desarrollo urbano | MADRID

JORNADAS DE GEODATOS

JORNADAS DE GEODATOS

IA aplicada a la teledetección

Monitorización de valor

4ª EDICIÓN

#GeoJornadas2022

04 – 05/MAYO/2022

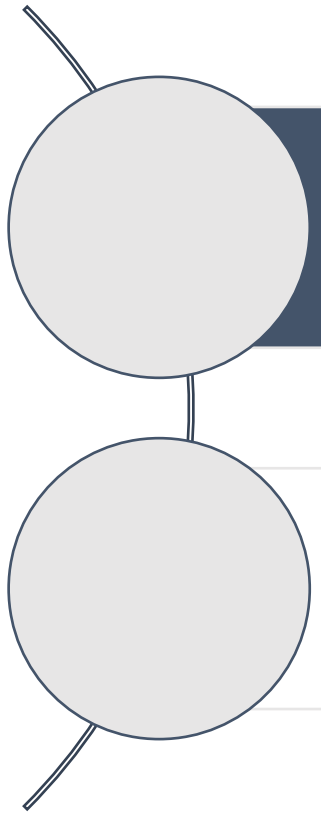

Introducción al proyecto y objetivos

Descripción de los productos y servicios

Vídeo IA

CARTOGRAFÍA INTELIGENTE
IA aplicada a la Cartografía
del Ayuntamiento de Madrid
geoportal
desarrollo urbano | MADRID
Empresa adjudicataria:
cotesa

Objetivo: monitorización continua de la ciudad permitiendo una mayor frecuencia y la detección de objetos mediante técnicas **de Inteligencia Artificial** que, además, proporcionan valor añadido al **GEOPORTAL.**

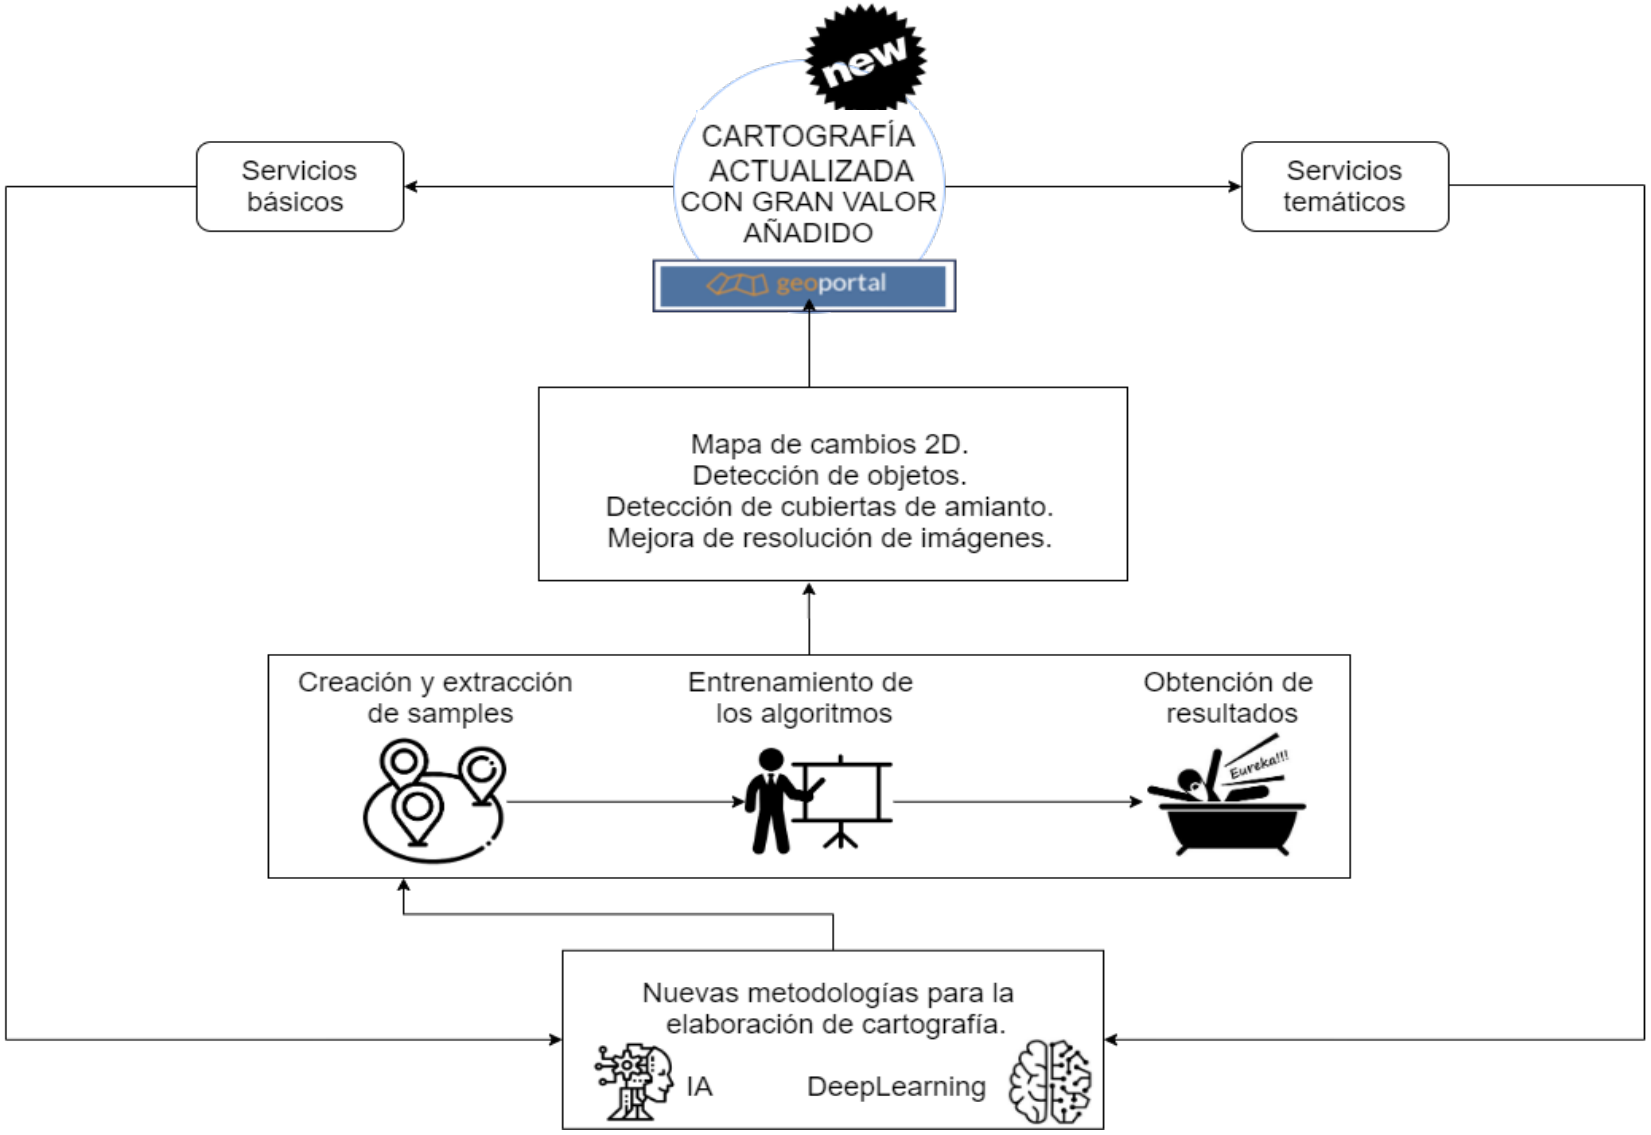

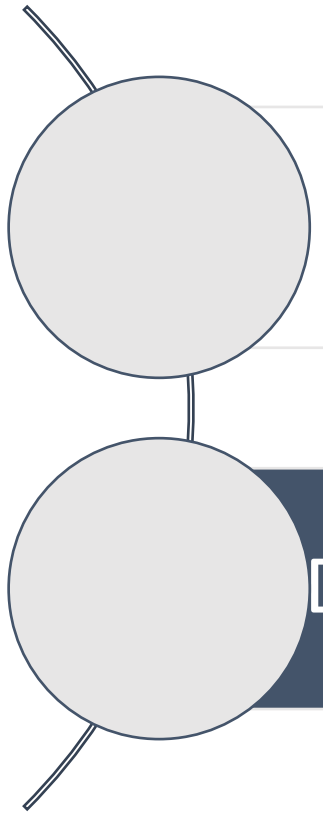

Introducción al proyecto y objetivos

Descripción de los productos y servicios

Introducción a la Inteligencia Artificial

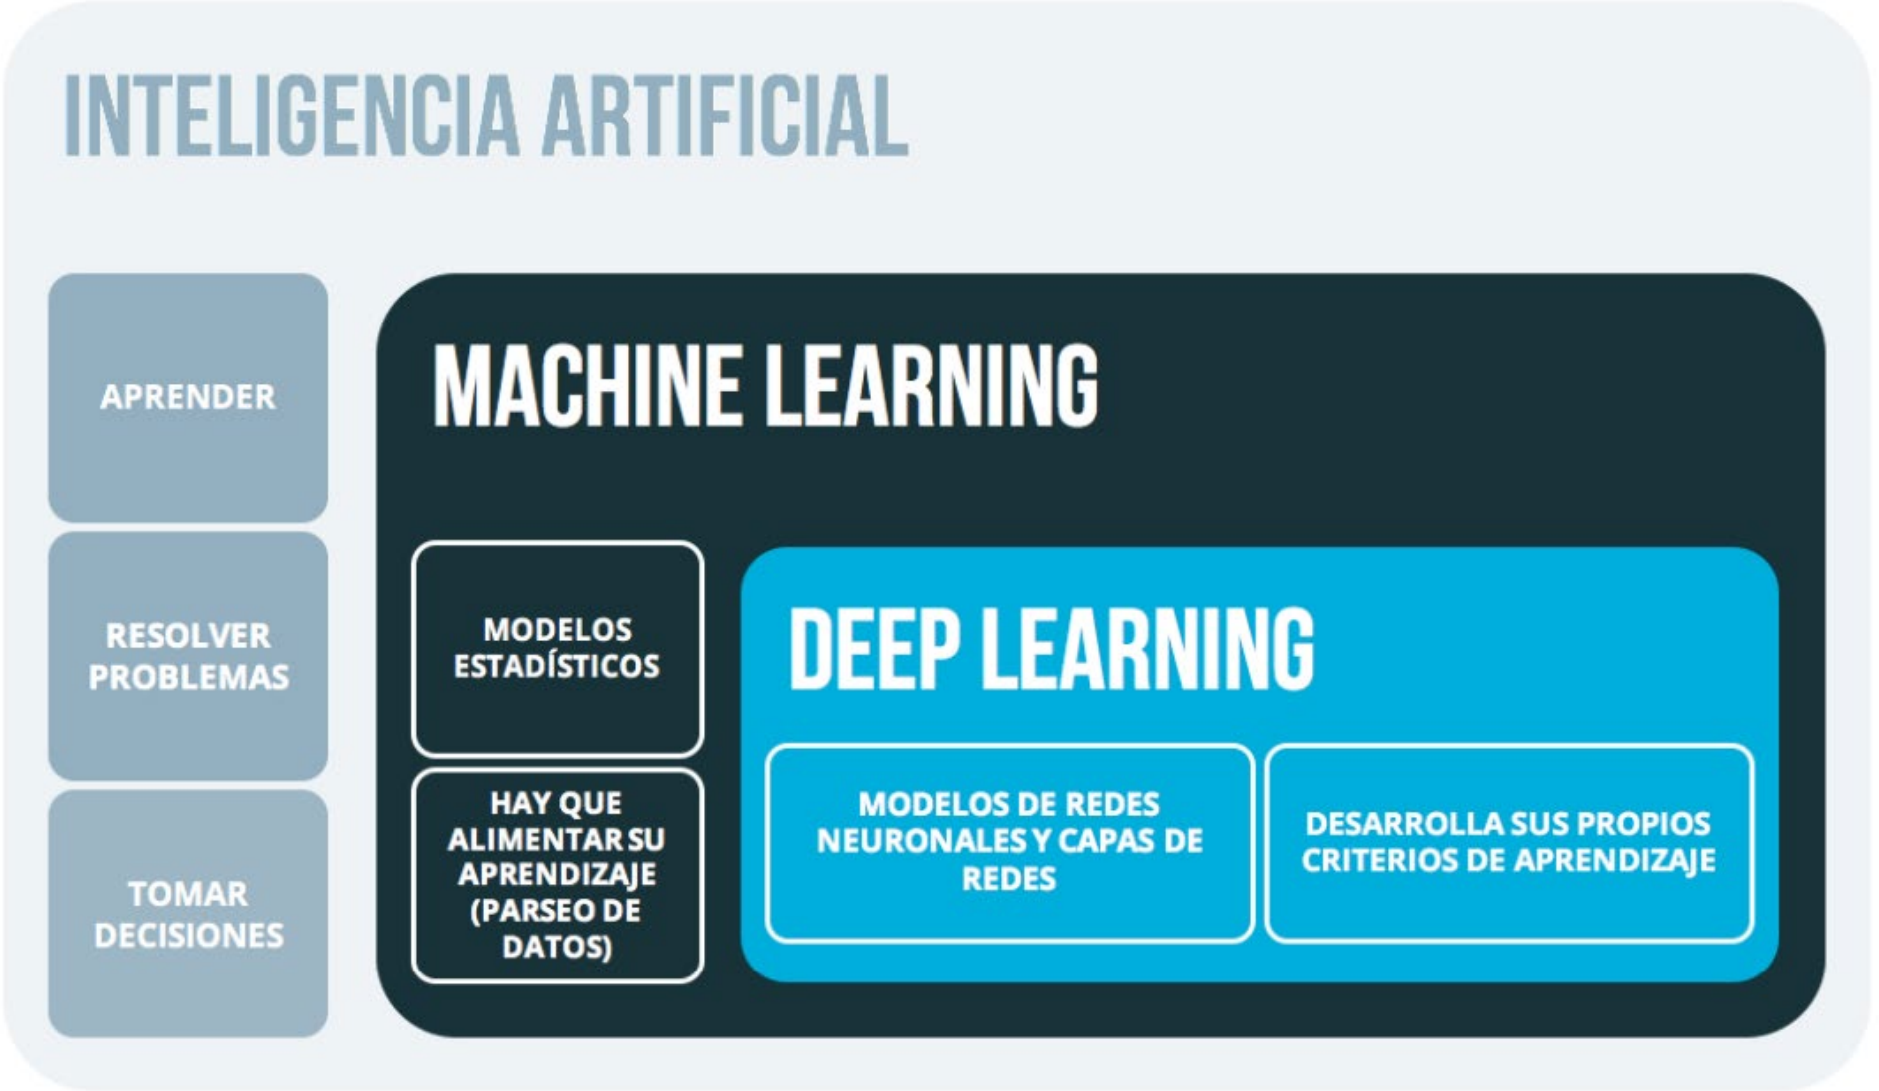

Introducción a la IA: qué es el Deep Learning

¿Qué es el Deep Learning?

Dos conceptos fundamentales:

- **Propagación hacia atrás.**
- **Redes neuronales**: modelo computacional => gran conjunto de unidades neuronales simples.
  - **Comportamiento análogo** en axones de las neuronas de los cerebros biológicos.
  - **Diagrama**:
    - Datos de **entrada** de la neurona.
    - La **unidad de sesgo** => valor que le da flexibilidad en el aprendizaje a la neurona.
    - **Pesos** relativos de cada entrada.
    - **Salida** de la neurona.

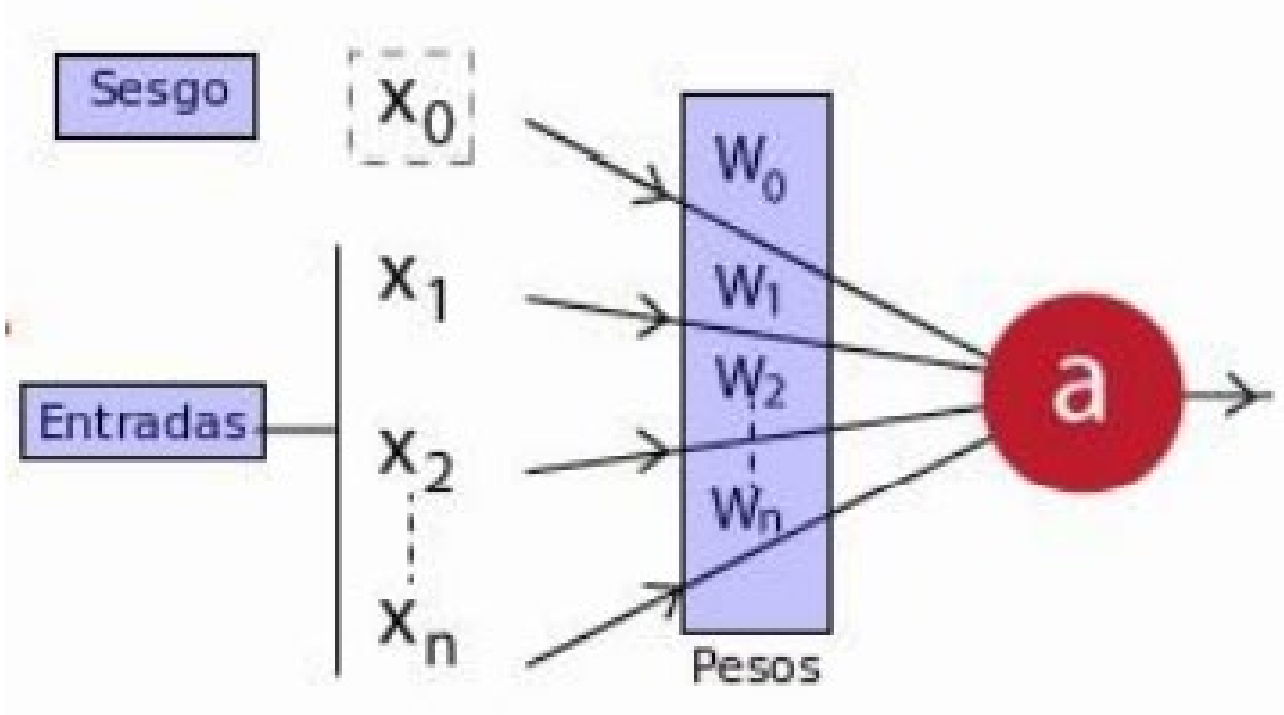

Servicios básicos: mapa de cambios urbanos

FASES:

1. Captura de **2 imágenes** de muy alta resolución.
2. **Muestras** entrenamiento.
3. Detección de cambios 2D con **algoritmos Deep Learning**.
4. **Refinado** de los resultados obtenidos. Comisiones y omisiones.
5. **Control de calidad** de los resultados.

- 3 por año.
- **138 cambios** (otoño de 2020 - primavera de 2021).
- Alturas entre **2 metros y los 180** (Torre Caleido).
- Precisión de más del 90%.

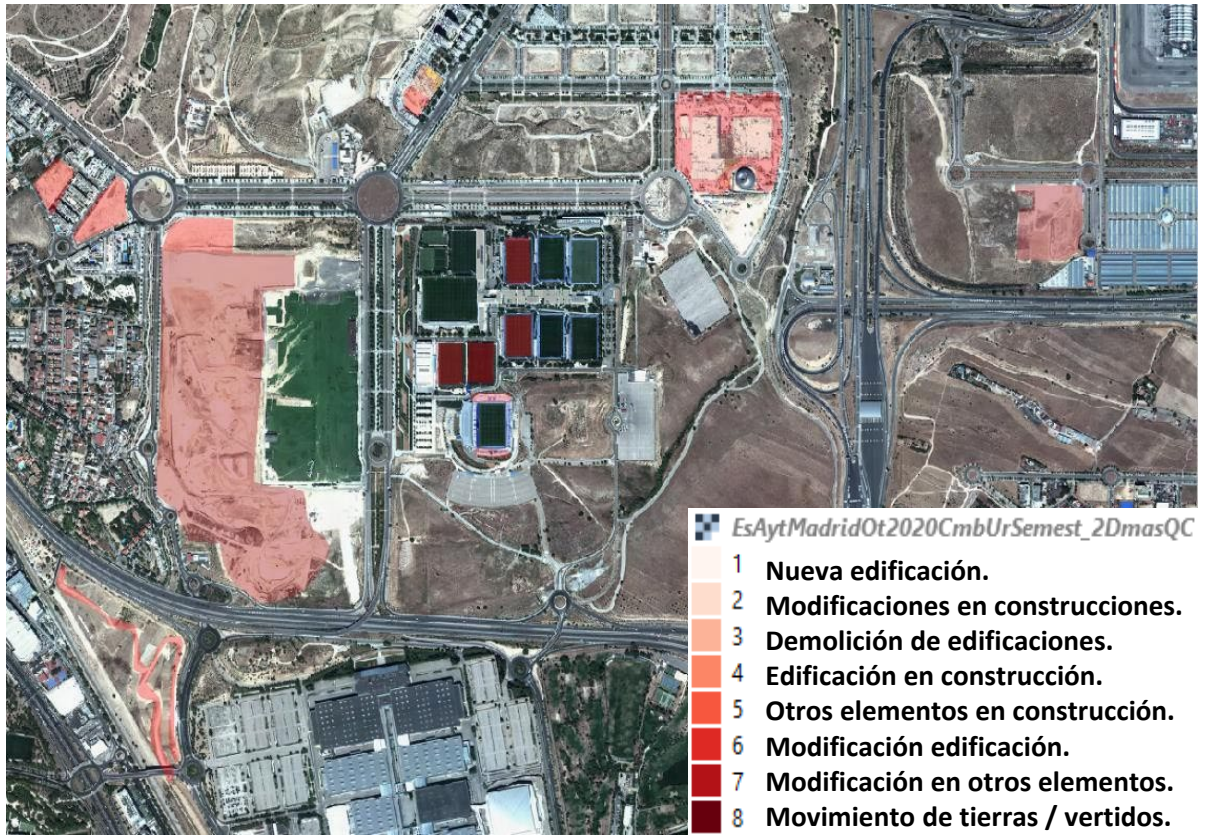

IA aplicado a Servicio de mapa de cambios 2D

- Dos **fases:**
  - **Detección y segmentación** de todos los cambios que se han producido.
  - **Clasificación** en las clases correspondientes.

- NO todas las clases tienen la misma dificultad:
  - La demolición total o la construcción sobre suelo desnudo es **fácil de detectar**.
  - Los elementos en construcción o las modificaciones parciales son más complicadas y requieren de más muestras y más entrenamiento para **detectar toda la variabilidad del objeto**.

- Resultado: archivo shapefile (.shp) => **máscara con los cambios** clasificados.

IA aplicada a las detección de objetos: zonas verdes

¿Qué se obtiene?

- Cartografía de cobertura basada en la **detección de zonas verdes de la ciudad.**
- Detección de **estratos** vegetales.

Fases:

- Cálculo de **índices de vegetación** (NDVI, RVI).
- Áreas de **entrenamiento**.
- **Clasificación por píxel** RF + poligonización.
- Refinamiento de resultados + **validación**.

Precisión:

- > 90% en los tres estratos.

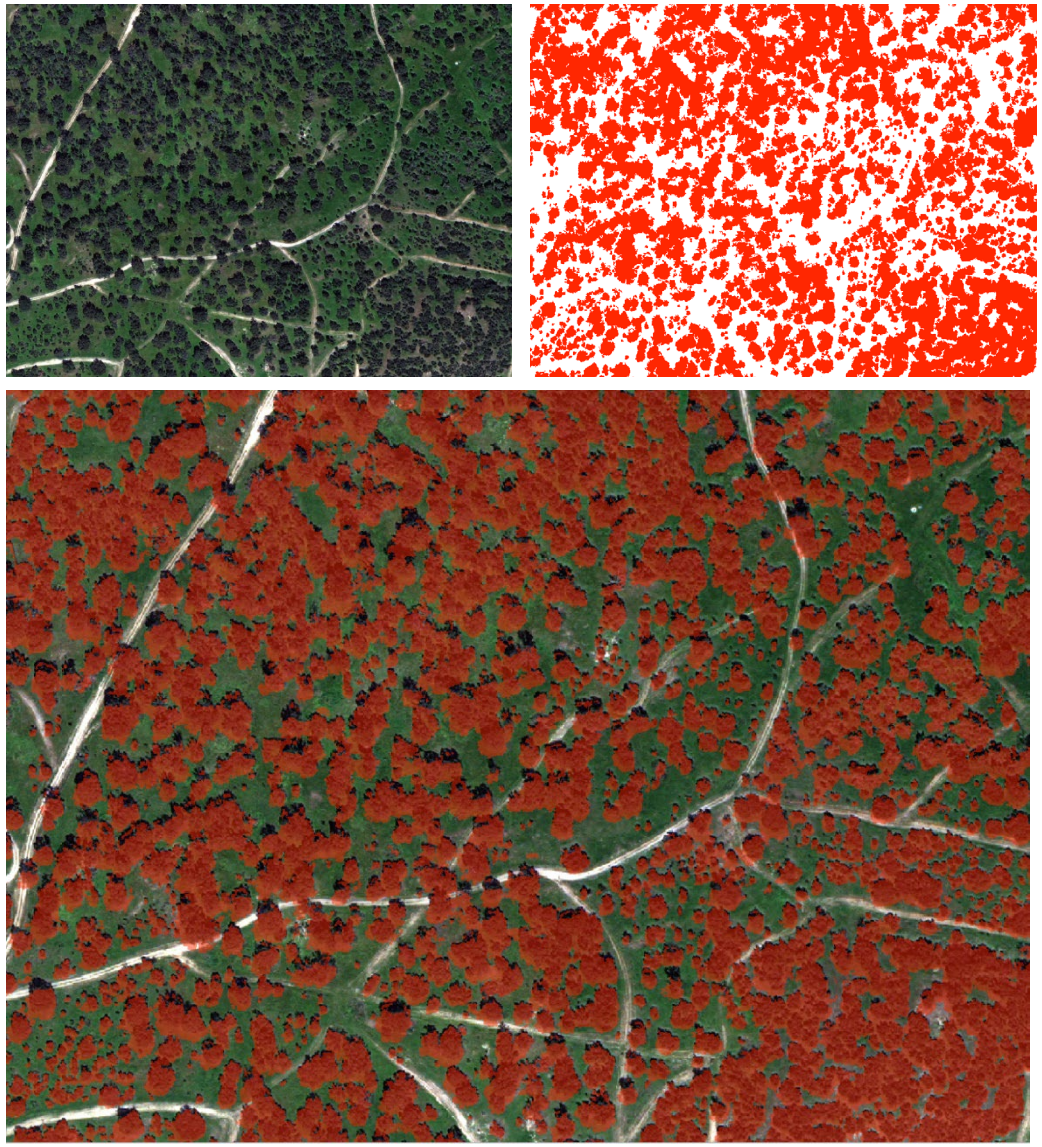

IA aplicada a las detección de objetos: zonas verdes

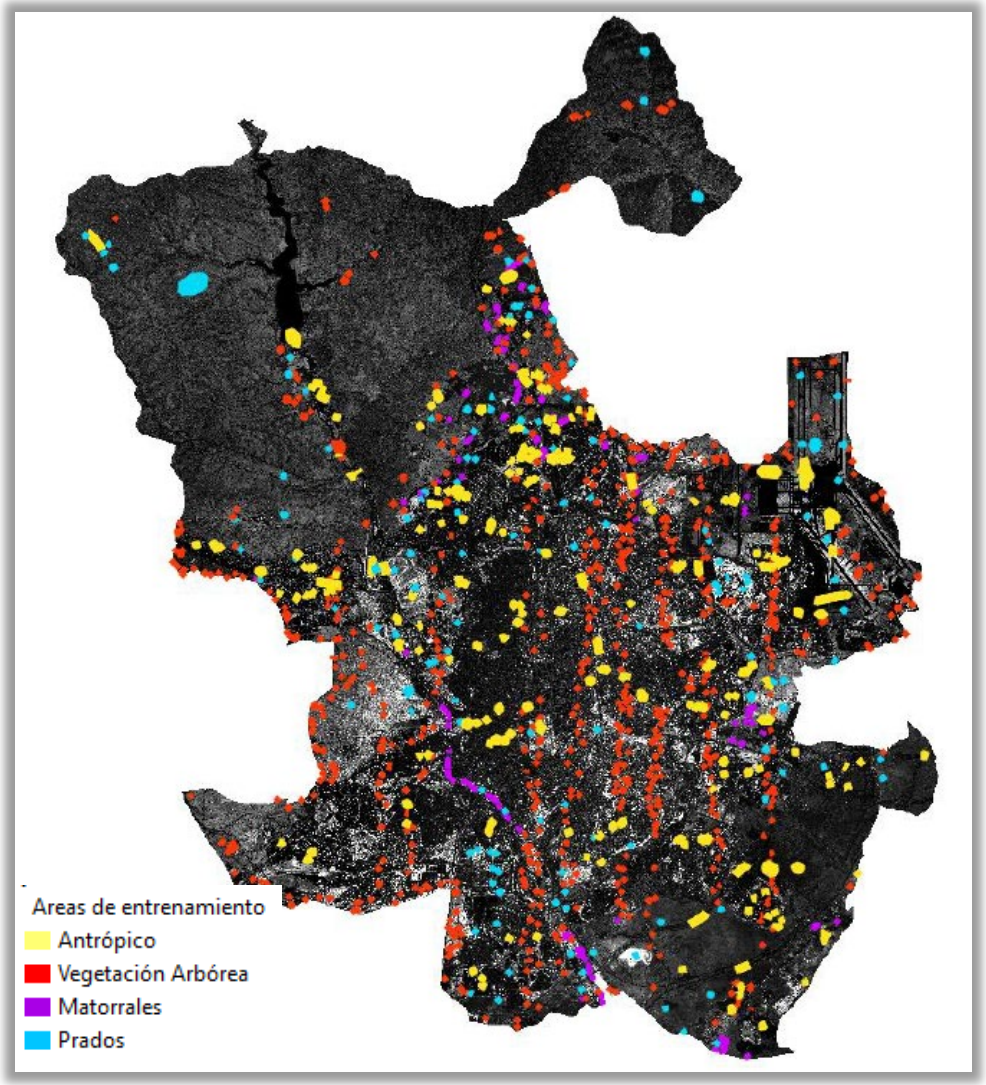

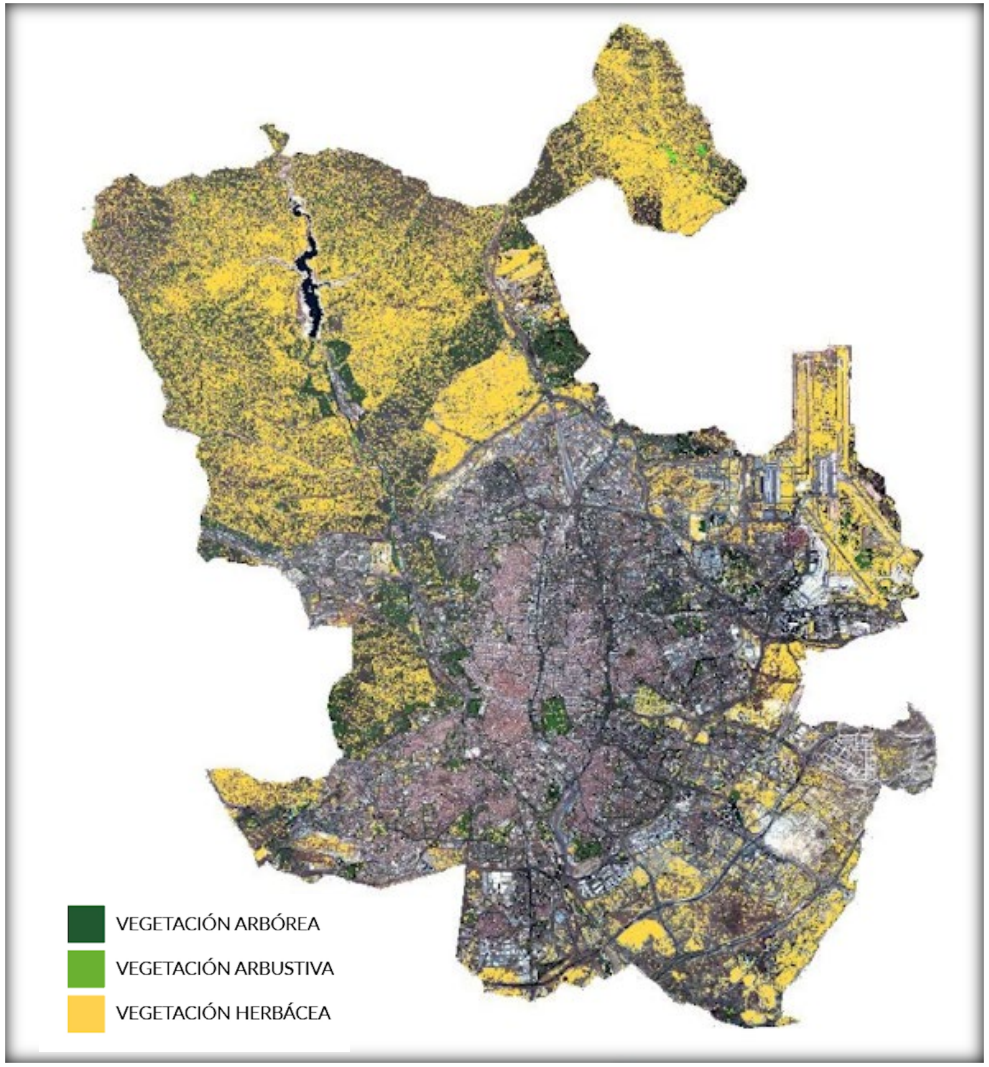

Bondad del algoritmo en la imagen comparando las áreas de entrenamiento con los resultados obtenidos.

- ❑ Vegetación **arbórea**. 98%.
- ❑ Vegetación **arbustiva**. 99%.
- ❑ Vegetación **herbácea**. 97%.

IA aplicada a las detección de objetos: zonas verdes

Precisión geométrica > 80%

Precisión temática > 97%

Entregables: Formato vectorial (.shp) y ráster (.tif) con los estratos de vegetación.
1. Vegetación baja; 2. Vegetación de matorral; 3. Vegetación arbórea

IA aplicada a las detección de objetos: tipo de especies

FASES:

- **Cálculo de índices**: NDVI y RVI. Generación de Bandas.
- Selección **áreas de entrenamiento** con capa municipal de puntos de especies arbóreas.
- **Clasificación por píxel**. Estadísticas de 12 bandas del mosaico. Datos con los que el algoritmo entrena obteniendo modelo de clasificación. Poligonización.
- **Control de calidad.** Teselas de 20x20 m. prevalece la especie con mayor superficie para evitar errores por sombras.
- **Matriz de confusión**. Índice Kappa.

Puntos utilizados como áreas de entrenamiento para la detección de especies

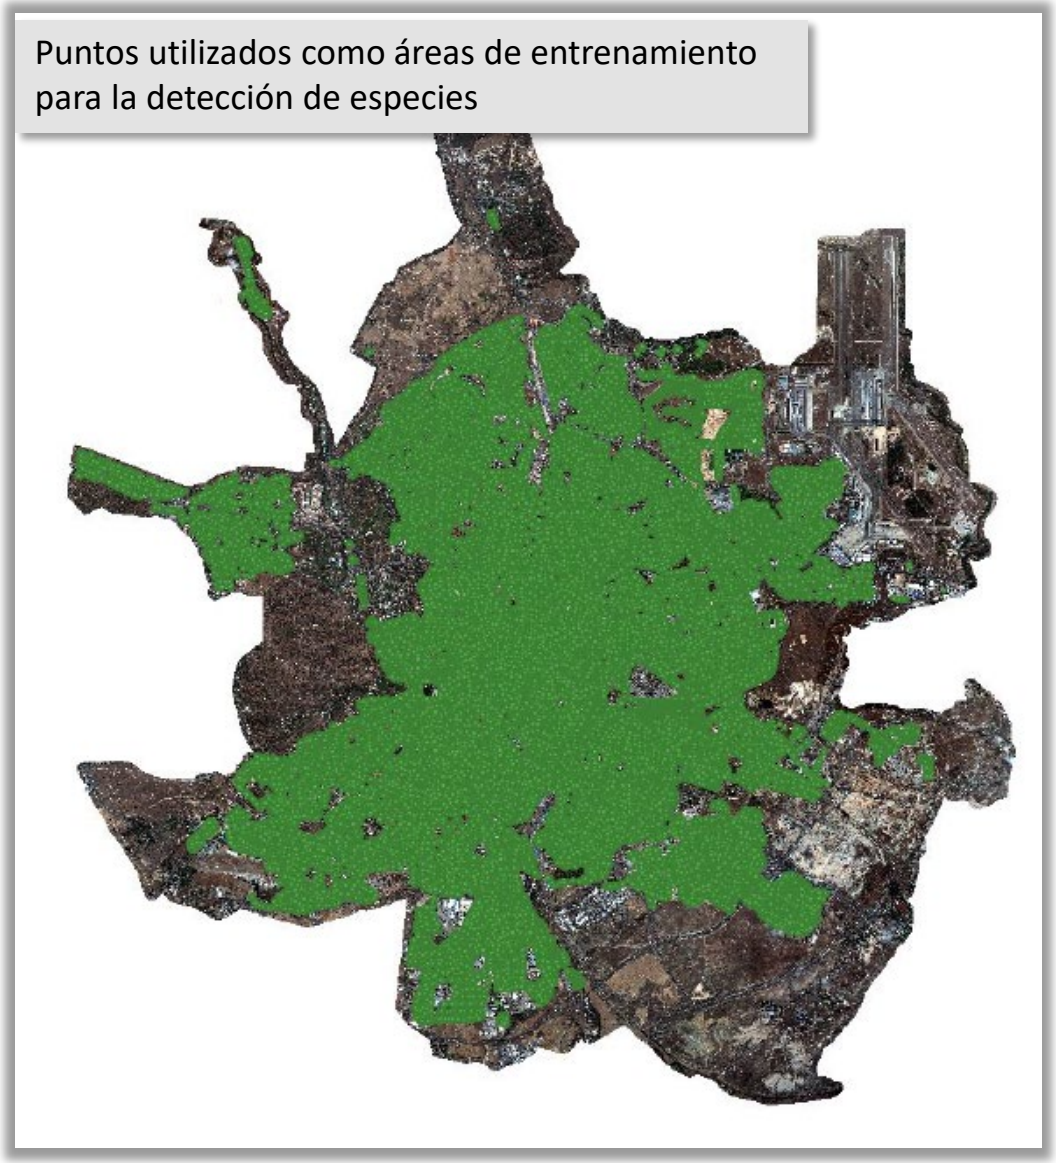

IA aplicada a las detección de objetos: tipo de especies

Bondad del algoritmo en las áreas de entrenamiento con los resultados obtenidos

Pino. 91%

Platanero. 96%

Arce. 94%

Olmo. 97%

Acacia. 94%

Falsa acacia. 97%

Almez. 90%

Aligustre. 94%

Castaño. 95%

Encina. 94%

Otras. 89%

Entregables:

- Formatos **vectorial** (*.shp) y **ráster** (*.tif)

IA aplicada a la detección de cubiertas de amianto.

Técnicas:
Detección automática mediante aplicación de inteligencia artificial y machine learning en imágenes de muy alta resolución.

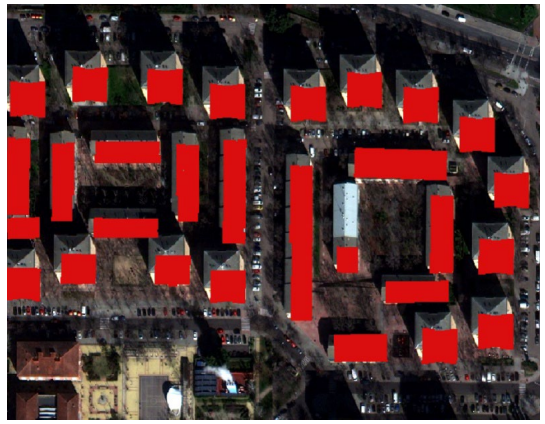

FASES:

- ❑ **Capa de edificios**. Vectorial.
- ❑ Generación de **áreas de entrenamiento** y análisis radiométrico de cubiertas.
- ❑ **Revisión bibliográfica** de estudios de identificación con diferentes métodos de clasificación.
- ❑ Método **algoritmo SAM** (cálculo del ángulo espectral entre firmas espectrales píxeles imagen y áreas entrenamiento): realizado en entorno R.
- ❑ **Validación** en campo.

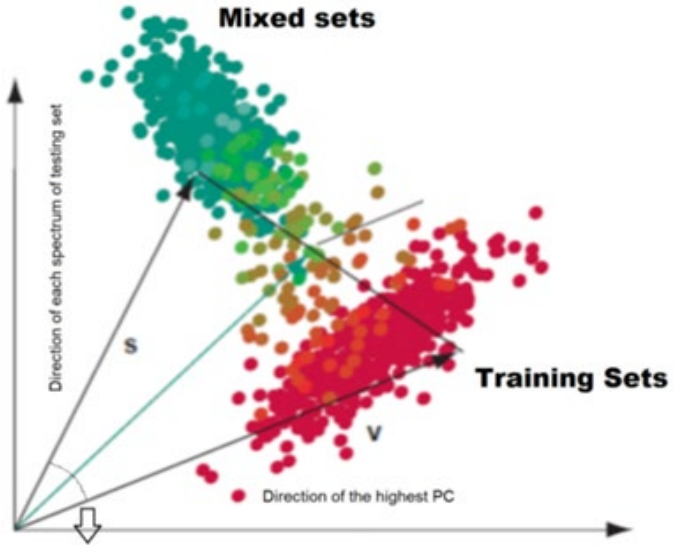

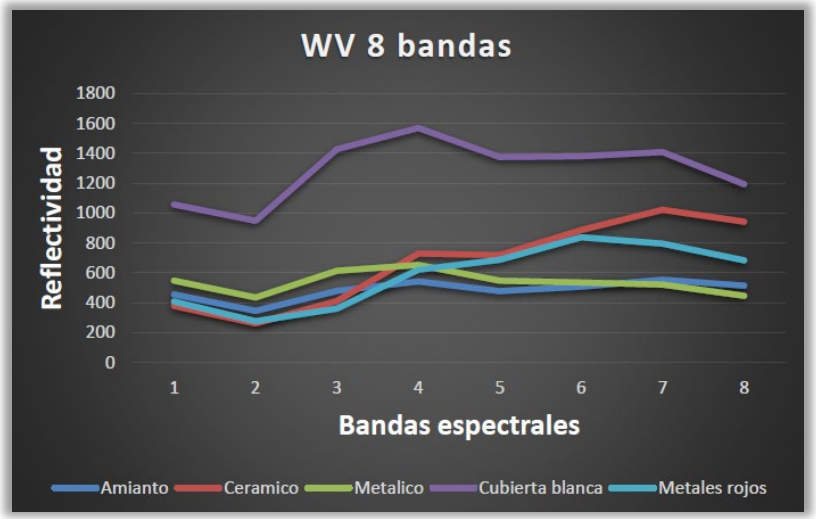

Comportamiento espectral diferente en las bandas 4 (YELLOW), 5(RED), 7(NIR 1) y 8(NIR 2)

IA aplicada a la detección de cubiertas de amianto

1. **Cruce de los resultados ráster del algoritmo con cartografía 2016 del Ayuntamiento + refinamiento.**
2. **Validación en campo: AOI con alta cantidad de tejados de amianto => Villaverde y Fuencarral.**
    - **50 puntos. 88 % acierto.**

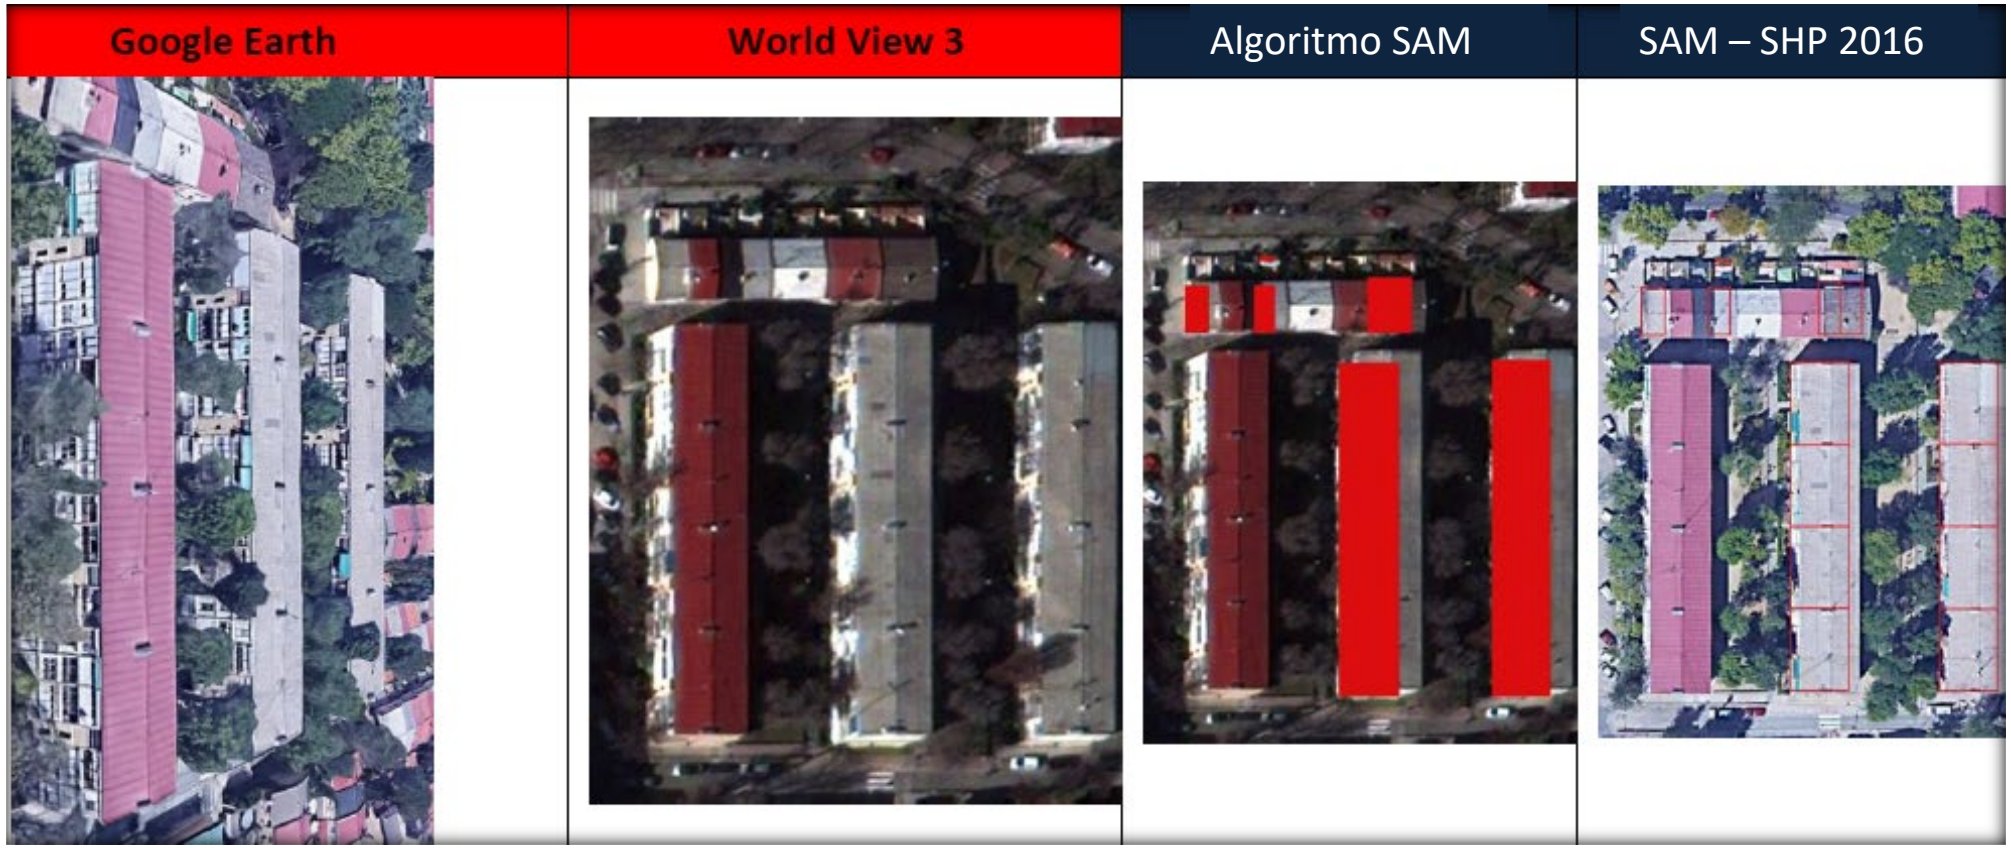

IA aplicada a la detección de cubiertas de amianto

Entregables:

Representación de las **cubiertas con amianto** detectado

- ❑ Archivo **vectorial** *.shp
- ❑ Archivo **ráster** *.tif

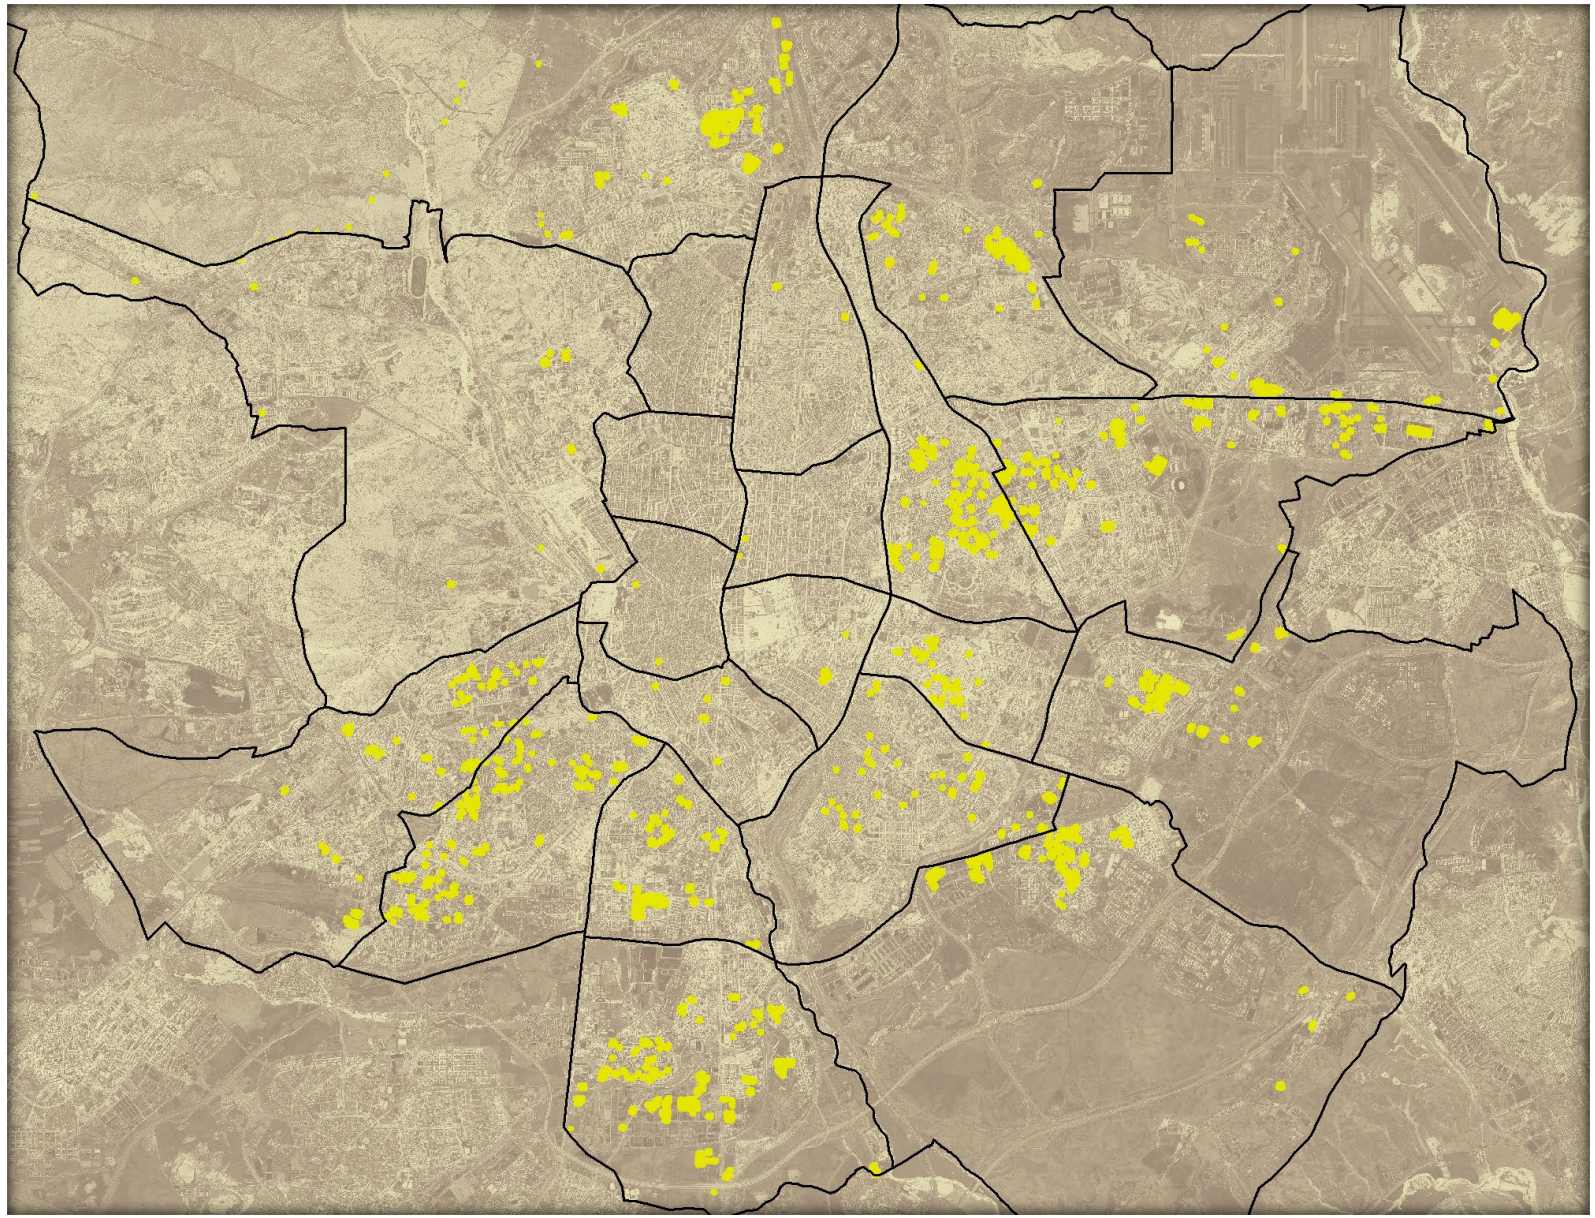

Deep Learning aplicado a la mejora de la resolución de las imágenes

Cartografía viva

- **Objetivo** principal: **mejorar las imágenes de Sentinel-2** mediante técnicas de **Deep Learning** debido a las limitaciones de las técnicas de interpolación lineales.
- **Algoritmo utilizado =>** red neuronal de tipo **GAN** (Generative Adversarial Network).
- Estas redes están construidas con **dos subredes**:
  - El **generador**, su propósito es "generar" una **imagen superresuelta a partir de ruido** (imagen de Sentinel).
  - El **discriminador**, determina si una imagen ha sido elaborada por el generador o pertenece al conjunto de imágenes HR/VHR.
- ¿Cuándo sabemos que la imagen está correctamente superresuelta?

  => **Discriminador no puede decir si la imagen es del conjunto de verdaderas o falsas.**

Deep Learning aplicado a la mejora de la resolución de las imágenes

15	12	11
9	10	11

15	15	15	15
15	15	15	15
15	15	15	15
15	15	15	15

?	?	?	?
?	?	?	?
?	?	?	?
?	?	?	?

Imagen Sentinel Original 10x10m con fecha similar a las imágenes de entrenamiento PNOA.

15	14	13	15
14	12	15	14
11	15	10	16
13	14	11	10

Imagen Sentinel SuperResuelta con una resolución 4 veces mayor.

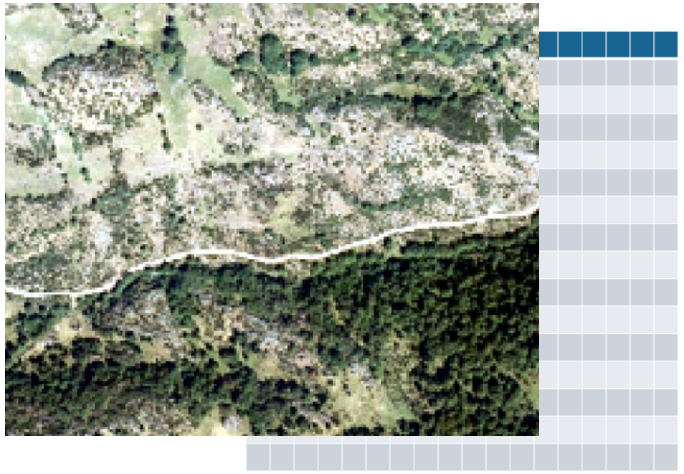

Imagen PNOA Original 0.25 x0.25 m

16	14	13	15
14	10	15	13
11	15	10	16
14	13	12	10

Imagen PNOA a resolución objetivo 2.5 x 2.5 m

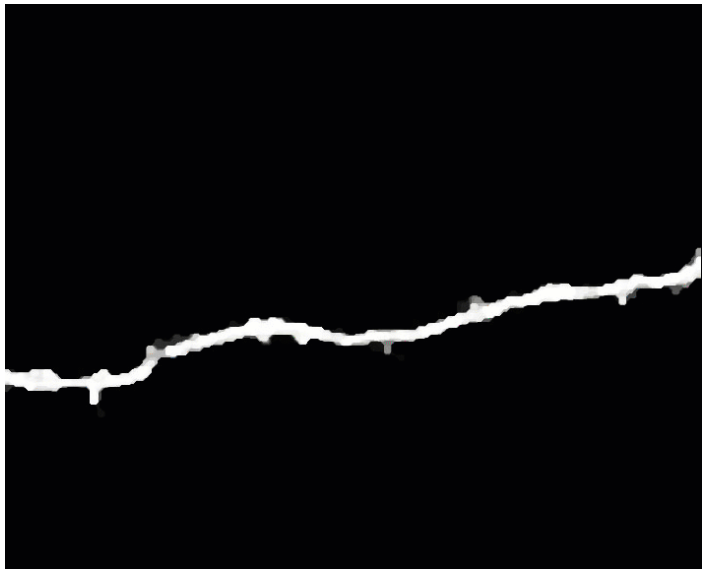

Copyright © GRUPOTECOPY

Deep Learning aplicado a la mejora de la resolución de las imágenes.

SRGAN emplea una Generative Adversarial Networks (GAN) que permite generar imágenes satelitales de Super-Resolución con un 'upscalling factor' x4 o x8 en la resolución espacial de las imágenes. Para alcanzar esta mejora en las imágenes SRGAN emplea dos tipos de redes convolucionales:

- **Generator Network**: la red G genera imágenes de alta resolución a partir de las imágenes de baja resolución utilizando como **retroalimentación** de mejora las imágenes VHR.
- **Discriminator Network:** la red D determina si una imagen introducida es **real** (puede pertenecer al conjunto de VHR debido a su similitud con el mismo) o es **falsa** (no puede pertenecer al conjunto de VHR debido a las discordancias que presenta con el mismo).

Cuando la red G es capaz de generar imágenes SR que la red D no es capaz de diferenciar de las VHR originales, se genera la imagen de super-resolución.

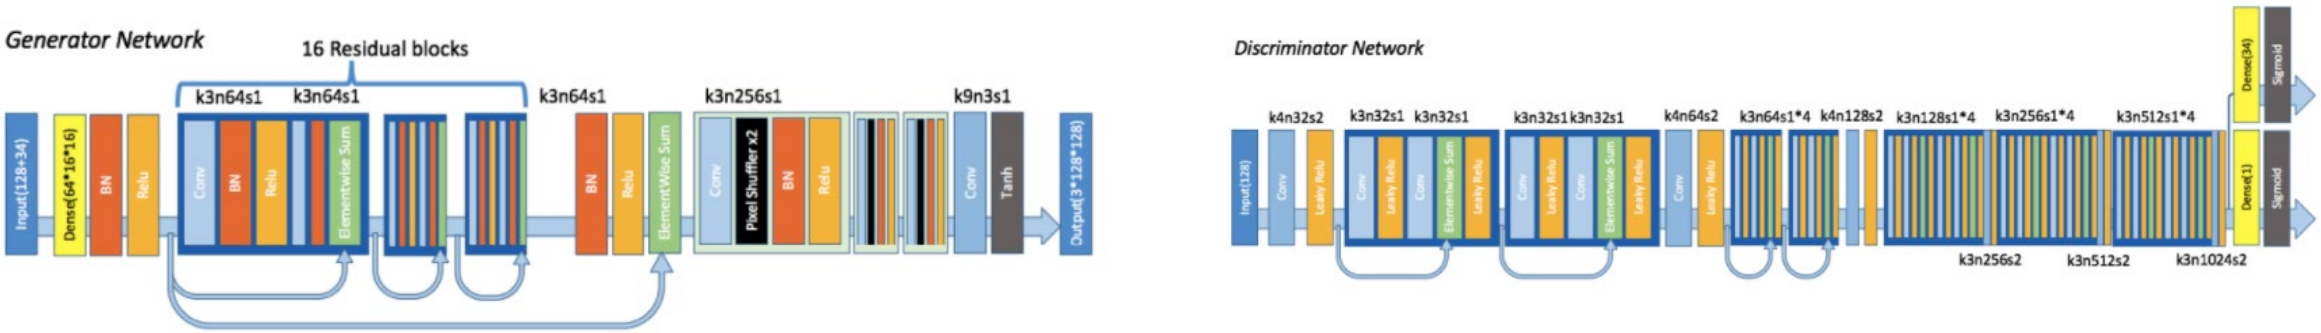

Generative Adversarial Network (GAN)

Deep Learning aplicado a la mejora de la resolución de las imágenes.

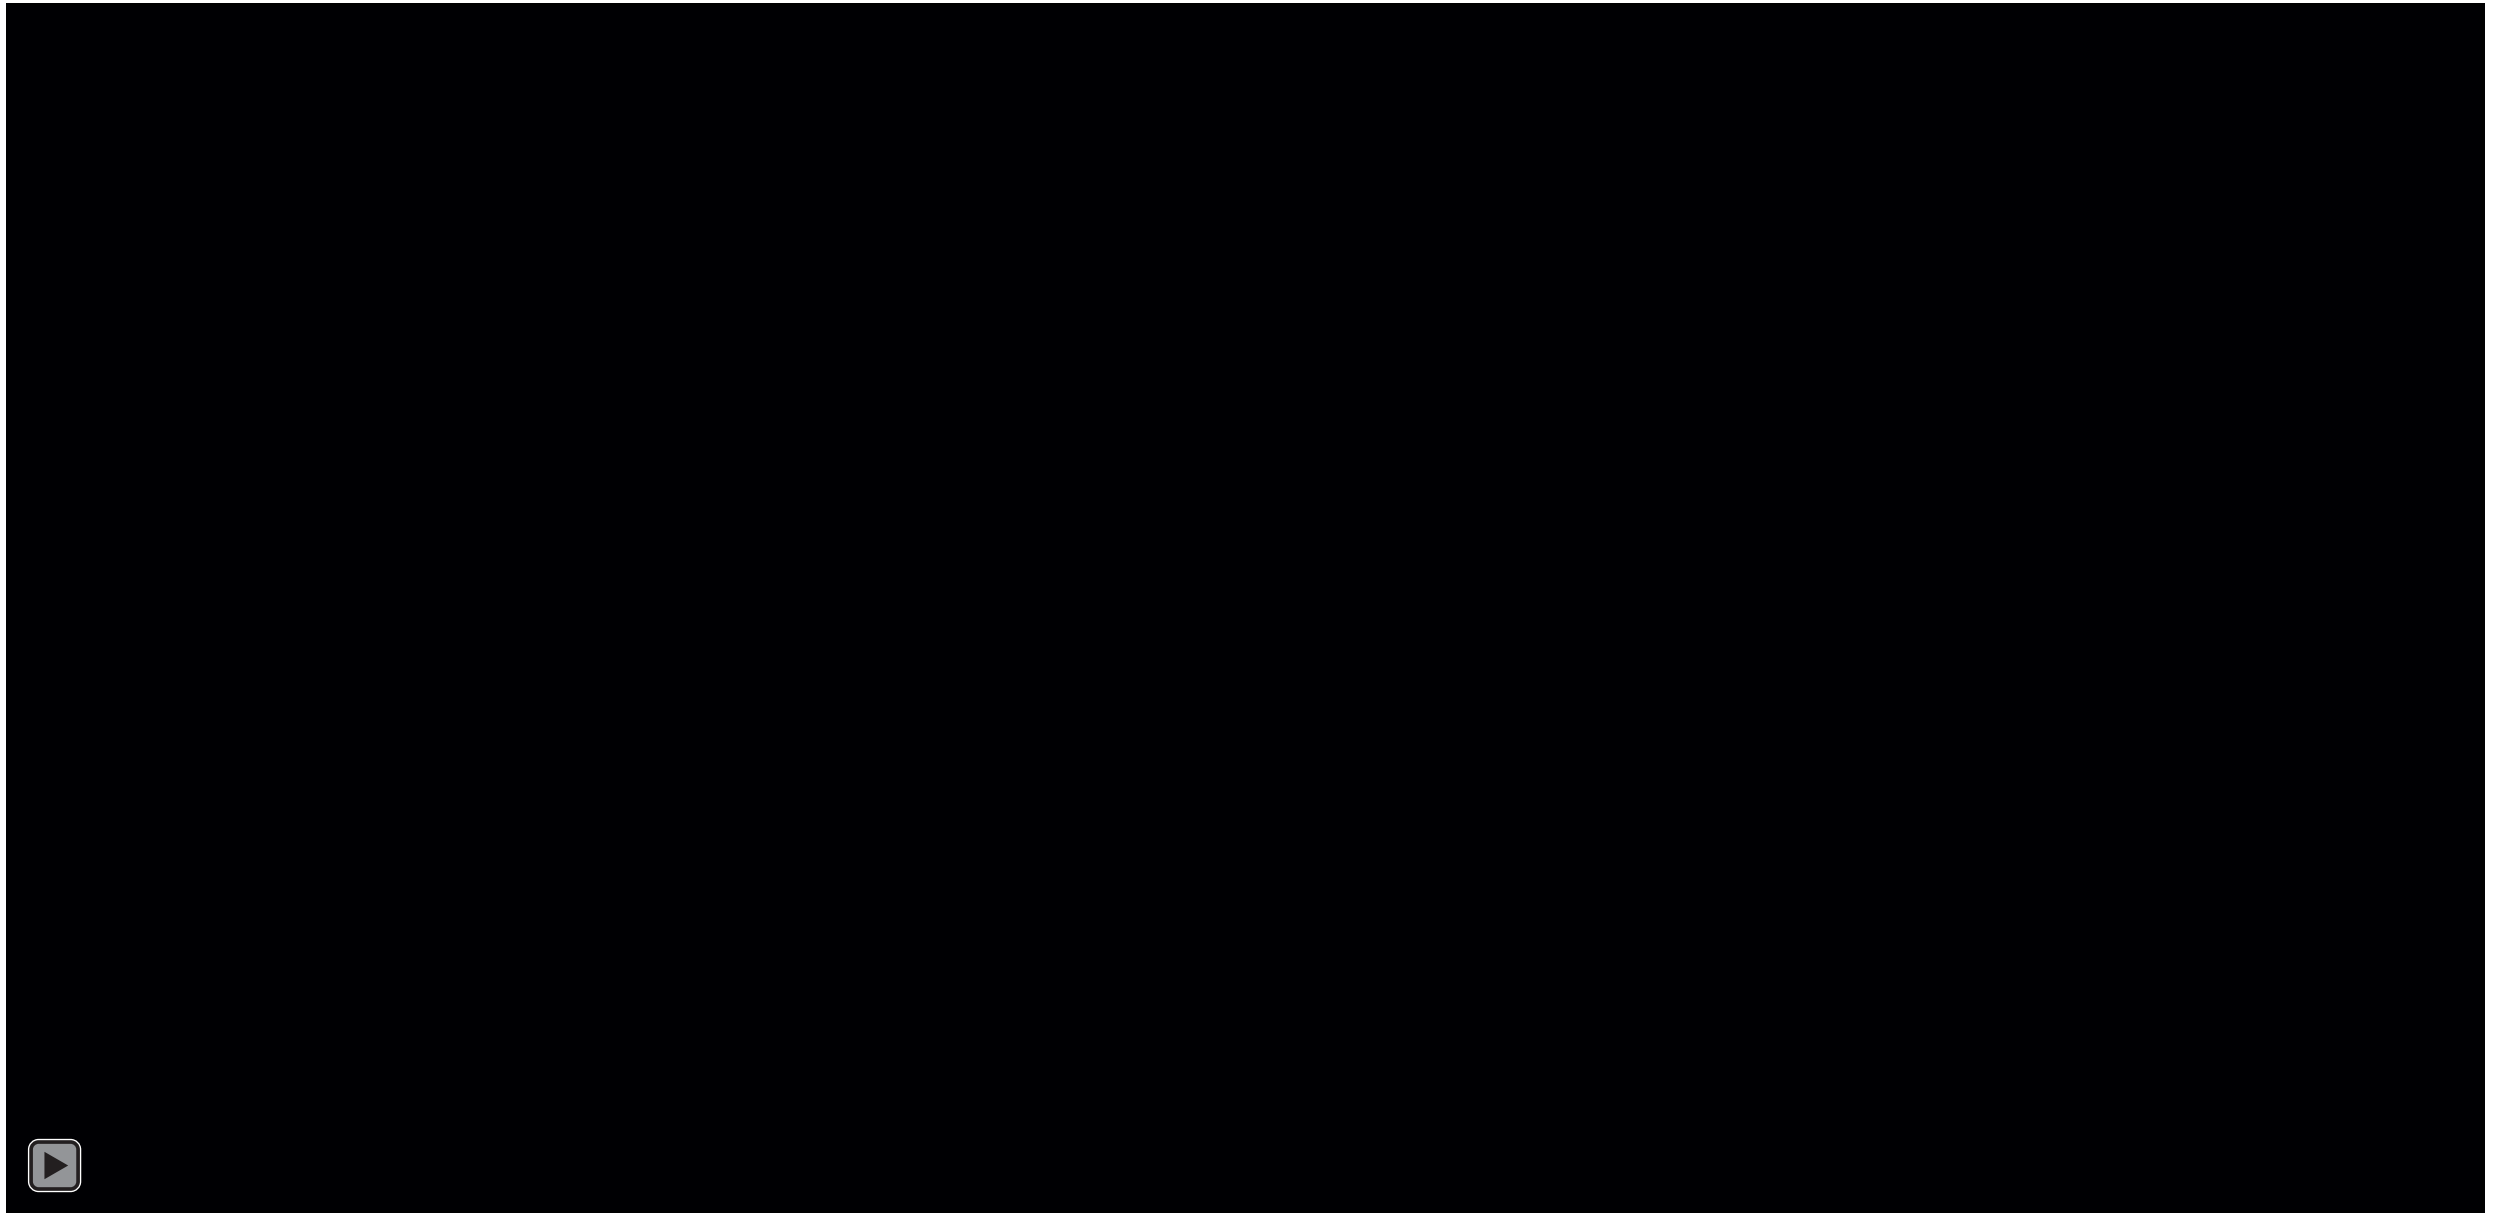

Deep Learning aplicado a la mejora de la resolución de las imágenes.

Imagen S2 original (izqda.) y superresuelta (dcha) en Parque de las Naciones

Deep Learning aplicado a la mejora de la resolución de las imágenes.

Imagen S2 original (izqda.) y superresuelta (dcha) en Puerta de Hierro

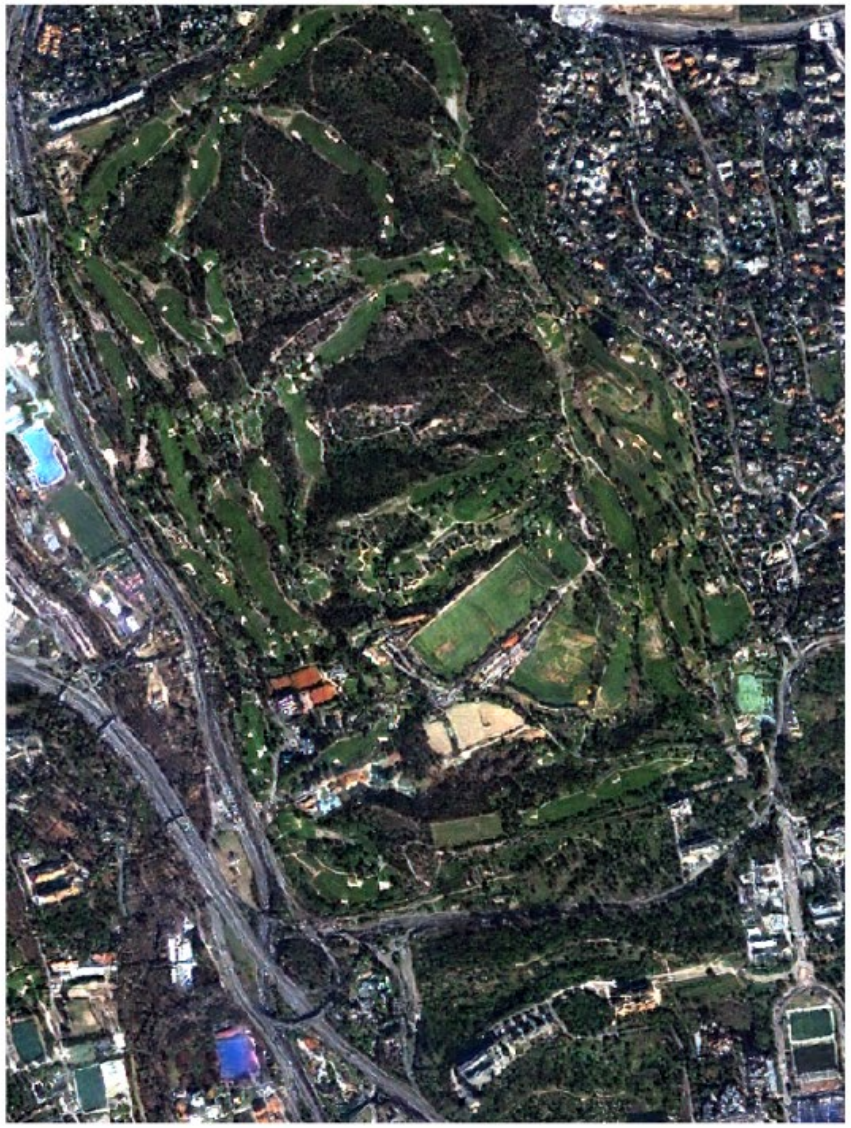

desarrollo urbano | MADRID

JORNADAS DE GEODATOS

MUCHAS GRACIAS

#GeoJornadas2022

Aurelio García / Javier Becerra
COTESA