

# Extracción de conocimiento mediante la aplicación de Inteligencia Artificial a la información espacial

Aplicación de técnicas de *Machine Learning* a la producción de conjuntos de datos espaciales temáticos a partir de imágenes georreferenciadas.

**RODRIGO, Jose Julio; ROSALES, Juan Jorge**

Los conjuntos de datos espaciales de imágenes, o ráster, ofrecen una visión intuitiva y amplia de la realidad, sin embargo, su análisis mediante técnicas de procesamiento espacial o geoprocesamiento resulta más difícil que usando datos vectoriales. En una ortofoto aérea -quizás el exponente más representativo de este tipo de de datos espaciales- es relativamente sencillo, si se cuenta con la resolución adecuada, apreciar la presencia o ausencia de una determinada entidad mediante inspección visual. Ahora bien, tareas como identificar automáticamente todos los emplazamientos que registran ocurrencias de esa entidad (por ejemplo, una construcción), generar representaciones geométricas de dichas ocurrencias o identificar en una secuencia temporal de imágenes cuándo aparece por primera vez, han sido difícilmente automatizables hasta la fecha y relegadas a trabajos de operador.

En el pasado, los intentos de automatizar el análisis y extracción de información en imágenes aéreas mediante técnicas de visión por computador han obtenido resultados de escasa aplicación práctica. En este artículo se presenta la utilización de técnicas de Machine Learning (Aprendizaje Automático) aplicadas a la detección automática de cambios utilizando ortofotos suministradas por servicios estándares de Infraestructuras de Datos Espaciales.

## **PALABRAS CLAVE**

Inteligencia Artificial, Deep Learning, Machine Learning, Redes Neuronales, Control de cambios.

## **1. INTRODUCCIÓN**

Las competencias de muchas áreas de la Administración poseen una relación intensa y directamente referida al territorio. No sólo porque el medio físico constituye en sí mismo un objetivo de toda la gestión administrativa de protección del medio ambiente y ordenación territorial, sino porque es en él donde se desarrollan las actuaciones propias de estas administraciones relativas a actividades como la agricultura, el transporte, la seguridad, la educación o la sanidad.

Esta estrecha relación entre territorio y Administración hace que abordar con garantías muchos procesos de planificación, gestión o inspección requieran de un adecuado conocimiento de dicho territorio y de los cambios que en él se producen. La naturaleza de los cambios que son de interés para un área determinada de la Administración viene determinada por sus responsabilidades. En este sentido existe un espectro muy amplio: variaciones de cultivos, nuevas construcciones, ejecución de infraestructuras, evolución de suelos urbanizables a urbanos, crecimiento de masas forestales, procesos erosivos, evolución del contenido de vertederos, etc.

En los sistemas de información geográfica (SIG) e infraestructuras de datos espaciales (IDE) el conocimiento de la realidad se modela a través de conjuntos de datos espaciales. Estos conjuntos pueden englobarse en dos grandes categorías: información geográfica de referencia e información geográfica temática. La primera es de carácter horizontal, su producción suele ser sostenida en el tiempo y, generalmente, es la base sobre la que se apoya la segunda. Esta información de referencia se materializa a través de productos como los mapas topográficos, la ortofotos o los modelos digitales de elevación.

El conocimiento de los cambios que se producen en el territorio se obtiene a partir del análisis comparado de conjuntos de datos espaciales. Por lo general, suele requerir la aplicación de un conocimiento específico, relacionado con la naturaleza de los cambios, capaz de sintetizar en un nuevo conjunto de datos espaciales las modificaciones o alteraciones detectadas. La bondad de los resultados obtenidos depende, en gran medida, tanto de las características de la información de partida como de las técnicas de extracción de conocimiento empleadas.

Las condiciones ideales exigibles a un proceso de control de cambios incluyen la detección temprana, es decir, en fechas próximas a aquellas en las que se han producidos los cambios, unos costes reducidos, un alto grado de fiabilidad y garantías de completitud.

Los primeros trabajos de detección de cambios sobre el territorio desarrollados por Cartográfica de Canarias, S.A. (GRAFCAN) se remontan a más de quince años y, con modificaciones, han tenido continuidad hasta la actualidad. Casi siempre centrados en construcciones y viario como principales elementos vertebradores del territorio. Las primeras actuaciones consistieron en trabajos de fotointerpretación de ortofotos por parte de operadores y, por tanto, presentaban un elevado componente de intervención humana. En el año 2010, la utilización de la tecnología LIDAR supuso un punto de inflexión en la detección de cambios e introdujo importantes mejoras en términos de productividad, fiabilidad y completitud.

Los avances producidos durante los últimos años en el campo de Machine Learning [1][2], de la mano de grandes empresas tecnológicas, junto con la disponibilidad gratuita de diversas plataformas de desarrollo para esta disciplina, hicieron que en el año 2016 GRAFCAN iniciara una línea de investigación interna con el objetivo de evaluar la viabilidad y resultados de aplicar estas técnicas de inteligencia artificial a la extracción de conocimiento del territorio mediante la generación automática de conjuntos de datos espaciales vectoriales. En cierto sentido, se planteaba el reto, en problemas acotados, de examinar en qué medida era reproducible la forma de trabajar de un operador experimentado en labores que actualmente son costosas, en recursos y tiempo, y por tal motivo, en muchos casos, ni siquiera se abordan.

Esta investigación se materializó en un primer proyecto piloto que combinó la familiarización con las técnicas y herramientas de Machine Learning con la resolución de un problema muy concreto y acotado: detección de señalización horizontal. Los avances y buenos resultados de este proyecto piloto fueron la base para abordar otro proyecto de complejidad superior, consistente en la detección de cambios sobre ortofotos, cuyos resultados han sido satisfactorios hasta el punto de ser incorporados a la oferta de servicios de GRAFCAN.

## **2. ANTECEDENTES**

Los primeros controles de cambios abordados en GRAFCAN consistían en la comparación de ortofotos de un mismo ámbito territorial en diferentes momentos de tiempo. Esta forma de trabajar puede detectar elementos de mucho detalle, si se cuenta con imágenes de resolución adecuada, y asociar con precisión tipologías de cambios complejas. Por el contrario, adolece de inconvenientes como la necesidad de personal experimentado, efecto de la fatiga, diferencia de criterios entre personas, lentitud por su naturaleza manual y probabilidad de omisiones. Además hay que considerar la limitación que supone la ausencia de información altimétrica cuantificable en la fuente de información utilizada.

Al poco de iniciar este tipo control de cambios en GRAFCAN, se llevaron a cabo varios proyectos, en colaboración con la Universidad de La Laguna, con el objetivo de automatizar estos trabajos mediante la aplicación de técnicas de visión por computador. Estos proyectos se centraron en la detección de construcciones y viables pero sus resultados no fueron satisfactorios y, por lo tanto, no tuvieron aplicación práctica. Una de las conclusiones de estos trabajos fue la sensibilidad de las técnicas aplicadas a la variabilidad existente entre las imágenes comparadas por efecto de factores como la estacionalidad, hora de vuelo, condiciones climáticas, estado de la vegetación, mareas y

oleaje.

Los controles de cambios mediante fotointerpretación de ortofotos tuvieron continuidad en el tiempo, en el marco de proyectos relacionados con la disciplina urbanística hasta la adopción de la tecnología LIDAR en el año 2010. Una variante de estos controles, que hoy en día aún se usa ocasionalmente en GRAFCAN, es la detección de cambios por comparación de pares estereoscópicos con cartografía destinada a la actualización de mapas topográficos.

A mediados del año 2010, el control de cambios sufrió un importante avance con la utilización de los vuelos LIDAR como elementos de comparación. Los vuelos LIDAR permiten obtener nubes de puntos tridimensionales que pueden ser convertidas a superficies continuas, de terreno o superficie, sobre las que se pueden realizar operaciones aritméticas como la resta. Así, diferencias positivas obedecerán a crecimientos en el eje z y las negativas a decrecimientos. Al tratarse de información tridimensional también se pueden acometer cálculos de volúmenes sobre una determinada superficie. En cuanto a la superficie mínima de los cambios a detectar, ésta está condicionada por la densidad de las nubes de puntos que es uno de los factores más relevantes en la planificación de vuelos LIDAR.

Por lo general, los resultados de la resta de superficies generadas a partir de vuelos LIDAR deben ser sometidos a procesos de revisión posterior. En algunos casos automatizables y en otros asistidos por operador. La obtención de una diferencia indiscriminada hace que puedan proliferar falsos positivos producto de, por ejemplo, la posición de grandes medios de transporte (guaguas, aviones, barcos...) o el tamaño y orientación de la vegetación. También tiene incidencia en el análisis de datos LIDAR la orografía de las zonas voladas, en especial, las de elevada pendiente, y otros factores como la densidad de la vegetación.

La principal ventaja de la tecnología LIDAR aplicada al control de cambios es su objetividad, productividad y capacidad de análisis tridimensional. Por el contrario, es necesario disponer de vuelos que pueden ser bastante costosos, en función de la densidad de puntos, y aplicar procedimientos de filtrado a los resultados.

La crisis económica de los últimos años trajo consigo la disminución de la frecuencia de actualización de la información geográfica de referencia de Canarias. A excepción de la OrtoExpress de 25 cm/píxel, que mantiene una frecuencia de actualización anual, el resto de productos se renueva en intervalos de dos, tres o cuatro años. En el caso concreto del LIDAR, cada tres años.

Esta circunstancia obligó a pensar en una alternativa, o complemento, al control de cambios basado en la tecnología LIDAR para sostener la detección de cambios anual en el ámbito de toda la Comunidad Autónoma. Dicha reflexión coincidió con el reciente auge del Machine Learning. Un Machine Learning que ya está presente en ámbitos tan cotidianos y tan dispares como el filtrado de correo no deseado, la búsqueda de imágenes por contenido o la confección de ofertas a medida.

En el año 2016 se iniciaron trabajos de I+D+i relacionados con el Machine Learning con el objetivo de extraer información a partir de ortofotos. En concreto, se centraron en la rama de Deep Learning (Aprendizaje Profundo) en la que existen algoritmos de Machine Learning que permiten modelar ciertos tipos de conocimiento usando arquitecturas de Redes Neuronales Artificiales como las Redes Neuronales Convolucionales Profundas (*Deep Convolutional Neural Networks*). A grandes rasgos, el proceso de aprendizaje conlleva un proceso previo de diseño de una arquitectura de neuronas artificiales organizadas en capas que se conectan entre sí y, posteriormente, el proceso de aprendizaje en sí mismo. Este último se lleva a cabo utilizando lo que se conoce como patrones de entrenamiento. Es decir, parejas de información de entrada y resultados deseados a la salida.

### **3. DETECCIÓN DE SEÑALIZACIÓN HORIZONTAL**

Este proyecto piloto se planteó principalmente como un proceso de capacitación y acumulación de

experiencia con las técnicas y herramientas asociadas a la rama de Deep Learning del Machine Learning. Para ello se abordó el problema de detectar, clasificar y ubicar automáticamente determinadas señales horizontales presentes en los carriles de la red viaria canaria. En concreto, las siguientes:

- Mantener el sentido de circulación (recto).
- Giro a izquierda.
- Giro a derecha.
- Mantener el sentido de circulación o girar a la izquierda.
- Mantener el sentido de circulación o girar a la derecha.
- Mantener el sentido de circulación, girar a la izquierda o girar a la derecha.
- Ceda el paso.
- Ausencia de señal.

Disponer de esta información clasificada y georreferenciada es útil, por ejemplo, para contrastar los sentidos de circulación asociados a los tramos viarios de la red de transporte o las maniobras permitidas en la confluencia de dos o más tramos.

Como fuente de información principal se utilizó la OrtoExpress Urbana de Canarias que tiene una resolución de 10 cm/píxel. La definición de la arquitectura de la red y los procesos de aprendizaje se desarrollaron sobre el entorno de trabajo Tensorflow [7] desarrollado por Google para proyectos de esta naturaleza.

La entrada a la red la conformaron recortes de la ortofoto con presencia de la señalización ya enumerada. Se optó por imágenes en blanco y negro porque el color no es una información relevante y la disminución del tamaño de las imágenes reduce los tiempos de proceso. Estas imágenes junto a la categoría correspondiente a cada una constituyeron los patrones de entrenamiento de la red.



Figura 1: Ejemplos de patrones de señales de diferentes clases.

La arquitectura de la red se basó en capas convolucionales seguidas de capas de generalización (*pooling*) y finalmente un clasificador basado en capas totalmente conectadas (*fully connected*). Su configuración final fue el resultado de un proceso de pruebas sistemáticas y análisis comparado de resultados.

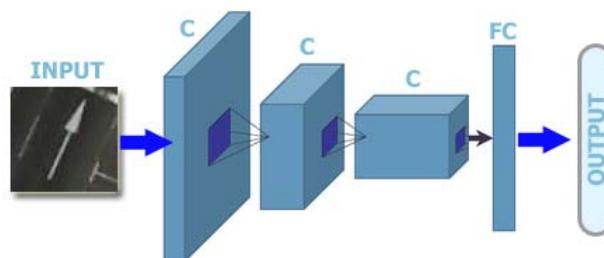


Figura 2: Arquitectura de la Red Neuronal Convolutiva

Los resultados de este primer proyecto, después de haber probados numerosas variantes de arquitectura y valores de parámetros, fue de un 98,48% de aciertos sobre el conjunto de datos de evaluación que estaba formado por 662 patrones.

Al margen de la valoración de los resultados de este proyecto, el abordar un problema muy concreto y acotado permitió adquirir, en relativamente poco tiempo, conocimientos de arquitecturas de redes y familiarizarnos con técnicas de generación de patrones, entrenamiento y explotación de resultados. Entre las lecciones aprendidas: el elevado número de pruebas que este tipo de redes necesitan para ajustar metaparámetros asociados a la propia red y al proceso de entrenamiento, y la importancia de interpretar adecuadamente los resultados estadísticos de las iteraciones de aprendizaje para poder mejorarlos.

#### **4. DETECCIÓN DE CAMBIOS EN IMÁGENES ORTORECTIFICADAS**

El problema de detección automatizada de cambios en imágenes no es nuevo y existen numerosas aproximaciones basadas en técnicas de visión por computador [3]. Una de las principales dificultades a la que tiene que enfrentarse este tipo de soluciones reside en la variabilidad natural existente entre imágenes de una misma zona captadas en fechas diferentes [4]. Factores como la estación del año en que han sido tomadas las imágenes, la hora de la misma, que condiciona el ángulo solar y por tanto la iluminación y las sombras, los cambios en la vegetación y los cultivos, elementos móviles como los vehículos o los efectos producidos por las mareas y el oleaje, provocan, en unos casos, modificaciones en la representación de elementos que no han sufrido alteración alguna y, en otros, cambios apreciables entre las imágenes pero que deben ser excluidos por responder a casuísticas que no revisten interés. Generalmente el impacto de estos inconvenientes se suele tratar de aminorar con ajustes radiométricos y cromáticos previos pero aún así los resultados, fuera de entornos muy controlados, nunca han sido suficientemente satisfactorios o, al menos, comparables con los de un operador.

El enfoque con la Inteligencia Artificial y el Deep Learning es totalmente diferente y, de hecho, no precisa ningún tipo de ajuste previo en las imágenes utilizadas. Frente a los algoritmos de visión por computador que trabajan, desde un punto de vista simplista, con valores de píxeles, las redes aportan la capacidad de aprender e interiorizar un determinado comportamiento, descrito en términos de patrones de entrada, y generalizar su aplicación en escenarios distintos al de aprendizaje.

Con respecto al proyecto anterior, la detección de cambios en imágenes presenta una complejidad muy superior. En primer lugar, las imágenes que recibirá como entrada la red y que formarán parte de los patrones de entrada, necesitan abarcar un ámbito territorial mayor ya que es necesaria una información de contexto suficiente para determinar la presencia o ausencia de cambios. Además hay que considerar que en estas imágenes el color (canales RGB) si es relevante y, por lo tanto, también contribuirá a incrementar el espacio que ocupan las imágenes. La complejidad no sólo va a estar influenciada por el requisito de gestionar mayores volúmenes de información sino, y principalmente, porque es necesario diseñar una arquitectura de red que permita comparar dos imágenes y tal arquitectura no se corresponde con las tradicionalmente empleadas en los problemas de clasificación o localización más comunes [1][2].

La ejecución de este segundo proyecto se puede dividir en cuatro fases principales: la preparación de patrones de entrenamiento, el diseño de la arquitectura de red y el proceso de entrenamiento, la evaluación de resultados y la puesta en funcionamiento de la red en un entorno de trabajo real. Las tres primeras fases conforman el ciclo que determina el comportamiento que exhibe la red.

#### **PREPARACIÓN DE PATRONES DE ENTRENAMIENTO**

La generación y preparación de patrones de entrenamiento es una de las fases más importantes en el proceso de aprendizaje supervisado de una red neuronal. Estos patrones son el vehículo por el que

una red tiene acceso a la información y forma en la que debe proceder en el contexto de un problema concreto. En último término, los patrones de entrenamiento junto con la arquitectura de la red serán quienes, tras un proceso de aprendizaje, determinarán el comportamiento futuro que exhibirá la red neuronal.

El conjunto de patrones de entrenamiento debe representar lo más exhaustivamente posible la totalidad de la casuística de un problema concreto. En la práctica esto obliga a trabajar con un número de patrones muy elevado, lo cual es una constante en todos los problemas de Deep Learning. Estos patrones, por lo tanto, deben ser variados y representativos a fin de evitar sesgos en el conjunto, sesgos que podrían influir negativamente en el comportamiento aprendido por la red.

Ante la necesidad de disponer de un gran número de patrones de entrada se acometió una primera actuación consistente en desarrollar una herramienta que asistiera a un operador en su elaboración y ahorrara tiempo frente a la alternativa de abordar este proceso de manera enteramente manual. Esta herramienta permite examinar, para una misma ubicación, dos ortofotos de fechas diferentes y numerosas capas con información de apoyo. En el caso de Canarias, se recurrió a la base de datos vinculada al control de cambios en el territorio mediante tecnología LIDAR como principal fuente de información para la confección del conjunto inicial de patrones de entrenamiento.

También se desarrolló un módulo específico para incrementar artificialmente (*data augmentation*) el número de patrones generado con la aplicación descrita. Este módulo emplea técnicas de procesamiento de imágenes para crear variantes de una misma imagen y así poder incrementar de una forma rápida y efectiva el número de patrones del conjunto de entrenamiento. Cuanto mayor sea este conjunto, previsiblemente, mejor será la capacidad de generalización de la red entrenada y menor será la probabilidad de problemas relacionados con el sobreajuste (*overfitting*) de la red. El sobreajuste es un efecto que provoca que la red funcione muy bien con los patrones utilizados en la fase de entrenamiento pero carezca de capacidad de generalización y, por lo tanto, no funcione bien con entradas que no hayan formado parte del entrenamiento.



Figura 3: Ejemplos de patrones de entrenamiento (cambios a la izquierda, no cambio a la derecha).

En la figura 3 se puede observar que los patrones de entrenamiento constan, por un lado, de una pareja de imágenes (fecha anterior y fecha posterior) y, por otro, de la clasificación (cambios a la izquierda y ausencia de cambios a la derecha) asociada a dicha pareja de imágenes. Tan importante es transmitir a la red neuronal el conocimiento de lo que constituye un cambio como el conocimiento de lo que no lo es. En los patrones de la derecha se observa como imágenes significativamente diferentes por los efectos, según los casos, de la vegetación, los cultivos y las sombras carecen del tipo de cambios buscado. Por lo tanto, se puede concluir que una correcta clasificación en las categorías de cambio o ausencia de cambio, implica no sólo apreciar diferencias entre imágenes sino comprender el tipo de cambio que representan esas diferencias. Es, precisamente, en este tipo de razonamientos donde las técnicas y algoritmos de Inteligencia Artificial han demostrado ser muy superiores a otras alternativas.

Actualmente el conjunto de patrones de entrenamiento, considerando los creados artificialmente, supera la cifra de 110.000. Estos patrones están formados por una pareja de imágenes y un valor categorizado en tres clases (ausencia de cambio, cambio en construcción o cambio en vial).

#### DISEÑO DE LA ARQUITECTURA DE RED Y ENTRENAMIENTO

Esta fase llevó aparejada la evaluación de numerosas arquitecturas de red hasta dar con la más adecuada para resolver el problema planteado inicialmente. Se realizaron pruebas con multitud de variaciones en profundidad, ancho, filtros, bloques y etapa de clasificación final. La configuración actual (versión 25) se muestra esquemáticamente en la siguiente figura.

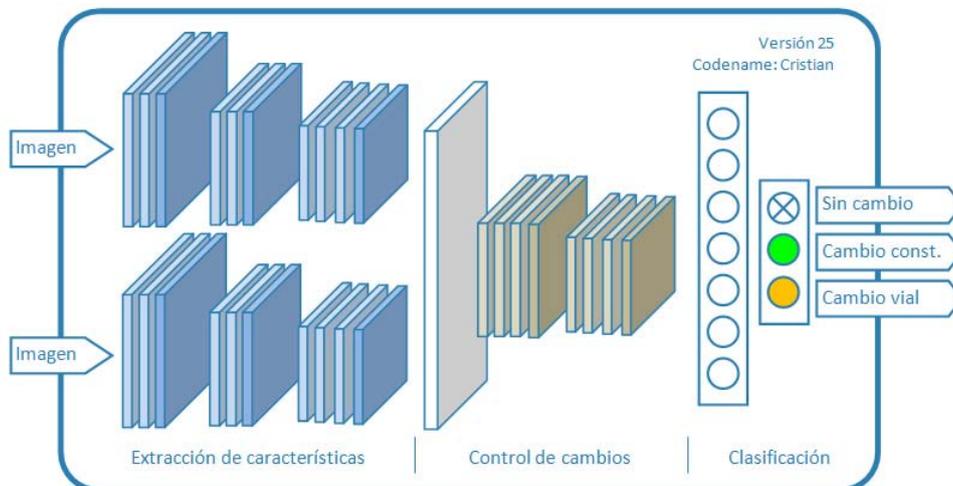


Figura 4: Arquitectura de la red de control de cambios.

La red recibe como entrada dos imágenes cuadradas de 50 metros de lado cada una. Las imágenes atraviesan una serie de capas agrupadas en bloques de *convoluciones* y *simplificaciones* que permiten una extracción de características de las imágenes manteniendo la relación espacial de los elementos. Estas características son analizadas por una segunda parte de la red que realiza la comparativa y detección de cambios. La parte final de la red, integrada por capas de neuronas totalmente conectadas, se encarga de la clasificación final y la generación de resultados: ausencia de cambio, cambio en construcción o cambio en vial. La red permite, además de la clasificación de los cambios, su localización en el territorio de manera que sus resultados puedan ser georreferenciados.

La arquitectura actual está compuesta por 22 capas de neuronas y un total de algo más de 36

millones de parámetros, o pesos, a ajustar. Este ajuste lo realiza un algoritmo de retropropagación (*backprogragation*), perteneciente a la familia de métodos de gradiente descendiente, que utiliza los patrones de entrada de forma iterativa hasta que logra una configuración de los parámetros de la red capaz de reproducir el comportamiento que se infiere de los patrones de entrada utilizados.

La duración del proceso de entrenamiento de la red actual utilizando el conjunto de patrones de entrada completo es algo inferior a las 24 horas, en una máquina dedicada y equipada con hardware específico.

## EVALUACIÓN DE RESULTADOS

Esta fase está estrechamente ligada a la anterior y basada en un conjunto de patrones de evaluación. Estos patrones son desconocidos para la red, no forman parte del conjunto de entrenamiento, y son representativos de los casos reales con los que tendrá que trabajar la red. El objetivo del conjunto de evaluación es poder evaluar el nivel de generalización alcanzado por la red tras el proceso de entrenamiento.

La evaluación de resultados se lleva a cabo durante la fase de entrenamiento. De hecho, cada cierto número de iteraciones se realiza una evaluación de este tipo. Cuando se dispone de una configuración de la red que se considera válida, ésta se utiliza sobre una determina extensión del territorio y sus resultados son revisados por un operador a efectos de poder valorar su funcionamiento.

El objetivo de esta fase, en combinación con las dos anteriores, es conseguir una configuración de la de la red que la dote de un nivel de generalización adecuado para poder trabajar sobre la totalidad del territorio. Para alcanzar este objetivo es necesario trabajar conjuntamente en la generación de patrones de entrada y el diseño de la arquitectura de la red, teniendo como herramienta de contraste la evaluación estadística de resultados.

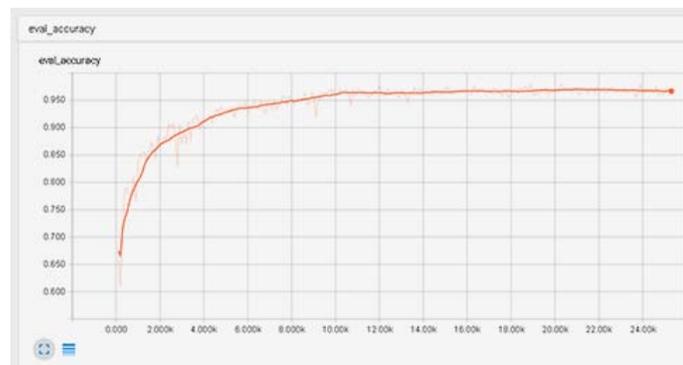


Figura 5: Monitorización de precisión durante la fase de entrenamiento.

## PUESTA EN FUNCIONAMIENTO DE LA RED EN UN ENTORNO DE TRABAJO

El resultado del ciclo descrito por las tres fases anteriores es la configuración de una arquitectura de red especializada en el control de cambios. Esta configuración, como tal, no es directamente utilizable si no forma parte de un sistema que la integre y sea el encargado de suministrarle entradas y gestionar sus salidas. A tal efecto, se desarrolló una aplicación que utiliza como entrada la url de dos servicios estándares WMS [5]. Cada uno de los servicios suministra una imagen de una fecha diferente de manera que para una ubicación concreta del territorio se dispone de una imagen anterior y otra posterior.

La integración de servicios WMS, además de simplificar el acceso a imágenes georreferenciadas, ha dotado de versatilidad a la aplicación ya que le permite ser utilizada en otros ámbitos territoriales y

con imágenes actuales o históricas. Las pruebas realizadas con información de otras Comunidades Autónomas han sido satisfactorias y han puesto de manifiesto la capacidad de generalización y extrapolación de resultados de la red.

Conceptualmente el esquema de la aplicación desarrollada es el siguiente:

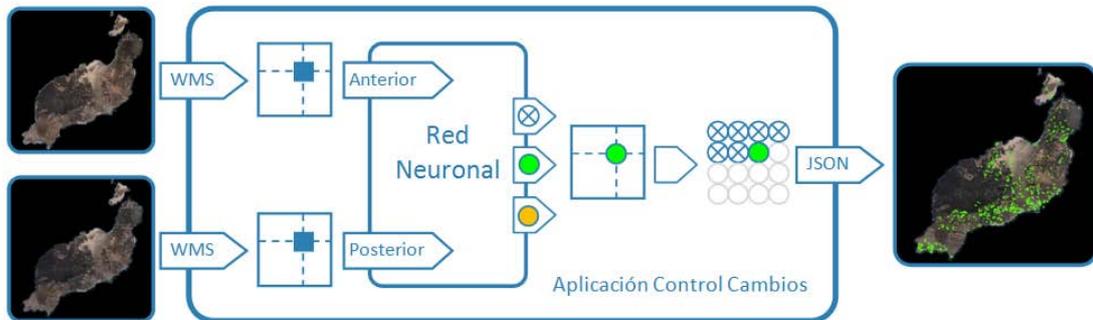


Figura 6: Puesta en producción del sistema de detección de cambios basado en servicios WMS.

La aplicación recibe como entrada la url de los dos servicios WMS (imágenes anterior y posterior) y la delimitación geográfica de la zona en la que se quiere realizar el control de cambios. Esta zona se recorre sistemáticamente realizando llamadas a los servicios interoperables con unos desplazamientos predeterminados en ambos ejes. En cada ubicación del recorrido de la zona se obtienen dos imágenes que son suministradas a la red neuronal y a partir de estas imágenes la red realiza el proceso de *inferencia* utilizando la información suministrada y determina si existe un cambio de construcción o vial. En caso afirmativo se procede a la localización del cambio y su incorporación a un fichero georreferenciado de salida en formato GeoJSON.



Figura 7: Ejemplos de cambios encontrados por el sistema.

A título informativo, el procesamiento de una isla como Lanzarote, con una extensión aproximada de 850 km<sup>2</sup>, es de 42 horas en una máquina dedicada.

## 5. RESULTADOS

Los resultados obtenidos por la red, a través de la aplicación desarrollada, fueron valorados muy positivamente e impulsaron, en mayo de 2017, su incorporación al contexto de servicios prestados por GRAFCAN a la Administración.

La inclusión del control de cambios basado en técnicas de Deep Learning en el catálogo de servicios de GRAFCAN fue acompañada del establecimiento de un proceso de revisión final por parte de un operador con el objetivo de supervisar los resultados del sistema. Esta revisión permite detectar y descartar falsos positivos y así mejorar la calidad del resultado final. Además es una información que se recopila e incorpora a posteriores procesos de reentrenamiento de la red a fin de mejorar su respuesta en las circunstancias en las que no ha sido la adecuada.

La configuración actual de la red (octubre de 2017) obtiene sobre el conjunto de evaluación, compuesto por 587 patrones, una tasa de acierto del 97,6%. Cuando la red se puso en

funcionamiento en mayo, esta cifra estaba alrededor del 95,7%. Por tanto, es evidente que la experiencia acumulada con su uso ha servido para mejorar su comportamiento y que la red se encuentra aún en un proceso de evolución.

La red ha abordado exitosamente la comparación de las ortofotos del año 2016 frente a las ortofotos del año 2015 y ya se han iniciado los trabajos para realizar la comparativa entre las anualidades 2017 y 2016.

## 6. CONCLUSIONES

Desde el año 2012 los avances producidos en el campo de la Inteligencia Artificial han sido muy significativos y cada vez son más los ámbitos cotidianos en los que se incorpora su uso. La gran cantidad de grupos de trabajo y multitud de publicaciones existentes auguran un futuro más que prometedor a esta disciplina de la computación.

En cuanto al control de cambios sobre ortofotos basado en técnicas de Deep Learning, sus resultados han superado las expectativas iniciales y son una base fiable sobre la que articular nuevos procesos o servicios. El proyecto no reemplazará otros procesos de control de cambios que trabajan con mayores niveles de granularidad o fuentes de datos diferentes pero, sin duda, puede ser un excelente complemento. Otra aportación significativa de este proyecto ha sido su contribución a la puesta en valor de un producto como la ortofoto. Las ortofotos existen en la mayoría de las Infraestructuras de Datos Espaciales y son de uso muy recurrente. Sin embargo, la extracción de conocimiento automático a partir de las mismas siempre había sido una labor compleja y los resultados obtenidos hasta la fecha bastante discretos.

Los proyectos descritos en este artículo han puesto de manifiesto que el mundo de la información geográfica se puede beneficiar de los avances producidos por la investigación en el ámbito de la Inteligencia Artificial y que la combinación de ésta con la información espacial es un binomio de enorme potencial que, a buen seguro, generará importantes innovaciones durante los próximos años. Quizás en forma de Infraestructuras de Conocimiento Espacial [6] en las que además de información y datos se comparta de forma colectiva los análisis y conclusiones que expertos de diferentes materias pueden extraer.

Existen numerosas áreas de la producción, gestión y análisis de información geográfica que pueden verse mejoradas o potenciadas con el uso de técnicas de Inteligencia Artificial. Por tal motivo, son varias las líneas de trabajo que ya hemos iniciado con el objetivo de explorar estas nuevas posibilidades.

## AUTORES

Jose Julio RODRIGO BELLO, [jrodrigo@grafcan.com](mailto:jrodrigo@grafcan.com), GRAFCAN, Departamento de Ingeniería  
Juan Jorge ROSALES LEÓN, [jrosales@grafcan.com](mailto:jrosales@grafcan.com), GRAFCAN, Director Técnico

## REFERENCIAS

- [1] A Krizhevsky, I Sutskever, GE Hinton: Imagenet classification with deep convolutional neural networks. <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>
- [2] Karen Simonyan, Andrew Zisserman: Very Deep Convolutional Networks for Large-Scale Image Recognition. <https://arxiv.org/pdf/1409.1556.pdf>

- [3] Richard J. Radke, Srinivas Andra, Omar Al-Kofahi, and Badrinath Roysam.: Image Change Detection Algorithms: A Systematic Survey. <https://www.ecse.rpi.edu/~rjradke/papers/radketip04.pdf>
- [4] G Ambrosio, J González, V Arévalo: Corrección radiométrica y geométrica de imágenes para la detección de cambios en una serie temporal. <http://mapir.isa.uma.es/varevalo/drafts/ambrosio2002crg.pdf>
- [5] IDECanarias. <http://www.idecanarias.es>
- [6] Matt Duckham, Dr Lesley Arnold, Kylie Armstrong, Dr David McMeekin and Darren Mottolini: Spatial Knowledge Infrastructure White Paper. <http://www.crcsi.com.au/spatial-knowledge-infrastructure-white-paper?stage=Stage>
- [7] Tensorflow, <https://www.tensorflow.org>.