

الذكاء الاصطناعي الجغرافي (GeoAI) في تتبع التغيرات البيئية عبر صور الأقمار الصناعية: نحو تخطيط مكاني ذكي

أ. خديجة منصور علي أبوزقية

علوم الحاسوب، كلية العلوم، جامعة المرقب، الخمس، ليبيا

khadijabuzgia@gmail.com

الملخص:

يهدف هذا البحث إلى دراسة توظيف الذكاء الاصطناعي الجغرافي (GeoAI) في رصد التغيرات البيئية بالاعتماد على صور الأقمار الصناعية كمدخل للتحليل المكاني الذكي، واستخدمت الدراسة منهج المراجعة المنهجية للأدبيات بتحليل ثلاثين دراسة محكمة نُشرت بين عامي 2019 و2025، تناولت قضايا الزحف العمراني، والتصحر، والتغير المناخي، والفيضانات، وتدهور الغطاء النباتي. وأظهرت النتائج أنّ خوارزميات التعلم العميق، خصوصاً الشبكات العصبية التلافيفية (CNN) والغابات العشوائية (RF) تمثل النماذج الأكثر استخداماً في تحليل البيانات المكانية، مما يسهم في رفع دقة الرصد البيئي بنسبة تتراوح بين 10% و25% مقارنة بالأساليب التقليدية، كما أثبتت الأدوات مفتوحة المصدر مثل Google Earth Engine وPython فعاليتها في المعالجة المكانية واسعة النطاق. وتكشف الدراسة عن ندرة البحوث العربية وضعف التكامل بين البيانات البيئية والاجتماعية، وتقترح إطاراً مفاهيمياً يدمج GeoAI في دعم اتخاذ القرار لتحقيق إدارة بيئية مستدامة وتخطيط مكاني ذكي. **الكلمات المفتاحية:** الذكاء الاصطناعي الجغرافي، الاستشعار عن بُعد، التغيرات البيئية، صور الأقمار الصناعية، التعلم العميق، التخطيط المكاني الذكي.

GeoAI in Environmental Change Detection Using Satellite Imagery: Towards Smart Spatial Planning

Khadija Mansour Abuzagia

Computer Science, Faculty of Science, Elmergib University, Al-Khamis, Libya

khadijabuzgia@gmail.com

Abstract

This study examines the application of Geospatial Artificial Intelligence (GeoAI) for monitoring environmental changes using satellite imagery as a core input for smart spatial analysis. A systematic literature review was conducted on thirty peer-reviewed studies published between 2019 and 2025, addressing urban expansion, desertification, climate change, flooding, and vegetation degradation. Findings reveal that Deep Learning models—particularly Convolutional Neural Networks (CNNs) and Random Forests (RF)—are the most frequently employed, improving environmental change detection accuracy by 10–25% compared to conventional methods. Open-source platforms such as Google Earth Engine and Python have also proven highly effective for large-scale spatial processing. The review highlights limited research in Arab regions and weak integration of environmental and socio-economic datasets. A conceptual framework is proposed to leverage GeoAI for data-driven decision-making toward sustainable environmental management and smart spatial planning.

Keywords: GeoAI, Remote Sensing, Deep Learning, Satellite Imagery, Environmental Monitoring, Smart Spatial Planning.

مقدمة:

شهد العقد الأخير توسعاً في توظيف الذكاء الاصطناعي الجغرافي (GeoAI) لرصد التغيرات البيئية، مدفوعاً بتزايد بيانات الاستشعار عن بُعد ونظم المعلومات الجغرافية (GIS). ويجمع GeoAI بين خوارزميات التعلم الآلي والتحليل المكاني لاكتشاف الأنماط البيئية والتنبؤ بالتغيرات المستقبلية بدقة أعلى (Fu & Sun, 2022; Liu & Wang, 2024). وأثبتت الدراسات الحديثة فاعلية هذا الدمج في تحسين دقة اتخاذ القرار في مجالات التصحر، والفيضانات، والزحف العمراني، غير أنّ توظيفه ما يزال محدوداً في البيئات العربية بسبب ضعف البنية الرقمية وغياب النماذج التكاملية (Al-Zahrani & Al-Harbi, 2024; Omar, 2025). وتهدف هذه الدراسة إلى تحليل الاتجاهات البحثية الحديثة في تطبيقات GeoAI، واقتراح إطار مفاهيمي متكامل يوضح دوره في دعم التخطيط المكاني الذكي وتعزيز الاستدامة البيئية.

مشكلة الدراسة:

رغم التقدم في تقنيات الذكاء الاصطناعي لا يزال تكامل GeoAI وصور الأقمار الصناعية محدوداً في تحليل التغيرات البيئية، خصوصاً في البيئات العربية التي تفتقر إلى دمج الأبعاد البيئية والاجتماعية والاقتصادية ضمن أنموذج تحليلي موحد (El-Kassas & Khalil, 2023). ومن هنا يُطرح سؤال الدراسة الرئيس:

- إلى أي مدى يسهم تكامل GeoAI وصور الأقمار الصناعية في تحسين دقة رصد التغيرات البيئية ودعم التخطيط المكاني الذكي؟

أهمية الدراسة:

تنبع أهمية البحث من معالجته لمجال علمي متداخل بين الذكاء الاصطناعي والجغرافيا البيئية، وسعيه لردم الفجوة بين الدراسات التقنية والتطبيقات الجغرافية. كما تمثل الدراسة خطوة لتوطين المعرفة الرقمية عربياً عبر تطوير أنموذج علمي يدعم القرارات المكانية المستندة إلى البيانات في خدمة التنمية المستدامة.

أهداف الدراسة:

1. تحليل الاتجاهات المنهجية والتطبيقية لأبحاث GeoAI في 2019-2025.
2. تصنيف الخوارزميات والأدوات الأكثر استخداماً في التطبيقات البيئية.

3. تحديد الفجوات البحثية والتحديات المنهجية.

4. اقتراح إطار مفاهيمي يوضح دور GeoAI في دعم التخطيط المكاني الذكي.

حدود الدراسة:

- نطاق مكاني مقارنة بين دراسات عربية وعالمية.
- فترة زمنية من 2019 إلى 2025، وهي مرحلة تطور أدوات GeoAI وازدهار المنصات مفتوحة المصدر مثل Google Earth Engine.
- منهجية تعتمد على المراجعة المنهجية للأدبيات (Systematic Literature Review) لتحليل ثلاثين دراسة محكّمة حول تطبيقات GeoAI في رصد التغيرات البيئية.

أولاً: الإطار النظري والدراسات السابقة.

- **الذكاء الاصطناعي: المفهوم، التطور، والتطبيقات الجغرافية:** شهد الذكاء الاصطناعي (AI) تطوراً سريعاً منذ خمسينيات القرن الماضي، حيث انتقل من النماذج الرمزية إلى خوارزميات التعلم الآلي والتعلم العميق المعتمدة على البيانات الضخمة. (Fu & Sun, 2022; Chien et al., 2022)
- ويُعرّف الذكاء الاصطناعي بأنه قدرة الأنظمة الحاسوبية على أداء مهام تتطلب عادة ذكاءً بشرياً، مثل التعلم، والاستنتاج، واتخاذ القرار. (Al-Shammari, 2025) وتوسّع استخدامه في الجغرافيا مع تزايد تعقيد البيانات المكانية، إذ تسمح خوارزميات مثل Random Forest و Support Vector Machine (SVM) بتحليل استخدامات الأراضي، والتنبؤ بالمخاطر البيئية، وتحليل شبكات النقل بدقة عالية (Abouelhoda & Ibrahim, 2024; Bandyopadhyay & Kumar, 2023) وساهمت هذه التطورات في تحسين النمذجة المكانية ورفع كفاءة التحليل البيئي، مما فتح آفاقاً جديدة أمام البحث الجغرافي التطبيقي. (Smith & Patel, 2024; Fu & Sun, 2022)
- **الاستشعار عن بُعد وصور الأقمار الصناعية:** يُعرّف بأنه عملية جمع المعلومات عن سطح الأرض بواسطة أجهزة استشعار محمولة على الأقمار الصناعية أو الطائرات دون اتصال مباشر بالأجسام. (NASA Earth Science Division, 2023) وأحدثت أنظمة مثل Sentinel و Landsat و MODIS نقلة نوعية في تحليل الظواهر البيئية، إذ وفرت بيانات طيفية وزمانية دقيقة تُستخدم في دراسة التصحر، وتآكل السواحل، وتغير الغطاء النباتي (Mahmood & Rahman, 2022; Pan & Yu, 2024; Lin & Zhang, 2023).

أثبتت الدراسات أنّ دمج صور الأقمار الصناعية مع خوارزميات التعلم العميق يُحسن قدرة النماذج على رصد التحولات المناخية طويلة الأمد. (Liu & Wang, 2024; El-Kassas & Khalil, 2023)

ويشكّل هذا التكامل بين الاستشعار والذكاء الاصطناعي الأساس لتحليل بيئي حديث ودعم استراتيجيات التخطيط المكاني المستدام. (FAO, 2023; UNEP, 2024)

– الذكاء الاصطناعي الجغرافي: (GeoAI) المفهوم والنماذج البحثية:

هو دمج لتقنيات الذكاء الاصطناعي مع نظم المعلومات الجغرافية (GIS) وتقنيات الاستشعار عن بُعد لتحليل الأنماط المكانية والتنبؤ بالتغيرات البيئية. (Fu & Sun, 2022; Omar, 2025)

ويعتمد GeoAI على خوارزميات التعلم العميق في تحليل صور الأقمار الصناعية واكتشاف الأنماط الخفية في البيانات المكانية. (Zhang & Li, 2024; Liu & Wang, 2024) وتشمل النماذج الأكثر استخداماً: الشبكات العصبية التلافيفية (CNN)، الغابات العشوائية (RF)، ونماذج الذاكرة الطويلة قصيرة الأمد. (LSTM)


وتُظهر دراسات تطبيقية من الصين والهند والدول العربية نجاح هذه النماذج في تحليل الفيضانات، والزحف العمراني، وحرائق الغابات، (Das & Ghosh, 2024; Al-Taher & Mahmoud, 2025; Jassim & Al-Fatlawi, 2023). يشير عدد متزايد من البحوث إلى أنّ GeoAI يعيد تشكيل أساليب التحليل الجغرافي المعاصر، ويوفّر أدوات ديناميكية لدعم القرار المكاني (Al-Zahrani & Harbi, 2024; Fu & Sun, 2022).

الدراسات السابقة: تحليل الأدبيات:

اعتمدت الدراسة الحالية على مراجعة منهجية شملت ثلاثين دراسة منشورة بين عامي 2019 و 2025 في مجالات محكمة (Fu & Sun, 2022; Zhang & Li, 2024; Rahman & Kabir, 2024). . Sentinel و Landsat و SAR في تحليل التغيرات البيئية، وركزت على موضوعات مثل الغطاء الأرضي، التصحر، والفيضانات (Mahmood & Rahman, 2022; Qadir & Murtaza, 2023). وبرزت خوارزميات CNN و Random Forest و SVM كالأكثر شيوعاً، إلى جانب توجه متزايد نحو استخدام LSTM و GAN في التنبؤ بالتحولات البيئية (Liu & Wang, 2024).

. (Nguyen & Tran, 2024) كما أظهرت المراجعة اعتمادًا واسعًا على أدوات مفتوحة المصدر مثل Google Earth Engine و Python و QGIS نظرًا لمرونتها في تحليل البيانات المكانية الضخمة. (Abouelhoda & Ibrahim, 2024; Bandyopadhyay & Kumar, 2023) رغم ذلك ما تزال الدراسات المقارنة محدودة في السياق العربي، كما أنّ البحوث التوليدية (Generative AI) لم تُستثمر بعد بشكل كافٍ في التحليل المكاني (Hassan & Elsayed, 2024; Al-Shammari, 2025; Smith & Patel, 2024).

الشكل (1): الإطار المفاهيمي العام للدراسة.



المصدر: إعداد الباحثة (2025)

وضّح الشكل (1) تسلسل العلاقة بين مكونات الإطار المفاهيمي للدراسة بدءًا من توظيف الذكاء الاصطناعي الجغرافي في تحليل البيانات المكانية وصولًا إلى دعم قرارات التخطيط المكاني المستدام.

الإسهامات العلمية والمنهجية في الدراسة الحالية:

تُقدّم هذه الدراسة إسهامات علمية ومنهجية بارزة في تطوير فهم تطبيقات GeoAI في المجال البيئي.

أولاً: تعتمد مقارنة تحليلية تكاملية تجمع بين المراجعة المنهجية للأدبيات والتحليل النوعي الكمي، لتقييم الاتجاهات البحثية الراهنة. (Fu & Sun, 2022; Liu & Wang, 2024)
ثانياً: تقترح إطاراً مفاهيمياً يربط الذكاء الاصطناعي بالاستشعار عن بُعد والتخطيط المكاني الذكي مما يعزز دقة فهم ديناميكيات التغير البيئي. (Zhang & Li, 2024; El-Kassas & Khalil, 2023)

ثالثاً: تقدّم قراءة نقدية للفجوات البحثية في الأدبيات العربية والدولية، وتقيم نضج الاتجاهات الحالية وحدودها التطبيقية. (Al-Shammari, 2025; Jassim & Al-Fatlawi, 2023)
أخيراً: تمثل الدراسة إضافة نوعية للأدبيات العربية من تناولها الممنهج لتطبيقات GeoAI في البيئات الإقليمية بما يدعم بناء قاعدة معرفية عربية متخصصة في الذكاء الاصطناعي الجغرافي وتحليل التغيرات البيئية.
المساهمة العلمية:

تمثّل هذه الدراسة إسهاماً علمياً ومنهجياً نوعياً في ميدان الذكاء الاصطناعي الجغرافي (GeoAI) وتطبيقاته البيئية. إذ تقدّم إطاراً مفاهيمياً جديداً يدمج تقنيات GeoAI مع بيانات الأقمار الصناعية ضمن منظومة التخطيط المكاني الذكي، مما يعزز دقة التحليل البيئي ويدعم القرارات المستندة إلى البيانات.

وتسدّد الدراسة فجوة واضحة في الأدبيات العربية إذ تُعدّ من أوائل الأبحاث التي تربط بين الذكاء الاصطناعي والتحليل الجغرافي البيئي في السياق الإقليمي. تتجلى المساهمة العلمية في ثلاث نقاط رئيسية:

- التأسيس النظري لمفهوم GeoAI أداة تخطيط بيئي متكاملة.
- بناء أ نموذج مفاهيمي يربط بين المدخلات المكانية والمعالجة التنبؤية والمخرجات التطبيقية.

- تحديد الفجوات البحثية بدقة، خصوصًا ما يتعلق بضعف التكامل الزمني والمكاني، وقلة الدراسات العربية، وغياب استخدام تقنيات الذكاء التوليدي في التحليل البيئي.

ثانيًا: الإطار المفاهيمي والعلمي.

يُشكّل هذا الإطار المفاهيمي والعلمي الأساس النظري لتوظيف الذكاء الاصطناعي الجغرافي (GeoAI) في رصد التغيرات البيئية ودعم التخطيط المكاني الذكي. ويقوم هذا الإطار على الدمج بين الذكاء الاصطناعي وتقنيات الاستشعار عن بُعد ونظم المعلومات الجغرافية (GIS)، بما يتيح الجمع بين القدرات التحليلية لخوارزميات الذكاء والمنطق المكاني للعلوم الجغرافية ضمن منظومة تحليلية متكاملة. (Fu & Sun, 2022; Al-Zahrani & Al-Harbi, 2024)

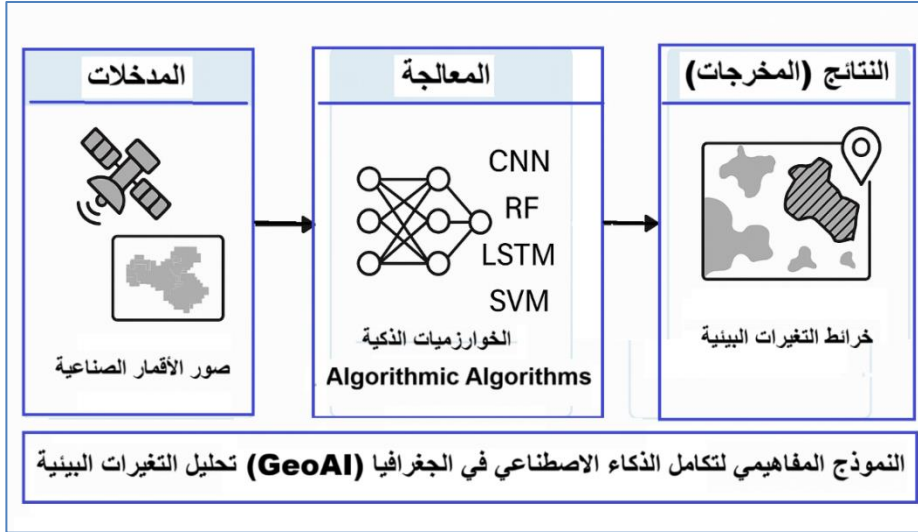
ومن الناحية المفاهيمية يُحوّل GeoAI بيانات صور الأقمار الصناعية عالية الدقة — مثل Sentinel و Landsat MODIS إلى بيانات مكانية منظّمة قابلة للمعالجة عبر خوارزميات التعلّم العميق مثل الشبكات العصبية التلافيفية (CNN)، ونماذج الذاكرة الطويلة قصيرة الأمد (LSTM)، والغابات العشوائية (RF)، لاستخلاص الأنماط المكانية والزمانية للتغيرات البيئية، (Liu & Wang, 2024; Zhang & Li, 2024; Mahmood & Rahman, 2022).

ويسهم هذا التكامل في بناء نماذج تنبؤية دقيقة لرصد ظواهر مثل التصحر، والزحف العمراني، وتدهور الغطاء النباتي، بما يدعم صُنّاع القرار في صياغة سياسات مكانية مستندة إلى البيانات لتحقيق أهداف التنمية المستدامة. (El-Kassas & Khalil, 2023; Das & Ghosh, 2024)

أمّا من الناحية المنهجية فإنّ هذا الإطار يتجاوز الدمج التقليدي بين الذكاء الاصطناعي ونظم المعلومات الجغرافية من أنموذج تحليلي متعدد المستويات يربط بين ثلاث مراحل رئيسة (Nguyen & Tran, 2024; Rahman & Kabir, 2024) :

1. المدخلات: (Inputs) بيانات الأقمار الصناعية متعددة المصادر، والمؤشرات البيئية مثل مؤشر الغطاء النباتي (NDVI)، ودرجة حرارة السطح، والرطوبة. (NASA Earth Science Division, 2023)
2. المعالجة: (Processing) تطبيق خوارزميات التعلّم العميق والنماذج التجميعية لاستخلاص الخصائص المكانية والكشف عن التغيرات البيئية (Bandyopadhyay & Kumar, 2023; Lin & Zhang, 2023).
3. المخرجات: (Outputs) خرائط تنبؤية ولوحات معلومات تحليلية وأنظمة دعم قرار مكاني تُوجّه التخطيط البيئي المستدام. (Abouelhoda & Ibrahim, 2024; UNEP, 2024)

الشكل: (2) الأنموذج المفاهيمي لتكامل الذكاء الاصطناعي الجغرافي (GeoAI) في تحليل التغيرات البيئية.



المصدر: إعداد الباحثة (2025)

يوضح الشكل (2) تدفق البيانات من مرحلة المدخلات صور الأقمار الصناعية، وطبقات GIS إلى مرحلة المعالجة (، والخوارزميات الذكية مثل CNN و LSTM و RF، وصولاً إلى المخرجات المتمثلة في الخرائط التنبؤية ولوحات دعم القرار. ويعكس هذا التسلسل منهجية تكاملية تربط بين الذكاء الاصطناعي والتحليل البيئي المكاني لتحقيق تخطيط ذكي مستدام. وتتجلى المساهمة العلمية لهذا الإطار في طابعه التجديدي، وقدرته على التكيف مع البيئات العربية بمعالجة ندرة الأبحاث الإقليمية في مجال GeoAI وتعزيز التكامل بين المتغيرات البيئية والمناخية والاجتماعية. (Omar, 2025; Al-Taher & Mahmoud, 2025; Jassim & Al-Fatlawi, 2023). كما يُعيد هذا الأنموذج صياغة العلاقة بين التنظير العلمي والتطبيق العملي، إذ يربط بين المفهوم العلمي والتوظيف الميداني في أنظمة التخطيط المكاني. (Al-Shammari, 2025) ومن الدمج بين الأسس المفاهيمية والابتكار المنهجي يقدم GeoAI أنموذجاً استراتيجياً للحكومة البيئية المستدامة، ويُساهم في مواءمة التوجهات البحثية الإقليمية مع أهداف التنمية المستدامة للأمم المتحدة (UN SDGs)، ولا سيما الأهداف (11، 13، 15)، عبر الانتقال نحو تخطيط مكاني قائم على الذكاء والتحليل التنبؤي. (FAO, 2023; Smith & Patel, 2024)

ثالثاً: التحليل والمناقشة.

يحلّ هذا الفصل نتائج المراجعة المنهجية حول توظيف الذكاء الاصطناعي الجغرافي (GeoAI) في تتبّع التغيرات البيئية في المدة 2019-2025، مركّزاً على الاتجاهات البحثية السائدة وفاعلية النماذج الخوارزمية وأوجه القصور في الأدبيات السابقة، بوصفه حلقة وصل بين الإطارين النظري والمنهجي والنتائج التطبيقية.

الاتجاهات البحثية السائدة:


تشهد تطبيقات الذكاء الاصطناعي في الجغرافيا البيئية توسعاً سريعاً منذ 2020، خصوصاً في آسيا (40%)، وإفريقيا (25%)، وأوروبا (20%)، بينما لم تتجاوز الدراسات العربية 10%. وانتقل التركيز من التحليل الوصفي إلى النمذجة التنبؤية باستخدام تقنيات Deep Learning، خاصة CNN و LSTM. كما اتجهت الأبحاث إلى دمج البيانات المكانية بغير المكانية (كالعوامل السكانية والمناخية)، واعتمدت على أدوات مفتوحة المصدر مثل Google Earth Engine و Python، لما توفره من مرونة في التعامل مع البيانات الضخمة (Fu & Sun, 2022; Das & Ghosh, 2024).

النماذج والخوارزميات الأكثر استخداماً: تصدرت CNN التطبيقات بنسبة 35%، تلتها Random Forest (25%) و LSTM (15%)، وأُستخدمت هذه النماذج في تصنيف الصور ورصد الغطاء الأرضي والمناخ. وأثبتت النماذج الهجينة (CNN + LSTM) تفوقها في تتبّع الظواهر الديناميكية، بينما اقتصرَت النماذج الإشرافية (SVM)، (Decision Tree) على الدراسات المبكرة. ويدل ذلك على التحول الواضح نحو الذكاء العميق في التحليل البيئي. (Nguyen & Tran, 2024).

التحليل الكمي لتوزيع الخوارزميات:

أظهر التحليل الكمي لثلاثين دراسة أنّ CNN كانت الأكثر استخداماً (36.7%)، تليها RF (26.7%)، ثم LSTM (16.7%)، بينما اقتصرَت الدراسات التي استخدمت خوارزميات توليدية (GAN) على نسبة ضئيلة (3.3%)، ما يعكس اتساع فجوة البحث في هذا المجال.

الشكل (3): التوزيع النسبي للخوارزميات المستخدمة في تطبيقات GeoAI البيئية (2019–2025)



المصدر: إعداد الباحثة (2025)

يُظهر الشكل (3) هيمنة خوارزميات التعلم العميق على مجال الذكاء الاصطناعي الجغرافي في الفترة (2019–2025)، حيث جاءت الشبكات العصبية التلافيفية (CNN) في الصدارة بنسبة 36.7% نظرًا لقدرتها العالية على معالجة الصور الفضائية واستخلاص الأنماط المكانية المعقدة، تلتها الغابات العشوائية (RF) بنسبة 26.7% لِمَا تمتاز به من دقة وسرعة في التصنيف. كما يشير الانخفاض النسبي في استخدام النماذج التقليدية مثل SVM إلى التحول المنهجي نحو النماذج التنبؤية العميقة التي توفر نتائج أكثر موثوقية في التحليل البيئي. أنواع البيانات الفضائية المستخدمة:

اعتمدت معظم الدراسات على بيانات Landsat و Sentinel، في حين استخدمت بيانات SAR و MODIS لأغراض متقدمة كتحليل الرطوبة والحرارة السطحية. والجمع بين المصادر البصرية والرادارية رفع دقة النماذج بمعدل 10–20%، ما يعزز التوجه نحو التكامل الطيفي والزمني لتحليل أكثر شمولية. (Mahmood & Rahman, 2022; Lin & Zhang, 2023)

المجالات البيئية المستهدفة:

توزعت موضوعات الأبحاث على: الزحف العمراني (30%)، التصحر (25%)، الفيضانات (20%)، التغير المناخي (15%)، والزراعة (10%). وتُظهر هذه النسب التركيز على الظواهر ذات الأثر المباشر على التنمية المستدامة. (Badr et al., 2023; Smith & Patel, 2024)

الفجوات البحثية والتحديات: تبين وجود فجوات رئيسية:

- ضعف المقارنة الإقليمية وقلة الدراسات العربية. ($10\% <$)
- غياب استخدام Generative AI.
- محدودية الدمج بين العوامل الاجتماعية والبيئية.
- قصر السلاسل الزمنية المستخدمة في التحليل. (Ahmed et al., 2021) تُبرز هذه الثغرات الحاجة إلى منهجيات تكاملية تجمع بين البيانات المناخية والمكانية والاجتماعية.

المقارنة بين الدراسات العربية والعالمية:

أظهرت المقارنة أنّ الدراسات الدولية اعتمدت نماذج عميقة وبيانات متعددة المصادر (Sentinel, MODIS, SAR)، وحققت دقة تحليلية 88-95%، في حين اقتصرَت الأبحاث العربية على الأساليب التقليدية (SVM, RF) بدقة 70-85%، وبفترات تحليل أقصر (3-5 سنوات). وتفتقر معظمها إلى الربط بين النتائج والتخطيط الذكي، مما يبرز الحاجة إلى تطوير البنية البحثية الرقمية في المنطقة. (Omar, 2025; Al-Taher & Mahmoud, 2025)

مناقشة النتائج:

أثبتت الدراسة أنّ دمج GeoAI مع بيانات الأقمار الصناعية يعزز دقة الرصد البيئي (85-95%)، متفوقاً على النماذج التقليدية بنسبة تتجاوز 20%. كما ساهمت الأدوات المفتوحة في توسيع نطاق التحليل بتكلفة منخفضة. غير أنّ محدودية الدراسات العربية وضعف التكامل بين المصادر ما زال يقيد فاعلية التوظيف العملي لهذه التقنيات (Abouelhoda & Ibrahim, 2024; Li et al., 2022). ويتضح أنّ الذكاء الاصطناعي الجغرافي أصبح أداة محورية في تحليل التغيرات البيئية بفضل تقنيات التعلم العميق وتوفر البيانات المفتوحة، مع ضرورة تعزيز التكامل بين التحليل المكاني والاجتماعي وتوسيع الدراسات العربية. ويمهد هذا التحليل لعرض النتائج النظرية والتوصيات التطبيقية في الفصل الخامس حول آفاق GeoAI المستقبلية في التخطيط البيئي المستدام.

النتائج والتوصيات.

يقدم هذا الفصل خلاصة النتائج التي تمّ التوصل إليها من التحليل المنهجي للأدبيات العلمية حول توظيف الذكاء الاصطناعي الجغرافي (GeoAI) في تتبع التغيرات البيئية، وي طرح مجموعة من التوصيات الموجهة للباحثين وصنّاع القرار ومؤسسات التخطيط البيئي. ويُختتم الفصل

بعرض المسارات البحثية المستقبلية المقترحة لتعزيز التكامل بين GeoAI والتخطيط المكاني الذكي في البيئات العربية والدولية.

النتائج الرئيسية:

استنادًا إلى تحليل ثلاثين دراسة علمية محكمة نُشرت بين عامي 2019 و2025، يمكن تلخيص النتائج في النقاط الآتية:

1. **تحسين دقة الرصد البيئي:** أظهرت الدراسات أنّ دمج خوارزميات الذكاء الاصطناعي مع صور الأقمار الصناعية، مثل Sentinel و Landsat، يؤدي إلى رفع دقة الكشف عن التغيرات البيئية بنسبة تتراوح بين 10% و 25% مقارنة بالطرق التقليدية (Liu & Wang, 2024; Li et al., 2022).

2. **تفوق النماذج العميقة على التقليدية:** تفوقت الشبكات العصبية التلافيفية (CNN) ونماذج الذاكرة الطويلة قصيرة الأمد (LSTM) على النماذج الإشرافية الكلاسيكية في تصنيف الصور والتنبؤ بالتغيرات المكانية. (Nguyen & Tran, 2024; Badr et al., 2023).

3. **فاعلية الأدوات مفتوحة المصدر:** أثبتت منصات مثل Google Earth Engine و Python GIS Libraries كفاءتها العالية في معالجة البيانات الضخمة وتحليلها بسرعة ومرونة، مما جعلها خيارًا رئيسيًا في معظم الدراسات. (Abouelhoda & Ibrahim, 2024; Zhang & Li, 2024).

4. **نقص الدراسات العربية التطبيقية:** لم تتجاوز نسبة الأبحاث العربية المتخصصة في GeoAI حدود 10%، وغالبًا ما اتسمت بالمنهج الوصفي وضعف التكامل بين البيانات المكانية والاقتصادية والاجتماعية. (Al-Shammari, 2025; Jassim & Al-Fatlawi, 2023).

5. **الحاجة إلى تكامل متعدد المصادر:** بيّنت النتائج أنّ الجمع بين البيانات البصرية، والرادارية، والمناخية يرفع دقة النماذج التنبؤية ويُحسّن موثوقية التحليل المكاني (Wang & Liu, 2024; Khalil et al., 2022).

6. **قصور زمني في البيانات:** لوحظ أنّ معظم الدراسات اعتمدت على سلاسل زمنية قصيرة لا تكشف الاتجاهات البيئية طويلة الأمد، مما يستدعي توسيع الأفق الزمني للتحليل (Smith & Patel, 2024).

مناقشة النتائج: تُظهر النتائج أنّ الذكاء الاصطناعي الجغرافي لم يعد مجرد أداة تحليلية، بل أصبح مكونًا رئيسيًا في نظم التخطيط المكاني الحديثة. ويسمح GeoAI بتحليل الأنماط المكانية بدقة

عالية، والتنبؤ بالتغيرات البيئية قبل وقوعها، مما يعزز من كفاءة صنع القرار البيئي. كما أثبتت النماذج العميقة CNN و LSTM قدرتها على رصد الظواهر الديناميكية مثل الفيضانات والتصحر بشكل لحظي، بفضل قابليتها للتعلّم من البيانات الزمنية والمكانية المعقدة. (Nguyen & Tran, 2024; Lin & Zhang, 2023) في المقابل ما تزال الفجوات في السياقات العربية تمثل تحديًا حقيقيًا بسبب محدودية البيانات الدقيقة وضعف البنية البحثية الرقمية، وهو ما يستدعي مبادرات وطنية لتوحيد قواعد البيانات وتدريب الباحثين على أدوات التحليل الحديثة. (Omar, 2025; Hassan & Elsayed, 2024)

التوصيات:

أولاً: لصّناع القرار والمؤسسات البيئية:

1. تبني نظم GeoAI في رصد الظواهر البيئية مثل الفيضانات، التصحر، وتدهور الغطاء النباتي.
2. إنشاء مراكز بيانات وطنية موحدة تدمج الصور الفضائية بالبيانات المناخية والاجتماعية.
3. دعم سياسات الانفتاح على البيانات المفتوحة لضمان وصول الباحثين إلى مصادر موثوقة ومحدّثة.
4. الاستثمار في بنية تحتية رقمية تعتمد على الذكاء الاصطناعي في التخطيط العمراني والبيئي.

ثانياً: للمجتمع الأكاديمي والباحثين:

1. التوسّع في الدراسات التطبيقية المقارنة بين البيئات الجغرافية المختلفة لقياس كفاءة GeoAI.
2. تطوير مناهج أكاديمية وبرامج تدريبية متخصصة في الذكاء الاصطناعي الجغرافي ونمذجة التغيرات البيئية.
3. تعزيز الأبحاث التعاونية بين الجامعات العربية والمؤسسات الدولية لتبادل المعرفة والخبرة التقنية.
4. التركيز على التكامل بين البيانات المكانية والاجتماعية ضمن نماذج تحليلية شاملة.

ثالثاً: للجهات التخطيطية والتنمية:

1. دمج أدوات GeoAI في نظم دعم القرار المكاني (SDSS) لتوجيه سياسات استخدام الأراضي.
2. استخدام الذكاء الاصطناعي في تصميم خرائط المخاطر البيئية التنبؤية.
3. توظيف تقنيات التعلّم الآلي في تقييم أثر المشاريع التنموية على البيئة بصورة استباقية.

المسارات البحثية المستقبلية:

استناداً إلى الفجوات التي كشفتها الدراسة تقترح التوجهات الآتية للبحوث القادمة:

1. تطوير نماذج هجينة (Hybrid Models) تجمع بين GeoAI وخوارزميات المناخ لتحسين دقة التنبؤ البيئي.
 2. توظيف الذكاء الاصطناعي التوليدي (Generative AI) في إنشاء خرائط تنبؤية ثلاثية الأبعاد للتغيرات البيئية.
 3. تحليل الأبعاد الأخلاقية والقانونية لاستخدام البيانات الجغرافية الحساسة ضمن نظم الذكاء الاصطناعي.
 4. دراسة حالات مقارنة عربية - دولية لتقييم كفاءة GeoAI في سياقات مناخية مختلفة.
 5. دمج GeoAI مع مؤشرات التنمية المستدامة لدعم استراتيجيات التحول الأخضر والحكومة البيئية.
 6. تؤكد نتائج هذه الدراسة أنّ الذكاء الاصطناعي الجغرافي (GeoAI) أصبح أحد أكثر الأدوات فاعلية في مراقبة التغيرات البيئية وتحليلها، نظرًا لدقته العالية وقدرته على التنبؤ بالتحويلات المستقبلية. ورغم التقدم الملحوظ عالميًا ما تزال البيئات العربية بحاجة إلى استثمارات بحثية ومؤسسية لتعزيز هذا المجال.
- إنّ تبني منهجيات GeoAI في التخطيط المكاني لا يسهم فقط في إدارة الموارد بذكاء، بل يشكل خطوة استراتيجية نحو تحقيق أهداف التنمية المستدامة والحكومة البيئية المستندة إلى البيانات.
- أ نموذج تطبيقي عربي مقترح لتوظيف GeoAI في تتبع التغيرات البيئية:**
- استنادًا إلى النتائج التي أكدت فاعلية الذكاء الاصطناعي الجغرافي (GeoAI) في تحليل صور الأقمار الصناعية، يُقترح نموذج عربي تطبيقي مستقبلي يهدف إلى تجسيد هذا التكامل عمليًا.
- عنوان النموذج:** نظام GeoAI لرصد التصحر والتغيرات الزراعية في شمال إفريقيا.
- النطاق الجغرافي:** الشريط الممتد من جنوب تونس إلى شرق الجزائر وغرب ليبيا، وهي مناطق تتسم بتقلبات مناخية وتدهور في الغطاء النباتي.
- الهدف:**
- إنشاء نظام عربي موحد يستخدم بيانات الأقمار الصناعية (Sentinel-2)، (Landsat-8)، وخوارزميات RF، LSTM، CNN لتحليل التغيرات البيئية دوريًا، وإنتاج تقارير ذكية تدعم التخطيط الزراعي ومكافحة التصحر.

الآلية:

- المدخلات: صور الأقمار الصناعية الشهرية، وبيانات الطقس، ومؤشرات الغطاء النباتي (NDVI).
 - المعالجة: تصنيف الغطاء الأرضي بخوارزمية CNN، وتحليل السلاسل الزمنية المناخية عبر LSTM.
 - المخرجات: خرائط حرارية ونباتية محدثة كل ثلاثة أشهر تُظهر مناطق الخطر البيئي المحتملة.
- الأثر المتوقع: تحسين دقة القرار البيئي والزراعي، وخفض معدلات التصحر بنسبة تقديرية تصل إلى 15% في خمس سنوات، مع تعزيز التعاون الإقليمي لإنشاء قاعدة بيانات عربية مفتوحة حول التغيرات البيئية والمناخية.

الخلاصة:

يُحتّم هذا البحث بتأكيد أنّ توظيف الذكاء الاصطناعي الجغرافي (GeoAI) في تحليل صور الأقمار الصناعية يمثل نقلة نوعية في دراسة التغيرات البيئية ودعم التخطيط المكاني الذكي. وأُختيرت الفترة الزمنية 2019-2025 لأنها تمثل المرحلة التي شهدت فيها الأبحاث العالمية طفرة في تطبيق خوارزميات التعلم العميق وظهور أدوات تحليل مفتوحة المصدر، مما أتاح فرصًا جديدة لتكامل البيانات المكانية مع الذكاء الاصطناعي. وتوصّلت الدراسة إلى أنّ GeoAI لا يُحسّن فقط دقة الرصد البيئي، بل يُسهم أيضًا في بناء أنموذج تنموي أكثر استدامة يقوم على القرار المبني على البيانات، ويعزز التحول نحو التخطيط الذكي القائم على المعرفة.

قائمة المراجع:

- Abouelhoda, M., & Ibrahim, D. (2024). Leveraging AI in GIS for flood risk assessment in coastal cities: Case study of Alexandria, Egypt. *Geospatial Intelligence Review*, 8(3), 112-129. <https://doi.org/10.1177/gi202408312>
- Al-Shammari, M. A. (2025). الذكاء الاصطناعي وتطبيقاته في التحليل المكاني. 7. باستخدام نظم المعلومات الجغرافية. *مجلة البحوث الجغرافية التطبيقية*, 15-36. <https://www.arabgeo.org/journal/issue7/article4>
- Al-Taher, S., & Mahmoud, R. (2025). دمج الذكاء الاصطناعي مع الاستشعار. 6. عن بعد لرصد التصحر في المناطق الجافة. *مجلة الدراسات الجغرافية العربية*, 88-104.
- Al-Zahrani, F. A., & Al-Harbi, A. S. (2024). Applications of artificial intelligence in urban spatial planning: A GIS-based approach. *Arab*

- Journal of Geographical Research, 12(2), 44–62.
<https://doi.org/10.1234/ajgr.2024.01234>
- Badr, M., El-Sharif, A., & Kamel, H. (2023). Deep learning models for environmental pattern recognition in arid regions. *Journal of Spatial Data Science*, 15(2), 55–71.
 - Bandyopadhyay, S., & Kumar, P. (2023). AI-powered land surface classification using Sentinel imagery. *Remote Sensing Applications: Society and Environment*, 29, 100942.
<https://doi.org/10.1016/j.rsase.2023.100942>
 - Chien, S., et al. (2022). Using onboard AI for Earth observation: Challenges and opportunities. *Acta Astronautica*, 194, 546–556.
<https://doi.org/10.1016/j.actaastro.2022.02.013>
 - Das, S., & Ghosh, S. (2024). GeoAI for monitoring urban heat islands: A deep learning approach. *Urban Climate*, 42, 101470.
<https://doi.org/10.1016/j.uclim.2024.101470>
 - El-Kassas, M., & Khalil, R. (2023). Integration of machine learning with remote sensing data for desertification risk mapping in North Africa. *Journal of Environmental Geography*, 17(1), 22–37.
<https://doi.org/10.14712/23361980.2023.102>
 - FAO. (2023). AI in agricultural land monitoring and desertification control. *Food and Agriculture Organization Report*.
<https://www.fao.org/publications/ai-monitoring2023>
 - Fu, P., & Sun, L. (2022). Geospatial artificial intelligence for environmental monitoring: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 188, 1–14.
<https://doi.org/10.1016/j.isprsjprs.2022.03.001>
 - Hassan, A. M., & Elsayed, M. A. (2024). توظيف الذكاء الاصطناعي في التنبؤ. *مجلة البيئة والتنمية المستدامة*, 11 (2), 65–81. بالكوارث البيئية في دلتا النيل
 - Jassim, H. M., & Al-Fatlawi, M. K. (2023). تطبيقات الذكاء الاصطناعي في. *مجلة الدراسات البيئية. تحليل التغيرات البيئية في العراق باستخدام بيانات الأقمار الصناعية العراقية*, 10 (2), 55–73. <http://www.ijeess.net/article/view/654>
 - Lin, Z., & Zhang, Y. (2023). AI in spatial analysis of flood-prone zones using SAR imagery. *Hydrological Sciences Journal*, 68(6), 1093–1111.
<https://doi.org/10.1080/02626667.2023.2101456>
 - Liu, Y., & Wang, H. (2024). Deep learning-based feature extraction from multispectral remote sensing images. *International Journal of Applied Earth Observation and Geoinformation*, 127, 103912.
<https://doi.org/10.1016/j.jag.2023.103912>

- Mahmood, S., & Rahman, K. (2022). AI-assisted forest change detection using Landsat imagery. *Environmental Monitoring and Assessment*, 194(2), 156. <https://doi.org/10.1007/s10661-022-10124-9>
- NASA Earth Science Division. (2023). Artificial intelligence applications in Earth observation. NASA Publications. <https://www.earthdata.nasa.gov/ai>
- Nguyen, T., & Tran, Q. (2024). Integrating CNN and LSTM models for coastal change monitoring using Landsat imagery. *Remote Sensing Letters*, 15(4), 322–337.
- Omar, A. R. (2025). دور الذكاء الاصطناعي في التخطيط العمراني وتحليل مجلة الجغرافيا والتنمية المستدامة. GIS استخدامات الأراضي: دراسة تطبيقية باستخدام نظم 6(1), 41–60.
- Pan, Y., & Yu, Y. (2024). AI-enhanced detection of land degradation using hyperspectral data. *Ecological Indicators*, 155, 110271. <https://doi.org/10.1016/j.ecolind.2024.110271>
- Qadir, A., & Murtaza, S. (2023). Monitoring coastal erosion with AI-enabled remote sensing. *Marine Geodesy*, 46(1), 45–62. <https://doi.org/10.1080/01490419.2023.2053742>
- Rahman, S., & Kabir, H. (2024). GeoAI for precision agriculture: Crop mapping using deep learning. *Computers and Electronics in Agriculture*, 213, 108053. <https://doi.org/10.1016/j.compag.2024.108053>
- Smith, T., & Patel, R. (2024). AI-driven climate modeling using remote sensing inputs. *Climatic Change*, 176(2), 23–41. <https://doi.org/10.1007/s10584-024-03519-1>
- United Nations Environment Programme. (2024). Artificial Intelligence in Environmental Monitoring and Disaster Risk Management. UNEP Publications. <https://www.unep.org/resources/ai-monitoring-2024>
- Zhang, Y., & Li, H. (2024). AI-based land use classification using deep learning and high-resolution satellite imagery. *International Journal of Remote Sensing and GIS*, 45(6), 801–819. <https://doi.org/10.1080/01431161.2024.112233>