

دراسة مرجعية لفرص الذكاء الاصطناعي والتعلم الآلي في العلوم البيئية:

أداة تحليلية متقدمة للدراسات الحديثة - مع امثلة تطبيقية

Ali K. M. Al-Nasrawi^{1,2,*}, Ameen Kadhim³, Omar T. Hazzaa⁴,
Mahmoud M. H. Al-Shammari¹, Wisam R. Muttashar⁵, and
Qassim M. Al-Aesawi^{1 (١)}

(ملخص البحث)

تمثل الزيادة الهائلة في وفرة البيانات البيئية وحجمها والتعقيد المتزايد فيها، تمثل تحديات وفرصاً جديدة في مجال علوم الأرض والبيئة. ولأجل تحليل هذا الكم الهائل المعقد من البيانات فإن الذكاء الاصطناعي (Artificial Intelligence (AI والتعلم الآلي (Machine learning (ML) يقدمان مجموعة من الأدوات الفاعلة لتحليلها واستخلاص استنتاجات مرضية بدرجة كبيرة للإدارة البيئية والمراقبة والبحث، وكذلك تساعد هذه الأدوات (AI و ML) على حل الصعوبات وإيجاد العلاقات المكانية والتباينات الزمانية عند تحليل البيانات البيئية. في هذه الدراسة، تم شرح نماذج التعلم العميق المختلفة deep learning models، بما في ذلك الشبكات العصبية ذات الطبقات الالتفافية (Convolutional Neural Networks (CNNs)، والشبكات العصبية المتكررة (Neural Networks (RNNs)، وشبكات الخصومة التوليدية (Generative Adversarial Networks (GANs)، والشبكات العصبية الرسومية (Graph Neural Networks (GNNs))، وأجهزة التشفير التلقائي (Autoencoders) ومزاياها وتطبيقاتها البيئية. تم تسليط الضوء على مجموعة واسعة من المجالات البيئية، بما في ذلك إدارة الموارد المائية، والتخطيط الحضري، ودراسات تغير المناخ، والتنبؤ بالطقس، إذ تسلط هذه الدراسة الضوء على استعمال نماذج التعلم العميق في مجموعة من المجالات البيئية، مثل الكشف عن حالات الطقس الشاذة، والتنبؤ بجودة الهواء، وتحليل البيانات المناخية، وتحليل صور الأقمار الصناعية، ومراقبة النظام البيئي. فضلاً عن ذلك فإن هذه الدراسة سلطت الضوء

¹ Department of Geography, University of Babylon, Hillah, Iraq.

² Environmental Futures Research Centre, School of Earth, Atmospheric and Life Sciences, University of Wollongong, Wollongong, NSW 2522, Australia

³ Department of Applied Geography, College of Education for Human Sciences, University of Karbala

⁴ Agricultural Directorate of Anbar, ministry of Agriculture, Iraq


⁵ Marine Science Centre, University of Basrah, Basrah, Iraq.

* Corresponding author: alial@uow.edu.au

على بعض جوانب بنيات التعلم العميق ومزاياها وعيوبها في التعامل مع التحديات البيئية، بما في ذلك شبكات CNN، وشبكات RNN، وشبكات GAN، وشبكات GNN، وأجهزة التشفير التلقائي، وآليات الانتباه، والمحولات، إذ يؤكد هذا البحث أيضًا على كيفية استعمال أساليب معالجة اللغات الطبيعية (Natural Language Processing (NLP لتحليل البيانات النصية المتعلقة بالاهتمامات البيئية، ويناقش أخيرًا الاتجاهات والصعوبات المتعلقة بدمج الذكاء الاصطناعي وتعلم الآلة في تفسير بيانات علوم الأرض المتعلقة بالظواهر البيئية والجغرافية وتحليلها.

مقدمة :

تشتمل البيئة على تفاعل معقد بين العمليات الفيزيائية والكيميائية والبيولوجية (Aqel et al .، ٢٠٢٤)؛ لذا تعد لغات البرمجة أدوات أساسية لفهم مزيج معقد من هذه العمليات في بيئتنا (Karssenber ٢٠٠٢)، إذ تعتمد الأساليب التحليلية التقليدية للبيانات البيئية في كثير من الأحيان المنهجيات الإحصائية والتفسير البشري (Haining ١٩٩٣). تعد الأساليب التحليلية المتقدمة ضرورية لتزايد حجم البيانات البيئية وتعقيدها من مصادر مختلفة مثل: وسائل التواصل الاجتماعي social media، وشبكات الاستشعار sensor، networks والتصوير عبر الأقمار الصناعية Satellite photography. في هذه الحالة فإن التعلم الآلي (Machine learning (ML والذكاء الاصطناعي artificial intelligence (AI) يوفران علاجًا فاعلاً (Konya & Nematzadeh، ٢٠٢٤)، فالتعلم الآلي (ML) يركز على الخوارزميات التي يمكنها التعلم من البيانات من دون برمجة واضحة، في حين يشير الذكاء الاصطناعي (AI) إلى قدرة الآلات على محاكاة الوظائف المعرفية البشرية (Lipizzi، ٢٠٢٤). يستعمل فرعاً من التعلم الآلي يسمى التعلم العميق (DL) الشبكات العصبية الاصطناعية متعددة الطبقات لاستخراج أنماط معقدة من مجموعات البيانات الضخمة (LeCun et al., 2015; Konya & Nematzadeh، ٢٠٢٤)، إذ تعتمد هياكل DL المختلفة غرض الموديل (Goodfellow et al، ٢٠١٦)، الشكل ١. في ضوء التخصصات البيئية المعاصرة، يدرس هذا البحث إمكانيات واستعمالات نماذج التعلم العميق لعلماء البيئة والتخصصات المكانية.



شكل (١) هياكل نماذج التعلم العميق المختلفة (المصدر: Wang et al., ٢٠٢٠).

١ أطر أو هياكل التعلم العميق للبحوث البيئية Deep Learning Frameworks for Environmental Research


أحدثت هياكل التعلم عن بعد ثورة في البحث البيئي عبر توفير أدوات قوية لتحليل مجموعات البيانات المعقدة وإجراء تنبؤات دقيقة (LeCun et al., ٢٠١٥)، إذ تسمح هذه الهياكل مثل TensorFlow و PyTorch للباحثين ببناء نماذج متطورة يمكنها معالجة كميات كبيرة من البيانات من مصادر مثل: صور الأقمار الصناعية، وأجهزة استشعار الطقس، والمسوحات البيئية (Lipizzi, ٢٠٢٤)، فضلا عن ذلك، تُمكن أطر التعلم عن بعد الباحثين من تطوير حلول مبتكرة للتحديات البيئية، مثل: التخفيف من تغير المناخ والتنبؤ بالكوارث الطبيعية (Goodfellow et al., 2016; Zhao et al., ٢٠٢٤).

١.١ الكشف عن بيئة الشبكات العصبية ذات الطبقات الالتفافية (CNN Unveiling the Environment with Convolutional Neural Networks)

أحدث ظهور الشبكات العصبية ذات الطبقات الالتفافية (CNNs) ثورة في مجال الدراسة البيئية (Franci & McDermott, ٢٠٢٢)؛ لقدرتها الفائقة على تحليل البيانات المرئية، إذ تعد خوارزميات التعلم الآلي هذه مثالية لاستخلاص استنتاجات من الكميات الهائلة من المعلومات التي تم جمعها من المراقبة البيئية والاستشعار عن بعد (Gao et al., ٢٠٢٠). تعمل شبكات CNN على تطوير الأبحاث البيئية في اتجاهات جديدة، إذ يعد فحص الحمض النووي البيئي (eDNA)، أو المواد الوراثية التي تتركها الكائنات وراءها، وسيلة فاعلة لإجراء مسوحات التنوع البيولوجي، عبر تحليل تسلسلات الحمض النووي الموجزة، قد تتمكن شبكات CNN من التعرف بسرعة على الأنواع المتوفرة في النظام


البيئي، مما يؤدي إلى تسريع تقديرات التنوع البيولوجي. وعلى الرغم من ذلك، لا تزال هناك صعوبات؛ بسبب الحاجة إلى مجموعات بيانات كبيرة من الصور الموسومة لتدريب CNN، إذ قد يكون من الصعب الحصول عليها أو أن جمعها باهظ الثمن. فضلا عن ذلك، قد يكون من الصعب فهم "التفكير" الكامن وراء تنبؤات شبكة CNN، والذي يزيد من تقييد المعرفة العلمية. وعلى الرغم من هذه العقبات، تعمل شبكات CNN على إعادة تشكيل مشهد البحوث البيئية، فهي توافر أداة قوية لرؤية كوكبنا، وفهم العمليات البيئية، وفي نهاية المطاف دفع الاستدامة البيئية، ويرجع ذلك في المقام الأول إلى قدرتها الفريدة على اكتشاف الأنماط والعلاقات الزمانية-المكانية المخفية في البيانات المرئية (Borowiec et al., 2022). تعد شبكات CNN قوية؛ لأنها تستطيع التعرف على الأنماط المعقدة في الصور، إذ يمكنها مسح الصور من الأقمار الصناعية أو الطائرات من دون طيار أو مصائد الكاميرا تحت الماء لأتمتة العمليات مثل:

أ. تصنيف الغطاء الأرضي: تعتمد مراقبة إزالة الغابات، ومتابعة التغيرات في استعمال الأراضي، وتقييم صحة النظم البيئية والقدرات التمييز بين الغابات والأراضي العشبية والمناطق الحضرية باستعمال صور الأقمار الصناعية (Wang et al., 2022)، فهي - CNN - ممتازة في هذا المجال، من حيث توفير خرائط للغطاء الأرضي بقدر كبير من التفصيل للباحثين (الشكل ٢).



شكل (٢) مثال على الافادة من الذكاء الاصطناعي لاستعمال الأراضي وتغيير الغطاء الأرضي. (المصدر: Wang et al., 2022).

ب. الكشف عن التهديدات البيئية: يعد تحديد التهديدات البيئية الفوري لحرائق الغابات أو الفيضانات أو تكاثر الطحالب أمراً ضرورياً للتأهب والاستجابة للموقف (Chen et al, ٢٠٢٣)، إذ يمكن لشبكات CNN اكتشاف مؤشرات الإنذار المبكر لهذه المخاطر، والتدخل بسرعة أكبر عبر تحليل صور الأقمار الصناعية والصور الجوية في الوقت الفعلي (الشكل ٣).



شكل (٣) معالجات تغير المناخ استناداً إلى الذكاء الاصطناعي المصدر (Chen et al, ٢٠٢٣)
١.٢ شبكات الذاكرة الطويلة و القصيرة المدى (LSTMs) والشبكات العصبية المتكررة: (RNNs)

تعد شبكات RNN مثالية للتطبيقات التي تتضمن سلاسل زمنية؛ لأنها جيدة بشكل استثنائي في تحليل البيانات التسلسلية (Jung et al, ٢٠٢٠)، يتم التقاط التبعيات طويلة المدى في البيانات بشكل جيد بواسطة نوع معين من RNN يسمى LSTM (Jung et al, ٢٠٢٠). إن لدى RNNs و LSTMs العديد من التطبيقات في البيئة (Jung et al, ٢٠٢٠).

إن أحد العناصر الأساسية التي تشترك فيها تحليلات البيانات المناخية جميعها، ونمذجة تغير المناخ، ومعرفة النظام البيئي، والتنبؤات بجودة الهواء هو الوقت، ففي مجالات عدة، تكون البيانات متسلسلة بشكل طبيعي، إذ تؤثر الملاحظات السابقة في النتائج اللاحقة؛ لذا تعد الشبكات العصبية المتكررة (RNNs)، ولاسيما شبكات الذاكرة طويلة المدى (LSTMs)، مفيدة في هذه الحالة، وتوافر نماذج LSTM أدوات قوية لتقويم السلوك البيئي والتنبؤ به عبر التعلم من الأنماط والتبعيات السابقة، بما في ذلك:

أ. تحليل البيانات المناخية ونمذجة تغير المناخ: تتضمن سجلات المناخ بيانات تاريخية عن درجة الحرارة وهطول الأمطار والعوامل الأخرى المستعملة لتحليل تغير المناخ ونمذجته ، وكثيراً ما يصعب على النماذج التقليدية تمثيل الروابط المعقدة في هذه السلاسل الزمنية (Nwokolo et al، ٢٠٢٤) ؛ لأن نماذج LSTM يمكنها تذكر البيانات السابقة، فهي جيدة بشكل خاص في اكتشاف الأنماط الدورية والاتجاهات طويلة المدى (Liu et al، ٢٠٢٢)، فلديهم القدرة على فحص مجموعات بيانات هائلة للعثور على علاقات غير مكتشفة سابقاً بين المتغيرات المناخية، مما يعزز معرفتنا بكيفية عمل النظام المناخي، وهذه المعرفة ضرورية لإنشاء نماذج مناخية أكثر واقعية:

ب. يمكن للعلماء تحسين توقعاتهم لزيادات درجات الحرارة المستقبلية، وأنماط هطول الأمطار، والظواهر الجوية المتطرفة عبر تضمين تنبؤات LSTM في نماذج تغير المناخ الخاصة بهم (Liu et al، ٢٠٢٢).

ج. الأنظمة البيئية: الأنظمة البيئية هي شبكات معقدة من العناصر المترابطة، إذ يعد تحليل البيانات المتسلسلة أمراً ضرورياً لفهم الأنظمة المختلفة، مثل التفاعلات المعقدة بين الدوران الجوي والمحيطي وديناميكيات المفترس والفريسة في النظم البيئية. ويمكن استعمال البيانات التاريخية من مجموعة متنوعة من المصادر، بما في ذلك شبكات الاستشعار وعمليات رصد الأقمار الصناعية والمسوحات البيئية، لتدريب (LSTMs (Kim et al، ٢٠١٨)، كما يمكن للعلماء التنبؤ بكيفية تأثير التغير في أحد المكونات على النظام بصورة عامة باستعمال LSTMs لمعالجة هذه البيانات (كيم وآخرون، ٢٠١٨) واكتشاف الروابط الفطرية بين هذه الأجزاء، إذ يمكن أن يكون ذلك مفيداً للغاية لإدارة موارد المياه، أو توقع انتشار الأنواع الغريبة، أو تقليل آثار التلوث.

د. التنبؤ بجودة الهواء: يعد التنبؤ بجودة الهواء بدقة أمراً بالغ الأهمية للحفاظ على البيئة والصحة العامة، إذ تؤثر العديد من المتغيرات، مثل حركة المرور والانبعاثات الصناعية وأنماط الطقس، في كمية تلوث الهواء (Wang et al، ٢٠١٩)، فغالباً يصعب على تقنيات التنبؤ التقليدية مراعاة هذه العلاقات المعقدة ، ومن ناحية أخرى، تستطيع LSTMs الحصول على هذه الارتباطات من بيانات جودة الهواء السابقة، فضلاً عن بيانات الطقس والمتغيرات الأخرى ذات الصلة (Wang et al، ٢٠١٩). عن طريق تحليل هذه البيانات، يمكن لـ LSTMs التنبؤ بشكل أكثر دقة بالمستويات المستقبلية لجودة الهواء، مما يسمح للسلطات بإصدار تحذيرات وتنفيذ خطط للمعالجة على الفور.

ولكن هناك قيود، فهناك حاجة إلى مجموعات بيانات كبيرة والكثير من قوة المعالجة لتدريب (Jung et al, LSTMs, ٢٠٢٠)، فضلاً عن ذلك، قد يكون من الصعب تقويم توقعاتهم؛ لأنه ليس من الواضح دائماً كيفية وصولهم إلى نتيجة معينة (Jung et al, ٢٠٢٠)، وعلى الرغم من ذلك، ليس هناك من ينكر فوائد شبكات RNN و LSTMs. تتمتع هذه الأساليب بالقدرة على إحداث تغيير كامل في الطريقة التي نرى البيئة بها ونتحكم بها في أثناء تطورها، إذ يتطلب بناء مستقبل أكثر استدامة استعمال LSTMs و RNNs، مما يبسط تعقيد البيانات البيئية.

١.٣ استعمال الشبكات المتعكسة التوليدية (GANs) في الدراسات البيئية والجغرافية: Using Generative Adversarial Networks (GANs) in environmental and geographical studies

أحدث إدخال تقنيات التعلم الآلي ثورة في مجال الدراسات الجغرافية والبيئية (Wu et al, ٢٠٢٢)، إذ إن هناك صعوبات رئيسة، وهي الشبكات المتعكسة التوليدية (GANs)، يظهر فيها التعلم العميق بشكل جيد في حلها، وهي زيادة البيانات، وتقليص حجم الأنموذج المناخي. تشمل التطبيقات البيئية لشبكات GAN ما يأتي:

١.٣.١ زيادة البيانات: سد الثغرات في البيانات البيئية

قد يكون جمع البيانات البيئية مكلفاً ويستغرق وقتاً طويلاً ومقيداً في نطاقه (Pérez et al, ٢٠٢٣)، وهذا النقص في البيانات يعيق قدرتنا على تطوير نماذج موثوقة للعمليات البيئية، فتوافر شبكات GAN علاجاً فاعلاً عبر زيادة البيانات، ويمكن للشبكة "تعلم" الأنماط والعلاقات الأساسية في البيانات عن طريق التدريب على مجموعات البيانات المتوفرة مسبقاً (Pérez et al, Pérez, ٢٠٢٣) ويمكنه بعد ذلك استعمال هذه المعلومات لإنتاج نقاط بيانات جديدة وواقعية تماماً. يمكن أن تؤدي إضافة هذه البيانات الاصطناعية إلى زيادة كمية مجموعات البيانات وتنوعها المتوفرة بالفعل.

لنأخذ على سبيل المثال دراسة بشأن اتجاهات إزالة الغابات في غابات الأمازون، إذ لا تغطي صور الأقمار الصناعية سوى جزء صغير من الغابة، وإن شبكة GAN المدربة على الصور المتوفرة بالفعل، التي يمكنها تجميع نقاط بيانات إضافية تمثل أماكن لم تتم رؤيتها من قبل، قد تجعل من الممكن إجراء فحص أكثر شمولاً لاتجاهات إزالة الغابات.

١.٣.٢ تقليل حجم نموذج المناخ: سد الفجوة بين العالمية والمحلية:

يمكن التنبؤ بأنماط المناخ طويلة المدى بدقة كبيرة باستعمال نماذج المناخ العالمية (Yuan et al, 2024, Global Climate models (GCMs)). وعلى الرغم من ذلك، غالباً يتم إخفاء التغيرات المحلية المهمة بسبب دقتها التقريبية، وعبر تقليل حجم النماذج المناخية، يمكن لشبكات GAN سد هذه الفجوة، وإلى جانب مطابقة النواتج منخفضة الدقة من نموذج GCM، يمكن استعمال بيانات الأرصاد الجوية عالية الدقة لتدريب شبكة (Yuan et al, 2024, GAN). يمكن لـ GAN بعد ذلك إنتاج بيانات طقس عالية الدقة تتماشى مع الاتجاهات الأكثر عمومية التي ينتجها GCM عبر فهم العلاقة بين هذين المقياسين. تعد المعلومات التي توافرها هذه الإحصائيات المصغرة ضرورية لتقييم التأثير المحلي. على سبيل المثال، يعتمد التخطيط للزراعة وإدارة الموارد المائية بشكل كبير الوعي بالتغيرات الإقليمية المحتملة في أنماط هطول الأمطار.

تعد شبكات GAN تقنية سريعة التطور وستؤثر بشكل كبير في الأبحاث الجغرافية والبيئية، فمع تقدم الأبحاث، من المتوقع أن تجد شبكات GAN استعمالاً في مجالات مثل تحليل تغير الغطاء الأرضي، والتنبؤ بمخاطر الفيضانات، فضلاً عن نمذجة مدى ملائمة الموائل لأنواع المهددة بالانقراض، وعلى الرغم من ذلك، من المهم أن نتذكر أن البيانات التي تنتجها شبكات GAN ليست بديلاً مثالياً للملاحظات الشخصية، ولضمان موثوقية الرؤى الناتجة عن شبكات GAN، سيكون التحقق الدقيق والتكامل مع التقنيات التقليدية أمراً ضرورياً.

١.٤ رسم بياني للشبكات العصبية (GNNs): فك التعقيد البيئي Graph Neural Networks (GNNs): Untangling Environmental Complexity

إن شبكات GNN هي نوع من الشبكات العصبية المصممة لتحليل البيانات المنظمة على شكل رسوم بيانية، إذ تمثل العقد الكيانات (مثل: الأنواع وأجهزة الاستشعار) وتمثل الحواف العلاقات بينها (Rahmani et al, 2023). تمتلك شبكات GNN إمكانيات كبيرة لعلماء الجيولوجيا المكانية الذين يعملون في النظم البيئية وإدارة البنية التحتية، إذ يمكن استعمالها لتحليل الشبكات البيئية المعقدة لتحديد تفاعلات الأنواع ومراقبة التنوع البيولوجي (Rahmani et al, 2023)، فضلاً عن ذلك، تتعامل دراسات الجغرافيا والبيئة مع أنظمة مرتبطة بشكل معقد حينما يتعلق الأمر بتحليل هذه العلاقات المعقدة. لقد بدأت شبكات GNN وهي تقنية فعالة للتعلم الآلي في تغيير اللعبة (Rahmani et al, 2023). يتم في هذا البحث فحص إمكانيات الشبكات GNN في مجالين مهمين - شبكات توزيع المياه

ومراقبة النظام البيئي والتنوع البيولوجي. إذ شملت التطبيقات البيئية لشبكات GNN ما يأتي:

١.٤.١ رصد النظم البيئية والتنوع البيولوجي Monitoring of ecosystems and biodiversity

إن شبكات GNN جيدة جدًا في الافادة من الترابط بين الأنواع وبيئاتها (El-Shawa ٢٠٢٣)؛ لأنها تعتمد في كثير من الأحيان نقاط بيانات معزولة، فإن المراقبة البيئية التقليدية غير قادرة على تمثيل الترابط بين الأنواع وبيئاتها. إن شبكات GNN جيدة جدًا في استغلال هذا الترابط (El-Shawa ٢٠٢٣)، إذ تقوم شبكات GNN بتحليل مجموعات كبيرة من البيانات للعثور على أنماط مخفية عبر وصف النظم البيئية على شكل رسوم بيانية، إذ تمثل العقد الأنواع أو المواقع أو الظروف البيئية وتعكس الحواف العلاقات بينها (El-Shawa ٢٠٢٣).

فلو تم تدريب شبكة GNN باستعمال البيانات المتعلقة بالمجتمعات النباتية، مع توافر حواف تشير إلى التوافر المشترك أو المنافسة والعقد التي تمثل أنواعًا نباتية مختلفة؛ لذا يمكن استعمال GNN لتحديد الأنواع الأساسية، تلك التي لها تأثير كبير بشكل غير متناسب في النظام البيئي، وبالمثل، يمكن لشبكات GNN التنبؤ بالاضطرابات الناجمة عن الأنواع الغازية عن طريق فحص التفاعلات بين مجموعات الحيوانات المفترسة والفرائس (El-Shawa ٢٠٢٣).

١.٤.٢ شبكات توزيع المياه Water distribution networks

هي مضخات وصمامات ومناطات أنابيب معقدة. يعد الفهم الشامل لهذه الأنظمة المترابطة ضروريًا للحفاظ على الكفاءة واكتشاف المشكلات المحتملة؛ لذا تعد شبكات GNN أداة فاعلة لتحسين الشبكة وتحليلها (Xing & Sela, ٢٠٢٢). يمكن لشبكة GNN تحليل أنماط تدفق المياه، وتوقع توزيع الضغوط، واكتشاف التسريبات أو الاختناقات المحتملة عبر تصور الشبكة كرسم بياني، إذ تمثل العقد الوصلات أو الخزانات والحواف التي تمثل خطوط الأنابيب. تعمل هذه المراقبة في الوقت الفعلي على تقليل فقدان المياه وتجعل الصيانة المستهدفة ممكنة (Xing & Sela, ٢٠٢٢). فضلًا عن ذلك، يمكن استعمال شبكات GNN لتحسين توزيع المياه في أثناء حالات الطوارئ مثل الجفاف، فيمكن لشبكات GNN التنبؤ بالارتفاع الكبير في الطلب وضبط تدفق المياه عبر فحص البيانات السابقة واتجاهات الاستهلاك الحالية. وهذا يقلل من الهدر الإجمالي مع ضمان حصول المواقع الحيوية على كمية كافية من المياه (Xing & Sela, ٢٠٢٢). وخلاصة القول،

تتمتع الشبكات GNNs بإمكانات هائلة لتحويل البحوث الجغرافية والبيئية، فإن قدرتهم على تشريح الشبكات المعقدة تفتح الباب أمام فهم أكبر للنظم البيئية وأنظمة توزيع المياه، مما يسهل إدارة الموارد والحفاظ عليها ومراقبتها بشكل أفضل؛ لذا سيكون المستقبل أكثر استدامة مع تقدم تكنولوجيا GNN وإيجاد استعمالات أكبر في هذه المجالات.

١.٥ الكشف عما هو غير عادي: أجهزة التشفير التلقائي للكشف عن الشذوذ في

Unveiling the Unusual: Autoencoders for Anomaly Detection in Environmental and Geographical Studies

تتكون أجهزة التشفير التلقائي Autoencoders من برنامج تشفير يقوم بضغط البيانات إلى تمثيل كامن ذي أبعاد أقل ووحدة فك ترميز تعيد بناء البيانات الأصلية من التمثيل الكامن، يتيح لهم ذلك تعلم التمثيلات المضغوطة للبيانات في أثناء تحديد الحالات الشاذة، وبما أن كوكبنا نظام معقد، فمن الضروري مراقبة حالته، إذ هو المكان الذي تكون فيه الشبكات العصبية الاصطناعية، ولاسيما أجهزة التشفير التلقائي مفيدة. تعد أجهزة التشفير التلقائي رائعة في اكتشاف البنية الأساسية للبيانات، مما يجعلها مثالية لأبحاث الجغرافيا والبيئة، ولاسيما لتحديد الشذوذ (Corizzo et al., ٢٠٢١). تستلزم عملية تحديد الشذوذ بيان نقاط البيانات والتي تختلف بشكل كبير عن المتوسط، ويمكن أن يتخذ هذا أشكالاً عديدة في الظروف البيئية، مثل: الارتفاع غير المتوقع في درجة حرارة سطح البحر أو الزيادة الحادة في تلوث الهواء. يمكن أن يساعد تحديد الحالات الشاذة الدراسات الجغرافية في العثور على تحولات غريبة في الغطاء الأرضي أو الحالات الشاذة في أنماط الطقس. ومن أجل استخراج معظم الميزات الرئيسية من البيانات المدخلة، تقوم أجهزة التشفير التلقائي بضغطها في تمثيل ذي أبعاد أقل، إذ يستعمل جهاز التشفير التلقائي إصدار البيانات المضغوطة هذا لمحاولة استرداد النسخة الأصلية في أثناء إعادة الإعمار (Corizzo et al., ٢٠٢١).

إن خطأ إعادة الإعمار أمر بالغ الأهمية، وإن نقاط البيانات ذات الانحرافات الكبيرة عن الأنماط التي تم تعلمها سيكون لها خطأ أكبر، يصبح خطأ إعادة الإعمار هذا أداة فاعلة لتحديد الشذوذ، وقد تشير المناطق التي بها أخطاء كبيرة في البيانات البيئية إلى حرائق الغابات أو إزالة الغابات أو الحوادث الصناعية، وبالمثل، يمكن استعمال أنماط الأخطاء الفردية في صور الأقمار الصناعية أو بيانات الاستشعار لتحديد الشذوذات الجغرافية مثل: الانهيارات الأرضية أو الفيضانات المفاجئة. وتشمل التطبيقات البيئية لأجهزة التشفير

التقائي اكتشاف الحالات الشاذة، التي تحدد الظواهر البيئية غير العادية، مثل: إنسكابات النفط أو تكاثر الطحالب السامة، إن الطبيعة غير الخاضعة لرقابة أجهزة التشفير التقائي هي ما يجعلها جميلة جدًا، إذ يمكن لأجهزة التشفير التقائي تحديد ما هو "طبيعي" فقط عبر البيانات، على عكس الأساليب القديمة التي تحتاج إلى بيانات مصنفة (عادية مقابل شاذة)، وهذا مفيد للغاية في التحقيقات البيئية والجغرافية، إذ قد يكون من الصعب الحصول على البيانات المصنفة أو تكون باهظة الثمن. يمكن للباحثين معرفة المزيد عن الأنماط المكانية وخطوط الأساس البيئية عبر استعمال أجهزة التشفير التقائي، فيتيح التعرف المبكر على الحالات الشاذة إتخاذ تدابير التخفيف والتدخل الفوري، مما قد يؤدي إلى إنقاذ الأموال والأرواح، وإن من المؤكد أن أجهزة التشفير التقائي ستكون ضرورية لحماية عالمنا مع تقدم الذكاء الاصطناعي البيئي والجغرافي (Corizzo et al., ٢٠٢١).

٢. المجالات البيئية باستعمال نماذج التعلم المتعمق المتعددة والدراسات النموذجية

Environmental Fields Utilising multi-Deep Learning Models and example studies

أظهرت نماذج التعلم العميق (DL)، مثل الشبكات العصبية الالتفافية (CNNs)، والشبكات العصبية المتكررة (RNNs)، و شبكات الخصومة التوليدية (GANs)، والشبكات العصبية الرسومية (GNNS)، وأجهزة التشفير التقائي، وآليات/محولات الانتباه، إمكانيات ملحوظة في التطبيقات البيئية، إذ يقدم كل أنموذج مزايا فريدة تناسب مهام التحليل البيئي المختلفة. يعرض الجدول ١ مجموعة من المقالات العلمية التي تركز على تطبيق التعلم الآلي والذكاء الاصطناعي عبرمختلف المجالات البيئية مثل: الاستشعار عن بعد، وإدارة الموارد المائية، واكتشاف حرائق الغابات، والمزيد. ويوفر كل إدخال معلومات تفصيلية بما في ذلك المؤلفين، وعنوان المقالة، وسنة النشر، واسم المجلة، ومعرف الكائن الرقمي (DOI)، الذي يحدد كل مستند بشكل فريد لسهولة استرجاعه عبر الإنترنت.

جدول (١) نظرة عامة على بعض المقالات العلمية الحديثة التي توضح تطبيق التعلم الآلي والذكاء الاصطناعي في مجالات متنوعة مثل المراقبة البيئية وإدارة الموارد والتحليلات التنبؤية، مما يعرض اتساع نطاق البحث والتطوير في هذه التقنيات.

Authors	Article Title	Year	Journal	DOI
Wang Z.; Zhang J.; Bai L.; Chang H.; Chen Y.; Zhang Y.; Tao J.	A Deep Learning Based Platform for Remote Sensing Images Change Detection Integrating Crowdsourcing and Active Learning	2024	Sensors	10.3390/s24051509
Kamyab H.; Khademi T.; Chelliapan S.; SaberiKamarposhti M.; Rezanian S.; Yusuf M.; Farajnezhad M.; Abbas M.; Hun Jeon B.; Ahn Y.	The latest innovative avenues for the utilization of artificial Intelligence and big data analytics in water resource management	2023	Results in Engineering	10.1016/j.rineng.2023.101566
Thangavel K.; Spiller D.; Sabatini R.; Amici S.; Sasidharan S.T.; Fayek H.; Marzocca P.	Autonomous Satellite Wildfire Detection Using Hyperspectral Imagery and Neural Networks: A Case Study on Australian Wildfire	2023	Remote Sensing	10.3390/rs15030720
Zhang Y.; Tian Y.; Wang D.	Evaluation of rocky desertification degree in karst peak cluster depression based on machine learning	2023	Science of Soil and Water Conservation	10.16843/j.sswc.2023.05.006
Omeka M.E.; Igwe O.; Onwuka O.S.; Nwodo O.M.; Ugar S.I.; Undiandeye P.A.; Anyanwu I.E.	Efficacy of GIS-based AHP and data-driven intelligent machine learning algorithms for irrigation water quality prediction in an agricultural-mine district within the Lower Benue Trough, Nigeria	2023	Environmental Science and Pollution Research	10.1007/s11356-023-25291-3
Liu W.; Wei G.; Wang Y.; Wu R.	Indoor Multipedestrian Multicamera Tracking Based on Fine Spatiotemporal Constraints	2023	IEEE Internet of Things Journal	10.1109/JIOT.2023.3235148

Wang J.; Li K.; Yan X.; Zheng L.; Han X.	Development and prospects of machine learning methods in geographic elements classification; [地理要素分类机器学习方法发展与前景]	2023	National Remote Sensing Bulletin	10.11834/jrs.20232299
Golkarian A.; Khosravi K.; Panahi M.; Clague J.J.	Spatial variability of soil water erosion: Comparing empirical and intelligent techniques	2023	Geoscience Frontiers	10.1016/j.gsf.2022.101456
Yulianto F.; Raharjo P.D.; Pramono I.B.; Setiawan M.A.; Chulafak G.A.; Nugroho G.; Sakti A.D.; Nugroho S.; Budhiman S.	Prediction and mapping of land degradation in the Batanghari watershed, Sumatra, Indonesia: utilizing multi-source geospatial data and machine learning modeling techniques	2023	Modeling Earth Systems and Environment	10.1007/s40808-023-01761-y
Mayanja A.; Eryürük Ş.; Eryürük K.	Using LSTM as Intelligent Machine Learning Method to Forecast the Annual Average Relative Humidity: A Case Study for Konya, Türkiye	2023	Lecture Notes in Networks and Systems	10.1007/978-3-031-39777-6_34
Sameh S.; Elghamrawy S.	An Artificial Intelligent-Based System for Crop Yield Prediction Using Climate Change Data and Sensor Fusion	2023	Lecture Notes on Data Engineering and Communications Technologies	10.1007/978-3-031-43247-7_14
Lu Y.; Chen Q.; Yu M.; Wu Z.; Huang C.; Fu J.; Yu Z.; Yao J.	Exploring spatial and environmental heterogeneity affecting energy consumption in commercial buildings using machine learning	2023	Sustainable Cities and Society	10.1016/j.scs.2023.104586

Maraveas C.; Kotzabasaki M.I.; Bartzanas T.	Intelligent Technologies, Enzyme-Embedded and Microbial Degradation of Agricultural Plastics	2023	AgriEngin eering	10.3390/agrieng ineering501000 6
Cusack M.; Quintos C.; Foster K.; Lomax N.; McCord M.; Wu A.; Yemen C.; Wehrli J.; Zimmerman C.; Bidanset P.; Horne T.; McCluskey W.	A Review of the Methods, Applications, and Challenges of Adopting Artificial Intelligence in the Property Assessment Office	2022	Journal of Property Tax Assessmen t and Administr ation	EID:2-s2.0- 85136632024
Kodikara B.D.E.; Thibotuwa A.; Niles Perera H.; Gamage P.	Comparing the Behaviour of Ensemble Algorithms for Route Optimization in Last- Mile Deilivery Considering the Weather Condition and Holiday Effect	2022	6th SLAAI - International Conference on Artificial Intelligence, SLAAI- ICAI-2022	10.1109/SLAAI - ICAI56923.202 2.10002604
Zhang B.	Intelligent photogrammetry for digital elevation model production	2021	Proceedings of SPIE - The International Society for Optical Engineering	10.1117/12.259 5802
Reddy D.J.; Kumar M.R.	Crop yield prediction using machine learning algorithm	2021	Proceedings - 5th International Conference on Intelligent Computing and Control Systems, ICICCS 2021	10.1109/ICICC S51141.2021.94 32236
Rahmati O.; Panahi M.; Ghiasi S.S.; Deo R.C.; Tiefenbacher J.P.; Pradhan B.; Jahani A.; Goshtasb H.; Kornejady A.; Shahabi H.; Shirzadi A.; Khosravi H.; Moghaddam D.D.; Mohtashamian M.; Tien Bui D.	Hybridized neural fuzzy ensembles for dust source modeling and prediction	2020	Atmospher ic Environme nt	10.1016/j.atmos env.2020.11732 0


Bigham B.S.; Mazaheri S.	A Survey on Measurement Metrics for Shape Matching Based on Similarity, Scaling and Spatial Distance	2020	Lecture Notes on Data Engineering and Communicat ions Technologie s	10.1007/978-3- 030-37309-2_2
Farroha J.S.; Farroha B.S.	Enabling intelligent battlefield healthcare through secure cyber medicine	2019	Proceedings of SPIE - The International Society for Optical Engineering	10.1117/12.251 6021
Sanikhani H.; Deo R.C.; Samui P.; Kisi O.; Mert C.; Mirabbasi R.; Gavili S.; Yaseen Z.M.	Survey of different data- intelligent modeling strategies for forecasting air temperature using geographic information as model predictors	2018	Computers and Electronic s in Agricultur e	10.1016/j.comp ag.2018.07.008
Coronel A.D.; Estuar M.R.E.; Garcia K.K.P.; Dela Cruz B.L.T.; Torrijos J.E.; Lim H.P.M.; Abu P.A.R.; Victorino J.N.C.	Streamlining machine learning in mobile devices for remote sensing	2017	Proceedings of SPIE - The International Society for Optical Engineering	10.1117/12.227 9061
Iyengar S.; Sharma N.; Irwin D.; Shenoy P.; Ramamritham K.	A cloud-based black- box solar predictor for smart homes	2017	ACM Transaction s on Cyber- Physical Systems	10.1145/300405 6
Yang L.; Jia K.; Liang S.; Liu J.; Wang X.	Comparison of four machine learning methods for generating the glass fractional vegetation cover product from modis data	2016	Remote Sensing	10.3390/rs8080 682
	International Conference on Artificial Intelligence and Evolutionary Algorithms in Engineering Systems, ICAEES 2014.	2015	Advances in Intelligent Systems and Computing	EID:2-s2.0- 84920517752

	2014 3rd International Conference on Material Science, Environment Science and Computer Science, MSESCS 2014	2014	Advanced Materials Research	EID:2-s2.0-84892753533
Csépe Z.; Makra L.; Voukantsis D.; Matyasovszky I.; Tusnády G.; Karatzas K.; Thibaudon M.	Predicting daily ragweed pollen concentrations using Computational Intelligence techniques over two heavily polluted areas in Europe	2014	Science of the Total Environment	10.1016/j.scitotenv.2014.01.056

٣. بعض الأمثلة عن المجالات البيئية التي تستعمل مجموعة من أدوات الذكاء الاصطناعي والتعلم الآلي.

٢.١ تحليل الطقس والتنبؤ به Weather Analysis and Forecasting

تعمل تقنيات الذكاء الاصطناعي والتعلم الآلي على تسهيل التحليل الدقيق للطقس والتنبؤ به عبر استيعاب كميات هائلة من بيانات الأرصاد الجوية (Chattopadhyay et al., ٢٠٢٠)، إذ تقوم شبكات CNN (الشكل ٤) وشبكات RNN بمعالجة بيانات الطقس المكانية والزمانية للتنبؤ بأنماط الطقس قصيرة المدى والطويلة، مما يتيح إصدار التحذيرات في الوقت المناسب واستراتيجيات إدارة المخاطر.



شكل (٤) رسم توضيحي تخطيطي لبنية شبكتنا العصبية الالتفافية (CNN) المصممة للتنبؤ بالطقس المتقدم، (المصدر: Chattopadhyay et al., ٢٠٢٠).

٢.٢ تأثيرات تغير المناخ وتغيرات الغطاء الأرضي Climate Change Influences and Land Cover Changes

تعد نماذج التعلم العميق DL، ولاسيما شبكات CNN وشبكات GAN، مفيدة في تحليل صور الأقمار الصناعية لرصد تأثيرات تغير المناخ وتغيرات الغطاء الأرضي. توافر هذه النماذج رؤى بشأن إزالة الغابات، والتوسع الحضري، وفقدان الموائل، مما يساعد على جهود الحفظ وممارسات الإدارة المستدامة للأراضي.

٢.٣ إدارة الموارد المائية Water Resources Management


تدعم خوارزميات الذكاء الاصطناعي/التعلم الآلي (AI/ML) الإدارة الفاعلة للموارد المائية عن طريق تحليل البيانات الهيدرولوجية وتحسين أنظمة توزيع المياه، إذ يتم استعمال شبكات GNN لنمذجة شبكات المياه المعقدة، واكتشاف التسربات، والتخطيط لترقية البنية التحتية، مما يضمن إمدادات مياه موثوقة ومستدامة (Chen et al., ٢٠٢١).

٢.٤ أحواض تصريف الأنهار، الجريان السطحي، المعلمات الجيومورفولوجية Rivers Catchments, Runoff, Geomorphic Parameters

يتم تعزيز تحليل أحواض تصريف الأنهار والجريان السطحي والمعلمات الجيومورفولوجية عبر تقنيات الذكاء الاصطناعي/التعلم الآلي (AI/ML)، إذ تقوم شبكات CNN وشبكات GNN بمعالجة البيانات المكانية لتقييم الدورات الهيدرولوجية، ونقل الرواسب، وأنماط التآكل، وتوجيه استراتيجيات إدارة أحواض تصريف المياه وتدابير التخفيف من مخاطر الفيضانات (Chen et al., ٢٠٢١).

٢.٥ ديناميكية البيئة الساحلية وحركات الشواطئ Coastal Environment Dynamism and Shoreline Movements


تعد نماذج التعلم العميق DL محورية في مراقبة التغيرات الساحلية وحركات الخط الساحلي باستعمال صور الأقمار الصناعية وبيانات الاستشعار عن بعد (Gao et al., ٢٠٢٣; Chowdhury et al., 2020). إذ تكتشف شبكات CNN و RNN التغيرات الساحلية ونقاط التآكل الساخنة وتأثيرات ارتفاع مستوى سطح البحر، مما يدعم إدارة المناطق الساحلية وتخطيط التكيف (Ham et al., ٢٠٢١)، شكل ٥.



شكل (٥) تطبيق الذكاء الاصطناعي والتعلم العميق على دراسة التغيرات المورفولوجية الساحلية وتغير المناخ: التفاعلات الإقليمية (المصدر: Chowdhury et al., ٢٠٢٣).

٢.٦ مواضيع ارتفاع مستوى سطح البحر Sea Level Rise Issues


تساعد منهجيات الذكاء الاصطناعي/التعلم الآلي AI/ML في تقويم ومعالجة تحديات ارتفاع مستوى سطح البحر عبر تحليل البيانات التاريخية والتنبؤ بالاتجاهات المستقبلية (الشكل ٦). إذ تمثل شبكات RNN وشبكات GAN أنموذجًا لتغيرات مستوى سطح البحر، ومخاطر الغمر، ونقاط الضعف الساحلية (Ham et al., ٢٠٢١)، مما يسترشد به في تخطيط البنية التحتية الساحلية واستراتيجيات التكيف (Nieves et al., ٢٠٢١).



شكل (٦) استعمال التعلم الآلي للتنبؤ بالتغيرات في مستوى سطح البحر بشأن المناطق الساحلية، (المصدر: Ham et al., 2021; Nieves et al., ٢٠٢١).

٢.٧ الجغرافيا الطبيعية والنظم الطبيعية Physical Geography and Natural Systems


يشمل تطبيق الذكاء الاصطناعي/التعلم الآلي AI/ML في الجغرافيا الطبيعية تحليل التضاريس، ونمذجة النظام البيئي، وتقويم المخاطر الطبيعية (الشكل ٧)، إذ تسهل نماذج التعلم العميق تفسير البيانات الجغرافية المكانية، مما يتيح توصيف الأشكال الأرضية ونقاط التنوع البيولوجي الساخنة والمخاطر الجيولوجية (Gonzales-Inca et al., ٢٠٢٢).



شكل (٧) أصبح تفسير البيانات الجغرافية المكانية أسهل بفضل نماذج التعلم العميق، التي تجعل من الممكن وصف الأشكال الأرضية، ونقاط التنوع البيولوجي الساخنة، والمخاطر الجيولوجية.

٢.٨ الجغرافيا البيئية وإدارة الموارد Environmental Geography and Resource Management

تدعم تقنيات الذكاء الاصطناعي/التعلم الآلي AI/ML دراسات الجغرافيا البيئية عبر تحليل أنماط استعمال الأراضي، وتوزيع الموارد، ومؤشرات الجودة البيئية (الشكل ٨)، إذ تحدد شبكات CNN وأجهزة التشفير التلقائي الحالات الشاذة البيئية، وتقيم مستويات التلوث، وتحسن استراتيجيات تخصيص الموارد (Zhu et al., 2017; Gao et al., ٢٠٢٠).



شكل (٨) التعلم العميق في مجال الاستشعار البيئي عن بعد: التحديات والابتكارات والإنجازات (المصدر: Zhu et al, ٢٠١٧).

٢.٩ الجغرافيا الحضرية/الاقتصادية Urban/Economic Geography

في الجغرافيا الحضرية والاقتصادية، تساعد نماذج الذكاء الاصطناعي/التعلم الآلي على نمذجة النمو الحضري، وتخطيط النقل، وتحليل التنمية الاقتصادية (الشكل ٩)، إذ تقوم شبكات GAN وآليات الاهتمام بتحليل البيانات المكانية والعوامل الاجتماعية والاقتصادية، مما يسهل التخطيط للمرونة الحضرية ومبادرات التنمية المستدامة (Alahi et al, ٢٠٢٣).



شكل (٩) الذكاء الاصطناعي في التخطيط الحضري: إحداث ثورة في الكفاءة والاستدامة وجودة الحياة (المصدر: Alahi et al, ٢٠٢٣).

٢.١.٠ الجغرافيا التاريخية/الاجتماعية/الثقافية Historical/Social/Cultural Geography

تساهم منهجيات الذكاء الاصطناعي/التعلم الآلي في أبحاث الجغرافيا التاريخية والاجتماعية والثقافية عبر تحليل الخرائط التاريخية والبيانات الأرضية ومحتوى الوسائط الاجتماعية (الشكل ١٠)، إذ تستخرج شبكات RNN والمحولات الأنماط الزمنية والرؤى الثقافية، مما يؤدي إلى إثراء الروايات التاريخية والدراسات الاجتماعية والثقافية (Moira) (٢٠٢٣).

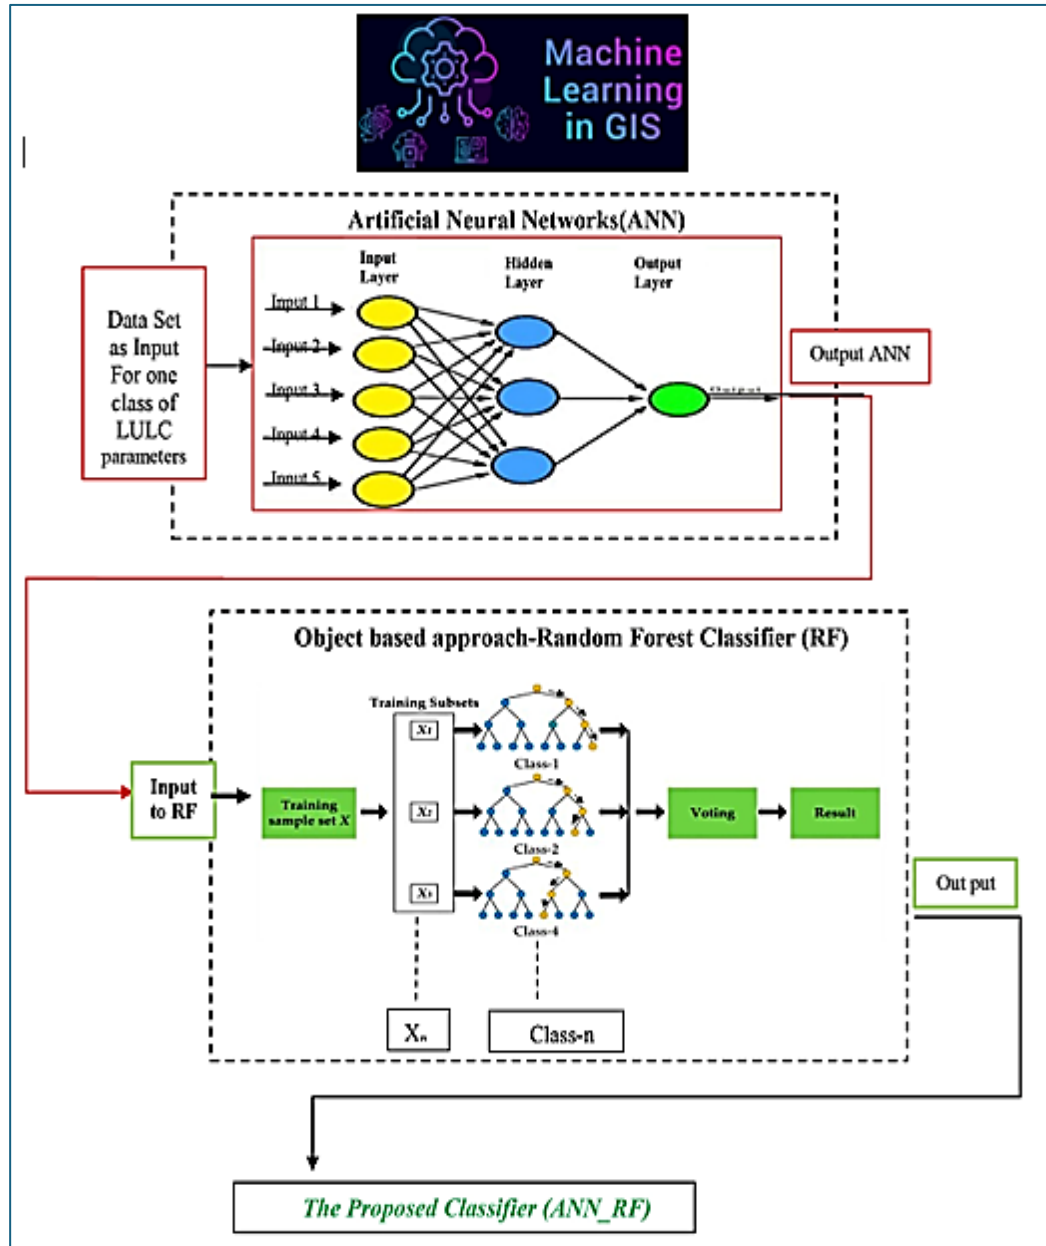


شكل (١٠) كيف يساعد الذكاء الاصطناعي المؤرخين على فهم ماضيها بشكل أفضل (المصدر: Moira: ٢٠٢٣).

٢.١.١ نظم المعلومات المكانية Spatial Information Systems

تعمل نماذج التعلم العميق DL على تعزيز أنظمة المعلومات المكانية عن طريق التجزئة الدلالية semantic segmentation واكتشاف الأشياء وتحليل البيانات المكانية (Alshari et al., ٢٠٢٣)، إذ تعمل شبكات CNN وشبكات GNN على أتمتة إنتاج


الخرائط، وتعزيز قواعد البيانات الجغرافية المكانية، وتمكين مراقبة الظواهر البيئية في الوقت الفعلي (الشكل ١١).



شكل (١١) التعلم العميق في التحليل الجغرافي المكاني وتصنيف استعمال الأراضي/الغطاء الأرضي باستعمال الذكاء الاصطناعي (ANN-RF). (المصدر: Alshari et al ، ٢٠٢٣).

٢.١٢ أدوات رسم الخرائط ورسم الخرائط Cartography and Mapping Tools

تُحدث خوارزميات الذكاء الاصطناعي/التعلم الآلي ثورة في أدوات رسم الخرائط، ورسم الخرائط من خلال أتمتة إنشاء الخرائط واستخراج المعالم ومهام التحليل المكاني (الشكل ١٢)، إذ تعمل شبكات CNN وأجهزة التشفير التلقائي على تحسين دقة الخرائط وتسهيل التصور ثلاثي الأبعاد ودعم اتخاذ القرار في التخطيط والإدارة الجغرافية المكانية.



شكل (١٢) رسم خريطة الكوكب باستعمال الذكاء الاصطناعي AI والتحليلات الخلوية Raster Analytics (تدمج Esri هياكل الذكاء الاصطناعي الشائعة جميعها في نظم المعلومات الجغرافية). وباستعمال البيانات المتاحة، يتم إنشاء مجموعات بيانات التدريب المسمى دمج هياكل التعلم العميق مثل TensorFlow وCNTK. كما يتم الكشف عن أفضل الطرائق لاستعمال أدوات الذكاء الاصطناعي للقيام بالمهام الحكومية النموذجية: - الغطاء الأرضي الديناميكي - نقل التعلم لاكتشاف الأشياء - استخراج الميزات تلقائياً (المصدر: <https://www.esri.com>).

٣ الاستنتاجات Conclusion

توافر تقنيات الذكاء الاصطناعي والتعلم الآلي فرصًا غير مسبوقة لتطوير الدراسات البيئية عبر مختلف المجالات، ومن خلال تسخير قدرات نماذج التعلم العميق، يمكن للباحثين والممارسين اكتساب رؤى أعمق، واتخاذ قرارات مستنيرة، ومعالجة التحديات البيئية الملحة بفعالية. وعلى الرغم من ذلك، فإن البحث والتعاون المستمرين ضروريان لإطلاق الإمكانيات الكاملة للذكاء الاصطناعي/التعلم الآلي في علوم الأرض وضمان الإدارة البيئية المستدامة للأجيال القادمة، ممكن أن يُستنتج هنا بالتأكيد على الإمكانيات التحويلية للذكاء الاصطناعي/التعلم الآلي في الدراسات البيئية ويؤكد الحاجة على مزيد من البحث والتعاون. وأخيرًا، هناك إمكانيات هائلة لإحداث ثورة في البحوث البيئية والجغرافية عبرالمزوجة بين نماذج التعلم العميق المتعددة والمجالات البيئية، وباستعمال هذه التكنولوجيا، يمكن للمرء أن يتخذ قرارات مدروسة عن طريق التحليل، والتنبؤ، وفهم تعقيدات الديناميكيات الساحلية والأنماط التاريخية، فضلًا عن التنبؤ بالطقس وإدارة الموارد. تتمتع هذه التقنية بالقدرة على تعزيز فهمنا والعناية بأنظمة الكوكب المعقدة بشكل كبير مع استمرار الدراسة والتطبيقات.

المراجع References

- Alahi, M.E.E., Sukkuea, A., Tina, F.W., Nag, A., Kurdthongmee, W., Suwannarat, K. and Mukhopadhyay, S.C., 2023. Integration of IoT-enabled technologies and artificial intelligence (AI) for smart city scenario: recent advancements and future trends. *Sensors*, 23(11), p.5206. <https://doi.org/10.3390/s23115206>
- Alshari, E.A., Abdulkareem, M.B. and Gawali, B.W., 2023. Classification of land use/land cover using artificial intelligence (ANN-RF). *Frontiers in Artificial Intelligence*, 5, p.964279. <https://doi.org/10.3389/frai.2022.964279>
- Aqel, H., Sannan, N., Al-Hunaiti, A. and Fodah, R., 2024. Integrated water quality dynamics in Wadi Hanifah: Physical, chemical, and biological perspectives. *Plos one*, 19(2), p.e0298200. <https://doi.org/10.1371/journal.pone.0298200>
- Borowiec, M.L., Dikow, R.B., Frandsen, P.B., McKeeken, A., Valentini, G. and White, A.E., 2022. Deep learning as a tool for ecology and evolution. *Methods in Ecology and Evolution*, 13(8), pp.1640-1660. <https://doi.org/10.1111/2041-210X.13901>
- Chattopadhyay, A., Hassanzadeh, P. and Pasha, S., 2020. Predicting clustered weather patterns: A test case for applications of convolutional neural networks to spatio-temporal climate data. *Scientific reports*, 10(1), p.1317. <https://doi.org/10.1038/s41598-020-57897-9>
- Chen, L., Chen, Z., Zhang, Y., Liu, Y., Osman, A.I., Farghali, M., Hua, J., Al-Fatesh, A., Ihara, I., Rooney, D.W. and Yap, P.S., 2023. Artificial intelligence-based solutions for climate change: a review. *Environmental Chemistry Letters*, 21(5), pp.2525-2557. <https://doi.org/10.1007/s10311-023-01617-y>

Chen, X., Ma, L., & Li, H., 2021. Applications of deep learning in hydrological modeling: A review. *Journal of Hydrology*, 592, 125903.

Chowdhury, P., Lakku, N.K.G., Lincoln, S., Seelam, J.K. and Behera, M.R., 2023. Climate change and coastal morphodynamics: Interactions on regional scales. *Science of The Total Environment*, p.166432. <https://doi.org/10.1016/j.scitotenv.2023.166432>

Corizzo, R., Ceci, M., Pio, G., Mignone, P. and Japkowicz, N., 2021, October. Spatially-aware autoencoders for detecting contextual anomalies in geo-distributed data. In *International conference on discovery science* (pp. 461-471). Cham: Springer International Publishing. https://link.springer.com/chapter/10.1007/978-3-030-88942-5_36

El- Shawa, S., 2023. *Exploring and Predicting Plant-Arthropod Interactions: Hierarchical Modelling of Species Communities and Graph Neural Network Approaches* (Doctoral dissertation, University of Guelph). <https://hdl.handle.net/10214/27633>

Franc, A. and McDermott, J.H., 2022. Deep neural network models of sound localization reveal how perception is adapted to real-world environments. *Nature human behaviour*, 6(1), pp.111-133. <https://doi.org/10.1038/s41562-021-01244-z>

Gao, J., Tang, Y., & Liu, H., 2020. Applications of Deep Learning in Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 166, 305-317.

Gonzales-Inca, C., Calle, M., Croghan, D., Torabi Haghighi, A., Marttila, H., Silander, J. and Alho, P., 2022. Geospatial artificial intelligence (GeoAI) in the integrated hydrological and fluvial systems modeling: Review of current applications and trends. *Water*, 14(14), p.2211. <https://doi.org/10.3390/w14142211>

Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y., 2016. *Deep learning* (Vol. 1). MIT press Cambridge.

Haining, R.P., 1993. *Spatial data analysis in the social and environmental sciences*. Cambridge university press. Book, ISBN: 0521384168.

Ham, Y., Kim, H., & Chae, H. D., 2021. Deep learning in coastal science and engineering: A review. *Coastal Engineering*, 167, 103815.

Jung, Y., Jung, J., Kim, B. and Han, S., 2020. Long short-term memory recurrent neural network for modeling temporal patterns in long-term power forecasting for solar PV facilities: Case study of South Korea. *Journal of Cleaner Production*, 250, p.119476. <https://doi.org/10.1016/j.jclepro.2019.119476>

Karssenber, D., 2002. The value of environmental modelling languages for building distributed hydrological models. *Hydrological Processes*, 16(14), pp.2751-2766. <https://doi.org/10.1002/hyp.1068>

Kim, K., Kim, D.K., Noh, J. and Kim, M., 2018. Stable forecasting of environmental time series via long short term memory recurrent neural network. *IEEE Access*, 6, pp.75216-75228. DOI: [10.1109/ACCESS.2018.2884827](https://doi.org/10.1109/ACCESS.2018.2884827)

Konya, A. and Nematzadeh, P., 2024. Recent applications of AI to environmental disciplines: A review. *Science of The Total Environment*, 906, p.167705. <https://doi.org/10.1016/j.scitotenv.2023.167705>

LeCun, Y., Bengio, Y., & Hinton, G., 2015. Deep learning. *Nature*, 521(7553), 436-444.

Lipizzi, C., 2024. AI and Machine Learning. In *Societal Impacts of Artificial Intelligence and Machine Learning* (pp. 19-29). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-031-53747-9_3

Liu, Y., Li, D., Wan, S., Wang, F., Dou, W., Xu, X., Li, S., Ma, R. and Qi, L., 2022. A long short-term memory-based model for greenhouse climate prediction. *International Journal of Intelligent Systems*, 37(1), pp.135-151. <https://doi.org/10.1002/int.22620>

Moira D., 2023. How AI is helping historians better understand our past. The historians of tomorrow are using computer science to analyze how people lived centuries ago, *MTI Technology Review*. <https://www.technologyreview.com/2023/04/11/1071104/ai-helping-historians-analyze-past/>

Nieves, V., Radin, C. and Camps-Valls, G., 2021. Predicting regional coastal sea level changes with machine learning. *Scientific reports*, 11(1), p.7650. <https://doi.org/10.1038/s41598-021-87460-z>

Nwokolo, S.C., Meyer, E.L. and Ahia, C.C., 2024. Exploring the Interactive Influences of Climate Change and Urban Development on the Fraction of Absorbed Photosynthetically Active Radiation. *Atmosphere*, 15(3), p.253. <https://doi.org/10.3390/atmos15030253>

Pérez, J., Arroba, P. and Moya, J.M., 2023. Data augmentation through multivariate scenario forecasting in Data Centers using Generative Adversarial Networks. *Applied Intelligence*, 53(2), pp.1469-1486. <https://doi.org/10.1007/s10489-022-03557-6>

Rahmani, S., Baghbani, A., Bouguila, N. and Patterson, Z., 2023. Graph neural networks for intelligent transportation systems: A survey. *IEEE Transactions on Intelligent Transportation Systems*. DOI: [10.1109/TITS.2023.3257759](https://doi.org/10.1109/TITS.2023.3257759)

Wang F., Zhang M., Wang X., Ma X., and Liu J., 2020. "Deep Learning for Edge Computing Applications: A State-of-the-Art Survey," in *IEEE Access*, vol. 8, pp. 58322-58336. Doi: [10.1109/ACCESS.2020.2982411](https://doi.org/10.1109/ACCESS.2020.2982411).

Wang, B., Kong, W., Guan, H. and Xiong, N.N., 2019. Air quality forecasting based on gated recurrent long short term memory model in Internet of Things. *IEEE Access*, 7, pp.69524-69534. DOI: [10.1109/ACCESS.2019.2917277](https://doi.org/10.1109/ACCESS.2019.2917277)

Wang, J., Bretz, M., Dewan, M.A.A. and Delavar, M.A., 2022. Machine learning in modelling land-use and land cover-change (LULCC): Current status, challenges and prospects. *Science of The Total Environment*, 822, p.153559. <https://doi.org/10.1016/j.scitotenv.2022.153559>

Wu, A.N., Stouffs, R. and Biljecki, F., 2022. Generative Adversarial Networks in the built environment: A comprehensive review of the application of GANs across data types and scales. *Building and Environment*, 223, p.109477. <https://doi.org/10.1016/j.buildenv.2022.109477>

Xing, L. and Sela, L., 2022. Graph neural networks for state estimation in water distribution systems: Application of supervised and semisupervised learning. *Journal of Water Resources Planning and Management*, 148(5), p.04022018. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001550](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001550)

Yuan, S., Feng, X., Mu, B., Qin, B., Wang, X. and Chen, Y., 2024. A generative adversarial network-based unified model integrating bias correction and downscaling for global SST. *Atmospheric and Oceanic Science Letters*, 17(1), p.100407. <https://doi.org/10.1016/j.aosl.2023.100407>

Zhao, A.P., Li, S., Cao, Z., Hu, P.J.H., Wang, J., Xiang, Y., Xie, D. and Lu, X., 2024. AI for Science: Predicting Infectious Diseases. *Journal of Safety Science and Resilience*. <https://doi.org/10.1016/j.jnlssr.2024.02.002>

Zhu, X.X., Tuia, D., Mou, L., Xia, G.S., Zhang, L., Xu, F. and Fraundorfer, F., 2017. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE geoscience and remote sensing magazine*, 5(4), pp.8-36. DOI: [10.1109/MGRS.2017.2762307](https://doi.org/10.1109/MGRS.2017.2762307)

Artificial Intelligence and Machine Learning opportunities in Geo-environmental Sciences: Advanced analytical tool of Modern studies. A Review

Ali K. M. Al-Nasrawi^{1,2,*}, Ameen Kadhim³, Omar T. Hazzaa⁴, Mahmoud M. H. Al-Shammari¹, Wisam R. Muttashar⁵, and Qassim M. Al-Aesawi¹

¹ Department of Geography, University of Babylon, Hillah, Iraq.

² Environmental Futures Research Centre, School of Earth, Atmospheric and Life Sciences, University of Wollongong, Wollongong, NSW 2522, Australia

³ Department of Applied Geography, College of Education for Human Sciences, University of Karbala

⁴ Agricultural Directorate of Anbar, ministry of Agriculture, Iraq

⁵ Marine Science Centre, the University of Basrah, Basrah, Iraq.

* Corresponding author: alial@uow.edu.au

Abstract

The ever-growing volume and complexity of environmental data presents new challenges and opportunities in geosciences. Machine learning (ML) and artificial intelligence (AI) provide a set of potent tools for analysing this data and deriving insightful conclusions for environmental management, monitoring, and research. The difficulties in analysing environmental data and how AI and ML might help. The various deep learning models, including Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), Generative Adversarial Networks (GANs), Graph Neural Networks (GNNs), Autoencoders and their advantages and environmental applications were succinctly explained in this work. A wide range of environmental domains, including water resource management, urban planning, climate change studies, and weather forecasting, are highlighted in Compelling Applications. This study investigates the use of deep learning models in a range of environmental domains, such as anomaly detection, air quality forecasting, climate data analysis, satellite image analysis, and ecosystem monitoring. Conversely, it addresses the various deep learning architectures and their advantages and disadvantages in handling environmental challenges, including (CNNs, RNNs, GANs, GNNs, and autoencoders) Attention Mechanisms, and Transformers. This work also emphasises how Natural Language Processing (NLP) methods can be used to analyse textual data pertaining to environmental concerns. Lastly, it discusses the directions and difficulties for incorporating AI and ML into the geosciences workflow for datasets related to environmental and geographical phenomena.

Keywords: environmental sciences, GPU computing, earth observations, BIG DATA processing, geoinformatics AI, geospatial artificial intelligence (GeoAI).