuna los cambios en el entorno urbano, se pueden tomar decisiones informadas que promuevan la planificación responsable, la conservación de recursos naturales, la mejora de la calidad de vida de los habitantes y la reducción de impactos ambientales negativos, fortaleciendo el compromiso con un desarrollo sustentable y resiliente a largo plazo.

Un desafío importante que conlleva el uso de técnicas de IA es la disponibilidad de datos anotados, lo cual es crucial para entrenar modelos de *machine learning* y *deep learning* de manera efectiva. Una manera de solventar este problema es mediante el uso de modelos pre-entrenados, conocidos como modelos fundacionales, que puedan transferir conocimiento aprendido a tareas específicas. Además, la aplicación de modelos generativos para la creación de datos sintéticos podría ser una estrategia prometedora para mitigar la escasez de datos anotados, permitiendo la expansión y diversificación del conjunto de datos disponible para el aprendizaje. Estas líneas de investigación podrían mejorar la robustez y eficiencia de los

modelos, así como abrir nuevas posibilidades para la aplicación de técnicas avanzadas de inteligencia artificial en el análisis de imágenes satelitales.

La integración de la inteligencia artificial con la teledetección encierra un inmenso potencial para abordar los retos que conlleva un desarrollo sostenible y una gestión ambiental efectivos. Para avanzar, es fundamental establecer marcos regulatorios claros y éticamente sólidos que guíen el desarrollo y despliegue de sistemas de inteligencia artificial en contextos de teledetección. Se debe fomentar la investigación en métodos que aseguren la interpretación y explicación de los resultados obtenidos por los modelos de IA, facilitando así la confianza y aceptación de estas tecnologías por las comunidades y entes comprometidos con el desarrollo de este tipo de proyectos. Además, la colaboración con diversas partes interesadas y la consulta pública son fundamentales para asegurar que estas tecnologías se implementen en beneficio de la sociedad en su conjunto.

Finalmente, es necesario recordar que si bien el binomio IA-teledetección alimenta grandes expectativas para favorecer la generación de energía verde y una expansión urbana con mayores garantías de calidad de vida para las personas y un acotado impacto ambiental, también es imperativo abordar, de manera activa y responsable, los riesgos para el ambiente natural asociados con su implementación y uso. Esto garantizará que los beneficios de la IA puedan ser maximizados sin comprometer los objetivos de conservación ambiental y sostenibilidad a largo plazo.

Referencias

Benos, L., Tagarakis, A.C., Dolias, G., Berruto, R., Kateris, D., Bochtis, D. (2021). Machine Learning in Agriculture: A Comprehensive Updated Review. *Sensors*, 21, 3758. <https://doi.org/10.3390/s211137>.

Burke, M., Driscoll, A., Lobell, D., Ermon, S. (2021). Using satellite imagery to understand and promote sustainable development. *Science*. 371(6535):eabe8628. doi: 10.1126/science.abe8628.

Campbell, J. (2023). *Introduction to remote sensing*. Sixth edition. The Guilford Press.

Carrijo, J., Miguel, E., Teixeira Do Vale, A., Matricardi, E., Monteiro, T., Rezende, A., Inkotte, J. (2020). Artificial intelligence associated with satellite data in predicting energy

potential in the Brazilian savanna woodland area. *iForest* 13:48-55. doi: 10.3832/ifor3209-012.

CIDET. (2019). Disponibilidad de biomasa residual y su potencial para la producción de Biogas en Colombia. *Revista del Centro de Innovación y Desarrollo Tecnológico del Sector Eléctrico*. Número 19. pp. 16. <http://revista.cidet.org.co/revistas/revista-19/>.

Chuvieco, E. (2016). *Fundamentals of Satellite Remote Sensing. An Environmental Approach*, Second Edition. CRC Press.

Ferreira, B., Iten, M., Silva, R. (2020). Monitoring sustainable development by means of earth observation data and machine learning: a review. *Environmental Sciences Europe*, 32(120). <https://doi.org/10.1186/s12302-020-00397-4>.

Geron, A. (2022). *Hands-On Machine Learning with Scikit-Learn and TensorFlow. Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media.

Gruenhagen, L, Juergens, C. (2022). Multitemporal Change Detection Analysis in an Urbanized Environment Based upon Sentinel-1 Data. *Remote Sensing*. 14(1043). <https://doi.org/10.3390/rs14041043>.

Holloway, J., Mengersen, K. (2028). Statistical Machine Learning Methods and Remote Sensing for Sustainable Development Goals: A Review. *Remote Sensing*. 10(9):1365 <https://doi.org/10.3390/rs10091365>.

IDEAM, Fundación Natura, PNUD, MADS, DNP, CANCELLEÍA (2021). Tercer Informe Bienal de Actualización de Colombia a la Convención Marco de las Naciones Unidas para el Cambio Climático (CMNUCC). IDEAM, Fundación Natura, PNUD, MADS, DNP, CANCELLEÍA, FMAM. Bogotá D.C., Colombia.

Janga, B., Asamani, G.P., Sun, Z., Cristea, N. (2023). A Review of Practical AI for Remote Sensing in Earth Sciences. *Remote Sensing*. 15(16):4112. <https://doi.org/10.3390/rs15164112>.

Jeon, G. (2023). Advanced Machine Learning and Deep Learning Approaches for Remote Sensing. *Remote Sensing*. 15(11):2876. <https://doi.org/10.3390/rs15112876>.

Jung, J., Maeda, M., Chang, A., Bhandari, M., Ashapure, A., Landivar-Bowles, J. (2021). The potential of remote sensing and artificial intelligence as tools to improve the resilience

of agriculture production systems. *Current Opinion in Biotechnology*. 70:15-22. doi: 10.1016/j.copbio.2020.09.003.

Kim, J., Kim, D., Jun, H-J., Heo, J-P. (2024). The detection of residential developments in urban areas: Exploring the potentials of deep-learning algorithms, *Computers, Environment and Urban Systems*. 107(102053). <https://doi.org/10.1016/j.compenvurbsys.2023.102053>.

Li, F., Yigitcanlar, T., Nepal, M., Nguyen, K., Dur, K. (2023). Machine learning and remote sensing integration for leveraging urban sustainability: A review and framework, *Sustainable Cities and Society*. 96(104653). <https://doi.org/10.1016/j.scs.2023.104653>.

Li, Y., Zhang, H., Xue, X., Jiang, Y., Shen, Q. (2018). Deep learning for remote sensing image classification: A survey. *WIREs Data Mining and Knowledge Discovery*. 8(6). <https://doi.org/10.1002/widm.1264>.

Lillesand, T., Kiefer, R., Chipman, J. (2015). *Remote Sensing and Image Interpretation*. Wiley.

Lindahl, J., Johansson, R., Lingfors, D. (2023). Mapping of decentralised photovoltaic and solar thermal systems by remote sensing aerial imagery and deep machine learning for statistic generation. *Energy and AI*. 14, 100300. <https://doi.org/10.1016/j.egyai.2023.100300>

Liu, H., Mou, C., Yuan, J., Chen, Z., Zhong, L., Cui, X. (2024). Estimating Urban Forests Biomass with LiDAR by Using Deep Learning Foundation Models. *Remote Sensing*. 16(9):1643. <https://doi.org/10.3390/rs16091643>

Miller, L., Pelletier, G., Webb, G. (2024). Deep Learning for Satellite Image Time-Series Analysis: A review. *IEEE Geoscience and Remote Sensing Magazine*. 99:2-45. <https://doi.org/10.1109/MGRS.2024.3393010>.

Onochie, Paul., Itoje, John., Itabor, N., Akhator, P., Ojariafe, G. (2015). Calorific Value of Palm Oil Residues for Energy Utilisation. *International Journal of Engineering Innovation & Research*. 4(4): 664-667. ISSN : 2277 – 5668.

Paletta, Q., Terrén-Serrano, G., Nie, Y., Li, B., Bieker, J., Zhang, W., Dubus, L., Dev, S., Feng, C. (2023). Advances in solar forecasting: Computer vision with deep learning. *Advances in Applied Energy*. 11, 100150. <https://doi.org/10.1016/j.adapen.2023.100150>.

Persello, C., Wegner, J., Hänsch, R., Tuia, D., Ghamisi, P., Koeva, M., Camps-Valls, G. (2022). Deep Learning and Earth Observation to Support the Sustainable Development

Goals: Current approaches, open challenges, and future opportunities. *IEEE Geoscience and Remote Sensing Magazine*. 10(2):172-200. doi: 10.1109/MGRS.2021.3136100.

Senocak, A., Guner, H. (2022). Forecasting the biomass-based energy potential using artificial intelligence and geographic information systems: A case study. *Engineering Science and Technology an International Journal* 26(5). <https://doi.org/10.1016/j.jestch.2021.04.011>

Teixeira, I., Morais, R., Sousa, J., Cunha, A. (2023). Deep Learning Models for the Classification of Crops in Aerial Imagery: A Review. *Agriculture*. Special Issue "Computer Vision for Intelligent Crop Identification and Crop Protection". 13(5), 965; <https://doi.org/10.3390/agriculture13050965>.

Thapa, A., Horanont, T., Neupane, B., Aryal, J. (2023). Deep Learning for Remote Sensing Image Scene Classification: A Review and Meta-Analysis. *Remote Sensing*. 15(19), 4804; <https://doi.org/10.3390/rs15194804>.

Veneri, P., Banquet, A., Delbouve, P., Daams, M. (2022). Monitoring land use in cities using satellite imagery and deep learning. *OECD Regional Development Papers*. Vol. 28. OECD. <https://doi.org/10.1787/dc8e85d5-en>.

Wu, P., Zhang, Z., Peng, X. (2024). Deep learning solutions for smart city challenges in urban development. *Scientific Reports*. 14(5176). <https://doi.org/10.1038/s41598-024-55928-3>