



SIN DATOS NO HAY IA: EL PAPEL DEL *TRANSFER LEARNING* Y LA IDENTIFICACIÓN DE PLATAFORMAS

Introducción

La inteligencia artificial (IA) se ha convertido en un aliado estratégico en el ámbito de la defensa. Su capacidad para procesar enormes volúmenes de datos y detectar patrones permite incrementar la rapidez y la precisión de muchas operaciones militares. En particular, la IA está revolucionando las tareas de vigilancia, reconocimiento e identificación de amenazas, entornos tradicionalmente exigentes para los analistas humanos.

En un artículo anterior, presenté el programa ATLAS del Ejército de Estados Unidos, que integra algoritmos de IA en carros de combate Abrams para automatizar la detección y selección de blancos, así como el Proyecto Maven, también estadounidense, que emplea técnicas avanzadas de aprendizaje automático para interpretar, en tiempo real, las imágenes obtenidas mediante drones militares (Vereda Gorgé, 2024).

En este artículo se mostrará que la clave para desarrollar modelos de IA avanzados radica en el *dato* y su calidad, y se explicará cómo, a través de herramientas de *transfer learning* (transferencia de conocimiento), se pueden utilizar modelos ya entrenados y ajustarlos a

nuevos requerimientos, como la identificación automática de aeronaves.

«Es el dato, estúpido»

El éxito de estos sistemas no se limita a la sofisticación de los algoritmos o a la potencia de cómputo disponible, sino que descansa de manera fundamental en la calidad de los datos de entrenamiento. La piedra angular para entrenar modelos de IA robustos es contar con una base de datos cuidadosamente etiquetada. Este proceso consiste en asignar a cada imagen, por ejemplo, una categoría precisa que refleje las características específicas del objeto o fenómeno que se desea identificar.

La famosa expresión *garbage in, garbage out* (basura entra, basura sale) advierte que datos de entrada deficientes producen resultados igualmente deficientes, por muy sofisticado que sea el algoritmo. Un modelo entrenado con datos erróneos, incompletos o sesgados aprenderá de forma incorrecta y arrojará conclusiones equivocadas. Por el contrario, un conjunto de datos cuidadosamente preparado y etiquetado proporciona los ejemplos necesarios para que las redes neuronales aprendan patrones fiables del mundo real.



ImageNet es una de las bases de datos de imágenes etiquetadas más grande.
(Fuente: Krizhevsky & Sutskever, 2012)

En este sentido, la importancia de estas bases de datos radica en que, para el *aprendizaje profundo*, cada imagen actúa como un ejemplo del mundo real que permite a la red neuronal aprender a reconocer patrones y matices sutiles (Lecun *et al.*, 2015). Una recopilación de datos etiquetada con rigor posibilita que la IA pueda distinguir, por ejemplo, entre un F/A-18 y un F-35, a pesar de que ambos puedan compartir ciertos rasgos visuales.

Centralización del dato

La creciente relevancia de los datos en el ámbito de la defensa ha llevado a las organizaciones militares a diseñar estrategias y plataformas específicas para su gestión y explotación. En el plano internacional, un caso destacado es el Departamento de Defensa de Estados Unidos, que en 2018 fundó el Joint Artificial Intelligence Center (JAIC) como centro



F-18 Hornet. (Fuente: www.wikipedia.org)

integrador de los esfuerzos de IA en las Fuerzas Armadas estadounidenses.¹

El JAIC impulsó la creación de la plataforma Joint Common Foundation (JCF), concebida como un entorno común para almacenar datos, compartir algoritmos y desarrollar herramientas de IA de forma colaborativa y segura. En esencia, la JCF funciona como una plataforma en la nube con herramientas de desarrollo (DevSecOps), lo que permite a usuarios de todo el Departamento de Defensa acceder a datos, reutilizar modelos y entrenar nuevos algoritmos en un entorno compartido, acelerando así el ciclo de innovación en IA.

Iniciativas como la JCF muestran el camino hacia un ecosistema de datos integrado, donde distintos mandos y servicios (Ejército, Marina, Fuerza Aérea, etc.) puedan nutrir y beneficiarse de un repositorio común de información y modelos.

En España, a nivel del Ministerio de Defensa, aunque aún no contamos con un órgano centralizado dedicado exclusivamente a la inteligencia artificial como el JAIC/CDAO estadounidense, el enfoque actual liderado por el Centro de Sistemas y Tecnologías de la Información y las Comunicaciones (CESTIC) parece estar asumiendo estas funciones. Tradicionalmente encargado de comunicaciones, arquitectura de red y ciberseguridad —en línea con el modelo del DISA estadounidense²—, el CESTIC ya gestiona iniciativas en el ámbito de la IA, como el asistente IdolA³ lanzado

en 2024. No obstante, se mantiene el reto de crear una «ventanilla» única que facilite el acceso al dato, elemento esencial para potenciar de forma estratégica el desarrollo de la inteligencia artificial en defensa.

En la Armada contamos con el Centro de Supervisión y Análisis de Datos (CESADAR), que lleva recopilando los datos del comportamiento de equipos y sistemas de plataformas navales desde 2010. Se trata de un buen ejemplo de centralización de datos, aunque muy focalizado en el mantenimiento predictivo de las unidades a flote. Sin embargo, todavía se carece de un órgano interejércitos que sea capaz de recoger, auditar y poner a disposición de los ejércitos y la Armada el elemento básico para la creación de IA: el dato.

En definitiva, tanto a nivel internacional, con plataformas como la JCF —en España con

1. En 2022 el JAIC se integró en la Chief Digital and Artificial Intelligence Office (CDAO).

2. DISA es la Defense Information System Agency encargada de los servicios TIC (Tecnologías de la Información y la Comunicación) del ejecutivo estadounidense. Entre sus aplicaciones se encuentra, por ejemplo, la red CENTRIXS.

3. IdolA es el asistente de inteligencia artificial del Ministerio de Defensa, lanzado en 2024 y gestionado por el CESTIC. Su objetivo es integrar soluciones de IA en procesos de defensa, aunque se ha difundido poca información sobre sus capacidades.



Escudo del CESADAR

iniciativas como el CESADAR—, la tendencia es avanzar hacia un entorno unificado de datos militares. Romper los silos tradicionales y disponer de una base de datos común, segura y bien gobernada, se perfila como la solución óptima para explotar la IA en todos los ámbitos de la defensa.

Cuando los datos son limitados

Ante el desafío de conseguir datos suficientes, el aprendizaje por transferencia se ha posicionado como una herramienta fundamental en IA. ¿En qué consiste? Básicamente, en reutilizar el conocimiento adquirido por un modelo pre-entrenado en una tarea previa, aplicándolo a una nueva tarea relacionada. En otras palabras, en vez de entrenar una red neuronal desde cero, se aprovecha una red ya entrenada en un conjunto de datos masivo (por ejemplo, la base de datos de ImageNet, con millones de imágenes)


y se refina con datos específicos. De este modo, los conocimientos (patrones de bajo nivel, características...) que la red aprendió inicialmente, como bordes, formas, texturas comunes, se transfieren al nuevo problema, acelerando el entrenamiento y reduciendo drásticamente la cantidad de datos requeridos.

Esta técnica posibilita abordar casos en los que no se dispone de un gran *dataset* etiquetado. En nuestro ámbito, a menudo no se cuenta con millones de ejemplos de un tipo de plataforma o de un nuevo sistema de armas; sin embargo, gracias al *transfer learning*, unos pocos cientos de muestras pueden bastar si se aprovechan modelos genéricos entrenados con *big data*. Esto resulta especialmente útil en visión por computador (reconocimiento de imágenes de satélite o identificación de objetivos en infrarrojo, por ejemplo) o en procesamiento del lenguaje natural, donde se reutilizan modelos de lenguaje entrenados con grandes corpus para tareas específicas con datos limitados⁴.

Para ilustrar todo lo anterior, consideremos un caso práctico enfocado en la identificación de aeronaves militares a partir de imágenes. En un escenario naval, reconocer rápidamente si un avión que se aproxima es un aliado o una amenaza (y de qué tipo) es vital. Los métodos tradicionales —IFF (*Identification Friend or Foe*), el radar o la observación humana a través de cámaras electrónicas o prismáticos— tienen limitaciones, por lo que dotar a un buque de una IA de visión artificial puede suponer un salto cualitativo en conciencia situacional.

Imaginemos entrenar un sistema capaz de clasificar imágenes de aviones de distintos

4. Modelos *open source* como LLaMA, el ChatGPT de Meta (Facebook) están disponibles *online* y pueden ser descargados para utilizarlos en servidores propios o aplicar técnicas de *transfer learning* para adaptarlos a funciones específicas. Todo esto, de forma totalmente *offline*.



Las CNN ofrecen grandes resultados a la hora de clasificar imágenes⁶. (Imagen facilitada por el autor)

modelos (por ejemplo, distinguir un AV-8B *Harrier II* de un F/A-18 *Hornet* y, dentro de esta clasificación, poder determinar si porta armamento). Con suficientes patrones de entrenamiento, una red neuronal convolucional (CNN)⁵ podría lograrlo en segundos, incluso antes de que el ojo humano distinga la silueta.

En una investigación reciente (Vereda Gorgé, 2023) exploré esta idea utilizando aprendizaje por transferencia. Se seleccionaron tres arquitecturas de CNN populares: InceptionV3, DenseNet121 y EfficientNetB0. Estas redes están preentrenadas en ImageNet, y se afinaron para clasificar cuatro tipos de aviones de combate: AV-8B *Harrier II*, F-18 *Hornet*, F-35 *Lightning II* y Eurofighter *Typhoon*.

El conjunto de entrenamiento fue relativamente pequeño: 500 imágenes por cada modelo de avión (obtenidas de fuentes abiertas), lo que suma un total de 2.000 imágenes. Aun así, el uso de *transfer learning* permitió obtener modelos con precisión aceptable. En concreto, DenseNet121 (una CNN muy profunda con conexiones densas entre capas) obtuvo alrededor del 79 por 100 de acierto en la identificación de los aviones. Cabe

destacar que esta precisión se refiere a la clasificación de una sola imagen; si se empleara un vídeo a 24 fotogramas por segundo, el porcentaje de acierto podría aumentar significativamente.

Estos resultados, resumidos en la tabla 1, evidencian que elegir la arquitectura adecuada es crucial, pues no todas las redes preentrenadas rinden igual al ser transferidas a un problema específico. En este caso, DenseNet121 supo aprovechar mejor los pocos datos disponibles para diferenciar los cazas, mientras que EfficientNetB0, a pesar de ser moderno, posiblemente sufrió por su menor número de parámetros o requería más ejemplos para ajustarse. InceptionV3 ofreció un rendimiento intermedio, indicando que con algunas mejoras podría acercarse a DenseNet.

MODELO CNN	PRECISIÓN EN TEST
Densenet21	79 por 100
InceptionV3	73 por 100
EfficientnetB0	25 por 100

Tabla 1. Medida del *accuracy* de los tres modelos reentrenados utilizando *transfer learning*

5. Las CNN son un tipo de red neuronal que funciona aplicando «filtros» que detectan patrones básicos y ofrecen excelentes resultados en el análisis de imágenes.

6. En la figura se presenta una red neuronal convencional para facilitar la visualización. Las CNN son un poco más complejas.

Este experimento demuestra, en primer lugar, la utilidad del *transfer learning* que, incluso con 500 ejemplos por clase (una cantidad modesta para estándares de *deep learning*), fue posible entrenar clasificadores de imágenes con resultados aceptables a partir de modelos ya preentrenados. Entrenar desde cero con tan pocos datos seguramente habría resultado un mal desempeño (*underfitting*).

En segundo lugar, pone de relieve la importancia de contar con *datasets* representativos. Aun con *transfer learning*, EfficientNetB0 no logró generalizar bien, lo que sugiere que el conjunto de imágenes quizás no cubría suficientemente la variabilidad (ángulos, fondos, etc.) o que el modelo necesitaba más iteraciones.

En aplicaciones militares, un falso reconocimiento (confundir un avión propio por uno enemigo o viceversa) puede tener conse-

cuencias graves, de modo que habría que refinar el modelo ganador, quizás ampliando el *dataset* con nuevas imágenes sintéticas o ajustando el algoritmo, hasta lograr precisiones muy superiores (idealmente >95 por 100). En definitiva, este caso demuestra el potencial de la IA para el reconocimiento de aeronaves y subraya que ningún modelo es infalible sin datos adecuados y un riguroso proceso de validación.

Conclusión

La inteligencia artificial en el sector de la defensa es una revolución en marcha, pero su éxito depende de una base sólida de datos compartidos y estructurados. Para ello, España debería avanzar hacia un centro de datos conjunto de las Fuerzas Armadas, unificando información de los Ejércitos y la Armada. Esto

AV-8B Harrier II en la cubierta del LHD Juan Carlos I. (Fuente: Armada)



permitiría estandarizar formatos, mejorar la seguridad y optimizar el entrenamiento de algoritmos de IA multidominio.

Además, la adopción de modelos abiertos como DenseNet para reconocimiento de imágenes o LLaMA como gran modelo del lenguaje (LLM) ofrecen ventajas estratégicas: soberanía tecnológica, adaptación a doctrinas nacionales y menor dependencia de proveedores externos. Países como Estados Unidos y China ya los están aplicando en defensa, lo que refuerza la nece-

sidad de que España invierta en talento y colaboración público-privada.

La IA promete mejorar la eficacia operativa, reducir la carga de trabajo y anticipar amenazas, pero su éxito depende de datos de calidad y plataformas colaborativas. Un «copiloto» de IA en buques o centros de mando pronto será una realidad, y su efectividad dependerá de cómo sepamos integrarlo de manera segura. La revolución de la IA en defensa ha comenzado, y España debe posicionarse para aprovecharla.

BIBLIOGRAFÍA

Vereda Gorgé, J.: «Aplicaciones de la inteligencia artificial en la industria de defensa». *Revista General de Marina*, pp. 339-346, marzo de 2024. Disponible en https://armada.defensa.gob.es/archivo/rgm/2024/03/rgmmar2024_Parte08.pdf

—«Comparativa de modelos pre-entrenados para la identificación de aeronaves de guerra utilizando transfer learning», Universidad Internacional de La Rioja, 2023.

Krizhevsky A.; Sutskever, I.; Hinton, G. E.: «ImageNet Classification with Deep Convolutional Neural Networks». *Communications of the ACM*, volumen 60, pp. 84-90. Disponible en <https://dl.acm.org/doi/10.1145/3065386>
https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf
 LeCun, Y.; Bengio, Y.; Hinton, G.: «Deep learning», *Nature*, vol. 521, n.º 7.553, pp. 436-444, mayo de 2015, doi: 10.1038/NATURE14539

Chief Digital and Artificial Intelligence Office (CDAO). Disponible en <https://www.ai.mil/>
 Centro de Sistemas y Tecnologías de la Información y las Comunicaciones (CESTIC). Ministerio de Defensa de España. Disponible en <https://www.defensa.gob.es/ministerio/organigrama/sedef/cestic/>
 «Idoia, el nuevo asistente de inteligencia artificial del Ministerio de Defensa». Disponible en <https://www.info-defensa.com/texto-diario/mostrar/4930887/idoia-nuevo-asistente-inteligencia-artificial-ministerio-defensa>

Ocaso en la fragata *Cristóbal Colón* (F-105).
(Foto: Mercedes García García)

