

# Detección automatizada de basurales a cielo abierto

Inteligencia artificial, satélites y políticas públicas



Documento  
de Trabajo  
2021-03

# DetECCIÓN AUTOMATIZADA DE BASURALES A CIELO ABIERTO

---

Documento de Trabajo

2021-03

## Coordinación general

### **Brenda Walter**

Coordinadora Senior de Proyectos

### **Eugenia Hernández**

Asistente de Proyectos

## Autores

### **Antonio Vazquez Brust**

Fellow de la Fundación Bunge y Born

### **Leandro Rodriguez**

Fellow de la Fundación Bunge y Born

1. Introducción	5
2. La problemática de los basurales a cielo abierto	6
3. Objetivos y plan de trabajo	7
4. Metodología	9
4.1 Desarrollo del sistema de detección automatizada de basurales	9
4.2 Fuentes de información utilizadas para la identificación	10
4.3 Entrenamiento	10
4.4 Predicción y postprocesamiento	13
5. Principales hallazgos y desafíos	14
6. Difusión	16
7. Recursos	17

Agradecemos el acompañamiento técnico para el desarrollo de este trabajo por parte del equipo de Dymaxion Labs, especialmente a Federico Bayle, Roberta Devesa e Ignacio Paviolo. Resaltamos también la contribución de la Agencia Espacial Europea (ESA), que comparte las imágenes de la misión satelital Sentinel de forma pública, gratuita y de fácil acceso.

La sección que describe la implementación del algoritmo de inteligencia artificial está basada en el paper *Mapping illegal waste dumping sites with neural-network classification of satellite imagery*, desarrollado por Roberta Devesa y Antonio Vázquez Brust<sup>1</sup>.

Todos los hallazgos, interpretaciones y opiniones expresadas en esta publicación son de los autores y no representan necesariamente el punto de vista de sus respectivas instituciones.

1. Devesa, M. and Vazquez Brust, A., 2021. *Mapping illegal waste dumping sites with neural-network classification of satellite imagery*. [online] arXiv.org. Disponible en: <<https://arxiv.org/abs/2110.08599v2>> [Último Acceso: 9 November 2021].



# Introducción

El manejo de los basurales a cielo abierto es un enorme desafío de gestión para gobiernos nacionales y municipales. Por su naturaleza no planificada, se emplazan y crecen sin monitoreo, generando una severa degradación ambiental.

Asimismo, esta problemática afecta en forma desmedida a la población vulnerable, que en ocasiones habita terrenos colindantes o incluso dentro de los basurales.

Por ello, a partir de imágenes satelitales y mediante el entrenamiento de un sistema de inteligencia artificial, nos propusimos crear un método que permita **identificar y monitorear a bajo costo y con alta frecuencia el crecimiento de basurales a cielo abierto**, con el propósito final de visibilizar la problemática y ofrecer a los gobiernos locales insumos para diseñar e implementar intervenciones tempranas. El siguiente documento refleja el trabajo realizado para desarrollar el sistema de detección de basurales a cielo abierto, su adaptación al territorio y su difusión.

# La problemática de los basurales a cielo abierto

La gestión de residuos es un servicio crítico, esencial para la vida urbana, y también un enorme reto para los gobiernos municipales de todo el mundo<sup>2</sup>. El desafío se agrava en las regiones en desarrollo, como América Latina, donde el rápido aumento de la producción de residuos, junto a reducidos presupuestos municipales y escasa atención del Estado nacional, hace inevitable una mala gestión de residuos<sup>3</sup>.

Los basurales a cielo abierto o basurales son zonas en las que se acumulan residuos abandonados de forma intencional e ilegal y constituyen la manifestación física de esta problemática. Los basurales producen una grave degradación ambiental que afecta de forma desproporcionada a la población más vulnerable<sup>4</sup>, especialmente a aquellos que -sin acceso a mejores opciones- ocupan terrenos cercanos o incluso al interior de los lotes cubiertos de basura. Esta proximidad a los asentamientos humanos con las zonas informales de vertido de residuos se ha asociado a serios riesgos para la salud, como enfermedades respiratorias<sup>5</sup> o intoxicación por metales pesados<sup>6</sup>.

A lo anterior se suma otro problema, que es la falta de visibilidad: en todo el mundo se carece de datos precisos sobre numerosos aspectos de la gestión de residuos. Un informe desarrollado en 2015 por un equipo internacional que fue convocado por la ONU para medir el impacto social y medioambiental de la mala gestión de residuos alrededor del mundo, concluyó que "la disponibilidad y la fiabilidad de los datos sobre residuos y recursos es *pésima* y requiere atención urgente"<sup>7</sup>.

Como suele ocurrir con los problemas que afligen al mundo en desarrollo, aquí la ausencia crónica de información hace difícil decidir cómo actuar, frenando el proceso de desarrollo de políticas públicas que produzcan un impacto positivo en la vida de las personas.

2. David C Wilson y Costas A Velis. 2015. *Waste management – still a global challenge in the 21st century: An evidence-based call for action*. Waste Management & Research: The Journal for a Sustainable Circular Economy 33, 12 (Dec.2015), 1049–1051. <https://doi.org/10.1177/0734242X1561605>
3. DaOniel Hoornweg y Natalie Giannelli. 2007. *Managing Municipal Solid Waste in Latin America and the Caribbean : Integrating the Private Sector, Harnessing Incentives*. Technical Report 28. World Bank. <https://openknowledge.worldbank.org/handle/10986/10639>
4. David N. Pellow. 2004. *The Politics of Illegal Dumping: An Environmental Justice Framework*. Qualitative Sociology 27, 4 (2004), 511–525. <https://doi.org/10.1023/B: QUAS.0000049245.55208.4b>
5. Mohd Faiz Ibrahim, Rozita Hod, Haidar Rizal Toha, Azmawati Mohammed Nawwi, Idayu Badilla Idris, Hanizah Mohd Yusoff, y Mazrura Sahani. 2021. *The Impacts of Illegal Toxic Waste Dumping on Children's Health: A Review and Case Study from Pasir Gudang, Malaysia*. International Journal of Environmental Research and Public Health 18, 5 (Feb. 2021), 2221. <https://doi.org/10.3390/ijerph18052221>
6. Alejandro Cittadino, Natalia Ocello, María Victoria Majul, Raquel Ajhuacho, Patricia Dietrich, and María Adela Igarzabal. 2020. *Heavy metal pollution and health risk assessment of soils from open dumps in the Metropolitan Area of Buenos Aires, Argentina*. Environmental Monitoring and Assessment 192, 5 (Mayo 2020), 291. <https://doi.org/10.1007/s10661-020-8246-x>
7. David C Wilson and Costas A Velis. 2015. *Waste management – still a global challenge in the 21st century: An evidence-based call for action*. Waste Management & Research: The Journal for a Sustainable Circular Economy 33, 12 (Dic. 2015), 1049–1051. <https://doi.org/10.1177/0734242X15616055>

# Objetivos y plan de trabajo

A partir de la identificación de la problemática que representa la aparición de basurales a cielo abierto, su falta de visibilidad y escasez de datos, desarrollamos un proyecto orientado a diseñar una estrategia de detección de basurales a cielo abierto basada en teledetección, que tiene el potencial de producir resultados útiles y de actualización frecuente, a una fracción de los costos asociados a la inspección en terreno.

El **objetivo principal** del proyecto fue *crear un método de bajo costo para identificar y monitorear con alta frecuencia el crecimiento de basurales a cielo abierto a partir de imágenes satelitales y mediante el entrenamiento de un sistema basado en Inteligencia Artificial (IA)*.

Los **objetivos específicos** del proyecto fueron a) *crear una metodología que permita a gobiernos de distintos niveles e investigadores monitorear de forma continua la aparición y consolidación*, b) *detectar nuevos basurales para realizar intervenciones tempranas* y c) *reconocer basurales a cielo abierto y cuantificarlos con un set de nuevas imágenes*.

En este sentido, este trabajo pretende contribuir a aumentar la visibilidad de la problemática, y generar una herramienta transferible para que los gobiernos locales realicen intervenciones tempranas orientadas a la reducción de los impactos ambientales producidos por la presencia de basurales a cielo abierto.

Para alcanzar los objetivos mencionados anteriormente, y con la intención de resolver considerables desafíos tecnológicos y metodológicos, se sumaron los servicios de Dymaxion Labs<sup>8</sup>, *startup* argentina especializada en el desarrollo de algoritmos de inteligencia artificial para el análisis de imágenes satelitales.

Junto a Dymaxion Labs se diseñó un plan de trabajo orientado a obtener un modelo funcional con rapidez, que permitiera pasar lo antes posible a una posterior etapa de prueba en campo. Se resume en los siguientes puntos, explicados en mayor detalle en las siguientes secciones:

- **Análisis exploratorio**
  - Descarga de imágenes Sentinel-2
  - Repaso de literatura
  - Adquisición de anotaciones y verdad de campo
- **Desarrollo de modelo de machine learning**
  - Preprocesamiento de datos (anotaciones e imágenes)
  - Adquisición/configuración de hardware para procesamiento.
  - Desarrollo de scripts de preprocesamiento y de entrenamiento

8. <https://dymaxionlabs.com/>

- Experimentación y entrenamiento de modelos
  - Desarrollo de scripts de predicción
  - Revisión y ajustes
  - Informe de resultados
- **Predicción del modelo y mapeo**
    - Evaluación de resultados de modelo
    - Experimentación con entrenamiento de modelos alternativos
    - Revisión y ajustes
- **Publicación de resultados y metodología**
    - Publicación del código fuente en un repositorio público
    - Desarrollo de tests y documentación de la metodología
    - Publicación de mapas en formato ráster y vectorial
- **Organización de jornadas de difusión y feedback**

En resumen, la hoja de ruta fue la siguiente:

Visualización 1  
Hoja de ruta



El plan de trabajo se completó de modo satisfactorio, produciendo un modelo analítico automatizado que permite monitorear la aparición y crecimiento de basurales a cielo abierto analizando imágenes satelitales de acceso público.

Se realizó un test sobre los 3528 centros urbanos de Buenos Aires, barriendo un área de 10 km de diámetro en torno a cada localidad, detectando los basurales conocidos junto a un conjunto adicional de potenciales emplazamientos, cuya evaluación se realizará junto a expertos ambientales como parte de una nueva iniciativa aún en etapa de diseño.

Al finalizar la etapa de desarrollo, se organizó una jornada de demostración y capacitación en el uso de la herramienta, de la que participaron técnicos y funcionarios del Ministerio de Ambiente y Desarrollo Sostenible de la Nación, y de diversos gobiernos municipales.

## Metodología

### 4.1 Desarrollo del sistema de detección automatizada de basurales

Este sistema implementa un modelo de Red Neural Convolutiva (CNN, *Convolutional Neural Network*) mediante una arquitectura U-Net<sup>9</sup> desarrollada para realizar el proceso de segmentación (señalar los límites precisos de áreas de interés en la imagen) que identifique los patrones característicos de los basurales. El resultado del modelo es una imagen del mismo tamaño que la de entrada, en la que cada píxel tiene una probabilidad asociada de pertenecer a un basural. Esto significa que el modelo encontrará no sólo la presencia de basurales sino también su forma (posición de sus bordes). Esta característica es de gran importancia para las aplicaciones de planificación, ya que permite medir el crecimiento de los basurales a lo largo del tiempo, así como su posible solapamiento con otros usos del suelo (cursos de agua, zonas habitadas, etc.).

El modelo requiere de un conjunto de imágenes “anotadas” para el proceso de entrenamiento, es decir imágenes que muestran los basurales conocidos con sus áreas delimitadas. Cada imagen de entrenamiento lleva asociada una máscara binaria -una capa adicional que cubre sólo el espacio ocupado por basural- que permite delimitar el objeto de interés. Por ser originadas por sensores satelitales las imágenes pueden contener muchas bandas; además de luz visible en espectro rojo, verde y azul (RGB) pueden utilizarse otras mediciones incluidas en la imagen satelital como parte del input, como se describe a continuación.

#### Bandas disponibles en la imagen satelital provista por Sentinel

Consideramos entonces las siguientes bandas:

- **RGB:** Las 3 bandas cromáticas
- **NIR:** Infrarrojo cercano, por ser sensible a la vegetación (ayuda a detectar el *background*)
- **SWIR-1 y SWIR-2:** Cercano infrarrojo de onda corta (*short wave infrared*) también por ser sensible a la vegetación
- **NDSW:** Diferencia normalizada de las dos bandas de onda corta (SWIR) 10 y 11 del satélite Sentinel-2, por ser sensible a la emisión de metano

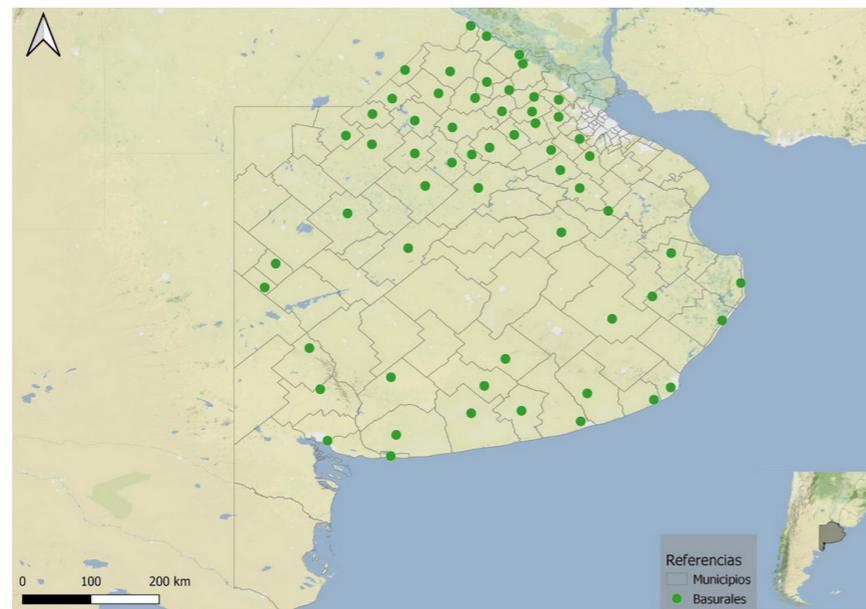
El algoritmo desarrollado alcanzó su mejor performance utilizando la información de 6 bandas: las tres bandas de color (RGB), una banda de infrarrojo cercano (NIR), la diferencia normalizada de las banda de infrarrojo de onda corta (SWIR-1 y SWIR-2) y la banda SWIR-1.

## 4.2 Fuentes de información utilizadas

Las imágenes de satélite utilizadas en este trabajo proceden del proyecto Sentinel-2, la misión de observación de la Tierra a cargo de la Agencia Espacial Europea (ESA). Se obtuvieron a través de Google Earth Engine. La resolución de imagen utilizada es de 10 metros por píxel, y fueron capturadas entre el primer y el último día de febrero de 2021.

Para el proceso de entrenamiento contamos con dos conjuntos de datos con ubicaciones georreferenciadas de basurales a cielo abierto ilegales ya conocidos. Un conjunto fue obtenido de un reporte de ACUMAR, la Autoridad de la Cuenca Matanza Riachuelo (organismo público encargado de mejorar la calidad ambiental de la principal cuenca fluvial de la región). El restante, de un informe de la Defensoría del Pueblo de la Provincia de Buenos Aires sobre la situación de los basurales en la Provincia. Estas fueron las fuentes a las que se acudió para obtener anotaciones, el término que reciben los datos previamente validados utilizados como ejemplo para entrenar sistemas de aprendizaje automático. En combinación, las fuentes proporcionan 81 casos de basurales delimitados y georreferenciados, que fueron utilizados para entrenar el algoritmo de aprendizaje automático supervisado que permite la detección automatizada de áreas similares.

Imagen 1  
Ubicación de los basurales en base a fuentes secundarias



10. GDAL es un conjunto de funciones que permiten traducir entre formatos de datos geoespaciales rasterizados y vectoriales. <https://gdal.org/>

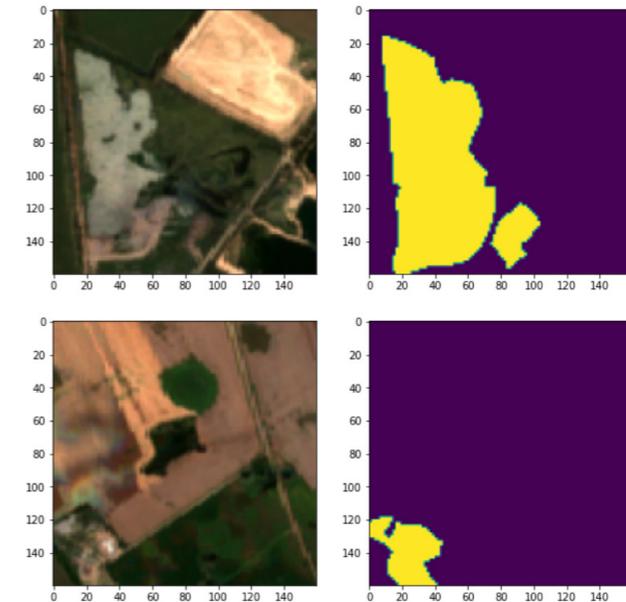
11. pysatproc es una librería de funciones para el lenguaje de programación Python, dedicada al procesamiento de imágenes geoespaciales para aplicaciones de machine learning. <https://pypi.org/project/pysatproc/>

## 4.3 Entrenamiento

La etapa de entrenamiento del algoritmo tuvo como paso inicial la creación del conjunto de datos con el formato y características necesarias para el insumo de un modelo predictivo. Se utilizó una combinación de herramientas para el manejo de datos geoespaciales libremente disponibles, como GDAL<sup>10</sup> y pysatproc<sup>11</sup>, para crear una colección de imágenes conteniendo las bandas de información explicadas antes, junto a las máscaras que indican la presencia de basurales en

cada una de ellas. Se recortaron las imágenes satelitales de su tamaño original en fragmentos pequeños, con dimensiones más prácticas para su procesamiento por el algoritmo U-Net. También se obtuvieron muestras adicionales rotando y recortando de distintas formas las imágenes originales, logrando así un mayor número de anotaciones disponibles para el entrenamiento: En total 1917 imágenes con un tamaño de 100x100 píxeles por 6 bandas (colores visibles e infrarrojos) y sus respectivas máscaras.

Imagen 2  
Imagen satelital color (RGB) de basurales conocidos, junto a la "máscara" asociada que señala sus límites



12. TensorFlow es una plataforma de código abierto que ofrece funciones para realizar todas las operaciones del ciclo de vida del aprendizaje automático. <https://www.tensorflow.org/>

13. Keras es una librería de Python que ofrece una interfaz simple de usar para interactuar con TensorFlow (como analogía, TensorFlow sería un motor de auto, y Keras la carrocería, transmisión, comando, etc). <https://keras.io/>

Una vez producido el conjunto de imágenes de entrenamiento, se alimentó a una red neuronal U-Net vía *Tensorflow*<sup>12</sup>, utilizando *Keras*<sup>13</sup> como interfaz para programar el proceso en código de programación Python. A modo de resumen de especificaciones técnicas, podemos decir que la arquitectura U-Net se construyó con cuatro capas de muestreo descendente y cuatro capas de muestreo ascendente, con seis canales en la primera capa convolucional, y un tamaño de núcleo de 3x3 en todas las capas convolucionales del modelo.

Como es habitual en la práctica de *machine learning*, se dividió el total de imágenes en subconjuntos dedicados a fines de entrenamiento, de validación y de prueba. Los dos primeros conjuntos fueron alimentados al modelo para su aprendizaje, y el último para evaluar su performance prediciendo sobre imágenes que no fueron utilizadas en el proceso de entrenamiento y por tanto el algoritmo no "conoce". Se dedicó un 10% de las imágenes para la prueba de performance, y de las restantes se dedicó un 70% para el entrenamiento y la diferencia para validación.

En la práctica, este problema de clasificación presenta *desequilibrio* entre clases. Es decir, la clase "imagen donde no aparece un basural a cielo abierto" es muchísimo más frecuente que la clase a la que corresponden las imágenes que presentan un basural visible. En estas condiciones, el modelo tiende a conocer el terreno de fondo mucho más que los objetos de interés, por lo que tiende a predecir el fondo (paisaje general) más que los objetos deseados (basurales). Para reducir el

problema, utilizamos una opción de entrenamiento llamada entropía cruzada binaria ponderada. Esta opción permite considerar diferentes valores de peso para cada clase (o una clase, en este caso), para forzar el aprendizaje de patrones a centrarse más en los casos que son menos frecuentes en el conjunto de datos.

La métrica utilizada para evaluar la performance alcanzada por el algoritmo es la Intersección sobre Unión (IoU por *Intersection over Union* en inglés), que se utiliza con frecuencia en aplicaciones relacionadas con la detección y segmentación de objetos. Es esencialmente un método para cuantificar el porcentaje de solapamiento entre la máscara que define los basurales conocidos y la que produce nuestra predicción, midiendo el número de píxeles en común dividido por el número total de píxeles presentes en ambas máscaras.

## Visualización 2 Métricas

### Métricas

A partir de las 81 anotaciones de basurales generamos un dataset de 1917 imágenes, el cual dividimos en entrenamiento, validación y testeo.

Entrenamiento	Validación	Testeo
Para entrenar al modelo	Para ajustar los parámetros del modelo	Para evaluar al modelo y medir la performance

**Métrica utilizada:**  
Intersection over union (IOU) muestra la coincidencia por solapamiento entre la predicción y el objeto.

- $IOU = \text{verdadero\_positivo} / (\text{verdadero\_positivo} + \text{falso\_positivo} + \text{falso\_negativo})$ .
- Tiende a 1 cuando la predicción mejora.

**Ejemplo**  
Umbral: 0.5

Verdadero positivo  
verdad de campo

predicción  
IoU = 0.8

Falso negativo  
verdad de campo

predicción  
IoU = 0.1

Falso positivo

$$IOU = \frac{\text{area de solapamiento}}{\text{area de unión}}$$

Así comparamos los resultados de entrenar la red neuronal con distintas combinaciones de bandas disponibles en las imágenes satelitales que provee Sentinel: Sólo color visible (R, G, B), color visible más infrarrojo cercano, color visible y bandas de onda corta, etc. Tras comparar la capacidad de predicción de modelos entrenados con diferentes combinaciones, se halló el mejor rendimiento utilizando las ya mencionadas capas R,G,B junto a infrarrojo cercano y la diferencia entre las dos bandas de onda corta del infrarrojo cercano.

Tabla 1  
Comparación de performance entre modelos entrenados con distintas bandas

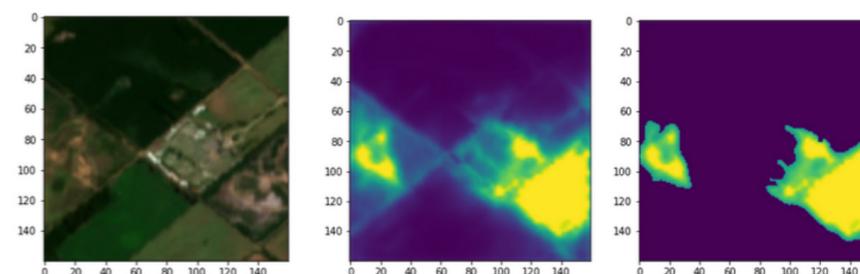
Bandas utilizadas para entrenamiento	Performance alcanzada (IoU)
RGB	0.593
RGB-NIR	0.660
RGB-NIR-SWIR	0.650
<b>RGB-NIR-SWIR-NDSW</b>	<b>0.675</b>

## 4.4 Predicción y postprocesamiento

Tras completar el entrenamiento se obtuvo un modelo capaz de predecir (esto es señalar la presencia) de basurales a cielo abierto a partir de nuevas imágenes provistas; por ejemplo, repitiendo el proceso con imágenes de áreas donde no se conoce a priori la existencia de basurales. La predicción producida consiste en un conjunto de imágenes con una banda adicional que indica la probabilidad estimada, para cada píxel, de que la imagen muestre un basural a cielo abierto.

Para eliminar los casos con baja probabilidad -que se asumen como falsos positivos- se implementa un proceso de filtrado sobre todos los resultados predichos, aplicando un umbral de probabilidad por píxel: se descartan todas las predicciones cuya probabilidad estimada es baja. Además se eliminan ciertas predicciones en función de su superficie, ya que las áreas más pequeñas clasificadas como basurales tienen más chances de ser falsos positivos. El umbral se fijó en 100 m<sup>2</sup>, teniendo en cuenta que los basurales de alto impacto ambiental y social alcanzan superficies mucho mayores. Sin embargo, vale aclarar que este umbral es modificable al momento de aplicar el algoritmo, permitiendo retener áreas predichas de menor extensión.

Imagen 3  
Imagen RGB, predicción "en crudo", resultado tras aplicar umbral de probabilidad para limpiar la predicción



# Principales hallazgos y desafíos

Habiendo identificado el modelo de mejor performance, se lo aplicó para analizar imágenes satelitales cubriendo los alrededores de 3528 centros urbanizados en la Provincia de Buenos Aires, considerando un área de 10 km de diámetro en torno a cada localidad. **El modelo identificó la ubicación de un 95% de los basurales conocidos** (aquellos que fueron parte del conjunto para entrenamiento) junto a un conjunto adicional de potenciales emplazamientos. La evaluación en terreno de éstas áreas de interés se realizará junto a expertos ambientales como parte de una nueva iniciativa aún en etapa de diseño.

Más allá de este resultado, es posible mencionar algunos desafíos y potenciales mejoras. En primer lugar, se observó la obtención frecuente de falsos positivos entre las predicciones, lo que revela que ciertas tipologías visibles desde el espacio -como grandes terrenos baldíos, excavaciones de cimientos, o barrizales en márgenes de ríos- pueden ser detectados por el algoritmo como basurales por presentar un aspecto similar al de los basurales. Este comportamiento cabe dentro de lo esperado, ya que la puesta en práctica de la metodología asume la participación de una persona con conocimiento del tema, que evalúe y descarte con rapidez los falsos positivos, conservando aquellas áreas detectadas con potencial como nuevo basural hallado.

Un segundo desafío es que los basurales pequeños (de tamaño inferior a una hectárea) son difíciles de detectar utilizando la imagen gratuita provista por Sentinel, debido a que su resolución óptica no es suficiente. Para la detección de microbasurales habría que recurrir a fuentes de mayor definición -y considerable costo asociado- como proveedores comerciales de imagen satelital, o imágenes aéreas capturadas con drones o vuelos de reconocimiento.

Por último, como es común en aplicaciones que dependen de fuentes satelitales, la presencia de nubes al momento de la captura de la imagen hace imposible realizar la detección sobre el terreno cubierto. Esto puede resolverse buscando imágenes tomadas en distintas fechas, pero se ha observado que en áreas particulares por su clima puede resultar difícil adquirir imágenes libres de nubosidad. Aún con sus limitaciones como fuente, las imágenes del satélite Sentinel-2 resultan de enorme valor para la reproducibilidad de estos resultados y la aplicación de la metodología en otros contextos territoriales, debido a su disponibilidad pública y a su facilidad de adquisición. El acceso gratuito a las imágenes de satélite de 10 metros de resolución, junto con los algoritmos de aprendizaje automático de código abierto como los que hemos hecho públicos, permiten el análisis rápido de extensas áreas a un coste mínimo.

Imagen 4. Ejemplos de resultados del modelo, basurales identificados tras procesar imágenes de 594 centros urbanos de toda la provincia de Buenos Aires.

Imagen 4  
Ejemplos de resultados del modelo, basurales identificados tras procesar imágenes de 594 centros urbanos de toda la provincia de Buenos Aires.



# Difusión

La difusión de este proyecto se realizó mediante dos estrategias: por un lado, se pusieron a disposición los datos para el público en general y, por otro lado, se realizaron dos jornadas de difusión y un taller práctico.

En relación a la apertura de datos y posibilidad de replicar el proceso, se generó un repositorio: <https://github.com/dymaxionlabs/basurales> con un conjunto de *notebooks* Jupyter (conjuntos de código y documentación listos para usar).

Visualización 3  
**Notebooks de código y documentación para reproducir los resultados del proyecto**



Por otro lado, en materia de eventos de difusión:

14. Devesa, María Roberta, y Vazquez Brust, Antonio. (2021). *Mapping illegal waste dumping sites with neural-network classification of satellite imagery*. Disponible en <https://arxiv.org/abs/2110.08599>

15. <https://kdd-humanitarian-mapping.herokuapp.com/>

16. Disponible en: <https://www.youtube.com/watch?v=u9Yf8BJMiao>

17. Disponible en: <https://www.youtube.com/watch?v=h-WUOalG4mU>

- Se presentaron los resultados y un paper<sup>14</sup> específico en la Conferencia Internacional de Descubrimiento de Conocimiento y Minería de Datos (2nd KDD workshop on Data-driven Humanitarian Mapping)<sup>15</sup>, que reúne a una comunidad global de especialistas para promover una agenda de investigación en ciencia de datos compartida, con foco en acciones humanitarias equitativas y desarrollo sostenible, organizado por el MIT, Facebook, Harvard University, y Oak Ridge National Laboratory.
- Se realizó una presentación general del proyecto y sus resultados<sup>16</sup>, abierto al público en general, y un taller práctico<sup>17</sup> con un listado pre seleccionado de funcionarios municipales y provinciales, especialistas y entusiastas en el tema, los cuales fueron capacitados y realizaron una práctica interactiva sobre los datos obtenidos en el proyecto, a partir de una serie de notebooks creadas a tal fin.

Estos eventos fueron realizados junto a Dymaxion, y el taller contó con la coordinación y difusión de la Red de Innovación Local (RIL).

# Recursos

## Datos abiertos

- Repositorio de código y notebooks Jupyter: <https://github.com/dymaxionlabs/basurales>

## Webinars

- Inteligencia Artificial, Satélites y Políticas Públicas: <https://www.youtube.com/watch?v=u9Yf8BJMiao>
- Taller práctico: <https://www.youtube.com/watch?v=h-WUOalG4mU>

## Paper

Devesa, M. and Vazquez Brust, A., 2021. *Mapping illegal waste dumping sites with neural-network classification of satellite imagery*. [online] arXiv.org. Available at: <https://arxiv.org/abs/2110.08599v2> [Último Acceso: 9 November 2021].



FUNDACIÓN  
BUNGE Y BORN

25 de Mayo 501, 6° Piso (C1002ABK)  
Ciudad de Buenos Aires, Argentina  
[www.fundacionbyb.org](http://www.fundacionbyb.org)

