



Potencial de la inteligencia artificial para avanzar en el estudio de la desertificación

Emilio Guirado^{1,*} , Jaime Martínez-Valderrama¹

(1) Instituto Multidisciplinar para el Estudio del Medio 'Ramón Margalef', Universidad de Alicante, Alicante, España.

* Autor de correspondencia: Emilio Guirado [emilio.guirado@ua.es]

> Recibido el 19 de mayo de 2021 - Aceptado el 16 de noviembre de 2021

Como citar: Guirado, E., Martínez-Valderrama, J. 2021. Potencial de la inteligencia artificial para avanzar en el estudio de la desertificación. *Ecosistemas* 30(3): 2250. <https://doi.org/10.7818/ECOS.2250>

Potencial de la inteligencia artificial para avanzar en el estudio de la desertificación

Resumen: La desertificación es un problema global que afecta a más de 1500 millones de personas que viven en los lugares más pobres y vulnerables del planeta. En los últimos años numerosos estudios han contribuido a aportar información para evaluar el problema. Algunos de ellos se basan en analizar variables biofísicas y socio-económicas mediante técnicas de inteligencia artificial. Por ejemplo, se han usado para completar datos de anomalías en la estimación de almacenamiento de agua, la identificación precisa de cobertura del suelo, estimación de la radiación solar diaria a nivel global y mejora en predicciones climáticas, entre otras. Si bien su uso todavía no está muy extendido, el futuro en los estudios sobre desertificación parece prometedor. En este trabajo revisamos el potencial de las técnicas de inteligencia artificial (aprendizaje automático y aprendizaje profundo) en el estudio de la desertificación y su reciente crecimiento en los últimos años. Durante el periodo 2015-2020 el número de publicaciones que implementan el aprendizaje profundo se incrementó un 63%, mientras que para el aprendizaje automático su crecimiento fue más modesto, del 3%. En particular, cuando buscamos estudios relacionados con la desertificación, las cifras de crecimiento son más llamativas: un incremento medio del 103% en estudios con aprendizaje profundo, y del 43% en aprendizaje automático. Sin embargo, se requieren más estudios y esfuerzos que agrupen todas las disciplinas implicadas en el estudio de la desertificación para obtener una visión global y transversal de este fenómeno y así diseñar acciones efectivas para mitigar sus efectos adversos o anticiparse a ellos.

Palabras clave: aprendizaje automático; aprendizaje profundo; degradación; redes neuronales; sobreexplotación

Potential of artificial intelligence to advance the study of desertification

Abstract: Desertification is a global problem affecting 1.5 billion people living in the poorest and most vulnerable parts of the world. In recent years, several studies have contributed to provide information to assess the problem. Some of them are based on analysing biophysical and socio-economic variables using artificial intelligence techniques. For example, artificial intelligence have been used to complete anomaly data for water storage estimation, accurate identification of land cover, estimation of global daily solar radiation and improved climate predictions, and others. Although their use is not yet widespread, the future in desertification studies looks promising. In this paper we review the potential of artificial intelligence techniques (machine learning and deep learning) in the study of desertification and its recent growth in recent years. During the period 2015-2020 the number of publications implementing deep learning increased by 63%, while for machine learning its growth was more modest at 3%. In particular, when we look for studies related to desertification, the growth figures are more striking: an average increase of 103% in studies with deep learning, and 43% in machine learning. However, more studies and efforts are needed to bring together all the disciplines involved in the study of desertification in order to obtain a global and transversal vision of this phenomenon and thus design effective actions to mitigate or anticipate its adverse effects.

Keywords: machine learning; deep learning; degradation; neural networks; overexploitation

Introducción

Según la Convención de las Naciones Unidas para Lucha contra la Desertificación (UNCCD 1994), la desertificación es “la degradación de la tierra en zonas áridas, semiáridas y seco-subhúmedas resultante de varios factores, incluyendo las variaciones climáticas y las actividades humanas”. En muchos casos, esta degradación es irreversible, al menos a escala humana, como ocurre por ejemplo con la lenta recuperación del suelo tras sufrir episodios severos de erosión (Fernández et al. 2021). Se trata de un problema global, en el que más de 1500 millones de personas se ven afectadas directamente por la pérdida de productividad del

territorio, incluyendo los lugares más pobres y vulnerables del planeta (Barbier y Hochard 2018). Como sostiene la definición, la causa es doble. Por un lado, las variaciones climáticas, en forma de sequías o lluvias torrenciales (cuestión acentuada por el cambio climático), y por otro la intervención humana como la deforestación, la sobreexplotación de recursos o el sobrepastoreo (Reynolds et al. 2007; Dudley y Alexander 2017; Yu et al. 2018).

En todo el mundo, alrededor de 3600 Mha están en riesgo de desertificación (Millennium Ecosystem Assessment 2005). Los lugares con riesgo muy elevado de sufrir desertificación incluyen algunas zonas del continente africano (Tolba 1986), el 30% de las tierras de Estados Unidos (Fredrickson et al. 1998), una cuarta parte

de América del sur, por ejemplo, el Chaco árido (Verón et al. 2018), Australia (Ludwig y Tongway 1995), Oriente Medio, Asia Central (Feng et al. 2015) o una quinta parte de España (Huang et al. 2020). El deterioro de recursos como el agua es un claro ejemplo de desertificación (Nick et al. 2011) y puede provocar el desplazamiento de millones de personas. Debido a las sequías y a la intensificación de la agricultura, el deterioro de las aguas subterráneas, fuente principal en las tierras secas (Bradford et al. 2020; Williams et al. 2020), es una cuestión global (Famiglietti 2014). En este contexto, y con la mejora y abaratamiento de la tecnología para la extracción de agua subterránea, observamos una proliferación de agricultura de regadío insostenible o ambiciosos programas de restauración forestal en algunas de las zonas más secas del planeta para intentar frenar la desertificación, por ejemplo, en los desiertos del Sahara (Gadzama 2017) y Gobi (Jiang 2016) o la península Arábiga (Independent UK 2021). Por ello, se debe considerar con especial atención este tipo de actuaciones, ya que pueden causar efectos opuestos a los que persiguen.

Debido a la complejidad del fenómeno, donde se intercalan variables biofísicas y socioeconómicas, el estudio coordinado de toda la información disponible es clave para que los actores políticos, socioeconómicos, científicos y la sociedad puedan diseñar medidas adecuadas de gestión y conservación de los recursos naturales para evitar o disminuir los impactos de la desertificación en los sistemas socio-ecológicos. Vivimos en la era de la información (Lazer et al. 2009; Bao y Zhang 2017), y recibimos un flujo continuo de datos e imágenes (Savtchenko et al. 2004; Drusch et al. 2012; Roy et al. 2014) que, debidamente procesados y combinados, aportarían respuestas a preguntas complejas como es la cartografía de la desertificación (Prince 2016).

Para dar sentido a este enorme caudal de datos, existen técnicas basadas en inteligencia artificial (O'Leary 2013; Duan et al. 2019), como el aprendizaje automático (*machine learning*), que permite a una máquina aprender sin necesidad de estar programada para que lo haga, o el aprendizaje profundo (*deep learning*) incluido en el conjunto de aprendizaje automático y que consiste en modelos que aprenden a partir de transformaciones iterativas de datos matriciales o en forma de tensor (Bengio et al. 2013). Con ambos se aprovecha la creciente potencia de procesamiento de las computadoras para realizar operaciones que imitan la inteligencia humana (LeCun et al. 2015). Todo comienza en la década de los 50, con el "*imitation game*" o también llamado "*Test de Turing*", que nos indica si una máquina es inteligente (Turing 1950). El test se basa en darnos cuenta si quien responde a nuestra maniobra es una máquina o una persona. Después, en los años 90, se resolvieron problemas complejos con el aprendizaje automático mediante técnicas como el *K-Nearest Neighbors* (K-NN), *Support Vector Machine* (SVM), o *Random Forest* (RF), entre otras. El aprendizaje profundo, aunque obtuvo grandes logros a partir del año 2000 (Hinton y Salakhutdinov 2006), no se popularizó hasta 2015 con el auge de la tecnología basada en unidades de procesamiento gráfico (GPUs) y publicaciones como "*Deep learning*" de Yann LeCun, donde se detalla el funcionamiento y el potencial de esta tecnología aplicada a múltiples campos de estudio (LeCun et al. 2015).

Las primeras disciplinas en adoptar estas técnicas fueron la rama informática, mediante la optimización de la tecnología (e.g. Young et al. 2015), y la biomédica, para la detección de enfermedades mediante visión por computación (e.g. la detección de tumores malignos en dermatología; Esteva et al. 2017). Más tarde, el "*Deep learning*" estaría presente en multitud de campos y se convertiría en algo cotidiano a través de los teléfonos móviles. En 2017 el uso del aprendizaje profundo en ecología y otras disciplinas relacionadas con estudios de desertificación con datos obtenidos mediante sensores remotos, publicados mayormente en "*preprints*", aumentaron considerablemente. Sin embargo, los métodos para identificar y hacer seguimiento de la desertificación, como la idoneidad en el tipo de vegetación en restauraciones (Li et al. 2020), mapas de cobertura del suelo (Ling y Foody 2019), o

detección del riesgo de degradación de la tierra (Chen et al. 2021) son aún insuficientes para cartografiar el riesgo de desertificación debido a su complejidad multidisciplinar y particularidades locales (Cherlet et al. 2015).

En este trabajo se lleva a cabo una revisión bibliográfica de los estudios relacionados con la inteligencia artificial y la desertificación. Además, se presenta una propuesta de identificación de zonas proclives a la degradación a partir del nuevo paradigma de la 'Convergencia de la Evidencia' propuesto por el Atlas Mundial de la Desertificación (Cherlet et al. 2015) utilizando técnicas de inteligencia artificial.

Métodos más usados basados en inteligencia artificial

Existen multitud de métodos basados en inteligencia artificial, en este trabajo nos centramos en los más usados para el estudio de disciplinas relacionadas con la desertificación. Los métodos basados en inteligencia artificial se subdividen en supervisados y no supervisados. Los más extendidos son los primeros, donde el usuario proporciona una base de datos etiquetada para entrenar un modelo. En particular, exploramos los métodos supervisados en el aprendizaje automático, subdividido, a su vez, en el K- vecino más cercano, random forest, support vector machine, y en el aprendizaje profundo, con el perceptrón multicapa y las redes neuronales (e.g. Redes Neuronales Convolucionales y Redes Neuronales Recurrentes) (Fig. 1).

Aprendizaje automático

Vecino más cercano (K-NN)

Un método no paramétrico, de los más simples en el grupo del aprendizaje automático (Sahan et al. 2007), pero con muy buenos resultados (e.g. Ali et al. 2020). El método determina la probabilidad de que un elemento pertenezca a una clase a partir de la distancia de cada elemento a los demás obteniendo *k* vecinos cercanos a una clase u otra de la información proporcionada por los datos de entrenamiento. Si un elemento obtiene distancias menores con una alta frecuencia a elementos de una clase determinada, se le asignará esa clase (Dudani 1976).

Random forest (RF)

Funciona construyendo una multitud de árboles de decisión en el entrenamiento para clasificar o hacer predicciones a partir de los resultados de los árboles individuales de una muestra aleatoria para minimizar el error y aumentar la generalización (Breiman 2001).

Support vector machine (SVM)

Es un método usado en clasificación y regresión. Representa espacialmente las muestras utilizando un hiperplano separando las clases mediante un vector soporte con la máxima distancia de las muestras a este (Cortes y Vapnik 1995).

Aprendizaje profundo

Perceptrón multicapa (MLP)

Se compone de múltiples capas con activación no lineal que lo distinguen del perceptrón lineal (Gardner y Dorling 1998). Es una red neuronal artificial con una estructura de capas conectadas (e.g. entrada, oculta, salida) entre sí con un rendimiento bueno en la resolución de problemas simples. Sin embargo, para la resolución de problemas de visión por computación más complejos se usan otras redes neuronales más modernas (e.g. CNN, RNN).

Redes Neuronales Convolucionales (CNN)

Son redes neuronales capaces de extraer patrones espaciales en imágenes con una arquitectura basada en capas con tres tipos




Figura 1. Subconjuntos de la disciplina inteligencia artificial. K-Nearest Neighbor (KNN), Random Forest (RF), Support Vector Machine (SVM), Multilayer Perceptron (MPL), Recurrent Neural Network (RNN), Convolutional Neural Network (CNN).

Figure 1. Subsets of the artificial intelligence discipline. K-Nearest Neighbor (KNN), Random Forest (RF), Support Vector Machine (SVM), Multilayer Perceptron (MPL), Recurrent Neural Network (RNN), Convolutional Neural Network (CNN).

principales. Se componen de capas convolucionales, que extraen características a diferentes niveles, capas de agrupación, que reducen las características extraídas para aumentar su nivel de abstracción y la capa completamente conectada, que se utiliza como clasificador final. Las CNN necesitan una gran cantidad de datos de ejemplo para obtener un buen aprendizaje. Sin embargo, crear un gran conjunto de datos es costoso. Para superar estas limitaciones se utilizan dos técnicas que detallamos en la siguiente sección: aumentación de datos y aprendizaje de transferencia.

Redes Neuronales Recurrentes (RNN)

Es un modelo de red neuronal propuesto en los años 80 (Rumelhart et al. 1986) para modelar series temporales. Tiene una estructura multicapa similar al perceptrón multicapa (MLP) con conexiones entre datos temporales, lo que permite correlaciones entre eventos históricos.

Gestión de datos para entrenar los modelos basados en aprendizaje profundo

Hay infinidad de bases de datos accesibles a distintos niveles, desde locales a globales en diferentes disciplinas. Sin embargo, en muchos casos, los datos etiquetados para estudios específicos son limitados y debemos usar técnicas de optimización y generación de nuevos datos a partir de una muestra limitada. Aquí exponemos las dos técnicas más usadas en modelos basados en aprendizaje profundo:

Aumentación de datos (data-augmentation)

Consiste en aumentar artificialmente el número de muestras independientes en el conjunto de datos de entrenamiento aplicando transformaciones específicas a las imágenes. Algunos ejemplos de ellos son rotar la imagen 180°, recortar el margen en un 10%, aumentar el tamaño de las imágenes en un 10%, aclarar el nivel de píxeles hasta un 50% u oscurecer el nivel de píxeles hasta un 50% (Tabik et al. 2017).

Aprendizaje de transferencia (transfer-learning)

Consiste en utilizar los conocimientos adquiridos en un problema anterior para resolver uno nuevo (Marmanis et al. 2016). Para ello se utiliza el re-entrenamiento de modelos previamente entrenados con otras fuentes de información y que podrían ayudar a resolver el problema nuevo.

Extracción y organización de los estudios basados en inteligencia artificial

Para conocer el número de publicaciones relacionadas con las metodologías propuestas en esta revisión de carácter narrativo, se utilizó el motor de búsqueda Google Scholar (Vine 2006), que indexa: Web of Science, Science Direct, conferencias y páginas de publicación de "preprints" como bioRxiv y Arxiv. Se emplearon las siguientes palabras clave: a) "Artificial intelligence", b) "Machine learning"; c) "Deep learning". Además, se hizo una búsqueda adicional de categorías relevantes para la desertificación, para lo que se añadió: d) "desertification"; e) "land degradation" a las consultas generales de búsqueda.

El análisis se realizó para el periodo 2000-2020. Se obtuvo un total de 14 560 resultados, con la siguiente distribución: 6180 para "artificial intelligence" + "desertification" AND "artificial intelligence" + "land degradation"; 7180 para "Machine learning" + "desertification" AND "Machine learning" + "land degradation"; y 1200 para "Deep learning" + "desertification" AND "Deep learning" + "land degradation" (Fig. 2). En particular, se ha registrado un incremento medio, en los últimos 5 años, del 103% en estudios con aprendizaje profundo, y del 43% en aprendizaje automático en los estudios de desertificación y degradación de la tierra. Estas cifras demuestran el creciente interés en la comprensión de procesos del sistema terrestre mediante técnicas de inteligencia artificial (Reichstein et al. 2019). A continuación se discuten distintos casos de estudio siguiendo la dicotomía causal que presenta la Convergencia de la evidencia propuesto por el Atlas Mundial de la Desertificación (Cherlet et al. 2015): variables biofísicas (aridez, el estrés hídrico, descenso de la productividad, los incendios forestales o la pérdida de arbolado) y variables socioeconómicas (densidad de población, los cambios demográficos, la renta media, el incremento de áreas urbanas, el balance de nitrógeno, la superficie de regadío o densidad ganadera). En los casos de estudio relacionados con variables biofísicas y socio-económicas en el estudio de la desertificación, se seleccionaron 83 artículos obtenidos por orden de relevancia en la base de datos Google Scholar (una métrica de peso son las citas), donde se observan métodos usados como el aprendizaje automático (ML) $n = 18$, las redes neuronales convolucionales (CNN) $n = 58$ y las recurrent neural network (RNN) $n = 7$. Además, la mayoría de los artículos revisados hacen referencia a "deep learning" $n = 65$ y se publicaron en el año 2020 o posterior $n = 56$. También, se proporciona un análisis de conexiones entre




Figura 2. (a) Cronología de barras ilustrando el número de trabajos basados en inteligencia artificial (AI), aprendizaje automático (ML) y aprendizaje profundo (DL) en los últimos 20 años indexados por Google scholar (Vine 2006). (b) Porcentaje de trabajos para desertificación. ML 49%, AI 43%, DL 8%.

Figure 2. (a) Chronology bar chart illustrating the number of papers based on artificial intelligence (AI), machine learning (ML) and deep learning (DL) in the last 20 years indexed by Google scholar. (Vine 2006). (b) Percentage of desertification work. ML 49%, AI 43%, DL 8%.

estos términos de 1000 publicaciones proporcionadas por el software "Publish or Perish" de Harzing (2007) (<https://harzing.com/resources/publish-or-perish>) y visualizadas con el software Vosviewer (Van Eck y Waltman 2013).

Variables biofísicas en el estudio de la desertificación

Las tierras potencialmente desertificables son, según la citada definición de las Naciones Unidas para Lucha contra la Desertificación, aquellas en las que el índice de aridez (IA; ratio de la precipitación anual y la evapotranspiración potencial anual) está comprendido entre 0.05 y 0.65. En nuestra opinión, deberían incluir las zonas híper-áridas, aquellas en que $AI < 0.05$ (Martínez-Valderrama et al. 2020) y por ello incluimos esos territorios en este estudio. El aprendizaje automático y profundo han mejorado los modelos que predicen la evapotranspiración y la precipitación. Un ejemplo de ello son la predicción de precipitación de forma precisa (Ha et al. 2016; Shi et al. 2017), o el cálculo de la ET diaria a partir de la temperatura y la humedad relativa a nivel horario utilizando técnicas de machine learning -como *Random Forest*, *XGBoost*-, y *deep learning* -como redes neuronales artificiales y una red neural convolucional de 1 dimensión- (Ferreira et al. 2020a; 2020b). También, encontramos aproximaciones basadas en aprendizaje automático para la mejora de la estimación de la ET con datos intradía (Bellido-Jiménez et al. 2021), predicciones fiables en un marco de aprendizaje automático probabilístico (Başagaoglu et al. 2021) o enfoques de modelos predictivos híbridos para estimar la respiración de los ecosistemas con resultados prometedores (Chen et al. 2020).

El estrés hídrico de la vegetación y la identificación del estado de las reservas de agua subterránea son clave para observar indicadores tempranos de riesgo de desertificación. Especialmente relevante es en este campo la misión espacial GRACE (Experimento de Clima y Recuperación Gravitatoria; Tapley y Reigber 2001), que mide, entre otras, la tendencia en nivel piezométrico de las reservas de agua subterránea globales. Las redes neuronales convolucionales se han usado para completar datos de anomalías en la estimación de almacenamiento de agua terrestre derivadas del Experimento de Clima y Recuperación Gravitatoria (Mo et al. 2021), obteniendo una caracterización más completa de las masas de agua subterránea. Además, para la gestión de masas de agua subterránea es clave conocer el comportamiento hidrológico a nivel regional y local, cuestión que es posible abordar utilizando un gran volumen de datos de la zona (Kratzert et al. 2019). Por ejemplo, existen estudios basados en aprendizaje profundo que utilizan modelos de 22 capas, cuantificando el estrés hídrico con una precisión de hasta el 98% (Chandel et al. 2020). Por otra parte, el uso del aprendizaje profundo con imágenes térmicas infrarrojas se ha identificado como una

técnica prometedora para la evaluación del estrés hídrico de los cultivos y de la vegetación natural (Singh et al. 2018; Gao et al. 2020; Azimi et al. 2021; Zhou et al. 2021).

Hay una gran cantidad de estudios que hacen referencia al descenso de la productividad de la tierra (Ichii et al. 2002; Pouliot et al. 2009; De Jong et al. 2011; Wang et al. 2020a) mediante análisis de tendencias de NDVI (Índice de vegetación de diferencia normalizada). El aprendizaje automático y el aprendizaje profundo facilitan la detección de vegetación y suelo, haciendo que sean más precisos los resultados de los algoritmos que identifican esas tendencias. Así, la combinación de ambas técnicas reduce el ruido vegetación-suelo desnudo en el análisis de tendencias (Guirado et al. 2017, 2020, 2021; Ayhan et al. 2020). Además, estos métodos ayudan a la identificación precisa de pastizales (Pi et al. 2020) y del carbono orgánico en suelo (Emadi et al. 2020), datos relevantes para la evaluación del riesgo de desertificación de una zona.

El clima generalmente es modelado con algoritmos informáticos convencionales, usando reglas predefinidas para guiar la salida del sistema. El aprendizaje automático crea sus propias reglas de comportamiento tras analizar grandes cantidades de datos (Jones 2017). Algunos ejemplos de este procedimiento son: (i) Predicción de respuestas de las tierras secas a las perturbaciones humanas y climáticas (Buckland et al. 2019); (ii) Redes neuronales recurrentes (RNN) que integran bucles de realimentación y analiza datos temporales climáticos (Sungmin et al. 2020), permitiendo que la información se mantenga a lo largo de las épocas o pasos, útiles en los análisis temporales; (iii) Análisis temporal de modelos de redes neuronales profundas para la predicción de condiciones climáticas en situaciones controladas, extensibles a grandes áreas (Jung et al. 2020); (iv) Predicción de tendencias climáticas a partir de series históricas (Ise y Oba 2019); (v) Estimación de la radiación solar diaria a nivel global y mejora en predicciones climáticas (Kaba et al. 2018; Lima et al. 2020); (vi) Cartografía de la susceptibilidad de inundaciones (Bui et al. 2020); o (vii) Detección de partículas en suspensión (Zamani et al. 2019).

La detección de incendios forestales está ampliamente estudiada con aprendizaje profundo (Jiao et al. 2019; Vani 2019; Liu et al. 2020) y aprendizaje automático (Pham et al. 2020; Cruz et al. 2021). Sin embargo, la localización de las zonas más vulnerables debido, por ejemplo, a la acumulación de biomasa, resulta esencial para la prevención y control de los incendios y para ello, pueden utilizarse datos satelitales y métodos basados en inteligencia artificial (Ban et al. 2020; Rahul et al. 2020).

La deforestación es una de las principales causas de erosión y puede ser detectada a partir de imágenes de satélite mediante señales abruptas que refleja cambios en la cubierta vegetal (Finer et al. 2018). Tradicionalmente, para ello se han usado índices

espectrales y series temporales (Eckert et al. 2015; Muñoz-Peña et al. 2016). Los nuevos métodos basados en aprendizaje profundo permiten elaborar mapas cada vez más precisos de zonas deforestadas (Mhatre et al. 2019; Maretto et al. 2020; Ortega et al. 2020; Lee et al. 2020). Además, implementando técnicas de aprendizaje automático se pueden predecir zonas potenciales de deforestación (Mayfield et al. 2020), proporcionando información relevante para la gestión del territorio.

Variables socio-económicas en el estudio de la desertificación

Como anuncia la definición de la desertificación, esta no es posible sin la intervención del ser humano. Conocer con precisión el número de habitantes de una zona y su distribución es un dato esencial para calibrar el impacto de la sociedad en el medio que habita. La estimación de la densidad de población mediante técnicas de aprendizaje profundo (Doupe et al. 2016; Yuan y Tao 2018) es una de las aplicaciones clave de la Inteligencia artificial en el estudio de la desertificación. En India, el segundo país más poblado del mundo con una tendencia demográfica positiva, cartografiar la población rural es esencial para gestionar los recursos (Hu et al. 2019). Sin embargo, hay que considerar que el auge de las megaurbes y del comercio internacional ha desacoplado los centros de producción de los de consumo (Yu et al. 2013). La inteligencia artificial, podría ayudarnos a cuantificar las redes comerciales productor-consumidor a nivel global y así conocer el impacto de la ciudad en el campo. En relación al incremento de áreas urbanas, numerosos estudios combinan datos, que incluyen imágenes a partir de drones, aviones o satélites, con inteligencia artificial para elaborar mapas urbanos precisos, diseñar redes de abastecimiento, predecir la expansión del territorio urbano (Khryashchev et al. 2018; Grekousis 2019; Li et al. 2019; Oh et al. 2020; Phan et al. 2020; Wang et al. 2020b; Ghaffarian y Emtehani 2021) o ayudar en la planificación urbana (Arribas-Bel et al. 2019; He et al. 2020; Xue et al. 2020; Zhao et al. 2020).

La asociación de la renta media y la desertificación se aborda en distintos estudios. Suel y colaboradores (2019) muestran las desigualdades sociales, ambientales y de salud utilizando el aprendizaje profundo e imágenes del entorno urbano que ponen de manifiesto desafíos sociales, económicos, éticos y legales de nuestra era (Helbing 2019). En África, han usado imágenes satelitales y aprendizaje profundo para entender el bienestar económico de la población de distintos países (Yeh et al. 2020).

La agricultura a gran escala (industrial), una práctica extendida en la actualidad, es uno de los mayores responsables de la degradación del suelo. La inteligencia artificial es ampliamente aplicada en estudios relacionados con la agricultura (Kamilaris y Prenafeta-Boldú 2018; Zhang et al. 2020). En particular, prediciendo la cantidad de nutrientes en el suelo (Dong et al. 2018), el rendimiento del cultivo (Nyéki et al. 2019), biovolumen para inferencia de la producción de olivos (Safonova et al. 2021) y los cultivos (Alif et al. 2018; Camardo et al. 2021) y en el análisis de seguimiento de áreas agrícolas (Nguyen et al. 2020).

La agricultura de regadío basada en el uso de aguas subterráneas, se ha extendido en las últimas décadas gracias al desarrollo y accesibilidad a la tecnología de perforación y bombeo y a otros factores como la electrificación rural (Foster et al. 2000). Un buen ejemplo de ello son los regadíos en zonas hiperáridas del desierto del Sahara (e.g. Argelia, Libia) y de la península Arábiga. La consecuencia más inmediata es el deterioro de las masas de agua subterránea. Con el uso de aprendizaje profundo y datos satelitales, es posible la detección automática de zonas de regadío (Colligan et al. 2021), como los cultivos de pivote (Saraiva et al. 2020) y anticiparse así a la degradación irreversible de este recurso estratégico y vital.

El sobrepastoreo es otra de las principales causas de desertificación (Peters et al. 2013). Usando redes neuronales convolucionales, incluidas en el aprendizaje profundo, es posible detectar el ganado pastoreando (Han et al. 2019; Qiao et al. 2020; Zuo et al. 2020; Meena y Agilandeewari 2021), predecir el

rendimiento en granjas de precisión, que integran las tecnologías de la información y la comunicación para la mejora del proceso agrícola (García et al. 2020; Karegowda et al. 2021) o la medición de características morfológicas del ganado (Dohmen et al. 2021) que podría ayudar a la gestión sostenible de los recursos para combatir la desertificación.

Inteligencia artificial y ‘puntos calientes’ de la desertificación

La existencia de una definición oficial de desertificación no se corresponde con la ambigüedad que aún rodea este concepto. Ya en 1987 el número de definiciones superaba la centena (Reynolds 2021) y las discusiones alrededor de este tema son continuas. La confusión se traslada a otros aspectos, como por ejemplo la posibilidad de cartografiar la desertificación (Prince 2016; Martínez-Valderrama et al. 2021), evaluar su intensidad o diseñar soluciones apropiadas. Un punto de inflexión en esta deriva conceptual ha sido la publicación del Atlas Mundial de la Desertificación (Cherlet et al. 2015). En él encontramos mapas globales sobre una amplia colección de variables: desde algunas sobradamente conocidas como la población o la superficie en regadío, hasta otras más específicas como el tamaño medio de las explotaciones ganaderas, e incluso llamativas como la iluminación nocturna. Sin embargo, sorprendentemente, no hay un solo mapa de desertificación. El Atlas renuncia a cartografiarla. El argumento que respalda esta decisión sostiene que es imposible mapear una variable que no se puede medir o, dicho de otra forma, que se puede medir de demasiadas maneras. Teniendo en cuenta los *drivers* y los múltiples factores la degradación de la tierra y la necesidad de respuestas específicas al contexto, el desarrollo de un único indicador o índice que represente o mapee la degradación de la tierra de la tierra representa un gran reto (UNCCD 2017). Prueba de ello es que los mapas realizados hasta la fecha no han funcionado bien. Los expertos ni siquiera se ponen de acuerdo sobre la situación y las tendencias en zonas bien estudiadas como Europa y Norteamérica. Además, las interacciones entre las distintas variables que intervienen en el problema requieren un contexto regional e incluso local para poder interpretar correctamente lo que está ocurriendo.

Alternativamente, el Atlas propone un nuevo paradigma para detectar los ‘puntos calientes de la desertificación’. Para ello sugiere considerar la concurrencia de diversas evidencias (los denomina Global Change Issues; GCI) que indiquen tanto altas tasas de consumo de recursos como bajas tasas de reposición. La denominada “Convergencia de la Evidencia” muestra cómo utilizar datos geoespaciales e información relevante de distinta índole sobre interacciones entre el ser humano y la naturaleza. Los GCI’s incluyen información sobre variables biofísicas relacionadas con la aridez, el estrés hídrico, descenso de la productividad, los incendios forestales o la pérdida de arbolado y variables socioeconómicas como la densidad de población, los cambios demográficos, la renta media, el incremento de áreas urbanas, el balance de nitrógeno, la superficie de regadío o densidad ganadera (Fig. 3).

La importancia de las variables descritas anteriormente, puede ayudar a detectar dónde puede existir degradación de la tierra (Cherlet et al. 2015). Sin embargo, el contexto local/regional e información adicional deben contemplarse para interpretar de forma apropiada estos datos. La convergencia de estas variables (e.g. aridez, sobreexplotación de agua, sobrepastoreo) no significa que se pueda inferir degradación de la tierra y por tanto desertificación, pero sí nos alerta de que es un lugar en el que se están produciendo cambios relevantes que pueden desequilibrar el sistema y, por tanto, desencadenarse diversos procesos de degradación.

Abordamos la relación entre los términos y palabras clave que contienen las publicaciones seleccionadas de la base de datos Google Scholar con ayuda del software “Publish or Perish” (Harzing 2007) en un diagrama de conexiones (Fig. 4). En este diagrama se puede observar la importancia de “land degradation” (Fig. 4B) como cabría esperar, ya que es uno de los principales impulsores de la desertificación. Respecto a los métodos se pueden observar

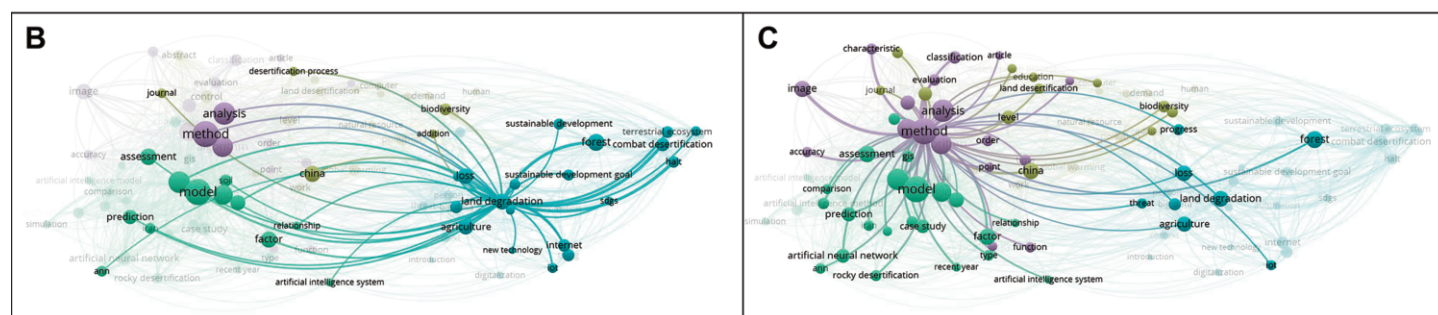
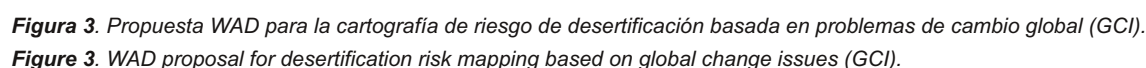


Figura 4. A) Mapa conceptual en relación con “inteligencia artificial” + “desertificación” en el que se pueden ver los vínculos entre los términos que actualmente reciben más atención (hasta 2020) en las publicaciones científicas identificadas. **B)** Conexiones con “land degradation”. **C)** Conexiones con los métodos basados en inteligencia artificial, donde se puede observar “neural networks” como término con gran importancia .

Figure 4. A) Conceptual map in relation to “artificial intelligence” + “desertification” showing the links between the terms currently receiving most attention (until 2020) in the identified scientific publications. **B)** Connections with land degradation. **C)** Connections with methods based on artificial intelligence, where “neural networks” can be seen as a term of high importance.

en la **Figura 4C**, dónde destaca “artificial neural networks” en consonancia con los resultados del aumento del aprendizaje profundo en el estudio de la desertificación en los últimos años. Sin embargo, a pesar de los avances en las distintas técnicas usadas, la desertificación es un problema complejo, que requiere trabajar en distintas escalas espaciales y temporales con la dificultad que esto ocasiona. Además, el seguimiento de las variables biofísicas y socioeconómicas es clave para comprender la magnitud del problema y obtener directrices y criterios para la gestión de recursos en la lucha contra la desertificación. Aunque la inteligencia artificial está presente en diversas iniciativas dedicadas al estudio de variables esenciales para determinar el riesgo de desertificación, queda pendiente el reto de su integración. Esta tarea de integración, es susceptible de probarse en la Convergencia de la Evidencia propuesta por el Atlas Mundial de la Desertificación como un marco para desarrollar una nueva familia de mapas sobre el riesgo de desertificación.

Conclusiones

La inteligencia artificial, en particular el aprendizaje profundo y automático, es una herramienta útil para analizar grandes cantidades de datos y aportar respuestas complejas no lineales y así avanzar en el entendimiento de los procesos de desertificación y el diseño de estrategias útiles para combatirla. La complejidad y el carácter multiescalar de la desertificación la convierte en un campo propicio para la aplicación de estas técnicas en distintos campos de estudio del fenómeno. Sin embargo, su verdadera utilidad emerge con la puesta en común de las partes estudiadas por cada especialidad (e.g. cuantificación de erosión edáfica, predicciones del aumento de la población, entre otros).

El nuevo enfoque del Atlas Mundial de la Desertificación en relación al diagnóstico de la desertificación mediante la Convergencia de la Evidencia es un buen punto de partida para utilizar las variadas y voluminosas bases de datos que no con inusitada frecuencia vemos publicadas en las mejores revistas científicas. Mediante las distintas técnicas basadas en inteligencia artificial, dar respuesta a dónde y cuándo podría ocurrir la desertificación se convierte en un reto apasionante. Conocer el impacto de los condicionantes biofísicos y socio-económicos de este grave problema es imprescindible para diseñar soluciones adecuadas, que pasan por modificarlos o desactivarlos. Las aplicaciones interdisciplinarias basadas en el aprendizaje automático y profundo nos brindan la oportunidad de buscar esas sendas de sostenibilidad y aportar datos e información relevante para la gestión de recursos que contribuyan en la lucha contra la desertificación.

Agradecimientos

Especiales agradecimientos a Fernando T. Maestre por su guía en este trabajo y a los tres revisores, que con sus comentarios ha mejorado en consideración el trabajo. Este artículo ha sido financiado por the European Research Council (ERC Grant agreement 647038 [BIODESERT]).

Referencias

- Ali, M., Jung, L.T., Abdel-Aty, A.H., Abubakar, M.Y., Elhoseny, M., Ali, I. 2020. Semantic-k-NN algorithm: an enhanced version of traditional k-NN algorithm. *Expert Systems with Applications* 151, 113374.
- Alif, A.A., Shukanya, I.F., Afee, T.N. 2018. *Crop prediction based on geographical and climatic data using machine learning and deep learning*. Tesis doctoral, BRAC University, Dacca, Bangladesh.
- Arribas-Bel, D., García-López, M.Á., Viladecans-Marsal, E. 2019. Building (s and) cities: Delineating urban areas with a machine learning algorithm. *Journal of Urban Economics* 103217.
- Ayhan, B., Kwan, C., Budavari, B., Kwan, L., Lu, Y., Perez, D., et al. 2020. Vegetation Detection Using Deep Learning and Conventional Methods. *Remote Sensing* 12(15), 2502.
- Azimi, S., Wadhawan, R., Gandhi, T.K. 2021. Identifying Water Stress in Chickpea Plant by Analyzing Progressive Changes in Shoot Images using Deep Learning. *arXiv preprint arXiv:2104.07911*.
- Ban, Y., Zhang, P., Nascetti, A., Bevington, A.R., Wulder, M.A. 2020. Near real-time wildfire progression monitoring with Sentinel-1 SAR time series and deep learning. *Scientific reports* 10(1), 1-15.
- Bao, P., Zhang, X. 2017. Uncovering and predicting the dynamic process of collective attention with survival theory. *Scientific reports* 7(1), 1-8.
- Barbier, E.B., Hochard, J.P. 2018. Land degradation and poverty. *Nature Sustainability*, 1(11), 623-631.
- Başağaoğlu, H., Chakraborty, D., Winterle, J. 2021. Reliable Evapotranspiration Predictions with a Probabilistic Machine Learning Framework. *Water* 13(4), 557.
- Bellido-Jiménez, J.A., Estévez, J., García-Marín, A.P. 2021. New machine learning approaches to improve reference evapotranspiration estimates using intra-daily temperature-based variables in a semi-arid region of Spain. *Agricultural Water Management* 245, 106558.
- Bengio, Y., Courville, A., Vincent, P. 2013. Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence* 35(8), 1798-1828.
- Bradford, J.B., Schlaepfer, D.R., Lauenroth, W.K., Palmquist, K.A. 2020. Robust ecological drought projections for drylands in the 21st century. *Global Change Biology* 26, 3906-3919.
- Breiman, L. 2001. Random forests. *Machine learning* 45(1), 5-32.
- Buckland, C.E., Bailey, R.M., Thomas, D.S.G. 2019. Using artificial neural networks to predict future dryland responses to human and climate disturbances. *Scientific reports* 9(1), 1-13.
- Bui, Q.T., Nguyen, Q.H., Nguyen, X.L., Pham, V.D., Nguyen, H.D., Pham, V.M. 2020. Verification of novel integrations of swarm intelligence algorithms into deep learning neural network for flood susceptibility mapping. *Journal of Hydrology* 581, 124379.
- Camardo Leggieri, M., Mazzoni, M., Battilani, P. 2021. Machine Learning for Predicting Mycotoxin Occurrence in Maize. *Frontiers in Microbiology* 12, 782.
- Chandel, N.S., Chakraborty, S.K., Rajwade, Y.A., Dubey, K., Tiwari, M.K., Jat, D. 2020. Identifying crop water stress using deep learning models. *Neural Computing and Applications* 1-15.
- Chen, J., Dafflon, B., Tran, A.P., Falco, N., Hubbard, S.S. 2020. A Deep-Learning Hybrid-Predictive-Modeling Approach for Estimating Evapotranspiration and Ecosystem Respiration. *Hydrology and Earth System Sciences Discussions* 1-38.
- Chen, M., Cui, Y., Wang, X., Xie, H., Liu, F., Luo, T., et al. 2021. A reinforcement learning approach to irrigation decision-making for rice using weather forecasts. *Agricultural Water Management* 250, 106838.
- Cherlet, M., Ivits, E., Kutnjak, H., Smid, M., Sommer, S. 2015. Use of Remote Sensing-Derived Land Productive Capacity Dynamics for the New World Atlas of Desertification (WAD). En: *Use of the Normalized Difference Vegetation Index (NDVI) to Assess Land Degradation at Multiple Scales Current Status, Future Trends, and Practical Considerations*, p. 67-72. JRC99734. Springer International Publishing.
- Colligan, T., Ketchum, D., Brinkerhoff, D., Maneta, M. 2021. A Deep Learning Approach to Mapping Irrigation: IrrMapper-U-Net. *arXiv preprint arXiv:2103.03278*.
- Cortes, C., Vapnik, V. 1995. Support vector machine. *Machine learning* 20(3), 273-297.
- Cruz, H., Gualotuña, T., Pinillos, M., Marcillo, D., Jácome, S., Fonseca C.E.R. 2021. Machine Learning and Color Treatment for the Forest Fire and Smoke Detection Systems and Algorithms, a Recent Literature Review. En: *Artificial Intelligence, Computer and Software Engineering Advances: Proceedings of the CIT 2020 Volume 1*, pp. 109-120. Springer International Publishing.
- De Jong, R., de Bruin, S., de Wit, A., Schaepman, M.E., Dent, D.L. 2011. Analysis of monotonic greening and browning trends from global NDVI time-series. *Remote Sensing of Environment* 115(2), 692-702.
- Dohmen, R., Catal, C., Liu, Q. 2021. Computer vision-based weight estimation of livestock: a systematic literature review. *New Zealand Journal of Agricultural Research* 1-21.
- Dong, W., Wu, T., Sun, Y., Luo, J. 2018. Digital mapping of soil available phosphorus supported by AI technology for precision agriculture. En: *Proceedings of the 7th International Conference on Agro-geoinformatics (Agro-geoinformatics)*, 6-9 Agosto 2018, Hangzhou, China, pp. 1-5. IEEE, Piscataway, NJ, Estados Unidos.

- Doupe, P., Bruzelius, E., Faghmous, J., Ruchman, S.G. 2016. Equitable development through deep learning: The case of sub-national population density estimation. En: *Proceedings of the 7th Annual Symposium on Computing for Development*, Nairobi, Kenya, 18 - 20 noviembre 2016, pp. 1-10. Association for Computing Machinery, New York, NY, Estados Unidos.
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., et al. 2012. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote sensing of Environment* 120, 25-36.
- Duan, Y., Edwards, J.S., Dwivedi, Y.K. 2019. Artificial intelligence for decision making in the era of Big Data—evolution, challenges and research agenda. *International Journal of Information Management* 48, 63-71.
- Dudani, S.A. 1976. The distance-weighted k-nearest-neighbor rule. *IEEE Transactions on Systems, Man, and Cybernetics* (4), 325-327.
- Dudley, N., Alexander, S. 2017. *Global Land Outlook*, UNCCD, Bonn, Alemania.
- Eckert, S., Hüsler, F., Liniger, H., Hodel, E. 2015. Trend analysis of MODIS NDVI time series for detecting land degradation and regeneration in Mongolia. *Journal of Arid Environments* 113, 16-28.
- Emadi, M., Taghizadeh-Mehrjardi, R., Cherati, A., Danesh, M., Mosavi, A., Scholten, T. 2020. Predicting and mapping of soil organic carbon using machine learning algorithms in Northern Iran. *Remote Sensing* 12(14), 2234.
- Esteva, A., Kuprel, B., Novoa, R.A., Ko, J., Swetter, S.M., Blau, H.M., Thrun, S. 2017. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 542(7639), 115-118.
- Famiglietti, J.S. 2014. The global groundwater crisis. *Nature Climate Change* 4: 945-948.
- Feng, Q., Ma, H., Jiang, X., Wang, X., Cao, S. 2015. What has caused desertification in China?. *Scientific reports* 5(1), 1-8.
- Fernández, C., Fontúrbel, T., Vega, J.A. 2021. Cumulative effects of salvage logging and slash removal on erosion, soil functioning indicators and vegetation in a severely burned area in NW Spain. *Geoderma* 393, 115004.
- Ferreira, L.B., da Cunha, F.F. 2020a. New approach to estimate daily reference evapotranspiration based on hourly temperature and relative humidity using machine learning and deep learning. *Agricultural Water Management* 234, 106113.
- Ferreira, L.B., da Cunha, F.F. 2020b. Multi-step ahead forecasting of daily reference evapotranspiration using deep learning. *Computers and Electronics in Agriculture* 178, 105728.
- Finer, M., Novoa, S., Weisse, M.J., Petersen, R., Mascaro, J., Souto, T., et al. 2018. Combating deforestation: From satellite to intervention. *Science* 360(6395), 1303-1305.
- Foster, S., Chilton, P.J., Moench, M., Cardy, W.F., Schiffler, M. 2000. *Groundwater in Rural Development: Facing the Challenges of Supply and Resource Sustainability*. Water P-Notes; No. 19. World Bank, Washington, DC. Estados Unidos. <https://openknowledge.worldbank.org/handle/10986/11749>
- Fredrickson, E., Havstad, K.M., Estell, R., Hyder, P. 1998. Perspectives on desertification: south-western United States. *Journal of Arid Environments* 39(2), 191-207.
- Gadzama, N.M. 2017. Attenuation of the effects of desertification through sustainable development of Great Green Wall in the Sahel of Africa. *World Journal of Science, Technology and Sustainable Development* 14, 279-289.
- Gao, Z., Luo, Z., Zhang, W., Lv, Z., Xu, Y. 2020. Deep learning application in plant stress imaging: a review. *AgriEngineering* 2(3), 430-446.
- García, R., Aguilar, J., Toro, M., Pinto, A., Rodríguez, P. 2020. A systematic literature review on the use of machine learning in precision livestock farming. *Computers and Electronics in Agriculture* 179, 105826.
- Gardner, M.W., Dorling, S.R. 1998. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment* 32(14-15), 2627-2636.
- Ghaffarian, S., Emtehani, S. 2021. Monitoring Urban Deprived Areas with Remote Sensing and Machine Learning in Case of Disaster Recovery. *Climate* 9(4), 58.
- Grekousis, G. 2019. Artificial neural networks and deep learning in urban geography: A systematic review and meta-analysis. *Computers, Environment and Urban Systems* 74, 244-256.
- Guirado, E., Tabik, S., Alcaraz-Segura, D., Cabello, J., Herrera, F. 2017. Deep-learning versus OBIA for scattered shrub detection with Google earth imagery: *Ziziphus Lotus* as case study. *Remote Sensing* 9(12), 1220.
- Guirado, E., Alcaraz-Segura, D., Cabello, J., Puertas-Ruiz, S., Herrera, F., Tabik, S. 2020. Tree Cover Estimation in Global Drylands from Space Using Deep Learning. *Remote Sensing* 12(3), 343.
- Guirado, E., Blanco-Sacristán, J., Rodríguez-Caballero, E., Tabik, S., Alcaraz-Segura, D., Martínez-Valderrama, J., Cabello, J. 2021. Mask R-CNN and OBIA Fusion Improves the Segmentation of Scattered Vegetation in Very High-Resolution Optical Sensors. *Sensors* 21(1), 320.
- Ha, J.H., Lee, Y.H., Kim, Y.H. 2016. Forecasting the precipitation of the next day using deep learning. *Journal of Korean institute of intelligent systems* 26(2), 93-98.
- Han, L., Tao, P., Martin, R.R. 2019. Livestock detection in aerial images using a fully convolutional network. *Computational Visual Media* 5(2), 221-228.
- Harzing, A.W. 2007. *Publish or Perish* [Software] Disponible en: <https://harzing.com/resources/publish-or-perish>
- He, M., Xu, Y., Li, N. 2020. Population spatialization in Beijing city based on machine learning and multisource remote sensing data. *Remote Sensing* 12(12), 1910.
- Helbing, D. 2019. Societal, economic, ethical and legal challenges of the digital revolution: from big data to deep learning, artificial intelligence, and manipulative technologies. En: *Towards Digital Enlightenment*, pp. 47-72. Springer, Cham, Alemania.
- Hinton, G.E., Salakhutdinov, R.R. 2006. Reducing the dimensionality of data with neural networks. *Science* 313(5786), 504-507.
- Hu, W., Harshadhai Patel, J., Robert, Z.-A., Novosad, P., Asher, S., Tang, Z., et al. 2019. Mapping missing population in rural india: A deep learning approach with satellite imagery. En: *Proceedings of the 2019 AAAI/ACM Conference on AI, Ethics, and Society, January 2019, Honolulu, Estados Unidos*, pp. 353-359. Association for Computing Machinery, New York, NY, Estados Unidos.
- Huang, J., Zhang, G., Zhang, Y., Guan, X., Wei, Y., Guo, R. 2020. Global desertification vulnerability to climate change and human activities. *Land Degradation and Development* 31(11), 1380-1391.
- Independent UK 2021. Saudi Arabia 'to plant 10 billion trees' in bid to tackle climate change. <https://www.independent.co.uk/news/world/middle-east/saudi-arabia-climate-trees-oil-b1824070.html> [access May, 2011]
- Ichii, K., Kawabata, A., Yamaguchi, Y. 2002. Global correlation analysis for NDVI and climatic variables and NDVI trends: 1982-1990. *International journal of remote sensing* 23(18), 3873-3878.
- Ise, T., Oba, Y. 2019. Forecasting climatic trends using neural networks: an experimental study using global historical data. *Frontiers in Robotics and AI* 6, 32.
- Jiang, H. 2016. Taking Down the 'Great Green Wall': The Science and Policy Discourse of Desertification and Its Control in China. En: Behnke R., Mortimore M. (eds). *The End of Desertification?* Springer Earth System Sciences. Springer, Berlin, Heidelberg, Alemania, doi:10.1007/978-3-642-16014-1_19.
- Jiao, Z., Zhang, Y., Xin, J., Mu, L., Yi, Y., Liu, H., Liu, D. 2019. A deep learning based forest fire detection approach using UAV and YOLOv3. En: *Proceedings of the 2019, 1st International Conference on Industrial Artificial Intelligence (IAI)*, pp. 1-5. IEEE, Piscataway, NJ, Estados Unidos. doi: 10.1109/ICIAI.2019.8850815.
- Jones, N. 2017. How machine learning could help to improve climate forecasts. *Nature News* 548(7668), 379.
- Jung, D.H., Kim, H.S., Jhin, C., Kim, H.J., Park, S.H. 2020. Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. *Computers and Electronics in Agriculture*, 173, 105402.
- Kamilaris, A., Prenafeta-Boldú, F.X. 2018. Deep learning in agriculture: A survey. *Computers and electronics in agriculture* 147, 70-90.
- Kaba, K., Sargül, M., Avci, M., Kandirmaz, H.M. 2018. Estimation of daily global solar radiation using deep learning model. *Energy* 162, 126-135.
- Karegowda, A.G., Devika, G., Geetha, M. 2021. Deep Learning Solutions for Agricultural and Farming Activities. En: Senthilnathan, K., Shanmugam, B., Goyal, D., Annappoorani, I., Samikannu, R. (eds.), *Deep Learning Applications and Intelligent Decision Making in Engineering*, pp. 256-287. IGI Global, Pensilvania, Estados Unidos.

- Khryashchev, V.V., Pavlov, V.A., Priorov, A., Ostrovskaya, A.A. 2018. Deep learning for region detection in high-resolution aerial images. En: *Proceedings of the 2018, IEEE East-West Design and Test Symposium (EWDTS), 14-17 septiembre, Kazan, Russia*, pp. 1-5. IEEE, Piscataway, NJ, Estados Unidos.
- Kratzert, F., Klotz, D., Shalev, G., Klambauer, G., Hochreiter, S., Nearing, G. 2019. Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. *Hydrology and Earth System Sciences* 23(12), 5089-5110.
- Lazer, D., Pentland, A., Adamic, I., Aral, S., Barabasi, A.L., Brewer, D., et al. 2009. Life in the network: the coming age of computational social science. *Science (New York, NY)*, 323(5915), 721
- LeCun, Y., Bengio, Y., Hinton, G. 2015. Deep learning. *Nature* 521(7553), 436-444.
- Lee, S.H., Han, K.J., Lee, K., Lee, K.J., Oh, K.Y., Lee, M.J. 2020. Classification of Landscape Affected by Deforestation Using High-Resolution Remote Sensing Data and Deep-Learning Techniques. *Remote Sensing* 12(20), 3372.
- Li, W., Liu, H., Wang, Y., Li, Z., Jia, Y., Gui, G. 2019. Deep learning-based classification methods for remote sensing images in urban built-up areas. *IEEE Access* 7, 36274-36284.
- Li, W., Buitenwerf, R., Munk, M., Bøcher, P.K., Svenning, J.C. 2020. Deep-learning based high-resolution mapping shows woody vegetation densification in greater Maasai Mara ecosystem. *Remote Sensing of Environment* 247, 111953.
- Liu, Z., Zhang, K., Wang, C., Huang, S. 2020. Research on the identification method for the forest fire based on deep learning. *Optik* 223, 165491.
- Lima, M.A.F., Carvalho, P.C., Fernández-Ramírez, L.M., Braga, A.P. 2020. Improving solar forecasting using Deep Learning and Portfolio Theory integration. *Energy* 195, 117016.
- Ling, F., Foody, G.M. 2019. Super-resolution land cover mapping by deep learning. *Remote Sensing Letters*, 10(6), 598-606.
- Ludwig, J.A., Tongway, D.J. 1995. Desertification in Australia: an eye to grass roots and landscapes. *Environmental monitoring and Assessment*, 37(1), 231-237.
- Maretto, R.V., Fonseca, L.M., Jacobs, N., Körting, T.S., Bendini, H.N., Parente, L.L. 2020. Spatio-temporal deep learning approach to map deforestation in Amazon rainforest. *IEEE Geoscience and Remote Sensing Letters*, doi: 10.1109/LGRS.2020.2986407
- Marmanis, D., Datcu, M., Esch, T., Stilla, U. 2016. Deep Learning Earth Observation Classification Using ImageNet Pretrained Networks. *IEEE Geoscience and Remote Sensing Letters* 13, 105-109.
- Martínez-Valderrama, J., Guirado, E., Maestre, F.T. 2020. Desertifying deserts. *Nature Sustainability* 3(8), 572-575.
- Martínez-Valderrama, J., Guirado, E., Maestre, F.T. 2021. ¿Se puede cartografiar la desertificación? Luces y sombras de una tarea desafiante. *Ecosistemas* 30(3): <https://doi.org/10.7818/ECOS.2211>
- Mayfield, H.J., Smith, C., Gallagher, M., Hockings, M. 2020. Considerations for selecting a machine learning technique for predicting deforestation. *Environmental Modelling and Software* 131, 104741.
- Mhatre, A., Mudaliar, N.K., Narayanan, M., Gurav, A., Nair, A., Nair, A. 2019. Using Deep Learning on Satellite Images to Identify Deforestation/Afforestation. En: Smys, S., R.S. Tavares, J.M., Balas, V.E., Iliyasu, A.M. (eds.), *Proceedings of the International Conference On Computational Vision and Bio Inspired Computing, Coimbatore, India, 25-26 de Septiembre*, pp. 1078-1084. Springer, Cham, Alemania.
- Meena, S.D., Agilandeewari, L. 2021. Smart Animal Detection and Counting Framework for Monitoring Livestock in an Autonomous Unmanned Ground Vehicle Using Restricted Supervised Learning and Image Fusion. *Neural Processing Letters* 1-33.
- Millennium Ecosystem Assessment (MEA) 2005. Ecosystems and human well-being: Desertification synthesis. World Resources Institute. Washington, DC, Estados Unidos.
- Mo, S., Zhong, Y., Shi, X., Feng, W., Yin, X., Wu, J. 2021. Filling the gap between GRACE and GRACE-FO-derived terrestrial water storage anomalies with Bayesian convolutional neural networks. *arXiv preprint arXiv:2101.09361*.
- Muñoz-Peña, M.A., Navarro, F.A.R. 2016. An NDVI-data harmonic analysis to study deforestation in Peru's Tahuamanu province during 2001-2011. *International Journal of Remote Sensing* 37(4), 856-875.
- Nguyen, T.T., Hoang, T.D., Pham, M.T., Vu, T.T., Nguyen, T.H., Huynh, Q.T., Jo, J. 2020. Monitoring agriculture areas with satellite images and deep learning. *Applied Soft Computing* 95, 106565.
- Nick, M., Lindsay, S., Andrew, G. David, T. 2011. *The forgotten billion: MDG achievement in the drylands*. UNDP, New York, NY, Estados Unidos, y UNCCD, Bonn, Germany. http://catalogue.unccd.int/39_Forgotten_Billion.pdf
- Nyeki, A., Kerepesi, C., Daróczy, B., Benczúr, A., Milics, G., Kovács, A.J., Neményi, M. 2019. Maize yield prediction based on artificial intelligence using spatio-temporal data. En: Stafford, J.V. (ed.), *Precision agriculture '19*, pp. 1011-1017. Wageningen Academic Publishers, Wageningen. Países Bajos.
- Oh, J.W., Ngarambe, J., Duhirwe, P.N., Yun, G.Y., Santamouris, M. 2020. Using deep-learning to forecast the magnitude and characteristics of urban heat island in Seoul Korea. *Scientific reports* 10(1), 1-13.
- Ortega Adarme, M., Queiroz Feitosa, R., Nigri Happ, P., Aparecido De Almeida, C., Rodrigues Gomes, A. 2020. Evaluation of deep learning techniques for deforestation detection in the Brazilian Amazon and cerrado biomes from remote sensing imagery. *Remote Sensing* 12(6), 910.
- O'Leary, D.E. 2013. Artificial intelligence and big data. *IEEE intelligent systems* 28(2), 96-99.
- Pham, B.T., Jaafari, A., Avand, M., Al-Ansari, N., Dinh Du, T., Yen, H.P.H., et al. 2020. Performance evaluation of machine learning methods for forest fire modeling and prediction. *Symmetry* 12(6), 1022.
- Pouliot, D., Latifovic, R., Olthof, I. 2009. Trends in vegetation NDVI from 1 km AVHRR data over Canada for the period 1985-2006. *International Journal of Remote Sensing* 30(1), 149-168.
- Pi, W., Du, J., Liu, H., Zhu, X. 2020. Desertification Grassland Classification and Three-Dimensional Convolution Neural Network Model for Identifying Desert Grassland Landforms with Unmanned Aerial Vehicle Hyperspectral Remote Sensing Images. *Journal of Applied Spectroscopy* 87(2), 309-318.
- Prince, S.D. 2016. Where Does Desertification Occur? Mapping Dryland Degradation at Regional to Global Scales. En: Behnke, R., Mortimore, M. (eds.), *The End of Desertification? Disputing Environmental Change in the Drylands*, pp. 225-263. Springer Earth System Sciences. Springer-Verlag GmbH Berlin Heidelberg, Alemania.
- Peters, D.P.C., Bestelmeyer, B.T., Havstad, K.M., Rango, A., Archer, S.R., Comrie, A.C., et al. 2013. Desertification of rangelands. En: Pielke, R.A. (ed.), *Climate vulnerability: understanding and addressing threats to essential resources*, pp. 239-258. Elsevier Inc.
- Qiao, Y., Su, D., Kong, H., Sukkarieh, S., Lomax, S., Clark, C. 2020. Data Augmentation for Deep Learning based Cattle Segmentation in Precision Livestock Farming. En: *Proceedings of the 2020 IEEE 16th International Conference on Automation Science and Engineering (CASE), 20-21 Agosto 2020 (Virtual conference)*, pp. 979-984. IEEE, Piscataway, NJ, Estados Unidos.
- Rahul, M., Saketh, K.S., Sanjeet, A., Naik, N.S. 2020. Early Detection of Forest Fire using Deep Learning. En: *Proceedings of the 2020 IEEE Region 10 Conference (TENCON), Osaka, Japan, 16-19 noviembre 2020*, pp. 1136-1140. IEEE, Piscataway, NJ, Estados Unidos.
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N. 2019. Deep learning and process understanding for data-driven Earth system science. *Nature* 566(7743), 195-204.
- Reynolds, J.F. 2021. Desertification is a prisoner of history: An essay on why young scientists should care. *Ecosistemas* 30(3):2302, <https://doi.org/10.7818/ECOS.2302>
- Reynolds, J.F., Stafford Smith, D.M., Lambin, E.F., Turner II, B.L., Mortimore, M., Batterbury, S.P.J., et al. 2007. Global desertification: building a science for dryland development. *Science* 316, 847-851.
- Roy, D.P., Wulder, M., Loveland, T.R., Woodcock, C.E., Allen, R.G., Anderson, M., et al. 2014. Landsat-8: Science and product vision for terrestrial global change research. *Remote sensing of Environment* 145, 154-172.
- Rumelhart, D.E., Hinton, G.E., Williams, R.J. 1986. Learning representations by back-propagating errors. *nature* 323(6088), 533-536.
- Safonova, A., Guirado, E., Maglinets, Y., Alcaraz-Segura, D., Tabik, S. 2021. Olive Tree Biovolume from UAV Multi-Resolution Image Segmentation with Mask R-CNN. *Sensors* 21(5), 1617.
- Şahan, S., Polat, K., Kodaz, H., Güneş, S. 2007. A new hybrid method based on fuzzy-artificial immune system and k-nn algorithm for breast cancer diagnosis. *Computers in Biology and Medicine* 37(3), 415-423.
- Saraiva, M., Protas, É., Salgado, M., Souza Jr, C. 2020. Automatic mapping of center pivot irrigation systems from satellite images using deep learning. *Remote Sensing* 12(3), 558.

- Savtchenko, A., Ouzounov, D., Ahmad, S., Acker, J., Leptoukh, G., Koziana, J., Nickless, D. 2004. Terra and Aqua MODIS products available from NASA GES DAAC. *Advances in Space Research* 34(4), 710-714.
- Shi, X., Gao, Z., Lausen, L., Wang, H., Yeung, D.Y., Wong, W.K., Woo, W.C. 2017. Deep learning for precipitation nowcasting: A benchmark and a new model. *arXiv preprint arXiv:1706.03458*.
- Singh, A.K., Ganapathysubramanian, B., Sarkar, S., Singh, A. 2018. Deep learning for plant stress phenotyping: trends and future perspectives. *Trends in plant science* 23(10), 883-898.
- Suel, E., Polak, J.W., Bennett, J.E., Ezzati, M. 2019. Measuring social, environmental and health inequalities using deep learning and street imagery. *Scientific reports* 9(1), 1-10.
- Sungmin, O., Dutra, E., Orth, R. 2020. Robustness of process-based versus data-driven modeling in changing climatic conditions. *Journal of Hydrometeorology* 21(9), 1929-1944.
- Tabik, S., Peralta, D., Herrera-Poyatos, A., Herrera, F. 2017. A snapshot of image pre-processing for convolutional neural networks: case study of MNIST. *International Journal of Computational Intelligence Systems* 10, 555.
- Tapley, B.D., Reigber, C. 2001. The GRACE mission: status and future plans. En: *AGU Fall Meeting Abstracts* (Vol. 2001, pp. G41C-02. American Geophysical Union, Washington DC, Estados Unidos.
- Tolba, M.K. 1986. Desertification in Africa. *Land Use Policy* 3(4), 260-268.
- Turing, A.M. 1950. Computing Machinery and Intelligence, *Mind* LIX(236): 433-460, <https://doi.org/10.1093/mind/LIX.236.433>
- UNCCD 1994. *United Nations convention to combat desertification in countries experiencing serious drought and/or desertification, particularly in Africa*. A/AC.241/27, Paris, Francia.
- UNCCD 2017. *The Global Land Outlook*. 1st ed. United Nations Convention to Combat Desertification, Bonn, Alemania.
- Van Eck, N.J., Waltman, L. 2013. VOSviewer manual. *Universteit Leiden*, (Leiden, Países Bajos) 1(1), 1-53.
- Vani, K. 2019. Deep Learning Based Forest Fire Classification and Detection in Satellite Images. En: *Proceedings of the 2019 11th International Conference on Advanced Computing (ICoAC), Chennai, India, 18-20 diciembre 2019*, pp. 61-65. IEEE, Piscataway, NJ, Estados Unidos.
- Verón, S.R., Blanco, L.J., Teixeira, M.A., Irisarri, J.G.N., Paruelo, J.M. 2018. Desertification and ecosystem services supply: The case of the Arid Chaco of South America. *Journal of Arid Environments* 159, 66-74.
- Vine, R. 2006. Google scholar. *Journal of the Medical Library Association* 94(1), 97.
- Wang, M., Fu, J.E., Wu, Z., Pang, Z. 2020a. Spatiotemporal variation of NDVI in the vegetation growing season in the source region of the Yellow River, China. *ISPRS International Journal of Geo-Information* 9(4), 282.
- Wang, Y., Li, Z., Zeng, C., Xia, G.S., Shen, H. 2020b. An urban water extraction method combining deep learning and Google Earth engine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13, 768-781.
- Williams, A.P., Cook, E.R., Smerdon, J.E., Cook, B.I., Abatzoglou, J.T., Bolles, K., et al. 2020. Large contribution from anthropogenic warming to an emerging North American megadrought. *Science* 368, 314-318.
- Xue, F., Cao, Y., Ding, Z., Tang, H., Yang, X., Chen, L., Li, J. 2020. Urban population density estimation based on spatio-temporal trajectories. *Concurrency and Computation: Practice and Experience* 32(14), e5685.
- Yeh, C., Perez A., Driscoll, A., Azzari, G., Tang, Z., Lobell, D., et al. 2020. Using publicly available satellite imagery and deep learning to understand economic well-being in Africa. *Nature communications* 11(1), 1-11.
- Yu, Y., Feng, K., Hubacek, K. 2013. Tele-connecting local consumption to global land use. *Global Environmental Change* 23: 1178-1186.
- Yu, P., Han, D., Liu, S., Wen, X., Huang, Y., Jia, H. 2018. Soil quality assessment under different land uses in an alpine grassland. *Catena* 171, 280-287. <https://doi.org/10.1016/j.catena.2018.07.021>
- Yuan, Z., Tao, C. 2018. Estimation population density built on multilayer convolutional neural network. En: *Proceedings of the 5th International Conference on Systems and Informatics (ICSAI), Nanjing, China, November 10-12, 2018*, pp. 424-428. IEEE, Piscataway, NJ, Estados Unidos.
- Young, S.R., Rose, D.C., Karnowski, T.P., Lim, S.H., Patton, R.M. 2015. Optimizing deep learning hyper-parameters through an evolutionary algorithm. En: *Proceedings of the Workshop on Machine Learning in High-Performance Computing Environments, Austin Texas 15 November 2015*, pp. 1-5. Association for Computing Machinery. New York, NY, Estados Unidos
- Zamani Joharestani, M., Cao, C., Ni, X., Bashir, B., Talebiesfandarani, S. 2019. PM2.5 prediction based on random forest, XGBoost, and deep learning using multisource remote sensing data. *Atmosphere* 10(7), 373.
- Zhang, Q., Liu, Y., Gong, C., Chen, Y., Yu, H. 2020. Applications of deep learning for dense scenes analysis in agriculture: A review. *Sensors* 20(5), 1520.
- Zhao, S., Liu, Y., Zhang, R., Fu, B. 2020. China's population spatialization based on three machine learning models. *Journal of Cleaner Production* 256, 120644.
- Zhou, Z., Majeed, Y., Naranjo, G.D., Gambacorta, E.M. 2021. Assessment for crop water stress with infrared thermal imagery in precision agriculture: A review and future prospects for deep learning applications. *Computers and Electronics in Agriculture* 182, 106019.
- Zuo, C., Han, L., Tao, P., Lei Meng, X. 2020. Livestock Detection Based on Convolutional Neural Network. En: *Proceedings of the 2020 the 3rd International Conference on Control and Computer Vision, Macau China August 23 - 25, 2020*, pp. 1-6. Association for Computing Machinery. New York, NY, Estados Unidos.