

Tecnologías emergentes

Resultados del proyecto SEDA Satellite Data AI para el procesado automático de imágenes satélite

Autores: Isabel Iglesias Pallín, Bernardo Martínez Reif, OT TICS, SDG PLATIN.

Palabras clave: *Deep Learning*, redes convolucionales, procesado de imágenes, inteligencia artificial.

Líneas I+D+i ETID relacionadas: 11.1.3, 11.1.4.

Introducción

SEDA – *Satellite Data Ai* es una propuesta de proyecto seleccionada y presentada por la empresa Hi-Iberia a la convocatoria Coincidente 2018 dentro de la temática *Sistemas inteligentes de análisis y explotación de información aplicado a la resolución de problemas militares*.

El objetivo principal del proyecto SEDA es desarrollar y probar un demostrador tecnológico que permita automatizar el proceso de obtención, análisis y fusión de datos satelitales de diferentes fuentes de datos (tanto privadas como públicas) de tal forma que se garantice la detección temprana y eficaz de elementos o situaciones anómalas relevantes que apoyen la toma de decisiones en el proceso de creación de inteligencia militar del Centro de Operaciones y Vigilancia de Acción Marítima (COVAM).

Este artículo pretende describir las tecnologías de detección que se han empleado durante el desarrollo del proyecto y presentar los resultados obtenidos, una vez finalizado el proyecto.

Los resultados del proyecto SEDA han permitido disponer de una plataforma web de inteligencia geoespacial para defensa que, basada en un conjunto de motores de inteligencia artificial, es parametrizable de tal forma que permite seleccionar una localización concreta a monitorizar así como el tipo de objeto o anomalía que se pretende detectar.

Deep Learning para el procesamiento automático de imágenes

La principal tecnología disruptiva utilizada en el proyecto SEDA ha sido el uso de motores de inteligencia artificial para el procesamiento automático de imágenes satelitales mediante el uso de *Deep Learning*.

La tecnología *Deep Learning* se puede considerar un subconjunto de algoritmos de *Machine Learning* basados en el uso de redes neuronales profundas. La principal diferencia entre ambas tecnologías es que el *Deep Learning* es capaz de extraer de forma automática las caracterís-

cada una de ellas formada por estructuras complejas que realizan múltiples transformaciones no lineales y que son capaces de extraer diferentes características de los datos.

Una de las principales novedades que ha introducido el proyecto SEDA ha sido el reconocimiento de imágenes satelitales no solo en imágenes ópticas del tipo RGB¹ sino en imágenes radar, extendiendo así la capacidad de detección fuera del espectro visible. Sin embargo, este proceso no ha sido sencillo ya que uno de los problemas encontrados durante la fase de implementación del sistema de

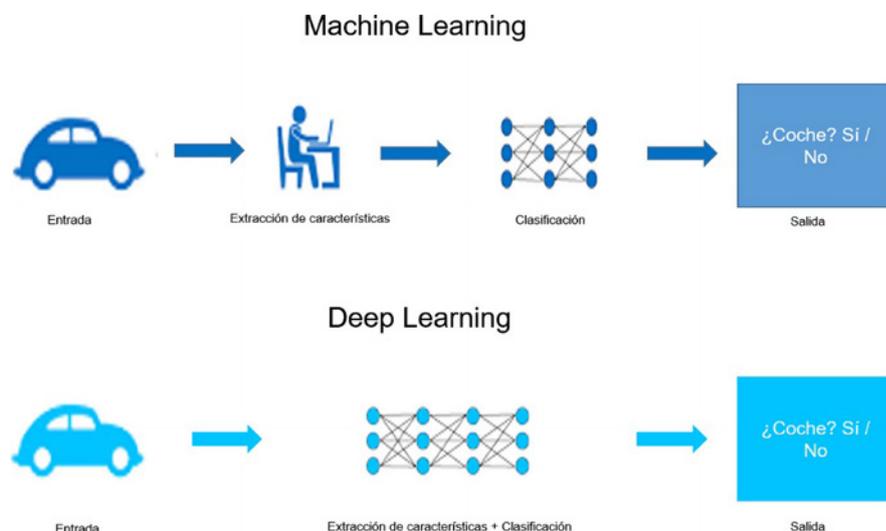


Fig. 1. Comparativa entre el análisis de datos del Machine Learning frente al Deep Learning (Fuente: propia).

ticas que definen un sistema, proporcionando un marco universal de aprendizaje para la representación de información visual.

Aunque las redes neuronales artificiales eran conocidas desde los años cincuenta, su popularización no se produjo hasta la aparición del *Deep Learning* hace algunos años, favorecido por factores como el aumento de la potencia de computación, la cantidad de datos existentes, la aparición de nuevos algoritmos, paradigmas de programación o la mejora en las infraestructuras a nivel *hardware*.

Deep Learning modela abstracciones de alto nivel en datos mediante redes neuronales profundas compuestas por múltiples capas de procesamiento,

Deep Learning como el planteado en SEDA ha sido el hecho de que, para entrenar los motores de inteligencia artificial que lo componen, se necesitan una cantidad ingente de datos etiquetados de imágenes similares a las que se quieren reconocer. A pesar de la existencia de gran cantidad de imágenes satelitales en fuentes de información específicas, la mayoría de ellas se encuentran sin etiquetar. La solución que se ha buscado para abordar este problema durante el proyecto SEDA ha sido el uso de algoritmos de *Deep Learning* que permiten entrenar modelos con poca

¹ RGB (sigla del inglés *red, green, blue*; en español, rojo, verde, azul) composición del color en términos de la intensidad de los colores primarios de la luz.

Tecnologías emergentes

cantidad de imágenes etiquetadas. En concreto se ha trabajado con las llamadas redes neuronales convolucionales profundas, donde se realiza una transferencia de conocimiento para reutilizar modelos de *Deep Learning* entrenados en una antigua tarea a la tarea en curso. Con esto, se consigue entrenar nuevos modelos con

de *Machine learning* frente al uso de la transferencia de aprendizaje.

Redes neuronales convolucionales

Las redes neuronales convolucionales se pueden definir como un tipo de red neuronal especializada en analizar las propiedades visuales de los objetos. Estas características logran que

Al aplicar estas técnicas al dominio de interés de defensa se pueden identificar plataformas, instalaciones militares o cambios que se puedan producir en el terreno entre dos momentos diferentes, por ejemplo, el despliegue de un campamento de campaña en zona de operaciones.

Resultados obtenidos en el proyecto SEDA

El alcance final del proyecto ha sido la obtención de un demostrador tecnológico completamente operativo entrenado para los casos de uso determinados y definidos por el Centro de Operaciones y Vigilancia de Acción Marítima de la Armada. Entre estos casos de uso contemplados se encuentran el reconocimiento de buques por tipo y por clase, la detección de buques en zonas específicas definidas con la posibilidad de alertar sobre su localización, la detección de buques abarloados² o el seguimiento múltiple de trazas a lo largo del tiempo, entre otros.

El desarrollo del demostrador ha permitido mejorar el análisis para la detección de objetivos en imágenes satélite basado en un sistema inteligente de redes neuronales profundas debidamente entrenado para la interpretación automática de imágenes y la detección en ellas de los elementos buscados, en base a los casos de uso previamente definidos.

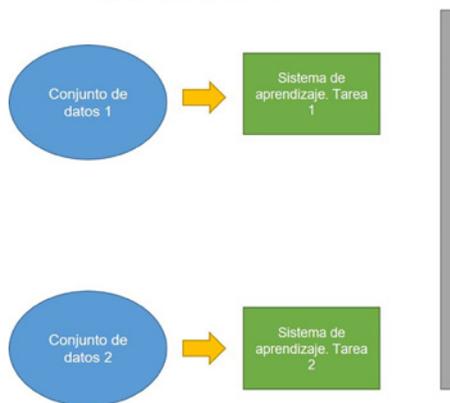
Además, se ha desarrollado un portal web para la generalización del proceso de obtención de datos de diferentes fuentes, tanto públicas como privadas, que permite recolectar y almacenar los datos en una base de datos georreferenciada.

Por último, también se ha desarrollado un sistema de fusión e integración de los datos obtenidos desde diferentes fuentes para combinar aquellas características relevantes y obtener un conjunto de datos geoespaciales preprocesados.

El proyecto SEDA, de esta forma, está facilitando los procesos de inteligencia militar asociados al tratamiento de imágenes satelitales y mejorando la consciencia situacional de nuestras Fuerzas Armadas en el desarrollo de las misiones que se le encomiendan.

² Un buque está *abarloado* cuando se sitúa con el costado muy próximo a un muelle o a otro buque.

Aprendizaje máquina tradicional



Transferencia de aprendizaje

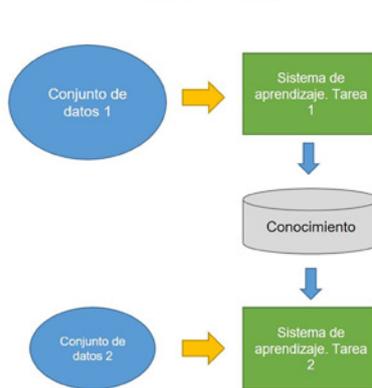


Figura 2. Diferencias entre el aprendizaje máquina tradicional frente a la transferencia de aprendizaje (Fuente: propia).

menos datos y en menor tiempo.

Transferencia de aprendizaje con redes neuronales convolucionales

El término de transferencia de aprendizaje se refiere, como se ha comentado anteriormente, a reutilizar el conocimiento adquirido al realizar una tarea para hacer otra similar. De forma específica, cuando se transfiere aprendizaje en redes neuronales convolucionales muchas características que son comunes a una variedad de conjuntos de datos como pueden ser las líneas o bordes de las imágenes se transfieren de una imagen a otra.

La transferencia de aprendizaje es una de las técnicas más importantes utilizadas en *Deep Learning* para el aprendizaje automático en inteligencia artificial, ya que es un recurso economizador de tiempo y de grandes esfuerzos de cálculo. Con los datos obtenidos de una tarea similar, pero más genérica, se evitan aproximaciones más costosas a un punto de partida óptimo.

En la siguiente imagen (fig. 2) se muestra de forma esquemática la diferencia entre el funcionamiento tradicional de aprendizaje con técnicas

la inteligencia artificial pueda llegar a simular a la visión humana.

En este caso particular de una red neuronal, el término convolución proviene de las matemáticas y describe una función aplicada a otra. Se trata de una operación en la que se descartan las diferencias internas entre una misma categoría de objetos, y esta discriminación sobre las peculiaridades resulta clave al asegurar una asignación de etiquetas con altas probabilidades de ser las correctas.

Sin embargo, para la aplicación de estas técnicas, la cantidad de imágenes para el entrenamiento de las redes neuronales debe ser elevada ya que cada una de las imágenes se analiza diferenciando todas sus partes en base al color. Cada uno de los píxeles de la imagen segmentada proporciona una información numérica y es, en este momento, cuando las convoluciones entran en juego al buscar patrones por comparación con la imagen objeto de clasificación automática y el grupo de píxeles segmentados superponiéndose en la imagen. Las superposiciones sobre la imagen generan nuevas salidas. Cuanto más complejas sean las imágenes y formas contenidas en ellas, mayor deberá ser el número de convoluciones.