

Aprendizaje profundo para predicciones que usan imágenes multiespectrales en agricultura

Deep Learning for Multispectral Imaging based Predictions in Agriculture

¹ Julio Torres Tello  <https://orcid.org/0000-0001-9694-6578>
Investigador Independiente, Saskatoon, Canadá.
juliotorrest@gmail.com



Artículo de Investigación Científica y Tecnológica

Enviado: 22/08/2023

Revisado: 20/09/2023

Aceptado: 02/10/2023

Publicado: 13/10/2023

DOI: <https://doi.org/10.33262/concienciadigital.v6i4.1.2734>

Cítese:

Torres Tello, J. (2023). Aprendizaje profundo para predicciones que usan imágenes multiespectrales en agricultura. *ConcienciaDigital*, 6(4.1), 75-87.
<https://doi.org/10.33262/concienciadigital.v6i4.1.2734>



CONCIENCIA DIGITAL, es una revista multidisciplinar, **trimestral**, que se publicará en soporte electrónico tiene como **misión** contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://concienciadigital.org>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec

Esta revista está protegida bajo una licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 International. Copia de la licencia: <https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>

Palabras claves:

Aprendizaje profundo,
Aprendizaje de máquina,
Sensado remoto,
Agricultura,
Multiespectral,
Hiperespectral.

Resumen

Introducción. La Inteligencia Artificial ha logrado un gran éxito en los últimos años, y aunque las aplicaciones comercialmente rentables compiten actualmente con los humanos en términos de precisión y eficiencia, hay otras áreas que podrían beneficiarse de estas tecnologías y en las cuales aún existen obstáculos por superar. Uno de los aspectos importantes de este estudio, es que estos resultados nos permiten comprender de mejor manera las limitaciones relacionadas al uso de datos atípicos en modelos de IA. Esto puede permitir el desarrollo de herramientas para implementar modelos más pequeños, rápidos, y eficientes con aplicaciones en la agricultura, y otras áreas que utilicen imágenes multiespectrales. **Objetivo.** Se busca proponer un esquema en el cual datos de fuentes no convencionales y relacionadas a la agricultura, son analizados por modelos personalizados de IA a fin de generar predicciones sobre variables medidas en el campo, y que eventualmente pueden ayudar al entendimiento de los fenómenos físicos y biológicos subyacentes. **Metodología.** Este trabajo resume los resultados obtenidos a lo largo de la implementación de un proyecto que ha usado datos de imágenes multi e hiperespectrales de cultivos agrícolas, así como información tomada en el campo. Los conjuntos de datos incluyen imágenes multiespectrales de cultivos de trigo, e imágenes hiperespectrales de canola y trigo, e incluye mediciones manuales de ciertas variables. En lo que se refiere a los modelos de IA, estos están estrechamente relacionados al abordaje del problema del procesamiento de datos. En ambos casos se ha optado por modelos sencillos de aprendizaje profundo, pero con diferencias en el tipo de datos que estos están optimizados para procesar. **Resultados.** El principal resultado de este trabajo es la demostración del uso de modelos de IA/DL para el análisis de datos no convencionales. En el primer caso, usando redes convolucionales tridimensionales, hemos logrado implementar un modelo que es capaz de predecir el rendimiento de los cultivos de trigo bajo análisis; y en el segundo caso, usando un esquema dual, con modelos secuenciales y espaciales, hemos logrado realizar la predicción del contenido de humedad. **Conclusión.** Principalmente, este trabajo demuestra que un modelo DL es capaz de encontrar características útiles dentro de un conjunto de datos MSI para la predicción del rendimiento; además de

encontrar un modelo DL preciso para la predicción del contenido de humedad de los cultivos de canola y trigo, basado en HSI. Estos resultados evidencian la versatilidad de los modelos de aprendizaje automático y la posibilidad de extenderlos resultados obtenidos en otras aplicaciones. **Área de la ciencia:** inteligencia artificial

Keywords:

Deep Learning
Machine Learning
Remote Sensing
Agriculture
Multispectral
Hyperspectral

Abstract

Introduction. Artificial Intelligence has achieved immense success in recent years, and although commercially profitable applications currently compete with humans in terms of accuracy and efficiency, there are other areas that could benefit from these technologies and in which obstacles still exist. An important aspect of this paper is that these results allow us to better understand the limitations related to the use of uncommon data in AI models. This may enable the development of tools to implement smaller, faster, and more efficient models with applications in agriculture, and other areas that use multispectral images. **Objective.** This paper proposes a scheme in which data from non-conventional sources related to agriculture are analyzed by custom AI models to generate predictions about variables measured in the fields, and that can eventually help the understanding of the underlying physical and biological phenomena. **Methodology.** This work summarizes the results obtained throughout the implementation of a project that has used multi- and hyperspectral image data of agricultural crops, as well as information taken in the field. The datasets include multispectral images of wheat crops, and hyperspectral images of canola and wheat, and includes manual measurements of certain variables. When it comes to AI models, these are closely related to addressing the problem of data processing. In both cases, simple deep learning models have been chosen, but with differences in the type of data that they are optimized to process. **Results.** The main result of this work is the demonstration of the use of AI/DL models for unconventional data analysis. In the first case, using 3D convolutional networks, we have managed to implement a model that can predict the yield of the wheat crops under analysis; and in the second case, using a dual scheme, with sequential and spatial models, we have managed to predict the moisture content. **Conclusion.** Primarily, this work demonstrates

that a DL model can find useful features within an MSI dataset for yield prediction; in addition to finding an accurate DL model for the prediction of moisture content of canola and wheat crops, based on HSI. These results demonstrate the versatility of ML models and the possibility of extending the results obtained in other applications.

Introducción

La Inteligencia Artificial (IA) ha logrado un gran éxito en los últimos años, y aunque las aplicaciones comercialmente rentables, como el reconocimiento de imágenes y *chatbots* compiten actualmente con los humanos en términos de precisión y eficiencia (Chollet, 2017), hay otras áreas que podrían beneficiarse de estas tecnologías y en las cuales aún existen obstáculos por superar. Uno de los problemas actuales para adoptar y adaptar la IA para ayudar a resolver nuevos problemas es la implementación de estos modelos cuando los conjuntos de datos usados no son los típicos (imágenes, videos, o texto). Por esto, es necesario implementar, probar, y optimizar modelos de aprendizaje automático (otro de los nombres de la IA) con conjuntos de datos atípicos (Virnodkar et al., 2020). En este trabajo se describe la implementación de algunas de estas soluciones, usando imágenes con una cobertura espectral extendida (multi e hiperespectrales - MSI y HSI, respectivamente).

Uno de los aspectos importantes de este estudio, es que estos resultados nos permiten comprender de mejor manera las limitaciones relacionadas al uso de datos atípicos en modelos de IA. Esto puede permitir el desarrollo de herramientas para implementar modelos más pequeños, rápidos, y eficientes con aplicaciones en la agricultura, y otras áreas que utilicen imágenes multiespectrales.

Debido a que este artículo compila parte de los resultados de una investigación de varios años, es importante hacer una breve revisión de los trabajos ya publicados al respecto. En este sentido, tenemos que *Identifying Useful Features in Multispectral Images with Deep Learning for Optimizing Wheat Yield Prediction* (Torres-Tello & Ko, 2021a) presenta la implementación y uso de modelos personalizados de IA para el análisis de MSI de campos de trigo, tomadas a diferentes intervalos de tiempo. Dicho artículo también explora la posibilidad de identificar las características más relevantes dentro del conjunto de datos, que usa el modelo para mejorar las predicciones.

Por otra parte, *A Novel Approach to Identify the Spectral Bands that Predict Moisture Content in Canola and Wheat* (Torres-Tello & Ko, 2021b) presenta una metodología para

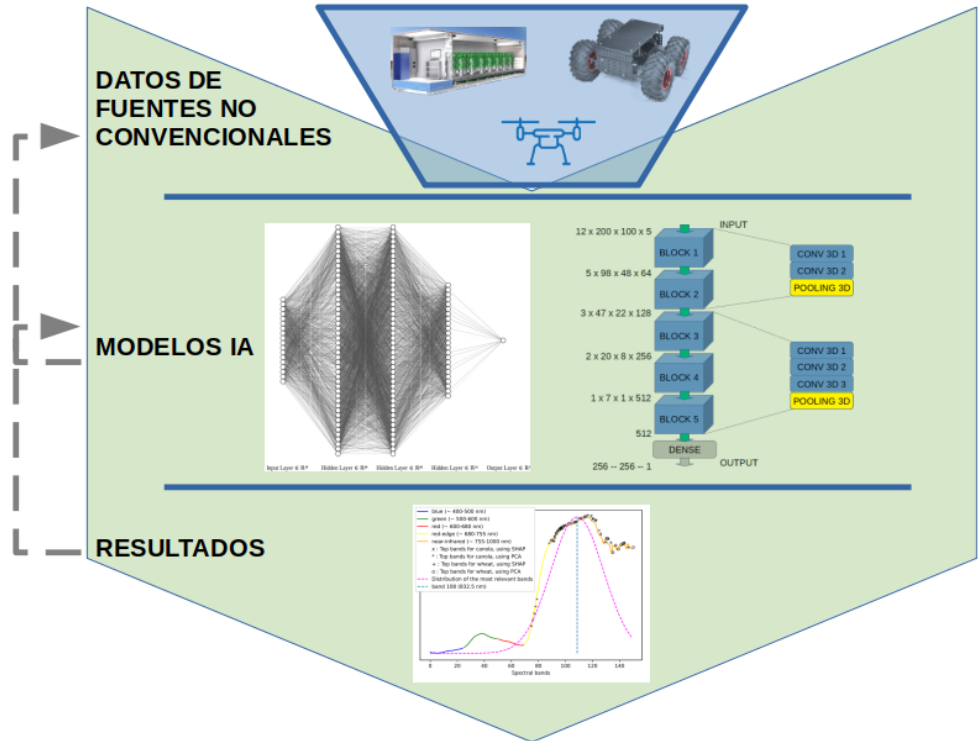
la selección de las características más relevantes para las predicciones de un modelo de IA, basada en un algoritmo diseñado por Lundberg & Lee (2017), para la explicabilidad / interpretabilidad (SHAP) de este tipo de modelos. Este enfoque se utiliza para analizar qué características generan ciertas predicciones. Una ventaja de la técnica propuesta es que puede preservar el significado físico de las características originales, proporcionando resultados más significativos que los algoritmos de extracción de características como PCA (Xiong et al., 2018). Otro beneficio de esta línea de acción es que puede generar explicaciones del modelo entrenado enfocadas en un objetivo (por ejemplo, el contenido de humedad), una característica (por ejemplo, espectral o espacial) o un subconjunto de las muestras. Si se necesita una explicación global, las contribuciones individuales se pueden agregar en un único valor SHAP por característica, debido a su propiedad aditiva (Carlsson et al., 2020).

Finalmente, tenemos que *Optimizing a Multispectral-Images-Based DL Model, Through Feature Selection, Pruning and Quantization* (Torres-Tello & Ko, 2022) introduce el uso de los algoritmos de *pruning* y *quantization*, que son técnicas de optimización de modelos que complementan el enfoque de selección de características y mejoran aún más la tarea de crear modelos eficientes de IA que usan datos no convencionales (Han et al., 2015).

En resumen, este trabajo busca proponer un esquema, como se observa en la figura 1, en el cual datos de fuentes no convencionales, y relacionadas a la agricultura, son analizados por modelos personalizados de IA a fin de generar predicciones sobre variables medidas en el campo, y que eventualmente pueden ayudar al entendimiento de los fenómenos físicos y biológicos subyacentes (Virnodkar et al., 2020).

Figura 1

Esquema general del flujo de trabajo



Metodología

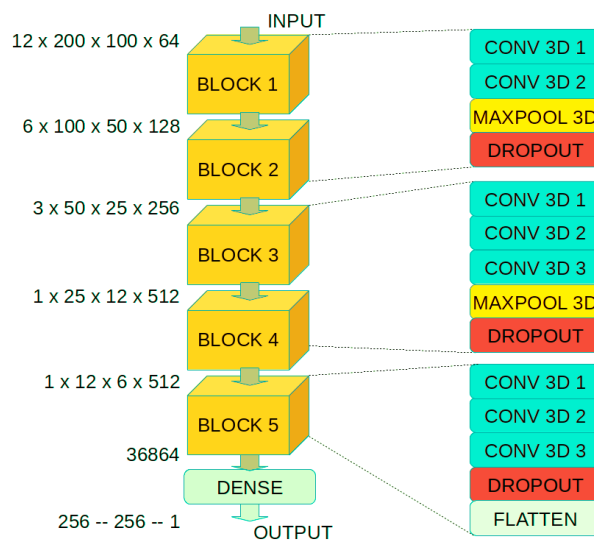
Como se ha mencionado antes, este trabajo resume los resultados obtenidos a lo largo de la implementación de un proyecto (Torres-Tello, 2022) que ha usado datos de imágenes multi e hiperespectrales de cultivos agrícolas, así como información tomada en el campo. Los conjuntos de datos incluyen 48 imágenes multiespectrales de cultivos de trigo, de 12 fechas diferentes en cuatro ubicaciones (dos ubicaciones en dos años diferentes). Cada imagen con 48 parcelas por ubicación, para un total de 192 muestras, cada una de las cuales contiene información de 12 fechas y 5 bandas espectrales (Torres-Tello & Ko, 2021a). Por otro lado, tenemos imágenes hiperespectrales de canola y trigo, en donde el primer grupo consiste en datos de 8 fases de crecimiento de la canola con un total de 512 muestras, e incluye mediciones manuales de humedad de la vaina, entre otras. Para el caso del trigo, se tiene información de solamente 2 etapas de crecimiento, para un total de 90 muestras (Torres-Tello & Ko, 2021b). A diferencia de lo que sucede en el caso de procesamiento de imágenes tradicionales (con 3 canales), en nuestro caso, un punto importante es el procesamiento de la información espectral (Montesinos-López et al., 2017). Para este cometido, se puede tratar de procesar las imágenes en sus tres dimensiones (alto, ancho, y espectro) al mismo tiempo, o se puede separarla información

espacial (alto y ancho) de la espectral, y procesarlas por separado. Dado que en el caso de las imágenes multispectrales tenemos solamente 5 canales, se ha optado por el primer caso; mientras que para las imágenes hiperespectrales, que en nuestro caso tienes 150 canales, se ha optado por la segunda opción.

En lo que se refiere a los modelos de IA, estos están estrechamente relacionados al abordaje del problema del procesamiento de datos. En ambos casos se ha optado por modelos sencillos de aprendizaje profundo (DL – del inglés *Deep Learning*), pero con diferencias en el tipo de datos que estos están optimizados para procesar. Para el caso de las imágenes multispectrales (Torres-Tello & Ko, 2021a), adoptamos un modelo 3D CNN (*Convolutional Neural Network*), basado en el modelo VGG-16, el cual es un modelo clásico de visión artificial y que ha servido de base para varios desarrollos posteriores. Este modelo se escogió, debido a su facilidad para ser modificado y reimplementado; esto debido a que por el tipo de datos, es poco factible usar un modelo pre entrenado. Es importante mencionar que las redes neuronales convolucionales (CNN) generalmente realizan el procesamiento de imágenes en 2 dimensiones (alto y ancho), pero en este caso se utilizó una dimensión adicional (tiempo), razón por la cual es una red 3D CNN (Dumoulin & Visin 2018), como se observa en la figura 2.

Figura 2

Diagrama de bloques del modelo 3D CNN implementado para el procesamiento de imágenes multispectrales.




Nota: Las dimensiones de la red indican 5 canales espectrales, y la adición del tiempo de la toma de la imagen como una dimensión adicional.

Fuente: Torres-Tello & Ko (2022)

Por otro lado, para el caso de las imágenes hiperespectrales, buscamos opciones que den una mayor importancia al contenido espectral de los datos. Como se ve en la figura 3, este tipo de imágenes tiene una resolución espectral mucho mayor que otro tipo de imágenes, lo que quiere decir que el contenido de información suele ser mucho mayor en el componente espectral que en el espacial (alto y ancho).

Figura 3

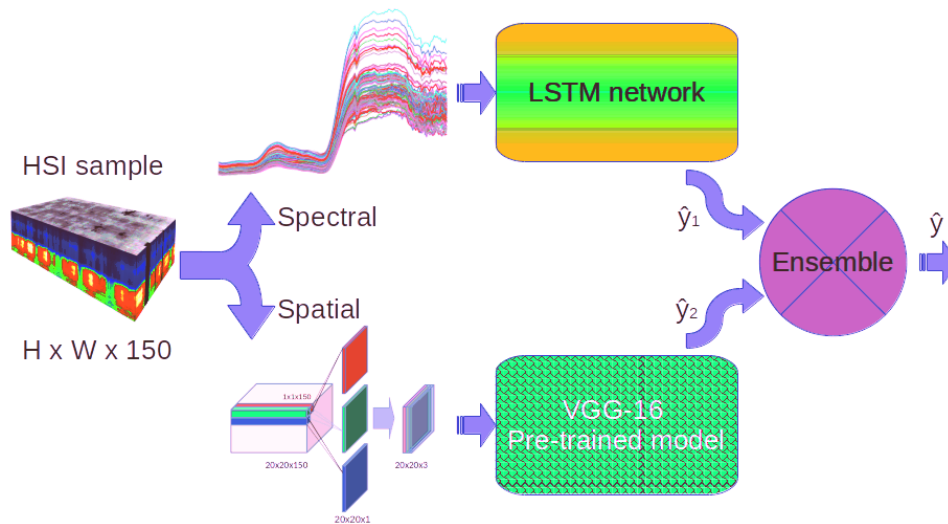
Las imágenes multi- e hiperespectrales (medio y abajo, respectivamente) contienen más información espectral que las imágenes RGB (rojo-verde-azul) -arriba-, pero las imágenes hiperespectrales tienen una mayor resolución (30 veces más en este caso).



La figura 4 muestra el doble camino que se implementó para el procesamiento de estas imágenes hiperespectrales. Por una parte, tenemos la información espectral que usa una red secuencial (generalmente usada en datos como voz, texto, tendencias, etc.) LSTM (*Long Short-Term Memory*), inicialmente propuesta por Hochreiter & Schmidhuber (1997), y que se encarga de relacionar la firma espectral de los cultivos, a sus niveles de humedad. Por otra parte, la información espacial es reducida a 3 canales (Torres-Tello. et al., 2020), para poder ser procesada por una red pre entrenada en el procesamiento de imágenes RGB. Este esquema nos permite usar toda la información contenida en las imágenes hiperespectrales, a fin de obtenerlos mejores resultados.

Figura 4

Esquema general del procesamiento de las imágenes hiperespectrales. Nótese la división en 2 flujos, para procesar la información espacial y espectral, con redes neuronales diferentes.



Fuente: Torres-Tello & Ko (2021b)

Resultados y Discusión

El principal resultado de este trabajo es la demostración del uso de modelos de IA/DL para el análisis de datos no convencionales. En el primer caso, usando redes convolucionales tridimensionales, hemos logrado implementar un modelo que es capaz de predecir el rendimiento de los cultivos de trigo bajo análisis, con un coeficiente de determinación del 0.676, como se observa en la figura 5.

Figura 5

Valores reales y previstos del rendimiento de las parcelas, para todo el conjunto de datos de trigo, utilizando imágenes multiespectrales.



Fuente: Torres-Tello & Ko (2022)

En el caso de la predicción del contenido de humedad en cultivos de canola y trigo, usando un esquema dual, con modelos secuenciales y espaciales, hemos logrado obtener un coeficiente de determinación del 0.916 para la canola y 0.818 para el trigo, en lo que se refiere a la predicción del contenido de humedad.

Estos resultados evidencian la versatilidad de los modelos de aprendizaje automático y la posibilidad de extenderlos resultados obtenidos en aplicaciones comunes, como el procesamiento de imágenes, texto, audio, y video, para aplicaciones más puntuales y que no cuentan con bases de datos enormes, o grandes capacidades de entrenamiento. Es también interesante el relativo nivel de mejora en los resultados, al usar imágenes hiperespectrales, que por definición, contienen más información en cada muestra (Manolakis et al., 2016). Es decir, este es un resultado esperado.

Conclusiones

- El principal enfoque y motivación de este trabajo han sido las oportunidades de inclusión de nuevas tecnologías (como la IA) en la agricultura, que todavía

presenta muchas oportunidades y necesidades de innovación. Por lo tanto, estudiamos una forma de utilizar diferentes fuentes de datos obtenidos principalmente de sitios agrícolas, para implementar modelos de IA personalizados capaces de predecir algunas variables de interés. Principalmente, este trabajo demuestra que un modelo DL es capaz de encontrar características útiles dentro de un conjunto de datos MSI para la predicción del rendimiento; además de encontrar un modelo DL preciso para la predicción del contenido de humedad de los cultivos de canola y trigo, basado en HSI.

Conflicto de intereses

Los autores declaran que no existe conflicto de intereses.

Referencias Bibliográficas

- Carlsson, L. S., Samuelsson, P. B., & Jönsson, P. G. (2020). Interpretable Machine Learning—Tools to interpret the predictions of a Machine Learning model predicting the electrical energy consumption of an electric arc furnace. *Steel Research International*, 91(11), 2000053. <https://doi.org/10.1002/srin.202000053>
- Chollet, F. (2017). *Deep Learning with Python*. <https://www.manning.com/books/deep-learning-with-python>
- Dumoulin, V., & Visin, F. (2018). A guide to convolution arithmetic for Deep Learning. *arXiv*. <https://doi.org/10.48550/arXiv.1603.07285>
- Han, S., Mao, H., & Dally, W. J. (2015, October 1). Deep compression: Compressing deep neural networks with pruning, trained quantization and huffman coding. *arXiv.Org*. <https://arxiv.org/abs/1510.00149v5>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 4768–4777.
- Manolakis, D. G., Lockwood, R. B., & Cooley, T. W. (2016). *Hyperspectral imaging remote sensing: Physics, sensors, and algorithms*. Cambridge University Press.
- Montesinos-López, O. A., Montesinos-López, A., Crossa, J., De los Campos, G., Alvarado, G., Suchismita, M., Rutkoski, J., González-Pérez, L., & Burgueño, J. (2017). Predicting grain yield using canopy hyperspectral reflectance in wheat

breeding data. *Plant Methods*, 13(1), 4. <https://doi.org/10.1186/s13007-016-0154-2>

Torres-Tello, J., Singh, K., Ko, S.-B., & Shirtliffe, S., (2020). Transfer learning from RGB to hyperspectral images by means of pointwise convolutions. 5th Annual P2IRC Symposium. <https://doi:10.13140/RG.2.2.31919.5648054>

Torres-Tello, J., & Ko, S.-B. (2021a). Identifying useful features in multispectral images with deep learning for optimizing wheat yield prediction. 2021 IEEE International Symposium on Circuits and Systems (ISCAS), 1–5. <https://doi.org/10.1109/ISCAS51556.2021.9401360>

Torres-Tello, J. W., & Ko, S. (2021b). A novel approach to identify the spectral bands that predict moisture content in canola and wheat. *Biosystems Engineering*, 210, 91–103. <https://doi.org/10.1016/j.biosystemseng.2021.08.004>

Torres-Tello, J., & Ko, S.-B. (2022). Optimizing a multispectral-images-based dl model, through feature selection, pruning and quantization. 2022 IEEE International Symposium on Circuits and Systems (ISCAS), 1352–1356. <https://doi.org/10.1109/ISCAS48785.2022.9937940>

Torres Tello, J. W., (2022). Optimization of AI models as the main component in prospective edge intelligence applications [Thesis, University of Saskatchewan]. <https://harvest.usask.ca/handle/10388/14092>

Virnodkar, S. S., Pachghare, V. K., Patil, V. C., & Jha, S. K. (2020). Remote Sensing and Machine Learning for crop water stress determination in various crops: A critical review. *Precision Agriculture*, 21(5), 1121–1155. <https://doi.org/10.1007/s11119-020-09711-9>

Xiong, Z., Yuan, Y., & Wang, Q. (2018). Ai-net: Attention inception neural networks for hyperspectral image classification. IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium, 2647–2650. <https://doi.org/10.1109/IGARSS.2018.8517365>

El artículo que se publica es de exclusiva responsabilidad de los autores y no necesariamente reflejan el pensamiento de la **Revista Conciencia Digital**.



El artículo queda en propiedad de la revista y, por tanto, su publicación parcial y/o total en otro medio tiene que ser autorizado por el director de la **Revista Conciencia Digital**.



Indexaciones

