



# International Journal of Multidisciplinary Research and Growth Evaluation.

**Ferdowsi University Mashhad/ The second International Conference  
Artificial Intelligence: Between Scientific Innovation and Human Responsibility**

## Using Deep Learning to Monitor and Predict Desertification and Land Degradation Risks: A Research Review

**MM Shaimaa Khairy Zayer<sup>1\*</sup>, M.D. Hanan Ahmed Abdel Karim<sup>2</sup>**

Department of Geography, College of Education for Women, University of Basra, Iraq

\* Corresponding Author: **MM Shaimaa Khairy Zayer**

### Article Info

**ISSN (Online):** 2582-7138

**Impact Factor (RSIF):** 7.98

**Volume:** 06

**Issue:** 06

**November - December 2025**

**Received:** 23-09-2025

**Accepted:** 25-10-2025

**Published:** 21-11-2025

**Page No:** 85-93

### Abstract

Desertification and land degradation represent a global environmental, social, and economic challenge, affecting food security, biodiversity, and the livelihoods of millions. Effective management of these risks requires advanced tools for monitoring and prediction. In recent decades, deep learning—a branch of artificial intelligence—has emerged as a transformative tool in Earth sciences, offering unprecedented capabilities for analyzing complex spatiotemporal data.

This review paper critically examines the recent academic literature on the applications of deep learning models in monitoring and predicting the risks of desertification and land degradation. Published studies were analyzed to evaluate the methodologies employed, the data sources used (particularly multispectral satellite imagery), and the most prominent deep learning architectures applied, such as Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), and Generative Adversarial Networks (GANs).

The results show that deep learning achieves high accuracy in land cover classification, monitoring vegetation health through indicators such as NDVI, estimating soil moisture, and predicting drought as a primary driver of desertification. The paper also discusses emerging trends, including hybrid models and explainable artificial intelligence (XAI), which aims to open the "black box" of complex models, thereby enhancing trust in their outputs and supporting decision-making processes. Nevertheless, significant challenges remain, particularly related to data quality, model transferability across different regions, and the need to integrate socio-economic factors. The study concludes that deep learning provides a powerful and evolving framework, but realizing its full potential requires multidisciplinary collaboration and systematic addressing of existing research gaps to ensure the development of sustainable and globally scalable solutions.

**Keywords:** Desertification, Land Degradation, Deep Learning, Satellite Imagery, Explainable AI (XAI)

### Introduction

يُعد تدهور الأراضي والتتصحر من أخطر التحديات البيئية التي تواجه البشرية في القرن الحادي والعشرين. يُعرف التتصحر بأنه نوع من تدهور الأراضي في المناطق الفاحلة وشبه الفاحلة والجافة شبه الرطبة، وينتتج بشكل أساسى عن الأنشطة البشرية والتغيرات المناخية. إنه ليس توسيعًا للصحراء القائمة، بل هو عملية تدريجية تتحول الأرضي الخصبة إلى أراضٍ فاحلة وغير منتجة (Feng et al., 2022). يؤثر هذا التدهور الصامت وغير المرئي على ما يقرب من 10% من جميع الأراضي الجافة، مما يهدد بشكل مباشر سبل عيش حوالي 250 مليون شخص في جميع أنحاء العالم (Baartman, 2007; Ahmed et al., 2007). تجاوز عوّق تدهور الأرضي مجرد فقدان الإنتاجية الزراعية؛ فهـي تشمل فقدان التنوع البيولوجي، وانخفاض قدرة التربة على تخزين الكربون، (ar., 2024).

.) إن الترابط وزراعة مخاطر الكوارث الطبيعية مثل العواصف الترابية والفيضانات، وتفاقم الفقر والهجرة القسرية (Earth.org, 2022; Elhini et al., 2022) ، المعقد بين تغير المناخ والأنشطة البشرية غير المستدامة، مثل الرعي الجائر وإزالة الغابات والعمارات الزراعية الخاطئة، يسرع من وتيرة هذه العمليات، مما يجعل رصدتها والتتبّع بها أمراً بالغ الأهمية لتحقيق أهداف التنمية المستدامة، وخاصة الهدف 15 الذي يدعو إلى "حماية النظم الإيكولوجية البرية وترميمها وتعزيز استخدامها على نحو مستدام" (United Nations, n.d.).

الآلة مثلاً أشجار القراءةMachine Learning، تم تحليل هذه البيانات الضخمة باستخدام الأساليب الإحصائية التقليدية ونماذج تعلم الآلة (al., 2022). Higginbottom & Symeonakis, 2014; Zolfaghari et al., 2022. ( )  
Walker, 1981) ( )  
Rivera-Marín et al., 2022; ( )  
MODIS و Sentinel و Landsat ( )  
Yang et al., 2021; Rukhovich et al., 2023) ( ).  
البيئة، مثل تلك التي توفرها برامج ( )  
، حيث تتحول نموذجي في مرآبة البيئة، أكانت صور الأقمار الصناعية، مثل تلك التي توفرها برامج ( )  
، مما يوفر سجلاً تاريخياً لا يقدر بثمن للتغيرات البيئية ( )  
، وعلى نطاقات مكانية واسعة، مما يوفر سطح الأرض بشكل مستمر ومتغير ( )  
، ومؤشر الجفاف، NDVI). وقد تم تطوير العديد من المؤشرات المستندة إلى الاستشعار عن بعد، مثل مؤشر الغطاء النباتي بالفرق المعياري ( )  
، على الرغم من دقة هذه الطرق على تأثيرياً، اعتمد رصد التصرّف وتدهور الأراضي على أساليب المسح الميداني التقليدية وجمع العينات وتحليلها في المختبر. على

(Machine Learning) في البداية، تم تحليل هذه البيانات الضخمة باستخدام الأساليب الإحصائية التقليدية ونماذج تعلم الآلة (Decision Trees). وقد أثبتت هذه الأدوات فعاليتها في مهام مثل تصنیف الغطاء الأرضي وتحديد Support Vector Machines (SVM) (Yousefi et al., 2021). يمكنها تحقيق دقة جيدة (Random Forest). على سبيل المثال، أظهرت دراسات أن نماذج الغابات العشوائية (Yan et al., 2022) في تقدیر تدهور الأراضي الرعوية والتباين (Non-forest) يمكنها تكافع من أجل التقاط العلاقات غير الخطية (Non-linear) ما يقلل من خطأ التنبؤ. ومع ذلك، فإن هذه النماذج "الضحلة" غالباً ما تتطلب في كثير من الأحيان هندسة ميزات يدوية، وهي عملية تستغرق وقتاً طويلاً وتعتمد على خبرة المجال لتحديد المتغيرات الأكثر صلة بالموضوع.

، وهو مجموعة فرعية متقدمة من تعلم الآلة تميز ببنيتها الشبكية متعددة الطبقات (الشبكات العصبية Deep Learning) هنا يأتي دور التعلم العميق (العميق)، وقد أحدث التعلم العميق ثورة في العديد من المجالات، من التعرف على الصور والكلام إلى اكتشاف الأدوية، وذلك بفضل قدرته على تعلم تنبؤات هرمية (Alzubaidi et al., 2021; Mienye & Swart, 2024). في سياق علوم الأرض والبيئة، توفر نماذج التعلم العميق إمكانات هائلة Alzubaidi et al., 2021; Mienye & Swart, 2024 معاقة للبيانات تلقائياً (Alzubaidi et al., 2021; Mienye & Swart, 2024)، المصممة أساساً لمعالجة الصور وتحليل الكمييات الهائلة من بيانات الاستشعار عن بعد. تتمتع معماريات مثل الشبكات العصبية الإلأفاقية (CNNs)، بقدرة فطرية على استخلاص الميزات المكانية من صور الأقمار الصناعية، مما يجعلها مثالية لمهام مثل تصنيف الغطاء الأرضي بدقة عالية. واكتشاف التغيرات (RNNs) وخاصة متغيراتها مثل شبكات الذاكرة طويلة الأمد التي قد تشير إلى بداية التدهور. من ناحية أخرى، تتفوق الشبكات العصبية المتكررة (LSTM)، في نتاجها البيانات التسلسليه، مما يجعلها مناسبة تماماً لتحليل السلسل الزمنية لمושرات الغطاء النباتي أو بيانات المناخ للتنبؤ بالجفاف أو المدى (Hasan et al., 2025; Lim & Zohren, 2021).

أفاد شهد العقد الماضي زيادة كبيرة في عدد الدراسات التي تستكشف تطبيقات التعلم العميق لرصد وتوقع التصحر وتدور الأراضي. فقد تم استخدام نماذج CNN للتباين بالجفاف LSTM و (CNN) Zhang et al., 2022، بينما تم تطوير نماذج هجينية تجمع بين تحديد مناطق التصحر الصخري بدقة تصل إلى 94.7% (GANs) كنداة واحدة للكشف عن التغيرات الدقيقة في الغطاء الزراعي المستقبلي، علاوة على ذلك، ظهرت تقنيات أكثر تقدماً مثل الشبكات التوليدية التنافسية (Zerrouki et al., 2022). على الرغم من هذه التطورات السريعة، فإن المجال لا يزال يواجه تحديات كبيرة. إن طبيعة الأرضية التي قد تتجه لها الطرق الأخرى (Başağaoğlu et al., 2022) الصندوق الأسود" العديد من الصعب تفسير قراراتها، مما يحد من ثقة صانعي السياسات في مخرجاتها (Lundvall et al., 2022)، ولمواجهة هذا التحدي، بدأ الباحثون في استكشاف مجال الذكاء الاصطناعي القابل للتفسير (Dikshit et al., 2021)، وقابلية نقل النماذج بين المناطق (ground-truth data)، بالإضافة إلى ذلك، فإن قضايا مثل ندرة البيانات المرجعية الدقيقة (Olwade et al., 2024) الجغرافية ذات الخصائص البيئية المختلفة، والتكلفة الحاسوبية العالية لتدريب النماذج المعقدة، لا تزال تشكل عقبات كبيرة أمام التطبيق التشغيلي واسع النطاق (هذه التقنيات)

تهدف هذه المراجعة إلى تقديم تحليل شامل ومنهجي للأسس العلمية الحديثة المتعلقة باستخدام التعلم العميق في رصد وتوقع مخاطر التصحر وتدهور الأراضي. تسعى الورقة إلى تحقيق الأهداف التالية: (1) تحديد وتصنيف معماريات التعلم العميق الرئيسية المستخدمة في هذا المجال ومناقشة نقاط قوتها وضعفها؛ (2) مراجعة التطبيقات الرئيسية لهذه النماذج، بما في ذلك تصنيف الغطاء النباتي، ورصد صحة الغطاء النباتي، وتقيير خصائص التربة، والتتبُّق بالجفاف؛ (3) (4) تحديد التحديات الرئيسية والعقبات التي تواجه XAI/استكشاف الاتجاهات الناشئة مثل النماذج الهجينة والذكاء الاصطناعي القابل للتفسير)؛ (5) التطبيق العملي لهذه التقنيات. من خلال تجميع وتحليل هذه المعلومات، تقدم هذه المراجعة رؤية متمعة للحالة الراهنة للمجال وتتوفر خارطة طريق للباحثين وصانعي السياسات والمهنيين الذين يسعون إلى تحسين فوائد التعلم العميق لمكافحة واحدة من أكثر القضايا البيئية الحاكمة في عصرنا.

٢. منهجية المراجعة

لضمان الشمولية والدقة في هذه المراجعة، تم اتباع منهجية منظمة لاستعراض الأبيات. استندت عملية البحث بشكل أساسي إلى المواد المرجعية المقدمة، والتي تضمنت مجموعة واسعة من المقالات الصحفية المحكمة، وأوراق المؤتمرات، والأطروحات، والتقارير الفنية المنشورة بين عامي 2014 و2025. تم التركيز على دراسات التي تربط بشكل صريح بين "التعلم العميق" (Machine Learning) أو "تعلم الآلة" (Deep Learning) (ومفاهيم "التصرّف")

**3. الإطار المفاهيمي:** التقاء الجغرافي بالذكاء الاصطناعي لفهم كيفية مساهمة التعلم العميق في مكافحة التصحر، من الضروري أولاً بناء إطار مفاهيمي يربط بين الظاهرة الجغرافية المعقدة والأداة التكنولوجية المتقدمة. يتكون هذا الإطار من ثلاثة أعمدة رئيسية: طبيعة التصحر وتدور الأرضي، ودور الاستشعار عن بعد في التقاط بياناتهم، وقدرة التعلم العميق على تحليل هذه البيانات.

### **3.1 التصحر وتدور الأراضي: الأساليب والعمليات والمؤشرات**

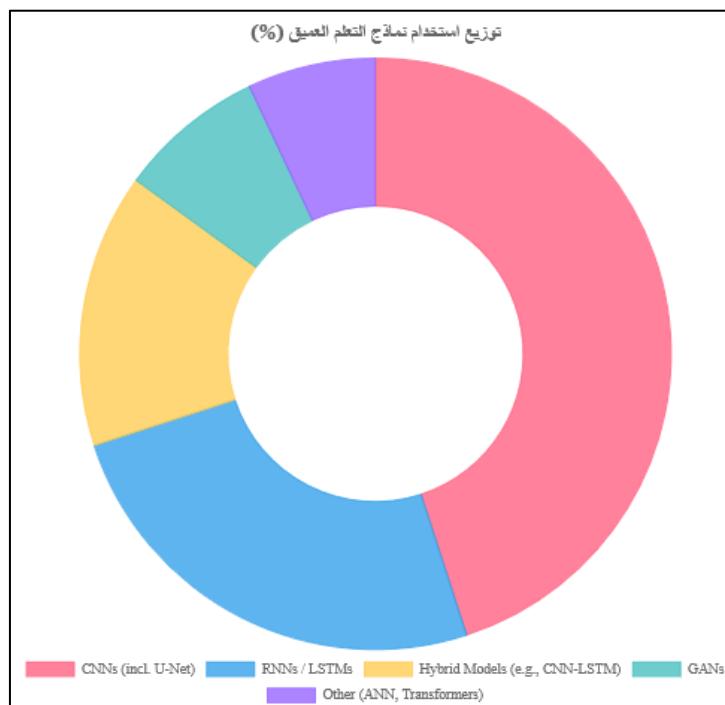
(ج). التصحر هو عملية معقدة تتجم عن تفاعل متشابك بين العوامل المناخية والأنشطة البشرية (Meng et al., 2024). تشمل العوامل المناخية الرئيسية قدرات Feng et al., 2022 على إحداث التغيرات الطبيعية، وارتفاع درجات الحرارة، وتغير أنماط هطول الأمطار، وكلها تؤدي إلى إجهاد النظم البيئية في الأراضي الجافة (AbdelRahman et al., 2023). أما أحد الآثار السلبية للتصحر فهو تدمير الأراضي الزراعية غير المستدامة التي تستنزف مغذيات التربة، والرعي الحاد الذي يزيد من الأنشطة البشرية، فتلاعب دورا حاسماً في تسيريع هذه العملية. وتشمل الممارسات الزراعية غير المستدامة التي تستنزف مغذيات التربة، والرعي الحاد الذي يزيد من الغطاء النباتي الواقعي، وإزالة الغابات للحصول على الوقود أو لتوسيع الأراضي الزراعية، والتلوّح الحضري غير المخطط له (Boroughhani et al., 2023). يؤدي هذا التفاعل إلى حلقة مفرغة: إزالة الغطاء النباتي تعرّض التربة لعوامل التعرية بفعل الرياح والمياه، مما يؤدي إلى فقدان التربة السطحية 2023 الخصبة. التربة المتدورة تفقد قدرتها على الاحتفاظ بالماء، مما يزيد من جفافها ويجعل من الصعب على النباتات النمو مرة أخرى، مما يؤدي إلى مزيد من التدهور (Boroughhani et al., 2023).

يمكن رصد هذه العمليات من خلال مجموعة من المؤشرات البيوفيزيانية. يعد الغطاء النباتي أحد أهم المؤشرات؛ فانخفاض كثافته وتغير تكوينه يعدان علامات مبكرة (Zolfaghari et al., 2022). خصائص التربة، مثل محتوى الرطوبة، ونسبة المواد العضوية، ومستوى الملوحة، هي مؤشرات حيوية أخرى على التدهور (Singh et al., 2023). كما أن الظروف المناخية، وخاصة مؤشرات الجفاف، مثل مؤشر هطول الأمطار القياسي (SPI)، تعتبر عوامل دافعة (Osmanr et al., 2025). إن فهم هذه المؤشرات والعلاقات المتباينة بينها هو الخطوة الأولى نحو تطوير أنظمة رصد فعالة.

**3.2. الاستشعار عن بعد: عين الأرض من الفضاء**  
 (التي تتابع لناسا، تتفق مستمرة من البيانات متعددة الأطيف التي تلتقط معلومات MODIS التابعة لوكالات الفضاء الأوروبية و Sentinel عمل منذ السبعينيات) و (Radeloff et al., 2024). يمكن استخدام النطاقات الطيفية المختلفة لحساب مؤشرات حيوية. على سبيل المثال، يعد مؤشر الغطاء النباتي NDVI (نسبة تتجاوز الرؤية البشرية) ، الذي يحسب من النطاقين الأحمر والأشعة تحت الحمراء القريبة، مقياساً يستخدم على نطاق واسع لصحة وكثافة الغطاء (Hasan et al., 2025). وبالمثل، يمكن استخدام النطاقات الحرارية لتقدير درجة حرارة سطح الأرض ورطوبة التربة، بينما يمكن للأقمار الصناعية SAR (Sentinel-1) (Nijaguna et al., 2023). هذه الفكرة على جمع بيانات متسقة وموضوعية عبر المكان والزمان تجعل الاستشعار عن بعد أداة لا غنى عنها لدراسة العمليات الديناميكية مثل تدهور الأراضي (Rivera-Marín et al., 2022).

**3.3. أساسيات التعلم العميق للتحليل الجغرافي المكانى**  
 التعلم العميق هو الحل الأمثل للتتعامل مع الحجم الهائل والتعقيد المتباين في بيانات الاستشعار عن بعد. على عكس نماذج تعلم الآلة التقليدية، يمكن لنماذج التعلم المكانى: (العميق تعلم الميزات ذات الصلة تلقائياً من البيانات الخام، فيما يلي بعض المعماريات الرئيسية ذات الصلة بالتحليل الجغرافي) :  
 • هذه الشبكات هي حجر الزاوية في تطبيقات رؤية الكمبيوتر. تستخدم طبقات التفافية لتطبيق مرشحات (فلتر) على CNNs الشبكات العصبية الافتافية (Alzubaidi et al., 2021).  
 • تم تصميم هذه الشبكات لمعالجة البيانات التسلسليّة. لديها "ذاكرة" LSTM (والذاكرة طويلة قصيرة المدى RNNs) الشبكات العصبية المتكررة (Lim & Zohren, 2021). تسمح لها بالاحتفاظ بمعلومات من الخطوات الزمنية السابقة، مما يجعلها فعالة للغاية في تحليل السلسل الزمنية لبيانات الاستشعار عن بعد، مثل التغيرات.  
 • تتكون هذه الشبكات من نموذجين، "المولد" و "المميز" ، ينتجان ضد بعضهما البعض. يمكن استخدامها لإنشاء GANs الشبكات التوليدية التنافسية (Foroumandi et al., 2024; Zerrouki et al., 2022).  
 • على الرغم من أنها طورت في الأصل لمعالجة اللغة الطبيعية، إلا أن المحولات أظهرت إمكانات كبيرة في مهام رؤية الكمبيوتر والسلسل الزمنية. تستخدم آلية "الانتباه" لتقدير أهمية أجزاء مختلفة من بيانات الإدخال، مما يسمح لها بالتقاط تغيرات طويلة المدى بشكل أكثر فعالية (Mienye & Swart, 2024).

إن دمج هذه المعماريات القوية مع البيانات الغنية من الاستشعار عن بعد يخلق إطاراً تحليلياً قادرًا على فك شفرة العمليات المعقدة للتصرّر وتدهور الأراضي، مما يمهد الطريق لأنظمة رصد وتنبؤ أكثر دقة وفعالية.



الشكل 1: رسم بياني يوضح التوزيع النسبي لاستخدام معماريات التعلم العميق المختلفة في دراسات تدهور الأراضي والتصرّر بناءً على مراجعة الأدبيات. يُظهر الرسم هيمنة CNNs/LSTMs ( الشبكات العصبية المتكررة ) و الشبكات العصبية الافتافية ( RNNs / LSTMs ) .

**4. تطبيقات التعلم العميق في رصد تدهور الأراضي والتصرّر**  
 لقد أدى تطبيق نماذج التعلم العميق على بيانات الاستشعار عن بعد إلى تحقيق قفزات نوعية في القدرة على رصد الجوانب المختلفة لتدهور الأراضي والتصرّر. يمكن تصنيف هذه التطبيقات إلى عدة مجالات رئيسية، يركز كل منها على مؤشر بيوفيزيان مختلف. وكشف التغيرات LULC 4. تصنّيف استخدامات الأرضي والغطاء الأرضي (

أحد التطبيقات الأساسية للاستشعار عن بعد، حيث يوفر خريطة أساسية لفهم كيفية استخدام الأراضي وتغيرها بمرور الوقت. بعد التغيير من ULC إلى LULC، يمكن تصنيف الغابات أو المراعي إلى المناطق الزراعية أو المناطق الحضرية مؤشرًا على الضغط البشري الذي يمكن أن يؤدي إلى التدهور. لقد تفوقت نماذج التعلم مصممة للتجزئة الدلالية، بشكل كبير على الطرق التقليدية (CNNs وهي نوع من U-Net) وعمارية CNNs العميق، وخاصة الشبكات العصبية الالتفافية (في الهند، دقة اجمالية تجاوزت 95%)، مما سمح بتحليل III-LIIS التصنيف صور CNN على سبيل المثال، أظهرت دراسة استخدمت في دقة تصنيف لقيق للتغيرات على مدى عقد من الزمن.

تحليل الأحياء (CNNs)، كمن قوة نماذج التعلم العميق في قدرتها على تعلم الميزات السياقية والمكانية المعقّدة. بدلاً من تصنيف كل ببساطة بشكل مستقل، يمكن لمجاورة للمكسل لفهم السياق، مما يقلل من خطأ التصنيف الشائعة في الطرق التقليدية (مثل تصنيف ببساطة واحد في حقل على أنه منطقة حضرية). علاوة على ذلك، فإن تقنيات كشف التغيرات القائمة على التعلم العميق يمكنها مقارنة الصور متعددة الأزمنة مباشرة لتسلیط الضوء على المناطق التي شهدت تغيرات كبيرة، مما يساعد في تحديد النقاط الساخنة للتدهور بشكل فعال. وقد تم تطوير إطار عمل يستخدم التعلم العميق لتحديد وتصنيف ست مجموعات أساسية للخطاء الأرضي بما في ذلك الأسطح الأرضية غير النباتية والأشجار، مما يوفر أساساً متيناً لرصد ديناميكيات المناظر الطبيعية.

**4.2. رصد صحة الغطاء النباتي وдинاميكياته**

يعتبر الغطاء النباتي خط الدافع الأول ضد تدهور الأراضي. إن مراقبة صحته وكثافته وتغيراته الموسمية أمر بالغ الأهمية. تستخدم نماذج التعلم العميق، وخاصة RNNs وLSTMs، لتحليل السلسل الزمنية لمؤشرات الغطاء النباتي مثل ذلك التي تعتمد على للغطاء النباتي في منطقة معينة، وبالتالي يمكنها اكتشاف الانحرافات عن هذه الأنماط التي قد تشير إلى إجهاد ناتج عن الجفاف أو الرعي الجائر أو المرض المستقبلي، مع دمج بيانات الطقس (NDVI). على سبيل المثال، استخدمت أحدى الدراسات نماذج هجينية للتعلم العميق للتنبؤ بقيم (Hasan et al., 2025). هذا النهج التنبؤي لا يقتصر على الرصد الحالي فحسب، بل يوفر أيضاً نظام إنذار مبكر (Hasan et al., 2025) والميزات الطبوغرافية لتحسين دقة التنبؤات (التدهور المحتمل).

()، والتي لها ميزة العمل في جميع SAR لتقدير مؤشرات الغطاء النباتي مباشرة إلى تحليل السلسل الزمنية، يمكن استخدام CNNs بالإضافة إلى بيانات الرادار (بالإضافة إلى تحليل البيانات الزمنية، يمكن استخدام باستخدام التعلم العميق، مما يتبع مراقبة الغطاء النباتي بشكل SAR من بيانات NDVI Sentinel-1). أظهرت دراسة حديثة إمكانية تقدير مستمر حتى في المناطق التي يكثر فيها الغطاء السحابي. هذا يمثل تقدماً كبيراً، حيث أن الاعتماد على البيانات البصرية وحدها كان يمثل تحدياً في العديد من المناطق الاستوائية وشبه الاستوائية.

**4.3. تقدير خصائص التربة الرئيسية**

(Soil Moisture) والمحتوى العضوي للتربة (Soil Organic Carbon) من بين أهم هذه الخصائص. لقد أظهر التعلم العميق إمكانات هائلة في تقدير هذه المتغيرات من بيانات الاستشعار عن بعد.

**4.3.1. تقدير رطوبة التربة**

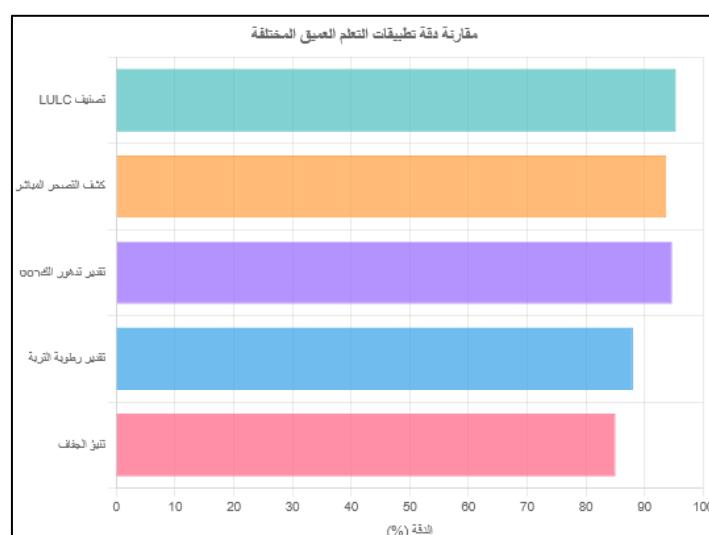
تعتبر رطوبة التربة متغيراً رئيسياً يربط بين المناخ والغطاء النباتي والهيدرولوجيا. إنها مؤشر حاسم للجفاف الزراعي. ومع ذلك، فإن قياسها مباشرة على نطاقات (أو نماذج هجينة، لتقدير رطوبة التربة السطحية من ANNs) أو واسعة أمر صعب. لقد تم تطوير نماذج تعلم عميق، غالباً ما تكون شبكات عصبية اصطناعية (SAR)، خلال دمج بيانات من مصادر متعددة، مثل بيانات الأقمار الصناعية البصرية (مثل مؤشرات الغطاء النباتي)، والحرارية (درجة حرارة سطح)، والرادار (). أظهرت مراجعة منهجة أن الطريق القائم على التعلم تمثل 54% من الدراسات في هذا المجال (Singh et al., 2023). بالإضافة إلى بيانات التربة والطقس ()، مما يسلط الضوء على هيمنتها. يمكن لهذه النماذج التقطال العلاقات غير الخطية المعقدة بين هذه المتغيرات المختلفة ورطوبة التربة، مما يوفر تقديرات مكانية (Lee et al., 2019).

**4.3.2 SOC**

(). يُعد المحتوى العضوي للتربة مؤشراً حيوياً لخصوبتها التربية وقدرتها على الاحتفاظ بالماء ومقاومة التعرية. لقد تم استخدام نماذج التعلم العميق، مثل الشبكات TFF على نماذج تعلم الآلة التقليدية مثل DNN على نطاقات وطنية. أظهرت إحدى الدراسات أن نموذج (SOC)، للتنبؤ بتوزيع العصبية العصبية (DNNs)، من خلال دمج البيانات الطيفية مع (Sentinel-3) (Odebiri et al., 2022) باستخدام صور (SOC) في رسم خرائط العشوائية (Random Forest)، مما يساعد في تحديد المناطق المتدهورة (SOC) المتغيرات البيئية الأخرى (مثل التضاريس والمناخ)، يمكن لهذه النماذج إنشاء خرائط انتشار خرائط عالية الدقة لتوزيع وتوجيه جهود الإدارة المستدامة للأراضي.

**4.4. الكشف المباشر عن التصحر**

(GANs) أو GANs، بالإضافة إلى رصد المؤشرات الفردية، تم تطوير نماذج تعلم عميق للكشف المباشر عن التصحر كظاهرة متكاملة. تستخدم هذه النماذج عادةً لتحليل صور الأقمار الصناعية وتصنيف المناطق إلى مستويات مختلفة من التصحر (على سبيل المثال، خفيف، متوسط، شديد). على سبيل المثال، استخدمت (Yang et al., 2023)، وهو نموذج تعلم عميق، لتحديد وتصنيف أراضي التصحر بدقة بلغت 93.71% دراسة نموذج ENVINet5 (Zerrouki et al., 2022) للكشف عن وحدات المكسل المتأثرة بتغير الغطاء الأرضي المرتبط بالتصحر في صور (GAN)، مما يتيح التصريح قائم على هذه الأساليب المباشرة مفيدة بشكل خاص لأنها تدمج مؤشرات متعددة (مثل تغير الغطاء النباتي، وسطوع التربة، والأنماط المكانية) بشكل ضمني داخل التموذج، مما يوفر تقييمًا شاملًا لحالة التصحر.



الشكل 2: مقارنة بين متوسط الدقة المبلغ عنها لتطبيقات التعلم العميق المختلفة في رصد تدهور الأراضي. تستند البيانات إلى قيم الدقة المذكورة في الأدب.

#### 5. تطبيقات التعلم العميق في توقع مخاطر التصحر وتدهور الأراضي

إلى جانب الرصد الحالي، تتمكن القواعد الحقيقة للتعلم العميق في قدرته على التنبؤ. إن التنبؤ بالمخاطر المستقبلية للتصحر وتدهور الأراضي يسمح باتخاذ تدابير هاساستباقية وتحوطط تكيفي، بدلاً من مجرد الاستجابة للكوارث بعد وقوعها. يركز هذا القسم على مجالين رئيسيين للتنبؤ: التنبؤ بالجفاف والتنبؤ المباشر بمخاطر التدهور.

#### 5.1. التنبؤ بالجفاف: الإنذار المبكر لأحد المحرّكات الرئيسية للتصحر

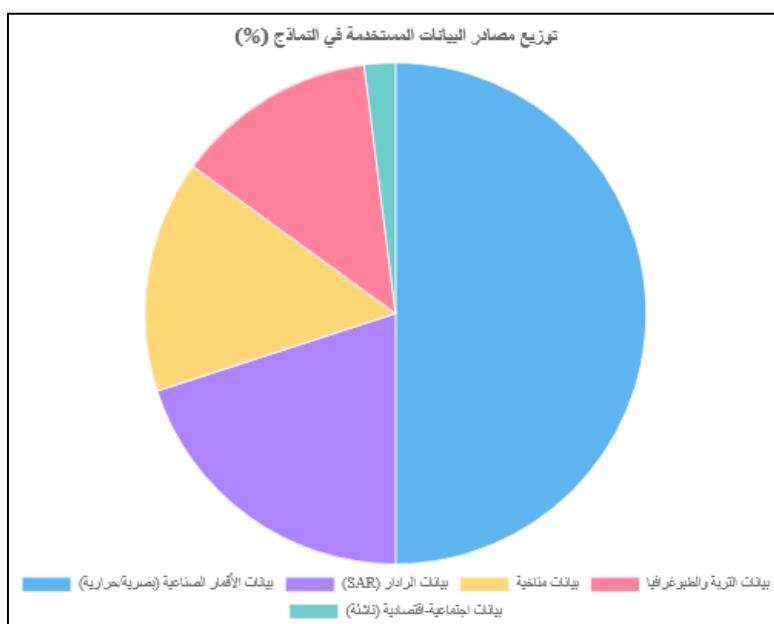
الجفاف هو محرك أساسي للتصحر في الأراضي الجافة. إن القدرة على التنبؤ بحدوثه ودته أمر بالغ الأهمية. لقد أثبتت نماذج التعلم العميق، وخاصة أنها أدوات قوية للتنبؤ بالجفاف. يمكن لهذه النماذج تحليل السلسلة الزمنية الطويلة للمتغيرات المناخية (مثل هطول الأمطار ودرجة RNNs وLSTMs et Osmani et al., 2024) ورطوبة التربة) للتنبؤ بمؤشرات الجفاف المستقبلية (NDVI). وقد استعرضت العديد من الدراسات ب بشكل منهجي استخدام نماذج التعلم العميق للتنبؤ بالجفاف، وخالت إلى أنها غالباً ما تتفق على النماذج Gyaneshwar et al., 2023; Márquez-Grajales et al., 2024).

(العدة أشهر في SPEI) ومؤشر هطول الأمطار والتباخر القياسي (SPI على سبيل المثال، تم استخدام نماذج LSTM على سبيل المثال، تم استخدام نماذج Data Fusion (Márquez-Grajales et al., 2024) يعزز علامة على ذلك، فإن دمج مصادر بيانات متعددة (Data Fusion) يعزز من دقة التنبؤ. أظهرت إحدى الدراسات أن تهجاً يعتمد على الذكاء الاصطناعي لدمج البيانات أدى إلى تحسين دقة الكشف عن الجفاف بنسبة 27٪، وهو (Flash Drought)، مما يتم تطوير نماذج للتنبؤ بتنوع معينة من الجفاف، مثل "الجفاف الخاطف" (Duan et al., 2025). مقارنة باطرق التقليدية (التنبؤ اليومي بالجفاف الخاطف، مما يدل على قدرة GAN على تطوير بسرعة ويمكن أن يكون له آثار مدمرة على الزراعة. استخدمت إحدى الدراسات شبكات Foroumandi et al., 2024).

#### 5.2. النماذج التنبؤية لتدهور الأراضي والتصحر

يتجاوز هذا التطبيق التنبؤ بالعوامل الدافعة (مثل الجفاف) إلى التنبؤ المباشر بخطر التدهور نفسه. تتضمن هذه النماذج عادةً دمج مجموعة واسعة من المتغيرات، بما في ذلك العوامل المناخية، والطبوغرافية (مثل الانحدار والارتفاع)، وخصائص التربة، واستخدام الأرض، وحتى العوامل الاجتماعية والاقتصادية (مثل الكثافة السكانية والمسافة إلى الطرق) للتنبؤ بالمناطق الأكثر عرضة للتدهور في المستقبل. أظهرت دراسة استخدمت الشبكات العصبية الاصطناعية (Habibi et al., 2021) أن تصبح 100٪ من منطقة الدراسة في إيران متدهورة بشدة بحلول عام 2025، مما يسلط الضوء على القدرة التنبؤية القوية لهذه النماذج (Li et al., 2025). وفي دراسة أخرى، تم استخدام إطار عمل متكامل "للتقدير والإسناد والتنبؤ" لتقييم تطور قابلية التأثير بالتصحر في هضبة منغوليا من عام 2001 إلى 2020 والتنبؤ بالأنماط المستقبلية في ظل سيناريوهات مختلفة (Tutubayeva et al., 2025).

تعبر هذه النماذج التنبؤية أدوات لا تقدر بثمن لتخطيط استخدام الأراضي وتوجيه الاستثمارات في تدابير الحفظ والاستعادة. من خلال تحديد "ال نقاط الساخنة" المستقبلية للتدهور، يمكن لواضعي السياسات تركيز الموارد المحدودة على المناطق التي هي في أمس الحاجة إليها، مما يزيد من فعالية التدخلات. على سبيل المثال، يمكن استخدام خرائط مخاطر التدهور لتحديد المناطق التي يجب فيها تشجيع الممارسات الزراعية المستدامه أو تنفيذ مشاريع إعادة التشجير.



الشكل 3: توزيع مصادر البيانات المستخدمة في نماذج التعلم العميق لرصد وتوقع التصحر. يظهر الرسم البياني الاعتماد الكبير على بيانات الأقمار الصناعية، مع أهمية متزايدة لدمج البيانات المناخية والتربة.

#### 6. التقنيات المتقدمة والاتجاهات الناشئة

مع نضوج مجال تطبيق التعلم العميق في علوم البيئة، بدأت تظهر تقنيات أكثر تطوراً واتجاهات جديدة تعالج بعض القيود الكامنة في النماذج الأولية. هذه الاتجاهات لا تعمل فقط على تحسين الدقة، بل تهدف أيضاً إلى جعل النماذج أكثر قوّة وتفصيلاً وفائدة من الناحية العملية.

#### 6.1. النماذج الهجينة (Hybrid Models)

تدرك النماذج الهجينية أنه لا يوجد نموذج واحد مثالي لجميع المهام. بدلاً من ذلك، تجمع هذه النماذج بين نقاط القوة لمعماريّات مختلفة لإنشاء حل أكثر قوّة. أحد أوّل الاستخلاصات المميزات المكانية المعقدة من صور الأقمار الصناعية في CNN. في هذا النهج، يتم استخدام LSTM وCNN (الأساليب الشائعة هو الجمع بين LSTM)، وقد ثبت أن هذا النهج فعال Lilonga et al., 2025 لنموذج التنبؤات الزمنية (LSTM)، كل خطوة زمنية، ثم يتم تغذية تسلسل هذه الميزات المستخلصة إلى بشكل خاص في التنبؤ بالجفاف الزراعي والتنبؤ بمسارات العواصف الترابية.

هذا نهج هجين آخر يجمع بين نماذج التعلم العميق والنماذج الإحصائية التقليدية أو النماذج القائمة على القواعد. على سبيل المثال، يمكن استخدام نموذج مع البقاء غير الخطية، مما يحسن الأداء العام. يمكن أيضاً LSTM لمعالجة الاتجاهات الخطية في سلسلة زمنية، بينما يتعامل نموذج ARIMA/تحصاني مثل

دمج نماذج التعلم العميق مع نماذج قائمة على القواعد مستمدۃ من معرفة الخبراء، مما يخلق إطاراً يجمع بين التعلم القائم على البيانات والخبرة البشرية (Mohamed et al., 2025). وقد أظهرت الدراسات باستمرار أن النموذج الهجين غالباً ما تتفوق على النماذج المستقلة المكونة لها.

#### 6.6 الذكاء الاصطناعي القابل للتفسير (XAI)

أحد أكبر الانتقادات الموجهة لنماذج التعلم العميق هو طبيعتها كـ "صناديق أسود". قد يقدم النموذج تنبؤاً دقيقاً للغاية، ولكن من الصعب فهم "الماذ" توصل إلى هذا التنبؤ. هذا النقص في الشفافية يمثل مشكلة كبيرة في التطبيقات البنية، حيث يحتاج صانعو السياسات إلى فهم العوامل الدافعة وراء التنبؤات لاتخاذ قرارات (XAI) إلى معالجة هذه المشكلة من خلال تطوير تقنيات "النظر داخل" الصندوق الأسود. يهدف الذكاء الاصطناعي القابل للتفسير (XAI) من بين أكثر SHAP (SHapley Additive exPlanations) و LIME (Local Interpretable Model-agnostic Explanations) بعد تقنيات مثل

شيغوا. يمكن لهذه التقنيات تحديد أهمية كل متغير إدخال في التنبؤ النهائي للنموذج. على سبيل المثال، استخدمت دراسة حول التنبؤ المكتاني بالجفاف XAI طرق Dikshit et al., 2021 لتحديد أن متغيرات مثل الارتفاع والمسافة إلى الطرق كانت أهم العوامل المؤثرة في قابلية منطقة ما للجفاف (XAI) تقنية.

لا يزدعي Başağaoğlu et al., 2022 إلى زيادة النسبة في النماذج فحسب، بل يمكنه أيضاً الكشف عن رؤى علمية جديدة حول العلاقات المعقدة في النظم البنية (XAI) في سير عمل التعلم العميق أمر بالغ الأهمية لترجمة التنبؤات الدقيقة إلى اجراءات سياسية فعالة ومقبولة (XAI) ان دمج

#### 6.7 Transfer Learning and Few-Shot Learning

يتطلب تدريب نماذج التعلم العميق من الصفر كميات هائلة من البيانات المصنفة، والتي غالباً ما تكون نادرة ومكلفة في التطبيقات البنية. يعالج التعلم بالنقل هذه (الصور) وتكييفه لمهمة جديدة ذات صلة. يمكن للنموذج المدرب ImageNet المشكلة عن طريقأخذ نموذج تم تدريسه مسبقاً على مجموعة بيانات ضخمة (مثل

مسبيقاً أن ينقل "معرفته" حول الميزات المرئية العامة (مثل الحواف والاتسجة)، مما يقلل بشكل كبير من كمية البيانات المطلوبة للتدريب على المهمة الجديدة

(Mienye & Swart, 2024) ويحسن الأداء (

) هذه الفكرة خطوة إلى الأمام، حيث يهدف إلى تدريب النماذج على التعرف على فئات جديدة باستخدام عدد قليل Few-Shot Learning (XAI) يأخذ الأسئلة من الأمثلة المصنفة (أحياناً مثل واحد فقط). على الرغم من أنه لا يزال مجالاً ناشئاً في الاستشعار عن بعد البنية، إلا أنه يحمل وعياً كبيراً للمناطق التي تدور

فيها البيانات المرجعية، مما يسمح بنشر نماذج الرصد بسرعة وبتكلفة زهيدة.

**7. التحديات والتوجهات المستقبلية**  
على الرغم من التقدم المثير للإعجاب، فإن تطبيق التعلم العميق لرصد وتوقع التصحر وتدور الأراضي لا يزال يواجه العديد من التحديات الكبيرة. إن معالجة هذه التحديات ستكون محور البحث في السنوات القادمة.

#### 7.1 التحديات المتعلقة بالبيانات

الجودة والتوازن: تعتمد نماذج التعلم العميق بشكل كبير على جودة وكمية بيانات التدريب. في العديد من المناطق، وخاصة في البلدان النامية، قد تكون (Olawade, 2024) نادرة أو غير متوفرة أو غير متسقة. هذا يجعل من الصعب تدريب وتقدير النماذج بشكل موثوق (ground-truth) والبيانات المرجعية الدقيقة (

عدم التجانس: غالباً ما تأتي البيانات البنية من مصادر متعددة (أقمار صناعية مختلفة، أجهزة استشعار أرضية، نماذج مناخية) وبذلة مكانية وزمانية (Alotaibi, 2024) مختلفة. إن دمج هذه البيانات غير المتاجنة في إطار عمل متماسك يمثل تحدياً تقنياً كبيراً (

القطاع السحابي والفضاء: لا تزال البيانات البصرية من الأقمار الصناعية تعانى من مشكلة الغطاء السحابي، مما يخلق فجوات في السلسلة الزمنية. على يمكن أن تساعده، إلا أن دمج البيانات البصرية والرادارية بشكل فعال لا يزال مجالاً للبحث النشط. SAR (Hoffman et al., 2025) الرغم من أن تقنيات مثل

#### 7.2 التحديات المتعلقة بالنقل

قابلية التعلم والنقل: غالباً ما يتم تدريب النماذج على بيانات من منطقة جغرافية معينة. قد لا يكون أداء هذه النماذج جيداً عند تطبيقها على منطقة أخرى (Osman et al., 2025). هو تحدٍ رئيسي للتطبيقات التشغيلية العالمية (transferability) (GPs)، مما قد يكون عائقاً أمام الباحثين والمؤسسات في البلدان (التكلفة الحاسوبية: يتطلب تدريب نماذج التعلم العميق المعقدة موارد حاسوبية كبيرة ( ذات الموارد المحدودة.

مشكلة "الصناديق الأسود": كما ذكرنا سابقاً، لا يزال نقص الشفافية في نماذج التعلم العميق يمثل عقبة أمام قبولها على نطاق واسع في صنع السياسات. Hoffman et al., 2025) يجعله جزءاً لا يتجزأ من عملية التنبؤة (XAI) هناك حاجة إلى مزيد من البحث في مجال

#### 7.3 التوجهات المستقبلية

بناءً على التحديات الحالية والفرص المتاحة، يمكن تحديد العديد من التوجهات المستقبلية الرئيسية للبحث:

- التكامل مع العوامل الاجتماعية والاقتصادية: التصحر ليس مجرد ظاهرة بنية، إنه مدفوع بعوامل اجتماعية واقتصادية. يجب أن تدمج النماذج المستقبلية متغيرات مثل الكثافة السكانية، وسياسات استخدام الأراضي، والوصول إلى الأسواق، ومستويات الفقر لفهم الديناميكيات الاجتماعية والبنية بشكل أفضل (Chen et al., 2025) وتقديم تنبؤات أكثر واقعية (
- : يهدف هذا النهج إلى دمج المبادئ الفيزيائية المعروفة (مثـل قوانين تدفق المياه أو دورات Physics-Informed AI) في بنية نماذج التعلم العميق. هذا يمكن أن يساعد في تقييد النماذج لإنتاج نتائج أكثر واقعية من الناحية المادية، خاصة في سيناريوهات ندرة البيانات.
- : لمعالجة مخاوف خصوصية البيانات والسماح بالتدريب التعاوني عبر المؤسسات أو البلدان دون مشاركة Federated Learning (البيانات الأولية، يمكن أن يكون التعلم الفيدرالي حلًّا واحداً. في هذا النهج، يتم تدريب النماذج محلياً على بيانات خاصة، ويتم مشاركة تحديثات النموذج فقط (Brust et al., 2021).
- الرسـد في الوقت الفعلي والأنظمة التشغيلية: الهدف النهائي هو الانتقال من الدراسات البحثية إلى أنظمة الرصد والتتبـؤ التشغيلية في الوقت الفعلي. يتطلب هذا تطوير بنـى تحتية قابلة للتطوير لمعالجة البيانات، ونماذج محسنة للسرعة، وأطر عمل لنشر النماذج وخدمتها لصناع القرار والمزارعين والجمهور (

الجدول 1: ملخص للتحديات الرئيسية والتوجهات المستقبلية المقترنة في مجال استخدام التعلم العميق لرصد التصحر.

المجال	التحديات الرئيسية	التوجهات المستقبلية المقترنة
البيانات	ندرة البيانات المرجعية، عدم التجانس، الضوضاء (الغيموم).	()، تحسين أساليب دمج البيانات متعددة GANs تطوير تقنيات توليد البيانات الاصطناعية (
النماذج	قابلية التعلم المحدودة، التكلفة الحاسوبية العالية، مشكلة "الصناديق الأسود".	التركيز على التعلم بالنقل والتعلم قليل الأمثلة، تطوير نماذج أكثر كفاءة، التكامل المنهجي لتقنيات XAI.
التطبيقات	الفجوة بين البحث والتطبيق العملي، التركيز على المؤشرات البيوفيزيانية.	بناء أنظمة تشغيلية للرصد في الوقت الفعلي، دمج العوامل الاجتماعية والاقتصادية في النماذج، تطوير نماذج فизيانية مستقرة.

## 8. خاتمة

لقد أثبتت التعلم العميق، عند اقترانه بالشروع الهائلة من بيانات الاستشعار عن بعد، أنه أداة تحويلية في المعركة العالمية ضد التصحر وتدور الأرضي. تقدم هذه المراجعة الشاملة دليلاً قاطعاً على أن نماذج التعلم العميق قد تجاوزت مرحلة الإثبات النظري ودخلت مرحلة التطبيق العملي، محققة لفة غير مسبوقة في رصد المؤشرات الحيوية مثل تغير الغطاء الأرضي، وصحة الغطاء النباتي، ورطوبة التربة. علاوة على ذلك، فإن قدرتها على تحليل السلسلة الزمنية المعقدة قد فتحت آفاقاً جديدة للتنبؤ بالحفاف والمخاطر المستقبلية للتدور.

ومع ذلك، فإن الطريق نحو التطبيق العالمي والتشغيل لهذه التقنيات لا يزال محفوفاً بالتحديات. إن قضياباً جودة البيانات، وقابلية تفسير النماذج، وقابليتها للنقل بين البيانات المختلفة ليست مجرد عقبات فنية، بل هي أسئلة جوهرية يجب معالجتها لضمان أن تكون الحلول القائمة على الذكاء الاصطناعي موثوقة وعادلة (XAI) وفعالة للمجتمعات الأقل تضرراً. إن الاتجاهات الناشئة، مثل الذكاء الاصطناعي القابل للتفسير (XAI) والأقتصادية، تقدم مسارات واحدة للتغلب على هذه العقبات.

كمجتمع علمي، يجب أن يكون الهدف التالي هو تجاوز تحسيينات الدقة الهاشمية والتركيز على بناء أنظمة متكاملة وقابلة للتطوير يمكنها تقديم روى قابلة للتنفيذ لصانعي السياسات ومديري الأرض والمنزاريين على أرض الواقع. يتطلب هذا تعاوناً متعدد التخصصات يجمع بين خبراء التعلم العميق وعلماء الجغرافيا وعلماء البيئة وعلماء الاجتماع. من خلال سد الفجوة بين البحث المتقدم والاحتياجات العملية، يمكننا تسخير الإمكانيات الكاملة للتعلم العميق ليس فقط لرصد "الصامت" المتمثل في التصحر، ولكن للمساهمة بفعالية في عكس اتجاهه وبناء مستقبل أكثر استدامة ومرنة للأراضي الجافة في العالم.

## المصادر

1. AbdelRahman, M. A. (2023). An overview of land degradation, desertification and sustainable land management using GIS and remote sensing applications. *Rendiconti Lincei. Scienze Fisiche e Naturali*, 34(3), 767-808.
2. Ahmed, Z., Gui, D., Abd-Elmabod, S. K., Murtaza, G., & Ali, S. (2024). An overview of global desertification control efforts: Key challenges and overarching solutions. *Soil Use and Management*, 40(4), e13154.
3. Alotaibi, E., & Nassif, N. (2024). Artificial intelligence in environmental monitoring: in-depth analysis. *Discover Artificial Intelligence*, 4(1), 84.
4. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O.,..., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8(1), 53.
5. Baartman, J. E., van Lynden, G. W., Reed, M. S., Ritsema, C. J., & Hessel, R. (2007). Desertification and land degradation: origins, processes and solutions. *DESIRE Report series: Scientific Report*, (Wageningen: DESIRE).
6. Başağaoğlu, H., Chakraborty, D., Lago, C. D., Gutierrez, L., Şahinli, M. A., Giacomon, M.,..., & Şengör, S. S. (2022). A review on interpretable and explainable artificial intelligence in hydroclimatic applications. *Water*, 14(8), 1230.
7. Boroughani, M., Mirchooli, F., Hadavifar, M., & Fiedler, S. (2023). Mapping land degradation risk due to land susceptibility to dust emission and water erosion. *Soil*, 9(2), 411-423.
8. Brust, C., Kimball, J. S., Maneta, M. P., Jencso, K., & Reichle, R. H. (2021). DroughtCast: A machine learning forecast of the United States drought monitor. *Frontiers in big Data*, 4, 773478.
9. Chen, C., & Dong, J. (2025). Deep learning approaches for time series prediction in climate resilience applications. *Frontiers in Environmental Science*, 13, 1574981.
10. Dikshit, A., & Pradhan, B. (2021). Interpretable and explainable AI (XAI) model for spatial drought prediction. *Science of the Total Environment*, 801, 149797.
11. Duan, X., Aslam, R. W., Naqvi, S. A. A., Kucher, D. E., Afzal, Z., Raza, D.,..., & Said, Y. (2025). Multi-index assessment and machine learning integration for drought monitoring in Yunnan, China, using Google Earth Engine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.
12. Earth.org. (2022). What Is Desertification? Causes, Effects, And Solutions. Earth.org. <https://earth.org/what-is-desertification/>
13. Elhini, M., Hassaballa, H., Simpson, N. P., Balbaa, M., Ibrahim, R., Mansour, S.,..., & Ganzour, S. (2024). The land degradation and desertification-socioeconomic nexus in Egypt's delta region: A case study on Alexandria and Beheira. *Heliyon*, 10(10).
14. Feng, K., Wang, T., Liu, S., Kang, W., Chen, X., Guo, Z., & Zhi, Y. (2022). Monitoring desertification using machine-learning techniques with multiple indicators derived from MODIS images in Mu Us Sandy Land, China. *Remote Sensing*, 14(11), 2663.
15. Feng, S., Zhao, W., Zhan, T., Yan, Y., & Pereira, P. (2022). Land degradation neutrality: A review of progress and perspectives. *Ecological Indicators*, 144, 109530.
16. Foroumandi, E., Gavahi, K., & Moradkhani, H. (2024). Generative adversarial network for real-time flash drought monitoring: A deep learning study. *Water Resources Research*, 60(5), e2023WR035600.
17. Gyaneshwar, A., Mishra, A., Chadha, U., Raj Vincent, P. D., Rajinikanth, V., Pattukand Ganapathy, G., & Srinivasan, K. (2023). A contemporary review on deep learning models for drought prediction. *Sustainability*, 15(7), 6160.
18. Habibi, V., Ahmadi, H., Jaffari, M., & Moeini, A. (2021). Prediction of land degradation by machine learning methods: a case study from Sharifabad Watershed, Central Iran. *Earth Sciences Research Journal*, 25(3), 353-362.
19. Hasan, S. B., & Kareem, S. W. (2025). Advanced time series forecasting of vegetation health using deep learning models: A remote sensing approach to analyzing climate change impact. *The Egyptian Journal of Remote Sensing and Space Sciences*, 28(4), 645-658.
20. Hugginbottom, T. P., & Symeonakis, E. (2014). Assessing land degradation and desertification using vegetation index data: Current frameworks and future directions. *Remote Sensing*, 6(10), 9552-9575.
21. Hoffman, L., Mazloff, M. R., Gille, S. T., Giglio, D., & Heimbach, P. (2025). Evaluating the Trustworthiness of Explainable Artificial Intelligence (XAI) Methods Applied to Regression Predictions of Arctic Sea Ice Motion. *Artificial Intelligence for the Earth Systems*, 4(1), e240027.
22. Ilionga, S. N., & Ajayi, O. G. (2025). Implementation of deep learning algorithms to model agricultural drought towards sustainable land management in Namibia's Omusati region. *Land Use Policy*, 156, 107593.

23. Lee, C. S., Sohn, E., Park, J. D., & Jang, J. D. (2019). Estimation of soil moisture using deep learning based on satellite data: A case study of South Korea. *GIScience & Remote Sensing*, 56(1), 43-67.
24. Li, M., Avirmed, B., Bayanmunkhd, G., Liu, Y., Wang, Y., Yang, X.,..., & Yu, Q. (2025). Assessment, driving mechanism identification and future scenario projection of desertification vulnerability in the Mongolian Plateau: an integrated study using multi-source data and machine learning. *Ecological Indicators*, 180, 114340.
25. Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A*, 379(2194), 20200209.
26. Márquez-Grajales, A., Villegas-Vega, R., Salas-Martínez, F., Acosta-Mesa, H. G., & Mezura-Montes, E. (2024). Characterizing drought prediction with deep learning: A literature review. *MethodsX*, 13, 102800.
27. Meng, X., Li, S., Akhmadzi, K., He, P., & Dong, G. (2024). Trends, turning points, and driving forces of desertification in global arid land based on the segmental trend method and SHAP model. *GIScience & Remote Sensing*, 61(1), 2367806.
28. Mienye, I. D., & Swart, T. G. (2024). A comprehensive review of deep learning: Architectures, recent advances, and applications. *Information*, 15(12), 755.
29. Mienye, I. D., & Swart, T. G. (2024). A comprehensive review of deep learning: Architectures, recent advances, and applications. *Information*, 15(12), 755.
30. Mohamed, S. A., Maksoud, O. O. A., Fathy, A., Mohamed, A. S., Hosny, K., Keshk, H. M., & Mohamed, S. A. (2025). A hybrid deep learning and rule-based model for smart weather forecasting and crop recommendation using satellite imagery. *Scientific Reports*, 15(1), 36102.
31. Nijaguna, G. S., Manjunath, D. R., Abouhawwash, M., Askar, S. S., Basha, D. K., & Sengupta, J. (2023). Deep learning-based improved WCM technique for soil moisture retrieval with satellite images. *Remote Sensing*, 15(8), 2005.
32. Odebiri, O., Mutanga, O., & Odindi, J. (2022). Deep learning-based national scale soil organic carbon mapping with Sentinel-3 data. *Geoderma*, 411, 115695.
33. Olawade, D. B., Wada, O. Z., Ige, A. O., Egbewole, B. I., Olojo, A., & Oladapo, B. I. (2024). Artificial intelligence in environmental monitoring: Advancements, challenges, and future directions. *Hygiene and Environmental Health Advances*, 12, 100114.
34. Osmanr, A. I. A., AlDahoul, N., Chong, K. L., Huang, Y. F., Ng, J. L., Elshafie, A.,..., & Ahmed, A. N. (2025). A review on machine learning models for drought monitoring and forecasting. *Climate Risk Management*, 100758.
35. Radeloff, V. C., Roy, D. P., Wulder, M. A., Anderson, M., Cook, B., Crawford, C. J.,..., & Zhu, Z. (2024). Need and vision for global medium-resolution Landsat and Sentinel-2 data products. *Remote Sensing of Environment*, 300, 113918.
36. Rivera-Marín, D., Dash, J., & Ongutu, B. (2022). The use of remote sensing for desertification studies: A review. *Journal of Arid Environments*, 206, 104829.
37. Rukhovich, D. I., Koroleva, P. V., Rukhovich, D. D., & Kalinina, N. V. (2021). The use of deep machine learning for the automated selection of remote sensing data for the determination of areas of arable land degradation processes distribution. *Remote Sensing*, 13(1), 155.
38. Singh, A., & Gaurav, K. (2023). Deep learning and data fusion to estimate surface soil moisture from multi-sensor satellite images. *Scientific Reports*, 13(1), 2251.
39. United Nations. (n.d.). Desertification, land degradation and drought. [sdgs.un.org](http://sdgs.un.org). <http://sdgs.un.org/topics/desertification-land-degradation-and-drought>
40. Walker, A. S., & Robinove, C. J. (1981). *Annotated bibliography of remote sensing methods for monitoring desertification* (Vol. 851). US Geological Survey.
41. Yan, H., Ran, Q., Hu, R., Xue, K., Zhang, B., Zhou, S.,..., & Wang, Y. (2022). Machine learning-based prediction for grassland degradation using geographic, meteorological, plant and microbial data. *Ecological Indicators*, 137, 108738.
42. Yang, J., Wang, Q., Chang, D., Xu, W., & Yuan, B. (2023). A high-precision remote sensing identification method for land desertification based on ENVINet5. *Sensors*, 23(22), 9173.
43. Yousefi, S., Pourghasemi, H. R., Avand, M., Janizadeh, S., Tavangar, S., & Santosh, M. (2021). Assessment of land degradation using machine-learning techniques: A case of declining rangelands. *Land Degradation & Development*, 32(3), 1452-1466.
44. Zerrouki, N., Dairi, A., Harrou, F., Zerrouki, Y., & Sun, Y. (2022). Efficient land desertification detection using a deep learning-driven generative adversarial network approach: A case study. *Concurrency and Computation: Practice and Experience*, 34(4), e6604.
45. Zhang, Y., Tian, Y., Li, Y., Wang, D., Tao, J., Yang, Y.,..., & Wu, L. (2022). Machine learning algorithm for estimating karst rocky desertification in a peak-cluster depression basin in southwest Guangxi, China. *Scientific Reports*, 12(1), 19121.
46. Zolfaghari, F., Azarnivand, H., Khosravi, H., Zehtabian, G., & Sigaroudi, S. K. (2022). Monitoring the severity of degradation and desertification by remote sensing (case study: Hamoun International Wetland). *Frontiers in Environmental Science*, 10, 902687.