

المؤتمر الدولي للذكاء الاصطناعي
في تحقيق التنمية المستدامة

الذكاء الاصطناعي الجيومكاني: نظرة عامة GoeAI: An Overview

د. حنا صابات

مدير الشؤون العلمية والتدريب
المركز الإقليمي لتدريس علوم وتكنولوجيا الفضاء لغرب آسيا/
المركز الجغرافي الملكي الأردني

Bristol Hotel, Amman
19 – 20/11/2025

تعريفات ومفاهيم أساسية

**Definitions
& Basic Concepts**

الذكاء الاصطناعي الجيومكاني (تعريف)

هو دمج الذكاء الاصطناعي (AI) مثل التعلّم الآلي (ML)، والتعلّم العميق (DL)، وتنقيب البيانات data mining – مع البيانات الجغرافية المكانية (الجيومكانية) وتقنياتها، مثل نظم المعلومات الجغرافية (GIS)، والاستشعار عن بُعد (RS)، والإحصاء المكاني ... وذلك من أجل تحليل النظم الجغرافية المكانية ونمذجتها وتفسيرها.

Definition of GeoAI

(Geospatial Artificial Intelligence)

It is the integration of artificial intelligence (AI) – such as machine learning (ML), deep learning (DL) and data mining – with geospatial data and technologies – such as geographic information systems (GIS), remote sensing (RS), and spatial statistics; in order to analyze, model, and interpret geospatial phenomena.

الذكاء الاصطناعي الجيومكاني (تعريفات أخرى)

فرع من الذكاء الاصطناعي يهدف إلى تنفيذ برامج حاسوبية ذكية تسعى إلى محاكاة الإدراك البشري، وذلك فيما يتعلق بالتحليل المكاني والديناميكيات الجغرافية.

Gao, Song, Geospatial artificial intelligence (GeoAI),
Vol. 10. Oxford University Press New York, 2021. DOI:
10.1093/OBO/9780199874002-0228.

الذكاء الاصطناعي الجيومكاني (تعريفات أخرى)

مجال جديد من الأبحاث متعددة التخصصات multidisciplinary يستخدم البيانات الضخمة big data الجيومكانية مع الاستفادة من الذكاء الاصطناعي وتطويره لإجراء التحليل القائم على الموقع.

Wenwen Li and Chia-Yu Hsu. “GeoAI for large-scale image analysis and machine vision: recent progress of artificial intelligence in geography”. In: ISPRS International Journal of Geo-Information 11.7 (2022), p. 385. DOI: 10.3390/ijgi11070385.

الذكاء الاصطناعي الجيومكاني (تعريفات أخرى)

يجمع الذكاء الاصطناعي الجيومكاني بين خوارزميات الذكاء الاصطناعي والأساليب الجغرافية المكانية (الجيومكانية) لاستخلاص أهم المعلومات، بهدف تنفيذ مهام متقدمة في نفس المجال.

Bala Bhavya Kausika et al. "GeoAI for detection of solar photovoltaic installations in the Netherlands". In: Energy and AI 6 (2021), p. 100111. DOI: 10.1016/j.egyai. 2021.100111.

يجمع الذكاء الاصطناعي الجيومكاني بين 3 مجالات رئيسية:

- العلوم الجيومكانية

هي المعنية بالبيانات المكانية مثل الخرائط، وصور الأقمار الصناعية، وبيانات نظام تحديد المواقع والتحليلات المعتمدة على الموقع.

- الذكاء الاصطناعي

من خلال تطبيق خوارزميات قادرة على التعلّم من البيانات، مثل الشبكات العصبية، والغابات العشوائية، والتعلّم المعزز.

- علوم البيانات / البيانات الضخمة

تشمل إدارة وتحليل مجموعات ضخمة من البيانات المكانية بكفاءة، مثل تلك الواردة من الأقمار الصناعية والمستشعرات والأجهزة المحمولة.

ما معنى "جيومكاني/ جغرافي مكاني" Geospatial؟

جميع أشكال نظم المعلومات الجغرافية (GIS) تعد نوعًا من التكنولوجيا الجغرافية المكانية، ولكن ليست كل تكنولوجيا الجغرافية المكانية هي نوع من نظم المعلومات الجغرافية. وبشكل أكثر تحديدًا، فإن مصطلح *الجغرافي المكاني* (الجيومكاني) هو مصطلح واسع يعرف البيانات الجماعية والتقنيات المرتبطة بها التي تتضمن مكونات جغرافية ومكانية، وتشمل صورًا جغرافية متنوعة وخرائط وإحداثيات وأدوات والتقنيات ذات صلة.

أنواع التكنولوجيا الجيومكانية/ الجغرافيا المكانية الرئيسية:

- . الاستشعار عن بُعد Remote Sensing
- . أنظمة تحديد المواقع العالمية (أنظمة أقمار الملاحه العالمية)
GPS/ GNSS
- . نظم المعلومات الجغرافية GIS

نظم المعلومات الجغرافية

(Geographic Information Systems - GIS)

نظم المعلومات الجغرافية هي أداة محددة أو جانب من جوانب التكنولوجيا الجيومكانية، يمكن فهمها على أنها نظام حاسوبي يختص بجمع وتخزين وفحص ودمج ومعالجة وعرض البيانات التي تأتي من مصادر متنوعة مثل أجهزة الاستشعار عن بُعد وطرائقه المختلفة، وتقارير ومخططات التعداد السكاني، والخرائط (الطوبوغرافية والموضوعية)، والمسوح الميدانية ...

الذكاء الاصطناعي (AI) Artificial Intelligence

(تعريف)

هو مجال يشير إلى محاكاة الذكاء البشري بواسطة الآلات، بهدف تقليد السلوك البشري في مواقف مختلفة.

Yongjun Xu et al. “Artificial intelligence: A powerful paradigm for scientific research”. In: *The Innovation* 2.4 (2021). DOI: 10.1016/j.xinn.2021.100179.

تعلم الآلة (Machine Learning (ML

(AI tool)

التعلم الآلي: مجموعة من التقنيات لتقريب دالة تربط بين فضاء المدخلات وفضاء المخرجات، مع استخراج معلومات مفيدة وغير زائدة عن الحاجة من عينات البيانات.

A set of techniques for approximating a function that maps an input space to an output space, while extracting meaningful, non-redundant information from data samples.

KC Santosh, Nibaran Das, and Swarnendu Ghosh. *Deep learning models for medical imaging*. Academic Press, 2021

التعلم العميق (DL) Deep Learning

فرع من التعلم الآلي يستخدم بنيات متعددة الطبقات لتعلم تمثيلات متعددة للبيانات. وتجدر الإشارة إلى أن التعلم العميق يستخدم تقنية الانتشار الخلفي back-propagation لضبط المعاملات الداخلية للنموذج من أجل إعادة حساب هذه التمثيلات في كل دورة تدريب epoch.

A branch of Machine Learning using multi-layer architectures to learn multiple representations of data. It is noted that deep learning uses the back-propagation technique to adjust the internal parameters of the model in order to recalculate these representations at each epoch.

Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. “Deep learning”. In: *nature* 521.7553 (2015), pp. 436–444. DOI: 10.1038/nature14539.



بدايات الـ GeoAI

(بعض البحوث المبكرة)

- Terence R **Smith**, **1984**, “Artificial intelligence and its applicability to geographical problem solving”. In: The Professional Geographer 36.2 (1984), pp. 147–158. DOI: 10. 1111/j.0033-0124.1984.00147.x
- John E **Estes**, Charlene **Sailer**, and Larry R **Tinney**, **1986**, “Applications of artificial intelligence techniques to remote sensing”. In: The Professional Geographer 38.2 (1986), pp. 133–141. DOI: 10 . 1111 / j . 0033 - 0124 . 1986 . 00133.x

- Helen **Couclelis**, **1986**, “Artificial intelligence in geography: Conjectures on the shape of things to come”. In: The professional geographer 38.1 (1986), pp. 1–11. DOI: 10 . 1111/j.0033-0124.1986.00001.x.
- Stan **Openshaw** and Christine **Openshaw**, **1997**, Artificial intelligence in geography. John Wiley and Sons, Inc., 1997. ISBN: 978-0-471-96991-4.

* محطة رئيسية ...

يعدّ مؤتمر SIGSPATIAL المنعقد عام 2017 لرابطة آلات الحوسبة Association for Computing Machinery (ACM) ، والمتخصص في النظم الجيومكانية، محطة رئيسية في تاريخ الذكاء الاصطناعي الجيومكاني GeoAI، حيث خُصّصت ورشة عمل محددة لهذا الموضوع، وعُرف الذكاء الاصطناعي الجيومكاني صراحةً على أنه اقتران (إقران) تقنيات الذكاء الاصطناعي بالمعلومات الجغرافية أو البيانات الجيومكانية.

25th ACM SIGSPATIAL: International Conference on Advances in Geographic Information Systems (ACM SIGSPATIAL 2017), 7 - 10 November 2017, Redondo Beach, California, USA

مجموعات بيانات صور الأقمار الصناعية

Satellites images datasets

Due to the lapse in federal government funding, NASA is not updating this website. We sincerely regret this inconvenience.

We are in the process of migrating all NASA Earth science data sites into Earthdata from now until end of 2026. Not all NASA Earth science data and resources will appear here until then. Thank you for your patience as we make this transition. [Read about the Web Unification Project](#)



EARTHDATA

Data ▾ Topics ▾ Learn ▾ Centers ▾ Engage ▾ About ▾ News & Events ▾

Your Gateway to NASA Earth Observation Data

The Earth Science Data Systems (ESDS) Program provides open access to NASA's archive of Earth science data, empowering researchers and decision makers to better understand and protect our home planet.





We are in the process of migrating all NASA Earth science data sites into Earthdata from now until end of 2026. Not all NASA Earth science data and resources will appear here until then. Thank you for your patience as we make this transition. [Read about the Web Unification Project](#)



EARTHDATA

[Data](#) ▾[Topics](#) ▾[Learn](#) ▾[Centers](#) ▾[Engage](#) ▾[About](#) ▾[News & Events](#) ▾

[Home](#) / [About The ESDS Program](#) / [ESDIS Project](#) / **EOSDIS**

EOSDIS

NASA's Earth Observation System Data and Information System (EOSDIS) comprises elements including Distributed Active Archive Centers, Science Investigator-led Processing Systems, and web infrastructure.

NASA's Earth Observing System Data and Information System (EOSDIS) is a key core capability in the Earth Science Data Systems (ESDS) Program. It provides end-to-end capabilities for managing NASA Earth science data from various sources — satellites, aircraft, field measurements, and various other programs. For the EOS satellite missions, EOSDIS provides capabilities for command and control, scheduling, data capture and initial (level 0) processing. These capabilities, constituting the EOSDIS Mission Operations, are managed by NASA's Earth Science Mission Operations (ESMO) Project. NASA network capabilities transport the data to the science operations facilities.



We are in the process of migrating all NASA Earth science data sites into Earthdata from now until end of 2026. Not all NASA Earth science data and resources will appear here until then. Thank you for your patience as we make this transition. [Read about the Web Unification Project](#)





EARTHDATA

Data ▾ Topics ▾ Learn ▾ Centers ▾ Engage ▾ About ▾ News & Events ▾



Overview Data and Tools News Learn Publications Contact People Preservation Documents

Home / Centers / LP DAAC



LP DAAC

Land Processes Distributed Active Archive Center

Because of the federal government shutdown, www.usgs.gov is not being updated and the agency will not be able to respond to inquiries until appropriations are enacted. For more information please visit: <https://www.doi.gov/shutdown>



SCIENCE PRODUCTS NEWS CONNECT ABOUT

Latest Earthquakes



[LANDSAT MISSIONS](#) | [DATA](#)

Landsat Data Access

By [Landsat Missions](#)

HOME

LANDSAT MISSIONS

SCIENCE

PRODUCT INFORMATION

DATA

Landsat Acquisitions

Landsat Data Access

Useful Landsat Tools


GLOSSARY AND ACRONYMS

MULTIMEDIA

ENVISATATIONS

In 2008, the Landsat products stored in the USGS EROS archive became available for download at no cost to users. The applications described below allow access to the Landsat products from the USGS archive. Each application provides unique capabilities that may be useful to user preferences, as either single file or large quantity (bulk) downloads.

USGS EarthExplorer




EarthExplorer's graphical interface lets you define areas of interest by using the map to create points or polygon selections, entering

Landsat in the Cloud



Besides downloads from traditional data portals, Landsat Collection 2 operational products can be accessed from the Amazon Web Services (AWS)

USGS ESPA



The EROS Science Processing Architecture (ESPA) On-Demand Interface enables users to request spectral indices like NDVI, SAVI, and

Due to the lapse in federal government funding, NASA is not updating this website. We sincerely regret this inconvenience.

SeaBASS

Home

About SeaBASS

Get Data

Contribute Data

Wiki

Lists

Login

Search wiki articles...

Welcome to the SeaWiFS Bio-optical Archive and Storage System (SeaBASS), the publicly shared archive of in situ oceanographic and atmospheric data maintained by the NASA Ocean Biology Processing Group (OBPG). For information on how to search for data, please refer to the "Get Data" menu options. For information about preparing files for submission to SeaBASS, refer to "Contribute Data."

Data Shortcuts

File Search

Validation Search

Time Series Tool

SST Search

NOMAD Dataset

Lists

Investigators

Experiments

Cruises

Fields

Submission Special Requirements

News

Server Update Security Alert for Data Submitters

2025-08-30

If uploading data for the first time since August 1, 2025:

- You may see a one-time security warning about the server's host key
- This is expected due to recent server updates
- You may safely select Update and proceed

If concerned:


- Follow standard security protocols
- Contact the SeaBASS team with questions

New metadata _id headers

2024-02-13

Recent Data Updates

Date	Investigator	Cruise	Parameters
2025-09-30	Antonio_Mannino	OXR20250118	date,time,lat,lon,RelAz,SZA,AOT,cloud,win...
2025-09-30	Antonio_Mannino	OXR20250118	date,time,lat,lon,RelAz,SZA,AOT,cloud,win...
2025-09-30	Michael_Sayers	GLOC_WQS_SPR2025	Wavelength,Es,Es_sd,Es_bincount,Lt,Lt_s...



Home

 [View image information & credits](#)

Access to data

Copernicus Data Access

Copernicus services catalogue

At the heart of Copernicus is a constellation of satellites – the Sentinels – that make a huge number of daily observations of the Earth ecosystem. The technological prowess of Copernicus, especially in terms of availability and accessibility, has made Copernicus the largest space data provider in the world.

The following diagram illustrates the conceptual elements of Copernicus as it relates to data access.

بعض الطرائق الرئيسية
التي يساهم بها الذكاء
الاصطناعي في هذا المجال

1. معالجة البيانات والمعالجة المسبقة

**(Data Processing and
Preprocessing)**



These images show the results of the TetraPLEX satellite image preprocessing precision correction performance test. The unusable satellite image with confirmed quality issues (left) and the image restored through precision correction processing with TetraPLEX in space (right). (Source: TelePIX)

출처 : Businesskorea (<https://www.businesskorea.co.kr>)

1.1 التصحيح التلقائي للصورة (المرئية):

(Automatic Image Correction)


يمكن أن تعاني صور الأقمار الصناعية من التشوهات بسبب الظروف الجوية أو عدم دقة المستشعر أو الحركة. يمكن لخوارزميات الذكاء الاصطناعي اكتشاف وتصحيح مشكلات مثل التشوهات الهندسية والغطاء السحابي وعدم محاذاة المستشعر تلقائيًا.



Contents lists available at [ScienceDirect](https://www.sciencedirect.com)

ISPRS Journal of Photogrammetry and Remote Sensing

journal homepage: www.elsevier.com/locate/isprsjprs



Quality control and class noise reduction of satellite image time series

Lorena A. Santos^{*}, Karine R. Ferreira, Gilberto Camara, Michelle C.A. Picoli, Rolf E. Simoes

Earth Observation General-Coordination, National Institute for Space Research, INPE, Brazil

ARTICLE INFO

Keywords:

Self-organizing map
Class noise reduction
Bayesian inference
Satellite image time series
Land use and cover classification

ABSTRACT

The extensive amount of Earth observation satellite images available brings opportunities and challenges for land mapping in global and regional scales. These large datasets have motivated the use of satellite image time series analysis coupled with machine learning techniques to produce land use and cover class maps. To be successful, these methods need good quality training samples, which are the most important factor for determining the accuracy of the results. For this reason, training samples need methods for quality control of class noise. In this paper, we propose a method to assess and improve the quality of satellite image time series training data. The method uses self-organizing maps (SOM) to produce clusters of time series and Bayesian inference to assess intra-cluster and inter-cluster similarity. Consistent samples of a class will be part of a neighborhood of clusters in the SOM map. Noisy samples will appear as outliers in the SOM. Using Bayesian inference in the SOM neighborhoods, we can infer which samples are noisy. To illustrate the methods, we present a case study in a large training set of land use and cover classes in the Cerrado biome, Brazil. The results prove that the method is efficient to reduce class noise and to assess the spatio-temporal variation of satellite image time series training samples.

2.1 تقليل الضوضاء

(Noise Reduction)

يمكن استخدام طرائق الذكاء

الاصطناعي مثل التعلم العميق

لتصفية الضجيج وتعزيز

وضوح الصورة، ما يسهل

اكتشاف السمات المهمة في

صور الأقمار الصناعية.

3.1 ضغط البيانات:

(Data Compression)

نظرًا لكم الهائل من بيانات الأقمار الصناعية، يمكن للذكاء الاصطناعي المساعدة في ضغط البيانات بكفاءة دون فقدان المعلومات المهمة، ما يقلل الحاجة إلى تخزين الهائل للبيانات ويجعل التحليل في الوقت الفعلي أكثر جدوى.

2. اكتشاف السمات والتعرف على الأشياء

**(Feature Detection
and Object Recognition)**


1.2 تصنيف استخدام الأراضي والغطاء الأرضي

(Land Use and Land Cover Classification)

يمكن استخدام نماذج الذكاء الاصطناعي، وبخاصة التعلم العميق والشبكات العصبية التلافيفية (convolutional neural networks: CNNs)، لتصنيف أنواع مختلفة من الغطاء الأرضي (على سبيل المثال، المسطحات المائية والغابات والمناطق الحضرية) من خلال صور الأقمار الصناعية. وهذا مفيد للتخطيط الحضري ومراقبة البيئة وإدارة الكوارث.

The Traditional work

Landast8-satellite-2016




Artificial Neural Network Classification (OpenCV)

- Builtup Area
- Agricultural Area
- Bare Land
- Vegetation
- Land Area
- Rocky Area & Mountains
- HighLand

0 400 800 1200 1600



Sentinel-2A-satellite-2016



Artificial Neural Network Classification (OpenCV)


- Bare Land
- Rocky Area & Mountains
- Builtup Area
- Vegetation
- Agricultural Area
- Land Area
- HighLand

0 400 800 1200 1600




The proposed work (ANN_RF)


(ANN_RF) Landast8 satellite 2016




ANN_RF Model



(ANN_RF) Sentinel 2A satellite 2016




ANN_RF Model




2.2 اكتشاف التغيرات

(Change Detection)


يمكن للذكاء الاصطناعي اكتشاف التغيرات وتتبعها تلقائيًا بمرور الزمن، مثل إزالة الغابات أو التوسع الحضري أو الكوارث الطبيعية كالفيضانات أو حرائق الغابات، وذلك من خلال مقارنة بيانات الأقمار الصناعية الحالية بالصورة التاريخية.



High Resolution Satellite Image



AI/ML enhanced Image



AI/ML enhanced Image






Image overlay
Automated Change Detection



3.2 التعرف على الأجسام والمعالم

(Object Detection)

يساعد الذكاء الاصطناعي في تحديد أجسام أو معالم معينة، مثل المباني والطرق والمركبات وحتى السمات الأخرى كالحقول الزراعية أو المسطحات المائية، وذلك من خلال صور الأقمار الصناعية، ما يسهل التطبيقات في الزراعة ومراقبة البنية التحتية والدفاع.

3. دمج البيانات وتكاملها

(Data Fusion and Integration)

1.3 دمج البيانات متعددة الأطياف ومتعددة الأزمنة

(Multispectral and Multitemporal Data Fusion)

غالبًا ما تجمع الأقمار الصناعية البيانات من أجهزة استشعار مختلفة عبر نطاقات طيفية متعددة (على سبيل المثال، النطاق المرئي، ونطاق الأشعة تحت الحمراء، ونطاق الرادار (أمواج راديوية)). ويمكن للذكاء الاصطناعي دمج مجموعات البيانات هذه لإنشاء منظور أكثر شمولاً لسطح الأرض. على سبيل المثال، يمكن أن يساعد الجمع بين البيانات البصرية والرادارية في اختراق السحب أو اكتشاف التغيرات السطحية.

2.3 التحليل عابر المستشعرات




(Cross-Sensor Analysis)

يمكن للذكاء الاصطناعي دمج البيانات من منصات الأقمار الصناعية المختلفة، مثل الأقمار الصناعية البصرية، وأقمار رادار الفتحة التركيبية

(SAR: Synthetic Aperture Radar)

والأقمار الصناعية للطقس، لأجل تحسين مراقبة الأرض وتحليل بياناتها في مجالات متنوعة مثل تغير المناخ والزراعة والمخاطر الطبيعية

Sentinel-1 SAR
images



Generated
images



Sentinel-2 RS
images





Contents lists available at ScienceDirect

International Journal of Applied Earth Observations and Geoinformation

journal homepage: www.elsevier.com/locate/jag



Fusion of optical and SAR images based on deep learning to reconstruct vegetation NDVI time series in cloud-prone regions

Jingbo Li^{b,c}, Changchun Li^c, Weimeng Xu^{b,d}, Haikuan Feng^b, Fa Zhao^b, Huiling Long^b, Yang Meng^b, Weinan Chen^c, Hao Yang^{b,*}, Guijun Yang^{a,d,*}

^a Key Laboratory of Quantitative Remote Sensing in Agriculture of Ministry of Agriculture and Rural Affairs, Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

^b National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China

^c School of Surveying and Mapping Land Information Engineering, Henan Polytechnic University, Jiaozuo 454000, China

^d School of Geological Engineering and Surveying and Mapping, Chang'an University, Xi'an 710054, China

ARTICLE INFO

Keywords:

Vegetation Monitoring
Time series
Deep learning
Transformer
SAR data
Optical data
NDVI

ABSTRACT

The normalized difference vegetation index (NDVI) is crucial to many sustainable agricultural practices such as vegetation monitoring and health evaluation. However, optical remote sensing data often suffer from a large amount of missing information due to sensor failures and harsh atmospheric conditions. The synthetic aperture radar (SAR) offers a new approach to filling in missing optical data based on its excessive revisit density and its potential to image without interference from clouds and rain. Due to the difference in imaging mechanisms between SAR and optical sensors, it is very difficult to fuse the data. This paper developed an advanced deep learning Spatio-temporal fusion method, i.e., Transformer Temporal-spatial Model (TTSM), to synergize the SAR and optical time-series to reconstruct vegetation NDVI time series in cloudy regions. The proposed multi-head attention and end-to-end architecture achieved satisfactory accuracy (R^2 greater than 0.88), outperforming the existing deep learning solutions. Extensive experiments were carried out to evaluate the TTSM method on large-scale areas (the spatial scale of megapixels) in northeast China with the main vegetation types of crops and forests. The R^2 , SSIM, RMSE, NRMSE, and MAE of our prediction results were 0.88, 0.80, 0.06, 0.16, and 0.05, respectively. The influence of training sample size was investigated through a transfer learning study, and the result indicated that the model had good generalizability. Overall, our proposed method can fill in the gap of optical data at an extensive regional scope over the vegetated area using SAR.

1. Introduction

Due to the limitations in physical conditions, technical requirements, and financial support, there are no satellite image sensors with exquisite spatial resolution and great temporal frequency (Wang and Wang 2020). Meanwhile, the lack of high-quality optical satellite data impedes the extensive, accurate, and spatially specified surveillance of vegetation over giant areas (Zhao et al. 2020). Fortunately, with the advent of denser, better-performing satellites, the resolution and repeated visit period of optical images have been improved considerably in the previous decades (Drusch et al. 2012; Li et al. 2021c). Meanwhile, NDVI (Myneni and Williams 1994), one universal indicator of vegetation condition, has been comprehensively applied to vegetation phenology

extraction (Pastor-Guzman et al. 2018), vegetation growth monitoring (Chu et al. 2018), etc. However, due to sensor failures and harsh atmospheric conditions, optical remote sensing data usually have a large amount of missing information, thus leading to low availability and further hindering subsequent applications (Li et al. 2021c; Shen et al. 2015).

Although solving the optical data deficit problem has become a research hotspot in the latest decades, many studies have only explained the problem (A et al. 2010; Wang and Atkinson 2018; Zhao et al. 2018). The common strategy is to resample statistics at a meticulous resolution to healthy statistics at an uncaredful resolution, but the authenticity of the techniques depends on the percentage of cloud-clear images. Also, the precondition is tough to obtain in practice, especially for the areas

* Corresponding authors at: Key Laboratory of Quantitative Remote Sensing in Agriculture of Ministry of Agriculture and Rural Affairs, Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China (G. Yang).

E-mail addresses: yangh@nrcita.org.cn (H. Yang), yanggj@nrcita.org.cn (G. Yang).

<https://doi.org/10.1016/j.jag.2022.102818>

Received 20 February 2022; Received in revised form 1 May 2022; Accepted 9 May 2022

Available online 21 June 2022

1569-8432/© 2022 Published by Elsevier B.V. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

4. التحليلات التنبؤية والنمذجة

**(Predictive Analytics
and Modeling)**


1.4 التنبؤ بالمناخ والحالة الجوية

(Climate and Weather Forecasting)


يمكن للذكاء الاصطناعي المساعدة في تحليل مجموعات البيانات الكبيرة من الأقمار الصناعية لتحسين التنبؤات الجوية والنمذجة المناخية والتنبؤ طويل الأمد. فمن خلال تحليل الأنماط في بيانات الأقمار الصناعية، يمكن للذكاء الاصطناعي المساعدة في التنبؤ بالأحداث الجوية المتطرفة أو الاتجاهات المناخية.

Climate (long term)

Weather (short term)



Sebastian Scher




2.4 التنبؤ بالكوارث ومراقبتها:

(Disaster Prediction and Monitoring)

يستخدم الذكاء الاصطناعي للتنبؤ بالكوارث الطبيعية وتتبعها، مثل الأعاصير أو الفيضانات أو حرائق الغابات، وذلك من خلال تحليل صور الأقمار الصناعية وتحديد علامات الإنذار المبكر. كما يمكن أن يساعد الذكاء الاصطناعي في تقييم الأضرار بعد وقوع الحدث.



AI was used to identify damage in Adiyaman, Turkey, after the 2023 earthquake. ILYAS AKENGİN—AFP /Getty Images
<https://time.com/7171445/ai-natural-disaster-cities/>



Review

Deep artificial intelligence applications for natural disaster management systems: A methodological review

Akhyar Akhyar^a, Mohd Asyraf Zulkifley^{a,*}, Jaesung Lee^b, Taekyung Song^b, Jaeho Han^b,
Chanhee Cho^b, Seunghyun Hyun^b, Youngdoo Son^c, Byung-Woo Hong^b

^a Department of Electrical, Electronic and Systems Engineering, Universiti Kebangsaan Malaysia, 43600 Bangi, Selangor, Malaysia

^b Department of Artificial Intelligence, Chung-Ang University, Heukseok-Dong, Dongjak-Gu, Seoul 06974, Republic of Korea

^c Department of Industrial and Systems Engineering, Dongguk University-Seoul, Seoul, 04620, Republic of Korea

ARTICLE INFO

Keywords:

Artificial intelligence
Deep learning
Neural network
Convolutional neural network
Semantic segmentation
Forest fire
Flood
Earthquake

ABSTRACT

Deep learning techniques through semantic segmentation networks have been widely used for natural disaster analysis and response. The underlying base of these implementations relies on convolutional neural networks (CNNs) that can accurately and precisely identify and locate the respective areas of interest within satellite imagery or other forms of remote sensing data, thereby assisting in disaster evaluation, rescue planning, and restoration endeavours. Most CNN-based deep-learning models encounter challenges related to the loss of spatial information and insufficient feature representation. This issue can be attributed to their suboptimal design of the layers that capture multiscale-context information and their failure to include optimal semantic information during the pooling procedures. In the early layers of CNNs, the network encodes elementary semantic representations, such as edges and corners, whereas, as the network progresses toward the later layers, it encodes more intricate semantic characteristics, such as complicated geometric shapes. In theory, it is advantageous for a segmentation network to extract features from several levels of semantic representation. This is because segmentation networks generally yield improved results when both simple and intricate feature maps are employed together. This study comprehensively reviews current developments in deep learning methodologies employed to segment remote sensing images associated with natural disasters. Several popular deep learning models, such as SegNet U-Net, FCNs, FCDenseNet, PSPNet, HRNet, and DeepLab, have exhibited notable achievements in various applications, including forest fire delineation, flood mapping, and earthquake damage assessment. These models demonstrate a high level of efficacy in distinguishing between different land cover types, detecting infrastructure that has been compromised or damaged, and identifying regions that are fire-susceptible to further dangers.

1. Introduction

A natural disaster is any calamitous occurrence generated by the effects of natural phenomena rather than human-driven activities that produce significant loss of human life and destruction of the natural environment, private properties, and public infrastructures (Prasad et al., 2017). A natural disaster may be caused by changes in weather and climate events, earthquakes, landslides, and other anomalies on the Earth's surface or within the planet itself. Truthfully, no spot-on Earth is safe from a natural disaster; however, certain types of disasters are often limited to or occur more frequently in specific geographic regions.

Natural disasters, such as forest fires, earthquakes, and floods, have devastating and extensive adverse effects on human populations and the natural environment (Wallemacq et al., 2018).

The natural disaster of forest fires, if it is not controlled, can produce blazes over 1.8 m in height that can cause devastating damage to the ecosystems (Kane, 2023). Forest fires are generally triggered by a combination of factors, including wind speed, terrain conditions, and moisture level in the surrounding plants. They have the potential to rapidly intensify, emitting combustible gases and undergoing pyrolysis, burning the plants, and emitting unhealthy smoke, which can have adverse effects on air quality and ecosystems (Dhall et al., 2020).

Abbreviations: CNNs, Convolutional Neural Networks; FCNs, Fully Convolutional Networks; HRNet, High Resolution Network; DL, Deep Learning; NIR, Near Infrared Region; SWIR, Short-wave infrared; OLI, Operational Land Imager; TIR, Thermal Infrared Sensor.

* Corresponding author.

E-mail address: asyraf.zulkifley@ukm.edu.my (M. Asyraf Zulkifley).

<https://doi.org/10.1016/j.ecolind.2024.112067>

Received 27 February 2024; Received in revised form 9 April 2024; Accepted 18 April 2024

Available online 6 May 2024

1470-160X/© 2024 The Author(s). Published by Elsevier Ltd. This is an open access article under the CC BY-NC license (<http://creativecommons.org/licenses/by-nc/4.0/>).



Contents lists available at ScienceDirect

Computers and Electrical Engineering

journal homepage: www.elsevier.com/locate/compeleceng



A systematic review of trustworthy artificial intelligence applications in natural disasters

A.S. Albahri^{a,b}, Yahya Layth Khaleel^c, Mustafa Abdulfattah Habeeb^c,
Reem D. Ismael^c, Qabas A. Hameed^c, Muhammet Deveci^{d,e,f}, Raad Z. Homod^g,
O.S. Albahri^{h,i}, A.H. Alamoodi^{j,k}, Laith Alzubaidi^{l,m,n,*}

^a Iraqi Commission for Computers and Informatics (ICCI), Baghdad, Iraq

^b Technical College, Imam Ja'afar Al-Sadiq University, Baghdad, Iraq

^c Department of Computer Science, College of Computer Science and Mathematics, Tikrit University, Iraq

^d Department of Industrial Engineering, Turkish Naval Academy, National Defence University, 34942 Tuzla, Istanbul, Turkey

^e The Bartlett School of Sustainable Construction, University College London, London, WC1E 6BT, United Kingdom

^f Department of Electrical and Computer Engineering, Lebanese American University, Byblos, Lebanon

^g Department of Oil and Gas Engineering, Basra University of Oil and Gas, Basra 1004, Iraq

^h Australian Technical and Management College, Melbourne, Australia

ⁱ Computer Techniques Engineering Department, Mazaya University College, Nasiriyah, Iraq

^j Applied Science Research Center, Applied Science Private University, Amman, Jordan

^k MEU Research Unit, Middle East University, Amman, Jordan

^l School of Mechanical, Medical, and Process Engineering, Queensland University of Technology, Brisbane, QLD 4000, Australia

^m ARC Industrial Transformation Training Centre—Joint Biomechanics, Queensland University of Technology, Brisbane, QLD 4000, Australia

ⁿ Centre for Data Science, Queensland University of Technology, Brisbane, QLD 4000, Australia

ARTICLE INFO

Keywords:
Artificial intelligence
Natural disasters
Explainability
Data fusion
Taxonomy
Trustworthy

ABSTRACT

Artificial intelligence (AI) holds significant promise for advancing natural disaster management through the use of predictive models that analyze extensive datasets, identify patterns, and forecast potential disasters. These models facilitate proactive measures such as early warning systems (EWSs), evacuation planning, and resource allocation, addressing the substantial challenges associated with natural disasters. This study offers a comprehensive exploration of trustworthy AI applications in natural disasters, encompassing disaster management, risk assessment, and disaster prediction. This research is underpinned by an extensive review of reputable sources, including Science Direct (SD), Scopus, IEEE Xplore (IEEE), and Web of Science (WoS). Three queries were formulated to retrieve 981 papers from the earliest documented scientific production until February 2024. After meticulous screening, deduplication, and application of the inclusion and exclusion criteria, 108 studies were included in the quantitative synthesis. This study provides a specific taxonomy of AI applications in natural disasters and explores the motivations, challenges, recommendations, and limitations of recent advancements. It also offers an overview of recent techniques and developments in disaster management using explainable artificial intelligence (XAI), data fusion, data mining, machine learning (ML), deep learning (DL), fuzzy logic, and multicriteria decision-making (MCDM). This systematic contribution addresses seven open

* Corresponding author.

E-mail addresses: ahmed.bahri1978@gmail.com (A.S. Albahri), yahya@tu.edu.iq (Y.L. Khaleel), mustafa@tu.edu.iq (M.A. Habeeb), reem.dh.ismail@tu.edu.iq (R.D. Ismael), qabas.a.hameed@tu.edu.iq (Q.A. Hameed), muhammetdeveci@gmail.com (M. Deveci), raadahmood@yahoo.com (R.Z. Homod), osamahsh89@gmail.com (O.S. Albahri), alamoodi.abdullah91@gmail.com (A.H. Alamoodi), l.alzubaidi@qut.edu.au (L. Alzubaidi).

<https://doi.org/10.1016/j.compeleceng.2024.109409>

Received 22 December 2023; Received in revised form 30 May 2024; Accepted 16 June 2024

Available online 29 June 2024

0045-7906/© 2024 The Author(s). Published by Elsevier Ltd. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

5. المراقبة الآلية وإعداد البلاغات

**(Automated Monitoring
and Reporting)**

1.5 المراقبة في الوقت الفعلي

(Real-time Monitoring)

يمكن للذكاء الاصطناعي تمكين الجهات المعنية من المراقبة في الوقت الفعلي لتدفقات بيانات الأقمار الصناعية، والتعرف التلقائي على الحوادث أو المخالفات البيئية المثيرة للاهتمام، مثل إزالة الغابات، أو التسربات النفطية، أو التعدين غير القانوني. حيث يمكن للأنظمة الآلية تشغيل إنذارات أو عمل بلاغات لأجل المزيد من التدخل البشري.

2.5 مراقبة النشاط الزراعي

(Monitoring Agricultural Activity)

يمكن لخوارزميات الذكاء الاصطناعي تحليل صور الأقمار الصناعية لمراقبة صحة المحاصيل، ورطوبة التربة، والممارسات الزراعية. ويمكن أن يساعد هذا في تحسين الإنتاجية الزراعية، أو مراقبة أمراض المحاصيل، أو تحسين الاستخدام الأمثل للمياه في الري.

**Hyperspectral
satellite
imagery in
agriculture**



6. تحليل البيانات الجيومكانية

(Geospatial Data Analytics)

1.6 التحليل المكاني

(Spatial Analysis)

يمكن للذكاء الاصطناعي تعزيز تحليلات البيانات الجيومكانية من خلال تحديد الأنماط المكانية والتجمعات والعلاقات عبر مناطق جغرافية واسعة. على سبيل المثال، يمكن للذكاء الاصطناعي المساعدة في تحديد التوسع الحضري، أو تحليل أنماط المرور، أو تتبع هجرة الحياة البرية ...

2.6 التنبؤات الجيومكانية

(Geospatial Prediction)

باستخدام بيانات الأقمار الصناعية التاريخية، يمكن
لنماذج الذكاء الاصطناعي التنبؤ بالتغيرات المستقبلية
في الغطاء الأرضي أو تطوير البنية التحتية، ودعم
التخطيط الحضري وجهود الحفاظ على البيئة.

7. الذكاء الاصطناعي

في الاستشعار عن بعد

(Artificial Intelligence
in Remote Sensing)

1.7 تفسير بيانات الرادار ذي الفتحة التركيبية

(SAR Data Interpretation)

تلتقط أقمار الرادار ذي الفتحة التركيبية بيانات خارج نطاق الضوء المرئي، ما يجعلها مفيدة في دراسة الأرض ليلاً أو في الطقس الغائم. ويساعد الذكاء الاصطناعي في تفسير هذه البيانات المعقدة، واكتشاف التغيرات السطحية مثل التشوهات الأرضية (بعد الزلازل، مثلاً)، أو تغييرات البنية التحتية، أو الأنشطة غير القانونية.

2.7 التصوير فرط الطيفي

(Hyperspectral Imaging)

يمكن للذكاء الاصطناعي معالجة وتحليل البيانات فرط الطيفية، والتي تتضمن جمع الصور عبر مئات النطاقات الطيفية. ويساعد هذا في تطبيقات مثل استكشاف المعادن، أو اكتشاف أمراض النباتات، أو حتى تقييم جودة المياه ...

Review

A Review of Practical AI for Remote Sensing in Earth Sciences

Bhargavi Janga ¹, Gokul Prathin Asamani ¹, Ziheng Sun ^{1,*}  and Nicoleta Cristea ²

¹ Center for Spatial Information Science and Systems, College of Science, George Mason University, 4400 University Drive, MSN 6E1, Fairfax, VA 22030, USA; bjanga@gmu.edu (B.J.); gasamani@gmu.edu (G.P.A.)

² Department of Civil and Environmental Engineering, University of Washington, Seattle, WA 98195, USA; cristn@uw.edu

* Correspondence: zsun@gmu.edu; Tel.: +1-703-993-6124

Abstract: Integrating Artificial Intelligence (AI) techniques with remote sensing holds great potential for revolutionizing data analysis and applications in many domains of Earth sciences. This review paper synthesizes the existing literature on AI applications in remote sensing, consolidating and analyzing AI methodologies, outcomes, and limitations. The primary objectives are to identify research gaps, assess the effectiveness of AI approaches in practice, and highlight emerging trends and challenges. We explore diverse applications of AI in remote sensing, including image classification, land cover mapping, object detection, change detection, hyperspectral and radar data analysis, and data fusion. We present an overview of the remote sensing technologies, methods employed, and relevant use cases. We further explore challenges associated with practical AI in remote sensing, such as data quality and availability, model uncertainty and interpretability, and integration with domain expertise as well as potential solutions, advancements, and future directions. We provide a comprehensive overview for researchers, practitioners, and decision makers, informing future research and applications at the exciting intersection of AI and remote sensing.

Keywords: Artificial Intelligence; remote sensing technology; deep learning; LiDAR; image classification; object detection; change detection; data analysis



Citation: Janga, B.; Asamani, G.P.; Sun, Z.; Cristea, N. A Review of Practical AI for Remote Sensing in Earth Sciences. *Remote Sens.* **2023**, *15*, 4112. <https://doi.org/10.3390/rs15164112>

Academic Editor: Lefei Zhang

Received: 7 July 2023

Revised: 14 August 2023

Accepted: 15 August 2023

Published: 21 August 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Remote sensing is a technology that enables data collection without direct contact with the subject, utilizing sensors to measure or detect various types of energy, such as electromagnetic radiation and acoustic signals, emitted, reflected, or scattered by the object under investigation [1]. Multiple sensors and platforms have been developed for remote sensing. As sensors continue to advance, the amount of remote sensing data generated has reached staggering proportions. For example, according to NASA's Earth Science Data Systems (ESDS), the Earthdata Cloud held more than 59 petabytes (PB) of data as of September 2021. ESDS estimates that this amount is expected to increase to more than 148 PB in 2023, 205 PB in 2024, and 250 PB in 2025 [2]. To effectively manage this massive volume of remote sensing data, preprocessing techniques, including noise reduction and sensor calibration using a variety of algorithms and data compression algorithms, are utilized to minimize the data size, while computer systems with ample memory and parallel processing capabilities facilitate the handling of these large datasets [3].

With the increasing data quality and volume from remote sensing platforms, there is a need for computational platforms and effective tools to handle and extract valuable information from remote sensing datasets. AI tools can assist in managing large volumes of observations, modeling, analysis, and environmental forecasting, and have proven effective for key tasks such as noise reduction [4], data fusion [5], object detection [6,7], and many other important applications. As AI technologies develop, acquiring and storing remote sensing data becomes increasingly important. The process of obtaining this large volume of data entails using various sensors on different platforms, such as Unmanned Aerial

بعض التحديات المستقبلية

جودة البيانات وتوافرها:

قد تكون بيانات الأقمار الصناعية عالية الجودة باهظة الثمن أو يصعب الوصول إليها. غالبًا ما تتطلب نماذج الذكاء الاصطناعي مجموعات بيانات كبيرة لتكون فعالة، ما قد يحد من إمكانية تطبيقها في بعض المناطق.

- NASA Earth Observing System Data and Information System (EOSDIS)
- USGS Earth Explorer
- Copernicus Open Access Hub (European Space Agency - ESA)
- Google Earth Engine
- National Oceanic and Atmospheric Administration (NOAA)
- Japan Aerospace Exploration Agency (JAXA)
- China Earth Observation Satellite Data Service Platform and CRESDA
- Indian Space Research Organization (ISRO)

شفافية النموذج وقابليته للفهم:

يُنظر إلى العديد من نماذج الذكاء الاصطناعي، وبخاصة التعلم العميق، على أنها "صناديق سوداء"، ما يجعل من الصعب الفهم الكامل لكيفية اتخاذ القرارات. قد يشكل هذا إشكالية في التطبيقات الحرجة مثل إدارة الكوارث أو أمور الأمن القومي.

عدم تجانس البيانات

تُشكّل عدم تجانس البيانات مشكلات كبيرة، خصوصًا عند التعامل مع مشكلات معقدة تتطلب عدة أنواع من البيانات التي غالبًا ما تكون غير منظمة. وتزداد هذه المشكلة وضوحًا في حالة البيانات القادمة من مصادر متعددة. بالإضافة إلى ذلك، ونظرًا لحجم وتنوع البيانات الجغرافية المكانية، لا يزال التعامل مع البيانات الضخمة واستثمارها يمثل تحديًا كبيرًا، على الرغم من التقدم المحرز في الأبحاث في هذا المجال.

شكرا لحسن استماعكم

تعمل تقنيات الذكاء الاصطناعي على تعزيز إدارة بيانات الأقمار الصناعية وتحليلها بشكل كبير من خلال أتمتة المهام وتحسين دقة التفسيرات واستكشاف منظورات عميقة، وذلك من خلال مجموعات البيانات الضخمة.

كما أن هذه التقنيات تمكن من اتخاذ قرارات أكثر كفاءة في مجالات تتباين من الزراعة إلى الاستجابة للكوارث إلى التخطيط الحضري.

ومع تطور تكنولوجيا الذكاء الاصطناعي، سيستمر دورها في بيانات الأقمار الصناعية في التوسع، ما قد يؤدي إلى أدوات أكثر قوة ودقة لفهم وإدارة موارد الأرض وبيئاتها المختلفة.