

الجغرافيا من أجل استدامة الذكاء الاصطناعي

والاستدامة من أجل الذكاء الجغرافي الاصطناعي

Meilin Shi a , Krzysztof Janowicz a , Judith Versteegen b , Kitty Currier c , Nina Wiedemann d ,
Gengchen Mai Ivan Majic a a , Zilong Liu a and Rui Zhu f Department of Geography and Regional
Research, University of Vienna, Austria; b e Department of Human Geography and Spatial Planning,
Utrecht University, Netherlands; c Department of Geography, University of California, Santa Barbara,
USA; Geoinformation, ETH Zurich, Switzerland; e d Institute of Cartography and Department of
Geography and the Environment, University of Texas at Austin, USA; Geographical Sciences,
University of Bristol, UK

ترجمة بتصرف
أ.د. مضر خليل عمر

مقدمة

يُقدّر حجم عمليات البحث اليومية على جوجل بنحو ٨,٥ مليار عملية (فلينستيد، ٢٠٢٤)، ويُنتج البحث الواحد حوالي ٠,٥ غرام من انبعاثات ثاني أكسيد الكربون (بيرنر-زلي، ٢٠٢٠). منذ إطلاق ChatGPT في نوفمبر ٢٠٢٢، شهد الذكاء الاصطناعي التوليدي نموًا ملحوظًا، إذ يُزعم أنه يُحسن تجربة المستخدم من خلال توفير نتائج أكثر فائدة من محركات البحث التقليدية (هريستيديس وآخرون، ٢٠٢٣؛ شو وآخرون، ٢٠٢٣). وقد أدت مراكز البيانات والبنية التحتية للتدريب اللازمة لتشغيل الاستخدام المتزايد للذكاء الاصطناعي حتمًا إلى زيادة استهلاك الطاقة وانبعاثات الكربون (وو وآخرون، ٢٠٢٢). على الرغم من فوائد الذكاء الاصطناعي العديدة، إلا أن عامة الناس لم يدركوا على نطاق واسع **البصمة الكربونية الكبيرة للذكاء الاصطناعي التوليدي**. على سبيل المثال، هل تساءلت يومًا عن كمية انبعاثات الكربون التي يُنتجها استعمال واحد على ChatGPT مقارنةً بعملية بحث على جوجل؟ يمثل نموذج GPT-4 (OpenAI، 2023)، الذي يُقال إنه يحتوي على 1.76 تريليون مُعامل (Schreiner، 2023)، تقدمًا كبيراً في تعقيد النماذج ومتطلبات الحوسبة. وقد أدى دمج تقنيات الذكاء الاصطناعي التوليدي في سوق محركات البحث الأوسع، مثل تعاون GPT-4 مع محرك بحث مايكروسوفت بينج (Blogs، 2023)، إلى توسيع نطاق استخدام الذكاء الاصطناعي المتقدم في الحياة اليومية.

ومع ذلك، أثار الانتشار الواسع لهذه النماذج الضخمة مخاوف بيئية. وتزايدت الدعوات في مجتمع التعلم الآلي لتحسين كفاءتها في استهلاك الطاقة (Bender et al.، 2021؛ Schwartz et al.، 2020؛ Strubell et al.، 2019). ويستمر حجم نماذج الذكاء الاصطناعي وتعقيدها في النمو. أصبحت معالجة قضايا الاستدامة أكثر إلحاحًا نظرًا لتزايد اعتمادها في مجالات أوسع، مثل تلك التي تُطوّر نماذج الذكاء الاصطناعي الجغرافي كثيفة الحساب (كاي وآخرون، 2020؛ جياو وآخرون، 2018؛ باتاك وآخرون، 2022). وفي سياق الذكاء الاصطناعي، تشير **الاستدامة إلى تطوير أنظمة الذكاء الاصطناعي لتقليل أثرها البيئي مع تعزيز السلامة البيئية والعدالة الاجتماعية** (فان وينسبرغ، 2021). واستجابةً لهذه المخاوف المُلحة، اتخذ مجتمع التعلّم الآلي خطوات لقياس الأثر البيئي لتدريب النماذج والإبلاغ عنه، والعمل في نهاية المطاف على تخفيفه (توفيريون وآخرون، 2023).

في هذا العمل، ندمج منظور الجغرافيا لاستدامة الذكاء الاصطناعي والاستدامة للذكاء الاصطناعي الجغرافي. ومن خلال إدخال منظور جغرافي، نضع الجهود الحالية المبذولة في مجتمع التعلّم الآلي لتحسين الاستدامة البيئية والاجتماعية للذكاء الاصطناعي في سياقها الصحيح، ونسلط الضوء على

المعطيات الجغرافية التي لم تحظَ بالاهتمام الكافي حتى الآن. يلي ذلك نقاش حول كيفية تطبيق هذه الجهود على نماذج الذكاء الاصطناعي الجغرافي. نسعى إلى رفع مستوى الوعي داخل مجتمع الذكاء الاصطناعي الجغرافي، حيث إن نماذجه، مثل نماذج المناخ (رولنيك وآخرون، 2022)، قد يكون لها آثار أكبر على الاستدامة من نماذج الذكاء الاصطناعي التقليدية. ولتقديم رؤية شاملة، نتناول مجموعة واسعة من المواضيع، بما في ذلك استهلاك الطاقة والموارد الطبيعية، وانبعاثات الكربون، والشفافية، والآثار الاجتماعية المترتبة على نشر الذكاء الاصطناعي. تساهم جميع هذه العوامل في تصورنا لاستدامة الذكاء الاصطناعي. نأمل من خلال هذا العمل تشجيع مجتمع الذكاء الاصطناعي الجغرافي على إعطاء الأولوية للاستدامة إلى جانب أداء النموذج في البحوث المستقبلية، والدعوة إلى اتخاذ قرارات واعية بالموارد.

تُقدّم هذه الورقة البحثية إسهامين رئيسيين:

- الجغرافيا من أجل استدامة الذكاء الاصطناعي: نُضيف منظورًا جغرافيًا للتفاوتات الإقليمية والتقييمات المُراعية للأثر البيئي في مناقشات استدامة الذكاء الاصطناعي الحالية.
- الاستدامة في الذكاء الاصطناعي الجغرافي: ندرس مدى إمكانية تطبيق جهود استدامة الذكاء الاصطناعي الحالية على مجال الذكاء الاصطناعي الجغرافي، مُسلطين الضوء على فريدة نماذج الذكاء الاصطناعي الجغرافي والتحديات التي تواجهها في تحقيق أهداف الاستدامة.

يُقسّم باقي هذه الورقة البحثية على النحو الآتي: يُقدّم القسم الثاني نظرة عامة على أدوات البرمجيات المتاحة، ومقاييس التقييم، والمعايير المرجعية، والأطر التحليلية المُصممة لمعالجة استدامة الذكاء الاصطناعي. يُحدّد القسم الثالث التحديات التي تمّ تحديدها من خلال هذه النظرة العامة والأدبيات الحديثة في مجال التعلّم الآلي. بعد ذلك، يُقدّم القسم الرابع منظورًا جغرافيًا لمناقشات استدامة الذكاء الاصطناعي الحالية. تُركّز هنا على التفاوتات الإقليمية في الأثر البيئي وضرورة دمج الوعي الجغرافي في تقييمات استدامة الذكاء الاصطناعي. يناقش القسم الخامس الخصائص الفريدة للبيانات الجغرافية المكانية والتحديات التي تواجه تطبيق جهود استدامة الذكاء الاصطناعي الحالية في مجال الذكاء الجغرافي المكاني. في القسم السادس، نقترح توجهات مستقبلية وحلولًا محتملة لتحسين استدامة الذكاء الاصطناعي. وأخيرًا، نلخص نتائجنا في القسم السابع.

الشكل 1: تطور تقييم النماذج لتقييم استدامة الذكاء الاصطناعي.



الشكل 1. تطور تقييم النموذج لتقييم استدامة الذكاء الاصطناعي

التقييم الحالي للاستدامة في أبحاث الذكاء الاصطناعي

مدفوعاً بتزايد الوعي العام بتغير المناخ، ازداد التدقيق في الآثار البيئية للحوسبة في أبحاث الذكاء الاصطناعي. وتهدف الدعوات إلى الذكاء الاصطناعي الأخضر (شوارتز وآخرون، ٢٠٢٠) إلى تحسين الكفاءة وتقليل البصمة الكربونية لأبحاث الذكاء الاصطناعي. ركزت المخاوف المبكرة على استهلاك الطاقة وتقدير الانبعاثات (جيليني وكاسو، ٢٠١٥؛ هيلتي وآخرون، ٢٠٠٩؛ مالمودين وآخرون، ٢٠١٣)، ثم توسعت لاحقاً لتشمل مقاييس مثل مؤشر الشفافية (بوماساني وآخرون، ٢٠٢٣، ٢٠٢٤) لمقارنة النماذج. علاوة على ذلك، أقر مجتمع التعلم الآلي بالآثار الاجتماعية لأبحاث الذكاء الاصطناعي (بيندر وآخرون، ٢٠٢١)، وناقش أيضاً إلى أي مدى تفوق فوائد الذكاء الاصطناعي على التكاليف المحتملة (بوماساني وآخرون، ٢٠٢١). نُصنّف هذا التطور إلى ثلاث مراحل:

(1) تقييم التكلفة الواحدة،

(2) تقييم التكاليف المتعددة، و

(3) التحليل الشامل.

يوضح الشكل 1 هذا التطور في تقييم نماذج استدامة الذكاء الاصطناعي، وسناقشه بمزيد من التفصيل في الأقسام الثلاثة اللاحقة.

تقييم التكلفة الواحدة:

استجابةً للدعوات إلى مزيد من الذكاء الاصطناعي المستدام (في مجال البحث)، طُوّرت أطر عمل وأدوات برمجية متنوعة لتقدير انبعاثات الكربون، وعرضها بصرياً، والإبلاغ عنها بشفافية. تبدأ هذه الأدوات بتقييم التكلفة الواحدة، الذي يُقيّم عامل انبعاثات الكربون فقط، حيث تُقدّر الانبعاثات عادةً بضرب استهلاك الطاقة في كثافة الكربون. تشير كثافة الكربون إلى كمية ثاني أكسيد الكربون المنبعثة لكل وحدة طاقة مُنتجة أو مُستهلكة، وهي عامل أساسي للحصول على تقديرات دقيقة. يُلخص الجدول 1 الأدوات والأطر المجانية والمفتوحة المصدر المتاحة لتقدير الانبعاثات، بالإضافة إلى مصادر بيانات كثافة الكربون التفصيلية الخاصة بها.

الجدول 1. ملخص لأدوات المصادر المفتوحة المتاحة ومصادر بياناتها.	البيانات	التعليق	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	السنة
2019	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2019
2021	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2021
2017	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2017
2016	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2016
2016	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2016
2017	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2017
2019	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2019
2020	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2020
2021	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2021
2021	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2021
2022	مالي	مصدر بيانات كثافة الكربون	مصدر بيانات كثافة الكربون	نوع	حاسبة انبعاثات الكربون	2022

من أوائل هذه الأدوات حاسبة انبعاثات التعلم الآلي (لاكوست وآخرون، 2019)، التي توفر واجهة لتقدير كمية انبعاثات الكربون الناتجة عن تدريب نماذج التعلم الآلي. وبإدخال معلومات حول نوع الجهاز، وعدد ساعات الاستخدام، ومزود الخدمة، ومنطقة الحوسبة، يمكن للمستخدمين الحصول على تقدير لكمية الكربون المنبعثة، بالإضافة إلى كمية الكربون التي قام مزود الخدمة بتعويضها بالفعل. ويتم حساب انبعاثات الكربون من خلال دمج مصادر بيانات متعددة، بما في ذلك قاعدة بيانات الانبعاثات وتوليد الطاقة المتكاملة (eGRID) التابعة لوكالة حماية البيئة الأمريكية (وكالة حماية البيئة الأمريكية، 2022)، وخرائط الكهرباء (بدون تاريخ)، وتقارير مختلفة حول كثافة الكربون في قطاع الكهرباء.

في الفترة نفسها تقريباً، طُرح برنامج CodeCarbon (لوتيكي وآخرون، 2019) كحزمة برمجية خفيفة الوزن تُدمج في التعليمات البرمجية. يُقدّر البرنامج كمية ثاني أكسيد الكربون الناتج عن موارد الحوسبة

السحابية أو الشخصية المستخدمة لتنفيذ التعليمات البرمجية. ثم تُعرض الانبعاثات وما يُعادلها من خلال لوحة تحكم مرئية. وقد تم توفير بيانات مزيج الطاقة والانبعاثات من قبل eGRID التابعة لوكالة حماية البيئة الأمريكية (2022) وإدارة معلومات الطاقة الأمريكية (2019). وعلى غرار CodeCarbon، يُعدّ Carbontracker (أنتوني وآخرون، 2020) حزمة برمجية لتتبع وتوقع استهلاك الطاقة وانبعاثات الكربون الناتجة عن تدريب نماذج التعلم العميق، حيث يُقدّم بيانات كثافة الكربون في الوقت الفعلي عند توفرها.

حاليًا، تقتصر البيانات المتاحة في الوقت الفعلي على الدنمارك وبريطانيا عبر واجهات برمجة التطبيقات (APIs). بالنسبة للمناطق الأخرى، تستخدم الأداة متوسط قيمة كثافة الكربون لدول الاتحاد الأوروبي الـ 28، والمقدمة من وكالة البيئة الأوروبية (EEA، 2020). وبلاستناد إلى إمكانيات أدوات مثل Carbontracker و CodeCarbon، يوفر برنامج experiment-impact-tracker إطار عمل بسيطاً (Henderson et al.، 2020) لتتبع استهلاك الطاقة وانبعاثات الكربون في الوقت الفعلي لأبحاث التعلم الآلي. يتطلب البرنامج إضافة بسيطة للبرنامج لجمع تفاصيل استهلاك الطاقة لوحدة المعالجة المركزية ووحدات معالجة الرسومات، واستخدام الذاكرة، وما إلى ذلك. ويتضمن البرنامج نصاً برمجياً لإنشاء ملاحق موحدة عبر الإنترنت للإبلاغ عن هذه المقاييس. تُقدّر انبعاثات الكربون باستخدام أجزاء مفتوحة المصدر من خرائط الكهرباء (بدون تاريخ)، باختيار كثافة الكربون لأصغر منطقة محيطة بموقع معين. حاليًا، تتوفر بيانات انبعاثات الكربون في الوقت الفعلي لولاية كاليفورنيا فقط في الولايات المتحدة.

بينما تركز بعض الأدوات على التكامل البرمجي، تقدم أدوات أخرى نهجاً مرئياً وتفاعلياً. على سبيل المثال، EnergyVis (الشيخ وآخرون، 2021) هي منصة إلكترونية تتيح للمستخدمين تتبع ومقارنة وعرض استهلاك الطاقة والبصمة الكربونية لتدريب نماذج التعلم الآلي. تساعد المنصة المستخدمين على استكشاف مواقع نشر بديلة وخيارات أجهزة لتقليل بصمتهم الكربونية. تُحسب انبعاثات الكربون باستخدام ثوابت كثافة الكربون الخاصة بكل ولاية أمريكية من المختبر الوطني للطاقة المتجددة (NREL، 2020). يُمكن هذا EnergyVis من تقدير ناتج الكربون للتجارب التي تُجرى في مواقع مختلفة في جميع أنحاء الولايات المتحدة، مما يساعد المستخدمين على تقييم البدائل القائمة على الموقع. أداة أخرى قائمة على لوحة تحكم، تشبه حاسبة انبعاثات التعلم الآلي ولكنها توسع قدراتها من خلال توفير مدخلات أكثر تفصيلاً، وهي Green Algorithms (لانيلونج وآخرون، 2021). توفر هذه الأداة إطاراً منهجياً ومنصة إلكترونية تتيح للمستخدمين تقييم البصمة الكربونية لمهامهم الحسابية.

تدعم الخوارزميات الخضراء نطاقاً واسعاً من تكوينات الأجهزة، ويمكنها تقدير وفورات الكربون أو تكاليف إعادة نشر العمليات الحسابية على بنى مختلفة. تُحسب انبعاثات الكربون باستخدام متوسط قيمة كثافة الكربون العالمية من تقرير انبعاثات وكالة الطاقة الدولية (IEA، 2019). ومؤخراً، برزت مكتبة Eco2AI (بوديني وآخرون، 2022) كمكتبة بايثون مصممة لتتبع انبعاثات ثاني أكسيد الكربون. تراقب هذه المكتبة استهلاك الطاقة للأجهزة أثناء تدريب النموذج، وتقدر انبعاثات الكربون المكافئة باستخدام معاملات انبعاثات إقليمية. تُستمد هذه المعاملات، المعروفة أيضاً بكثافة الكربون، من تقارير الطاقة العالمية مثل تقرير إمبر (2022) ومجموعات بيانات إقليمية متعددة، بما في ذلك بيانات من أستراليا وكندا وروسيا والولايات المتحدة. بالإضافة إلى الأدوات المُلخصة في الجدول 1، اقترح دودج وآخرون (2022) إطار

عمل لتقدير كثافة الكربون البرمجية (SCI) للحالات السحابية من خلال دمج الانبعاثات الحدية المرتبطة بالموقع والوقت.

من الناحية المثالية، تُحسب كثافة الكربون البرمجية (SCI) من خلال مراعاة كل من الانبعاثات التشغيلية والانبعاثات المُضمّنة، والتي تُمثل الكربون المنبعث أثناء تشغيل النموذج ودورة حياة الأجهزة (التصنيع والاستخدام والتخلص)، على التوالي. مع ذلك، ونظرًا لمحدودية المعلومات المتوفرة حول الأجهزة المتخصصة مثل وحدات معالجة الرسومات (GPUS)، فإن التطبيق الأولي يُعالج الانبعاثات التشغيلية فقط. وما يزال توثيق البصمة الكربونية عبر جميع مراحل استخدام الأجهزة يُمثل تحديًا رئيسيًا. ومع ذلك، يُوفر إطار العمل هذا طريقة لتقدير كثافة الكربون البرمجية (SCI) كبديل لانبعاثات الكربون من الحالات السحابية.

التقييم متعدد التكاليف:

على الرغم من توجيه الكثير من الاهتمام (بحق) نحو تقدير انبعاثات الكربون، فإن التقييم الشامل يتجاوز مجرد الإبلاغ عن أرقام الانبعاثات. إذ يأخذ التقييم متعدد التكاليف في الحسبان عوامل إضافية مثل كفاءة الطاقة، واستهلاك الموارد، والتأثيرات المجتمعية الأوسع. وقد صُممت المؤشرات والمعايير المرجعية لتوفير إطار عمل منظم لتقييم جوانب الاستدامة هذه، مما يتيح فرصة مقارنة أداء النماذج المختلفة. يُقدّم مؤشر شفافية نماذج البنية التحتية (FMTI) (بوماساني وآخرون، 2023، 2024) مجموعة واسعة من المقاييس على مستوى النظام، تتألف من 100 مؤشر دقيق، لتقييم شفافية نماذج البنية التحتية (FMS) - وهي نماذج تُعلّم آلي واسعة النطاق مُدرّبة مسبقًا على مجموعات بيانات متنوعة، وتُعمّم على مختلف المهام (بوماساني وآخرون، 2021) - عبر مختلف المراحل، بدءًا من استهلاك الموارد في المراحل الأولية وبناء النموذج، وصولًا إلى استخدامه المستقبلي في المراحل اللاحقة. يتم تقييم أربعة عشر محورًا رئيسيًا لنماذج البنية التحتية بناءً على ممارساتهم في نماذجهم الرائدة. يشمل ذلك GPT-4 (OpenAI، 2023) لشركة OpenAI، Gemini 1.0 Ultra (فريق Gemini، جوجل، 2023) لشركة جوجل، و Llama 2 (توفيريون وآخرون، 2023) لشركة Meta. من خلال قياس الشفافية وتقييمها بين المطورين، يهدف مؤشر FMTI إلى تشجيع هذه الشركات الرائدة في مجال نماذج البنية التحتية الكبيرة على تحسين درجات شفافتها بمرور الوقت. إلى جانب هذه المؤشرات، تلعب المعايير المرجعية دورًا محوريًا في ممارسات الذكاء الاصطناعي المستدامة، إذ توفر أطرًا معيارية لتقييم كفاءة الطاقة والآخر البيئي (X. Zhou et al., 2020).

وحتى الآن، لا توجد معايير مرجعية معتمدة على نطاق واسع لتقييم هذا الأداء. إن وضع مجموعة من المقاييس المعيارية لتقييم نماذج الذكاء الاصطناعي بناءً على العوامل البيئية (مثل استهلاك الطاقة، والبصمة الكربونية) من شأنه أن يُتيح مقارنة النماذج المختلفة. وتُقدم جهودٌ جارية، مثل MLCommons، معيارًا مرجعيًا لكفاءة الخوارزميات (Dahl et al., 2023)، إلى جانب مجموعة شاملة من المعايير المرجعية (<https://mlcommons.org/benchmarks>)، تشمل معايير التدريب والاستدلال والتخزين، لتقييم أداء نماذج التعلم الآلي عبر إعدادات أجهزة مختلفة (مثل وحدات المعالجة المركزية، ووحدات معالجة الرسومات، والمُسرّعات).

يهدف معيار MLCommons إلى تمكين التحسين الأمثل لنماذج التعلم الآلي قبل نشرها، مما يسمح بإجراء مقارنات مباشرة بين مختلف النماذج وتكوينات الأجهزة. وبفضل إمكانية الحصول على مزيد

من المعلومات حول كفاءة استهلاك الطاقة في نماذج الذكاء الاصطناعي، يمكن لهذه المعايير أن تُسهم في تطوير مجال الذكاء الاصطناعي بطريقة تنافسية بيئيًا من خلال قياس استهلاك الطاقة وانبعاثات الكربون (وو وآخرون، 2022)

التحليل الشامل:

من الناحية المثالية، ينبغي أن تُسهم نماذج الذكاء الاصطناعي في تحقيق الصالح العام للمساعدة في موازنة تأثيرها البيئي. على سبيل المثال، يمكنها المساعدة في تشخيص الرعاية الصحية، وتعزيز الزراعة الدقيقة، وتحسين التنبؤات للتخفيف من آثار تغير المناخ (بوماساني وآخرون، 2021؛ تومايف وآخرون، 2020). يدرس التحليل الشامل تكاليف وفوائد هذه النماذج، لتحديد ما إذا كانت آثارها الاجتماعية والبيئية الإجمالية تُبرر تطبيقها. ولتقييم المفاضلة بين الفوائد الاجتماعية والتكاليف الاجتماعية والبيئية المرتبطة بنشر نموذج أساسي، اقترح بوماساني وآخرون (2021) معادلة لقياس التأثير الإجمالي للنموذج. تأخذ هذه المعادلة في الحسبان عدة متغيرات، جميعها معبر عنها بقيم نقدية، بما في ذلك الفوائد الاجتماعية والبيئية، والتكلفة الاجتماعية (الضرر المستقبلي الذي يلحق بالمجتمع) للكربون المنبعث من خلال استخدام الطاقة، وتكلفة الطاقة للنموذج، والتكلفة الاجتماعية للآثار البيئية الأخرى من الدرجة الثانية.

من خلال دراسة جميع هذه العوامل، يمكن لأصحاب المصلحة اختيار نموذج أكثر كفاءة أو إعادة النظر في عملية النشر. وهذا من شأنه أن يساعد في ضمان استدامة نماذج إدارة المرافق قبل اعتمادها ونشرها على نطاق واسع. في حين أن تحديد هذه المتغيرات كميًا يطرح تحديات، وقد يختلف تقديرها التجريبي اختلافًا كبيرًا، فإن تحليل التكلفة والعائد هذا يوفر إطارًا أوليًا للنظر في المفاضلات البيئية والاجتماعية في تدريب نموذج إدارة المرافق ونشره.

التحديات المحددة في الأدبيات

في هذا القسم، نلخص التحديات المحددة من القسم السابق والأدبيات الحديثة في مجال التعلم الآلي. نركز على الشفافية، موضحين كيف يمكن أن تؤدي مصادر البيانات المختلفة وتكوينات النماذج المكانية والزمانية إلى تقديرات مختلفة لانبعاثات الكربون. بالإضافة إلى ذلك، نجمع العوامل المذكورة في أدبيات التعلم الآلي وندرجها في التأثير البيئي الإجمالي لأنظمة الحوسبة من خلال منظور تقييم دورة الحياة، متجاوزين التركيز الحالي على الانبعاثات التشغيلية.

الشفافية والموثوقية:

تُعَد الشفافية حجر الزاوية في تطوير الذكاء الاصطناعي المستدام، وهي وثيقة الصلة بالثقة، لا سيما فيما يتعلق بثقة المعلومات (بشر ويانوفيتش، 2010). مع ذلك، تفنقر العديد من أدوات تقدير انبعاثات الكربون المذكورة في القسم السابق إلى الشفافية الكاملة فيما يتعلق بمصادر البيانات المستخدمة لتحديد قيم كثافة الكربون. إذ تُبلغ المصادر المختلفة عن أنواع مختلفة من قيم كثافة الكربون، على سبيل المثال، الطاقة المنتجة مقابل الطاقة المستهلكة في منطقة ما. وقد لا تتطابق القيم الناتجة في حال تصدير الطاقة أو استيرادها. قد تؤدي هذه التناقضات إلى مشاكل في قابلية التشغيل البيئي، لعدم وجود معيار موحد للإبلاغ عن كثافة الكربون في تقديرات الانبعاثات، مما يُصعّب مقارنة النتائج بين الأدوات المختلفة. وكما هو موضح في الجدول 2، قد تختلف قيم كثافة الكربون المُبلغ عنها لإنتاج الطاقة واستهلاكها في النمسا بنسبة تصل إلى 174% خلال العام نفسه. حتى ضمن فئة قيم كثافة الكربون لإنتاج الطاقة، توجد اختلافات كبيرة تبعًا لمصدر البيانات.

الجدول 2. كثافة الكربون للطاقة في بلدان مختارة حسب مصدر البيانات.

مصدر البيانات	نوع كثافة الكربون	السنة	كثافة الكربون (غرام ثاني أكسيد الكربون/كيلوواط ساعة)		
			النمسا	بلجيكا	كرواتيا
دقة أعلى (2020)	الإنتاج	2017	104	176	188
البيضة الكربونية (2018)	الإنتاج	2017	148	139	303
عالميا في بيانات (2024)	الإنتاج	2017	163	160	256
خراط الكهبياء (بدون تاريخ)	الاستهلاك	2017	285	228	303

علاوة على ذلك، عندما توفر مصادر البيانات معلومات على مستويات مكانية متعددة (دون الوطنية، أو الوطنية، أو المتوسطة الإقليمية)، يبقى مصدر قيمة كثافة الكربون غير واضح، مما يجعل المستخدمين غير مدركين للمعلومات الأساسية المستخدمة في تقدير الانبعاثات. كما أن البيانات المستخدمة في هذه الحسابات قد تكون غير متسقة (أو غير مكتملة) في بعض الأحيان، مما يثير مخاوف بشأن دقة النتائج وموثوقيتها. ووفقاً لهندرسون وآخرون (2020)، ونظراً للتفاوت المكاني، فإن استقرار التقديرات بمعلومات جزئية قد يحدث اختلافات كبيرة مقارنةً بتتبع جميع البيانات. وقد يجد المستخدمون صعوبة في الوثوق بهذه التقديرات والإبلاغ عنها في حال غياب الشفافية الكاملة والتحديثات المنتظمة لعوامل مثل كثافة الكربون.

وبالإضافة إلى تحسين الشفافية فيما يتعلق باختيار قيم كثافة الكربون المُبلغ عنها، ثمة حاجة أيضاً إلى زيادة شفافية التكوين المكاني والزمني لنموذج الذكاء الاصطناعي لتحسين تقدير بصمته الكربونية. وقد أوضح دودج وآخرون (2022) أن اختيار مراكز البيانات في مناطق جغرافية مختلفة وأوقات مختلفة من اليوم لضبط نموذج BERT بدقة يؤدي إلى تباين في انبعاثات الكربون. وجد الباحثون أن كثافة الكربون تتفاوت جغرافياً بين 200 و755 غراماً من ثاني أكسيد الكربون لكل كيلوواط ساعة في المناطق الأكثر والأقل كفاءة. ومن منظور زمني، قد يؤدي تدريب النموذج في منتصف الليل إلى زيادة انبعاثات الكربون بنسبة تصل إلى 8% مقارنةً بالتدريب في الساعة السادسة صباحاً. يُعزى هذا التباين في الانبعاثات إلى تركيبة الطاقة داخل المنطقة، حيث قد يتضمن التدريب خلال النهار نسبة أعلى من الطاقة المتجددة مقارنةً بمصادر الوقود الأحفوري (دي تشاليندار وبنسون، 2019).

علاوة على ذلك، ناقش لي وآخرون (2023) التنوع المكاني والزمني في كفاءة استخدام المياه أثناء تشغيل نماذج الذكاء الاصطناعي، مُسلطين الضوء على أن زمان ومكان تدريب نموذج ذكاء اصطناعي كبير يؤثر على بصمته المائية. ويعود ذلك إلى التغيرات في الأحوال الجوية ومزيج الطاقة والوقود في الشبكة، والتي يتم تعديلها لتلبية الطلب المتغير بمرور الوقت. عموماً، من الضروري أن تُفصح أدوات التقدير هذه بوضوح عن مصادر البيانات، وأن تُقدم معلومات تفصيلية عن التكوينات المكانية والزمانية للنموذج، وأن تُوفر تحديثات منتظمة لتحديثات بشأن عوامل مثل كثافة الكربون. بهذه الطريقة فقط تضمن هذه الأدوات موثوقية التقارير. من خلال تبني العلوم المفتوحة وقابلية التكرار، يستطيع الباحثون التحقق من صحة النتائج وتعزيز التعاون، وهو أمر بالغ الأهمية لبناء الثقة وضمان فعالية هذه الأدوات في تعزيز تدابير الاستدامة.

تقييم دورة الحياة:

تركز الأدوات والأطر الحالية المذكورة في الجدول 1 فقط على استهلاك الطاقة وانبعاثات الكربون خلال المرحلة التشغيلية للأجهزة، وخاصة مرحلة تدريب النموذج. ومع ذلك، نحتاج إلى تقييم دورة حياة أوسع تأخذ في الحسبان أكثر من مجرد الانبعاثات التشغيلية الناتجة عن التدريب لفهم التأثير البيئي لأنظمة الحوسبة فهماً كاملاً. تشمل المكونات الرئيسية الإضافية إلى الآتي:

(1) استهلاك الموارد المتضمنة، والذي يمثل الموارد الطبيعية المستهلكة أثناء تصنيع الأجهزة، مثل الماء والألمنيوم والكوبالت والنحاس والزجاج والذهب والقصدير والليثيوم والزنك والبلاستيك (Gupta et al., 2022)؛

(2) استهلاك الموارد التشغيلية، بما في ذلك موارد مثل المياه المستخدمة لأنظمة التبريد في مراكز البيانات؛
(3) الانبعاثات الناتجة عن الاستدلال، والتي تشمل انبعاثات الكربون من نماذج الذكاء الاصطناعي المدربة مسبقاً عند استخدامها لأداء المهام؛

(4) الانبعاثات المضمنة، في إشارة إلى انبعاثات الكربون المتولدة طوال دورة حياة الجهاز، بما في ذلك التصنيع والنقل وإعادة التدوير في نهاية المطاف (Wu et al., 2022).

يمكن دراسة هذه العوامل من خلال إطار عمل تقييم دورة الحياة، كما هو موضح في المراحل الخمس في الشكل 2، مع الأخذ في الحسبان أن عوامل إضافية قد تُسهم في التأثير البيئي مع استمرار تطور أنظمة الذكاء الاصطناعي. في مرحلتي استخراج المواد الخام والتصنيع من تقييم دورة الحياة، يعتمد تقدير استهلاك الموارد المضمنة بشكل كبير على البيانات المقدمة من الشركات المصنعة أو تقارير الصناعة. ومع ذلك، يوجد حالياً نقص كبير في المعلومات في هذا المجال، مما يُعيق جهود فهرسة هذه الموارد وقياسها كميًا في التطبيقات العملية. نظرًا لتعقيد عمليات التصنيع وتنوعها، ما يزال الحصول على بيانات كاملة لتفسيرها بشكل كامل أمرًا صعبًا. لذا، ينبغي تشجيع جهود مثل استخدام قواعد بيانات جرد دورة الحياة أو تطوير أطر عمل موحدة لإعداد التقارير لتحسين التقديرات في هذا المجال (ليغوزات وآخرون، 2022).

الشكل 2: خمس مراحل في إطار عمل تقييم دورة الحياة لأنظمة الحوسبة.



الشكل 2. خمس مراحل في إطار تقييم دورة حياة أنظمة الحوسبة

بالإضافة إلى استهلاك المواد الخام، يشمل استهلاك الموارد التشغيلية خلال مرحلة الاستخدام من تقييم دورة الحياة الموارد المستخدمة أثناء تشغيل الجهاز، ولا سيما استهلاك المياه في الموقع لأنظمة تبريد مراكز البيانات (بي. لي وآخرون). اقترح باحثون (عام 2023) منهجية دقيقة لتقدير البصمة المائية لنماذج الذكاء الاصطناعي، وحثوا المطورين على مراعاة البصمة المائية للنموذج إلى جانب بصمته الكربونية لتمكين ذكاء اصطناعي أكثر استدامة، نظرًا لمحدودية موارد المياه. كما سلطوا الضوء على المفاضلات

بين المياه والطاقة. على سبيل المثال، يمكن أن تُسهم وفرة الطاقة الشمسية في ارتفاع درجات الحرارة وزيادة الحاجة إلى التبريد، لا سيما في مراكز البيانات بالمناطق الحارة والجافة (كريمي وآخرون، 2022؛ لي وآخرون، 2023). وبالإضافة إلى استهلاك الموارد والانبعاثات التشغيلية الناتجة عن تدريب النموذج في مرحلة الاستخدام من تقييم دورة الحياة، تُشكل الانبعاثات الناتجة عن الاستدلال - وهي المرحلة التي يُستخدم فيها النموذج المُدرَّب للتنبؤ (كرانكشو وآخرون، 2017) - نسبة كبيرة من إجمالي الانبعاثات في دورة حياة نموذج الذكاء الاصطناعي، ناهيك عن تبسيط النموذج، وضبطه، ونشره، وإعادة تدريبه (إيلام وآخرون، 2023؛ وو وآخرون، 2024).

وكما أوضح لأكوست وآخرون (2019)، تُركز أدوات تقدير انبعاثات الكربون الحالية بشكل أساسي على مرحلة تدريب النموذج، متجاهلةً في كثير من الأحيان الطبيعة كثيفة الاستهلاك للطاقة لعملية الاستدلال، خاصةً عند إجرائها بشكل مستمر ومتكرر وعلى نطاق واسع. وينطبق هذا على الأدوات المذكورة في الجدول 1 تشين وآخرون. أكدت دراسة (2023) كذلك أن الانبعاثات الناتجة عن الاستدلال قد تُشكل غالبية انبعاثات الكربون التشغيلية المرتبطة بنماذج الذكاء الاصطناعي التوليدية. وأظهرت الدراسة أن انبعاثات الاستدلال في الخدمات المشابهة لـ ChatGPT قد تُنتج في عام واحد ما يعادل 25 ضعف انبعاثات الكربون الناتجة عن تدريب GPT-3.

تحدث الانبعاثات المتضمنة عبر مراحل متعددة من تقييم دورة الحياة. وتتراكم هذه الانبعاثات من عمليات تشمل بناء مرافق تصنيع الأجهزة، وشراء المواد الخام، وتصنيع الأجهزة وتجميعها وتغليفها ونقلها وإعادة تدويرها (شي وآخرون، 2023). عند تقدير الانبعاثات المتضمنة المرتبطة باستخدام نموذج بلوم (سكاو وآخرون، 2022)، استند لوتشيوني وآخرون (2023) في تقديراتهم إلى معدل استبدال لمدة ست سنوات ومتوسط استخدام 85% لوحدة معالجة الرسومات الخاصة بهم، وخلصوا إلى أن الخوادم ووحدات معالجة الرسومات ساهمت مجتمعةً بـ 11.2 طن من مكافئ ثاني أكسيد الكربون من الانبعاثات المتضمنة، وهو ما يمثل 22.2% من إجمالي البصمة الكربونية للنموذج. وقد انصبَّ معظم الاهتمام على الانبعاثات الناتجة عن استخدام الطاقة خلال مرحلة تدريب النموذج. ومع ذلك، فإن الجوانب الأوسع التي يكشف عنها تقييم دورة الحياة - مثل استهلاك الموارد المتضمنة، واستهلاك موارد التشغيل، والانبعاثات الناتجة عن الاستدلال، والانبعاثات المتضمنة - قد تكون أكثر أهمية (غوبتا وآخرون، 2022). تُشكل هذه الجوانب تحديات بيئية إضافية وتستحق مزيداً من الاهتمام.

منظور جغرافي في استدامة الذكاء الاصطناعي

وفقاً لوكالة الطاقة الدولية (2023أ)، مثَّلت مراكز البيانات 1% من انبعاثات الغازات الدفيئة العالمية المرتبطة بالطاقة في عام 2022، ومن المتوقع أن ترتفع هذه النسبة مع النمو السريع للذكاء الاصطناعي. يُشير هذا القسم إلى ضرورة معالجة التفاوتات الإقليمية في الآثار البيئية لمراكز البيانات. وبشكل أكثر تحديداً، نناقش أهمية دمج المنظور الجغرافي لفهم أشمل للآثار البيئية والاجتماعية للذكاء الاصطناعي على المجتمعات المحلية.

التفاوتات الإقليمية في الآثار البيئية لمراكز البيانات:

يختلف توزيع مراكز البيانات وكثافة انبعاثات الكربون فيها جغرافياً، كما هو موضح في الشكل 3، مما يُشير إلى وجود تفاوتات إقليمية في آثارها البيئية. قدّم لأكوست وآخرون (2019) البيانات الأولية حول كثافة انبعاثات الكربون لمزودي خدمات الحوسبة السحابية الرئيسيين، بما في ذلك منصة جوجل السحابية،

وخدمات أمازون السحابية، ومايكروسوفت أزور. وقد قمنا منذ ذلك الحين بتحديث هذه البيانات لتعكس أحدث القيم. في حين تستفيد بعض المناطق اقتصادياً من هذه المرافق، تتحمل مناطق أخرى أعباءً بيئية بسبب كثافة الكربون العالية فيها.




Figure 3. Distribution and carbon intensity of data centers from major cloud computing providers: Google Cloud Platform, Amazon Web Services, and Microsoft Azure. Circle size indicates the count of data centers, and color represents carbon intensity. More details on location and carbon intensity can be found in Appendix.

غالباً ما تنجم هذه التفاوتات عن اختلافات في مصادر الطاقة والبنية التحتية واللوائح المحلية (دودج وآخرون، 2022). فعلى الرغم من التزامات كبرى شركات الحوسبة السحابية، مثل جوجل، بتحقيق أهداف الطاقة الخالية من الكربون بحلول عام 2030، إلا أنها ما تزال تعتمد حالياً على مصادر طاقة تُنتج انبعاثات كربونية (جوجل، 2023). علاوة على ذلك، حتى في المناطق التي تُنتج طاقة منخفضة الكربون، قد تأتي الطاقة المستهلكة محلياً من مصدر مختلف وأكثر كثافة للكربون. يحدث هذا عندما تُصدر المنطقة طاقة "نظيفة" منتجة محلياً وتستورد طاقة "أكثر تلويثاً" لتلبية الطلب المحلي (شي وآخرون، 2023). وقد برز استهلاك المياه كأحد الشواغل الرئيسية الأخرى المتعلقة بعمليات مراكز البيانات (بي. لي وآخرون، 2019) (أوساكا، 2023). على سبيل المثال، تضاعف استهلاك جوجل للمياه في مدينة ذا داليس بولاية أوريغون ثلاث مرات تقريباً خلال السنوات الخمس الماضية، وتستهلك مراكز بياناتها الآن أكثر من ربع إجمالي المياه المستخدمة في المدينة (روغواي، 2023).

يُعدّ مؤشر كفاءة استخدام المياه (WUE) مقياساً شائعاً لتقييم تأثيره، حيث يحسب كمية المياه المستخدمة (باللترات) سنوياً لترطيب وتبريد مركز البيانات نسبةً إلى إجمالي استهلاك الطاقة السنوي بالكيلوواط/ساعة لتشغيل معدات تكنولوجيا المعلومات فيه. يشير انخفاض مؤشر كفاءة استخدام المياه إلى كفاءة أفضل في استخدام المياه. بالنظر إلى قيم مؤشر كفاءة استخدام المياه المتاحة للجمهور لمراكز بيانات مايكروسوفت في جميع أنحاء الولايات المتحدة المتجاورة، نلاحظ في الشكل 4 أن هذه الأرقام قد تختلف بما يصل إلى 10 أضعاف حسب المنطقة.




Figure 4. Water usage effectiveness for Microsoft data centers in the contiguous United States, reflecting the only publicly available data. Lower values indicate higher effectiveness. Data sourced from Microsoft (2016) for the fiscal year 2023 (07-2023-06-2023).

تتمتع المنشآت في المناطق القاحلة، مثل أريزونا، بمؤشرات أعلى لكفاءة استخدام المياه، مما يُبرز تأثيرها غير المتناسب على موارد المياه المحلية ويثير مخاوف محتملة بشأن العدالة البيئية للمجتمعات المجاورة. تُبرز هذه التباينات ضرورة مراعاة السياقات البيئية المحلية عند تقييم الآثار الأوسع نطاقاً لمراكز البيانات على الاستدامة. ويمكن لتقييم مُراعي للجوانب الجغرافية، كما هو موضح في القسم الاتي، أن يُساعد صُنّاع القرار على فهم كيفية تأثير مراكز البيانات على السكان المحليين، بما في ذلك موارد الطاقة والمياه، كما يُمكن أن يُسهم في اتخاذ قراراتٍ مُستنيرة بشأن مواقع مراكز البيانات المُستقبلية للتخفيف من الأضرار المُحتملة.

استخدام الطاقة في سياق اجتماعي:

بالرجوع إلى السؤال المطروح في بداية هذه الورقة، وباستخدام استهلاك الطاقة في ChatGPT كمثال، يُشير كولبرت (2024) إلى أن ChatGPT يتلقى ما يقرب من مئتي مليون طلب يوميًا، ويُقدّر استهلاكه بأكثر من نصف مليون كيلوواط ساعة يوميًا. وبافتراض متوسط كثافة الكربون العالمي البالغ 436 غرامًا من ثاني أكسيد الكربون لكل كيلوواط ساعة (إمبر، 2023)، فإن هذا يُترجم إلى ما يقرب من 1.09 غرام من انبعاثات ثاني أكسيد الكربون لكل استعمال، أي أكثر من ضعف انبعاثات بحث جوجل (بيرنر-زلي، 2020). من المهم ملاحظة أن هذا التقدير لا يشمل سوى الانبعاثات الناتجة عن الاستدلال. ويُقدّر دي فريس (2023) استهلاك الطاقة لـ ChatGPT بنحو عشرة أضعاف استهلاك بحث جوجل، أي 2.9 واط/ساعة لكل استعمال، مقارنةً بـ 0.3 واط/ساعة لجوجل. أما نماذج مثل BLOOM، فتستهلك طاقةً أكبر، تصل إلى حوالي 4 واط/ساعة لكل طلب. وبناءً على هذه السيناريوهات، قد يصل استهلاك الطاقة لتشغيل بحث جوجل المدعوم بالذكاء الاصطناعي إلى 9 واط/ساعة لكل استعمال، ما قد يتطلب حوالي 29 تيراواط/ساعة سنويًا.

للمقارنة، يُصنف هذا الاستهلاك بين استهلاك الإكوادور ونيجيريا السنوي للكهرباء، وفقًا لوكالة الطاقة الدولية (2023ب). يتطلب تفسير إحصاءات استهلاك أنظمة الحوسبة هذه فهمًا للسياق، لأنها قد تعكس واقعًا مختلفًا تمامًا بين الدول. فعلى سبيل المثال، قد يعادل الاستهلاك اليومي للطاقة في ChatGPT الاستهلاك السنوي للطاقة لثلاثة أشخاص في قطر أو ما يقارب 2300 شخص في الصومال. يوضح الشكل 5أ هذه المقارنة من خلال رسم خريطة للاستهلاك العالمي اليومي للطاقة في ChatGPT مقابل الاستهلاك السنوي للطاقة للأفراد حسب الدولة. بينما يعرض الشكل 5ب هذه الأرقام نسبةً إلى حجم السكان. فعلى سبيل المثال، عندما يساوي الاستهلاك اليومي للطاقة في ChatGPT الاستهلاك السنوي لثمانية أشخاص في جرينلاند وبلجيكا، فإنه يمثل 0.01% من سكان جرينلاند، ولكنه أقل من 0.0001% من سكان بلجيكا. وهذا يعني أن الدول ذات الكثافة السكانية الأقل تتأثر بشكل أكبر بمستوى استهلاك الطاقة نفسه. نظرًا للنفقات الكبيرة في توزيع استهلاك الطاقة للفرد على مستوى العالم، فإن تفسير هذه الإحصاءات بشكل موحد لا يعكس الأثر الاجتماعي في مختلف المناطق. كما تلعب الفوارق الاقتصادية دوراً محورياً في هذا السياق، حيث تتمتع الدول الأكثر ثراءً عادةً بموارد أفضل وإمكانية وصول أكبر إلى التقنيات المستدامة، بينما غالباً ما تكافح المناطق الأفقر لتلبية احتياجاتها الأساسية من الطاقة (ياو وآخرون، 2020).




Figure 5. Comparison of ChatGPT's global daily energy consumption with per capita energy usage by country in 2021: a) absolute values and b) relative values, expressed as a percentage of the total population. A logarithmic color scale is used. Data sources: primary energy consumption per capita (Ritchie, Rosado, et al., 2023) and population (Ritchie, Rod s-Guirao, et al., 2023).

لا تُقدِّم تقارير الاستدامة المتاحة حاليًا لنماذج الذكاء الاصطناعي سوى بيانات إجمالية حول استهلاك الطاقة وانبعاثات الكربون. مع ذلك، نحتاج إلى تقييمات تراعي الموقع الجغرافي لمراكز البيانات المعنية لفهم أعمق. ينبغي أن يشمل ذلك على الأقل دراسة مؤشرات مثل نصيب الفرد من استهلاك الطاقة والمياه للسكان المحليين، بالإضافة إلى مراعاة الظروف البيئية والسياقات الاجتماعية والاقتصادية المختلفة. حتى الآن، لا توجد إحصاءات خاصة بكل دولة حول استخدام ChatGPT. مع ذلك، أظهرت دراسة تشين وآخرون (2024) أن أداء النموذج غير متكافئ في مهام مثل التعرف على اللغة، مع أداء ضعيف بشكل خاص في اللغات الأفريقية. لذا، قد تواجه الدول ذات الأداء الأضعف والطلبات الأقل انبعاثات ثاني أكسيد الكربون أعلى للفرد بشكل غير متناسب. تُبرز هذه النتائج ضرورة مراعاة استهلاك الطاقة في سياق مجتمعي أوسع، حيث لا يتوزع الوصول إلى أدوات الذكاء الاصطناعي ومزاياها بالتساوي.

تحديات استدامة نماذج الذكاء الجغرافي المكاني

على عكس نماذج اللغة الكبيرة التي تعمل على مجموعات بيانات نصية موحدة، تستفيد نماذج الذكاء الجغرافي المكاني من البيانات الجغرافية المكانية التي تتنوع بطبيعتها. يشمل ذلك النصوص، وصور الاستشعار عن بُعد، وبيانات المسارات والشبكات، وغيرها. علاوة على ذلك، تُضيف السمات البيئية المتباينة في المناطق المختلفة تعقيدات، لأن الأنماط الملاحظة في موقع ما قد لا تنطبق بسهولة على موقع آخر. يتناول هذا القسم الخصائص الفريدة لنماذج الذكاء الجغرافي المكاني، مُسلطاً الضوء على تحديات استدامتها نظراً لتنوعها المكاني وتعدد وسائطها.

الحاجة المستمرة لإعادة التدريب:

في سياق استدامة الذكاء الجغرافي المكاني، تتمثل إحدى الخصائص الفريدة في الطبيعة الديناميكية للبيانات الجغرافية المكانية، والتي تخضع لتغيرات زمنية نتيجة لتطور البيئات المادية، والظروف الحضرية، والتغيرات الثقافية، وأنماط الهجرة، وما إلى ذلك (لي وآخرون، 2024). على سبيل المثال، يتطلب نموذج تصنيف الغطاء الأرضي الحضري إعادة تدريب متكررة نظرًا للمشاريع الإنشائية والبنية التحتية الجديدة التي تُنشأ باستمرار. غالبًا ما يُشكل التباين المكاني - الذي يُمثل تباين الملاحظات وأحجام التأثير عبر المكان - تحديات أمام تعميم نماذج الذكاء الاصطناعي الجغرافي على مناطق جديدة (H. Li et al., 2023). وقد أدى هذا التحدي إلى تطوير أساليب نمذجة محلية (مثل الانحدار الموزون جغرافيًا) وأساليب تعلم آلي مُقابلة (مثل الغابة العشوائية الموزونة جغرافيًا).

ونظرًا لأن أساليب التعلم العميق الأكثر تقدمًا من غير المرجح أن تُعالج هذا التحدي بشكل كامل، فقد تتطلب نماذج الذكاء الاصطناعي الجغرافي في كثير من الأحيان دورة جديدة تمامًا من التدريب والضبط والنشر بشكل أكثر تكرارًا للحفاظ على أهميتها (Janowicz, 2023). وبهذه الطريقة، من المتوقع أيضًا أن تستهلك نماذج الذكاء الاصطناعي الجغرافي طاقة أكبر من نماذج الذكاء الاصطناعي التقليدية. وهذا بمثابة تذكير لمجتمع الذكاء الاصطناعي الجغرافي بضرورة دمج معطيات الاستدامة في تطوير وصيانة نماذج الذكاء الاصطناعي الجغرافي لضمان فعاليتها على الرغم من الطبيعة الديناميكية للبيانات الجغرافية المكانية.

مقارنة بين تكاليف وفوائد نماذج الذكاء الاصطناعي الجغرافية ذات النطاق المكاني:

بالمقارنة مع نماذج التعلم الخطي، تميل نماذج الذكاء الاصطناعي الجغرافية إلى أن تكون أكثر تحديدًا في نطاق مكاني معين. على سبيل المثال، طور كاستريجون وآخرون (2023) نموذجًا للتنبؤ بحرائق الغابات قائمًا على التعلم الآلي، ويركز على ولاية كاليفورنيا. عند تقييم المفاضلة بين التكاليف والفوائد، يجب مراعاة المناطق التي تستفيد من النموذج وتلك التي تتحمل التكاليف البيئية. على سبيل المثال، قد لا يؤثر نموذج عالمي يتنبأ بانتشار كوفيد-19 مخاوف أخلاقية بشأن مناطق تدريبه ونشره، لأنه يعود بالنفع على سكان العالم أجمع. أما بالنسبة لنموذج يتنبأ بحالة المرور في لوس أنجلوس، فلا ينبغي أن تتحمل دول بعيدة في أنحاء العالم التكاليف البيئية لتدريبه ونشره. يجب أن يراعي تحليل التكلفة والعائد لنماذج الذكاء الاصطناعي الجغرافي عوامل مثل قابلية التكيف مع مختلف النطاقات المكانية، ودقة الأداء المكاني، وتوزيع التكاليف (مثل الموارد الحاسوبية المستخدمة في التدريب والاستدلال)، وتوزيع الفوائد (مثل تحسين الخدمات، وتقليل المخاطر).

واستكمالاً لإطار تحليل التكلفة والعائد الذي اقترحه بوماساني وآخرون (2021) نقترح نسبة التكلفة إلى الفائدة المكانية (SBCR) المصممة خصيصًا لنماذج الذكاء الاصطناعي الجغرافي ذات النطاق المكاني. تقارن هذه النسبة، الموضحة في المعادلة 1، بين السكان المستفيدين (P_{ij}) والسكان المتأثرين (P_{ij}). وهي تتضمن عامل التفاعل (I_{ij}) من نموذج الجاذبية (فوثرينغهام وأوكيلي، 1989)، كما هو موضح في المعادلة 2، ليعكس التفاعل المكاني بين المنطقتين i و j . هنا، يتم تطبيق I بين 0 و 1. تشير القيمة 1 إلى التفاعل الذاتي، بينما تشير القيم الأقرب إلى 0 إلى تفاعل منخفض. لتجنب مشكلة القسمة على صفر عندما تكون مواقع التدريب والاستفادة متطابقة، نضبط I_{ij} في هذه الحالات.

$$SBCR = \frac{P_{bi}}{\sum_j \frac{P_{ej}}{I_{ij}}} \quad (1)$$

$$I_{ij} = \frac{P_i \cdot P_j}{D_{ij}^2} \quad (2)$$

نظرًا لعدم وجود تقارير استدامة حتى الآن لأي من نماذج الذكاء الاصطناعي الجغرافي، ناهيك عن الكشف عن مواقع مراكز البيانات المستخدمة في تدريبها، نقدم هنا بعض الأمثلة الافتراضية لتوضيح معامل الاستدامة القائم على الموقع (SBCR). لنفترض نموذجًا للتنبؤ بحركة المرور مصممًا لمدينة لوس أنجلوس ويخدم سكانها البالغ عددهم 3.82 مليون نسمة، بينما يتم تدريبه في لاس فيغاس (عدد سكانها 0.66 مليون نسمة) وكولومبوس، أوهايو (عدد سكانها 0.91 مليون نسمة). باتباع صيغة SBCR، نحسب عامل التفاعل I_{ij} بين لوس أنجلوس وكل موقع تدريب، مع الأخذ في الحسبان مسافات تقارب 360 كم إلى لاس فيغاس و3600 كم إلى كولومبوس.

في هذه الحالة، سيكون معامل الاستدامة القائم على الموقع قريبًا من الصفر نظرًا لُبُعد مواقع التدريب. للمقارنة، فإن نموذجًا تم تدريبه والافادة منه محليًا في لوس أنجلوس سيحقق نسبة تكلفة-عائد (SBCR) تساوي 1. أما إذا كان نموذج ما، مثل نموذج التنبؤ بحالات كوفيد-19، يفيد سكان العالم أجمع أثناء تدريبه في لوس أنجلوس، فإن نسبة التكلفة-العائد ستتجاوز 1 بشكل ملحوظ. تُعد هذه النسبة مقياسًا نسبيًا، يسمح بإجراء مقارنات بين سيناريوهات مختلفة للنموذج نفسه، ويسهل اتخاذ قرارات مستنيرة بشأن اختيار مراكز البيانات واستراتيجيات نشر النماذج. في نهاية المطاف، ينبغي تقييم هذه النسبة المُراعية للموقع الجغرافي، إلى جانب عوامل أخرى في تحليل التكلفة-العائد، تقييمًا دقيقًا قبل اعتماد هذه النماذج ونشرها.

اعتماد نماذج (الأساس الجغرافي):

يتم دمج نماذج الأساس (FMs) بشكل متزايد في البحوث الجغرافية المكانية مع التطورات الحديثة في الذكاء الاصطناعي الجغرافي. على سبيل المثال، طُبقت نماذج ChatGPT و GPT في مهام تشمل تفسير صور الاستشعار عن بُعد (Guo et al., 2024)، وإنشاء الخرائط (Zhang, He, et al., 2024)، وإثراء محتوى الخرائط (Juhász et al., 2023)، وتحديد الموقع الجغرافي للصور (Z. Manvi, Khanna, Burke, 2024; Zhou et al., 2024)، والتنبؤ بمؤشرات الاستدامة (Manvi, Khanna; Mai et al., 2024)، والتنقل باستخدام الرؤية واللغة (J. Chen et al., 2024)، والاستعلام والتحليل المكاني (Zhang, Wei, et al., 2024). ويمكن لهذه النماذج أن تعمل كأدوات تنقية وتحويل وتوليد واستدلال في هذه المهام (Wang et al., 2024). على الرغم من التكاليف الحسابية المرتفعة، تتمتع نماذج الأساس الجغرافي بميزة رئيسية: إذ يُمكنها تدريبها المسبق المكثف من تطبيق معارفها السابقة على مهام جديدة، مما يقلل الحاجة إلى مزيد من التدريب ويحد من انبعاثات الكربون الإجمالية (يومانساني وآخرون، 2021).

وبالمثل، عند دمجها مع المعرفة المتخصصة في المجال، يمكن لنماذج الأساس الجغرافي (Geo-FMS) تحسين كفاءة ودقة مجموعة واسعة من المهام اللاحقة، مما يسهم في استدامة البحوث الجغرافية المكانية على المدى الطويل (ماي، 2024؛ شي وآخرون، 2023). ومع ذلك، يطرح اعتماد نماذج الأساس الجغرافي العديد من التحديات، لا سيما بسبب الطبيعة متعددة الوسائط للمهام الجغرافية المكانية، كما أشار ماي وآخرون (2024). ففي مجال الذكاء الاصطناعي الجغرافي، تمتلك كل وسيلة - نص، أو صور استشعار عن بُعد أو صور عرض الشوارع، أو مخططات معرفية، أو بيانات مسار - تفاصيل هندسية ودلالية مهمة تتطلب تمثيلات فريدة للاستخدام الأمثل. ومن الأمثلة المبكرة على نماذج الاستشعار عن بُعد الجغرافية (Geo-FM) نموذج Prithvi-100 M للاستشعار عن بُعد، والذي تم تدريبه على مجموعات بيانات صور الأقمار الصناعية واسعة النطاق. وتشمل مهامه اللاحقة الكشف عن آثار الحروق، ورسم خرائط الفيضانات، وتصنيف المحاصيل (Jakubik et al., 2023). على الرغم من أن تطوير نموذج جغرافي شامل ما يزال يمثل تحديًا، إلا أنه ينبغي تشجيع الاستفادة من النماذج المدربة مسبقًا لتمكين إعادة استخدام التمثيلات المُتعلمة وتقليل البصمة الكربونية لتدريب نماذج جديدة من الصفر.

التوجهات المستقبلية

تُبذل جهود عالمية لوضع لوائح وإرشادات للذكاء الاصطناعي الأخلاقي والمستدام (جوبين وآخرون، 2019). على سبيل المثال، أصدر الكونجرس الأمريكي قانون التأثيرات البيئية للذكاء الاصطناعي في فبراير 2024 (الكونجرس الأمريكي، 2024)، ودخل قانون الذكاء الاصطناعي للاتحاد الأوروبي (الاتحاد الأوروبي، 2024) حيز التنفيذ في أغسطس 2024. كما أصدرت اليونسكو ومنظمات دولية أخرى إرشادات (اليونسكو، 2021) لمعالجة التأثير البيئي لأنظمة الذكاء الاصطناعي. ومن المتوقع أن تساعد هذه الإرشادات واللوائح الشركات والمؤسسات والباحثين والمطورين وغيرهم على تعزيز الذكاء الاصطناعي المستدام. ويجب اتخاذ تدابير استباقية لإعطاء الأولوية للإنصاف والشفافية والاستدامة في استخدام تقنيات الذكاء الاصطناعي (جاي وآخرون، 2024).

يُحدد هذا القسم التوجهات المستقبلية، بما في ذلك إعداد تقارير أكثر منهجية، وتقييمات تراعي البُعد الجغرافي، وحلول لخفض الانبعاثات من خلال زيادة الكفاءة، والتي يُمكن تطبيقها في مجالي الذكاء الاصطناعي الجغرافي والذكاء الاصطناعي بشكل عام.

نحو إعداد تقارير منهجية وتقييمات تراعي البُعد الجغرافي:

على الرغم من توفر أدوات وأطر تقدير الانبعاثات الموضحة انفا ، إلا أن إعداد تقارير منهجية عن البصمة الكربونية ما يزال غير شائع في المنشورات البحثية. علاوة على ذلك، وكما هو مبين سابقاً، ما تزال التقارير الحالية عن الانبعاثات تفتقر إلى العديد من العناصر الأساسية:

- (1) الشفافية فيما يتعلق بمصادر البيانات وتكوينات النماذج المكانية والزمانية؛
- (2) تقييم دورة الحياة الذي يشمل عوامل مثل استهلاك المياه (وغيرها من الموارد الطبيعية)، والانبعاثات أثناء استنتاج النموذج ونشره، والانبعاثات المتضمنة طوال دورة حياة نماذج الذكاء الاصطناعي؛
- (3) تحليل شامل للتكلفة والعائد مع مراعاة البُعد الجغرافي.

في المستقبل، ومع توفر المزيد من المعلومات حول استهلاك مراكز البيانات للطاقة والموارد، يمكن استخدام مقاييس مثل نصيب الفرد من الكهرباء والمياه في مراكز البيانات نسبةً إلى عدد السكان المحليين. تأخذ هذه التقييمات المُراعية للبُعد الجغرافي في الحسبان البيانات المتنوعة التي تعمل فيها أنظمة الذكاء الاصطناعي، مما يوفر فهمًا شاملاً لتأثيرها البيئي. بالإضافة إلى معالجة ثغرات الإبلاغ المنهجية وتنفيذ

التقييمات المُراعية للبعد الجغرافي، قد تُسهم مبادرات مثل إنشاء لوحات صدارة للخوارزميات الموفرة للطاقة (هندرسون وآخرون، 2020)، وتطوير أنظمة اعتماد للذكاء الاصطناعي الأخضر (دودج وآخرون، 2022)، وتوفير شارات الاستدامة لأوراق المؤتمرات (شي وآخرون، 2023)، في تعزيز ممارسات البحث المستدامة والمسؤولة في هذا المجال.

نحو الذكاء الاصطناعي الجغرافي منخفض الانبعاثات وفعال من حيث الموارد:

تقدم التطورات الحديثة في مجال التوليد المعزز بالاسترجاع (RAG) (لويس وآخرون، 2020)، والذي يدمج النماذج القائمة على الاسترجاع والنماذج التوليدية في معالجة اللغة الطبيعية، نهجًا واعدًا لتعزيز استدامة الذكاء الاصطناعي. تستخدم تقنية RAG مُسترجعًا مُدرَّبًا مُسبقًا لاستخراج المعلومات ذات الصلة بكفاءة من قاعدة بيانات مُحدَّدة، مما يُحسِّن قدرة النموذج على توليد استجابات صحيحة. ومن خلال دمج نماذج الوظائف مع مستودعات المعرفة الخارجية المُحدَّثة، مثل مخططات المعرفة (Janowicz et al., 2022)، تتمتع الأنظمة القائمة على RAG بإمكانية تقليل الموارد الحاسوبية اللازمة للتدريب والاستدلال. فبدلًا من الاعتماد فقط على نماذج اللغة واسعة النطاق والمُستهلكة للموارد، يُمكن لتقنية RAG توفير آلية استرجاع أكثر كفاءة للوصول إلى المعرفة الخارجية، وتحسين دقة النتائج وملاءمتها في الوقت نفسه. تشمل الجهود الإضافية في أبحاث الذكاء الاصطناعي الحديثة تقنيات التكميم، التي تُحوّل معلمات النموذج من أعداد عشرية إلى أعداد صحيحة ذات عرض بت أقل، مع الحفاظ على دقة النموذج (Nagel et al., 2021). هذا الانخفاض في متطلبات المعالجة لا يُقلِّل فقط من استهلاك الطاقة أثناء التدريب والاستدلال، بل يُقلِّل أيضًا من تكاليف البنية التحتية المرتبطة بصيانة وتشغيل مراكز البيانات. من الأمثلة على ذلك تطوير نماذج LLM أحادية البت (Ma et al., 2024)، حيث يتخذ كل مُعامل شكلًا ثلاثيًا بقيم {-1، 0، 1}. تُقلِّل هذه الطريقة بشكل كبير من متطلبات الحساب مع الحفاظ على الأداء. يُكمِّل تقليم النموذج، الذي يُزيل الأوزان أو الخلايا العصبية الأقل أهمية من الشبكة العصبية، عملية التكميم عن طريق تقليل حجم النموذج وتعقيده (Blalock et al., 2020). أسفرت الجهود الحديثة، مثل تلك التي بذلها باغانيني وفورد (2020)، عن نماذج أسرع وأكثر كفاءة في استهلاك الطاقة. تُشكل هذه التقنيات مجتمعةً بداية نموذج حوسبة جديد، وتُوفّر وسائل للحدّ بشكلٍ كبير من الأثر البيئي لأنظمة الذكاء الاصطناعي.

الخلاصة

منذ إطلاق ChatGPT في نوفمبر 2022، حظيت نماذج الذكاء الاصطناعي التوليدية باهتمام جماهيري غير مسبوق. وقد دفعت المناقشات المتزايدة حول استهلاكها للطاقة وانبعاثات الكربون مجتمعًا أكثر وعيًا بالبيئة إلى الدعوة إلى استدامة الذكاء الاصطناعي. في هذه الورقة، نستكشف التقاطع بين الجغرافيا لاستدامة الذكاء الاصطناعي واستدامة الذكاء الاصطناعي الجغرافي. نقدم نظرة عامة على الأدوات والأطر المتاحة لتقدير الانبعاثات، ومقاييس التقييم، والأطر التحليلية. بعد ذلك، نُحدد التحديات من هذه النظرة العامة ومن أدبيات التعلّم الآلي الحديثة، بما في ذلك الشفافية والثقة في مصادر البيانات، وتكوينات النماذج المكانية والزمانية، وتقييم دورة الحياة الذي يشمل استهلاك الموارد بما يتجاوز معطيات الطاقة والكربون فقط. من خلال إدخال منظور جغرافي في النقاش الدائر حول استدامة الذكاء الاصطناعي، نسعى إلى تسليط الضوء على جوانب مُغفلة في مجال التعلّم الآلي فيما يتعلق بالفوارق الإقليمية، وإشراك مجتمع الذكاء الاصطناعي الجغرافي. ونشير إلى تفرد نماذج الذكاء الاصطناعي الجغرافي في سعيها لتحقيق أهداف الاستدامة، لا سيما معالجة التباين المكاني والطبيعة متعددة الوسائط للبيانات الجغرافية المكانية، إلى جانب التحديات المصاحبة. وأخيرًا، نناقش التوجهات المستقبلية لكل من الذكاء الاصطناعي الجغرافي ومجال

الذكاء الاصطناعي بشكل عام فيما يتعلق بالإبلاغ المنهجي، والتقييم الواعي جغرافياً، والحلول المحتملة للحد من الأثر البيئي لأنظمة الذكاء الاصطناعي، مثل اعتماد نظام RAG وتطبيق تقنيات التكميم والتقليل الناشئة. ونهدف من خلال هذه الورقة إلى تقديم رؤية شاملة لجهود الاستدامة الحالية، وتشجيع أبحاث الذكاء الاصطناعي الجغرافي على أن تصبح أكثر وعياً بانبعاثات الكربون في المستقبل.

في سياق الجغرافيا من أجل استدامة الذكاء الاصطناعي، نأمل في الاعتراف بالفوارق الإقليمية ودمج التقييمات المراعية للمعطيات الجغرافية في تقييم الآثار البيئية في أبحاث الذكاء الاصطناعي العامة. وفي الوقت نفسه، وفي سياق استدامة الذكاء الاصطناعي الجغرافي، ندعو إلى تبني أدوات من مجال الذكاء الاصطناعي العام في الذكاء الاصطناعي الجغرافي لوضع ممارسات منهجية لإعداد التقارير المتعلقة بتكوينات النماذج وانبعاثات الكربون. ونظراً لموقع مجتمع الذكاء الاصطناعي الجغرافي عند تقاطع الجغرافيا والذكاء الاصطناعي، فإنه ينبغي عليه التوافق مع الدعوة إلى الذكاء الاصطناعي الأخضر والمساهمة بفعالية في تحقيق الهدف الأسمى المتمثل في الاستدامة.