

UNIVERSIDAD DEL VALLE DE GUATEMALA  
Facultad de Ingeniería



**Sistema automatizado de identificación de botaderos a cielo  
abierto mediante procesamiento de imágenes satelitales  
multiespectrales de Guatemala**

Trabajo de graduación presentado por Adrian Fulladolsa Palma para  
optar al grado académico de Licenciado en Ingeniería en Ciencias de la  
Computación y Tecnologías de la Información

Guatemala,

2025



UNIVERSIDAD DEL VALLE DE GUATEMALA  
Facultad de Ingeniería




**Sistema automatizado de identificación de botaderos a cielo  
abierto mediante procesamiento de imágenes satelitales  
multiespectrales de Guatemala**

Trabajo de graduación presentado por Adrian Fulladolsa Palma para  
optar al grado académico de Licenciado en Ingeniería en Ciencias de la  
Computación y Tecnologías de la Información

Guatemala,

2025

Vo.Bo.:




(f) \_\_\_\_\_  
M. SC. Diego Incer Núñez

Tribunal Examinador:



(f) \_\_\_\_\_  
M. SC. Diego Incer Núñez



(f) \_\_\_\_\_  
PhD. Gabriel Barrientos

Fecha de aprobación: Guatemala, noviembre de 2025.

<b>Lista de figuras</b>	<b>VI</b>
<b>Lista de cuadros</b>	<b>VII</b>
<b>Resumen</b>	<b>VIII</b>
<b>Abstract</b>	<b>IX</b>
<b>1. Introducción</b>	<b>1</b>
<b>2. Justificación</b>	<b>3</b>
<b>3. Objetivos</b>	<b>5</b>
3.1. Objetivo general . . . . .	5
3.2. Objetivos específicos . . . . .	5
<b>4. Alcance</b>	<b>6</b>
4.1. Alcance del sistema . . . . .	6
4.2. Fuera de alcance . . . . .	6
4.3. Supuestos y dependencias de uso . . . . .	7
4.4. Entregables . . . . .	7
4.5. Limitaciones y criterios de confidencialidad . . . . .	7
<b>5. Marco teórico</b>	<b>9</b>
5.1. Gestión de residuos y botaderos a cielo abierto . . . . .	9
5.1.1. Definición y marco normativo en Guatemala . . . . .	9
5.1.2. Características y problemáticas de los botaderos a cielo abierto . . . . .	10
5.1.3. Efectos sobre la salud pública . . . . .	10
5.1.4. Limitaciones de los métodos tradicionales de monitoreo . . . . .	10
5.2. Modelos de inteligencia artificial aplicados al análisis ambiental . . . . .	11
5.2.1. Aprendizaje automático y aprendizaje profundo . . . . .	11
5.2.2. Redes neuronales convolucionales (CNN) . . . . .	11
5.2.3. Red de pirámides de características (FPN) . . . . .	12

5.2.4.	Modelos de fusión multimodal y redes densas . . . . .	12
5.2.5.	Aprendizaje por transferencia en contextos locales . . . . .	13
5.2.6.	Métricas de evaluación de modelos de clasificación . . . . .	13
5.3.	Teledetección y análisis de imágenes satelitales . . . . .	14
5.3.1.	Principios de la teledetección . . . . .	14
5.3.2.	Aplicaciones de la teledetección en gestión de residuos . . . . .	15
5.3.3.	Conjuntos de datos para detección de botaderos a cielo abierto . . . . .	16
5.3.4.	Experiencias regionales y contexto guatemalteco . . . . .	16
5.4.	Integración de información atmosférica en teledetección . . . . .	17
5.4.1.	Importancia de los contaminantes atmosféricos como indicadores in- directos . . . . .	17
5.4.2.	Fuentes de datos atmosféricos satelitales . . . . .	18
5.4.3.	Integración de datos satelitales y atmosféricos en modelos de IA . . . . .	18
5.4.4.	Contenerización y despliegue con <i>Docker</i> . . . . .	18
<b>6.</b>	<b>Metodología</b>	<b>20</b>
6.1.	Integración de datos de imágenes satelitales y métricas atmosféricas . . . . .	20
6.1.1.	Sitios de referencia y generación de muestras negativas . . . . .	20
6.1.2.	Adquisición de imágenes satelitales . . . . .	21
6.1.3.	Recolección de datos atmosféricos . . . . .	21
6.1.4.	Ensamblado del conjunto de datos y partición . . . . .	21
6.1.5.	Preprocesamiento . . . . .	22
6.2.	Algoritmo de estimación de probabilidad de botadero a cielo abierto . . . . .	22
6.2.1.	Rama visual basada en arquitectura ResNet50-FPN . . . . .	22
6.2.2.	Rama atmosférica . . . . .	22
6.2.3.	Red de fusión multimodal . . . . .	22
6.2.4.	Proceso de entrenamiento y evaluación . . . . .	22
6.3.	Contenerización y servicio de inferencia . . . . .	23
6.4.	Reproducibilidad y consideraciones éticas . . . . .	24
<b>7.</b>	<b>Resultados</b>	<b>25</b>
7.1.	Resultados de la integración de datos de imágenes satelitales y métricas at- mosféricas . . . . .	25
7.2.	Análisis exploratorio de las métricas atmosféricas . . . . .	26
7.2.1.	Distribución de las variables atmosféricas . . . . .	26
7.3.	Resultados del algoritmo de estimación de probabilidad de botadero a cielo abierto . . . . .	28
7.3.1.	Desempeño del modelo base (visual) . . . . .	28
7.3.2.	Desempeño del modelo final (multimodal) . . . . .	29
7.3.3.	Distribución de probabilidades de salida . . . . .	29
7.3.4.	Correlación con variables atmosféricas . . . . .	31
7.3.5.	Comparación entre el modelo base y el modelo final . . . . .	31
7.4.	Resultados del proceso de contenerización y servicio de inferencia . . . . .	33
7.4.1.	Estructura del servicio . . . . .	33
7.4.2.	Contenerización del sistema . . . . .	33
7.4.3.	Pruebas de validación . . . . .	34
<b>8.</b>	<b>Discusión</b>	<b>35</b>

<b>9. Conclusiones</b>	<b>37</b>
<b>10.Recomendaciones</b>	<b>39</b>
<b>11.Bibliografía</b>	<b>41</b>
<b>12.Anexos</b>	<b>44</b>
12.1. Anexo A. Ejemplos de puntos de interés . . . . .	44
12.2. Anexo B. Repositorio con código del servicio de inferencia y guía de uso . . .	47
12.3. Anexo C. Repositorio con pesos de modelo y estadísticos de normalización atmosférica . . . . .	47

---

## Lista de figuras

---

1.	Flujo general del algoritmo multimodal para estimar la probabilidad de presencia de botadero a cielo abierto . . . . .	23
2.	Matriz de correlación entre las variables atmosféricas y la etiqueta clasificadora	26
3.	Distribución del dióxido de nitrógeno ( $NO_2$ ) para muestras positivas (barras rojas), y negativas (barras azules) . . . . .	27
4.	Distribución del monóxido de carbono ( $CO$ ) para muestras positivas (barras rojas), y negativas (barras azules) . . . . .	27
5.	Distribución del material particulado menor a 10 micrómetros ( $PM_{10}$ ) para muestras positivas (barras rojas), y negativas (barras azules) . . . . .	27
6.	Distribución del material particulado menor a 2.5 micrómetros ( $PM_{2.5}$ ) para muestras positivas (barras rojas), y negativas (barras azules) . . . . .	28
7.	Distribución de probabilidades del modelo base, barras rojas son clase positiva y barras azules son clase negativa . . . . .	30
8.	Distribución de probabilidades del modelo final, barras rojas son clase positiva y barras azules son clase negativa . . . . .	30
9.	Matriz de correlación del modelo final en relación con variables atmosféricas, en conjunto de datos de prueba . . . . .	31
10.	Comparación de resultados entre el modelo base y el modelo final mediante diagrama de flujo . . . . .	32
11.	Ejemplos de imágenes satelitales de puntos de interés . . . . .	45
12.	Ejemplos de imágenes satelitales de puntos de interés . . . . .	46

---

## Lista de cuadros

---

1.	Estructura general de la matriz de confusión empleada en este estudio . . . .	13
2.	Métricas de desempeño del modelo base (solo visual), sobre el conjunto de prueba . . . . .	28
3.	Matriz de confusión del modelo base . . . . .	29
4.	Métricas de desempeño del modelo final (multimodal), sobre el conjunto de prueba . . . . .	29
5.	Matriz de confusión del modelo final . . . . .	29
6.	Comparación de resultados de predicción entre modelo base y modelo final para muestras de botaderos a cielo abierto . . . . .	32
7.	Comparación de resultados de predicción entre modelo base y modelo final para muestras que no son botaderos a cielo abierto . . . . .	32

Este trabajo implementa un sistema automatizado para detectar botaderos a cielo abierto en Guatemala mediante la integración de imágenes satelitales RGB y métricas atmosféricas con modelos de inteligencia artificial. Se construyó un conjunto de 463 muestras balanceadas entre clases positivas y negativas. Cada punto de interés combina una imagen satelital de alta resolución con promedios locales de dióxido de nitrógeno ( $NO_2$ ), monóxido de carbono ( $CO$ ) y material particulado ( $PM_{10}$  y  $PM_{2.5}$ ), obtenidos a partir de *Sentinel-5P* y *CAMS* mediante *Google Earth Engine*.

El modelo base *ResNet50-FPN*, entrenado originalmente con el conjunto de datos *AerialWaste*, fue reentrenado con estas muestras y ampliado con una rama atmosférica que vincula el comportamiento de los contaminantes con la probabilidad de presencia de un botadero. La fusión entre las ramas visual y atmosférica generó un modelo multimodal con probabilidades calibradas y un equilibrio mejorado entre precisión y sensibilidad, adecuado para tareas de clasificación ambiental.

Asimismo, se implementó un servicio de inferencia basado en *FastAPI* y contenerizado con *Docker*, lo que facilita su portabilidad, reproducibilidad e integración con plataformas de monitoreo ambiental en Guatemala.

En conjunto, el sistema desarrollado constituye una herramienta funcional, auditable y escalable que combina evidencia visual y contexto atmosférico para apoyar la detección y el seguimiento automatizado de botaderos a cielo abierto en el país.

This work implements an automated system to detect open-air landfills in Guatemala by integrating RGB satellite imagery and atmospheric metrics through artificial intelligence models. A dataset of 463 samples was built, balanced between positive and negative classes. Each point of interest combines a high-resolution satellite image with local averages of nitrogen dioxide ( $NO_2$ ), carbon monoxide ( $CO$ ), and particulate matter ( $PM_{10}$  and  $PM_{2.5}$ ), obtained from Sentinel-5P and CAMS via Google Earth Engine.

The base model, ResNet50-FPN, originally trained with the AerialWaste dataset, was retrained using these samples and extended with an atmospheric branch that relates pollutant behavior to the probability of landfill presence. The fusion between the visual and atmospheric branches produced a multimodal model with calibrated probabilities and improved balance between precision and sensitivity, suitable for environmental classification tasks.

Additionally, an inference service was implemented using FastAPI and containerized with Docker, ensuring portability, reproducibility, and seamless integration with environmental monitoring platforms in Guatemala.

Overall, the developed system provides a functional, auditable, and scalable tool that combines visual evidence and atmospheric context to support the automated detection and monitoring of open-air landfills in the country.

Los botaderos a cielo abierto representan uno de los problemas ambientales de mayor impacto para la población guatemalteca, tal como lo establece el Acuerdo Gubernativo No. 281-2015 del Ministerio de Ambiente y Recursos Naturales (MARN) [1]. En estos sitios, los residuos sólidos se disponen sin separación ni tratamiento, generando afectaciones al ambiente y a la salud pública. La exposición a contaminantes asociados a estos botaderos se ha relacionado con síntomas respiratorios, fatiga, estrés psicológico e incluso malformaciones [2]. A ello se suma que la descomposición anaeróbica de la fracción orgánica produce emisiones de biogás que contribuyen al cambio climático [3]. La presión de la urbanización, que incrementa la generación de desechos por encima de la capacidad institucional, y la naturaleza intensiva en mano de obra de los procesos de caracterización convencionales [4], [5], dificultan la detección oportuna de sitios de botaderos a cielo abierto ilícitos.

En los últimos años, la teledetección ha emergido como una alternativa eficaz y rentable para el monitoreo de botaderos, combinando índices de vegetación, temperatura superficial e información SAR [6]. En particular, los enfoques basados en aprendizaje profundo con arquitecturas como ResNet50 y redes de pirámides de características (FPN, por sus siglas en inglés), han alcanzado altos niveles de precisión en la clasificación de escenas aéreas [7]. Un hito relevante es el conjunto de datos AerialWaste, de Torres y Fraternali, que ofrece más de 10,000 imágenes validadas para el entrenamiento y evaluación [8]. Sobre esta base, experiencias recientes en Guatemala han demostrado la viabilidad de adaptar modelos preentrenados a contextos locales mediante aprendizaje por transferencia, mejorando su desempeño en condiciones nacionales [9].

Este trabajo además de utilizar el modelo preentrenado en imágenes satelitales, integra, de manera multimodal, mediciones atmosféricas georreferenciadas a estas imágenes en espectro visual RGB, para la estimación de probabilidad de presencia de botaderos a cielo abierto en Guatemala. Concretamente, se construyó un conjunto de datos nacional que combina 213 ubicaciones de botaderos a cielo abierto oficialmente reconocidos (clase positiva), con 250 puntos negativos generados con criterios espaciales. Cada muestra se acompaña con una imagen satelital de alta resolución (640x640, *zoom* 20), y con promedios locales (radio de 5 km)

de  $NO_2$ ,  $CO$ ,  $PM_{10}$  y  $PM_{2.5}$ , obtenidos desde *Google Earth Engine* a partir de *Sentinel-5P* y *CAMS* en un periodo reciente y consistente con los sistemas de análisis atmosférico. El algoritmo propuesto combina una rama visual basada en *ResNet50-FPN (CAM\_PRED)*, la cual da una probabilidad sigmoide de la presencia de un botadero a cielo abierto en una imagen; a esta se le agrega una rama atmosférica que comprende las relaciones entre las variables atmosféricas y una capa de fusión que evalúa el resultado de las dos ramas para producir la probabilidad final. El entrenamiento se realizó en dos etapas (congelamiento y ajuste fino), se evaluó con métricas estándar (exactitud, precisión, sensibilidad, *F1-Score* y *ROC-AUC*), así como matrices de confusión. Finalmente el sistema se contenerizó y expuso mediante *FastAPI* y *Docker* para facilitar su integración con plataformas de monitoreo y reproducibilidad. En conjunto, esta aproximación aporta una herramienta escalable y auditable que combina evidencia visual y contexto atmosférico para apoyar la detección asistida de botaderos a cielo abierto en Guatemala.

---

### Justificación

---

Dentro del Acuerdo Gubernativo No. 281-2015 del Ministerio de Ambiente y Recursos Naturales (MARN) del Gobierno de la República de Guatemala, se establece que la problemática de los residuos y desechos sólidos constituye uno de los principales impactos ambientales que afectan a la población, y que requiere una gestión integral [1]. Esta problemática abarca múltiples dimensiones, entre ellas la ausencia de métodos ambientalmente responsables que salvaguarden la salud pública. En dicho documento se reconoce el uso de botaderos a cielo abierto como una práctica inadecuada y contraria al desarrollo sostenible. Según la definición institucional, estos sitios son espacios donde los residuos sólidos se abandonan sin separación ni tratamiento alguno.

La exposición a contaminantes provenientes de los botaderos a cielo abierto ha sido asociada con diversos efectos negativos en la salud humana, incluyendo síntomas respiratorios, fatiga, somnolencia, estrés psicológico e incluso malformaciones congénitas [2]. Al no existir separación ni tratamiento adecuado de los residuos, los botaderos contienen materiales biológicos que se acumulan y compactan, generando condiciones anaeróbicas que favorecen la descomposición orgánica y la producción de biogás que constituyen los principales gases de efecto invernadero [3].

El crecimiento poblacional y la urbanización acelerada han incrementado la generación de desechos sólidos a un ritmo superior al de la expansión de la infraestructura y la planificación urbana. La responsabilidad del manejo de estos desechos recae, en su mayoría, en las municipalidades, como parte de los servicios básicos que prestan a la ciudadanía, junto con salud, transporte y educación [4]. En respuesta, el MARN publicó la Guía para elaborar estudios de caracterización de residuos y desechos sólidos comunes, que detalla un procedimiento técnico para la gestión integral de residuos y la toma de decisiones a nivel municipal [5]. Sin embargo, este proceso depende fuertemente del trabajo manual para la recolección, separación y análisis de muestras, y no contempla mecanismos de detección previa o automatizada de sitios de disposición ilegal o informal.

A nivel internacional, el uso de técnicas de teledetección ha demostrado ser una alternativa viable y costo-eficiente para la detección y monitoreo de botaderos a cielo abierto,

permitiendo el análisis multitemporal de su evolución. Estas técnicas emplean imágenes satelitales multiespectrales y productos derivados —como índices de vegetación (NDVI), temperatura superficial y datos SAR—, los cuales pueden analizarse de forma individual o combinada para identificar patrones anómalos en el terreno [6]. En estudios recientes, Papale et al. desarrollaron métodos que integran índices de vegetación, temperatura superficial del suelo e información SAR para mejorar la sensibilidad en la detección de cambios geométricos y espectrales en los sitios de disposición de residuos [6]. Por otra parte, los avances en aprendizaje profundo han permitido el uso de redes neuronales convolucionales (CNN, por sus siglas en inglés) con arquitecturas como ResNet50, complementadas con redes piramidales de características (FPN, por sus siglas en inglés), para la clasificación automática de imágenes aéreas RGB de alta resolución, alcanzando precisiones superiores al 87 % en la detección de botaderos a cielo abierto [7].

Un aporte significativo en este campo es el conjunto de datos AerialWaste, desarrollado por Torres y Fraternali, que recopila imágenes aéreas RGB de múltiples fuentes con validación técnica. Este *dataset* incluye 3 478 ejemplos positivos y 6 956 negativos de sitios de interés, y ha permitido la generación de modelos de detección altamente precisos tanto en imágenes procesadas como en imágenes originales [8].

En el contexto europeo, el programa Copernicus de la Unión Europea, a través de su Servicio de Cambio Climático (C3S), ofrece información atmosférica y terrestre derivada de satélites como Sentinel-5P y Sentinel-2, que facilitan tanto el monitoreo de la calidad del aire como la obtención de imágenes multiespectrales [10], [11]. Estas fuentes proporcionan datos consistentes y actualizados que pueden integrarse en sistemas de observación ambiental y detección remota.

Recientemente, el Programa de las Naciones Unidas para el Desarrollo (PNUD) desarrolló una metodología innovadora para la detección de sitios con botaderos a cielo abierto en Guatemala, aplicando técnicas de aprendizaje por transferencia. En esta metodología, se utilizó la arquitectura ResNet50 preentrenada en ImageNet, posteriormente adaptada con el conjunto de datos AerialWaste, y finalmente ajustada con información local para mejorar su precisión en condiciones guatemaltecas [9]. Este trabajo constituye un precedente metodológico relevante, al demostrar la posibilidad de combinar modelos preentrenados con datos locales para la detección automatizada de botaderos a cielo abierto en contextos específicos.

Basándose en esta experiencia previa, el presente proyecto extiende el enfoque existente al integrar, de manera multimodal, imágenes satelitales RGB con mediciones atmosféricas georreferenciadas, con el propósito de desarrollar un sistema más robusto y preciso para la detección automatizada de botaderos a cielo abierto en Guatemala.

### 3.1. Objetivo general

Implementar imágenes satelitales y mediciones atmosféricas para la detección de botaderos a cielo abierto en Guatemala.

### 3.2. Objetivos específicos

- Integrar imágenes satelitales con mediciones atmosféricas georreferenciadas para generar conjuntos de datos multidimensionales de puntos de interés.
- Desarrollar un algoritmo para calcular la probabilidad de presencia de botaderos a cielo abierto combinando procesamiento de datos y modelos de inteligencia artificial.
- Contenerizar el proceso de detección para su integración con sistemas de monitoreo a nivel nacional y futura integración con tecnologías complementarias

### 4.1. Alcance del sistema

El presente trabajo se limita a mejorar el rendimiento en Guatemala de un modelo base previamente entrenado sobre el conjunto de datos *AerialWaste*, mediante:

1. La construcción de un conjunto de puntos de interés en Guatemala y su integración con cuatro métricas atmosféricas ( $NO_2$ ,  $CO$ ,  $PM_{10}$ ,  $PM_{2.5}$ ) para aportar contexto físicoquímico a la inferencia.
2. El ajuste fino (*fine-tuning*) y evaluación de un modelo *multimodal* que fusiona la probabilidad sigmoide del modelo visual base con una representación latente de las variables atmosféricas.
3. La contenerización para inferencia de dicho modelo (servicio *FastAPI* dockerizado) a fin de facilitar su despliegue y uso operativo.

### 4.2. Fuera de alcance

El sistema no cubre las siguientes funciones:

- Adquisición automática de datos: no descarga ni procesa imágenes satelitales ni métricas atmosféricas de forma autónoma.
- Validación de co-registro/consistencia: no verifica que la imagen y las métricas atmosféricas correspondan al mismo punto de interés, período temporal o sistema de referencia.
- Entrenamiento en producción: la imagen dockerizada se orienta a inferencias (predicción), no a ciclos de entrenamiento o reentrenamiento en campo.

- Liberación de scripts de scraping propietarios: aunque el autor desarrolló código para recolectar datos, este depende de *licencias comerciales de Google* y no se integra al contenedor final.
- Liberación de programas para la obtención de información propietaria: aunque el autor desarrolló código para recolectar datos, la propiedad intelectual y derechos de autor tanto de las imágenes satelitales como los datos atmosféricos dependen de licencias comerciales de *Google*, el principal proveedor de información. Estos programas no se integran en el entregable funcional (contenedor final).

### 4.3. Supuestos y dependencias de uso

Para operar correctamente, el servicio requiere:

1. Una imagen RGB preprocesada y las cuatro variables atmosféricas numéricas provistas por el usuario para el mismo punto de interés, esto para el compuesto de puntos de interés que se deseen procesar.
2. La aplicación coherente de normalizaciones provistas (archivos estadísticos en formato NPZ) y el uso del umbral de decisión configurado ( $\tau = 0.5$  por defecto), salvo que el usuario defina otro.
3. Respeto a licencias y términos de los proveedores de datos utilizados por el usuario (p. ej., *Google Maps Static API*, *GEE/Copernicus*).

### 4.4. Entregables

- Modelo multimodal ajustado para el contexto de Guatemala (pesos finales) y estadísticos de normalización atmosférica.
- Servicio de inferencia (*FastAPI*) contenerizado en *Docker*, con endpoints `/live`, `/predict` y `/predict-multipart`.
- Guías de uso (variables de entorno, montaje de modelos y ejemplos de llamada) y pruebas de validación con *pytest* para estructura de respuestas.

### 4.5. Limitaciones y criterios de confidencialidad

- El conjunto de datos con ubicaciones oficiales de botaderos municipales en Guatemala fue provisto por el Ministerio de Ambiente y Recursos Naturales (MARN) bajo acuerdo de confidencialidad; no se comparte en este trabajo. La obtención de dicha información debe gestionarse directamente con el MARN, según su propio criterio de otorgamiento.
- Las métricas reportadas reflejan el rendimiento del modelo sobre el conjunto de prueba construido y descrito en este estudio, con sus ventanas temporales y supuestos de preprocesamiento.

- Las salidas del sistema son probabilidades e interpretaciones auxiliares; no constituyen un dictamen definitivo y deben complementarse con validación humana y criterios técnicos para la toma de decisiones.

## 5.1. Gestión de residuos y botaderos a cielo abierto

En el contexto institucional y el manejo de residuos sólidos en Guatemala, existen marcos normativos y actores responsables tanto de la administración de la gestión de residuos y desechos sólidos como del manejo de residuos sólidos apropiadamente. La problemática causada por botaderos a cielo abierto en Guatemala tiene efectos en la salud pública, como en la disminución de incendios y daño ambiental. Existen métodos de monitoreo, estos tradicionalmente traen consigo una gran labor manual con altos costos asociados e ineficiencias para el monitoreo continuo.

### 5.1.1. Definición y marco normativo en Guatemala

La gestión de residuos y desechos sólidos en Guatemala se enmarca en la Política Nacional para la Gestión Integral de Residuos y Desechos Sólidos establecida por el Acuerdo Gubernativo 281-2015 del Ministerio de Ambiente y Recursos Naturales (MARN). Esta política define lineamientos para la prevención, reducción, valorización y disposición final de residuos, y reconoce que los botaderos a cielo abierto constituyen prácticas contrarias a la gestión integral por su carácter no controlado y su potencial de impacto socioambiental [1]. Posteriormente, el Acuerdo Gubernativo 164-2021 actualiza y precisa disposiciones reglamentarias, reforzando obligaciones de las municipalidades y de los generadores en la separación en fuente, rutas de recolección, y en la progresiva sustitución de botaderos por sistemas de disposición final técnicamente controlados [12]. En este marco, el MARN funge como la autoridad rectora en materia ambiental, con la responsabilidad de formulación de política, regulación y supervisión, mientras que las municipalidades asumen la competencia operativa para la prestación del servicio de limpieza y manejo de residuos sólidos en su jurisdicción, incluyendo recolección, transporte y disposición final conforme a los instrumentos normativos vigentes [1], [12].

### 5.1.2. Características y problemáticas de los botaderos a cielo abierto

Los botaderos a cielo abierto se caracterizan por la disposición sin control de residuos, usualmente sin separación ni tratamiento previo ni control sanitario para prevenir contaminación del ambiente [1]. Estas condiciones favorecen procesos de contaminación del suelo (lixiviados con carga orgánica y metálica), de cuerpos de agua superficiales y subterráneos (percolación y escorrentía), y de la atmósfera (emisión de gases traza) [3].

La fracción biodegradable bajo condiciones anaeróbicas genera biogás con proporciones relevantes de metano ( $CH_4$ ) y dióxido de carbono ( $CO_2$ ); estos contribuyen al cambio climático. Adicionalmente la acumulación de residuos y la falta de sistemas de cobertura incrementan el riesgo de incendios, vectores biológicos y degradación paisajística, con impactos al bienestar de comunidades aledañas. [3]

Los botaderos a cielo abierto representan un foco de impacto acumulativo y difuso, donde se combinan presiones físicoquímicas, biológicas y sociales. Hay demanda de respuestas coordinadas entre regulación, fiscalización y alternativas tecnológicas de cierre o reconversión.

### 5.1.3. Efectos sobre la salud pública

En el contexto latinoamericano, se han documentado efectos adversos en salud asociados a la proximidad de botaderos a cielo abierto. Girón et al. (2009), reportan incremento de síntomas respiratorios en infantes y costos familiares de atención vinculados a la exposición crónica a contaminantes asociados a residuos dispuestos sin control [2]. Estos hallazgos son consistentes con reportes más recientes, que muestran que la exposición crónica a material particulado, compuestos orgánicos volátiles y bioaerosoles causan, complican y exacerban condiciones de salud adversas debido a la toxicidad de los contaminantes [13]. La contaminación ambiental afecta a personas de todas las regiones, edades y grupos sociales, especialmente a personas vulnerables debido a causas de salud preexistentes o comunidades con menor apoyo social [13].

### 5.1.4. Limitaciones de los métodos tradicionales de monitoreo

Los métodos convencionales para localizar y caracterizar sitios de disposición de residuos consisten en: inspección en campo, levantamientos manuales y estudio de caracterización. Estos métodos son intensivos en mano de obra, costosos y poco escalables, especialmente cuando se pretende cubrir áreas extensas con periodicidad suficiente para la toma de decisiones [4].

A nivel mundial se ha reportado que la dependencia de reportes ciudadanos y actividades de fiscalización puntuales tienden a generar sesgos de cobertura y demoras en la detección de sitios emergentes o reactivados, especialmente contra regiones relativamente silenciosas [14]. En este contexto, la adopción de herramientas automatizadas y escalables que integren datos heterogéneos (imágenes satelitales, información atmosférica y registros administrativos), permiten monitoreo continuo y alertan tempranamente, esto permite optimizar recursos ins-

titucionales, tanto con un análisis a distancia previo a la verificación en terreno si esta se desea realizar [4].

## 5.2. Modelos de inteligencia artificial aplicados al análisis ambiental

La inteligencia artificial tiene aplicaciones diversas, desde el aprendizaje automático que extrae patrones para la identificación de características que permiten desarrollar predicciones. En el contexto ambiental, se pueden desarrollar modelos de aprendizaje automático que reconocen patrones espaciales, como la clasificación de coberturas terrestres, la detección de incendios y la identificación de botaderos a cielo abierto. Los modelos para esta última aplicación suelen tener arquitecturas complejas que capturan patrones visuales más allá de los que pueden ser identificados por humanos. Estos modelos permiten llevar un proceso de aprendizaje por transferencia con el cuál se mejora la capacidad de estos ante un conjunto de datos específico.

### 5.2.1. Aprendizaje automático y aprendizaje profundo

El aprendizaje automático (*machine learning*), constituye el núcleo de la inteligencia artificial moderna. Se fundamenta en la capacidad de los algoritmos para extraer patrones a partir de datos y utilizarlos para realizar predicciones o clasificaciones sin requerir reglas explícitas programadas por humanos. Dentro de este campo, el aprendizaje supervisado emplea conjuntos de datos etiquetados para ajustar los parámetros de un modelo hasta minimizar la diferencia entre las predicciones y los valores reales [15].

En la última década, el avance en capacidades de cómputo y acceso a grandes volúmenes de datos han impulsado el desarrollo del aprendizaje profundo (*deep learning*), una de las grandes ramas de aprendizaje automático está basado en redes neuronales artificiales con múltiples capas ocultas. Estas redes pueden representar relaciones jerárquicas y no lineales entre variables, lo cual las hace particularmente convenientes en el estudio de procesamiento de imágenes, audio y texto [16]. En el contexto ambiental, el aprendizaje profundo ha permitido automatizar tareas de reconocimiento de patrones espaciales, como la clasificación de coberturas terrestres, la detección de incendios y la identificación de botaderos a cielo abierto [17].

### 5.2.2. Redes neuronales convolucionales (CNN)

Las redes neuronales convolucionales (CNN, por sus siglas en inglés), son una clase especializada de redes profundas diseñadas para procesar datos con estructura espacial, como imágenes. Su arquitectura imita la organización del córtex visual y se compone de capas de convolución, funciones de activación no lineales, operaciones de *pooling* y capas completamente conectadas [15].

Las capas convolucionales aplican filtros que detectan patrones locales como bordes,

texturas o formas, mientras que el *pooling* reduce la resolución espacial preservando las características relevantes y disminuyendo el costo computacional. Este proceso permite un aprendizaje jerárquico de características, donde las capas iniciales capturan detalle fino y las capas profundas abstraen formas complejas y semánticamente ricas [18].

Una arquitectura ampliamente adoptada es la *ResNet50*, propuesta por He et al. (2016), que introdujo los bloques residuales para mitigar el problema del desvanecimiento del gradiente en redes profundas. Estos bloques emplean conexiones de salto llamadas *skip connections* que permiten aprender funciones residuales en lugar de transformaciones completas. Este proceso mejora la convergencia y estabilidad del entrenamiento. La arquitectura basada en *ResNet50* muestra un balance entre precisión y eficiencia, convirtiéndose en una base estándar para tareas de clasificación y detección en visión por computadora [19].

### 5.2.3. Red de pirámides de características (FPN)

A pesar de su robustez, las CNN tradicionales presentan dificultades para reconocer a múltiples escalas, tienden a ser específicas a una escala. Esta limitación fue abordada por Lin et al. (2017), desarrollaron la *Feature Pyramid Network (FPN)*, esta arquitectura explota la jerarquía intrínseca de las redes convolucionales construyendo una pirámide semántica de características. La FPN combina dos rutas complementarias: una *bottom-up*, que se basa en la imagen original para extraer características de bajo nivel, y una *top-down*, que utiliza conexiones laterales para proyectar representaciones de alto nivel hacia resoluciones más finas. Esta estructura genera un mapa de características con alta semántica y buena resolución espacial en todos los niveles del modelo, esto permite mejorar la detección de objetos pequeños sin incrementar significativamente el costo computacional [18].

Esta arquitectura ha sido seleccionada en varios estudios de clasificación, especialmente en aplicaciones de teledetección, la combinación *ResNet50 + FPN* constituye una de las configuraciones más efectivas para la identificación de patrones antrópicos en imágenes aéreas [7], [17].

### 5.2.4. Modelos de fusión multimodal y redes densas

Los modelos de fusión multimodal integran datos provenientes de fuentes heterogéneas, como imágenes, señales espectrales o variables numéricas. Su objetivo es aprovechar la complementariedad de la información para mejorar la capacidad predictiva del sistema. En este tipo de arquitecturas, generalmente se utilizan perceptrones multicapa (*MLP*, por sus siglas en inglés), como una capa que aprende representaciones conjuntas que capturan relaciones entre modalidades. El objetivo de estas arquitecturas es combinar modelos que pueden tener resultados balanceados y trabajar bajo la complementariedad de múltiples modos, imágenes, audio, métricas, comportamientos y tendencias, para mejorar la calibración del resultado final en tareas de clasificación [20].

### 5.2.5. Aprendizaje por transferencia en contextos locales

El aprendizaje por transferencia (*transfer learning*, permite reutilizar el conocimiento aprendido por un modelo en un dominio fuente, como lo es imágenes aéreas globales, y mejorar el desempeño de un dominio destino con datos limitados, como lo es imágenes locales de Guatemala. En la práctica, esto se logra ajustando parcialmente los pesos de un modelo preentrenado sobre un gran conjunto de datos mediante un proceso de ajuste fino sobre el nuevo conjunto específico [18].

Este enfoque reduce costos de entrenamiento, acelera la convergencia y mejora la generalización en entornos donde la obtención de muestras etiquetadas es costosa o limitada. En el contexto de detección de botaderos a cielo abierto, el estudio desarrollado por Barón et al. (2025) demostró la eficacia del aprendizaje por transferencia al adaptar un modelo *ResNet50-FPN* preentrenado con el conjunto de datos *AerialWaste* a condiciones geográficas y ambientales de Guatemala, logrando un incremento significativo en la precisión de detección, únicamente observando imágenes satelitales [9].

### 5.2.6. Métricas de evaluación de modelos de clasificación

La evaluación del desempeño del modelo se basa en métricas derivadas de la matriz de confusión, que resume las predicciones del modelo frente a las etiquetas reales. Cada predicción se clasifica en un cuadro categorías: verdaderos positivos (*TP*), falsos positivos (*FP*), verdaderos negativos (*TN*), y falsos negativos (*FN*). En este estudio, la clase positiva corresponde a la presencia de botaderos a cielo abierto.

**Matriz de confusión.** La matriz de confusión resume los aciertos y errores del modelo en cada clase. En este estudio se emplea el formato mostrado en el Cuadro 1, donde las filas corresponden a las predicciones del modelo y las columnas a las etiquetas reales.

Cuadro 1: Estructura general de la matriz de confusión empleada en este estudio

		Etiqueta real		Total
		Botadero a cielo abierto (1)	No botadero (0)	
Predicción	Botadero a cielo abierto (1)	TP	FP	TP+FP
	No botadero (0)	FN	TN	FN+TN
Total		TP+FN	FP+TN	N

**Exactitud (*accuracy*).** Esta métrica de evaluación mide la proporción total de predicciones correctas, tanto positivas como negativas, es un indicador general:

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN}.$$

[15], [21]

**Precisión (*precision*).** Representa la fracción que casos identificados como positivos que realmente lo son, en este estudio refleja cuántos de los puntos clasificados como botaderos que efectivamente son sitios confirmados:

$$\text{Precision} = \frac{TP}{TP + FP}.$$

[15], [21]

**Sensibilidad (*recall*).** Mide la capacidad del modelo para detectar todos los positivos como reales, indica la proporción de botaderos existentes que fueron correctamente identificados por el modelo:

$$\text{Recall} = \frac{TP}{TP + FN}.$$

[15], [21]

**F1-Score.** Mide la armónica entre precisión y sensibilidad, permite evaluar las capacidades del modelo y su aplicación sobre el caso promedio:

$$F_1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}.$$

[15], [21]

**Curva ROC y AUC-ROC.** La curva ROC (*Receiver Operating Characteristic*), muestra la relación entre la Tasa de Verdaderos Positivos (TPR = Sensibilidad) y la Tasa de Falsos Positivos (FPR = FP / (FP + TN)) para distintos umbrales de decisión. El área bajo la curva (AOC-ROC) cuantifica la capacidad global del modelo para discriminar entre clases: un valor cercano 1.0 representa una separación casi perfecta, mientras que 0.5 indica un desempeño aleatorio. Esta métrica es útil para comparar modelos sin depender de un umbral fijo de clasificación.[15], [21]

## 5.3. Teledetección y análisis de imágenes satelitales

La teledetección es el proceso de obtención de información sobre un objeto desde una distancia. En el contexto de este estudio, se utiliza teledetección por medio de satélites. La información obtenida por satelites provee información para encontrar patrones tanto en el suelo, como atmosféricos. El análisis puede revelar procesos antrópicos, permite la identificación y monitoreo de áreas problemáticas.

### 5.3.1. Principios de la teledetección

La teledetección es la ciencia y tecnología que permite obtener información del entorno terrestre mediante sensores que capturan la radiación electromagnética reflejada o emitida

por la superficie terrestre. Estos sensores, instalados en satélites o aeronaves, registran datos en diferentes bandas espectrales, lo que permite analizar propiedades físicas y químicas de los objetos observados sin necesidad de contacto directo [6].

Las imágenes satelitales se caracterizan por tres dimensiones fundamentales:

- Resolución espacial, que indica el tamaño de píxel en el terreno y determina el nivel de detalle observable.
- Resolución espectral, que se refiere al número y amplitud de las bandas del espectro electromagnético capturadas.
- Resolución temporal, que describe la frecuencia con el satélite revisita una misma área, permitiendo el análisis multitemporal y la detección de cambios [18].

Las imágenes *RGB* (rojo, verde y azul), corresponden a una representación visual del espectro visible y son ampliamente utilizadas para tareas de clasificación visual, dado su parecido con la percepción humana. En la actualidad, diversas plataformas de observación proporcionan datos satelitales con fines ambientales. Entre ellas destacan los satélites del programa *Copernicus* de la Agencia Espacial Europea, particularmente *Sentinel-2*, con imágenes multispectrales de alta resolución espacial (10-60 m), y *Sentinel-5P (TROPOMI)*, especializado en la medición de contaminantes atmosféricos como *NO<sub>2</sub>*, *CO*, *CH<sub>4</sub>*. Además, fuentes comerciales y de acceso controlado, como la *Google Maps Static API*, permiten obtener imágenes *RGB* de muy alta resolución (hasta 0.5 m por píxel), útiles para el análisis visual detallado y la generación de conjuntos de datos de entrenamiento [10].

### 5.3.2. Aplicaciones de la teledetección en gestión de residuos

La teledetección satelital constituye una herramienta fundamental para el monitoreo ambiental y la gestión de residuos sólidos, al permitir observar el territorio de forma continua y sistemática. Las imágenes RGB, que combinan la información de las bandas roja, verde y azul, son en sí mismas un tipo de imagen multispectral y proporcionan una base suficiente para la identificación visual de coberturas y alteraciones del terreno.

En la detección de botaderos a cielo abierto, estas imágenes permiten identificar patrones anómalos de color y textura asociados a acumulaciones de desechos, alteración del suelo o pérdida de vegetación. Su análisis se complementa con el uso de indicadores espectrales derivados, que sintetizan información ambiental de alta relevancia para el diagnóstico superficial.

Wulder et al. (2019) destacan que la continuidad del programa Landsat ha permitido establecer un registro histórico sin precedentes de la superficie terrestre, con aplicaciones directas en el seguimiento de cambios ambientales y la planificación territorial. A partir de esta información, el uso combinado de índices como:

- el índice de vegetación de diferencia normalizada (NDVI), que mide la densidad y vigor de la vegetación,

- el índice de diferencia normalizada de agua (NDWI), que identifica la humedad superficial y presencia de lixiviados, y
- la temperatura superficial del suelo (LST), que permite detectar incrementos térmicos asociados a la descomposición orgánica o a focos de combustión,

En conjunto, estos indicadores, aplicados sobre imágenes RGB de alta resolución o datos derivados de misiones como Landsat, posibilitan la detección indirecta de botaderos a cielo abierto a partir de su firma espectro-temporal distintiva: baja cobertura vegetal, elevada temperatura superficial y heterogeneidad de la textura del terreno [22].

### 5.3.3. Conjuntos de datos para detección de botaderos a cielo abierto

El avance del aprendizaje profundo en teledetección ha estado estrechamente ligado a la disponibilidad de conjuntos de datos etiquetados. En este contexto, el conjunto de datos *AerialWaste*, desarrollado por Torres y Fraternali (2023), constituye un hito en la detección automatizada de vertederos mediante imágenes aéreas y satelitales.

El conjunto de datos *AerialWaste* está compuesto por 10,434 imágenes RGB de alta resolución, de las cuales 3,478 corresponden a sitios positivos (botaderos a cielo abierto), y 6,956 sitios negativos. Las imágenes provienen de fuentes como *AGEA*, *WorldView-3* y *Google Earth*, y fueron validadas manualmente por expertos en gestión de residuos. Las anotaciones siguen el estándar *MS COCO* (Microsoft Common Objects in Context) un formato ampliamente utilizado en visión por computadora que define estructuras uniformes para etiquetas, categorías y coordenadas de objetos dentro de imágenes, lo que permite su uso en tareas de clasificación, segmentación y detección de objetos [8].

En su trabajo de base, Torres et al. (2021) demostraron que las arquitecturas *ResNet50-FPN* alcanzan precisiones superiores al 87%, estableciendo un punto de referencia para tareas de clasificación de escenas aéreas. Además, su metodología permitió el desarrollo de variantes del modelo ajustadas para distintos entornos geográficos, mostrando su transferibilidad del enfoque a nuevos contextos [7].

### 5.3.4. Experiencias regionales y contexto guatemalteco

En América Latina, la aplicación de metodologías basadas en teledetección para la identificación de botaderos a cielo abierto es escasa. Sin embargo, iniciativas recientes han demostrado su potencial adaptabilida a contextos locales.

En Guatemala, el Programa de las Naciones Unidas para el Desarrollo (PNUD), en colaboración con el Politécnico de Milán, implementó un proyecto piloto para la detección de botaderos a cielo abierto mediante aprendizaje por transferencia, utilizando el modelo *ResNet50-FPN* preentrenado en el conjunto *AerialWaste*. Este modelo fue posteriormente ajustado con imágenes de Guatemala y validado con datos del MARN, alcanzando un desempeño que muestra la viabilidad del enfoque para Guatemala [9].

El proceso de validación incluyó métricas estándar como precisión, recuperación (*recall*) y *F1-Score*. Demostró un equilibrio entre la capacidad del modelo para detectar correctamente entre botaderos a cielo abierto. Los resultados confirmaron que la integración de información satelital de alta resolución con técnicas de aprendizaje profundo representan una alternativa viable y escalable para el monitoreo ambiental automatizado en Guatemala.

## 5.4. Integración de información atmosférica en teledetección

La calidad del aire y las emisiones atmosféricas pueden indirectamente dar una imagen de la actividad humana en el suelo. Los botaderos a cielo abierto aportan a la contaminación ambiental, la descomposición de residuos e incendios ocurridos liberan contaminantes que irradian áreas cercanas. Estos contaminantes pueden ser detectados mediante sensores satelitales especializados. Las imágenes satelitales aportan información sobre el suelo, combinar estas imágenes con mediciones atmosféricas de contaminantes pueden no solo aportar al monitoreo individual de estos, pero también fortalecer la detección combinando características visuales con patrones de contaminantes.

### 5.4.1. Importancia de los contaminantes atmosféricos como indicadores indirectos

Los contaminantes atmosféricos pueden actuar como indicadores indirectos de la actividad antrópica asociada al manejo de residuos. Entre ellos, el dióxido de nitrógeno ( $NO_2$ ), y el monóxido de carbono ( $CO$ ) son subproductos de la combustión incompleta y de los procesos de degradación térmica en botaderos a cielo abierto. El material particulado fino ( $PM_{10}$  y  $PM_{2.5}$ ) refleja la resuspensión de polvo, la quema de residuos y la actividad vehicular en las cercanías. Estas variables son particularmente útiles para la detección indirecta de botaderos a cielo abierto, donde las emisiones de gases y partículas tienden a superar los valores de fondo ambiental [23].

Aunque el metano ( $CH_4$ ), constituye el principal componente de biogás generado en los botaderos a cielo abierto por procesos de descomposición anaeróbica, su utilización como indicador atmosférico para Guatemala presenta limitaciones técnicas y físicas relevantes. El estudio de Silva et al. (2025), integró observaciones in situ, mediciones satelitales de *TROPOMI* y *EMIT*, y modelado por inversión atmosférica (*AERMOD*), mostró que las emisiones de metano de botaderos a cielo abierto presentan alta variabilidad temporal y espacial, con plumas que dispersan rápidamente en la troposfera y alcanzan zonas urbanas adyacentes.

El metano posee una vida media atmosférica prolongada y alta movilidad vertical y horizontal, lo que provoca la dilución de su concentración cerca de la fuente emisora y dificulta su detección puntual mediante sensores de resolución media como *TROPOMI* [24]. Incluso con sistemas de captura y combustión, Silva et al. observaron emisiones fugitivas que se dispersan en plumas extensas, generando concentraciones promedio del orden de 3-35 ppm a distancias variables del foco emisor. La señal resultante, más representativa de un campo regional que de una fuente puntual, limita la capacidad de correlacionar  $CH_4$  con

coordenadas espaciales específicas de botaderos a cielo abierto individual.

#### 5.4.2. Fuentes de datos atmosféricos satelitales

Las principales fuentes de observación atmosférica empleadas en este estudio provienen de plataformas satelitales y servicios de monitoreo global:

- *Sentinel-5P (TROPOMI)* ofrece observaciones diarias de gases traza como  $NO_2$  y  $CO$ , con una resolución espacial aproximada de  $7 \times 3.5$  km
- *Copernicus Atmosphere Monitoring Service (CAM5)* proporciona campos modelados de  $PM_{10}$  y  $PM_{2.5}$  con cobertura global y resolución horaria, útiles para complementar la información espectral y atmosférica de superficie.
- Las series temporales y composiciones se procesan mediante *Google Earth Engine (GEE)*, permitiendo la extracción geoespacial sincronizada de variables atmosféricas con las coordenadas de interés.

De forma paralela, las imágenes *RGB* utilizadas para la clasificación visual se obtienen mediante la *Google Maps Static API*, la cual permite descargar la imagen más reciente disponible para cada coordenada, garantizando así la actualización continua de los datos de superficie y una cobertura homogénea en todo el territorio analizado.

#### 5.4.3. Integración de datos satelitales y atmosféricos en modelos de IA

La integración entre información visual y variables atmosféricas se basa en un enfoque de fusión multimodal que combina características de distintas dimensiones dentro de un mismo marco de aprendizaje profundo. En esta arquitectura, las representaciones derivadas de imágenes satelitales son procesadas mediante una red convolucional, mientras que los contaminantes atmosféricos se introducen como vectores numéricos en una red densa (MLP). Ambas ramas se fusionan en una capa conjunta que aprende relaciones no lineales entre patrones visuales y condiciones atmosféricas locales.

Este tipo de integración ha mostrado un alto potencial para el monitoreo y la detección temprana de actividad emisora, como la quema de residuos o la acumulación de material particulado [23]. A escala global, la combinación de imágenes satelitales y métricas atmosféricas permite establecer correlaciones espaciales robustas entre la presencia de botaderos y la degradación de la calidad del aire, contribuyendo a sistemas de vigilancia automatizados y escalables para la gestión de residuos sólidos.

#### 5.4.4. Contenerización y despliegue con *Docker*

La contenerización es una técnica que permite empaquetar aplicaciones, dependencias, librerías y configuraciones dentro de entornos aislados denominados contenedores. Estos comparten el núcleo del sistema operativo de la máquina anfitriona, utilizando sus recursos

disponibles mientras mantienen aislamiento operativo. Esto facilita la portabilidad y reproducibilidad del entorno en distintas plataformas. Un contenedor puede ejecutarse de manera consistente en cualquier máquina que soporte su ejecución. Estas características han convertido a los contenedores de *Docker* en un estándar ampliamente adoptado para el despliegue de entornos reproducibles, tanto en investigación como en aplicaciones industriales [25].

Desde la perspectiva científica, *Docker* aborda problemas de reproducibilidad que han existido históricamente en experimentos computacionales, tales como documentación imprecisa, degradación del código o cambios en las versiones de dependencias. Boettiger (2015) destaca que, al combinar virtualización a nivel de sistema operativo, versionamiento modular y automatización mediante el archivo *Dockerfile*, *Docker* permite reconstruir el entorno de ejecución de manera exacta, transparente y replicable, incluso años después de desarrollados los experimentos originales [25].

En investigaciones basadas en modelos de inteligencia artificial, la contenerización es esencial para garantizar consistencia entre plataformas. La reproducibilidad en el aprendizaje automático se ve afectada por diferencias en hardware, librerías, versiones de frameworks y configuraciones del entorno computacional. Kopeinik et al. (2024) identifican la virtualización y la contenerización como impulsores tecnológicos clave para la reproducibilidad. El empaquetamiento de código, dependencias y configuraciones en un entorno portátil reduce la variabilidad asociada a la ejecución en distintos sistemas y facilita compartir de entornos listos para ser utilizados [26].

En el caso particular de sistemas de teledetección y modelos multimodales, *Docker* permite encapsular el modelo entrenado, los módulos de preprocesamiento, los scripts de inferencia y las dependencias de frameworks como PyTorch dentro de un contenedor. Esto no solo garantiza que el sistema funcione correctamente en cualquier máquina, sino que también facilita su integración mediante APIs y automatiza el despliegue en servidores locales o en la nube. La contenerización se convierte así en un componente fundamental para garantizar la reproducibilidad, portabilidad y mantenibilidad del sistema de detección propuesto.

El principal objetivo de este trabajo fue el desarrollo de un sistema automatizado capaz de identificar botaderos a cielo abierto en Guatemala combinando imágenes satelitales con información atmosférica mediante el uso de modelos de inteligencia artificial. Para lograr esto, el trabajo fue dividido en tres objetivos que guiaron esta metodología: (1) la integración de información espacial y atmosférica en un conjunto de datos unificado; (2) el diseño y entrenamiento de un algoritmo capaz de estimar la probabilidad de la presencia de un botadero a cielo abierto; y (3) la contenerización del modelo entrenado para su integración con sistemas y plataformas para el monitoreo nacional.

### **6.1. Integración de datos de imágenes satelitales y métricas atmosféricas**

#### **6.1.1. Sitios de referencia y generación de muestras negativas**

El Ministerio de Ambiente y Recursos Naturales (MARN), compartió un conjunto de 213 ubicaciones de botaderos a cielo abierto municipales oficialmente reconocidos a los cuales se les asignó la clase positiva (etiqueta = 1). Con tal de obtener un conjunto de datos balanceado, se generaron 250 puntos negativos (etiqueta = 0), dentro de los límites geográficos de Guatemala. Estos puntos fueron distribuidos proporcionalmente con el área de cada municipio para mantener representación geográfica. Adicionalmente, se utilizó un búfer de exclusión 0.5 km alrededor de los puntos reconocidos para evitar superposición entre muestras positivas y negativas. Cada punto fue validado para asegurar su ubicación dentro de los límites municipales y fuera de cualquier búfer de exclusión antes de ser incluidos en el conjunto de datos completo.

### 6.1.2. Adquisición de imágenes satelitales

En cada coordenada del conjunto de datos completo, se obtuvo una imagen satelital RGB de 640 x 640 pixeles, obtenida desde *Google Maps Static API*. Cada imagen fue recolectada con un nivel de *zoom* x20, y el tipo de mapa se colocó como satelital para así asegurar un alto detalle espacial y consistencia entre las muestras. A este nivel de resolución, cada píxel representa aproximadamente 0.11 m, de modo que cada recorte cubre un área aproximada de 70x70m ( $\approx 0.5ha$ ). Cada imagen fue almacenada en formato PNG y luego preprocesada para su ingesta por el modelo.

### 6.1.3. Recolección de datos atmosféricos

La información para las variables atmosféricas fue extraída de los repositorios en *Google Earth Engine (GEE)*, que almacenan datos de *Copernicus Sentinel-5P* y *ECMWF CAMS (Near Real Time)*. Se utilizó una ventana de tiempo entre el 1 de enero de 2023 y el 31 de octubre de 2025, cubriendo así mediciones satelitales amplias lo más recientes posible al momento de trabajo. En cada muestra, se obtuvo el promedio de concentración del contaminante en un radio de 5 km en un área circular centrada en el punto de muestra. Los contaminantes incluidos fueron dióxido de nitrógeno ( $NO_2$ ), monóxido de carbono ( $CO$ ), material particulado menor de 2.5  $\mu m$  ( $PM_{2.5}$ ), material particulado menor de 10  $\mu m$  ( $PM_{10}$ ). En el caso de  $PM_{2.5}$  y  $PM_{10}$  se utilizó un periodo empezando 180 días antes de la fecha final de recolección, es decir, en este caso la fecha final fue 31 de octubre de 2025, la fecha inicial fue 4 de mayo de 2025. Esto debido a la alta cantidad de información obtenida desde *ECMWF CAMS* que no ha sido previamente procesada, generado problemas de procesamiento desde el servidor de *GEE* para el procesamiento requerido.

Todas las concentraciones fueron convertidas a unidades consistentes con los sistemas de análisis atmosféricos

Se realizó un análisis dimensional con el fin de tener un valor con alta practicidad. En el caso de las variables  $NO_2$  y  $CO$ , estas son retornadas por el sistema *GEE* como  $mol/m^2$ , luego son multiplicadas por  $1000mmol/mol$  para trabajar sobre la unidad  $mmol/m^2$ . Mientras que, las variables  $PM_{10}$  y  $PM_{2.5}$  son retornadas como  $kg/m^3$  son multiplicadas por  $1e - 9\mu g/kg$  para trabajar sobre la unidad  $\mu g/m^3$ .

### 6.1.4. Ensamblado del conjunto de datos y partición

Dentro de un registro estructurado se guardó la información de cada muestra, su imagen, coordenadas geográficas, municipalidad, mediciones atmosféricas y etiqueta clasificadora. Posterior a esto, el conjunto de datos, compuesto por 463 muestras, fue dividido en subconjuntos de entrenamiento 80 % y prueba 20 %, manteniendo el balance de clases con una división estratificada y una semilla de aleatoriedad fija. Estos subconjuntos se exportaron en formato *JSON* para su utilización en las etapas consecutivas.

### 6.1.5. Preprocesamiento

Se utilizó un tensor de imágenes para redimensionar y normalizar cada imagen con tal de ser compatible con *ImageNet* según la media y la desviación estándar de cada canal de entrada. En el caso de las variables atmosféricas, se normalizaron utilizando una estandarización de la puntuación  $z$  calculada en base al conjunto de datos de entrenamiento. Esta normalización se aplicó al conjunto de prueba y validación.

## 6.2. Algoritmo de estimación de probabilidad de botadero a cielo abierto

### 6.2.1. Rama visual basada en arquitectura ResNet50-FPN

El componente visual de este sistema está basado en un sistema integrado por un *ResNet50* y una red piramidal de características. Esta arquitectura genera como salida una probabilidad sigmoide que representa la probabilidad de que la imagen del análisis contenga un botadero a cielo abierto.

### 6.2.2. Rama atmosférica

La información de las variables atmosféricas obtenida, compuesta por  $NO_2$ ,  $CO$ ,  $PM_{2.5}$  y  $PM_{10}$  se procesaron mediante un perceptrón multicapa, obteniendo una representación latente compacta. Cada variable fue normalizada antes de entrar a esta red, con tal de asegurar la homogeneidad en la escala.

### 6.2.3. Red de fusión multimodal

Se integraron los resultados de las ramas, concatenando la probabilidad sigmoide de la rama visual con el vector resultante de la rama atmosférica. El resultante es un tensor que se procesa por una red de fusión compuesta por tres capas completamente conectadas (256, 64 y 1 neuronas), el resultado es un *logit* al cual se le aplica una función sigmoide que proporciona la probabilidad de presencia de un botadero a cielo abierto.

### 6.2.4. Proceso de entrenamiento y evaluación

El modelo completo fue entrenado siguiendo un proceso de dos etapas con una estrategia de ajuste fino. Durante la primera etapa, se congeló la rama visual para así únicamente entrenar la rama atmosférica y la red de fusión. En la segunda etapa, todos los parámetros se descongelaron y fueron optimizados utilizando una tasa de aprendizaje baja. Se utilizó una función de pérdida *Binary Cross-Entropy with Logits*. El rendimiento se midió utilizando precisión, exactitud, recuperación, el *F1-Score*, y la curva AUC-ROC, así como una matriz de confusión.

El umbral seleccionado fue de 0.5 para clasificar las predicciones. Además, se implementó un *Early stopping* y mecanismos de guardado para evitar sobreajuste y convergencia estable.

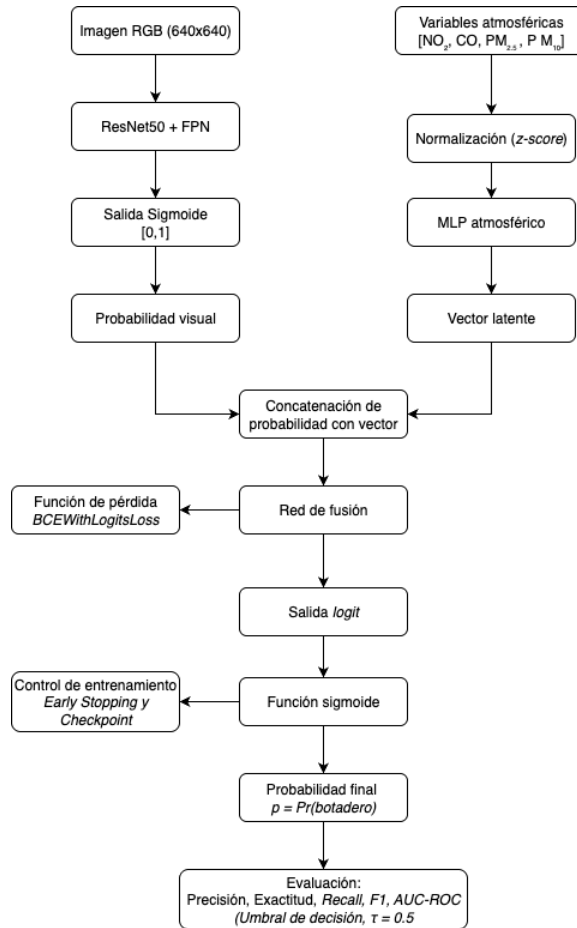


Figura 1: Flujo general del algoritmo multimodal para estimar la probabilidad de presencia de botadero a cielo abierto

La Figura 1 muestra el flujo general del modelo, desde la entrada de la imagen satelital en la rama visual, la entrada de información atmosférica para el punto de interés, su respectivo procesamiento en la rama indicada, luego la capa de fusión que devuelve la probabilidad final que para el punto de interés exista la presencia de un botadero a cielo abierto.

### 6.3. Contenerización y servicio de inferencia

Una vez entrenado el modelo, se utilizó el *framework* de *FastAPI* para *Python*, con el cual se desarrolló un servicio capaz de cargar el modelo entrenado y generar inferencias a partir de una imagen y valores para las variables atmosféricas. El servicio expone tres *endpoints*:

- GET /live que verifica la salud del sistema, si este se encuentra encendido y esperando

mensajes.

- `POST /predict` toma un mensaje JSON conteniendo una imagen codificada en base64 y los valores para las variables ambientales.
- `POST /predict-multipart` toma un mensaje en *form-data* conteniendo el archivo de la imagen y los valores para las variables ambientales.

Las respuestas de las rutas de inferencia tienen una respuesta estructurada con la probabilidad estimada (`prob`) y el valor binario de predicción (0 ó 1), determinado por defecto mediante el umbral 0.5.

Este servicio, incluyendo las dependencias necesarias para cargar el modelo, realizar inferencias y montar el servicio; se contenerizaron en una imagen de *Docker* para garantizar la reproducibilidad del servicio e integración con servicios externos.

## 6.4. Reproducibilidad y consideraciones éticas

Estos experimentos deben mantenerse concorde con los parámetros fijados para asegurar la reproducibilidad:

- Búfer de exclusión de 0.5 km entre muestras positivas y negativas.
- Nivel de *zoom* 20 en las imágenes satelitales con tamaño 640x640.
- 5 km como área de interés sobre cada punto muestra en la recolección de información atmosférica.
- Periodo temporal con fecha inicial en 01 de enero de 2023 y fecha final en 31 de octubre de 2025 para las variables atmosféricas, en el caso de  $PM_{2.5}$  y  $PM_{10}$  la fecha inicial es 04 de mayo de 2025.
- División estratificada 80/20 entre los conjuntos de entrenamiento y prueba.
- Umbral de decisión en 0.5.

Esta metodología completa puede ser reproducida completamente en *Python* utilizando *PyTorch* para los modelos de inteligencia artificial y servicios de *Google* como *Google Earth Engine* y *Google Maps Static API* para la recolección de información.

Se debe tomar en consideración la confidencialidad del conjunto de datos con las coordenadas geográficas de los botaderos a cielo abierto municipales oficialmente reconocidos, la cual fue provista exclusivamente para su uso dentro de este trabajo con propósitos de investigación. Debido a esto, no se comparte la información específica de las muestras positivas utilizadas en el entrenamiento. El resultado del modelo al ser una probabilidad tiene la intención de apoyar el monitoreo ambiental y toma de decisiones, pero no de constituir una verdad absoluta.

## 7.1. Resultados de la integración de datos de imágenes satelitales y métricas atmosféricas

El proceso de integración de datos generó un conjunto de 463 muestras georreferenciadas, compuesto por 213 puntos positivos correspondientes a los botaderos a cielo abierto oficialmente y 250 puntos negativos generados aleatoriamente dentro de los límites municipales de Guatemala. Cada muestra contiene una imagen satelital RGB y cuatro variables atmosféricas: dióxido de nitrógeno ( $NO_2O$ ), monóxido de carbono ( $CO$ ), material particulado menor a 10 micrómetros ( $PM_{10}$ ) y material particulado menor a 2.5 micrómetros ( $PM_{2.5}$ ).

Las variables atmosféricas contienen el promedio de concentración del contaminante en un radio de 5 km en un área circular centrada en el punto de muestra. Las mediciones de  $NO_2$  y  $CO$  se obtuvieron en  $mmol/m^2$  a partir del repositorio *Sentinel-5P OFFL* para el contaminante específico. En cambio, las mediciones de  $PM_{10}$  y  $PM_{2.5}$  se obtuvieron del repositorio *Copernicus Atmosphere Monitoring Service (CAMS) Global Near-Real Time* en  $\mu g/m^3$ . Cada registro fue almacenado en formato *JSON*, tal como se muestra en el siguiente ejemplo de una muestra negativa:

Listing 7.1: Ejemplo de estructura de registro en formato JSON

```
{
  "image": "img_15.406402_-91.769784.png",
  "lat": 15.4064015793,
  "lon": -91.7697835751,
  "municipio": "Muni_89",
  "atmospheric": {
    "NO2": 0.0497,
```

```

"CO": 25.8929,
"PM10": 19.127,
"PM2.5": 17.522
},
"label": 0
}

```

## 7.2. Análisis exploratorio de las métricas atmosféricas

Se examinó la relación entre las variables atmosféricas y la etiqueta clasificadora, se calculó la matriz de correlación de Pearson, presentada en la Figura 2.

	Etiqueta	PM10 ( $\mu\text{g}/\text{m}^3$ )	PM2.5 ( $\mu\text{g}/\text{m}^3$ )	NO2 ( $\text{mmol}/\text{m}^2$ )	CO ( $\text{mmol}/\text{m}^2$ )
Etiqueta	1.00	0.54	0.54	0.27	-0.29
PM10 ( $\mu\text{g}/\text{m}^3$ )	0.54	1.00	1.00	0.64	-0.34
PM2.5 ( $\mu\text{g}/\text{m}^3$ )	0.54	1.00	1.00	0.63	-0.36
NO2 ( $\text{mmol}/\text{m}^2$ )	0.27	0.64	0.63	1.00	0.18
CO ( $\text{mmol}/\text{m}^2$ )	-0.29	-0.34	-0.36	0.18	1.00

Figura 2: Matriz de correlación entre las variables atmosféricas y la etiqueta clasificadora

La matriz muestra valores positivos para la correlación entre  $PM_{10}$  y  $PM_{2.5}$  con respecto a la etiqueta ( $r = 0.54$ ). Al mismo tiempo, El  $CO$  presenta una correlación negativa, no solo con la etiqueta ( $r = -0.29$ ), sino también con las variables del material particulado ( $r = [-0.36, -0.34]$ ), teniendo una correlación débil con el  $NO_2$  ( $r = 0.18$ ). En el caso de esta última variable atmosférica, tiene una correlación débil con la etiqueta ( $r = 0.27$ ), pero con las variables del material particulado es moderada ( $r = 0.63-0.64$ ).

### 7.2.1. Distribución de las variables atmosféricas

Las Figuras 3 a 6 presentan la distribución de las variables atmosféricas diferenciadas por clase, donde las barras rojas corresponden a las muestras positivas y las barras azules a las muestras negativas. Estas distribuciones se realizaron sobre el conjunto completo de muestras.

La distribución del  $NO_2$  presenta valores concentrados en rangos bajos de concentración, con una dispersión hacia valores medios en ambas clases, no presenta tendencias distintas por clase.




Figura 3: Distribución del dióxido de nitrógeno ( $NO_2$ ) para muestras positivas (barras rojas), y negativas (barras azules)




Figura 4: Distribución del monóxido de carbono ( $CO$ ) para muestras positivas (barras rojas), y negativas (barras azules)




Figura 5: Distribución del material particulado menor a 10 micrómetros ( $PM_{10}$ ) para muestras positivas (barras rojas), y negativas (barras azules)




Figura 6: Distribución del material particulado menor a 2.5 micrómetros ( $PM_{2.5}$ ) para muestras positivas (barras rojas), y negativas (barras azules)

La distribución del  $CO$  presenta valores concentrados en rangos intermedios de concentración, con una dispersión hacia valores altos en ambas clases, no presenta tendencias distintas por clase.

Las variables  $PM_{10}$  y  $PM_{2.5}$  presentan distribuciones similares, con valores predominantes en rangos bajos e intermedios de concentración.

Adicionalmente, en el *Anexo A* se presentan ejemplos visuales de los puntos de interés utilizados en este estudio, donde se incluyen imágenes satelitales representativas de las clases positiva y negativa, no se incluye su ubicación geográfica.

### 7.3. Resultados del algoritmo de estimación de probabilidad de botadero a cielo abierto

#### 7.3.1. Desempeño del modelo base (visual)

El modelo base, entrenado con el conjunto de imágenes AerialWaste mediante la arquitectura *ResNet50-FPN (CAM\_PRED)*, obtuvo las siguientes métricas de evaluación calculadas sobre el conjunto de prueba se presentan en el Cuadro 2.

Cuadro 2: Métricas de desempeño del modelo base (solo visual), sobre el conjunto de prueba

Métricas	Valor
Exactitud ( <i>Accuracy</i> )	0.7097
Precisión ( <i>Precision</i> )	1.000
Sensibilidad ( <i>Recall</i> )	0.3721
<i>F1-Score</i>	0.5424
<i>ROC-AUC</i>	0.6326

La matriz de confusión correspondiente se muestra en el Cuadro 3.

Cuadro 3: Matriz de confusión del modelo base

		Etiqueta real		Total
		Botadero a cielo abierto (1)	No botadero (0)	
Predicción	Botadero a cielo abierto (1)	16	0	16
	No botadero (0)	27	50	77
Total		43	50	93

### 7.3.2. Desempeño del modelo final (multimodal)

El modelo final integró la rama visual con una rama atmosférica compuesta por las variables  $NO_2$ ,  $CO$ ,  $PM_{10}$  y  $PM_{2.5}$ , además de una capa de fusión multimodal. Las métricas obtenidas se presentan en el Cuadro 4

Cuadro 4: Métricas de desempeño del modelo final (multimodal), sobre el conjunto de prueba

Métricas	Valor
Exactitud ( <i>Accuracy</i> )	0.6989
Precisión ( <i>Precision</i> )	0.7027
Sensibilidad ( <i>Recall</i> )	0.6047
<i>F1-Score</i>	0.6500
<i>ROC-AUC</i>	0.7344

La matriz de confusión correspondiente se muestra en el Cuadro 5.

Cuadro 5: Matriz de confusión del modelo final

		Etiqueta real		Total
		Botadero a cielo abierto (1)	No botadero (0)	
Predicción	Botadero a cielo abierto (1)	26	11	37
	No botadero (0)	17	39	56
Total		43	50	93

### 7.3.3. Distribución de probabilidades de salida

Las Figuras 7 y 8 muestran la distribución de probabilidades obtenidas por el modelo base y el modelo final respectivamente, separadas por clase.




Figura 7: Distribución de probabilidades del modelo base, barras rojas son clase positiva y barras azules son clase negativa




Figura 8: Distribución de probabilidades del modelo final, barras rojas son clase positiva y barras azules son clase negativa

### 7.3.4. Correlación con variables atmosféricas

La Figura 9 presenta la matriz de correlación entre la probabilidad dada en cada muestra del conjunto de prueba por el modelo final (multimodal), en relación con las variables atmosféricas utilizadas. Se observa una correlación positiva entre la probabilidad del modelo y las variables  $PM_{10}$ ,  $PM_{2.5}$  y  $NO_2$ , mientras que la correlación con  $CO$  es negativa.

	Probabilidad Modelo Final	PM10 ( $\mu\text{g}/\text{m}^3$ )	PM2.5 ( $\mu\text{g}/\text{m}^3$ )	NO2 ( $\text{mmol}/\text{m}^2$ )	CO ( $\text{mmol}/\text{m}^2$ )
Probabilidad Modelo Final	1.00	0.61	0.61	0.55	-0.13
PM10 ( $\mu\text{g}/\text{m}^3$ )	0.61	1.00	1.00	0.72	-0.36
PM2.5 ( $\mu\text{g}/\text{m}^3$ )	0.61	1.00	1.00	0.71	-0.38
NO2 ( $\text{mmol}/\text{m}^2$ )	0.55	0.72	0.71	1.00	0.13
CO ( $\text{mmol}/\text{m}^2$ )	-0.13	-0.36	-0.38	0.13	1.00

Figura 9: Matriz de correlación del modelo final en relación con variables atmosféricas, en conjunto de datos de prueba

### 7.3.5. Comparación entre el modelo base y el modelo final

El diagrama de flujo de la Figura 10 resume los cambios en las predicciones entre el modelo base y el modelo final. Esto para el conjunto de prueba.

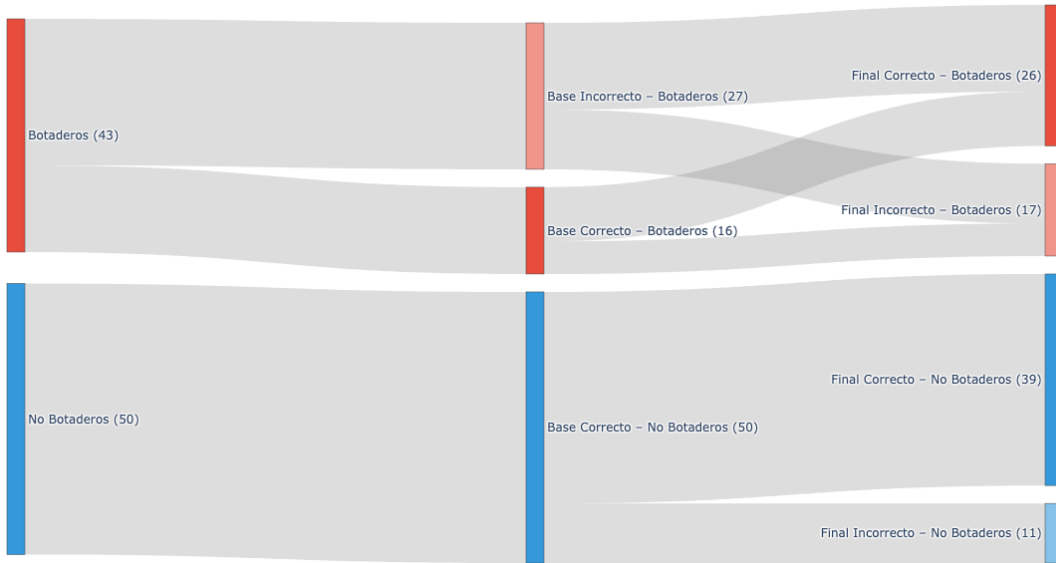


Figura 10: Comparación de resultados entre el modelo base y el modelo final mediante diagrama de flujo

Este diagrama de flujo muestra el cambio de resultados entre el modelo base y el modelo final. Este diagrama de flujo se acompaña con el Cuadro 6 y el Cuadro 7.

Cuadro 6: Comparación de resultados de predicción entre modelo base y modelo final para muestras de botaderos a cielo abierto

		Predicción de Modelo Base		Total
		Correcta	Incorrecta	
Predicción de Modelo Final	Correcta	10	16	26
	Incorrecta	6	11	17
Total		16	27	43

Cuadro 7: Comparación de resultados de predicción entre modelo base y modelo final para muestras que no son botaderos a cielo abierto

		Predicción de Modelo Base		Total
		Correcta	Incorrecta	
Predicción de Modelo Final	Correcta	39	0	39
	Incorrecta	11	0	11
Total		50	0	50

En las muestras de botaderos a cielo abierto, el modelo final incrementó el número de aciertos en 10 casos netos (16 aciertos nuevos, 6 aciertos perdidos y 10 aciertos mantenidos). En las muestras que no son botaderos a cielo abierto, el modelo base acertó en todos los casos; el modelo final mantuvo 39 aciertos y registró 11 falsos positivos.

## 7.4. Resultados del proceso de contenerización y servicio de inferencia

El modelo final fue implementado como un servicio de inferencia utilizando el *framework* *FastAPI*. Este servicio expone las funcionalidades del modelo final para predecir sobre una imagen satelital y variables atmosféricas a través de una interfaz accesible mediante peticiones HTTP. La implementación se integró con una imagen de *Docker* para garantizar su portabilidad, reproducibilidad y despliegue en diferentes entornos.

### 7.4.1. Estructura del servicio

El servicio principal se definió en el archivo `main.py`, el cual inicializa una aplicación de *FastAPI* y expone tres rutas principales:

- GET `/live`: verifica el estado de la aplicación y confirma que el servicio se encuentra activo.
- POST `/predict`: recibe un mensaje en formato *JSON* que contiene la imagen codificada en base64 y los valores para las variables atmosféricas ( $NO_2$ ,  $CO$ ,  $PM_{2.5}$ ,  $PM_{10}$ ). Retorna la probabilidad inferida por el modelo y la etiqueta clasificadora según el umbral de decisión, que corresponde a la predicción del modelo.
- POST `/predict-multipart`: permite la inferencia mediante el envío de una imagen en formato *form-data* junto con los valores numéricos de las variables atmosféricas. Tiene el mismo propósito que la ruta anterior, únicamente cambia la forma de recepción de información.

Las funciones de predicción, definidas en el módulo `model_runtime.py`, realizan la carga del modelo final (multimodal), previamente entrenado, aplican las transformaciones de preprocesamiento requeridas y ejecutan la inferencia de manera automática. Los valores de normalización atmosférica son cargados desde un archivo `.npz`, y el modelo se inicializa con los pesos finales obtenidos en la fase de entrenamiento. El servicio es compatible tanto con CPU como con GPU y permite ajustar el umbral de decisión ( $\tau = 0.5$ ) a través de variables de entorno.

### 7.4.2. Contenerización del sistema

El servicio se contenerizó mediante un archivo `Dockerfile`. La imagen generada incluye las dependencias requeridas (*Python*, *PyTorch*, *FastAPI*, *Uvicorn* y librerías auxiliares), luego copia los archivos del modelo y de configuración al contenedor. Una vez haya terminado esto, se puede realizar el despliegue del contenedor donde, los pesos del modelo y las estadísticas de normalización se montan como volúmenes de solo lectura para evitar modificaciones no deseadas.

El servicio puede iniciarse mediante los comando:

Listing 7.2: Comando de ejecución del servicio Dockerizado.

```
docker run --rm -p 8000:8000 \  
  --env-file ./env \  
  -v /ruta/absoluta/a/modelos:/models:ro \  
  ecomentat-api
```

### 7.4.3. Pruebas de validación

Se desarrolló un conjunto de pruebas automatizadas utilizando el módulo `pytest` que verifica el correcto funcionamiento de las rutas del servicio. Las pruebas se encuentran definidas en el archivo `test_api.py`, se validan las respuestas esperadas de cada ruta y la estructura de los datos retornados.

- La prueba `test_live()` confirma que la ruta `/live` responde con un código 200 y un valor lógico “ok”: `true`.
- La prueba `test_predict_json()` envía una imagen simulada codificada en base64 junto con un conjunto de valores atmosféricos y verifica que la respuesta incluya los campos `prob` y `label`.
- La prueba `test_predict_multipart()` ejecuta el mismo procedimiento utilizando el método `multipart/form-data`.

En este estudio se evaluó un sistema para identificar botaderos a cielo abierto en Guatemala a partir de la integración de imágenes satelitales RGB y métricas atmosféricas. Se compararon dos configuraciones de modelo: (i) un modelo base entrenado con la arquitectura *ResNet50-FPN* sobre el conjunto de datos *AerialWaste*, este tiene un carácter completamente visual y (ii) un modelo final multimodal que incorpora al modelo base, cuatro variables atmosféricas ( $NO_2$ ,  $CO$ ,  $PM_{10}$  y  $PM_{2.5}$ ), y una capa de fusión. Los resultados muestran diferencias importantes en el comportamiento de las probabilidades y en el equilibrio entre precisión y sensibilidad, esto tiene implicaciones directas en el monitoreo asistido por revisión humana.

Al analizar el conjunto de datos generado, este integra 463 muestras con un balance geográfico y separación espacial explícita entre muestras positivas (botadero a cielo abierto), y negativas. El análisis exploratorio evidenció asociaciones consistentes entre las variables atmosféricas y la etiqueta clasificadora (Figura 2). En particular, las variables  $PM_{10}$  y  $PM_{2.5}$  muestran correlaciones positivas medias con las muestras positivas ( $r \approx 0.54$ ), mientras que  $NO_2$  muestra una correlación débil ( $r \approx 0.27$ ), y  $CO$  una correlación negativa leve ( $r \approx -0.29$ ). Este patrón se replica al correlacionar la probabilidad del modelo final con las mismas variables, lo cual sugiere que el algoritmo multimodal logró internalizar relaciones coherentes con la estructura estadística del conjunto.

En cuanto al desempeño de los modelos, el modelo base mostró un comportamiento conservador. En el conjunto de prueba obtuvo una exactitud de 0.7097, precisión 1.0000, sensibilidad 0.3721, *F1-Score* 0.5424 y *ROC-AUC* 0.6326 (Cuadro 2). La matriz de confusión correspondiente indica ausencia de falsos positivos y una proporción relevante de falsos negativos, esto implica que el modelo acierta cuando asigna una etiqueta positiva, pero omite una fracción notable de botaderos a cielo abierto reales. En la distribución de este modelo se refleja este comportamiento (Figura 7), donde la gran mayoría de los casos son otorgados una probabilidad inferior a 0.1. Entre una probabilidad 0.0 y 0.1 se registran 50 muestras

negativas y 22 positivas, el resto de las activaciones se encuentran casi siempre por encima de 0.5 que es el umbral de decisión. Esto sugiere que el modelo tiene una subactivación del clasificador, donde el modelo desplaza probabilidades hacia el centro poco, pero cuando lo hace típicamente acierta, en el caso del conjunto de prueba únicamente lo hace para un 37 % de las muestras positivas.

El modelo final incorpora la rama atmosférica y una capa de fusión entre el resultado de la rama visual y atmosférica para así dar una probabilidad y predicción sobre las imágenes y variables atmosféricas. En el conjunto de prueba, reportó una exactitud de 0.6989, precisión 0.7027, sensibilidad 0.6047, *F1-Score* 0.6500 y *ROC-AUC* 0.7344 (Cuadro 4). La matriz de confusión evidencia que aumento el número de verdaderos positivos (26/43), aunque introdujo 11 falsos positivos en la clase negativa. El cambio más notable se observa en la distribución de probabilidades (Figura 8), que pasa de ser extremadamente sesgada hacia probabilidades cercanas a 0 a una distribución más central. En cuanto a las muestras positivas, estas en su mayoría se encuentran en el rango de probabilidad entre 0.4 y 0.7, mientras que las negativas también se ubican mayoritariamente en el rango 0.4–0.5 (37 casos). Este recentrado de probabilidades muestra una mejor calibración relativa para el contexto de Guatemala. Este modelo mueve un número considerable de casos de un rango menor a 0.1 hacia probabilidades intermedias. Esto puede permitir que se asigne un umbral operativo que facilite la revisión (por ejemplo, zona de revisión 0.4–0.6 y zona de alerta  $> 0.6$ ). En términos comparativos, el diagrama de flujo (Figura 10), muestra que el modelo final convierte una proporción relevante de falsos negativos del modelo base en verdaderos positivos (16 casos), mantiene 10 aciertos y pierde 6; en cuanto a la clase negativa conserva 39 verdaderos negativos e introduce 11 falsos positivos. El incremento neto en *F1-score* (+0.108) y en *ROC-AUC* (+0.102), con una variación marginal en exactitud, es consistente con un re-balance entre precisión y sensibilidad cuando la prioridad es reducir omisiones sobre la clase de interés. Esto quiere decir que el modelo final muestra un mejor balance en cuanto a la clasificación, deja de ser conservador para evitar falsos negativos que en temas reales, podrían ser botaderos a cielo abierto sin detectar.

Se podría decir que el modelo base opera como un detector de alta precisión pero baja sensibilidad, fuertemente sesgado a probabilidades cercanas a cero, mientras que el modelo final ofrece un perfil de probabilidades balanceado y mejor recuperación, conservando precisión operable. Esto es particularmente pertinente para flujos que incorporan estas predicciones dentro del monitoreo y como apoyo a la toma de decisiones. En un sistema donde se reportan puntos de interés, estas probabilidades permiten rápidamente validar tanto la presencia de un botadero a cielo abierto, así como el comportamiento promedio de contaminantes atmosféricos alrededor del área. Se complementaría grandemente de la validación humana, donde un operador sea el que asigne la etiqueta clasificadora en base a la probabilidad en base a la información provista.

Desde la perspectiva de integración y despliegue, la implementación del servicio de inferencia mediante *FastAPI* y *Docker* asegura la portabilidad y reproducibilidad del sistema. Las rutas del sistema facilitan la incorporación con sistemas externos y asegura su funcionamiento tanto en dispositivos que cuentan con *GPU* como aquellos que no, el tiempo de respuesta dependerá de las capacidades del sistema. La contenerización del sistema permite que esta metodología se traduzca en una herramienta estable, auditable y escalable para propósitos de monitoreo ambiental.

El objetivo de este estudio fue implementar imágenes satelitales y mediciones atmosféricas para la detección de botaderos a cielo abierto en Guatemala. Esto se llevó a cabo con la integración de imágenes satelitales con mediciones atmosféricas georreferenciadas que se utilizaron para desarrollar un algoritmo que calcula la probabilidad de presencia de un botadero a cielo abierto utilizando modelos de inteligencia artificial. Finalmente, el sistema se contenerizó con el fin de garantizar la portabilidad y reproducibilidad del algoritmo de predicción y permitir su integración con sistemas de monitoreo a nivel nacional y futura integración con tecnologías complementarias.

La integración de información satelital y atmosférica permitió generar un conjunto de datos combinando imágenes satelitales de alta resolución con métricas atmosféricas derivadas de fuentes satelitales. El conjunto de datos generado contiene 463 muestras distribuidas en todo el territorio de Guatemala, fue construido con un enfoque espacialmente equilibrado manteniendo un búfer de exclusión de 0.5 km alrededor de cada punto positivo y una asignación proporcional de muestras negativas por área municipal. Este diseño permitió representar adecuadamente las condiciones geográficas y ambientales de Guatemala, evitando la redundancia espacial y asegurando balance entre las clases.

El análisis exploratorio de las variables atmosféricas muestra coherencia estadística con los patrones asociados a la presencia de botaderos a cielo abierto. Las concentraciones de  $PM_{10}$  y  $PM_{2.5}$  mostraron correlaciones positivas medias con las muestras positivas ( $r \approx 0.54$ ), mientras que  $NO_2$  mostró una correlación débil positiva ( $r \approx 0.27$ ), y  $CO$  una correlación negativa leve ( $r \approx -0.29$ ). Este comportamiento sugiere que las emisiones atmosféricas y la concentración de material particulado pueden actuar como indicadores indirectos de actividad antrópica. El enfoque multimodal es validado por la consistencia de estas relaciones, los contaminantes atmosféricos aportan contexto adicional al análisis visual, mejorando la discriminación entre sitios con botaderos a cielo abierto y áreas no intervenidas.

En cuanto al desempeño de los modelos, el modelo base (entrenado con el conjunto de imágenes satelitales *AerialWaste* y con una arquitectura basada en *ResNet50-FPN*), mos-

tró un comportamiento conservador con una alta precisión y baja sensibilidad, evidenciando una fuerte tendencia a omitir casos positivos. La distribución de probabilidades, concentrada casi por completo en valores inferiores a 0.1 muestran una subactivación del clasificador. Este modelo únicamente responde ante patrones visuales muy evidentes ya que no ha sido entrenado con información de Guatemala, por lo que su utilidad *out of the box* tiene limitada utilidad para tareas de monitoreo ambiental donde la detección de sitios potenciales es crucial.

El modelo final multimodal generado como parte del algoritmo que calcula la probabilidad de presencia de un botadero a cielo abierto incorpora con el modelo visual una rama que analiza las variables atmosféricas y mediante una capa de fusión provee una probabilidad sobre cada punto de interés. Esta arquitectura mostró una mejora importante en su capacidad predictiva. Obtuvo un aumento de más de 17 puntos porcentuales en sensibilidad y una mejora neta en el equilibrio entre precisión y recuperación. Además, concentró la distribución de probabilidades en valores intermedios (0.4 – 0.7), mostrando un perfil más calibrado y balanceado.

La comparación entre ambos modelos evidenció que el modelo final multimodal convierte una cantidad considerable de falsos negativos del modelo base en verdaderos positivos (16 casos adicionales de 43), manteniendo la mayoría de los aciertos previos. Aunque también aumenta la cantidad de falsos positivos, este resultado demuestra que el enfoque multimodal mejora la capacidad de detección y ofrece una representación más informativa del nivel de confianza en cada predicción. Esto facilita la priorización y validación manual de casos probables.

Finalmente, la implementación del sistema dentro de un servicio de inferencia basado en *FastAPI* y contenerización con *Docker* garantizan la reproducibilidad, portabilidad y estabilidad del flujo completo de detección. El servicio, validado mediante pruebas automatizadas con *pytest*, permite realizar inferencias tanto en formato *JSON* como *multipart/form-data*, procesando imágenes y variables atmosféricas de forma integrada. Su diseño modular permite la ejecución en entornos con GPU o CPU, y su estructura fácilmente desplegable asegura compatibilidad con plataformas de monitoreo ambiental y sistemas nacionales de gestión de datos.

Los resultados demuestran que la integración de imágenes satelitales y datos de contaminantes atmosféricos constituye una alternativa viable y eficiente para la identificación de botaderos a cielo abierto en Guatemala. El modelo final multimodal desarrollado representa una mejora importante con respecto al enfoque puramente visual, al no solo ofrecer probabilidades más calibradas y balanceadas que el modelo base, pero también permite el monitoreo atmosférico. Asimismo, la contenerización del sistema asegura su escalabilidad e integración a futuro con sistemas de monitoreo y vigilancia ambiental basadas en inteligencia artificial para Guatemala.

---

### Recomendaciones

---

A partir de los resultados obtenidos y del análisis realizado en este estudio, se proponen las siguientes recomendaciones orientadas a fortalecer el desarrollo, validación y aplicación futura del sistema de detección de botaderos a cielo abierto en Guatemala.

En primer lugar, se recomienda incrementar la cantidad de muestras positivas incluidas en el conjunto de datos, incorporando tanto sitios no oficiales de botaderos a cielo abierto reportados como aquellos identificados mediante observación remota. Asimismo, podría considerarse el uso del conjunto de datos *AerialWaste*, obteniendo las coordenadas geográficas de sus muestras para recopilar imágenes satelitales y métricas atmosféricas correspondientes. Este aumento en la diversidad y cantidad de datos permitiría validar de manera más robusta el desempeño del enfoque multimodal y cuantificar su capacidad de generalización a gran escala.

En segundo lugar, se sugiere integrar al sistema un módulo automatizado de recolección de información satelital y atmosférica. Esto podría lograrse mediante la incorporación de rutas adicionales al contenedor desarrollado, vinculadas directamente con servicios como *Google Earth Engine* y *Google Maps Static API*. De esta forma, el sistema podría actualizar periódicamente los datos, mantener la información vigente y facilitar el monitoreo continuo de nuevos puntos de interés en Guatemala.

En tercer lugar, se propone el desarrollo de una aplicación de apoyo para la visualización y revisión manual de resultados, que permita mostrar la imagen satelital, las métricas atmosféricas y la probabilidad estimada por el modelo para cada punto de interés. Esto aceleraría el proceso de validación humana y fortalecería la retroalimentación del sistema, facilitando la ampliación del conjunto de datos positivos y, en caso necesario, el reentrenamiento del modelo con información más actualizada.

Finalmente, se recomienda evaluar la viabilidad de utilizar imágenes satelitales de fuentes abiertas, como las proporcionadas por el programa *Copernicus*, particularmente mediante los satélites *Sentinel-2*. La integración de esta fuente permitiría desarrollar versiones del modelo y del sistema completamente libres de licencias comerciales, promoviendo su adopción a nivel

institucional y reduciendo los costos operativos asociados a la obtención de imágenes de alta resolución.

Estas acciones permitirían consolidar el sistema propuesto como una herramienta escalable, sostenible y de actualización continua, potenciando su utilidad para el monitoreo ambiental, la planificación territorial y la gestión sostenible de residuos sólidos en Guatemala.

- 
- [1] Ministerio de Ambiente y Recursos Naturales (MARN), *Acuerdo Gubernativo 281-2015: Política Nacional para la Gestión Integral de Residuos y Desechos Sólidos*, Documento oficial, Ciudad de Guatemala, 2015.
  - [2] S. L. Girón, J. C. Mateus y F. Méndez, “Impacto de un botadero a cielo abierto en el desarrollo de síntomas respiratorios y en costos familiares de atención en salud de niños entre 1 y 5 años en Cali, Colombia,” *Biomédica*, vol. 29, n.º 3, págs. 392-402, sep. de 2009. DOI: 10.7705/biomedica.v29i3.11.
  - [3] M. D. Vaverková, “Landfill Impacts on the Environment—Review,” *Geosciences*, vol. 9, n.º 10, pág. 431, 2019. DOI: 10.3390/geosciences9100431.
  - [4] M. A. Hannan, M. Abdulla Al Mamun, A. Hussain, H. Basri y R. A. Begum, “A review on technologies and their usage in solid waste monitoring and management systems: Issues and challenges,” *Waste Management*, vol. 43, págs. 509-523, 2015. DOI: 10.1016/j.wasman.2015.05.033.
  - [5] Ministerio de Ambiente y Recursos Naturales (MARN), *Guía para elaborar estudios de caracterización de residuos y desechos sólidos comunes*. Ciudad de Guatemala: Dirección para el Manejo de los Residuos y Desechos Sólidos, 2024.
  - [6] L. G. Papale, G. Guerrisi, D. De Santis, G. Schiavon y F. Del Frate, “Satellite Data Potentialities in Solid Waste Landfill Monitoring: Review and Case Studies,” *Sensors*, vol. 23, n.º 8, pág. 3917, 2023. DOI: 10.3390/s23083917.
  - [7] R. N. Torres y P. Fraternali, “Learning to Identify Illegal Landfills through Scene Classification in Aerial Images,” *Remote Sensing*, vol. 13, n.º 22, pág. 4520, 2021. DOI: 10.3390/rs13224520.
  - [8] R. N. Torres y P. Fraternali, “AerialWaste dataset for landfill discovery in aerial and satellite images,” *Scientific Data*, vol. 10, n.º 1, pág. 63, 2023. DOI: 10.1038/s41597-023-01976-9.
  - [9] C. Baron, M. Szigeti y G. Dikmener, “Illegal Dumpsite Detection Guatemala,” UNDP Istanbul Centre for Private Sector in Development, inf. téc., 2025.

- [10] S. Jutz y M. Milagro-Pérez, “Copernicus: the European Earth Observation Programme,” *Revista de Teledetección*, vol. 56, págs. 5-11, 2020. DOI: 10.4995/raet.2020.14346.
- [11] J.-N. Thépaut, D. Dee, R. Engelen y B. Pinty, “The Copernicus Programme and its Climate Change Service,” en *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, 2018, págs. 1591-1593. DOI: 10.1109/IGARSS.2018.8518067.
- [12] Ministerio de Ambiente y Recursos Naturales (MARN), *Reglamento para la Gestión Integral de los Residuos y Desechos Sólidos Comunes, Acuerdo Gubernativo 164-2021*. Ciudad de Guatemala: Dirección para el Manejo de los Residuos y Desechos Sólidos, 2023.
- [13] D. E. Schraufnagel et al., “Air Pollution and Noncommunicable Diseases,” *Chest*, vol. 155, n.º 2, págs. 409-416, feb. de 2019. DOI: <https://doi.org/10.1016/j.chest.2018.10.042>.
- [14] Z. Liu, U. Bhandaram y N. Garg, “Quantifying spatial under-reporting disparities in resident crowdsourcing,” *Nature Computational Science*, vol. 4, n.º 1, págs. 57-65, dic. de 2023, ISSN: 2662-8457. DOI: 10.1038/s43588-023-00572-6. dirección: <http://dx.doi.org/10.1038/s43588-023-00572-6>.
- [15] I. Goodfellow, Y. Bengio y A. Courville, *Deep learning*. The MIT Press, 2017.
- [16] Y. LeCun, Y. Bengio y G. Hinton, “Deep learning,” *Nature*, vol. 521, n.º 7553, págs. 436-444, mayo de 2015. DOI: 10.1038/nature14539.
- [17] P. Fraternali, L. Morandini y S. L. Herrera González, “Solid waste detection, monitoring and mapping in Remote Sensing Images: A survey,” *Waste Management*, vol. 189, págs. 88-102, dic. de 2024. DOI: 10.1016/j.wasman.2024.08.003.
- [18] Y. Li, H. Zhang, X. Xue, Y. Jiang y Q. Shen, “Deep Learning for Remote Sensing Image Classification: A Survey,” *WIREs Data Mining and Knowledge Discovery*, vol. 8, n.º 6, mayo de 2018. DOI: 10.1002/widm.1264.
- [19] K. He, X. Zhang, S. Ren y J. Sun, “Deep residual learning for image recognition,” *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, págs. 770-778, jun. de 2016. DOI: 10.1109/cvpr.2016.90.
- [20] C. Cui et al., “Deep multimodal fusion of image and non-image data in disease diagnosis and prognosis: A Review,” *Progress in Biomedical Engineering*, vol. 5, n.º 2, pág. 022001, abr. de 2023. DOI: 10.1088/2516-1091/acc2fe.
- [21] M. Sokolova y G. Lapalme, “A systematic analysis of performance measures for classification tasks,” *Information Processing and Management*, vol. 45, n.º 4, págs. 427-437, jul. de 2009. DOI: 10.1016/j.ipm.2009.03.002.
- [22] M. A. Wulder et al., “Current status of landsat program, science, and applications,” *Remote Sensing of Environment*, vol. 225, págs. 127-147, mayo de 2019. DOI: 10.1016/j.rse.2019.02.015.
- [23] X. Sun et al., “Revealing influencing factors on global waste distribution via deep-learning based dumpsite detection from satellite imagery,” *Nature Communications*, vol. 14, n.º 1, mar. de 2023. DOI: 10.1038/s41467-023-37136-1.

- [24] T. A. Silva et al., “Landfill methane emission: A case study using inversion methods, satellite and CRDS-based observations,” *Frontiers in Earth Science*, vol. 13, abr. de 2025. DOI: 10.3389/feart.2025.1549385.
- [25] C. Boettiger, “An introduction to docker for reproducible research,” *ACM SIGOPS Operating Systems Review*, vol. 49, n.º 1, págs. 71-79, ene. de 2015. DOI: 10.1145/2723872.2723882.
- [26] H. Semmelrock et al., “Reproducibility in machine-learning-based research: Overview, barriers, and drivers,” *AI Magazine*, vol. 46, n.º 2, abr. de 2025. DOI: 10.1002/aaai.70002.

## 12.1. Anexo A. Ejemplos de puntos de interés

En este anexo se incluyen ejemplos representativos de los puntos de interés utilizados en la etapa de integración de datos. Cada imagen corresponde a un recorte satelital de 640x640 píxeles centrado en la coordenada procesada, tanto para puntos clasificados como botaderos a cielo abierto y puntos sin botaderos a cielo abierto. Estas imágenes se incluyen para ilustrar la problemática de clasificación de botaderos a cielo abierto mediante imágenes satelitales, se incluyen imagenes tanto para el conjunto de entrenamiento y prueba.



Figura 11: Ejemplos de imágenes satelitales de puntos de interés

En la Figura 11 se pueden observar cuatro imágenes muestras.

- La muestra a (superior izquierda) es una muestra negativa del conjunto de entrenamiento a la que modelo base acertó ( $p < 0.01$  y modelo final fallo en clasificar  $p \approx 0.92$ ).
- La muestra b (superior derecha) es una muestra positiva del conjunto de entrenamiento a la que modelo base fallo ( $p \approx 0.3$  y modelo final acertó en clasificar  $p \approx 0.85$ ).
- La muestra c (inferior izquierda) es una muestra negativa del conjunto de entrenamiento a la que modelo base acertó ( $p < 0.01$  y modelo final fallo en clasificar  $p \approx 1.0$ ).
- La muestra d (inferior derecha) es una muestra positiva del conjunto de entrenamiento a la que modelo base fallo ( $p < 0.01$  y modelo final acertó en clasificar  $p \approx 0.65$ ).



Figura 12: Ejemplos de imágenes satelitales de puntos de interés

En la Figura 12 se pueden observar cuatro imágenes muestras.

- La muestra e (superior izquierda) es una muestra negativa del conjunto de entrenamiento a la que modelo base acertó ( $p \approx 0.23$  y modelo final acertó en clasificar  $p \approx 0.48$ ).
- La muestra f (superior derecha) es una muestra positiva del conjunto de entrenamiento a la que modelo base falló ( $p < 0.01$  y modelo final acertó en clasificar  $p \approx 0.91$ ).
- La muestra g (inferior izquierda) es una muestra negativa del conjunto de entrenamiento a la que modelo base falló ( $p \approx 68$  y modelo final falló en clasificar  $p \approx 0.90$ ).
- La muestra h (inferior derecha) es una muestra positiva del conjunto de prueba a la que modelo base falló ( $p \approx 0.19$  y modelo final acertó en clasificar  $p \approx 0.96$ ).

## 12.2. Anexo B. Repositorio con código del servicio de inferencia y guía de uso

El servicio de inferencia contenerizado en *Docker* se encuentra en un repositorio de GitHub ubicado en esta dirección: <https://github.com/adrianfulla/EcoMentat-api.git>

## 12.3. Anexo C. Repositorio con pesos de modelo y estadísticos de normalización atmosférica

Los pesos de modelo y estadísticos de normalización atmosférica un repositorio ubicado en esta dirección: <https://www.dropbox.com/scl/fo/5hrka9p8erlzbz399ppoa/AEv632o7om0vayJvp3y7L0rlkey=j9rq9clo8csbt89xlxcvkyw9e&st=12dlq7s6&dl=0>

Los pesos del modelo *AerialWaste* se pueden encontrar en la descripción del repositorio de GitHub para el proyecto elaborado por Torres y Fraternali, se puede encontrar en esta dirección: <https://github.com/nahtorres/aerialwaste-model>