

تطبيقات الذكاء الاصطناعي في علوم الأرض

Applications of Artificial Intelligence in Earth Sciences



عبد الله بن محمد العمري

قسم الجيولوجيا والجيوفيزياء - كلية العلوم - جامعة الملك سعود

١٤٤٥ هـ - ٢٠٢٤ م



www.alamrigeo.com



ح عبد الله بن محمد العمري، ١٤٤٥هـ

فهرسة مكتبة الملك فهد الوطنية أثناء النشر

العمري ، عبدالله بن محمد

تطبيقات الذكاء الاصطناعي في علوم الأرض. / عبدالله بن محمد

العمري - ط ١ - الرياض، ١٤٤٥هـ

٣٧٤ صفحة ، ٢١ X ٢٧ سم

ردمك: ١-٠٤٥٤-٠٥-٠٣-٦٠٣-٩٧٨ رقم الإيداع ٢٢٢٦٤ / ١٤٤٥

حقوق الطبع محفوظة للمؤلف

الطبعة الأولى

١٤٤٥هـ / ٢٠٢٤م

للنشر
العبيكان
Obekan
Publishing

للاستفسارات والملاحظات: الاتصال على المؤلف

alamri.geo@gmail.com

www.alamrigeo.com

هاتف : +966505481215

جميع الحقوق محفوظة، ولا يسمح بإعادة إصدار هذه الموسوعة أو نقلها في أي شكل أو واسطة، سواء أكانت إلكترونية أو ميكانيكية بما في ذلك التصوير بالنسخ (فوتوكوبي)، أو التسجيل، أو التخزين والاسترجاع، دون إذن خطي من المؤلف.



بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



الصفحة	المحتويات
7	❖ مقدمة
9	❖ أساسيات الذكاء الاصطناعي
23	❖ مبادئ الذكاء الاصطناعي الكلاسيكي
35	❖ المنطق الضبابي
43	❖ البحث الشامل
61	❖ أهمية استخدام الذكاء الاصطناعي في علوم الأرض
64	❖ تقنيات الذكاء الاصطناعي (تعليم الآلة)
68	❖ الأبحاث الحالية حول الذكاء الاصطناعي في علوم الأرض
68	♦ الغلاف الصخري
68	♦ البراكين
69	♦ الانهيارات الأرضية
70	♦ الغلاف المائي
72	♦ الغلاف الجوي
72	♦ الأعاصير
73	♦ حرائق الغابات
74	♦ العواصف الترابية
75	♦ ملوثات الهواء
75	♦ المحيط الحيوي
78	♦ الغلاف الجليدي
79	♦ علم المحيطات
81	❖ البيانات الضخمة وإدارتها في علوم الأرض
84	♦ تعريفات البيانات الضخمة
87	♦ خصائص البيانات الضخمة
91	♦ البيانات الضخمة لرصد الأرض
94	♦ تحديات تحليلات البيانات الضخمة لعلوم الأرض: نهج EarthServer

الصفحة	المحتويات
96	❖ تحديات تحليل بيانات علوم الأرض
124	❖ الذكاء الاصطناعي والاستكشاف الجيولوجي
124	♦ تحليل البيانات وتفسيرها
126	♦ أتمتة عمليات الاستكشاف
133	❖ استخدام الذكاء الاصطناعي في معالجة المعادن واستكشافها
142	❖ دور الذكاء الاصطناعي في استكشاف النفط والغاز
150	❖ دور الذكاء الاصطناعي في استكشاف المياه الجوفية
175	❖ دور الذكاء الاصطناعي في تقييم المخاطر الجيولوجية
190	❖ تحليل البيانات الجيوفيزيائية بواسطة الذكاء الاصطناعي
194	♦ التطبيقات الجيوفيزيائية للتعلم العميق
200	❖ دور الذكاء الاصطناعي في تصنيف الصخور والمعادن
211	❖ الذكاء الاصطناعي في مجال صناعة النفط والغاز
215	♦ كيف يقوم الذكاء الاصطناعي بتغيير المنبع؟
239	❖ التحديات والفرص المستقبلية للذكاء الاصطناعي في علوم الأرض
267	❖ الذكاء الاصطناعي ودوره في البيئة
291	❖ دور الذكاء الاصطناعي في الجيوفيزياء التطبيقية والزلازل
312	❖ مخاطر الذكاء الاصطناعي
326	❖ دور الذكاء الاصطناعي في التنمية المستدامة
328	♦ تطبيقات الذكاء الاصطناعي في التنوع البيولوجي
329	♦ تطبيقات الذكاء الاصطناعي في الطاقة
329	♦ تطبيقات الذكاء الاصطناعي في النقل
330	♦ تطبيقات الذكاء الاصطناعي في إدارة المياه
330	♦ كيف يمكن للذكاء الاصطناعي المساعدة في مكافحة تغير المناخ؟
332	♦ تحديات استخدام الذكاء الاصطناعي لتحقيق الاستدامة البيئية

تطبيقات الذكاء الاصطناعي في علوم الأرض

مقدمة

الذكاء الاصطناعي (Artificial Intelligence (AI، بمعناه الأوسع، هو الذكاء الذي تظهره الآلات، وخاصة أنظمة الحاسوب، على عكس الذكاء الطبيعي للكائنات الحية. أو هو قدرة الآلة على اتخاذ القرارات واتخاذ الإجراءات بناءً على تحليل البيانات والاتجاهات.

وهو مجال بحث في علوم الحاسوب يقوم بتطوير ودراسة الأساليب والبرمجيات التي تمكن الآلات من إدراك بيئتها واستخدام التعلم والذكاء لاتخاذ إجراءات تزيد من فرصها في تحقيق أهداف محددة.

أما التعلم الآلي (Machine learning (ML فهو نوع من الذكاء الاصطناعي الذي يمكن أنظمة الحاسوب من تصنيف مجموعات كبيرة ومعقدة من البيانات وتجميعها وتحديدتها وتحليلها مع التخلص من الحاجة إلى تعليمات وبرمجة واضحة.

تشمل تطبيقات الذكاء الاصطناعي والتعلم الآلي في علوم الأرض؛ رسم الخرائط الجيولوجية واكتشاف تسرب الغاز وتحديد المعالم الجيولوجية. وعلم الأرض هو دراسة أصل وتطور ومستقبل كوكب الأرض. يمكن تقسيم نظام الأرض إلى أربعة مكونات رئيسية بما في ذلك الأرض الصلبة والغلاف الجوي والغلاف المائي والمحيط الحيوي.

يمكن تطبيق مجموعة متنوعة من الخوارزميات اعتماداً على طبيعة استكشاف علوم الأرض. قد يكون أداء بعض الخوارزميات أفضل بكثير من غيرها لأهداف

معينة. على سبيل المثال، الشبكات العصبية التلافيفية (CNN) جيدة في تفسير الصور، والشبكات العصبية الاصطناعية (ANN) تؤدي أداءً جيدًا في تصنيف التربة ولكن تدريبها أكثر تكلفة من الناحية الحسابية من تعلم آلة الدعم المتجه (SVM).

وقد أصبح تطبيق التعلم الآلي شائعًا في العقود الأخيرة، حيث أدى تطوير تقنيات أخرى مثل؛ المركبات الجوية بدون طيار (UAVs)، وتكنولوجيا الاستشعار عن بعد فائقة الدقة، ووحدات الحوسبة عالية الأداء إلى توفر مجموعات كبيرة من البيانات عالية الجودة، وخوارزميات أكثر تقدمًا.

هناك العديد من الرؤى المقنعة حول الشكل الذي يجب أن يبدو عليه الذكاء الاصطناعي في مستقبل علوم الأرض. ومن خلال دراسة الماضي، قد نتمكن من تحديد الاتجاهات المستقبلية المحتملة.

في هذا العمل الذي بين أيدينا قمنا بتغطية كل التطبيقات الممكنة للذكاء الاصطناعي في علوم الأرض، والتي تشمل: أهمية الذكاء الاصطناعي في علوم الأرض والأدوار التي يمكن أن يقوم بها في مجالات البيئة والزلازل وتوقعات الطقس والمناخ والتنبؤ بمواقع الموارد الطبيعية وتقييم الأخطار الجيولوجية وتحليل البيانات الجيوفيزيائية وتصنيف الصخور والمعادن.

لكن، قبل ذلك كان لابد لنا من مقدمة موجزة عن الذكاء الاصطناعي والبيانات الضخمة وإدارتها في علوم الأرض.

وفي الختام، تناولنا التحديات والفرص المستقبلية للذكاء الاصطناعي في علوم الأرض، وأخطار الذكاء الاصطناعي.

نأمل أن نكون قد وفقنا في سد ثغرة مهمة في المكتبة العربية، في تسليط الضوء على فوائد الذكاء الاصطناعي في علوم الأرض.

أساسيات الذكاء الاصطناعي

لقد ظهر مجال الذكاء الاصطناعي (AI) فعلاً مع ولادة أجهزة الحاسوب في أربعينيات وخمسينات القرن العشرين وما حولها. في الفترة المبكرة من تطورها، كان الاهتمام يتركز بشكل واضح على جعل أجهزة الحاسوب تقوم بأشياء، إذا قام بها الإنسان، فإنها تُعد ذكية.

في الأساس، تضمن ذلك محاولة جعل أجهزة الحاسوب تقلد البشر في بعض أو كل جوانب سلوكهم. في ستينيات وسبعينيات القرن العشرين، فتح هذا نقاشاً فلسفياً حول مدى قرب الحاسوب من الدماغ البشري، وما إذا كانت أي اختلافات قد تنشأ مهمة حقاً. ومع ذلك، كانت هذه الفترة (التي يشار إليها باسم «الذكاء الاصطناعي الكلاسيكي» في هذا الكتاب)، محدودة في إمكاناتها.

في الثمانينيات والتسعينيات، رأينا نهجاً جديداً تماماً، وهو نوع من الهجوم من القاعدة إلى القمة على المشكلة، وبناء أدمغة صناعية بشكل فاعل لتحقيق الذكاء الاصطناعي، أدى هذا إلى فتح احتمالات وخلق مجموعة جديدة حقاً من الأسئلة.

لم يعد الذكاء الاصطناعي مقتصرًا على تقليد الذكاء البشري فقط، بل أصبح الآن قادراً على أن يكون ذكياً بطريقته الخاصة. وفي بعض الحالات، لا يزال من الممكن تحقيق ذلك عن طريق محاكاة الطريقة التي يعمل بها الدماغ البشري، وأصبح الآن من الممكن أن يكون أكبر وأسرع وأفضل. وكانت النتيجة الفلسفية لذلك هي أن الدماغ الاصطناعي يمكن أن يتفوق في الأداء على الدماغ البشري.

في السنوات الأخيرة، انطلق هذا المجال فعلاً. إن تطبيقات الذكاء الاصطناعي في العالم الحقيقي، وخاصة في قطاعات التمويل والتصنيع والقطاعات العسكرية، تعمل بطرق لا يستطيع العقل البشري منافستها بسهولة.

يتم الآن منح العقول الاصطناعية جسداً خاصاً بها، يمكنها من خلاله إدراك العالم بطريقتها الخاصة، والتحرك فيه وتعديله على النحو الذي تراه مناسباً. حيث يتم منحها القدرة على التعلم والتكيف وتنفيذ رغبات البشر، وهذا يثير كل أنواع القضايا مستقبلاً.

• التاريخ المبكر للذكاء الاصطناعي

هناك روابط قوية بين تطور أجهزة الحاسوب وظهور الذكاء الاصطناعي. ومع ذلك، فقد زُرعت بذور الذكاء الاصطناعي قبل وقت طويل من تطور أجهزة الحاسوب الحديثة. نظر الفلاسفة مثل ديكارت إلى الحيوانات من حيث أدائها الآلي، وكانت الآلات الآلية هي أسلاف الروبوتات البشرية اليوم. ولكن يمكن إرجاع الكيانات الاصطناعية إلى أبعد من ذلك، إلى قصص براغ جوليم، أو حتى إلى الأساطير اليونانية مثل جالاتيا بيجماليون *Pygmalion's Galatea*.

من المحتمل أن تعود أقوى الجذور المباشرة إلى عمل ماركولوتش وبيتس، اللذين وصفا في عام 1943م، نماذج رياضية (تسمى الإدراك الحسي) للخلايا العصبية في الدماغ (خلايا الدماغ) بناءً على تحليل مفصل للأصول البيولوجية. لم يوضحوا فقط كيف تنشط الخلايا العصبية أو لا تنشط (تكون «مفعلة» أو «متوقفة»)، وبالتالي تعمل بطريقة تبديل ثنائية، ولكنها أظهرت أيضاً كيف يمكن لهذه الخلايا العصبية أن تتعلم، وبالتالي تغير عملها فيما يتعلق بالوقت.

ولعل أحد أعظم رواد هذا المجال كان العالم البريطاني آلان تورينج. في الخمسينات (قبل وقت طويل من ظهور أجهزة الحاسوب اليوم)، كتب تورينج ورقة بحثية مهمة حاول فيها الإجابة على سؤال «هل يمكن للآلة أن تفكر؟» كان مجرد طرح السؤال في ذلك الوقت أمراً ثورياً، ولكن التوصل أيضاً إلى اختبار قابل للتطبيق (المعروف باسم اختبار تورينج)، يمكن من خلاله الإجابة على السؤال، كان أمراً استغفازياً إلى أقصى الحدود.

الذكاء العام الاصطناعي	الحوسبة الكمومية	الروبوتات العاطفية	المستقبل
الذكاء الاصطناعي التعاوني على أجهزة الذكاء الاصطناعي الجديدة	التعاون بين الإنسان والآلة	الحوسبة العصبية	بعد 20 سنة
الديمقراطية وتجسيد الذكاء الاصطناعي	عالم البيانات في صندوق	الروبوتات المنزلية والخدمة	بعد 5 سنوات
الذكاء الاصطناعي الضيق - مع البيانات الضخمة (C-1-B)، البحث، التجارة الإلكترونية	التعلم العميق - معالجة الصور	الكتابة اليدوية والتعرف على الصوت	الألفية الثانية
الذكاء الاصطناعي الضيق (القيام على القواعد، والكلام)	إضفاء الطابع الشخصي: 76,897 الأنواع الدقيقة	القرارات المبنية على القواعد	الماضي
الذكاء الاصطناعي الضيق	إضفاء الطابع الشخصي: 76,897 الأنواع الدقيقة	الروبوتات الصناعية	الماضي

الجدول الزمني لتطورات الذكاء الاصطناعي، ونلاحظ هنا أن الماضي ليس مقدمة عندما يتعلق الأمر بالذكاء الاصطناعي (Herweijer & Waughray, 2018).

وبعد فترة وجيزة، قام مارفن مينسكي ودين إدموندز ببناء ما يمكن وصفه بأنه أول حاسوب يعمل بالذكاء الاصطناعي، استناداً إلى شبكة من نماذج الخلايا العصبية لمكولوتش وبيتس.

في الوقت نفسه، بحث كلود شانون في إمكانية لعب الحاسوب للشطرنج، واختيار نوع الاستراتيجيات اللازمة لتحديد الخطوة التالية التي يجب القيام بها.

في عام 1956م، وبتحريض من جون مكارثي ومع مينسكي وشانون، اجتمع الباحثون في كلية دارتموث في الولايات المتحدة الأمريكية لحضور أول ورشة عمل للاحتفال بالمجال الجديد للذكاء الاصطناعي، حيث تم وضع العديد من الأسس الكلاسيكية اللاحقة للموضوع لأول مرة.

■ العصور الوسطى لتطور الذكاء الاصطناعي

في ستينات القرن العشرين، كانت المساهمة الأكثر عمقاً في هذا المجال هي كتاب «حل المشكلات العامة» الذي قدمه نيويل وسيمون. كان برنامجاً متعدد الأغراض يهدف إلى محاكاة بعض أساليب حل المشكلات البشرية باستخدام الحاسوب. لسوء الحظ، لم تكن التقنية المستخدمة فاعلة بشكل خاص، وبسبب الوقت المستغرق ومتطلبات الذاكرة لحل المشكلات الحقيقية المباشرة نسبياً، تم التخلي عن المشروع.

المساهمة المهمة الأخرى في الستينات، كانت مساهمة العالم الأذري - الأمريكي، لطفي زاده، حيث قدم فكرة المجموعات والأنظمة الضبابية **Fuzzy Systems**، مما يعني أن أجهزة الحاسوب لا يتعين عليها أن تعمل في تنسيق منطقي ثنائي مجرد، ولكن يمكنها أيضاً العمل كالإنسان، مثل الطريقة «الضبابية».

بخلاف هذه الأمثلة، ربما كانت فترة الستينات فترة لبعض الادعاءات المتهورة فيما يتعلق بقدرة الذكاء الاصطناعي على نسخ، وربما إعادة إنشاء أعمال الدماغ البشري كاملة خلال فترة زمنية قصيرة جداً.

هناك ملاحظة؛ وإن كانت متأخرة، وهي أن محاولة جعل الحاسوب يعمل بالطريقة نفسها التي يعمل بها الدماغ البشري تماماً كانت بمنزلة محاولة جعل الطائرة تطير بالطريقة نفسها التي يعمل بها الطائر. وفي هذه الحالة، قد تفوت الخصائص الجيدة للطائرة، وبالتالي فإن أبحاث الذكاء الاصطناعي في هذا الوقت قد فاتها الكثير من النقاط الجيدة التي تقدمها أجهزة الحاسوب.

ولكن من المؤسف (وهذا ما يثير الدهشة)، أن بعض التفكير المحدود الذي كان سائداً في ستينات القرن الماضي لا يزال قائماً حتى يومنا هذا. لا تزال بعض الكتب المدرسية الحالية (بعضها تحت ستار الذكاء الاصطناعي الحديث)، تركز فقط على النهج الكلاسيكي المتمثل في محاولة جعل الحاسوب ينسخ الذكاء البشري، دون النظر حقاً في مدى التنوع الكبير في أنماط الذكاء الاصطناعي، وإمكاناتها المثيرة؛ من حيث كون الآلات ذكية بطريقتها الخاصة، وليست مجرد تقليد للذكاء البشري.

في هذه الفترة، تم بذل جهد كبير لجعل أجهزة الحاسوب تفهم وتتحدث اللغة البشرية الطبيعية، بدلاً من كود/رمز الآلة المباشر. وكان هذا مدفوعاً جزئياً بأفكار تورينج حول الذكاء، ولكن أيضاً جزئياً بدافع الرغبة في أن تتفاعل أجهزة الحاسوب بسهولة أكبر مع العالم الحقيقي.

أحد أفضل برامج الحاسوب الناطقة باللغة الإنجليزية كان برنامج **ELIZA** لجوزيف فايزنباوم. كان هذا في الواقع، أول ما كان يُعرف باسم «روبوتات الثرثرة **Chatterbots**». وحتى في هذه المرحلة المبكرة نسبياً، كانت بعض محادثاتها واقعية بما فيه الكفاية، بحيث تم خداع بعض المستخدمين أحياناً للاعتقاد بأنهم يتواصلون مع إنسان وليس جهاز حاسوب.

في الواقع، قدمت **ELIZA** بشكل عام رداً جاهزاً، أو كررت ببساطة ما قيل لها، مع مجرد إعادة صياغة الرد مع بعض القواعد النحوية الأساسية. ومع ذلك، فقد تبين أن مثل هذا الإجراء يبدو أنه ينسخ بشكل مناسب بعض أنشطة المحادثات التي يقوم بها البشر، إلى حد ما.

■ العصور المظلمة لأبحاث الذكاء الاصطناعي

بعد الإثارة التي شهدتها فترة الستينات، ومع التمويل الكبير للأبحاث والمزاعم عما سيتم تحقيقه لاحقاً من حيث محاكاة الذكاء الاصطناعي للذكاء البشري، أثبتت السبعينات أنها كانت مثل خيبة الأمل، وكانت في كثير من النواحي عصرًا مظلمًا للذكاء الاصطناعي.

بعض الادعاءات الأكثر تفاؤلاً في الستينات رفعت التوقعات إلى مستوى عالٍ جداً، وعندما فشلت النتائج الموعودة في تحقيقها، اختفى الكثير من تمويل أبحاث الذكاء الاصطناعي.

في الوقت نفسه، توقف مجال الشبكات العصبية - أجهزة الحاسوب التي تتسخ التركيبة العصبية للدماغ - بين عشية وضحاها تقريباً بسبب هجوم لاذع من مارفن مينسكي وسيمور بايبرت على عدم قدرة الإدراك الحسي على التعميم من أجل التعامل مع أنواع معينة من المشكلات البسيطة نسبياً.

ومع ذلك، يجب أن ندرك أنه في السبعينات كانت قدرات أجهزة الحاسوب، وبالتالي برامج الذكاء الاصطناعي محدودة جداً مقارنة بما هي عليه اليوم. حتى أفضل البرامج لا يمكنها التعامل إلا مع إصدارات بسيطة من المشكلات التي تهدف إلى حلها. في الواقع، كانت جميع البرامج في ذلك الوقت، إلى حد ما، برامج «دُمى». في الحقيقة، واجه الباحثون العديد من الحدود الأساسية التي لن يتم التغلب عليها إلا بعد وقت طويل. كان السبب الرئيس لهذه القوة هو القدرة الحاسوبية المحدودة.

لم تكن هناك سرعة أو ذاكرة كافية للقيام بمهام مفيدة حقاً؛ ومن الأمثلة على ذلك، حينذاك، آلة اللغة الطبيعية التي ابتكرها روس كويلان، والتي كان عليها أن تتعامل مع إجمالي عدد من المفردات يبلغ 20 كلمة!

ومع ذلك، كانت المشكلة الرئيسية هي أن مهام الذكاء الاصطناعي، مثل جعل الحاسوب يتواصل بلغة طبيعية، أو فهم محتوى الصورة بأي شيء يشبه الطريقة البشرية، تتطلب الكثير من المعلومات والكثير من قوة المعالجة، حتى تعمل عند مستوى منخفض جداً ومقيد.

بشكل عام، قد يكون من الصعب على أجهزة الحاسوب تمييز الأشياء اليومية الموجودة في الصورة، وما يعتبره البشر تفكيراً منطقياً حول الكلمات والأشياء، يتطلب في الواقع الكثير من المعلومات الأساسية.

إذا لم تكن الصعوبات التقنية التي واجهتها في السبعينات كافية، فقد أصبح هذا المجال أيضاً موضوعاً مقبولاً لاهتمام الفلاسفة. على سبيل المثال، توصل جون سيرل إلى حجة الغرفة الصينية لإظهار أنه لا يمكن القول بأن الحاسوب «يفهم» الرموز التي يتواصل معها.

علاوة على ذلك، قال: إنه بسبب هذا لا يمكن بالضرورة وصف الآلة بأنها «تفكر» (كما افترض تورينج سابقاً)، من حيث التلاعب بالرموز فقط. على الرغم من أن العديد من الباحثين العمليين استمروا ببساطة في عملهم وتجنبوا الانتقادات، إلا أن العديد من الفلاسفة (مثل سيرل)، أعطوا انطباعاً قوياً بأن الإنجازات الحقيقية للذكاء الاصطناعي ستكون دائماً محدودة جداً.

قال مينسكي عن هؤلاء الناس: «إنهم يسيئون الفهم، ولا بد من تجاهلهم». ونتيجة لذلك، حدث الكثير من الاقتتال الداخلي، الأمر الذي أدى إلى تحويل التركيز بعيداً عن التطورات التقنية، وتجاه الحجج الفلسفية التي يرى الكثيرون الآن أنها (بعد فوات الأوان) مجرد رنجة حمراء.

كان جون مكارثي وحيداً تقريباً في ذلك الوقت، حيث اعتبر أن كيفية عمل الدماغ البشري وما يفعله البشر لا علاقة له بشكل مباشر بالذكاء الاصطناعي. لقد شعر

أن ما نحتاج إليه حقاً هو الآلات التي يمكنها حل المشكلات؛ وليس بالضرورة أجهزة الحاسوب التي تفكر تماماً بالطريقة نفسها التي يفكر بها الناس. انتقد مينسكي هذا الادعاء، مدعياً أن فهم الكيانات والتحدث بشكل جيد يتطلب من الحاسوب أن يفكر مثل البشر، وهكذا استمرت الحجج.

■ عصر النهضة للذكاء الاصطناعي

شهدت الثمانينات شيئاً من الانتعاش في الذكاء الاصطناعي. وكان ذلك بسبب ثلاثة عوامل:

أولاً: اتبع العديد من الباحثين خطى مكارثي، واستمروا في تطوير أنظمة الذكاء الاصطناعي من وجهة نظر عملية. بكل بساطة، لقد استمروا في الأمر. شهدت هذه الفترة تطور «الأنظمة الخبيرة **Expert Systems**»، والتي تم تصميمها للتعامل مع مجال محدد جداً من المعرفة؛ وبالتالي تجنب إلى حد ما الحجج القائمة على الافتقار إلى «الفطرة السليمة». على الرغم من أن هذه الأنظمة تم تجربتها في البداية في السبعينات، إلا أنه في الثمانينات بدأ استخدام هذه الأنظمة للتطبيقات العملية الفعيلة في الصناعة.

ثانياً: على الرغم من استمرار المناقشات (والحجج) الفلسفية، لا سيما فيما يتعلق بما إذا كانت الآلة قادرة على التفكير بالطريقة نفسها التي يفكر بها الإنسان أم لا، إلا أنها تبدو وكأنها تفعل ذلك بشكل مستقل إلى حد كبير عن العمل التطبيقي للذكاء الاصطناعي الذي كان يحدث. شرعت المدرستان ببساطة في تنفيذ مشروعهما الخاص، حيث توصل مطورو الذكاء الاصطناعي إلى حلول صناعية تطبيقية دون أن يزعموا بالضرورة أن أجهزة الحاسوب يجب أو يمكنها أن تتصرف كالإنسان.

ثالثاً: بدأ التطور الموازي للروبوتات في إحداث تأثير كبير على الذكاء الاصطناعي. وفي هذا الصدد، نشأ نموذج جديد في الاعتقاد بأن إظهار الذكاء «الحقيقي» يتطلب أن يكون لدى الحاسوب جسم حتى يتمكن من إدراك العالم والتحرك والبقاء فيه.

ومن دون هذه المهارات، تقول الحجة: كيف يمكن أن نتوقع من الحاسوب أن يتصرف بالطريقة نفسها التي يتصرف بها الإنسان؟ بدون هذه القدرات، كيف يمكن للحاسوب أن يختبر الحس السليم؟ لذلك، فإن ظهور التأثير السيبراني على الذكاء الاصطناعي قد ركز بشكل أكبر على بناء الذكاء الاصطناعي من الأسفل إلى الأعلى، وهو النهج الذي افترضه ماکولوتش وبيتس في الأصل.

■ في الوقت الحاضر

تدريجياً، وجد الذكاء الاصطناعي الناشئ أقدامه. ازداد عدد تطبيقات الذكاء الاصطناعي وبدأ استخدامها في مجالات واسعة؛ مثل الأنظمة المالية والجيش. في هذه المجالات، تبين أنه ليس فقط بديلاً للعنصر البشري، ولكنه أيضاً، في كثير من الحالات، قادر على الأداء بشكل أفضل بكثير.

لقد توسعت الآن تطبيقات الذكاء الاصطناعي في هذه المجالات بشكل عظيم، لدرجة أن الشركات المالية التي كانت تكسب أموالها من تقديم المشورة للعملاء، تحقق الآن أرباحاً أكبر بكثير من تطوير أنظمة الذكاء الاصطناعي المخصصة للبيع، وتقديم الخدمات لعملائها.

وشهدت الفترة منذ بداية التسعينات أيضاً تحقيق العديد من المعالم والأهداف. على سبيل المثال، في 11 مايو 1997م، أصبح «ديب بلو» أول نظام حاسوب يلعب الشطرنج، ويهزم بطل العالم في الشطرنج (غاري كاسباروف) في لعبته الخاصة.

وفي سياق آخر، وفي 14 مارس 2002م، كان كيفن وأرويك أول من نجح في ربط الجهاز العصبي البشري مباشرة بالحاسوب، لتحقيق شكل مشترك جديد من الذكاء الاصطناعي.

في 8 أكتوبر 2005م، تم الإعلان عن فوز روبوت من جامعة ستانفورد بتحدي DARPA الكبير، من خلال القيادة بشكل مستقل لمسافة 131 ميلاً على طول طريق صحراوي لم يتم التدريب عليه. وفي الوقت نفسه، في عام 2009م، أعلن فريق مشروع الدماغ الأزرق أنهم نجحوا في محاكاة أجزاء من قشرة دماغ الفئران.

في الغالب الأعم، لم تكن لمثل هذه النجاحات أن تتحقق نتيجة لشكل جديد من أشكال التكنولوجيا، بل كانت نتيجة لتجاوز حدود التكنولوجيا المتاحة. في الواقع، كان جهاز الحاسوب، ديب بلو، أسرع بعشرة ملايين مرة من نظام حاسوب فيرانتلي الذي تم تدريبه للعب الشطرنج في عام 1951م.

إن الزيادة الهائلة المستمرة سنة بعد سنة في قوة الحوسبة، يتبعها ويتبأ بها ما أصبح يعرف باسم قانون مور Moore's Law. يشير قانون مور إلى أن سرعة وسعة ذاكرة أجهزة الحاسوب تتضاعف كل عامين. وهذا يعني أن المشكلات السابقة التي واجهتها أنظمة الذكاء الاصطناعي يتم التغلب عليها بسرعة كبيرة من خلال القوة الحاسوبية المطلقة.

ومن المثير للاهتمام أنه في كل عام نرى بعض الادعاءات أو غيرها في إحدى الصحف بأن قانون مور سينتهي بسبب عامل مقيد ما؛ مثل الحجم والحرارة والتكلفة، وما إلى ذلك. ومع ذلك، فإن التقدم التكنولوجي الجديد يعني كل عام أن قوة الحوسبة المتاحة تتضاعف، ويستمر قانون مور في العمل.

علاوة على ذلك، شهدت هذه الفترة أيضاً ظهور أساليب جديدة للذكاء الاصطناعي. أحد الأمثلة على ذلك هو طريقة «الوكيل الذكي **Intelligent Agent**». هذا هو النهج المعياري الذي يمكن القول بأنه يحاكي الدماغ في بعض النواحي؛ حيث يجمع عوامل متخصصة مختلفة لمعالجة كل مشكلة، بالطريقة نفسها التي يمتلك بها الدماغ مناطق مختلفة لاستخدامها في مواقف مختلفة.

يتناسب هذا النهج أيضاً بشكل مريح مع أساليب علوم الحاسوب التي ترتبط فيها البرامج المختلفة بكيانات أو وحدات مختلفة؛ حيث يتم جمع الكيانات المناسبة معاً حسب الحاجة.

الوكيل الذكي هو أكثر بكثير من برنامج مجرد. إنه في حد ذاته، نظام يجب عليه أن يدرك بيئته ويتخذ الإجراءات اللازمة لتعظيم فرص نجاحه. ومع ذلك، فمن الواقع أن الوكيل الذكي، في أبسط أشكاله، هو برنامج يحل مشكلات محددة. ومع ذلك، يمكن أن يكون هذا الوكيل عبارة عن روبوت فردي أو نظام آلي، يعمل بشكل مستقل مادياً.

بالإضافة إلى الوكلاء، ظهرت الكثير من الأساليب الجديدة الأخرى في مجال الذكاء الاصطناعي خلال هذه الفترة. وكان بعضها بالتأكيد أكثر رياضية بطبيعتها، مثل نظرية الاحتمالية والقرار. وفي الوقت نفسه، لعبت الشبكات العصبية ومفاهيم التطور، مثل الخوارزميات الأصلية، دوراً أكثر تأثيراً.

من المؤكد أن أفعالاً معينة يمكن تفسيرها على أنها أفعال ذكية (في البشر أو الحيوانات) إلى درجة أنه يمكن تنفيذها (في كثير من الأحيان بشكل أكثر فاعلية) بالحاسوب.

ومن الصحيح أيضًا أن كثيرًا من التطورات الجديدة في الذكاء الاصطناعي وجدت طريقها إلى تطبيقات أكثر عمومية. ومن خلال القيام بذلك، غالبًا ما يفقدون علامة «الذكاء الاصطناعي». ويمكن الاستشهاد على أمثلة جيدة على ذلك من استخراج البيانات، والتعرف على الكلام، والكثير من عمليات صنع القرار التي يتم تنفيذها حاليًا في القطاع المصرفي. وفي كل حالة، أصبح ما كان في الأصل ذكاءً اصطناعيًا يُنظر إليه على أنه جزء آخر من برنامج الحاسوب.

■ ظهور الاتصال اللاسلكي

إحدى التقنيات الرئيسية التي أصبحت واقعًا عمليًا في التسعينات هي التكنولوجيا اللاسلكية، التي هي شكل من أشكال الاتصال لأجهزة الحاسوب، بعد إدخال واستخدام الإنترنت على نطاق واسع. ومن منظور الذكاء الاصطناعي، أدى هذا إلى تغيير ساحة اللعب تمامًا.

وحتى ذلك الوقت، كانت أجهزة الحاسوب الموجودة قائمة بذاتها، والتي يمكن مقارنة قوتها وقدراتها بشكل مباشر مع العقول البشرية المستقلة؛ الإعداد الطبيعي. ومع انتشار أجهزة الحاسوب المتصلة بالشبكات، بدلًا من النظر إلى كل جهاز حاسوب على حدة، أصبح من الضروري من الناحية الواقعية النظر إلى الشبكة بالكامل على أنها عقل ذكي، واحد وكبير، يتمتع بقدر كبير من التوزيع، وهو ما يسمى الذكاء الموزع.

بفضل التكنولوجيا اللاسلكية، يعد الاتصال ميزة هائلة للذكاء الاصطناعي على الذكاء البشري، في شكله الحالي المستقل. بداية، كانت تكنولوجيا الاتصال في الأساس وسيلة يمكن لأجهزة الحاسوب التواصل من خلالها بسرعة مع بعضها البعض. ومع ذلك، فقد ازدادت السرعة، ذلك أن جيوبًا كبيرة من الذاكرة تنتشر حول الشبكة، لينتشر التخصص ولتتدفق المعلومات بحرية وسرعة. لقد غيرت تكنولوجيا الاتصال النظرة الإنسانية للأمن والخصوصية، وغيّرت الوسائل الرئيسية التي يتواصل بها البشر مع بعضهم البعض.

■ نحو المستقبل

يعتمد جزءٌ كبير من الفلسفة الكلاسيكية للذكاء الاصطناعي إلى حد كبير على مفهوم الدماغ أو الحاسوب على أنه كيان مستقل؛ دماغ بلا جسد في وعاء، إذا جاز التعبير. أما في العالم الحقيقي، يتفاعل البشر مع العالم من حولهم من خلال أجهزة الاستشعار والمهارات الحركية.

ما هو مثير للاهتمام الآن، وسيكون أكثر إثارة في المستقبل، هو تأثير الجسم على القدرات الفكرية لدماغ ذلك الجسم. تهدف الأبحاث الجارية إلى تحقيق نظام ذكاء اصطناعي في الجسد - التجسيد - حتى يتمكن من تجربة العالم، سواء كان النسخة الحقيقية للعالم أو العالم الافتراضي أو حتى عالم المحاكاة. على الرغم من أن دراسة الذكاء الاصطناعي لا تزال تركز على دماغ الذكاء الاصطناعي المعني، إلا أن حقيقة أن لديه جسمًا يمكنه التفاعل مع العالم تُعد أمرًا مهمًا.

وبينما نخطو نحو المستقبل، ربما يكون المجال الأكثر إثارة في أبحاث الذكاء الاصطناعي هو ذلك المجال الذي يتم فيه زراعة أدمغة الذكاء الاصطناعي من الأنسجة العصبية البيولوجية؛ التي يتم الحصول عليها عادة إما من الفئران أو الإنسان.

من المؤكد أن هذا الموضوع مثير للاهتمام في حد ذاته باعتباره شكلًا جديدًا من أشكال الذكاء الاصطناعي، ومن المحتمل أن يكون مفيدًا في المستقبل للروبوتات المنزلية. ومع ذلك، فإنه يوفر أيضًا مجالًا جديدًا مهمًا للدراسة من حيث التشكيك في العديد من الافتراضات الفلسفية من الذكاء الاصطناعي الكلاسيكي.

في الأساس، ناقشت هذه الفلسفة الفرق بين الذكاء البشري وذكاء آلة السيليكون. ومع ذلك، في هذا المجال البحثي الجديد، يمكن تنمية أدمغة الذكاء الاصطناعي من الخلايا العصبية البشرية، عن طريق بنائها إلى ما يشبه نسخة الذكاء الاصطناعي من نوع الدماغ البشري، وبالتالي طمس ما كان بمنزلة انقسام واضح بين نمطين مختلفين تمامًا من الدماغ.

يمكن القول إنه عندما يُمنح دماغ الذكاء الاصطناعي البيولوجي جسمًا آليًا تكنولوجياً، فإنه يكون نوعًا من السايبورغ **CYBORG**؛ أي كائن سيبراني (جزء منه حيوان / إنسان، وجزء تكنولوجيا / آلة)، مع دماغ متجسد.

يُعد هذا المجال من البحث هو الأكثر إثارة على الإطلاق، فهو الرابط المباشر بين الحيوان والآلة من أجل تحسينهما كليهما (من حيث الأداء). إن مثل هذا السايبورغ كما تمت مناقشته هو نسخة واحدة محتملة. في الواقع، لا الشكل الطبيعي للسايبورغ الذي يتم بحثه، ولا الشكل الذي يتم مواجهته عادةً في الخيال العلمي، هو من هذا النوع.

نوع السايبورغ الذي يتم مواجهته مرارًا وتكرارًا، هو في شكل إنسان لديه تقنية متكاملة مزروعة فيه، ومرتبطة بجهاز حاسوب، مما يمنحه قدرات أعلى من تلك التي يتمتع بها الإنسان العادي؛ وهذا يعني أن السايبورغ لديه مهارات لا يمتلكها الإنسان.

يمكن أن تكون هذه المهارات جسدية و/أو عقلية، ويمكن أن تتعلق بالذكاء. على وجه الخصوص، سنرى أن دماغ الذكاء الاصطناعي عادة ما يكون (باستثناء دماغ الذكاء الاصطناعي البيولوجي)، مختلفًا تمامًا عن الدماغ البشري، ويمكن تحقيق هذه الاختلافات من حيث المزايا (خاصة بالنسبة للذكاء الاصطناعي).

تدور أسباب إنشاء السايبورغ بشكل عام حول تعزيز أداء الدماغ البشري من خلال ربطه مباشرة مع الدماغ الآلي. يمكن للدماغ المدمج بعد ذلك، على الأقل، أن يعمل بسمات مميزة من كلا الجزأين المكونين له؛ وبالتالي يمكن أن يتمتع السايبورغ بذاكرة أفضل، ومهارات حسابية أسرع، وحواس أفضل، وفكر متعدد الأبعاد، ومهارات اتصال محسنة بالمقارنة مع الدماغ البشري.

حتى الآن، أظهرت التجارب الناجحة تعزيزًا حسيًا، وشكلًا جديدًا من التواصل للسايبورغ (Warwick, 2012).

مبادئ الذكاء الاصطناعي الكلاسيكي

مما لا شك فيه أن من سمات الإنسانية أننا نحب مقارنة أنفسنا بالآخرين، وفي كثير من الحالات، نحاول إيجاد طرق نصبح بها أفضل من شخص ما أو شيء آخر.

ومع بدء ظهور أجهزة الحاسوب على الساحة وولادة مفهوم الذكاء الاصطناعي في الخمسينات والستينات من القرن الماضي، ظهرت الرغبة في مقارنة الذكاء الاصطناعي بالذكاء البشري بشكل مباشر.

ولكن مع هذه المقارنة جاءت قاعدة أساسية مفادها أن الذكاء البشري هو أفضل ما وصل إليه الذكاء، بل بلغ إلى الاعتقاد أحياناً بأن الذكاء البشري هو الشكل الوحيد للذكاء. ويترتب على ذلك أن أفضل ما يمكن أن يحققه الذكاء الاصطناعي هو أن يكون بجودة الذكاء البشري نفسه وأن يقلده بطريقة ما.

لذلك اتضح أن تقنيات الذكاء الاصطناعي الكلاسيكية ركزت على جعل الآلة تحاكي الذكاء البشري. وقد تأكد هذا من تعريف مبكر لمارفن مينسكي، الذي قال: «الذكاء الاصطناعي هو علم جعل الآلات تقوم بأشياء تتطلب الذكاء إذا قام بها الرجال». هذا التعريف يتجاهل المفهوم الكامل لماهية الذكاء وما لا يمثله، بدقة تامة (وربما عن قصد)، ويشير فقط إلى الآلات التي تقلد البشر.

ربما يكون أفضل وصف لفلسفة ذلك الوقت هو ما أدلى به هيرب سيمون في عام 1957م، والذي نُقل عنه قوله: «توجد الآن في العالم آلات تفكر، وتتعلم، وتبدع». علاوة على ذلك، فإن قدرتها على القيام بهذه الأشياء سوف تتزايد بسرعة حتى على نطاق المشكلات التي يمكنها التعامل معها سوف يكون متوازياً مع النطاق الذي تم تطبيق العقل البشري عليه.

ما نشأ في تلك الأيام كان نهجاً في التعامل مع الذكاء الاصطناعي على غرار نهج الطبيب النفسي: محاولة فهم معالجة الدماغ البشري من الخارج فقط، ثم محاولة بناء آلة لنسخ طريقة العمل هذه، وهو نهج من أعلى إلى أسفل.

أحد جوانب الذكاء البشري الذي تم التقاطه آنذاك هو قدرة الدماغ البشري على التفكير. إذا تم إعطاء عدد من الحقائق، يمكن للعقل البشري أن يقوم بافتراض منطقي حول موقف ما، ويقرر الاستنتاج.

على سبيل المثال، إذا كانت الساعة السابعة صباحاً وكان المنبه يرن، فهذا يعني أن الوقت قد حان للاستيقاظ. وقد تم استخدام هذا النهج لأول مرة بنجاح لبناء أنظمة الذكاء الاصطناعي.

■ تعريف الذكاء: مهمة مستحيلة؟

من المهم، قبل النظر في الذكاء الاصطناعي الكلاسيكي، أن نحاول فهم ما هو الذكاء بالضبط في المقام الأول؟ ماذا نعني عندما نقول إن الإنسان أو الحيوان أو الشيء ذكي؟

في الواقع، كل شخص لديه مفهوم مختلف بناءً على تجاربه ووجهات نظره الخاصة، ويعتمد على ما يعتقد أنه مهم وما هو غير مهم.

مثال؛ في قاموس اللغة الإنجليزية الجديد لعام 1932م، تم تعريف الذكاء على النحو التالي: «ممارسة الفهم؛ والقوة الفكرية؛ والمعرفة المكتسبة؛ وسرعة الفكر». ومن الواضح أنه في ذلك الوقت تم التركيز على المعرفة والسرعة العقلية، مع الميل نحو الذكاء البشري.

وفي الآونة الأخيرة، ذكرت موسوعة ماكملان لعام 1995م أن: «الذكاء هو القدرة على التفكير والاستفادة من الخبرة». يتم تحديد مستوى ذكاء الفرد من خلال التفاعل المعقد بين الوراثة والبيئة.

في القرن العشرين، اختار بينيه (مخترع اختبار الذكاء)، الحكم والفطرة السليمة والمبادرة والقدرة على التكيف باعتبارها «مكونات أساسية للذكاء». ومؤخراً، تم ربط الذكاء بالوعي الروحي أو العاطفي.

من الواضح أن الذكاء عند البشر مهم، ولكنه ليس المثال الوحيد للذكاء، ويجب ألا نسمح له بتجاوز كل شيء آخر. إذا كنا نقارن القدرة الفكرية بين البشر، فإن الاختبارات القياسية من نوع أو آخر تكون مفيدة. ومع ذلك، نحتاج هنا إلى النظر في الذكاء بمعنى أوسع بكثير، خاصة إذا أردنا التحقيق في ذكاء الآلة.

■ النظم الخبيرة

مفهوم النظام الخبير هو أن الآلة قادرة على التفكير في الحقائق في مجال معين، والعمل بالطريقة نفسها التي يعمل بها عقل الخبير. للقيام بذلك، ستحتاج الآلة إلى معرفة بهذا المجال، وبعض القواعد (التي أنشأها الخبراء) لاتباعها عند حدوث معلومات جديدة، وبعض طرق التواصل مع مستخدم النظام بأكمله.

تسمى هذه الأنظمة بالأنظمة القائمة على القواعد **Rule-based Systems**، أو الأنظمة القائمة على المعرفة، أو بشكل عام، الأنظمة المتخصصة.

من أوائل أنظمة العمل الناجحة كان يسمى **MYCIN**، وهو نظام طبي لتشخيص التهابات الدم. يحتوي **MYCIN** على ما يقرب من 450 قاعدة، ويُزعم أنه أفضل من العديد من الأطباء المبتدئين وبجودة بعض الخبراء.

لم يتم إنشاء قواعدها نظرياً، بل تم بناؤها عبر إجراء مقابلات مع أعداد كبيرة من الخبراء الذين يمكنهم تقديم تقاريرهم من خلال الخبرة المباشرة. ولذلك يمكن أن تعكس القواعد، جزئياً على الأقل، الشكوك الواضحة في الحالات الطبية.

كان الهيكل العام لـ **MYCIN** مشابهاً لجميع الأنظمة الخبيرة. في النظام الخبير، كل قاعدة لها شكل أساسي:

IF (Condition) THEN (Conclusion).

إذا (شرط) ثم (استنتاج).

على سبيل المثال، القاعدة في **MYCIN** يمكن أن تكون إذا كان هناك (عطاس) إذاً هناك (أنفلونزا).

ومع ذلك، قد يكون من الضروري وجود عدة شروط في الوقت نفسه حتى يكون الشرط واضحاً (كي تكون القاعدة صحيحة)، أو على العكس من ذلك، يمكن أن يوجد عدد من الشروط حتى يمكن استخلاص النتيجة. لذا، قد تبدو القاعدة أشبه بما يلي:

IF (condition1 and condition2 or condition3) THEN (conclusion).

إذا (الشرط 1 والشرط 2 أو الشرط 3) ثم (الاستنتاج).

في المثال الصحي السابق قد يصبح هذا:

IF (Sneezing and Coughing or Headache) THEN (flu).

إذا كان هناك (عطاس وسعال أو صداع) إذاً، هناك (الأنفلونزا).

يتم الحصول على القواعد الفعلية المستخدمة من خلال سؤال عدد من الخبراء عن آرائهم. وفي هذه الحالة قال الخبراء الطبيون: ما هي أعراض الأنفلونزا؟ أو إذا كان المريض يعطس ويسعل ماذا يعني ذلك؟

قد يكون هناك العديد من الاستنتاجات المحتملة التي يمكن استخلاصها من مجموعة الحقائق نفسها. وهذه مشكلة بالنسبة للخبير تماماً كما هي الحال بالنسبة للنظام الخبير.

من أجل التعامل مع مثل هذا الموقف، يجب أن يكون لدى النظام قواعد إضافية لمثل هذه الحالات فقط من أجل تحديد مسار العمل الذي يجب اتخاذه، ويشار إلى ذلك باسم فضّ أو حلّ النزاع **Conflict Resolution**.

■ حل النزاعات

هناك العديد من المواقف التي يتم فيها استيفاء عدة شروط ولكن لا يلزم سوى نتيجة واحدة فقط. في مثل هذه الحالات، من الضروري اتخاذ قرار بشأن أي القواعد (التي تم استيفاء جميع شروطها بالكامل) لها الأسبقية. ويجب حل التعارض بين هذه القواعد.

هناك عدد من الاحتمالات؛ يعتمد المرء الفعلي الذي سيتم استخدامه على النظام الخبير نفسه. عند استيفاء جميع شروط العديد من القواعد، فإن القاعدة المحددة تعتمد على تطبيق أحد المعايير التالية:

- ◆ **قاعدة الأولوية العليا:** كل قاعدة لها أولوية مرتبطة بها وفي حالة تطبيق عدة قواعد، يتم اختيار القاعدة ذات الأولوية العليا.
- ◆ **الشروط ذات الأولوية القصوى:** كل شرط له أولوية مرتبطة به. كي يتم اختيار القاعدة، يجب أن تحتوي على شروط الأولوية القصوى.
- ◆ **الأحدث:** يتم اختيار القاعدة التي تم استيفاء شرطها مؤخرًا.
- ◆ **الأكثر تحديدًا:** يتم تحديد القاعدة التي استوفيت معظم الشروط. ويشار إلى هذا أيضًا باسم «المطابقة الأطول **Longest Matching**».
- ◆ **تحديد السياق:** يتم تقسيم القواعد إلى مجموعات، بعضها فقط يكون نشطًا في وقت معين. لكي يتم اختيار القاعدة، يجب أن تنتمي إلى مجموعة نشطة؛ وبهذه الطريقة يمكن للنظام الخبير أن يتكيف بمرور الوقت مع الظروف المختلفة.

تعتمد طريقة حل النزاع المستخدمة بشكل كامل على التطبيق، بالنسبة للأنظمة البسيطة، من المرجح أن يكون الحل نفسه بسيطاً جداً.

في ظروف معينة، قد يُتوقع من النظام الخبير أن يستخلص عدة استنتاجات من مجموعة الشروط نفسها، وقد يُطلب منه فقط إبلاغ المستخدم بأن جميع هذه الشروط تنطبق في ذلك الوقت. ويمكن بعد ذلك تنفيذ أي قرارات أخرى، وبالتالي أي حل للصراع، من قبل المستخدم.

■ قواعد متعددة

تشتمل معظم الأنظمة الخبيرة على عدة قواعد تعتمد على بعضها البعض. هذه منظمة في طبقات. وبالتالي، عندما يتم استيفاء جميع الشروط لقاعدة واحدة بحيث يتم استخلاص استنتاجها، يمكن لهذا الاستنتاج بدوره أن يلبي شرطاً لقاعدة في الطبقة التالية، وهكذا. على سبيل المثال، فكر في نظام إدارة المحرك للمركبة:

قواعد الطبقة الأولى:

➤ إذا (تم الضغط على زر التشغيل) إذا (ابدأ تشغيل المحرك)

➤ إذا (تم اختيار الترس) إذا (تعشيق التروس)

قاعدة الطبقة الثانية:

➤ إذا (تم تشغيل المحرك وتعشيق التروس) إذا (قيادة السيارة)

➤ من الواضح أن كلا قاعدتي الطبقة 1 يجب أن يتم إطلاقها حتى يتم استيفاء كلا الشرطين لإطلاق قاعدة الطبقة 2، بحيث تتمكن السيارة من السير.

يمكن اعتبار أن شرط إطلاق القاعدة 2 أصبح حقيقةً، لأن كلا القاعدتين الضروريتين في الطبقة 1 قد تم إطلاقهما. وبطبيعة الحال، لا يوجد حل للصراع مطلوب في هذه الحالة، لأن القواعد مستقلة.

ومع ذلك، فمن الواضح من هذا المثال أنه إذا قمنا بتضمين عوامل أخرى مثل الضغط على الفرامل، والحد الأدنى لمستوى الوقود في الخزان، والاتجاه المحدد، والجسم أمام السيارة وما إلى ذلك، فإن النظام الخبير يصبح سريعاً أكثر تعقيداً، مع العديد من طبقات من القواعد التي تتعامل مع المتطلبات المتضاربة في كثير من الأحيان. ومن المثير للاهتمام النظر في العدد الإجمالي للقواعد التي قد تكون ضرورية لنظام خبير لقيادة مركبة على شبكة الطرق العادية.

في هذه الحالة، الحقائق (البيانات) الأصلية التي تدخل إلى نظامنا الخبير هي: أولاً، تم الضغط على زر البدء؛ وثانياً، أنه تم اختيار الترس. يتم بعد ذلك إدراك المزيد من الحقائق المتمثلة في تشغيل المحرك وتشغيل التروس. وبعد ذلك، يتم تحقيق الهدف العام أثناء قيادة السيارة. لذلك نبدأ بمجموعة من الحقائق التي تُعد مدخلات لنظام الخبراء لدينا والهدف الذي تم تحقيقه، والذي يمكن القول بأنه الناتج.

■ السلسلة الأمامية

مع النظام الخبير الذي يعمل بشكل طبيعي، ستظهر مجموعة من الحقائق في وقت معين، وستؤدي هذه إلى إطلاق عدد من القواعد، وتحقيق المزيد من الحقائق التي تطلق قواعد أخرى، وهكذا حتى يتم التوصل إلى نتيجة نهائية، تماماً كما تم وصفه في مثال إدارة المحرك.

يُشار إلى طريقة العمل هذه بدءاً من بيانات الإدخال وحتى الهدف النهائي باسم «السلسلة الأمامية Forward Chaining». والغرض من ذلك هو اكتشاف كل ما يمكن استخلاصه من مجموعة معينة من الحقائق.

■ السلسلة الخلفية

يمكن أيضاً استخدام الأنظمة الخبيرة بطريقة عكسية. أي بمعنى، عندما يتم تحقيق الهدف يتم بعد ذلك البحث عن القواعد للتحقيق في الحقائق (البيانات) التي حدثت حتى يتمكن النظام من الوصول إلى النتيجة التي قام بها. من الممكن أيضاً النظر إلى الوراء من خلال النظام لتقييم الحقائق التي يجب علينا إدخالها في النظام من أجل تحقيق هدف محدد.

في المثال المذكور، يمكن طرح السؤال: ما الذي حدث ليقود السيارة؟ سيتم بعد ذلك استخدام السلسلة الخلفية **Backward Chaining** لتوفير الإجابة بأنه تم الضغط على زر البداية، وتم إجراء اختيار الترس.

يعد التسلسل الخلفي مفيداً للتحقق من النظام، لا سيما عندما يجب أن يكون النظام الخبير بالغ الأهمية للسلامة، ولا يمكنه التوصل إلى نتيجة «خاطئة».

من المفيد أيضاً تقييم الأداء العام للنظام لمعرفة ما إذا كانت هناك حاجة إلى قواعد إضافية أو ما إذا كانت مجموعة غريبة من الظروف (المدخلة) يمكن أن تؤدي إلى استخلاص نتيجة غير متوقعة.

■ نقاط جيدة

تتمتع الأنظمة الخبيرة بعدد من المزايا مقارنة بطرق الذكاء الاصطناعي الأخرى. أولاً، يمكن ملاحظة أنه من السهل جداً برمجتها في جهاز حاسوب (أسطر موحدة من التعليمات البرمجية في بنية **IF-THEN**). كل قاعدة عبارة عن كيان منفصل له بياناته المطلوبة للانطلاق، واستنتاجه الفردي الخاص به.

إذا أخذت قاعدة جديدة ضرورية، فيمكن إضافتها إلى النظام الشامل، على الرغم من أن هذا قد يعني، في بعض الأحيان، أيضاً تغيير القواعد التي تحكم حل النزاعات.

النظام مثالي للتعامل مع المعلومات الطبيعية في العالم الحقيقي. ففي نهاية المطاف، هي المعلومات نفسها التي يتناولها الخبراء. لذلك عندما يقول أحد الخبراء: «في مثل هذه الحالة، هذا ما أفعله»، يمكن إدخال ذلك بسهولة في نظام الخبراء.

إن بنية النظام منفصلة عن البيانات، وبالتالي منطقة المشكلة، بمعنى أنه يمكن استخدام بنية النظام الخبير نفسه في مجالات مختلفة تماماً.

إن القواعد نفسها وكيفية دمجها هي التي ستختلف. ومن ثم، يمكن استخدام بنية النظام الخبير نفسه في الحاسوب لنظام التشخيص الطبي ولنظام إدارة المحرك، على الرغم من الحاجة إلى إدخال قواعد مختلفة، وقد تؤدي البيانات المختلفة إلى تفعيل القواعد، ليتم استخلاص استنتاجات مختلفة.

يمكن للنظام الخبير أن يتعامل مع عدم اليقين، كما سنرى عندما ننظر إلى المنطق الضبابي. في هذه الحالة، عندما يتم عرض سلسلة من الحقائق، قد يكون استنتاج النظام، في ضوء تلك الحقائق، أنه متأكد بنسبة 75% من صحة الاستنتاج الذي يتوصل إليه.

قد يكون هذا مؤشراً على أدلة أخرى مفيدة ومفقودة، والتي يمكن أن تجعل النظام مؤكداً صحتها بنسبة 100%. يعد التشخيص الطبي أحد الأمثلة التي تكون فيها قيم الثقة مفيدة.

بالنظر إلى الأعراض المدخلة على أنها حقائق، يمكن للنظام الخبير أن يعطي نتيجة تشير إلى أنه متأكد بنسبة 50% فقط من التشخيص. في مثل هذه الحالة،

نادرًا ما يكون الخبراء أنفسهم متأكدين بنسبة 100% من التشخيص (إن حدث ذلك على الإطلاق)، وهذا ينعكس فقط في النظام نفسه.

إحدى المزايا الكبيرة لمثل هذا النظام، كما هو الحال مع معظم أنظمة الذكاء الاصطناعي، هي سرعة الاستجابة، خاصة عند مقارنتها بسرعة الخبير البشري. عندما تصل آخر قطعة من المعلومات الضرورية، قد يستغرق الأمر جزءًا صغيرًا من الثانية فقط حتى تصل الآلة إلى نهايتها.

قد يستغرق الخبير البشري عدة ثوانٍ، أو في بعض الظروف، عدة دقائق للوصول إلى النتيجة نفسها للمشكلة نفسها. قد يعني هذا توفيرًا ماليًا كبيرًا أو تعزيز سلامة الأفراد. تُعد الأنظمة المتخصصة للتعامل مع إنذارات فشل الماكينة أو الإمداد أو أنظمة التعامل المالي أمثلة ممتازة.

■ مشكلات الأنظمة الخبيرة

هناك عدد من المشكلات مع الأنظمة المتخصصة. أولاً، قد يكون جمع القواعد أمرًا محرجًا إلى حد ما. غالبًا ما يكون من الصعب على الشخص أن يشرح بعبارات بسيطة ما يفعله في المواقف اليومية.

علاوة على ذلك، إذا تم سؤال العديد من الخبراء، فقد يفكرون في المشكلة بطرق مختلفة، بحيث يصعب توحيد القواعد. قد يعني هذا أنهم يختلفون تمامًا حول الحل. في بعض الحالات قد يكون من الممكن الحصول على متوسط النتائج، ولكن في حالات أخرى قد لا يكون ذلك ممكنًا.

لنأخذ على سبيل المثال نظامًا خبيرًا مصممًا لقيادة مركبة: في حالة وجود جسم أمامك مباشرة، قد يقترح أحد الخبراء التوجيه إلى اليسار، في حين قد يفضل آخر

التوجيه إلى اليمين. إن حساب متوسط هذه الاستجابات والتوجيه للأمام مباشرة لن يكون منطقيًا!

ومن الجدير بالذكر أيضًا أن الخبراء البشريين، وخاصة المتخصصين، قد يكونون مكلفين جدًا، خاصة إذا كانت هناك حاجة إلى العديد منهم، وقد يكون من الصعب حجزهم والحصول على إجابات منهم. يذهب كل هذا الوقت والنفقات نحو تكلفة تحقيق النظام الشامل.

واحدة من أكبر مشكلات الأنظمة الخبيرة هي ما يشار إليه باسم «الانفجار التوافقي **Combinatorial Explosion**». بكل بساطة، يصبح النظام الخبير أكبر من اللازم. أحد الأهداف الرئيسية لمثل هذا النظام هو التعامل مع المشكلات والتوصل إلى نتيجة بغض النظر عن الوضع.

ولكن من أجل التعامل مع كل الاحتمالات على الإطلاق، يجب إضافة القواعد باستمرار لتغطية كل موقف محتمل، بغض النظر عن مدى احتمالية حدوثه.

على سبيل المثال، خذ بعين الاعتبار حالة النظام الخبير لقيادة مركبة على الطرق العادية: من غير المرجح أن يمشي فيل أمام السيارة، ومن غير المرجح أن يكون هناك الكثير من الطين، ومن غير المرجح أن يكون هناك أريكة، ولكن قد يكون هناك ويجب أن تغطي القواعد بكل من هذه الظروف.

نظرًا لأن بعض الأنظمة الخبيرة قد تحتوي على عدة آلاف من القواعد، حتى للتعامل مع شيء قد يكون مباشرًا نسبيًا بالنسبة للإنسان، فإنه في كل حدث يجب اختبار العديد من هذه القواعد (إن لم يكن كلها)، جنبًا إلى جنب مع أي حل ضروري للصراع والتسلسل.

لذا فبدلاً من أن يكون أسرع بكثير من الخبير البشري، عندما تكون هناك العديد من القواعد، قد يكون مثل هذا النظام أبطأ بكثير من الإنسان في اتخاذ القرار. قد يكون من الصعب أيضاً تصحيح أخطاء مثل هذا النظام للتأكد من أنه يعمل في كل الاحتمالات، حيث تتفاعل القواعد وربما تلغي بعضها البعض.

نقطة أخيرة يجب توضيحها هنا هي أن الأنظمة الخبيرة هي مجرد نوع واحد من الذكاء الاصطناعي، فهي تشير ببساطة إلى جانب واحد من الذكاء بشكل عام. وعلى وجه الخصوص، يحاول المختصون محاكاة وظيفة التفكير المنطقي للدماغ البشري من حيث كيفية التوصل إلى القرارات في ضوء عدد من الحقائق في وقت معين، بناءً على معرفة الخبراء حول ما يجب فعله بهذه الحقائق.

ومن المهم ألا ننظر إلى مثل هذه الأنظمة باعتبارها مجرد آليات مبرمجة لصنع القرار تعمل دائماً كما نتوقع. من الممكن بالتأكيد تشغيلها بهذه الطريقة، ولكن من الممكن أيضاً تمكينها من التعلم أثناء استخلاص النتائج وتجربة مجالها. من الواضح أن هذا يعتمد على الوظيفة المطلوبة من أجلها. سيتم النظر في هذا التعلم بمزيد من التفصيل لاحقاً.

نكتفي هنا بالقول: إذا كان مثل هذا النظام يستخلص عدداً من الاستنتاجات، فيمكن «مكافأة» القواعد التي أدت إلى الاستنتاج «الفائز/المختار»، بمعنى جعلها أكثر عرضة للرفض و/أو أن تكون جزءاً من النتيجة الشاملة، للاستنتاج في المرة القادمة. على العكس من ذلك، إذا أدت القاعدة المستبعدة إلى نتيجة لم يتم اختيارها، فسيكون احتمال إطلاقها مرة أخرى أقل. النجاح يُكافأ وال فشل يُعاقب! ويمكن تحقيق ذلك أيضاً من تحديد أولويات حل النزاعات.

المنطق الضبابي

مع الأنظمة الخبيرة التي تم تناولها حتى الآن، تم افتراض وجود الشرط أو عدم وجوده، وهذا منطق واضح. الحقيقة إما أن تكون صادقة أو كاذبة.

ومع ذلك، كما رأينا، فقد وجد أنه من المفيد في ظروف معينة أن تكون الاستنتاجات صحيحة جزئياً أو بالأحرى أن يتم تطبيق نسبة الثقة على النتائج.

في الواقع، هذا هو عدد الأشياء التي تظهر فعلاً في حياة الإنسان. إذا كان شخص ما يستحم فإنه يريد أن يكون الماء دافئاً. الماء ليس ساخناً أو بارداً فحسب، بل إنه دافئ. المنطق الضبابي يوفر الأساس لذلك.

لنفترض للحظة أن ماء الاستحمام كي يكون بارداً تماماً ستكون درجة حرارته 0°C ، في حين كي يكون ساخناً تماماً، ستكون درجة حرارته 50°C .

إذا كانت درجة حرارة الماء الفعلي الذي نقيسه تتراوح بين 0 و 50°C ، فيمكننا القول، على سبيل المثال، أنه ساخن بنسبة 65% ، مما يعني أنه دافئ إلى حد ما، ولكن لا يزال أمامه طريق طويل قبل أن يصبح ساخناً. إذا كانت درجة حرارته 12°C ، فهو بارد جداً.

على الرغم من تقديم قيم مياه الاستحمام كنسب مئوية، فإن استخدام المنطق الغامض لا يعني بالضرورة أن درجة الحرارة الفاعلة المقاسة ستكون 65% من 50°C (32.5°C).

المنطق الضبابي موجه أكثر إلى المفهوم البشري لدرجة الحرارة؛ تذكر أنه شكل من أشكال الذكاء الاصطناعي. لذا يمكننا، إذا أردنا، إنشاء علاقة بين درجة الحرارة الفاعلة وقيمة النسبة التي سنخصصها لها، بين 0% و 100% .

■ التضييب

في النظام المنطقي الضبابي، تتمثل الخطوة الأولى في أخذ قيمة فعلية في العالم الحقيقي وجعلها غامضة، ويشار إلى هذا باسم « التضييب ». إذا كنا نتعامل مع درجة حرارة الماء، فسيتم قياس درجة حرارة الماء الفعلية ومن ثم تشويشها.

على سبيل المثال، قد تصبح درجة الحرارة 20°C قيمة غامضة تبلغ 45% . ويمكن بعد ذلك إدخال هذه القيمة الغامضة في نظام الخبراء الغامض الخاص بنا.

يجب أن تكون العلاقة بين القيمة الفعلية والقيمة الغامضة محددة جيداً لمشكلة معينة، ويمكن القيام بذلك باستخدام وسائل رسومية أو ربما جداول بحثية أو حتى العلاقات الرياضية. كمثال يمكن أن يكون لدينا، بالنسبة لدرجة حرارة الماء، ما يلي:

0°C تصبح 0% ، 10°C تصبح 20% ، بينهما أضف 2% لكل درجة مئوية، تصبح 3 درجات مئوية تعادل 6% .

10°C تصبح 20% و 30°C تصبح 80% ، بينهما أضف 3% لكل درجة مئوية، وبذلك تصبح 24°C تعادل 62% .

30°C تصبح 80% و 50°C تصبح 100% ، بينهما أضف 1% لكل درجة مئوية، وبذلك تصبح 43°C تعادل 93% .

يعتمد روتين التضييب الحقيقي كلياً على التطبيق المعين. لقد تم تقديم هذا المثال فقط لإظهار ما هو ممكن.

■ قواعد التضييب

حال تضييب القيمة، يتم تمريرها إلى قواعد التقييم. قواعد التضييب هي تلك التي وجدناها سابقاً فعلاً:

◆ إذا كان (الشرط) إذاً (الاستنتاج)

ومع ذلك، لدينا الآن موقف مفاده أن الشرط قد يكون صحيحاً جزئياً فقط. بالنسبة لنظام خبير يكون فيه الماء إما ساخناً أو بارداً، قد تكون لدينا القواعد:

◆ إذا كان (الماء بارداً) إذاً (قم بتشغيل سخان الماء)

◆ إذا كان (الماء ساخناً) إذاً (أطفئ سخان الماء)

يمكننا الآن استبدال هذه القواعد بقاعدة غامضة واحدة:

◆ إذا كان (الماء ساخناً) ثم (قم بتشغيل سخان الماء)

قد يبدو هذا غريباً للوهلة الأولى، ولكن يجب أن نتذكر أننا نتعامل مع قواعد غامضة؛ لذا فإن جزء الشرط سيكون عبارة عن قيمة مئوية (وليس فقط «نعم» أو «لا»).

ونتيجة لذلك، سيكون جزء الاستنتاج أيضاً بمنزلة قيمة مئوية. الآن لن يتم تشغيل أو إيقاف سخان الماء فحسب، بل سيتم تشغيله إلى حد ما، كما سنرى.

كما رأينا من قبل، مع الأنظمة الخبيرة المباشرة، قد يكون للقاعدة عدة شروط يجب استيفائها قبل أن يتم تفعيل القاعدة. أو على العكس من ذلك، قد يحدث أي شرط من عدد من الشروط لإطلاق القاعدة. على سبيل المثال:

◆ إذا (كان الماء ساخناً وتعرفة الطاقة مرتفعة) ثم (قم بتشغيل سخان الماء) سيتطلب

هذا أن يكون كلا الشرطين صحيحاً حتى يتم تشغيل سخان الماء. بدلاً عن ذلك:

◆ إذا (كان الماء بارداً أو كانت تعرفه الطاقة منخفضة) ثم (قم بتشغيل سخان الماء)

قد يتطلب ذلك أن يكون أحد الشرطين (أو كليهما) صحيحاً حتى يتم تشغيل سخان الماء.

ولكن مع القواعد الغامضة، يكون لكل شرط نسبة مئوية مخصصة له. تعمل معظم الأنظمة الغامضة على النحو التالي؛ عندما يظهر المصطلح **AND**، يتم ترحيل الحد الأدنى لقيمة النسبة المئوية للشرط.

عندما يظهر مصطلح **OR**، يتم ترحيل الحد الأقصى لقيمة النسبة المئوية للشرط. على سبيل المثال، قد يكون لدينا القاعدة الغامضة:

◆ إذا كانت (درجة حرارة الماء ساخنة وتعرفه الطاقة مرتفعة) ثم (قم بتشغيل سخان الماء).

في هذا المثال، دعونا نتخيل أنه بعد التقييد، تم تعيين درجة حرارة الماء بقيمة **62%**، وتم تخصيص تعرفه الطاقة (المضبية أيضاً) بقيمة **48%**. القيمة المرحلة، حيث أن هذه عملية **AND**، ستكون الحد الأدنى للقيمتين **62%** و **48%**، أي ستكون **48%**. على العكس من ذلك، إذا كان الشرط يحتوي على عملية **OR**، فإن القيمة التي تم المضي قدماً بها ستكون الحد الأقصى للقيم المعنية، في هذه الحالة **62%**. سنرى قريباً ما يحدث مع القيمة التي تم المضي قدماً بها.

من الممكن أن يتم تفعيل قاعدة واحدة فقط في النظام الخبير؛ ومع ذلك، فمن المعتاد أن يتم تفعيل عدد من القواعد المختلفة.

ستؤدي كل قاعدة بعد ذلك إلى قيمة مختلفة يتم المضي بها قدماً، ويجب تجميع هذه القيم لتوفير قيمة نهائية واحدة تعني شيئاً ما في العالم الخارجي. في المثال الذي ندرسه هنا، نطلب نسبة إجمالية للإخراج، والتي ستشير إلى مقدار الحاجة إلى تشغيل سخان الماء.

■ إزالة التضييب

هناك عدد من الطرق التي يمكن من خلالها تجميع قيم النسب المئوية المختلفة التي تم المضي قدماً بها. ولعل أبسطها وأكثرها وضوحاً هو مجرد حساب متوسط القيم.

إذا كانت لدينا ثلاث قواعد - $R1$ و $R2$ و $R3$ - والتي أنتجت قيم النسبة المئوية الناتجة $R1=23\%$ ، $R2=81\%$ و $R3=49\%$ ، فإن القيمة المتوسطة ستكون النسب المئوية الثلاث المضافة معاً ومقسمة على ثلاثة (أي 51%). في مثالنا، يشير هذا إلى مقدار تشغيل سخان الماء - ما يزيد قليلاً عن النصف.

ومع ذلك، كما تمت مناقشته سابقاً، غالباً ما تكون بعض القواعد أكثر أهمية من غيرها. وبالتالي فإن الطريقة الأكثر شيوعاً لإزالة الضبابية هي طريقة المتوسط المرجح، والتي يشار إليها باسم طريقة مركز الثقل (COG). في هذه الحالة، يتم ضرب كل قيمة نسبة مئوية ناتجة في قيمة ترجيح مرتبطة بها، ويتم إضافة الإجابات معاً وتقسيمها على إجمالي جميع قيم الترجيح المضافة معاً.

في المثال الذي تم تناوله للتو، لنفترض أن $R1$ أكثر أهمية من العناصر الأخرى، لذلك سنعطيه وزناً قدره 5؛ يحصل $R2$ على وزن 2؛ و $R3$ بترجيح 3. وبالتالي فإن $R2$ هو أقل القواعد أهمية.

عندما جمع هذه الأوزان معاً يكون الجواب 10. الآن نضرب قيمنا لـ $R1-R3$ بأوزانها (3×49 ، 2×81 ، 5×23)، ويكون الناتج 424، والتي عندما نقسمها بمقدار 10 (مجموع الأوزان التي طبقناها) يعطينا قيمة مبهمّة تبلغ 42.4% .

وهذا أقل من الحساب غير المرجح السابق لأنه تم التركيز بشكل أكبر، من خلال الترجيح، على مخرجات القاعدة R1، والتي كانت أقل بكثير من مخرجات القاعدتين الأخريين. وبسبب هذا لن يتم تسخين الماء بالقدر نفسه.

■ نظام الخبير الضبابي

عند بناء نظام الخبير، فإن الأمر ببساطة هو أنه يجب إنشاء القواعد وترتيبها في طبقات مع وضع مخطط مناسب لحل النزاعات.

مع الأنظمة الخبيرة الغامضة، نحتاج بالتأكيد إلى قواعد، ولكن في هذه الحالة يجب أن تكون قواعد غامضة. وقد يكون من الضروري أيضاً وجود خطة لحل النزاع؛ ومع ذلك، قد لا يكون الأمر كذلك، لأن تقنية إزالة الضبابية، في هذه الحالة، قد تأخذ في الاعتبار أشياء أخرى مثل تحديد الأولويات بين القواعد، وتحديد الوقت الذي تنطلق فيه القاعدة، بأن تجعل قيم ترجيح إزالة الضبابية تعتمد على الوقت.

على سبيل المثال، عندما يتم إطلاق قاعدة غامضة لأول مرة، قد تكون قيمة الترجيح النسبي عالية، ولكن مع مرور الوقت، قد يتضاءل الترجيح بالنسبة للوقت.

يمكن أن يصل هذا إلى حد أنه إذا لم يتم إطلاق قاعدة معينة لفترة طويلة، فسيتم ترجيحها على أنها صفر، أي أنه سيتم تجاهلها من قبل النظام.

لذلك، حتى لو تم إطلاق القاعدة، بعد انقضاء فترة زمنية معينة، يمكن التغاضي عنها في روتين إزالة الغموض.

في حالة الأنظمة الخبيرة الغامضة، بالإضافة إلى مجموعة من القواعد الغامضة، يلزم أيضاً وجود خطط مناسبة للتشويش وإلغاء الضبابية. يجب أن تأخذ عملية

إزالة الضبابية في الاعتبار الغرض الفعلي من قيمة المخرج، ربما التحكم في محرك أو مضخة بنسبة من قدراتها الكاملة، أو ربما قيادة السيارة بنسبة مئوية من سرعتها الكاملة.

يمكن أن يكون التعقيم أكثر إشكالية لأن الكميات المختلفة التي يتم تعويمها يمكن أن تكون مصطلحات مختلفة تماماً في الواقع، مثل الفولتية أو درجة الحرارة أو معدل التدفق، والتي يتم قياسها جميعاً بشكل مختلف.

لسوء الحظ، لا توجد طريقة منهجية محددة جيداً ومجربة ومختبرة لبناء طريقة التشويش أو القواعد الغامضة اللاحقة. وبالتالي، من أجل الحصول على نظام خبير غامض ناجح، من الضروري إجراء قدر كبير من التجربة والخطأ للحصول على أفضل أداء.

■ حل المشكلات

لقد نظرنا إلى أحد جوانب الذكاء الاصطناعي الذي يمكننا من خلاله إدخال مجموعة من القواعد التي يجب على النظام اتباعها، بحيث يتم تغطية جميع الاحتمالات. يحدث نوع مختلف من المواقف عند الحاجة إلى إنشاء نظام ذكاء اصطناعي لحل المشكلات بالنسبة لنا. أحد الأمثلة البسيطة على ذلك، هو نظام الملاحة عبر الأقمار الصناعية المستخدم لتوجيه المركبات. نحن نعرف أين هي نقطة البداية ونعرف أيضاً إلى أين نرغب في الوصول، لكننا لا نعرف كيف نصل إلى هناك.

نادرًا ما تكون هذه مشكلة تافهة نظرًا لوجود العديد من الحلول المختلفة. لذلك عادةً ما يكون لدينا متطلبات إضافية، مثل الرغبة في معرفة أسرع طريق أو ربما أقصره، أو قد نطلب حتى الطريق الأكثر جمالاً. في الواقع، هناك أنواع كثيرة من المتطلبات المحتملة عند السفر، من مكان ما لآخر.

يعد هذا النوع من المشكلات نموذجياً للكثيرين، وهو أمر يمكن أن يكون الذكاء الاصطناعي جيداً جداً في حله بسرعة كبيرة.

لنفترض أننا نرغب في السفر من مدينة ريدينغ إلى نيوكاسل في بريطانيا عبر عدة مدن أخرى. هناك العديد من الطرق الممكنة لاتخاذها. على سبيل المثال، يمكننا أن نبدأ بالسفر من ريدينغ إلى أكسفورد أو ربما ريدينغ إلى لندن.

سيكون لكل من هذين المسارين تكاليف مرتبطة بهما من حيث الوقت الذي سيستغرقه الطريق، والوقود المستخدم، والمسافة المقطوعة، وما إلى ذلك. من أكسفورد يمكن للمرء أن يسافر إلى بانبري أو ربما ستراتفورد وما إلى ذلك؛ كل مسار من مدينة إلى أخرى له تكاليفه المرتبطة به. وأخيراً، تم التوصل إلى الهدف النهائي لنيوكاسل.

على افتراض أننا نحد من عدد المدن المحتملة التي يجب أخذها في الاعتبار في رحلتنا من ريدينغ إلى نيوكاسل وأننا نزور المدينة مرة واحدة فقط، فهناك عدد من الطرق التي يمكن لنظام الذكاء الاصطناعي من خلالها البحث عن الحل الأفضل.

البحث الشامل

من أجل تحديد الحل الأفضل لمشكلة السفر لدينا، من الضروري النظر في جميع الاحتمالات. في مثالنا مع ريدينغ كنقطة بداية، يمكننا البحث عن أفضل طريق بالنظر أولاً إلى جميع المدن المحتملة للسفر إليها من ريدينغ؛ بما في ذلك أكسفورد ولندن. بالنسبة لكل مدينة من تلك المدن، يمكننا بعد ذلك النظر في جميع الخيارات الممكنة منها. وفي كل مرحلة سنقوم بتقييم التكلفة الإجمالية لسلوك هذا الطريق.

سنصل في النهاية إلى نيوكاسل عبر عدد من الطرق المختلفة، ولكن نظراً لأن لدينا سجلاً للتكلفة الإجمالية لكل طريق من هذه الطرق، فيمكن إجراء مقارنة بينهم لتحديد الأفضل من حيث المسافة أو الزمن أو أيًا كان المطلوب.

في الأساس، يُبحث في جميع الحلول الممكنة وبعد إجراء المقارنة، طالما كانت معلومات التكلفة دقيقة، فسنكون بالتأكد قادرين على إيجاد الحل الأفضل.

في بعض الحالات، خاصة بالنسبة للطرق البسيطة التي لا تحتوي إلا على عدد قليل من المدن، يكون مثل هذا البحث مقبولاً تماماً.

ومع ذلك، نظراً لعدد الحلول المحتملة، يمكن أن يكون ذلك مشكلة من حيث مقدار ذاكرة الحاسوب المطلوبة، والوقت المستغرق، حتى وإن كان الحاسوب قوياً جداً، لجميع المسارات التي يجب أخذها في الاعتبار وحساب التكاليف المرتبطة بها. ترجع مشكلة الذاكرة إلى حقيقة أنه يجب حفظ كافة المعلومات المتعلقة بجميع المسارات حتى نصل إلى مدينة الهدف نيوكاسل، حيث يمكن إجراء المقارنة النهائية.

■ عمق البحث الأول

في بحث العمق أولاً، تتم تجربة مسار واحد كامل في البداية من نقطة البداية حتى النهاية عند الهدف. ثم يتم تجربة طريق مختلف من البداية إلى النهاية. يمكن إجراء مقارنة التكلفة على الفور بين الاثنين، ويُفضل الاحتفاظ بها. ويمكن تجربة الطرق الأخرى بشكل منهجي بالطريقة نفسها. إذا كنا نبحث فقط عن الحل الأفضل، فيجب الاحتفاظ بمسار واحد فقط في الذاكرة.

إذا، بالمقارنة، يتبين أن طريقاً آخر أفضل من حيث التكلفة (بافتراض أن هذا هو تركيزنا)، فهذا ببساطة يحل محل المسار الأصلي. بالنسبة لهذا النوع من البحث، فإن متطلبات ذاكرة الحاسوب تكون قليلة الأهمية.

إحدى المشكلات الكبيرة المتعلقة بعمليات البحث المتعمق أولاً هي أنه إذا تم اتخاذ اختيار أولي سيئ، فقد ينتج عنه اتجاه يؤدي إلى مسار طويل ومكلف جداً يشمل مئات البلدات. يمكن بعد ذلك البحث عن مسارات أخرى فقيرة وطويلة مماثلة.

وفي الوقت نفسه، قد يكون الحل الأفضل هو البدء في اتجاه أولي مختلف بحيث يمكن اتباع طرق منخفضة التكلفة. مع عمليات عمق البحث أولاً، قد لا يتم اكتشاف مثل هذا الحل لبعض الوقت. إن البحث الموسع لنفس المشكلة كان سيجد مثل هذا الحل بسرعة كبيرة.

■ البحث العميق والمحدود

يمكن التخفيف من مشكلة البحث العميق أولاً في الطرق الطويلة والمكلفة جداً بالبحث العميق والمحدود. يتم تعيين عدد محدد من المدن، حد العمق، في الرحلة أولاً. ثم يبدأ البحث بطريقة العمق أولاً حتى يتم الوصول إلى الرقم المحدد. ثم التخلي عن هذا البحث المحدد، وبدء البحث التالي في وضع العمق الأول.

ومن الواضح أن قدرًا من الحس السليم، حيثما أمكن، والمعرفة بمشكلة معينة يجب تطبيقها من خلال بحث محدود العمق. تُعرف الطريقتان السابقتان (العرض أولاً والعمق أولاً) باسم «البحث الأعمى»، لأنه لا يلزم معرفة سوى القليل عن المشكلة حتى يمضي البحث قدمًا.

مع البحث محدود العمق، سيكون من الغباء، على سبيل المثال، اختيار حد منخفض جدًا عندما يكون من المتوقع أن يؤدي الحل إلى نتيجة من خطوتين أو ثلاث خطوات.

قد تخبرنا دراسة مختصرة للمشكلة أن الحل محتمل، على سبيل المثال، في تسع أو عشر خطوات، لذا قد يكون الاختيار الجيد للحد في هذه الحالة هو 10-11، إذا لم يبدُ الحل جيدًا بعد هذا الرقم، من غير المرجح أن يكون هو الحل الأفضل، لذلك دعونا نستسلم ونجرب طريقًا آخر.

■ بحث ثنائي الاتجاه

تتمثل الاستراتيجية البديلة في تقسيم البحث إلى قسمين، وبدء بحث واحد (للأمام) من نقطة البداية وفي الوقت نفسه لبدء بحث ثانٍ (للخلف) من الهدف. الميزة الكبيرة لهذه التقنية، أنها يمكن أن توفر الكثير من الوقت في إيجاد الحل؛ ومع ذلك، قد يتطلب الأمر ذاكرة كبيرة.

لتحقيق النجاح، في جزء من إحدى عمليات البحث، يجب أيضًا أن تتضمن أسلوبًا للتحقق مما إذا كانت النقطة التي تم الوصول إليها قد تم الوصول إليها حاليًا على هامش البحث الآخر أم لا.

ولذلك فإن معرفة المشكلة مفيدة هنا، حيث أن تمرين التدقيق الهامشي هذا، الذي يمكن أن يستغرق وقتاً طويلاً، لا يلزم تنفيذه حتى يتم الوصول إلى هذا العمق الذي يجعل الحل محتملاً أو ممكناً.

■ مشكلات البحث

من طرق إهدار الوقت الهائل المحتمل هو استكشاف النقاط التي تم الوصول إليها فعلاً، وتم استكشافها بشكل كامل ومتكرر. قد يؤدي ذلك إلى عدم إيجاد حل مطلقاً أو التوصل إلى حل ضعيف أو غير صحيح.

بالنسبة لبعض المشكلات (خاصة البسيطة منها) لا ينبغي أن يحدث مثل هذا الموقف، ولكن يمكن أن تكون المشكلات الأخرى معقدة، وقد يكون هناك العديد من الطرق المتداخلة التي يجب أخذها في الاعتبار.

لشرح المشكلة بمزيد من التفصيل، فكر مرة أخرى في محاولة السفر من ريدينغ إلى نيوكاسل. قد نسلك طريقاً واحداً من ريدينغ إلى أكسفورد ثم إلى كوفنتري، ومن ثم نستكشف كل الاحتمالات من كوفنتري.

كجزء من البحث، قد نحاول بعد ذلك القراءة إلى بانبري ثم إلى كوفنتري، بعد أن وصلنا إلى كوفنتري عبر طريق مختلف. لقد تم فعلاً البحث في جميع المسارات الممكنة للخروج من كوفنتري، مع التكاليف المرتبطة بها، لذا لا فائدة من القيام بالتمرين نفسه مرة أخرى. ومع ذلك، فهذا يعني أن ذاكرة جميع المسارات المختلفة، مع التكاليف المرتبطة بها، مطلوبة حتى يتم العثور على حل شامل.

كجزء من البحث، من الضروري، عند الوصول إلى نقطة جديدة، مقارنة النقطة بتلك التي تم توسيعها فعلاً. وبصرف النظر عن عدم توسيع النقطة مرة أخرى، يمكن مقارنة الطريقين المؤديين إلى تلك النقطة، واختيار أفضل طريق وتجاهل

الخاسر. كما هو الحال مع الذكاء بشكل عام، فإن بحث الذكاء الاصطناعي الذي ينسى أو يتجاهل ماضيه من المرجح أن يرتكب الأخطاء نفسها مرارًا وتكرارًا.

■ البحث الإرشادي

إذا كانت بعض المعلومات موجودة فعلاً حول المشكلة، فهناك استراتيجيات مختلفة لتعديل إجراءات البحث كما هو موضح. يعتمد الأسلوب الفعلي المستخدم في أي حالة معينة إلى حد كبير على طبيعة المعلومات الموجودة. إحدى الطرق الواضحة، والتي يشار إليها باسم أول أفضل بحث، تعمل على توسيع البحث من نقطة معينة بناءً على الحد الأدنى من التكلفة المتوقعة للحل.

ويمكن توسيع ذلك، حيث يلزم إجراء تقديرات التكلفة أو الاحتمالات، لإيجاد الحد الأدنى من الوظيفة الرياضية التي يتم من خلالها وضع تقديرات التكاليف لحلول مختلفة.

يؤدي البحث الأول الجشع إلى توسيع نطاق البحث من خلال إيجاد الحد الأدنى من التكلفة للخطوة التالية المتخذة. لا ينتج عن هذا دائماً الحل الأفضل ولكنه فاعل بشكل عام ويمكن أن يكون سريعاً جداً.

تتضمن التقنيات الأخرى العثور على قائمة بجميع الحلول الممكنة والبدء بحل أولي واحد. يتم بعد ذلك إسقاط هذا الحل فقط من أجل اختيار بديل إذا كانت التكلفة الإجمالية أفضل، والتي بدورها يتم الاحتفاظ بها حتى يتم تحسينها.

يشار إلى هذا عموماً بتسلق التل أو الهبوط الأكثر انحداراً. وهو ما يشار إليه بطريقة البحث المحلي حيث سيتم ترتيب قائمة الحلول بحيث تكون الحلول المتشابهة قريبة من بعضها البعض، مع إجراء تغييرات صغيرة على كل حل.

وبالتالي فإن إحدى مشكلات التقنية هي أنها ستجد الحل الأفضل الذي يكون فقط الأفضل محلياً لتلك الحلول من حولها؛ وبعبارة أخرى، قد لا تجد الحل الأفضل (العالمي) بشكل عام.

ويشار إلى هذا باسم «التعثر في الحد الأدنى المحلي **Getting Stuck in a Local Minimum**». تتضمن طرق التغلب على ذلك الانتقال عشوائياً إلى جزء آخر من قائمة الحلول.

■ تمثيل المعرفة

أحد الجوانب المهمة لأنواع أنظمة الذكاء الاصطناعي التي ننظر إليها هنا هو كيفية تخزين المعلومات أو المعرفة حول المشكلة التي يتم مواجهتها والتعامل معها. في الأساس، يتعين علينا أن نقرر المحتوى الذي سنضعه في قاعدة المعرفة وأفضل طريقة لتمثيل العالم بأسره داخل الحاسوب. وعلى وجه الخصوص، نواجه متطلبات مختلفة جداً اعتماداً على نوع المعلومات التي نقوم بتخزينها.

يجب علينا أن نتعامل مع الأشياء المادية، والوقت، والأفعال، والمعتقدات التي نعتبرها صحيحة في أنواع البيئات المختلفة جميعها. إن محاولة نمذجة وتمثيل كل شيء في العالم ستكون مهمة كبيرة جداً؛ لا يستطيع البشر القيام بذلك، لذا لا يمكننا أن نتوقع من نظام الذكاء الاصطناعي أن يفعل ذلك. ولكن ما يمكن تمثيله هو مجال محدود من المعرفة، مع التركيز على مجال معين أو موضوع الاهتمام.

هناك العديد من الأساليب المختلفة المستخدمة في عالم الذكاء الاصطناعي لتمثيل المعرفة. سنلقي نظرة هنا على إحدى الطرق الأكثر استخداماً، وهي طريقة تسمى الإطارات. تُستخدم الإطارات لتمثيل كميات كبيرة من الأغراض العامة والمعرفة الفطرية بطريقة منظمة.

■ الإطارات

يمثل الإطار المعرفة النموذجية اليومية الضرورية حول كيان ما . وهو عبارة عن ملف داخل الحاسوب، يحوي عدداً من المعلومات المخزنة في فتحات في الملف. كل واحدة من هذه الفتحات هي في حد ذاتها إطار فرعي (أو ملف فرعي) يحتوي على المزيد من مستويات المعلومات المضمنة.

لنفترض أن لدينا نظام ذكاء اصطناعي قائم على الإطار يُستخدم لوصف المنزل. الإطار الأولي هو المنزل. يوجد داخل المنزل عدد من الفتحات، على سبيل المثال؛ غرفة الطعام، والمطبخ، والصالة، وما إلى ذلك. كل من هذه الفتحات هي في حد ذاتها إطار. إذن لدينا إطار مطبخ يحتوي على عدد من الفتحات، على سبيل المثال؛ ثلاجة، وطباخ، وبالوعة، الخ. هذه الفتحات هي بدورها إطارات في حد ذاتها مع فتحات خاصة بها. وهكذا حتى يتم تحقيق عمق كافٍ من المعرفة للمشكلة المطروحة.

يتم استخدام الأساس نفسه تماماً للإجراءات، حيث يتم وصف كل إجراء محتمل بإطار به فتحات تحتوي على أجزاء فرعية. إذا كان لدينا إطار للخروج، فقد يحتوي هذا على فتحات عمل مثل؛ ارتداء الأحذية، وارتداء المعطف، وأخذ مفاتيح السيارة، وما إلى ذلك.

كما نرى، هذا النوع من تمثيل المعرفة يشبه إلى حد كبير الطريقة التي قد يفكر بها البشر إن خرجت، ماذا يجب أن أتذكر فعله؟

في بعض الأحيان، في الحياة اليومية، إذا كانت المهمة التي نواجهها غير عادية أو كانت في وقت ما في المستقبل، فمن المحتمل أننا -البشر- قد ننسى بعض الفترات. لذلك نكتب قائمة بما يتعين علينا القيام به لإنجاز المهمة. هذه القائمة هي في الأساس مبدأ مخزن المعرفة القائم على الإطار في نظام الذكاء الاصطناعي.

يمكن أن يحتوي الإطار (في فتحاته) على جميع أنواع المعلومات المتعلقة بموضوع الإطار. يمكن أن تكون هذه حقائق حول موقف ما أو أشياء داخله. وعلى العكس من ذلك، يمكن أن تكون معرفة بالإجراءات أو الإجراءات التي يتعين تنفيذها. ومن ناحية أخرى، يمكن أن يحتوي الإطار على خليط من هذه المعلومات.

إذا كان الإطار يصف إجراءً ما، فإن بعض فتحاته تصف المهام الفرعية التي يتعين تنفيذها من أجل تنفيذ الإجراء العام. ولكن يجب أيضاً أن يكون هناك مكان للممثل، للإشارة إلى ما الذي سينفذ الإجراء.

ومن الضروري أيضاً أن تكون هناك فتحة للكائن، للإشارة إلى ما سيتم التصرف بناءً عليه أو من فتحة المصدر للإشارة إلى نقطة البداية؛ وفتحة وجهة لوصف وجهة نقطة النهاية لهذا الإجراء.

■ الأساليب وبرامج الخلفية

لقد رأينا حتى الآن كيف يمكن التعامل مع المعرفة بطريقة الإطار. ومع ذلك، لتوظيف هذا في نظام الذكاء الاصطناعي، نحتاج إلى أن نكون قادرين على التعامل مع المعرفة واستجوابها. الأساليب والبرامج الخلفية **Methods and Demons** هي الطريقة التي يمكن من خلالها تنفيذ الإجراءات المناسبة.

الطريقة عبارة عن سلسلة من الأوامر المرتبطة بكيان معين في فتحة إما لمعرفة شيء ما عن الكيان أو لتنفيذ سلسلة من الإجراءات عندما تتغير قيمة الكيان بطريقة معينة. يمكن أن تكون الأساليب إما من ذلك النوع عند تغييرها أو عند الحاجة إليها.

في طريقة «عند التغيير **When Changed**»، سيتم تنفيذ الإجراء المناسب عندما تتغير قيمة الكيان. على سبيل المثال، في نظام الذكاء الاصطناعي لتداول الأسهم، يمكن

مراقبة قيمة أسهم شركة معينة. عندما يتغير الإجراء، يتم تنفيذ الإجراء تلقائياً لاختبار ما إذا كانت قيمة السهم الآن أعلى أو أقل من أرقام العتبة المحددة مسبقاً. وإذا تجاوزت القيمة هذه الحدود، يجوز بيع الأسهم أو شراؤها تلقائياً حسب الاقتضاء.

وفي طريقة «عند الحاجة **When Needed**»، سيتم تنفيذ الإجراء المناسب عند ظهور طلب لمعرفة قيمة الكيان. في مثالنا لسعر السهم، في وقت تقديم طلب «عند الحاجة»، ربما من مستثمر محتمل، سيتم تحديد قيمة أسهم الشركة.

برامج الخلفية هي عبارات **IF** (الشرط) ثم (الاستنتاج) التي يتم إطلاقها عندما تتغير قيمة مصطلح الشرط. بهذه الطريقة، تتشابه برامج الخلفية وأساليب «عند التغيير» إلى حد كبير.

هناك أوجه تشابه واضحة بين الأنظمة الخبيرة - من النوع القائم على القواعد الذي تم تناوله سابقاً - وطريقة تشغيل نظام الإطار من حيث أساليبه وبرامج الخلفية.

في الواقع، من الممكن تماماً تشغيل نظام خبير قائم على الإطار. الاختلافات بين الأساليب طفيفة وتعود إلى الفلسفة الكامنة وراء كل نهج. في نظام الإطارات، تحاول الإطارات أن تتطابق مع الوضع الحالي، والهدف من عملية التفكير التي يتم تنفيذها هو العثور على الإطارات التي تنطبق في أي وقت، أي الموقف أو الإجراء أو الكائن الذي يتم التركيز عليه.

إذا لم يكن هناك تطابق، فسيتم منح التحكم لإطار آخر، ويتم توجيه الانتباه إلى مكان آخر. يمكن أن تتغير قطعة من البيانات أو القيم، ولكن إذا لم يكن لها علاقة بالإطار المتحكم، فقد لا يكون لها أي تأثير.

عادةً ما يعتمد النظام الخبير القائم على القواعد على البيانات كثيرًا جدًا. إذا تغيرت قيمة ما، فقد تؤدي إلى تفعيل بعض القواعد التي ستؤدي إلى استنتاجات قد تؤدي إلى تفعيل قواعد أخرى، وما إلى ذلك. ومع ذلك، ومن خلال استخدام حل النزاعات، يمكن تحديد الأولويات، وهذا يمكن أن يمنع بفاعلية قواعد معينة من أن يكون لها أي تأثير في أوقات معينة؛ مما يؤدي إلى طريقة مشابهة لنظام الإطار.

ومع ذلك، يجب الإشارة إلى أنه بالنسبة لأنظمة الذكاء الاصطناعي العملية، فإن النظام الخبير القائم على القواعد شائع على نطاق واسع، خاصة داخل البيئة الصناعية.

■ تعلم الآلة

أحد أكبر المفاهيم الخاطئة التي يحملها العديد من الأشخاص حول أجهزة الحاسوب هو أنهم غير قادرين على التعلم والتكيف مع الفرص الجديدة. ومن المؤكد أن هذا قد يكون هو الحال بالنسبة لبعض أجهزة الحاسوب حيث أنها فقط مبرمجة، ويتوقع منها أن تعمل فقط كما تمت برمجتها.

ومع ذلك، يمكن للعديد من أجهزة الحاسوب أن تتعلم من التجربة، وتغير طريقة عملها كثيرًا، وتغير سلوكها بطرق أساسية. وبطبيعة الحال، لا بد من منحهم القدرة على القيام بذلك، ولكنهم يستطيعون القيام بذلك.

في الواقع، أحد الجوانب المهمة في مجال الذكاء الاصطناعي هو قدرة أجهزة الحاسوب على التعلم. مع الأنواع الكلاسيكية من الذكاء الاصطناعي التي تم تناولها في هذا الفصل، على الرغم من أنها ربما لا تكون مناسبة تمامًا مثل بعض الأساليب الموصوفة في الفصول اللاحقة للتكيف، بخلاف المدخلات البشرية، إلا أنها قادرة تمامًا على القيام بذلك.

يتم إنشاء النظام الخبير القائم على القواعد، بحكم التعريف، في الأصل عن طريق استخراج سلسلة من القواعد من الخبراء البشريين، إلى جانب أجزاء أخرى من المعلومات، على سبيل المثال: أوراق البيانات في مجال المشكلة.

وينتج عن ذلك بنك من القواعد، يؤدي بعضها إلى قواعد أخرى عندما تتطرق. لذا، عند إدخال بيانات معينة، قد تتضمن سلسلة القواعد الفائزة إطلاق 6 أو 7 قواعد أو أكثر بشكل متتابع، كل قاعدة تؤدي إلى إطلاق القاعدة التالية حتى يتم الوصول إلى النتيجة النهائية للقاعدة النهائية. ويترتب على ذلك أنه حتى تتوصل القاعدة النهائية إلى نتيجة، يجب إطلاق جميع القواعد السابقة في السلسلة.

ربما يكون الاستنتاج جيداً فيما يتعلق بأي إجراء يتم اتخاذه في العالم الخارجي - ربما يتم بيع الأسهم وتحقيق الربح أو ربما يتم إطلاق الإنذار في الوقت المناسب.

يمكن بعد ذلك مكافأة كل قاعدة من القواعد التي شاركت في الاستنتاج الناجح بحيث أنه عند حدوث مجموعة مماثلة من بيانات الإدخال، تكون القواعد أكثر عرضة للتشيط. يمكن تحقيق آلية المكافأة هذه إما من خلال تحديد الأولويات عبر حل النزاعات أو عن طريق زيادة قيم النسبة المئوية للشرط في نظام قائم على قواعد غامضة. والعكس صحيح إذا تبين أن النتيجة النهائية سيئة، حيث تُعاقب القواعد بتناقص الاحتمالات.

يُشار إلى الطريقة العامة المستخدمة باسم تقنية لواء الدلو، لأن المكافأة أو العقوبة يتم إرجاعها، إلى حد ما، من نتيجة الإخراج.

الطريقة المستخدمة، والأوزان المطبقة، ومقدار المرونة التي تتطوي عليها القواعد، كلها تعتمد على مجال المشكلة. قد يكون الأمر، على سبيل المثال، أن بعض القواعد

يجب ألا تتغير بالضرورة لأسباب تتعلق بالسلامة أو الموثوقية، ومن ثم لا يمكن لهذه القواعد أن تشارك في عملية التعلم.

من الممكن أيضاً أن يقوم الحاسوب بإنشاء قواعد جديدة بنفسه. يمكن إنشاء قاعدة جديدة ببساطة عن طريق السماح بحدوث طفرات صغيرة في احتمالات الحالة أو إجراء حل النزاع.

إذا شاركت القاعدة الجديدة بعد ذلك في خاتمة نهائية ناجحة، فستحصل على مكافأة وستتعزيز. أما إذا شاركت في أي استنتاجات غير ناجحة، فسيتم معاقبتها في كل مناسبة حتى تذبل. يعتمد مقدار هذا التعلم المسموح به كلياً على المشكلة ومدى التجربة والخطأ المسموح به في العالم الحقيقي.

■ تعدين البيانات

يعمل البشر من خلال الحصول على الحقائق، التي تسمى البيانات، حول العالم من حولنا واتخاذ خيارات مستتيرة ومعقولة بناءً على تلك المعلومات. قد يكون هذا ببساطة هو تحديد رغيف الخبز الذي يجب شراؤه بناءً على السعر أو القطار الذي يجب اللحاق به اعتماداً على التوقيت والمكان.

ومع ذلك، فإن حجم المعلومات المتاحة لنا الآن، بالنسبة للعديد من القرارات، أكبر بكثير مما تستطيع أدمغتنا البشرية التعامل معه - إنها حالة من الحمل الزائد للمعلومات.

ومن ثم، فإن العديد من الشركات موجودة ببساطة لتقديم المشورة لنا، بسعر، على سبيل المثال، بشأن التأمين الذي يجب شراؤه وكيفية القيام بذلك. نحن نعتمد عليهم للقيام بالتفكير «الصعب» بالنسبة لنا.

حتى عند شراء منتج بسيط فإننا نواجه عددًا كبيرًا من أنواع البيانات المختلفة. موردون وأسعار ومنتجات مختلفة بمقاييس أداء مختلفة وصفقات تأمين وعروض توصيل وما إلى ذلك. لا نريد أن نخدع أنفسنا ونضيع وقتنا وأموالنا. ومع ذلك، فإننا نرغب في الحصول على تلك الصفقة الخاصة، صفقة لأننا حصلنا على النصيحة الصحيحة في الوقت المناسب.

سواء تم تنفيذ ذلك بواسطة إنسان أو آلة، فإن استخراج أجزاء حيوية من المعرفة من تعقيد البيانات المتاحة حول موضوع معين يشار إليه باسم استخراج البيانات.

وأنظمة الذكاء الاصطناعي مناسبة تمامًا لذلك نظرًا لقدرتها على تخزين كميات هائلة من البيانات واستخلاص جميع أنواع العلاقات داخل تلك البيانات من أجل تحقيق الأنماط والاتصالات والروابط ذات المغزى.

يقال إن كمية البيانات في العالم (تقريبًا) تتضاعف كل عام - وهذا يعني أنه خلال فترة عشر سنوات (على سبيل المثال من 2002 إلى 2012) هناك زيادة في البيانات بمقدار 1000 مرة!

تنشأ العديد من مجالات الدراسة الجديدة بسبب التحسينات في التكنولوجيا، ويساهم كل من هذه المدخلات كثيرًا في البيانات المتاحة؛ البيانات التي ليست مفهومة جيدًا وغالبًا ما تكون ذات معاني لا يمكن استخلاصها بسهولة.

في السنوات الأخيرة، فتح مشروع الجينوم البشري تعقيدات الحمض النووي، والآن أصبحنا قادرين على النظر في عمل الأدمغة (حتى العقول البشرية) ومحاولة فهم ما يجري بناءً على الأشكال الجديدة من البيانات التي تم الحصول عليها.

ونتيجة لذلك، هناك فرص عمل جديدة يجب اغتنامها، وتقنيات طبية جديدة يجب تطويرها، والأهم من ذلك كله، هو توفر فهم أكثر تعمقًا للعالم العلمي من حولنا. لكننا بحاجة إلى فهم البيانات التي تم جمعها.

■ الارتباطات

هناك الكثير من المواقف التي توجد فيها أجزاء مختلفة من البيانات. ما قد نرغب في اكتشافه هو أوجه التشابه والروابط والعلاقات بين هذه القطع. أو ربما نرغب في اكتشاف القطع الأكثر أهمية.

من ناحية أخرى، من الممكن أن نرغب في التنبؤ بالنتائج المحتملة في المستقبل بناءً على البيانات المتاحة في الوقت الحالي؛ لذلك نحتاج إلى معرفة أي أجزاء البيانات مفيدة للتنبؤ؛ وأياً ليست كذلك.

أحد الأمثلة على ذلك هو التسوق في السوق المركزية. بالنسبة لكثير من الناس، يعد هذا التسوق ممارسة منتظمة، على سبيل المثال. يتم تنفيذ المتجر الأسبوعي الرئيس مساء كل يوم خميس.

هناك ما يقرب من 100 نوع مختلف من المنتجات المتوفرة في السوق المركزية النموذجي (الأطعمة خاصة)، وفي كل مرة يستخدم فيها هذا الشخص السوق المركزية، يتم الحصول على بيانات حول ما اشتراه.

وعلى مدى فترة من الزمن، يمكن بعد ذلك وضع روابط إحصائية للفرد فيما يتعلق بما يشترونه وعدد المرات التي يشترونه فيها. وبالمثل بالنسبة للمنتجات المختلفة، يمكن استخلاص الروابط من البيانات للإشارة إلى الأشخاص الذين يشترون منتجات معينة ومتى يشترونها.

الهدف الواضح هنا هو أن نكون قادرين على القول: «يوم الخميس المقبل، سيدخل شخص معين إلى السوق المركزية، وسيشتري هذا المنتج وذلك المنتج؛ إذا جعلناهما متاحين، فسيشتري الشخص أيضاً منتجات أخرى بناءً على توقعاتنا».

قد لا يكون التنبؤ دقيقاً بنسبة 100 % لشخص معين في وقت معين، ولكن بالنسبة لأكثر من 100 أو 1000 شخص، قد يكون دقيقاً بدرجة كافية (في المتوسط) لتحقيق ربح كبير. هذه هي الطريقة التي يمكن بها تحقيق الربح من استخراج البيانات.

إحدى التقنيات الإحصائية الأساسية التي يمكن تطبيقها هي تقنية الارتباط؛ لمعرفة كيفية ربط جزء من البيانات بجزء آخر من البيانات. على سبيل المثال، دعونا نفكر في شخص يزور السوق المركزية على مدار عام واحد، وننظر إلى مشترياته من الحليب والجبن.

يمكن بعد ذلك تحليل البيانات المتعلقة بكمية الحليب والجبن التي اشتراها ذلك الشخص، أسبوعاً بعد أسبوع، على مدار فترة عام واحد لمعرفة مدى ارتباط هاتين البيانات ببعضها بعض.

عندما يزيد أحدهما يزيد الآخر، وعندما ينقص أحدهما يزيد الآخر؛ يتوفر عدد من الأدوات الإحصائية لهذا الغرض، مثل تحليل المكونات الرئيسية، لاكتشاف الروابط الرئيسية بين أجزاء مختلفة من البيانات. على سبيل المثال؛ بالنسبة لشخص واحد، قد يكون شراء ملمع الأحذية مرتبطاً ارتباطاً وثيقاً بشراء المخللات. ولكن باستخدام الحاسوب، يمكن إجراء هذا التحليل لجميع المنتجات المختلفة البالغ عددها 100 (أو أكثر).

وقد تم استخدام مثل هذه التقنيات لاكتشاف العديد من الحقائق الغريبة حول أنماط الشراء المنتظمة في الأسواق المركزية. أحد الأمثلة المثيرة للاهتمام هو الرابط، خاصة في ليالي الجمعة، للشباب الذكور البالغين لشراء كل من الحفاضات والعصير؛ سأترك لك استخلاص استنتاجاتك الخاصة حول هذا الموضوع!

■ أشجار القرار

أحد الأساليب المستخدمة لتقليل تعقيد المشكلات، وبالتالي جعل تحليل قاعدة البيانات الضخمة أسهل قليلاً، هو استخدام أشجار القرار. إنها في الأساس طريقة يتم فيها تقسيم قاعدة البيانات بأكملها إلى نسب أكثر قابلية للإدارة، بناءً على متطلبات المستخدم. هذا يجعل من السهل اتباع المسار عبر الشجرة.

في المثال المتعلق بالمشتريات من السوق المركزية، يمكننا أن نقرر فقط النظر في المشتريين من الإناء. سيكون هذا فرعاً محدداً من قبل المستخدم، بحيث لا يلزم أخذ البيانات المرتبطة بالمشتريات إلا في الاعتبار منذ البداية. يمكن أن يتجاهل نظام الذكاء الاصطناعي الفرع (قسم من مجموعة البيانات الإجمالية) الذي يتعامل مع المشتريين المذكورين تماماً.

ومع ذلك، قد نقوم أيضاً بإدخال متطلبات أخرى، والتي يمكن اكتشاف الفروع الناتجة عنها كجزء من التحليل. على سبيل المثال، فقط هؤلاء المشتريين الذين ينفقون أكثر من 60 جنيهًا إسترلينيًا في كل زيارة، هم من يشترون الحساء بانتظام ويشتررون الخضروات الطازجة.

فبدلاً من التعامل مع عدد كبير من الأشخاص (على سبيل المثال 50000)، قد نحتاج، مع مثل هذه المجموعة الفرعية الصغيرة الناتجة عن معايير محددة، إلى النظر في 1000 شخص فقط أو حتى أقل، مما سيؤدي إلى تقليل الوقت المستغرق للتحليل كثيراً جداً، ومن ثم سيؤدي الوقت نفسه إلى تحسين دقة النتائج وبالتالي أي تنبؤات تم إجراؤها.

■ أشجار غامضة

لقد وصفت الشجرة فعلاً بأنها قرار منطقي رتيب لتقطيع قاعدة البيانات بأكملها. لا ينبغي أن يكون هذا هو الحال حيث يكون لدينا أشجار غامضة. في المثال ذكرت كلمة «بانتظام» من حيث تكرار شراء الحساء.

يمكننا تعريف «بانتظام» بطريقة مباشرة (منطقية). على سبيل المثال؛ مرة واحدة على الأقل شهرياً هو منتظم، وأقل من ذلك (في المتوسط) ليس كذلك.

وعلى العكس من ذلك، يمكننا تعريف «بانتظام» بطريقة غامضة. على سبيل المثال؛ لا تبلغ أبداً 0% وكل أسبوع 100%، وأي تردد بين هذه القيم يكون غامضاً بنسبة مئوية مرتبطة به؛ لذا فإن الفرد الذي يشتري الحساء مرة كل شهرين قد يرتبط بقيمة غامضة تبلغ 26% (على سبيل المثال).

إن تشويش شجرة القرار بهذه الطريقة لا يزال يقلل من تعقيد التحليل من حيث عدد المعلومات المختلفة (المنتجات الغذائية في هذه الحالة) التي تم النظر فيها. ومع ذلك، فإن أي نتائج نهائية سيكون لها مستوى من الثقة يرتبط بها. الشخص الذي يحصل على 26% في شراء الحساء لن يكون عضواً قوياً في المجموعة النهائية مثل الشخص الذي يحصل على 84%.

ويمكن إجراء عملية تشويش مماثلة فيما يتعلق بكميات أخرى. في مثالنا، يمكن أن ينفق شخص ما 10 جنيهات إسترلينية أسبوعياً على الخضروات الطازجة، في حين قد ينفق شخص آخر 25 جنيهًا إسترلينيًا أسبوعياً على المنتج نفسه.

يمكن لكل الشخصين شراء الخضروات الطازجة كل أسبوع، ولكن من الواضح أننا قد نهتم بمتسوق واحد أكثر من الآخر. قد نرغب في التركيز بشكل أكبر على المتسوق الذي ينفق الكثير، خاصة عندما يتعلق الأمر بالتبؤ.

أحد الخيارات هو زيادة أبعاد قاعدة البيانات، ببساطة عن طريق تسجيل المزيد من القيم المنفصلة. هذه ليست فكرة جيدة، لأنه في هذه الظروف، في أي وقت، سيظهر الإدخال في قسم واحد فقط من الأقسام المقسمة الجديدة (على سبيل المثال، إنفاق مرتفع على الخضروات أو إنفاق منخفض على الخضروات).

والأكثر ملاءمة هو المفهوم الغامض المتمثل في تخصيص قيمة مئوية للشخص فيما يتعلق بالمبلغ الذي يتم إنفاقه. ويمكن بعد ذلك ربط هذه الكمية بتكرار الشراء لتوفير نسبة مئوية إجمالية للفرد.

لذلك، يمكن منح الفرد قيمة عضوية إجمالية تبلغ (على سبيل المثال) 47% في قاعدة بيانات شراء الخضروات لأنه ينفق 18 جنيهًا إسترلينيًا على الخضروات، ولكنه يشتريها مرة واحدة فقط كل أسبوعين.

■ التطبيقات

كما رأينا، يعد التنقيب في البيانات مفيدًا جدًا لتسويق المنتجات حيث من الممكن تحليل أنماط وسلوكيات الشراء ومن ثم استهداف أي عروض لمجموعة معينة من الأشخاص بطريقة مناسبة لتلك المجموعة.

يعد استخراج البيانات مفيدًا أيضًا لتحليل حركات الأعمال والتمويل، مثل سوق الأوراق المالية. يمكن التنبؤ بالاتجاهات وتقدير النتائج المحتملة إذا تم تنفيذ صفقات معينة.

أحد المجالات الجديدة نسبيًا لاستخراج البيانات التي سيتم استخدامها هو اكتشاف النشاط الإجرامي. أولاً، يمكن مراقبة السلوكيات النموذجية لمجموعات من الأشخاص، وحتى لأفراد معينين، بدقة ومن ثم يمكن تسليط الضوء بسرعة على أي انحرافات لأن النشاط لن يرتبط جيدًا بالسلوك السابق. وبهذه الطريقة يمكن التعرف على جرائم مثل الاحتيال أو الإبلاغ عن استخدام بطاقة الائتمان المسروقة، (Warwick, 2012).

أهمية استخدام الذكاء الاصطناعي في علوم الأرض

مع انتشار عدد لا يحصى من أجهزة الاستشعار في جميع أنحاء العالم، تنمو المعرفة البشرية حول أنظمة الأرض بشكل هائل. تلتقط هذه المستشعرات كل يوم كميات هائلة من البيانات المحددة جغرافياً لمساعدتنا في الحصول على فهم أعمق للبيئة الطبيعية والمجتمع البشري والفضاء الخارجي.

هذه المعلومات حاسمة بالنسبة إلى:

- ♦ تعلم وفهم النظم الطبيعية.
 - ♦ توقع اتجاهات وعواقب الأنشطة البشرية.
 - ♦ تقييم الأخطار التي يتعرض لها المجتمع البشري والأرض.
- على الرغم من الأدوات والأساليب والنظريات العديدة، ما زلنا غير قادرين على الاستفادة بكفاءة كاملة من جم البيانات الضخم هذا.
- النظريات الحالية حول كيفية استجابة الأرض للتغير العالمي مليئة بالافتراضات غير الواقعية والذاتية بسبب التكوين اليدوي للبيانات والتعامل معها.
- لقد تفوقت نماذج الذكاء الاصطناعي (AI) في التعامل مع البيانات التقليدية في كثير من الحالات، مثل التعرف على مناظر الشوارع، واستخراج الطرق، وفهم الصور الطبية.
- أدى الجيل الأول من أبحاث الذكاء الاصطناعي في الثمانينات إلى العديد من النظريات والأساليب الكلاسيكية، لكن النماذج الأولى استغرقت وقتاً طويلاً للتدريب بسبب قيود الحوسبة.
- ومع التطور السريع الأخير للأجهزة والبرمجيات، أدى الذكاء الاصطناعي إلى تسريع التقدم العلمي والاكتشافات في الطب والبيولوجيا والاقتصاد.

في الوقت الحاضر، لم يعد الذكاء الاصطناعي مفهومًا مخبريًا، ولكنه يستخدم عمليًا في العديد من السيناريوهات اليومية مثل الأعمال المصرفية، وتحديد كائن الكاميرا، والاتصالات، ومنظمات الروبوتات المنزلية، وأنظمة التوصية، والقيادة الذاتية، والخروج الذاتي، وما إلى ذلك.

وتعتمد كل هذه التطبيقات على خوارزميات حاسوبية تعمل على هضم المعلومات وحل المشكلات عن طريق محاكاة الجهاز العصبي في الدماغ. ومع ذلك، على عكس العقول البشرية التي يمكنها التمييز بين العديد من الأشياء من خلال التعلم الاستنتاجي لكائن واحد فقط، يجب أن تتعلم خوارزميات الذكاء الاصطناعي آلاف الأنماط قبل اتخاذ قرارات دقيقة (Qiu et al., 2016).

نظرًا للدور الحيوي الذي تلعبه البيانات الضخمة في بناء الذكاء الاصطناعي، فإن التعامل مع البيانات الضخمة أمر بالغ الأهمية لتصميم مسارات عمل موثوقة تعتمد على الذكاء الاصطناعي (Mayer-Schonberger and Cukier, 2013).

قاد علماء الجيولوجيا تطوير أدوات لسد الفجوات بين البيانات العلمية الجيولوجية ونماذج الذكاء الاصطناعي (كما في الشكل الآتي).

هنا، سنتكلم عن سير عمل الحوسبة الحديثة، واحتياجات التخزين، والبنية التحتية السيبرانية الثورية لإجراء أبحاث الذكاء الاصطناعي في علوم الأرض. إن الاختراقات في كل من النظرية والبنية التحتية ستنتقل علم الأرض إلى المرحلة التالية: الذكاء الاصطناعي للأرض (Earth AI).

إننا نتصور أن الذكاء الاصطناعي للأرض عبارة عن مجموعة ضخمة من الأنظمة لرصد الطبيعة والتنبؤ بها تلقائيًا، والمساعدة في تكيف المجتمع البشري مع التغيرات البيئية، وتوجيه البشر لاتخاذ سياسات وقرارات تتعلق بالكوكب، وحمايتهم من الأخطار الجيولوجية.



نظرة عامة على الذكاء الاصطناعي للأرض.

سيكون الذكاء الاصطناعي للأرض أداة مهمة لمواجهة التحديات الكبرى مثل؛ الانفجار السكاني والأمن الغذائي وتغير المناخ. ستلقي هنا نظرة عامة على الوضع الحالي للذكاء الاصطناعي للأرض، وستدرج التحديات الكبرى، ويُنْتَبَأ بالفرص الكبيرة في علوم الأرض.

تقنيات الذكاء الاصطناعي (تعليم الآلة)

قد يكون مصطلح الذكاء الاصطناعي، وهو كلمة طنانة تستخدم في العديد من الأماكن المختلفة، مربكاً لعلماء الجيولوجيا. نطاق تقنيات الذكاء الاصطناعي أكبر بكثير من التقنيات الشائعة مثل تعليم الآلة **Machine Learning (ML)** والتعلم العميق **Deep (DL) Learning**. وعموماً، فإن تعليم الآلة هي مجموعة فرعية من الذكاء الاصطناعي، والتعلم العميق هي مجموعة فرعية من تعليم الآلة.

■ النظام القائم على المعرفة

قبل أن يصبح تعلم الآلة فيروسيًا، كانت الأنظمة القائمة على القواعد تهيمن على تقنيات هضم البيانات ودعم القرار، ولا تزال تقوم بتحليل البيانات المهمة حتى اليوم. تعتمد المناهج المبنية على القواعد على مجموعة من القواعد، كل منها يصور بعض المعرفة السياقية (Clancey, 1983)، وعادة ما تظهر على شكل تعبيرات **IF/THEN**.

على سبيل المثال، إذا وصل النهر إلى مرحلة العمل (الفيضان)، فيجب على وكالة الأرصاد الجوية اتخاذ إجراءات التخفيف استعداداً لنشاط هيدرولوجي كبير محتمل (NWS, 2021).

وبما أن القواعد هي معرفة عامة وتحتوي على أحكام أقل غموضاً، فإن الأنظمة القائمة على القواعد تتمتع باستقرار وبقين جيدين جداً، ويتم رؤيتها بشكل شائع في العديد من الصناعات.

■ تعليم الآلي الاحتمالي

يقدم تعليم الآلة الاحتمالي **Probabilistic Machine Learning** طريقة عملية للآلات الهندسية التي يمكن أن تتطور من خلال تعلم بيانات واقعية. تستخدم معظم نماذج تعليم الآلة النظرية الاحتمالية لمواجهة تحديات عدم اليقين.

يمكن استخدام نظرية الاحتمالية للتعبير عن العديد من أشكال التباينات والضوضاء ومنع الأخطاء المفرطة في التنبؤ. في تعلم الآلة، يمكن للمفكر الاحتمالي

أن يستنتج دالة الاحتمالية بالنظر إلى بيانات الإدخال ويقوم في النهاية بالتنبؤات مع التحكم في عدم اليقين (Pearl, 1988).

■ التعلم غير الخاضع للرقابة

يبحث التعليم غير الخاضع للرقابة **Unsupervised Learning** عن الأنماط المخفية في مجموعة البيانات بدون تعليقات توضيحية أو تدخل (Ferran et al., 2013). ويختلف التعليم غير الخاضع للإشراف عن التعليم الخاضع للإشراف والذي يخضع كثيرًا للتسميات اليدوية، حيث يقوم بالتحقق من كثافات الاحتمالية العامة بناءً على المدخلات ببساطة.

أحد الأمثلة الشائعة؛ هو التحليل العنقودي المترسخ في التحليل العلمي للأرض. على سبيل المثال، جميع العينات الجيوكيميائية (Templ et al., 2008). يتم تجميع المجموعات تلقائيًا باستخدام مقاييس المسافة مثل المسافة الإقليدية في مساحة مميزة وخوارزميات مثل **K Means** وماركوف المخفي **Hidden Markov**، وما إلى ذلك.

■ التعلم الخاضع للإشراف

تتضمن معظم تطبيقات الذكاء الاصطناعي الحالية التعليم الخاضع للإشراف **Supervised Learning** والذي يبني محولاً يربط المخرجات بالمدخلات. ويمكن تصنيفها أيضًا إلى نوعين فرعيين: الانحدار **Regression** والتصنيف **Classification**.

يمكن أن ينتج الانحدار أي رقم مستمر في نطاق (كالضغط الجوي ودرجة حرارة السطح وتساقط الأمطار). تقتصر مخرجات نموذج التصنيف على مجموعة من الأرقام الثابتة مسبقًا. يحتوي التعلم الخاضع للإشراف على مجموعة واسعة من الأساليب بما في ذلك أقرب جار (KNN)، (Henley and Hand, 1996)، وشجرة القرار (DT)، (Safavian and Landgrebe, 1991)، وآلة ناقل الدعم (SVM)، والغابات العشوائية (RF) (Breiman, 2001)، والشبكة العصبية الاصطناعية (ANN) (Gurney, 2014)، إلخ. يمكن استخدام الخوارزميات الوصفية مثل؛ (Breiman, 1996) Baging (bootstrapping) أو **Boosting** (أي AdaBoost) لتعزيز الدقة والاستقرار.

■ التعلم العميق

يشير التعلم العميق (DL) إلى مجموعة قوية من الشبكات العصبية ذات الطبقات المخفية والبنية المعقدة مقارنة بأسلافها (أي متعدد الطبقات **Perceptron**). يمكن استخدام التعلم العميق لطرق خاضعة أو غير خاضعة أو شبه خاضعة للإشراف. من الشائع أن تُستخدم الشبكات العصبية التلافيفية العميقة (DCNN) لاستخراج السمات وتقليل الأبعاد (Krizhevsky et al., 2012).

عادةً ما تؤدي قوة الشبكات العصبية CNN في تمثيل التعلم إلى أداء أفضل في التنبؤ. ومع ذلك، يأتي الأداء المتفوق مع وجود قيود على أن التعلم بواسطة التعلم أكثر تعقيداً للبيانات، وغالباً ما يقتصر تطبيقه على الحالات التي تتوفر فيها كميات كبيرة من البيانات عالية الجودة، (Mousavi et al., 2019).

وفقاً لتدفق البيانات، يمكن تقسيم التعلم العميق عمومًا إلى فرعين رئيسيين: الشبكات العصبية المغذية (FNN)، والشبكات العصبية المتكررة (RNN). الأول بسيط حيث تتحرك المعلومات في اتجاه واحد للأمام. يحتوي الآخر على معلومات تتحرك في دائرة، مما يعني أنه سيتم إدخال مخرجات الخطوة السابقة في الخطوة المستمرة. يحتوي كل فرع على العديد من المتغيرات ويشكل مجموعة واسعة من الشبكات المتقدمة مثل: ResNet (He et al., 2016)،

و U-Net (Ronneberger et al., 2015)

و PSP (Zhao et al., 2017)

و SegNet (Badrinarayanan et al., 2017)

و VGG-16, DenseNet (Iandola et al., 2014)

و YOLO (Redmon and Farhadi, 2018)

و R-CNN (Girshick, 2015)

و Mask RCNN (He et al., 2017)

و DeepLab (Chen et al., 2017)

■ تعزيز التعليم

يجد التعليم المعزز **Reinforcement Learning** طريقة مثالية لتعظيم إشارة المكافأة الرقمية (Sutton and Barto, 2018). يجب أن تقوم وحدة التعلم النمطية بتحديد الإجراءات من خلال قراراتها الخاصة للعثور على أفضل مسار (ليس فريداً) مع أكبر قدر من المكافأة. وهو يختلف عن التعلم الخاضع للإشراف أو غير الخاضع له، والذي لا يتطلب مجموعة بيانات تدريبية أو العثور على بنية مخفية في مجموعات البيانات غير المسماة.

الميزة الرئيسية هي أنه يأخذ في الاعتبار صراحة المشكلات الموجهة نحو الأهداف من قبل الوكلاء الذين يتفاعلون مع بيئة غير مؤكدة وحلول محتملة لا تعد ولا تحصى. مصطلح «الوكيل» ليس بالضرورة روبوتاً حقيقياً، ولكنه قد يكون برنامجاً افتراضياً لاستكشاف البيانات.

يعد التعلم المعزز مناسباً للمواقف التي يكون فيها من غير الواقعي استرجاع بيانات السلوكيات المرغوبة والتي تكون صحيحة وشاملة لجميع الاحتمالات التي قد يتصرف بها الوكلاء.

الأبحاث الحالية حول الذكاء الاصطناعي في علوم الأرض

■ الغلاف الصخري

يثير النمو السكاني البشري تحديات هائلة في الحاجة إلى موارد طبيعية للحفاظ على السكان، ولكنه يزيد من الضعف من خلال تعريض المزيد من الناس للأخطار الجيولوجية الطبيعية (كالزلازل التكتونية والبراكين والانهيارات الأرضية)، والبشرية (كالزلازل المصطنعة وانهيار السدود).

ويتطلب الحفاظ على البنية التحتية في مواجهة هذه التحديات فهماً أعمق لهذه الظواهر والآليات الفيزيائية التي تقف وراءها، وهو ما يقدمه علماء الأرض. على الرغم من أنه لا يزال بعيداً عن التنفيذ الكامل، إلا أن الذكاء الاصطناعي أصبح الآن منتشرًا على نطاق واسع في جميع مجالات الجيولوجيا، بما في ذلك البحث عن المعادن (Saliu et al., 2020)، والطاقة (Koroteev and Tekic, 2021).

■ البراكين

في علم البراكين، تم استخدام التحليلات اليدوية لانبعاثات الغاز، وقياس التشوه، والإشارات الزلزالية لعقود من الزمن لرصد وتخفيف وتقليل الأخطار المرتبطة بالأخطار البركانية (Tilling, 1989).

أحد التطبيقات الرئيسية للذكاء الاصطناعي في مراقبة البراكين هو التمييز بين الهزات البركانية الزلزالية وما يماثلها من أحداث، بما في ذلك الزلازل والانهيانات الأرضية ونوافير الحمم البركانية والرياح والرعدي.

تتضمن تقنيات تعلم الآلة التي تم اختبارها بنجاح:

Hidden (Masotti et al., 2006)، وANN (Scarpetta et al., 2005)، ونماذج SVM، وMarkov (Beyreuther et al., 2008)، والمنطق الضبابي (Hibert et al., 2014). ويمكن أيضاً إجراء التنبؤ على المدى القصير بالانفجارات المفاجئة التي يحركها البخار باستخدام الذكاء الاصطناعي/التعلم الآلي من خلال الكشف عن الأسلاف Precursors من البيانات الزلزالية المتدفقة (Dempsey et al., 2020).

إن قدرة الذكاء الاصطناعي على تحديد انفجارات الطاقة التي تحدث من بضعة ساعات إلى عدة أيام قبل الانفجارات الكبيرة هي أمر مفيد، وأثبت التعلم الآلي قدرته على إصدار تنبيهات بركانية قصيرة المدى منقذة للحياة في المستقبل.

■ الانهيارات الأرضية

وتسبب الانهيارات الأرضية في المناطق الجبلية خسائر بمليارات الدولارات سنوياً. تم تخصيص تطبيقات الذكاء الاصطناعي في دراسات الانهيارات الأرضية بشكل أساسي لجهود تقدير الأخطار (Mousavi et al., 2011).

لقد جرب رسم خرائط قابلية الانهيارات الأرضية أساليب التعلم الآلي مثل الانحدار اللوجستي (Umar et al., 2014)، و ANN (Nefeslioglu et al., 2008) و SVM (Peng et al., 2014).

يتم قياس مجموعة من متغيرات التحكم مثل: المنحدر الأرضي، والغطاء النباتي، وتساقط الأمطار، وكتلة التربة، والإعداد الهيدرولوجي، واستخدامها كمدخلات تعلم الآلة لحساب احتمالات الانهيارات الأرضية.

مجموعة أخرى من تطبيقات الذكاء الاصطناعي هي أتمتة تحديد الانهيارات الأرضية باستخدام صور الاستشعار عن بعد (RS). على سبيل المثال، تم تقييم CNN في إنجاز الكشف التلقائي عن الانهيارات الأرضية في نيبال، وخلص إلى أن CNN «لا تزال في مهدها» للكشف عن الانهيارات الأرضية (Ghorbanzadeh et al., 2019).

ولا يزال التنبؤ الدقيق بزمان الانهيارات الأرضية يمثل تحدياً حيوياً (Korup and Stolle, 2014). ورغم أن معرفتنا بالآلية الأساسية لفشل المنحدرات يمكن دمجها في نماذج فيزيائية، فإن عدم كفاية المراقبة عالية الدقة للتربة والمياه الجوفية يقيدنا من تشغيل النماذج بفاعلية أو تعزيز الدقة.

تظل جودة بيانات الإدخال والتركيب المحتمل من المشكلات الرئيسة التي تؤثر على دقة النماذج في سيناريوهات التنبؤ في العالم الحقيقي. ومع ذلك، فإن أساليب التنقيب عن البيانات والتعلم الآلي تحظى بشعبية متزايدة في معالجة التنبؤ بالانهيارات الأرضية.

■ الغلاف المائي

استفادت أبحاث الغلاف المائي كثيراً من أساليب وتطبيقات الذكاء الاصطناعي (Hu et al., 2018; Kratzert et al., 2018; Mo et al., 2019; Mohajerani et al., 2019; Naganna et al., 2019; Shen, 2018). وسيتناول هذا القسم ثلاثة جوانب: تساقط الأمطار، والمياه السطحية، والمياه الجوفية.

◆ تساقط الأمطار

يتضمن التنبؤ بتساقط الأمطار تعلم أنماط غير خطية معقدة في البيانات. تشمل الطرق المقترحة للتنبؤ بتساقط الأمطار استخدام مجموعات من **RNNs** و **SVMs** ((Hong, 2008; Lin et al., 2009) أو تحليل الطيف المفرد (**SSA**) و **SVMs** (Sivapragasam et al., 2001).

تم توسيع هذا النهج متعدد النماذج ليشمل **ANN** و **KNN** و **SVM** على أساس شعاعي للتنبؤ بتساقط الأمطار اليومي أو الشهري (Sumi et al., 2012).

تشمل الأمثلة الأخرى استخدام **LSTMs** التلافيفي (Shi et al., 2015)، والترددات الراديوية لاستعادة معدلات تساقط الأمطار من صور الأقمار الصناعية الضوئية (Kühnlein et al., 2014)، والجمع بين **ANN** و **SVM** و **DT** لتساقط الأمطار على مدى التنبؤ القصير (Ingsrisawang et al., 2008).

♦ المياه السطحية

تم ممارسة الأساليب المعتمدة على الذكاء الاصطناعي بشكل متكرر في نمذجة المشكلات الهيدرولوجية غير الخطية (Fathian et al., 2019; Yaseen et al., 2015).

تُظهر الأساليب القائمة على التعلم الآلي، مثل الأنظمة الهجينة بين الموجات العصبية والخلايا العصبية، أداءً مماثلاً للتنبؤ بتدفق المجاري المائية (Anctil and Tape, 2004)، ومراقبة جودة المياه الساحلية (Kim et al., 2014)، واكتشاف العلاقات المعقدة بين مستوى المياه وتصريفها (Bhattacharya and Solomatine, 2005).

كما أن FNN والانحدار المعمم NN والمنطق الضبابي مفيدة أيضاً في ملء بيانات مستوى المياه غير المقاسة (Turan and Yurdusev, 2009). يستخدم باحثو الأنهار ANN ونظام الاستدلال الضبابي التكيفي القائم على الشبكة (ANFIS) و NN المقترنة بالموجات للتنبؤ بحمل الرواسب (Olyaie et al., 2015) ومستوى المياه (Seo et al., 2015)، ويكتشفون أن تقنيات تعلم الآلة أكثر كفاءة.

يتم اختبار الأساليب المقترنة مثل مجموعة ANN والخوارزميات الافتراضية والأصلية (GA)، وتحسين الإنتاجية (بنسبة 3-11 %) (Perea et al., 2019). تم استخدام RNN مثل LSTM في اكتشاف المواد الملوثة في الماء (Wang et al., 2019b).

توفر بيانات الاستشعار عن بعد مثل صور Landsat 8 مصادر بيانات غنية للتعلم الآلي لتحديد تركيزات معلمات جودة المياه السطحية المختلفة (Sharaf El Din et al., 2017). وبالنظر إلى أبحاث المياه، فقد تم استخدام نماذج التعلم الآلي بنجاح في التنبؤ باستهلاك المياه حول إنديانابوليس (Shah et al., 2018) والعديد من السيناريوهات الأخرى.

■ الغلاف الجوي

يسلط هذا القسم الضوء على ما أُحرز من تقدم في تطوير الذكاء الاصطناعي في الظواهر الجوية. بالإضافة إلى معالجة الأخطار الجيولوجية المحددة أدناه، يتمتع الذكاء الاصطناعي بأهمية متزايدة في جميع جوانب الأرصاد الجوية بشكل أساسي، وخاصة لتحسين مهارة وكفاءة التنبؤ العددي بالطقس، وفي استيعاب وتفسير الكميات الهائلة من البيانات الواردة في عمليات رصد الأقمار الصناعية للطقس (Boukabara et al., 2021).

■ الأعاصير

تعد الأعاصير المدارية من بين أكثر الكوارث تكلفة (Klotzbach et al., 2018). تم استخدام التعليم الآلي للتنبؤ بمسار الإعصار وتقييم الأضرار باستخدام بيانات إعادة التحليل (Giffard-Roisin et al., 2018) وصور الأقمار الصناعية (Cao and Choe, 2019; Yu et al., 2020).

حقق نموذج التعليم الآلي الخاص بالتعليق التوضيحي للضرر دقة تزيد عن 97% لإعصار هاري. يمكن لنماذج التنبؤ بالسلاسل الزمنية مثل RNN و ConvLSTM أن تتعلم سلوك الإعصار وتحسب المسارات (Alemany et al., 2019; Kim et al., 2019). تُظهر التجارب الموسعة لإعادة تحليل المناخ باستخدام بيانات تم جمعها على مدى 20 عامًا، أن ConvLSTM يتمتع بدقة أعلى من الأساليب الأخرى. تُستخدم أيضًا مصادر البيانات الأخرى مثل بيانات الأقمار الصناعية السلبية بالموجات الدقيقة مع التعليم العميق لرصد الأعاصير المدارية (Wimmers et al., 2019).

لتبسيط المشكلة عن طريق إزالة الأحداث صغيرة الحجم ذات التأثير المنخفض، نجح التعليم العميق في اكتشاف العواصف الشديدة فقط (Maskey et al., 2018). ومن منظور التأثير الاجتماعي، استخدم بعض الباحثين التعلم الآلي لتحديد التغريدات الحرجة المتعلقة بالإعصار بسرعة (Shams et al., 2019).

■ الجفاف الجوي

يعد الجفاف خطراً طبيعياً معقداً يسبب أضراراً اقتصادية واجتماعية وبيئية هائلة على مستوى العالم كل عام، (Wilhite, 2016).

وقد طبقت الجهود التعلم الآلي للتنبؤ بالجفاف في أفريقيا (Belayneh et al., 2016)، وأستراليا، والولايات المتحدة الأمريكية (Agana and Homaifar, 2018)، والصين (Chen et al., 2012).

استخدمت بعض الدراسات التعلم الآلي للتنبؤ بمؤشرات الجفاف (Sutanto et al., 2019)، مثل SPEI و SPI (Belayneh and Adamowski, 2012; Maca and Sadri and Burn, 2016)، وأخرى لتقدير شدة الجفاف في المواقع غير المقاسة (Pech, 2012)، استخدمت فيها نموذجاً عالي الدقة للتنبؤ بالجفاف مدعوماً بالتعلم الآلي باستخدام بيانات الاستشعار عن بعد (Rhee and Im, 2017).

فيما يتعلق بمعالجة المنتج، تتم مقارنة طرق تعلم الآلة المختلفة في تقليص حجم تساقط الأمطار كل ساعة إلى البيانات الشهرية، وتعمل آلات المتجهات ذات الصلة بشكل أفضل، (Sachindra et al., 2018).

■ حرائق الغابات

تتزايد حرائق الغابات في العديد من البلدان، مما يفرض آثاراً ضارة على صحة الإنسان والاقتصاد. يعد الكشف عن الحرائق والتدخل المبكر أمراً حيوياً لتقليل أضرار حرائق الغابات.

تم تطبيق طرق مختلفة للذكاء الاصطناعي/التعلم الآلي لتحسين اكتشاف الحرائق والتنبؤ بها (Jain et al., 2020)، وتصنيف خطورة حرائق الغابات ورسم خريطة لها (Brewer et al., 2005)، واكتشاف حرائق الغابات تلقائياً باستخدام الطائرات بدون طيار أو صور الأقمار الصناعية (Zhao et al., 2018).

استخدمت دراسات رفيعة المستوى الذكاء الاصطناعي في تحسين التنبؤ بأعمدة الدخان من خلال الجمع بين التعلم الآلي وعمليات رصد الأقمار الصناعية (مثل (Yao et al., 2018) (CALIPSO) واستنتاج توسع الأوزون وتوزيعه (Watson et al., 2019). وتشمل التطبيقات الأخرى تحديد حرائق الغابات على صور جمهورية صربسكا (Sayad et al., 2019)، وتقييم قضايا صحة الإنسان المرتبطة بسوء نوعية الهواء، (Reid et al., 2016).

وفي الوقت نفسه، يستخدم العلماء التعلم الآلي لتتبع حرائق الغابات التي يسببها الإنسان، ووجدوا أن الترددات اللاسلكية هي الأكثر دقة حالياً بين تلك التي تم اختبارها، (Rodrigues and de la Riva, 2014).

■ العواصف الترابية

ترتبط مصادر الغبار بآثار صحية وتأثيرات اجتماعية واقتصادية متعددة، بما في ذلك الأمراض المعدية (Tong et al., 2017) والسلامة على الطرق السريعة (Ashley et al., 2015).

يتم استخدام التعليم الآلي بشكل متزايد للكشف عن مصادر الغبار والنقل وقابلية تآكل الرياح على مستويات مختلفة (Boloorani et al., 2022; Gholami et al., 2021; Lin et al., 2020).

تم استخدام التعليم الآلي في نمذجة الانبعاثات العكسية لتحسين الدقة وتفوق على نموذج النقل الكيميائي التقليدي (Jin et al., 2020). تم تطوير خريطة حساسية مصدر الغبار (DSSM) باستخدام RS والتعليم الآلي لإظهار مصادر الغبار 2005-2016 في إيران، (Boroughani et al., 2020).

تم قياس نماذج التعلم الآلي المختلفة للتحقق من قابلية التربة لإثارة الغبار، ووجد أن التردد اللاسلكي يعمل بشكل أفضل (Gholami et al., 2021). على المستوى العالمي، لا يزال تعلم الآلة قابلاً للتطبيق (Lee et al., 2021).

■ ملوثات الهواء بشرية المنشأ

ويرتبط تلوث الهواء بأكثر من سبعة ملايين حالة وفاة مبكرة كل عام، (WHO, 2021). تتبع غالبيتها من التعرض لـ O_3 (الأوزون) و $PM_{2.5}$ (الجزيئات الدقيقة).

ومع ذلك، فإن الديناميكيات المتغيرة باستمرار تجعل من الصعب جداً على نماذج الحاسوب التنبؤ بجودة الهواء. لقد شارك الذكاء الاصطناعي في مواجهة هذه التحديات، لا سيما فيما يتعلق بالتنبؤ بـ O_3 و $PM_{2.5}$ وأكاسيد النيتروجين، وهي مادة كيميائية أولية تساهم في تكوين O_3 (Nowack et al., 2018; Wang et al., 2012; Zhang et al., 2012; Wu et al., 2017; al., 2003). غالباً ما تستخدم الأعمال السابقة أساليب الشبكة العصبية لتحسين التنبؤ بجودة الهواء (Abdul-Wahab and Al-Alawi, 1995; Ruiz-Suarez et al., 2001; Kolehmainen et al., 2002).

في الآونة الأخيرة، يتم استخدام خوارزميات ML الأكثر تقدماً لتعزيز التنبؤ بـ O_3 و NO_2 ويكون SVM أفضل من NN في التنبؤ بتركيزات O_3 القصوى اليومية (Chelani, 2010).

بالنسبة للتنبؤ بجودة هواء الحبوب الصغيرة، يمكن لـ DL إكمال المهام الشائعة مثل الفسيفساء أو إدراج القيم المفقودة أو اختيار السمات (Du et al., 2018; Fan et al., 2017; Qi et al., 2018).

■ المحيط الحيوي

يمثل المحيط الحيوي الأجزاء الحية من نظام الأرض. يقدم هذا القسم بإيجاز حالة الذكاء الاصطناعي في علوم الحياة تحت ثلاثة مواضيع: النبات والحيوان والكائنات الحية الدقيقة.

■ النباتات

تعد الجغرافيا النباتية، وهي دراسة توزيع النباتات، مجالاً نشطاً في أبحاث الذكاء الاصطناعي للأرض، وأصبح استخدام صور **RS** وتعلم الآلة، وخاصة **DL**، هو الأسلوب السائد بسبب التكلفة المنخفضة والدقة العالية لتصنيف تعلم الآلة.

تتزايد الخرائط المشتقة من الذكاء الاصطناعي في الدراسات الجغرافية الحيوية. يمكن لـ **DCNN**، التي تم تدريبها على مجموعة بيانات عامة من الأوراق للتمييز بين أربعة عشر محصولاً وستة وعشرين مرضاً، أن تحقق دقة بنسبة 99.35% (**Mohanty et al., 2016; Sun et al., 2019a**).

تتمتع الزراعة بالعديد من سيناريوهات الاستخدام العميق للذكاء الاصطناعي مثل اكتشاف الأمراض والتنبؤ بإنتاج المحاصيل وتوصيات الري (**Kamilaris et al., 2017**). يمكن لنموذج **RNN-CNN** المقترن، التنبؤ بمحصول الذرة في الغرب الأوسط للولايات المتحدة (**Sun et al., 2019b**)، ويمكن أن يكون بديلاً موثقاً ومنخفض التكلفة في توجيه الري (**Vij et al., 2020**).

■ الحيوان

يوفر التقدم في تقنيات الاستشعار بيانات كبيرة عن الحيوانات مثل نظام تحديد المواقع العالمي (**GPS**) والمراقبة بالفيديو. جنباً إلى جنب مع البيانات التي تم جمعها يدوياً من قبل المتخصصين والعلماء المواطنين، توجد مجموعة بيانات ضخمة حول مواقع الحيوانات البرية، وحركاتها، وسلوكياتها، ورفاهيتها. وبالمثل، أصبحت البيانات الضخمة معياراً في الزراعة الحيوانية (**Neethirajan, 2020**).

بناءً على مجموعات البيانات هذه، يركز تطبيق الذكاء الاصطناعي في علم الحيوان على اكتشاف الحيوانات وإحصائها ووصفها وسلوكها من خلال الصور. لقد أثبت **DL** فاعليته في التعرف على الحيوانات البرية من خلال صور مصيدة الكاميرا

(Chen et al., 2014)، وإسناد سلوكيات الحياة البرية (Norouzzadeh et al., 2018)، والكشف عن نداءات الخفافيش بالموجات فوق الصوتية (Mac Aodha et al., 2018)، وإسقاط غوص طيور الغاق (Browning et al., 2018).

بالنسبة للحيوانات الحضرية، يمكن لـ DL تحليل البيانات الصوتية للمدينة (Fairbrass et al., 2019) ومسارات الحيوانات (Maekawa et al., 2020). مع ذلك، وعلى الرغم من التقدم، لا يزال الذكاء الاصطناعي في علم الحيوان في مرحلة تجريبية ولم يتغلغل بشكل كامل في مجتمع علم الحيوان.

■ الكائنات الحية الدقيقة

على غرار علم الحيوان، تتم دراسة الذكاء الاصطناعي بشكل مكثف في علم الأحياء الدقيقة (Egli et al., 2020). حددت DL 30 مسبباً للأمراض البكتيرية الشائعة، (Ho et al., 2019)، واكتشفت البكتيريا المسببة للأمراض في الطعام والماء على الصور المجسمة بفاصل زمني، (Wang et al., 2020a)، وحقت دقة إجمالية قدرها 99% لتصنيف 80 نوعاً من الدياتوم (Kloster et al., 2020; Pedraza et al., 2017).

يمكن لسير العمل المعتمد على DL التعرف تلقائياً على الصور المجهرية للفيروسات والبكتيريا والفطريات والطفيليات، (Zhang et al., 2021). كما يستخدم العلماء الذكاء الاصطناعي في التنبؤ بتطور الكائنات الحية الدقيقة، وتقدير درجة الحرارة المثلى لنمو البكتيريا والعتائق وحقيقيات النوى الميكروبية (Li et al., 2019)، والتنبؤ بنشاط sgRNA في الإشريكية القولونية (Wang and Zhang, 2019).

ومع ذلك، نظراً لأن تعليم الآلة يتطلب الكثير من العمل للحصول على تسميات تدريبية مناسبة، فيمكن إعادة استخدام النماذج المدربة مسبقاً لتصنيف الكائنات الحية الدقيقة البيئية لخفض التكلفة، (Kosov et al., 2018).

■ الغلاف الجليدي

يدرس العلم القطبي المناطق المتجمدة على الأرض، والتي تكون أكثر عرضة للتغيرات البيئية من الكوكب كاملاً. على الرغم من سنوات من الجهود المبذولة في مجال النمذجة، فإن التنبؤ الدقيق بالتغيرات والعواقب لا يزال يمثل تحدياً لم يتم حله لمجتمع الغلاف الجليدي.

■ الجليد البحري

تم استخدام الذكاء الاصطناعي/التعلم الآلي لرسم خريطة للرف الجليدي في القارة القطبية الجنوبية من Sentinel-1 (Baumhoer et al., 2019)، وتقدير سمك الجليد البحري في القطب الشمالي (Tiemann et al., 2018)، وتقييم سرعة ذوبانه على صور (SAR) (Lee et al., 2016; Wang et al., 2016)، وتمييز الماء عن الجليد (Leigh et al., 2013). يمكن أن يساعد في تحديد أعمار/أنواع الجليد البحري، حيث أن إشارات التشتت الخلفي للجليد البحري تتكون من التشتت من السطح الخشن وكذلك من تحت الجليد وفقاً لاختراق إشارة الرادار، (Ghanbari et al., 2019; Lohse et al., 2019; Park et al., 2020).

يمكن تنسيق صور GNSS و ML للكشف عن الجليد البحري (Yan and Huang, 2018). تُعد الروابط الغامضة بين الزلازل الدقيقة وأنشطة الجليد البحري مناسبة أيضاً للذكاء الاصطناعي/التعلم الآلي (Cannata et al., 2019).

■ الثلج

تحتوي أبحاث الثلوج على مؤشرين رئيسين: معادل مياه الثلج (SWE) وعمق الثلوج؛ ويمكن رصد كليهما والتنبؤ بهما بواسطة الذكاء الاصطناعي/التعلم الآلي بموثوقية جيدة، (Holt et al., 2015; Wang and Zhang, 2019).

يمكن لمنتجات عمق الثلج المشتقة من SVM من الأقمار الصناعية بالموجات الدقيقة اجتياز اختبارات التحقق من الصحة من خلال المراقبة الثابتة بدقة أعلى مع قمع تأثيرات التشبع بشكل فاعل، (Xiao et al. 2018). تُظهر أساليب DL المتقدمة

مثل الشبكات العميقة المتبقية التميز على الترددات اللاسلكية و **SVM** و **NN** في اكتشاف الثلوج من صور الأقمار الصناعية (Xia et al., 2019). في هذه الأثناء، يتم تجربة الذكاء الاصطناعي/التعلم الآلي بشكل مكثف للتمييز بين الثلج والسحاب على مستوى البكسل (Zhan et al., 2017).

■ علم المحيطات

يحتوي المحيط المضطرب على دوامات صغيرة الحجم تؤثر على الملاحظات الأوقيانوغرافية مثل ارتفاع سطح البحر (**SSH**) واللون والخشونة ودرجة الحرارة (**SST**). يعد تحديد هذه السمات باستخدام **ML** مجالاً ساخناً للدراسة. عادةً ما يتم تحديد الدوامات المحيطية متوسطة النطاق (قطرها حوالي 300 كم) من خلال الخوارزميات القائمة على الفيزياء، وقد أنتج العمل الأساسي السابق قاعدة بيانات دوامية (Chelton et al., 2011) كمعيار قوي لتعلم الآلة.

تم استخدام **CNN** في تحديد الدوامة مع **SSH** (Santana et al., 2020)، وصور **SAR** (Liu et al., 2021; Du et al., 2019; Huang et al., 2017)، وصور **SST** (Moschos et al., 2020). يوفر **SAR** تفاصيل غير مسبقة عن خشونة سطح المحيط بدقة عالية (~ 10–25 متر). ومع نجاح **Sentinel-1** عالي الجودة في مهمتي **Radarsat-1** و **Envisat** السابقتين، تتزايد جهود التعلم الآلي على صور **SAR** للمحيطات لتحديد ورسم العديد من السمات السطحية خارج الدوامات (Wang et al., 2019a). يتم التقاط الدوامات دون المتوسطة (التي يتراوح قطرها من 5 إلى 30 كم) بشكل كامل على صور **SAR** القياسية في المناطق الساحلية، في ظل سرعات رياح منخفضة إلى معتدلة، بسبب تعدد البقع الداكنة المنحنية داخل كل دوامة. كان التطبيق المبكر لتعلم الآلة في اكتشاف المحيطات **SAR**، هو رسم خرائط الطفوح النفطية الناشئة عن التسريبات النفطية.

تُعد عمليات رصد سطح المحيط عبر الأقمار الصناعية مليئةً بالفجوات بشكل جوهري، بسبب الغطاء السحابي أو المسارات الأرضية المشتتة مثل أجهزة قياس الارتفاع التقليدية، ومهمة قياس الارتفاع **SWOT** القادمة (Durand et al., 2010).

يمكن للذكاء الاصطناعي/التعلم الآلي معالجة مشكلة الفجوات في بيانات **SWOT SSH** الاصطناعية التي توضح جدوى خوارزميات الاستيفاء القائمة على الذكاء الاصطناعي في سد الثغرات التي تحتوي على دوامات محيطية صغيرة الحجم، (Manucharyan et al., 2020).

وفي خطوة أبعد من ذلك، يمكن تطبيق الخوارزمية المستندة إلى **CNN** لإعادة بناء التدفقات الناجمة عن تلك الدوامات (Bolton and Zanna, 2019; George et al., 2021). ستكون هذه الخوارزميات مفيدة في تحديد معالم التدفقات الدوامية التي لم يتم حلها في النماذج المناخية ذات الدقة الخشنة. نظراً لأن دوران المحيطات ثلاثي الأبعاد، يمكن للخوارزميات القائمة على الذكاء الاصطناعي أيضاً استرداد معلومات أعماق المحيطات بناءً على مجالات الأقمار الصناعية السطحية (Ali et al., 2007; Cheng et al., 2021; Wang et al., 2021).

وتشمل الطرق الأخرى؛ خريطة ذاتية التنظيم (Chapman and Charantonis, 2017;) و (Wu et al., 2012)، و (CCN (Han et al., 2019)، وشبكة عصبية لتحسين خوارزمية ذبابة الفاكهة (Bao et al., 2019)، والترددات اللاسلكية (Su et al., 2018).

يتنقل علم المحيطات من حالة ندرة البيانات إلى حالة الوفرة الشديدة فيها. إن كيفية الاستفادة من بحر من البيانات على نطاق البيتابايت واستخلاص المعلومات المفيدة إما للاكتشافات العلمية الجديدة أو التطبيقات ذات التأثير المجتمعي المباشر على «الاقتصاد الأزرق **Blue Economy**»، يمثل تحدياً جديداً للمجتمع (Watson-Wright and Snelgrove, 2021). ومن المتوقع أن تلعب الخوارزميات القائمة على الذكاء الاصطناعي دوراً مقنعاً في عملية الانتقال.

البيانات الضخمة وإدارتها في علوم الأرض

تُعد علوم الأرض من أوائل المستخدمين لكل من البيانات الحاسوبية والرقمية؛ يعود تاريخ أسلاف التنسيقات الجيوفيزيائية **SEG-D** و **SEG-Y** إلى عام 1967. معايير البيانات الخاصة بالبيانات السيزمية (**SEG-Y، SEG-D**) أو بيانات السجل الجيوفيزيائي (**LAS، DLIS**)، تجعل تفسير البيانات وتصورها عملياً تحدث في الوقت نفسه، ولكن طبيعتها الثنائية أيضاً تجعل تطبيق التقنيات التحليلية معقداً بشكل غير عادي. غالباً ما تكون هناك حاجة إلى برامج متخصصة لمعالجة أنواع البيانات المختلفة وتفسيرها.

وتتفاقم هذه المشكلات بسبب ممارسات إدارة البيانات السيئة تاريخياً. نادراً ما يتم تجميع مجموعات البيانات في نهاية المشاريع أو تخزينها مع بيانات وصفية كافية لوصفها بدقة، والعديد من مجموعات البيانات المفيدة استراتيجياً تصل إلى البيانات الضخمة في علوم الأرض **BGS** غير مكتملة أو غير قابلة للاستخدام أو لا يمكن الوصول إليها.

وسواء نشأ هذا الوضع بسبب الافتقار إلى البصيرة بشأن القيمة المستقبلية للبيانات، أو سوء الممارسات، أو مجرد القيود المفروضة على مساحة التخزين، فإن هذه المشكلات تشكل تحدياً عظيماً لعلماء الجيولوجيا اليوم.

ونتيجة لذلك، هناك مشكلات كبيرة في تطبيق تحليلات البيانات الضخمة في علوم الأرض. على سبيل المثال، لا تقوم العديد من التقنيات بأخذ عينات من الجيولوجيا بشكل مباشر، ولكنها تستخدم الوكلاء الذين يحتاجون إلى مزيد من التفسير.

لقد كان استخدام التقنيات التحليلية محدوداً بشكل عام، بسبب النسبة العالية من الضوضاء المدمجة في مجموعات البيانات مع مهارات تفسير كبيرة جداً مطلوبة لتحديد الإشارة ونوعها.

حتى الآن، اقتصرَت التطبيقات الناجحة لتحليلات «البيانات الضخمة» على الأنظمة المغلقة، أو تحليلات أنواع البيانات الرقمية الشائعة جداً.

ولا تزال هناك مشكلات كبيرة، بما في ذلك نقص البيانات التي يمكن التفاعل معها على الفور، وصعوبات الجمع بين مجموعات بيانات متعددة حول الظواهر ذات الصلة. وكذلك عدم وجود بيانات وصفية كافية حول البيانات المتاحة، لفهم سياقها ونطاقها وكيفية تطبيق النتائج وتأهيلها.

وبينما تحتوي مجموعات بيانات علوم الأرض على جميع سمات البيانات الضخمة؛ من حيث الحجم والمصدقية والسرعة والقيمة والتنوع، فإن عنصري التحكم الأخيرين لهما أهمية غير متناسبة.


أولهما يحدد مدى فائدة البيانات، والثاني هو أكبر عائق أمام الوفاء بالوعد التي تقدمها البيانات الضخمة خاصة في علوم الأرض.

من أجل تقديم منصة موحدة للبيانات يمكن من خلالها تحديد السمات الجيولوجية الفردية، استثمرت البيانات الضخمة في علوم الأرض في إنشاء **PropBase**. تسهل هذه البوابة الفردية جمع مجموعات البيانات المتوفرة بتنسيقات موحدة، وهذا يسمح لجميع البيانات من نقطة واحدة (كالآبار) أو المناطق ذات الاهتمام، على سبيل المثال، ليتم استخراجها معاً بتنسيق مشترك يسمح بمقارنة جميع البيانات على الفور.

يسمح وجود بوابة **PropBase** للباحث بالإجابة على السؤال: «ما هو المتوفر في الموقع؟» وقد تم استخدامه فعلاً في توصيف الموقع لمشروع مراصد الطاقة الجيولوجية في المملكة المتحدة.

تُعد مثل هذه المبادرات التي تسمح بجمع كميات كبيرة من البيانات في تنسيق واحد قابل للاستخراج، خطوة حاسمة للأمام للسماح بتحليلات البيانات الضخمة.

إلى جانب التوافر المتزايد والانخفاض المستمر في تكلفة الحوسبة عالية الطاقة، والإجراءات التحليلية، تزايد فرص التحليل للبيانات الضخمة باستمرار. ومع ذلك، لا تزال هناك تحديات كبيرة، وحاجة إلى تفاعلات جديدة، وإلى مزيد من علماء الحاسوب للوفاء بهذا الوعد، (Kingdon, et al., 2016).



إن الإجابة السريعة على الأسئلة المعقدة تحتاج إلى: استيعاب البيانات الواردة من مختلف الجهات وتحليلها بسرعة، وترجمتها الفوري آلياً، فضلاً عن عدم اليقين والحساسية وتحليل الاتجاه، (Kingdon, et al., 2016)

• تعريفات البيانات الضخمة

تشير البيانات الضخمة **Big Data** في المقام الأول إلى مجموعات البيانات الكبيرة جداً أو المعقدة، بحيث لا يمكن التعامل معها بواسطة برامج تطبيقات معالجة البيانات التقليدية. توفر البيانات التي تحتوي على العديد من الإدخالات (الصفوف) قوة إحصائية أكبر، في حين أن البيانات ذات التعقيد الأعلى (المزيد من السمات أو الأعمدة)، قد تؤدي إلى معدل اكتشاف خاطئ أعلى، (Breur, 2016).

وعلى الرغم من استخدام البيانات الضخمة أحياناً، بشكل فضفاض جزئياً بسبب الافتقار إلى تعريف رسمي، فإن أفضل تفسير لها هو أنها عبارة عن مجموعة كبيرة من المعلومات التي لا يمكن فهمها عند استخدامها بكميات صغيرة فقط، (Mahdavi-Damghani, 2019).

تتضمن تحديات تحليل البيانات الضخمة؛ التقاط البيانات، وتخزينها، وتحليلها، ومن ثم البحث، والمشاركة، والنقل، والتصور، والاستعلام، والتحديث، وخصوصية المعلومات، ومصدر البيانات. ارتبطت البيانات الضخمة في الأصل بثلاثة مفاهيم رئيسية: الحجم والتنوع والسرعة. يمثل تحليل البيانات الضخمة تحديات في أخذ العينات، وبالتالي كان يسمح في السابق بالملاحظات وأخذ العينات فقط. وبالتالي فإن المفهوم الرابع، وهو المصادقية يشير إلى جودة البيانات أو توفرها.

وبدون الاستثمار الكافي في الخبرة اللازمة للتحقق من صحة البيانات الضخمة، فإن حجم البيانات وتنوعها يمكن أن يؤدي إلى تكاليف وأخطار تتجاوز قدرة المنظمة على إنشاء القيمة والاستفادة منها، (Cappa, et al. 2021). يميل الاستخدام الحالي لمصطلح البيانات الضخمة إلى الإشارة إلى استخدام التحليلات التنبؤية، أو تحليل سلوك المستخدم، أو بعض طرق تحليل البيانات المتقدمة الأخرى التي تستخرج القيمة من البيانات الضخمة، ونادراً ما تصل إلى حجم معين من مجموعة البيانات. «ليس هناك شك في أن كميات البيانات المتاحة الآن كبيرة فعلاً، ولكن هذه ليست السمة الأكثر صلة بهذا النظام البيئي الجديد للبيانات»، (Boyd, and Kate, 2011).

ومن الممكن أن يجد تحليل مجموعات البيانات ارتباطات جديدة «لتحديد اتجاهات الأعمال، والوقاية من الأمراض، ومكافحة الجريمة، وما إلى ذلك». يواجه العلماء ومديرو الأعمال وممارسون الطب ووسائل الإعلام والحكومات على حد سواء، صعوبات مع مجموعات البيانات الكبيرة بانتظام، وذلك في مجالات، منها؛ عمليات البحث على الإنترنت والتكنولوجيا المالية، وتحليلات الرعاية الصحية، وأنظمة المعلومات الجغرافية، والمعلوماتية الحضرية، والمعلوماتية التجارية. كما يواجه العلماء قيوداً في عمل العلوم الإلكترونية، بما في ذلك؛ الأرصاد الجوية، وعلم الجينوم، وعلوم الاتصال، ومحاكاة الفيزياء المعقدة، وعلم الأحياء، والبحوث البيئية (Reichman, et al. 2011).

لقد نما حجم وعدد مجموعات البيانات المتاحة سريعاً، حيث يتم جمع البيانات بواسطة أجهزة مختلفة مثل؛ أجهزة الاتصال المحمولة، وأجهزة الإنترنت، والكيانات الرخيصة والمتعددة لاستشعار المعلومات، والمعدات الجوية (الاستشعار عن بعد)، وسجلات البرامج، والكاميرات، والميكروفونات، والترددات الراديوية، وقارئات تشخيص الهوية (RFID)، وشبكات الاستشعار اللاسلكية، (Segaran, and Jeff, 2009).

تتضاعف قدرة نصيب الفرد التكنولوجي على تخزين المعلومات، على مستوى العالم أجمع، مرة كل أربعين شهراً تقريباً، منذ ثمانينات القرن العشرين؛ (Hilbert and López, 2011)، واعتباراً من عام 2012م، يتم إنشاء 2.5 إكسابايت ($2^{60} \times 2.17$ بايت) من البيانات يومياً. استناداً إلى تنبؤات تقرير IDC، من المتوقع أن ينمو حجم البيانات العالمية كثيراً من 4.4 زيتابايت إلى 44 زيتابايت، ما بين عامي 2013م و2020م. وبحلول عام 2025، تتوقع IDC أن يكون هناك 163 زيتابايت من البيانات، (Reinsel, et al. 2017). وفقاً لمؤسسة IDC، من المتوقع أن يصل الإنفاق العالمي على حلول البيانات الضخمة وتحليلات الأعمال (BDA) إلى 215.7 مليار دولار في عام 2021م. وفقاً لتقرير Statista، من المتوقع أن ينمو سوق البيانات الضخمة العالمي إلى 103 مليار دولار بحلول عام 2027م.

في عام 2011م، ذكرت شركة ماكينزي آند كومباني أنه إذا استخدمت الرعاية الصحية في الولايات المتحدة البيانات الضخمة بشكل إبداعي وفاعل، لتعزيز الكفاءة والجودة، فيمكن للقطاع أن يخلق أكثر من 300 مليار دولار من القيمة كل عام. وفي الاقتصادات المتقدمة في أوروبا، يستطيع المسؤولون الحكوميون توفير أكثر من 100 مليار يورو (149 مليار دولار أميركي)، من تحسينات الكفاءة التشغيلية وحدها، باستخدام البيانات الضخمة. ومن الممكن أن يحصل مستخدمو الخدمات التي يتم دعمها ببيانات الموقع الشخصي على 600 مليار دولار من فائض المستهلك. من الأسئلة التي تطرح على المؤسسات الكبيرة، من هي الجهة التي يجب أن تمتلك مبادرات البيانات الضخمة التي تؤثر على المؤسسة بأكملها؟

غالبًا ما تواجه أنظمة إدارة قواعد البيانات العلاقية وحزم البرامج الإحصائية المكتبية المستخدمة لتصوير البيانات، صعوبة في معالجة البيانات الضخمة وتحليلها. قد تتطلب معالجة البيانات الضخمة وتحليلها «برامج متوازية على نطاق واسع، تعمل على عشرات أو مئات أو حتى آلاف الخوادم» (Jacobs, 2009). ويختلف ما يمكن وصفه بـ «البيانات الضخمة» باختلاف قدرات القائمين على تحليلها وأدواتهم. علمًا، أن توسيع القدرات يجعل البيانات الضخمة هدفًا متحركًا. «بالنسبة لبعض المؤسسات، فإن مواجهة مئات الجيجابايت من البيانات لأول مرة قد يؤدي إلى الحاجة إلى إعادة النظر في خيارات إدارة البيانات. وبالنسبة للآخرين، قد يستغرق الأمر عشرات أو مئات التيرابايت قبل أن يصبح حجم البيانات أحد الاعتبارات المهمة»، (Magoulas and Ben, 2009).

• خصائص البيانات الضخمة

يمكن وصف البيانات الضخمة بالخصائص التالية:

♦ المقدار

كمية البيانات المولدة والمخزنة. يحدد حجم البيانات القيمة والرؤية المحتملة، وما إذا كان يمكن اعتبارها بيانات ضخمة أم لا. عادة ما يكون حجم البيانات الضخمة أكبر من التيرابايت والبيتا بايت (Sagiroglu, 2013).

♦ التنوع

نوع وطبيعة البيانات، كانت التقنيات السابقة مثل RDBMSs قادرة على التعامل مع البيانات المنظمة بكفاءة وفاعلية. ومع ذلك، فإن التغيير في نوع وطبيعة البيانات من منظمة إلى شبه منظمة أو غير منظمة يمثل تحدياً للأدوات والتقنيات الحالية.

تطورت تقنيات البيانات الضخمة بهدف رئيس هو التقاط وتخزين ومعالجة البيانات شبه المنظمة وغير المنظمة (المتنوعة) التي تم إنشاؤها بسرعة عالية (سريعاً)، وضخمة الحجم (المقدار).

ولاحقاً، تم استكشاف هذه الأدوات والتقنيات، واستخدامها للتعامل مع البيانات المنظمة أيضاً ولكنها تبقى المفضلة للتخزين. في نهاية المطاف، ظلت معالجة البيانات المنظمة اختيارية، إما باستخدام البيانات الضخمة أو أنظمة إدارة قواعد البيانات الراديوية التقليدية.

ويساعد ذلك في تحليل البيانات من أجل الاستخدام الفاعل للرؤى الخفية التي تكشفها البيانات مما تم جمعها عبر وسائل التواصل الاجتماعي، وملفات السجلات البثية، وأجهزة الاستشعار، وما إلى ذلك. البيانات الكبيرة مستمدة من النصوص والصور والصوت والفيديو، كما يمكن اكمال الأجزاء المفقودة من خلال دمج البيانات.

♦ السرعة

السرعة التي يتم بها إنشاء البيانات ومعالجتها لتلبية المتطلبات والتحديات التي تكمن في طريق النمو والتنمية، غالباً ما تكون بياناتها الضخمة متاحة في الوقت الفعلي.

بالمقارنة مع البيانات الصغيرة، يتم إنتاج البيانات الكبيرة بشكل مستمر. هناك نوعان من السرعة المتعلقة بالبيانات الضخمة هما؛ تكرار الإنشاء، وتكرار المعالجة والتسجيل والنشر، (Kitchin and Gavin, 2016).

♦ الموثوقية

صدق أو موثوقية البيانات، وهو ما يشير إلى جودة البيانات وقيمتها، (Onay and Elif, 2018)، لا يجب أن تكون البيانات الضخمة كبيرة الحجم فحسب، بل يجب أيضاً أن تكون موثوقة من أجل تحقيق القيمة في تحليلها. قد تختلف جودة البيانات الملتقطة كثيراً، وهذا يؤثر على التحليل الدقيق.

♦ القيمة

قيمة المعلومات التي يمكن تحقيقها من معالجة وتحليل مجموعات البيانات الكبيرة. ويمكن أيضاً قياس القيمة من تقييم الصفات الأخرى للبيانات الضخمة. قد تمثل القيمة أيضاً ربحية المعلومات التي يتم استرجاعها من تحليل البيانات الضخمة.

♦ التقلب

سمة الأشكال المتغيرة أو البنية أو مصادر البيانات الضخمة. يمكن أن تتضمن البيانات الضخمة بيانات منظمة، أو غير منظمة، أو مجموعات من البيانات المنظمة

وغير المنظمة. قد يدمج تحليل البيانات الضخمة البيانات الأولية من مصادر متعددة، وقد تتضمن أيضاً معالجة البيانات الأولية تحويل البيانات غير المنظمة إلى بيانات منظمة.

الخصائص المحتملة الأخرى للبيانات الضخمة هي:

- الشمولية

وتعني ما إذا كان النظام قد تم التقاطه أو تسجيله كاملاً أم لا. فقد تتضمن البيانات الضخمة أو لا تتضمن جميع البيانات المتاحة من المصادر.

- دقة الحبيبات ومعجمية فريدة من نوعها

على التوالي، يتم جمع نسبة البيانات المحددة لكل عنصر، وفيما إذا تم فهرسة العنصر وخصائصه أو تحديدها بشكل صحيح.

- العلاقة

إذا كانت البيانات التي تم جمعها تحتوي على حقول مشتركة من شأنها تمكين الدمج أو التحليل البعدي لمجموعات البيانات المختلفة.


- الامتداد

إمكانية إضافة أو تغيير حقول جديدة لعناصر البيانات المجمع بيسر وسهولة.

- قابلية التوسع

إذا كان حجم نظام تخزين البيانات الضخمة يمكن أن يتوسع بسرعة،

(Kitchin and Gavin, 2016).



أمثلة على مشكلات علوم الأرض: التفاعلات المعقدة بين الجيولوجيا والعمليات البشرية، والمساحة الكبيرة، وأنواع وأدوار متعددة من البيانات، والتحول السريع. تحتاج البيانات إلى توحيد الخصائص للسماح بالتحليل. وقد قامت BGS بتجربة رسم خرائط الدعائم الطبيعية بتقنية ثلاثية الأبعاد لمدة 20 عامًا. فالبيانات التي تأتي من طبقة المياه الجوفية تختلف عن البيانات التي تأتي من طبقة التربة، ولا بد من التنسيق بين مختلف الطبقات حتى يمكننا استثمارها بالشكل الأمثل، (Kingdon, et al., 2016).

• البيانات الضخمة لرصد الأرض

تتزايد بيانات رصد الأرض من حيث الحجم والتنوع بمعدل سريع جداً. أنظمة جديدة للاستشعار عن بعد عبر الأقمار الصناعية والمحمولة جوا وأرضية تتميز باستبانة مكانية وزمانية وإشعاعية عالية، متاحة أو ستتوفر قريباً؛ إن زيادة قوة الحوسبة تمكن من إجراء عمليات المحاكاة على نطاق عالمي بدقة غير مسبوقة؛ يعمل نوع جديد من أجهزة الاستشعار والتطبيقات على تحويل الأجهزة اللوحية والهواتف الذكية وأجهزة الملاحة في السيارات إلى أنظمة مراقبة التلوث الجماعي التي توفر كمية هائلة من المعلومات.

وهذه فرصة عظيمة لتعزيز معرفتنا بنظام الأرض، ولكنها تشكل أيضاً تحديات كبيرة لكل من العلماء وخبراء تكنولوجيا المعلومات.

في الواقع، وفقاً للعديد من العلماء والتقنيين، فإن التوافر المتزايد للملاحظات من أجهزة الاستشعار والنماذج، إلى جانب القوة الحاسوبية المتزايدة باستمرار التي توفرها التقنيات الجديدة بما في ذلك الأنظمة السحابية، من شأنه أن يمكن من اتباع نهج جديد تماماً للعلوم يعتمد على الاكتشافات العلمية المكثفة للبيانات.

وهذا من شأنه أن يستلزم تحولاً نموذجياً حقيقياً، وإدخال ما يسمى بالنموذج الرابع. ومع ذلك، لجعله حقيقة واقعة، فإنه يتطلب تقنيات تمكينية مبتكرة، لإدارة وتحليل وتقديم وعرض كميات كبيرة من البيانات.

يشمل مصطلح البيانات الضخمة كل هذه الجوانب، وهو أحد الاتجاهات الرئيسية الحالية في علم البيانات وتكنولوجيا المعلومات. ومع ذلك، فإن مفهوم البيانات الضخمة في حد ذاته بعيد المنال، مما يؤدي إلى العديد من التعريفات الممكنة وفقاً للجوانب المختلفة التي يتم التركيز عليها.

قدم دوج لاني من مجموعة **META** (التي استحوذت عليها شركة **Gartner** بعد ذلك) في عام **2001م** ما هو على الأرجح التعريف الأول للبيانات الضخمة باعتبارها بيانات تتطلب قدرات إدارية عالية تتميز بـ **3Vs**: الحجم والسرعة والتنوع. ويشير إلى أن البيانات الضخمة لا تعني ببساطة مجموعات البيانات الضخمة أو كمية كبيرة من مجموعات البيانات (الحجم الكبير)، ولكن أيضاً القيود الصارمة (السرعة الكبيرة) وعدم التجانس الكبير (التنوع الكبير).

في وقت لاحق، تم اقتراح **Vs** أخرى باعتبارها ذات صلة في مجال البيانات الضخمة مثل الصدق؛ بمعنى الحاجة إلى توثيق الجودة وعدم اليقين، والقيمة؛ الإشارة إلى الحاجة إلى تصفية البيانات للحصول على معلومات قيمة، التصور؛ بمعنى الحاجة إلى تقديم بنية بيانات معقدة ومعلومات غنية بطريقة فاعلة.

وعلى الرغم من كون هذا التعريف قديماً إلى حد ما، إلا أنه لا يزال صحيحاً ومفيداً بشكل عام. وعلى وجه التحديد، عند أخذ بيانات رصد الأرض في الاعتبار، مع مراعاة متطلبات **EO** والتطبيقات النموذجية.

تتميز بيانات **EO** بعدم تجانس كبير لأسباب تاريخية وتكنولوجية، بما في ذلك: أجهزة استشعار اكتساب مختلفة، ومنهجية متنوعة لوصف ظواهر العالم الحقيقي (مثل عرض المجال أو التغطية وعرض الميزة أو الحدود)، وتنسيقات التشفير المختلفة.

يستمر حجم بيانات **EO** في التضاعف كثيراً بسبب إطلاق منصات طيران جديدة، والتي تستضيف أجهزة استشعار أكثر قوة ومتعددة الأطياف ودقيقة؛ على سبيل المثال، يتجاوز أرشيف وكالة الفضاء الأوروبية الحالي **1.5** بيتا بايت، ومن المتوقع أن يتجاوز هذا الحجم **2** بيتا بايت في غضون سنوات قليلة.

فيما يتعلق بالسرعة، تعد التحليلات في الوقت الفعلي أمراً مهماً لتوليد منتجات عالية المستوى (مثل المعلومات الفيزيائية) من بيانات الاستشعار عن بعد ذات المستوى

المنخفض (مثل بيانات الأقمار الصناعية الأولية). بالنسبة لتطبيقات EO، تتعلق السرعة أيضاً بربط مجموعات البيانات غير المتجانسة التي تأتي بسرعات مختلفة، على سبيل المثال. السلسلة المكانية والزمانية المستشعرة عن بعد وفي الموقع.

تعد استجابات علوم البيانات لمواجهة تحديات البيانات الضخمة أمراً أساسياً لضمان نجاح المبادرات العالمية، وتلك متعددة التخصصات مثل: النظام العالمي لأنظمة مراقبة الأرض: (GEO 2012) (GEO 2005) GEOSS. كما تم طرح هذا المفهوم وتحليله خلال اجتماع عمل نظمته مؤخراً GEO (مجموعة مراقبة الأرض) لمناقشة رؤية وبنية نظام معلومات GEOSS.

إن مجموعة مراقبة الأرض (GEO) هي شراكة تطوعية بين الحكومات والمنظمات الدولية، تم إطلاقها استجابة لدعوات العمل الصادرة عن القمة العالمية للتنمية المستدامة لعام 2002م، ومجموعة الثماني من البلدان الصناعية الرائدة.

أدركت هذه الاجتماعات رفيعة المستوى أن التعاون الدولي ضروري لاستغلال الإمكانيات المتزايدة لرصد الأرض، لدعم عملية صنع القرار في عالم متزايد التعقيد والضغط البيئي.

ولتحقيق هذا الهدف، يقوم GEO بتنسيق الجهود لبناء نظام عالمي لأنظمة مراقبة الأرض، أو (GEOSS (GEO 2005). إن الهدف من GEOSS هو إنشاء شبكة عالمية ومرنة من موفري المحتوى، مما يسمح لصانعي القرار بالوصول إلى مجموعة غير عادية من البيانات والمعلومات الموجودة على مكاتبهم، راجع <http://www.earthobservations.org>.

يقوم GEO ببناء نظام GEOSS على أساس خطة تنفيذية مدتها 10 سنوات للفترة من 2005م إلى 2015م، عندما يصبح جاهزاً للعمل (GEO 2012). تحدد الخطة بيان رؤية لـ GEOSS والغرض منها، وأهدافها؛ الكوارث والصحة والطاقة والمناخ والمياه والطقس والنظم البيئية والزراعية والتنوع البيولوجي.

وفي الاجتماع الوزاري العام لعام 2014م في جنيف، حصل فريق رصد البيئة على الموافقة بالإجماع لإطلاق العنان لقوة البيانات المفتوحة للعقد الثاني حتى عام 2025م. وكان هناك اتفاق على مواصلة البناء على أول الإرشادات التي أطلقتها الشركات الرائدة في مجال البيانات المفتوحة، (Nativi, et al. 2015).

• تحديات تحليل بيانات علوم الأرض: نهج EarthServer

لقد سمح تطور تقنيات الاتصالات والتخزين الرقمي، في السنوات الأخيرة، بجمع كمية هائلة من المعلومات، مما أدى إلى زيادة الحاجة إلى طرق فاعلة للحفاظ على البيانات والوصول إليها ومعالجتها بكفاءة.

في المجال العلمي، تواجه العديد من المجالات التخصصية تحديات البيانات الضخمة كجزء من نهج مبتكر للعلوم يشار إليه عادة باسم العلوم الإلكترونية.

لقد كانت علوم الأرض من بين المجالات التخصصية التي تدفع بقوة نهج العلوم الإلكترونية، وربما تستفيد منه، والمقصود منه أن يكون «تعاوناً عالمياً في مجالات العلوم الرئيسية، والجيل القادم من البنية التحتية التي ستمكنه».

لقد كانوا في طليعة العديد من المبادرات المتعلقة بالحوسبة الموزعة التي تحاول تحقيق رؤية العلوم الإلكترونية، بما في ذلك الحوسبة عالية الأداء، والتقنيات الشبكية، والخدمات السحابية. والسبب هو أن علوم الأرض تثير تحديات كبيرة من حيث قدرات التخزين والحوسبة:

- تشمل مجموعة واسعة من التطبيقات: من العلوم التخصصية (كالمناخ والمحيطات والجيولوجيا)، إلى الدراسة متعددة التخصصات للأرض نظاماً (ما يسمى بعلوم نظام الأرض). ولذلك تستفيد علوم الأرض من المعلومات غير المتجانسة (التنوع الكبير):

- ♦ تغطي نطاقاً زمنياً متنوعاً (مثل الدراسات المناخية والجيولوجية).
 - ♦ تدعم تغطية مكانية واسعة (الأرض بأكملها، للدراسات العالمية، وخارجها عند النظر في علوم الكواكب).
 - ♦ تُتمدج العديد من أنواع البيانات الجغرافية المكانية المختلفة، بما في ذلك الملامح والمسارات والبيانات الشبكية المنتظمة وغير المنتظمة، وما إلى ذلك.
- وهي تستند إلى الملاحظات والقياسات الواردة من الموقع وبيانات الاستشعار عن بعد ذات الاستبانة المكانية والزمانية، والإشعاعية المتزايدة باستمرار، والتي تتطلب التعامل مع كميات كبيرة من البيانات. مثال؛ ستعمل الأقمار الصناعية المنوطة بالحماية على زيادة حجم أرشيف بيانات وكالة الفضاء الأوروبية إلى أكثر من 20 بيتا بايت في عام 2020م.
- وفيها تستخدم النمذجة والمحاكاة العلمية المعقدة لدراسة السيناريوهات المعقدة (كتغير المناخ)، التي تتطلب معالجة سريعة جداً.
- بالإشارة إلى البيانات الضخمة مقابل الحجم والتنوع الكبير والسرعة العالية، من الواضح أنها قضايا مميزة لأنظمة بيانات علوم الأرض.

تحديات تحليل بيانات علوم الأرض

منذ بدايته، أولى مشروع **EarthServer** اهتماماً كبيراً لجمع المتطلبات العلمية والتكنولوجية من مجتمعات علوم الأرض ذات الصلة. علاوة على ذلك، تم تخصيص إجراء محدد لجمع المتطلبات وتقييم المواءمة مع المبادرات الدولية المتعلقة بالأرض، وتبادل البيانات البيئية مثل:

GEOSS (<http://www.earthobservations.org>)

و **INSPIRE** (<http://inspire.ec.europa.eu>)

وكوبرنيكوس (<http://www.copernicus.eu>).

خاطب مشروع **EarthServer** المجتمعات العلمية من خلال شركاء يشكلون جزءاً من المجتمعات نفسها. كان هذا النهج ناجحاً لأنه أدى إلى تبسيط التفاعل إلى حد كبير.

كان مختبر بليموث البحري (**PML**) بمنزلة وكيل للمجتمع البحري، كما كانت هيئة المسح الجيولوجي البريطانية (**BGS**) لمجتمع الأرض الصلبة، وشركة مراقبة الأرض البيئية للأرصاد الجوية (**MEE0**)، و(**S.r.l**) للمجتمع الجوي. وقاموا بجمع المتطلبات والتحقق من صحة الأنشطة الجارية، من خلال الاستبانات والمشاورات وتنظيم ورش العمل المخصصة، والتي عادة ما تكون مصاحبة للأحداث ذات الصلة بالمجتمع.

بالإضافة إلى ذلك، تمت مخاطبة مجتمع علوم الأرض ككل من خلال الاجتماعات المخصصة التي عقدت خلال الجمعية العامة السنوية للاتحاد الأوروبي لعلوم الأرض (**EGU**). كما تم توجيه الإجراءات الأخرى على وجه التحديد إلى مجتمع مراقبة الأرض من خلال تنظيم العروض التقديمية والاجتماعات خلال الجلسة العامة لفريق مراقبة الأرض (**GEO**)، والمشاركة في تنظيم مؤتمر وكالة الفضاء الأوروبية «البيانات الضخمة من الفضاء».

يمكن تلخيص النتائج الرئيسية لهذا النشاط في قائمة المتطلبات العامة التالية:

- تواجه تطبيقات مراقبة الأرض حقا مشكلة البيانات الضخمة، مع الحاجة إلى حلول متقدمة تدعم معالجة البيانات الضخمة وتحليلاتها.
- هناك حاجة إلى حلول مرنة تتيح إجراء تحليلات مخصصة للبيانات الضخمة لاستكشاف تلك العلمية منها عند الطلب.
- يحتاج المستخدمون إلى تقنيات البيانات الضخمة التي تدعم نماذج البيانات المتعددة وتقلل من نقلها.
- يحتاج المستخدمون إلى تقنيات تصور متقدمة يمكن دمجها بسهولة في واجهات المستخدم الرسومية المختلفة، بما في ذلك أنظمة الويب والهواتف المحمولة.

• نهج EarthServer

باختصار، يوفر **EarthServer** وصولاً مفتوحاً وقابلاً للتشغيل البيئي ومستقلاً عن التنسيق إلى «البيانات الجغرافية الكبيرة»، بدءاً من الوصول والاستخراج البسيط إلى خدمات التحليل/الاسترجاع المعقدة للبيانات. حيث تعمل قاعدة بيانات المصفوفة، **rasdaman** (<http://www.rasdaman.org>) ، على تمكين تقنية **EarthServer** من استرجاع البيانات/البيانات الوصفية ودمجها، مما يؤدي إلى المستوى نفسه من البحث، والتصفية، وسهولة الاستخراج كما هو معتاد للبيانات الوصفية.

تقليدياً، يتم تصنيف البيانات التي تتعامل مع الأرض أو الأنظمة الكوكبية إلى بيانات متجهة ونقطية وبيانات وصفية. والأخيرة هي ما تعتبر بشكل عام صغيرة وغنية بالدلالات وقابلة للاستعلام.

لقد وصلت البيانات المتجهة التي تمثل النقاط والخطوط والمساحات وما إلى ذلك إلى أقصاها منذ بعض الوقت أيضاً.

البيانات النقطية: أي أن نقاط البيانات تتماشى مع بعض الشبكات المنتظمة أو غير المنتظمة. ونظراً لحجمها الهائل، تُعد بشكل عام مناسبة للتنزيل فقط، وربما لاستخراج مجموعات فرعية، ولكن بخلاف ذلك، لا تحتوي على دلالات معينة يمكن الاستعلام عنها، وهي بدون مجموعة وظائف قياسية.

يُعد التقييس إحدى وسائل تعزيز إمكانية التشغيل البيئي. في مجال البيانات الجغرافية المكانية، يلعب الاتحاد الجغرافي المكاني المفتوح (OGC) دوراً رئيساً في توحيد المعايير. وفيما يتعلق بواجهات الخدمة، فهي توفر مواصفات للوصول إلى البيانات المختلفة: تم تصميم خدمة سمات الويب (WFS) لخدمة البيانات المتجهة، في حين أن خدمة تغطية الويب (WCS) هي مخصصة للبيانات النقطية متعددة الأبعاد، والسحب النقطية، والشبكات. وتلعب خدمة خرائط الويب (WMS) دوراً خاصاً حيث تهدف إلى تصور الخرائط المتجهة والنقطية ثنائية الأبعاد بأبسط الطرق الممكنة.

يعد WCS مثيراً للاهتمام بشكل خاص لأرشفة البيانات، لأنه يسمح بالوصول إلى قيم البيانات لمزيد من المعالجة وليس فقط للتصور (كما يفعل WMS). إحدى حالات الاستخدام هي الحصول على بيانات مضمونة غير معدلة، مثل بيانات قياس الأعماق؛ والأخرى هي المعالجة من جانب الخادم للحصول على المنتج المصمم خصيصاً للمطلوب.

يمكن تنفيذ جزء من هذه المعالجة الإضافية بسهولة من جانب الخادم، مباشرة داخل الأرشفة وتنفيذها عند الطلب. تم تصميم خدمة معالجة تغطية الويب (WCPS) خصيصاً لتعزيز أرشفة البيانات من خلال القيام بذلك، وتوفير «التحليلات» مباشرة معها، بهدف تعزيز استخدام البيانات واستغلالها.

بالنسبة إلى «البيانات الضخمة» الزمانية المكانية (الزمكان)، حددت OGC نموذج التغطية الموحد الخاص بها (المسمى بـ GMLCOV)، والذي يعمل على تحسين النموذج المجرد لـ ISO 19123 إلى نموذج ملموس قابل للتشغيل البيئي يمكن اختبار توافقه حتى مستوى بكسل واحد.

التغطية: هي نوع فرعي (أي تخصص) لميزة ما، حيث تكون الميزة كائنًا جغرافيًا غير رسمي. التغطية؛ هي تمثيل رقمي لبعض الظواهر المتغيرة للزمكان (متعددة الأبعاد) (Baumann, 2012a). من الناحية الفنية، تشمل التغطية كل الشبكات المنتظمة وغير المنتظمة، والسحب النقطية، والشبكات العامة.

نظرًا لأن هذه الفكرة غير مرتبطة بنموذج خدمة معين، يمكن للعديد من الخدمات تلقي أو إنشاء تغطيات، مثل **OGC WFS**، و**WMS**، و**WCS**، و**WCPS**، و**WPS**. وعلى وجه التحديد، يوفر معيار خدمة تغطية الويب وظائف غنية ومصممة خصيصًا للوصول إلى البيانات وتحليلها.

بالنسبة للأخيرة، ترتبط **WCS** ارتباطًا وثيقًا بخدمة معالجة تغطية الويب (**WCPS**) التي تحدد لغة استعلام على التغطيات، الموجودة حاليًا على البيانات النقطية الزمانية المكانية، أي المصفوفات ذات المرجعية الجغرافية التي يمكن معالجتها بواسطة بعض أنظمة الإحداثيات المكانية والزمانية.

بشكل عام، يتضمن ذلك مستشعر **n-D** والصورة ومخرجات المحاكاة والبيانات الإحصائية. بالنسبة لكيانات البيانات متعددة الأبعاد، يوفر معيار **WCPS** قفزة للأمام فيما يتعلق بالمعالجة القابلة للتشغيل البيني؛ فهو يحدد لغة استعلام قوية ومرنة، تتيح بالإضافة إلى أرشيفات البيانات، إمكانية استخدام بيانات التغطية في الاستعلامات المعقدة. وبالتالي يمكن بناء المنتجات المشتقة بسرعة ودمجها مع التغطيات الأخرى.

يدرك **EarthServer** أن البيانات الضخمة في الخدمات الجغرافية غالبًا ما تعني عمليات تغطية؛ وخاصة فيما يتعلق بالحجم، ولكنها على العموم تغطي جميع جوانب **Vs** التي تميز البيانات الضخمة. لذلك، تتمحور البنية بأكملها حول التغطيات الداعمة.

النواة؛ هي قاعدة بيانات مصفوفة راسد امان التي تخدم الشبكات المنتظمة وغير المنتظمة، وتجريبياً، السحب النقطية. إنها مناسبة بشكل خاص للخدمات الجغرافية المكثفة من حيث كمية البيانات ومعالجتها، لأن لغة الاستعلام الخاصة بها تمنح المرونة لصياغة أي مهمة دون إعادة برمجة الخادم (كما هو الحال فعلياً، على سبيل المثال مع الأنظمة المستندة إلى WPS).

تمثل معايير OGC للبيانات الجغرافية الكبيرة، التي تتمحور حول بيانات تغطية OGC ونموذج الخدمة، واجهة عميل/خادم مناسبة للاستخدام للأغراض العامة في علوم الأرض. لذلك، تم اعتماد معايير WCS و WCPS بواسطة EarthServer، جنباً إلى جنب مع WMS للتصور ثنائي الأبعاد.

يقوم EarthServer بتوسيع هذا النظام الأساسي نحو محرك تحليلات التغطية الشاملة، وهو يدعم بشكل شامل مجموعة WMS/WCS/WCPS على التغطيات المكانية والزمانية متعددة الأبعاد؛ حيث تم دمج البحث عن البيانات والبيانات الوصفية، وبالتالي إلغاء هذا التمييز القديم بشكل فاعل.

تم إنشاء واجهات لأدوات نظم المعلومات الجغرافية مثل MapServer و GDAL؛ وتمت موازنة محرك الخادم على نطاق واسع لتحقيق قابلية التوسع القوية؛ وتم إنشاء خوادم المتصفح ثلاثي الأبعاد بشكل فاعل لإخفاء لغة الاستعلام عن المستخدمين العاديين، مع السماح بكتابة الاستعلام للمستخدمين الخبراء. تشكل هذه التقنية منصة مشتركة لتطبيقات Lighthouse الستة التي تتناول معاً علوم الأرض بشكل شامل.

أخيراً، يتم إدخال النتائج التي تم الحصول عليها في تطوير النظام الأساسي وتشغيل الخدمة مرة أخرى في عملية التقييس، حيث شكلت كثيراً أعمال مواصفات WCS و WCPS الحديثة.

• التصور

يمكن لأي خادم متوافق الوصول إلى نقاط نهاية الخدمة، التي توفر التغطية عبر **WCS** و **WCPS**، مباشرة عبر الويب.

لتسهيل الوصول إلى الأرشفات بطريقة أكثر سهولة في الاستخدام ومخصصة للمجال، توفر خدمات البيانات واجهة خادم ويب مخصصة، والتي تبني الاستعلامات وفقاً لمعلمة محددة من قبل المستخدم، وتعرض النتائج في شكل رسومي يمكن للمستخدم تفسيره بسهولة. تم توفير كل من مكتبات عناصر واجهة المستخدم ثنائية الأبعاد ومكتبات التصور ثلاثية الأبعاد لتطوير الواجهة من جانب الخادم.

إن استخدام واجهات الخادم هذه يجعل من التفاعل الفوري قدر الإمكان للمستخدمين مع محتويات أرشيفات خدمة البيانات، بما في ذلك عرض الخرائط والرسوم البيانية للبيانات المجمعة الناتجة عن الاستعلامات.


• عميل ثلاثي الأبعاد

يعتمد عميل الويب **EarthServer 3D** على (**X3DOM**, n.d.)، وهو إطار عمل مفتوح المصدر، ووقت تشغيل المحتوى التعريفي ثلاثي الأبعاد. يستفيد الخادم ثلاثي الأبعاد كثيراً من مزايا تقنية **EarthServer**: إذ يتم تقسيم مجموعات البيانات الكبيرة والوصول إليها أجزاءً أصغر، وإدراجها بشكل منفصل في نموذج كائن المستند (**DOM**) الخاص بالمتصفح للحفاظ على معدل إطارات مرتفع، وبالتالي تمكين التفاعل.

يصل الخادم إلى البيانات من بروتوكولات **OGC** مثل **WCS** و **WMS** و **WCPS**. تعمل الوحدات المختلفة على تحويل البيانات إلى تمثيلات مرئية، ويتم دمج التمثيلات المتعددة في مشهد مشترك ثلاثي الأبعاد. على وجه الخصوص، سمح **WCPS**، الذي يسمح باستعلامات معبرة جداً، بتمكين وظائف العميل المتقدمة مثل تحديد أنواع مختلفة من المعلومات لكل قناة **RGB** وقناة ألفا.

توجد وحدات تصور إضافية لبيانات السحب النقطية (LIDAR)، وبيانات تحت الأرض (رادار شراد SHARAD المخترق للأرض)، وما إلى ذلك. وتشمل السمات الأخرى التعليقات التوضيحية، وتسميات المحاور، والشبكات، والمبالغات، وفصل الطبقات، وما إلى ذلك.

توضح النتيجة أنه يمكن تحقيق تصور عالي الجودة، ومسرّع للأجهزة، ومرن للبيانات متعددة الأبعاد على الويب، من خلال الجمع بين تقنية جانب الخادم EarthServer، وتقنية جانب الخادم X3DOM (كما في الشكل الآتي).



خادم الويب ثلاثي الأبعاد، الذي تم تكوينه لعرض البيانات من مصدرين (DEM ونقطة السحابة) في مشهد مشترك، (Baumann et al. 2015).



الخدمات المحمول


يوفر EarthServer تطبيقاً للهاتف المحمول يسمى «EarthServer SG Mobile»، مصمم للمنصتين الرئيسيتين:

(Android (<https://play.google.com/store/apps/details?id=it.infn.ct.earthserverSGmobile>

و iOS

. (<https://itunes.apple.com/us/app/earthserver-sg-mobile/id740603213?ls=1&mt=8>)

يوفر التطبيق الوصول إلى مجموعة من ثلاث خدمات (كما في الشكل الآتي):



EarthServer Science Gateway Mobile. (Baumann et al. 2015) لقطات شاشة من تطبيق

- ♦ الوصول إلى خدمات البيانات المناخية التي يوفرها خادم **MEEOWCS**. يمكن للمستخدم الوصول إلى توقعات لمدة **97** ساعة، على شكل رسم بياني أو صورة متحركة، ابتداء من تاريخ محدد لموقع محدد، أو ما يتم استرجاعه من خلال نظام تحديد المواقع العالمي (**GPS**).
- ♦ خادم **WCS** و **WMS** عام كامل، بما في ذلك إمكانيات التصور، تم تطويره بواسطة **Software Engineering Italia**. يعرض التغطيات وطبقات الخريطة التي تدعم تفاعل المستخدم.
- ♦ متصفح مستودع لبيانات الغلاف الجوي القادمة من مطياف **ESAMERIS**. يمكن للمستخدم التنقل في المستودع باستخدام آلية التصفية الهرمية المستندة إلى بيانات تعريف الأصول التي تتيح للمستخدمين العثور بسهولة على الأصول التي تم الاستعلام عنها.
- يدعم التطبيق المصادقة والترخيص من خلال **Catania Science Gateway** **Framework (Bruno and Barbera 2013)** استناداً إلى تقنيات **Shibboleth** و **LDAP**.

EarthServer: تطبيقات المنارة

من أجل عرض الحلول التكنولوجية لـ **EarthServer** والتحقق من صحتها، تم تطوير ستة تطبيقات للمنارات. تتناول خمسة منها احتياجات محددة للمجتمع العلمي، في حين أن النشاط السادس عبارة عن نشاط مشترك مع وكالة ناسا بشأن الوصول الآمن إلى أرشيفات البيانات.

♦ الخدمة البحرية

يغطي مصطلح "المجتمع البحري **Marine Community**" مجموعة واسعة ومتنوعة جداً بما فيهم علماء الأبحاث والكيانات التجارية والعلماء المواطنين. في الماضي،

استخدمت هذه المجموعات مجموعات بيانات صغيرة نسبياً، على سبيل المثال، جمع الأنواع في الموقع أو تركيز الكلوروفيل.

لقد تطورت هذه القياسات المنفصلة إلى سلاسل زمنية واسعة النطاق، وهي مهمة في توفير الرؤية والسياق للسيناريوهات المعقدة مثل تغير المناخ والتكيف مع الأنواع.

مع ظهور وانتشار بيانات الاستشعار عن بعد، أصبح إنشاء مجموعات بيانات أكبر وأكبر أمراً شائعاً في المجتمع البحري. أصبحت البيانات الآن بدقة مكانية عالية ومتاحة لأطوال السلاسل الزمنية العشرية.

قد يتجاوز حجم سلسلة زمنية واحدة متغيرة لشمال المحيط الأطلسي 1 تيرابايت. وهذا يخلق تحديات للتخزين والنقل والتحليل.

مجموعة البيانات التي تم اختيارها لتكون جوهر خدمة بيانات المحيطات (PML 2013a) هي السلسلة الزمنية للكلوروفيل التابعة لمبادرة تغير مناخ لون المحيط (OC-CCI) التابعة لوكالة الفضاء الأوروبية (Clements and Walker 2013). تغطي مجموعة البيانات العالمية هذه سلسلة زمنية مدتها 15 عاماً (1998 إلى الوقت الحاضر)، تم إنشاؤها عن طريق دمج منتجات لثلاثة أجهزة استشعار (SeaWiFS، وMODIS، وMERIS)، ويبلغ حجمها حوالي 17 تيرابايت.

أحد أسباب اختيار مجموعة بيانات OC-CCI، هو أنه بالإضافة إلى المعلومات المستشعرة مباشرة والمحسوبة بشكل غير مباشر، تحتوي مجموعة البيانات على بيانات وصفية لكل بكسل تصف أجهزة الاستشعار التي ساهمت في المعلمة، وتصنيف نوع المياه من تسع فئات وتقديرين لعدم اليقين لكل بكسل فيهما.

يحتوي عدد قليل من مجموعات بيانات ألوان المحيط الأخرى على مثل هذا النطاق الواسع من البيانات الوصفية لكل بكسل، وهذا يوفر فرصة رائعة لتوضيح

كيف يمكن استخدام خدمة بيانات أكثر ذكاءً لإنشاء منتجات مشتقة بناءً على دمج هذه المعلومات في منتج واحد في الوقت الفعلي.


عند إنشاء خدمة بيانات المحيطات، كان التركيز على تزويد المستخدم بالقدرة على التفاعل مع هذه السلاسل الزمنية الكبيرة من بيانات الاستشعار عن بعد، وتحليلها باستخدام واجهة قائمة على الويب.

يمكن اختيار البيانات ذات الاهتمام باستخدام مربع محيط رسومي، وتم تنفيذ «جدول زمني Timeline» بسيط للسماح باختيار أجزاء من السلسلة الزمنية باستخدام نموذج مماثل. يمكن بعد ذلك استخدام هذا النطاق الجغرافي الزمني للتحليل والتصور أو اختيار البيانات للتنزيل.

كان منح المستخدمين القدرة على أخذ بيانات انعكاس الضوء الخام، واستخدامها لإنتاج منتجات بيانات مشتقة جديدة بمنزلة هدف رئيسي أيضًا. ولتحقيق ذلك، تم إنشاء خادم نسبة النطاق على شبكة الإنترنت، الذي يسمح للمستخدمين بسحب وإفلات المتغيرات والعمليات الرياضية (انظر الشكل الآتي).

باستخدام هذه الواجهة، يمكن للمستخدمين تكرار خوارزميات إنشاء المنتجات الحالية أو تصميم واختبار خوارزميات جديدة. يتم عرض مخرجات الخوارزمية مباشرة مما يسمح للمستخدم بإجراء تعديلات صغيرة، ومعرفة مدى تأثيرها على المخرجات.

سيشهد العمل المستقبلي المزيد من خيارات التخطيط لاستخدامات Ocean Data Service ومدى الحياة بعد نهاية مشروع EarthServer. ستتم إضافة القدرة على حفظ التحليل، ومشاركته لإنشاء أداة تعاونية لاستكشاف وتحليل منتجات البيانات الضخمة.



خدمة EarthServer البحرية: يوفر Band Ratio Client واجهة مستخدم بسيطة لإنشاء خوارزميات معقدة لتدريس الأفكار الجديدة واختبارها، (Baumann et al. 2015)

سيتم أيضاً تحسين خادم نسبة النطاق من خلال عدد أكبر من العمليات الرياضية المحددة مسبقاً، مما يمنح المستخدم المزيد من القدرة على إنشاء واختبار خوارزميات نسبة النطاق الجديدة.

♦ خدمة الجيولوجيا

تم تطوير خدمة الجيولوجيا (BGS 2013) EarthServer بواسطة BGS. ويتميز مجتمع علوم الأرض بتنوعه، حيث يضم العديد من التخصصات الفرعية لكل منها متطلبات مختلفة للبيانات والمعالجة.

في تطوير خدمة منارة الجيولوجيا، كان الهدف هو تقديم خدمة قيمة لتخصصات فرعية مختارة، وفي الوقت نفسه توضيح إمكانيات تقنية EarthServer للمجتمع بأكمله.

وقد تم اختيار مجالين ستركز عليهما الخدمة؛ الاستشعار الجيولوجي عن بعد، والنمذجة المكانية ثلاثية الأبعاد.

تم إجراء دراسة استقصائية لمقدمي بيانات علوم الأرض، وثبت أن معظم التخصصات الفرعية لعلوم الأرض لديها خبرة محدودة في استخدام بيانات التغطية، على الرغم من أن تطبيق بيانات الاستشعار عن بعد على علوم الأرض راسخ، وممتلكات كبيرة من البيانات تم إنشاؤها من قبل العديد من منظمات علوم الأرض.

إن توفير الوصول السهل إلى مقتنيات البيانات هذه، إلى جانب القدرة على معاينة مجموعات البيانات لمعرفة مدى ملاءمتها وتنفيذ بعض المعالجة المسبقة البسيطة قبل التنزيل، هو حالة الاستخدام التي تهدف الخدمة إلى معالجتها.

تقليدياً، كانت الخرائط الجيولوجية هي الوسيلة الرئيسة التي يتم من خلالها نشر المعلومات الجيولوجية، وفي الآونة الأخيرة تطورت هذه إلى توفير الخرائط الرقمية وخدمات الويب.

هناك تحرك متزايد من الخرائط الجيولوجية نحو النماذج المكانية الجيولوجية ثلاثية الأبعاد، لتوضيح الهندسة الضمنية على الخرائط الجيولوجية.

كما أن هناك حاجة لتقديم نماذج ثلاثية الأبعاد وتصورها باستخدام خدمات الويب والمتصفحات القياسية، وتهدف خدمة الجيولوجيا **EarthServer** إلى معالجة هذا الأمر مع إشارة خاصة إلى النماذج المكانية ثلاثية الأبعاد للرواسب السطحية في منطقة غلاسكو.

وتتكون هذه النماذج من 35 سطحاً شبكياً يفصل بين الوحدات الجيولوجية، ولكل وحدة جيولوجية سطح محيط؛ علوي وسفلي. تشتمل بيانات الاستشعار

عن بعد المتوفرة في الخدمة على ستة نطاقات **Landsat 7** (أزرق، أخضر، أحمر، **NIR 1**، **NIR 2**، **MIR**)، وثلاثة نطاقات للتصوير الجوي بالألوان الزائفة (**NIR**)، أخضر، أزرق) للمملكة المتحدة.


يعد توفر نماذج التضاريس الرقمية (**DTMs**) أمراً مهماً لتصوير ومعالجة كل من بيانات ونماذج الاستشعار عن بعد، وتتضمن الخدمة نماذج **DTM** بدقة 50 متراً و2 متر للمملكة المتحدة. وبحلول نهاية المشروع، سيكون حجم البيانات المجمعة 20 تيرابايت.

من السمات المشتركة لبيانات علوم الأرض أن قيود الوصول المختلفة تنطبق على مجموعات البيانات المختلفة. على سبيل المثال، يمكن إتاحة بيانات **Landsat** في خدمة الجيولوجيا مجاناً، في حين يقتصر استخدام بيانات الصور الجوية على موظفي **BGS** فقط.

تم تطوير نموذجين للرواسب السطحية في غلاسكو، أحدهما يقتصر على وسط غلاسكو ومتاح مجاناً، والآخر يغطي مساحة أوسع ويتضمن المزيد من البيانات التي يقتصر استخدامها على أعضاء اتحاد المستخدمين الذين وقعوا على اتفاقية ترخيص. ومن أجل معالجة متطلبات الوصول المختلفة هذه، تم إنشاء خدمات متوازية مع واجهات المستخدم الرسومية، التي توفر الوصول إلى مجموعات مختلفة من التغطيات. يمكن الوصول إلى البيانات المستشعرة عن بعد من واجهة المستخدم الرسومية على الويب، والتي تسمح بإجراء الاختيار المكاني بيانياً مقابل مجموعة من خرائط الخلفية.

يتم سرد الصور المتوفرة في المنطقة المختارة، ويمكن عرضها ومقارنتها وتراكبها على **DTMs** في الخادم ثلاثي الأبعاد للمساعدة في الاختيار والتنزيل. يمكن أيضاً تحسين الصور من خلال تعديل التباين التفاعلي (كما في الشكل الآتي) وتنزيل الصورة المحسنة.

توفر واجهة المستخدم الرسومية أيضاً إمكانية الوصول إلى نموذج غلاسكو في الخادم ثلاثي الأبعاد، حيث يمكن للمستخدم عرض النموذج بشكل تفاعلي، وتشغيل وإيقاف الأسطح الفردية، وزيادة المبالغة الرأسية لتعزيز السمات الجيولوجية.



خدمة جيولوجيا EarthServer: تعديل تباين الصورة المحددة، (Baumann et al. 2015).

من المتوقع أن تعمل التطورات المستقبلية لهذه الخدمة على زيادة نطاق أنواع البيانات المتاحة، والانتقال من واجهات EarthServer المحددة إلى دمج خدمات التغطية في مجموعة من البوابات والتطبيقات الخاصة بالمجال.

♦ خدمة الغلاف الجوي

خدمة بيانات المناخ هي تطبيق المنارة الذي طورته (MEE0 2013) لدعم مجتمعات المناخ والغلاف الجوي في استغلال مجموعات البيانات غير المتجانسة متعددة الأبعاد على المستويات الإقليمية والأوروبية والعالمية **up to 5D**:

x/y/z/time/forecast time, in case of time series of forecasts of three-dimensional pollutant fields; (Mantovani, Barboni and Natali, 2013)

تضم مجموعة اهتمامات مستخدمي خدمة البيانات المناخية السلطات الوطنية والدولية التي تستخدم مجموعة متنوعة من البيانات لتحليل الظواهر البيئية التي تحدث على مستويات مختلفة، وتستخدم بشكل مستقل بيانات النماذج العددية، والمنتجات الساتلية (الخاصة بالأقمار الصناعية) لرصد الأرض، والقياسات الأرضية لمعاملات الغلاف الجوي والمناخ. تطبيقات محددة، مثل مراقبة جودة الهواء) أو في الوقت نفسه لتحسين المنتجات التشغيلية كما في حالة استيعاب القياسات الأرضية ومنتجات **EO** في نماذج رقمية لتحسين توقعات جودة الهواء.


العامل المشترك هو التعامل مع مجموعة متنوعة من البيانات الضخمة وأحجامها: لقد تم فعلاً توحيد خبرات المجتمعات المعنية في التعامل مع البيانات الضخمة، مع معالجة مئات الجيجابايت من البيانات وإنتاجها يومياً في سلاسل المعالجة التشغيلية والبحثية.

ومع ذلك، فإن استخدام الواجهات والخدمات القياسية لمعالجة البيانات في الوقت الفعلي وتصورها واستغلالها لا يزال غير فاعل، مما يترك لمكونات المعالجة غير المتصلة بالإنترنت دوراً لإجراء تحليل البيانات وتوفير خرائط موجزة (على سبيل المثال، نشرات كل ثلاث ساعات).

تتيح خدمة البيانات المناخية إمكانية الوصول الفوري إلى تيرابايت من البيانات وإمكان معالجتها. توفر واجهة المستخدم الرسومية لتحليل تطور أجهزة الاستشعار المتعددة (**MEA**) أدوات فاعلة لتحليل بيانات السلاسل الزمنية مدعومة بواجهة **WCS/WCPS** التي توفرها قاعدة بيانات مصفوفة راسدامان، (ESA, 2014).

تسمح البنية التحتية القوية (+50 وحدة معالجة مركزية، و+150 جيجابايت من ذاكرة الوصول العشوائي، و+20 تيرابايت من مساحة القرص)، الموزعة ما بين وكالة الفضاء الأوروبية وMEO باستغلال البيانات في الوقت الفعلي على:

- ♦ **أساس البكسل:** السماح باختيار مجموعة من المنتجات ليتم تصورها وتحليلها في الوقت نفسه لدراسة العلاقة بين الظواهر الطبيعية والبشرية.
- ♦ **أساس مجال الاهتمام:** السماح باختيار مجالات تحليل المناطق المحدودة أو العالمية، لتركيب قياسات مختلفة للمعلومة نفسها من مصادر مختلفة، أو لدفع تحليل وحدات البكسل المحددة التي توفر خريطة خلفية ذات معنى.



خدمة الغلاف الجوي EarthServer: تحليل الهباء الجوي (AATSR، MODIS، MACC)، والسلاسل الزمنية لدرجات الحرارة (MACC)؛ تمت دراسة شذوذ (القيم العالية) AOT فوق الصين، في 21 مارس 2013، لتحديد التأثيرات المكانية والزمانية لمعلومات الأرصاد الجوية، (Baumann et al. 2015).

بناءً على طلب مجتمعات علوم الغلاف الجوي، تم إثراء خدمة بيانات المناخ بمجموعات من البيانات المشتقة من نماذج ثلاثية ورباعية وخماسية الأبعاد، (مثل مجالات الأرصاد الجوية وخرائط الملوثات، وما إلى ذلك)، وذلك للسماح للمستخدمين بتنفيذ خدمات معالجة الوصول المتقدمة عبر واجهة **WCPS**: (<http://earthserver.services.meeo.it/tools/#wcps>) على سبيل المثال، تقييم المقارنة بين بيانات الأقمار الصناعية والبيانات النمذجية، واستخراج المعلومات الإحصائية، وما إلى ذلك.

في الوقت الحاضر، أكثر من **100** مجموعة، بما في ذلك بيانات الطرف الثالث (خرائط الهباء الجوي البصرية في جميع أنحاء العالم، مقدمة من **ECMWF**؛ مجالات الأرصاد الجوية، وخرائط تراكيز الملوثات في أوروبا وإيطاليا والنمسا، مقدمة من **SHMI**، **ENEA**، و**ZAMG**، على التوالي)، وهي متاحة للاستغلال المكثف للبيانات.

بحلول نهاية مشروع **EarthServer**، ستوفر خدمة بيانات المناخ إمكانية الوصول ومعالجة الوصول إلى أكثر من **130** تيرابايت من منتجات وكالة الفضاء الأوروبية، ووكالة ناسا، ومنتجات الجهات الخارجية.

◆ خدمة الغلاف الجليدي

تم تصميم خدمة الغلاف الجليدي لمساعدة المجتمع على اكتشاف وتقييم منتجات الغطاء الثلجي. وهو يتألف من البنية التحتية لـ **EarthServer** في الخلفية، وهي أداة مزامنة بين **CryoService** وموفر بيانات الغطاء الثلجي. علاوة على ذلك، فهو خادم ويب يسمح بالمعالجة المسبقة للبيانات وتصورها.


يتم توفير منتجات الغطاء الثلجي من خلال مشروع:

FP7 CryoLand (<http://cryoland.eu>).

المنتجات الأكثر صلة هي الغطاء الثلجي الجزئي (**FSC**)، بالإضافة إلى مكافئ مياه الثلج (**SWE**). وبصرف النظر عن التغطيات لعموم أوروبا، تنتج **CryoLand** منتجات إقليمية ذات دقة أعلى يمكن الوصول إليها عبر خدمة الغلاف الجليدي.

تتوفر أيضًا بيانات إضافية مثل نماذج الارتفاع الرقمية المختلفة (GTOPO30)، (SRTM، EUDM)، ومناطق أحواض الأنهار (EEA WISE WFD). وهذا يجعل من الممكن دمج بيانات الغطاء الثلجي مع المعلومات الكنتورية والإحصائيات المجمعة في مناطق معينة من مستجمعات المياه.

تحدد مناطق مستجمعات المياه أو أحواض الصرف مساحات من الأرض، تقتارب فيها جميع المياه السطحية الناتجة عن تساقط الأمطار في نقطة واحدة، معظمها نهريّة. وبالتالي فإن تقدير كمية الثلوج في منطقة مستجمعات المياه هذه يوفر معلومات مفيدة لعلماء الهيدرولوجيا أو محطات الطاقة الكهرومائية).



خدمة الغلاف الجليدي EarthServer: إحصاءات حوض الصرف، (Baumann et al. 2015).

يتم إنشاء منتجات الثلج بشكل أساسي على أساس يومي إما من بيانات **MODIS/Terra** البصرية، أو من مزيج من مقياس الإشعاع القائم على الأقمار الصناعية **DMSP SSM/I**، من عام **1987م** إلى الوقت الحاضر)، وبيانات عمق الثلج المقدمة من محطات الأرصاد الجوية الأرضية (**ECMWF**). يقوم البرنامج النصي للمزامنة بالتحقق يوميًا من توفر شرائح زمنية جديدة، وتنزيلها واستيعابها وتسجيلها في البنية التحتية لـ **EarthServer**.

بصرف النظر عن نقاط نهاية **WMS** و **WCS** و **WCPS** الإلزامية (المقدمة من **Rasdaman**)، توفر خدمة الغلاف الجليدي نقاط النهاية **EO-WCS** (**Baumann and Meissl, 2010**) و **EO-WMS** (**Lankester, 2009**) (المقدمة من **EOxServer**) للبيانات.

يعد ملف تعريف تطبيق **EO** لـ **WCS** امتدادًا مصممًا للتعامل مع الاحتياجات المحددة لبيانات رصد الأرض. فهو يضيف بيانات وصفية إلزامية مثل الطوابع الزمنية وآثار الأقدام، بالإضافة إلى تعريفات التغطية الموسعة لتمثيل سلسلة مجموعات البيانات أو الفسيفساء المدمجة.

يوفر تطبيق الويب في الواجهة الأمامية واجهة خريطة ونوعين من الأدوات للتفاعل مع البيانات. تقوم أدوات التحديد بتتبع التحديدات المحددة من قبل المستخدم من خلال معالجة النماذج الأساسية.

تسمح عناصر واجهة المستخدم المرئية بعرض رسوم بيانية متنوعة من خلال الاستخدام المكثف لمكتبة **D3 JavaScript (D3 2013)**. يتم تقديم الرسوم البيانية باستخدام استجابات استعلامات **WCPS** التي تم إنشاؤها ديناميكيًا والتي تعتمد على بيانات النموذج الأساسية.

لكل منتج، يمكن للمستخدم تحديد مجموعات فرعية مكانية مختلفة: نقاط الاهتمام، أو مناطق حوض النهر، أو المربعات المحيطة. بالإضافة إلى ذلك، يمكن

إنشاء مجموعات فرعية وفقاً للمستويات الكنتورية، باستخدام نماذج الارتفاع الرقمية الأساسية. لتحديد المجموعة الفرعية الزمنية، تم تطوير عنصر واجهة مستخدم شريط تمرير الوقت. هنا، يمكن للمستخدم تحديد وقت الاهتمام الذي يتم تطبيقه بعد ذلك على استعلام **WCPS**. بالإضافة إلى ذلك، يعمل شريط تمرير الوقت كأداة تصور للتوزيع الزمني للمنتج المعني.

في النهاية، يتم تصور النتائج من خلال مخططات شبيهة بـ **Hovmoeller**، وهي مناسبة تماماً لإظهار السلاسل الزمنية للبيانات القادمة من مواقع مختلفة، باستخدام البرنامج المساعد **Cubism D3**. يتيح ذلك للمستخدم تقييم تطور معلمات الغطاء الثلجي المختلفة التي تم تجميعها فعلاً في الكيانات المكانية ذات الصلة؛ مثل مناطق أحواض الأنهار.

♦ خدمة الكواكب

تتوفر بيانات الكواكب مجاناً في الأرشفات ذات الصلة التي تقدمها وكالات الفضاء، مثل نظام بيانات الكواكب التابع لناسا (**McMahon 1996; PDS**) وأرشفات علوم الكواكب التابعة لوكالة الفضاء الأوروبية.

ويقتصر استغلالها من قبل المجتمع على الكمية المتغيرة من مجموعات البيانات المعاييرة / الأعلى مستوى. يرجع تعقيد مجموعات البيانات المتعددة التجارب والمهام هذه إلى حد كبير إلى عدم تجانس البيانات نفسها، وليس حجمها الهائل.

تُعد البيانات المدارية، حتى الآن، هي الأنسب لإدراجها في قواعد بيانات المصفوفة. معظم تجارب الاستشعار عن بعد المعتمدة على مركبة الهبوط أو المركبة الجواله (وربما في الموقع أيضاً) مناسبة لمناهج مماثلة، على الرغم من أن تعقيد الأنظمة المرجعية الإحداثية (**CRS**) يكون أعلى في الحالة الأخيرة.

PlanetServer، الخدمة الكوكبية لـ **EarthServer** (صفحة **PlanetServer** الرئيسة 2013م)، هو نظام حديث لاستكشاف البيانات وتحليلها عبر الإنترنت، يعتمد على معايير الاتحاد الجغرافي المكاني المفتوح (**OGC**) للبيانات المدارية للمريخ.

وهو يوفر الوصول إلى البيانات الطبوغرافية والبانكروماتية والمتعددة الأطياف والفائقة الطيفية. لقد كان قيد التطوير في جامعة جاكوبس بريمن منذ أكتوبر 2011، (**Oosthoek et al. 2013**).

منذ بداية عام 2013، قدمت شركة **Software Engineering Italia** إعادة هيكلة وإعادة تصميم **Planetary Service Client** نحو تطبيق قائم على الويب 2.0، أي الإصدار الجديد، متبوعاً بمزيد من التطويرات.

لا يمكن تحليل البيانات فائقة الطيفية من المريخ حالياً إلا في وضع عدم الاتصال من خلال معالجة مرهقة نسبياً وتحتاج إلى الوصول إلى أدوات تجارية، بالإضافة إلى الحاجة إلى أدوات معالجة (لتقليل بيانات سطح المكتب) ومحطة عمل مفتوحة المصدر.

يسمح **WCPS** بالتحليل عبر الإنترنت مع الحد الأدنى من عرض النطاق الترددي ومساحة التخزين التي تحتاجها سير العمل النموذجي لتحليل الصور الكوكبية. تركز الخدمة بشكل أساسي على البيانات المستمدة من مقياس طيف التصوير الاستطلاعي المدمج الموجود على متن مركبة **NASA Mars Reconnaissance Orbiter (MRO)** كما أنها تتضمن أيضاً بيانات تصوير أخرى، مثل كاميرا **MRO context Imager (CTX)**.


وكاميرا **الستيريو عالية الدقة (MEX) Mars Express**، من بين أمور أخرى. وبينما تركزها الأساسي كان على تحليل البيانات فوق الطيفية من خلال **WCPS** المطابق لتسليم خرائط **WMS**، فقد توسعت الخدمة تدريجياً لتستضيف أيضاً بيانات رادارية السبر لما تحت السطح.

بالإضافة إلى ذلك، تمت إضافة كل من الصور المفردة والفسيفساء والبيانات الطبوغرافية إلى الخدمة، المستمدة من تجربة **HRSC**.

يمكن أن يمتد التركيز الحالي المتمحور حول المريخ، إلى أجسام كوكبية أخرى، مما يجعل من الممكن تطبيقه على القمر أو عطارد أو ما شابه ذلك.

هذا، ويمكن الوصول إلى الخدمة الكوكبية لـ **EarthServer** على <http://www.planetserver.eu/> بالإضافة إلى الروابط على بوابة مشروع **Earthserver.eu**.

تشتمل بنية **PlanetServer** على خادم رئيس (الشكل الآتي: **A**) وخوادم ويب متعددة (الشكل الآتي: **B , C**). المزيد من الجهود التي يبذلها خادم نظم المعلومات الجغرافية لسطح المكتب تمضي قدمًا. يستخدم كلا خادمي الويب تقنيات الويب القياسية، ويتم إصدار جميع التعليمات البرمجية التي تم تطويرها داخل المشروع، في كل من مستودع المشروع، وعلى **GitHub** على: <https://github.com/planetserver>. (Baumann et al. 2015)



خدمة EarthServer الكوكبية؛ البنية (A) والخوادم المتعددة (B, C) وإعداد الخادم. البيانات الأصلية مستمدة من أرشيفات نظام بيانات الكواكب العامة، معلومات محدثة، والوصول إلى (Baumann et al. 2015) <http://planetserver.eu>

• البنية التحليلية للبيانات الضخمة في الوقت الحقيقي لتطبيقات الاستشعار عن بُعد

تولد أصول العالم الرقمي للاستشعار عن بعد يومياً حجماً هائلاً من البيانات في الوقت الفعلي (يشار إليها بشكل أساسي بمصطلح «البيانات الضخمة»)، حيث يكون للمعلومات المتعمقة أهمية محتملة إذا تم جمعها وتجميعها بشكل فاعل.

في عصرنا الحالي، تمت إضافة قدر كبير إلى البيانات الضخمة للاستشعار عن بعد في الوقت الحقيقي مما يبدو في البداية، واستخراج المعلومات المفيدة بطريقة فاعلة يقود النظام نحو تحديات حسابية كبيرة، مثل التحليل والتجميع والتحليل والخرن، حيث يتم جمع البيانات عن بعد.

مع الأخذ في الاعتبار العوامل المذكورة أعلاه، هناك حاجة لتصميم بنية نظام ترحب بالوقت الفعلي ومعالجة البيانات دون الاتصال بالإنترنت. لذلك، في هذا البحث، نقترح بنية تحليلية للبيانات الضخمة في الوقت الحقيقي لتطبيقات الاستشعار عن بعد عبر الأقمار الصناعية.

ويتكون الهيكل المقترح من ثلاث وحدات رئيسية، مثل

◀ وحدة الحصول على البيانات الضخمة بالاستشعار عن بعد (RSDU).

◀ وحدة معالجة البيانات (DPU).

◀ وحدة قرار تحليل البيانات (DADU).

أولاً، تحصل RSDU على البيانات من القمر الصناعي وترسل هذه البيانات إلى المحطة الأساسية، حيث تتم المعالجة الأولية.

ثانياً، تلعب DPU دوراً حيوياً في الهندسة المعمارية للمعالجة الفاعلة للبيانات الضخمة في الوقت الفعلي من خلال توفير الترشيح وموازنة التحميل والمعالجة المتوازية.

ثالثاً، DADU هي وحدة الطبقة العليا للبنية المقترحة، وهي المسؤولة عن تجميع النتائج وتخزينها وإصدار القرار بناءً على النتائج الواردة من **DPU**.

تتمتع البنية المقترحة بالقدرة على التقسيم وموازنة التحميل والمعالجة المتوازية للبيانات المفيدة فقط. وبالتالي، فإنه يؤدي إلى تحليل البيانات الضخمة للاستشعار عن بعد في الوقت الحقيقي بكفاءة باستخدام نظام المرصد الأرضي.

علاوة على ذلك، تتمتع البنية المقترحة بالقدرة على تخزين البيانات الأولية الواردة لإجراء تحليل دون اتصال بالإنترنت على عمليات التفريغ المخزنة إلى حد كبير، عند الحاجة.

وأخيراً، يتم توفير تحليل مفصل للبيانات الضخمة لمرصد الأرض المستشعر عن بعد للمنطقة البرية والبحرية باستخدام **Hadoop**. بالإضافة إلى ذلك، تم اقتراح خوارزميات مختلفة لكل مستوى من مستويات **RSDU** و **DPU** و **DADU** للكشف عن المناطق البرية والبحرية لتوضيح عمل البنية المعمارية.

♦ النظام الموجود

تعمل أحدث أجهزة الاستشعار المصممة حديثاً والمستخدم في نظام رصد الأرض والكواكب على توليد تدفق مستمر من البيانات.

علاوة على ذلك، تم إنجاز معظم العمل في مجالات مختلفة لبيانات صور الأقمار الصناعية الحسية عن بعد، مثل اكتشاف التغيير، واكتشاف الحواف القائمة على التدرج، واكتشاف الحواف القائمة على تشابه المنطقة، وتقنية تدرج الكثافة للتنبؤ الداخلي الفاعل.

♦ مساوئ النظام الحالي:

تُعد عواقب تحويل بيانات الاستشعار عن بعد إلى الفهم العلمي مهمة حاسمة. عادة، البيانات التي يتم جمعها من المناطق النائية ليست جاهزة للتحليل؛ في شبكات الوصول عن بعد، حيث يمكن لمصدر البيانات مثل أجهزة الاستشعار، إنتاج كمية هائلة من البيانات الأولية.

♦ النظام المقترح:

في هذه الدراسة، تمت إحالة التدفق المستمر عالي السرعة للبيانات أو البيانات كبيرة الحجم غير المتصلة بالإنترنت إلى «البيانات الضخمة»، والتي تقود إلى عالم جديد من التحديات.

تقدم هذه الدراسة بنية تحليلية للبيانات الضخمة للاستشعار عن بعد، والتي تستخدم لتحليل الوقت الحقيقي، وكذلك البيانات غير المتصلة بالإنترنت. في البداية، تتم معالجة البيانات مسبقاً عن بعد، والتي يمكن بعد ذلك قراءتها بواسطة الأجهزة. وبعد ذلك، يتم إرسال هذه المعلومات المفيدة إلى المحطة الأساسية الأرضية لمزيد من معالجة البيانات. تقوم المحطة الأساسية الأرضية بنوعين من المعالج؛ مثل معالجة البيانات في الوقت الفعلي والبيانات غير المتصلة بالإنترنت. في حالة البيانات غير المتصلة بالإنترنت، يتم نقل البيانات إلى جهاز تخزين البيانات غير المتصل بالإنترنت.

يساعد دمج جهاز تخزين البيانات غير المتصل بالإنترنت في الاستخدام اللاحق للبيانات، في حين يتم نقل البيانات في الوقت الفعلي مباشرة إلى خادم الترشيح وموازنة التحميل، حيث يتم استخدام خوارزمية الترشيح، والتي تستخرج المعلومات المفيدة من البيانات الضخمة. من ناحية أخرى، يقوم موازن التحميل بموازنة قوة المعالجة؛ من خلال التوزيع المتساوي للبيانات في الوقت الفعلي على الخوادم. لا يقوم خادم الترشيح وموازنة التحميل بتصفية الحمل وموازنته فحسب، بل يتم استخدامه أيضاً لتعزيز كفاءة النظام.

تم تنفيذ البنية المقترحة والخوارزميات في **Hadoop** باستخدام برمجة **MapReduce** من خلال تطبيق بيانات مرصد الأرض للاستشعار عن بعد .
ويتكون الهيكل المقترح من ثلاث وحدات رئيسية، مثل:

♦ **RSDU**.

♦ **DPU**.

♦ **DADU**.

تقوم هذه الوحدات بتنفيذ خوارزميات لكل مستوى من مستويات البنية اعتماداً على التحليل المطلوب.

♦ **مزايا النظام المقترح:**

مع الحصول على البيانات، حيث لا تكون معظم البيانات ذات أهمية، يمكن تصفيتها أو ضغطها بأوامر من حيث الحجم. ومن أجل استخدام هذه المرشحات، فإنها لا تتجاهل المعلومات المفيدة.

من خلال استخراج البيانات الذي يسحب المعلومات المفيدة من المصادر الأساسية ويسلمها في تشكيل منظم مناسب للتحليل. على سبيل المثال، يتم تقليل مجموعة البيانات إلى تصنيف فئة واحدة لتسهيل التحليل، على الرغم من أن أول شيء يُفكر فيه دائماً هو أن البيانات الضخمة تصف الحقيقة دائماً.

يساعد دمج جهاز تخزين البيانات غير المتصل بالإنترنت في الاستخدام اللاحق للبيانات.

يقوم موازن التحميل بموازنة قوة المعالجة من خلال التوزيع المتساوي للبيانات في الوقت الفعلي على الخوادم. (Rathore, et al., 2015)

الذكاء الاصطناعي والاستكشاف الجيولوجي

يلعب الذكاء الاصطناعي (AI) دوراً محورياً في تسهيل التطوير عالي الجودة لصناعة الاستكشاف الجيولوجي. تمتد تطبيقاتها عبر مجالات متنوعة، بما في ذلك تحليل البيانات وتفسيرها، وعمليات الاستكشاف الآلية، وإدارة تحسين الموارد، وتقييم الأخطار وإدارتها، وتطوير الموارد الذكية، وتبادل المعرفة والتعاون. وبالاستفادة من الذكاء الاصطناعي في هذه المجالات، يمكن لصناعة الاستكشاف الجيولوجي أن تتقدم نحو تحقيق نتائج عالية الجودة.

يتيح الذكاء الاصطناعي توجيهات أكثر دقة لأنشطة الاستكشاف، ويعزز الكفاءة، ويحسن جودة النتائج، ويقلل التكاليف، ويتنبأ بالأخطار، ويحسن تنمية الموارد، ويسرع نشر المعرفة وتطبيقها. تساهم هذه الأدوار الحاسمة التي يوفرها الذكاء الاصطناعي كثيراً في التنمية المستدامة لصناعة الاستكشاف الجيولوجي.

• تحليل البيانات وتفسيرها

♦ معالجة البيانات على نطاق واسع

يتضمن الاستكشاف الجيولوجي كمية هائلة من البيانات الجيولوجية، بما في ذلك الصور الجيولوجية والبيانات الجيوفيزيائية والبيانات الجيوكيميائية وغيرها. يتيح الذكاء الاصطناعي المعالجة الفاعلة لمثل هذه البيانات واسعة النطاق، واستخراج المعلومات الأساسية، وتسريع سرعة ودقة تحليل البيانات.

♦ التعرف على المعالم الجيولوجية

من خلال استخدام التعلم الآلي وخوارزميات التعلم العميق، يمكن للذكاء الاصطناعي تعلم وتحديد السمات الجيولوجية المختلفة، مثل علم الصخور والهياكل. تساعد هذه القدرة في تحديد الدقيق لمناطق الموارد المعدنية المحتملة، مما يوفر إرشادات أفضل لأهداف الاستكشاف.

♦ التنبؤ ببنية ما تحت الأرض

يستفيد الذكاء الاصطناعي من البيانات الجيولوجية التاريخية والبيانات الجيوفيزيائية لإنشاء نماذج تنبؤية، مما يتيح التنبؤ الدقيق بالهياكل الموجودة تحت الأرض والسمات الطباقية. وهذا الجانب مهم جداً، خاصة في استكشاف الموارد الجوفية وتقييم الأخطار الجيولوجية.

♦ تحسين خطة الاستكشاف

ومن خلال تحليل بيانات الاستكشاف التاريخية والمعلومات الجيولوجية، يمكن للذكاء الاصطناعي تقديم توصيات لتحسين خطط الاستكشاف، بما في ذلك تخطيط مسارات الاستكشاف، واختيار أنسب طرق الاستكشاف، مما يساعد في تحسين كفاءة الاستكشاف وجودة النتائج.

♦ التنبؤ بتوزيع الموارد

وباستخدام التعلم الآلي وخوارزميات التعلم العميق، يمكن للذكاء الاصطناعي تحليل البيانات الجيولوجية، والعوامل البيئية للتنبؤ بتوزيع ووفرة الموارد الجوفية. وتساهم هذه القدرة في توجيه استكشاف الموارد وتطويرها. فضلاً عن تعزيز دقة وكفاءة أنشطة الاستكشاف.

♦ تفسير البيانات والتصور

يسهل الذكاء الاصطناعي تفسير وتصور البيانات الجيولوجية من تحليل البيانات وتفسير النماذج. تتيح تقنيات تصور العرض للسمات الجيولوجية وبنيات ما تحت الأرض، في التعرف على توزيع الموارد، من ثم مساعدة صناع القرار والباحثين على فهم البيانات الجيولوجية واستخدامها بشكل أفضل.

• أتمتة عمليات الاستكشاف

♦ معالجة البيانات وإدارتها

يتضمن الاستكشاف الجيولوجي قدرًا هائلًا من البيانات، بما في ذلك المزيد من بيانات الاستكشاف، والصور الجيولوجية والبيانات الجيوفيزيائية. يمكن للذكاء الاصطناعي معالجة هذه البيانات الشاملة وإدارتها بشكل فاعل، ثم استخراج المعلومات المهمة وتسريع سرعة ودقة معالجة البيانات. على سبيل المثال، يمكن استخدام تقنيات الذكاء الاصطناعي في تنقية بيانات الاستكشاف وتنظيمها وأرشفتها تلقائيًا، مما يقلل من التدخل اليدوي ويقلل من الأخطاء.

♦ التعرف على المعالم الجيولوجية

ومن تطبيق التعلم الآلي وخوارزميات التعلم العميق، يمكن للذكاء الاصطناعي أن يتعلم ويتعرف على السمات الجيولوجية مثل؛ علم الصخور والجيولوجيا البنائية. تسهل هذه القدرة التحديد الدقيق لمناطق الموارد المعدنية المحتملة، وتوفير أهداف استكشاف محسنة.

♦ التنبؤ بالبنية تحت السطحية

يمكن للذكاء الاصطناعي الاستفادة من البيانات الجيولوجية التاريخية والبيانات الجيوفيزيائية لإنشاء نماذج للتنبؤ الدقيق بالبنية تحت السطحية، والسمات الطباقية. وهذا يحمل أهمية كبيرة لاستكشاف الموارد الجوفية، وتقييم الأخطار الجيولوجية.

♦ تحسين خطط الاستكشاف

من تحليل بيانات الاستكشاف التاريخية والمعلومات الجيولوجية، يمكن للذكاء الاصطناعي تقديم اقتراحات تحسين لخطط الاستكشاف، بما في ذلك التخطيط الأمثل للمسار واختيار طرق الاستكشاف واستراتيجيات جمع العينات. ويساهم ذلك في تحسين كفاءة الاستكشاف ونتائج الجودة، مع تقليل التدخل اليدوي، والأخطاء المرتبطة باتخاذ القرار البشري.

♦ تحليل البيانات وتفسيرها

يمكن للذكاء الاصطناعي استخراج المعلومات الأساسية من البيانات الجيولوجية، ومن ثم تقديم تحليل وتفسير دقيق للبيانات. وبمساعدة التعلم الآلي وخوارزميات التعلم العميق، يمكن للذكاء الاصطناعي تحديد السمات الجيولوجية، والتنبؤ بالبنى تحت السطح، وتقييم توزيع الموارد، وتقديم إرشادات أكثر دقة للاستكشاف الجيولوجي.

♦ دعم القرار الآلي

وبالاعتماد على البيانات والمعرفة الوفيرة، يمكن للذكاء الاصطناعي أن يوفر دعمًا آليًا للقرار لمساعدة صناع القرار. باستخدام تقنيات متنوعة؛ مثل تحليل البيانات، والنمذجة التنبؤية، وخوارزميات التحسين، يقدم الذكاء الاصطناعي توصيات القرار وخطط التحسين، مما يمكن صناع القرار من اتخاذ خيارات أكثر استتارة طوال عملية الاستكشاف.

• تحسين الموارد وإدارتها

♦ تحسين تخصيص الموارد

يلعب الذكاء الاصطناعي (AI) دورًا حاسمًا في تحليل متطلبات الاستكشاف الجيولوجي وظروف الموارد لتحديد الاستراتيجية المثلى لتخصيصها. وبالاستفادة من الخوارزميات الذكية ونماذج التحسين، يأخذ الذكاء الاصطناعي في الاعتبار عوامل مثل؛ خصائص منطقة الاستكشاف، وفاعلية أساليب الاستكشاف، وكفاءة استخدام الموارد لتحقيق التخصيص الأمثل. وهذا يعزز كفاءة الاستكشاف والفوائد الاقتصادية.

♦ اختيار الموقع لمناطق الاستكشاف

يستخدم الذكاء الاصطناعي التعلم الآلي وخوارزميات التعلم العميق للاستفادة من البيانات الجيولوجية الوفيرة والمعلومات ذات الصلة، مما يسمح بتحديد مناطق الاستكشاف المثالية. ومن تحليل السمات الجيولوجية وإمكانات الموارد والأخطار الجيولوجية، يقوم الذكاء الاصطناعي بتقييم إمكانات وجدوى مناطق الاستكشاف بدقة، مما يؤدي إلى تحسين اختيار أهداف الاستكشاف.

♦ تحسين طرق الاستكشاف

يعمل الذكاء الاصطناعي على تحسين اختيار وتطبيق طرق الاستكشاف من تحليل البيانات وإنشاء النماذج. فمن تحليل بيانات الاستكشاف التاريخية والمعلومات ذات الصلة، يحدد الذكاء الاصطناعي أفضل طرق الاستكشاف، وبالتالي تحسين فاعلية الاستكشاف وجودة النتائج.

♦ تعزيز كفاءة استخدام الموارد

يعزز الذكاء الاصطناعي كفاءة استخدام الموارد بالاستفادة من الخوارزميات الذكية ونماذج التحسين. ومن تحليل بيانات الاستكشاف والمعلومات ذات الصلة، يعمل الذكاء الاصطناعي على تحسين استخدام الموارد أثناء عملية الاستكشاف، مما يؤدي إلى تقليل تكاليف الاستكشاف.

♦ مراقبة التكاليف وإدارة الأخطار

يوفر الذكاء الاصطناعي استراتيجيات فاعلة لإدارة الموارد وإدارة الأخطار باستخدام نماذج التحكم في التكاليف ونماذج تقييم الأخطار. وبالتنبؤ وتقييم التكاليف والأخطار أثناء عملية الاستكشاف، يتيح الذكاء الاصطناعي صياغة تدابير الرقابة والإدارة المناسبة، مما يؤدي إلى خفض التكاليف، وتخفيف الأخطار، مع تحسين كفاءة إدارة الموارد.

• تقييم الأخطار وإدارتها

♦ تحليل البيانات والتعرف على الأنماط

يلعب الذكاء الاصطناعي (AI) دوراً حيوياً في التحليل والتعرف على الأنماط الخاصة بالكميات الهائلة من البيانات الجيولوجية التاريخية، وبيانات المراقبة في الوقت الفعلي. ومن الاستفادة من التعلم الآلي المتقدم وخوارزميات التعلم العميق، يمكن للذكاء الاصطناعي إنشاء نماذج للتنبؤ باحتمالية حدوث الأخطار الجيولوجية والمدى المكاني لها.

♦ تقييم الأخطار البيئية

يستخدم الذكاء الاصطناعي تقنيات تحليل البيانات والنمذجة لتقييم الأخطار البيئية المرتبطة بأنشطة الاستكشاف الجيولوجي. ومن التحليل الشامل والدقيق للخصائص الجيولوجية، والحساسية البيئية، وبيانات المراقبة، يتيح الذكاء الاصطناعي إجراء تقييم دقيق للأخطار البيئية وتأثيراتها المحتملة، وبالتالي توفير أساس علمي لحماية البيئة والإدارة الفاعلة للأخطار.

♦ الإنذار المبكر وإدارة الطوارئ

وبمساعدة النماذج التنبؤية وبيانات المراقبة في الوقت الفعلي، يسهل الذكاء الاصطناعي الإنذار المبكر والإدارة الفاعلة للأخطار الجيولوجية. وبالمراقبة المستمرة للأحداث الجيولوجية والتنبؤ بها، يمكن للذكاء الاصطناعي اكتشاف الظروف غير الطبيعية فوراً، وإطلاق أنظمة إنذار مبكر مناسبة واستراتيجيات الاستجابة السريعة للطوارئ، مما يضمن سلامة واستدامة عمليات الاستكشاف.

♦ دعم القرار والتحسين

يقدم الذكاء الاصطناعي دعماً قيماً في اتخاذ القرارات لتقييم الأخطار وإدارتها. من التحليل الشامل، والمحاكاة لسيناريوهات القرار المختلفة، يوفر الذكاء الاصطناعي لصانعي القرار رؤى مهمة حول الأخطار، مما يمكنهم من تحسين القرارات وتخفيف الأخطار المحتملة بشكل فاعل.

♦ مراقبة البيانات والتغذية الراجعة

يتيح الذكاء الاصطناعي المراقبة المستمرة وتقييم الأخطار في الوقت الفعلي أثناء أنشطة الاستكشاف، من خلال التكامل مع أجهزة الاستشعار وأجهزة المراقبة. من خلال جمع البيانات وتحليلها بشكل مستمر، يمكن للذكاء الاصطناعي اكتشاف وتفسير المعلومات الجيولوجية ذات الصلة، مما يسهل ردود الفعل في الوقت المناسب وتدابير الإدارة لضمان سلامة وكفاءة عمليات الاستكشاف.

• تنمية الموارد الذكية

♦ تحليل البيانات المتكاملة

يلعب الذكاء الاصطناعي دوراً حاسماً في توفير دعم شامل لاتخاذ القرار لتنمية الموارد من التحليل المتكامل للبيانات الجيولوجية والمعايير الهندسية والعوامل الاقتصادية. من خلال الاستفادة من التعلم الآلي المتقدم وخوارزميات التعلم العميق، يمكن للذكاء الاصطناعي تحديد الارتباطات والاتجاهات ذات المغزى داخل البيانات، مما يمكن صناع القرار من الحصول على رؤى حول خصائص الموارد وأنماط التوزيع والإمكانات المتوفرة.

♦ صياغة استراتيجيات التنمية المثلى

يساعد الذكاء الاصطناعي في صياغة الاستراتيجيات المثلى لتنمية الموارد بالنظر في عوامل متعددة. ومن الاستفادة من نماذج التحسين المتطورة والخوارزميات الذكية، يأخذ الذكاء الاصطناعي في الاعتبار الظروف الجيولوجية والتقنيات الهندسية والفوائد الاقتصادية والعوامل الأخرى ذات الصلة لتحديد المسار الأكثر فاعلية لتنمية الموارد وطرق الاستخراج وتوقيتها. وهذا يؤدي إلى تعزيز كفاءة تنمية الموارد وتحسين النتائج الاقتصادية.

♦ التنبؤ والمحاكاة

يستخدم الذكاء الاصطناعي نماذج التنبؤ، وتقنيات المحاكاة للتنبؤ بالنتائج والأخطار المرتبطة بعمليات تنمية الموارد. ومن تحليل البيانات التاريخية والمعايير ذات

الصلة، إلى جانب قدرات الذكاء الاصطناعي للتعلم، يمكن إجراء تنبؤات دقيقة فيما يتعلق بإنتاجية الموارد وجودتها وتأثيرات البيئة المحتملة. تعد هذه المعلومات بمنزلة إرشادات قيمة لاتخاذ القرارات المتعلقة بتنمية الموارد والتخطيط الاستراتيجي.

♦ تعزيز كفاءة استخدام الموارد

يلعب الذكاء الاصطناعي دوراً حيوياً في تحسين كفاءة استخدام الموارد وذلك من تطبيق الخوارزميات الذكية ونماذج التحسين. ومن تحليل بيانات الاستكشاف والخصائص الجيولوجية والعوامل الاقتصادية، يساعد الذكاء الاصطناعي في تحسين خطط وعمليات تنمية الموارد. ويشمل ذلك تقليل هدر الموارد، وزيادة كفاءة استخدامها إلى الحد الأقصى، وفي النهاية تقليل تكاليف التطوير الإجمالية.

♦ دعم القرار الذكي

يوفر الذكاء الاصطناعي دعماً ذكياً لاتخاذ القرار لتنمية الموارد، وتمكين صناع القرار بالمعلومات المهمة. ومن تحليل الفوائد والأخطار والجدوى لسيناريوهات القرار المختلفة، يقدم الذكاء الاصطناعي لصانعي القرار الرؤى والإرشادات اللازمة لاتخاذ قرارات مستتيرة. ويساعد ذلك في صياغة استراتيجيات فاعلة لتنمية الموارد، ويضمن استخدام الموارد بطريقة مستدامة وفاعلة.

• تبادل المعرفة والتعاون

♦ منصة البيانات والمشاركة

يمكن الذكاء الاصطناعي من إنشاء منصات بيانات ذكية تدمج بيانات الاستكشاف الجيولوجي ونتائج الأبحاث من مختلف المناطق والمنظمات. ومن تبادل البيانات والوصول المفتوح، فإنه يسهل تبادل ونشر مصادر البيانات المتنوعة، مما يوفر مصدر معلومات شامل ومثري لمجال الاستكشاف الجيولوجي.

♦ إدارة المعرفة والمعالجة الذكية

يمكن لتطبيق الذكاء الاصطناعي في إدارة المعرفة ومعالجة البيانات الذكية المساعدة في تنظيم وتحليل وتعزيز معرفة وتقنيات الاستكشاف الجيولوجي. ومن خلال إنشاء مستودعات للمعرفة وأنظمة الخبراء، من بين أدوات ذكية أخرى، فإنها تحول المعرفة المهنية في مجال الاستكشاف الجيولوجي إلى موارد قابلة للتنفيذ، وتعمل على تسريع نشر نتائج البحث العلمي وتطبيقها.

♦ التعاون والتواصل عبر الإقليمي

يسهل الذكاء الاصطناعي التعاون والتواصل عبر الإقليمي في مجال الاستكشاف الجيولوجي من خلال منصات البيانات الذكية وآليات الاتصال. يمكن للمناطق والمنظمات المختلفة تعزيز التعاون والتواصل بتبادل البيانات ونتائج البحوث والخبرات، ومعالجة التحديات بشكل جماعي في الاستكشاف الجيولوجي ودفع تنمية الصناعة.

♦ تبادل الخبرات والتدريب التعاوني

يساهم الذكاء الاصطناعي في تعزيز تبادل الخبرات والتدريب التعاوني. ومن خلال إنشاء منصات تعليمية ذكية وآليات تدريب، توفر موارد تعليمية للتقنيات والمعرفة ذات الصلة في الاستكشاف الجيولوجي. علاوة على ذلك، فهو يسهل تعاون المواهب وتبادلها بين المناطق والمنظمات المختلفة، مما يعزز المهارات المهنية والقدرات التقنية جماعياً.

♦ الابتكار والتعاون البحثي

يعزز الذكاء الاصطناعي الابتكار والتعاون البحثي في مجال الاستكشاف الجيولوجي. فمن التحليل الذكي للبيانات وبناء النماذج، يعمل الذكاء الاصطناعي على تسريع البحث وتطبيق التقنيات والنتائج المبتكرة. يمكن للمناطق والمنظمات المختلفة التعاون في المشاريع البحثية والمشاركة في التبادلات الفنية، والدفع المشترك للابتكار والتقدم في تقنيات الاستكشاف الجيولوجي، (Xia & Feng, 2023).

استخدام الذكاء الاصطناعي في معالجة المعادن واستكشافها

يتعامل الذكاء الاصطناعي بشكل فاعل مع البيانات الجيولوجية واسعة النطاق باستخدام التعلم الآلي المتقدم وخوارزميات التعلم العميق لاستخراج المعلومات المهمة، وتحديد السمات الجيولوجية، والتنبؤ بالبنيات الموجودة تحت الأرض وتوزيع الموارد.

لدى أتمتة عمليات التنبؤ، يعمل الذكاء الاصطناعي على تحسين معالجة البيانات، وإنشاء نماذج جيولوجية دقيقة، وصياغة استراتيجيات تنبؤ فاعلة. كما أنه يعزز إدارة الموارد باستخدام خوارزميات ذكية ونماذج التحسين لتحسين تخصيص الموارد، بما في ذلك مجالات الاستكشاف والأساليب وكفاءة استخدام الموارد. يسهل الذكاء الاصطناعي تقييم الأخطار وإدارتها من تحليل البيانات التاريخية، وفي الوقت الفعلي، مما يتيح التنبؤ بالأخطار الجيولوجية وتقييم الأخطار البيئية، وبالتالي إطلاق التحذيرات وتدابير الطوارئ في الوقت المناسب.

علاوة على ذلك، يدعم الذكاء الاصطناعي التطوير الذكي للموارد بالتحليل الشامل للبيانات الجيولوجية والمعايير الهندسية والعوامل الاقتصادية لتوجيه عملية صنع القرار، وتحسين استغلال الموارد. يوفر الذكاء الاصطناعي (AI) طريقاً لاستخراج المعادن بكفاءة وفاعلية من حيث التكلفة. يهدف الذكاء الاصطناعي إلى تطوير أنظمة تتعلم وتفكر بشكل مشابه للبشر، وتستخدم الخبرة لحل المشكلات، وأداء المهام المنطقية من خلال مقارنة البيانات ومقارنتها. يتغلغل الذكاء الاصطناعي تدريجياً في صناعة التعدين، ويؤثر على كل شيء بدءاً من إدارة سير العمل وحتى التنبؤ بالتوضعات المعدنية. تواجه صناعة التعدين العديد من التحديات، بما في ذلك انخفاض درجات الخام، وارتفاع التكاليف، واللوائح البيئية الصارمة، وأخطار السلامة. وللتغلب على هذه التحديات، يجب على الصناعة أن تتبنى تقنيات مبتكرة تعزز الكفاءة والإنتاجية والجودة والاستدامة.

ومن بين هذه التقنيات، يبرز الذكاء الاصطناعي منافسًا واعدًا، حيث يتيح اتخاذ القرارات المستندة إلى البيانات، والأتمتة، والتحسين عبر مختلف جوانب عمليات التعدين. سيقدم هذا التقرير تطبيق الذكاء الاصطناعي في استكشاف المعادن ومعالجتها، ويناقد فوائدها المحتملة لصناعة التعدين.

• كيف يتم دمج الذكاء الاصطناعي في التعدين لمعالجة المعادن واستكشافها؟

♦ الذكاء الاصطناعي وتحليلات البيانات: تحويل صناعة التعدين

يعمل الذكاء الاصطناعي (AI) وتحليلات البيانات على إحداث تحول في صناعة التعدين من خلال تمكين استكشاف المعادن ومعالجتها بشكل أسرع وأكثر دقة. يمكن أن يساعد الذكاء الاصطناعي وتحليلات البيانات في تحديد المناطق ذات إمكانات التمعدن العالية بطريقة سريعة وآمنة، مما يقلل من تكاليف الاستكشاف والوقت. يمكن لخوارزميات الذكاء الاصطناعي، مثل الشبكات العصبية العميقة، تعزيز التعرف على الصور والكلام، وتحسين جودة وكمية عملية استخراج الخام. يمكن لتقنية الرؤية المعززة بالذكاء الاصطناعي أيضًا أتمتة تحديد وتصنيف المعادن من بيانات الحفر وعينات الصخور، مما يوفر الوقت والجهد مقارنة بالتحليل اليدوي.

♦ تطبيقات الذكاء الاصطناعي في استخراج المعادن ومعالجتها

كما يتم استخدام الذكاء الاصطناعي لفرز النفايات المعدنية والتخلص منها، وخاصة عند استخراج الماس. ومن الجمع بين بيانات أجهزة الاستشعار والأشعة السينية، يمكن لخوارزميات الذكاء الاصطناعي استعادة أكثر من 96% من وزن جميع قطع الماس التي يزيد مقاسها عن 1 مم، مما يزيد من كفاءة وربحية عملية استرداد الماس. علاوة على ذلك، يمكن للذكاء الاصطناعي تحسين عملية تقليل حجم الخامات، وهو أمر ضروري للتوزيع الموحد للمعادن. يمكن لأجهزة الاستشعار المجهزة بالذكاء الاصطناعي مراقبة وضبط حجم الصخور التي تدخل الطاحونة، وتنقل على الحزام الناقل، مما يمنع الأعطال ويحسن الأداء.

♦ التحول الرقمي: الاستفادة من التكنولوجيا والبيانات للتعدين

يمكن أن تستفيد صناعة التعدين من التحول الرقمي، الذي يتضمن استخدام التكنولوجيا والمبادرات لتقليل وقت الإنتاج وتكلفته، وزيادة الإنتاجية والعائد، وتلبية المتطلبات التنظيمية. يمكن أن يستلزم التحول الرقمي تحديث أو تعديل مصانع ومعدات التعدين الحالية، أو إعادة هندسة العمليات والمنشآت لإنشاء عملية متماسكة ومربحة.

تعد تحليلات البيانات عنصراً أساسياً في التحول الرقمي، حيث يمكنها تقديم نظرة عامة شاملة عن حالة أعمال الشركة في أي لحظة. يمكن أن تساعد أتمتة العمليات الروبوتية (RPA) في استخراج البيانات وتحميلها والتحقق من صحتها وتنسيقها وحسابها، مما يزيد من السرعة والدقة مقارنة بالمشغلين البشريين. يمكن أن تساعد تقنية أتمتة العمليات الروبوتية أيضاً في تقدير احتياطات الخام والتحقق من صحتها، وتقارير الإنتاج والتسوية، وتخطيط الصيانة. يمكن للوحات المعلومات الذكية دمج هذه البيانات وتصورها، مما يوفر رؤى حول مجالات الأداء وتحسينها في المنجم، بالإضافة إلى الجدول الزمني للمعالجة بالكامل.

♦ الأتمتة الذكية: تعزيز السلامة في قطاع التعدين

جانب آخر من التحول الرقمي هو الأتمتة الذكية، والتي يمكن أن تعزز السلامة في قطاع التعدين. تشكل صناعة التعدين العديد من الأخطار الجسدية على العاملين في مجال الاستخراج؛ يمكن للأتمتة أن تقلل من هذه الأخطار باستخدام تكنولوجيا الاستشعار والحاسوب لإنشاء بيئات أكثر أماناً.

على سبيل المثال، قامت منظمة CSIRO في أستراليا بتطوير نظام توجيهه عن بعد للتعدين ذي الجدران الطويلة، يستخدم أجهزة استشعار ومعالجة في الوقت الحقيقي لتوجيه المعدات، وذلك برسم موقعها في ثلاثة أبعاد.

تسمح هذه التقنية لعمال المناجم بالوصول إلى مواقع أعمق وأبعد دون تعريضهم لمواقف خطيرة. كما أنها تمكن المشغلين من تشغيل المعدات عن بعد، مما يزيد من الكفاءة والسلامة.

♦ منصة جديدة لاستكشاف المعادن تعتمد على الذكاء الاصطناعي والبيانات

♦ المنصة الجديدة

تدمج المنصة المعرفة من مجالات مختلفة مثل؛ الجيولوجيا وعلم المعادن والجيولوجيا الاقتصادية والجيوكيمياء والجيولوجيا البنائية والجيوفيزياء والاستشعار عن بعد وعلوم البيانات والذكاء الاصطناعي. توفر هذه التغطية الشاملة للتنقيب عن المعادن للمستخدمين معلومات معدنية فاعلة ودقيقة.

تمتد قاعدة معارف النظام الأساسي إلى مجالات متعددة، وتدعم معالجة البيانات وتحليلها ووضع نماذج لها. لا تؤدي هذه المعرفة إلى بناء قاعدة بيانات النظام فحسب، بل تعمل أيضاً على تحفيز تطوير التطبيقات، وتعزيز الابتكار المستمر.

تستخدم المنصة كلاً من أدوات البرمجيات والأجهزة، بما في ذلك نماذج الذكاء الاصطناعي التوليدية مثل **ChatGPT**، ونماذج التعلم العميق المتطورة، بالإضافة إلى الأجهزة والأدوات الجديدة مثل؛ الأنظمة الجوية بدون طيار، والمعدات الجيوفيزيائية.

تتبنى المنصة أربعة أنواع من النماذج: مفتوحة، وقائمة على المعرفة، وقائمة على البيانات، وقائمة على الذكاء الاصطناعي. تسمح هذه النماذج بإضافة سمات جديدة بشكل مرن بناءً على متطلبات ترقيات النموذج.

يتكون هيكل المنصة من ثلاثة عناصر أساسية: البحث والتطوير، والتطبيق (النماذج المعممة)، وتسويق المنتجات. ويضمن هذا الهيكل التطوير الشامل للمنصة في مجالات البحث والتطبيق والأعمال.

يعتمد منطق النظام الأساسي على التفاعل بين المعرفة بالمجال والأدوات وقدرات التسويق القائمة على الطلب. كما تعمل المعرفة بالمجال أساساً ومحركاً يدعم الاستخدام الفاعل للأدوات. تعمل الأدوات جسوراً ونوافذ، حيث تربط المعرفة بقدرات التسويق القائمة على الطلب. إن قدرات التسويق القائمة على الطلب هي هدف المنصة وقوتها الدافعة، مما يعزز التنمية المستدامة بتلبية احتياجات السوق.

وفي الختام، قامت هذه المنصة، عن طريق الاستخدام المتكامل لعلوم الأرض والذكاء الاصطناعي، ببناء منصة شاملة وفاعلة ودقيقة لاستكشاف المعادن. يشكل تنسيق المعرفة والأدوات والنماذج والبنية تكاملاً عضوياً للبحث والتطبيق والأعمال. يهدف مقترح العمل هذا، إلى توفير استراتيجيات وخطة واضحتين للترويج للمنصة وتسويقها تجارياً.

♦ التكنولوجيا الرئيسة للمنصة الجديدة

♦ إحداث ثورة في استكشاف المعادن باستخدام البيانات الضخمة والذكاء الاصطناعي

يمكن أن يحدث هذا الحل ثورة في استكشاف المعادن بتسخير قوة تحليلات البيانات الضخمة والتعلم الآلي. حيث تستخدم تقنيات متقدمة لاستخراج البيانات وخوارزميات الذكاء الاصطناعي لتحليل مجموعات البيانات المعقدة من مصادر متنوعة، بما في ذلك؛ البيانات الجيولوجية، والجيوكيميائية، والجيوفيزيائية، والاستشعار عن بعد، وبيانات الحفر. يوفر هذا النهج الشامل معلومات تعدينية فاعلة ودقيقة للمستخدمين.

فوائد الحل المقترح متعددة. فهو يساعد على؛ تحديد مناطق الاستكشاف المحتملة وتحديد أولوياتها، واكتشاف التوضعات المعدنية وتوصيفها، وتقدير الموارد والاحتياطيات المعدنية، وتحسين استراتيجيات الاستكشاف، وتقليل أخطار الاستكشاف والشكوك.

يعتمد الحل المقترح على أحدث التطورات في تحليلات البيانات الضخمة والتعلم الآلي. ويدعمه فريق من المحترفين المتمرسين الذين يقدمون الخبرة والحلول المخصصة لتتوافق مع أهداف المؤسسة الفريدة.

وحيث أن حجمًا واحدًا لا يناسب الجميع، لذا فإن حلول المقترح قابلة للتكيف لتلبية الاحتياجات والأهداف المميزة لمشاريع الاستكشاف الخاصة. كما يمكن تقديم تدريب شامل وخدمات دعم مستمرة، للمساعدة على تحقيق أقصى قدر من إمكانيات الحل الذي تقدمه.

لقد أحدث الحل المقترح تأثيرًا كبيرًا فعلاً، باستخدام النمذجة الجيولوجية الناجحة في منطقة ساوثرن كروس، حيث تم تحديد مناطق الاستكشاف ذات الأولوية، وتقليل الشكوك وتكاليف الاستكشاف كثيرًا.

♦ اكتشف المزيد باستخدام الاستشعار عن بعد لاستكشاف المعادن

يُحدث الحل المقترح ثورة في استكشاف المعادن عن طريق تسخير قوة تحليل البيانات الضخمة والتعلم الآلي. الاستشعار عن بعد هو طريقة تقوم بجمع وتحليل البيانات من مسافة بعيدة، باستخدام أجهزة الاستشعار الموجودة على منصات مختلفة مثل الأقمار الصناعية أو الطائرات أو الطائرات بدون طيار أو المنصات الأرضية. توفر هذه الطريقة رؤية شاملة للجيولوجيا الإقليمية، والبنائية، والتغيير، والتمعدن، والغطاء النباتي، والآثار البيئية والاجتماعية لأنشطة التعدين.

يمكن لفريق الخبراء في الاستشعار عن بعد والجيوفيزياء والجيولوجيا والتنقيب عن المعادن، المساعدة في اختيار أفضل مصادر بيانات الاستشعار عن بعد وطرقها للمشاريع المختلفة، ومعالجة وتفسير بيانات الاستشعار عن بعد باستخدام تقنيات متقدمة، وإنشاء خرائط ونماذج وتقارير توضح ذلك. فضلاً عن تحديد مواقع التوضعات المعدنية المحتملة وأنواعها ودرجاتها، بالإضافة إلى الأخطار والفرص المرتبطة بها.

وهناك سجل حافل في تقديم نتائج عالية الجودة من خلال التقنيات الرائدة، والممارسات الفضلى في مجال الاستشعار عن بعد واستكشاف المعادن. يمكن لهذه المساعدة تقليل تكاليف الاستكشاف، وزيادة معدلات الاكتشاف وتحسين استراتيجياته. ومثال على ذلك، تم تحديد عرق من الرصاص والزنك الطبقي مع احتياطي من الموارد المعدنية يتجاوز **770,000** طن من الرصاص والزنك في منطقة غرب كولون/الصين. وتتميز هذه المنطقة بجبالها الشاهقة وتشققاتها العميق، مع تضاريس منتظمة، وشذوذ جيوكيميائي للرصاص.

تكشف بيانات الاستشعار عن بعد أيضاً عن سمات كبيرة لرصد بقع الحديد ثلاثي التكافؤ، وتغيير الهيدروكسيل، والتي تم تأكيدها بالتحقق الميداني.

♦ اكتشاف أسرار الأرض باستخدام التصوير المقطعي للضوء المحيطية

هل أنت مستعد لكشف أسرار القشرة الأرضية الضحلة؟ هل ترغب في رسم خريطة للأجسام الخام والصدوع والموارد المائية وخزانات الطاقة الحرارية الأرضية بدقة وتفصيل؟

يقف التصوير المقطعي للضوء المحيطية في طليعة تقنيات الاستكشاف، وذلك باستخدام الضوء الزلزالية الطبيعية والناجمة عن النشاط البشري مصدرا للتوير تحت السطح. ومن الارتباط المتبادل لإشارات الضوء الملتقطة بواسطة محطات متعددة، يمكن استخراج الموجات السطحية المنتشرة بين هذه المحطات.

من التحليل التفصيلي لانتشار الموجات السطحية، يتم استنتاج نماذج للسرعة القريبة من السطح، والكشف عن الاختلافات في الخصائص الفيزيائية مثل؛ كثافة ومسامية ومرونة الصخور.

تمكّن هذه التقنية من الحصول على صور تفصيلية للبنية القشرية الضحلة التي يصل عمقها إلى **3 كيلومترات**، مما يوفر دقة مكانية تصل إلى عشرات الأمتار.

تعمل هذه الصور أدوات قوية لتحديد موقع التوضعات المعدنية المحتملة، والصدوع وموارد المياه، وخزانات الطاقة الحرارية الأرضية. بالإضافة إلى ذلك، فإنها تساعد في تقييم الأخطار والفرص المرتبطة بها. تقلل التقنية من متطلبات الحفر، وتحسن استراتيجيات الاستكشاف، وتسهل المراقبة المستمرة تحت السطح.

♦ ما هي المزايا التي يقدمها الذكاء الاصطناعي؟

تواجه شركات التعدين تحديات كبيرة في تحديد موقع واستخراج المعادن ذات الجدوى الاقتصادية من التوضعات العميقة أو منخفضة الدرجة. ويمكن أن يساعد الذكاء الاصطناعي في بناء نماذج أكثر دقة للتنبؤ بنوع المعادن وموقعها، مما يوفر الوقت والمال. يمكن للذكاء الاصطناعي أيضاً تعزيز سلامة عمال المناجم في الخطوط الأمامية من خلال تمكين اتخاذ القرار سريعاً أثناء الاستكشاف التعديني. وباستخدام البيانات والتحليلات في الوقت الفعلي، يمكن للذكاء الاصطناعي اكتشاف المشكلات العملية ومنع الحوادث والإصابات. علاوة على ذلك، يمكن للذكاء الاصطناعي أتمتة وتبسيط عملية معالجة البيانات التي لا تزال تتم يدوياً في العديد من عمليات التعدين. يمكن أن يوفر الذكاء الاصطناعي نتائج سريعة وذلك بجمع البيانات وتحليلها في الموقع، مما يقلل الأخطاء، ويحسن الكفاءة.

ووفقاً لبعض التقديرات، يمكن للشركات توفير ما يصل إلى 80% من مصاريفها باستخدام الذكاء الاصطناعي والبيانات الضخمة لتحديد مناجم جديدة، مقارنة بالطرق التقليدية. علاوة على ذلك، يمكن استخدام البيانات التي تم الحصول عليها في جهود إعادة التأهيل اللاحقة التي تعمل على استعادة البيئة الطبيعية للمنطقة.

♦ تحديات معالجة المعادن واستكشافها في مجال التعدين

ومع استفاد احتياطات المعادن القريبة من السطح في جميع أنحاء العالم، يتعين على شركات التعدين أن تستثمر المزيد للوصول إلى التوضعات الأقل جودة.

وقد أصبح تعدين هذه التوضعات ومعالجتها أكثر تعقيداً وتكلفةً، لأنها تتطلب تقنيات ومعدات أكثر تقدماً. هناك أيضاً طلب متزايد على التعدين الأخلاقي الذي يقلل من التأثير البيئي والمادي لسلسلة العملية بأكملها. التحدي الآخر الذي تواجهه صناعة التعدين هو الحجم المتزايد للبيانات التي تحتاج إلى إدارة جيدة لاستخدامها. يمكن استخدام 10% فقط من البيانات للتعامل مع التباين وتحسين العمليات، لأن البيانات غير مرتبطة بسلسلة القيمة. كما أن استخدام الذكاء الاصطناعي في صناعات التعدين محدود أيضاً بالوقت الذي يستغرقه التنفيذ. فهي لا تحقق أرباحاً فورية للمساهمين، وتتطلب فهماً جيداً وتكاملاً لأنظمة الذكاء الاصطناعي مع المنصات المختلفة.

◆ مستقبل الأتمتة الذكية في التعدين

تشهد صناعة التعدين تحولاً رقمياً سريعاً، وقد أدى التقدم في الذكاء الاصطناعي إلى تحسينات في أتمتة العمليات واستخدام الأجهزة الآلية في مواقع التعدين. يوفر الذكاء الاصطناعي الفرصة لتحسين العمليات وزيادة الكفاءة، ولكنه ليس حلاً عالمياً، فهو يعتمد على الاحتياجات والظروف المحددة لكل شركة ومنجم. وللتغلب على هذه العوائق، من المهم توضيح كيف يمكن للتدقيق الداخلي تحسين العمليات الشاملة بطريقة موحدة وقابلة للقياس، وكيف يمكنه تعزيز السلامة في الوقت نفسه.

◆ التوقعات المستقبلية

مع انخفاض المعروض من الخامات المعدنية الجديدة، تبحث شركات التعدين عن طرق أكثر ابتكاراً وفاعلية لمعالجة أنواع البيانات المختلفة في كل مرحلة من مراحل صناعتها. أصبح الذكاء الاصطناعي الآن معروفاً على نطاق واسع أنه أداة لاستخراج الموارد المعدنية بكفاءة وفاعلية من حيث التكلفة. وبحلول عام 2035م، من المتوقع أن تدخل صناعة التعدين حقبة جديدة من التعدين الذكي، حيث سيتم استخدام الذكاء الاصطناعي لتحقيق مستويات جديدة من الأداء، مما يوفر على منتجي المواد الخام المعدنية ما بين 290 مليار دولار إلى 390 مليار دولار سنوياً، (Wang, 2024).

دور الذكاء الاصطناعي في استكشاف النفط والغاز

يُعد التنقيب عن النفط والغاز عمليةً مكلفةً جداً، مما يدفع الشركات إلى البحث عن طرق أكثر ذكاءً لاستخدام مواردها. ويرجع ذلك إلى ارتفاع تكلفة الآلات المتخصصة التي يديرها متخصصون ماهرون، وإلى صعوبة الحصول على تصاريح المسح الزلزالي، والتداعيات البيئية لآبار الاختبار.

ويقدم الذكاء الاصطناعي في مجال التنقيب عن النفط والغاز علاجات أساسية للمشكلات الرئيسية التي تواجه الصناعة. وتشمل هذه المشكلات كل شيء، ابتداءً من الاستكشاف والنمو، إلى الإنتاج والتوزيع، وعمليات التكسير، والتسويق، والمبيعات.

ومع توقع وصول الذكاء الاصطناعي العالمي في سوق النفط والغاز إلى 7.99 مليار دولار بحلول عام 2031م، ونموه بمعدل 13.5 % من عام 2022م إلى عام 2031م، تصبح أهمية اعتماد الذكاء الاصطناعي جلية واضحة.

كيف يتم استخدام الذكاء الاصطناعي في استكشاف النفط والغاز؟

باستخدام خوارزميات التعلم الآلي، يستطيع الذكاء الاصطناعي تحليل البيانات الجيولوجية الشاملة للتنبؤ باحتمالية اكتشاف مكامن النفط والغاز. غالباً ما يعتمد التنقيب التقليدي عن النفط والغاز على العمل الميداني البشري، الأمر الذي ينطوي على أخطار حدوث أخطاء. يمكن أن تؤدي الأخطاء، مثل حفر الآبار غير المنتجة، إلى خسائر مالية كبيرة تتراوح بين 5 - 20 مليون دولار لكل موقع.

لقد تحولت صناعة النفط إلى الأتمتة لمواجهة هذه التحديات لتعزيز الدقة والكفاءة. تعد أتمتة تفسير البيانات الزلزالية واحدة من أهم التطورات في هذا الصدد. وقد أدى هذا التحول إلى تقليل احتمالية حدوث أخطاء بشرية كثيرة، وتسريع عملية الاستكشاف.

يستخدم معهد واديا لجيولوجيا الهيمالايا (WIHG) الذكاء الاصطناعي لمعالجة بيانات الموجات الزلزالية، سواء كانت ناجمة عن تفجيرات أو أحداث طبيعية. يعمل هذا النهج المبتكر على تسريع اكتشاف الاحتياطيات الهيدروكربونية القيّمة، كالنفط والغاز الطبيعي، بكفاءة أكبر. علاوة على ذلك، فتحت تكنولوجيا الروبوتات المتطورة آفاقاً جديدة في الاستكشاف، مما يجعل الوصول حتى إلى البيئات النائية وغير المضيفة متاحاً.

على سبيل المثال، قدمت شركة إكسون موبيل روبوتات تعمل بالذكاء الاصطناعي، قادرة على تحليل بيانات قاع البحر حتى عمق 6000 متر. وهذا لا يقلل من أخطار الاستكشاف فحسب، بل يقلل أيضاً من الضرر الذي يلحق بالنظم البيئية البحرية.

بالإضافة إلى ذلك، تلتقط الطائرات بدون طيار المتقدمة، والمجهزة بأجهزة استشعار دقيقة، صوراً سيزمية عالية الجودة، في حين تستخرج خوارزميات معالجة الصور المتطورة معلومات مهمة، مما يوفر رؤية دقيقة للتكوينات الجيولوجية تحت الأرض.

تسخير البيانات الضخمة مع الذكاء الاصطناعي في استكشاف النفط والغاز

يعتمد الذكاء الاصطناعي في صناعة النفط والغاز على خوارزميات متقدمة، ويستخدم التعلم العميق في إجراء تنبؤات بناءً على أنماط البيانات التاريخية. تحتاج أنظمة الذكاء الاصطناعي إلى تدريب مكثف باستخدام مجموعات البيانات الكبيرة، للحصول على رؤية من هذه البيانات. وتستخدم شركات النفط مجموعات البيانات هذه لاتخاذ قرارات إدارة الموارد، مع إدراك الدور الحيوي للنفط والغاز في تلبية الطلب العالمي على الطاقة.

ومن الجدير بالذكر أن الوكالات الحكومية مثل؛ هيئة النفط والغاز في المملكة المتحدة (OGA)، تقدم مجموعات بيانات هائلة بفضل مستودع البيانات الوطني

(NDR)، مع كمية مذهلة تبلغ 130 تيرابايت من المعلومات المتاحة للعامة. لتوضيح السياق، يمكن مقارنة مجلد من هذه البيانات بالمواد الموجودة في أفلام عالية الوضوح لمدة ثماني سنوات. إلى جانب الدراسات الاستقصائية التقليدية التي يجريها باحثون من القطاعين العام والخاص، تستفيد الشركات من البيانات التي تولدها أجهزة الاستشعار.

تستخدم العديد من أصول استخراج النفط والغاز، والتي غالبًا ما تقع في مواقع نائية أو تحت الماء، أجهزة استشعار للتغلب على صعوبة الوصول إليها. بالإضافة إلى ذلك، قد تقوم الشركات بتنفيذ مبادرات الاستشعار، مثل تكنولوجيا التوائم الرقمي أو برامج نمذجة المصافي. ولتوضيح ذلك، توفر التوائم الرقمية المعتمدة على الذكاء الاصطناعي، مثل تلك المستخدمة في مصافي التكرير، رؤية ومرونة في الوقت الحقيقي، مما يعزز الكفاءة التشغيلية كثيرًا. وبالمثل، توفر برامج نمذجة المصافي رؤى قيمة حول العمليات المعقدة داخل المصافي، مما يساعد في تحسين الإنتاج واتخاذ القرار.

توفر جميع مصادر البيانات هذه المادة الخام الأساسية لتدريب أنظمة الذكاء الاصطناعي في قطاع النفط والغاز.

ما هي مزايا الذكاء الاصطناعي في استكشاف النفط والغاز؟

يوفر الذكاء الاصطناعي العديد من المزايا في صناعة النفط والغاز، بما في ذلك تحديد الاحتياطيات المحتملة، وتقديم توقعات دقيقة للاستخراج. ومع انخفاض احتياطيات الوقود الأحفوري التي يسهل الوصول إليها، تدرك شركات الطاقة بشكل متزايد أهمية إتقان استخراج واستخدام المصادر الأكثر تعقيدًا.

بينما يتم التعمق في مزايا الذكاء الاصطناعي في استكشاف النفط والغاز، يتم التركيز على العديد من المجالات الرئيسية، منها:

♦ توصيف الخزان والنمذجة

إن فهم المكامن الجوفية أمر ضروري في التنقيب عن النفط والغاز. في هذه المهمة الحاسمة، تلعب تقنيات الذكاء الاصطناعي والتعلم الآلي دوراً مهماً. إنها تقوم بتحليل مجموعات البيانات الشاملة بدقة للكشف عن أنماط لا تقدر بثمن، بما في ذلك المعلومات الزلزالية، وسجلات الآبار، وبيانات الإنتاج. علاوة على ذلك، تستخدم هذه التقنيات نماذج تنبؤية تحاكي سلوك الخزان، وتساعد في تقدير الاحتياطي، وفي تحسين الإنتاج، وفي مهام تخفيف الأخطار.

♦ الحفر وتحسين الآبار

تقوم أنظمة الذكاء الاصطناعي باستمرار بالتحقيق في بيانات الحفر، واكتشاف الحالات الشاذة على الفور. يعمل هذا الكشف في الوقت الفعلي على تعزيز كفاءة الحفر، وتقليل وقت التوقف عن العمل، وتعزيز السلامة.

بالإضافة إلى ذلك، تلعب خوارزميات التعلم الآلي دوراً بارزاً عند تحليل بيانات الحفر التاريخية، لتوجيه اختيار المثقب الأمثل ومعلومات الحفر. يعمل هذا النهج التحليلي على تبسيط عملية صنع القرار، مما يؤدي إلى تحسين عمليات الحفر بشكل كبير، وتحسين كفاءة التكلفة الإجمالية.

♦ كفاءة الإنتاج

يتنبأ الذكاء الاصطناعي بدقة بأعطال المعدات، من تحليل بيانات المستشعر، ومن سجلات الصيانة. هذا النهج الاستباقي للصيانة يقلل بفاعلية كبيرة من وقت التوقف عن العمل والتكاليف، كل ذلك مع تعزيز السلامة العامة. بالتوازي، توفر الأنظمة القائمة على الذكاء الاصطناعي والتعلم الآلي رؤى في الوقت الفعلي في مجالات الإنتاج. تحدد هذه الأنظمة أوجه القصور التشغيلية بكفاءة من خلال تحليل البيانات ومراقبة المعدات، مما يعزز الأداء الميداني ويقلل التكلفة كثيراً.

♦ التأثير البيئي والاستدامة

تقوم خوارزميات تعلم الآلة بتحليل البيانات من أجهزة الاستشعار وصور الأقمار الصناعية، مما يتيح الكشف في الوقت المناسب عن التأثيرات البيئية مثل التسربات والانبعاثات. تسمح هذه القدرة بالتدخلات السريعة لتقليل الأضرار المحتملة.

علاوة على ذلك، تتفوق تقنيات الذكاء الاصطناعي والتعلم الآلي في عملية تحسين استهلاك الطاقة. ومن خلال القيام بذلك، فإنها تقلل فعلاً من آثار الكربون، مع تعزيز الكفاءة العامة في الوقت نفسه.

وتلعب هذه التقنيات دوراً أساسياً في تحديد الفرص المتاحة للحفاظ على الطاقة، وتوفير رؤى تنبؤية من تحليلات الطاقة، ودمج مصادر الطاقة المتجددة بسلسلة في الأنظمة الحالية.

ما هي تحديات الذكاء الاصطناعي في استكشاف النفط والغاز؟

كان تنفيذ الذكاء الاصطناعي في صناعة النفط والغاز بطيئاً مقارنة بالقطاعات الأخرى. ينبع هذا التأخير من النهج الحذر تجاه الاستثمار في التكنولوجيا الناشئة والقبول المتأخر للذكاء الاصطناعي في هذا المجال.

تشمل التحديات الرئيسية في تنفيذ الذكاء الاصطناعي في التنقيب عن النفط والغاز ما يلي:

♦ جودة البيانات وتكاملها

يواجه دمج الذكاء الاصطناعي في هذه الصناعة عقبة كبيرة بسبب اختلاف الجودة وتباين تنسيقات البيانات. تولد المصادر المتنوعة مثل؛ أجهزة الاستشعار والمعدات وعمليات الحفر كميات هائلة من البيانات التي يصعب دمجها وتحليلها.

♦ نقص المهارات

يتطلب الذكاء الاصطناعي خبرة في علوم البيانات والتعلم الآلي والترميز للتطوير والنشر الفاعل. ومع ذلك، فقد ركزت الصناعة تاريخياً على الهندسة وعلوم الأرض، مما أدى إلى ندرة الأفراد الأكفاء في المجالات ذات الصلة بالذكاء الاصطناعي.

♦ البنية التحتية التي عفا عليها الزمن

إن الأنظمة القديمة في العديد من شركات النفط والغاز غير متوافقة مع الذكاء الاصطناعي، مما يعوق تكامل واعتماد حلول الذكاء الاصطناعي الجديدة. إن التكاليف الكبيرة والوقت المرتبط بتحديث البنية التحتية القديمة يمكن أن يعيق تبني التقنيات المبتكرة.

♦ المخاوف التنظيمية والأخلاقية

تتشأ مشكلات أخلاقية وتنظيمية مع استخدام الذكاء الاصطناعي في هذا القطاع، لا سيما فيما يتعلق بخصوصية البيانات والتحيز والشفافية. يعد الالتزام باللوائح والمعايير الأخلاقية الحالية أمراً بالغ الأهمية لنشر الذكاء الاصطناعي بشكل مسؤول.

♦ مقاومة التغيير

تشكل نزعة المحافظة التقليدية في صناعة النفط والغاز تحدياً أمام اعتماد تقنيات وسير عمل جديدة. قد تنشأ معارضة التغيير من الموظفين أو العملاء أو الهيئات التنظيمية، مما يعيق التقدم. ويتطلب التغلب على هذه العقبات التعاون بين الجهات الفاعلة في الصناعة. يجب على الشركات تحسين جودة البيانات، وتدريب الموظفين، والشراكة مع خبراء التكنولوجيا والمنظمين لمعالجة الأخلاقيات واللوائح. إن احتضان الابتكار، وتعزيز ثقافة التغيير، يسمح لقطاع النفط والغاز بالاستفادة من المخزون الهائل من إمكانيات الذكاء الاصطناعي. ولحسن الحظ، فإن الجهود جارية فعلاً على قدم وساق لتشجيع العجلات، والاستفادة من كل قطرة من الذكاء الاصطناعي.

دور الذكاء الاصطناعي في التغلب على تحديات استكشاف النفط والغاز

مع تجاوز إنتاج الولايات المتحدة من النفط الخام **12.9** مليون برميل يوميًا في أواخر عام **2023م**، أصبحت الحاجة الملحة للابتكار في مجال الاستكشاف واضحة لا لبس فيها. ومع ذلك، لا تزال الأساليب التقليدية قائمة، وهي مثقلة بالتكاليف المفرطة، وتدفقات العمل كثيفة العمالة.

تعاني الجيوفيزياء الاستكشافية، وهي حيوية لصناعة النفط، من تكاليف عالية وعدم دقة النتائج. إن مجال الخطأ واسع، مما يؤدي إلى إهدار الموارد والوقت ورأس المال. وحتى التحليل البشري، على الرغم من أهميته، ليس محصنًا ضد الخطأ، مما يعرض نتائج الاستكشاف للخطر. وقد أقام قادة الصناعة مثل شركتي شل وبيكر هيوز شراكات استراتيجية مع الشركات العملاقة الراسخة مثل مايكروسوفت لمواجهة هذه التحديات بشكل مباشر. مهمتهم المشتركة؟ تطوير حلول الذكاء الاصطناعي المخصصة والمصممة لقطاع الطاقة.

وعلى نحو مماثل، خصصت شركات كبرى مثل شركة بريتيش بتروليوم فنتشرز **5** ملايين دولار لاستغلال الذكاء الاصطناعي لتحسين عمليات المصدر. ويؤكدون على دور الذكاء الاصطناعي في الاستكشاف، زاعمين أنه يقلل من وقت جمع البيانات، وتحليلها، ومحاكاتها بنسبة **90%** من خلال تحسين دورة الحياة. تعد هذه الاستثمارات مؤشرًا واضحًا على تحول الصناعة نحو أساليب الاستكشاف عالية الكفاءة، المعتمدة على البيانات.

• الذكاء الاصطناعي في استكشاف النفط والغاز: الوجبات السريعة الرئيسة

في عالم التنقيب عن النفط والغاز الذي يتطور باستمرار، يقترب اعتماد الذكاء الاصطناعي من الحصول على الذهب السائل. وقد أدت التكاليف المرتفعة للعمالة الماهرة، والتعقيدات المرتبطة بتأمين تصاريح المسح الزلزالي، والمخاوف البيئية المحيطة بالطرق التقليدية، أدت إلى تغذية التعطش لحلول أكثر ذكاءً.

لقد ورد أنّ مزايا الذكاء الاصطناعي في التنقيب عن النفط والغاز كبيرة جداً، وتغطي ما يلي:

- توصيف ونمذجة الخزان.
- الحفر وتحسين الآبار.
- كفاءة الإنتاج.
- التأثير البيئي والاستدامة.
- تقليل آثار الكربون، ودمج مصادر الطاقة المتجددة.

ومع ذلك، فإن احتضان الصناعة البطيء للتكنولوجيا الناشئة، وتعقيدات تكامل البيانات، ونقص المهارات، وبنية التحتية القديمة، والمخاوف التنظيمية والأخلاقية تشكل تحديات. بالإضافة إلى ذلك، هناك مقاومة للتغيير، ويتطلب التغلب على هذه العقبات التعاون والابتكار.

يستثمر قادة الصناعة فعلاً في الذكاء الاصطناعي لتعزيز كفاءة الاستكشاف وخفض التكاليف. وتشير مبادراتهم إلى التحول نحو التقنيات المتجذرة في تحليل البيانات، والتي تُعد ضرورية في صناعة تحظى فيها الدقة والكفاءة بأهمية قصوى. وبناءً على هذا الزخم، سيلعب الذكاء الاصطناعي دوراً مركزياً في تشكيل مستقبله مع استمرار صناعة النفط والغاز في التراجع. (Sahota, 2023)

دور الذكاء الاصطناعي في استكشاف المياه الجوفية

نظراً لصعوبة قياس المياه الجوفية على نطاق واسع، فإن الخوارزميات القائمة على الذكاء الاصطناعي مفيدة في استخلاص المعلومات وجعل التنبؤات حاسمة لإدارة المياه الجوفية.

نجح تعليم الآلة في إنشاء خرائط لإدارة المياه الجوفية (Barzegar et al., 2018)، وتقييم أخطار التلوث بالنترات (Nolan et al., 2015; Sajedi-Hosseini et al., 2018) والتنبؤ بمستويات المياه الجوفية (Sahoo et al., 2017).

يمكن لنماذج تعليم الآلة، بما في ذلك الغابات العشوائية المحسنة SVM و RF و GA، تقييم إمكانات المياه الجوفية حسب المواقع (Naghibi et al., 2017). ولوحظ أن الترددات اللاسلكية تتفوق على التصنيف الشجري والانحدار (CART) في التنبؤ بتركيز النترات على نطاق واسع (Knoll et al., 2019).

تعد نماذج التعليم الآلي المجموعة بدائل عملية للنماذج التقليدية المتطورة لإدراك أنماط المياه الجوفية. فيما يتعلق بشبكات المياه الجوفية في المدينة، يمكن أن يساعد التعلم الآلي (آلة التعلم القصوى - ELM) (Sattar et al., 2019) في تقدير الأعطال المحتملة في الأنابيب الفردية لمنع الأحداث المأساوية المستقبلية.

♦ تقنيات الذكاء الاصطناعي لتقييم جودة المياه الجوفية

تعد كمية المياه العذبة العالية بالقدر الكافي والنوعية المناسبة من المتطلبات الأساسية لاستدامة حياة الإنسان وحضارته. والواقع أن النمو السكاني الهائل والإنجازات المعجزة في مجال العلوم والتكنولوجيا أدت إلى زيادة استخدام المياه الجوفية للأغراض المنزلية والصناعية والري عدة أضعاف في جميع أنحاء العالم على مدى العقود القليلة الماضية.

كما أثر التحضر السريع والاستغلال المفرط والتخلص غير العلمي من النفايات على إمكانية الوصول إلى المياه الجوفية وجودتها. وقد أدى النمو السكاني المفرط والتوسع الحضري السريع إلى استخدام المواد الكيميائية والمبيدات الحشرية للأغراض الزراعية، مما أدى في كثير من الأحيان إلى الترشيع والاختلاط بالمياه الجوفية.

ووفقاً لمنظمة الصحة العالمية، فإن المياه غير المناسبة أو الملوثة تسبب حوالي 80% من الأمراض التي تصيب الإنسان.

علاوة على ذلك، لا يمكن تحسين نوعية المياه الجوفية الملوثة أو إعادة إنشائها عن طريق منع التلوث من المصدر. ولذلك، فإن فهم وتحديد نوعية المياه أمر حتمي في دراسة الموارد المائية والهندسة البيئية.

تحدد نوعية المياه بشكل أساسي مدى قابلية استخدام المياه من المصدر من حيث طبيعة وتركيز الشوائب الموجودة في العينة. وكأثر مشترك للتدهور المستمر في نوعية المياه وكميتها، يواجه ما يقرب من مليار شخص في جميع أنحاء العالم نقصاً في إمدادات المياه الكافية والأمنة.

إن الطبيعة المتزايدة لهذه الإحصائيات تجعل من الضروري مراقبة جودة المياه من أجل إدارتها وإمداداتها بكفاءة.

الطريقة الأكثر فاعلية لتصنيف جودة المياه هي استخدام مؤشر جودة المياه (WQI). غالباً ما يتم تقدير جودة المياه بناءً على مؤشرات. إنها أداة تم استخدامها على نطاق واسع لتقييم أداء أساليب إدارة جودة المياه.

لقد تطور النهج والمنهجية المستخدمة لحساب وتفسير مؤشرات جودة المياه على مر السنين. تم استخدام القيم المقدرة لمؤشرات جودة المياه للإشارة إلى مدى ملاءمة عينات المياه للاستخدام اليومي. ويمكن استخدامها فعلاً في تنفيذ برامج إصلاح جودة المياه.

تشتمل متغيرات **WQI** على الطلب على الأكسجين البيولوجي (**BOD**)، ودرجة الحرارة، والأكسجين المذاب (**DO**)، وإجمالي المواد الصلبة العالقة (**TSSs**)، ونيتروجين الأمونيا (**AN**)، والطلب على الأكسجين الكيميائي (**COD**)، ودرجة الحموضة.

عادة ما يتم التنبؤ بمؤشرات جودة المياه الجوفية (**GQIs**) عن طريق قياس المتغيرات القياسية، مثل المغنيسيوم (**Mg²⁺**)، والكالسيوم (**Ca²⁺**)، والنترات (**NO⁻³**). إن القيمة التي يقدمها مؤشر الجودة العالمية كبيرة وافية لمساعدة صناع القرار. ومع ذلك، فإن تقدير مؤشر جودة الجودة ليس بهذه البساطة لأن حسابات المؤشر الفرعي تتم في معادلات مؤشر جودة الجودة نفسها.

تتوفر عدة طرق في الأدبيات العلمية لحساب مؤشر جودة المياه في جميع أنحاء العالم. ومنها على سبيل المثال؛ مؤشر جودة المياه التابع لمؤسسة الصرف الصحي الوطنية بالولايات المتحدة (**NSFWQI**)، ومؤشر جودة المياه في كولومبيا البريطانية (**BCWQI**)، ومؤشر جودة المياه الكندي (**CWQI**).

يهدف مؤشر جودة المياه إلى تحويل المعلومات المعقدة المتعلقة بجودة المياه إلى بيانات مباشرة يمكن للباحثين استخدامها بسهولة، ويمكن نقلها إلى الناس بشكل عام. في المقابل، يمكن أن تكون عملية الحساب في حالة بعض الأساليب المطبقة في العديد من البلدان، بما في ذلك الهند، معقدة جداً وتستغرق وقتاً طويلاً. ونتيجة لذلك، فإن العملية تتطوي دائماً على خطر اجتذاب حسابات خاطئة غير مقصودة.

وبالتالي، فإن القيود المفروضة على حسابات **WQI** هي كما يلي:

- ◆ تستغرق وقتاً طويلاً.
- ◆ عملية طويلة.
- ◆ عملية معقدة.
- ◆ يتم استخدام معادلات مختلفة لحسابات **WQI**.

وعليه، ستبقى هناك تناقضات، قد يكون واضحاً من المناقشة أعلاه أنه لا توجد طريقة قياسية متاحة لمؤشر جودة الجودة.

للتغلب على المشكلات المذكورة أعلاه، اقترح عدد قليل من العلماء نهجاً غير مادي يمكنه التنبؤ بنجاح بمؤشر جودة الجودة (WQI) باستخدام التعلم الآلي (ML) والذكاء الاصطناعي (AI). بعد التدريب المرضي، يمكن للنموذج القائم على الذكاء الاصطناعي إنتاج قيمة WQI على الفور بالتخلص من حسابات المؤشر الفرعي.

يتزايد الوعي بخوارزميات الذكاء الاصطناعي بسبب الفوائد التي تشمل الهياكل غير الخطية، والقدرة على حساب الاتجاهات المعقدة، والقدرة على إدارة مجموعات البيانات الضخمة التي تتكون من مقاييس بيانات مختلفة، وعدم الحساسية للبيانات الناقصة. وتعتمد القدرة على التنبؤ لخوارزميات ML-AI كثيراً على إجراءات ودقة جمع البيانات وتحليلها. لقد سمح التطور المستمر لقدرة الباحثين الحاسوبية، باستخدام ترتيبات متنوعة لنماذج التعلم الآلي والذكاء الاصطناعي.

تم تطبيق أساليب مختلفة مثل: الشبكات العصبية الاصطناعية (ANNs)، وأنظمة الاستدلال العصبي غامض التكيفية، وآلات ناقلات الدعم (SVMs) بشكل فاعل للتنبؤ بنوعية المياه في جميع أنحاء العالم. وصف الباحث أبا وآخرون (2020م)، بالتفصيل تقنيات التعلم الآلي والذكاء الاصطناعي المستخدمة في قياس الجودة. يمكن لمعظم خوارزميات ML-AI أن تعمل بدرجة معينة من الدقة ومن الصعب مقارنتها بناءً على أدائها.

تتضمن تقنيات الذكاء الاصطناعي المستخدمة أحياناً تنفيذاً يدوياً معقداً لتقليل فاعليتها الحقيقية لموظفي إدارة جودة المياه. لدى الممارسين اهتمام كبير بتعلم الرموز بحيث يمكن استخدام الرموز لحل النماذج المعقدة مثل تلك التي تمت مناقشتها أعلاه.

ويجب إجراء مقارنة شاملة لتطبيقات هذه النماذج مع حزم البرامج المطلوبة لتحسين دقة التنبؤات وملاءمة النماذج القائمة على الذكاء الاصطناعي. ومع ذلك، لا تتضمن برامج استخراج البيانات المختلفة معالجة واسعة النطاق للعديد من نماذج الذكاء الاصطناعي؛ بدلاً من ذلك، يدعم معظمهم فقط الأساليب الأساسية دون تحسين.

تهدف دراستنا أيضاً إلى تطوير واجهة سهلة الاستخدام في **MATLAB** للممارسين الذين ليس لديهم خلفية برمجية. تعتمد الواجهة الموصى بها على نظام تصنيف **Metaheuristic** مستوحى من الطبيعة، والذي يدمج تحسين سرب الجسيمات (**PSO**)، إلى جانب **SVM** و **NBC**.

تم التنبؤ بجودة المياه باستخدام تقنيات الذكاء الاصطناعي الأساسية، والتي تضمنت خوارزمية تحسين سرب الجسيمات (**PSO**) جنباً إلى جنب مع أجهزة ناقل الدعم (**SVMs**) للتنبؤ.

تم تطوير نظام التصنيف والتنبؤ للذكاء الاصطناعي الذي تم بحثه في الدراسة باستخدام أربعة نماذج للذكاء الاصطناعي (فردية)، والانحدار الهجين الماورائي، وأربع مجموعات (هي التراص، والانتخاب، والتعبئة، والتصنيف). تشمل النماذج الأساسية نماذج فردية باستخدام تقنيتين للذكاء الاصطناعي: **SVM** و **NBC**، على التوالي.

بعد ذلك، قامت نماذج المجموعة بدمج النماذج الفردية المسجلة واستخدمت أساليب التصويت والتعبئة والتصنيف والتراص. كان الهدف من العمل الحالي هو اقتراح إطار عمل لنموذج مرنة لنوعية المياه. كان للتقنية التحليلية أهداف مماثلة: الدقة التنبؤية للنماذج وإمكانية تطبيقها.

سيمكن الإطار المسؤولين وعلماء الهيدرولوجيا من اختيار أفضل الأدوات التحليلية لإدارة المياه باستخدام تقنيات الذكاء الاصطناعي.

يجب اختيار هذه النماذج بناءً على متطلبات محددة. ومع ذلك، في بعض الأحيان يمكن أن يؤدي تطبيق نموذج مجمع إلى تحسين دقة النموذج كثيرًا، وتقليل التكلفة الحسابية، (Agrawal et al. 2021).

♦ طرق الذكاء الاصطناعي في نمذجة منسوب المياه الجوفية

يعد قياس وتحليل مستوى المياه الجوفية (GWL) Groundwater level في طبقات المياه الجوفية مهمة بالغة الأهمية ومفيدة في إدارة موارد المياه الجوفية، ويمكن استخدام المعرفة حول اختلافات مستوى المياه الجوفية لتحديد مدى توفرها.

توفر اختلافات GWL في الآبار مقياسًا مباشرًا لتأثير تنمية المياه الجوفية، وغالبًا ما يتم تضمين المعلومات المهمة حول ديناميكيات طبقة المياه الجوفية في السلسلة الزمنية المسجلة بشكل مستمر لـ GWL.

ولذلك، فإن نمذجة GWL والتنبؤ بها أمر ضروري لمديري ومهندسي المياه لتأهيل وقياس موارد المياه الجوفية والحفاظ على التوازن بين العرض والطلب.

بالنسبة لنمذجة GWL، تعد النماذج التصورية أو المادية هي الأداة الرئيسية تقليديًا؛ ومع ذلك، فإن هناك بعض القيود العملية، بما في ذلك الحاجة إلى كمية كبيرة من البيانات ومعلومات الإدخال.

في كثير من الحالات، تكون البيانات محدودة من ناحية، ويكون الحصول على تنبؤات دقيقة أكثر أهمية من فهم الآليات الأساسية، ومن ناحية أخرى، يمكن أن تكون نماذج الذكاء الاصطناعي للصندوق الأسود (AI) بديلًا مناسبًا.

على الرغم من وجود طرق مختلفة لنمذجة GWL والتنبؤ بها في طبقات المياه الجوفية مثل الأساليب التصورية والفيزيائية والعديدية والإحصائية وما إلى ذلك. إلا أنه في السنوات الأخيرة، تم استخدام أساليب الذكاء الاصطناعي لبساطتها ونتائجها

المقبولة، وقد قامت العديد من الأبحاث بالتحقيق في أداء نماذج الذكاء الاصطناعي لنمذجة **GWL** في أجزاء مختلفة من العالم.

تحتوي أساليب الذكاء الاصطناعي لنمذجة **GWL** والتنبؤ بها على بعض نقاط الضعف مثل؛ الإفراط في التدريب، وانخفاض قابلية التعميم، وخطر استخدام بيانات غير ذات صلة، والنمذجة غير الصحيحة باستخدام أساليب غير مناسبة، وما إلى ذلك. إلا أن بساطتها في الاستخدام وسرعتها العالية ودقتها المقبولة دون الحاجة إلى معرفة المشكلات الفيزيائية، دفعت العديد من الباحثين إلى تطبيقها.

وتجدر الإشارة إلى أن طبيعة نماذج الذكاء الاصطناعي أو ربما عيوبها؛ هي أنه إذا تم تطويرها للتنبؤ بسلسلة زمنية محددة، فإنه لا يمكن بالضرورة استخلاص نتائج دقيقة في تلك المماثلة. لكن الميزة الرئيسة لنماذج الذكاء الاصطناعي هي نمذجة الظواهر غير الخطية والمعقدة دون الحاجة إلى الفهم الكامل للآليات الأساسية. ولذلك، فإن استخدام أساليب الذكاء الاصطناعي في نمذجة **GWL** يتزايد بشكل مطرد، ويجذب اهتمام العديد من الباحثين في العالم.

من أجل تطوير أساليب جديدة وأفضل للذكاء الاصطناعي لنمذجة **GWL**، من المهم التحقق مما تم إنجازه باستخدام نماذج الذكاء الاصطناعي والأبحاث الحالية، وهناك حاجة للباحثين لمعرفة ما فعله العلماء الآخرون في هذا الصدد.

تم نشر العديد من أوراق المراجعة مؤخراً والتي استكشفت استخدام نماذج الذكاء الاصطناعي في الهيدرولوجيا، (على سبيل المثال؛ **e.g., Solomatine, 2005**)، أو في مختلف المجالات الهيدرولوجية والموارد المائية كما في نمذجة متغيرات الأنهار، وفي مجال نمذجة جودة المياه، (**Wu et al, 2014**)، في حين لم يتم العثور على أي ورقة مراجعة تركز على الاستخدام المحدد لنماذج الذكاء الاصطناعي لنمذجة **GWL** والتنبؤ بها (**Rajae et al., 2019**).

♦ التنبؤ بمنسوب المياه الجوفية باستخدام الشبكات العصبية الاصطناعية

على الرغم من أن النماذج التصورية والمادية هي الأداة الرئيسة لتصوير المتغيرات الهيدرولوجية وفهم العمليات الفيزيائية التي تحدث في النظام، إلا أن لها قيود عملية. عندما لا تكون البيانات كافية ويكون الحصول على تنبؤات دقيقة أكثر أهمية من تصور الفيزياء الفعلية، تظل النماذج التجريبية طريقة بديلة جيدة، ويمكن أن توفر نتائج مفيدة دون الحاجة إلى وقت معايرة مكلف.

نماذج ANN هي نماذج «الصندوق الأسود» ذات خصائص معينة مناسبة كثيراً لنمذجة النظام الديناميكي غير الخطي.

تختلف تطبيقات ANN في الهيدرولوجيا، من النمذجة في الوقت الحقيقي إلى النمذجة القائمة على الأحداث. وقد تم استخدامها لنمذجة تساقط الأمطار؛ الجريان السطحي، والتنبؤ بتساقط الأمطار، ونمذجة جودة المياه.

إحدى أهم سمات نماذج ANN، هي قدرتها على التكيف مع التغيرات المتكررة واكتشاف الأنماط في النظام الطبيعي المعقد. تمت مناقشة المزيد من المفاهيم والتطبيقات لنماذج ANN في الهيدرولوجيا من قبل لجنة العمل التابعة لـ ASCE المعنية بتطبيق الشبكات العصبية الاصطناعية في الهيدرولوجيا (2000).

كما تم تطبيق الشبكات العصبية بنجاح في التنبؤ بمستوى المياه الجوفية، وفي الشبكات العصبية سابقاً. وهي عبارة عن معالجة متوازية ضخمة، تتكون من خلايا عصبية اصطناعية واحدة. كما تمثل المشابك العصبية البنية التي يتم فيها تخزين قيم الوزن، (Daliakopoulos et al. 2005).

♦ محاكاة منسوب المياه الجوفية من خلال نظام الذكاء الاصطناعي

تعد محاكاة السلوك التذبذبي لمستوى المياه الجوفية من أهم المهام الهيدرولوجية، ويتم تنفيذها في الغالب من خلال نماذج تصورية وحتمية مختلفة.

في العديد من التحقيقات، قام الباحثون بتقدير مستوى المياه الجوفية، باستخدام نموذج توازن المياه الذي يربط التعديلات في مستوى المياه بعناصر توازن المياه الرئيسية (Adamowski and Chan 2011; Jones et al. 2001; Mohanty et al. 2010).

على سبيل المثال، معلمات التصريفات الواردة والصادرة، وتساقط الأمطار، والتبخر، والرطوبة، ودرجة الحرارة، هي بعض المعلمات التي تمت دراستها لمحاكاة المياه الجوفية.

ضمنياً، يتسبب تساقط الأمطار في حدوث تذبذبات طفيفة في أي مكان تكون فيه فقد تساقط الأمطار تحت السطح كبير بسبب الاختراق الرأسي.

لذلك، في طبقات المياه الجوفية ذات النفاذية الكافية، قد تكون استجابة مستوى المياه الجوفية لتساقط الأمطار سريعة؛ ومع ذلك، يمكن اعتبار تساقط الأمطار مؤشراً كبيراً لتذبذب مستوى المياه الجوفية في مثل هذه طبقات المياه الجوفية.

في العقود السابقة، تم تطبيق أساليب الذكاء الاصطناعي (AI) مثل: الشبكات العصبية الاصطناعية (ANNs)، ونظام الاستدلال العصبي الغامض (ANFIS)، كأدوات قوية وحلول دقيقة للعديد من التحديات الصعبة جداً التي تواجهها علوم المياه (الهيدرولوجيا)، وقد زاد هذا الاستخدام.

تتمتع أساليب الذكاء الاصطناعي المتنامية بالقدرة على سد الفجوات في القياسات، والتنبؤ بالقيم المستقبلية دون الحاجة إلى بيانات مراقبة طويلة. الشبكات العصبية الاصطناعية تميز الأنواع العددية المبسطة بشكل ملحوظ، من الشبكات العصبية العضوية.

الشبكات العصبية الاصطناعية قادرة على تطوير الحلول ومعالجة البيانات سريعاً، لتحديد الهيكل داخل المعلومات من أمثلة التعلم. بالنسبة لـ **ANFIS** هي عبارة عن مزيج من الشبكة العصبية التكيفية جنباً إلى جنب مع نظام الاستدلال الغامض.

لقد تم استخدامه لمجموعة متنوعة من الأغراض، بالإضافة إلى تحديده على أنه يحقق نتائج أفضل مقارنة ببعض أساليب الحوسبة السلسلة الأخرى.

تُعرف طريقتا **ANN** و **ANFIS** بأنها تطبيقات مناسبة لمحاكاة البرامج غير الخطية المعقدة، وقد حظيت بشعبية كبيرة في تصنيف وتقييم تقلبات منسوب المياه الجوفية. وهي مهمة بشكل عام في تعلم العلاقة الأساسية بين المدخلات واتصالات المخرجات بناءً على مجموعة البيانات المرصودة فقط. لقد تم فعلاً دراسة تطبيقات نمذجة **ANFIS** في الأنظمة الهيدرولوجية مع تطبيق محدد لنمذجة مستوى المياه.

في الآونة الأخيرة، قام العديد من الخبراء بتحليل فوائد نماذج **ANN** و **ANFIS** مقارنة بتقنيات المحاكاة العادية (Daliakopoulos et al. 2005). ويمكن دمج طريقتي **ANN** و **ANFIS** لتطوير طريقة هجينة في تقدير تقلبات منسوب المياه.

♦ تطبيق نماذج الذكاء الاصطناعي الهجين لرسم خرائط المياه الجوفية

تُعد المياه الجوفية مصدراً موثوقاً للمياه العذبة، خاصة في المناطق القاحلة وشبه القاحلة.

في الآونة الأخيرة، وبسبب الزيادة السكانية، وتأثير تغير المناخ، لا تستطيع موارد المياه السطحية تلبية متطلبات المياه العذبة للري والشرب والاستخدام الصناعي، مما يزيد الضغط على استخدام موارد المياه الجوفية.

وقد استلزم ذلك رسم خرائط منهجية لموارد المياه الجوفية باستخدام التكنولوجيا الحديثة لتقييم إمكانات المياه الجوفية المناسبة لمنطقة ما من أجل الاستخدام الأمثل لها، وإدارتها بالتزامن مع استخدام المياه السطحية من أجل التنمية المستدامة.

تتطلب الطرق التقليدية لتقييم المياه الجوفية بناءً على رسم الخرائط الميدانية والاستكشاف قدرًا كبيرًا من الوقت والتكلفة.

ولذلك، تم استخدام أساليب إحصائية أحدث مع نظم المعلومات الجغرافية: نظام المعلومات الجغرافية لتطوير خرائط المياه الجوفية المحتملة.

تم استخدام تقنيات نظم المعلومات الجغرافية والاستشعار عن بعد لرسم خرائط لمناطق المياه الجوفية المحتملة في مستجمع مياه موسي باستخدام الخرائط الجغرافية البيئية الموضوعية.

قام مول وآخرون (2007م)، بتحديد منطقة المياه الجوفية المحتملة في جبال باري الجنوبية في تنزانيا، باستخدام خريطة جيولوجية وبيانات التحليل الكيميائي.

واستخدم ساراف وآخرون (2004م)، خريطة طبوغرافية تعتمد على نموذج الارتفاع الرقمي (DEM)، لتحليل إمكانات المياه الجوفية في مناطق مختارة من ولاية البنغال الغربية ومادهايا براديش، الهند. وبينوا علاقة إمكانات المياه الجوفية مع تقاطع الصرف.

في العقود الأخيرة، تم تطوير أساليب جديدة للذكاء الاصطناعي بما في ذلك التعلم الآلي (ML) واستخدامها لاستكشاف إمكانات المياه الجوفية، وأشهرها:

- ♦ Support Vector Machine (SVM),
- ♦ Artificial Neural Network (ANN),

- ♦ Classification and Regression Tree (CRT) (Naghibi et al., 2016),
- ♦ K-Nearest Neighbor (KNN) (Naghibi and Dashtpajardi, 2017),
- ♦ Maximum Entropy (ME),
- ♦ Functional Tree (FT) (Chen et al., 2018),
- ♦ Fisher's Linear Discriminant Function Analysis (FLDA) (Chen et al., 2019),
- ♦ Boosted Regression Tree (BRT) (Mousavi et al., 2017).

في الوقت الحاضر، يتم استخدام أساليب التعلم الآلي الهجينة على نطاق أوسع لتقييم ورسم خرائط إمكانات المياه الجوفية، حيث أن أداء هذه النماذج أفضل في كثير من الحالات مقارنة بنماذج التعلم الآلي الفردية.

استخدم ميرافي وآخرون (2019م)، طريقة هجينة جديدة، وهي الترددات الراديوية القائمة على الفضاء الفرعي العشوائي لبناء خريطة إمكانات المياه الجوفية، في سهل قورفه-دهغولان (إيران).

أظهرت النتائج أن الطريقة الهجينة لديها قدرة تنبؤية أكثر دقة لإمكانات المياه الجوفية من نماذج ML الفردية (Logistic Regression - LR, RF, and Naïve Bayes).

طبق تشن وآخرون (Chen et al., 2019a)، نموذجاً هجيناً يعتمد على FLDA مع التعبئة (BFLDA) وغابة التدوير (RFLDA) لتقييم إمكانات المياه الجوفية في منطقة نينجتياوتا (الصين). وقد أشارت النتائج إلى أن نموذج BFLDA كان أفضل من نماذج FRLDA و FLDA الأخرى.

حسين وآخرون (2019م)، طبقوا طريقة هجينة جديدة تعتمد على MABLR - الانحدار اللوجستي متعدد التكيف لبناء خريطة إمكانات المياه الجوفية لحوض

جيونج سانج بوكدو (كوريا الجنوبية)، ومقارنة النتائج مع النماذج الأخرى: طرق LR والإدراك متعدد الطبقات (MPL) و SVM. أشارت النتائج إلى أن نموذج MABLR كان فاعلاً في رسم خرائط إمكانات المياه الجوفية.

بشكل عام، أظهرت نماذج ML الهجينة/المجمعة تنبؤاً أفضل لمناطق المياه الجوفية المحتملة مقارنة بنماذج ML الفردية. ومع ذلك، لا توجد طريقة معروفة للتعليم الآلي يمكنها حل جميع مشكلات المياه الجوفية، وخاصة تقييم إمكانات المياه الجوفية في مناطق مختلفة.

لذلك، جرت محاولة لتطبيق أساليب ML الهجينة المتقدمة مثل Random Forest ((RF وإطار Ensemble الخاص بها (AdaBoost-ABRF، و Baging-BRF، و LogitBoost-LBRF) لتطوير خرائط المياه الجوفية المحتملة لمقاطعة DakNong (فيتنام)، حيث أن تطوير النموذج هو عملية مستمرة لتحسين الأداء التنبؤي، (Hai et al. 2022).

♦ إدارة المياه الجوفية باستخدام الذكاء الاصطناعي

يعد دمج الذكاء الاصطناعي في إدارة المياه الجوفية مرحلة تحويلية تتميز بالابتكار والتحديات. تستكشف هذه الورقة البحثية التطبيق متعدد الطبقات للذكاء الاصطناعي في هذا المجال، وتقسيم مساهماته، ومعالجة التحديات المرتبطة به، والكشف عن آفاق الإمكانيات المستقبلية.

تم تصميم الابتكارات المعتمدة على الذكاء الاصطناعي لإحداث ثورة في إدارة المياه الجوفية، وتوفير نماذج تنبؤية دقيقة، ومراقبة في الوقت الفعلي، وتكامل البيانات. ومع ذلك، تواجه هذه الابتكارات تحديات مثل مشكلات قابلية التفسير، ومتطلبات الخبرة الفنية المتخصصة، ومحدودية جودة البيانات وكميتها لأداء نموذج الذكاء الاصطناعي الفاعل.

في المستقبل، يحمل الذكاء الاصطناعي وعدًا كبيرًا في إدارة المياه الجوفية. ومن الممكن أن تسفر نماذج الذكاء الاصطناعي المتقدمة عن تنبؤات محسنة لسلوك المياه الجوفية، وتحديد المناطق المعرضة للتلوث والاستنزاف، والتدخلات الاستباقية الفورية، وتعزيز المنصات التعاونية بين العلماء وصناع السياسات والمجتمعات المحلية. توفر المنصات التعاونية التي يقودها الذكاء الاصطناعي إمكانية المشاركة التآزرية بين العلماء وصناع السياسة ومسؤولي المجتمعات المحلية، لتوجيه إدارة موارد المياه الجوفية جماعيا.

ويبقى احتضان إمكانات الذكاء الاصطناعي مع مواجهة تحدياته أمراً محورياً لممارسات إدارة المياه الجوفية المستدامة والمرنة. ومن تبني إمكانات الذكاء الاصطناعي أثناء مواجهة تحدياته، سيستمر مشهد إدارة موارد المياه الجوفية في التطور.

♦ النمذجة التنبؤية

تعمل تطبيقات الذكاء الاصطناعي المبتكرة في إدارة المياه الجوفية، على تغيير الأساليب التقليدية بالاستفادة من التقنيات المتقدمة لتعزيز عملية صنع القرار، وتحسين تخصيص الموارد، وضمان الاستخدام المستدام.

إحدى الابتكارات البارزة في هذا المجال هي النمذجة التنبؤية، المدفوعة بالذكاء الاصطناعي. تستخدم النمذجة التنبؤية بيانات المياه الجوفية التاريخية والخوارزميات المتطورة للتنبؤ بمستويات المياه الجوفية، مما يوفر رؤى قيمة لممارسات الإدارة الفاعلة (Krishnan, S.R. et al. 2022).

تتمتع النماذج التنبؤية المعتمدة على الذكاء الاصطناعي بالقدرة على تحليل الأنماط الهيدروجيولوجية المعقدة، والاتجاهات التاريخية، مما يتيح تنبؤات دقيقة بمستويات المياه الجوفية المستقبلية.

وبالنظر في عوامل مثل؛ أنماط تساقط الأمطار، وتغيرات استخدام الأراضي، ومعدلات الاستخراج، توفر هذه النماذج فهماً شاملاً لسلوك المياه الجوفية (Hai Tao et.al. 2022).

تكمن أهمية النمذجة التنبؤية في قدرتها على تسهيل اتخاذ القرارات الاستباقية. وبدلاً من الاستجابة للتغيرات غير المتوقعة في مستويات المياه الجوفية، يمكن لأصحاب المصلحة توقع التغيرات والتخطيط لأنشطة الاستتباب وفقاً لذلك.

وهذا يساعد في منع الإفراط في الاستتباب، والذي يمكن أن يؤدي إلى آثار بيئية ضارة مثل هبوط الأرض وتسرب المياه المالحة. بالإضافة إلى ذلك، تساهم النمذجة التنبؤية في كفاءة تخصيص المياه، مما يضمن التوزيع العادل بين مختلف المستخدمين. فضلاً عن ذلك، تعتمد الإدارة المستدامة للمياه الجوفية على تقليل استنزاف الموارد. تلعب النماذج التنبؤية المعتمدة على الذكاء الاصطناعي دوراً محورياً في هذا الصدد، بتحديد معدلات الاستتباب المثالية التي تحافظ على مستويات المياه الجوفية ضمن حدود السحب الآمن.

وبالموازنة بين احتياجات الإنسان من المياه والحفاظ على النظم البيئية التي تعتمد على المياه الجوفية، تساهم هذه النماذج في استدامة الموارد على المدى الطويل.

كما تقدم النمذجة التنبؤية رؤى حول التأثيرات المحتملة لتغير المناخ على توافر المياه الجوفية. ومن دمج التوقعات المناخية في النماذج، يمكن لصناع القرار توقع كيف يمكن أن تؤثر أنماط الطقس المتغيرة على معدلات تغذية المياه الجوفية وتوافرها بشكل عام.

وهذه المعلومات ضرورية لتكييف استراتيجيات الإدارة مع الظروف البيئية المتطورة. باختصار، تعد النمذجة التنبؤية المعتمدة على الذكاء الاصطناعي بمنزلة ابتكار رائد في إدارة المياه الجوفية.

ومن خلال تسخير البيانات التاريخية والخوارزميات المتقدمة، فإنه يمكن أصحاب المصلحة من الحصول على تنبؤات دقيقة لمستويات المياه الجوفية، مما يتيح اتخاذ قرارات استباقية ومستدامة.

وبينما يواجه العالم تحديات متزايدة في مجال المياه، فإن دمج النمذجة التنبؤية في ممارسات إدارة المياه الجوفية يحمل الوعد بضمان مستقبل مائي أكثر أماناً ومرونة.

♦ الرصد في الوقت الحقيقي

شهد مجال إدارة المياه الجوفية تحولاً واضحاً عند دمج تطبيقات الذكاء الاصطناعي المبتكرة. ومن بين هذه التطورات، تبرز (المراقبة في الوقت الفعلي) باعتبارها ابتكاراً محورياً، مدعوماً بتضافر أجهزة استشعار إنترنت الكيانات (IoT)، وخوارزميات الذكاء الاصطناعي.

يتيح هذا الاندماج الديناميكي إجراء تقييم مستمر وفوري لجودة المياه الجوفية، مما يوفر إمكانات الكشف المبكر عن أحداث التلوث المحتملة (Shah, S.F.A et.al. 2022).

تستخدم (المراقبة في الوقت الفعلي) أجهزة استشعار إنترنت الكيانات الموضوعية بشكل استراتيجي داخل مصادر المياه الجوفية، لالتقاط مجموعة متنوعة من نقاط البيانات.

تقوم هذه المستشعرات بجمع معلومات في الوقت الفعلي عن معلمات مثل؛ مستويات الأس الهيدروجيني، والأكسجين المذاب، والتركيزات الكيميائية، ودرجة الحرارة. بعد ذلك تنقل هذه البيانات إلى خوارزميات الذكاء الاصطناعي التي تقوم بمعالجتها وتحليلها وتفسيرها في الوقت الفعلي، مما يسهل الفهم الشامل لديناميات جودة المياه الجوفية (Mustaq and Farjana 2024).

تكمّن إحدى المزايا الأساسية (للمراقبة في الوقت الفعلي) في قدرتها على تقديم تنبيهات فورية فيما يتعلق بأي انحراف عن ظروف جودة المياه الجوفية العادية. فإن تجاوزت الملوثات مثل؛ المعادن الثقيلة أو النتترات أو مسببات الأمراض الميكروبية الحدود المسموح بها، تقوم خوارزميات الذكاء الاصطناعي بإطلاق التنبيهات، مما يتيح التدخل السريع.

وتمكّن آلية الكشف المبكر هذه مديري المياه والسلطات من اتخاذ تدابير استباقية للتخفيف من أخطار التلوث، وحماية الصحة العامة.

إضافة إلى ذلك، فإن الطبيعة المستمرة للرصد في الوقت الحقيقي تعزز الفهم الديناميكي لاتجاهات جودة المياه الجوفية. وبدلاً من الاعتماد على عينات متفرقة، يتمكن أصحاب المصلحة من الوصول إلى مجموعة كبيرة من نقاط البيانات الحديثة، ما يمكنهم من تحديد مصادر التلوث وتتبع التغييرات بمرور الوقت. تشكل هذه الرؤية المبنية على البيانات الأساس لاستراتيجيات العلاج المستهدفة واتخاذ القرارات المستنيرة.

أهمية المراقبة في الوقت الفعلي تمتد إلى ما هو أبعد من الكشف فحسب؛ فهو يؤدي إلى التحول من الإدارة التفاعلية إلى الإدارة الاستباقية للمياه الجوفية. ومن تحديد أحداث التلوث بسرعة، يمكن لأصحاب المصلحة بدء إجراءات الاستجابة مثل تعديل متوسط الاستنباط، أو تغيير ممارسات استخدام الأراضي، أو تنفيذ تقنيات إزالة الملوثات. وهذا يساهم في الحفاظ على جودة المياه الجوفية، ويمنع تصاعد سيناريوهات التلوث.

وفي الختام، فإن دمج أجهزة استشعار إنترنت الكيانات وخوارزميات الذكاء الاصطناعي في المراقبة في الوقت الحقيقي يعيد تعريف مشهد إدارة المياه الجوفية.

ويسهل هذا الابتكار الفهم المستمر والغني بالبيانات لجودة المياه الجوفية، مما يتيح الكشف المبكر والاستجابة السريعة لتهديدات التلوث. ومع تزايد ضرورة حماية موارد المياه، تظهر المراقبة في الوقت الفعلي كأداة حاسمة لتعزيز القدرة على الصمود، وتعزيز الصحة العامة، وضمان الاستخدام المستدام لمصادر المياه الجوفية.

♦ تكامل البيانات

وفي مجال إدارة المياه الجوفية، تقود تطبيقات الذكاء الاصطناعي المبتكرة تحولات مباشرة في الطريقة التي ننظر بها إلى الموارد المائية ونديرها. ومن بين هذه التطورات، يعد التكامل السلس لمصادر البيانات المتنوعة من خلال تقنيات الذكاء الاصطناعي بمنزلة ابتكار محوري، يُحدث ثورة في دقة وكفاءة النماذج الهيدرولوجية ومحاكاة تدفق المياه الجوفية.

تقليدياً، تعتمد إدارة المياه الجوفية على مصادر بيانات مجزأة ومتباينة في كثير من الأحيان، مما يؤدي إلى رؤية مجزأة للديناميكيات الهيدرولوجية.

ومع ذلك، توفر تقنيات الذكاء الاصطناعي الآن القدرة على دمج البيانات من مصادر مختلفة بشكل متناغم، بما في ذلك المسوحات الجيولوجية، وصور الأقمار الصناعية، والبيانات المناخية، والقياسات في الموقع. من خلال تفكيك صوامع البيانات بشكل فاعل، يؤدي تكامل البيانات المستندة إلى الذكاء الاصطناعي إلى الحصول على رؤية شاملة لأنظمة المياه الجوفية.

تكمّن قوة الذكاء الاصطناعي عند تكامل البيانات في قدرته على تحديد الأنماط والعلاقات المتبادلة والترابط عبر مجموعات البيانات المختلفة. تتفوق خوارزميات التعلم الآلي في التعرف على العلاقات المعقدة، مما يمكنها من استخلاص رؤى ذات معنى من مصادر تبدو غير ذات صلة. ويعزز هذا الدمج دقة النماذج الهيدرولوجية، مما يجعل عمليات المحاكاة أكثر انعكاساً لسلوكيات المياه الجوفية في العالم الحقيقي.

إحدى المزايا الرئيسية لتكامل البيانات المدعومة بالذكاء الاصطناعي هي تقليل الريبة في عمليات محاكاة تدفق المياه الجوفية. ومن خلال دمج مجموعة واسعة من أنواع البيانات، تصبح النماذج أكثر شمولاً وقوة، مما يتيح تنبؤات أفضل لحركة المياه الجوفية، ومعدلات التغذية، وتشتت الملوثات.

وتعزز هذه الدقة اتخاذ قرارات مستتيرة من قبل أصحاب المصلحة ومديري الموارد المائية. بالإضافة إلى ذلك، تتيح تقنيات الذكاء الاصطناعي وتتعلم بمرور الوقت، مما يعزز دقة التنبؤات مع توفر بيانات جديدة.

إن عملية التعلم التكرارية هذه تعمل على تمكين النماذج من تحسين مخرجاتها بشكل مستمر، ومواءمتها بشكل أوثق مع الظواهر الهيدروجيولوجية المرصودة. ونتيجة لذلك، أصبحت استراتيجيات إدارة المياه الجوفية أكثر استجابة وقدرة على التكيف مع الظروف المتغيرة.

تمتد الإمكانيات التحويلية لتكامل البيانات المدعومة بالذكاء الاصطناعي إلى معالجة تحديات ندرة المياه، وتحسين تخصيص الموارد، وتخفيف الآثار البيئية.

ومن توفير رؤية شاملة لديناميات المياه الجوفية، يمكن لأصحاب المصلحة تنفيذ تدابير فاعلة لتعزيز الاستدامة، وتقليل الإفراط في الاستتباط، والحماية من أخطار التلوث. وفي الختام، يمثل دمج مصادر البيانات المتنوعة من خلال تقنيات الذكاء الاصطناعي علامة بارزة في إدارة المياه الجوفية.

يعمل هذا الابتكار على رفع دقة النماذج الهيدروجيولوجية ومحاكاة تدفق المياه الجوفية، مما يوفر فهماً شاملاً لأنظمة المياه الجوفية. بينما يتصارع العالم مع تحديات المياه المتطورة، يظهر تكامل البيانات المدعومة بالذكاء الاصطناعي كأداة حيوية لضمان الاستخدام الحكيم والمستدام لهذا المورد الثمين.

♦ أنظمة دعم القرار

تساعد أنظمة دعم القرار المدعومة بالذكاء الاصطناعي صناع السياسة ومديري المياه على اتخاذ خيارات مستتيرة لتخصيص المياه الجوفية والحفاظ عليها. في مجال إدارة المياه الجوفية، يعد ظهور أنظمة دعم القرار المدعومة بالذكاء الاصطناعي بمنزلة تقدم كبير.

تستفيد أنظمة دعم القرار المدعومة بالذكاء الاصطناعي من قدرات الذكاء الاصطناعي وتحليلات البيانات لمعالجة كميات هائلة من المعلومات المعقدة. ومن خلال دمج مصادر البيانات المتنوعة مثل مستويات المياه الجوفية، ومعدلات التغذية، وأنماط الاستتباط، والاتجاهات المناخية، وتغيرات استخدام الأراضي، تولد هذه الأنظمة رؤى شاملة توجه صناع القرار في فهم ديناميكيات موارد المياه الجوفية.

أحد التطبيقات الأساسية لهذه الأنظمة هو تخصيص المياه الجوفية. ومع تزايد الطلب من المراكز الحضرية والأنشطة الزراعية والعمليات الصناعية، يصبح التخصيص الحكيم لموارد المياه الجوفية أمراً بالغ الأهمية.

يمكن للأنظمة المعتمدة على الذكاء الاصطناعي تحليل البيانات التاريخية، والتنبؤ بالاتجاهات المستقبلية، ووضع نماذج لسيناريوهات التخصيص المختلفة لتحديد معدلات الاستتباط المثالية التي توازن إمدادات المياه مع الاستدامة طويلة المدى.

علاوة على ذلك، تلعب أنظمة دعم القرار هذه دوراً محورياً في جهود الحفاظ. ويمكنهم وضع نماذج لتأثير استراتيجيات الحفاظ المختلفة، مثل تنفيذ طرق التغذية الاصطناعية، أو تعزيز ممارسات كفاءة استخدام المياه، أو إنفاذ التدابير التنظيمية.

ومن محاكاة نتائج هذه الاستراتيجيات، يمكن لصناع القرار تحديد الأساليب الأكثر فاعلية للحفاظ على موارد المياه الجوفية وتخفيف أخطار استنزافها.

تمتد فوائد أنظمة دعم القرار المدعومة بالذكاء الاصطناعي إلى ما هو أبعد من تحليل البيانات. يمكن لهذه الأنظمة توفير تصورات ولوحات معلومات تفاعلية ومقارنات سيناريوهات تسهل التواصل الفاعل بين أصحاب المصلحة.

ويمكن لواقعي السياسات ومديري المياه والمجتمعات المحلية التعامل مع هذه الأنظمة لاستكشاف خيارات الإدارة المختلفة بشكل تعاوني وفهم الآثار المحتملة لقراراتهم. مع تطور تقنيات الذكاء الاصطناعي، أصبحت الإمكانيات المستقبلية لأنظمة دعم القرار واعدة. ستعمل خوارزميات التعلم الآلي المحسنة وتكامل البيانات في الوقت الفعلي وتقنيات النمذجة المحسنة، على تحسين الدقة والقدرات التنبؤية لهذه الأنظمة. علاوة على ذلك، يمكن أن يوفر اقتران الذكاء الاصطناعي مع أنظمة المعلومات الجغرافية (GIS) رؤى مكانية تعزز دقة اتخاذ القرار.

في الختام، تمثل أنظمة دعم القرار المدعومة بالذكاء الاصطناعي تقدماً محورياً في إدارة المياه الجوفية. إن قدرتها على معالجة البيانات المعقدة، والتنبؤ بالاتجاهات، والسيناريوهات النموذجية، تزود صناع القرار بالأدوات اللازمة لتخصيص موارد المياه الجوفية بحكمة وتنفيذ تدابير فاعلة للحفاظ. وبتسخير قوة الذكاء الاصطناعي، يمكن لإدارة المياه الجوفية أن تتنقل نحو مستقبل أكثر استدامة ومرونة.

♦ التحسين

تعمل تطبيقات الذكاء الاصطناعي المبتكرة على إعادة تشكيل مشهد إدارة المياه الجوفية، حيث تقدم استراتيجيات تحويلية تعزز كفاءة الموارد والاستدامة البيئية. ومن بين هذه التطورات، تمتلك خوارزميات التحسين المعتمدة على الذكاء الاصطناعي إمكانيات هائلة لإحداث ثورة في جداول الضخ، وتقليل استهلاك الطاقة، وتخفيف الآثار البيئية المرتبطة باستنباط المياه الجوفية. إن استنباط المياه الجوفية لأغراض مختلفة، بما في ذلك الري الزراعي والعمليات الصناعية وإمدادات البلديات، غالباً

ما ينطوي على قرارات معقدة حول متى وكم يتم ضخها. إن استتباط المياه الجوفية لأغراض مختلفة، بما في ذلك الري الزراعي والعمليات الصناعية وإمدادات البلديات، غالباً ما ينطوي على قرارات معقدة حول متى وكم يتم ضخها.

ومن تحليل البيانات المتطورة والحسابات الخوارزمية، تولد هذه النماذج جداول ضخ مثالية تحقق التوازن بين تلبية الاحتياجات البشرية وحماية النظام البيئي للمياه الجوفية. تكمن إحدى المزايا المحورية للتحسين المعتمد على الذكاء الاصطناعي في قدرته على تقليل استهلاك الطاقة. ومن خلال تصميم جداول الضخ بما يتناسب مع فترات الطاقة خارج أوقات الذروة وتحسين معدلات الاستتباط، تعمل خوارزميات الذكاء الاصطناعي على تقليل متطلبات الطاقة الإجمالية لضخ المياه الجوفية.

ولا يؤدي هذا إلى توفير التكاليف لمديري المياه فحسب، بل يساهم أيضاً في جهود الحفاظ على الطاقة على نطاق أوسع. علاوة على ذلك، تأخذ خوارزميات تحسين الذكاء الاصطناعي الاعتبارات البيئية، وبالتالي تقلل الآثار السلبية المحتملة على النظم البيئية المعتمدة على المياه الجوفية. ومن منع الإفراط في الاستتباط وضمان مستويات مستدامة للمياه الجوفية، تعمل هذه الخوارزميات على تخفيف الأخطار مثل؛ هبوط الأراضي في المناطق الجبلية، وتسرب المياه المالحة إلى المناطق الساحلية، وتدهور الموائل. يتوافق هذا النهج الواعي بيئياً مع ضرورة الحفاظ على التنوع البيولوجي، وعلى الصحة العامة للنظم البيئية المائية.

كما أن دمج التحسين القائم على الذكاء الاصطناعي في استراتيجيات إدارة المياه الجوفية يعزز أيضاً توافر المياه. ومن تحسين معدلات الاستتباط بناءً على أنماط الطلب وتوافر الموارد، يستطيع مديرو المياه منع الاستنزاف المفرط للمياه الجوفية خلال فترات الندرة. وهذا بدوره يساهم في استدامة موارد المياه الجوفية على المدى الطويل، مما يضمن توفرها للأجيال الحالية والمستقبلية.

في الختام، يمثل دمج خوارزميات التحسين المعتمدة على الذكاء الاصطناعي في إدارة المياه الجوفية قفزة كبيرة إلى الأمام في كفاءة الموارد والإشراف البيئي. تعمل هذه الخوارزميات على تمكين أصحاب المصلحة من اتخاذ قرارات مستتيرة تقلل من استهلاك الطاقة، وتحافظ على صحة النظام البيئي، وتضمن توافر المياه.

ومع تزايد تحديات ندرة المياه وتزايد الحاجة إلى الإدارة المستدامة للموارد، فإن التحسين المدعوم بالذكاء الاصطناعي يمثل أداة قوية لتعزيز نموذج أكثر مرونة وتوازناً بيئياً لإدارة المياه الجوفية.

• التحديات والقيود

♦ جودة البيانات وكميتها

يمثل دمج الذكاء الاصطناعي (AI) في إدارة المياه الجوفية فرصة تحويلية، ولكنه يطرح أيضاً تحديات وقيوداً واضحة تستحق الدراسة. ومن بين هذه التحديات، نوعية وكمية البيانات باعتبارها مصدر قلق أساسي، لا سيما في السياقات الهيدروجيولوجية، حيث يمكن أن يكون الحصول على مجموعات بيانات شاملة أمراً معقداً. تزدهر نماذج الذكاء الاصطناعي بفضل ثراء البيانات، مما يتطلب كميات كبيرة من المعلومات المتنوعة والدقيقة للحصول على رؤى مفيدة. ومع ذلك، في مجال إدارة المياه الجوفية، يمكن أن يكون الحصول على مجموعات البيانات هذه مهمة عظيمة.

غالباً ما يكون جمع البيانات الهيدروجيولوجية مقيداً بعوامل مثل شبكات المراقبة المحدودة، والمواقع النائية التي يتعذر الوصول إليها، والقيود المالية. يمكن أن تؤدي ندرة البيانات هذه إلى إعاقة تطوير نماذج قوية للذكاء الاصطناعي تعتمد على الاتجاهات وعلاقات الارتباط التاريخية.

إن جودة البيانات المتاحة لها أهمية قصوى. يمكن أن تؤدي البيانات غير الدقيقة أو غير الكاملة إلى تحريف مخرجات نموذج الذكاء الاصطناعي وتعريض موثوقية التنبؤات للخطر. ويمكن أن تؤدي المتغيرات في تقنيات القياس وعمليات المعايرة وترددات أخذ العينات إلى حدوث أخطاء تنتشر من خلال خوارزميات الذكاء الاصطناعي. وبالتالي، يصبح ضمان دقة البيانات من خلال عمليات مراقبة الجودة الصارمة شرطاً أساسياً حاسماً للتكامل الفاعل للذكاء الاصطناعي. ويتطلب التصدي لهذه التحديات اتباع نهج متعدد الجوانب. إن توسيع وتعزيز شبكات جمع البيانات، واستخدام تقنيات الاستشعار عن بعد، ودمج السجلات التاريخية يمكن أن يساهم في زيادة كمية البيانات.

قد يؤدي استخدام بروتوكولات موحدة لجمع البيانات والاستثمار في معدات المراقبة المتقدمة إلى تحسين جودة البيانات. ومن الممكن أن يساعد التعاون بين الباحثين ومديري المياه وصناع السياسة في التغلب على ندرة البيانات بتجميع الموارد ومشاركة مجموعات البيانات الحالية. كما يمكن لتقنيات الذكاء الاصطناعي مثل نقل التعلم وزيادة البيانات أن تساعد في تحقيق أقصى استفادة من البيانات المحدودة، بالاستفادة من المعرفة في المجالات ذات الصلة، أو إنشاء مجموعات بيانات تركيبية. يمكن لهذه الأساليب تحسين أداء النموذج على الرغم من قيود البيانات.

في الختام، بينما يحمل الذكاء الاصطناعي إمكانات عظيمة لتحويل إدارة المياه الجوفية، لا ينبغي الاستهانة بالتحديات المتعلقة بجودة البيانات وكميتها. ويتطلب التصدي لهذه التحديات بذل جهود متضافرة لتوسيع شبكات المراقبة، وتوحيد إجراءات جمع البيانات، واعتماد تقنيات مبتكرة تعمل على تعظيم قيمة البيانات المتاحة. ومع استمرار تطور الذكاء الاصطناعي، فإن التغلب على قيود البيانات سيلعب دوراً محورياً في تحقيق إمكاناته الكاملة في عملية صنع القرار بشأن إدارة المياه الجوفية.

♦ القابلية للتفسير

إن دمج تقنيات الذكاء الاصطناعي في إدارة المياه الجوفية يحقق فوائد عديدة، ولكن عادة ما يكون مصحوباً ببعض التحديات والقيود. ومن بين هذه القضايا، تبرز مسألة قابلية التفسير **Interpretability** باعتبارها مصدر قلق كبير، خاصة فيما يتعلق ببعض تقنيات الذكاء الاصطناعي التي تفتقر إلى الشفافية، مما يعيق قدرة أصحاب المصلحة على فهم النتائج التي تولدها هذه النماذج ووضع الثقة فيها.

أظهرت نماذج الذكاء الاصطناعي، وخاصة تلك التي تعتمد على التعلم العميق والخوارزميات المعقدة، قدرات ملحوظة في تحليل مجموعات البيانات الواسعة والمعقدة للحصول على رؤى لم يكن من الممكن تحقيقها في السابق. ومع ذلك، فإن الطبيعة المعقدة لهذه النماذج غالباً ما تؤدي إلى سيناريو «الصندوق الأسود»، حيث لا يمكن فك رموز عملية صنع القرار وراء تنبؤاتها بسهولة. يشكل هذا التعتيم تحدياً في فهم كيفية وصول النموذج إلى استنتاجات محددة، ويشير تساؤلات حول مصداقية النتائج.

♦ الخبرة الفنية

إن دمج الذكاء الاصطناعي في إدارة المياه الجوفية يحمل وعداً كبيراً، إلا أنه مصحوب بمجموعة من التحديات والقيود التي يجب معالجتها. ومن بين هذه التحديات، تبرز الحاجة إلى الخبرة الفنية المتخصصة، حيث أن التنفيذ الناجح لحلول الذكاء الاصطناعي غالباً ما يتطلب مهارات قد لا تكون متاحة بسهولة داخل وكالات إدارة المياه. تشمل تقنيات الذكاء الاصطناعي مجموعة واسعة من المنهجيات، بدءاً من خوارزميات التعلم الآلي، وحتى المعالجة المسبقة للبيانات وتحسين النماذج. تتطلب هذه التقنيات فهماً عميقاً للمفاهيم الرياضية ولغات البرمجة ومبادئ علم البيانات. ومع ذلك، قد لا تتمكن وكالات إدارة المياه دائماً من الوصول إلى الأفراد الذين يتمتعون بهذه الخبرة المتخصصة، مما يصعب معه تسخير الإمكانيات الخاصة بتطبيقات الذكاء الاصطناعي كاملاً (Shaikh & Birajdar, 2024).

دور الذكاء الاصطناعي في تقييم المخاطر الجيولوجية

وفقاً لإدارة السلامة والصحة المهنية (OSHA) فإن الخطر هو أي مصدر للضرر المحتمل أو الأذى أو التأثيرات الضارة على شيء ما أو شخص ما في ظل ظروف معينة في العمل. وتشير الأخطار الجيولوجية إلى الأحداث الناجمة عن الظروف أو العمليات الجيولوجية التي تشكل تهديداً لحياة الإنسان أو الممتلكات أو البيئة الطبيعية.

وفقاً لقاعدة بيانات أحداث الطوارئ (EM-DAT، <https://public.emdat.be>)، (تم الوصول إليها في 7 يوليو 2022م)، وهي قاعدة بيانات عالمية للكوارث الفنية والطبيعية، فقد وقع 1877 خطراً جيولوجياً واسع النطاق في جميع أنحاء العالم في الفترة ما بين 1 يناير 1990م و7 يوليو 2022م. تسببت هذه الكوارث في مقتل 2.43 مليون شخص، وتشريد 25.74 مليون شخص، وتسببت في أضرار بقيمة 862 مليون دولار.

اليابان والصين هما الدولتان اللتان تعانيان من أعلى الخسائر بسبب الأخطار الجيولوجية، والتي تسببت في أضرار تبلغ حوالي 392 مليون دولار و114 مليون دولار، على التوالي. وكما نرى، فقد زاد عدد الأخطار الجيولوجية من عام 1990م إلى عام 2000م. وكانت آسيا والأمريكتان، اللتان تمثلان 55.5% و22.9% من إجمالي عدد الأخطار الجيولوجية في جميع أنحاء العالم، على التوالي، الأكثر معاناة من الأخطار الجيولوجية.

• الفوائد والتطبيقات الرئيسية

إن تقييم الأخطار الجيولوجية باستخدام الذكاء الاصطناعي يستخدم تقنيات الذكاء الاصطناعي المتقدمة (AI) لتحليل البيانات الجيولوجية وتحديد الأخطار المحتملة، مما يوفر رؤية قيمة للشركات العاملة في المناطق المعرضة للأخطار الجيولوجية.

توفر هذه التكنولوجيا العديد من الفوائد والتطبيقات الرئيسة من منظور الأعمال:

■ تقييم الأخطار والتخفيف من حدتها

يمكن تقييم الأخطار الجيولوجية باستخدام الذكاء الاصطناعي الشركات من تقييم وتخفيف الأخطار الجيولوجية المرتبطة بعملياتها. من تحليل البيانات التاريخية والتكوينات الجيولوجية والعوامل البيئية، يمكن للشركات تحديد المناطق المعرضة للانزلاقات الأرضية أو الزلازل أو المجاري أو غيرها من الأخطار. وتساعد هذه المعلومات على تطوير تدابير استباقية؛ لتقليل الأخطار وحماية الأصول وضمان سلامة الأفراد والمجتمعات.

■ تخطيط وتطوير البنية التحتية

يلعب تقييم الأخطار الجيولوجية باستخدام الذكاء الاصطناعي دوراً حاسماً في تخطيط البنية التحتية وتطويرها. يمكن للشركات الاستفادة من هذه التكنولوجيا لتحديد المواقع المناسبة لمشاريع البناء أو طرق النقل أو مرافق الطاقة. وبالنظر في الأخطار الجيولوجية والأخطار المحتملة، يمكن للشركات تحسين تصميمات المشاريع، واختيار أساليب البناء المناسبة، وتنفيذ تدابير للتخفيف من الأخطار، مما يؤدي إلى بنية تحتية أكثر أماناً ومرونة.

■ تقييم الأثر البيئي

يدعم تقييم الأخطار الجيولوجية باستخدام الذكاء الاصطناعي تقييمات الأثر البيئي بتحديد الأخطار الجيولوجية المحتملة التي قد تنشأ عن مشاريع التنمية.

يمكن للشركات استخدام هذه المعلومات لتقييم الآثار البيئية لعملياتها، وتطوير استراتيجيات التخفيف، والامتثال للوائح البيئية. ومن خلال تقليل الأخطار الجيولوجية، يمكن للشركات تقليل بصمتها البيئية وتعزيز الممارسات المستدامة.

■ الاستجابة للطوارئ والتأهب لها

يساعد تقييم الأخطار الجيولوجية باستخدام الذكاء الاصطناعي الشركات في الاستجابة لحالات الطوارئ والتخطيط للتأهب. ومن خلال تحديد المناطق المعرضة للخطر والتنبؤ بالحجم والتأثير المحتملين للأخطار الجيولوجية، يمكن للشركات وضع خطط للطوارئ، وتخصيص الموارد بشكل فاعل، والاستجابة لحالات الطوارئ. يساعد هذا النهج الاستباقي على تقليل الأضرار وحماية الأرواح وضمان استمرارية العمل أثناء الأحداث الخطرة.

■ التأمين وإدارة الأخطار

يوفر تقييم الأخطار الجيولوجية بالذكاء الاصطناعي معلومات قيمة لشركات التأمين ومتخصصي إدارة الأخطار. ومن تقييم الأخطار الجيولوجية ونقاط الضعف، يمكن لشركات التأمين ضمان السياسات بدقة، وتحديد أقساط التأمين المناسبة وربما خفضها، وتطوير استراتيجيات إدارة الأخطار، فضلاً عن استخدام هذه المعلومات لتحسين تغطيتها التأمينية، وتخفيف الأخطار المالية المرتبطة بالأخطار الجيولوجية.

■ تخطيط استخدام الأراضي وتقسيم المناطق

يساعد تقييم الأخطار الجيولوجية القائم على الذكاء الاصطناعي الوكالات الحكومية والمخططين الحضريين في تخطيط استخدام الأراضي وتقسيم المناطق. ومن تحديد المناطق المعرضة للأخطار الجيولوجية، يمكن للسلطات وضع لوائح مناسبة لاستخدام الأراضي، وتقييد التنمية في المناطق عالية الأخطار، وتعزيز ممارسات الاستخدام المستدام للأراضي، مما يساعد على حماية المجتمعات من الأخطار الجيولوجية، وتقليلها، وضمان سلامة ورفاهية السكان.

يوفر تقييم الأخطار الجيولوجية باستخدام الذكاء الاصطناعي للشركات أداة قوية لتقييم الأخطار الجيولوجية والتخفيف منها، وتحسين تخطيط البنية التحتية، وتقليل التأثيرات البيئية، والاستعداد لحالات الطوارئ، وإدارة التأمين والأخطار، ودعم تخطيط استخدام الأراضي. ومن خلال الاستفادة من تكنولوجيا الذكاء الاصطناعي، يمكن للشركات اتخاذ قرارات مستتيرة، والحد من الأخطار، وضمان سلامة واستدامة عملياتها في المناطق الخطرة جيولوجيا.

• سبل الوقاية

لقد تم بذل جهود كبيرة في الوقاية من الأخطار الجيولوجية والتخفيف من آثارها. ومع ذلك، توصف الأخطار الجيولوجية بأنها معقدة وغير مؤكدة؛ وبالتالي، لا تزال هناك تحديات أمام الباحثين والممارسين. في الآونة الأخيرة، أصبح الذكاء الاصطناعي (AI) شائعاً بين الباحثين والممارسين، وأدى إلى تقدم كبير في أبحاث الأخطار الجيولوجية. تتأثر بيانات مراقبة الأخطار الجيولوجية بعوامل محفزة متعددة، وعادةً ما تتميز بعلاقات معقدة وغير خطية. على سبيل المثال، بسبب تساقط الأمطار الموسمية والتقلبات الدورية في الخزان، تتميز حركات الانهيارات الأرضية في منطقة خزان الخوانق الثلاثة بتشوه يشبه الخطوة، مما يجعل تنبؤات النزوح تظل بمنزلة تحديات.

الذكاء الاصطناعي قادر على تحليل هذه الخصائص المعقدة وغير الخطية جيداً، بإنشاء خريطة بيانات فيها ميزة الإدخال والنتائج النهائية للمخرجات. لقد أثبت الذكاء الاصطناعي قدرته على التعامل مع مجموعات البيانات عالية الأبعاد وواسعة النطاق من خلال توفير تنبؤات مرضية. غير أن الذكاء الاصطناعي، وهو نهج يعتمد على البيانات، يعتمد بشكل أقل على الخبرة والفهم الواضح للعمليات الفيزيائية. استناداً إلى أعمال المراجعة السابقة، يُستخدم الذكاء الاصطناعي على نطاق واسع في مجال الأخطار الجيولوجية. على سبيل المثال، كالانتار وآخرون، وشيا وآخرون

درسوا حساسية الانهيارات الأرضية باستخدام خوارزمية آلة ناقل الدعم (SVM)، وخوارزمية الانحدار اللوجستي (LR)، وخوارزمية الشبكة العصبية الاصطناعية (ANN). أما غربانزاده وآخرون، فاستخدموا تقييم تطبيق التعلم العميق (DL) في تحديد الانهيارات الأرضية.

استخدم تشانغ وآخرون، خوارزميات ML مثل شجرة القرار (DT) والغابة العشوائية (RF) لرسم خريطة قابلية الانهيار الأرضي. موسوي وآخرون، اقترحوا نموذج DL للكشف السيزمي المتزامن واختيار المرحلة. استخدم وو، وآخرون، خوارزميات الذكاء الاصطناعي مثل SVM لتقييم أخطار انهيار الأنفاق. شوبين وآخرون، اعتمدوا خوارزميات الذكاء الاصطناعي مثل التحليل التمييزي متعدد المتغيرات للتنبؤ بأخطار الانهيارات الجليدية. نفذ فالادي وآخرون، مراقبة ذكية للنشاط البركاني العالمي باستخدام تقنيات الذكاء الاصطناعي على صور الأقمار الصناعية متعددة الحواس من Sentinel-1. أدى التطور السريع لأبحاث الذكاء الاصطناعي في مجال الأخطار الجيولوجية إلى زيادة سريعة في عدد المنشورات حول هذا الموضوع.

وهذا ما يصعب على الباحثين والممارسين مواكبة أحدث المعلومات البحثية والحالة العامة للأبحاث في هذا المجال، مما قد يؤدي بسهولة إلى دراسات لا معنى لها ومتكررة. لحل هذه المشكلة، من الضروري إجراء تحاليل علمية، ومراجعة للحالة الراهنة للأبحاث الحديثة في هذا المجال.

وقد أجرى العديد من الباحثين في السابق دراسات مراجعة في هذا المجال. على سبيل المثال، قدم ديكشيت وآخرون، تحليلاً نوعياً لتطبيق الذكاء الاصطناعي في الأخطار الجيولوجية مع تسليط الضوء على اتجاه التطور في هذا المجال. حل هوانغ وآخرون، وميرغدي وآخرون، تطبيق DL في مجال تقييم قابلية الانهيارات الأرضية. قدم شيه وآخرون لمحة عامة عن تطبيقات وآفاق التعلم الآلي (ML) في مجال البحوث الزلزالية.

على الرغم من مساهماتها المهمة في تطوير هذا المجال، فإن هذه الدراسات المراجعة لها بعض القيود. معظم دراسات المراجعة هذه هي دراسات نوعية أو تقتصر على تطبيق ذكاء اصطناعي معين على نوع معين من الأخطار الجيولوجية؛ وبالتالي، هناك نقص في دراسات المراجعة الكمية والشاملة لتطوير الذكاء الاصطناعي في أبحاث الأخطار الجيولوجية. بالإضافة إلى ذلك، لا تتضمن دراسات المراجعة الحالية في هذا المجال تحليلاً لخصائص النشر للأوراق الموجودة، والمؤلفين الرئيسيين، والمؤسسات، والبلدان، أو الدراسات المتعلقة بتحديد الأبحاث الساخنة في هذا المجال. ولذلك، فإن دراسات المراجعة الحالية لا تقدم وصفاً شاملاً وموضوعياً للوضع الحالي لأبحاث الذكاء الاصطناعي في مجال الأخطار الجيولوجية.

يعد التحليل العلمي، الذي يشير إلى الدراسة الكمية للعلوم والتواصل في العلوم، واعدًا لمعالجة القيود المذكورة أعلاه لأنه يمكنه التعامل مع كميات كبيرة من المنشورات؛ وبالتالي تقديم تصور لشبكات البحث للعلماء الرئيسيين والمؤسسات والمقالات الأساسية والموضوعات البارزة. لذلك، تم تطبيق المراجعات العلمية على مجالات بحثية مختلفة. ومع ذلك، حتى الآن، لم تقم أي مراجعات سابقة بإجراء التحليل العلمي لأبحاث الأخطار الجيولوجية القائمة على الذكاء الاصطناعي بتحديد المصطلح البارز، واتجاه البحث ورسم خرائط الترابط.

لسد الفجوة في أبحاث التحليل الكمي في مراجعات الأخطار الجيولوجية وتعزيز التطوير، تُستخدم أساليب التحليل الكمي لتحليل وتلخيص تطور الذكاء الاصطناعي في أبحاث الأخطار الجيولوجية من عام 1990م إلى عام 2022م.

• التطبيق الأمثل

لقد تم تطبيق الذكاء الاصطناعي على نطاق واسع في أبحاث الأخطار الجيولوجية، مما حقق نجاحاً عظيماً. واستناداً إلى التحليل العلمي للأدبيات حتى الآن، يوصي الباحثون بمعالجة الجوانب التالية لأبحاث الأخطار الجيولوجية القائمة على الذكاء الاصطناعي.

■ إنشاء قاعدة بيانات مرجعية

تعتمد نمذجة الذكاء الاصطناعي على البيانات؛ ولذلك، فإن كمية ونوعية البيانات قد تؤثر بشكل مباشر على أداء الذكاء الاصطناعي. ومع ذلك، لا تزال هناك بعض القيود الأساسية للحصول على البيانات وإعدادها.

أولاً: التكلفة العالية لمعدات الرصد التي تحد من تغطية الرصد الميداني وتحد من وصول الباحثين إلى البيانات الميدانية عالية الجودة.

ثانياً: الافتقار إلى مجموعات بيانات كبيرة ومعقدة بشأن الأخطار الجيولوجية. على الرغم من نشر عشرات الآلاف من الأوراق البحثية لأبحاث الأخطار الجيولوجية القائمة على الذكاء الاصطناعي، إلا أنه من الصعب استخلاص واستخدام بيانات التدريب المتاحة والمنسقة والمصنفة بشكل مفتوح.

ثالثاً: استخدام الباحثين من مؤسسات مختلفة مجموعات بيانات وطرق بحث مختلفة لدراساتهم، مع اختلاف المصطلحات واكتمال البيانات في الأوراق البحثية كثيرًا.

وقد أدى كل ذلك إلى دعوات قوية من الباحثين لإنشاء قاعدة بيانات مرجعية، ومشاركة البيانات، وتوحيد تقارير البيانات التي ستكون بمنزلة دفعة مهمة لتطوير أبحاث الأخطار الجيولوجية القائمة على الذكاء الاصطناعي. وقد بدأ بعض الباحثين فعلاً العمل على تبادل البيانات. على سبيل المثال، جي وآخرون تمت مشاركة مجموعة بيانات كبيرة للانهييارات الأرضية (٦) <http://study.rsgis.whu.edu.cn/pages/download> (تم الوصول إليها في 4 أكتوبر 2022)، وتحتوي على صور الانهييارات الأرضية، ومعلومات عن حدودها، وبيانات DEM لمناطقها، وما إلى ذلك.

موسوي وآخرون ساهم بعدد كبير من مجموعات بيانات التحليل الزلزالي عالية الجودة (٦) <https://github.com/smousavi05/STEAD> (تم الوصول إليها في 4

أكتوبر 2022م)، والتي تحتوي على أشكال موجية زلزالية محلية، وأخرى للضوضاء الزلزالية، دون توفر إشارات زلزالية. يمكن استخدام مجموعات البيانات عالية الجودة المتاحة للجمهور، على أنها مجموعات بيانات مرجعية لتقييم أداء خوارزميات الذكاء الاصطناعي المختلفة في هذا المجال، وتوفير بيئة تقييم قابلة للتكرار.

وبالإضافة إلى ذلك، فإن قاعدة البيانات الأساسية الموحدة لا تزود الباحثين بمجموعات بيانات عالية الجودة فحسب، بل تسهل أيضاً عملهم في إدارة البيانات. لذلك، يرغب الباحثون في إنشاء قاعدة بيانات موحدة للأخطار الجيولوجية.

■ دمج الذكاء الاصطناعي مع العمليات الفيزيائية

توفر تقنيات الذكاء الاصطناعي أداءً جيداً في الأخطار الجيولوجية مثل تقييم قابلية الانهيارات الأرضية، وتحديد الزلازل، واختيار المرحلة، ومراقبة النشاط البركاني. ومع ذلك، لا يزال الباحثون والممارسون يواجهون تحديات في تعزيز الموثوقية.

ولتحسين موثوقية الذكاء الاصطناعي، حاول بعض الباحثين دمج الذكاء الاصطناعي والعمليات الفيزيائية لتجسيد قدرات معالجة البيانات القوية لتقنيات الذكاء الاصطناعي وموثوقية العمليات الفيزيائية في خوارزمية جامعة. على سبيل المثال، اقترح جيانغ وآخرون خوارزمية لتحسين المعرفة الجيولوجية للذكاء الاصطناعي. استخدم ديبينا وآخرون، خوارزمية لدراسة تدفق المياه الجوفية غير المشبعة باستخدام مزيج من الذكاء الاصطناعي والعمليات الفيزيائية. تم تعزيز الموثوقية بالاعتماد على مكونات تعتمد على البيانات لتحسين الأجزاء غير القابلة للتمثيل من العمليات الفيزيائية وتكامل تطور العمليات الفيزيائية في خوارزميات الذكاء الاصطناعي.

■ تعليم الآلة التلقائي

إن الإتقان القوي للمعرفة المتخصصة بأبحاث الأخطار الجيولوجية القائمة على الذكاء الاصطناعي مطلوبة جداً. يتكون سير العمل العام لنمذجة الذكاء الاصطناعي عادةً من المعالجة المسبقة للبيانات، وهندسة السمات، واختيار نموذج التعليم الآلي، وتحسين الملمات الفائقة المرتبطة بها.

يعد تقليل متطلبات المعرفة المتخصصة وأتمتة خطوات المعالجة جميعها، توقعاً شائعاً بين الباحثين. قدم بعض الباحثين منصات تعلم الآلة التلقائية التي تغلبت إلى حد ما على مشكلات اختيار الخوارزمية وتحسين الملمات الفائقة، مما يقلل الحاجة إلى الخبرة في خوارزميات الذكاء الاصطناعي. ومن الأمثلة على ذلك، التحديد الأمثل للملمات الفائقة باستخدام خوارزمية بايزي، واختيار السياسة التلقائية باستخدام تعلم التلوي وبنيات التكامل. ينفذ **Auto-WEKA** الاختيار التلقائي للخوارزميات وتحسين الملمات الفائقة استناداً إلى تقنيات التحسين الافتراضية. أثبتت منصات التعلم الآلي هذه قدرتها في مجالات الطب والميكانيكا وعلوم الأرض.

■ عدم اليقين الكمي

يقوم الذكاء الاصطناعي بتحليل بيانات الأخطار الجيولوجية عن طريق بناء نماذج مقابلة للتنبؤ بحدوث الأخطار الجيولوجية، وتقديم الأدلة والاقتراحات لمنعها والتخفيف من آثارها. في هذه العملية، قد تؤدي الريبة وعدم اليقين الموجود في البيانات والنماذج، إلى تحيز نتائج التحليل. يتم إنشاء الريبة في البيانات بسبب تداخل الفصل والضوضاء في بيانات التدريب، ولا يمكن الوصول إليه بسبب القيود المفروضة على كيفية جمع البيانات. تنتج الريبة المعرفية عن الأخطاء الناجمة عن الاستدلال النموذجي أو أداء النموذج.

مع الاستخدام الواسع للذكاء الاصطناعي في الأخطار الجيولوجية، أصبح تقييم صحة وموثوقية أنظمة الذكاء الاصطناعي أكثر أهمية قبل استخدام نتائج التحليل الخاصة بها. حالياً، يعد القياس الكمي الدقيق للريبة هو المفتاح لتعزيز موثوقية ودقة نتائج تحليل الذكاء الاصطناعي واتجاهه المستقبلي في مجال الأخطار الجيولوجية.

بدأ عدد قليل من الباحثين إجراء أبحاث حول القياس الكمي للريبة/ عدم اليقين. يمكن تقسيم الأساليب الأكثر شيوعاً إلى القياس الكمي لعدم اليقين بايزي الذي يركز على تحديد مجموعة التدريب لتقريب التوزيع الاحتمالي الخلفي، مثل مونت كارلو، وسلسلة ماركوف مونت كارلو، والتقدير الكمي لعدم اليقين الذي يحصل على دقة محسنة من خلال الجمع بين نماذج متعددة كالنماذج العميقة، ومجموعة و Dirichlet Deep Networks.

■ الذكاء الاصطناعي القابل للتفسير

لا تستطيع بعض خوارزميات الذكاء الاصطناعي تقديم تفسير معقول لنتائجها مما يجعل الباحثين والممارسين لا يثقون في النتائج التي يتم الحصول عليها من الذكاء الاصطناعي. وقد أدى ذلك إلى الحد من تطوير أبحاث الأخطار الجيولوجية القائمة على الذكاء الاصطناعي إلى حد كبير، وجذب اهتماماً متزايداً إلى الذكاء الاصطناعي القابل للتفسير. واستناداً إلى الدراسات السابقة، فإن طرق البحث لتفسير تقنيات الذكاء الاصطناعي تتضج، ويتم تنسيق المصطلحات والمقاييس، وهناك بعض التطور في تفسير الذكاء الاصطناعي وفي تقييم ذلك القابل للتفسير.

وتُستخدم حالياً بعض أساليب البحث الأولية لدراسة «الصناديق السوداء» الخاصة بالذكاء الاصطناعي، على سبيل المثال؛ تحليل مكونات النموذج إلى أجزاء صغيرة يمكن شرحها، وتصور أوزان النماذج المختلفة لتحسين إمكانية تفسير التعليم العميق للرصد الزلزالي واختيار المرحلة.

يجب أن تتضمن الأعمال المستقبلية التغلب على عقبات التطوير الناجمة عن عدم اليقين في أساليب التفسير الكمي للذكاء الاصطناعي، والتفسير السببي، والاعتماد على السمات، وغيرها من المشكلات (Jiang et al. 2023).

• كيف تعمل التحسينات في مراقبة الأرض والتعلم الآلي على إعادة تشكيل تقييم أخطار الأرض

مع زيادة عدد الأقمار الصناعية التي تصور الأرض وتزايد قوة المعالجة الحاسوبية، فإن عملية تقييم الأخطار الجيولوجية تنتقل من الأساليب الأرضية التقليدية إلى التقنيات التي تسمح بقدر أكبر من الدقة والدقة الزمنية وإمكانية الوصول. عندما تقول مصطلحات «الأخطار الأرضية» أو «الأخطار الجيولوجية»، قد تفترض أن أفضل طريقة لجمع البيانات وتقييمها هي من الدراسات على أرض الواقع.

كان هذا بطبيعة الحال هو القاعدة في معظم الأوقات التي كان العلماء يدرسون فيها العالم تحت أقدامنا، ولكن في العقود القليلة الماضية كان هناك تحول كبير في كيفية رؤية علماء الجيولوجيا للأخطار الطبيعية وتقييمها. إن استخدام عمليات الرصد الأرضية وحدها يأتي مع عدد من القيود، بما في ذلك إمكانية الوصول، والسرعة التي يمكن بها تغطية مناطق كبيرة، وعدم الاتساق بين المسوحات المختلفة.

بالنسبة للسمات واسعة النطاق؛ كالعيوب، أو المواقع النائية كبعض البراكين، فإن هذا يعني صعوبة تقييم الأخطار التي تشكلها بشكل كامل ودقيق. يمكن أن تغطي صور الأقمار الصناعية سمات؛ كالصدوع والبراكين والانهيارات الأرضية على نطاق عالمي، مما يسمح بالحصول على صورة أكثر اكتمالاً من عمليات الرصد الأرضية، ويوفر الوصول حتى إلى المواقع النائية أو غير المضيافة.

الصور مستقلة عن طرق المراقبة الأرضية، ومن مقارنة صور متعددة عبر الزمن باستخدام طرق مثل InSAR (رادار فتحة الأقمار الصناعية التداخلية) يمكن ملاحظة الحركة الأرضية، والتشوه على مدى نطاق من الفترات الزمنية.

يمكن أن تساعد المقارنة مع عمليات الرصد الأرضية على تحسين الدقة وحساب أخطاء الأجهزة، ويمكن أن يوفر الجمع بين المراقبة الأرضية والمراقبة عبر الأقمار الصناعية صورة أكثر اكتمالاً لسمات مثل؛ أنظمة الصدوع ومجمعات الصهارة. أحد الجوانب الأكثر إثارة لاستخدام صور الأقمار الصناعية لتحليل الأخطار الجيولوجية مؤخرًا، هو أن هناك تحسينات مستمرة في التردد والنوع والوفرة.

إن إطلاق الأقمار الصناعية مثل **Sentinel-1** يعني أنه أصبح من الممكن بشكل متزايد إجراء دراسة روتينية للأخطار البركانية والزلازل في المناطق النائية، والتي يتعذر الوصول إليها، ولكن هذا يأتي مع مجموعة من التحديات الخاصة به.

إن الكمية الهائلة من البيانات التي ينتجها **Sentinel-1** كبيرة جدًا، بحيث لا يمكن تحليلها يدويًا على نطاق عالمي، لذلك تم العمل على استخدام خوارزميات التعلم الآلي والشبكات العصبية التلافيفية (**CNN**) للكشف تلقائيًا عن البراكين والتشوهات الزلزالية المشتركة، وتمييزه عن الضوضاء الجوية.

يعد اكتشاف الانهيارات الأرضية خطرًا آخر يتم فحصه باستخدام مزيج من صور الأقمار الصناعية والتعلم الآلي، في محاولة لتقليل الموارد مثل؛ معرفة الخبراء والإشراف والعمل الميداني اللازم لطرق رسم الخرائط التقليدية. العمل الذي قام به غربانزاده وآخرون (**2019م**)، يستخدم البيانات البصرية من القمر الصناعي «**Rapid Eye**» لتحليل إمكانات عدد من أساليب التعلم الآلي مثل الشبكات العصبية التلافيفية (**CNNs**) للكشف عن الانهيارات الأرضية، وعلى الرغم من أن الورقة تخلص إلى أن هذه الطريقة لا تزال في مهدها، ويظهر بداية واعدة لاستخدام التعلم العميق في هذا المجال.

في الآونة الأخيرة، تبحث مسابقة **Landslide4Sense (L4S)** لعام **2022م** التي ينظمها معهد البحوث المتقدمة في الذكاء الاصطناعي (**IARAI**) في كيفية اكتشاف الانهيارات

الأرضية تلقائياً، باستخدام صور الأقمار الصناعية متعددة المصادر واسعة النطاق، والتي تم جمعها على نطاق عالمي، بالإضافة إلى أفضل أداء لخوارزميات التعلم العميق.

في سنة 2022م، كتب غريبانزاده وآخرون، مقالة تهدف إلى تعزيز البحوث متعددة التخصصات في هذا المجال، ودعوة الباحثين إلى تقديم المزيد من النتائج وتقييم دقة الأساليب المستخدمة على أمل تحسين نتائج الكشف عن الانهيارات الأرضية المبلغ عنها. ولكن لماذا يعتبر هذا الأمر مهماً لنا، وكيف تساهم شبكة أبحاث WTW؟ لقد كان لاستخدام الأقمار الصناعية لرصد الأخطار الجيولوجية تأثير على صناعة التأمين، وكذلك على الأوساط الأكاديمية، مع وجود كتالوج متزايد من البيانات يسمح بالتحليل الاحتمالي. ويمكن رؤية مثال على ذلك في الورقة التي كتبها بيغز وآخرون (2014م)، الذي يدرس الروابط بين التشوه البركاني والثوران، باستخدام كتالوج يضم 540 بركانا تم رصدها على مدى 3 سنوات.

استمر هذا العمل في الفوز بجائزة لويدز لندن، وكان جزءاً من مشروع أكبر قامت به مجموعة علم البراكين بجامعة بريستول وهيئة المسح الجيولوجي البريطانية. وشاركت هذه المنظمات في تطوير شبكة النموذج العالمي للبراكين (GVM) في عام 2011م، ووجدت أن ما لا يقل عن 80% من البراكين في العالم تفتقر إلى المراقبة الأرضية.

حددت أعمال جامعة بريستول في المسوحات الإقليمية والعالمية وتصحيحات الغلاف الجوي والتعلم الآلي تشوهاً نشطاً في أكثر من 25 بركاناً، كانت تُعد في السابق غير نشطة، وساهم هذا العمل في قيام مكتب الأمم المتحدة للحد من أخطار الكوارث بنشر تقرير التقييم العالمي للأخطار لعام 2015 (GAR15). مع النظر في الأخطار البركانية لأول مرة. تم عرض العمل الذي قامت به جامعة بريستول و GVM في المراجعة السنوية لعام 2016م. وقد تم وصف هذا العمل المتعلق بالعلاقة

بين قواعد البيانات العالمية بشأن الأخطار البركانية وتأثيراتها، إلى جانب ملفات تعريف الأخطار البركانية لجميع البلدان ذات البراكين النشطة ومقاييس الأخطار التي تم تطويرها لـ **GAR15**، بأنها «متطلبات البيانات الأساسية لبناء نماذج لاتخاذ القرارات المالية لصناعة التأمين». لقد أدى عمل بريستول إلى تطوير إمكانية نمذجة أخطار الانفجارات البركانية كثيرًا، ودعم التسعير الدقيق لوثائق التأمين القائمة على الأخطار.

المزيد من التحسينات على نطاق بيانات الأقمار الصناعية المتاحة، وطرق الكشف عن الصور ومعالجتها، تعني أنه يمكن مراجعة وثائق مثل **GAR15** لتوفير تحليل أكثر دقة للأخطار الاحتمالية لصناعات التأمين، وإعادة التأمين البارامترية.

يُعد العمل الإضافي في هذا المجال هدفًا رئيسًا لشبكة أبحاث **WTW** لعام **2023م**، متابعةً للشراكات السابقة مع جامعة بريستول و**GVM**. بالإضافة إلى البراكين والزلازل والانهيارات الأرضية، تم استخدام صور الأقمار الصناعية و**InSAR** والتعلم الآلي لتحسين فهم أخطار الأرض وتأثيرها على البيئة المبنية.

تم العمل على قياس وإعادة بناء الإزاحة الأرضية الناتجة عن تعدين الفحم في الصين، وذلك بالجمع بين معدلات التشوه المستمدة من كل من الأقمار الصناعية **TerraSAR-X** و**Sentinel-1**، واستخدام خوارزمية لمجموعة فرعية أساسية صغيرة (**SBAS-InSAR**). تسلط ورقة تشين وآخرون، الضوء على القيود الموجودة في طرق المسح الجيوديسي التقليدية، مثل التسوية الدقيقة، وقياس المحطة الإجمالية، والنظام العالمي لأقمار الملاحة الفضائية (**GNSS**)، بالإضافة إلى التقنيات التقليدية متعددة الزمن (**MTInSAR**).

في المملكة المتحدة، كانت الأبحاث تهدف إلى النظر في الهبوط والارتفاع المرتبط بتعدين الفحم، وسحب المياه الجوفية، والانهيارات الأرضية، وأعمال هندسة الأنفاق. وقد أثبت هذا أنه تطبيق أكثر تحديدًا لشبكات التعلم العميق مقارنةً بالأخطار والمواقع

التي تمت مناقشتها سابقاً، وذلك بسبب تشتت نقاط القياس ووجود الضوضاء وإشارات التشوه البطيئة، وعدم كفاية بيانات الحقيقة الأرضية لإنشاء مجموعة بيانات تدريب متوازنة.

لكن العمل المقدم في ورقة أنانتراسيريتشاي وآخرين، يقترح تحسينات للتمكن من اكتشاف كل من الهبوط والارتفاع الناتج عن الأنشطة البشرية، مما يدل على إمكانية تطبيق هذا الإطار المقترح لتطوير تحليل الحركة الأرضية الآلي. لا يتم استخدام رصد الأرض لتعزيز تحليل الأخطار فحسب، بل مكن من فهم أفضل للتنمية الحضرية والتعرض لها. فقد أدى العمل الذي قامت به مؤسسة نموذج الزلازل العالمية (GEM) إلى إنشاء إطار عمل للتنبؤ بالتوزيع المكاني للسكان، وتطوير المباني السكنية في كوستاريكا، باستخدام صور الأقمار الصناعية التاريخية، من أجل التنبؤ بالتعرض للأخطار الزلزالية.

تم إجراء عمل مماثل لتحليل نمذجة النمو الحضري، وتقييم مدى الضعف في وادي كاتماندو (نيبال) بالتعاون مع الأكاديميين في كلية لندن الجامعية، حيث أن التقدم الكبير في تقنيات الاستشعار عن بعد، والنمذجة المكانية قد تمكنت من إنشاء (من مجموعات البيانات المكانية في جميع أنحاء العالم)، مستوطنات بشرية يمكن استخدامها في نمذجة الأخطار الطبيعية. تسلط هذه المجموعة الواسعة من الأبحاث، التي تم إجراؤها خلال العقد الماضي، الضوء على أن جودة وتوافر بيانات رصد الأرض تتحسن باستمرار، ومع زيادة القوة الحسابية وتطوير خوارزميات التعلم الآلي للمساعدة في المعالجة والكشف، يساعد في إجراء تقييمات أكثر اكتمالا ودقة للأخطار ما لا يقدر بثمن بالنسبة لصناعة التأمين.

بالاستمرار في دعم العمل في هذا المجال من قبل الشراكات الأكاديمية، من المأمول أن يتم استخدام بيانات الأقمار الصناعية الجديدة وتطوير مسارات عمل موثوقة للكشف عن الأخطار الجيولوجية وقياسها، وحتى التنبؤ بها، بالإضافة إلى الأخطار التي تتعرض لها المناطق الحضرية النامية، (Dalziel, 2022).

تحليل البيانات الجيوفيزيائية بواسطة الذكاء الاصطناعي

الجيوفيزياء هي مجال يستخدم المبادئ والأساليب الفيزيائية لدراسة وتوصيف الأرض، من قلبها إلى سطحها. تمتد الجيوفيزياء الحديثة إلى الفضاء الخارجي، من الطبقات الخارجية للغلاف الجوي للأرض إلى الكواكب الأخرى. تتكون الطرق العامة للجيوفيزياء من مراقبة البيانات ومعالجتها والنمذجة والتنبؤ. الملاحظة هي وسيلة أساسية يستطيع الإنسان من خلالها فهم الظواهر الجيوفيزيائية غير المعروفة. تستخدم مراقبة البيانات بشكل أساسي تقنيات (غير جراحية) مثل: الموجات الزلزالية، ومجالات الجاذبية، والاستشعار عن بعد.

تقوم تقنيات معالجة البيانات، بما في ذلك تقليل الضوضاء وإعادة البناء، باسترجاع المعلومات المفيدة من الملاحظات الأولية. تساعد النمذجة الرياضية المبنية على القوانين الفيزيائية في توصيف الظواهر الجيوفيزيائية. توفر التنبؤات معلومات عن المجهول بناءً على البيانات والنماذج المعروفة. تُستخدم التنبؤات المكانية للكشف عن باطن الأرض، كما هو الحال في الجيوفيزياء الاستكشافية، التي تصور الخصائص الفيزيائية لباطن الأرض. توفر التنبؤات الزمنية الحالات التاريخية أو المستقبلية للأرض، كما هو الحال في التنبؤ بالطقس.

ومع تقدم معدات الاقتناء، تتزايد كمية البيانات الجيوفيزيائية المرصودة بسرعة عظيمة. تُعد كيفية استخدام مثل هذه الكمية الكبيرة من البيانات للمعالجة والنمذجة والتنبؤ مشكلة كبيرة. وقد يكون من المفيد حل جزء من الاختناقات بالطرق الجيوفيزيائية التقليدية. إذا أخذنا النمذجة مثالاً، فإن إحدى المهام الأكثر تحدياً في النمذجة هي توصيف الأرض بدقة عالية. ومع ذلك، هناك تناقض في الأساليب التقليدية التي تمنع الإنجاز المتزامن لكل من الدقة العالية ومجموعة مراقبة البيانات بشكل واسع بسبب قيود الأجهزة.

لذلك، يكاد يكون من المستحيل الحصول على نموذج عالي الدقة للأرض، سواء مكانياً أو زمانياً، لأن الأرض تتمتع بمقياس مكاني وزماني كبير جداً.

يمكن لمنشأة المحاكاة العددية لنظام الأرض في الصين، والتي تسمى **EarthLab** (Li, Bao, et al., 2019)، أن توفر على الأكثر دقة تبلغ 25 كم للغلاف الجوي و10 كم للمحيطات بناءً على جهاز حسابي عالي الأداء مع 15 P FLOPs (عمليات الفاصلة العائمة في الثانية). لتوضيح الاختناقات في المعالجة والتنبؤ، تُستخدم جيوفيزياء الاستكشاف مثلاً. تهدف الجيوفيزياء الاستكشافية إلى مراقبة باطن الأرض أو الكواكب الأخرى من خلال البيانات المجمعة على السطح، مثل المجالات الزلزالية ومجالات الجاذبية.

تتضمن العملية الرئيسة للاستكشاف الجيوفيزيائي المعالجة المسبقة والتصوير، حيث يعني التصوير التنبؤ بالبنيات تحت السطح. في مرحلة ما قبل المعالجة للإشارات الجيوفيزيائية، فإن أبسط افتراض فيما يتعلق بأشكال الطبقات تحت الأرض هو أن السجلات الزلزالية العاكسة تكون خطية في النواخذ الصغيرة. يقدر افتراض التشتت أن البيانات تكون متفرقة في ظل تحويلات معينة، مثل المجال المنحني أو مجالات التردد الزمني الأخرى (Mousavi, Langston, et al., 2016; Mousavi & Langston 2016, 2017).

كما يقدر افتراض الرتبة المنخفضة أن البيانات تكون ذات رتبة منخفضة بعد تحويل هانكل. ومع ذلك، فإن الافتراض الخطي المصمم مسبقاً أو افتراض التحويل المتشتت لا يتكيف مع أنواع مختلفة من البيانات الزلزالية وقد يؤدي إلى انخفاض جودة تقليل الضوضاء، أو جودة استيفاء البيانات ذات الهياكل المعقدة. في مرحلة التصوير الجيوفيزيائي، تُعد المعادلات الموجية أدوات أساسية للتحكم في حركات وديناميكيات انتشار الموجات الزلزالية. تقدم معادلات الموجات الصوتية أو المرنة أو اللزجة عدداً متزايداً من العوامل في معادلات الموجة، ويمكن لسجلات مجال الموجة التي تم إنشاؤها تقدير السيناريوهات الحقيقية بدقة.

ومع ذلك، ومع تزايد تعقيد المعادلة الموجية، يصبح التطبيق العددي لها معتبراً، وتزداد التكلفة الحسابية كثيراً بالنسبة للسيناريوهات واسعة النطاق.

يختلف التعلم الآلي (ML) عن الأساليب التقليدية القائمة على النماذج، وهو نوع من النهج القائم على البيانات الذي يقوم بتدريب نموذج الانحدار أو التصنيف من خلال رسم خرائط غير خطية معقدة مع معلمات قابلة للتعديل بناءً على مجموعة بيانات التدريب.

على مدى عقود من الزمن، تم اعتماد أساليب تعلم الآلة على نطاق واسع في العديد من التطبيقات الجيوفيزيائية، مثل جيوفيزياء الاستكشاف، وتوطين الزلازل، وتحليل أنماط الهزات الارتدادية، وتحليل نظام الأرض (Reichstein et al., 2019).

نُشرت مؤخراً مقالة مراجعة حول التعلم الآلي في علوم الأرض الصلبة في مجلة Science (2019). يتضمن الموضوع مجموعة متنوعة من تقنيات التعلم الآلي، بدءاً من الأساليب التقليدية، مثل الانحدار اللوجستي، وآلات ناقلات الدعم، والغابات العشوائية، والشبكات العصبية، إلى الأساليب الحديثة، كالشبكة العصبية العميقة والنماذج التوليدية العميقة.

في مجتمع تعلم الآلة، تعد الشبكة العصبية الاصطناعية (ANN) أحد نماذج الانحدار أو التصنيف التي تشبه الدماغ البشري، وتتكون من طبقات من الخلايا العصبية. إن الشبكة العصبية الاصطناعية التي تحتوي على أكثر من طبقة واحدة، أي الشبكة العصبية العميقة (DNN)، هي جوهر طريقة التعلم الآلي التي تم تطويرها مؤخراً، والتي تسمى التعلم العميق.

يشمل التعلم العميق بشكل أساسي الأساليب الخاضعة للإشراف وتلك غير الخاضعة للإشراف اعتماداً على ما إذا كانت المصنقات متاحة أم لا، على التوالي. تعمل الأساليب الخاضعة للإشراف على تدريب شبكة DNN من مطابقة المدخلات والتسميات، وعادةً ما تُستخدم لمهام التصنيف والانحدار.

تعمل الأساليب غير الخاضعة للرقابة على تحديث المعلومات عن طريق إنشاء تمثيل داخلي مدمج، ثم يتم استخدامها للتجميع أو التعرف على الأنماط. بالإضافة إلى ذلك، يحتوي التعلم العميق أيضاً على التعلم شبه الخاضع للإشراف، حيث تتوفر تسميات جزئية، والتعلم المعزز حيث توفر البيئة المصممة من قبل تعليقات الإنسان لـ **DNN**. لقد أظهرت عملية التعلم العميق إمكانية التغلب على القيود المفروضة على الأساليب التقليدية في مختلف المجالات. يتفوق أداء التعلم العميق على أداء الدماغ البشري في مهام محددة، مثل تصنيف الصور (5.1% مقابل 3.57% فيما يتعلق بأخطاء التصنيف الخمسة الأولى، (He et al., 2016)، وفي لعبة **Game of Go**.

أبدى المجتمع الجيوفيزيائي اهتماماً كبيراً بالتعلم العميق في السنوات الأخيرة. وتبين بعض الأوراق المنشورة، والمتعلقة بالذكاء الاصطناعي في اتحادين جيوفيزيائيين رئيسيين، وهما جمعية الجيوفيزياء الاستكشافية (**SEG**) والاتحاد الجيوفيزيائي الأمريكي (**AGU**). ويلاحظ نمو عظيم واضح في كلتا المكتبتين، بسبب استخدام تقنيات التعلم العميق. علاوة على ذلك، قدم التعلم العميق أيضاً العديد من النتائج العظيمة للمجتمع الجيوفيزيائي.

على سبيل المثال، في مجموعة بيانات الزلازل الأرضية في ستانفورد (**STEAD**)، تم تحسين دقة الكشف عن الزلازل إلى 100% مقارنة بدقة 91% لطريقة **STA/LTA** التقليدية (خارج قسمة متوسط الوقت القصير على متوسط الوقت الطويل) (Mousavi, Zhu, Sheng, et al., 2019, Mousavi et al., 2020). يمكن التعلم العميق توصيف الأرض بدقة عالية على نطاق واسع. ويمكن استخدامه لاكتشاف المفاهيم الفيزيائية مثل النظام الشمسي (مركزية الشمس).

• التطبيقات الجيوفيزيائية للتعلم العميق

الطريقة الأكثر مباشرة لتطبيق التعلم العميق في الجيوفيزياء هي نقل المهمات الجيوفيزيائية إلى مهمات الرؤية الحاسوبية، مثل تقليل الضوضاء أو التصنيف. ومع ذلك، في بعض تطبيقات الجيوفيزياء، تختلف خصائص المهام أو البيانات الجيوفيزيائية تمامًا عن تلك الخاصة بالرؤية الحاسوبية.

■ الاستشعار عن بعد

يعد الاستشعار عن بعد وسيلة مهمة لجمع البيانات والصور الجيوفيزيائية باستخدام أجهزة الاستشعار الموجودة في الأقمار الصناعية أو الطائرات. تتضمن صور الاستشعار عن بعد بشكل أساسي: الصور البصرية، والصور فائقة الطيفية، وصور الرادار ذي الفتحة الاصطناعية (SAR).

يمكن استخدام الصور الضوئية الملونة للأقمار الصناعية واسعة النطاق وعالية الدقة في الزراعة الدقيقة، وفي التخطيط الحضري. لمعالجة مشكلة اختلافات دوران الاعتراض، تم اقتراح شبكة CNN ثابتة الدوران للكشف عن كيانات في صور استشعار بصرية عن بعد عالية الدقة جدًا، حيث تم تقديم طبقة ثابتة الدوران من خلال فرض عينات التدريب قبل وبعد التدوير لمشاركة سمات الكيان نفسها. إن لم تكن التسميات دقيقة، يتم استخدام نهج تدريب من خطوتين؛ حيث يتم تهيئة CNN أولاً بواسطة العديد من البيانات المرجعية غير الدقيقة، ثم يتم تنقيحها على كمية صغيرة من البيانات المصنفة بشكل صحيح.

ولتحسين دقة الصورة كثيرًا، يتم استخراج خطوط الصورة باستخدام شبكة GAN لتحسين الحواف لإزالة أثر القطع والضوضاء بدقة فائقة. تحتوي صور أجهزة الاستشعار فائقة الطيف على معلومات طيفية غنية، بحيث يمكن التمييز بدقة بين فئات الغطاء الأرضي المختلفة. في السنوات الأخيرة، استكشفت العديد من الأعمال طرق التعلم العميق DL لتصنيف الصور فوق الطيفية.

للنظر في البنية الطيفية المكانية في آن واحد، يجب استخدام CNN ثلاثي الأبعاد، بدلاً من ثنائي الأبعاد، لاستخراج السمات الفاعلة للصور فوق الطيفية. تُعد السمات المستخرجة مفيدة لتصنيف الصور واكتشاف الأهداف، وهي تفتح آفاقاً جديدة للبحث المستقبلي. هناك وسيلة بديلة لاستكشاف العلاقات بين قنوات الطيف المختلفة؛ وهي استخدام RNN، الذي يعتبر وحدات البكسل الطيفية الفائقة بمنزلة مدخلات بيانات تسلسلية. تعمل أنظمة SAR على توسيع فتحة الرادار صناعياً لإنتاج صور عالية الدقة. يمكن أن يعمل نظام SAR في جميع الأحوال الجوية، وفي ظروف النهار والليل. يتم استخدام CNN لتصنيف الأهداف في صور SAR، مما يتجنب السمات المدخلة يدوياً، ويوفر دقة أعلى. للنظر في كل من معلومات السعة والمرحلة لصور SAR المعقدة، تم اقتراح CNN ذات القيمة المعقدة، لتصنيف صور SAR لمعالجة المدخلات ذات القيمة المعقدة.

■ الكشف عن بنية الأرض

يُعد فهم بنية الأرض مهمة صعبة جداً، لأن الملاحظات تقتصر بشكل أساسي على سطح الأرض. تنقسم الأرض تقريباً إلى الطبقات السطحية والقشرة والوشاح واللب ومن السطح الخارجي إلى الداخل. ومع ذلك، فإن البنيات والتراكيب التفصيلية للأرض وخصائصها مازال غير واضحة.

تم التنبؤ بالزلازل باعتبارها سمة مهمة للتربة، بدقة عالية من بيانات الأقمار الصناعية في العامين الأخيرين، مما يوضح إمكانات LSTM في التنبؤ الخلفي واستيعاب البيانات والتنبؤ بالطقس.

أما تحديد خاصية الصخور، فيتطلب الأمر بيانات CT ثلاثية الأبعاد، عالية الدقة، لكنها تؤدي إلى مجال رؤية صغير.

تم اقتراح **CycleGAN** للحصول على صور فائقة الدقة من صورة منخفضة الدقة، وذلك بالتدريب على مجموعة بيانات غير مقترنة. تم اكتشاف التشوه البركاني باستخدام **CNN** لتصنيف هامش التداخل في مخططات التداخل الملفوفة. وقد تم تقدير سمك القشرة الأرضية في شرق التبت وغرب نهر اليانغتسى بناءً على سرعات موجة رايلي السطحية.

تم التنبؤ بالحالة الحرارية لأوشحة الكواكب النموذجية المبسطة، بناءً على التعلم العميق **DL** بدقة **99%**، لكل من متوسط درجة حرارة الوشاح، ومتوسط تدفق الحرارة السطحي، مقارنة بالقيم المحسوبة.

■ موارد المياه

للمياه على الأرض تأثير كبير على النظم البيئية والكوارث الطبيعية. يمكن أن يساعد التعلم عن بعد في مواجهة العديد من التحديات الرئيسة في علوم المياه (Shen, 2018). يمكن للتعلم العميق **DL** التنبؤ بالتيارات الحلقية في المحيط عن طريق تعلم النمط في ارتفاع سطح البحر (**SSH**).


تم اقتراح **LSTM** للتنبؤ بـ **SSH** والحلقة الحالية في خليج المكسيك، في حدود 40 كيلومتراً، قبل حدوثها بتسعة أسابيع، (Wang, Zhuang, et al., 2019). ونظراً لمحدودية الذاكرة الحسابية، يتم تقسيم المنطقة محل الاهتمام إلى مناطق فرعية مختلفة. تقدم الأعمال الإضافية على إعادة بناء **SSH** مباشرة على مساحة كبيرة؛ مكانية وزمانية بناءً على بيانات قليلة العينات، باستخدام **CNN**. وباستخدام مراقبة المحطات الفضائية والساحلية في آن واحد، يمكن استخدام **GAN** لإعادة بناء **SSH** لبحر الشمال بأكمله.

يساعد **DL** أيضاً في تقدير حجم الجبل الجليدي في المنطقة القريبة من الساحل في القارة القطبية الجنوبية، والتي تغطي القارة القطبية الجنوبية بأكملها، لرصد ذوبان الجليد وارتفاع مستوى سطح البحر والغمر الساحلي، من أجل فهم أفضل للتغيرات الجغرافية المكانية والزمانية، وخصائص الفيضانات الساحلية.

بالإضافة إلى المحيطات، يتم تخزين المياه في أشكال مختلفة، مثل؛ البحيرات، والأنهار، والتساقط، والجليد. وقد وجد التعليم العميق DL أدواره في تقدير تخزين المياه الجوفية (Sun et al., 2019)، وتخزين المياه العالمي في الولايات المتحدة (Sun, Scanlon, et al., 2020)، وقياس عرض الأنهار بدقة فائقة، والتنبؤ بدرجة حرارة مياه البحيرات، والتنبؤ بتساقط الأمطار، والجريان السطحي، والتنبؤ باسترجاع بخار الماء من بيانات الاستشعار عن بعد.

■ علوم الغلاف الجوي

يقوم علم الغلاف الجوي بملاحظة؛ المناخ والطقس والظواهر الجوية والتنبؤ بها. إن المراقبة العالمية لمعلومات الغلاف الجوي في العالم أمر صعب، لأن الأرض كبيرة جداً، ومواقع أجهزة الاستشعار محدودة. اختار الباحثون خوارزمية الرسم المستندة إلى CNN، لإعادة بناء القيم المفقودة في مجموعات بيانات المناخ العالمي مثل؛ HadCRUT4 كما في الشكل الآتي.



تعيد نماذج الذكاء الاصطناعي بناء الانحرافات في درجات الحرارة مع العديد من القيم المفقودة، (Kadow et al., 2020).

تلوث الهواء يضر ببيئة الأرض وصحة الإنسان. استخدم الباحثون التعليم العميق **DL** لتقدير مستويات **PM2.5** أو **PM10** على مستوى الأرض، وذلك باستخدام ملاحظات الأقمار الصناعية وقياسات المحطات (Shen et al., 2018). ويساعد التعلم عن بعد أيضاً على تحسين دقة التنبؤ بالطقس، وهو ما يمثل تحدياً طويل الأمد في علوم الغلاف الجوي. تم التنبؤ بمسارات الأعاصير باستخدام شبكة **GAN** استناداً إلى صور الأقمار الصناعية.


تم إنتاج مسار مدته ست ساعات بمتوسط خطأ **95.6 كم**. تم تقدير تبريد درجة حرارة سطح البحر الناجم عن الإعصار المعتمد على التدفق بواسطة **DNN**، واستخدم لتحسين التنبؤات بالأعاصير.

■ علم الفضاء

يعد تقدير المعلومات الفضائية في العالم والتنبؤ بها من المهمات طويلة الأمد في علوم الفضاء. استخدم الباحثون شبكة **DNN** للتنبؤ بكثافة الإلكترونات الديناميكية ثلاثية الأبعاد، قصيرة وطويلة المدى في الغلاف المغناطيسي الداخلي. يمكن لهذه الشبكة الحصول على كثافة بلازما الغلاف المغناطيسي في أي وقت ولأي مكان. يتم استخدام **GAN** المنتظم لإعادة بناء خرائط المحتوى الإلكتروني الإجمالي الديناميكي (Chen et al., 2019) (TEC). وقد تم استخدام العديد من الخرائط الموجودة كمراجع لاستكمال القيم المفقودة في بعض المناطق، مثل المحيطات.

يمكن أيضاً التنبؤ بخرائط **TEC** لما قبل ساعتين باستخدام **LSTM** (Liu et al., 2020) أو قبل يوم واحد باستخدام **GAN** (Lee et al., 2021). علاوة على ذلك، يتم استخدام **DNN** لتقدير العلاقة بين درجة حرارة الإلكترون وكثافته في المناطق الصغيرة. ولذلك، يمكن قياس كثافة الإلكترون العالمية بسهولة، واستخدامها للتنبؤ بدرجة حرارة الإلكترون العالمية. كما يمكن التنبؤ بالعواصف المغناطيسية الأرضية باستخدام **LSTM**، مع تقدير الريبة/عدم اليقين، مما يوفر الثقة في المخرجات.

الشفق القطبي هو ظاهرة فلكية تُلاحظ عادة في المناطق القطبية. ويحدث الشفق القطبي نتيجة اضطرابات في الغلاف المغناطيسي ناجمة عن الرياح الشمسية. التصنيف الشفقي مهم لأبحاث الرياح القطبية والشمسية. استخدم الباحثون **DNN** لتصنيف الصور الشفقية كما في الشكل الآتي. ويمكن أيضاً استخدام نتائج التصنيف لإنتاج توزيع حدوث الشفق القطبي. للتعامل مع الموقف الذي تم فيه شرح الصور المحدودة، تم استخدام نموذج **CycleGAN** لاستخراج الهياكل المحلية الرئيسة من الصور الشفقية للسماء بأكملها، (Yang et al., 2019).



تُظهر اللوحة السفلية مخططاً بيانياً من البيانات الشفقية التي تم جمعها في 21 يناير 2006 في مدخل رانكين Rankin Inlet. يتكون الكيوغرام Keogram من عمود واحد من الصور الشفقية في أوقات مختلفة. تُظهر اللوحة الوسطى احتمالات الفئات الست كما تنبأ بها مصنف التلال الذي تم تدريبه باستخدام مجموعة بيانات التدريب بأكملها. توجد في الأعلى صور شفقية في أوقات مختلفة، (Clausen & Nickisch (2018).

دور الذكاء الاصطناعي في تصنيف الصخور والمعادن

يعد تصنيف الصخور والمعادن جزءاً حيوياً من هندسة التعدين، والذي يمكن استخدامه لاستكشاف ورسم خرائط التوضعات المعدنية، وتقييم وتحسين طرق معالجة المعادن واستخراجها، وتقييم وإدارة الآثار البيئية والاجتماعية لأنشطة التعدين، وحتى تعزيز المعرفة الجيولوجية بالتعدين.

باستخدام التعلم الآلي، يمكن أتمتة عملية التصنيف مع زيادة دقتها وكفاءتها. كما يمكن اكتشاف أنماط ورؤى جديدة من البيانات المختلفة. طبعاً، قبل التمكن من تطبيق التعلم الآلي لتصنيف الصخور والمعادن، يُحتاج إلى جمع البيانات وإعدادها.

يمكن الحصول على البيانات؛ من الاستشعار عن بعد، ومن صور الأقمار الصناعية ومن المسوحات الجيولوجية، ومن أخذ العينات الميدانية ومن التحليل المخبري، ومن التحليل الطيفي، ومن سجلات الحفر الأساسية، ومن المسح الضوئي. ومن الضروري التأكد من أن البيانات موثوقة ومتسقة، وتمثل المنطقة والأهداف التي وضعت لها.

بالإضافة إلى ذلك، يُحتاج إلى المعالجة المسبقة للبيانات وتحويلها للتعلم الآلي. يتضمن ذلك تنظيف وتنقية الضوضاء والقيم المفرطة، وتطبيع القيم الرقمية، وترميز المتغيرات الفئوية، وتقليل الأبعاد، واختيار السمات ذات الصلة.

الخطوة التالية؛ هي اختيار نموذج التعلم الآلي وتدريبه لتصنيف الصخور والمعادن. يمكن استخدام نماذج التعلم الخاضعة أو غير الخاضعة أو شبه الخاضعة للإشراف، مثل؛ الانحدار اللوجستي، أو أشجار القرار، أو الشبكات العصبية، أو وسائل k ، أو التجميع الهرمي، أو نماذج الخليط الغاوسي.

لقياس أداء النموذج، يمكن استخدام مقاييس محددة؛ كالدقة والإحكام والاستدعاء ودرجة $F1$. كما يمكن أيضاً تحسين هذا النموذج باستخدام التحقق المتبادل، أو ضبط المعلومات الفائقة، أو هندسة السمات.

يُعد تقسيم البيانات إلى مجموعة تدريب ومجموعة التحقق من الصحة أمراً ضرورياً لتدريب النموذج وتقييمه. تتضمن هندسة السمات إنشاء سمات جديدة أو تعديل السمات الموجودة لتحسين أداء هذا النموذج.

الخطوة الأخيرة؛ وهي اختبار ونشر نموذج التعلم الآلي الخاص بالباحث لتصنيف الصخور والمعادن عملياً. للقيام بذلك، يجب استخدام مجموعة فرعية منفصلة من البيانات، تسمى مجموعة الاختبار، والتي لم يتم استخدامها للتدريب أو التحقق من الصحة.

ثم تُقارن نتائج النموذج السابق بالتسميات الفعلية للبيانات لتقييم تعميمها وقوتها. هناك عدة طرق لنشر النموذج الأخير، مثل حفظه وتحميله بتنسيق ملف مثل **Pickle** أو **JSON** أو **HDF5**؛ وتصديره واستيراده باستخدام تنسيق قياسي مثل **ONNX** أو **PMML** أو **TensorFlow Lite**؛ وإنشائه ونشره باستخدام منصة سحابية مثل **AWS** أو **Azure** أو **Google Cloud**؛ أو دمجها وتضمينها مع واجهة برمجة التطبيقات (**API**) مثل **REST** أو **SOAP** أو **GraphQL**.

بالإضافة إلى ذلك، يُحتاج إلى مراقبة هذا النموذج وتحديثه بانتظام لضمان الموثوقية والملاءمة، بالإضافة إلى معالجة أي مشكلات أو تعليقات من المستخدمين.

تم استخدام التعلم الآلي لتصنيف الصخور والمعادن في أمثلة وتطبيقات مختلفة، مثل تحديد الوحدات الصخرية، والأحداث المعدنية باستخدام بيانات الاستشعار عن بعد، وتمييز وقياس درجات الخام والمراحل المعدنية باستخدام بيانات الحفر الأساسية، والتنبؤ باسترداد المعادن وجودتها باستخدام البيانات العملية، واكتشاف وتخفيف الأخطار البيئية والاجتماعية باستخدام بيانات التأثير.

يمكن أن تساعد هذه التقنية القوية على تحسين المهارات ونتائج هندسة التعدين بتوفير حلول أسرع وأكثر ذكاءً وأكثر دقة لتصنيف الصخور والمعادن، (Zarei, 2024).

• الذكاء الاصطناعي لتصنيف المعادن والصخور الفضائية

عمل الباحثون على تطوير نظام ذكي لفهم البيانات (IDU)، يستخدم الشبكات العصبية لتصنيف المعادن والصخور. سيؤثر IDU على المسوحات الجيولوجية التي تجريها المركبات الفضائية الجوالة أو رواد الفضاء؛ والتي تسعى إلى اكتشاف البصمات الحيوية، واستخراج الموارد، وتحليل أسطح الكواكب وأقمارها أو البيئات النائية والقاسية على الأرض. وقد استخدم الباحثون الإدراك الحسي متعدد الطبقات (MLP)، ونوعاً جديداً من الشبكات العصبية التلافيفية، يُسمى «الشبكة العصبية النموذجية» (MNN). إن تطبيع كل طيف محلياً، عن طريق ضبط أعلى قمة على 1، يفسر اختلافات شدة تشتت رامان.

أخذ المشتق الأول للكثافة فيما يتعلق بحسابات Wavenumber لتغيرات إزاحة خط الأساس. يؤدي ضغط الأطياف باستخدام تحليل المكونات الرئيسية (PCA) إلى تخفيف مشكلات الأبعاد العالية. قام IDU بالتمييز بين تسعة معادن رئيسية تكون الصخور، وهي: الكوارتز، والفلسبار البوتاسي، والبلاجيوكلاز، والميكا، والزيبرجند الزيتوني، والبيروكسين، والجبس، والكربونات، والهاليت. صنفت الطرق السابقة المعادن الستة الأولى باستخدام أطياف رامان 852 نانومتر بدقة 83%، وأطياف الأشعة تحت الحمراء بدقة 80%.

استخدمت أحدث أساليب MNN لدمج المعلومات من مصدرين لإثارة رامان: 532 نانومتر و785 نانومتر. باستخدام هذه الأطياف، قام الذكاء الاصطناعي بتمييز المعادن التسعة بدقة 95%، متفوقاً على شبكات MLP وغيرها من الشبكات التي تم اختبارها، والتي تستخدم مصدراً واحداً للإثارة. بالإضافة إلى ذلك، تم تطبيق مرشحات غابور لالتقاط الأنماط الجيبية التي تظهر في نسيج الصخور ولونها. تمكن MLP من استخدام هذه المعلومات لتصنيف عينات الصخور النارية إلى فلسية أو ماافية أو متوسطة بدقة تصل إلى 91% (Johnsen, & Gulick, 2019).

• تصنيف المعادن باستخدام التعلم الآلي وصور شرائح رقيقة مجهرية من الصخر

إن الطريقة الأكثر استخداماً لتصنيف نوع المعدن من شريحة صخرية رقيقة، تتم من مراقبة الخصائص البصرية أثناء دوران المجهر المستقطب. تقترح العديد من الدراسات تطبيق تقنيات معالجة الصور الرقمية والشبكات العصبية لأتمتة هذه المهمة. تستخدم هذه الدراسة تقنيات تعلم آلي أبسط وأكثر قابلية للتطوير، كونها أقرب جار وشجرة قرار، وتضيف خصائص بصرية جديدة يمكن استخلاصها من الصور الرقمية.

وقد استخدم الباحثون مجموعتي بيانات، واحدة مقدمة من جامعة فردوسي في مشهد (إيران)، تحتوي على 17 معدناً مختلفاً، والأخرى تم إنشاؤها من الصفر في قسم الجيولوجيا بجامعة بيلوتاس الفيدرالية (البرازيل)، وتحتوي على 4 معادن مختلفة. تتكون مجموعات البيانات من صور معدنية تم التقاطها تحت الضوء المستقطب المتقاطع والمستوي، من شرائح رقيقة من صخور مختلفة. بالنسبة لكل مجموعة بيانات مستخدمة، أخذ زوج من الصور للمعدن نفسه تم التقاطها بأضواء مختلفة، واستخرجت الخصائص البصرية للون والنسيج، وطبقت خوارزمية التعلم الآلي ومن ثم قدمت النتائج.

في نهاية هذه الدراسة، أثبت الباحثون أنه من الممكن تحقيق دقة عالية مثل الشبكات العصبية باستخدام خوارزميات تعلم الآلة الأكثر بساطة، حيث أظهرت مجموعة البيانات في بيلوتاس نتائج متوسطة تصل إلى 97 %، وفي مشهد تصل إلى 93 % (Pereira

(Borges & de Aguiar, 2019)

• التصنيف الآلي للأحجار الكريمة باستخدام الرؤية الحاسوبية

يعد التصنيف الدقيق للأحجار الكريمة أمراً بالغ الأهمية لتجارة الأحجار الكريمة والمجوهرات، حيث يعد التحديد خطوة أولى مهمة في تقييم وتقدير أي جوهرة. حالياً، يتم تحديد هوية الحجر الكريم باستخدام مزيج من المراقبة البصرية والتحليل الطيفي الكيميائي. ومن المراقبة الدقيقة للأحجار الكريمة بالعين المجردة،

وتحت التكبير، يكتشف علماء الأحجار الكريمة مختلف الخصائص البصرية، مثل؛ اللون، والشفافية، والبريق، والمكسر، وأسطح الانقسام، والشوائب، وتعدد الألوان الظاهرة والانكسار المزدوج لتسهيل تمييز الأحجار الكريمة. وهي عملية صعبة، حيث أن العديد من الأحجار الكريمة تشترك في اللون والخصائص، كما هو موضح في الشكل الآتي، الذي يعرض عينة مكونة من 500 جوهرة موزعة على 87 فئة مختلفة. غالبًا ما يكون التحديد والتصنيف مصحوبًا باستخدام أدوات علم الأحجار الكريمة، والتي تشمل أجهزة؛ قياس الانكسار، ومجاهر الاستقطاب، والمنظار الطيفي المحمول، ومنظار الديكروسكوب، والأشعة فوق البنفسجية لاستكشاف الخصائص البصرية للأحجار الكريمة.

يوفر قياس الخصائص الفيزيائية مثل الثقل النوعي (المعروف أيضًا بالكثافة النسبية) معلومات إضافية تتعلق بهوية الحجر الكريم. مع ظهور الأحجار الكريمة الاصطناعية الجديدة وتقنيات المعالجة، تم إدخال أدوات معقدة بشكل متزايد ذات قدرات التحليل الطيفي أو الفلورسنت أو التحليل الكيميائي القوية في مختبرات علم الأحجار الكريمة.



خمسائة صورة للأحجار الكريمة مختارة من سبعة وثمانين فئة مختلفة، من الألمندين إلى الزوسيت. الصور مرتبة حسب اللون لتوضيح صعوبة التعرف على الأحجار الكريمة بالفحص البصري، (Chow & Reyes, 2022).

وتشمل هذه الأجهزة مقاييس طيف الأشعة تحت الحمراء، ومقاييس طيف رامان، ومقاييس الطيف فوق البنفسجي المرئي، والتألق الكاثودي، ومقاييس طيف الأشعة السينية مشتتة الطاقة، ومطياف كتلة البلازما المقترنة حثياً بالليزر، ومقاييس طيف التألق.

ومع ذلك، لا يزال تحديد الهوية صعباً ويستغرق وقتاً طويلاً، ولا تستطيع جميع المختبرات الوصول إلى هذه الأدوات المتطورة؛ وبالتالي، فإن تحديد الهوية من خلال التقنيات التلقائية التي تعتمد فقط على الصور يعد أمراً جذاباً.

في السنوات الأخيرة، تطورت أجهزة الحاسوب والخوارزميات كثيراً، وأصبحت مهمة معالجة الصور والرؤية الحاسوبية شائعة في العديد من المجالات، مثل؛ التصوير الطبي والتصنيع والأمن. في العلوم الجيولوجية، تم تطوير خوارزميات الرؤية الحاسوبية لتصنيف الحبيبات المعدنية والصخور.

قسم الباحث طومسون وآخرون (2001)، الشرائح الرقيقة المجهرية باستخدام الحواف، وحقت دقة اختبار تصل إلى 93.53% عند تصنيف 10 معادن مختلفة باستخدام شبكة عصبية اصطناعية مدربة على سمات اللون والنسيج المستخرجة.

من المحتمل أن تكون الدقة المبلغ عنها مبالغاً فيها، حيث تم استخدام أمثلة البيوتيت نفسها للتدريب والاختبار. قام بايكان ويلمز (2010) بتطوير شبكة عصبية اصطناعية لفصل خمسة معادن باستخدام قيم البكسل الأحمر والأخضر والأزرق (RGB) في شرائح رقيقة مجزأة يدوياً كمداخلات، وحققا دقة قدرها 89.53%. اليزادي وآخرون (2017)، استخدموا شرائح رقيقة مجزأة باستخدام المجموعات الإضافية، وتم تصنيف المعادن باستخدام نهج متسلسل.

تم استخدام شبكة عصبية اصطناعية لأول مرة للتمييز بين 23 نوعاً من المعادن والزجاج بناءً على ألوان البكسل، وتم تمرير فقط تلك المعادن التي تظهر ألواناً

متشابهة تحت الضوء المستوي والمتقاطع إلى شبكة عصبية اصطناعية ثانية لتحليل الألوان والنسيج المتزامن.

وأدى ذلك إلى دقة إجمالية قدرها **93.81%**. أثبت بورخيس ودي أغيار (2019) أن خوارزميات التعلم الآلي البسيطة، أقرب جار **K-Nearest Neighbor** وشجرة القرار، كانت قادرة على تصنيف المعادن في شرائح مجهرية رقيقة بناءً على اللون والنسيج بمتوسط دقة مرتفع يتراوح بين **94.11 - 97.71%**، باستخدام مجموعتي بيانات ذات أربعة، وسبعة عشر نوعاً من المعادن.

قام مايتر وآخرون (2019)، بتقسيم الصور المجهرية التي تحتوي على ثمانية أنواع معدنية وخلفية عن طريق مجموعات تكرارية خطية بسيطة وتصنيفها باستخدام ثلاث خوارزميات للتعلم الآلي، وهي **K-Nearest Neighbor**، و **Random Forest**، و **Decision Tree**، استناداً إلى سمات الألوان في **RGB** وقيمة **(HSV)** و **Hue-Saturation**، ومساحة **CIELAB**.

أنتجت خوارزمية **Random Forest** أعلى دقة تبلغ **82%**. قام زانك وآخرون، (2019) بالتحقيق في تصنيف أربعة معادن باستخدام ستة خوارزميات مختلفة، وهي الانحدار اللوجستي، وآلة ناقل الدعم، و **Random Forest**، و **K-Nearest Neighbor** أقرب جار **K**، و **Perseptron** متعدد الطبقات، و **Naive Bayes**، باستخدام السمات المستخرجة من الصور المجهرية باستخدام **Inception-v3**. تم تحديد آلة دعم المتجهات باعتبارها الخوارزمية الوحيدة التي تحقق أعلى دقة (**90.6%**). أدت آلات ناقل الدعم والانحدار اللوجستي ونماذج الإدراك متعدد الطبقات إلى تحسين الدقة بنسبة **0.3%**.

على الرغم من قوة أنظمة الرؤية الحاسوبية في التعرف على المعادن، إلا أنه لم يتم الإبلاغ مؤخرًا إلا عن دراسة واحدة فقط حول التعرف التلقائي على صور الأحجار الكريمة، بناءً على أحد المؤلفين.

تم تحقيق دقة لكل فئة بنسبة 75-100% لتصنيف صور الياقوت والياقوت الأزرق (الزفير) والزمرد غير المرئية استناداً إلى قناة Hue في مساحة الألوان HSV، باستخدام شبكة عصبية اصطناعية. تجدر الإشارة إلى أن الياقوت والزفير الأزرق Sapphire والزمرد Emerald لها ألوان مميزة جداً، وبالتالي يسهل تمييزها عن بعضها البعض نسبياً، وهو أسهل بكثير من الأحجار الكريمة ذات الألوان المماثلة مثل التوباز والأكوامارين.

ركزت أبحاث الرؤية الحاسوبية الأخرى في الغالب على تقييم الأحجار الكريمة والتعرف عليها. تم تطوير أنظمة رؤية حاسوبية قوية لتصنيف ألوان العنبر والجاديت Jadeite والأوبال واللؤلؤ. اقترح زانك وغو (2021م) نظاماً يمكن تطويره ليصبح أداة لقياس لون الأحجار الكريمة، (Chow & Reyes-Aldasoro, 2022).

• تصنيف المعادن النارية الشائعة

لقد انتشرت استكشافات التركيبات المعدنية التي تهدف إلى الكشف عن العمليات الصهارية المعقدة أثناء الانصهار مع تزايد إمكانية الوصول إلى مجموعات البيانات الجيوكيميائية، من قواعد البيانات بما في ذلك PetDB وLEPR/TraceDs وGEOROC والأساليب الحسابية.

يتطلب إنشاء البيانات المعدنية وضمان جودتها بشكل مستمر في قواعد البيانات هذه تدخلاً بشرياً كبيراً، ومعالجة فردية بعد المعالجة. إحدى المشكلات الرئيسية هي أن المعادن قد يتم تصنيفها بشكل خاطئ (على سبيل المثال، مجموعة بيانات مجمعة من الكالينوبيروكسينات قد تحتوي على بعض الأمفيبولات)، وقد تحتوي المجموعات على تحليلات رديئة الجودة للمسبار الإلكتروني الدقيق (EPMA) مع مجاميع منخفضة، أو مجاميع كاتيونية منخفضة، أو مراسلات ضعيفة مع القياس الكيميائي النظري للمرحلة المعدنية).

في الوقت الحالي، تميل الدراسات الفردية التي تجمع مجموعات البيانات الجيوكيميائية لإعدادات تكتونية محددة أو معايرة المقاييس الحرارية بناءً على توازن انصهار المعادن إلى تطبيق المرشحات الخاصة بها.

من خلال الدفع باتجاه اتباع نهج أكثر اتساقًا، يمكن إنشاء حزمة **Python** جديدة مفتوحة المصدر تسمى **MIN-ML** (تصنيف المعادن باستخدام التعلم الآلي) لتصنيف المعادن النارية الشائعة، بناءً على بيانات الأكاسيد التي تم جمعها بواسطة **EPMA**، مع وظائف لحساب العناصر المتفاعلة والمواقع البلورية بناءً على هذا التصنيف.

يسمح استخدام هذه الحزمة بتحديد المراحل المعدنية المصنفة بشكل خاطئ، والبيانات ذات الجودة الرديئة. نقوم بتبسيط معالجة البيانات وتنظيفها للسماح بالانتقال السريع إلى البيانات القابلة للاستخدام، وتحسين فائدة البيانات المنسقة في قواعد البيانات هذه، وتعزيز قدرات الحوسبة والنمذجة.

بينما تحديد المعادن وتصنيفها أمرٌ بالغ الأهمية لنجاح المنهجيات الحسابية والتعلم الآلي (**ML**) المطبق على مجموعات البيانات الكبيرة هذه، فإن مسألة كيفية تصنيف المعادن على أفضل وجه من تحليلات **EPMA** تأتي في المقدمة.

نحن نتعامل مع هذه المسألة باستكشاف وتطوير سير عمل تعلم الآلة، سواء الخاضع للإشراف (خوارزميات التصنيف) أو غير الخاضع للإشراف (تقليل الأبعاد والتجميع). توفر الأساليب غير الخاضعة للرقابة، بما في ذلك أجهزة التشفير التلقائي، وهي نوع من الشبكات العصبية الاصطناعية، الفرصة لتصنيف المعادن مع القليل من المعلومات المسبقة.

تعمل أجهزة التشفير التلقائي على ربط شبكتين عصبيتين مع جهاز تشفير، مما يؤدي إلى ضغط بيانات الإدخال إلى تمثيل كامن مخفض الأبعاد، ووحدة فك ترميز، مما يؤدي إلى توسيع التمثيلات الكامنة لإعادة بناء المدخلات وتقليل الخسارة.

هناك نموذج جديد للتشفير التلقائي يهدف إلى تمثيل تحليلات EPMA بشكل هادف للمعادن في الفضاء الكامن، والتحقق من العلاقات بين المراحل المعدنية، وإجراء تصنيفات لهذه المعادن.

تم تدريب هذا النموذج باستخدام مجموعات البيانات الم جمعة حديثاً، والمكونة من اثنتي عشرة مرحلة معدنية نارية على آلاف إلى عشرات الآلاف من التحليلات لكل مرحلة؛ عبر الإعدادات التكنونية لتدريب نماذج التعلم الآلي هذه.

يتم تطبيق جهاز التشفير التلقائي على مجموعات بيانات التحليلات المعدنية من PetDB و LEPR و GEOROC لتقييم أداء النموذج وإظهار تحسينات كبيرة في فصل وتصنيف الطور المعدني، وهو أمر بالغ الأهمية لمراقبة جودة مجموعة البيانات الصارمة، والتكامل المستقبلي في إجراءات معالجة البيانات (Shi, et al., 2023).

• تصنيف جسيمات الرماد البركاني

يوفر الرماد البركاني أجزاء فريدة من المعلومات التي يمكن أن تساهم في فهم التقدم المحرز في النشاط البركاني في المراحل المبكرة من الاضطرابات والتحوللات المحتملة نحو أنماط الثوران المختلفة.

يحتوي الرماد على أنواع مختلفة من الجزيئات التي تدل على أنماط الثوران والعمليات المتعلقة بصعود الصهارة. ومع ذلك، فإن تصنيف جزيئات الرماد إلى مكوناته الرئيسية ليس بالأمر السهل.

تختلف الملاحظات التشخيصية اعتماداً على تكوين الصهارة وأسلوب الثوران، مما يؤدي إلى الغموض في تخصيص جسيم معين لفئة معينة. علاوة على ذلك، لا توجد منهجية موحدة لتصنيف الجسيمات، وبالتالي قد يستنتج المراقبون المختلفون تفسيرات مختلفة. ومن أجل المساعدة في تحسين هذا الوضع، تم إنشاء منصة على شبكة الإنترنت بعنوان (Volcanic ash DataBase (VolcashDB).

تحتوي قاعدة البيانات هذه على أكثر من 6300 صورة متعددة التركيز، عالية الدقة لجزيئات الرماد، كما تُرى تحت المجهر من مجموعة واسعة من تركيبات الصهارة وأنماط الثوران.

وقد استخرج الباحثون كمًّا واسعًا من سمات متعددة من؛ الشكل والنسيج واللون في كل صورة جسيمية، وتم تصنيف كل جسيم من الناحية الصخرية إلى واحدة من الفئات الأربع الرئيسة: البلورة الحرة، والمواد المتغيرة، والمواد الحجرية، والأحداث.

برنامج **VolcashDB** متاح للعامة، ويمكن المستخدمين من التصفح والحصول على الملخصات المرئية، وتنزيل الصور مع التصنيفات المقابلة لها، وبالتالي يمكن استخدامها في الدراسات المقارنة. كما يمكن استخدام الصور المصنفة لتدريب نماذج التعلم الآلي على تصنيف الجسيمات تلقائيًا وتقليل تحيزات المراقب، (Benet, et al., 2023).

الذكاء الاصطناعي في مجال صناعة النفط والغاز

لقد دخل الذكاء الاصطناعي (AI)، باعتباره أهم تكنولوجيا للأغراض العامة اليوم، الصناعات بسرعة، مما خلق إمكانات كبيرة للابتكار والنمو، وفي مجالات الرعاية الصحية، والنقل، وتجارة التجزئة، والإعلام، والتمويل.

أحدث الذكاء الاصطناعي تغييرات جوهرية وغير قواعد المنافسة. فبدلاً من الاعتماد على العمليات التجارية التقليدية التي تركز على الإنسان، تقوم الشركات في هذه الصناعات بإنشاء قيمة باستخدام حلول الذكاء الاصطناعي.

إن الخوارزميات المتقدمة المدربة على مجموعات البيانات الكبيرة والمفيدة، والتي يتم تزويدها باستمرار ببيانات جديدة، هي التي تقود عملية إنشاء القيمة. هذه هي الطريقة التي تحارب بها **Gero.ai** فيروس كورونا، وتحدد أمازون أسعار المنتجات التي تقدمها، ويعطي **InboxVudu** الأولوية للبريد الإلكتروني، وتحرك **Yandex** السيارات (ذاتية القيادة).

ومع ذلك، لا تستفيد الشركات من الصناعات الرقمية من الذكاء الاصطناعي فحسب، ولكنها أصبحت أيضاً تعتمد بشكل متزايد على حلول الذكاء الاصطناعي، وعلى الرغم من أن التطبيقات الأولى للذكاء الاصطناعي في صناعة النفط والغاز قد تم النظر فيها في السبعينات من القرن الماضي، إلا أن الصناعة بدأت في البحث بشكل استباقي عن فرص تطبيق الذكاء الاصطناعي منذ عدة سنوات.

يتزامن ذلك مع النمو الهائل لقدرات الذكاء الاصطناعي وتحرك الصناعة نحو مفهوم النفط والغاز، الذي يتمثل هدفه الأساسي في تحقيق قيمة أعلى باستخدام التقنيات الرقمية المتقدمة.

وبما أن شركات النفط والغاز أسرع بكثير في تبني تقنيات جديدة بدلاً من تجربة نماذج أعمالها وتغييرها، فإن الهدف الأساسي للذكاء الاصطناعي (وغير ذلك من أشكال التحول الرقمي) هو تحسين الكفاءة.

من الناحية العملية، فإن هذا يعني عادةً تسريع العمليات وتقليل الأخطار. فيما يلي تفاصيل كيفية قيام الذكاء الاصطناعي بتحويل جذري في استخراج النفط والغاز. وسوف يتم التركيز هنا بشكل رئيس على الأسئلة الثلاثة التالية:

- ماذا يعني التخلص من الأخطار في صناعة النفط والغاز، وكيف يساعد الذكاء الاصطناعي في ذلك؟

- ما هي العمليات التي يمكن تسريعها من خلال تطبيق الذكاء الاصطناعي وما مقدار ذلك؟

- ما الذي تم إنجازه فعلاً، وما هي التطورات المتوقعة في السنوات القادمة؟

بما أن صناعة النفط والغاز معقدة ومتنوعة، فإن التركيز في النقاش سيكون على قطاع المنبع، الذي يغطي إنتاج النفط الخام والغاز الطبيعي.

ويشمل البحث عن حقول النفط الخام والغاز الطبيعي المحتملة تحت الأرض أو تحت الماء حفر الآبار الاستكشافية، وحفر وتشغيل الآبار المستخدمة لرفع النفط الخام أو الغاز الطبيعي الخام إلى السطح. يحظى قطاع المنبع بأهمية خاصة، لأنه الأكثر كثافة في رأس المال، والأكثر أهمية من بين القطاعات الثلاثة في أعمال النفط والغاز. تتعامل شركات القطاع مع حالات عدم اليقين الكبيرة يدوياً، اعتماداً على معرفة الخبراء دون اعتماد البيانات الفعلية.

إن مقولة: «صخرة واحدة، وجيولوجيان اثنان، وثلاثة آراء»، تحكي الكثير عن الشكوك الكبيرة والأخطار التي يتعين على شركات النفط والغاز التعامل معها.

تحتاج حالات الريبة إلى التعامل معها عند اتخاذ قرارات بمليارات الدولارات حول مكان وكيفية الاستثمار في السنوات الخمس إلى العشرين القادمة. ومع ذلك، وعلى الرغم من الطبيعة المعقدة وغير المؤكدة لمشكلات الإدارة في هذا القطاع، فقد هيمنت النهج ذات المعيار الواحد تاريخياً على عملية صنع القرار.

لمراعاة أوجه عدم اليقين المرتبطة بالإدراك الذاتي للممارسين واتخاذ القرارات بناءً على الخبرة، يتم اتخاذ الخطوات الأولى، لاستخدام البيانات الميدانية الموجودة، نحو استخدام الذكاء الاصطناعي والتعلم الآلي في المنبع، مما أصبح شائعاً بشكل متزايد. فيما هنا، الدروس المستفادة من عشرات مشاريع الذكاء الاصطناعي التي تم تنفيذها على مدى السنوات الثلاث الماضية، لصالح شركات التنقيب عن النفط والغاز الرائدة في جميع أنحاء العالم، حيث غطت هذه المشاريع حلول الذكاء الاصطناعي لمجموعة كاملة من أنشطة المنبع؛ التقييم الجيولوجي للخزانات، وتحسين طرق الحفر، وهندسة المكامن / تطوير الحقول، وتحسين الإنتاج.

• المشكلة والحاجة إلى الذكاء الاصطناعي

إن هيمنة احتياطات النفط والغاز «التي يصعب استخراجها» على مدى السنوات العشر الماضية، تملي ضرورة اتباع نهج تشغيلية ونماذج أعمال جديدة في استكشاف وإنتاج الهيدروكربونات، موجهة نحو ضمان الربحية المناسبة لإنتاج النفط والغاز. وينطبق هذا الأخير على كل من الخزانات الهيدروكربونية تحت السطح؛ المطورة (الحقول البنية) والمكتشفة حديثاً (الحقول الخضراء).

على الرغم من أن الغالبية العظمى من الحقول البنية كبيرة نسبياً من حيث أحجامها الهندسية، وجيدة إلى حد ما من حيث خصائص النقل والتخزين (المسامية والنفاذية)، فإن كمية النفط والغاز القابلة للاستخراج عن طريق الحقن بالمياه الرخيصة صغيرة جداً.

من حيث المبدأ، تنتج جميع الحقول ذات البنية التقليدية ميهاً أكثر من النفط.

وللمحافظة على مستويات الإنتاج، يتعين على الشركات المشغلة أن تتفق مبالغه كافية لإجراء إحدى العمليات التالية: الحفر الإضافي، أو معالجة الآبار (كالتكسير الهيدروليكي)، أو إجراءات استخلاص النفط المعززة على نطاق الحقل (مثل زيادة حركة النفط المتبقي في المكمن عن طريق حقن مواد كيميائية). في كثير من الحالات، لا تؤدي الأموال المستثمرة في هذه الإجراءات ثمارها، مما يترك الحقول المطورة في عملية بطيئة من الموت.

الوضع ليس الأفضل بالنسبة للاكتشافات الجديدة، فجميع المكامن الهيدروكربونية المكتشفة حديثاً صعبة تقريباً أيضاً. لأنها قد تكون:

- واقعة في أماكن ذات ظروف بيئية قاسية (في الجرف القطبي الشمالي).
- معقدة من الناحية الهندسية (طبقات رقيقة ومتعرجة من الصخور المشبعة بالنفط، مع الكثير من الشقوق).
- تحت طبقة عميقة جداً من مياه البحر والمعادن المالحة (كما في قبالة سواحل البرازيل).
- ذات نفاذية ضعيفة (بحيث يكون الهيدروكربون ساكناً تقريباً داخل صخور المكمن).

ويتطلب تطوير هذه الحقول الخضراء تقنيات باهظة الثمن، ويجعل ربحية إنتاج المزيد من النفط موضع شك.

يتعامل صناع القرار مع حالات عدم اليقين المتعلقة بالاستثمارات طويلة الأجل وعالية القيمة، في مجال التنقيب عن النفط والغاز يدوياً، استناداً إلى معرفة الخبراء، وليس اعتماداً على البيانات الفعلية العظيمة.

هناك سؤالان رئيسان يجب الإجابة عليهما في هذا السياق.

السؤال الأول: هل هذا منظور خاص للأصول؟ هل يجب أن ننفق الأموال على الدراسات الجيوفيزيائية لتقييم إمكانات الأصول؟

عادة، تتم الإجابة على هذا السؤال من سير عمل النمذجة الجيولوجية ونمذجة المكامن، والذي يستغرق عدة أشهر إلى عدة سنوات، اعتماداً على ضرورة إجراء مسوحات جيوفيزيائية إضافية وتعقيد الإجراءات داخل الشركة.

والسؤال الثاني هو: هل يجب إنفاق المال على تعزيز إنتاج النفط على أصوله؟ إذا كان الأمر كذلك، ما هي التقنيات التي تستحق الاستثمار؟

يتم التعامل مع هذا السؤال في الغالب من قبل الخبراء ويتم دعمه، على مستوى ما، من أدوات نمذجة الخزانات التقليدية. إن الاعتماد القوي على آراء الخبراء، وعدم كفاية بيانات الإدخال المناسبة لأدوات النمذجة التقليدية يؤدي إلى إجابات متحيزة وغير مؤكدة. بالنسبة لكلا السؤالين، يمكن لأنظمة الذكاء الاصطناعي، المدربة باستخدام البيانات الميدانية الصحيحة، أن تقدم مساعدة كبيرة بتسريع عملية تقييم الأصول وجعلها أكثر موضوعية أو استقلالاً عن الخبراء. وتتم مناقشة الخطوات الأولى في هذا الاتجاه والإمكانات المستقبلية في القسم اللاحق.

• كيف يقوم الذكاء الاصطناعي بتغيير المنبع؟

تنقسم صناعة البترول (النفط والغاز) إلى؛ المنبع، والوسط، والمصب. يلخص المنبع الجزء تحت السطح (التعدين) من الصناعة، بما في ذلك الاستكشاف الذي يليه تطوير الحقل وإنتاج النفط الخام / الغاز. يشير مصطلح الوسط إلى نقل النفط والغاز، في حين يشير مصطلح المصب إلى المصفاة، (أي إنتاج الوقود ومواد التشحيم والبلاستيك وغيرها من المنتجات). ومن شرح العديد من الأنشطة التمهيديّة بالتفصيل، ستناقش النقاط التي يتم فيها تطبيق حلول الذكاء الاصطناعي فعلاً ونتائجها. ومن ثم تسليط الضوء على المكان الذي يُتوقع استخدام الذكاء الاصطناعي فيه، والنتائج التي يمكن أن تتجم عن تطبيقه.

■ الاستكشاف بمساعدة الذكاء الاصطناعي

استكشاف احتياطات النفط والغاز عبارة عن مجموعة من العمليات التي ينتج عنها نموذج جيولوجي ثلاثي الأبعاد لحقل أو خزان النفط/الغاز. وتشمل العمليات؛ الدراسات الجيوفيزيائية والبتروفيزيائية ومعالجة البيانات التي تم الحصول عليها خلال الدراسات.

تتكون الدراسات الجيوفيزيائية والبتروفيزيائية عادةً من:

- ◆ المسح السيزمي على مستوى الخزان.
 - ◆ تسجيلات الآبار.
 - ◆ التحليل الأساسي المعلمي و(في بعض الحالات المحددة جداً) التحليل الأساسي الرقمي.
- ينتج المسح السيزمي مجموعة من تسجيلات الاستشعار تسمى الآثار الزلزالية. هذه الآثار عبارة عن سلاسل زمنية، تمثل قوة الموجات المرنة التي يبدأها هزاز على السطح، وتنعكس من الحدود التي تقسم طبقات التكوين المختلفة تحت السطح. يتم وضع هذه السلاسل الزمنية المسجلة مع الإحداثيات المكانية لأجهزة الاستشعار المقابلة والهازاز في خوارزمية إعادة بناء خاصة، مما يؤدي إلى صور ثلاثية الأبعاد ذات وضوء توضح بعض الحدود العاكسة. عملية إعادة الإعمار لا تتصل بالإنترنت كثيراً، نظراً للمتطلبات الكبيرة جداً للحوسبة عالية الأداء. وتهدف الدراسات التي تركز على الذكاء الاصطناعي إلى تسريع هذه المرحلة.

تسمى الصور ثلاثية الأبعاد بالمكعبات الزلزالية. تتم دراسة المكعبات الزلزالية بواسطة مترجمات زلزالية، والتي يمكن أن تشارك أيضاً في تحديد معالم مرحلة إعادة الإعمار السابقة. تقوم المترجمات بتقسيم الصور ثلاثية الأبعاد، عن طريق تحديد النقاط والخطوط والأسطح داخل المكعب ثلاثي الأبعاد، والتي ترتبط «حتمًا» بالحدود بين الطبقات المختلفة في التكوين تحت السطح.

نقتبس «حتمًا» لأنه لا توجد معايير موضوعية لتحديد هذه النقاط والخطوط والأسطح. العملية برمتها، بدءًا من إعادة البناء إلى تجزئة المكعب ثلاثي الأبعاد، تستغرق وقتًا طويلاً جدًا، وتعتمد على الخبراء. يمكن أن تستغرق معالجة بيانات المسح بأكملها أكثر من عام لإجراء دراسة زلزالية دقيقة، كما يقرر الجيولوجيون، بناءً على المكعبات المجزأة ثلاثية الأبعاد، مكان حفر المجموعة الأولى من الآبار الاستكشافية لتحسين فهم التفاصيل تحت السطح.

بدأت تقنيات التعرف على الأنماط الحديثة القائمة على التعلم العميق في التعمق في هذه العملية المتعلقة بالزلازل، مما أدى إلى تسريع التفسير بعامل يتراوح بين 10 و1000.

هناك احتمال ضعيف بأن تعمل تقنيات الذكاء الاصطناعي على تحسين الجزء المادي (أي الكمية والتكلفة والتخطيط الخاص باختيار وضع أجهزة الاستشعار) للمسح الزلزالي للأصل الأول. ومع ذلك، فإنها تضيف قيمة إلى تحسين المسوحات الثانوية على الأصل نفسه. إن رياضيات أنظمة التوصية، وإمكانات الاستيفاء لخوارزميات التعلم الآلي ستمكن

من تقديم توصيات مناسبة بشأن جعل المسوحات الثانوية أرخص مع خسارة طفيفة في قيمة المعلومات المكتسبة. بينما توفر الصور السيزمية معلومات واسعة النطاق (تغطي عشرات الكيلومترات) ودقة منخفضة (تصل إلى عشرات الأمتار) حول طبولوجيا الخزانات وخصائصها المرنة، يتم استخدام تسجيلات البئر للحصول على معلومات أكثر دقة حول الخصائص الفيزيائية المختلفة لما تحت السطح على امتداد حفرة البئر. دقة تسجيلات البئر تصل إلى سنتيمترات. يمكن لأجهزة استشعار تسجيلات البئر قياس المقاومة الكهربائية، وكثافة أشعة جاما الطبيعية، والاستجابة للإثارة المغناطيسية (دراسة الرنين المغناطيسي النووي)، وكثافة النيوترونات.

نتائج تسجيلات البئر هي ناقلات للخصائص على امتداد حفرة البئر. يستخدم علماء الفيزياء البتروفيزيائية بيانات تسجيلات الآبار لروتين التفسير الخاص بها، على امتداد حفرة البئر، لاستخلاص: نوعية الصخور، وتقدير المسامية والنفاذية، وتقدير التشبع النسبي للسوائل (كمية النفط مقابل كميتي الغاز والماء).

إن التفسير البتروفيزيائي عملية تستغرق وقتاً طويلاً إلى حد ما، وتعتمد نتيجة التفسير بقوة على المترجم (أي الخبير). واجه المؤلفون هذه المشكلة عند تطوير خوارزمية تفسير آلية تعتمد على التعلم الآلي لشركات النفط.

تم تطبيق الخوارزمية، التي تم تدريبها على بيانات تسجيل الآبار التاريخية، على البيانات الواردة من الآبار الجديدة. وكانت دقة الترجمة الفورية باستخدام التعلم الآلي مقابل الترجمة الفورية اليدوية 92%. كان تفسير ML أسرع بحوالي 1000 مرة من الدليل. ثم قرر الباحثون إجراء تفسير يدوي آخر للبيانات نفسها مع الخبراء أنفسهم. ومن المثير للاهتمام أن الترجمة اليدوية الثانية مقابل الترجمة اليدوية الأولى أظهرت دقة قدرها 91%.

ومن هذا المنظور، فإن التقنيات المدعومة بالذكاء الاصطناعي هي الطريقة الواضحة، وربما الأكثر أهمية، لتسريع استبعاد الجزء الشخصي من عملية التفسير. علاوة على ذلك، أظهرت التجارب الداخلية التي أجريت للشركاء الصناعيين أنه يمكن إعادة بناء جزء كبير من قياسات تسجيلات الآبار بسهولة باستخدام التعلم الآلي.

وهذا من شأنه أن يمكّن من استخدام التعلم الآلي لبناء أنظمة التوصية التي تساعد شركات النفط على إنفاق مبالغ أقل على تسجيلات الآبار. تسارع مماثل ممكن مع التحليل الأساسي.

بعد ذلك، يتم استخدام نتائج التفسير البتروفيزيائي لتحسين التفسير الزلزالي. يقوم الجيولوجيون وعلماء الفيزياء البتروفيزيائية باستقراء الخصائص المكتسبة من المناطق القريبة من حفرة البئر في المكعب الزلزالي، مما يؤدي إلى تشبع المكعب المجزأ ثلاثي الأبعاد بالمسامية وتوزيع النفاذية وقيم تشبع السوائل. ربما يكون هذا الاستيفاء هو الجزء الأكثر استهلاكاً للوقت والأكثر موضوعية في سير عمل النمذجة الجيولوجية بأكمله. مع كل تمارين الضبط، يمكن أن تستغرق العملية من بضعة أشهر إلى بضع سنوات.

من المتوقع أنه إذا تم التدريب بطريقة صحيحة على العديد من تمارين الاستقراء التي يتم إجراؤها يدوياً، فإن البنى التوليدية للشبكات العصبية العميقة يمكنها تسريع العملية بعامل يزيد عن 1000. على الرغم من صعوبة توقع قبول الجيولوجيين وصناع القرار النموذج الجيولوجي ثلاثي الأبعاد الذي تم إنشاؤه تلقائياً باعتباره الحقيقة المطلقة، في المستقبل القريب، إلا أن الأتمتة مع التعلم العميق تمثل فرصة ممتازة لاقتراح البديل المستقل والسريع لمزيد من المعرفة والضبط واتخاذ القرار. وببساطة، يُتوقع أن يتم اتخاذ القرار النهائي بسرعة كبيرة باستخدام أدوات تمكين الذكاء الاصطناعي.

■ التطوير الميداني بمساعدة الذكاء الاصطناعي

حال بناء النموذج الجيولوجي الأولي، يذهب الأمر إلى مهندسي المكامن. يقوم مهندسو الخزان ببناء نموذج لخزان من النموذج الجيولوجي. عادةً ما يقومون بالترقية، مما يقلل من كمية الخلايا ثلاثية الأبعاد التي تصف خصائص الخزان عن طريق زيادة حجم الخلايا من النموذج الجيولوجي. بعد الارتقاء بمستوى الخزان، يستخدم مهندسو الخزان برنامج نمذجة الخزان لنمذجة تدفقات الخزان في مخططات تطوير الحقل المختلفة. يحتوي مخطط تطوير الحقل على خطة حفر الآبار وتشغيلها.

نتيجة كل عملية من عمليات نمذجة المكامن هي التنبؤ بإنتاج النفط/الغاز للسنوات القادمة (عادة من 10 إلى 25 سنة) لمخطط تطوير حقل معين. ومن إجراء العديد من العمليات، يختار مهندسو الخزان المخطط الأمثل لتطوير الحقل وخطة تطوير الحقل. كلمة الأمثل لها معاني مختلفة لشركات مختلفة. تبحث مجموعة واحدة من الشركات، عادةً ما تكون شركات متوسطة إلى كبيرة الحجم، على الحفاظ على الإنتاج طويل الأجل عند مستوى مناسب عند استثمار ثابت في التطوير الميداني وعمليات الإنتاج.

أما المجموعة الثانية، والتي عادة ما تكون شركات صغيرة ومتوسطة الحجم، فتبحث عن النتيجة القصوى في إنتاج النفط/الغاز بأقل تكاليف حفر على مدى بضع سنوات. قد ترغب المجموعة الثالثة في التأكد من إمكانية بيع الأصل أو الحقل بسعر معقول بعد مرور بعض الوقت على التشغيل الميداني. من الناحية الرياضية، لدى الشركات المختلفة وظائف مستهدفة مختلفة لتحسينها.

لا يتم إجراء تمرين هندسة الخزان على الحقول الخضراء فحسب، بل على الحقول البنية أيضاً. تتمتع الحقول البنية بتاريخ إنتاج محدد، مما يساعد على تصحيح النماذج الأولية من مطابقة التاريخ، وتقليل حالات عدم اليقين في توقعات الإنتاج. من الناحية النظرية، تعد مطابقة التاريخ مشكلة عكسية ليس لها حل خاص، ولكن هناك مسارات صنع عملية للتعامل معها في التطبيق على هندسة المكامن.

يوجد ثلاث فرص رئيسة لتطبيق الذكاء الاصطناعي في هندسة المكامن. الأول يتعلق بالحسابات التي تتم باستخدام أدوات نمذجة المكامن التقليدية. تقوم الأدوات بإجراء حلول عددية للمعادلات التفاضلية الجزئية التي تصف فيزياء تدفقات الخزان. يتم إجراء الحسابات على شبكة ثلاثية الأبعاد تحتوي عادةً على ما بين مليون إلى بضع مليارات من الخلايا. تكون العمليات الحسابية طويلة إلى حد ما، حتى مع محطات العمل الحديثة وخوادم HPC، مما يحد من عدد عمليات التشغيل المحتملة.

وهذا الأخير، بالترتيب، يحد من القدرة على التحسين للتخطيط السليم لتطوير الحقل. يعد تسريع نمذجة الخزانات أحد الاتجاهات الواضحة لتقنيات الذكاء الاصطناعي.

تعمل نماذج الخزان البديلة الحديثة مع محرك حسابي جديد، يعتمد على شبكات عصبية عميقة، على ضغط أبعاد المشكلة الرياضية وتقريب المشتقات الزمنية التي تعد أسرع بـ 100-1000 مرة من النماذج التقليدية مع الحفاظ على وظائف مماثلة.

وتتمثل الفرصة الثانية في رفع المستوى (أي نقل المعلومات المكتسبة من مختلف مستويات الدراسات الجيوفيزيائية إلى نماذج مكامن جيولوجية واحدة، ومن ثم نماذج هيدروديناميكية واحدة).

تحتوي عملية الارتقاء على جزء كبير من الفن بداخلها. لا يوجد إطار واحد مناسب علمياً للارتقاء بمستوى الخزانات، ويستخدم العديد من مهندسي الخزانات الحيل لتنفيذ ذلك بطريقة تبدو صحيحة لأنفسهم، وإن كان يقدم تحيزاً قوياً لنموذج الخزان.

ونظراً لعدم وجود إجراء واحد صحيح وموضوعي للارتقاء، يمكن للمرء التفكير في زيادة الموضوعية بتلخيص التجارب المتعددة باستخدام أداة ذكية.

يمكن القيام بذلك جيداً باستخدام خوارزمية التعلم العميق المدربة على حالات متعددة من الترقية اليدوية. ولن تكون النتيجة هنا زيادة الموضوعية فحسب، بل أيضاً زيادة سرعة عملية الارتقاء.

الفرصة الثالثة تشبه الارتقاء، ولكنها تلامس مطابقة السجل. يمكن أن يكون الإجراء هنا هو نفسه: محاولة إشراك الآلة أو التعلم العميق لجعل مطابقة التاريخ أسرع وأقل تحيزاً.

وكما ورد في المقدمة، فإن معظم الحقول الخضراء تحتوي على خزانات معقدة من حيث هندستها وخصائصها الجيولوجية. ويتطلب الأخير بناء آبار عالية التقنية بأجزاء أفقية وإكمال متعدد الأطراف. إن بناء الآبار في تطوير الحقل، هو العملية الأكثر تكلفة في تطوير الحقل. لكي يؤدي الاستثمار المرتفع في الحفر واستكمال البئر ثماره، من الضروري استخدام جميع معلومات مستشعرات الحفر.

الهدف هو ضمان أفضل اتصال بين حفرة البئر والجزء الإنتاجي من التكوين، وأقصى معدل لعملية بناء البئر بأكملها مع الحد الأدنى من خطر الفشل وبالتالي الحد الأدنى من الوقت غير الإنتاجي.

الحفر الحديث هو عملية غنية بالبيانات. هناك ثلاثة أنواع من أجهزة الاستشعار. الأولى: أجهزة الاستشعار الموجودة على السطح والتي تسجل المعلومات الميكانيكية لعملية الحفر في الوقت الفعلي.

والثانية: هي أجهزة استشعار التسجيل أثناء الحفر (LWD)، والتي تسجل المعلومات الفيزيائية للتكوين خلف مثقب الحفر.

والثالثة: أجهزة استشعار ميكانيكا الحفر (MWD) التي تسجل البيانات الميكانيكية من الفتحة السفلية.

تقوم جميع أجهزة الاستشعار بتوليد سلسلة زمنية يمكن استخدامها لإدارة عملية الحفر نفسها، وتحديث النموذج الجيولوجي أو المكمني لحقل النفط. هناك طرق متعددة لجعل عملية الحفر أكثر سرعة وأكثر أماناً ودقة.

يُتوقع انخفاض كبير في الوقت غير الإنتاجي بنسبة 20-40 % في المتوسط، مع انخفاض كبير في حالات الفشل تصل إلى 90 %، مع تطوير وتنفيذ أنظمة دعم الحفر بمساعدة الذكاء الاصطناعي التي تعمل مع قياس الحفر عن بعد في الوقت الفعلي.

■ الإنتاج بمساعدة الذكاء الاصطناعي

تُعد الخزانات المنتجة جذابة للأدوات المدعومة بالذكاء الاصطناعي، وكذلك الحقول الخضراء.

هناك تطبيقات واضحة للتعليم الآلي لمختلف المضخات لتنفيذ الصيانة التنبؤية، واختيار أنظمة التشغيل المثلى فيما يتعلق بتكاليف التشغيل مقابل الإنتاج.

العديد من المضخات، بما في ذلك المضخات الغاطسة الكهربائية ومضخات آبار الحقن والتكسير الهيدروليكي وغيرها من مضخات معالجة الآبار، مجهزة بعدد كبير من أجهزة الاستشعار التي تقيس الضغوط ودرجات الحرارة والاهتزازات ومعدلات التدفق، وما إلى ذلك.

هناك العديد من الأمثلة عندما يساعد النموذج المعتمد بالكامل على البيانات أو النموذج المختلط الذي يحتوي على الرياضيات المعتمدة على الفيزياء والرياضيات، المستندة إلى البيانات على تحسين الأنظمة، ومنع حالات الفشل غير المتوقعة، وتوفير الصيانة في الموعد المحدد.

وبصرف النظر عن هذه التطبيقات الواضحة لصيانة المعدات، فإننا نتوقع أن تكون معالجة الآبار مجالاً آخر يتمتع بإمكانية توفير التكلفة العالية.

يتم إجراء عملية معالجة البئر لتحفيز تدفق الهيدروكربون في بئر قديمة أو زيادة معدل التدفق الأولي لبئر تم حفرها حديثاً. إجراءات معالجة الآبار الأكثر شيوعاً هي التكسير الهيدروليكي والمعالجة الكيميائية.

تكاليف معالجة الآبار كبيرة جداً، ويمكن مقارنتها بتكلفة بناء الآبار. دائماً ما تكون الاستثمارات في حملات معالجة الآبار معرضة لخطر كبير بسبب شيئين.

- **الأول:** يتعلق بحقيقة أن النماذج المعتمدة على الفيزياء للتنبؤ بتأثير معالجة البئر تنتج تقديرات تقريبية جداً، بسبب الافتقار إلى المعرفة الدقيقة بالخصائص الفيزيائية للتكوين القريب من حفرة البئر.

• **الثاني:** ويتعلق بتحيز الخبراء المشاركين في تحديد الاختيار النهائي لإجراءات معالجة الآبار لمجموعة معينة من الآبار. ويرجع هذا التحيز أساسًا إلى الإجراءات القياسية لتقييم مستويات هامشية الإجراءات في الشركات العاملة.

تفترض العديد من المعايير مستويات هامشية ثابتة، والتي يستهدفها الخبراء للحصول على الاستثمارات اللازمة لوظائف تحفيز الآبار. هناك فرصة ممتازة لتقليل أخطار الاستثمار بتجميع البيانات من وظائف معالجة الآبار المنتجة فعليًا. لقد تم فعليًا بذل جهود رائدة للتنبؤ بكفاءة وظائف التكسير الهيدروليكي والتحليل القائم على التعلم الآلي لقضايا الحقن.

يتوقع أن يؤدي التطوير الإضافي للخوارزميات استنادًا إلى الرياضيات والبرمجة إلى تمكين أنظمة التوصية واسعة النطاق. ستساعد أنظمة التوصية في اختيار تصميم معالجة البئر المعين والتخطيط لحملات معالجة البئر.

■ الذكاء الاصطناعي والسلامة

وبصرف النظر عن تطبيق الذكاء الاصطناعي لخفض التكاليف وإزالة الأخطار، ينبغي أن نذكر تأثيره الاستثنائي على تدابير السلامة. تُعد عمليات حقول النفط محفوفة بالأخطار بالنسبة للموظفين، نظرًا لوجود العديد من عوامل الخطر، بما في ذلك المعدات الثقيلة، والمعدات الدوارة غير المغطاة، وضغط الكهرباء العالي، والعمليات ذات درجة الحرارة العالية، والمواد الكيميائية شديدة الأذى.

هناك العديد من أنظمة تكنولوجيا المعلومات التي تعتمد على التعلم العميق لمساعدة مسؤولي السلامة على اكتشاف أخطار بروتوكولات السلامة. يتيح التعرف على الأنماط باستخدام التعلم العميق وتدفقات الفيديو المسجلة بالكاميرات التنبؤ به إذا لم يكن الموظف يرتدي ملابس مناسبة لمجموعة معينة من العمليات.

علاوة على ذلك، فإن التحليلات التنبؤية تنبه المشغلين بشأن الحالة الصحية للمعدات، مما يتيح اتخاذ إجراءات استباقية لمنع وقوع كارثة لها عواقب على الصحة والسلامة والبيئة.

■ الخوارزميات في عمليات استخراج النفط والغاز

يعد التعلم الآلي الكلاسيكي والتعلم العميق من الأساليب السائدة المستخدمة في تطبيقات الذكاء الاصطناعي في قطاع التنقيب وصناعة النفط والغاز بأكملها. يتم استخدامها في حل أنواع المشكلات المتعلقة بالتصنيف أو التجميع أو الانحدار. إن خوارزميات التعلم الآلي والتعلم العميق عبارة عن صناديق سوداء، فلا توجد صيغة واضحة تصف الأسباب التي تجعل الأنظمة المبنية عليها تفعل ما تفعله أو كيف تعمله.

تحتوي هذه الخوارزميات على صيغ جبرية معقدة جداً، ومتعددة الأبعاد. يتم تعريف المعاملات ضمن هذه التعبيرات لتناسب بيانات الإدخال والإخراج، التي تصف النظام أو الكائن أو العملية. تسمى عملية التركيب هذه بالتدريب. وحال تدريبها على البيانات المعروفة، يمكن للخوارزميات توليد رؤى جديدة بناءً على مدخلات جديدة.

بالإضافة إلى ذلك، فإن النمذجة الهجينة، حيث يتم استخدام النماذج المبنية على الفيزياء مع خوارزميات التعلم الآلي، موجودة في التطبيقات الصناعية. هناك فرق بين النماذج الهجينة التي تهيمن عليها الفيزياء، وتلك الهجينة التي تهيمن عليها البيانات. في النماذج الهجينة التي تهيمن عليها الفيزياء، يتم استخدام التعلم الآلي لضبط معاملات المعادلة مع البيانات الفعلية الناتجة عن كائن محل الاهتمام.

من ناحية أخرى، في النماذج الهجينة التي تهيمن عليها البيانات، يتم استخدام النموذج المبني على الفيزياء لتوليد كميات كبيرة من بيانات التدريب، والتي بناءً عليها (+بيانات الحياة الواقعية)، يتعلم نموذج ML فيزياء المشكلة ويساعد في حلها.

وأخيراً، فإن التطبيقات الأولى التي تتطوي على تخطيط الذكاء الاصطناعي (مجموعة من أساليب التحسين والتعلم الآلي لتخطيط بعض الإجراءات لتحقيق هدف ما، والتي يتم تنفيذها عادة بواسطة الروبوتات المستقلة، والكيانات الذكية والمركبات بدون طاقم)، تظهر في صناعة النفط والغاز.

يمكن العثور على تحليل عميق لخوارزميات الذكاء الاصطناعي والتعلم الآلي المستخدمة في صناعة النفط والغاز في العديد من المراجعات الحديثة.

■ البيانات في مجال النفط والغاز المنبع

من الشائع بين جميع أساليب الذكاء الاصطناعي المذكورة أنه بدون الوصول إلى بيانات تدريب كبيرة وجيدة بما فيه الكفاية، فإن خوارزميات الذكاء الاصطناعي تكون أقل فائدة كثيراً، وأحياناً عديمة الفائدة. تعني عبارة «جيدة بما فيه الكفاية» أن البيانات يجب أن تكون متنوعة كافية، لتغطية جميع الأحداث والأنشطة والسلوكيات محل الاهتمام. على سبيل المثال، لبناء حل صيانة تنبؤي ناجح، يجب أن تحتوي مجموعة البيانات على عدد كافٍ من حالات الفشل المسجلة، لتكون مفيدةً للتعليم منها. من ناحية أخرى، ما هي مجموعة البيانات «الكبيرة الوافية» الأقل وضوحاً، حيث يعتمد حجم مجموعة البيانات المطلوبة على سياق المشكلة التي تتم معالجتها (وإيقاع تطوير الخوارزمية).

قدر الباحثون جودفيلو وبينجيو وكورفيل (2020م)، أنه لتحقيق مستويات أداء مقبولة إلى حد ما، مع الشكل الأكثر إثارة للاهتمام من الذكاء الاصطناعي اليوم (أي التعلم العميق الخاضع للإشراف)، هناك حاجة إلى حوالي 5000 مثال مصنّف للتدريب. وللمطابقة الأداء على المستوى البشري أو تجاوزه، يلزم وجود ما لا يقل عن 10 ملايين عينة مصنفة.

يقدم الذكاء الاصطناعي نهجاً جديداً في تطوير حقول النفط والغاز، وهو النهج الذي تُعد فيه البيانات أمراً أساسياً. قبل هذا التحول، مر تطوير حقول النفط والغاز واستخدام البيانات ذات الصلة بثلاث مراحل رئيسية.

الأولى: بداية القرن النفطي (أواخر القرن التاسع عشر - أوائل القرن العشرين)، وتميزت بالمنطق الذي يمكن صياغته على النحو التالي: «هناك تل، وهناك بئر إنتاج في التل المجاور. دعونا نحفر هذا التل في أقرب وقت ممكن».

لتحديد وتطوير حقول النفط والغاز، كان الناس يستخدمون نهجاً تجريبياً بالكامل يعتمد على الحالات التناظرية. ولم يتم استخدام أجهزة الاستشعار والقياسات والبيانات.

الثانية: عندما قام الأخوة شلمبرجير بتحديث عملية اتخاذ القرار التجريبية بقياسات الخصائص الفيزيائية تحت السطح، بدءاً من المقاومة الكهربائية من السطح، ثم من آبار البئر. قدمت هذه القياسات بيانات الاستشعار إلى أصحاب صنع القرار للكشف عن النفط وتطوير حقول النفط. وجاء المزيد من التطوير مع إضافة العديد من مصادر البيانات، واستخدامها لتوصيف وتحليل المجالات من تمارين المحاكاة والنمذجة المختلفة.

الثالثة: في هذه المرحلة استخدم الخبراء البيانات بثلاث طرق.

- استخدام بيانات الزلازل وتسجيل الآبار والبيانات الأساسية والسوائل بشكل أساسي لإنشاء نموذج جيولوجي للمكمن،
- يليه إنشاء نموذج مكمني يُستخدم في هندسة المكمن لنمذجة السيناريوهات لتخطيط تطوير الحقل. تعد هذه النمذجة مدخلاً رئيساً في عملية صنع القرار الأكثر تكلفة في مجال النفط والغاز.

• يتم استخدام بعض أجزاء البيانات، مثل قياس الحفر عن بعد، وقياس وظائف معالجة الآبار، ومعدلات الإنتاج، في الإدارة التشغيلية لمختلف العمليات الفنية التي تحدث في حقل النفط. ويتم استخدام بعض البيانات (مثل معدلات الإنتاج) في إعداد التقارير.

في الوقت الحاضر، نحن في فترة انتقالية بين المرحلة الثالثة، التي تستخدم الكثير من الممارسات كثيفة البيانات؛ مثل هندسة المكامن التقليدية، وهندسة الحفر، والنمذجة الجغرافية، والمرحلة الرابعة، حيث البيانات هي المفتاح، والذكاء الاصطناعي الحديث. وستساعد التطورات في التغلب على بعض التحديات التي لم تتم معالجتها من قبل.

من الضروري تسليط الضوء على أن الذكاء الاصطناعي، الذي يعد تقنية تمكن من إجراء بعض العمليات بشكل أسرع أو أرخص أو بجودة أعلى.

تستبعد أدوات الذكاء الاصطناعي بني البشر من العديد من العمليات، وتؤدي إلى إمكانات عديدة لابتكارات نماذج التشغيل والأعمال، مما يجعل من الممكن القيام بالأشياء بشكل مختلف على المستوى الإنشائي.

• التحديات الرئيسية وعوامل التمكين

في حين أن بعض شركات النفط والغاز، مثل BP وShell وSaudi Aramco وGazprom وNeft، تطلق مبادراتها في مجال الذكاء الاصطناعي من خلال الاستثمار بقوة في الشركات الناشئة والبحث والتطوير، فإن العديد من التحديات تمنعها من تنفيذ الذكاء الاصطناعي على نطاق واسع وسريع في الاستكشاف وإنتاج النفط والغاز. وهذه ليست مشكلة خاصة بالنفط والغاز، ولكنها مشكلة شائعة في تطبيق الذكاء الاصطناعي في هذه المرحلة من تطوره.

بناءً على الأدلة المتوفرة حالياً، ترتبط التحديات الحاسمة بالملف الشخصي (الجديد) للأفراد الذين تحتاجهم الصناعة، والأهمية المركزية للبيانات، والحاجة إلى التعاون المفتوح. ووسيتم مناقشة هذه القضايا الثلاث أدناه.

■ الناس

يعتمد نجاح الذكاء الاصطناعي بشكل حاسم على الذكاء البشري. إن حلول الذكاء الاصطناعي ليست عامة، ولا يمكن شراؤها فقط. حتى عندما يتم تطويرها من قبل أطراف ثالثة (وتقديمها مجاناً، مثل TensorFlow من Google)، يجب تخصيص حلول الذكاء الاصطناعي بما يتناسب مع سياق الأعمال والبيانات التي تمتلكها الشركة.

وبالتالي، لاستخدام الذكاء الاصطناعي بشكل فاعل في العمليات والمنتجات، يجب على الشركات تنمية فرق داخلية تتكون من متخصصين في البيانات والذكاء الاصطناعي. يجب أن تكون هذه الفرق قادرة على دعم تطوير البنية التحتية للذكاء الاصطناعي (الخوارزميات ومجموعات البيانات)، وعلى الأقل تخصيص الأدوات التي ستستخدمها الشركات لاحقاً في عملياتها.

وهذا يعني أن شركات النفط والغاز ستصبح (جزئياً) شركات تعتمد على البيانات، وسيصبح متخصصو الذكاء الاصطناعي لا يمكن الاستغناء عنهم في دعم جميع جهود الابتكار تقريباً، في شركات النفط والغاز في السنوات العشر المقبلة.

ومع ذلك، فإن العثور على مواهب الذكاء الاصطناعي والاحتفاظ بها يعد مهمة صعبة جداً. هناك نقص كبير في مواهب الذكاء الاصطناعي في سوق العمل، ومع دخول المزيد والمزيد من الشركات في الذكاء الاصطناعي وتشكيل مجموعات الذكاء الاصطناعي الخاصة بها، فإن الآفاق ليست جيدة للعقد المقبل. وهذا ينطبق بشكل خاص على شركات النفط والغاز.

وبعد ذلك، للتنافس مع عمالقة التكنولوجيا مثل جوجل، وياندكس، وآي بي إم، وأمازون، والجامعات الرائدة والشركات الناشئة الباهرة في جميع أنحاء العالم، يتعين على المواهب نفسها؛ وعلى شركات النفط والغاز أن تحارب المواقف السلبية تجاه صناعات الوقود الأحفوري، وهذه ليست مهمة سهلة ولا رخيصة. ورغم أن دخول الذكاء الاصطناعي إلى صناعة النفط والغاز يعلن عن «نهاية هندسة البترول كما نعرفها»، إلا أن مهندسي البترول لن يختفوا، لكن دورهم ومجموعة المهارات المطلوبة منهم فقط، سوف تتغير.

لنجاح الابتكار في عصر الذكاء الاصطناعي، تحتاج شركات النفط والغاز إلى جانب علماء البيانات، إلى مهندسي بترول يتمتعون بحس قوي بعلم البيانات والقدرة على تحديد وتصميم المهام التي يتعين حلها بواسطة الذكاء الاصطناعي. وسيكون دورهم هو التأكد من تحديد المشكلات الصحيحة لتطبيق الذكاء الاصطناعي، وجمع البيانات الصحيحة، وأن الحلول تناسب الواقع المادي والعمليات. وبمرور الوقت، سيصبح هذا دوراً حاسماً، وإلا فقد يتم طرح الأسئلة الخاطئة وتضخيم الأخطاء البشرية الحالية، كما حدث في حالة حل جوجل للكشف عن سرطان الثدي استناداً إلى تصوير الثدي بالأشعة السينية.

لذلك، لا يقتصر الطلب على علوم البيانات ومهارات الذكاء الاصطناعي بسبب اعتماد الذكاء الاصطناعي، بل هناك طريقة جديدة للتفكير في المشكلات التي تواجهها شركات النفط والغاز، متجذرة في الفهم العميق للعمليات، وفي المنطق الأساسي للمهام.

وبالتالي، فإن الدور الجديد لمهندسي البترول سيكون أكثر أهمية. ولإعداد الجيل القادم من مهندسي البترول، بدأت بعض الجامعات مثل معهد سكولكوفو للعلوم والتكنولوجيا (روسيا)، وجامعة وست فرجينيا (الولايات المتحدة)، فعلاً في تنفيذ برامج تعليمية خاصة تمثل مزيجاً صحيحاً من علوم البيانات والدراسات البترولية.

فإلى جانب العمل بشكل أكبر مع علماء البيانات، سيتعين على مهندسي البترول أن يتعلموا كيفية العمل مع مساعدي الذكاء الاصطناعي؛ وهي منتجات مشابهة لأليكسا وسيري، ولكنها تركز على تطبيقات الصناعة.

وفي هذه الشراكات الجديدة، سيكون التحدي هو الجمع بين الأفضل من الجانبين؛ قدرة الذكاء الاصطناعي على التعامل مع الكثير من البيانات وإيجاد الأنماط والعلاقات، والمعرفة العميقة بمجال الصناعة لمهندسي البترول. رغم توقع استخدام البشر الذكاء الاصطناعي كثيرا، لتعزيز قدراتهم على اتخاذ القرار بدلا من استبدالهم، إلا أنها ستكون مهمة صعبة حيث قد تنشأ العديد من الأسئلة المتعلقة بالثقة والخوف من فقدان الوظائف.

هناك أيضا مشكلة لم يتم حلها تتعلق بالأفراد، ألا وهي النظرة القانونية لتوصيات منظمة العفو الدولية. قد تكون هناك حالات توصي فيها أداة الذكاء الاصطناعي بإجراء يؤدي إلى خسارة المال أو الإنتاج أو أن تسبب مشكلات صحية أو بيئية خطيرة.

في هذه الحالة، ليس لدينا فهم واضح لتقاسم المسؤولية بين خوارزمية الذكاء الاصطناعي نفسها، أو مستخدم هذه الخوارزمية، أو مطورها، ومع تطور أدوات الذكاء الاصطناعي، سيُطرح هذا السؤال أكثر فأكثر.

لذلك من المتوقع هنا إنشاء قاعدة قانونية موازية، تنص على أن الخوارزميات ومطورها ليسوا مسؤولين، لكن المسؤولية لا تزال تقع على عاتق صناع القرار الذين يحصلون على المشورة من مستخدمي الذكاء الاصطناعي وعلى الذكاء الاصطناعي.

وبالتالي، للاستفادة من فرصة توسيع قدرات اتخاذ القرار بشكل كبير، لا يتعين على الشركات إنشاء استراتيجيات للذكاء الاصطناعي فحسب، بل أيضا استراتيجيات خاصة بها.

■ البيانات

تحتاج أدوات الذكاء الاصطناعي إلى بيانات عالية الجودة بحجم مناسب، ليتم تدريبها ومن ثم العمل بشكل صحيح في الوضع التشغيلي. وبينما استخدام خوارزميات أكثر ذكاءً قد يساعد في الحصول على نتائج أفضل من مجموعات البيانات ذات الحجم المحدود، إلا أنه لا يمكن لأي معالجة أن تساعد في التعامل مع البيانات السيئة. وبالتالي، فإن الوصول إلى البيانات الكبيرة ذات الجودة العالية يعد عامل تمكين وعائقاً حاسماً أمام التطوير الناجح لتطبيقات الذكاء الاصطناعي، علماً أن حقول النفط والغاز تولد كميات كبيرة من البيانات الأولية.

ومع ذلك، لا يعد ذلك ضماناً للنجاح نظراً لوجود مشكلات معروفة تتعلق بجودة ودقة البيانات الميدانية، والنقص العام الكبير في كمية البيانات المصنفة في صناعة النفط والغاز. يجب جمع مجموعات بيانات التدريب بعناية من خلال إجراءات متعددة السنوات لسير العمل والحالة المحددة جيداً. ومن أمثلة ذلك الجيدة ما تقوم به شركة **Ambyint**، وهي شركة ناشئة تعتمد على الذكاء الاصطناعي، وممولة من رأس المال الاستثماري، وهي تركز على تحسين إنتاج النفط والغاز، والتي أمضت أكثر من عقد من الزمن لبناء مستودعاتها من بيانات الإنتاج عالية الجودة، وتحسينها، ليتم استخدامها لتدريب حلولها وتحسينها.

لتعزيز قيمة البيانات التي تمتلكها شركات النفط والغاز أو يمكنها الوصول إليها، سيتعين عليها إعادة تصميم وتعديل هياكلها التنظيمية وعملياتها.

لا تُعرف شركات النفط والغاز بنهجها التتموي المرن والبسيط والمنطلق من القاعدة إلى القمة، ولكن من الضروري تغيير التقسيم الصارم لأصحاب الحكم، والعمليات وإجراءات المحاسبة.

أيضًا، يجب أن يكون تخزين البيانات مركزيًا في واحد أو عدد صغير من مستودعات البيانات للسماح للأشخاص وبرامج الذكاء الاصطناعي بالوصول والاستخدام بسهولة. تحديات البيانات (عبر الصناعات، وليس فقط في النفط والغاز)، تدفع الجهود التقنية لتحسين أنظمة الذكاء الاصطناعي، واستخدامها العملي الإضافي في استكشاف وإنتاج النفط والغاز.

أحد الاتجاهات الرئيسية هنا هو تعلم البيانات الصغيرة التي تمكن من تدريب خوارزميات الذكاء الاصطناعي بعدد صغير من الأمثلة. يجذب تعلم البيانات الصغيرة اهتمام الباحثين الجاد في جميع أنحاء العالم، ولكن لا يوجد تقدم كبير حتى الآن. ويتعلق الاتجاه الثاني بالتكيف الفاعل للنماذج المدربة فعليًا لمجموعات البيانات الجديدة التي تم إنشاؤها بواسطة كيانات أو عمليات أو أنظمة متشابهة، ولكن ليست الشيء نفسه. ستؤدي القدرة على تحديث النموذج المدرب مسبقًا بشكل فوري إلى زيادة نطاق قابلية التطبيق للأدوات المدعومة بالذكاء الاصطناعي بشكل كبير. وتخضع دراسات التكيف السريع هذه أيضًا لأبحاث مكثفة.

■ التعاون المفتوح

وُلد الذكاء الاصطناعي في بيئة مفتوحة وتعاونية لأن الأوساط الأكاديمية قوة رائدة في أبحاث الذكاء الاصطناعي لعقود من الزمن، دون أي تأثيرات تجارية تقريبًا.

أدى هذا إلى خلق ثقافة المشاركة المجانية (مثل [GitHub](#))، والنشر المفتوح (مثل [arXiv](#))، والتي كان على الشركات عبر الصناعات (وفي جميع أنحاء العالم) أن تتبناها معيارًا للنجاح في عصر الذكاء الاصطناعي حال انضمامها إلى السباق.

بينما أصبح الابتكار المفتوح معيارًا في قطاع التكنولوجيا، فإن شركات النفط والغاز لم تشتهر بمشاريعها الصناعية المشتركة، خاصة بين المتنافسين وسيما في المجالات الاستراتيجية مثل الذكاء الاصطناعي.

على الرغم من أن العديد من الشركات تعلن عن نشر بعض بياناتها في المصادر المفتوحة، وتدعي ضرورة تبادل البيانات عبر الشركات وعبر الحدود، إلا أن الواقع غير مبشر الآن إلى حد ما. هناك مصادر قليلة جداً للبيانات الجيوفيزيائية وبيانات الإنتاج، وإن كانت نوعيتها مشكوك فيها.

يُعد مستودع البيانات الوطنية للنفط والغاز في المملكة المتحدة واحداً من أوائل الإصدارات الكبيرة للبيانات المفتوحة المتعلقة بالنفط والغاز. يحتوي على 130 تيرابايت من البيانات الجيوفيزيائية والبنية التحتية والحقلية والآبار، وتغطي أكثر من 12500 حفرة بئر، و5000 مسح زلزالي، و3000 خط أنابيب. ويتم تسليط الضوء على فرص التعلم الآلي وتطبيقات الذكاء الاصطناعي بناءً على البيانات المتاحة. إلى جانب الوصول إلى البيانات، تعد الحاجة إلى الحصول على أحدث تقنيات الذكاء الاصطناعي والمواهب من الأسباب الإضافية التي تدفع شركات النفط والغاز إلى تبني التعاون المفتوح. إن القدرة على التشكيك في كل شيء وتجربة البيانات بكفاءة تسمح للشركات الناشئة في مجال الذكاء الاصطناعي بجذب الانتباه وتسجيل الاستثمارات.

في عام 2019م، جمعت الشركات المرتبطة بالذكاء الاصطناعي في الولايات المتحدة 18.5 مليار دولار، أي ما يزيد بنحو 2 مليار دولار عن عام 2018م. وتنشط أكبر شركات النفط والغاز في الاستحواذ على الشركات الناشئة في مجال الذكاء الاصطناعي. على سبيل المثال؛ استثمرت جنرال إلكتريك وشتات أويل بالاشتراك في شركة أمبينت Ambyint.

استثمرت أرامكو السعودية في شركة Earth Science Analytics، وهي شركة ناشئة تعمل على تطوير الجيل القادم من برامج الذكاء الاصطناعي لعلوم الأرض البترولية. استثمرت شركة BP في شركة Belmont Technology، وهي شركة ناشئة تهدف إلى تعزيز قدرات الشركة في مجال الذكاء الاصطناعي والقدرات الرقمية في أعمالها الأولية في الخارج.

كما استثمرت شركات؛ شل وأرامكو السعودية وشيفرون معاً في شركة **Maana** الناشئة للذكاء الاصطناعي، والتي دخلت في شراكة مع **Microsoft** لاستخدام منصة الحوسبة السحابية **Azure**. تعد مختبرات الجامعة مصدراً مهماً آخر لتكنولوجيا الذكاء الاصطناعي الجديدة ومواهب الذكاء الاصطناعي. وبالتالي، ينبغي لشركات النفط والغاز أن تعيد التفكير في استراتيجيات التعاون والتفاعل مع الجامعات، دون الاقتصار عليهم فقط.

إن التحديات الثلاثة المتعلقة بالنجاح في عصر الذكاء الاصطناعي؛ الوصول إلى البيانات، واكتساب التقنيات الجديدة، وجذب المواهب، تطلب من الشركات عبر الصناعات (بما في ذلك تلك العاملة في صناعة النفط والغاز) ليس فقط الانتقال من الابتكار القريب إلى الابتكار المفتوح فحسب، ولكن أيضاً التحرك من الشراكات إلى نهج النظام البيئي. يتألف نظام النفط والغاز المرتبط بالذكاء الاصطناعي من عدة لاعبين مختلفين؛ شركات ومؤسسات من قطاعات مختلفة، ذات مراحل مختلفة لتطوير الذكاء الاصطناعي، وذات استراتيجيات وأولويات مختلفة.

تركز المجموعة الأولى؛ والتي تتكون بشكل رئيس من شركات النفط العالمية الكبرى، على بناء أول بنية تحتية حديثة لتخزين البيانات (كبحيرات من البيانات)، وعلى رأسها حلول الذكاء الاصطناعي، على سبيل المثال. وتحاول المجموعة الثانية؛ التي تمثلها عادةً الشركات العاملة في الميدان الأصغر حجماً، الاستفادة من كل ما يساعد على تسريع أعمالها وعملياتها التكنولوجية، ومعرفة مشكلات تخزين البيانات ذات الصلة بالتوازي والبنية التحتية لتكنولوجيا المعلومات.

وتمثل المجموعة الثالثة قطاع التكنولوجيا فائقة النشأة، الشركات الناشئة (مثل **Ambyint**)، والجامعات (مثل جامعة ستانفورد)، وشركات خدمات النفط الموجهة نحو التكنولوجيا (مثل **Digital Petroleum**)، والتي تعمل على تطوير أدوات جديدة بمساعدة الذكاء الاصطناعي لشركات النفط (تلك من القرن الأول).

وتمثل المجموعة الرابعة شركات تكنولوجيا المعلومات التي تزود شركات النفط بشكل رئيس بالمنصات الرقمية وقدرات تخزين البيانات. على سبيل المثال، تم اختيار نظام **Microsoft Azure** الأساسي من قبل شركة **Shell** بنية تحتية أساسية لتمكين قابلية التوسع السريع، وتكرار تطبيقات الذكاء الاصطناعي عبر مؤسستها.

وتمثل المجموعة الخامسة المنظمين. وتشارك العديد من الأطراف الأخرى المهمة في تطوير الذكاء الاصطناعي، كالبنوك ومشغلي الاتصالات وغيرهم الكثير. على سبيل المثال، انضمت شركة غازبروم نيفت إلى بعض أكبر شركات التكنولوجيا الروسية (مثل **Yandex** و **Mail.ru** و **MTS** و **Sberbank**)، بهدف تحفيز تطوير حلول الذكاء الاصطناعي، وتسهيل تطوير سوق الذكاء الاصطناعي الديناميكي.

على هذه الشبكة الجديدة المترابطة من الشركاء، الذين لديهم في كثير من الأحيان خبرة محدودة جداً في التعاون السابق، أن يتعلموا كيفية إدارة الاعتماد المتبادل الجديد، وكيفية إنشاء القيمة وملاءمتها ومشاركتها. إن الدور المركزي للبيانات والتقارب المتزايد سيقودان طبيعة الاتصالات بين أعضاء النظام البيئي المتطور والمتوسع للنفط والغاز، مما يحدد كيفية إدارة الأخطار، وتوزيع القيمة، وتنسيق التعاون.

النجاح في المنافسة الرقمية لا يتعلق بالتكنولوجيا فقط. لن تفشل مبادرات الذكاء الاصطناعي بسبب الخوارزميات السيئة، بل بسبب الافتقار إلى الرؤية، أو التأخر في إجراء تغييرات أو حتى عدم حدوث تغييرات في النموذج التشغيلي والتجاري للمؤسسة، بسبب نقص البيانات عالية الدقة وضعف التعاون. وبالتالي، تلعب الإستراتيجية دوراً رئيساً للتحويل الرقمي، ويعتبر التزام الإدارة العليا ضرورياً لضمان نجاح الذكاء الاصطناعي، والجهود التحويلية الأخرى. قد يكون هذا أحد المشكلات الأساسية التي تواجه صناعة النفط والغاز المشهورة بثقافة تجنب الأخطار، وممارسات إدارة الابتكار السيئة.

إن نكهة الفشل التي شهدتها هذه الصناعة مرتين في السنوات الخمس الماضية، وخاصة الأخيرة (أبريل 2020م) التي انخفضت فيها أسعار النفط، ربما تكون الدافع الصحيح لبدء تحويل نماذج أعمالهم.

وبخلاف ذلك، هناك خطر كبير جداً يتمثل في أن النتائج الجيدة في البداية في استخدام الذكاء الاصطناعي لغرض واحد، سيتم فهمها بشكل مضلل على أنها الهدف النهائي. وقد يدفع هذا الشركات إلى زيادة الاستثمار في التكنولوجيا فقط، وهو ما لن يؤدي إلا إلى تحسينات هامشية وليست تحويلية. ومع ذلك، فهذه ليست مشكلة خاصة بصناعة النفط والغاز، حيث أن 8% فقط من الشركات تشارك في الممارسات الأساسية التي تدعم اعتماد الذكاء الاصطناعي على نطاق واسع. وفي الوقت نفسه، فإن غالبية المبادرات عبارة عن مشاريع تجريبية مخصصة تركز على عملية تجارية منفصلة.

وبافتراض غياب الإنجازات التكنولوجية الكبرى في مجال الطاقة، والعواصف الاجتماعية التي تؤثر على اتجاهات الطلب الحالية على الطاقة في السنوات المقبلة، يمكننا تصور ثلاثة سيناريوهات محتملة لانتشار الذكاء الاصطناعي في مجال استخراج النفط والغاز. هنا نفترض أن أزمة كوفيد-19 لن تغير بشكل دائم الافتراضات الرئيسة للصناعة. وتصنف السيناريوهات إلى؛ إيجابية وواقعية وسلبية من حيث استغلال إمكانات تطور الذكاء الاصطناعي.

يعتمد السيناريو الإيجابي على فهم منتشر عالمياً لأهمية مشاركة البيانات عبر الشركات وعبر الحدود. وبافتراض وجود قيادة قوية وملتزمة في الشركات الرئيسة ووجود منصات بيانات جيدة، يمكن للمرء أن يتوقع نمواً سريعاً جداً في قدرات الذكاء الاصطناعي للتطبيقات الأولية، تليها أدوات الذكاء الاصطناعي لاتخاذ القرار على مختلف المستويات. هنا يمكن أن نتوقع بشجاعة إمكانات هائلة في نمو أعمال التنقيب عن النفط والغاز، بسبب التوفير الكبير جداً في التكاليف، والخسائر النقدية بسبب القرارات غير المثالية التي تصل إلى 50% من المستويات الحالية.

هناك أيضًا جزء كبير من التأثير البيئي الموجود هنا. إذا اخترق الذكاء الاصطناعي الصناعة بهذه الطريقة، فإن العديد من الفرص تقلل من البصمة السلبية لتقنيات الأجهزة الأولية. على سبيل المثال، يمكن للمرء استخدام نموذج الذكاء الاصطناعي المناسب لتقليل المكونات الخطرة في وظائف معالجة الآبار أو إعادة استخدام المياه المنتجة بطريقة تحافظ على عامل الاسترداد عند مستوى مناسب.

السيناريو الواقعي (المحايد) هو عندما تكون منصات تكنولوجيا المعلومات موجودة، ولكن التقدم في اتفاقيات تبادل البيانات محدود. «محدود» يعني أن هناك بعض فرص المشاركة الإضافية فيما يتعلق بما لدينا الآن (مثل المشاركة بين مجموعات الشركات داخل الدولة).

سيتم قبول بعض أدوات الذكاء الاصطناعي كمستشارين مفيدتين، وسيتم تحويل التركيز في تطورات الذكاء الاصطناعي نحو نماذج الصندوق الرمادي الهجين، حيث سيعوض الجزء المدفوع بالفيزياء غياب الوصول إلى قدر لا بأس به من البيانات الميدانية الفعلية. من المتوقع أن تكون هذه هي الحالة الأكثر واقعية، حيث يكون التأثير الإجمالي على هوامش المنبع أقل مرتين أو ثلاث مرات مما هو عليه في السيناريو الإيجابي.

السيناريو السلبي يدور حول منع مشاركة البيانات، التوقعات هنا بسيطة مثل نهاية عصر النفط خلال 20 إلى 30 عامًا بسبب الانخفاض المستمر في هوامش مجال المنبع بأكمله، (Koroteev & Tekic, 2021).

التحديات والفرص المستقبلية للذكاء الاصطناعي في علوم الأرض

تتطلب التحديات الجسيمة التي تواجه مجتمعنا حلولاً للمشكلات ذات الطبيعة الجيوفيزيائية، مثل التنبؤ بآثار تغير المناخ، وقياس تلوث الهواء، والتنبؤ بالأخطار المتزايدة على البنى التحتية بسبب الكوارث كالأعاصير، ونمذجة مدى توفر واستهلاك المياه والغذاء والموارد المعدنية في المستقبل، وتحديد العوامل المسؤولة عن الزلازل والانهييارات الأرضية والفيضانات والانبعاثات البركانية. تتم دراسة مثل هذه المشكلات عند التقاء العديد من التخصصات مثل الفيزياء والجيولوجيا والهيدرولوجيا والكيمياء والأحياء والبيئة والأنثروبولوجيا التي تطمح إلى فهم نظام الأرض ومكوناته المختلفة المتفاعلة، والتي يشار إليها مجتمعة بمجال علوم الأرض.

مع استمرار طوفان البيانات الضخمة في التأثير عملياً على كل المجالات التجارية والعلمية، شهدت علوم الأرض أيضاً ثورة كبيرة من كونها مجالاً فقيراً بالبيانات إلى مجال غني بالبيانات. وقد أصبح هذا ممكناً مع ظهور تقنيات استشعار أفضل (مثل أقمار الاستشعار عن بعد، وسفن الحفر في أعماق البحار)، والتحسينات في الموارد الحاسوبية لتشغيل عمليات محاكاة واسعة النطاق لنماذج نظام الأرض، وإضفاء الطابع الديمقراطي على البيانات على شبكة الإنترنت، التي مكنت جمع وتخزين ومعالجة البيانات في البيئات ذات المصادر الجماعية والمنشورة، مثل المنصات السحابية.

معظم مجموعات بيانات علوم الأرض متاحة للجمهور، ولا تعاني من مشكلات الخصوصية التي أعاقَت اعتماد منهجيات علوم البيانات في مجالات أخرى، مثل الرعاية الصحية والأمن السيبراني.

يوفر الفيض المتزايد لبيانات علوم الأرض الكبيرة إمكانات عظيمة للتعلم الآلي (ML)، الذي أحدث ثورة في جميع جوانب حياتنا تقريباً (مثل التجارة والنقل والترفيه)، للمساهمة بشكل كبير في مشكلات علوم الأرض ذات الأهمية المجتمعية الكبيرة.

نظراً لتنوع التخصصات المشاركة في أبحاث علوم الأرض والطبيعة المتنوعة للمسائل التي يتم التحقيق فيها، فإن تحليل بيانات علوم الأرض له العديد من الجوانب الفريدة التي تختلف بشكل لافت للنظر عن مشكلات علم البيانات القياسية التي تتم مواجهتها في المجالات التجارية. على سبيل المثال، تخضع ظواهر علوم الأرض للقوانين والمبادئ الفيزيائية، وتتضمن أشياء وعلاقات غالباً ما يكون لها حدود غير متبلورة، ومتغيرات كامنة معقدة.

تحفز التحديات التي تفرضها هذه الخصائص على تطوير تركيبات ومنهجيات جديدة للمشكلات في التعلم الآلي، والتي قد تكون قابلة للتطبيق على نطاق واسع على المشكلات حتى خارج نطاق علوم الأرض. وبالتالي، هناك فرصة عظيمة للباحثين في مجال التعلم الآلي للتعاون بشكل وثيق مع علماء الجيولوجيا، وتلاقح الأفكار عبر التخصصات لتعزيز حدود التعلم الآلي وكذلك علوم الأرض.

هناك العديد من المجتمعات التي تعمل في هذا المجال الناشئ للتعاون متعدد التخصصات عند تقاطع علوم الأرض والتعلم الآلي. وتشمل هذه، على سبيل المثال لا الحصر، معلوماتية المناخ: مجتمع من الباحثين يعقدون ورش عمل سنوية لمواجهة المشكلات في علوم المناخ بأساليب الإحصاء والتعلم الآلي، واستخراج البيانات. رحلات تغير المناخ: تعاون متعدد التخصصات، ومتعدد المؤسسات بتمويل من البعثات الاستكشافية لمؤسسة العلوم الوطنية (NSF) في منحة الحوسبة حول «فهم تغير المناخ: نهج يعتمد على البيانات»؛ و ESSI: مجموعة تركيز تابعة للاتحاد الجيوفيزيائي الأمريكي (AGU) حول معلوماتية علوم الأرض والفضاء. وفي الآونة الأخيرة، قامت NSF بتمويل شبكة تنسيق بحثية حول الأنظمة الذكية لعلوم الأرض (IS-GEO)، بهدف إقامة روابط أقوى بين المجتمعين.

علاوة على ذلك، تم عقد عدد من المؤتمرات الرائدة في التعلم الآلي، واستخراج البيانات، مثل اكتشاف المعرفة والتقيب عن البيانات (KDD)، ومؤتمر IEEE الدولي

للتقريب عن البيانات (ICDM)، ومؤتمر SIAM الدولي للتقريب عن البيانات (SDM)، وأنظمة معالجة المعلومات العصبية (NIPS) تضمنت ورش عمل أو برامج تعليمية حول موضوعات تتعلق بعلوم الأرض. كما تم الاعتراف بدور البيانات الضخمة في علوم الأرض في المقالات المنظرية الحديثة، والأعداد الخاصة للمجلات.

سنتعرف الآن على مجتمع التعلم الآلي (ML)، والفرص والتحديات التي توفرها مشكلات علوم الأرض.

• مصادر بيانات علوم الأرض

الأرض ومكوناتها الرئيسية المتفاعلة (مثل الغلاف الصخري، والغلاف الحيوي، والغلاف المائي، والغلاف الجوي) هي أنظمة ديناميكية معقدة تتغير فيها حالات النظام بشكل دائم في المكان والزمان، من أجل خلق توازن بين الكتلة والطاقة. تتفاعل عناصر نظام الأرض (مثل طبقات المحيطات، والأيونات في الهواء، والمعادن والحبيبات في الصخور، والأغطية الأرضية على الأرض) مع بعضها البعض من عمليات علوم الأرض المعقدة والديناميكية (مثل سقوط المطر على سطح الأرض، وتغذيته للكتلة الحيوية، والرواسب التي تترسب على ضفاف الأنهار وتغير مجرى النهر، وانفجار الصحارة في قاع البحر وتشكيل الجزر).

عمومًا، يمكن الحصول على البيانات المتعلقة بمكونات نظام الأرض وعمليات علوم الأرض من فئتين واسعتين من مصادر البيانات:

- بيانات الرصد التي يتم جمعها عبر أجهزة الاستشعار في الفضاء أو في البحر أو على الأرض.
 - بيانات المحاكاة من النماذج القائمة على الفيزياء لنظام الأرض.
- وسنوضح بإيجاز هاتين الفئتين من مصادر بيانات علوم الأرض فيما يأتي.

■ أرصاد علوم الأرض

يتم جمع المعلومات حول نظام الأرض عبر طرق الحصول المختلفة على مستويات مختلفة من المكان والزمان ولمجموعة متنوعة من أهداف علوم الأرض. على سبيل المثال، هناك مجموعة من الأقمار الصناعية لمراقبة الأرض في الفضاء والتي تم تكليفها بمراقبة عدد من متغيرات علوم الأرض مثل، درجة حرارة السطح والرطوبة والانعكاس البصري والتركيبات الكيميائية للغلاف الجوي.

هناك مجموعة متنامية من منظمات أبحاث الفضاء، بدءاً من الوكالات العامة مثل الإدارة الوطنية للملاحة الجوية والفضاء (NASA)، ووكالة الفضاء الأوروبية (ESA)، ووكالة استكشاف الفضاء اليابانية (JAXA)، إلى الشركات الخاصة مثل (SpaceX) التي تساهم كلها معاً في توفير الحجم الهائل والمتنوع من بيانات الاستشعار عن بعد حول أرضنا، والعديد منها متاح للجمهور.

توفر بيانات الاستشعار عن بعد صورة عالمية لتاريخ متغيرات علوم الأرض على نطاقات مكانية دقيقة (من كيلومتر واحد إلى 10 أمتار وأقل)، وعلى فترات زمنية منتظمة (شهرية إلى يومية)، أو لفترات طويلة، بدءاً بعضها من السبعينات (مثل: أرشيفات لاندسات). بالنسبة للدراسات المستهدفة لمناطق جغرافية محددة ذات أهمية، يمكن أيضاً جمع ملاحظات علوم الأرض باستخدام أجهزة استشعار على متن الأجهزة الطائرة مثل؛ المركبات الجوية بدون طيار (الدرونز) أو الطائرات، لاكتشاف وتصنيف مصادر غاز الميثان (أحد غازات الدفيئة القوية)، المنبعثة في الغلاف الجوي.

مصدر رئيس آخر لملاحظات علوم الأرض، هو مجموعة أجهزة الاستشعار الموجودة في مواضع خاصة على الأرض (مثل محطات الأرصاد الجوية)، أو المتحركة في الغلاف الجوي (مثل بالونات الطقس)، أو المحيط (مثل السفن والعوامات المحيطية).

تتوفر عمليات الرصد المستندة إلى أجهزة الاستشعار لعمليات علوم الأرض بشكل عام عبر شبكات غير موحدة في الفضاء، وعلى فترات زمنية غير منتظمة، وأحياناً على الأجسام المتحركة مثل؛ البالونات أو السفن أو العوامات.

وهي تشكل بعضاً من مصادر المعلومات الأكثر موثوقية ومباشرة حول أنظمة الطقس والمناخ على الأرض، وتتم صيانتها بشكل نشط من قبل الوكالات العامة كالإدارة الوطنية للمحيطات والغلاف الجوي (NOAA). تعد القياسات المستندة إلى أجهزة الاستشعار؛ من مقاييس الأمطار والأنهار أساسية أيضاً لفهم العمليات الهيدرولوجية مثل تصريف المياه السطحية. كما تقوم أجهزة الاستشعار الزلزالية الأرضية، والأجهزة التي تدعم نظام تحديد المواقع العالمي (GPS)، وغيرها من الأدوات الجيوفيزيائية، بقياس البنى والعمليات الجيولوجية للأرض باستمرار.

بالإضافة إلى ذلك، هناك أيضاً قياسات بديلة مثل السجلات المناخية القديمة التي لا تتوفر إلا بشكل قليل في عدد قليل من المواقع المختارة، ولكنها تعود إلى عدة آلاف من السنين. نظراً للتنوع الكبير في خصائص البيانات لعمليات علوم الأرض المختلفة، فمن المهم تحديد نوع وخصائص مجموعة بيانات معينة لعلوم الأرض لتحقيق أقصى استفادة من منهجيات تحليل البيانات ذات الصلة.

على سبيل المثال، يمكن تمثيل مجموعات بيانات الاستشعار عن بعد، والتي تتوفر عادة على هيئة بيانات نقطية على خلايا شبكية متباعدة بانتظام في المكان والزمان، كصور مسجلة جغرافياً عبر نقاط زمنية فردية أو كبيانات سلاسل زمنية، في مواقع مكانية فردية. من ناحية أخرى، يمكن تمثيل قياسات أجهزة الاستشعار من السفن والعوامات المحيطية على هيئة بيانات مرجعية نقطية (تسمى أيضاً البيانات الإحصائية الجغرافية في أدبيات الإحصاءات المكانية) للحقول المكانية والزمانية المستمرة.

في الواقع، من الممكن تحويل نوع بيانات إلى آخر وعبر دقة مكانية وزمانية مختلفة، باستخدام طرق الاستيفاء البسيطة، أو طرق أكثر تقدماً تعتمد على الفهم المادي، مثل تقنيات إعادة التحليل.

■ محاكاة نموذج نظام الأرض

أحد الجوانب الفريدة لعمليات علم الأرض هو أن العلاقات بين المتغيرات أو تطور حالات النظام تتركز بعمق على القوانين والمبادئ الفيزيائية، التي اكتشفها المجتمع العلمي على مدى قرون عديدة من البحث المنهجي. على سبيل المثال، حركة الماء في الغلاف الصخري، أو حركة الهواء في الغلاف الجوي، تحكمها مبادئ ديناميكيات الموائع مثل معادلة نافير-ستوكس **Navier- Stokes Equation**.

على الرغم من أن مثل هذه المعادلات القائمة على الفيزياء يمكن حلها في بعض الأحيان بشكل مغلق للتجارب صغيرة الحجم، إلا أنه في أغلب الأحيان يكون من الصعب الحصول على حلول دقيقة لأنظمة العالم الحقيقي المعقدة، التي نواجهها في علوم الأرض. ومع ذلك، لا يزال من الممكن استخدام المبادئ الفيزيائية الأساسية لمحاكاة تطور حالات نظام الأرض، باستخدام النماذج الرقمية التي يشار إليها بالنماذج القائمة على الفيزياء.

مثل هذه النماذج هي العمود الفقري القياسي لدراسة غالبية عمليات علوم الأرض، حيث يمكن إرجاع حالة النظام الديناميكي إلى الوراء في الماضي أو إلى الأمام في المستقبل باستخدام مدخلات مثل؛ الشروط الأولية والحدية أو قيم الملاحظات الداخلية في المعادلات الفيزيائية. تولد النماذج المستندة إلى الفيزياء كميات كبيرة من بيانات المحاكاة لمكونات مختلفة لنظام الأرض، والتي يمكن استخدامها في التحليلات المستندة إلى البيانات. ويتم تطويرها وصيانتها من قبل عدد من المراكز التي تشكل مجموعات متنوعة من الباحثين حول العالم.

على سبيل المثال، يقوم برنامج أبحاث المناخ العالمي (WCRP) بتطوير وتوزيع عمليات محاكاة لنماذج الدورة العامة (GCM) للمتغيرات المناخية مثل؛ درجة حرارة سطح البحر، والضغط الجوي في إطار مشروع مقارنة النماذج المزدوجة (CMIP).

يتم إنتاج عمليات محاكاة العمليات الأرضية المتعلقة بالغلاف الصخري والمحيط الحيوي بواسطة نموذج الأرض المجتمعية (CLM)، الذي طورته عدد من الوكالات الدولية المتعاونة مع المركز الوطني لأبحاث الغلاف الجوي (NCAR).

• تحديات علوم الأرض

هناك العديد من الخصائص لتطبيقات علوم الأرض التي تحد من فائدة خوارزميات التعلم الآلي التقليدية لاكتشاف المعرفة.

أولاً: هناك بعض التحديات المتأصلة الناشئة عن طبيعة عمليات علوم الأرض. على سبيل المثال، تتمتع الكيانات في علوم الأرض بشكل عام بحدود غير متبلورة في المكان والزمان، والتي لا يتم تعريفها بشكل واضح، مثل الكيانات الموجودة في المجالات الأخرى، كالمستخدمين على موقع ويب للشبكات الاجتماعية، أو المنتجات في متجر بيع بالتجزئة.

تمتلك ظواهر علوم الأرض أيضاً بُنى مكانية وزمانية، وهي شديدة التنوع، وتتبع علاقات غير خطية (فوضوية)، وتظهر خصائص متغيرة، وغالباً ما تتضمن أحداثاً نادرة، ولكنها مثيرة للاهتمام.

ثانياً: بصرف النظر عن التحديات الكامنة في عمليات علوم الأرض، فإن الإجراءات المستخدمة لجمع ملاحظات علوم الأرض تقدم المزيد من التحديات للتعلم الآلي. يتضمن ذلك البيانات الدقيقة المتعددة للمكان والزمان، بدرجات متفاوتة من التشويش، وعدم الاكتمال وكثرة الشكوك.

ثالثاً: بالنسبة لمناهج التعلم الخاضع للإشراف، هناك تحديات إضافية بسبب صغر حجم العينة (عدد صغير من السنوات التاريخية مع سجلات كافية)، والافتقار إلى الحقيقة الأساسية المعيارية في تطبيقات علوم الأرض.

وفيما يلي، نعرض هذه الفئات الثلاث من تحديات علوم الأرض، وهي:

- التحديات الكامنة في عمليات علوم الأرض.
- تحديات جمع بيانات علوم الأرض.
- ندرة العينات والحقائق الأرضية بالتفصيل.

• التحديات الكامنة في عمليات علوم الأرض

• الخاصية 1: الكيانات ذات الحدود غير المتبلورة

تشمل كيانات علوم الأرض؛ الموجات والتدفقات والبنىات المتماسكة في جميع مراحل المادة. ومن ثم، فإن شكل وبنية وأنماط كيانات علوم الأرض التي يمكن أن توجد على مستويات متعددة في مجالات مكانية وزمانية مستمرة، هي أكثر تعقيداً بكثير من تلك الموجودة في المساحات المنفصلة التي تتعامل معها خوارزميات التعلم الآلي عادةً، مثل العناصر الموجودة في بيانات سلة السوق.

على سبيل المثال، تتشوه الدوامات والعواصف والأعاصير ديناميكياً بطرق معقدة من منظور بحث موجه للكيانات. ويجري تطوير تقنيات جديدة للنظر في كل من النموذج والمعلومات الديناميكية للأجسام المتماسكة وأوجه عدم اليقين الخاصة بها، ولكن هناك حاجة إلى طرق جديدة لالتقاط سمات أخرى لأجسام علوم الأرض، على سبيل المثال، تجزئة السوائل، وتوصيف سمات السوائل.

• الخاصية 2: الهيكل الزماني المكاني

نظراً لأن كل ظواهر علوم الأرض تقريباً تحدث في عالم المكان والزمان، فإن ملاحظات علوم الأرض تكون بشكل عام مرتبطة ذاتياً في كل من المكان والزمان عند ملاحظتها بدقة مكانية وزمانية مناسبة. على سبيل المثال، الموقع الذي يتم تغطيته بغطاء أرضي معين (على سبيل المثال، غابة أو شجيرات أو منطقة حضرية)، يكون عامة محاطاً بمواقع لها تسميات أغطية أرضية مماثلة.

كما أن تسميات الغطاء الأرضي تكون متسقة أيضاً على مدار الوقت، أي أن الغطاء في وقت معين يرتبط بالتسميات الموجودة في محيطه الزمني المباشر. علاوة

على ذلك، إذا تغير الغطاء الأرضي في موقع معين (على سبيل المثال، من الغابات إلى الأراضي الزراعية)، فإن التغيير يستمر عمومًا لمدة زمنية معينة بدلاً من التبديل ذهابًا وإيابًا. على الرغم من أن الارتباط الذاتي بالمكان والزمان يفرض اتصالاً أقوى بين الملاحظات القريبة في المكان والزمان، إلا أن عمليات علوم الأرض يمكن أن تظهر أيضًا تبعيات مكانية طويلة المدى.

مثال، إحدى الظواهر التي تتم دراستها بشكل شائع في علم المناخ هي الاتصالات عن بعد، حيث تظهر منطقتان بعيدتان في العالم نشاطًا مقترنًا بقوة في متغيرات المناخ مثل درجة الحرارة أو الضغط. يمكن أن تظهر عمليات علوم الأرض أيضًا خصائص الذاكرة الطويلة مع مرور الوقت، على سبيل المثال، تأثير مؤشرات المناخ مثل التذبذب الجنوبي لظاهرة النينو (ENSO)، وتذبذب الأطلسي متعدد العقود (AMO)، والفيضانات العالمية وحالات الجفاف وحرائق الغابات.

إن البنية المكانية والزمانية المتأصلة لبيانات علوم الأرض لها آثار عديدة على أساليب التعلم الآلي. وذلك لأن العديد من أساليب التعلم الآلي المستخدمة على نطاق واسع مبنية على افتراض أن المتغيرات المرصودة مستقلة وموزعة بشكل مماثل (i.i.d). ومع ذلك، يتم انتهاك هذا الافتراض بشكل روتيني في مشكلات علوم الأرض، حيث ترتبط المتغيرات هيكليًا ببعضها البعض في سياق المكان والزمان، ما لم يكن هناك انقطاع، مثل الخطأ، الذي يتوقف عبره الارتباط الذاتي. يعد إدراك الارتباط الذاتي المكاني والزمني في بيانات علوم الأرض التي تم جمعها في الوسائط المستمرة أمرًا بالغ الأهمية للنمذجة الفاعلة للظواهر الجيوفيزيائية.

• الخاصية 3: الأبعاد المرتفعة

إن نظام الأرض معقد جدًا، بشكل لا يصدق، خاصة مع وجود عدد كبير من المتغيرات المحتملة، والتي قد تؤثر جميعها على بعضها البعض، وبالتالي قد يتعين النظر في العديد منها في وقت واحد.

مثال، يتطلب الكشف القوي والكامل لتغيرات الغطاء الأرضي، كحرائق الغابات، تحليل متغيرات الاستشعار عن بعد المتعددة، مثل مؤشرات الغطاء النباتي وإشارات الشذوذ الحراري. إن التقاط تأثيرات هذه المتغيرات المتعددة بدقة دقيقة للمكان والزمان يجعل بيانات علوم الأرض ذات أبعاد مرتفعة بطبيعتها، حيث يمكن أن يصل عدد الأبعاد بسهولة إلى الملايين.

مثال، من أجل دراسة العمليات التي تحدث على سطح الأرض، حتى مجموعة البيانات ذات الدقة الخشنة نسبياً (عند 2.5 درجة من الدقة المكانية)، قد تؤدي بسهولة إلى أكثر من 10000 نقطة مكانية على الشبكة، حيث تحتوي كل نقطة شبكية على عمليات رصد متعددة في الوقت المناسب. علاوة على ذلك، لا تقتصر ظواهر علوم الأرض على سطح الأرض، ولكنها تمتد لما تحت سطح الأرض (دراسة المياه الجوفية، والنفط، والصدوع)، وعبر طبقات متعددة في الغلاف الصخري أو في الوشاح، مما يزيد من أبعاد البيانات، وفي اتخاذ القرارات المكانية ثلاثية الأبعاد.

ومن ثم، فإن هناك حاجة إلى توسيع نطاق أساليب التعلم الآلي الحالية للتعامل مع عشرات الآلاف أو الملايين من الأبعاد، للتحليل العالمي لظواهر علوم الأرض.

• الخاصية 4: عدم التجانس في المكان والزمان

من الخصائص المثيرة للاهتمام لعمليات علوم الأرض درجة تباينها في المكان والزمان، مما يؤدي إلى عدم تجانس غني في بيانات علوم الأرض عبر المكان والزمان. فبسبب وجود اختلاف في مناطق جغرافية، وأنواع الغطاء النباتي، والتكوينات الصخرية، والظروف المناخية في مناطق مختلفة من الأرض، فإن خصائص متغيرات علوم الأرض تختلف بشكل كبير من موقع إلى آخر. علاوة على ذلك، فإن نظام الأرض ليس ثابتاً زمنياً، ويمر بالعديد من الدورات، بدءاً من الدورات الموسمية والعقدية، إلى التغيرات الجيولوجية طويلة المدى (مثل التجلد وانعكاسات القطبية)، وحتى ظواهر تغير المناخ التي تؤثر على جميع العمليات المحلية.

هذا التباين في عمليات علوم الأرض، يجعل من الصعب دراسة التوزيع المشترك لمتغيرات علوم الأرض عبر جميع النقاط في المكان والزمان. ومن ثم، فمن الصعب تدريب نماذج التعلم الآلي التي تتمتع بأداء جيد في جميع المناطق في الفضاء، وفي جميع الخطوات الزمنية. وبدلاً من ذلك، هناك حاجة إلى بناء نماذج محلية أو إقليمية، يتوافق كل منها مع مجموعة متجانسة من الملاحظات.

• الخاصية 5: الاهتمام بالظواهر النادرة

في عدد من مسائل علوم الأرض، يثار اهتمام بدراسة الكيانات والعمليات والأحداث التي تحدث بشكل غير متكرر في المكان والزمان، ولكن لها تأثيرات كبيرة على المجتمع والنظام البيئي للأرض. إذ يمكن أن تؤدي الأحداث المناخية القاسية مثل الأعاصير والفيضانات المفاجئة، وموجات الحرارة الشديدة إلى خسائر فادحة في الأرواح والممتلكات، مما يجعل من الضروري مراقبتها لتحقيق متطلبات التخفيف من آثارها والتكيف معها. قد تتعلق هذه العمليات بالحالات الطارئة (أو الشاذة) لنظام الأرض، أو غيرها من سمات الأنظمة المعقدة مثل؛ مسارات الشذات وأحواض الجذب. ومثال آخر، يمكن أن يكون اكتشاف التغيرات النادرة في المحيط الحيوي للأرض، مثل إزالة الغابات، وأضرار الحشرات، وحرائق الغابات، مفيداً في تقييم تأثير الأفعال البشرية واتخاذ قرارات مستتيرة لتعزيز استدامة النظام البيئي.

يعد تحديد مثل هذه الفئات النادرة من التغيرات والأحداث من بيانات علوم الأرض وتوصيف سلوكها أمراً صعباً، وذلك لعدم توفر عدد كافٍ من عينات البيانات من الفئة النادرة، بسبب عدم التوازن فيما بين الفئات، مما يجعل نمذجتها وتوصيفها صعباً.

• تحديات جمع بيانات علوم الأرض

• الخاصية 6: بيانات متعددة الدقة

غالبًا ما تكون مجموعات بيانات علوم الأرض متاحة عبر مصادر مختلفة (كأجهزة استشعار الأقمار الصناعية، وقياسات الموقع، وعمليات المحاكاة القائمة على النماذج)، وبدقة مكانية وزمانية مختلفة.

قد تظهر مجموعات البيانات هذه خصائص مختلفة، مثل معدل أخذ العينات، والدقة وعدم اليقين. على سبيل المثال، غالبًا ما تكون أجهزة الاستشعار الموجودة في الموقع، مثل العوامات في المحيط ومحطات القياس الهيدرولوجية والطقس، متباعدة بشكل غير منتظم.

ومثال آخر، قد يتطلب جمع بيانات عالية الدقة لعمليات النظام البيئي، مثل حرائق الغابات، واستخدام الصور الجوية من الطائرات التي تحلق فوق المنطقة محل الاهتمام، والتي قد تحتاج إلى دمجها مع صور الأقمار الصناعية ذات الدقة الخشنة المتاحة على فترات زمنية متكررة.

يمكن أن يساعدنا تحليل مجموعات بيانات علوم الأرض متعددة الدقة في توصيف العمليات التي تحدث على مستويات مختلفة من المكان والزمان. على سبيل المثال، تحدث عمليات أرضية مثل تكتونية الصفائح والجاذبية على نطاق عالمي، في حين تشمل العمليات المحلية؛ البراكين والزلازل والانهيارات الأرضية.

للتعامل مع البيانات متعددة الدقة، يتمثل النهج الشائع في بناء جسر بين مجموعات البيانات بمقاييس متباينة (استخدام تقنيات الاستيفاء)، بحيث يمكن تمثيلها بالدقة نفسها. نحتاج أيضًا إلى تطوير خوارزميات يمكنها تحديد الأنماط المتعددة بدقة دون تجميع كل مجموعات البيانات إلى أعلى دقة.

• الخاصية 7: الضوضاء وعدم الاكتمال وعدم اليقين في البيانات

العديد من مجموعات بيانات علوم الأرض (تلك التي تم جمعها بواسطة أجهزة استشعار الأقمار الصناعية لرصد الأرض)، تعاني من الضوضاء والقيم المفقودة. فقد تتعطل أجهزة الاستشعار مؤقتاً بسبب الأعطال أو الظروف الجوية القاسية، مما يؤدي إلى فقدان بعض البيانات. إضافة إلى ذلك، فإن التغيرات في معدات القياس، (استبدال جهاز استشعار معيب أو التبديل من جيل قمر صناعي إلى آخر)، قد تغير تفسير قيم أجهزة الاستشعار بمرور الوقت، مما يجعل من الصعب نشر منهجية متسقة للتحليل عبر فترات زمنية مختلفة. في العديد من تطبيقات علوم الأرض، يمكن أن تكون الإشارة محل الاهتمام، صغيرة الحجم مقارنة بحجم الضوضاء. كما يمكن أن تؤدي العديد من خصائص أجهزة الاستشعار إلى زيادة الضوضاء، مثل تداخل أجهزة الاستشعار. على سبيل المثال، في حالة بيانات سطح الأرض المستشعرة عن بعد، حيث يتم مواجهة التداخل المستمر في الغلاف الجوي (من سحب وهباء جوي)، والسطح (ثلج وجليد). ولا يمكن حتى قياس العديد من متغيرات علوم الأرض بشكل مباشر، ولكن لا يمكن استنتاجها إلا من ملاحظات أخرى أو عمليات محاكاة نموذجية. على سبيل المثال، يمكن للمرء استخدام مقاييس الطيف التصويرية المحمولة جواً للكشف عن مصادر غاز الميثان (تسرب خطوط الأنابيب)، وهو أحد غازات الدفيئة المهمة. تقوم هذه الأجهزة بإجراء مسوحات علوية وترسم خريطة لأشعة الشمس المنعكسة عن الأرض والتي تصل إلى المستشعر. ويمكن بعد ذلك التعرف على أعمدة الميثان من خلال امتصاص ضوء الشمس الزائد.

ولتحديد معدل التسرب (التدفق) وتأثير الغازات الدفيئة الناتج، يجب على المرء أيضاً معرفة مدى سرعة تشتت كتلة الميثان الزائدة. وهذا يتطلب النظر في تأثير النقل الجوي، والذي يتطلب بدوره افتراضات فيزيائية ثابتة، أو نمذجة أعمدة قائمة على التشكل، أو قياسات مباشرة في الموقع لسرعة الرياح.

حتى البيانات الناتجة عن مخرجات النموذج تتطوي على شكوك، لعدم اكتمال معرفتنا بالظروف الأولية وحدودية النظام أو الأشكال العلمية للتقريبات المستخدمة في النموذج.

• ندرة العينات والحقيقة الأرضية

الخاصية 8: صغر حجم العينة

غالبًا ما يكون عدد العينات في مجموعات بيانات علوم الأرض محدودًا من حيث المكان والزمان. وتشمل العوامل التي تحد من حجم العينة: تاريخ جمع البيانات وطبيعة الظاهرة التي يتم قياسها. مثال، معظم منتجات الأقمار الصناعية متاحة فقط منذ السبعينات، وعندما تؤخذ العمليات الشهرية/السنوية في الاعتبار، فهذا يعني أن هناك أقل من 600 عينة متاحة.


علاوة على ذلك، هناك العديد من الأحداث في علوم الأرض التي من المهم مراقبتها، وإن كانت تحدث بشكل نادر جدًا، مما يؤدي إلى أحجام عينات صغيرة. على سبيل المثال، تعد غالبية تغيرات الغطاء الأرضي والانهيانات الأرضية والتسونامي وحرائق الغابات أحداثًا نادرة، ولا تحدث إلا لفترات زمنية قصيرة في الغالب فوق مناطق مكانية صغيرة. مع أقل من 80 عامًا من البيانات الموثوقة المستندة إلى أجهزة الاستشعار، لا تتوفر سوى بضع عشرات من الأحداث النادرة كبيانات للتدريب.

إن الدقة المكانية والزمانية المحدودة لبعض متغيرات علوم الأرض محدودة أيضًا بطبيعة منهجية المراقبة. مثال، يتم استخلاص بيانات المناخ القديم من المرجان ورواسب البحيرات (الفارفات **Varves**)، وحلقات الأشجار، وعينات الجليد العميقة، والتي لا تتوفر إلا في أماكن قليلة حول الأرض. وبالمثل، فإن السجلات المبكرة لتساقط الأمطار موجودة فقط في المناطق التي تغطيها اليابسة. وعلى النقيض، هناك التطبيقات التجارية التي تتضمن بيانات على نطاق الإنترنت، كاستخراج النصوص أو التعرف على الكيانات، حيث كانت الكميات الكبيرة من البيانات المصنفة أو غير المسماة أحد العوامل الرئيسية وراء نجاح منهجيات التعلم الآلي كالتعلم العميق.

يؤدي العدد المحدود من العينات في تطبيقات علوم الأرض إلى جانب العدد الكبير من المتغيرات الفيزيائية إلى مشكلات غير مقيدة بطبيعتها، وتتطلب تطورات جديدة في التعلم الآلي لإجراء تحليلاتها القوية.

• الخاصية 9: ندرة الحقيقة الأرضية

على الرغم من أن العديد من تطبيقات علوم الأرض تتضمن كميات كبيرة من البيانات، مثل عمليات الرصد العالمية لمتغيرات النظام البيئي بدقة مكانية وزمانية عالية، ناتجة من أقمار مراقبة الأرض، فإن السمة المشتركة لمشكلات علوم الأرض هي ندرة العينات المصنفة بالحقيقة الأرضية ذات المعيارية الذهبية.



كيف يمكن للذكاء الاصطناعي تحسين توقعات تسونامي؟ يقوم النظام بتخزين خصائص الزلازل والتسونامي التاريخية والمحكية، عبر شبكة من الأدوات التي تراقب الأحداث. تعتمد الخوارزميات على البيانات للتنبؤ بخصائص الموجة بعد دقائق قليلة فقط من البيانات الحقيقية، (EOS, American Geophysical Union)

وذلك لأن القياسات عالية الجودة للعديد من متغيرات علوم الأرض لا يمكن إجراؤها إلا بواسطة أجهزة باهظة الثمن؛ كالتأثيرات التي تحلق على ارتفاع منخفض، أو عمليات شاقة ومستهلكة للوقت؛ كالمسوحات الميدانية، والتي تحد بشدة من جمع عينات الحقيقة الأرضية.

عمليات علوم الأرض الأخرى (مثل تدفق المياه تحت السطح)، ليس لها حقيقة أساسية على الإطلاق. لأنه بسبب تعقيد النظام، فإن الحالة الدقيقة له غير معروفة تماماً على الإطلاق.

يمكن أن تؤدي ندرة العينات الممثلة للتدريب، إلى ضعف الأداء للعديد من أساليب التعلم الآلي، إما بسبب عدم التناسب حيث يكون النموذج بسيطاً جداً، أو بسبب التجاوز، حيث يكون النموذج معقداً جداً بالنسبة لأبعاد السمات والعدد المحدود لعينات التدريب.

لذلك؛ هناك حاجة لتطوير أساليب التعلم الآلي التي يمكنها تعلم نماذج شحيحة حتى في ظل ندرة البيانات المصنفة. والاحتمال الآخر هو إنشاء مجموعات بيانات تركيبية باستخدام عمليات المحاكاة أو الاضطراب التي يمكن استخدامها للتدريب، لتحقيق أقصى استفادة من الملاحظات القليلة.

• مشكلات علوم الأرض وتوجيهات تعلم الآلة

يسعى علماء الجيولوجيا باستمرار إلى تطوير أساليب أفضل لنمذجة الوضع الحالي لنظام الأرض (مقدار غاز الميثان الذي يتسرب إلى الغلاف الجوي في الوقت الحالي، وتلك الأجزاء من الأرض التي تغطيها أي نوع من الكتلة الحيوية)، وتطورها، بالإضافة إلى الروابط داخل جميع أنظمتها الفرعية وفيما بينها (كيف يؤثر ارتفاع درجة حرارة المحيط على أنظمة بيئية محددة). ويهدف هذا إلى تعزيز الفهم العلمي لعمليات علوم الأرض.

ويمكن أن يساعد ذلك أيضاً في توفير معلومات قابلة للتنفيذ (تحذيرات الطقس المتطرف)، أو اتخاذ قرارات مستتيرة تتعلق بالسياسات التي تؤثر بشكل مباشر على مجتمعنا (التكيف مع تغير المناخ، والتقدم نحو أنماط الحياة المستدامة).

غالباً ما تكون الحدود بين هذه الأهداف غير واضحة في الممارسة العملية، فقد يؤدي نموذج الإعصار المحسن في الوقت نفسه إلى نموذج علمي أفضل بالإضافة إلى نظام إنذار أكثر فاعلية.

ومن منظور علوم الأرض، فإن العديد من أساليب التعلم الآلي تعد مناسبة بشكل طبيعي للمشكلات التي تواجهها تطبيقات علوم الأرض. إذ تعد طرق التصنيف والتعرف على الأنماط مفيدة في تحديد خصائص الكيانات مثل الأحداث الجوية القاسية أو حشود الهزات النذيرة أو الهزات الارتدادية (الهزات التي تسبق الزلزال أو تليه)، وتقدير متغيرات علوم الأرض، وإنتاج تنبؤات طويلة المدى لحالة نظام الأرض. وكمثال آخر، يمكن أن توفر أساليب علاقات التعدين والعزو السببي نظرة ثاقبة للعمل الداخلي لنظام الأرض ودعم صنع السياسات.

فيما يلي تصنيف مختصر لخمس فئات واسعة من مشكلات علوم الأرض، واتجاهات التعلم الآلي الواعدة، وأمثلة لبعض النجاحات الحديثة ذات الصلة بكل مشكلة.

■ توصيف الكيانات والأحداث

يمكن أن تساعد خوارزميات التعلم الآلي في توصيف الكيانات والأحداث في علوم الأرض التي تُعد بالغة الأهمية لفهم نظام الأرض. على سبيل المثال، يمكننا تحليل الأنماط في مجموعات بيانات علوم الأرض للكشف عن الأحداث المناخية مثل تكوين التدوير والإعصار، واكتشاف أسلافها للتنبؤ بها مع فترات زمنية طويلة.

يمكن أن يساعد تحليل الأنماط المكانية والزمانية في بيانات علوم الأرض أيضًا في دراسة تكوين وحركة الأجسام المناخية مثل؛ الجبهات الجوية، والأنهار الجوية، ودوامات المحيطات، والتي تعد محركات رئيسة لعمليات علوم الأرض الحيوية مثل؛ نقل تساقط الأمطار، والطاقة والتغير المناخي، والعناصر الغذائية في الغلاف الجوي والمحيطات.

بينما تعتمد الأساليب التقليدية في المقام الأول، لتوصيف أجسام وأحداث علوم الأرض على استخدام السمات المشفرة يدويًا (القواعد المخصصة بشأن قيود الحجم والشكل للعثور على الدوامات المحيطية)، يمكن لخوارزميات التعلم الآلي تمكين اكتشافها تلقائيًا من البيانات، باستخدام تحسينات محسنة الأداء باستخدام تقنيات التعدين نمط.

ومع ذلك، في ظل وجود كيانات مكانية وزمانية ذات حدود غير متبلورة، وما يرتبط بها من أوجه عدم اليقين، هناك حاجة إلى تطوير أساليب تعدين الأنماط التي يمكن أن تأخذ في الاعتبار الخصائص المكانية والزمانية لبيانات علوم الأرض، مع وصف الكيانات والأحداث.

وقد تم استخدام أحد هذه الأساليب بنجاح للعثور على الأنماط المكانية والزمانية في بيانات ارتفاع سطح البحر، مما أدى إلى إنشاء كتالوج عالمي للدوامات المحيطية متوسطة الحجم.

تم استكشاف طريقة أخرى للعثور على الأجسام الشاذة المدفونة تحت سطح الأرض (المناجم الأرضية) من صور الرادار. باستخدام تقنيات غير خاضعة للرقابة يمكنها العمل مع وسائط ذات خصائص مختلفة. كما تم استكشاف استخدام نماذج المواضيع للعثور على الأحداث المتطرفة من بيانات السلاسل الزمنية المناخية.

■ تقدير متغيرات علوم الأرض من الملاحظات

هناك فرصة كبيرة لطرق التعلم الآلي لاستنتاج متغيرات علوم الأرض المهمة التي يصعب رصدها بشكل مباشر (تركيزات غاز الميثان في الهواء أو تسرب المياه الجوفية في التربة)، وذلك باستخدام معلومات حول المتغيرات الأخرى التي تم جمعها عبر الأقمار الصناعية وأجهزة الاستشعار الأرضية، أو محاكاتها باستخدام نماذج نظام الأرض.

وعليه، يمكن استخدام خوارزميات التعلم الآلي الخاضعة للإشراف لتحليل بيانات الاستشعار عن بعد، وإنتاج تقديرات لمتغيرات النظام البيئي مثل الغطاء الحرجي، وصحة الغطاء النباتي، ونوعية المياه، وتوافر المياه السطحية، على نطاقات مكانية دقيقة وعلى فترات زمنية منتظمة.

يمكن لمثل هذه التقديرات لمتغيرات علوم الأرض أن تساعد في اتخاذ القرارات الإدارية، وتمكين الدراسات العلمية للتغيرات التي تحدث على سطح الأرض.


يتمثل التحدي الرئيس في استخدام أساليب التعلم تحت الإشراف لتقدير متغيرات علوم الأرض في عدم تجانس خصائص المتغيرات عبر المكان والزمان. تتمثل إحدى الطرق لمعالجة تحدي عدم التجانس هذا، في استكشاف أطر التعلم متعددة المهام، حيث يعتبر تعلم نموذج في كل قسم متجانس من البيانات مهمة منفصلة، ويتم مشاركة النماذج عبر مهام مماثلة لتنظيم تعلمها، وتجنب مشكلة التجهيز الزائد، خاصة عندما تعاني بعض المهام من ندرة العينات التدريبية.

يمكن العثور على مثال للنهج القائم على التعلم متعدد المهام للتعامل مع عدم التجانس في عمل حديث ما، حيث يتم التعامل مع تعلم نموذج الغطاء الحرجي في كل نوع من أنواع النباتات (تم اكتشافه من خلال تجميع السلاسل الزمنية للنباتات في

المواقع منهجا منفصلا) تم استخدام المهمة، والتشابه بين أنواع النباتات (المستخرجة باستخدام تقنيات التجميع الهرمي) لمشاركة التعلم في المهام ذات الصلة.

يوضح الشكل الآتي التحسن في أداء التنبؤ بالغطاء الحرجي في البرازيل باستخدام نهج التعلم متعدد المهام. يتم تقديم مراجعة تفصيلية للتقدم الواعد في التعلم الآلي مثل التعلم متعدد المهام، والتعلم متعدد العروض، والتعلم متعدد المراحل، لمعالجة التحديات في المراقبة الخاضعة للإشراف لتغيرات الغطاء الأرضي من بيانات الاستشعار عن بعد.

ولمعالجة الطبيعة غير الثابتة للبيانات المناخية، تم تطوير خوارزميات التعلم عبر الإنترنت للجمع بين مخرجات المتنبئين الخبراء (نماذج المناخ)، وإنتاج تقديرات قوية لمتغيرات المناخ مثل درجة الحرارة.



تحسين الأداء في تقدير الغطاء الحرجي في أربع ولايات في البرازيل، باستخدام أسلوب التعلم متعدد المهام؛ (أ) الأخطاء المتبقية المطلقة لطريقة خط الأساس، (ب) الأخطاء المتبقية المطلقة لطريقة التعلم متعدد المهام. (Karpatne, et al., 2017)

في هذا النوع من العمل، تم تحديث الأوزان على الخبراء بطريقة تكيفية عبر المكان والزمان، لالتقاط البنية الصحيحة لعدم الثبات في البيانات. وقد تبين أن هذا يتفوق بشكل كبير على التقنية الأساسية المستخدمة في علوم المناخ، وهو المتوسط غير التكيفي على الخبراء (متوسط النماذج المتعددة). تم استكشاف نهج آخر لمعالجة عدم الاستقرار، حيث تم تعلم مزيج بايزي **Bayesian Mixture** من نماذج مختلفة لتقليص حجم متغيرات المناخ، حيث تم تعلم نموذج مختلف لكل مجموعة متجانسة من المواقع في الفضاء.

في عمل حديث، تم تطوير أساليب التعلم الجماعي التكيفي، جنباً إلى جنب مع تقنيات تحسين الملصقات القائمة على الفيزياء، لمواجهة التحدي المتمثل في عدم التجانس، وضعف جودة البيانات لرسم خرائط ديناميكيات المسطحات المائية السطحية باستخدام بيانات الاستشعار عن بعد. وقد مكن ذلك من إنشاء نظام عالمي لرصد المياه السطحية (متاح للعامة على الموقع)، قادر على اكتشاف مجموعة متنوعة من التغيرات في المياه السطحية مثل؛ تقلص البحيرات بسبب الجفاف، وذوبان البحيرات الجليدية، ومجاري الأنهار المهاجرة، وبناء السدود الجديدة والخزانات.

التحدي الآخر في التقدير الخاضع للإشراف لمتغيرات علوم الأرض هو صغر حجم العينة، وندرة تسميات الحقيقة الأرضية. تم استكشاف طرق التعامل مع مشكلة الأبعاد العالية وأحجام العينات الصغيرة، حيث تم تطوير أدوات التنظيم المحفزة للثلاثية مثل المجموعة المشتتة لاسو **Lasso** لنمذجة خصائص مجال متغيرات المناخ.

لمعالجة ندرة التسميات، يجب استخدام أطر التعلم الجديدة مثل، التعلم شبه الخاضع للإشراف، والذي يعزز البنية الموجودة في البيانات غير المسماة لتحسين أداء التصنيف، والتعلم النشط، حيث يشارك أحد الخبراء بنشاط في عملية بناء النموذج، لديه إمكانيات هائلة لتحسين أحدث مشكلات التقدير التي تواجهها تطبيقات علم الأرض.


وفي سلسلة من الأعمال الحديثة، أدت محاولات بناء نموذج للتعليم الآلي للتنبؤ بحرائق الغابات في المناطق الاستوائية باستخدام بيانات الاستشعار عن بعد إلى منهجية جديدة لبناء نماذج تنبؤية للظواهر النادرة التي يمكن تطبيقها في أي مكان، حيث لا يمكن الحصول على بيانات مصنفة عالية الجودة حتى بالنسبة لمجموعة صغيرة من العينات، ولكن التصنيفات ذات الجودة الرديئة (قد تكون في شكل استدلالات) متاحة لجميع العينات. بالإضافة إلى أساليب التعلم الخاضعة للإشراف، ونظرًا لتوافر البيانات غير المصنفة بكثرة في تطبيقات علوم الأرض مثل؛ الاستشعار عن بعد، هناك العديد من الفرص لأساليب التعلم غير الخاضعة للإشراف في تقدير متغيرات علوم الأرض.

مثال؛ تمت دراسة التغيرات في السلاسل الزمنية لبيانات الغطاء النباتي، التي تم جمعها بواسطة أدوات الأقمار الصناعية على فترات زمنية محددة، في كل موقع مكاني على سطح الأرض وعلى نطاق واسع، باستخدام أساليب التعلم غير الخاضعة للرقابة، لرسم خرائط التغيرات في الغطاء الأرضي؛ كإزالة الغابات، وأضرار الحشرات، وتحويل المزارع، وحرائق الغابات.

■ التنبؤ طويل المدى بمتغيرات علوم الأرض

إن التنبؤ طويل المدى لحالة نظام الأرض، كالتنبؤ مثلاً، بمتغيرات علوم الأرض مسبقاً، وفي الوقت المناسب، يمكن أن يساعد في نمذجة السيناريوهات المستقبلية، ووضع سياسات التخطيط المبكر للموارد وسبل التكيف معها. أحد الأساليب لتوليد تنبؤات لمتغيرات علوم الأرض هو تشغيل عمليات محاكاة النماذج القائمة على الفيزياء، والتي تشفر بشكل أساسي علوم الأرض. الأداة الأكثر شيوعاً لتحليل السببية في علوم الأرض هي تحليل جرانجر ثنائي المتغير **Bivariate Granger Analysis**، يليه تحليل جرانجر متعدد المتغيرات باستخدام نماذج الانحدار الذاتي المتجه **(VAR) Vector Autoregression**، ولكن هذا الأخير لا يزال غير شائع الاستخدام.

إلى الآن، نادراً ما يُستخدم إطار بيرل **Pearl's Framework** المبني على النماذج الرسومية الاحتمالية في علوم الأرض. إن حقيقة أن مثل هذه الأدوات السببية متعددة المتغيرات، والتي أسفرت عن اختراقات عظيمة في علم الأحياء والطب على مدى العقد الماضي، لا تزال غير شائعة الاستخدام في علوم الأرض، وتتناقض بشكل صارخ مع الإمكانيات العظيمة التي تمتلكها هذه الأساليب لمعالجة العديد من مشكلات علوم الأرض. وهذه تتراوح من الاختيار المتغير لمهام التقدير والتنبؤ، إلى تحديد المسارات السببية للتفاعلات حول العالم (انظر الشكل الآتي)، والإسناد السببي. وستتم مناقشة الموضوع الأخير بمزيد من التفصيل أدناه.



تعيين موقع الشبكة لنصف الكرة الشمالي المتولدة من بيانات الارتفاع اليومية للقذرة الأرضية باستخدام التعلم الهيكلية القائم على القيد للنماذج الرسومية. تمثل الأسهم الناتجة مسارات العاصفة، (Karpatne, et al., 2017).

تتأثر العديد من مكونات نظام الأرض بالأفعال البشرية، مما يؤدي إلى الحاجة إلى دمج إجراءات السياسة في مناهج النمذجة. يمكن أن تساعد المخرجات التي تنتجها نماذج علوم الأرض في توجيه عملية صنع السياسات والقرارات.

يعد علم السببية أداة أساسية لاتخاذ القرارات التي تساعد العلماء على تحديد أسباب الأحداث. يوفر إطار حساب التفاضل والتكامل السببي مصطلحات موجزة للإسناد السببي لأحداث الطقس والمناخ المتطرفة.

تم أيضاً اقتراح طرق تعتمد على نماذج جرانجر الرسومية، ولكن لم يتم استخدام أي من الإطارين على نطاق واسع. من الأمور ذات الاهتمام الكبير تطوير منهجية اتخاذ القرار مع احتمالات التنبؤ غير المؤكدة، مما ينتج عنه أخطار غامضة ذات ذيول سيئة الحل، تمثل الأحداث المتطرفة والنادرة والعابرة، الأكثر إثارة للاهتمام التي تنتجها النماذج.

يعد تطبيق التعلم المعزز وأساليب البرمجة الديناميكية العشوائية الأخرى، التي يمكنها حل مشكلات القرار ذات الأخطار الغامضة، اتجاهات واعدة يجب متابعتها.

• موضوعات بحثية شاملة

في هذا القسم، ستتم مناقشة موضوعين ناشئين لأبحاث التعلم الآلي والتي تنطبق بشكل عام على جميع مشكلات علوم الأرض. يتضمن ذلك التعلم العميق، ونموذج علم البيانات الموجه نظرياً، كما هو موضح أدناه.

■ التعلم العميق

تتمتع الشبكات العصبية الاصطناعية بتاريخ طويل ومتعرج، يمتد لأكثر من ستة عقود من البحث، بدءاً من الأصول المتواضعة مع خوارزمية الإدراك الحسي في ستينيات القرن الماضي، إلى البنى «العميقة» الحالية التي تتكون من عدة طبقات من العقد المخفية، والتي يطلق عليها اسم التعلم العميق.

يمكن أن تعزى قوة التعلم العميق إلى استخدامه للتسلسل الهرمي العميق للسّمات الكامنة (التي يتم تعلمها في العقد المخفية)، حيث يتم تمثيل السّمات المعقدة كتركيبات من السّمات الأبسط.

أدى هذا، جنباً إلى جنب، مع توفر مجموعات البيانات الكبيرة، والتقدم الحسابي لتدريب الشبكات الكبيرة، والتحسينات الخوارزمية لأخطاء الانتشار الخلفي عبر الطبقات العميقة من العقد المخفية، إلى إحداث ثورة في العديد من مجالات التعلم الآلي، مثل التعلم الخاضع وشبه الخاضع للإشراف والتعلم الآلي. والتعلم المعزز.

وقد أدى التعلم العميق إلى قصص نجاح كبيرة في مجموعة واسعة من التطبيقات التجارية، مثل؛ رؤية الحاسوب، والتعرف على الكلام، وترجمة اللغات الطبيعية.

ونظراً لقدرة أساليب التعلم العميق على استخراج السّمات ذات الصلة تلقائياً من البيانات، فإن لديها إمكانيات هائلة في حل مشكلات علوم الأرض، حيث يصعب بناء سمات مشفرة يدوياً للكيانات والأحداث والعلاقات من بيانات علوم الأرض المعقدة.

نظراً للطبيعة الزمانية والمكانية لبيانات علوم الأرض، تشترك مشكلات علوم الأرض في بعض التشابه مع مشكلات الرؤية الحاسوبية والتعرف على الكلام، حيث حقق التعلم العميق إنجازات كبيرة باستخدام أطر عمل مثل؛ الشبكات العصبية التلافيفية (CNN)، والشبكات العصبية المتكررة (RNN)، على التوالي.

مثال على ذلك؛ إذا تمكنت شبكة CNN من تعلم التعرف على كائنات كالقطط في الصور، فيمكن استخدامها أيضاً للتعرف على الكيانات والأحداث مثل؛ الأعاصير والعواصف والأنهار، والتي تظهر السّمات البنائية (مثل المجاري) في بيانات علوم الأرض.

في الواقع، تم مؤخراً استكشاف استخدام شبكات **CNN** للكشف عن الأحداث الجوية المفرطة، من محاكاة نماذج المناخ. وبالمثل، تم استكشاف الأطر القائمة على **RNN**، مثل نماذج الذاكرة طويلة المدى (**LSTM**)، لرسم خرائط المزارع في جنوب شرق آسيا من بيانات الاستشعار عن بعد، باستخدام الخصائص المكانية والزمانية لديناميات تحويلات المزارع.

مثل هذه الأطر قادرة على استخراج الطول المناسب من الذاكرة اللازمة، لإجراء التنبؤات في الوقت المناسب، وبالتالي يمكن أن تكون مفيدة للتنبؤ بمتغيرات علوم الأرض، مع فترات زمنية مناسبة.

كما تم استكشاف الأطر القائمة على التعلم العميق لتقليل حجم مخرجات نماذج نظام الأرض، وإنشاء توقعات تغير المناخ على المستويات المحلية، وتصنيف الأجسام كالأشجار والمباني في صور الأقمار الصناعية عالية الدقة.

تسلط هذه الجهود الضوء على الوعد باستخدام التعلم العميق للحصول على إنجازات مماثلة في علوم الأرض، كما هو الحال في الساحة التجارية، بدمج خصائص عمليات علوم الأرض (البنية المكانية والزمانية) في أطر التعلم العميق.

بينما كان توفر كميات كبيرة من البيانات المصنفة أحد العوامل الرئيسية وراء نجاح التعلم العميق في المجالات التجارية، فإن التحدي الرئيس في مشكلات علوم الأرض هو ندرة العينات المصنفة، مما يحد من فاعلية أساليب التعلم العميق التقليدية.

ومن ثم، هناك حاجة إلى تطوير أطر جديدة للتعلم العميق لمشكلات علوم الأرض، والتي يمكنها التغلب على ندرة البيانات المصنفة، على سبيل المثال، باستخدام معلومات محددة عن العمليات الفيزيائية.

■ علم البيانات الموجه نظرياً

نظراً لتعقيد المشكلات في تطبيقات علوم الأرض، والقيود المفروضة على الأطر المنهجية الحالية في علوم الأرض (انظر أوراق المناقشة الأخيرة في علم الهيدرولوجيا)، لا يمكن اعتبار نهج البيانات فحسب، ولا نهج الفيزياء فقط، كافياً لاكتشاف المعرفة.

بدلاً من ذلك، هناك فرصة لمتابعة نموذج بديل للبحث، يستكشف التواصل بين النماذج القائمة على الفيزياء (أو النظرية) وأساليب علم البيانات من التكامل العميق للمعرفة العلمية في منهجيات علم البيانات، والذي يطلق عليه نموذج علم البيانات الموجه بالنظرية.

إذ يمكن نسج الاتساق العلمي في أهداف التعلم لخوارزميات التعلم التنبؤية، بحيث لا تكون النماذج المستفادة أقل تعقيداً وتظهر أخطاء تدريب منخفضة فحسب، ولكنها أيضاً متوافقة مع المعرفة العلمية الحالية.

يمكن أن يساعد هذا في تشذيب مساحات كبيرة من النماذج التي لا تتوافق مع فهمنا المادي، وبالتالي تقليل التباين دون التأثير على التحيز على الأرجح. وبالتالي، من خلال ترسيخ أطر التعلم الآلي بالمعرفة العلمية، يمكن للنماذج المستفادة أن تحظى بفرصة أفضل ضد التجاوز، خاصة عندما تكون بيانات التدريب نادرة.

مثال، استخدام وظائف الخسارة الموجهة بالفيزياء، لتتبع الكيانات في تسلسلات من الصور، حيث يتم استخدام المعرفة الأولية لقوانين الحركة فقط لتقييد المخرجات ونماذج التعلم، دون مساعدة من تسميات التدريب.

الدافع الآخر لتعلم النماذج والحلول المتسقة مادياً، هو أنه يمكن فهمها بسهولة من قبل علماء المجال، واستيعابها في قواعد المعرفة الموجودة، وبالتالي ترجمتها إلى تقدم علمي.

بدأ اتباع نموذج علم البيانات الموجه نظرياً في العديد من التخصصات العلمية التي تتراوح من علم المواد إلى الهيدرولوجيا، ونمذجة الاضطرابات، والطب الحيوي. ورقة بحثية حديثة تبني أساس هذا النموذج، وتوضح عدة طرق لمزج المعرفة العلمية مع نماذج علم البيانات، باستخدام التطبيقات الناشئة من مجالات متنوعة. فهناك فرصة كبيرة لاستكشاف خطوط بحث مماثلة في تطبيقات علوم الأرض، حيث يمكن أن تلعب أساليب التعلم الآلي دوراً رئيساً في تسريع اكتشاف المعرفة، من تعلم الأنماط والنماذج تلقائياً من البيانات، ولكن دون تجاهل ثروة المعرفة المتراكمة في الفيزياء، وتمثيلات نموذجية لعمليات علوم الأرض.

يمكن أن يكمل هذا، الجهود الحالية في علوم الأرض، بشأن دمج البيانات في النماذج القائمة على الفيزياء. على سبيل المثال، في معايرة النماذج، حيث يتم تعلم الأشكال البارامترية للتقريبات المستخدمة في النماذج من البيانات، عن طريق حل المشكلات العكسية، أو في استيعاب البيانات. يتم تسلسل الإبلاغ عن تحولات حالة النظام من قياسات المتغيرات المرصودة حيثما كان ذلك متاحاً، (Karpatne, et al., 2017).

الذكاء الاصطناعي ودوره في البيئة

يُعتقد أن الذكاء الاصطناعي هو تقنية نقية دون أي عناصر بيئية أخرى. وأن التكنولوجيا يمكن أن تقوم بمفردها، دون تطبيقات تكنولوجية جانبية. الحقيقة هي أن هذه التكنولوجيا موجودة بسبب التقنيات المختلفة مجتمعة، والتي تطبق فقط الجوانب المكررة، التي خلقت شيئاً غير ملموس في الواقع، لكن له تأثيراً هائلاً على البشر وعلى البيئة والنظام العام للكوكب.

هناك دائماً جوانب رؤية مختلفة لكيان واحد. فمن الممكن أن يرى امرؤ من وجهة نظره منظراً، وقد يرى آخر جانبا آخر يخالف الأول والثالث والرابع.

إن التقدم التكنولوجي يمنح البشر العديد من الإمكانيات. لقد قاموا بتسريع جميع العمليات التي كانت تستغرق وقتاً وقوة في الماضي، مثل تحسين جودة المنتج وكميته، والتي في أغلب الأحيان تتعارض مع بعضها البعض، ولكنها كلها تعمل على المسار نفسه.

توفر التكنولوجيا للإنسان الراحة والأمان، وتقليل العمل الشاق، والعديد من الأعمال المماثلة الأخرى، إلا أنها تطرح أيضاً مشكلات غير ملحوظة وقد تكون ضارة، فضلاً عن أنها خطيرة، وقد تهدد حياة البشر والكوكب.

إن النتيجة الأكثر شيوعاً للتقدم التكنولوجي هي؛ الانحباس الحراري العالمي وما يصاحبه من شكوك. هذه الظاهرة تؤثر فعلاً على حياتنا الروتينية الراكدة إلى حالة لا يمكن التعرف عليها، لكن تأثيرها يمتد إلى مناطق مختلفة واسع.

تعمل ظاهرة الاحتباس الحراري على تغيير الممارسات التي كانت قابلة للتطبيق في السابق، ولكنها الآن غير مرغوب فيها. لا يؤثر التقدم التكنولوجي على البيئة أو الصحة فحسب، بل على أجزاء مختلفة من حياة الإنسان. يمكن أن تكون هذه

المشكلة مرتبطة بالكسل، أو التباعد الاجتماعي، أو سوق العمل الذي لا يمكن التنبؤ به، وما إلى ذلك.

كل يوم تظهر تقنيات جديدة، والتي ترتبط في معظم الأحيان بالبيئة. لقد تم إنشاؤها لمحاربة القضايا البيئية. البعض منها يغير وجهات النظر بشكل كبير، ولكن هل هذا يكفي؟ هذه التقنيات هي المشكلة في المقام الأول.

وهذا يعني أن مزيداً من التكنولوجيا يؤدي إلى المزيد من الدمار. ومع ذلك، فإن بعض التقنيات الناشئة تسلط الضوء على الظلام، حيث لا ضوء. ومن الأمثلة البارزة على ذلك؛ الذكاء الاصطناعي الذي يعد بتقليل بعض المشكلات أو القضاء عليها.

• نتائج مبشرة بالخير

وكما ذكرنا سابقاً، ينصب تركيز هذا العمل على تحديد التغييرات التي يجلبها الذكاء الاصطناعي لمكافحة القضايا البيئية. ومن ثم، سيتم تخصيص الفقرة التالية لتسليط الضوء على هذه التغييرات.

■ نفايات أقل

تسبب العديد من الصناعات تراكم نفايات عظيمة أثناء إنتاج السلع والمواد الغذائية، وما إلى ذلك. يتم إعادة تدوير هذه النفايات جزئياً (في أغلب الأحيان بنسبة صغيرة) أو يتم استخدامها بشكل غير صحيح. مما يؤدي إلى تعريض مناطق تراكم النفايات للخطر وزيادة تأثيرها على البيئة. إن التقنيات الجديدة، بما فيها الذكاء الاصطناعي المضمن في النظام، قادرة على تقليل أي هدر في أي مرحلة.

ونظراً للتقدم في الدقة، يمكن لهذه التكنولوجيا تقليل النفايات في أي مرحلة من مراحل الإنتاج. فهو يخلق أخطاء أقل خلال العمليات، وتساعد قدراته التحليلية والتنبؤية على تقليل النفايات بشكل أكبر، وبالتالي تقليل تأثيرها على البيئة.

■ الأخطاء البشرية

أحياناً تضر الأخطاء البشرية بالطبيعة أكثر من العوامل الأخرى مجتمعة. يميل البشر إلى ارتكاب الأخطاء، ليس لأنهم أقل ذكاءً من أي تكنولوجيا، ولكن لأنهم مبنون بشكل مختلف. يعمل الذكاء الاصطناعي والتقنيات الأخرى معاً لتقليد البشر أو استبدالهم بالكامل في العديد من الصناعات، والنتيجة هي أن الجمع بين التقنيات المدعومة بالذكاء الاصطناعي يكون عرضة لأخطاء أقل من البشر.

التقنيات تؤدي الوظيفة أو المهمة المحددة بدقة تامة، وبالتالي تكون النتيجة أخطاء أقل خلال 24 ساعة، أما البشر فهم أكثر عرضة لفقدان التركيز، والتعب، ونسيان المهمة القادمة، أو سوء التذكر، وما إلى ذلك.

الصفات المذكورة واضحة تماماً في عالم الخوارزميات، لأنه يجب اتباع بعض القواعد والأنماط الواضحة. لذلك، لا توجد دورات غير محددة في المعادلة، ومع ذلك، إذا تم إدخال متغير جديد إلى المعادلة، فإن النظام بأكمله سوف ينهار. ولذلك فإن كلا النوعين، سواء كان حقيقياً أو غير ذلك، سيكون له سلبياته وإيجابياته.

■ اختيار أفضل للمسار

ما يجعل الذكاء الاصطناعي ذا قيمة كبيرة في السوق هو قدرته على التطور بشكل أكبر مع الاتجاهات المحددة. فإذا تم تنفيذها بشكل صحيح، تكون هذه الأداة قادرة على العثور على المسارات المثالية الأكثر قبولاً للمستخدمين.

تم تصميم خوارزميات الذكاء الصناعي المعقدة لتحقيق تحسينات لا نهاية لها أثناء تعلمه على الطريق. ومع ذلك، فإن التفاعل البشري مطلوب لتوجيهه وتنسيق وتعزيز النتيجة المرغوبة. هناك حاجة إلى هذا النوع من النهج عند التعامل مع القضايا البيئية، مما يساعد على إيجاد المزيد من الطرق الاختيارية، لتقليل تأثيرات الأنظمة المختلفة على الطبيعة باستخدام هذه التقنية.

تُستخدم خوارزميات **Q-learning** للعثور على المسارات الأكثر كفاءة. **Q-learning** هو تعليم معزز، حيث يتم تكليف الوكيل (الكيان) بمهمة في عالم ديناميكي (بيئي)، للبحث عن المسار الأكثر كفاءة، بالتغلب على العقبات. يمكن استخدام هذا النوع من النهج في صناعات كثيرة، لتقليل النفقات من خلال حساب المسار (العمليات) المحتملة الأكثر كفاءة.

إن التغيير البسيط في بيئة واحدة لن يكون له تأثير كبير مثل آلاف وملايين المسارات المكررة. ومن تحسين العمليات، يمكن للمرء تقليل الهدر غير الضروري والقوة المطلوبة، والتي من الناحية النظرية يجب أن يكون لها تأثير إيجابي على البيئة.

■ طرق التنبؤ

كما ذكرنا سابقاً، فإن الأداة قادرة على التنبؤ بأحداث معينة، لذلك يمكن أن يكون لها عملية اتخاذ قرار مبكر. الفكرة وراء هذا النهج هي إدخال أكبر قدر ممكن من البيانات في النموذج، حتى يتمكن من العثور على الارتباطات والتناقضات مع صافي المسارات المحتملة. وهذا يساعد صناعات كثيرة على تقليل فقدان الطاقة غير المرغوب فيه، والذي يرتبط بالبيئة حتماً.

وفي القطاع الزراعي، المسؤول عما يقرب من **30 %** من إجمالي الإحساس، يُستخدم الذكاء الاصطناعي للتنبؤ بالظروف الجوية. مثال، تخطط هياكل الذكاء الاصطناعي بطريقة لا تتعارض فيها عملية الري والتسميد مع تساقط الأمطار.

وهذا يساعد على القضاء على الاستخدام الزائد للمياه والأسمدة. وتستخدم هذه التكنولوجيا أيضاً للتنبؤ بالكوارث البيئية. يمكن التقليل من انتشار حرائق الغابات عن طريق التحليل المبكر، الأمر الذي لن يساعد الطبيعة فحسب، بل إنه مفيد للبشر أيضاً.

تعتمد القدرات التقنية على البيانات التي يتم تغذيتها، ولا يعني المزيد دائماً الجودة، ولكن الخوارزمية المنظمة بشكل صحيح، مع الهدف الصحيح والبيانات المفيدة يمكن أن توفر نتيجة أفضل في التنبؤ.

■ جوانب سلبية

حققت تكنولوجيا الذكاء الاصطناعي أهدافاً أكثر من غيرها من التقنيات، في العقود الأخيرة، وبوتيرة سريعة. والسؤال هو: هل يمكن لهذه التكنولوجيا أن تلحق الضرر بالبيئة بأي شكل من الأشكال؟ الجواب بالطبع إيجابي. إن أول شيء وأكثره تأثيراً على البيئة هو الشيء نفسه الذي يزدهر في أي مجال. يمكن مقارنته بالحديد لأن صدأه وحده هو الذي يمكن أن يدمره.

فاعلية التكنولوجيا هي (عدو الطبيعة). وتدفع قدراتها الأتمتة إلى مستوى جديد في أي صناعة، وبالمثل، في معدل إنتاجها. إن إنتاج المنتج، حتى لو كان يحتوي على أقل قدر من النفايات أو التأثير على البيئة، يمكن أن يضر الطبيعة بأعداده الكبيرة.

يمكن أن يرتفع عدد المنتجات باستخدام الذكاء الاصطناعي مع التقنيات الحالية والجديدة إلى أرقام لا يمكن تصورها. ولذلك، يمكن للمرء أن يرى بوضوح كيف يمكن لهذه التكنولوجيا، حتى في شكلها النقي، أن تلحق الضرر بالكوكب. هناك، بالطبع، عوامل أخرى ستؤثر بشكل سلبي على طبيعتنا. التكنولوجيا أقل عرضة للأخطاء إذا ما قورنت بالبشر. ومع ذلك، فإن الإفراط في استقلالية التكنولوجيا ينطوي على احتمال أن يؤدي ذلك إلى عواقب أكثر خطورة من الأخطاء الصغيرة التي يرتكبها البشر.

ومع الإمكانيات التي تتمتع بها هذه التقنية اليوم، فإنها لا تستطيع تحديد الأخطاء التي ستحدث كافة. على سبيل المثال، إذا تم إزاحة طبقة واحدة بسبب الظروف المختلفة أثناء قيام الطابعة ثلاثية الأبعاد ببناء هيكل، فلن تتوقف العملية، بل تستمر حتى النهاية.

وبالمثل، ستذهب هذه التقنية إلى أبعد من ذلك في تجاهل الأخطاء، إذا لم تكن مدمجة في الخوارزمية أو لم يتم تحديدها. في هذه الحالة، فإن التكنولوجيا، إذا أخذنا الصناعة التحويلية مثلاً، سوف تهدر المواد مع المنتجات التي سيكون بها عيوب. في النهاية سيتم تركها نفايات. لذلك، يجب تجنب الأتمتة الكاملة في المناطق المعقدة أو المهمة. وعلى الرغم من أن التكنولوجيا تحتاج إلى الطاقة ليس لإكمال المهام المادية فحسب، بل لإجراء العمليات الحسابية أيضاً، إلا أن الأدوات التحليلية أو أي أدوات أخرى تعمل بالذكاء الاصطناعي، تستهلك الطاقة بكمية كبيرة.

في هذه العملية، يتم توليد الحرارة بسبب الحسابات المعقدة أو المتعددة. يتم استخدام أجهزة التبريد أيضاً للحفاظ على درجة حرارة منخفضة في المبنى. يمكن للمرء أن يرى أنه حتى التكنولوجيا التي توضح الفوائد في العديد من الجوانب، يمكن أن يكون لها سلوك معاكس إذا تمت دراستها بدقة.

ومن الواضح أن تكنولوجيا الذكاء الاصطناعي يمكن أن تكون على مرحلتين (تقدم نتيجتين مختلفتين) بالمدخلات نفسها. لذلك، يمكن القول إن الأفضل عدم تطبيق هذه التكنولوجيا في مجالات الإنتاج، وبالتالي حل المشكلة.

ومع ذلك، فإن المشكلة لا تكمن في التكنولوجيا نفسها، إذ لم تكن موجودة من قبل، بل في البشر. والنتيجة المعقولة هي أن على البشر التعايش مع التكنولوجيا على النحو الذي يضمن تكافل الفوائد من الجانبين، (Labazanova, et al., 2024).

• تسخير الذكاء الاصطناعي من أجل الأرض

أدى التصنيع إلى العديد من المشكلات البيئية الحالية في العالم. مثل؛ تغير المناخ، والمستويات غير الآمنة من تلوث الهواء، واستنفاد الأرصاد السمكية، وانتشار السموم في الأنهار والتربة، ومستويات النفايات الفائضة على الأرض وفي المحيطات، وفقدان التنوع البيولوجي، وإزالة الغابات، كلها يمكن إرجاعها إلى التصنيع.

ومع تسارع وتيرة الثورة الصناعية الرابعة، أصبحت الابتكارات أسرع وأكثر كفاءة، ويمكن الوصول إليها على نطاق أوسع من ذي قبل. كما أصبحت التكنولوجيا مرتبطة بشكل متزايد؛ وعلى وجه الخصوص، اندماج العوالم الرقمية والمادية والبيولوجية، إذ تعمل التقنيات الجديدة على تمكين التحولات المجتمعية من خلال التأثير على الاقتصاد والقيم والهويات والإمكانات للأجيال القادمة.

لدينا فرصة فريدة لتسخير هذه الثورة الصناعية الرابعة، والتحول المجتمعية التي تثيرها، للمساعدة في معالجة القضايا البيئية وإعادة تصميم كيفية إدارتنا لبيئتنا العالمية المشتركة. ومع ذلك، يمكن للثورة الصناعية الرابعة أيضاً أن تؤدي إلى تفاقم التهديدات الحالية للأمن البيئي، أو خلق أخطار جديدة تماماً يجب أخذها في الاعتبار وإدارتها. وسوف يتطلب استغلال هذه الفرص وإدارة هذه الأخطار بشكل استباقي إحداث تحول في «البيئة التمكينية» **Enabling Environment**، أي أطر الحوكمة وبروتوكولات السياسات، ونماذج الاستثمار والتمويل، والحوافز السائدة لتطوير التكنولوجيا، وطبيعة المشاركة المجتمعية.

وهذا التحول لا يحدث تلقائياً، بل سيتطلب تعاوناً استباقياً بين صناع السياسات والعلماء والمجتمع المدني، وأبطال التكنولوجيا والمستثمرين. وإذا تم القيام بالأمر بشكل صحيح، فقد يؤدي ذلك إلى إحداث ثورة في الاستدامة.

• التحديات

هناك إجماع علمي متزايد على أن أنظمة الأرض تتعرض لضغوط غير مسبوقة. إن نموذج التنمية البشرية والاقتصادية الذي تم تطويره منذ الثورات الصناعية الماضية، جاء إلى حد كبير على حساب الكوكب. على مدى 10000 عام، مكن الاستقرار النسبي للأرض الحضارات من الازدهار. ولكن في فترة قصيرة من الزمن، أدى التصنيع إلى تعريض هذا الاستقرار للخطر.

لقد حدد العلماء تسع «عمليات وأنظمة تنظم استقرار ومرونة نظام الأرض»، ويقولون إن أربعاً من العمليات التسع؛ وهي: تغير المناخ، وفقدان سلامة المحيط الحيوي، وتغير نظام الأرض، والدورات المتغيرة في كيمياء الكرة الأرضية لها، قد تجاوزت الآن مستويات «الحدود» بسبب النشاط البشري. وهذا يزيد من خطر أن تؤدي الأنشطة البشرية إلى «تدهور رفاهية الإنسان في أجزاء كثيرة من العالم، بما في ذلك البلدان الغنية». توفر أهداف الأمم المتحدة للتنمية المستدامة عدسة أخرى للتحديات التي تواجه البشرية. تنطبق ستة من الأهداف السبعة عشر بشكل مباشر على البيئة وتأثير الإنسان عليها، وهي: مكافحة تغير المناخ، واستخدام المحيطات والموارد البحرية بحكمة، وإدارة الغابات، ومكافحة التصحر، وعكس اتجاه تدهور الأراضي، وتطوير مدن مستدامة، وتوفير طاقة نظيفة بأسعار معقولة.

لإلقاء الضوء على ستة تحديات حاسمة، يتطلب الأمر إجراءات تحويلية في القرن الحادي والعشرين:

• تغير المناخ

قد تكون مستويات الغازات الدفيئة اليوم هي الأعلى منذ 3 ملايين سنة. إذا تم الوفاء بتعهدات اتفاق باريس الحالية، فمن المتوقع أن يظل متوسط درجات الحرارة العالمية في عام 2100م أعلى بمقدار 3 درجات مئوية من مستويات ما قبل الصناعة، وهو أعلى بكثير من الأهداف لتجنب أسوأ آثار تغير المناخ.

• المحافظة على التنوع البيولوجي

تفقد الأرض تنوعها البيولوجي بمعدلات الانقراض الجماعي. والآن يواجه واحد من كل خمسة أنواع على وجه الأرض خطر الانقراض، ويقدر العلماء أن هذه النسبة سوف ترتفع إلى 50% بحلول نهاية هذا القرن ما لم تُتخذ إجراءات عاجلة.

وقد تؤدي معدلات إزالة الغابات الحالية في حوض الأمازون إلى انخفاض تساقط الأمطار على المستوى الإقليمي بنسبة 8% بحلول عام 2050م، وهو ما من شأنه أن يؤدي إلى التحول إلى «ولاية سافانا» *Savannah State*، مع عواقب أوسع نطاقاً على أنظمة الدورة المائية في الغلاف الجوي للأرض.

• محيطات صحية

إن كيمياء المحيطات حالياً تتغير بسرعة أكبر من أي وقت مضى منذ 300 مليون سنة، حيث تمتص المياه غازات الدفيئة البشرية المنشأ، ويؤدي إلى زيادة حموضة المحيطات، وارتفاع درجة حرارتها إلى أضرار غير مسبوقة بالثروة السمكية والشعاب المرجانية.

• الأمن المائي

بحلول عام 2030م، قد تعاني البشرية من نقص بنسبة 40% في كمية المياه العذبة اللازمة لدعم الاقتصاد العالمي، حيث يؤثر التلوث وتغير المناخ على دورة المياه العالمية.

• هواء نظيف

يعيش حوالي 92% من سكان العالم في أماكن لا تستوفي المبادئ التوجيهية لمنظمة الصحة العالمية بشأن جودة الهواء. وقد أفادت منظمة الصحة العالمية أن حوالي 7 ملايين شخص يموتون سنوياً بسبب التعرض لتلوث الهواء، أي بمعدل وفاة واحدة من كل ثمانية على مستوى العالم.

• الطقس والقدرة على الصمود في مواجهة الكوارث

في عام 2016م، عانى العالم من 772 «خسارة طبيعية» جيوفيزيائية وجوية وهيدرولوجية ومناخية؛ ما يعادل ثلاثة أضعاف العدد الذي وقع في عام 1980م.

تشكل هذه القضايا الست مجتمعة تحدياً عالمياً عاجلاً. ومع نمو عدد سكان العالم الحالي الذي يبلغ نحو 7 مليارات نسمة إلى 9.8 مليار نسمة بحلول عام 2050م، فسوف يزيد ذلك الطلب على الغذاء والمواد والنقل والطاقة، مما يزيد من خطر التدهور البيئي والتأثير على صحة الإنسان، وعلى سبل عيشه وأمنه. هل تستطيع البشرية الحفاظ على كوكب الأرض للأجيال القادمة؟

• الفرص

ورغم أن هذه التحديات ملحة وغير مسبقة، فإنها تتزامن مع عصر الابتكار والتغير التكنولوجي غير المسبوق. توفر الثورة الصناعية الرابعة فرصاً لا مثيل لها للتغلب على هذه التحديات الجديدة. وترتكز هذه الثورة الصناعية، على عكس الثورات السابقة، على الاقتصاد الرقمي الراسخ، كما تستند إلى التقدم السريع في الذكاء الاصطناعي، وإنترنت الكيانات، والروبوتات، والمركبات ذاتية القيادة، والتكنولوجيا الحيوية، وتكنولوجيا النانو، والحوسبة الكمية، من بين أمور أخرى. ويتميز بدمج هذه التقنيات التي تزيد من مكاسب السرعة والذكاء والكفاءة.

يركز هذا التقرير على الذكاء الاصطناعي، التكنولوجيا الناشئة الأساسية والأكثر انتشاراً في الثورة الصناعية الرابعة. الذكاء الاصطناعي هو مصطلح يشير إلى أنظمة الحاسوب التي يمكنها؛ استشعار بيئتها، والتفكير، والتعلم، والتصرف استجابة لما تشعر به وأهدافها المبرمجة. من بين جميع تقنيات الثورة الصناعية الرابعة، من المتوقع أن يكون للذكاء الاصطناعي التأثير الأعمق، وأن يتغلغل في جميع الصناعات، ويلعب دوراً متزايداً في الحياة اليومية.

ومن دمج مع تقنيات جديدة أخرى، أصبح الذكاء الاصطناعي بمنزلة «كهرباء» الثورة الصناعية الرابعة، حيث يقوم المبتكرون بدمج الذكاء في المزيد من الأجهزة والتطبيقات والأنظمة المترابطة.

وبعيداً عن مكاسب الإنتاجية، يَعدّ الذكاء الاصطناعي أيضاً بتمكين البشر من تطوير الذكاء الذي لم يتم التوصل إليه بعد، مما يفتح الباب أمام اكتشافات جديدة.

لقد بدأ الذكاء الاصطناعي فعلاً في إحداث تحول في الصناعات التقليدية والحياة اليومية. في كثير من الأحيان، لا تعمل الإنجازات الجديدة المدعومة بالذكاء الاصطناعي بمفردها، بل بالاشتراك مع تقنيات الثورة الصناعية الرابعة الأخرى. وبينما يتطلع رواد الأعمال والشركات والمستثمرون والحكومات إلى نشر هذه التقنيات، وتوسيع نطاقها لخلق ميزة استراتيجية، فإن هناك أيضاً فرصاً مهمة لتطبيقها على التحديات المباشرة للأرض، والملحة، لتوليد الفرص لليوم ولغد والمستقبل.

يمكن القول إن الاعتبار الأكثر أهمية في تطوير الذكاء الاصطناعي هو التأكد من أنه يفيد البشرية، والذي يتضمن كونه «صديقاً للإنسان» و«صديقاً للأرض». يسلط الشكل الآتي الضوء على أولويات ست من التحديات البيئية الأكثر إلحاحاً في العالم، ومجالات العمل ذات الأولوية لمعالجتها بنجاح.

وفي مواجهة هذه التحديات، هناك مجال واسع للابتكار والاستثمار. يتمتع الذكاء الاصطناعي على وجه الخصوص بإمكانات هائلة للمساعدة في إطلاق الحلول.

• الذكاء الاصطناعي يغير قواعد اللعبة بالنسبة للأرض

بالإضافة إلى تعزيز الجهود الحالية لمعالجة القضايا البيئية، هناك إمكانات هائلة لإنشاء «تغييرات في قواعد اللعبة»، مدعومة بالذكاء الاصطناعي، حيث يكون لتطبيق الذكاء الاصطناعي، بالاشتراك مع تقنيات الثورة الصناعية الرابعة، القدرة على تقديم حلول تحويلية.



الطقس والقدرة
على الصمود في
مواجهة الكوارث

- التنبؤ.
- أنظمة الإنذار المبكر.
- بنية تحتية مرنة.
- أدوات مالية.
- التخطيط للمرونة.



الهواء النظيف

- التصفية والانتقاط.
- الرصد والوقاية.
- الإنذار المبكر.
- الوقود النظيف.
- الإدارة الحضريّة المتكاملة.
- والمتكيفة في الوقت الحقيقي.



الأمن المائي

- إمدادات المياه.
- مراقبة مستجمعات المياه.
- كفاءة استخدام المياه.
- المياح.
- مرافق الصرف الصحي الملائمة.
- التخطيط للجفاف.



محيطات صحية

- الصيد بشكل مستدام.
- منع التلوث.
- حماية الموانئ.
- حماية الأنواع.
- التأثيرات الناجمة عن تغير المناخ (بما في ذلك التحمض).



المحافظة على التنوع البيولوجي

- حماية الموائل واستعادتها.
- التجارة المستدامة.
- مكافحة التلوث.
- الأنواع الغازية ومكافحة الأمراض.
- تحقيق رأس المال الطبيعي.



تغير المناخ

- الطاقة النظيفة.
- خيارات النقل الذكية.
- الإنتاج والاستهلاك المستدام.
- الاستخدام المستدام للأراضي.
- المدن والمنزل الذكية.

يتم تحديد المجموعة التالية من مغيرات اللعبة المحتملة من خلال خمس سمات رئيسية:

- التأثير التحويلي (أي أنه يمكن أن يعطل أو يغير النهج الحالي بالكامل)
 - إمكانية التبني (أي أن حجم السكان المحتمل كبير).
 - مركزية الذكاء الاصطناعي في الحل (أي أن الذكاء الاصطناعي هو عنصر رئيس في الحل).
 - تأثير الأنظمة (أي أن مغير قواعد اللعبة يمكنه فعلاً تغيير الاتصال عبر الأنظمة البشرية).
 - بيئة تمكينية قابلة للتحقيق، بما في ذلك الديناميكيات السياسية والاجتماعية (أي يمكن تحديد البيئة التمكينية ودعمها).
- سيتم سرد بعض هذه التغيرات المحتملة في قواعد اللعبة بشكل فردي أدناه. ولكن في كثير من الأحيان، توفر المجموعات الشاملة لعدة قطاعات من هذه التغيرات في قواعد اللعبة أعظم الإمكانيات لإحداث تحول جذري في الأنظمة البشرية.
- مثال، من الممكن أن تعمل المركبات الكهربائية المستقلة، بالاشتراك مع شبكات الطاقة الموزعة، بحيث يتم تغذية محطات الشحن، وبالتالي المركبات، من شبكة طاقة متجددة لا مركزية ومحسنة، وتصبح في نهاية المطاف مصادر في هذه الشبكة نفسها.

• تغيرات لعبة الذكاء الاصطناعي الناشئة

▪ السيارات الكهربائية ذاتية القيادة وذاتية التواصل

سيكون الذكاء الاصطناعي أمراً حيوياً في التحول واسع النطاق إلى السيارات الكهربائية ذاتية التواصل، وذاتية القيادة (EVs)، والتي ستؤدي في نهاية المطاف

إلى تحويل التنقل لمسافات قصيرة، مع تقليل انبعاثات الغازات الدفيئة، وتوفير هواء أنظف. ستعمل المركبات الكهربائية المستقلة التي تعتمد على التعلم الآلي على تحسين كفاءة شبكات النقل، حيث تتواصل المركبات المتصلة مع بعضها البعض ومع البنية التحتية للنقل، لتحديد الأخطار وتحسين كفاءة الملاحة، وشبكات التواصل.

سيصبح شحن السيارات الكهربائية ميسور التكلفة، عبر برامج الاستجابة للطلب التي يتم تمكينها بواسطة البيانات الضخمة (مثل **Auto Grid**). وسوف تجمع وسائل النقل النظيفة والذكية والمتواصلة معا والمستقلة على نحو متزايد، بين الذكاء الاصطناعي وتكنولوجيات الثورة الصناعية الرابعة الأخرى، ولا سيما إنترنت الكيانات، والطائرات بدون طيار، والمواد المتقدمة (في اختراقات البطاريات). يمكن أن يؤدي الطلب المتزايد على النقل إلى تعويض بعض مكاسب الكفاءة، ولكن عموماً، من المتوقع أن يؤدي نظام النقل الذكي الذي يدعمه الذكاء الاصطناعي إلى خفض الانبعاثات، وقد يؤدي تحسين الكفاءة أيضاً إلى تشجيع مشاركة السيارات وتقليل ملكية السيارة، وبالتالي تقليل الانبعاثات الناتجة عن تصنيع المركبات وتشغيلها.

ومع ذلك، فإن الانتقال إلى أساطيل المركبات المستقلة، ذاتية الاتصال في المدن، سيكون تدريجياً، وسيختلف من بلد إلى آخر. وقد تمر عقود قبل أن تصبح الأساطيل الحضرية المستقلة بالكامل هي القاعدة.

بالإضافة إلى تطوير التكنولوجيا، يجب معالجة التحديات المتعلقة بالقبول العام، والمسائل القانونية، والمسؤولية التأمينية، وتوفير البنية التحتية للشحن. علاوة على ذلك، تستغرق دورة استبدال السيارة ما يقرب من 15 إلى 20 عاماً. وبينما نجد أن القيادة الذاتية الكاملة للمركبة من «المستوى الخامس» (بدون تدخل بشري على الإطلاق)، ربما لا تزال بعيدة المنال لعقود من الزمن، فإن المركبات ذاتية القيادة من «المستوى الرابع» (الآلية تماماً، ولكن مع إمكانية سيطرة السائق عليها عند الحاجة)، قد تم اختبارها بنجاح على الطرق، في وقت مبكر من عام 2021م.

في هذا المستوى، يمكن للسيارات القيادة داخل المدن، وتوفير خدمات التنقل حسب الطلب. كما بدأت تظهر المزيد من الفوائد الجوهرية فيما يتصل بخفض الانبعاثات.

■ شبكات الطاقة الموزعة

في شبكة الطاقة، ينتشر تطبيق التعلم الآلي على نطاق واسع في الصناعة، بما في ذلك التعلم العميق. بالنسبة للبيئة، يعد استخدام الذكاء الاصطناعي لجعل توزيع الطاقة ممكناً على نطاق واسع، أمراً بالغ الأهمية لإزالة الكربون من شبكة الطاقة، وزيادة كفاءة استخدامها، وتوسيع استخدام مصادر الطاقة المتجددة (وتسويقها)، يمكن للذكاء الاصطناعي أن يعزز القدرة على التنبؤ بالعرض والطلب لمصادر الطاقة المتجددة، وتحسين تخزينها وإدارة الأحمال، والمساعدة في تكامل مصادر الطاقة المتجددة وموثوقيتها، وتمكين التسعير والتجارة الديناميكيين، وخلق حوافز سوقية.

يمكن لمحطات الطاقة الافتراضية (VPPs) المجهزة بالذكاء الاصطناعي دمج وتجميع وتحسين استخدام الألواح الشمسية والشبكات الصغيرة، ومنشآت تخزين الطاقة، وغيرها من المرافق. ويمكن أيضاً توسيع شبكات توزيع الطاقة، لتشمل مصادر جديدة مثل؛ الرش الشمسي أو البنية التحتية المطلية للمركبات، والسماح «للطرق الشمسية» المدعومة بالذكاء الاصطناعي أن توسع شبكتها، وتواصلها، وتحسينها كثيراً.

في الطرق الشمسية، على سبيل المثال، يمكن للذكاء الاصطناعي أن يسمح للطريق بتعلم التسخين لإذابة الثلوج، أو ضبط مسار المرور بناءً على تدفق المركبات.

وسوف تستخدم الشبكات الذكية أيضاً تقنيات أخرى من الثورة الصناعية الرابعة، بما في ذلك إنترنت الكيانات، وسلسلة المنع Blockchain (لتداول الطاقة من نظير إلى نظير)، والمواد المتقدمة (لزيادة عدد موزعي المصادر، وتحسين تخزين الطاقة).

سيتطلب كل هذا تنظيمًا كافيًا لضمان أمان البرامج وسلامتها، وملكية حقوق الملكية الفكرية والتحكم فيها (مما قد يساعد في إطلاق العنان للاستثمار والابتكار)، وإدارة العناصر التشغيلية التي يدعمها التعلم الآلي والمسؤولية عنها. والأطر التنظيمية لنقل الطاقة وتداولها، بشكل افتراضي في كثير من الأحيان.

ومع ابتعاد الاقتصادات والمستوطنات عن «البنية التحتية الضخمة»، نحو البنية التحتية «الذكية»، ذات البصمة البيئية المنخفضة، فإن الطبيعة اللامركزية لشبكات توزيع الطاقة، تعني أن لديها القدرة على استخدامها عالميًا.

■ الزراعة الذكية

من المتوقع أن تشمل الزراعة الدقيقة (بما في ذلك التغذية الدقيقة)، جمع البيانات الآلية باطراد، واتخاذ القرارات على مستوى المزرعة، كزراعة المحاصيل ورشها وحصادها على النحو الأمثل للسماح بالكشف المبكر عن أمراضها ومشكلاتها، وتوفير التغذية في الوقت المناسب للماشية، وبشكل عام لتحسين المدخلات والعائدات الزراعية. ويشر هذا التوجه بزيادة كفاءة استخدام الموارد في الصناعة الزراعية، وخفض استخدام المياه والأسمدة والمبيدات الحشرية، وما ينشأ عنها من جريان المياه، الذي يجد طريقه إلى الأنهار والمحيطات، وإلى مجموعات الحشرات، مما يتسبب في إلحاق الضرر للنظم البيئية المهمة.

وهنا تشمل تقنيات الثورة الصناعية الرابعة الرئيسة، التي ستتحد مع الذكاء الاصطناعي للعمل الآلي (مثل منتجات بلو ريفر **Blue River** وروبوتات الدردشة الذكية الأساسية)، والطائرات بدون طيار، والبيولوجيا الاصطناعية (في تحليل جينوم المحاصيل)، والمواد المتقدمة. وسيعمل التعلم الآلي والعميق أيضًا جنبًا إلى جنب مع إنترنت الكيانات والطائرات بدون طيار. ستوفر أجهزة الاستشعار التي تقيس الحالة العامة مثل؛ رطوبة المحاصيل، ودرجة الحرارة، وتكوين التربة، البيانات اللازمة للذكاء الاصطناعي لتحسين الإنتاج تلقائيًا، وتفعيل إجراءات مهمة مثل إضافة الرطوبة.

يتم استخدام الطائرات بدون طيار بشكل متزايد لمراقبة الأوضاع، والتواصل مع أجهزة الاستشعار، والأنظمة التي تدعم الذكاء الاصطناعي. وسيتعين على تنظيم ملكية البيانات وخوارزميات تسعير السلع الأساسية وتدفقات البيانات عبر الحدود، أن تواكب التطورات التكنولوجية سريعة النمو. تتمتع «الزراعة الذكية» بالقدرة على إحداث تغيير جذري في الزراعة، حتى أكثر مما فعلته أساليب الزراعة الجماعية في القرن العشرين. وقد تنتشر هذه التغييرات بسرعة أكبر من التغييرات السابقة.

■ التنبؤ بالطقس والنمذجة المناخية

وهناك مجال جديد من «المعلوماتية المناخية» يزدهر فعلاً، حيث يعمل على تسخير الذكاء الاصطناعي لتحويل التنبؤ بالطقس جذرياً (بما في ذلك التنبؤ بالأحداث المتطرفة)، وتحسين فهم تأثيرات تغير المناخ. وهذا أمر واعد، لأن مجتمع علوم الطقس والمناخ لديه فعلاً كميات كبيرة من البيانات وما يزال يجمع المزيد، مما يوفر قاعدة اختبار جيدة لتطبيقات التعلم الآلي والتعلم العميق.

حتى الآن، يتطلب استخدام مجموعات البيانات التي يتم تحديثها بشكل متكرر قوة حوسبة كبيرة، عالية الأداء، ويحد من إمكانية الوصول إليها واستخدامها بالنسبة للمجتمعات العلمية، ومجتمعات صنع القرار. ويمكن للذكاء الاصطناعي أن يحل هذه التحديات، من خلال زيادة أداء نمذجة الطقس والمناخ، وجعلها أكثر سهولة وقابلية للاستخدام في صنع القرار. ومع ابتعاد الاقتصادات والمستوطنات عن «البنية التحتية الضخمة»، فإن الوكالات العامة (بما في ذلك مكتب الأرصاد الجوية في المملكة المتحدة، ووكالة ناسا، والجهات الفاعلة في القطاع الخاص مثل؛ **IBM** ومايكروسوفت)، تستخدم الذكاء الاصطناعي والتعلم الآلي، لتعزيز أداء وكفاءة نماذج الطقس والمناخ.

تعالج هذه النماذج معادلات فيزيائية معقدة؛ بما في ذلك ديناميكيات الموائع الخاصة بالغلاف الجوي والمحيطات، وتوفر الاستدلال على العناصر التي لا يمكن حلها بالكامل (جوانب من كيمياء الغلاف الجوي كتحويل جزيئات الجليد إلى ماء).

يتطلب تعقيد المعادلات الحاكمة حوسبة باهظة الثمن ومستهلكة للطاقة، لكن شبكات التعلم العميق، يمكنها محاكاة بعض جوانب عمليات المحاكاة المناخية هذه، مما يسمح لأجهزة الحاسوب بالعمل بشكل أسرع بكثير، ودمج المزيد من التعقيد لنظام «العالم الحقيقي» في الحسابات. قد تساعد تقنيات الذكاء الاصطناعي أيضًا في تصحيح التحيزات في النماذج، واستخراج البيانات الأكثر صلة، لتجنب تدهور البيانات ولتحسين الكفاءة الحسابية. وفي كل هذه الحالات، يقوم الذكاء الاصطناعي، بمراقبة بشرية، «بالإشراف» على تحسين عمليات المحاكاة.

وبمرور الوقت، يمكن لنماذج الطقس والمناخ الأرخص والأسرع التي يتم فتحها من خلال الذكاء الاصطناعي أن تقلل من الحاجة إلى أجهزة الحاسوب العملاقة المتعطشة للطاقة، وتخفض تكلفة البحث، وتفتح مجال علوم الطقس والمناخ أمام الباحثين. وتشمل التطبيقات الواسعة للذكاء الاصطناعي؛ تقنيات أبسط للتعلم الآلي، والجمع بين نماذج الطقس وبيانات التأثيرات الإضافية، للمساعدة في التنبؤ بتأثيرات الأحداث المناخية الشديدة، صغيرة النطاق (كالمواصف والفيضانات)، والأنظمة البشرية، مما يسمح بإدارة الأخطار بشكل أفضل.

ومع ذلك، وعلى نطاق أوسع، فإن تطبيق تقنيات التعلم المعزز العميق الناشئة يعد منطقة مجهولة لعلوم المناخ والطقس. وستظهر الحاجة إلى البحث لتحديد الأنظمة الفيزيائية في العالم الحقيقي، التي ستكون فيها هذه الأدوات الجديدة مفيدة جدًا. ونحن نرى فعلاً كيف تساعد بيانات الطقس والمناخ الفضلى صناع القرار في القطاعين العام والخاص على تحسين قدرتهم على التكيف مع تغير المناخ.

على سبيل المثال، قام مكتب الأرصاد الجوية في المملكة المتحدة بتطوير تطبيق روبوت الدردشة لتوضيح كيف يمكن استخراج البيانات أو الاستعلامات «السهلة» من مجموعات البيانات الكبيرة المعقدة، باستخدام الذكاء الاصطناعي المتطور في الوقت

الحقيقي، والتواصل مع المستخدم من خلال واجهة بسيطة. مثال آخر، استخدام مساعدين اصطناعيين، يتم تغذيتهم ببيانات التوقعات، للمساعدة في اتخاذ القرارات اليومية، بدءاً مما يجب ارتداؤه، وحتى موعد السفر.

وتعمل بعض الشركات معاً ومع الجامعات والهيئات الحكومية، في مجال المعلوماتية المناخية. هناك الآن فرصة لإضفاء الطابع الرسمي على المجال العلمي الناشئ للذكاء الاصطناعي في علوم الطقس والمناخ وتنظيمه وتعزيزه، بما في ذلك التنسيق الدولي (المنظمة العالمية للأرصاد الجوية، والهيئة الحكومية الدولية المعنية بتغير المناخ)، فضلاً عن تمويل وطني مخصص للبحث والتطوير والتعاون بين الصناعات.

■ منصة بيانات وتحليلات الاستجابة للكوارث المجتمعية

إن السرعة والفاعلية التي يمكن بها للمنظمات والأفراد الاستجابة للكوارث، لها تأثير كبير على حجم الخسائر الاقتصادية والمعاناة الإنسانية، لا سيما في أكثر الأحداث كارثية. لكن التأخير يحدث غالباً بسبب نقص المعلومات وغياب البصيرة التحليلية والوعي بأفضل مسار للعمل. وغالباً ما تكون أجزاء كبيرة من البيانات الضرورية موجودة، ولكنها موزعة بين المنظمات المختلفة، وبالتالي لا يمكن للمجتمعات المحلية الوصول إليها في الغالب. يعد أفضل تخطيط للمرونة عنصراً مهماً للتخفيف من الأضرار الناجمة عن الكوارث الطبيعية المستقبلية. كما يمكن استخدام الذكاء الاصطناعي لفرز البيانات متعددة الأبعاد حول منطقة ما، وتحديد الجوانب التي لها أكبر الأثر على المرونة.

يمكن للذكاء الاصطناعي تشغيل وتحليل عمليات محاكاة لأحداث الطقس والكوارث المختلفة في منطقة ما للبحث عن نقاط الضعف، وتحديد أكثر خطط المرونة قوة عبر مجموعة من أنواع الأحداث.

يمكن للأنظمة الهجينة الجديدة من القواعد والأدوات استخدام البيانات وتقنيات الذكاء الاصطناعي، لبناء نظام «مستودع البيانات الموزعة على مستوى المجتمع»، والذي يمكن أن يعزز الاستعداد للكوارث، والاستجابة لها، بالتنسيق بين قدرات معلومات الطوارئ. عند وقوع كارثة، يتم تفعيل الاستخدامات المحددة مسبقاً للبيانات، لتزويد أوائل المستجيبين بأفضل الأدوات لفهم السياق المحلي، واتخاذ إجراءات دقيقة.

وعليه، يمكن للتعليم الآلي جنباً إلى جنب مع خوارزميات معالجة اللغة الطبيعية، من تحديد أفضل نقاط المحطات، وطرق التوزيع والإخلاء، ومقدار الإغاثة المطلوبة، والجدول الزمني المثالية لجهود الإغاثة. هنا سيعمل الذكاء الاصطناعي، جنباً إلى جنب، مع تقنيات الثورة الصناعية الرابعة الأخرى، بما في ذلك الطائرات دون طيار، وإنترنت الكيانات. وقد يتم دمج التعلم المعزز العميق، يوماً ما، في عمليات محاكاة الكوارث لتحديد استراتيجيات الاستجابة المثلى، على غرار الطريقة التي يتم بها استخدام الذكاء الاصطناعي حالياً لتحديد أفضل حركة في الألعاب مثل AlphaGo.

إن تسخير الذكاء الاصطناعي لتوفير أفضل استجابة وتخطيط للكوارث سوف يتطلب شراكات ما بين القطاعين العام والخاص. ولذلك، سيحتاج مجتمع الخبراء التقنيين والقانونيين والمحاسبين إلى تحديد مجموعات البيانات الرئيسة وتوحيد الأساليب، وتحديد منهجيات الاستفادة من واجهات برمجة التطبيقات، وأدوات التعلم الآلي، للوصول إلى البيانات الحيوية بشكل آمن ومسؤول، ووضع الشروط والأحكام لأصحاب المصلحة للعمل داخل النظام.

■ المياه اللامركزية

يمكن أن يؤدي التعلم الآلي والعميق إلى إحداث تغيير كبير في تحسين إدارة الموارد المائية. وعلى نحو متزايد، يتمتع الذكاء الاصطناعي بالقدرة على إنشاء موارد مائية موزعة «خارج الشبكة»، على غرار أنظمة الطاقة اللامركزية.

يمكن للعدادات الذكية المنزلية إنتاج كميات كبيرة من البيانات التي يمكن استخدامها للتنبؤ بتدفقات المياه، واكتشاف التناقضات، والتحقق من التسربات. وستكون المرحلة التالية هي الجمع بين التعلم الآلي وإنترنت الكيانات، وتقنية سلسلة الكتلة **Blockchain** لإنشاء نظام مياه لامركزي حقيقي، حيث تكتسب الموارد المحلية وإعادة تدوير المياه ذات الحلقة المغلقة قيمة، ويمكن حتى تداول الموارد المائية عبر هذه التقنية. علاوة على ذلك، يمكن الجمع بين التعلم الآلي والنمذجة التنبؤية والروبوتات، لتحويل الأساليب الحالية لبناء وإدارة البنية التحتية للمياه وتسريع الابتكار في الهندسة البيئية.

مثال، يمكن للأمناء أن تهندس بحيث يمكن ضبط تدفقات الرواسب الخاصة بها بشكل مستقل. وإلى جانب التسعير المبني على الذكاء الاصطناعي، يمكن لمثل هذه الأساليب تحسين استخدام المياه، وتغيير السلوك بتوفير الحوافز للحفاظ على المياه.

■ مدن ذكية تتواصل مع بعضها، وصالحة للعيش، مصممة بواسطة الذكاء الاصطناعي

وبعيداً عن المركبات ذاتية القيادة، يعد التعلم العميق أيضاً بأفضل تخطيط حضري، مما يؤدي إلى إنشاء مدن مرنة تتمحور حول الإنسان، مع الحد الأدنى من تلوث الهواء والأثر البيئي. ويمكن أيضاً استخدام الذكاء الاصطناعي لمحاكاة وأتمتة عملية إصدار قوانين تقسيم المناطق، وقوانين البناء والسهول الفيضية. وإلى جانب الواقع المعزز والواقع الافتراضي، يمكن استخدام البيانات الناتجة عن الذكاء الاصطناعي من قبل مخططي المدن والمستثمرين في البنية التحتية، جنباً إلى جنب مع المسؤولين عن ضمان الاستعداد للكوارث، وإعادة الإعمار عند الحاجة.

كما يمكن أن يساعد الذكاء الاصطناعي والعدادات الذكية وإنترنت الكيانات، في التنبؤ وتحسين توليد الطاقة، ومعالجة الطلب عليها في المناطق الحضرية؛ سواء على مستوى المدينة بأكملها أو على مستوى المنازل والمباني الفردية.

ومن الممكن أن تخلف كفاءة استخدام الطاقة المعززة بالذكاء الاصطناعي في الوقت الحقيقي تأثيراً فورياً وجوهرياً على استهلاك الطاقة (مثال؛ خفضت شركة جوجل استخدام الطاقة في مراكز بياناتها بنسبة 40% باستخدام خوارزميات التعلم المعزز من شركة ديب مايند DeepMind لتحسين التبريد).

وستكون الشبكات الذكية المدعومة بالذكاء الاصطناعي أيضاً بالغة الأهمية للمدن الناشئة، سريعة النمو، وهي في واقع الأمر قيد التجربة فعلاً، (من البرازيل إلى الفلبين). ومن الممكن أن يؤدي الجمع بين البيانات في الوقت الفعلي، على مستوى المدينة، حول استهلاك الطاقة والمياه وتوافرها، وتدفقات حركة المرور، وتدفقات الأشخاص، والطقس، إلى إنشاء «لوحة تحكم حضرية».

ومع إضافة الذكاء الاصطناعي، قد يؤدي ذلك إلى تحسين استخدام المياه والطاقة في جميع أنحاء المدينة، مما قد يقلل الحاجة إلى بنية تحتية إضافية مكلفة مع تقليل التلوث والازدحام؛ ومن ثم تقليل البصمة البيئية للمدينة، وزيادة قابليتها للعيش.

■ منصة بيانات المحيطات

قد تؤدي المراقبة في الوقت الفعلي باستخدام الذكاء الاصطناعي إلى تحسين عملية صنع القرار، في مجالات تتراوح بين إدارة الأنواع وحمايتها وإدارة الموارد الطبيعية، والقدرة على التكيف مع تغير المناخ. ومن الأمثلة المبكرة على ذلك؛ تحالف بيانات المحيطات، الذي بدأ العمل به سوية، لتطوير وتنفيذ حلول مفتوحة المصدر لتوفير البيانات اللازمة للرصد الشامل لموارد المحيطات، من الأقمار الصناعية إلى البيانات المستمدة من تكنولوجيات استكشاف المحيطات.

وإذا ما تم تطوير هذا النهج بالكامل، فيمكن أن يسمح لصانعي القرار باستخدام التعلم الآلي لرصد الظروف المتغيرة، والتنبؤ بها والاستجابة لها، كالصيد غير

القانوني، أو تفشي الأمراض، أو ظاهرة ابيضاض المرجان. ومن الممكن أن توفر قدرات المعالجة الجديدة شفافية قريبة من الوقت الحقيقي، وذلك بتمكين السلطات، وحتى عامة الناس، من مراقبة صيد الأسماك، ومغادرة السفن، وتعددين المحيطات، وغيرها من الأنشطة.

يمكن للأنماط الخوارزمية للسفن تحديد الصيد غير القانوني، ويمكن لأجهزة الاستشعار البيولوجية مراقبة صحة الشعاب المرجانية، ويمكن لأنماط تيارات المحيطات تحسين التنبؤ بالطقس. أحد التحديات الرئيسية التي تحول دون تحقيق مثل هذه المنصة، هو قوة المعالجة المطلوبة؛ فتمدجة المحيطات تأتي في المرتبة الثانية بعد الفيزياء الفلكية في تعطشها للقوة الحاسوبية. ولكن مع انخفاض تكلفة تخزين البيانات ومعالجتها، ستصبح الإمكانيات الجديدة لنمذجة الأنشطة البشرية، وكيفية تأثيرها على محيطاتنا متاحة. ولنع ظهور منصات مختلفة متنافسة، والتي يمكن أن تقلل من الفاعلية وتزيد من التكاليف الإجمالية لجمع وإدارة واستخدام بيانات المحيطات، يمكن إنشاء منصة مفتوحة، تمكن من تحميل البيانات من مصادر مختلفة موحدة، وباستمرار. وقد تكون هناك حاجة إلى شراكات بين القطاعين العام والخاص لضمان الثقة، والحوكمة والدقة.

■ بنك الأرض من الرموز

تهدف الابتكارات المستوحاة من الطبيعة (كأدوية ضغط الدم المشتقة من سم الأفعى)، إلى تكرار منتجات وعمليات الطبيعة.

تاريخياً، لم يتم تقاسم الإيرادات المتأتية من هذه الأنشطة مع المجتمعات الأصلية والتقليدية التي تأتي منها المعرفة. ولأول مرة في التاريخ، أصبح التقاسم العادل للمنافع وتدفق جديد كبير لتمويل الحفظ ممكناً الآن، باستخدام مزيج من سلسلة الكتلة، والذكاء الاصطناعي، وأجهزة الاستشعار المتقدمة، وإنترنت الكيانات.

تعمل مبادرة طريق الأمازون الثالث على تطوير بنك الأرض للرموز (EBC) **Earth** **Bank of Codes**، وهو مشروع لإنشاء منصة رقمية عالمية مفتوحة للمنفعة العامة تسجل أصول الطبيعة، وتسجل مصدرها المكاني والزمني وتدوّن الحقوق والالتزامات المرتبطة بها. (مما يساعد على تنفيذ بروتوكول ناغويا لاتفاقية التنوع البيولوجي). إن دمج الذكاء الاصطناعي وتحليلات الأنظمة المعقدة أمر حيوي لتجميع الأصول البيولوجية، والمحاكاة الحيوية، والمعارف التقليدية من نقطة ساخنة للتنوع البيولوجي، لتعظيم القيمة الاقتصادية وقيمة الحفظ في وقت واحد.

بالإضافة إلى ذلك، سيسمح «محرك البحث البيولوجي»، الذي يعتمد على الذكاء الاصطناعي للمستخدمين بفهم كامل لشبكة الحياة على كوكب الأرض، وهو ما قد يؤدي إلى تحسين الاكتشافات العلمية، وتحفيز عدد لا يحصى من الابتكارات المستوحاة حيوية، وتحسين نتائج الحفاظ على البيئة، بخلق مصادر جديدة ذات قيمة اقتصادية. وستشمل تقنيات الذكاء الاصطناعي معالجة اللغة الطبيعية، والتعلم العميق، والرؤية الحاسوبية، والبرمجة الاحتمالية، ومجموعة من تقنيات التعلم الآلي الإحصائية.

يقوم هذا المشروع ببناء تحالف بين أصحاب المصلحة الراغبين في التصميم والتنفيذ المشترك لـ **EBC** في حوض الأمازون (يدعى: **Amazon Bank of Codes**)، قبل التكرار والتوسع في المناطق الأحيائية الأخرى على الأرض وفي المحيطات، (Herweijer & Waughray, 2018).

دور الذكاء الاصطناعي في الجيوفيزياء التطبيقية والزلازل

على الرغم من تواترها وعواقبها المدمرة، لا يزال هناك الكثير غير معروف حول الزلازل وآليات تولدها وتأثيراتها. لقد كان التنبؤ بالزلازل، وهو أهم ما في علم الزلازل، موضوع اهتمام واسع النطاق لتطبيقات تقنيات الذكاء الاصطناعي. تعد (Lin and Chiou, 2019) **Feedforward** والشبكات العصبية المتكررة (Adeli and Panakkat, 2009) من بين أساليب تعليم الآلة الأكثر استخداماً لهذه المهمة.

في هذه الأساليب، تتبأ الشبكات العصبية بحجم وموقع الزلازل المستقبلية (Karasozen and Karasozen, 2020)، في نافذة زمنية أو مكانية، غالباً بناءً على السلسلة الزمنية لخصائص الزلازل السابقة مثل؛ وقت الحدوث أو القدر أو تركز الموقع.

وعلى الرغم من التقدم الذي تم إحرازه مؤخراً في تطوير التعلم المحوسب المتقدم، لا تزال هناك تحديات فيما يتعلق بكيفية تطبيقه بفاعلية على تنبؤات الزلازل القائمة على الذكاء الاصطناعي (Mignan and Broccardo, 2020). ويرجع ذلك إلى حقيقة أن معظم كتالوجات الزلازل مسجلة بتنسيق جدولي عادي، ولا تتوفر إلا سمات محدودة لتدريب النماذج الأكثر تعقيداً. ومع ذلك، فقد أدت منهجيات التعلم العميق إلى تسريع تطوير خوارزميات أكثر موثوقية، وأكثر كفاءة لرصد الزلازل (Mousavi et al., 2020).

يمكن أن تؤدي أساليب مراقبة الزلازل القائمة على الذكاء الاصطناعي إلى تعزيز السلامة من أخطار الزلازل في شقين: - تمكين أنظمة الإنذار المبكر بالزلازل (Bose et al., 2008) (EEW)، بتقديرات أسرع، وأكثر موثوقية لمعلومات الزلازل، - توفير كتالوجات الزلازل أكثر اكتمالاً ودقة، والمستخدم لتحسين تقييمات الأخطار الزلزالية على المدى الطويل، (Mousavi and Beroza, 2018).

• الجيوفيزياء الاستكشافية

تقوم الجيوفيزياء الاستكشافية بتصوير ما تحت سطح الأرض عن طريق قلب المجالات الفيزيائية المجمعة على السطح، ومن بينها حقول الموجات الزلزالية التي هي الأكثر استخداماً. يستخدم الاستكشاف الزلزالي الموجات الزلزالية المنعكسة للتعقب بالبنيات تحت السطح. تتكون العمليات الرئيسية للاستكشاف الزلزالي من أخذ عينات من البيانات الزلزالية ومعالجتها (تقليل الضوضاء، والاستيفاء، وما إلى ذلك)، والعكس (الترحيل، والتصوير، وما إلى ذلك)، والتفسير (اكتشاف الأخطاء، وتصنيف السحنات، وما إلى ذلك).

■ معالجة البيانات الزلزالية

تتلوث البيانات السيزمية بأنواع مختلفة من الضوضاء، مثل الضوضاء العشوائية الصادرة عن الخلفية، والتدحرجات الأرضية التي تنتقل على طول السطح بطاقة عالية وتخفي الإشارات المفيدة، والضوضاء المتعددة التي تنعكس عدة مرات بين الواجهات.

إحدى المشكلات القديمة في جيوفيزياء الاستكشاف هي إزالة الضوضاء وتحسين نسبة الإشارة إلى الضوضاء (SNR). تستخدم الطرق التقليدية المرشحات أو التنظيمات المصنوعة يدوياً لتقليل أنواع معينة من الضوضاء من خلال تحليل السمات المقابلة. ومع ذلك، تفشل المرشحات المصنوعة يدوياً عندما تشترك الإشارة والضوضاء في ميزة مشتركة. تتجنب طرق التعلم العميق اختيار الميزة عند استخدامها لتقليل الضوضاء الزلزالية. على سبيل المثال، يمكن لـ **DeepDenoiser** القائم على **U-Net** فصل الإشارات والضوضاء من خلال تعلم الانحدار غير الخطي (Zhu et al., 2019).


علاوة على ذلك، مع **DnCNN** شبكة **CNN** لتقليل الضوضاء، يمكن استخدام البنية نفسها لثلاثة أنواع من الضوضاء الزلزالية، مع تحقيق نسبة إشارة إلى ضوضاء،

(SNR) طالما كانت عالية (Yu et al., 2019)، كما يتم إنشاء مجموعة التدريب المقابلة. ومع ذلك، لا يزال هناك طريق طويل لقطعه.

لا تتمتع شبكة **DNN** المدربة على مجموعات البيانات الاصطناعية بقدرة تعليمية جيدة على البيانات الميدانية. ولجعل الشبكة قابلة لإعادة الاستخدام، يمكن استخدام نقل التعلم لتقليل ضوضاء البيانات الميدانية. في بعض الأحيان، قد يصعب الحصول على تسميات البيانات النظيفة، ويتمثل أحد الحلول في استخدام تجارب متعددة تتضمن الضوضاء البيضاء التي يولدها المستخدم، لمحاكاة الضوضاء البيضاء الحقيقية.

يظهر الشكل الآتي مثالاً على التوهين المتشتت للتدرج الأرضي (Yu et al., 2019). تتم ملاحظة التدرج الأرضي بشكل رئيس في المنطقة الصحراوية، وينتج التوهين عن تشتت التدرج الأرضي، عندما يكون السطح القريب غير متجانس جانبياً. من الصعب إزالة اللفة الأرضية المتشتتة لأنها تشغل مجال التردد نفسه، مثل الإشارات المنعكسة. تم استخدام **DnCNN** لإزالة اللفة الأرضية المتشتتة بنجاح. نظراً للقيود البيئية أو الاقتصادية، عادةً ما يتم تحديد مواقع الجيوفونات الزلزالية بشكل غير منتظم، أو ليس بالكثافة الكافية وفقاً لمبدأ أخذ العينات نيكويست. تعد إعادة بناء أو تنظيم البيانات الزلزالية إلى شبكة كثيفة ومنتظمة أمراً ضرورياً لتحسين دقة الانعكاس.

في البداية، تم اقتراح شبكات **DNN** الشاملة لإعادة بناء البيانات المفقودة بانتظام (Wang, Zhang, Lu, et al., 2019)، أو تلك المفقودة عشوائياً. ومع ذلك، فإن مجموعات التدريب هي تركيبة عديدة، ولا تعمم بشكل جيد على البيانات الميدانية. يمكن استعارة بيانات التدريب من مجموعة بيانات الصور



التعلم العميق للتوهين المنتشر على الأرض. على اليسار توجد مجموعة البيانات الصاخبة الأصلية، على اليمين توجد مجموعة البيانات الموهنة، تتم إزالة اللفة الأرضية المشتتة المميزة بالأسهم الحمراء، (Yu, and Ma, 2021)

الطبيعية لتدريب **DnCNN**، ثم تضمينها في المشروع التقليدي في إطار عمل مجموعة محددة. تم تعميم خوارزمية الاستيفاء الناتجة بشكل جيد على البيانات الزلزالية. علاوة على ذلك، لم تكن هناك حاجة إلى شبكات جديدة لاستكمال مجموعات البيانات الأخرى. ويعطي الشكل مجموعة التدريب، ونتيجة استيفاء بسيطة.


يتم استخدام انتقاء الوصول الأول لاختيار القفزات الأولى للإشارات المفيدة، وقد تم تشغيله آلياً، ولكنه يحتاج إلى تدخل بشري مكثف للتحقق من الانتقاء

مع تصحيحات ثابتة كبيرة، وطاقة ضعيفة، ونسب إشارة إلى ضوضاء منخفضة، وتغيرات طورية مثيرة. يساعد التعلم العميق على تحسين أتمتة ودقة الانتقاء الأول للوصول إلى البيانات الزلزالية الواقعية. من الطبيعي تحويل انتقاء الوصول الأول إلى مشكلة تصنيف عن طريق تعيين الوصول الأول كآحاد، والمواقع الأخرى كأصفار عند استخدام التعلم العميق.

ومع ذلك، يمكن أن يسبب مثل هذا الإعداد تسميات غير متوازنة. هناك نهج مثير للاهتمام يتعامل مع اختيار الوصول الأول على أنه مشكلة في تصنيف الصور، حيث يتم تعيين أي شيء قبل الوصول الأول على الصفر، ويتم تعيين جميع الحالات بعد الوصول الأول على واحد (Wu, Zhang, Li, et al., 2019).

تعمل هذه الطريقة جيداً في المواقف شديدة الضوضاء، ومجموعات البيانات الميدانية. وبعد الحصول على صورة التجزئة، يمكن تطبيق خوارزمية انتقاء أكثر تقدماً، مثل **RNN**، للاستفادة من المعلومات العالمية.

ويبين الشكل الآتي نتائج اختيار الوصول الأول على أساس **U-Net**. باستخدام 8000 عينة زلزالية اصطناعية. تمت إضافة قيد التدرج إلى وظيفة الخسارة لتعزيز استمرارية المواضيع المحددة.



اختيار المرحلة على أساس، المدخلات هي البيانات الزلزالية، المخرجات هي أصفار فوق أول وصول في المنطقة الخضراء، وأصفار أسفل أول وصول في المنطقة الصفراء، واثنان لأول وصول على الخط الأزرق. يشير الخط الأخضر إلى الوصول الأول المتوقع. (Yu, and Ma, 2021)

بالنسبة للمخرجات؛ فقد تم وضع ثلاثة تصنيفات: أصفار قبل الوصول الأول، وواحد بعد الوصول الأول، واثنان عند الوصول الأول. كانت مجموعة بيانات التدريب ملوثة بالضوضاء القوية، وكان لها آثار مفقودة، وكانت نتائج الانتقاء المتوقعة قريبة من التسميات. يعد ضغط الإشارة ضرورياً لتخزين ونقل البيانات الزلزالية. يتم تخزين البيانات الزلزالية التقليدية في 32 بت لكل عينة. باستخدام RNN لتقدير العلاقات بين العينات في التتابع الزلزالي وضغط البيانات الزلزالية، هناك حاجة إلى 16 بت فقط للتمثيلات غير المفقودة، بحيث يتم حفظ نصف التخزين.

يقوم التسجيل الزلزالي بمحاذاة الصور الزلزالية لمهام متنوعة، مثل دراسات الفاصل الزمني. ومع ذلك، عندما تكون هناك تحولات كبيرة وتغيرات سريعة، تصبح هذه المهمة صعبة جداً. يتم تدريب CNN باستخدام صورتين زلزالتين على أنها مدخلات، والتحول على أنها مخرجات من خلال التعلم من مفهوم التدفق البصري. تتفوق هذه الطريقة على الطرق التقليدية، ولكنها تعتمد على مجموعة بيانات التدريب.

■ تصوير البيانات الزلزالية

يعد التصوير السيزمي مشكلة صعبة لأن الطرق التقليدية كالتصوير المقطعي والانعكاس الموجي الكامل (FWI) تعاني من عدة اختناقات:

- يستغرق التصوير وقتاً طويلاً بسبب «لعنة الأبعاد».
- يعتمد التصوير كثيراً على التفاعلات البشرية لاختيار السرعات المناسبة.
- يحتاج التحسين غير الخطي إلى تهيئة جيدة، أو معلومات ذات تردد منخفض، ومع ذلك هناك نقص في طاقة التردد المنخفض في البيانات المسجلة.

تساعد أساليب التعلم العميق في تخفيف الاختناقات من عدة زوايا:


أولاً: تستخدم طرق التصوير المستندة إلى التعلم العميق البيانات المسجلة على أنها مدخلات ونماذج السرعة مخرجات، مما يوفر نهجاً مختلفاً تماماً للتصوير. تتجنب أساليب التعلم العميق الاختناقات المذكورة، مما يوفر طريقة تصوير من الجيل التالي. تُظهر المحاولات الأولى للتعلم العميق في التوقيع المساحي، والتصوير المقطعي وFWI نتائج واعدة على البيانات الاصطناعية ثنائية الأبعاد. إحدى القضايا المهمة هي أن الإدخال موجود في مساحة البيانات، والمخرجات موجودة في مساحة النموذج، وكلاهما ذوا معلمات عالية الأبعاد. يتم استخدام U-Net للنقل من مساحات مختلفة بأبعاد مختلفة، ويتم استخدام الاختزال لتقليل المعلمات أثناء تدريب DNN.

ومع ذلك، فإن تصوير التعلم العميق من طرف إلى طرف له عيوبه أيضاً، مثل نقص عينات التدريب، وأحجام الإدخال المقيدة بسبب قيود الذاكرة. وفي عمل مثير للاهتمام، استخدم صوراً طبيعية سلسلة نماذج للسرعة، وبالتالي أنتج عدداً كبيراً من النماذج لبناء مجموعة التدريب.

وهناك المزيد من الأعمال تهدف إلى التعاون مع الطرق التقليدية، وحل إحدى الاختناقات المذكورة، مثل استقراء نطاق تردد البيانات الزلزالية من الترددات العالية إلى الترددات المنخفضة لـ **FWI** وإضافة قيود على **FWI**، وذلك لجعل التصوير القائم على التعلم العميق قابلاً للتطبيق على مدخلات واسعة النطاق.

للتخفيف من مشكلة «لعنة الأبعاد» الخاصة بالتحسين العالمي في **FWI**، يتم استخدام **CAE** لتقليل أبعاد **FWI** من خلال التحسين في الفضاء الكامن (Gao et al., 2019). ويهدف عمل آخر إلى التكلفة الحسابية العالية للنمذجة المستقبلية عند استخدام طريقة الفروق المحدودة ذات الترتيب العالي.

يتم استخدام **GAN** لإنتاج مجال موجي عالي الجودة من مجال موجي منخفض الجودة، مع اختلاف محدود من الترتيب الأدنى في سياق المضاعفات والأشباح والتشتت ذات الصلة بالسطح. يمكن استخدام **U-Net** لالتقاط السرعة أثناء التراص كما في الشكل الآتي (Wang et al. 2021). المدخلات هي بيانات زلزالية، والمخرجات لها قيم واحدة حيث توجد اللقطات، وقيم صفر في مكان آخر.




انتقاء السرعة على أساس U-Net (Wang et al., 2021). المدخلات هي البيانات الزلزالية على اليسار، والمخرجات هي مواضع الالتقاط على اليمين، AP يعني الجذر التقريبي لمتوسط السرعة المربعة. يمثل PD_CLS و PD_REG توقعات السرعة لشبكة الانحدار وشبكة التصنيف، على التوالي، (Yu, and Ma, 2021).

البديل هو استبدال كائن FWI بوظيفة فقدان RNN. يشبه هيكل RNN هيكل التطور الزمني المختلف المحدود، وتتوافق معلمات الشبكة مع نموذج السرعة المحدد. لذلك، فإن تحسين RNN يعادل تحسين FWI.

وتمتد مثل هذه الإستراتيجية لتشمل الانعكاس المتزامن للسرعة والكثافة. يوضح الشكل الآتي بنية RNN المعدلة بناءً على معادلة الموجة الصوتية المستخدمة من قبل الباحث ليو Liu.

يمثل الرسم البياني معادلة الموجة المنفصلة المطبقة في RNN مع مخطط انسيابي. يمكن أيضاً تعلم الطريقة المحسنة في FWI بواسطة DNN، بدلاً من اتباع نهج قائم



الشبكة العصبية المتكررة المعدلة (RNN) بناءً على معادلة الموجة الصوتية لنمذجة الموجة. يمثل الرسم البياني معادلة الموجة المنفصلة المطبقة في RNN. تساعد ميكانيكا التفاضل التلقائي للشبكة العصبية العميقة (DNN) على تحسين السرعة والكثافة بكفاءة، (Yu, and Ma, 2021).

على النسب التدريجي. وقد تم اقتراح طريقة النسب في التعلم الآلي، للنظر في المعلومات التاريخية للتدرج بناءً على RNN، بدلاً من الاتجاهات اليدوية.

■ تفسير البيانات الزلزالية وتحليل الصفات


يمكن استخدام التفسير الزلزالي (صدوع وطيّات ومنخفضات... إلخ)، أو تحليل السمات (من ممانعة وتردد وسحنة.... إلخ)، للمساعدة في استخلاص المعلومات الجيولوجية تحت السطح، وتحديد النقاط المهمة فيها. ومع ذلك، فإن كلتا المهمتين تستغرقان وقتاً طويلاً، ذلك أن تدخلات الخبراء مطلوبة. تظهر الأعمال الأولية أن التعلم العميق لديه القدرة على تحسين الكفاءة، والدقة في التفسير الزلزالي أو في تحليل السمات.

إن تحديد مواقع الصدوع والطيّات والمنخفضات في التفسير الزلزالي يشبه اكتشاف الكيانات في رؤية الحاسوب. ولذلك، يمكن تطبيق شبكات DNN للكشف عن الصور مباشرة في التفسير الزلزالي. ومع ذلك، وعلى عكس صناعة الرؤية الحاسوبية، من الصعب الحصول على مجموعة تدريب عامة، أو إنشاء مجموعة تدريب يدوية لمجموعات البيانات الميدانية.

يُعد بناء مجموعات بيانات اصطناعية واقعية بدلاً من مجموعات البيانات الميدانية المصنوعة يدوياً أكثر كفاءة، ويمكن أن يؤدي إلى نتائج مماثلة. ولذلك، يتم استخدام العينات الاصطناعية للتدريب. لبناء مجموعة بيانات تدريب ثلاثية الأبعاد واقعية تقريباً، يلزم اختيار معلمات الطي والصدع عشوائياً في نطاق معقول (Wu et al., 2020).

بعد ذلك، يتم استخدام مجموعة البيانات لتدريب شبكة **U-Net** ثلاثية الأبعاد على التفسير الهيكلي الزلزالي للسماوات، مثل الصدوع والطيات والمنخفضات، في مجموعات البيانات الميدانية. إذا كانت الكيانات المكتشفة ذات نسبة صغيرة، يتم استخدام دالة فقدان الإنتروبيا الثنائية المتوازنة للفئة، لضبط اختلال توازن البيانات بحيث لا يتم تدريب الشبكة على التنبؤ بالأصفار فقط.

البديل لمجموعة التدريب الاصطناعية هو النهج شبه الآلي الذي يوضح الأهداف على نطاق تقريبي، ويتنبأ بها على نطاق جيد. يظهر في الشكل الآتي مثال على تحليل أخطاء الصور الاصطناعية، والبيانات الميدانية ما بعد التكديس.



(A) مجموعة بيانات ما بعد التكديس، (B) نتيجة التنبؤ بالصدع (C) مجموعة بيانات مركبة، (Wu et al., 2020).

إن تحليل السمات يسببه تصنيف الصور، حيث تكون الصور الزلزالية عبارة عن مدخلات، ويتم إخراج المناطق ذات التسميات كسمات مختلفة. لذلك، يمكن تطبيق شبكات **DNN** لتصنيف الصور مباشرة في تحليل السمات الزلزالية.

إذا لم يكن من الممكن حساب السمات مباشرة من البيانات الزلزالية، فيمكن أن تعمل شبكة **DNN** بطريقة متتالية. إذا لم تكن التسميات متاحة، يتم استخدام **CAE** لاستخراج السمات، ثم يتم استخدام طريقة التجميع، مثل وسائل **K**، للتجميع غير الخاضع للرقابة. يشير التجميع إلى جمع السمات المتشابهة بطريقة غير خاضعة للرقابة. على سبيل المثال، يمكن استخدام التجميع لتحديد ما إذا كانت المنطقة تحتوي على سحنة نهريّة أو صدوع بناءً على المقاطع المكسدة.

يمكن أيضاً تحسين **CAE** و **K-means** في وقت واحد، لاستخراج السمات بشكل أفضل. للتخفيف من اعتماد شبكات **CNN** على كمية البيانات الزلزالية المتاحة، تم اقتراح خوارزمية تعتمد على **CycleGAN 1D** لانعكاس المعاوقة.

لم يتطلب **CycleGAN** اقتران مجموعة التدريب. هناك حاجة إلى مجموعتين فقط بدقة عالية وبدونها. للنظر في الاستمرارية المكانية والتشابه بين الآثار المجاورة، يتم استخدام **RNN** في تحليل السحنات.

• علم الزلازل

إن الهدف من معالجة بيانات الزلازل يختلف تماماً عن هدف الجيوفيزياء الاستكشافية؛ ولذلك، يركز هذا القسم على معالجة إشارات الزلازل المستدة إلى التعلم العميق. تتضمن المعالجة الأولية لإشارات الزلازل تصنيفاً لتمييز الزلازل الحقيقية عن الضوضاء، واختيار الوصول لتحديد أوقات وصول الموجات الأولية (**P**) والموجات الثانوية (**S**). وتشمل التطبيقات الأخرى موقع الزلازل والتصوير المقطعي للأرض. وقد أظهر التعلم العميق نتائج واعدة في هذه التطبيقات.

■ تصنيف الزلازل والضوضاء

يعد تصنيف إشارات الزلازل والضوضاء من أهم وأصعب المهام في مجال الإنذار المبكر بالزلازل (EEW). أنظمة EEW التقليدية تتجنب التنبهات الكاذبة والفائتة. يمكن تطبيق DNN مباشرة في تمييز الإشارة والضوضاء نظراً لأنها مهمة تصنيف.

من خلال مجموعة تدريب كافية، يمكن لـ DNN تحقيق ما يصل إلى ما بين 99.2% و 99.5% من الدقة في مناطق مختلفة. للكشف عن إشارات الزلازل الصغيرة والضعيفة التي تقاوم الضوضاء القوية والإشارات غير الزلزالية، تم تطوير شبكة متبقية ذات وحدات تلافيفية ومتكررة (Mousavi, Zhu, Sheng, et al., 2019).

تُستخدم RNN و CNN أيضاً في مهمة أكثر صعوبة للتمييز بين المصادر البشرية، مثل انفجارات التعدين أو المحاجر، والزلازل التكتونية. هناك حاجة إلى المزيد من فئات الإشارات لتحديد ما في مهام محددة، كما هو الحال في الكشف عن الزلازل البركانية. يمكن تصنيف الإشارات الزلزالية البركانية إلى ست فئات: الأحداث طويلة الأمد، والهزات البركانية، والأحداث البركانية التكتونية، والانفجارات، والأحداث الهجينة، والأعاصير. يتم أخذ عدم اليقين أيضاً في الاعتبار عند مراقبة الزلازل البركانية.

وهذا مثال على استخدام تحويل تشتت الموجات (WST) وآلة متجهة داعمة لتصنيف الزلازل مع عدد محدود من عينات التدريب. يتضمن WST سلسلة من تحويلات الموجات، ومشغل الوحدة، ومشغل المتوسط المتوافق مع المرشحات التلافيفية، والمشغل غير الخطي، ومشغل التجميع في CNN، على التوالي. الفرق الحاسم بين WST و CNN هو أن المرشحات مصممة مسبقاً مع تحويل الموجات في WST. في حالتنا، تم استخدام 100 سجل فقط للتدريب، وتم استخدام 2000 سجل للاختبار. وقد حصل الباحثون على دقة تصنيف تصل إلى 93% باستخدام طريقة WST.

■ اختيار الوصول

يحدد اختيار الوصول للزلازل وقت وصول الموجات **P** و **S**. تعد خوارزميات انتقاء الوصول الآلي التقليدية، مثل طريقة (المتوسط المدى القصير/ متوسط المدى الطويل) (**STA/LTA**)، أقل دقة من الخبراء البشريين وتعتمد على تحديد العتبة. يتغلب انتقاء الوصول المستند إلى **DL** على أوجه القصور هذه ويساعد في إلقاء الضوء على بنية الأرض بوضوح.

باستخدام مجموعة تدريب كبيرة بما فيه الكفاية، يمكن للمرء تحقيق دقة انتقاء وتصنيف بشكل ملحوظ أعلى من **STA/LTA**، حتى قريبة من الخبراء البشريين أو أفضل منهم (**4.5** مليون مجموعة التدريبات على قياس الزلازل). إذا لم تكن التصنيفات كافية، فيمكن استخدام نموذج **EarthquakeGen** المستند إلى **GAN** لتوسيع مجموعات البيانات المصنفة بشكل مصطنع (**Wang, Zhang, & Li, 2019**). تم تحسين دقة الكشف بشكل كبير بإجراء أخذ عينات صناعية لمجموعة التدريب. يمكن أن يؤدي الكشف المتزامن عن الزلازل واختيار الطور إلى تحسين دقة كلتا المهمتين (**Mousavi et al., 2020**).


■ موقع الزلزال والتطبيقات الأخرى

يُعد تقدير موقع الزلزال وحجمه أمرًا مهمًا في **EEW** والتصوير تحت السطح. يعتمد موقع الزلازل التقليدي بشكل كبير على نموذج السرعة، ويعاني من اختيار غير دقيق للمرحلة.

يتم استخدام **CNN** لتحديد موقع الزلازل عن طريق استخدام الأشكال الموجية المستقبلية في عدة محطات كمدخلات وخريطة الموقع كمخرجات (**Zhang, et al., 2020**). نجحت هذه الطريقة بشكل جيد مع الزلازل (**ML < 3.0**) ذات نسبة الإشارة إلى الضوضاء (**SNR**) المنخفضة، والتي تفشل فيها الطرق التقليدية.

يوضح الشكل الآتي نتائج التنبؤ والأخطاء الخاصة بمواقع مصادر الزلازل. ويساعد التعلم العميق أيضاً في تقدير مواقع الزلازل وحجمها بناءً على إشارات من محطة واحدة (Mousavi & Beroza, 2020a; Mousavi & Beroza, 2020b).

تشتمل التطبيقات الإضافية على ربط المراحل الزلزالية، والتي تتضمن جميع اختيارات الطور على محطات متعددة مرتبطة بحدث فردي، وتحليل العلاقة بين زلزال قوي وتشوه ما بعد الزلزال.



تحديد مصادر الزلازل مع التعلم العميق؛ المثلثات السوداء هي محطات. إلى اليسار: النقاط الزرقاء هي المواقع الفعلية، على اليمين: الدوائر الحمراء هي المواقع المتوقعة. يمثل نصف قطر الدائرة خطأ مركز الزلزال المتوقع (Zhang, Zhang, et al., 2020).

• الاستعانة بالذكاء الاصطناعي للتنبؤ بالزلازل

لقد كان التنبؤ بالزلازل هدفاً طويل الأمد في علم الزلازل حالياً، لا توجد طريقة موثوقة للتنبؤ بالزلازل على المدى القصير (دقائق-أسابيع). يمكن أن يكون للقدرة على تحديد أسلاف الزلازل المنتظمة تأثير كبير على الاستعداد لمواجهة الأخطار، وبالتالي تقليل تأثير الزلازل شديدة التدمير، (Ong & Lye, 2021).

إن التنبؤ الاحتمالي بالزلازل محدود جداً، وعمليات ما قبل الزلزال غير مفهومة بشكل جيد. يعد نموذج تسلسل الهزات الارتدادية من النوع البائي (ETAS) حالياً هو النموذج الأكثر شيوعاً لوصف الزلازل في منطقة ما.

يقدم النموذج فكرة أن الزلازل الكبيرة تؤدي إلى عدد أكبر من الهزات الارتدادية التي تصاحبها زلازل خلفية. لا تعتمد هذه الطريقة على الملاحظات التجريبية للأسلاف ولكنها توفر توقعات بناءً على حساب الاحتمالية.

ومع ذلك، فقد تمت ملاحظة الظواهر السابقة، مثل تجمعات الزلازل قصيرة المدى التي تعزى إلى زيادة نشاط الهزات الأمامية، والتغيرات في سرعة الزلازل قبل حدوث بعض الزلازل الكبيرة. تؤدي هذه الملاحظات في كثير من الأحيان إلى تنبؤات خاطئة وبالتالي تُعد غير موثوقة.

يمكن أن توفر الأسلاف التشخيصية الخاصة بميغاواط صغير ونطاق الموقع معلومات مهمة للتنبؤ بالزلازل، إذا تم تحديدها بشكل منهجي قبل حدوث الزلازل ضمن تلك النطاقات.

يمكن أن تكون الأسلاف غير المقيدة بنطاق M_w ، أو الموقع أكثر موثوقية عند استخدامها مع معلومات أخرى مثل؛ تكرار الزلازل النموذجي في المنطقة التي تم التحقيق فيها. (Ong & Lye, 2021)

تم تطبيق مجموعة متنوعة من الأساليب للتنبؤ بالزلازل. وقد تضمنت الأساليب السابقة للتنبؤ بالزلازل بناءً على فترات تكرارها، والأنماط الإحصائية.

وتعتمد الأساليب الأخرى الأكثر شيوعاً على الملاحظات التجريبية للتغيرات الأولية. يأخذ النهج التجريبي في الاعتبار مجموعة متنوعة من الملاحظات، بدءاً من النشاط الزلزالي الأولي والتقلبات الكهرومغناطيسية إلى الانبعاثات الكيميائية والسلوك الحيواني الشاذ. وعلى الرغم من حدوثها بشكل متكرر قبل بعض الزلازل الكبيرة، إلا أن هذه الأساليب لم تقدم تنبؤات موثوقة وقصيرة المدى على أساس ثابت. على سبيل المثال، من المفهوم أن العديد من الزلازل الطبيعية الكبيرة يسبقها تسلسلات انزلاقية وهزات أمامية بطيئة.

ومع ذلك، هناك صعوبة في استخدام أحداث الانزلاق البطيء، وحشود الزلازل (الهزات النذيرة) للتنبؤ بالزلازل الطبيعية، لأنها لا تحدث بشكل منهجي قبل الزلازل الكبيرة، وبالتالي لا يمكن اعتبارها صدع تنبؤ على المدى القصير. في الوقت الحالي، فإن غالبية أسلاف الزلازل المبلغ عنها ليست زلزالية.

في الآونة الأخيرة، أظهرت التجارب العملية تغيرات منهجية قبل الزلازل العملية. يُعتقد أن نذير الزلازل تنشأ عندما تصل الصدوع إلى ظروف الإجهاد الحرجة التي تسبق فشل القص. قبل فشل الصدع، أظهرت الزلازل المخبرية زيادة في فشل القص الصغير، حيث يصدر كل منها انبعاثات صوتية نبضية. وقد لوحظت أيضاً تغييرات منهجية في سرعة الموجة المرنة والانتقال الصوتي قبل فشل صدع المختبر.

في الآونة الأخيرة، تم استخدام التعلم الآلي، وهو مجال يستخدم لتحليل الخصائص الإحصائية لكميات كبيرة من البيانات، لدراسة التغيرات في الإشارة الصوتية المنبعثة من مناطق صدع المختبر.

أتاحت هذه التقنية التنبؤ الدقيق جداً بالزلازل المعملية من خلال تحديد الإشارة المنبعثة من منطقة الصدع التي كان يُعتقد سابقاً أنها ذات ضوضاء منخفضة السعة. على الرغم من تقديم أدلة ملموسة على الأسلاف، فإن النتائج التي تم الحصول عليها من التجارب المعملية لا يمكنها التقاط مجمل العمليات الفيزيائية المعقدة التي تحدث أثناء الزلزال الطبيعي.

تم تطبيق طريقة التعلم الآلي نفسها على البيانات الزلزالية من منطقة اندساس كاسكاديا **Cascadia**. ومن خلال طرح المشكلة على أنها انحدار بين الخصائص الإحصائية للبيانات الزلزالية المستمرة ومعدل إزاحة نظام تحديد المواقع العالمي (GPS) السطحي، أظهرت الدراسة أن دفع كاسكاديا الضخم يصدر بشكل مستمر إشارة تشبه الهزة ذات خصائص إحصائية تعكس معدل الإزاحة على الصدع.

وعلى الرغم من توفير إمكانية الوصول في الوقت الحقيقي إلى الحالة الفيزيائية للجزء الذي ينزلق ببطء من الدفع الكبير، إلا أن هذه الطريقة لم يتم تطبيقها على التنبؤ السريع بالزلازل. لم يتم بعد تحديد الأسلاف المنهجية للزلازل السريعة (Mignan & Broccardo 2019). تنشأ الصعوبة في تحديد الأسلاف الطبيعية جزئياً من حقيقة أنه بدون معرفة موقع الزلزال الوشيك، لا يمكن تركيز الجهود نحو اكتشاف التغيرات في الخصائص داخل منطقة الصدع وما حولها قبل الفشل.

علاوة على ذلك، من المرجح أن تكون مقياس قدر العزم **Mw** للأسلاف أصغر بكثير من مقياس قدر العزم **Mw** للحدث، وبالتالي غالباً ما تظل الأسلاف غير مسجلة أو غير محددة بواسطة أجهزة قياس الزلازل. بالإضافة إلى ذلك، قد يتم إخفاء الأسلاف في كثير من الأحيان بواسطة زلازل أخرى أو حشود زلازل تتميز بخصائص إحصائية مختلفة تماماً. هناك أمل في أن تؤدي الزيادة الكبيرة في كثافة المحطات وحساسيتها على مدار الخمسة عشر عاماً الماضية، إلى تقدم في التنبؤ بالزلازل، واكتشاف الأسلاف.

التعلم العميق هو مجموعة فرعية من التعلم الآلي المستخدم لاستخراج سمات عالية المستوى من البيانات الأولية. تشكل الطبقات المخفية المتعددة من الخلايا العصبية المترابطة جداً، المشابهة للخلايا العصبية الموجودة في الدماغ البيولوجي، شبكات عصبية عميقة (DNNs) والتي أظهرت أداءً فائقاً في اكتشاف الأنماط المعقدة ضمن مجموعات بيانات كبيرة جداً. الميزة الرئيسية لاستخدام شبكات DNN هي أنه، بشكل عام، ليست هناك حاجة لاستخراج السمات أو أي معالجة مسبقة مهمة. ونتيجة لذلك، يمكن استخدام كميات كبيرة من البيانات مباشرة لتدريب الشبكة العصبية. أظهر نوع من الشبكات العصبية الاصطناعية (ANN) المعروفة باسم الشبكة العصبية التلافيفية (CNN) أداءً ممتازاً في العديد من مشكلات التعرف البصري مثل تصنيف الصور واكتشاف الكيانات والتجزئة الدلالية (Zhao et al. 2019).

إن مهمة التعرف على التغيرات ضمن سلسلة زمنية موجية تشبه إلى حد كبير مهمة التعرف على الكيانات في الصور ثنائية الأبعاد. من المزايا المهمة لاستخدام CNN للكشف عن الأسلاف الزلزالية أن شبكات CNN يمكنها اكتشاف سمات بأي نطاق (Zhao et al. 2017). ونتيجة لذلك، يمكن اكتشاف حتى تغيير بسيط جداً في الإشارة القريبة من الزلزال.

تم تطبيق شبكات CNN بشكل متكرر للكشف عن الزلازل، مما أدى إلى إنشاء كتالوجات محسنة للزلازل من خلال التحليل الفاعل لكميات كبيرة من البيانات الزلزالية (Mousavi et al. 2019).

ومع ذلك، فإن البحث في إمكانيات شبكات CNN وهندسة الشبكات العصبية المعقدة لتحسين القدرة على التنبؤ بالزلازل محدود جداً. استخدم هوانغ وآخرون (2018)، شبكة CNN بسيطة للتحقيق في البيانات الزلزالية قبل وقوع الزلازل في تايوان. تم تحويل خرائط الزلازل التايوانية إلى صور ثنائية الأبعاد عن طريق تشفير الزلزال Mw على أنه سطوع.

تم استخدام نهج قائم على التصنيف لاكتشاف الاختلافات في الخرائط الزلزالية حتى 30 يوماً قبل الزلازل الكبيرة التي تبلغ $6 < M_w$ ، والخرائط الزلزالية حتى 30 يوماً قبل الزلازل الصغيرة ($M_w < 6$). أدت الخوارزمية الخاصة بها إلى درجة R تبلغ 0.303، حيث تكون درجة R البالغة 0 نتيجة لتنبؤ عشوائي تماماً ودرجة R البالغة 1 هي تنبؤ ناجح تماماً.

تشير درجة R البالغة 0.303 إلى أن CNN التقطت بعض أنماط الزلازل الأولية، ومع ذلك، لم يتم إجراء أي تحقيق إضافي في الأنماط التي أدت إلى نتيجة التصنيف هذه. وبالإضافة إلى ذلك، لم تؤخذ هذه النتائج في الاعتبار للتنبؤ الاحتمالي بالزلازل. بتشجيع من النجاح في مشكلات التصنيف، قام الباحثون أيضاً بتطبيق شبكات CNN بشكل متكرر لحل مشكلات التنبؤ المنظمة. أحد الأمثلة الشائعة الاستخدام على ذلك هو التجزئة الدلالية التي تنتج تنبؤاً لكل بكسل في الصورة. تشبه مهمة تجزئة بيانات السلاسل الزمنية تجزئة الصور، حيث يتم التنبؤ لكل عينة زمنية بدلاً من كل بكسل. تضمن أحد الأساليب، الذي حقق دقة عالية ومعدل استرجاع، استخدام التجزئة الدلالية للكشف عن مرحلتي P و S في البيانات الزلزالية (Zhu & Beroza 2019).

على الرغم من أن شبكات CNN شائعة الاستخدام في الصور ثنائية الأبعاد (Huang et al. 2018)، فإن هذا البحث سوف يبحث في الأسلاف بناءً على سمات الإشارة الزلزالية الخام فقط. وحسب هوانغ، لا يوجد بحث حالي يتضمن استخدام الشبكات العصبية للكشف عن الأسلاف في المختبر، وإعدادات الزلازل الحقيقية من خلال تحليل بيانات السلاسل الزمنية الأولية. بدلاً من استخدام أشجار القرار لاكتشاف التغيرات في السمات الإحصائية للإشارة، يمكن استخدام الشبكات العصبية لاكتشاف التغيرات المنهجية القائمة على الأنماط في السلاسل الزمنية الأولية.

ونتيجة لذلك، سيحدد هذا التحقيق ما إذا كان من الممكن اكتشاف الأسلاف دون أي معالجة جوهريّة مسبقة للبيانات. يتم الحصول على بيانات المختبر في بيئة خاضعة للرقابة، وبالتالي فهي أقل تعقيداً بكثير من بيانات الزلازل الحقيقية. ستشمل التحليلات الأولية أبسط مهمة، وهي الكشف عن الزلازل في بيانات المختبر. سيوفر هذا تحقيقاً أولياً جيداً لتمكين فهم أكبر لتطبيق شبكات CNN (التي يتم تطبيقها عادةً على مجموعات البيانات ثنائية الأبعاد)، على السلاسل الزمنية. يمكن بعد ذلك تصميم التقنيات المستخدمة هنا لتتناسب مع المهام الأكثر تعقيداً المتمثلة في اكتشاف الظواهر السابقة في المختبر، وبيانات الزلازل الحقيقية. أظهرت الدراسات العملية أسلاف منهجية لفشل احتكاكي يشبه الزلازل. ومع ذلك، ما يزال السؤال حول إمكانية اكتشاف مثل هذه التغييرات في بيئات الزلازل الحقيقية واستخدامها للتنبؤ بالفشل، دون إجابة.

نظراً لتوافر البيانات الزلزالية ووفرته على نطاق واسع، من خلال تحديد الأسلاف المنهجية ضمن البيانات الزلزالية، (مثال؛ ضمن الانبعاثات الكهرومغناطيسية)، يمكن تطبيق هذه الطريقة للتحقيق في الأسلاف في المناطق النشطة زلزالياً الأخرى، حيثما تتوفر البيانات الزلزالية بسهولة.

بالإضافة إلى ذلك، بدلاً من النظر في التغييرات طويلة المدى مثل انخفاض سرعة الموجات الزلزالية، وزيادة نشاط الهزات الأرضية التي لا تحدث بشكل منهجي قبل الزلازل الكبيرة، سيركز هذا المشروع على التقلبات قصيرة المدى، ويحاول اكتشاف الأنماط ضمن البيانات الزلزالية التي تحدث خلال إطار زمني أصغر (دقائق إلى ساعات) قبل الزلازل الكبيرة. إن التركيز على إطار زمني أصغر، وتدريب شبكة CNN المعقدة للتصنيف، قد يمكن بشكل أكثر قوة من اكتشاف الأنماط غير المكتشفة سابقاً في الإشارات الزلزالية.

وأخيراً، نظراً لنجاح التجزئة الدلالية لبيانات السلاسل الزمنية (Zhu & Beroza, 2019)، سيتم تطبيق هذه التقنية على اكتشاف الأسلاف. لم يستخدم أي عمل سابق التجزئة الدلالية للتحقيق في أسلاف الزلازل.

مخاطر الذكاء الاصطناعي

لقد أثبت الذكاء الاصطناعي (AI) أنه سلاح ذو حدين. وبينما يمكن قول هذا عن معظم التقنيات الجديدة، إلا أن كلا جانبي شفرة الذكاء الاصطناعي أكثر وضوحًا بكثير، ولا يمكن فهم أي منهما جيدًا.

لننظر أولاً في الإيجابيات. بدأت هذه التقنيات في تحسين حياتنا بطرق لا تعد ولا تحصى، بدءاً من تبسيط عملية التسوق وحتى تعزيز تجارب الرعاية الصحية. كما أصبحت قيمتها بالنسبة للشركات أيضاً أمراً لا يمكن إنكاره؛ فقد أخبرنا ما يقرب من 80% من المديرين التنفيذيين في الشركات التي تستخدم الذكاء الاصطناعي مؤخراً، أنهم يرون فعلاً قيمة معتدلة منه.

على الرغم من أن الاستخدام واسع النطاق للذكاء الاصطناعي في الأعمال التجارية لا يزال في مراحله الأولى، وأن التساؤلات ظلت مفتوحة حول وتيرة التقدم، فضلاً عن إمكانية تحقيقه الكأس المتمثلة في «الذكاء العام»، إلا أن الإمكانيات هائلة.

تشير أبحاث معهد ماكينزي العالمي إلى أنه بحلول عام 2030، يمكن للذكاء الاصطناعي تقديم ناتج اقتصادي عالمي إضافي بقيمة 13 تريليون دولار سنوياً. ولكن، بينما يعمل الذكاء الاصطناعي على توليد فوائد للمستهلكين وقيمة تجارية، فإنه يؤدي أيضاً إلى ظهور مجموعة من العواقب غير المرغوب فيها، والخطيرة أحياناً. وبينما يتم التركيز على الذكاء الاصطناعي، فإن هذه التأثيرات غير المباشرة (وطرق منعها أو تخفيفها) تنطبق بالتساوي على جميع التحليلات المتقدمة.

وأكثر العواقب وضوحاً، والتي تشمل؛ انتهاكات الخصوصية، والتمييز، والحوادث، والتلاعب بالأنظمة السياسية، هي أكثر من كافية للحث على الحذر. والأمر الأكثر إثارة للقلق، هو أن العواقب لم تُعرف أو لم يتم تجربتها بعد.

من الممكن حدوث تداعيات كارثية؛ بما في ذلك خسارة حياة بشرية، إذا حدث خطأ في خوارزمية طبية للذكاء الاصطناعي، أو تعريض الأمن القومي للخطر، إذا قام الخصم بتغذية معلومات مضللة لنظام الذكاء الاصطناعي العسكري. وكذلك هي التحديات الكبيرة التي تواجه المؤسسات، من الإضرار بالسمعة والانتهاكات، وخسائر الإيرادات بسبب ردود الفعل التنظيمية، والتحقيقات الجنائية، وتقلص ثقة الجمهور.

ولأن الذكاء الاصطناعي يمثل قوة جديدة نسبياً في مجال الأعمال، فقد أتيحت الفرصة لعدد قليل من القادة لصقل حدسهم حول النطاق الكامل للأخطار المجتمعية والتنظيمية والفردية، أو تطوير معرفة عملية بالدوافع المرتبطة بهم، والتي تتراوح من البيانات التي يتم تغذيتها في أنظمة الذكاء الاصطناعي لتشغيل النماذج الخوارزمية، والتفاعلات بين البشر والآلات.

ونتيجة لذلك، غالباً ما يتجاهل المسؤولون التنفيذيون الأخطار المحتملة (نحن لا نستخدم الذكاء الاصطناعي في أي شيء يمكن أن ينفجر، مثل السيارات ذاتية القيادة)، أو يبالغون في تقدير قدرات المؤسسة على تخفيف الأخطار (لقد كنا نقوم بالتحليلات منذ فترة طويلة، لذلك لدينا فعلاً الضوابط الصحيحة المعمول بها، حيث تتوافق ممارساتنا مع ممارسات أقراننا في الصناعة).

ومن الشائع أيضاً أن يجمع القادة أخطار الذكاء الاصطناعي مع الأخطار الأخرى المملوكة لمختصين في مؤسسات تكنولوجيا المعلومات والتحليلات (أنا أثق بفريقي الفني؛ إنهم يبذلون كل ما في وسعهم لحماية عملائنا وشركتنا).

يحتاج القادة الذين يأملون في تجنب العواقب غير المقصودة، أو على الأقل تخفيفها، إلى بناء مهاراتهم في التعرف على الأنماط فيما يتعلق بأخطار الذكاء الاصطناعي، وإشراك المنظمة بأكملها حتى تكون مستعدة لاحتضان القوة والمسؤولية المرتبطة بالذكاء الاصطناعي.

إن مستوى الجهد المطلوب لتحديد ومراقبة جميع الأخطار الرئيسية يتجاوز بشكل كبير المعايير السائدة في معظم المنظمات. يتطلب تحقيق تقدم حقيقي اتباع نهج متعدد التخصصات، يشمل القادة في الإدارة العليا وفي جميع أنحاء الشركة، الخبراء في مجالات تتراوح بين القانونية وأخطار تكنولوجيا المعلومات والأمن والتحليلات، والمديرين الذين يمكنهم ضمان اليقظة في الخطوط الأمامية.

يسعى هذا الموضوع إلى المساعدة بتوضيح مجموعة من الأخطار التي يسهل التغاضي عنها أولاً، ثم عرض الأطر التي من شأنها أن تساعد القادة في تحديد الأخطار الكبرى التي قد يواجهونها، ثم تنفيذ نطق الضوابط الدقيقة المطلوبة لتفاديها. كما يقدم لمحة مبكرة عن بعض الجهود الواقعية الجارية حالياً لمعالجة أخطار الذكاء الاصطناعي بتطبيق هذه الأساليب.

قبل المتابعة، لا بد من التأكيد على أن التركيز هنا ينصب على العواقب من الدرجة الأولى، التي تنشأ مباشرة من تطوير حلول الذكاء الاصطناعي، أو من سوء تطبيقها غير المقصود أو المتعمد، أو من سوء التعامل مع مدخلات البيانات التي تغذيها.

هناك عواقب مهمة أخرى، من بينها احتمال فقدان الوظائف على نطاق واسع في بعض الصناعات، بسبب أتمتة مكان العمل القائم على الذكاء الاصطناعي. وهناك أيضاً تأثيرات من الدرجة الثانية، مثل ضمور المهارات (كالمهارات التشخيصية للعاملين في المجال الطبي)، مع تزايد أهمية أنظمة الذكاء الاصطناعي. ستستمر هذه العواقب في جذب الاهتمام مع تزايد أهميتها الملموسة.

• فهم الأخطار ومحرركاتها

عندما يحدث خطأ ما في الذكاء الاصطناعي، ويظهر السبب الجذري للمشكلة، فغالبًا ما يكون هناك قدر كبير من الهزات الرأسية. مع الاستفادة من الإدراك المتأخر، يبدو من غير المتصور أن أحدا لم يتوقع حدوث ذلك.

ولكن إذا أجري استطلاع لآراء المديرين التنفيذيين، من ذوي المناصب الجيدة حول الأخطار المحتملة للذكاء الاصطناعي، فمن غير المرجح أن تحصل على أي نوع من الإجماع. ويتعين على القادة الذين يأملون في تحويل موقفهم من الإدراك المتأخر إلى الاستبصار، أن يفهموا بشكل أفضل أنواع الأخطار التي يتحملونها، وأوجه الترابط بينها، والأسباب الكامنة وراءها.

وللمساعدة في بناء هذا الحدس المفقود، نوضح أدناه خمس نقاط ضعف يمكن أن تؤدي إلى أخطار الذكاء الاصطناعي. ترتبط المشكلات الثلاث الأولى؛ صعوبات البيانات، ومشكلات التكنولوجيا، والعقبات الأمنية، بما يمكن أن نطلق عليه عوامل تمكين الذكاء الاصطناعي.

ويرتبط الأخيران بالخوارزميات والتفاعلات بين الإنسان والآلة، التي تُعد أساسية لتشغيل الذكاء الاصطناعي نفسه. من الواضح أننا ما نزال في الأيام الأولى لفهم ما يكمن وراء الأخطار التي نخوضها، والتي سعيًا أيضًا إلى تصنيف طبيعتها ونطقها في الشكل الآتي.

الجماع	النظم	الأفراد
الأمن القومي الاستقرار الاقتصادي الاستقرار السياسي سلامة البنية التحتية	الأداء المالي الأداء غير المالي القانونية والامتثال سلامة السمعة	السلامة الجسدية الخصوصية والسمعة السلامة الرقمية القدرة المادية الإنصاف والمعاملة العادلة

يتمتع الذكاء الاصطناعي والتحليلات المتقدمة بمجموعة من الفوائد، ولكنه يمكن أن يؤدي أيضًا إلى مجموعة متنوعة من العواقب الضارة وغير المقصودة على الجميع. (Cheatham et al., 2019)

■ صعوبات البيانات

أصبح استيعاب البيانات وفرزها وربطها واستخدامها بشكل صحيح أمراً صعباً تدريجياً، مع زيادة كمية البيانات غير المنظمة التي يتم استيعابها من مصادر مثل الويب ووسائل التواصل الاجتماعي والأجهزة المحمولة وأجهزة الاستشعار وإنترنت الكيانات.

ونتيجة لذلك، من السهل الوقوع فريسة لمزلق مثل الاستخدام غير المقصود أو الكشف عن معلومات حساسة مخبأة بين البيانات مجهولة المصدر. على سبيل المثال، بينما قد يتم حذف اسم المريض من قسم واحد من السجل الطبي الذي يستخدمه نظام الذكاء الاصطناعي، فإنه يمكن أن يكون موجوداً في قسم ملاحظات الطبيب في السجل.

من المهم أن يكون القادة على دراية بهذه الاعتبارات أثناء عملهم على الالتزام بقواعد الخصوصية، مثل اللائحة العامة لحماية البيانات (GDPR) للاتحاد الأوروبي، أو قانون خصوصية المستهلك في كاليفورنيا (CCPA)، وإدارة أخطار السمعة بطريقة أخرى.

■ مشكلات التكنولوجيا

يمكن أن تؤثر مشكلات التكنولوجيا والعمليات عبر مشهد التشغيل بأكمله سلباً على أداء أنظمة الذكاء الاصطناعي. مثال؛ واجهت إحدى المؤسسات المالية الكبرى مشكلات بعد أن فشل برنامج الامتثال الخاص بها في اكتشاف مشكلات التداول، لأن خلاصات البيانات لم تعد تشمل جميع تداولات العملاء.

■ عقبات أمنية

قد تنشأ هناك مشكلات أخرى، وهي احتمال قيام المحتالين باستغلال البيانات التسويقية والصحية والمالية التي تبدو غير حساسة والتي تجمعها الشركات لدعم أنظمة الذكاء الاصطناعي. فإذا كانت الاحتياطات الأمنية غير كافية، فمن الممكن ربط هذه الخيوط معاً لإنشاء هويات مزيفة. على الرغم من أن الشركات المستهدفة (التي قد تكون فاعلة جداً في حماية معلومات التعريف الشخصية)، هي متواطئة عن غير قصد، إلا أنها لا تزال عرضة لرد فعل عنيف من جانب المستهلكين، وتداعيات تنظيمية.

■ نماذج تتصرف بشكل سيئ

يمكن لنماذج الذكاء الاصطناعي نفسها أن تخلق مشكلات عندما تقدم نتائج متحيزة (وهو ما يمكن أن يحدث، على سبيل المثال، إذا كان تمثيل السكان ناقصاً في البيانات المستخدمة لتدريب النموذج)، أو تصبح غير مستقرة، أو تسفر عن استنتاجات لا يوجد بها ملاذ عملي للمتضررين من خلال قراراتها (كرفض شخص ما الحصول على قرض دون معرفة ما يمكنه فعله لإلغاء القرار). لنتأمل، على سبيل المثال، احتمال قيام نماذج الذكاء الاصطناعي بالتمييز عن غير قصد ضد الفئات المحمية، والمجموعات الأخرى من خلال الدمج بين الرمز البريدي، وبيانات الدخل لإنشاء عروض مستهدفة. من الصعب اكتشاف الحالات التي تكون فيها نماذج الذكاء الاصطناعي كامنّة في عروض البرامج على هيئة خدمة (SaaS). عندما يقدم البائعون سمات ذكية جديدة؛ غالباً بدون ضجة كبيرة؛ فإنهم يقدمون أيضاً نماذج يمكن أن تتفاعل مع البيانات الموجودة في نظام المستخدم لخلق أخطار غير متوقعة، بما في ذلك إثارة نقاط الضعف الخفية التي قد يستغلها المتسللون.

والمغزى من ذلك هو أن القادة الذين يعتقدون أنهم في مأمن، إذا لم تقم مؤسستهم بشراء أو بناء أنظمة الذكاء الاصطناعي، أو أنها تقوم فقط بتجريب نشرها، قد يكونون مخطئين.

■ قضايا التفاعل

تعد الواجهة بين الأشخاص والآلات مجالاً رئيساً آخر للخطر. ومن بين أبرز هذه التحديات تلك التي تواجه؛ النقل الآلي، والتصنيع، وأنظمة البنية التحتية. تُعد احتمالات الحوادث والإصابات مؤكدة إذا لم يدرك مشغلو المعدات الثقيلة أو المركبات أو الآلات الأخرى متى يجب تجاوز الأنظمة، أو كانوا بطيئين في تجاوزها، لأن انتباه المشغل يكون في مكان آخر؛ وهو احتمال واضح في تطبيقات كالسيارات ذاتية القيادة. وعلى العكس من ذلك، يمكن أن يكون الحكم البشري خاطئاً أيضاً في تجاوز نتائج النظام. خلف الكواليس، وفي مؤسسة تحليل البيانات، يمكن لأخطاء البرمجة النصية، وهفوات في إدارة البيانات، وسوء التقدير في بيانات التدريب النموذجي أن تؤدي بسهولة إلى الإضرار بالعدالة، والخصوصية، والأمن، والانسجام.

يمكن أيضاً لموظفي الخطوط الأمامية المساهمة عن غير قصد، كما هو الحال عندما يقوم فريق المبيعات الأكثر مهارة في البيع لفئات سكانية معينة بتدريب أداة مبيعات تعتمد على الذكاء الاصطناعي عن غير قصد لاستبعاد شرائح معينة من العملاء. وهذه مجرد عواقب غير مقصودة. وبدون ضمانات صارمة، قد يتمكن الموظفون الساخطون أو الأعداء الخارجيون، من إفساد الخوارزميات أو استخدام تطبيقات الذكاء الاصطناعي بطرق غير مشروعة.

■ إدارة أخطار الذكاء الاصطناعي: ثلاثة مبادئ أساسية

بالإضافة إلى تقديم لمحة عن التحديات المقبلة، فإن الأمثلة والتصنيفات المذكورة أعلاه مفيدة لتحديد الأخطار وترتيب أولوياتها وأسبابها الجذرية. إذا فُهمت الأماكن التي قد تكمن فيها الأخطار، لأنها غير مفهومة، أو ببساطة مجهولة الهوية، فهناك فرصة أفضل للإمساك بها قبل أن تتفاقم.

ولكن تبقى الحاجة إلى جهد مركز على مستوى المؤسسة للانتقال من فهرسة الأخطار إلى استئصالها. وتساعد تجارب اثنين من البنوك الرائدة في تفسير الوضع والاتساع والدقة الشديدة المطلوبة.

الأول، وهو لاعب أوروبي، يعمل على تطبيق التحليلات المتقدمة وقدرات الذكاء الاصطناعي لتحسين مراكز الاتصال، واتخاذ قرارات الرهن العقاري، وإدارة العلاقات، ومبادرات إدارة الخزنة، والثانية هي شركة عالمية رائدة تسعى إلى تطبيق نموذج التعلم الآلي على قراراتها المتعلقة بائتمان العملاء.

وكانت هذه البنوك، كغيرها من البنوك الأخرى في قطاع الخدمات المالية، تطبق شكلاً من أشكال التحليلات المتقدمة لعدة سنوات، ويرجع تاريخ استخدامها المبكر في الكشف عن الاحتيال في بطاقات الائتمان، وتداول الأسهم. كما أنها تخضع لدرجة عالية من الرقابة التنظيمية، وبالتالي فهي تطبق منذ فترة طويلة مجموعة واسعة من البروتوكولات، والضوابط، وتجعلها شفافة للتخفيف من الأخطار ذات الصلة؛ بما في ذلك أخطار الأمن السيبراني، حيث تكون في كثير من الأحيان في الخطوط الأمامية، نظراً لجذبها الواضح للمهاجمين.

ومع ذلك، فإن قصص هذه البنوك لا توضح سوى مجموعة فرعية من الضوابط الخاصة بالأخطار التي ينبغي للمؤسسات أن تأخذها في الاعتبار. يعرض (الشكل الآتي) أكثر قائمة اكتمالاً لعناصر التحكم المحتملة، والتي تغطي عملية التحليل بأكملها، بدءاً من التخطيط، ومروراً بالتطوير، وحتى الاستخدام والمراقبة لاحقاً.

عينة من الأخطار في كل مرحلة	ضوابط العينة	
التصور حالات الاستخدام غير الأخلاقية المحتملة، حلقة تغذية راجعة غير كافية للتعلم	← مواثيق حالة الاستخدام ومبادئ تطوير البيانات والتحليلات الأساسية (مع تصنيف واضح للأخطار)، المراقبة والاستجابة في الوقت الحقيقي	
إدارة البيانات بيانات غير كاملة أو غير دقيقة، البيانات "المحمية" غير المضمونة، عدم الامتثال التنظيمي الآخر	← مقاييس جودة البيانات وتدابير الضمان حماية الخصوصية	
تطوير نموذج بيانات غير تمثيلية نتائج النموذج المتحيزة أو التمييزية. عدم استقرار النموذج أو تدهور الأداء.	← متطلبات الشفافية وقابلية التفسير مراجعة العدالة تحليل الأداء في الوقت الحقيقي اختبار النموذج والتحقق من صحته	
تنفيذ النموذج أخطاء التنفيذ سوء تصميم التكنولوجيا والبيئة عدم كفاية التدريب وبناء المهارات	← التنفيذ واختبار المستخدم اختبار المهارات والمراقبة المنهجية لنتائج التدريب	
استخدام النموذج واتخاذ القرار خلل في التكنولوجيا والبيئة بطء الكشف عن/الاستجابة لمشكلات الأداء تهديدات الأمن السيبراني ال فشل في واجهة الإنسان والآلة	مراقبة الأداء (خاصة بالنسبة لتدفقات البيانات) إدارة الوصول والحماية السيبرانية الأخرى التقاط وتحليل الأخطاء والأخطاء الوشيكة والتجاوزات	

من الممكن أن تظهر أخطار الذكاء الاصطناعي في أي مرحلة من مراحل التطوير، لكن الضوابط يمكن أن تساعد في التخفيف من هذه الأخطار، (Cheatham et al., 2019)

■ الوضوح

أستخدم نهج منظم لتحديد أكثر الأخطار أهمية، بدأ المدير التنفيذي للعمليات في البنك الأوروبي بجمع قادة من الأعمال وتكنولوجيا المعلومات والأمن وإدارة الأخطار، لتقييم الأخطار الكبرى وتحديد أولوياتها. تضمنت المدخلات في هذا التمرين نظرة واضحة على الأخطار الحالية التي تواجهها الشركة، وكيف يمكن أن تتفاقم بسبب جهود التحليلات القائمة على الذكاء الاصطناعي قيد النظر، والأخطار الجديدة التي يمكن أن تخلقها عوامل تمكين الذكاء الاصطناعي، أو الذكاء الاصطناعي نفسه. وكان بعضها واضحاً، ولكن البعض الآخر أقل من ذلك.

أحد الكيانات التي اقتربت بشكل غير متوقع من أعلى القائمة كان تقديم توصيات منتجات سيئة أو متحيزة للمستهلكين. يمكن أن تؤدي مثل هذه التوصيات المعيبة إلى قدر كبير من الضرر، بما في ذلك خسائر المستهلكين، ورد الفعل العنيف والغرامات التنظيمية. إن ما حققه قادة البنك من هذه العملية المنظمة لتحديد الأخطار؛ هو الوضوح بشأن السيناريوهات الأكثر إثارة للقلق، وهو ما سمح لهم بتحديد أولويات الأخطار المشمولة، والتعرف على الضوابط التي كانت مفقودة، وتنظيم الوقت والموارد، وفقاً لذلك.

من الطبيعي أن تختلف هذه السيناريوهات والأخطار ذات الأولوية حسب الصناعة والشركة. قد تعطي الشركة المصنعة للأغذية الأولوية لسيناريوهات المنتجات الملوثة. قد يكون مطور البرامج قلقاً بشكل خاص بشأن الكشف عن كود البرنامج. قد تركز منظمة الرعاية الصحية على قضايا مثل؛ التشخيص الخاطئ للمريض أو إلحاق الضرر للمرضى عن غير قصد. يُعد الحصول على مجموعة متنوعة من المديرين الذين يركزون على تحديد السيناريوهات ذات الإشكالية وتصنيفها، طريقة جيدة لتحفيز الطاقة الإبداعية وتقليل خطر إغفال المتخصصين الضيقين أو التفكير ضيق الأفق لنقاط الضعف الرئيسة.

لا ينبغي للمؤسسات أن تبدأ من الصفر بهذه الجهود: على مدى السنوات القليلة الماضية، أصبح تحديد الأخطار فناً متطوراً، ويمكن نشره مباشرة في سياق الذكاء الاصطناعي.

■ السعة

وضع ضوابط قوية على مستوى المؤسسة، إن شحذ التفكير حول أخطار إيقاف العرض هو مجرد البداية. ومن الأمور الحاسمة أيضاً تطبيق الضوابط على مستوى الشركة، لتوجيه تطوير واستخدام أنظمة الذكاء الاصطناعي، وضمان الرقابة المناسبة، ووضع سياسات وإجراءات قوية، وتدريب العمال ووضع خطط للطوارئ.

وبدون بذل جهود واسعة النطاق، فإن احتمالات فشل عوامل الخطر مثل تلك التي تم وصفها سابقاً قد تتلاشى. وانطلاقاً من قلقه إزاء الأخطار المحتملة الناجمة عن توصيات المنتجات الرديئة أو المتحيزة، بدأ البنك الأوروبي في تبني مجموعة قوية من مبادئ العمل التي تهدف إلى تفصيل؛ كيف وأين يمكن استخدام الآلات لاتخاذ القرارات التي تؤثر على القدرة المالية للعميل. حدد المديرون المواقف التي يحتاج فيها الإنسان (كمدير العلاقات أو مسؤول القروض) إلى أن يكون «في الحلقة» قبل تسليم التوصية إلى العميل.

سيوفر هؤلاء العمال شبكة أمان لتحديد ما إذا كان العميل يعاني من ظروف خاصة، مثل وفاة أحد أفراد الأسرة أو صعوبات مالية، قد تجعل التوصية في غير وقتها أو غير مناسبة. كما أجرت لجنة الإشراف في البنك تحليلاً للنفجوات، فحددت المجالات إطاراً لإدارة الأخطار الحالية في البنك، والتي تحتاج إلى تعميق، أو إعادة تعريف، أو توسيع.

وتضمن الحوكمة الشاملة والمتسقة في البنك الآن التعريف المناسب للسياسات والإجراءات، وضوابط محددة لنماذج الذكاء الاصطناعي، والمبادئ الأساسية (المدعومة

بالأدوات) لتوجيه تطوير النماذج، والفصل بين الواجبات، والرقابة الكافية. تضمن أدوات تطوير النماذج قيام علماء البيانات بتسجيل؛ رمز النموذج، وبيانات التدريب، والمعلومات المختارة باستمرار طوال دورة حياة التطوير. كما تم اعتماد المكتبات القياسية لقابلية الشرح، وإعداد تقارير أداء النماذج، ومراقبة البيانات والنماذج في الإنتاج.

يوفر إطار الحوكمة هذا قيمة لا تقدر بثمن لجهود التطوير الداخلية، ولتقييم ومراقبة أدوات الذكاء الاصطناعي التابعة لجهات خارجية، مثل نموذج الاحتيال SaaS الذي اعتمده البنك. بالإضافة إلى ذلك، تتطلب سياسات البنوك الآن من جميع أصحاب المصلحة، بما في ذلك الرعاة من مديري الأعمال، إجراء تخطيط السيناريو، وإنشاء خطة احتياطية في حالة انحراف أداء نموذج الذكاء الاصطناعي، أو تحول مدخلات البيانات بشكل غير متوقع، أو حدوث تغييرات مفاجئة، مثل الكوارث الطبيعية، في بيئة خارجية.

يتم تضمين هذه الخطط الاحتياطية في عملية مراجعة الأخطار المنتظمة للبنك، مما يمنح لجنة الأخطار التابعة لمجلس الإدارة رؤية واضحة للخطوات التي يتم اتخاذها لتخفيف من الأخطار المرتبطة بالتحليلات، والمتعلقة بالذكاء الاصطناعي. كما يحتل تدريب العمال وتوعيتهم مكانة بارزة في جهود البنك لتخفيف الأخطار. يتلقى جميع الموظفين المتأثرين اتصالات شاملة حول مكان استخدام الذكاء الاصطناعي؛ ما هي الخطوات التي يتخذها البنك لضمان اتخاذ قرارات عادلة ودقيقة ولحماية بيانات العملاء؛ وكيفية عمل إطار حوكمة البنك، والتكنولوجيا الآلية، وأدوات التطوير معًا.

بالإضافة إلى ذلك، يتلقى رعاة الأعمال وفرق الأخطار وموظفو التحليلات تدريباً مستهدفاً حول دورهم في تحديد الأخطار وتقليلها. إذ يتعلم رعاة الأعمال طلب تفسيرات حول سلوك النموذج، والتي يستخدمونها لتقديم تعليقات حول افتراضات الأعمال وراء النموذج.

وفي الوقت نفسه، تدرب فريق الأخطار على كيفية تحديد وتخفيف المشكلات القانونية، والامتثال التنظيمي بشكل أفضل، مثل التمييز المحتمل ضد المجموعات المحمية أو الامتثال للقانون العام لحماية البيانات. تعد مراقبة التحليلات المعتمدة على الذكاء الاصطناعي جهداً مستمراً، وليست نشاطاً منفرداً. على هذا النحو، تقوم مجموعات الرقابة التابعة للبنك، بما في ذلك لجان الأخطار التابعة لمجلس الإدارة، بمراجعة البرنامج بانتظام، للإبقاء على الاطلاع الشامل على الأخطار الجديدة التي قد تنشأ نتيجة للتغييرات التنظيمية، والتحولات الصناعية، والتفسيرات القانونية (مثل السوابق القضائية الناشئة في القانون العام لحماية البيانات)، وتوقعات المستهلكين المتطورة، والتكنولوجيا سريعة التغير.

■ الفروق الدقيقة: تعزيز ضوابط محددة اعتماداً على طبيعة الأخطار

على الرغم من أهمية الضوابط على مستوى المؤسسة، إلا أنها نادراً ما تكون كافية لمواجهة كل الأخطار المحتملة.

غالباً ما تكون هناك حاجة إلى مستويات أخرى من الدقة والفروق الدقيقة، وستعتمد الضوابط المطلوبة على عوامل مثل: مدى تعقيد الخوارزميات، ومتطلبات البيانات الخاصة بها، وطبيعة التفاعل بين الإنسان والآلة (أو من آلة إلى آلة)، واحتمالية حدوث ذلك، وقابلية الاستغلال من قبل الجهات السيئة، ومدى دمج الذكاء الاصطناعي في العمليات التجارية.

الضوابط المفاهيمية، بدءاً من ميثاق حالة الاستخدام، تكون ضرورية في بعض الأحيان. وكذلك الأمر بالنسبة لضوابط البيانات والتحليلات المحددة، بما في ذلك متطلبات الشفافية، وضوابط التغذية الراجعة، والمراقبة مثل تحليل الأداء للكشف عن التدهور أو التحيز.

يلقي المثال الثاني ضوءاً قيماً على تطبيق الضوابط الدقيقة. أرادت هذه المؤسسة رؤية كيفية اتخاذ نموذج التعلم الآلي للقرارات المتعلقة بعملية معينة تواجه العملاء.

وبعد النظر بعناية في متطلبات الشفافية، قررت المؤسسة التخفيف من الأخطار عن طريق الحد من أنواع خوارزميات التعلم الآلي التي تستخدمها. إن عدم السماح ببعض النماذج النمذجية التي كانت مفرطة في التعقيد والغموض، مكن المؤسسة من تحقيق التوازن الذي كانت تستريح له.

ومع أنها فقدت بعض القدرة التنبؤية، الأمر الذي كان له تكاليف اقتصادية، إلا أن شفافية النماذج المستخدمة أعطت الموظفين ثقة أكبر في القرارات التي اتخذوها. كما سهّلت النماذج الأبسط فحص البيانات والنماذج نفسها بحثاً عن أي تحيزات قد تنشأ عن سلوك المستخدم أو التغيرات في متغيرات البيانات أو تصنيفاتها.

وكما يوحي هذا المثال، ستحتاج المؤسسات إلى مزيج من الضوابط الخاصة بالأخطار، وأفضل طريقة لتطبيقها هي إنشاء بروتوكولات تضمن وجودها ومتابعتها طوال عملية تطوير الذكاء الاصطناعي. وقد نفذت المؤسسات المذكورة تلك البروتوكولات، فضلاً عن الضوابط على مستوى المؤسسة، جزئياً على الأقل، من خلال البنية التحتية القائمة للأخطار.

ولا يزال بإمكان الشركات التي تفتقر إلى منظمة مركزية للأخطار أن تستخدم تقنيات إدارة أخطار الذكاء الاصطناعي هذه في العمل باستخدام عمليات قوية لإدارة الأخطار، (Cheatham et al., 2019).

دور الذكاء الاصطناعي في التنمية المستدامة

لقد أثارت القضايا والمناقشات والبرامج البيئية مؤخرًا الوعي العام، مما أثار الاهتمام بالتقنيات الجديدة كالذكاء الاصطناعي. وبينما يشهد الصراع مع التحديات البيئية في القرن الحادي والعشرين، برز الذكاء الاصطناعي مجالاً لدراسة حاسمة ومتميزة لحل الكثير من قضايا الاستدامة. يشير الذكاء الاصطناعي إلى أن الهندسة والعلوم كانت وراء تطور الآلات الذكية. وهو فرع من فروع علوم الحاسوب، وتعتمد قدراته على خبرة التعلم التي تساعد على زيادة فرص النجاح في حل المشكلات البيئية.

وفقاً لبول (1998م)، فإن ذكاء الآلات المتطورة، الذي يظهر من خلال الذكاء الفطري للحيوانات والبشر، يمكن أن يكون للذكاء الاصطناعي والمعلومات العلمية والتقنية يدًا تسمح للأجهزة بأن تكون ذكية مثل البشر. وقد وجد الباحثون أيضاً أن أنظمة الذكاء الاصطناعي يمكنها التعلم من التجربة لإنشاء خدمات اصطناعية، وتكييف المدخلات مع القضايا البيئية المتغيرة.

لقد دفع الذكاء الاصطناعي حدود الفكر البشري في العصر الحديث، وخلق واقعاً جديداً تتواصل فيه الآلات الذكية ذات العقول الاصطناعية مع العقول البشرية وبينما نواجه تحديات بيئية جديدة، أصبح الذكاء الاصطناعي أداة أساسية لتطوير حلول مستدامة من شأنها أن تساعدنا في الحفاظ على كوكبنا للأجيال القادمة.

إن إدارة الاستدامة البيئية مهمة معقدة ومليئة بالتحديات. ومع ذلك، مع تكامل الذكاء الاصطناعي، يمكن حل العديد من هذه المشكلات بكفاءة بالاستفادة من الموارد البشرية. إن الاقتصاد والبيئة والمجتمع مترابطون عندما يتعلق الأمر بالاستدامة. يتم تعريف الاستدامة أو التنمية المستدامة في ورقة الأمم المتحدة «تقاسم مستقبلنا»، والمعروفة أيضاً باسم تقرير برونتلاند **Brundtland Report**، بأنها: «برنامج يلبي

احتياجات الجيل الحالي دون المساس بقدرة الأجيال القادمة على تلبية احتياجاتها الخاصة». ولضمان ألا تؤثر المصالح البشرية على صحة النظم البيئية، يمكن أيضًا تعريف الاستدامة على أنها: «استراتيجية لتزويد الأجيال القادمة بالسلع والخدمات التي ستحتاجها».

يعد الذكاء الاصطناعي أداة قوية قد تساعد في السعي لتحقيق الاستدامة البيئية. فهو يمنح القدرة على التعمق في كميات عظيمة من البيانات، وفي كشف الأنماط، وإجراء التنبؤات. يمكن أن يساعدنا الذكاء الاصطناعي في معرفة المزيد حول كيفية تأثير أفعالنا على البيئة الطبيعية، والتوصل إلى حلول طويلة المدى لحماية الأرض لأجيال قادمة. إن إدارة الاستدامة البيئية وضمان تلبية احتياجات الحاضر والمستقبل تتطلب الذكاء الاصطناعي، الذي أصبح ذا أهمية متزايدة في مواجهة المخاوف البيئية الجديدة والملحة.

مع تعرض الأرض لخطر تأثيرات الاحتباس الحراري وتغير المناخ، يُعد تطوير منتجات صديقة للبيئة وطويلة الأمد أمرًا بالغ الأهمية. ذلك أن تغير المناخ أحد أكثر القضايا البيئية تعقيدًا، وتوفر التطورات الحديثة في الذكاء الاصطناعي حلولاً مبتكرة لمعالجتها. ومع الحاجة الملحة لمعالجة التدهور البيئي، أصبح الذكاء الاصطناعي حاسماً في إيجاد حلول مستدامة.

يمكن تقسيم الذكاء الاصطناعي والاستدامة البيئية إلى أربعة مجالات أساسية: الزراعة المستدامة، وحماية الموارد البيئية، وإدارة النفايات والتلوث، ومكافحة التلوث وإزالته. وبالتالي، كان التطبيق المستدام للذكاء الاصطناعي أمرًا حيويًا لتطوير وتنفيذ الذكاء الاصطناعي على مدار الخمسين عامًا الماضية. تشمل أبحاث الذكاء الاصطناعي من أجل الاستدامة البيئية مجموعة متنوعة من التخصصات. ولا بد من معالجة أغلب المشكلات البيئية الإقليمية والعالمية، واستخدام الذكاء الاصطناعي في قطاعات الطاقة والنقل، والتنوع البيولوجي والمياه. إلا أن هذه المجالات تتطور باستمرار، وتتغلغل في جميع جوانب المجتمع.

في بعض البلدان المتقدمة، بدأ فعلاً التطبيق العملي للذكاء الاصطناعي في التنوع البيولوجي والنقل. مثلاً؛ يتم جمع النفايات الإلكترونية باستخدام استراتيجية توجيه متطورة لحماية المحيط من التلوث، من قبل شاحنات القمامة الأوتوماتيكية التي تعمل بالذكاء الاصطناعي، وزيادة التنوع البيولوجي من خلال حماية الأنواع.

ومع ذلك، فإن الأبحاث الحالية حول تطبيق الذكاء الاصطناعي في قطاعي النقل والتنوع البيولوجي تحتاج إلى تعزيز. ومن المهم ملاحظة أن هناك نقصاً في الدراسات التي تبحث في كيفية استخدام الذكاء الاصطناعي لتحسين الاستدامة البيئية في مجالات تشمل المياه والطاقة والنقل والتنوع البيولوجي.

• تطبيقات الذكاء الاصطناعي في التنوع البيولوجي

لنمذجة خدمات النظام البيئي، تعد النماذج القائمة على القواعد مثل **ARIES**، واحدة من أكثر الأنظمة شهرة وانتشاراً. يتضمن البرنامج نماذج أخرى للتعليم الآلي تساعد الباحثين بشكل خاص في فهم العلاقات المختلفة من خلال برنامج (التحلي). بالإضافة إلى ذلك، تظهر العديد من أمثلة الذكاء الاصطناعي كيفية استخدام الذكاء الاصطناعي لتعزيز مراقبة التنوع البيولوجي والحفاظ عليه.

من المهم التأكيد على أهمية منع الاستخدام المفرط للموارد، والذي قد يسبب مشكلات بيئية، كما أن فهم الوصول إلى المعلومات المتعلقة بالذكاء الاصطناعي يعتمد على النظام البيئي وتنوعه البيولوجي، وقد طور أساليب فاعلة تعرض تقديرات للخدمات المقدمة عن طريق الأرض.

على غرار استخدام التدريب الآلي (**ML**) (المعروف أيضاً باسم المعالجة الطبيعية للغة (**NLP**))، يمكن لمعظم الأبحاث المتعلقة بالتنوع البيولوجي التي تستخدم الذكاء الاصطناعي التنبؤ بخدمات النظام البيئي.

الذكاء الاصطناعي هو طريقة جديدة لمعالجة قضايا التنوع البيولوجي عبر المكان والزمان. تركز الأبحاث في مجال الذكاء الاصطناعي للحفاظ على الاستدامة من خلال الخوارزميات الأصلية المتوفرة على تطبيقات معينة للذكاء الاصطناعي تستخدم خوارزميات أصلية، وهو نموذج التعلم الآلي المحبوب للتنوع البيولوجي، والشبكات العصبية الاصطناعية، وإحدى شبكات النمذجة المعروفة في النظم البيئية، والمعروفة باسم الشبكات الافتراضية.

• تطبيقات الذكاء الاصطناعي في الطاقة

يُعتقد أن الذكاء الاصطناعي قد ساعد في تقليل استهلاك الموارد الطبيعية وتقليل متطلبات الطاقة من الإجراءات المتعلقة بالإنسان. مجالات البحث الرئيسية هي التعرف على الأنماط، والأنظمة المتخصصة، والشبكات العصبية، والمنطق الغامض، والتي لها صلة بأبحاث الطاقة. ويشمل ذلك توزيع وإنتاج الطاقة والصيانة والعمليات، وهي مجالات البحث الرئيسية في مجال الطاقة. يتم استخدام التعلم بمساعدة الحاسوب للتنبؤ، ويمكن أيضاً استخدام خوارزميات NC في حل المشكلات المعقدة.

يتم تنفيذ معظم الخوارزميات التي يستخدمها العلماء في أنظمة المنطق الغامض التي تساعد في اتخاذ القرارات بناءً على التوقعات. علاوة على ذلك، فإن استخدام نماذج متعددة، مثل الشبكة العصبية للمنطقة، يؤدي إلى نتائج أفضل ومجموعات واسعة.

• تطبيقات الذكاء الاصطناعي في النقل

البحث في تطبيقات الذكاء الاصطناعي متاح للنقل المستدام، وقد تكون معظم المقالات المنشورة تدور حول عملية التعلم الآلي. تُعد تطبيقات أبحاث الذكاء الاصطناعي مهمة أيضاً للنقل المستدام. لقد كان التعلم من خلال الآلة هو المحور الرئيس لمعظم الأبحاث المنشورة. كما لوحظ استخدام الرؤية الحاسوبية للمساعدة في اتخاذ القرارات في؛ إدارة السلامة، وحركة المرور، والتقليل الحضري، والنقل العام.

تشمل تطبيقات الذكاء الاصطناعي في مجال النقل؛ التعلم الآلي والسلاسل الزمنية الأخرى، والنماذج الإحصائية المستخدمة لحركة المرور وإدارتها. تم استخدام أساليب الرؤية الحاسوبية في المقام الأول لوضع علامات على الطرق.

• تطبيقات الذكاء الاصطناعي في إدارة المياه

منذ عام 2015م، تم التركيز بشكل كبير على تطبيقات الذكاء الاصطناعي لتحسين إدارة المياه في مجال حمايتها. تدعم الشبكات العصبية الاصطناعية، وخاصة أنظمة التسلسل التكيفي المشوش العصبي، آلات المتجهات (SVMs) للتعلم الآلي (ML). في هذا المجال، يتم استخدام نماذج مثل أشجار القرار (الغابات العشوائية بشكل أساسي)، والانحدار المتعدد، ونماذج الإزاحة الانحدارية الذاتية (ARMS)، وخطوط الانحدار والاستدلال العصبي التكيفي، مع كون الخوارزمية الأصلية هي الحل الأمثل، أفضل طريقة معروفة حتى الآن.

بالإضافة إلى ذلك، تشمل نماذج التعلم الآلي الشائعة الشبكات الإقليمية الأكثر شيوعاً (ANNs) (بما في ذلك ANFIS) والخوارزميات الأصلية. على سبيل المثال، يمكننا استخدام خوارزميات التدريب الآلي (ML) لتحديد تدفق النهر، وتقييم معايير جودة المياه.

• كيف يمكن للذكاء الاصطناعي المساعدة في مكافحة تغير المناخ؟

تُستخدم هذه التكنولوجيا في الكوارث الطبيعية الكبرى في اليابان لرصد إزالة الغابات في منطقة الأمازون، وتصميم مناطق حضرية أكثر استدامة وذكاءً في الصين. ويمكن لتطبيقات الذكاء الاصطناعي أيضاً إنشاء مبانٍ أكثر كفاءة، وتحسين خزن الكهرباء، وتحسين وتجديد طاقة الرياح والطاقة الشمسية في الشبكة عند الحاجة.

وبطريقة بسيطة، يمكن أن يساعد ذلك الأسر على تقليل استهلاك الطاقة عندما تقوم بتشغيل الأضواء تلقائياً، أو تعطيلها عندما لا تكون قيد الاستخدام، أو حتى التحكم في متطلبات شبكة السيارات الكهربائية لتلبية التوقعات. كشفت دراسة بحثية حديثة أجرتها شركة المحاسبة الشهيرة برايس ووترهاوس كوبرز بالشراكة مع مايكروسوفت، وهي شركة متخصصة في تطوير حلول التعلم الآلي لقطاع تغير المناخ، عن بعض النتائج المثيرة للاهتمام. وجدت الدراسة أنه بحلول عام 2030م، يمكن أن يؤدي تطبيق تكنولوجيا الذكاء الاصطناعي إلى تقليل انبعاثات الغازات الدفيئة العالمية بشكل كبير، وخاصة بنسبة 4%. وهذه نتيجة جديرة بالملاحظة لأنها تسلط الضوء على إمكانيات الذكاء الاصطناعي في معالجة واحدة من أكثر المخاوف إلحاحاً في عصرنا، ألا وهي تغير المناخ.

إن كفاءة الذكاء الاصطناعي، وتحديداً قدرته على معالجة كميات هائلة من البيانات غير المنظمة مثل الصور والرسوم البيانية والخرائط، تدفع حدود النمذجة المناخية وتوفر فرصاً لا مثيل لها لفهم ديناميكيات ارتفاع مستوى سطح البحر، والقمم الجليدية بشكل أفضل. وهذا يجسد الإمكانيات العظيمة للذكاء الاصطناعي في تسهيل فهم أفضل لآثار النشاط البشري على الأرض، وإرشاده لإيجاد حلول مستدامة. يتيح لنا الذكاء الاصطناعي فهم عواقب أفعالنا على العالم بشكل أفضل، وإنشاء بدائل طويلة المدى لأزمة المناخ الحالية. يتمتع الذكاء الاصطناعي بالقدرة على المساهمة بشكل كبير في مكافحة تغير المناخ، وخفض انبعاثات الغازات الدفيئة.

توضح الشراكة بين مايكروسوفت وبراييس ووترهاوس كوبرز أهمية القطاع الخاص والباحثين الذين يعملون معاً لإيجاد الحلول. يجب أن نستمر في الاستثمار في البحث والتطوير في مجال تكنولوجيا الذكاء الاصطناعي لمعالجة القضية الملحة المتمثلة في الاستدامة البيئية، وضمان مستقبل مستدام لكوكبنا.

• مستخدمو التكنولوجيا والذكاء الاصطناعي

أدت الطبيعة المكلفة لقوة حوسبة الذكاء الاصطناعي إلى إجراء جزء كبير من الأبحاث في هذا المجال من قبل القطاع الخاص. أحد الأمثلة الساطعة هو **Climavision**، وهي شبكة رادارية حديثة فائقة الدقة تسخر قوة بيانات الأقمار الصناعية وبالونات الطقس عالية الارتفاع لملء «مئات الثغرات» في شبكات التنبؤ بالطقس الحالية.

تتيح هذه التقنية لشركات النقل والطاقة والشركات الخاصة والأفراد العسكريين إمكانية تحديث عناصر الطقس في الوقت الفعلي في كل ثانية. ومع تحرك العالم نحو الطاقة منخفضة الكربون، من المتوقع أن يزدهر سوق التطبيقات التي تعمل بالذكاء الاصطناعي والتي تتبأ بسلوك السوق، وتوازن المعاملات في الوقت الفعلي، وتعظيم كفاءة استخدام الطاقة من الشبكات إلى الأجهزة الذكية. إن الاستثمار في البحث لتحقيق إمكانات الذكاء الاصطناعي بشكل كامل في معالجة القضايا البيئية ودعم تحقيق أهداف التنمية المستدامة له أهمية قصوى. إنه استثمار في مستقبل كوكبنا ومستقبل الأجيال القادمة.

• تحديات استخدام الذكاء الاصطناعي لتحقيق الاستدامة البيئية

لقد ثبت أن الذكاء الاصطناعي يعالج القضايا البيئية بشكل فاعل، لكنه في المقابل يواجه تحديات لأنه يعتمد على البيانات التاريخية المستخدمة في التعلم الآلي. ذلك أن نماذج التعلم الآلي تجد صعوبة في مراعاة طبيعة الذكاء الاصطناعي التي لا يمكن التنبؤ بها وخصائص السلوك البشري المتغيرة باستمرار. وبالتالي، قبل أي نشاط بشري مهم، يمكن استخدام البيانات من الماضي لتعكس أعمار الناس ودوراتهم المناخية، لذلك من الصعب التنبؤ باحتمالية تغير المناخ.

كما أنه ليس من السهل التعامل مع التباين عند تضمين البيانات التاريخية في النماذج لأن معظم علماء الحاسوب يولونها اهتماماً وثيقاً. ويمكن تعميم البيانات المضافة إلى النماذج، والتي يمكن أن تكون أساساً للتنبؤات الخاطئة بالسيناريوهات المستقبلية، وهذا ما يسمى بتحول انحياز التباين **Variance bias shift**. بالإضافة إلى ذلك، تمثل زيادة أخطار الأمن السيبراني تحدياً عند تنفيذ الذكاء الاصطناعي من أجل المرونة. تُعد إدارة أخطار الأمن السيبراني أمراً ضرورياً لدمج البيانات في تطبيقات الذكاء الاصطناعي. ومع ذلك، فإن العدد المتزايد من تهديدات الأمن السيبراني بسبب المتسللين، يشكل تحدياً كبيراً عند معالجة قضايا الاستدامة البيئية.

هناك عقبة أخرى أمام استخدام الذكاء الاصطناعي من أجل الاستدامة البيئية وهي عدم وجود مؤشرات أداء مناسبة والاستجابات السلوكية البشرية غير الموثوقة لمختلف التدخلات القائمة على الذكاء الاصطناعي. ولزيادة الاستدامة البيئية، يعد تتبع وتقييم نتائج الإجراءات أمراً ضرورياً. إن طريقة القياس معقدة وغير ناجحة في كثير من الأحيان، لذا فإن الجمع بين الجوانب التحليلية والتقنية في مقياس قياسي واحد، يُعد أمراً بالغ الأهمية بالنسبة للذكاء الاصطناعي لتحقيق الاستدامة البيئية. إن برمجيات الذكاء الاصطناعي لا تقل تعقيداً عن عملية صنع القرار البشري؛ ومع ذلك، فإن نهجها يختلف عن ردود الفعل البشرية عند القرارات. ومع ذلك، فإن إدراك الاستجابات السلوكية أمر بالغ الأهمية لتجنب المشكلة الشائعة المرتبطة بالتقدم التكنولوجي، بسبب مصائد ردود الفعل. تأثير الارتداد هو مشكلة شائعة تنشأ من التكنولوجيا.

• الجانب السلبي للتكنولوجيا: يمكن أن يكون للذكاء الاصطناعي بصمة كربونية كبيرة

إن المتطلبات الحسابية للأنظمة القائمة على الذكاء الاصطناعي مرتفعة بشكل لا يصدق، وتتطلب معالجة وتحليل كميات كبيرة من البيانات. ويؤدي ذلك إلى زيادة عدد الخوادم، والطاقة اللازمة لتبريد مراكز البيانات، ويسبب ارتفاعاً كبيراً في استهلاك الطاقة. وفقاً لدراسة، فإن الطاقة اللازمة لمعالجة وتخزين البيانات لتطوير خوارزمية معقدة وحدها، يمكن أن تنتج كمية من ثاني أكسيد الكربون تعادل قيادة السيارة لمدة خمسة أضعاف عمرها، أو القيام بـ 300 رحلة ذهاباً وإياباً بين نيويورك وسان فرانسيسكو.

مراكز البيانات التي تقوم بمعالجة وتخزين المعلومات من الأنشطة عبر الإنترنت، مثل بث مقاطع الفيديو، وإرسال رسائل البريد الإلكتروني، مسؤولة عن جزء كبير من استخدام الطاقة في العالم يقدر بحوالي 1%. وتشير التوقعات إلى أنه بحلول عام 2030، يمكن أن تشكل الحوسبة ما يصل إلى 8% من إجمالي الطلب العالمي على الطاقة، مما يثير المخاوف بشأن زيادة استخدام الوقود الأحفوري.

إن حالة انبعاثات ثاني أكسيد الكربون الناتجة عن الذكاء الاصطناعي صادمة ومثيرة للقلق، وهذه دعوة للاستيقاظ. ومع ذلك، يجب علينا أن نرى الصورة الأكبر قبل التركيز أكثر من اللازم على هذه النتائج. هذه هي الدراسة الوحيدة غير الشائعة لنوع معين من الذكاء الاصطناعي. تولد أكثر مهام التدريب تمثيلاً كميات صغيرة نسبياً من الكربون. إن كون أكثر تقنيات الذكاء الاصطناعي استخداماً اليوم لا تؤدي إلى انبعاثات كربونية عظيمة، يعني أنها لن تساهم بشكل كبير في المستقبل المنظور. لا يتوفر حالياً سوى عدد قليل من الدراسات التي يمكنها مساعدة الشركات على تقييم البصمة الكربونية للذكاء الاصطناعي.

في المعركة ضد تغير المناخ، يمكن للذكاء الاصطناعي أن يكون عاملاً مساعداً ومعوفاً في آن واحد. قد يكون للحاجة إلى مواد أرضية نادرة لبناء الأجهزة تأثير سلبي، كما أن الذكاء الاصطناعي ليس حلاً سحرياً، ويمكن أن يرتكب أخطاء أثناء الحوسبة أو توليد المخرجات.

تشير إمكانية تسجيل استخدام الأفراد للطاقة مخاوف تتعلق بالخصوصية فيما يتعلق بالقدرة على تتبع البيانات التي تخص الأشخاص. يجب أن يؤثر تغير المناخ: «في المقام الأول على الأشخاص الذين يساهمون بشكل أكبر في الانبعاثات، وأن يغير حياتنا بشكل كبير». فلا يكفي الاعتماد على التكنولوجيا في المستقبل القريب لحل المشكلة، وإنقاذ ضمير الإنسان على المدى القصير والمتوسط.

• الذكاء الاصطناعي من أجل الاستدامة

ونظراً للترابط المتأصل في جميع أهداف التنمية المستدامة وطيف التنمية المستدامة والجهات الفاعلة فيها، فليس من المنطقي فصل القسم الثالث، الذي سيقدم بعد ذلك نظرة عامة أكثر تفصيلاً عن الاستخدام الحالي للذكاء الاصطناعي في سياق الجهات الفاعلة في التنمية المستدامة. من خلال تقييم آراء خبراء الذكاء الاصطناعي في مجال التطبيق الذي يتم إجراؤه لأغراض البحث، وإعطاء وجهات نظر حول مواقف معينة. وفي هذا الصدد، نحاول تحديد كيفية استخدام الذكاء الاصطناعي من قبل العديد من الشركات للمشاركة في التنمية المستدامة وتحديد ما وفي النهاية تحقيقها.

يجب توضيح الأسباب المحتملة لعدم القدرة على التنبؤ بالإضافة إلى الخصائص الأخرى، مثل الجهات الفاعلة والصناعات والمنظمات غير الحكومية والمجتمع العلمي والتكنولوجي، والجهات الفاعلة المحلية والمنتجين، للفرضية المقترحة، أي الجهات

الفاعلة السياسية الأفضل تصنيفاً لن يكون لها تأثير أكبر على التقدم نحو أهداف التنمية المستدامة فحسب.

ومع ذلك، ستكون أيضاً القنوات التي سيكون للذكاء الاصطناعي من خلالها تأثير إيجابي مثالي على التنمية المستدامة، وستكون أهداف التنمية المستدامة قادرة على الوصول إلى هذه النقطة. بالطبع، يجب أن يكون هذا هو التأثير الرئيس للهرم، الذي يتم إنشاؤه بعد ذلك، حيث يمكن للممثلين التأثير أو منح الرتب الأخرى في مواقع أفضل وأساليب تمثيل أكثر ملاءمة من الممثلين الآخرين الذين ينحدرون إلى الديناميكية.

يمكن للذكاء الاصطناعي أن يعزز التعاون الاجتماعي بين الجهات الفاعلة، وفي هذه الحالة يحافظ على مستوى واسع من التنمية المستدامة. يتمتع كل هدف من أهداف التنمية المستدامة بالقدرة على الاستفادة من استخدام الذكاء الاصطناعي. ويتجلى ذلك من خلال دراسة أجراها معهد ماكينزي العالمي، والتي وجدت ما يصل إلى 135 حالة استخدام للذكاء الاصطناعي تدعم أهداف التنمية المستدامة بحلول نوفمبر 2018م. وتوضح هذه الأمثلة فرصاً محددة أو جزئية أو افتراضية لتطبيقات الذكاء الاصطناعي.

سيكون لحالات الاستخدام المختلفة مجالات وإمكانات وقيود وملفات تعريف أخطار مختلفة؛ يتم تطبيق الذكاء الاصطناعي بطرق مختلفة. وفيما يلي بعض السيناريوهات التي يمكن أن تكون بمنزلة أمثلة لكيفية استخدام الذكاء الاصطناعي لتحقيق تنمية جيدة ومستدامة بشكل عام. هذه أمثلة قليلة، ولكنها تظهر مجموعة متنوعة من التطبيقات والمهارات والتأثيرات المحتملة. ازدهرت العديد من حالات الكتب المدرسية التي تتناول أمثلة مختلفة لتطبيقات التعلم العميق في التصوير الطبي.

نظرة عامة من شأنها أن توضح الاتجاه المذكور أعلاه. في الواقع، منذ عام 2015، نشأ نشاط اقتصادي مكثف وغني حول مجال التصوير الطبي والتشخيص. يُقال إن ما يصل إلى ثلث الشركات الناشئة في مجال الذكاء الاصطناعي في مجال الرعاية الصحية، والتي جمعت الأموال بعد يناير 2015، كانت تعمل في مجال التصوير والتشخيص.

بالإضافة إلى ذلك، يتوقع الباحثون في شركة **International Business Machines Corporation**، وهي إحدى الشركات المتعددة الجنسيات الأولى في صناعة الحوسبة، أنه بحلول عام 2026م، ستشكل الصور الطبية ما لا يقل عن 90% من جميع البيانات الطبية. إن كميتها الهائلة ستجعلها أكثر المصادر أهمية لبيانات الرعاية الصحية. عندما نفهم العلاقة بين الذكاء الاصطناعي والبيانات، خاصة بكمياتها الكبيرة، كما رأينا سابقاً مع ظهور البيانات الضخمة، فقد تم فعلاً تطبيق التعلم العميق في هذا المجال لتتبع؛ تطور الورم، وتحديد الكميات، وتصور تدفق الدم، والتفسير الطبي، وعلاج اعتلال الشبكية السكري.

في كل من الأمثلة، تتم مناقشة استخدام الذكاء الاصطناعي فيما يتعلق بالأعمال التجارية، بما في ذلك الشركات الناشئة، ولكن بشكل أكثر تحديداً، ثلاثة رواد عالميين في مجال التكنولوجيا: **IBM**، وجوجل ومجموعة سامسونج. ورد اسم آخر معروف جيداً في مجال صناعة التكنولوجيا الذي تم الاتصال به من خلال النظر في هذه السيناريوهات: **Argus**، وهو مشروع **SAP Labs** عالمي في الصين. وقام فريق هناك بتطوير حل «**Argus**»، الذي يستخدم التعلم الآلي للكشف عن علامات سرطان الرئة من خلال الأشعة المقطعية.

يتيح **Argus** بعد ذلك اختبار المزيد من المرضى في وقت أقل مع تعزيز دقة الكشف. مرة أخرى، نرى المكونات نفسها كما كان من قبل: الذكاء الاصطناعي،

والمساهمة في أهداف التنمية المستدامة المتعلقة بـ «التغذية والصحة والرفاهية»، ولكن على الأخص من قبل الجهات الفاعلة في قطاع «التجارة والصناعة»، على النحو المحدد في الأمم المتحدة. تعد شركة SAP مثالاً واقعياً لكيفية قيام الشركات بتوظيف الذكاء الاصطناعي بشكل معقول، لتحقيق التأثيرات المحتملة على التنمية المستدامة.

• الروابط الموثقة بين الذكاء الاصطناعي وأهداف التنمية المستدامة

تشير الأدلة إلى أن الذكاء الاصطناعي يمكن أن يساعد في تحقيق 134 هدفاً (79%) من جميع أهداف التنمية المستدامة، وذلك غالباً من خلال التحسينات التكنولوجية للتغلب على القيود المعروفة. ومع ذلك، فإن 59 هدفاً (35%) من جميع أهداف التنمية المستدامة المدرجة) يمكن أن تتأثر سلباً (الأمم المتحدة، 2019م) بتطوير الذكاء الاصطناعي.

• الذكاء الاصطناعي والنتائج البيئية

الفئة الأخيرة من أهداف الاستدامة تتعلق بالبيئة؛ عند فحصها، فإن ثلاثة من أهداف الاستدامة في هذه المجموعة تتعلق بقياسات المناخ، والحياة تحت الماء، والحياة على الأرض. بالنسبة للمنظمات البيئية، يمكن تحديد 25 هدفاً (93%)، حيث يمكن للذكاء الاصطناعي أن يعمل كعامل تمكين. قد تكمن فوائد الذكاء الاصطناعي في القدرة على تحليل قواعد البيانات المترابطة على نطاق واسع للعمل التنظيمي التعاوني.

عندما ننظر إلى الهدف 13 من أهداف التنمية المستدامة بشأن تغير المناخ، يمكننا أن نرى أن التقدم في الذكاء الاصطناعي يساعد على فهم تغير المناخ، ووضع نماذج لآثاره المحتملة. كما يتمتع الذكاء الاصطناعي أيضاً بالقدرة على المساعدة في تطوير أنظمة الطاقة منخفضة الكربون، والتي تُعد ضرورية في مكافحة تغير المناخ، لأنها تستخدم الموارد المتجددة وتحسين كفاءة الطاقة.

يمكن أيضاً تحسين صحة النظام البيئي باستخدام الذكاء الاصطناعي. باستخدام خوارزميات الكشف الآلي عن الانسكابات النفطية القائمة على الذكاء الاصطناعي، يمكننا تحقيق الهدف المتمثل في منع التلوث البحري، والحد منه بشكل كبير.

• مكافحة التصحر وإعادة تأهيل الأراضي والتربة المتدهورة

يمكن للشبكات العصبية الاصطناعية ومنهجيات معينة تحسين تصنيف أنواع الغطاء الأرضي من صور الأقمار الصناعية، وربما معالجة عدد كبير من الصور بسرعة. يمكن لأدوات الذكاء الاصطناعي هذه أن تساعد في اكتشاف أنماط التصحر واسعة النطاق، وتوفير معلومات مفيدة لصنع القرار والتخطيط والإشراف البيئي، ومنع المزيد من التصحر، أو عكس الاتجاهات من خلال تحديد الأسباب الجذرية.

ومع ذلك، وكما أشير سابقاً، فإن محاولات تحقيق الهدف 13 من أهداف التنمية المستدامة بشأن تغير المناخ قد تتعرض للعقلة بسبب متطلبات الطاقة العالية لتطبيقات الذكاء الاصطناعي، خاصة عند استخدام مصادر طاقة خالية من الكربون. علاوة على ذلك، من المتوقع أنه مع زيادة الوصول إلى المعلومات حول الذكاء الاصطناعي (AI) المتعلقة بالبيئة، سيكون هناك احتمال متزايد للاستغلال المفرط للموارد، على الرغم من العدد المتزايد من الأمثلة التي توضح كيفية استخدام الذكاء الاصطناعي للمساعدة في الحفاظ على التنوع البيولوجي والرصد. على الرغم من أن هذه الانتهاكات للذكاء الاصطناعي لم يتم توثيقها على نطاق واسع بعد، إلا أنه سيتم فحصها لاحقاً، حيث سيتم النظر في أوجه القصور الحالية في أبحاث الذكاء الاصطناعي.

• الثغرات البحثية في دور الذكاء الاصطناعي في التنمية المستدامة

مع تزايد استخدام تطبيقات الذكاء الاصطناعي لتعزيز أهداف التنمية المستدامة، مثل المركبات ذاتية القيادة، والشبكات الذكية القائمة على الذكاء الاصطناعي، والرعاية الصحية، يجب أن تصبح هذه الأنظمة أكثر أهمية، وأكثر مرونة وقيمة،

لتقليل أي اضطرابات. ومع تزايد استخدام الذكاء الاصطناعي في مختلف الصناعات، ستصبح الاستثمارات في أبحاث أمن الذكاء الاصطناعي أكثر أهمية لمنع سوء التعامل أو الضرر. أحد مجالات البحث المهمة في تكامل أمان الذكاء الاصطناعي، هو فهم الكوارث المحتملة، وفشل النظام الذي يمكن أن يحدث في تقنيات الذكاء الاصطناعي.

أثارت دراسة أجراها المنتدى الاقتصادي العالمي مؤخرًا مخاوف مماثلة بشأن استخدام الذكاء الاصطناعي في الصناعة المصرفية. وفي عالم يعتمد بشكل متزايد على هذه التكنولوجيا، من الضروري رفع مستوى الوعي حول أخطار فشل نظام الذكاء الاصطناعي، والاستثمار في الأبحاث التي تعالج هذه المخاوف.

ومن خلال القيام بذلك، يمكننا ضمان تطوير الذكاء الاصطناعي وتنفيذه بطريقة تعزز السلامة والكفاءة والاستدامة. مع استمرار المجتمع في التطور والتكيف مع تأثير الذكاء الاصطناعي والتقدم التكنولوجي غير المرتبط بالذكاء الاصطناعي، تتغير المتطلبات على الذكاء الاصطناعي أيضًا، مما يخلق تفاعلًا ديناميكيًا بين المجتمع والتكنولوجيا. يشكل هذا التفاعل المستمر سلسلة من الاتصالات، حيث يشكل المجتمع تطور واستخدام الذكاء الاصطناعي، وبالتالي يقوم الذكاء الاصطناعي بتشكيل المجتمع.

علاوة على ذلك، بينما تم العثور على بعض الدراسات التي تظهر أن الذكاء الاصطناعي لديه القدرة على المساهمة في العديد من أهداف وحسابات أهداف التنمية المستدامة، فإن معظم هذه الأبحاث تحتوي على بيانات محدودة. ولا يمكن إجراؤها في بيئة خاضعة للرقابة أو معملية باستخدام النماذج الأولية.

لذلك، غالبًا ما يكون من الصعب استقراء هذه المعلومات لتقييم التأثير في العالم الحقيقي. وهذا صحيح في الغالب عند دراسة تأثيرات الذكاء الاصطناعي على أبعاد زمنية وجغرافية أكبر.

نحن ندرك أنه من خلال إجراء تجارب مضبوطة لتقييم تأثير الذكاء الاصطناعي في العالم الحقيقي، من الممكن وصف مدى تكيف أدوات الذكاء الاصطناعي مع بيئة معينة .

مع تطور المجتمع وتكيفه مع تأثير التقدم التكنولوجي غير المرتبط بالذكاء الاصطناعي، تتغير المتطلبات على الذكاء الاصطناعي أيضاً، مما يخلق تفاعلاً ديناميكياً بين المجتمع والتكنولوجيا. يشكل هذا التفاعل المستمر سلسلة من الاتصالات، حيث يشكل المجتمع تطور واستخدام الذكاء الاصطناعي، وبالتالي يقوم الذكاء الاصطناعي بتشكيل المجتمع.

ومع ذلك، فإن الجانب المثير للقلق في الأبحاث الحالية، هو مقاومة المجتمع للتغيير الناجم عن الذكاء الاصطناعي. ولضمان تقييم تأثير التقنيات الجديدة من حيث الكفاءة والأخلاق والاستدامة، هناك حاجة إلى تنفيذ منهجيات جديدة قبل اعتماد الذكاء الاصطناعي على نطاق واسع، نظراً للأخطار الكبيرة المرتبطة بالأخطاء في أنظمة الذكاء الاصطناعي.

ومن الضروري إجراء البحوث لفهم أسباب هذه الأخطاء وتطوير أدوات تحليل متكاملة بين الإنسان والآلة. وهذا سيمهد الطريق للتطوير المسؤول واستخدام تكنولوجيا الذكاء الاصطناعي.

على الرغم من كشف المزيد من الأدلة المنشورة التي تشير إلى أن الذكاء الاصطناعي من شأنه المساعدة بدلاً من عرقلة تحقيق أهداف التنمية المستدامة، إلا أن هناك اعتبارين مهمين على الأقل يجب تذكرهما.

أولاً، تعمل المصالح الخاصة على تحفيز مجتمع أبحاث الذكاء الاصطناعي والصناعة على الإبلاغ عن نتائج إيجابية.

ثانياً، قد يكون البحث طويل المدى ضرورياً لاكتشاف أوجه القصور في الذكاء الاصطناعي، وكما ذكر من قبل، هناك عدد محدود من منهجيات التقييم التي يمكن الوصول إليها.

وكان الاتجاه إلى الإبلاغ عن نتائج إيجابية قويا بشكل خاص بالنسبة لأهداف التنمية المستدامة المقابلة للمجموعة البيئية. ويعد هدف الحماية الساحلية والبحرية، مثلاً ممتازاً على هذا التحيز.

توفر خوارزميات التعلم الآلي الحل الأفضل، لأن العديد من المعلومات تشارك في الاختيار الأمثل لشبكات الأمان. هناك حاجة إلى مزيد من البحث لتقييم التداعيات طويلة المدى لهذه الخوارزميات على الإنصاف والعدالة، حتى لو كان الناتج هو الأمثل من الناحية النظرية (ضمن نطاق المعلومات المقدم).

النقطة الثانية التي تم تسليط الضوء عليها أعلاه تلفت الانتباه إلى قضية بالغة الأهمية في مجال الذكاء الاصطناعي؛ الميل إلى توجيه التمويل نحو المشاريع التي تتمتع بأعلى إمكانية لتحقيق أقصى قدر من الربح.

ومن الممكن أن يؤدي هذا إلى تركيز غير متناسب على تطبيقات الذكاء الاصطناعي المدفوعة بمصالح اقتصادية وتجارية، مما يؤدي إلى قدر أكبر من عدم المساواة، كما أشار الباحثون في عام 2018م.

ومن الضروري أن نتذكر أن إمكانية تحقيق مكاسب اقتصادية لا ينبغي أن تكون العامل الوحيد المحدد في تحديد أولويات الحلول القائمة على الذكاء الاصطناعي، لتحقيق أهداف التنمية المستدامة.

وبدلاً من ذلك، ينبغي لنا أن ننظر أيضاً في التأثيرات الاجتماعية والأخلاقية والقانونية والبيئية الناشئة عن تكنولوجيا الذكاء الاصطناعي. ومن الأهمية بمكان أن

يتم تخصيص التمويل للمشاريع التي تعمل على تقييم ومعالجة هذه العوامل المهمة، بالإضافة إلى المشاريع التي تحمل وعدًا تجاريًا.

إن القيام بذلك سيساعد في ضمان تحقيق تقدم في الذكاء الاصطناعي بطريقة تعود بالنفع على الجميع، وتساعد جميع المجتمعات على الازدهار.

تتمثل إحدى طرق الاستفادة من قدرات تقنيات الذكاء الاصطناعي في تحقيق أهداف التنمية المستدامة في؛ إجراء بحث مكثف، وتطبيق خوارزميات التعلم الآلي، وفي تقنيات استخراج البيانات على الكمية المتزايدة من البيانات التي تم جمعها بمرور الوقت، بدءًا من تحليل الأحداث الجوية الماضية وحتى التنبؤ بالأحداث المستقبلية.

إن متطلب هذه الدراسة البحثية هو السماح بالعمل التحضيري والتغذية الراجعة لمجموعة واسعة من الأحداث المقبلة، إذا حدث أي شيء بشكل غير متوقع دون معرفة متى سيحدث.

تمثل الفجوة في التطبيقات الواقعية لأنظمة الذكاء الاصطناعي مصدر قلق كبير للحكومات التي تبحث عن طرق لدمج هذه التقنيات بشكل فاعل في عمليات صنع القرار. إذ تواجه المؤسسات العديد من العوائق التي يجب التغلب عليها أولاً قبل أن تتمكن من تنفيذ مثل هذا النهج بنجاح، بما في ذلك وضع تدابير الأمن السيبراني وحماية خصوصية المواطن في جميع الجوانب المتعلقة بقضايا المراقبة، بالإضافة إلى تتبع البيانات التي من المحتمل أن تتسرب أو تتعرض للخطر أثناء تشغيل المؤسسة؛ ويشمل ذلك أيضاً أتمتة عمليات محددة دون معايير أخلاقية صارمة ينص عليها القانون، والتي من شأنها استهداف أي تحيز محتمل، مهما بدا صغيراً في بعض الأحيان، باستخدام آلات الذكاء الاصطناعي.

هناك تطبيق ضيق لتقنيات الذكاء الاصطناعي في الوقت الحالي، حيث تعالج العديد من المشاريع المشكلات التي تواجهها البلدان المتقدمة فقط.

على سبيل المثال، يمكن إجراء الحصاد الآلي أو تحسين توقيته بشكل أكثر فاعلية من خلال الأنظمة التي تعمل داخل هذه البلدان لأنها تتمتع بإمكانية الوصول إلى أدوات متنوعة؛ مثل شبكات الكهرباء القوية، وقدرة الحوسبة المتطورة اللازمة لمثل هذه العمليات، حيث قد لا تحتوي المناطق الأقل نمواً دائماً على كل شيء، هناك حاجة إليها في وقت واحد، مما يجعل تكنولوجيا الذكاء الاصطناعي الخاصة بهم أقل فائدة هناك مما لو تم تصميمها من الصفر باستخدام مكونات متاحة محلياً، دون أي حاجة على الإطلاق لاتفاقيات التجارة الدولية التي غالباً ما تثقل كاهل الاقتصادات ذات الدخل المنخفض أيضاً.

على الرغم من أن التطورات الأخيرة في تكنولوجيا الذكاء الاصطناعي (AI) واعدة، فإنها تثير أيضاً مخاوف بشأن تفاقم عدم المساواة داخل الدول وفيما بينها. وقد يؤدي عدم المساواة هذا إلى عرقلة التقدم نحو تحقيق الأهداف العالمية.

لذلك، يجب على الباحثين والممولين التركيز على تصميم حلول مصممة خصيصاً لتلبية الاحتياجات المحددة للدول أو المناطق الأقل نمواً، حيث قد يكون اعتماد الذكاء الاصطناعي أكثر صعوبة.

ويجب أن تأخذ هذه الحلول في الاعتبار الديناميكيات الثقافية، والمجتمعية الفريدة لهذه المناطق، بدلاً من مجرد استيراد الحلول من الاقتصادات الأكثر تقدماً من الناحية التكنولوجية.

يجب أن يتناسب كل مشروع مع تقاليد واحتياجات المنطقة التي يتم تنفيذه فيها. ومن خلال اتباع نهج محلي، يُمكن ضمان استخدام تكنولوجيا الذكاء الاصطناعي لتعزيز المساواة والمساهمة في تحسين جميع المجتمعات، (Chaudhary, 2023).



المراجع

Abdar, M., Pourpanah, F., Hussain, S., Rezazadegan, D., Liu, L., Ghavamzadeh, M., Fieguth, P., Cao, X., Khosravi, A., Acharya, U.R., 2021. A Review of Uncertainty Quantification in Deep Learning: Techniques, Applications and Challenges. Information Fusion.

Abdul-Wahab, S.A., Al-Alawi, S.M., 2002. Assessment and prediction of tropospheric ozone concentration levels using artificial neural networks. Environ. Model. Software 17, 219–228.

Adeli, H., Panakkat, A., 2009. A probabilistic neural network for earthquake magnitude prediction. Neural Network. 22, 1018–1024.

Agana, N., Homaifar, A., 2018. EMD-based predictive deep belief network for time series prediction: an application to drought forecasting. Hydrology 5, 18.

Agrawal, P.; Sinha, A.; Kumar, S.; Agarwal, A.; Banerjee, A.; Villuri, V.G.K.; Annavarapu, C.S.R.; Dwivedi, R.; Dera, V.V.R.; Sinha, J.; et al. Exploring Artificial Intelligence Techniques for Groundwater Quality Assessment. Water 2021, 13, 1172. <https://doi.org/10.3390/w13091172>

Aleman, S., Beltran, J., Perez, A., Ganzfried, S., 2019. Predicting hurricane trajectories using a recurrent neural network. In: Proceedings of the AAAI Conference on Artificial Intelligence, pp. 468–475.

Ali, M., Jagadeesh, P.V., Jain, S., 2007. Effects of eddies on Bay of Bengal cyclone intensity. Eos, Transactions American Geophysical Union 88, 93–95.

Amani, M., Ghorbanian, A., Ahmadi, S.A., Kakooei, M., Moghimi, A., Mirmazloumi, S.M., Moghaddam, S.H.A., Mahdavi, S., Ghahremanloo, M., Parsian, S., 2020. Google earth engine cloud computing platform for remote sensing big data applications: a comprehensive review. IEEE J. Sel. Top. Appl. Earth Obs. Rem. Sens.



Anctil, F., Tape, D.G., 2004. An exploration of artificial neural network rainfall-runoff forecasting combined with wavelet decomposition. *J. Environ. Eng. Sci.* 3, S121–S128.

Ariew, R., 1976. OCKHAM'S RAZOR: A HISTORICAL AND

Ashley, W.S., Strader, S., Dziubla, D.C., Haberlie, A., 2015. Driving blind: weatherrelated vision hazards and fatal motor vehicle crashes. *Bull. Am. Meteorol. Soc.* 96, 755–778.

Badrinarayanan, V., Kendall, A., Cipolla, R., 2017. Segnet: a deep convolutional encoderdecoder architecture for image segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.* 39, 2481–2495.

Bao, S., Zhang, R., Wang, H., Yan, H., Yu, Y., Chen, J., 2019. Salinity profile estimation in the Pacific Ocean from satellite surface salinity observations. *J. Atmos. Ocean. Technol.* 36, 53–68.

Barzegar, R., Moghaddam, A.A., Deo, R., Fijani, E., Tziritis, E., 2018. Mapping groundwater contamination risk of multiple aquifers using multi-model ensemble of machine learning algorithms. *Sci. Total Environ.* 621, 697–712.

Baumann, Peter et al., (2015), Big Data Analytics for Earth Sciences: the EarthServer approach *International Journal of Digital Earth*, <http://dx.doi.org/10.1080/17538947.2014.1003106>.

Baumhoer, C.A., Dietz, A.J., Kneisel, C., Kuenzer, C., 2019. Automated extraction of antarctic glacier and ice shelf fronts from sentinel-1 imagery using deep learning. *Rem. Sens.* 11, 2529.

Belayneh, A., Adamowski, J., 2012. Standard precipitation index drought forecasting using neural networks, wavelet neural networks, and support vector regression. *Applied computational intelligence and soft computing* 6, 2012.

Belayneh, A., Adamowski, J., Khalil, B., Quilty, J., 2016. Coupling machine learning methods with wavelet transforms and the bootstrap and boosting ensemble approaches for drought prediction. *Atmos. Res.* 172, 37–47.



Benet, Damià, & Fidel Costa, Christina Widiwijayanti, John Pallister, Gabriela Pedreros, Patrick Allard, Hanik Humaida, Yosuke Aoki, (2023), VolcashDB: Volcanic ash particle image and classification database, DOI: <https://doi.org/10.31223/X53659>.

Beyreuther, M., Carniel, R., Wassermann, J., 2008. Continuous hidden Markov models: application to automatic earthquake detection and classification at Las Cañadas caldera, Tenerife. *J. Volcanol. Geoth. Res.* 176, 513–518.

Bhattacharya, B., Solomatine, D.P., 2005. Neural networks and M5 model trees in modelling water level–discharge relationship. *Neurocomputing* 63, 381–396.

Bhattacharya, B.; Solomatine, D.P. (March 2006). “Machine learning in soil classification”. *Neural Networks*. 19 (2): 186–195. doi:10.1016/j.neunet.2006.01.005. ISSN 0893-6080. PMID 16530382. S2CID 14421859.

Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N., Lloyd, S., 2017. Quantum machine learning. *Nature* 549, 195–202.

Bisong, E., 2019. Google Colaboratory, Building Machine Learning and Deep Learning Models on Google Cloud Platform. Springer, pp. 59–64.

Biwer, C.M., Capano, C.D., De, S., Cabero, M., Brown, D.A., Nitz, A.H., Raymond, V., 2019. PyCBC Inference: A Python-Based Parameter Estimation Toolkit for Compact Binary Coalescence Signals, 131. Publications of the Astronomical Society of the Pacific, 024503.

Bolloorani, A.D., Samany, N.N., Papi, R., Soleimani, M., 2022. Dust source susceptibility mapping in Tigris and Euphrates basin using remotely sensed imagery. *Catena* 209, 105795.

Bolton, T., Zanna, L., 2019. Applications of deep learning to ocean data inference and subgrid parameterization. *J. Adv. Model. Earth Syst.* 11, 376–399.

Boroughani, M., Pourhashemi, S., Hashemi, H., Salehi, M., Amirahmadi, A., Asadi, M.A. Z., Berndtsson, R., 2020. Application of remote sensing techniques and machine learning algorithms in dust source detection and dust source susceptibility mapping. *Ecol. Inf.* 56, 101059.



Bose, S., Das, K., Arima, M., 2008. Multiple stages of melting and melt-solid interaction in the lower crust: new evidence from UHT granulites of Eastern Ghats Belt, India. *J. Mineral. Petrol. Sci.* 103, 266–272.

Boukabara, S.-A., Krasnopolsky, V., Penny, S.G., Stewart, J.Q., McGovern, A., Hall, D., Ten Hoeve, J.E., Hickey, J., Allen Huang, H.-L., Williams, J.K., 2021. Outlook for exploiting artificial intelligence in the earth and environmental sciences. *Bull. Am. Meteorol. Soc.* 102, E1016–E1032.

Boyd, dana; Crawford, Kate (21 September 2011). “Six Provocations for Big Data”. *Social Science Research Network: A Decade in Internet Time: Symposium on the Dynamics of the Internet and Society*. doi:10.2139/ssrn.1926431. S2CID 148610111. Archived from the original on 28 February 2020. Retrieved 12 July 2019.

Breiman, L., 1996. Bagging predictors. *Mach. Learn.* 24, 123–140. Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32.

Breur, Tom (July 2016). “Statistical Power Analysis and the contemporary “crisis” in social sciences”. *Journal of Marketing Analytics.* 4 (2–3). London, England: Palgrave Macmillan: 61–65. doi:10.1057/s41270-016-0001-3. ISSN 2050-3318.

Brewer, C.K., Winne, J.C., Redmond, R.L., Opitz, D.W., Mangrich, M.V., 2005. Classifying and mapping wildfire severity. *Photogramm. Eng. Rem. Sens.* 71, 1311–1320.

Browning, E., Bolton, M., Owen, E., Shoji, A., Guilford, T., Freeman, R., 2018. Predicting animal behaviour using deep learning: GPS data alone accurately predict diving in seabirds. *Methods in Ecology and Evolution* 9, 681–692.

Buolamwini, J., Gebru, T., 2018. In: *Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification*, Conference on Fairness, Accountability and Transparency. PMLR, pp. 77–91.

Campos-Taberner, M., Moreno-Martínez, A., ' García-Haro, F.J., Camps-Valls, G., Robinson, N.P., Kattge, J., Running, S.W., 2018. Global estimation of biophysical variables from Google Earth Engine platform. *Rem. Sens.* 10, 1167.



Cannata, A., Cannavo, F., Moschella, S., Gresta, S., Spina, L., 2019. Exploring the link between microseism and sea ice in Antarctica by using machine learning. *Sci. Rep.* 9, 1–15.

Cao, Q.D., Choe, Y., 2020. Building damage annotation on post-hurricane satellite imagery based on convolutional neural networks. *Nat. Hazards* 103, 3357–3376.

Cappa, Francesco; Oriani, Raffaele; Peruffo, Enzo; McCarthy, Ian (2021). “Big Data for Creating and Capturing Value in the Digitalized Environment: Unpacking the Effects of Volume, Variety, and Veracity on Firm Performance”. *Journal of Product Innovation Management*. 38 (1): 49–67. doi:10.1111/jpim.12545. ISSN 0737-6782. S2CID 225209179.

Chapman, C., Charantonis, A.A., 2017. Reconstruction of subsurface velocities from satellite observations using iterative self-organizing maps. *Geosci. Rem. Sens. Lett. IEEE* 14, 617–620.

Chaudhary, Gyandeep, (2023), Environmental Sustainability: Can Artificial Intelligence be an Enabler for SDGs?, *Nature Environment and Pollution Technology*, An International Quarterly Scientific Journal, Vol. 22 pp. 1411-1420, <https://doi.org/10.46488/NEPT.2023.v22i03.027>.

Cheatham, Benjamin & Kia Javanmardian & Hamid Samandari, (2019), *Confronting the risks of artificial intelligence*, McKinsey Global Institute, McKinsey.com.

Chelani, A.B., 2010. Prediction of daily maximum ground ozone concentration using support vector machine. *Environ. Monit. Assess.* 162, 169–176.

Chelton, D.B., Schlax, M.G., Samelson, R.M., 2011. Global observations of nonlinear mesoscale eddies. *Prog. Oceanogr.* 91, 167–216.

Chen, G., Han, T.X., He, Z., Kays, R., Forrester, T., 2014. In: *Deep Convolutional Neural Network Based Species Recognition for Wild Animal Monitoring*, 2014 IEEE International Conference on Image Processing (ICIP). IEEE, pp. 858–862.



Chen, J., Jin, Q., Chao, J., 2012. Design of deep belief networks for short-term prediction of drought index using data in the Huaihe river basin. *Math. Probl Eng.* 2012.

Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K., Yuille, A.L., 2017. Deeplab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. *IEEE Trans. Pattern Anal. Mach. Intell.* 40, 834–848.

Cheng, H., Sun, L., Li, J., 2021. Neural network approach to retrieving ocean subsurface temperatures from surface parameters observed by satellites. *Water* 13, 388.

Chow, B.H.Y.; Reyes-Aldasoro, C.C. (2022), Automatic Gemstone Classification Using Computer Vision. *Minerals*, 12, 60.

Clancey, William J., 1983. The epistemology of a rule-based expert system—a framework for explanation. *Artif. Intell.* 20, 215–251.

Cranganu, Constantin and Henri Luchian and Mihaela Elena Breaban, (2015), *Artificial Intelligent Approaches in Petroleum Geosciences*, Springer International Publishing, Switzerland.

Daliakopoulos, Ioannis N. & Paulin Coulibaly, Ioannis K. Tsanis, (2005), Groundwater level forecasting using artificial neural networks, *Journal of Hydrology*, Volume 309, Issues 1–4, Pages 229-240, ISSN 0022-1694, <https://doi.org/10.1016/j.jhydrol.2004.12.001>.

Dalziel, James, (2022), How improvements in earth observation and machine learning are re-shaping earth hazard assessment, <https://www.wtwco.com/en-nz/insights/2022/11/how-improvements-in-earth-observation-and-machine-learning-are-re-shaping-earth-hazard-assessment>.

Dempsey, D., Cronin, S.J., Mei, S., Kempa-Liehr, A.W., 2020. Automatic precursor recognition and real-time forecasting of sudden explosive volcanic eruptions at Whakaari, New Zealand. *Nat. Commun.* 11, 1–8. Deo, R.C., S, ahin, M., 2015. Application of the extreme learning machine algorithm for the prediction of monthly Effective Drought Index in eastern Australia. *Atmos. Res.* 153, 512–525.



Deutsch, D., 1985. Quantum theory, the Church–Turing principle and the universal quantum computer. *Proceedings of the Royal Society of London. A. Mathematical and Physical Sciences* 400, 97–117.

Du, S., Li, T., Yang, Y., Horng, S.-J., 2018. Deep Air Quality Forecasting Using Hybrid Deep Learning Framework arXiv preprint arXiv:1812.04783.

Du, Y., Song, W., He, Q., Huang, D., Liotta, A., Su, C., 2019. Deep learning with multiscale feature fusion in remote sensing for automatic oceanic eddy detection. *Inf. Fusion* 49, 89–99.

Duerr, R., Kinkade, D., Witt, M., Yarmey, L., 2018. Data Repository Selection Decision Tree for Researchers in the Earth, Space, and Environmental Sciences. Enabling FAIR Data Community.

Durand, M., Fu, L.-L., Lettenmaier, D.P., Alsdorf, D.E., Rodriguez, E., EstebanFernandez, D., 2010. The surface water and ocean topography mission: observing terrestrial surface water and oceanic submesoscale eddies. *Proc. IEEE* 98, 766–779.

Egli, A., Schrenzel, J., Greub, G., 2020. Digital Microbiology. *Clinical Microbiology and Infection*.

ESIP, 2021. Awesome Earth Artificial Intelligence.

Eubanks, V., 2018. Automating Inequality: How High-Tech Tools Profile, Police, and Punish the Poor. s Press, St. Martin.

Fairbrass, A.J., Firman, M., Williams, C., Brostow, G.J., Titheridge, H., Jones, K.E., 2019. CityNet—deep learning tools for urban ecoacoustic assessment. *Methods in Ecology and Evolution* 10, 186–197.

Fan, J., Li, Q., Hou, J., Feng, X., Karimian, H., Lin, S., 2017. A spatiotemporal prediction framework for air pollution based on deep RNN. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 4, 15.



Fathian, F., Mehdizadeh, S., Sales, A.K., Safari, M.J.S., 2019. Hybrid models to improve the monthly river flow prediction: integrating artificial intelligence and non-linear time series models. *J. Hydrol.*

Ferran, A., Bernabe, S., Rodriguez, P.G., Plaza, A., 2013. A web-based system for classification of remote sensing data. *IEEE J. Sel. Top. Appl. Earth Obs. Rem. Sens.* 6, 1934–1948.

Ferrenberg, A., Swendsen, R., 1989. Optimized Monte Carlo data analysis. *Comput. Phys.* 3, 101–104. <https://doi.org/10.1063/1.4822862>.

Ghanbari, M., Clausi, D.A., Xu, L., Jiang, M., 2019. Contextual classification of sea-ice types using compact polarimetric SAR data. *IEEE Trans. Geosci. Rem. Sens.* 57, 7476–7491.

Gholami, V., Sahour, H., Amri, M.A.H., 2021. Soil erosion modeling using erosion pins and artificial neural networks. *Catena* 196, 104902.

Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., Meena, S.R., Tiede, D., Aryal, J., 2019. Evaluation of different machine learning methods and deep-learning convolutional neural networks for landslide detection. *Rem. Sens.* 11, 196.

Giffard-Roisin, S., Yang, M., Charpiat, G., K'egl, B., Monteleoni, C., 2018. In: *Fused Deep Learning for Hurricane Track Forecast from Reanalysis Data. Proceedings of 8th International Workshop on Climate Informatics, Boulder, Colorado, USA.*

Gil, Y., Honaker, J., Gupta, S., Ma, Y., D'Orazio, V., Garijo, D., Gadewar, S., Yang, Q., Jahanshad, N., 2019. Towards human-guided machine learning. In: *Proceedings of the 24th International Conference on Intelligent User Interfaces*, pp. 614–624.

Girshick, R., 2015. Fast r-cnn. In: *Proceedings of the IEEE International Conference on Computer Vision*, pp. 1440–1448.

Google earth engine: planetary-scale geospatial analysis for everyone. *Rem. Sens. Environ.* 202, 18–27.



Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017.

Gurney, K., (2014), An Introduction to Neural Networks. CRC press.

Hai Ha, Duong et al. (2022), Development and application of hybrid artificial intelligence models for groundwater potential mapping and assessment, Vietnam Academy of Science and Technology, Vietnam Journal of Earth Sciences, <http://www.vjs.ac.vn/index.php/jse>

Han, J., Zhang, L., 2020. Integrating Machine Learning with Physics-Based Modeling arXiv preprint arXiv:2006.02619.

Han, M., Feng, Y., Zhao, X., Sun, C., Hong, F., Liu, C., 2019. A convolutional neural network using surface data to predict subsurface temperatures in the Pacific Ocean. IEEE Access 7, 172816–172829.

He, K., Gkioxari, G., Dollár, P., Girshick, R., 2017. In: Mask R-Cnn, Computer Vision (ICCV), 2017 IEEE International Conference on. IEEE, pp. 2980–2988.

He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 770–778.

Henley, W., Hand, D.J., 1996. A k-nearest-neighbour classifier for assessing consumer credit risk. The Statistician 77–95.

Herweijer, Celine & Dominic Waughray, (2018), Harnessing Artificial Intelligence for the Earth, World Economic Forum.

Hibert, C., Mangeney, A., Grandjean, G., Baillard, C., Rivet, D., Shapiro, N.M., Satriano, C., Maggi, A., Boissier, P., Ferrazzini, V., 2014. Automated identification, location, and volume estimation of rockfalls at Piton de la Fournaise volcano.

Hilbert M, López P (April 2011). “The world’s technological capacity to store, communicate, and compute information” (PDF). Science. 332 (6025): 60–5. Bibcode:2011Sci...332...60H. doi:10.1126/science.1200970. PMID 21310967. S2CID 206531385. Archived (PDF) from the original on 19 August 2019. Retrieved 11 May 2019.



Hills, D., Downs, R.R., Duerr, R., Goldstein, J.C., Parsons, M.A., Ramapriyan, H.K., 2015. The importance of data set provenance for science. *Eos* 96.

Ho, C.-S., Jean, N., Hogan, C.A., Blackmon, L., Jeffrey, S.S., Holodniy, M., Banaei, N., Saleh, A.A., Ermon, S., Dionne, J., 2019. Rapid identification of pathogenic bacteria using Raman spectroscopy and deep learning. *Nat. Commun.* 10, 1–8.

Holt, B., Johnson, M.P., Perkovic-Martin, D., Panzer, B., 2015. Snow depth on Arctic sea ice derived from radar: in situ comparisons and time series analysis. *J. Geophys. Res.: Oceans* 120, 4260–4287.

Hong, W.-C., 2008. Rainfall forecasting by technological machine learning models. *Appl. Math. Comput.* 200, 41–57.

Hu, C., Wu, Q., Li, H., Jian, S., Li, N., Lou, Z., 2018. Deep learning with a long short-term memory networks approach for rainfall-runoff simulation. *Water* 10, 1543.

Huang, D., Du, Y., He, Q., Song, W., Liotta, A., 2017. DeepEddy: a simple deep architecture for mesoscale oceanic eddy detection in SAR images. In: 2017 IEEE 14th International Conference on Networking, Sensing and Control (ICNSC). IEEE, pp. 673–678.

Hüllermeier, E., Waegeman, W., 2021. Aleatoric and epistemic uncertainty in machine learning: an introduction to concepts and methods. *Mach. Learn.* 110, 457–506.

Hutchinson, D.K., Coxall, H.K., Lunt, D.J., Steinhorsdottir, M., de Boer, A.M., Baatsen, M., von der Heydt, A., Huber, M., Kennedy-Asser, A.T., Kunzmann, L., 2021. The Eocene–Oligocene transition: a review of marine and terrestrial proxy data, models and model–data comparisons. *Clim. Past* 17, 269–315.

Iandola, F., Moskewicz, M., Karayev, S., Girshick, R., Darrell, T., Keutzer, K., 2014. Densenet: Implementing Efficient Convnet Descriptor Pyramids arXiv preprint arXiv: 1404.1869.



Ingsrisawang, L., Ingsriswang, S., Somchit, S., Aungsuratana, P., Khantiyanan, W., 2008. Machine learning techniques for short-term rain forecasting system in the northeastern part of Thailand. In: Proceedings of World Academy of Science, Engineering and Technology. Citeseer.

International Geoscience and Remote Sensing Symposium. IEEE, pp. 1760–1763.

J. Geophys. Res.: Earth Surf. 119, 1082–1105.

Jacobs, A. (6 July 2009). “The Pathologies of Big Data”. ACMQueue. Archived from the original on 8 December 2015. Retrieved 21 April 2010.

Jain, P., Coogan, S.C., Subramanian, S.G., Crowley, M., Taylor, S., Flannigan, M.D., 2020. A review of machine learning applications in wildfire science and management. Environ. Rev. 28, 478–505.

Januschowski, T., Arpin, D., Salinas, D., Flunkert, V., Gasthaus, J., Stella, L., Vazquez, P., 2018. Now Available in Amazon Sagemaker: Deepar Algorithm for More Accurate Time Series Forecasting.

Jiang, Sheng, & Junwei Ma, ORCID, Zhiyang Liu, Haixiang Guo, (2023), Scientometric Analysis of Artificial Intelligence (AI) for Geohazard Research, MDPI journals, Sensors 2023, 23(22), 9262; <https://doi.org/10.3390/s23229262>- 18 Nov 2023

Jin, J., Segers, A., Liao, H., Heemink, A., Kranenburg, R., Lin, H.X., 2020. Source backtracking for dust storm emission inversion using an adjoint method: case study of Northeast China. Atmos. Chem. Phys. 20, 15207–15225.

Jobin, A., Ienca, M., Vayena, E., 2019. The global landscape of AI ethics guidelines. Nature Machine Intelligence 1, 389–399.

Johnsen, T. ; Gulick, V., (2019), Artificial Intelligence to Classify Minerals and Rocks with Raman Spectra and Image Analysis, American Geophysical Union, Fall Meeting 2019, abstract #P43E-3507.



Johnsirani Venkatesan, N., Nam, C., Shin, D.R., 2019. Deep learning frameworks on Apache spark: a review. IETE Tech. Rev. 36, 164–177.

Kamilaris, A., Kartakoullis, A., Prenafeta-Boldú, F.X., 2017. A review on the practice of big data analysis in agriculture. Comput. Electron. Agric. 143, 23–37.

Karasozen, " E., Karasozen, " B., 2020. Earthquake location methods. GEM-International Journal on Geomathematics 11, 1–28.

Karpatne, Anuj & Imme Ebert-Uphoff, Sai Ravela, Hassan Ali Babaie, and Vipin Kumar, (2017), Machine Learning for the Geosciences: Challenges and Opportunities, arXiv:1711.04708v1 [cs.LG] 13 Nov 2017.

Kashinath, K., Mustafa, M., Albert, A., Wu, J., Jiang, C., Esmaeilzadeh, S., Azizzadenesheli, K., Wang, R., Chattopadhyay, A., Singh, A., 2021. Physics-informed machine learning: case studies for weather and climate modelling. Philosophical Transactions of the Royal Society A 379, 20200093.

Kedron, P., Frazier, A.E., Trgovac, A.B., Nelson, T., Fotheringham, A.S., 2021. Reproducibility and replicability in geographical analysis. Geogr. Anal. 53, 135–147.

Kim, S., Kim, H., Lee, J., Yoon, S., Kahou, S.E., Kashinath, K., Prabhat, M., 2019. Deephurricane-tracker: tracking and forecasting extreme climate events. In: 2019 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, pp. 1761–1769.

Kim, Y.H., Im, J., Ha, H.K., Choi, J.-K., Ha, S., 2014. Machine learning approaches to coastal water quality monitoring using GOCI satellite data. GIScience Remote Sens. 51, 158–174.

Kingdon A., Nayembil, M.L., Richardson A.E., and Smith, A.G., 2016. A geodata warehouse: Using denormalisation techniques as a tool for delivering spatially enabled integrated geological information to geologists. Computers and Geosciences, 96, 87-97. DOI: 10.1016/j.cageo.2016.07.016.



Kitchin, Rob; McArdle, Gavin (17 February 2016). "What makes Big Data, Big Data? Exploring the ontological characteristics of 26 datasets". *Big Data & Society*. 3 (1): 205395171663113. doi:10.1177/2053951716631130.

Kloster, M., Langenkamper, D., Zurowietz, M., Beszteri, B., Nattkemper, T.W., 2020. Deep learning-based diatom taxonomy on virtual slides. *Sci. Rep.* 10, 1–13.

Klotzbach, P.J., Bowen, S.G., Pielke, R., Bell, M., 2018. Continental US hurricane landfall frequency and associated damage: observations and future risks. *Bull. Am. Meteorol. Soc.* 99, 1359–1376.

Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B.E., Bussonnier, M., Frederic, J., Kelley, K., Hamrick, J.B., Grout, J., Corlay, S., 2016. Jupyter Notebooks-A Publishing Format for Reproducible Computational Workflows, *ELPUB*, pp. 87–90.

Knoll, L., Breuer, L., Bach, M., 2019. Large scale prediction of groundwater nitrate concentrations from spatial data using machine learning. *Sci. Total Environ.* 668, 1317–1327.

Kolehmainen, M., Martikainen, H., Ruuskanen, J., 2001. Neural networks and periodic components used in air quality forecasting. *Atmos. Environ.* 35, 815–825.

Koroteev, D., Tekic, Z., 2021. Artificial intelligence in oil and gas upstream: trends, challenges, and scenarios for the future. *Energy and AI* 3, 100041.

Korup, O., Stolle, A., 2014. Landslide prediction from machine learning. *Geol. Today* 30, 26–33.

Kosov, S., Shirahama, K., Li, C., Grzegorzec, M., 2018. Environmental microorganism classification using conditional random fields and deep convolutional neural networks. *Pattern Recogn.* 77, 248–261.

Kratzert, F., Klotz, D., Brenner, C., Schulz, K., Herrnegger, M., 2018. Rainfall–runoff modelling using long short-term memory (LSTM) networks. *Hydrol. Earth Syst. Sci.* 22, 6005–6022.



Krishnan, M., 2019. Against Interpretability: a Critical Examination of the Interpretability Problem in Machine Learning. *Philosophy & Technology*, pp. 1–16.

Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. Imagenet classification with deep convolutional neural networks. *Adv. Neural Inf. Process. Syst.* 1097–1105.

Kühnlein, M., Appelhans, T., Thies, B., Nauss, T., 2014. Improving the accuracy of rainfall rates from optical satellite sensors with machine learning—a random forestsbased approach applied to MSG SEVIRI. *Rem. Sens. Environ.* 141, 129–143

Labazanova, Saida & Timur Aygumov, Timur Mustafaev, (2024), How artificial intelligence can fight environmental issues, *E3S Web of Conferences* 515, 02021 (2024), <https://doi.org/10.1051/e3sconf/20245150202>.

Lebo, T., Sahoo, S., McGuinness, D., Belhajjame, K., Cheney, J., Corsar, D., Garijo, D., Soiland-Reyes, S., Zednik, S., Zhao, J., 2013. Prov-o: the Prov Ontology.

Lee, J., Shi, Y.R., Cai, C., Ciren, P., Wang, J., Gangopadhyay, A., Zhang, Z., 2021. Machine learning based algorithms for global dust aerosol detection from satellite images: inter-comparisons and evaluation. *Rem. Sens.* 13, 456.

Lee, S., Im, J., Kim, J., Kim, M., Shin, M., Kim, H.-c., Quackenbush, L., 2016. Arctic sea ice thickness estimation from CryoSat-2 satellite data using machine learning-based lead detection. *Rem. Sens.* 8, 698.

Leigh, S., Wang, Z., Clausi, D.A., 2013. Automated ice–water classification using dual polarization SAR satellite imagery. *IEEE Trans. Geosci. Rem. Sens.* 52, 5529–5539.

Li, G., Rabe, K.S., Nielsen, J., Engqvist, M.K., 2019. Machine learning applied to predicting microorganism growth temperatures and enzyme catalytic optima. *ACS Synth. Biol.* 8, 1411–1420.

Li, H., Ota, K., Dong, M., 2018. Learning IoT in edge: deep learning for the Internet of Things with edge computing. *IEEE network* 32, 96–101.



Lin, G.F., Chen, G.R., Wu, M.C., Chou, Y.C., 2009. Effective forecasting of hourly typhoon rainfall using support vector machines. *Water Resour. Res.* 45, W08440.

Lin, J.-W., Chiou, J.-S., 2019. Active probability backpropagation neural network model for monthly prediction of probabilistic seismic hazard analysis in Taiwan. *IEEE Access* 7, 108990–109014.

Lin, X., Chang, H., Wang, K., Zhang, G., Meng, G., 2020. Machine learning for source identification of dust on the Chinese Loess Plateau. *Geophys. Res. Lett.* 47, e2020GL088950.

Liu, F., Zhou, H., Wen, B., 2021. DEDNet: offshore eddy detection and location with HF radar by deep learning. *Sensors* 21, 126.

Lohse, J., Doulgeris, A.P., Dierking, W., 2019. An optimal decision-tree design strategy and its application to sea ice classification from sar imagery. *Rem. Sens.* 11, 1574.

Mac Aodha, O., Gibb, R., Barlow, K.E., Browning, E., Firman, M., Freeman, R., Harder, B., Kinsey, L., Mead, G.R., Newson, S.E., 2018. Bat detective-deep learning tools for bat acoustic signal detection. *PLoS Comput. Biol.* 14, e1005995.

Maca, P., Pech, P., 2016. Forecasting SPEI and SPI drought indices using the integrated artificial neural networks. *Comput. Intell. Neurosci.* 14, 2016.

Maekawa, T., Ohara, K., Zhang, Y., Fukutomi, M., Matsumoto, S., Matsumura, K., Shidara, H., Yamazaki, S.J., Fujisawa, R., Ide, K., 2020. Deep learning-assisted comparative analysis of animal trajectories with DeepHL. *Nat. Commun.* 11, 1–15.

Magoulas, Roger; Lorica, Ben (February 2009). “Introduction to Big Data”. Release 2.0 (11). Sebastopol, CA: O’Reilly Media. Archived from the original on 2 November 2021. Retrieved 26 February 2021.

Mahdavi-Damghani, Babak (2019). *Data-Driven Models & Mathematical Finance: Apposition or Opposition?* (DPhil thesis). Oxford, England: University of Oxford. p. 21. SSRN 3521933.



Manucharyan, G.E., Siegelman, L., Klein, P., 2020. A Deep Learning approach to spatiotemporal SSH interpolation and estimation of deep currents in geostrophic ocean turbulence. *J. Adv. Model. Earth Syst.*, e2019MS001965

Maskey, M., Ramachandran, R., Miller, J.J., Zhang, J., Gurung, I., 2018. In: *Earth Science Deep Learning: Applications and Lessons Learned*, IGARSS 2018-2018 IEEE

Masotti, M., Falsaperla, S., Langer, H., Spampinato, S., Campanini, R., 2006. Application of support vector machine to the classification of volcanic tremor at etna, Italy. *Geophys. Res. Lett.* 33, L20304.

Mayer-Schonberger, V., Cukier, K., 2013. *Big Data: A Revolution that Will Transform How We Live, Work, and Think*. Houghton Mifflin Harcourt.

Miall, A.D. (December 1995). "The blue planet: An introduction to earth system science". *Earth-Science Reviews*. 39 (3–4): 269–271. doi:10.1016/0012-8252(95)90023-3. ISSN 0012-8252.

Mignan, A., Broccardo, M., 2020. Neural network applications in earthquake prediction (1994–2019): meta-analytic and statistical insights on their limitations. *Seismol Res. Lett.* 91, 2330–2342.

Mo, S., Zabaras, N., Shi, X., Wu, J., 2019. Deep autoregressive neural networks for highdimensional inverse problems in groundwater contaminant source identification. *Water Resour. Res.* 55, 3856–3881.

Mohajerani, Y., Wood, M., Velicogna, I., Rignot, E., 2019. Detection of glacier calving margins with convolutional neural networks: a case study. *Rem. Sens.* 11, 74.

Mohanty, S.P., Hughes, D.P., Salathé, M., 2016. Using deep learning for image-based plant disease detection. *Front. Plant Sci.* 7, 1419.

Molnar, C., Casalicchio, G., Bischl, B., 2020. *Interpretable Machine Learning—A Brief History, State-Of-The-Art and Challenges* arXiv preprint arXiv:2010.09337.



Mons, Barend, 2020. Invest 5% of research funds in ensuring data are reusable. *Nature* 578, 491-491.

Moreau, L., Freire, J., Futrelle, J., McGrath, R.E., Myers, J., Paulson, P., 2008. The Open Provenance Model: an Overview, International Provenance and Annotation Workshop. Springer, pp. 323–326.

Moschos, E., Stegner, A., Schwander, O., Gallinari, P., 2020. Classification of eddy sea surface temperature signatures under cloud coverage. *IEEE J. Sel. Top. Appl. Earth Obs. Rem. Sens.* 13, 3437–3447.

Mousavi, S.M., Beroza, G.C., 2018. Evaluating the 2016 one-year seismic hazard model for the central and eastern United States using instrumental ground-motion data. *Seismol Res. Lett.* 89, 1185–1196.

Mousavi, S.M., Ellsworth, W.L., Zhu, W., Chuang, L.Y., Beroza, G.C., 2020. Earthquake transformer—an attentive deep-learning model for simultaneous earthquake detection and phase picking. *Nat. Commun.* 11, 1–12.

Mousavi, S.M., Zhu, W., Sheng, Y., Beroza, G.C., 2019. CRED: a deep residual network of convolutional and recurrent units for earthquake signal detection. *Sci. Rep.* 9, 1–14.

Mousavi, S.Z., Kavian, A., Soleimani, K., Mousavi, S.R., Shirzadi, A., 2011. GIS-based spatial prediction of landslide susceptibility using logistic regression model. *Geomatics, Nat. Hazards Risk* 2, 33–50.

Mueller, J. P., & Massaron, L. (2021). *Machine learning for dummies*. John Wiley & Sons. Resources., National Academies Press (U.S.) National Research Council (U.S.). Commission on Geosciences, Environment, and (2001). Basic research opportunities in earth science. National Academies Press. OCLC 439353646.

Naganna, S.R., Deka, P.C., Ghorbani, M.A., Biazar, S.M., Al-Ansari, N., Yaseen, Z.M., 2019. Dew point temperature estimation: application of artificial intelligence model integrated with nature-inspired optimization algorithms. *Water* 11, 742.



Naghibi, S.A., Ahmadi, K., Daneshi, A., 2017. Application of support vector machine, random forest, and genetic algorithm optimized random forest models in groundwater potential mapping. *Water Resour. Manag.* 31, 2761–2775.

Nativi, Stefano & Paolo Mazzetti, Mattia Santoro, Fabrizio Papeschi, Max Craglia, Osamu Ochiai, (2015), Big Data Challenges in building the Global Earth Observation System of Systems, Institute of Atmospheric Pollution Research – National Research Council of Italy (CNR-IIA), Florence, Italy.

Neethirajan, S., 2020. The Role of Sensors, Big Data and Machine Learning in Modern Animal Farming. *Sensing and Bio-Sensing Research*, p. 100367.

Nefeslioglu, H.A., Gokceoglu, C., Sonmez, H., 2008. An assessment on the use of logistic regression and artificial neural networks with different sampling strategies for the preparation of landslide susceptibility maps. *Eng. Geol.* 97, 171–191.

Neylon, C., 2012. Open access must enable open use. *Nature* 492, 348–349.

Nolan, B.T., Fienen, M.N., Lorenz, D.L., 2015. A statistical learning framework for groundwater nitrate models of the Central Valley, California, USA. *J. Hydrol.* 531, 902–911.

Norouzzadeh, M.S., Nguyen, A., Kosmala, M., Swanson, A., Palmer, M.S., Packer, C., Clune, J., 2018. Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. *Proc. Natl. Acad. Sci. Unit. States Am.* 115, E5716–E5725.

Nowack, P., Braesicke, P., Haigh, J., Abraham, N.L., Pyle, J., Voulgarakis, A., 2018. Using machine learning to build temperature-based ozone parameterizations for climate sensitivity simulations. *Environ. Res. Lett.* 13, 104016.

Numpy, 2020. Case Study: First Image of a Black Hole. NWS, 2021. NWS High Water Level Terminology.



Olyaie, E., Banejad, H., Chau, K.-W., Melesse, A.M., 2015. A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems: a case study in United States. *Environ. Monit. Assess.* 187, 1–22.

Onay, Ceylan; Öztürk, Elif (2018). “A review of credit scoring research in the age of Big Data”. *Journal of Financial Regulation and Compliance*. 26 (3): 382–405. doi:10.1108/JFRC-06-2017-0054.S2CID158895306.

Ong, Veda, Lye, Sim, (2021), Artificial intelligence to detect and forecast earthquakes, Durham theses, Durham University. Available at Durham E-Theses Online: <http://etheses.dur.ac.uk/13978/>

Overpeck, J.T., Meehl, G.A., Bony, S., Easterling, D.R., 2011. Climate data challenges in the 21st century. *Science* 331, 700–702.

Park, J.-W., Korosov, A.A., Babiker, M., Won, J.-S., Hansen, M.W., Kim, H.-C., 2020. Classification of sea ice types in Sentinel-1 synthetic aperture radar images. *Cryosphere* 14, 2629–2645.

Pearl, J., 1988. Probabilistic reasoning in intelligent systems: networks of plausible inference. Morgan kaufmann.

Pedraza, A., Bueno, G., Deniz, O., Cristobal, G., Blanco, S., Borrego-Ramos, M., 2017. Automated diatom classification (Part B): a deep learning approach. *Appl. Sci.* 7, 460.

Peng, L., Niu, R., Huang, B., Wu, X., Zhao, Y., Ye, R., 2014. Landslide susceptibility mapping based on rough set theory and support vector machines: a case of the Three Gorges area, China. *Geomorphology* 204, 287–301.

Perea, R.G., Poyato, E.C., Montesinos, P., Díaz, J.A.R., 2019. Optimisation of water demand forecasting by artificial intelligence with short data sets. *Biosyst. Eng.* 177, 59–66.



Pereira Borges, H., de Aguiar, M.S. (2019). Mineral Classification Using Machine Learning and Images of Microscopic Rock Thin Section. In: Martínez-Villaseñor, L., Batyrshin, I., Marín-Hernández, A. (eds) Advances in Soft Computing. MICAI 2019. Lecture Notes in Computer Science(), vol 11835. Springer, Cham. https://doi.org/10.1007/978-3-030-33749-0_6

Qi, Z., Wang, T., Song, G., Hu, W., Li, X., Zhang, Z., 2018. Deepair learning: interpolation, prediction, and feature analysis of fine-grained air quality. IEEE Trans. Knowl. Data Eng. 30, 2285–2297.

Qiu, J., Wu, Q., Ding, G., Xu, Y., Feng, S., 2016. A survey of machine learning for big data processing. EURASIP J. Appl. Signal Process. 67, 2016.

Raissi, M., Yazdani, A., Karniadakis, G.E., 2020. Hidden fluid mechanics: learning velocity and pressure fields from flow visualizations. Science 367, 1026–1030.

Rajaei, Taher, & Hadi Ebrahimi, Vahid Nourani, (2019)), A review of the artificial intelligence methods in groundwater level modeling, Journal of Hydrology, Volume 572, Pages 336-351, ISSN 0022-1694, <https://doi.org/10.1016/j.jhydrol.2018.12.037>.

Rathore, Muhammad Mazhar Ullah & Anand Paul, Senior Member, IEEE, Awais Ahmad, Student Member, IEEE, Bo-Wei Chen, Member, IEEE, Bormin Huang, and Wen Ji, Member, (2015), IEEE, “Real-Time Big Data Analytical Architecture for Remote Sensing Application”, IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING.

Redmon, J., Farhadi, A., 2018. Yolov3: an Incremental Improvement arXiv preprint arXiv:1804.02767.

Reichman OJ, Jones MB, Schildhauer MP (February 2011). “Challenges and opportunities of open data in ecology”. Science. 331 (6018): 703–5. Bibcode:2011Sci...331..703R. doi:10.1126/science.1197962. PMID 21311007. S2CID 22686503. Archived from the original on 19 October 2020. Retrieved 12 July 2019.



Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., 2019. Deep learning and process understanding for data-driven Earth system science. *Nature* 566, 195.

Reid, C.E., Brauer, M., Johnston, F.H., Jerrett, M., Balme, J.R., Elliott, C.T., 2016. Critical review of health impacts of wildfire smoke exposure. *Environ. Health Perspect.* 124, 1334–1343.

Reinsel, David; Gantz, John; Rydning, John (13 April 2017). "Data Age 2025: The Evolution of Data to Life-Critical" (PDF). seagate.com. Framingham, MA, US: International Data Corporation. Archived (PDF) from the original on 8 December 2017. Retrieved 2 November 2017.

Rhee, J., Im, J., 2017. Meteorological drought forecasting for ungauged areas based on machine learning: using long-range climate forecast and remote sensing data. *Agric. For. Meteorol.* 237, 105–122.

Rodrigues, M., de la Riva, J., 2014. An insight into machine-learning algorithms to model human-caused wildfire occurrence. *Environ. Model. Software* 57, 192–201.

Ronneberger, O., Fischer, P., Brox, T., 2015. U-net: convolutional networks for biomedical image segmentation. In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, pp. 234–241.

Ruiz-Suarez, J., Mayora-Ibarra, O., Torres-Jimenez, J., Ruiz-Suarez, L., 1995. Short-term ozone forecasting by artificial neural networks. *Adv. Eng. Software* 23, 143–149.

Sachindra, D., Ahmed, K., Rashid, M.M., Shahid, S., Perera, B., 2018. Statistical downscaling of precipitation using machine learning techniques. *Atmos. Res.* 212, 240–258.

Sadri, S., Burn, D., 2012. Nonparametric methods for drought severity estimation at ungauged sites. *Water Resour. Res.* 48.



Safavian, S.R., Landgrebe, D., 1991. A survey of decision tree classifier methodology. IEEE transactions on systems, man, and cybernetics 21, 660–674.

Sagiroglu, Seref (2013). “Big data: A review”. 2013 International Conference on Collaboration Technologies and Systems (CTS). pp. 42–47. doi:10.1109/CTS.2013.6567202. ISBN 978-1-4673-6404-1. S2CID 5724608.

Sahoo, S., Russo, T.A., Elliott, J., Foster, I., 2017. Machine learning algorithms for modeling groundwater level changes in agricultural regions of the US. Water Resour. Res. 53, 3878–3895.

Sahota, Neil, (2023), AI in Oil and Gas Exploration: Digging into Data-Driven Efficiency, <https://www.linkedin.com/pulse/ai-oil-gas-exploration-digging-data-driven-efficiency-neil-sahota/>

Sajedi-Hosseini, F., Malekian, A., Choubin, B., Rahmati, O., Cipullo, S., Coulon, F., Pradhan, B., 2018. A novel machine learning-based approach for the risk assessment of nitrate groundwater contamination. Sci. Total Environ. 644, 954–962.

Saliu, O., Curilla, D., Lennon, M., Chung, A., 2020. In: Lessons Learned: Deep Learning for Mineral Exploration, First EAGE Conference on Machine Learning in Americas. European Association of Geoscientists & Engineers, 1-1.

Sang, Xuejia; Xue, Linfu; Ran, Xiangjin; Li, Xiaoshun; Liu, Jiwen; Liu, Zeyu (2020-02-05). “Intelligent High-Resolution Geological Mapping Based on SLIC-CNN”. ISPRS International Journal of Geo-Information. 9 (2): 99. Bibcode:2020IJGI....9...99S. doi:10.3390/ijgi9020099. ISSN 2220-9964.

Sansone, S.-A., McQuilton, P., Rocca-Serra, P., Gonzalez-Beltran, A., Izzo, M., Lister, A.L., Thurston, M., 2019. FAIRsharing as a community approach to standards, repositories and policies. Nat. Biotechnol. 37, 358–367.

Santana, O.J., Hern´andez-Sosa, D., Martz, J., Smith, R.N., 2020. Neural network training for the detection and classification of oceanic mesoscale eddies. Rem. Sens. 12, 2625.



Sayad, Y.O., Mousannif, H., Al Moatassime, H., 2019. Predictive modeling of wildfires: a new dataset and machine learning approach. *Fire Saf. J.* 104, 130–146.

Scarpetta, S., Giudicepietro, F., Ezin, E.C., Petrosino, S., Del Pezzo, E., Martini, M., Marinaro, M., 2005. Automatic classification of seismic signals at Mt. Vesuvius volcano, Italy, using neural networks. *Bull. Seismol. Soc. Am.* 95, 185–196.

Segaran, Toby; Hammerbacher, Jeff (2009). *Beautiful Data: The Stories Behind Elegant Data Solutions*. O'Reilly Media. p. 257. ISBN 978-0-596-15711-1. Archived from the original on 12 May 2016. Retrieved 31 December 2015.

Seo, Y., Kim, S., Kisi, O., Singh, V.P., 2015. Daily water level forecasting using wavelet decomposition and artificial intelligence techniques. *J. Hydrol.* 520, 224–243.

Shah, S., Hosseini, M., Miled, Z.B., Shafer, R., Berube, S., 2018. A water demand prediction model for central Indiana. In: *Proceedings of the AAAI Conference on Artificial Intelligence*.

Shaikh, Mustaq & Farjana Birajdar, (2024), Artificial intelligence in groundwater management: Innovations, challenges, and future prospects, *International Journal of Science and Research Archive*, 11(01), 502–512, Article DOI: <https://doi.org/10.30574/ijrsra.2024.11.1.0105>

Shams, S., Goswami, S., Lee, K., 2019. In: *Deep Learning-Based Spatial Analytics for Disaster-Related Tweets: an Experimental Study*, 2019 20th IEEE International Conference on Mobile Data Management (MDM). IEEE, pp. 337–342.

Sharaf El Din, E., Zhang, Y., Suliman, A., 2017. Mapping concentrations of surface water quality parameters using a novel remote sensing and artificial intelligence framework. *Int. J. Rem. Sens.* 38, 1023–1042.

Shen, C., 2018. A transdisciplinary review of deep learning research and its relevance for water resources scientists. *Water Resour. Res.* 54, 8558–8593.



Shi, Sarah; Wieser, Penny; Lehnert, Kerstin; Profeta, Lucia, (2023), MIN-ML: A Machine Learning Framework for Exploring Mineral Relations and Classifying Common Igneous Minerals, EGU23, the 25th EGU General Assembly, held 23-28 April, 2023 in Vienna, Austria and Online. Online at <https://egu23.eu/>, id. EGU-13612

Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., Woo, W.-c., 2015. Convolutional LSTM network: a machine learning approach for precipitation nowcasting. *Adv. Neural Inf. Process. Syst.* 802–810.

Si, Lei; Xiong, Xiangxiang; Wang, Zhongbin; Tan, Chao (2020-03-14). "A Deep Convolutional Neural Network Model for Intelligent Discrimination between Coal and Rocks in Coal Mining Face". *Mathematical Problems in Engineering*. 2020: 1–12. doi:10.1155/2020/2616510. ISSN 1024-123X.

Sivapragasam, C., Liong, S.-Y., Pasha, M., 2001. Rainfall and runoff forecasting with SSA–SVM approach. *J. Hydroinf.* 3, 141–152.

Su, H., Li, W., Yan, X.H., 2018. Retrieving temperature anomaly in the global subsurface and deeper ocean from satellite observations. *J. Geophys. Res.: Oceans* 123, 399–410.

Sumi, S.M., Zaman, M.F., Hirose, H., 2012. A rainfall forecasting method using machine learning models and its application to the Fukuoka city case. *Int. J. Appl. Math. Comput. Sci.* 22, 841–854.

Sun, J., Di, L., Sun, Z., Shen, Y., Lai, Z., 2019b. County-level soybean yield prediction using deep CNN-LSTM model. *Sensors* 19, 4363.

Sun, Z., Di, L., Burgess, A., Tullis, J.A., Magill, A.B., 2020b. Geoweaver: advanced cyberinfrastructure for managing hybrid geoscientific AI workflows. *ISPRS Int. J. Geo-Inf.* 9, 119.

Sun, Z., Di, L., Fang, H., 2019a. Using long short-term memory recurrent neural network in land cover classification on Landsat and Cropland data layer time series. *Int. J. Rem. Sens.* 40, 593–614.



Sun, Z., et al., 2020a. Advanced cyberinfrastructure for intercomparison and validation of climate models. *Environ. Modell. Softw.* 123, 104559. <https://doi.org/10.1016/j.envsoft.2019.104559>.

Sun, Z., Yue, P., Hu, L., Gong, J., Zhang, L., Lu, X., 2013. GeoPWProv: interleaving space map and faceted metadata for provenance visualization and navigation. *IEEE Trans. Geosci. Rem. Sens.* 51, 5131–5136.

Sutanto, S.J., van der Weert, M., Wanders, N., Blauhut, V., Van Lanen, H.A.J., 2019. Moving from drought hazard to impact forecasts. *Nat. Commun.* 10, 4945.

Sutton, R.S., Barto, A.G., 2018. Reinforcement Learning: an Introduction. MIT press.

Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., Brisco, B., 2020. Google Earth Engine for geo-big data applications: a meta-analysis and systematic review. *ISPRS J. Photogrammetry Remote Sens.* 164, 152–170.

Templ, M., Filzmoser, P., Reimann, C., 2008. Cluster analysis applied to regional geochemical data: problems and possibilities. *Appl. Geochem.* 23, 2198–2213.

Tenopir, C., Rice, N.M., Allard, S., Baird, L., Borycz, J., Christian, L., Grant, B., Olendorf, R., Sandusky, R.J., 2020. Data sharing, management, use, and reuse: practices and perceptions of scientists worldwide. *PLoS One* 15, e0229003.

Tiemann, L., Nicolaus, M., Hoppmann, M., Huntemann, M., Haas, C., 2018. Sea-ice properties derived from ice mass-balance buoys using machine learning. In: *Proceedings of Polar 2018 Open Science Conference*.

Tilling, R.I., 1989. Volcanic hazards and their mitigation: progress and problems. *Rev. Geophys.* 27, 237–269.

Tilmes, C., Fox, P., Ma, X., McGuinness, D.L., Privette, A.P., Smith, A., Waple, A., Zednik, S., Zheng, J.G., 2013. Provenance representation for the national climate assessment in the global change information system. *IEEE Trans. Geosci. Rem. Sens.* 51, 5160–5168.



Tong, D.Q., Wang, J.X., Gill, T.E., Lei, H., Wang, B., 2017. Intensified dust storm activity and Valley fever infection in the southwestern United States. *Geophys. Res. Lett.* 44, 4304–4312.

Turan, M.E., Yurdusev, M.A., 2009. River flow estimation from upstream flow records by artificial intelligence methods. *J. Hydrol.* 369, 71–77.

Umar, Z., Pradhan, B., Ahmad, A., Jebur, M.N., Tehrany, M.S., 2014. Earthquake induced landslide susceptibility mapping using an integrated ensemble frequency ratio and logistic regression models in West Sumatera Province, Indonesia. *Catena* 118, 124–135.

Vaughan-Nichols, S.J., 2021. Flying on Mars Fueled with Open-Source Software.

Verbraeken, J., Wolting, M., Katzy, J., Kloppenburg, J., Verbelen, T., Rellermeyer, J.S., 2020. A survey on distributed machine learning. *ACM Comput. Surv.* 53, 1–33.

Vij, A., Vijendra, S., Jain, A., Bajaj, S., Bassi, A., Sharma, A., 2020. IoT and machine learning approaches for automation of farm irrigation system. *Procedia Comput. Sci.* 167, 1250–1257.

Wang, C., Tandeo, P., Mouche, A., Stopa, J.E., Gressani, V., Longepe, N., Vandemark, D., Foster, R.C., Chapron, B., 2019a. Classification of the global Sentinel-1 SAR vignettes for ocean surface process studies. *Rem. Sens. Environ.* 234, 111457.

Wang, H., Koydemir, H.C., Qiu, Y., Bai, B., Zhang, Y., Jin, Y., Tok, S., Yilmaz, E.C., Gumustekin, E., Rivenson, Y., 2020a. Early detection and classification of live bacteria using time-lapse coherent imaging and deep learning. *Light Sci. Appl.* 9, 1–17.

Wang, H., Song, T., Zhu, S., Yang, S., Feng, L., 2021. Subsurface temperature estimation from sea surface data using neural network models in the western pacific ocean. *Mathematics* 9, 852.

Wang, L., Scott, K.A., Xu, L., Clausi, D.A., 2016. Sea ice concentration estimation during melt from dual-pol SAR scenes using deep convolutional neural networks: a case study. *IEEE Trans. Geosci. Rem. Sens.* 54, 4524–4533.



Wang, L., Zhang, J., 2019. Prediction of sgRNA on-target activity in bacteria by deep learning. *BMC Bioinf.* 20, 1–14.

Wang, M., Fu, W., He, X., Hao, S., Wu, X., 2020b. A survey on large-scale machine learning. *IEEE Trans. Knowl. Data Eng.*

Wang, P., Yao, J., Wang, G., Hao, F., Shrestha, S., Xue, B., Xie, G., Peng, Y., 2019b. Exploring the application of artificial intelligence technology for identification of water pollution characteristics and tracing the source of water quality pollutants. *Sci. Total Environ.* 693, 133440.

Wang, W., Xu, Z., Weizhen Lu, J., 2003. Three improved neural network models for air quality forecasting. *Eng. Comput.* 20, 192–210.

Wang, Xuan-Ce, (2024), Using Artificial Intelligence for Mineral Processing and Exploration, <https://www.linkedin.com/pulse/using-artificial-intelligence-mineral-processing-exploration-wang-pfnpc/>

Warwick, K., (2012), *Artificial intelligence: the basics*, Routledge, Milton Park, Abingdon, Oxon.

Watson-Wright, W., Snelgrove, P., 2021. Technical Advancements to Improve Ocean Understanding, Preparing a Workforce for the New Blue Economy. Elsevier, pp. 17–32.

Watson, G.L., Telesca, D., Reid, C.E., Pfister, G.G., Jerrett, M., 2019. Machine learning models accurately predict ozone exposure during wildfire events. *Environ. Pollut.* 254, 112792.

WHO, 2021. Air Pollution.

Wilhite, D.A., 2016. *Droughts: A Global Assessment*. Routledge. Wimmers, A., Velden, C., Cossuth, J.H., 2019. Using deep learning to estimate tropical cyclone intensity from satellite passive microwave imagery. *Mon. Weather Rev.* 147, 2261–2282.



Wu, X., Yan, X.-H., Jo, Y.-H., Liu, W.T., 2012. Estimation of subsurface temperature anomaly in the North Atlantic using a self-organizing map neural network. *J. Atmos. Ocean. Technol.* 29, 1675–1688.

Wu, Y.-C., Shiledar, A., Li, Y.-C., Wong, J., Feng, S., Chen, X., Chen, C., Jin, K., Janamian, S., Yang, Z., 2017. Air quality monitoring using mobile microscopy and machine learning. *Light Sci. Appl.* 6, e17046.

Xia, M., Liu, W.a., Shi, B., Weng, L., Liu, J., 2019. Cloud/snow recognition for multispectral satellite imagery based on a multidimensional deep residual network. *Int. J. Rem. Sens.* 40, 156–170.

Xia, Yao & Yan Feng, (2023), Prospects of Artificial Intelligence Application in the High-Quality Development of the Geological Exploration Industry, L. Moutinho et al. (eds.), *Proceedings of the 2023 International Conference on Management Innovation and Economy Development (MIED 2023), Advances in Economics, Business and Management Research* 260, https://doi.org/10.2991/978-94-6463-260-6_12.

Xiao, X., Zhang, T., Zhong, X., Shao, W., Li, X., 2018. Support vector regression snowdepth retrieval algorithm using passive microwave remote sensing data. *Rem. Sens. Environ.* 210, 48–64.

Xu, K., Zhu, W., Darve, E., 2020. Distributed Machine Learning for Computational Engineering Using MPI arXiv preprint arXiv:2011.01349.

Yan, Q., Huang, W., 2018. Sea ice sensing from GNSS-R data using convolutional neural networks. *Geosci. Rem. Sens. Lett. IEEE* 15, 1510–1514.

Yao, J., Raffuse, S.M., Brauer, M., Williamson, G.J., Bowman, D.M., Johnston, F.H., Henderson, S.B., 2018. Predicting the minimum height of forest fire smoke within the atmosphere using machine learning and data from the CALIPSO satellite. *Rem. Sens. Environ.* 206, 98–106.

Yaseen, Z.M., El-Shafie, A., Jaafar, O., Afan, H.A., Sayl, K.N., 2015. Artificial intelligence based models for stream-flow forecasting: 2000–2015. *J. Hydrol.* 530, 829–844.



Yu, M., Huang, Q., Qin, H., Scheele, C., Yang, C., (2019), Deep learning for real-time social media text classification for situation awareness—using Hurricanes Sandy, Harvey, and Irma as case studies. *International Journal of Digital Earth* 12, 1230–1247.

Yu, Siwei, & Ma, Jianwei, (2021), Deep Learning for Geophysics: Current and Future Trends, *Reviews of Geophysics*, Volume 59, Issue 3, <https://doi.org/10.1029/2021RG000742>.

Zarei, Ahmad, (2024), How can you use machine learning to classify rocks and minerals?, <https://www.linkedin.com/advice/1/how-can-you-use-machine-learning-classify-rocks-2lfie#:~:text=Machine%20learning%20can%20be%20utilized,under%20a%20microscope%2C%20aiding%20researchers>.

Zhan, Y., Wang, J., Shi, J., Cheng, G., Yao, L., Sun, W., 2017. Distinguishing cloud and snow in satellite images via deep convolutional network. *Geosci. Rem. Sens. Lett. IEEE* 14, 1785–1789.

Zhang, M., Jiang, L., Zhao, J., Yue, P., Zhang, X., 2020. Coupling OGC WPS and W3C PROV for provenance-aware geoprocessing workflows. *Comput. Geosci.* 138, 104419.

Zhang, Y., Bocquet, M., Mallet, V., Seigneur, C., Baklanov, A., 2012. Real-time air quality forecasting, part II: state of the science, current research needs, and future prospects. *Atmos. Environ.* 60, 656–676.

Zhang, Y., Jiang, H., Ye, T., Juhas, M., 2021. Deep learning for imaging and detection of microorganisms. *Trends Microbiol.* 29, 569–572.

Zhao, H., Shi, J., Qi, X., Wang, X., Jia, J., 2017. Pyramid scene parsing network. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2881–2890.




Zhao, Y., Ma, J., Li, X., Zhang, J., 2018. Saliency detection and deep learning-based wildfire identification in UAV imagery. *Sensors* 18, 712.



يتمتع الأستاذ الدكتور عبدالله بن محمد العمري بمسيرة علمية حافلة امتدت لأكثر من خمسة وثلاثين عاماً، حيث شغل منصب أستاذ علم الزلازل ورئيس قسم الجيولوجيا والجيوفيزياء في جامعة الملك سعود بالرياض، ويعمل مشرفاً على مركز الدراسات الزلزالية ورئيساً للجمعية السعودية لعلوم الأرض. يعمل العمري باحثاً رئيساً في 13 مجموعة عمل أمريكية وألمانية ومستشاراً محلياً ودولياً في العديد من الجمعيات والميئات داخل المملكة العربية السعودية وخارجها. أسس ورأس تحرير أول مجلة عربية للعلوم الجيولوجية تحت إشراف الناشر الألماني Springer وتمحورت أبحاثه العلمية حول نمذجة ومحاكاة ميكانيكية الزلازل والحد من مخاطرها، واستكشاف المياه الجوفية العميقة وتحديد مكامن الطاقة الحرارية الأرضية إلى جانب أعماله البحثية، يبذل العمري جهوداً حثيثة على نشر المعرفة، إذ ألف موسوعات وكتباً تعليمية تخصصية تهدف إلى إثراء المكتبة العربية بمواد تعليمية متفردة، ومن أبرز إنجازاته تأسيس أول موسوعة جيولوجية رقمية للمملكة العربية السعودية في عام 2024، حيث اشتملت على جميع الثروات الاقتصادية والظواهر الجيولوجية فيها. ونشر أكثر من 220 ورقة بحثية وأنجز أكثر من 60 مشروعاً بحثياً و 74 تقريراً علمياً، بالإضافة إلى تأليفه موسوعة تعليمية من 30 كتاباً و 5 موسوعات علمية تخصصية و 3 كتب أكاديمية في علوم الأرض. حصل على العديد من الجوائز ودروع التكريم المحلية والعالمية نظير إنجازاته العلمية المتميزة.



إصدارات المؤلف





موسوعة العبدى في علوم الأرض

Al-Amri's Encyclopedia of Earth Sciences



المد والجزر



المعادن والتعدين



التركيب الداخلى للأرض



الجاذبية الأرضية وتطبيقاتها



شكل الأرض وحركتها



تقدير عمر الأرض



الأغلفة المحيطية بالأرض



جيولوجية القمر



البراكين وسبل مجابهتها



تقييم مخاطر الزلازل



الزلازل والتفجيرات



موجات التسونامي



التصحّر والجفاف



السيول والسدود المائية



الانزلاقات والانهيارات والفيضانات



التشجير التحديات والحلول



التغيرات المناخية والاحتباس الحراري



المشاكل البيئية وحلولها



كتابة الرسائل والمشاريع الجيولوجية



الجيولوجيا الطبية



الجيوفيزياء النووية



الجيولوجيا السياسية



الطاقة الحرارية الأرضية



هل انتهى عصر النفط؟



300 سؤال وجواب في الجيوفيزياء التطبيقية



303 سؤال وجواب في علم الزلازل والزلزالية الهندسية



380 سؤال وجواب في المخاطر الجيولوجية



358 سؤال وجواب في الثروات الطبيعية



358 سؤال وجواب في علم الصخور والجيوكيمياء



321 سؤال وجواب في تطور الأرض



ماء زمزم



تطبيقات الذكاء الاصطناعي في علوم الأرض



نظام الإنذار المبكر في الزلازل

