

# Aplicación de la IA a la Guerra Electrónica en el Ámbito Aeroespacial

Diego Paramés Martínez  
David Cabornero Pascual

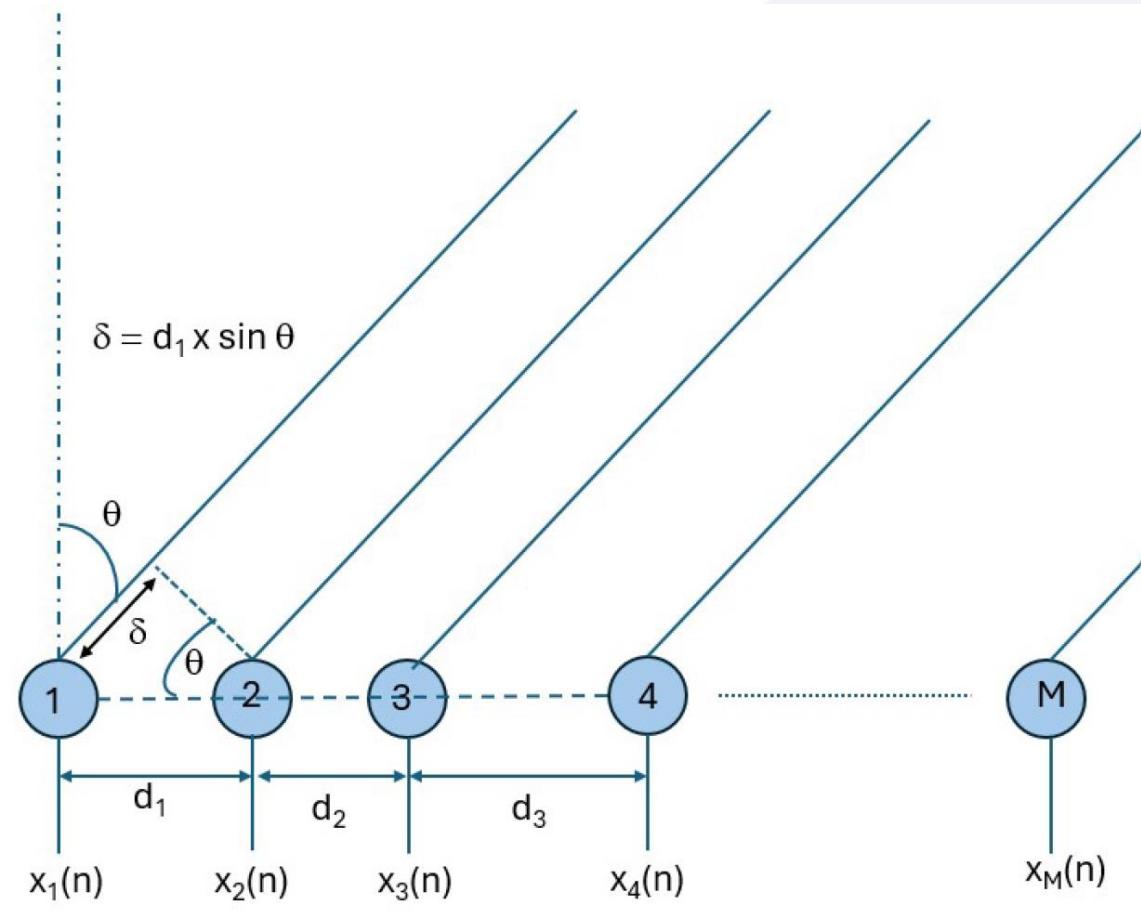
# Índice

- **Predicción de la Dirección de Llegada en entornos con ruido mediante Deep Learning (DOA).**
- Clasificación de aeronaves mediante redes neuronales convolucionales (CNN) sobre datos RCS e imágenes ISAR.

# Dirección de Llegada (DOA) con DL

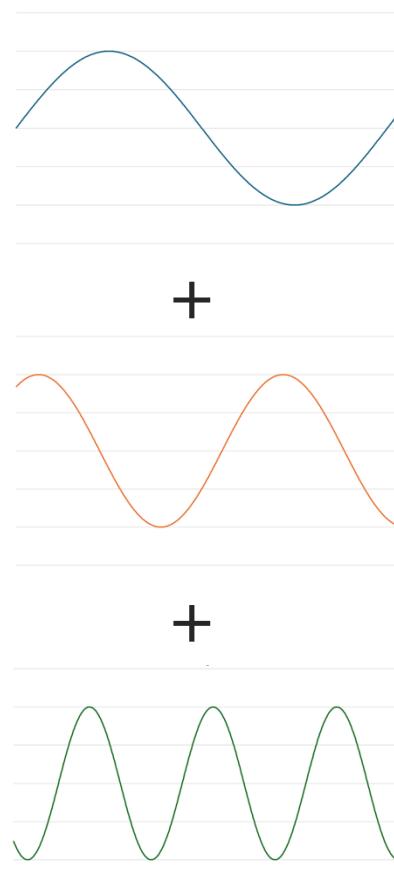
## Introducción

- Colocamos una serie de **antenas** a una cierta distancia aleatoria.
- Llegan **varias señales** en distintas direcciones.
- En unos tiempos determinados, tomamos una muestra del campo.
- **Objetivo:** averiguar cuáles son las direcciones de llegada

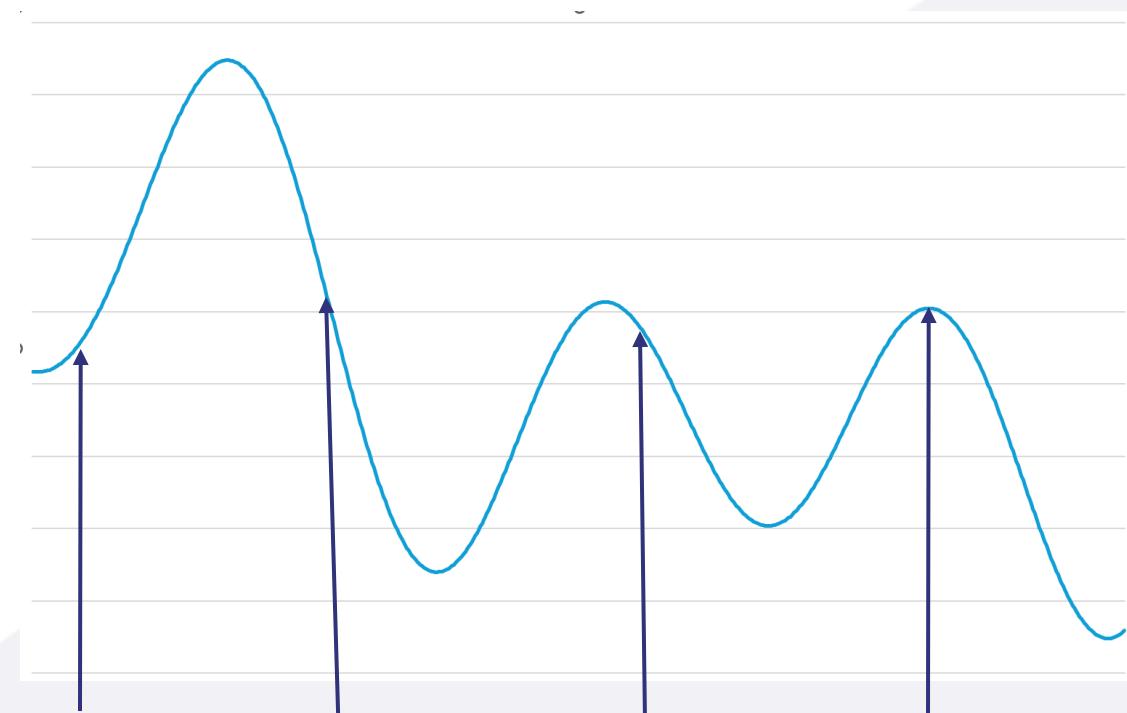


# Dirección de Llegada (DOA) con DL

Planteamiento del problema



=

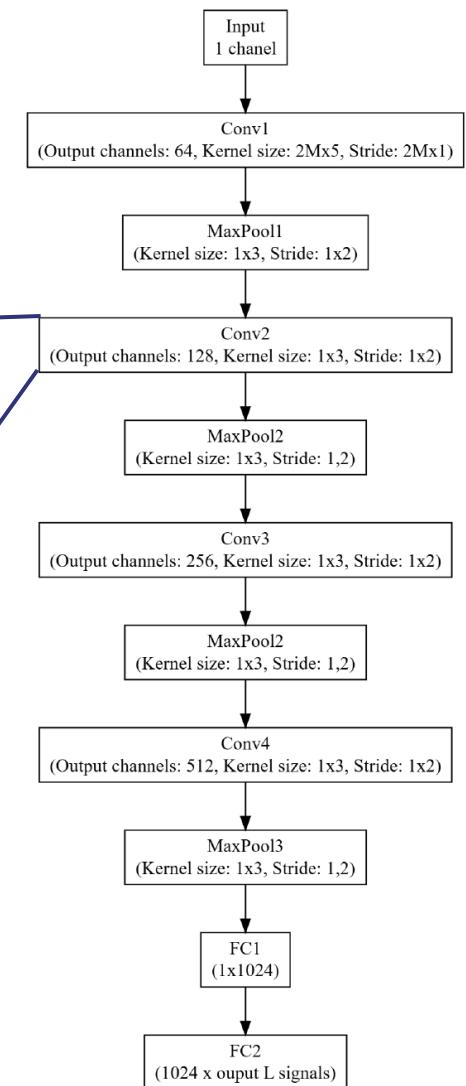
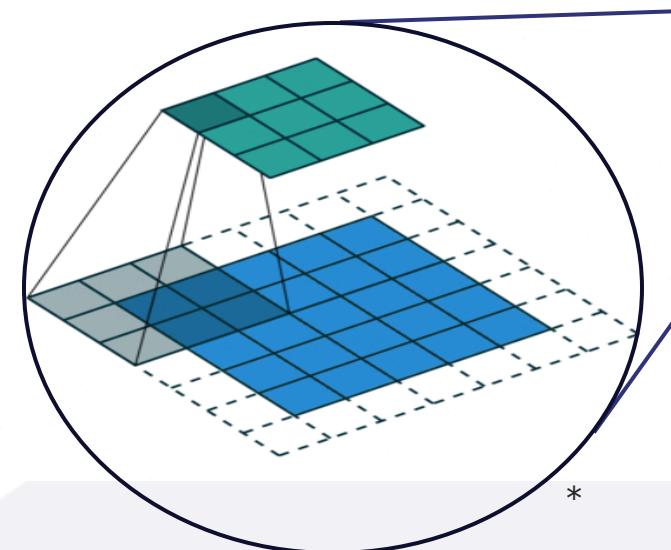


¿Cómo obtenemos de vuelta las señales iniciales? Solo disponemos de unas capturas tomadas de unas antenas a cierta distancia, no una función continua...

# Dirección de Llegada (DOA)

Solución propuesta: Redes Convolucionales

- Aunque existen algoritmos clásicos (por ejemplo, MUSIC), pero no funcionan tan bien con antenas separadas arbitrariamente.
- Nuestro problema tiene dos dimensiones, al igual que una imagen: una son los radares, la otra los instantes de tiempo.
- Se han utilizado redes convolucionales, que habitualmente utilizan imágenes para clasificar o extraer información de imágenes.

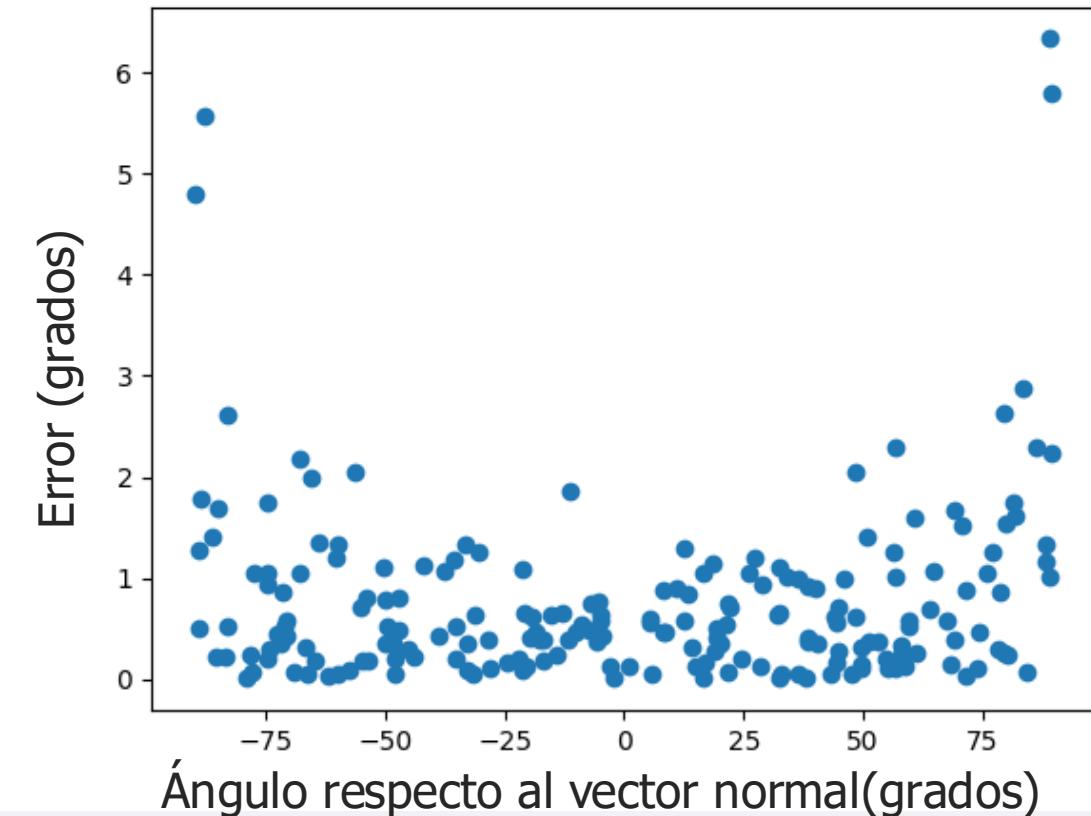


\*Convolution arithmetic - Padding strides, por Vincent Dumoulin, Francesco Visin, Wikimedia Commons

# Dirección de Llegada (DOA) con DL

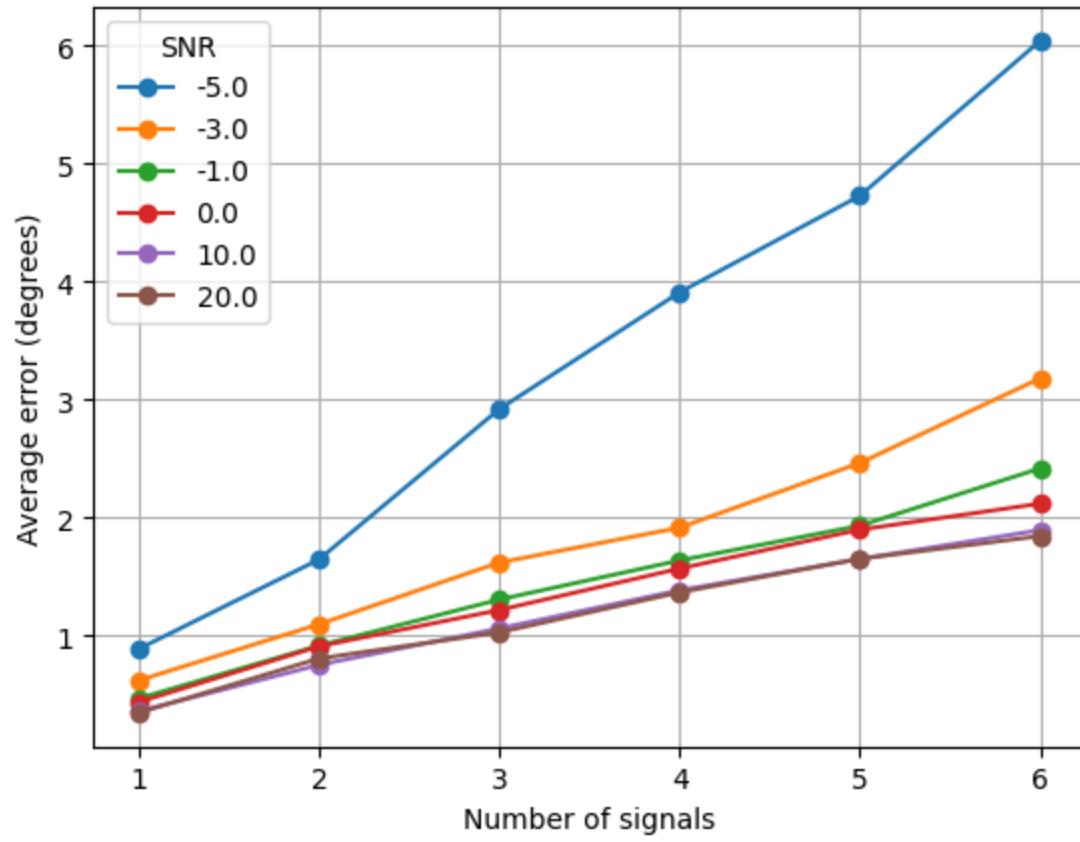
## Resultados

- La dirección de llegada es más fácil de predecir cuando la incidencia es normal.
- En cambio, las incidencias de ángulos oblicuos presentan mayores errores.
- Aún así, la red convolucional nunca se equivoca más de unos pocos grados.



# Dirección de Llegada (DOA) con DL

## Resultados



- Se puede aumentar considerablemente el número de señales a predecir con un error razonable.
- **¿Y si añadimos ruido?** Cuando la amplitud del ruido es igual de fuerte que la señal que nos llega (SNR = 0), podemos predecir hasta 6 señales con un error medio de 2°.

# Dirección de Llegada (DOA) con DL

## Conclusión

- Conclusiones
  - Para un array lineal de **antenas**, es decir, **colocadas en una línea** a distancia arbitraria.
  - Tienen **mayor dificultad** para direcciones de incidencia **oblicuas**.
  - **Buenos resultados** en casos donde el **ruido** es más **fuerte** que la señal.
- Trabajo futuro
  - Extrapolar el problema a antenas con **otros tipos de disposiciones**
  - Utilizar algoritmos de **IA generativa** para producir el problema inverso.

# Índice

- Predicción de la Dirección de Llegada en entornos con ruido mediante Deep Learning (DOA).
- **Clasificación de aeronaves mediante redes neuronales convolucionales (CNN) sobre datos RCS e imágenes ISAR.**

# Clasificación de Aeronaves mediante CNN

Definiciones

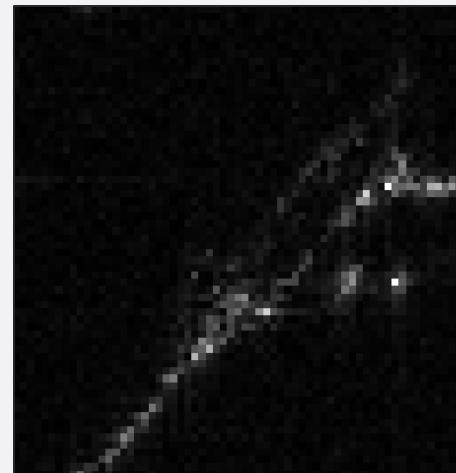
## Radar Cross Section (RCS)

Una medida de la radiación reflejada por un objetivo al incidir sobre él un frente de onda radar

## Inverse Synthetic Aperture Radar (ISAR)

Una representación bidimensional de la RCS haciendo uso de transformadas de fourier

$$\begin{pmatrix} f_1 & \cdots & f_o & \cdots & f_M \\ (\theta_o, \phi_1) & \left( \begin{matrix} E_{11} & \cdots & E_{1j} & \cdots & E_{1M} \end{matrix} \right) \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ (\theta_o, \phi_o) & \left( \begin{matrix} E_{i1} & \cdots & E_{ij} & \cdots & E_{iM} \end{matrix} \right) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ (\theta_o, \phi_N) & \left( \begin{matrix} E_{N1} & \cdots & E_{Nj} & \cdots & E_{NM} \end{matrix} \right) \end{pmatrix}$$



# Clasificación de Aeronaves mediante CNN

## Introducción

- **El objetivo:** A partir de una RCS / ISAR devolver la geometría a la que corresponde dicha señal.
  1. Se obtiene una RCS de la geometría a reconocer a través de un radar (terrestre o embarcado).
  2. Se preprocesa dicha señal para darle el formato adecuado.
  3. Se envía la señal al modelo entrenado (red neuronal) que devuelve la geometría a la que corresponde.

# Clasificación de Aeronaves mediante CNN

## Introducción

- ¿Como se llega a un modelo capaz de distinguir aeronaves?
- Una red neuronal se entrena con datos
- La clave reside en tener datos **abundantes y de calidad** (lo más realistas posibles)
- Los datasets de RCS de aeronaves no abundan
- Solución: Generar nuestros propios datos

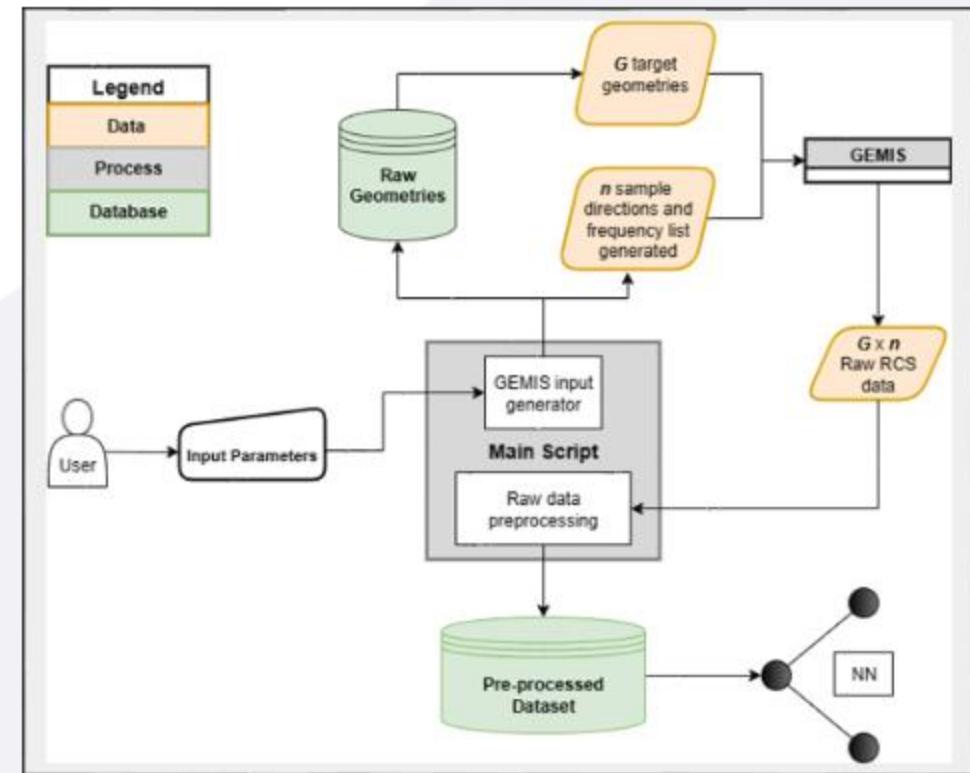
# Clasificación de Aeronaves mediante CNN

## Generación de datos

Las RCS empleadas en el entrenamiento de la red se generan a través de GEMIS.

(GEMIS es una herramienta de software desarrollada por nuestro grupo que gestiona los grandes volúmenes de datos necesarios para el cálculo de la RCS)

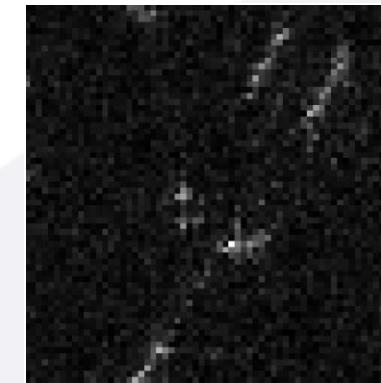
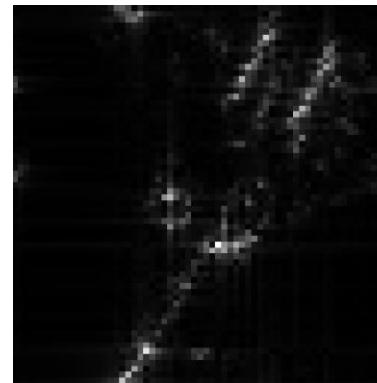
1. Se establecen los parámetros de las RCS y las geometrías entre las que se quiere diferenciar.
2. Los inputs necesarios para GEMIS son generados en base a dichos parámetros.
3. GEMIS computa las RCS deseadas.
4. Estas RCS se procesan para conseguir un **dataset**, el conjunto de datos con el que entrenamos el modelo. Este dataset contiene  $n$  RCS de cada geometría, con sus correspondientes imágenes ISAR y la etiqueta que indica a qué geometría pertenecen.



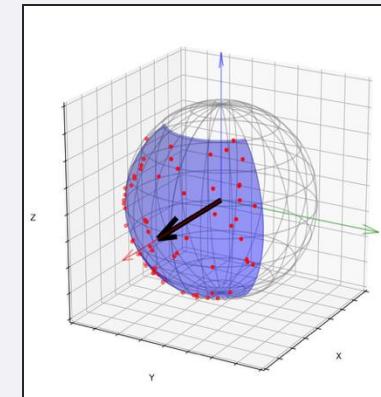
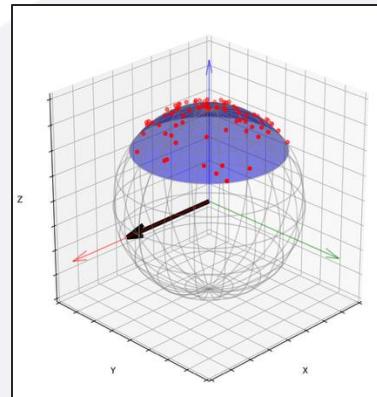
# Clasificación de Aeronaves mediante CNN

## Generación de datos

- Para acercar estos datos a los que recibe un radar real se les añade ruido. La cantidad de ruido que se añade se regula a través de la relación señal-ruido (SNR), que se establece como parámetro de entrada.



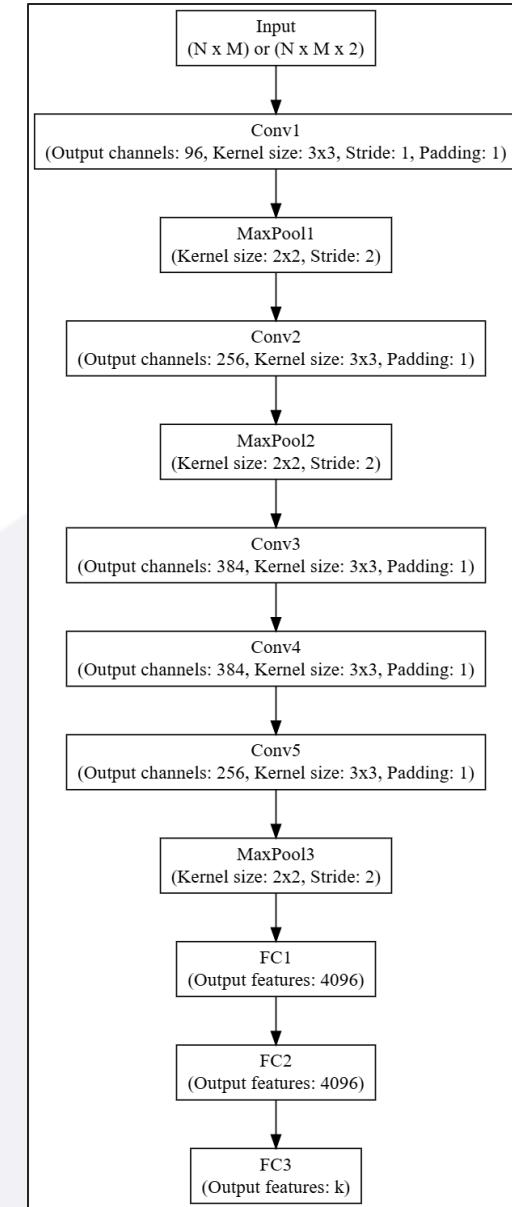
- Para entrenar modelos especializados, se añade la capacidad de restringir la zona desde la que se incide con el radar a la geometría.



# Clasificación de Aeronaves

## Red neuronal

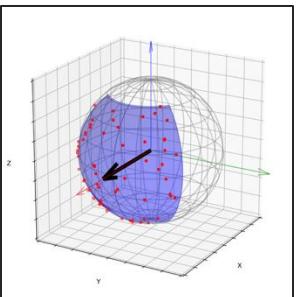
- Una vez se dispone del dataset se entrena con él la red hasta conseguir el grado de acierto deseado. El tipo de red neuronal empleada en este trabajo es una red neuronal convolucional
- Este entrenamiento siempre se hace asociado a un dataset. Esto significa que una vez entrenado, el modelo se especializa en:
  - Distinguir entre las  $k$  geometrías que componen el dataset
  - Distinguir la geometría recibiendo una RCS cuya dirección de incidencia pertenezca a la zona angular que se ha impuesto como restricción en la generación de datos



# Clasificación de Aeronaves mediante CNN

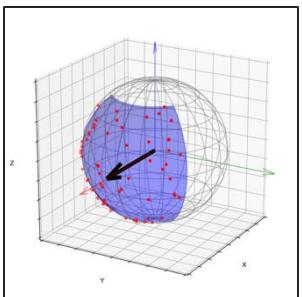
## Resultados

- 25 cazas de combate (500 muestras por geometría):



RCS	ISAR
95.17%	99.17%

- 8 geometrías pequeñas (UAVs y drones) :



RCS	ISAR
96.91%	99.13%

# Clasificación de Aeronaves mediante CNN

## Conclusión

- Los modelos funcionan:
  - Para **grandes grupos de geometrías**, independientemente de su tamaño
  - Cuando se aplican restricciones a las direcciones de incidencia (**modelos especializados**)
  - Aunque se añada una cantidad de **ruido** significativa
- Trabajo futuro:
  - Aproximar aún más la RCS a la que mediría un radar **real**
  - Trabajar con geometrías con **movimientos "menos colaborativos"**
  - Incluir la **dimensión temporal** en nuestro datasets (RNN)