

"الذكاء الاصطناعي مدخلًا لتعزيز الحوكمة التعليمية الخضراء وبناء الشراكات الدولية المستدامة في مؤسسات التعليم العالي: ليبيا حالة تطبيقية ضمن سياق عالمي"

¹ Saifallah Shibani Elhatab¹ ID, ² Ghadeer Zidan Suleiman² ID

¹ إدارة التعاون الدولي، الهيئة الليبية للبحث العلمي، طرابلس، ليبيا، Saifelhatab@gmail.com
² قسم علم الحاسوب، كلية الأمير الحسين بن عبد الله الثاني لتكنولوجيا المعلومات، جامعة آل البيت، المفرق، الأردن.

<https://orcid.org/0009-0001-6462-2138>, 2220901006@st.aabu.edu.jo

Artificial Intelligence as an Approach to Enhancing Green Educational Governance and Building Sustainable International Partnerships in Higher Education Institutions: Libya as an Applied Case within a Global Context

Saifallah Shibani Elhatab¹ ID, Ghadeer Zidan Suleiman² ID

¹ Department of International Cooperation, Libyan Authority for Scientific Research, Tripoli, Libya.

Email: Saifelhatab@gmail.com

ORCID: <https://orcid.org/0009-0001-2643-4152>

² Department of Computer Science, Prince Hussein Bin Abdullah II Faculty of Information Technology, Al al-Bayt University, Mafrq, Jordan.

Email: 2220901006@st.aabu.edu.jo

ORCID: <https://orcid.org/0009-0001-6462-2138>

تاريخ الاستلام: 2026/04/01 تاريخ المراجعة 2026 /04/30 تاريخ القبول: 2026/05/13- تاريخ النشر: 2026 /06/16

الملخص:

تسعى هذه الدراسة إلى مناقشة الكيفية التي يمكن من خلالها توظيف الذكاء الاصطناعي في دعم الحوكمة التعليمية الخضراء داخل مؤسسات التعليم العالي، وبما يساعد هذه المؤسسات على بناء شراكات دولية أكثر استدامة وارتباطًا باحتياجات التحول البيئي. فالدور الذي تؤديه الجامعات اليوم لم يعد يقتصر على التعليم ونقل المعرفة داخل القاعات الدراسية، بل أصبح يمتد إلى المشاركة في قضايا التنمية المستدامة، وتطوير القدرات البحثية، وتوجيه المعرفة العلمية نحو مجالات الطاقة النظيفة وخفض الانبعاثات. ومن هذا المنطلق، تقترح الدراسة إطارًا تحليليًا يساعد على قراءة جاهزية الدول للدخول في شراكات خضراء، اعتمادًا على مؤشرات عالمية ترتبط بالطاقة والكهرباء والانبعاثات ومصادر الطاقة المتجددة ومنخفضة الكربون. وقد جرى توظيف هذه المؤشرات في بناء مؤشر مركب يوضح مستوى الجاهزية، إلى جانب استخدام نماذج تنبؤية وتصنيفية تساعد على استشراف الاتجاهات المستقبلية لهذه الجاهزية. وتتناول الدراسة ليبيا بوصفها حالة تطبيقية ضمن سياق عالمي أوسع، بما يسمح بفهم موقعها وفرصها في مجال الشراكات التعليمية والبحثية الخضراء. وتشير النتائج إلى أن الذكاء الاصطناعي يمكن أن يقدم دعمًا عمليًا لصانع القرار في التعليم، من خلال تحويل البيانات البيئية والاقتصادية إلى مؤشرات تساعد على اختيار الشركاء الدوليين وتحديد أولويات التعاون. كما توضح الحالة الليبية أهمية توجيه هذه الشراكات نحو بناء القدرات المؤسسية، خاصة في مجالات الطاقة النظيفة وإدارة الانبعاثات. وتخلص الدراسة إلى أن دمج الذكاء الاصطناعي في الحوكمة التعليمية الخضراء يمكن أن يمنح مؤسسات التعليم العالي قدرة أكبر على بناء شراكات أكثر وعيًا واستدامة وعدالة، خصوصًا عندما تستند قرارات التعاون إلى بيانات واضحة ومؤشرات قابلة للتفسير.

الكلمات المفتاحية: الذكاء الاصطناعي؛ الحوكمة التعليمية الخضراء؛ الشراكات الدولية المستدامة؛ مؤسسات التعليم العالي؛ الدبلوماسية الاقتصادية الخضراء؛ التنمية المستدامة؛ ليبيا.

Abstract:

This study explores how artificial intelligence can be used to support green educational governance in higher education institutions and to strengthen their ability to develop sustainable and effective international partnerships. It is based on the view that universities are no longer

limited to their traditional teaching role, but have become key contributors to sustainable development through knowledge production, capacity building, and the orientation of research toward clean energy and low-carbon transition issues. In light of the growing need for data-driven partnership decisions, the study proposes an analytical framework for assessing countries' readiness to engage in green partnerships that support sustainable education, knowledge transfer, and environmental innovation. The study draws on a set of global indicators related to energy, electricity, emissions, and renewable and low-carbon energy sources to develop a composite index reflecting the readiness of green partnerships. Predictive and classification models are also employed to examine future readiness levels, with Libya presented as an applied case within a broader global context. The findings show that artificial intelligence can serve as a practical decision-support tool in the education sector by transforming environmental and economic data into usable indicators that help identify suitable international partners and set cooperation priorities. The Libyan case further highlights the importance of directing educational and research partnerships toward institutional capacity building, particularly in the areas of clean energy and emissions management. The study concludes that integrating artificial intelligence into green educational governance can enhance the ability of higher education institutions to build partnerships that are more informed, sustainable, and equitable, especially when cooperation decisions are guided by clear data and interpretable indicators.

Keywords: Artificial Intelligence; Green Educational Governance; Sustainable International Partnerships; Higher Education Institutions; Green Economic Diplomacy; Sustainable Development; Libya.

1. المقدمة

أصبحت مؤسسات التعليم العالي في العقد الأخير طرفاً محورياً في قيادة التحول نحو التنمية المستدامة، ليس فقط من خلال التعليم والبحث العلمي، بل أيضاً من خلال الحوكمة المؤسسية، وبناء الشراكات، وتوجيه المعرفة نحو معالجة التحديات البيئية والاقتصادية والاجتماعية المعقدة (Chankseliani & McCowan, 2021; Serafini et al., 2022; Trevisan et al., 2023).

وفي ظل تصاعد الضغوط العالمية المرتبطة بتغير المناخ، وأمن الطاقة، والتحول منخفض الكربون، لم تعد الجامعات مطالبة بإنتاج المعرفة فحسب، بل أصبحت مطالبة كذلك بتقديم نماذج عملية تساعد صانع القرار على بناء شراكات أكثر وعياً واستدامة (Leal Filho et al., 2021; García-Feijoo et al., 2020; De la Poza et al., 2021). وقد بينت الأدبيات الحديثة أن دمج الاستدامة في التعليم العالي يتطلب انتقالاً من المبادرات الجزئية إلى الحوكمة الشاملة التي تربط بين السياسات المؤسسية، والبيانات، والبحث العلمي، والمسؤولية المجتمعية (Leal Filho et al., 2021; Serafini et al., 2022; Blasco et al., 2021).

خلال العقد الماضي، لعبت مؤسسات التعليم العالي دوراً رئيسياً في قيادة التحول نحو التنمية المستدامة، ليس فقط عبر التعليم والبحث، بل أيضاً من خلال الإدارة المؤسسية، وبناء الشراكات، وتوجيه المعرفة لمعالجة التحديات البيئية والاقتصادية والاجتماعية المعقدة (Chankseliani & McCowan, 2021; Serafini et al., 2022; Trevisan et al., 2023).

تُظهر الدراسات الحديثة أن توظيف الذكاء الاصطناعي في التعليم العالي لم يعد مقتصرًا على تحسين عمليتي التدريس والتعلم، بل امتد ليشمل مجالات أوسع داخل المؤسسة الجامعية، مثل دعم الإدارة، وتحليل السياسات، وترشيده توجيه الموارد، وتعزيز قدرة الجامعات على التعامل مع التحولات الرقمية والخضراء في الوقت نفسه (Crompton & Burke, 2023; Chiu et al., 2023; Katsamakos et al., 2024).

وفي المقابل، تشير الأدبيات المعاصرة إلى أن العلاقة بين الذكاء الاصطناعي وأهداف التنمية المستدامة في مؤسسات التعليم العالي ما تزال بحاجة إلى أطر تطبيقية قابلة للقياس، خاصة في المجالات التي تتطلب وصل البيانات البيئية والاقتصادية بعملية صنع القرار التعليمي (Leal Filho et al., 2024; AlSagri & Sohail, 2024; Ferk Savec & Jedrinović, 2025).

وتبرز أهمية هذا التوجه بصورة أوضح عند الحديث عن الشراكات الدولية المستدامة؛ فاختيار الشركاء لم يعد مسألة إدارية أو دبلوماسية بالمعنى التقليدي، وإنما أصبح عملية تستند بدرجة متزايدة إلى مؤشرات كمية تساعد على تقدير مستوى الجاهزية، وقياس القدرة على نقل المعرفة، ودعم مسارات التحول الأخضر (Horan, 2022; Leal Filho et al., 2024; Trevisan et al., 2023).

ومن هذا المنطلق، يمكن للدبلوماسية الاقتصادية الخضراء أن تستفيد من الذكاء الاصطناعي بوصفه أداة مساندة في تحويل مؤشرات الطاقة والانبعاثات والكهرباء إلى معرفة عملية يمكن توظيفها في بناء شراكات تعليمية وبحثية أكثر فاعلية واستدامة (Vinuesa et al., 2020; Mhlanga, 2021; Chang et al., 2020; Budenny et al., 2022). وتبرز ليبيا بوصفها حالة تطبيقية ذات أهمية خاصة ضمن هذا الإطار؛ نظرًا لارتباط اقتصادها بقطاع الطاقة التقليدية، وحاجتها إلى بناء قدرات مؤسسية وبحثية تساعد على إدارة الانبعاثات، وتطوير التعليم الأخضر، والانفتاح على شراكات دولية أكثر استدامة (Serafini et al., 2022; Leal Filho et al., 2024; Caltarola et al., 2023). وفي ضوء ذلك، تسعى الدراسة إلى بناء طريقة تساعد على فهم موقع الدول من حيث جاهزيتها للشراكات الخضراء، بالاستفادة من أدوات الذكاء الاصطناعي، مع تطبيقها على ليبيا بوصفها نموذجًا للدراسة. ولا يُطرح المؤشر هنا باعتباره قيمة رقمية منفصلة عن الواقع، بل كأداة تساعد صانع القرار في التعليم العالي على قراءة فرص التعاون الدولي، وتحديد المجالات التي يمكن أن تخدم الحوكمة التعليمية الخضراء والدبلوماسية الاقتصادية المستدامة بصورة عملية (Trevisan et al., 2023; Ferk Savec & Jedrinović, 2025; Henderson et al., 2020).

1.1 مشكلة الدراسة

على الرغم من تزايد الاهتمام بدور الشراكات الدولية الخضراء في مؤسسات التعليم العالي لتحقيق أهداف التنمية المستدامة على مستوى العالم، فإن العديد من السياقات التعليمية ما تزال تعتمد في اختياراتها على اعتبارات عامة، مثل السمعة الأكاديمية أو العلاقات المؤسسية القائمة مسبقًا، بدلاً من مؤشرات كمية واضحة تحدد مدى جاهزية الدول أو الشركاء لهذا التحول الأخضر. وفي الدول النامية التي تشهد فيها الحاجة إلى شراكات تعليمية وبحثية موجهة لبناء القدرات، ونقل المعرفة، ورصد الانبعاثات، وتوسيع برامج الطاقة النظيفة، فإن هذه التحديات تتفاقم. ومن ثم، تتمثل مشكلة الدراسة في غياب إطار تحليلي متقدم يوجه مؤسسات التعليم العالي وصنّاع السياسات لإجراء تقييم كمي وشامل لمدى جاهزية الشركاء عالميًا للشراكات المستدامة، مع تطبيق خاص على ليبيا.

1.2 فجوة الدراسة

تكشف الأدبيات الحديثة عن اهتمام متزايد بثلاثة مسارات بحثية رئيسية: الذكاء الاصطناعي في التعليم العالي، واستدامة الجامعات، والتحول الأخضر. غير أن الربط العملي بين هذه المسارات ما يزال محدودًا، خاصة في ما يتعلق ببناء مؤشر تنبؤي يساعد على اختيار الشركاء الدوليين في ضوء مؤشرات الطاقة والانبعاثات والجاهزية الخضراء. كما أن معظم الدراسات السابقة تركز إما على الاستخدام التعليمي للذكاء الاصطناعي، أو على دمج الاستدامة داخل الجامعات، أو على تحليل الطاقة والانبعاثات بصورة منفصلة، بينما تحاول هذه الدراسة الجمع بين هذه الأبعاد في نموذج واحد يخدم الحوكمة التعليمية الخضراء والدبلوماسية الاقتصادية المستدامة.

1.3 أهداف الدراسة

تهدف هذه الدراسة إلى تحقيق الأهداف الآتية:

1. بناء مؤشر مركب لقياس جاهزية الدول للشراكات الخضراء المستدامة اعتمادًا على مؤشرات الطاقة والكهرباء والانبعاثات.
2. توظيف نماذج الذكاء الاصطناعي للتنبؤ بمستويات الجاهزية المستقبلية وتصنيف الدول إلى فئات جاهزية منخفضة ومتوسطة ومرتفعة.
3. تحليل العوامل الأكثر تأثيرًا في جاهزية الشراكات الخضراء من خلال نماذج قابلة للتفسير.
4. تطبيق النموذج على ليبيا بوصفها حالة خاصة ضمن سياق عالمي، بهدف إبراز الفجوة والفرص المتاحة أمام الشراكات التعليمية والبحثية الخضراء.
5. تقديم إطار داعم لصانع القرار في مؤسسات التعليم العالي لاختيار الشركاء الدوليين بطريقة أكثر استنادًا إلى البيانات.

1.4 أسئلة الدراسة

تسعى الدراسة إلى الإجابة عن الأسئلة البحثية الآتية:

1. كيف يمكن بناء مؤشر كمي يقيس جاهزية الدول للشراكات الدولية الخضراء في سياق مؤسسات التعليم العالي؟
2. إلى أي مدى تستطيع نماذج الذكاء الاصطناعي التنبؤ بدرجة جاهزية الشراكات الخضراء في السنة اللاحقة؟
3. ما النماذج الأكثر قدرة على تصنيف الدول إلى مستويات جاهزية منخفضة ومتوسطة ومرتفعة؟
4. ما العوامل الأكثر تأثيرًا في تحديد جاهزية الشراكات الخضراء وفقًا لتفسير النماذج الذكية؟

5. ماذا تكشف حالة ليبيا عن فرص وتحديات بناء الشراكات التعليمية والبحثية الداعمة للتحول الأخضر؟

1.5 إسهام الدراسة

تحاول الدراسة تقديم فكرة تربط بين الذكاء الاصطناعي والحوكمة التعليمية الخضراء والدبلوماسية الاقتصادية المستدامة. يستخدم المؤشر لمساعدة في فهم جاهزية الدول للشراكات الخضراء. لا يقتصر هذا المؤشر على الوصف فقط؛ بل يمكن اختباره ومقارنته من خلال نماذج تنبؤية وتصنيفية توضح مستويات الجاهزية واتجاهاتها.

ولا يقف هذا الإطار عند الجانب التحليلي، بل يتم اختباره من خلال نماذج تنبؤية وتصنيفية متعددة، بما يسمح بمقارنة مستويات الجاهزية واستشراف اتجاهاتها. كما يمكن أن يفيد الجامعات وصناع القرار في اختيار الشركاء الدوليين الأكثر ارتباطاً بمشروعات التعليم الأخضر، ونقل التكنولوجيا النظيفة، وتطوير القدرات البحثية. وتزداد أهمية الدراسة من خلال تطبيقها على ليبيا كحالة عربية ضمن نموذج عالمي، وهو ما يمنح نتائجها قابلية أكبر للنقاش والاستخدام في سياقات الدول النامية.

2. مراجعة الأدبيات والدراسات السابقة

شهدت الأدبيات الحديثة اهتماماً متزايداً بدور مؤسسات التعليم العالي في تحقيق أهداف التنمية المستدامة، حيث لم تعد الجامعات تُفهم بوصفها مؤسسات تعليمية وبحثية فقط، بل بوصفها فاعلاً تنموياً قادراً على التأثير في السياسات، وبناء القدرات، وتوجيه المعرفة نحو التحول المستدام. (Chankseliani & McCowan, 2021; Serafini et al., 2022). وقد أوضحت دراسة Serafini et al. (2022) أن مؤسسات التعليم العالي تؤدي دوراً أساسياً في دمج أهداف التنمية المستدامة داخل التعليم والبحث والممارسات المؤسسية، لكنها أشارت في الوقت نفسه إلى أن هذا الدمج لا يزال متفاوتاً بين الجامعات والدول. ويتقاطع ذلك مع ما أشار إليه Leal Filho et al. (2021) من أن الحوكمة الجامعية المستدامة تتطلب ربط الاستدامة بالقرار المؤسسي، وليس الاكتفاء بإدراجها في الأنشطة التعليمية أو المبادرات المعزولة.

وفي السياق نفسه، ركزت دراسات أخرى على العلاقة بين التحول الرقمي والاستدامة في التعليم العالي، إذ بين Trevisan et al. (2023) أن التحول الرقمي يمكن أن يدعم الاستدامة داخل الجامعات عندما يُوظف ضمن رؤية مؤسسية واضحة، تربط التكنولوجيا بالأهداف البيئية والاجتماعية والاقتصادية. كما أوضحت دراسة Chiu et al. (2023) أن الذكاء الاصطناعي في التعليم يوفر فرصاً مهمة لتحسين التحليل، والتنبؤ، ودعم اتخاذ القرار، غير أن فعاليته تعتمد على جودة البيانات، ووضوح الأهداف، ووجود إطار أخلاقي وحوكمي يوجه استخدامه. وتدعم دراسة Bond et al. (2024) هذا الاتجاه، إذ أكدت أن أبحاث الذكاء الاصطناعي في التعليم العالي تحتاج إلى قدر أكبر من الصرامة المنهجية، والتعاون متعدد التخصصات، والاهتمام بالأبعاد الأخلاقية والسياقية.

أما فيما يتعلق بالاستدامة والذكاء الاصطناعي، فقد قدمت دراسة Vinuesa et al. (2020) إطاراً مهماً يوضح كيف يمكن للذكاء الاصطناعي أن يساهم في تحقيق أهداف التنمية المستدامة، مع التنبيه إلى أن هذه المساهمة قد تكون إيجابية أو سلبية تبعاً لطريقة التصميم والاستخدام. وفي اتجاه أكثر قرباً من التعليم العالي، تناولت دراسة Leal Filho et al. (2024) استخدام الذكاء الاصطناعي في تنفيذ أهداف التنمية المستدامة داخل مؤسسات التعليم العالي، وأكدت أن الذكاء الاصطناعي يمكن أن يكون أداة مساعدة في التخطيط والتقييم ودعم القرار، خاصة عندما يرتبط بمؤشرات قابلة للقياس. وتتسجم هذه الرؤية مع دراسة AISagri and Sohail (2024) التي ربطت بين الذكاء الاصطناعي وجودة التعليم ضمن أهداف التنمية المستدامة، مشيرة إلى أهمية استخدامه في تحسين العدالة التعليمية وتوجيه السياسات القائمة على البيانات.

وعلى مستوى الشراكات، تشير الأدبيات إلى أن تحقيق أهداف التنمية المستدامة يتطلب بناء شراكات فعالة بين المؤسسات التعليمية والحكومات والقطاع الخاص والمنظمات الدولية. فقد أوضح Horan (2022) أن الشراكات الفعالة لا تتحقق بمجرد وجود اتفاقيات تعاون، بل تحتاج إلى أطر واضحة للحوكمة، وآليات قياس، وتحديد دقيق للأدوار والمسؤوليات. وهذا مهم في سياق الدراسة الحالية، لأن الشراكات التعليمية الخضراء لا ينبغي أن تقوم فقط على السمعة الأكاديمية أو العلاقات الدبلوماسية، بل على جاهزية حقيقية يمكن قياسها من خلال مؤشرات الطاقة والانبعاثات والتحول منخفض الكربون.

وبالرغم من أهمية هذه الدراسات، فإن معظمها تناول الذكاء الاصطناعي في التعليم العالي من زاوية التدريس والتعلم، أو تناول الاستدامة الجامعية من زاوية الحوكمة العامة، أو ناقش الشراكات من منظور مؤسسي واسع. أما الربط بين الذكاء الاصطناعي، والحوكمة التعليمية الخضراء، واختيار الشراكات الدولية المستدامة اعتماداً على مؤشر كمي قابل للتنبؤ والتفسير، فما يزال محدوداً في الأدبيات الحديثة. ومن هنا تأتي الدراسة الحالية لتسد هذه الفجوة من خلال بناء مؤشر جاهزية الشراكات الخضراء، وتوظيف نماذج تنبؤية وتصنيفية لتقدير الجاهزية المستقبلية، مع تطبيق خاص على ليبيا بوصفها حالة ضمن سياق عالمي.

وتتميز الدراسة الحالية عن الدراسات السابقة في ثلاثة جوانب رئيسية. أولاً، أنها لا تنظر إلى الذكاء الاصطناعي بوصفه أداة تعليمية داخل الصفوف أو المنصات الرقمية فقط، بل بوصفه أداة داعمة للحوكمة التعليمية وصنع القرار الاستراتيجي. ثانياً، أنها تربط قرار الشراكة الدولية بمؤشرات بيئية واقتصادية قابلة للقياس، مثل الطاقة المتجددة، الكهرباء منخفضة الكربون، الاعتماد على الوقود الأحفوري، وكثافة الانبعاثات. ثالثاً، أنها تقدم تطبيقاً خاصاً على ليبيا، بما يسمح بفهم الفجوة بين الجاهزية المحلية والمتوسط العالمي، ويفتح المجال أمام توجيه الشراكات التعليمية والبحثية نحو بناء القدرات والتحول الأخضر. وبذلك،

لا تكتفي هذه الدراسة بتأكيد أهمية الذكاء الاصطناعي والاستدامة في التعليم العالي، بل تقدم إطارًا تطبيقيًا يمكن استخدامه في تقييم الشركاء الدوليين ودعم الدبلوماسية الاقتصادية الخضراء.

3. منهجية الدراسة

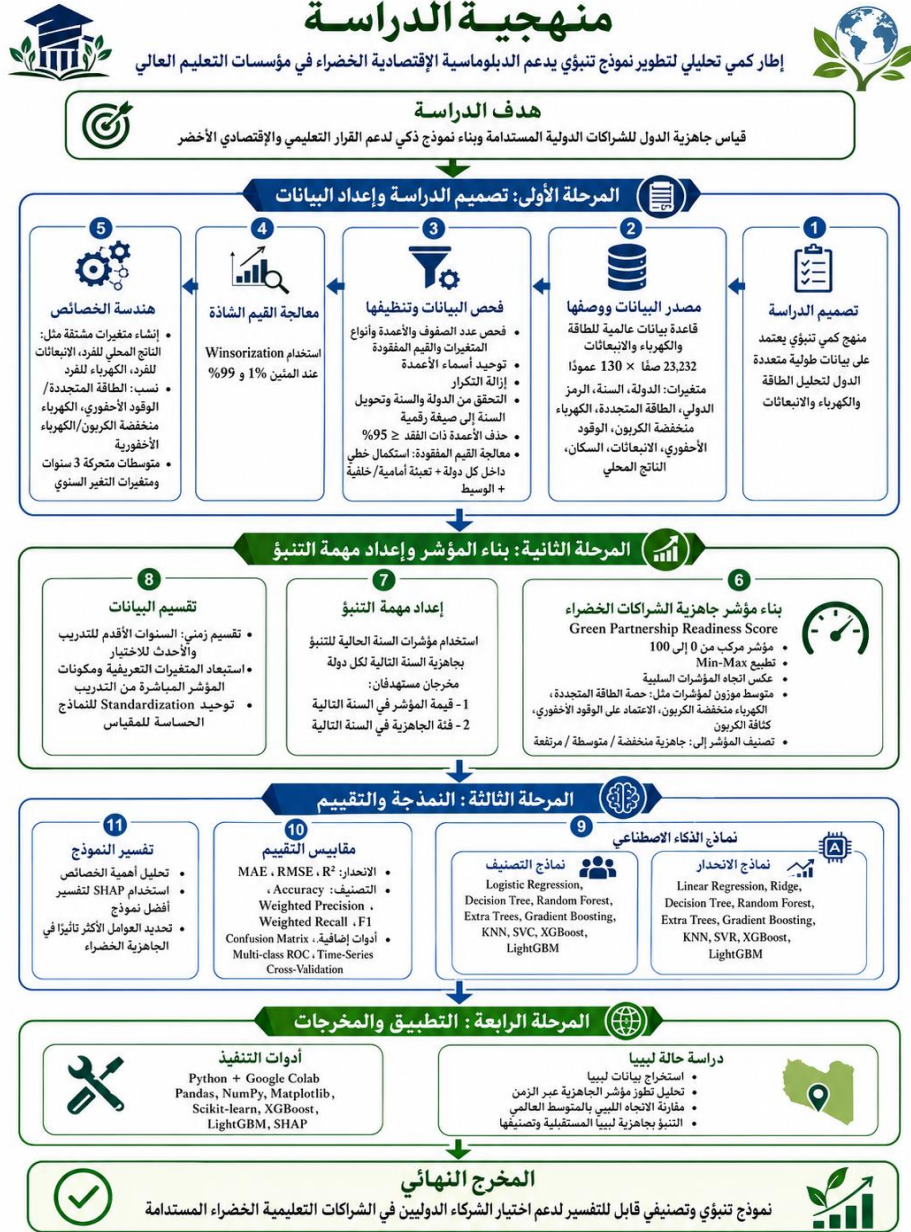
اعتمدت هذه الدراسة منهجًا كميًا تحليليًا قائمًا على توظيف تقنيات الذكاء الاصطناعي وتعلم الآلة في بناء نموذج تنبؤي يدعم الدبلوماسية الاقتصادية الخضراء في مؤسسات التعليم العالي، من خلال قياس درجة جاهزية الدول للشراكات الدولية المستدامة. وقد صُممت المنهجية بما ينسجم مع طبيعة الدراسة التي تجمع بين تحليل مؤشرات الطاقة والانبعاثات والاستدامة من جهة، وتطوير نموذج ذكي قادر على دعم القرار المؤسسي والتعليمي من جهة أخرى. وعليه، لم تقتصر الدراسة على الوصف الإحصائي للبيانات، بل انتقلت إلى بناء مؤشر مركب، ثم استخدامه في نماذج تنبؤية وتصنيفية تساعد على تحديد مستويات الجاهزية المستقبلية للشراكات الخضراء.

3.1 تصميم الدراسة

تقوم الدراسة على تصميم كمي تنبؤي يعتمد على البيانات الطولية متعددة الدول، حيث تم تحليل مؤشرات الطاقة والكهرباء والانبعاثات على مستوى الدول وعبر سنوات متعددة. ويستند التصميم البحثي إلى فكرة أن قرارات الشراكة الدولية المستدامة لا ينبغي أن تعتمد فقط على الاعتبارات السياسية أو الاقتصادية التقليدية، بل يجب أن تستند أيضًا إلى مؤشرات قابلة للقياس تتعلق بقدرة الدول على التحول نحو الطاقة النظيفة، وخفض الاعتماد على الوقود الأحفوري، وتحسين كفاءة الطاقة، وتقليل كثافة الانبعاثات.

ومن هذا المنطلق، تم بناء مؤشر مركب أُطلق عليه في هذه الدراسة اسم **مؤشر جاهزية الشراكات الخضراء (Green Partnership Readiness Score)**، وهو مؤشر كمي يتراوح بين 0 و100، بحيث تشير القيم الأعلى إلى جاهزية أكبر للدخول في شراكات دولية مستدامة في مجالات التعليم الأخضر، البحث العلمي، نقل التكنولوجيا النظيفة، وبناء القدرات المؤسسية. بعد ذلك، استُخدم هذا المؤشر بوصفه متغيرًا مستهدفًا في نماذج التنبؤ، كما تم تحويله إلى فئات تصنيفية ثلاث هي: جاهزية منخفضة، جاهزية متوسطة، وجاهزية مرتفعة.

يوضح الشكل التسلسل المنهجي الكامل للدراسة، بدءًا من تحديد هدف البحث وتصميم الدراسة، مرورًا بجمع البيانات وتنظيفها، ومعالجة القيم المفقودة والشاذة، وهندسة الخصائص، ثم بناء مؤشر جاهزية الشراكات الخضراء. كما يبين الشكل مرحلة إعداد مهمة التنبؤ، وتقسيم البيانات زمنيًا، وتدريب نماذج الانحدار والتصنيف، وانتهاءً بتفسير النموذج وتطبيقه على حالة ليبيا. ويُعد هذا الشكل مناسبًا لتقديم صورة شاملة عن الإطار التحليلي قبل عرض التفاصيل الفنية لكل مرحلة.



الشكل 1: مخطط سير العمل المنهجي للدراسة.

3.2 مصدر البيانات ووصفها


اعتمدت الدراسة على مجموعة بيانات عالمية للطاقة والكهرباء والانبعاثات من Kaggle، وهي مجموعة بيانات واسعة تضم مؤشرات متعددة مرتبطة باستهلاك الطاقة، توليد الكهرباء، مصادر الطاقة المتجددة، مصادر الطاقة منخفضة الكربون، الوقود الأحفوري، الانبعاثات، السكان، والناتج المحلي الإجمالي. تكونت النسخة الأولية من البيانات من 23,232 صفًا و130 عمودًا، وهو ما يعكس اتساع نطاقها الزمني والجغرافي وتعدد أبعادها التحليلية.

تضمنت البيانات متغيرات تعريفية أساسية مثل اسم الدولة، السنة، والرمز الدولي للدولة، إضافة إلى متغيرات كمية عديدة مثل استهلاك الطاقة المتجددة، حصة الطاقة المتجددة من الكهرباء، الكهرباء منخفضة الكربون، كثافة الكربون في الكهرباء، استهلاك الوقود الأحفوري، انبعاثات غازات الدفيئة، عدد السكان، والناتج المحلي الإجمالي. وقد تبين أن مجموعة البيانات تحتوي على سجلات خاصة بليبيا، الأمر الذي سمح بتناول ليبيا كحالة تطبيقية خاصة ضمن الإطار العالمي العام للدراسة.

ونظرًا لأن البيانات تتضمن دولاً ومناطق وتكتلات إقليمية، تم التركيز في النمذجة على السجلات ذات المستوى الدولي، وذلك بالاعتماد على الرموز الدولية الثلاثية للدول. وقد أتاح هذا الإجراء تقليل أثر السجلات التجميعية الإقليمية وضمان أن تكون المقارنات والتحليلات مبنية على وحدات تحليل متجانسة قدر الإمكان.

3.3 فحص البيانات وتنظيفها

بدأت المعالجة بفحص أولي لبنية البيانات من حيث عدد الصفوف، عدد الأعمدة، أنواع المتغيرات، ونسب القيم المفقودة. وقد أظهر الفحص الأولي وجود نسب مرتفعة من القيم المفقودة في عدد من الأعمدة، وهو أمر متوقع في قواعد البيانات العالمية الطولية، خاصة عند جمع مؤشرات متعددة عبر دول وسنوات مختلفة. لذلك، تم تطبيق سلسلة من خطوات التنظيف والمعالجة لضمان جاهزية البيانات للتحليل والنمذجة.



الشكل 2: أعلى ثلاثين متغيراً من حيث القيم المفقودة قبل تنظيف البيانات

يعرض الشكل المتغيرات الثلاثين الأعلى من حيث نسبة القيم المفقودة في النسخة الأولية من البيانات. ويظهر الشكل أن بعض المتغيرات المرتبطة بالتغيرات النسبية في مصادر الطاقة وحصصها تحتوي على نسب فقد مرتفعة، الأمر الذي برر تطبيق إجراءات تنظيف ومعالجة منظمة قبل بناء المؤشر والنماذج التنبؤية. لذلك استُخدم هذا الفحص لتحديد الأعمدة شديدة الفقد ومعالجة القيم المفقودة بطريقة تراعي البنية الزمنية للبيانات.

أولاً، تم توحيد أسماء الأعمدة من خلال تحويلها إلى صيغة موحدة بالحروف الصغيرة واستبدال الفراغات والرموز غير المناسبة بشرط سفلية، وذلك لتسهيل التعامل البرمجي مع المتغيرات. ثانياً، أزيلت الصفوف المكررة لضمان عدم تكرار الملاحظات داخل مجموعة البيانات. ثالثاً، تم التحقق من سلامة المتغيرات التعريفية الأساسية، ولا سيما متغير الدولة والسنة، ثم حُذفت السجلات التي لا تحتوي على قيم صالحة لهذين المتغيرين. كما تم تحويل السنة إلى صيغة رقمية صحيحة لضمان إمكانية استخدامها في التحليل الزمني.

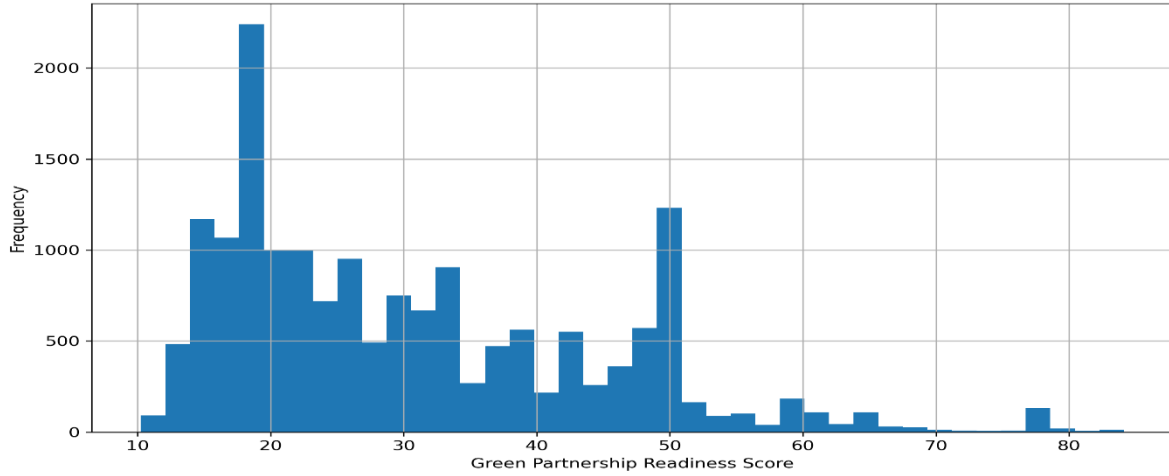
بعد ذلك، تم التعامل مع الأعمدة شديدة الفقد من خلال حذف الأعمدة التي بلغت نسبة القيم المفقودة فيها 95% أو أكثر، باستثناء الأعمدة التعريفية الأساسية. وقد استُخدم هذا الحد للحفاظ على أكبر قدر ممكن من المعلومات المفيدة، وفي الوقت نفسه التخلص من المتغيرات شبه الفارغة التي قد تؤثر سلباً في جودة النمذجة. أما القيم المفقودة المتبقية في المتغيرات الرقمية، فقد عولجت وفق منهج زمني داخل كل دولة، حيث استُخدم الاستكمال الخطي داخل كل سلسلة زمنية، متبوعاً بالتعبئة الأمامية والخلفية، ثم استُخدم الوسيط العام للمتغير لمعالجة أي قيم متبقية. وتعد هذه الاستراتيجية مناسبة لطبيعة البيانات الطولية، لأنها تراعي الترتيب الزمني داخل كل دولة بدلاً من التعامل مع البيانات بوصفها مشاهدات مستقلة تماماً.

3.4 معالجة القيم الشاذة

بعد معالجة القيم المفقودة، تم التعامل مع القيم الشاذة في المتغيرات الرقمية باستخدام أسلوب الحدّ الطرفي (Winsorization)، وذلك من خلال تقليص القيم عند المئين الأول والمئين التاسع والتسعين. وقد فضل هذا الإجراء على حذف الصفوف؛ لأن البيانات عالمية ومتعددة الدول، ومن الطبيعي أن تظهر فروق كبيرة بين الدول في السكان، الناتج المحلي، إنتاج الطاقة، واستهلاك الكهرباء. لذلك، فإن حذف القيم المتطرفة قد يؤدي إلى فقدان معلومات مهمة، في حين أن تقليص القيم الطرفية يقلل أثر القيم غير الاعتيادية دون إلغاء الملاحظة بالكامل.

3.5 هندسة الخصائص

بهدف تعزيز القدرة التفسيرية والتنبؤية للنماذج، تم إنشاء مجموعة من الخصائص المشتقة التي تعكس أبعاداً أكثر ارتباطاً بمفهوم الجاهزية الخضراء. شملت هذه الخصائص الناتج المحلي للفرد، انبعاثات غازات الدفيئة للفرد، توليد الكهرباء للفرد، نسبة الطاقة المتجددة إلى الوقود الأحفوري، ونسبة الكهرباء منخفضة الكربون إلى الكهرباء المولدة من الوقود الأحفوري.



كما تم إنشاء متوسطات متحركة لثلاث سنوات لبعض مؤشرات الطاقة المتجددة والطاقة منخفضة الكربون، إضافة إلى متغيرات تعكس التغير السنوي في هذه المؤشرات.

وقد هدفت هذه الخطوة إلى تجاوز الاعتماد على القيم الخام فقط، لأن القيم المطلقة قد تعكس حجم الدولة أكثر مما تعكس كفاءتها أو جاهزيتها للتحويل الأخضر. فعلى سبيل المثال، قد تمتلك دولة كبيرة انبعاثات مرتفعة بسبب حجمها السكاني أو الصناعي، بينما تقدم المؤشرات النسبية مثل الانبعاثات للفرد أو نسبة الطاقة المتجددة صورة أدق عن اتجاه التحول المستدام. وبذلك، ساعدت هندسة الخصائص في تحويل البيانات من مؤشرات وصفية متفرقة إلى متغيرات أكثر ملاءمة لبناء نموذج ذكي لدعم القرار.

3.6 بناء مؤشر جاهزية الشراكات الخضراء

تم بناء مؤشر جاهزية الشراكات الخضراء بوصفه مؤشرًا مركبًا يجمع بين مؤشرات إيجابية وأخرى عكسية. شملت المؤشرات الإيجابية حصة الطاقة المتجددة، حصة الكهرباء المتجددة، حصة الكهرباء منخفضة الكربون، نسبة الطاقة المتجددة إلى الوقود الأحفوري، وبعض مؤشرات القدرة الاقتصادية والاتجاه الزمني للتحسين. أما المؤشرات العكسية فشملت الاعتماد على الوقود الأحفوري، كثافة الكربون في الكهرباء، وانبعاثات غازات الدفيئة للفرد، حيث إن ارتفاع هذه المؤشرات يعكس انخفاضًا نسبيًا في الجاهزية الخضراء.


ولضمان قابلية المقارنة بين المتغيرات المختلفة في وحدات القياس، تم تطبيع المتغيرات باستخدام مقياس Min-Max لتصبح ضمن نطاق موحد. بعد ذلك، عكست اتجاهات المؤشرات السلبية بحيث تصبح القيم الأعلى دائمًا دالة على جاهزية أفضل. ثم تم حساب المؤشر النهائي من خلال متوسط موزون للمتغيرات الداخلة في تكوين المؤشر، مع إعطاء وزن أعلى لبعض المتغيرات الجوهرية مثل حصة الطاقة المتجددة، الكهرباء منخفضة الكربون، الاعتماد على الوقود الأحفوري، وكثافة الكربون. وقد تراوح المؤشر النهائي بين 0 و100، مما سهّل تفسيره ومقارنته بين الدول والسنوات.

بعد بناء المؤشر، تم تقسيمه إلى ثلاث فئات باستخدام التقسيم الكمي إلى ثلاث مجموعات متقاربة الحجم: جاهزية منخفضة، جاهزية متوسطة، وجاهزية مرتفعة. وقد استخدمت هذه الفئات في نماذج التصنيف، بينما استخدمت القيمة الرقمية للمؤشر في نماذج الانحدار.

يبين الشكل التوزيع العام لقيم مؤشر جاهزية الشراكات الخضراء بعد بنائه على مقياس يتراوح بين 0 و100. ويظهر التوزيع أن القيم تتركز بدرجة أكبر في المستويات المنخفضة والمتوسطة، مع وجود عدد أقل من الحالات ذات الجاهزية المرتفعة. ويعكس ذلك التباين العالمي في مستويات التحول نحو الطاقة النظيفة، كما يدعم الحاجة إلى استخدام نماذج ذكاء اصطناعي قادرة على التنبؤ بدرجات الجاهزية المستقبلية.

الشكل 3: توزيع مؤشر جاهزية الشراكات الخضراء

تعرض المصفوفة علاقات الارتباط بين مؤشر جاهزية الشراكات الخضراء وعدد من المؤشرات الرئيسية المرتبطة بالطاقة المتجددة، الكهرباء منخفضة الكربون، الوقود الأحفوري، كثافة الكربون، والانبعاثات. وتوضح المصفوفة أن المؤشر يرتبط إيجابياً بمؤشرات الطاقة النظيفة ومنخفضة الكربون، بينما يرتبط سلبياً بمؤشرات الاعتماد على الوقود الأحفوري وكثافة الكربون. وتدعم هذه العلاقات المنطق النظري لبناء المؤشر المركب المستخدم في الدراسة.



الشكل 4: مصفوفة الارتباط بين المؤشرات الرئيسية لجاهزية الشراكات الخضراء.

3.7 إعداد مهمة التنبؤ

لجعل النموذج أقرب إلى واقع دعم القرار، لم تقتصر الدراسة على تقدير الجاهزية في السنة نفسها، بل صُممت المهمة التنبؤية بحيث تستخدم مؤشرات السنة الحالية للتنبؤ بدرجة جاهزية السنة اللاحقة. ولهذا الغرض، تم إنشاء متغير مستهدف جديد يمثل قيمة مؤشر جاهزية الشراكات الخضراء في السنة التالية لكل دولة. كما تم إنشاء متغير تصنيفي يمثل فئة الجاهزية في السنة التالية.

يسمح هذا التصميم باختبار قدرة النماذج على التنبؤ بالتحول المستقبلي، بدلاً من الاكتفاء بوصف الحالة الراهنة. وهو أمر مهم في سياق الدبلوماسية الاقتصادية الخضراء؛ لأن صانع القرار في مؤسسات التعليم العالي يحتاج إلى استشراف الدول أو الشركاء الأكثر قابلية للتعاون المستدام في المستقبل القريب، وليس فقط تقييم وضعهم الحالي.

3.8 تقسيم البيانات

تم تقسيم البيانات وفق تقسيم زمني بدلاً من التقسيم العشوائي التقليدي. فقد استُخدمت السنوات الأقدم لتدريب النماذج، بينما استُخدمت السنوات الأحدث لاختبارها. ويعد هذا الإجراء أكثر ملاءمة لطبيعة الدراسة؛ لأن مهمة البحث تنبؤية زمنية، ومن

غير المنهجي تدريب النموذج على سنوات أحدث ثم اختباره على سنوات أقدم. كما أن التقسيم الزمني يحاكي بصورة أفضل ظروف الاستخدام الواقعي للنموذج، حيث يتم تدريب النظام على البيانات التاريخية ثم استخدامه للتنبؤ بالقيم المستقبلية.

إضافة إلى ذلك، تم استبعاد المتغيرات التعريفية مثل اسم الدولة والرمز الدولي من مصفوفة الخصائص، كما تم استبعاد المتغيرات الداخلة مباشرة في بناء المؤشر المركب من مرحلة التدريب، وذلك لتعزيز استقلالية التنبؤ وتقليل الاعتماد المباشر على مكونات المؤشر نفسه. وبعد تحديد الخصائص النهائية، تم تطبيق Standardization على المتغيرات لاستخدامها في النماذج الحساسة للمقياس مثل الانحدار اللوجستي، KNN، و SVC، بينما استُخدمت القيم الأصلية في النماذج الشجرية التي لا تتطلب بالضرورة توحيد المقياس.

3.9 نماذج الذكاء الاصطناعي المستخدمة

تم بناء نوعين من النماذج. النوع الأول هو نماذج الانحدار، وهدفها التنبؤ بالقيمة الرقمية لمؤشر جاهزية الشركات الخضراء في السنة التالية. أما النوع الثاني فهو نماذج التصنيف، وهدفها تصنيف الدولة إلى إحدى فئات الجاهزية الثلاث: منخفضة، متوسطة، أو مرتفعة.

في نماذج الانحدار، تمت مقارنة عدة خوارزميات شملت Linear Regression، Ridge Regression، Decision Tree Regressor، Gradient Boosting، Extra Trees Regressor، Random Forest Regressor، Tree Regressor، KNN Regressor، SVR، XGBoost، و LightGBM. وقد أتاح هذا التنوع مقارنة أداء النماذج الخطية، النماذج القائمة على الأشجار، النماذج التجميعية، ونماذج التعزيز.

أما في نماذج التصنيف، فقد تمت مقارنة Logistic Regression، Decision Tree Classifier، Random Forest Classifier، Gradient Boosting Classifier، Extra Trees Classifier، KNN، SVC، XGBoost، و LightGBM. وقد استخدمت هذه النماذج لاختبار قدرة الذكاء الاصطناعي على التمييز بين مستويات الجاهزية المختلفة، بما يخدم هدف الدراسة في دعم اختيار الشركاء الدوليين الأكثر ملاءمة للشركات التعليمية الخضراء.

3.10 مقاييس التقييم

تم تقييم نماذج الانحدار باستخدام ثلاثة مقاييس رئيسية: متوسط الخطأ المطلق (MAE)، جذر متوسط مربع الخطأ (RMSE)، ومعامل التحديد (R^2) ويقاس MAE متوسط مقدار الخطأ بين القيم الفعلية والمتنبأ بها، بينما يعطي RMSE وزناً أكبر للأخطاء الكبيرة، في حين يوضح R^2 نسبة التباين في المتغير المستهدف التي استطاع النموذج تفسيرها.

أما نماذج التصنيف، فقد قُيِّمت باستخدام الدقة (Accuracy)، الدقة الإيجابية الموزونة (Weighted Precision)، الاسترجاع الموزون (Weighted Recall)، ودرجة F1 الموزونة. كما تم استخدام مصفوفة الالتباس لتوضيح توزيع الأخطاء بين الفئات الثلاث، ومنحنى ROC متعدد الفئات لتقييم قدرة النموذج على التمييز بين مستويات الجاهزية المختلفة. وإلى جانب ذلك، تم استخدام التحقق المتقاطع الزمني Time-Series Cross-Validation لاختبار ثبات نماذج الانحدار عبر طيات زمنية متعددة.

3.11 تفسير النموذج

لم تكف الدراسة بقياس دقة النماذج، بل سعت أيضاً إلى تفسير العوامل التي تقود التنبؤات. ولهذا الغرض، تم استخدام تحليل أهمية الخصائص، إضافة إلى أسلوب SHAP لتفسير أثر المتغيرات في مخرجات أفضل نموذج انحدار. ويعد هذا الجانب مهماً في الدراسات المرتبطة بدعم القرار؛ لأن المؤسسات التعليمية وصناع القرار لا يحتاجون فقط إلى معرفة الدولة ذات الجاهزية الأعلى، بل يحتاجون أيضاً إلى فهم الأسباب التي تجعل دولة معينة أكثر ملاءمة للشركات الخضراء.

وقد ساعد تحليل SHAP في الكشف عن المتغيرات الأكثر تأثيراً في مخرجات النموذج، مثل مؤشرات الكهرباء منخفضة الكربون، الطاقة الكهرومائية، الطاقة النووية، حصة الوقود الأحفوري في الكهرباء، وبعض مؤشرات الطاقة للفرد. وتوفر هذه النتائج أساساً تفسيريًا يساعد في ربط مخرجات الذكاء الاصطناعي بالسياسات التعليمية والاقتصادية، بدلاً من التعامل مع النموذج بوصفه صندوقاً أسود.

3.12 دراسة حالة ليبيا

نظراً لوجود بيانات خاصة بليبيا داخل مجموعة البيانات، حُصص جزء من التحليل لدراسة ليبيا كحالة تطبيقية ضمن الإطار العالمي. تم استخراج السجلات الخاصة بليبيا، ثم تحليل تطور مؤشر جاهزية الشركات الخضراء عبر الزمن، ومقارنة الاتجاه الليبي بالمتوسط العالمي. كما استُخدمت النماذج المدربة للتنبؤ بدرجة الجاهزية المستقبلية لليبيا وتصنيفها ضمن إحدى فئات الجاهزية.

ويكتسب هذا التحليل أهمية خاصة لأن ليبيا تمثل حالة ذات صلة مباشرة بموضوع الدراسة، نظرًا لارتباط اقتصادها بقطاع الطاقة التقليدية وحاجتها المتزايدة إلى شركات دولية في مجالات التحول الأخضر، التعليم المستدام، وبناء القدرات البحثية. لذلك، فإن إدراج ليبيا كحالة خاصة لا يهدف إلى عزلها عن السياق العالمي، بل إلى إظهار كيف يمكن للنموذج المقترح أن يدعم صانع القرار في دولة نامية تسعى إلى تطوير سياسات تعليمية واقتصادية أكثر توافقًا مع أهداف الاستدامة.

3.13 أدوات التنفيذ

نُفذت جميع مراحل المعالجة والنمذجة باستخدام لغة Python على بيئة Google Colab. استُخدمت مكتبة Pandas و NumPy لمعالجة البيانات، و Matplotlib لإنتاج الرسوم البيانية، و Scikit-learn لبناء النماذج التقليدية والتقييم، إضافة إلى XGBoost و LightGBM للنماذج المعززة عالية الأداء، و SHAP لتفسير مخرجات النموذج. كما تم حفظ الجداول والرسوم الناتجة بصيغ مناسبة للاستخدام في العرض الأكاديمي والتحليل البحثي.

وبذلك، تقدم المنهجية إطارًا متكاملًا يبدأ من تنظيف البيانات العالمية ومعالجتها، مرورًا ببناء مؤشر مركب للجاهزية الخضراء، وانتهاءً بتطوير نماذج تنبؤية وتصنيفية قابلة للتفسير. ويتيح هذا الإطار توظيف الذكاء الاصطناعي بوصفه أداة عملية لدعم الدبلوماسية الاقتصادية الخضراء في مؤسسات التعليم العالي، من خلال تحويل البيانات البيئية والاقتصادية إلى مؤشرات قابلة للاستخدام في اختيار الشركات الدولية المستدامة.

4. النتائج والمناقشة

يعرض هذا القسم النتائج التي توصلت إليها الدراسة بعد تطبيق الإطار المنهجي المقترح لبناء مؤشر جاهزية الشركات الخضراء، وتطوير نماذج تنبؤية وتصنيفية قائمة على الذكاء الاصطناعي لدعم الدبلوماسية الاقتصادية الخضراء في مؤسسات التعليم العالي. وقد جاءت النتائج في أربعة محاور رئيسية: نتائج بناء المؤشر وتحليل توزيعه، نتائج نماذج الانحدار، نتائج نماذج التصنيف، وتفسير النموذج ودراسة حالة ليبيا. ويساعد هذا الترتيب على ربط النتائج مباشرة بالمنهجية، حيث انتقلت الدراسة من معالجة البيانات وبناء المؤشر إلى اختبار قدرة النماذج على التنبؤ بالجاهزية المستقبلية وتصنيف مستوياتها.

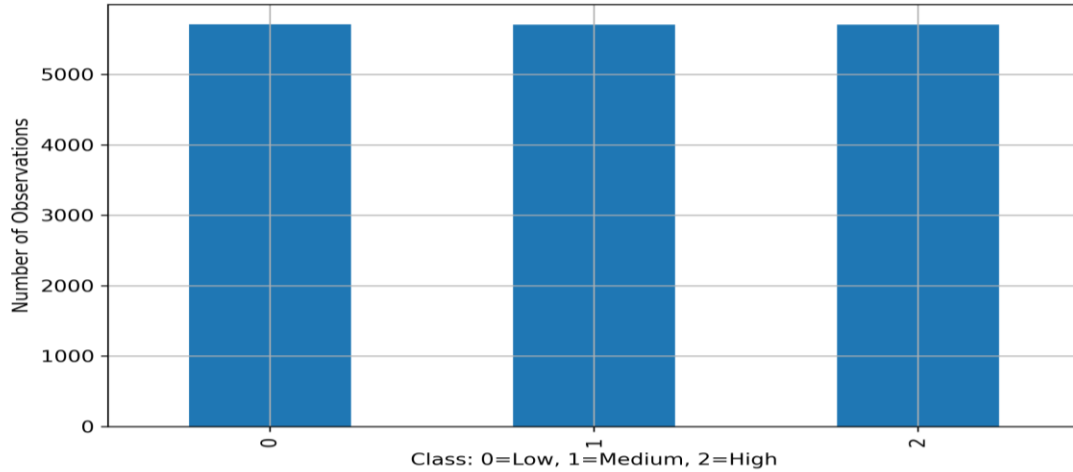
4.1 نتائج بناء مؤشر جاهزية الشركات الخضراء

أظهرت نتائج بناء مؤشر جاهزية الشركات الخضراء أن الدول تختلف بصورة واضحة في مستوى قابليتها للدخول في شركات دولية مستدامة. وقد تراوحت قيم المؤشر بين مستويات منخفضة وأخرى مرتفعة، الأمر الذي يعكس التباين العالمي في الاعتماد على مصادر الطاقة المتجددة، الكهرباء منخفضة الكربون، وكثافة الانبعاثات. ويشير هذا التباين إلى أن الجاهزية الخضراء ليست خاصية ثابتة أو مرتبطة فقط بمستوى الدخل، بل هي نتيجة مركبة تتداخل فيها مؤشرات الطاقة، الانبعاثات، البنية الاقتصادية، واتجاهات التحول عبر الزمن.

وقد كشف توزيع مؤشر الجاهزية أن عددًا كبيرًا من الملاحظات يتركز ضمن المستويات المنخفضة والمتوسطة، في حين ظهرت مجموعة أصغر من الدول ذات جاهزية مرتفعة. ويُفهم ذلك في ضوء أن التحول الأخضر ما يزال غير متوازن عالميًا؛ إذ تمتلك بعض الدول بنية طاقة متقدمة وقادرة على إنتاج الكهرباء من مصادر متجددة أو منخفضة الكربون، بينما لا تزال دول أخرى تعتمد بدرجة كبيرة على الوقود الأحفوري. ومن منظور الدبلوماسية الاقتصادية الخضراء، فإن هذا التوزيع مهم لأنه يساعد مؤسسات التعليم العالي على التمييز بين الشركاء المحتملين وفقًا لقدرتهم الفعلية على دعم برامج التعليم الأخضر، البحث العلمي التطبيقي، ونقل التكنولوجيا النظيفة.

كما أظهر توزيع فئات الجاهزية أن تقسيم المؤشر إلى ثلاث فئات، منخفضة ومتوسطة ومرتفعة، أدى إلى توزيع متوازن نسبيًا بين الفئات الثلاث. وتعد هذه النتيجة مهمة من الناحية النمذجية؛ لأن توازن الفئات يقلل من انحياز نماذج التصنيف نحو فئة واحدة، ويجعل مقاييس الأداء مثل الدقة ودرجة F1 أكثر تمثيلًا لقدرة النموذج على التمييز بين المستويات المختلفة للجاهزية.

يعرض الشكل توزيع الملاحظات على فئات الجاهزية الثلاث. ويُظهر الشكل أن التقسيم الكمي للمؤشر أنتج فئات متقاربة في الحجم، مما وفر أساسًا مناسبًا لتدريب نماذج التصنيف وتقييمها بصورة أكثر عدالة.



الشكل 5: توزيع فئات جاهزية الشركات الخضراء

4.2 نتائج نماذج الانحدار


هدفت نماذج الانحدار إلى التنبؤ بالقيمة الرقمية لمؤشر جاهزية الشركات الخضراء في السنة التالية اعتمادًا على مؤشرات السنة الحالية. وقد أظهرت النتائج أن النماذج غير الخطية، ولا سيما نماذج التعزيز والتجميع، تفوقت بوضوح على النماذج الخطية والنماذج الأبسط. فقد حقق نموذج Gradient Boosting أفضل أداء في مجموعة الاختبار، حيث سجل قيمة R^2 بلغت 0.905، مع RMSE مقداره 4.261 و MAE مقداره 2.588. ويشير ذلك إلى أن النموذج استطاع تفسير نسبة مرتفعة من التباين في مؤشر الجاهزية المستقبلية، مع مستوى خطأ مقبول على مقياس المؤشر الممتد من 0 إلى 100.

جاء نموذج LightGBM في المرتبة الثانية بقيمة R^2 بلغت 0.901، وحقق أقل قيمة MAE بين النماذج المتقدمة، إذ بلغت 2.517. كما حقق نموذج XGBoost أداءً قريبًا جدًا بقيمة R^2 بلغت 0.899. ويؤكد التقارب بين هذه النماذج أن العلاقات بين مؤشرات الطاقة والانبعاثات والجاهزية الخضراء ذات طبيعة غير خطية، وأن نماذج التعزيز قادرة على التقاط هذه العلاقات بصورة أفضل من النماذج الخطية التقليدية.

الجدول 1. أداء نماذج الانحدار في التنبؤ بمؤشر جاهزية الشركات الخضراء

النموذج	MAE	RMSE	R^2
Gradient Boosting	2.588	4.261	0.905
LightGBM	2.517	4.354	0.901
XGBoost	2.588	4.391	0.899
Extra Trees	3.191	5.401	0.847
Random Forest	3.196	5.431	0.846
Decision Tree	4.466	7.206	0.728
Ridge Regression	5.686	10.316	0.444
KNN	6.450	10.570	0.416
SVR	6.820	10.768	0.394
Linear Regression	7.471	14.556	-0.108


تُظهر نتائج الجدول أن النماذج الشجرية المعززة حققت أفضل أداء، في حين كان أداء الانحدار الخطي التقليدي ضعيفاً، إذ سجل قيمة R^2 سالبة. ويعني ذلك أن العلاقة بين الخصائص المدخلة ومؤشر الجاهزية ليست علاقة خطية بسيطة. كما أن الأداء الضعيف للنموذج الخطي يدعم التوجه المنهجي للدراسة في استخدام خوارزميات ذكاء اصطناعي أكثر قدرة على التعامل مع التفاعلات المعقدة بين المتغيرات.



الشكل 6: مقارنة أداء نماذج الانحدار وفق معامل التحديد R^2

يوضح الشكل الفروق بين نماذج الانحدار من حيث القدرة التفسيرية. ويظهر أن Gradient Boosting و LightGBM و XGBoost حققت أعلى مستويات الأداء، مما يشير إلى ملائمة نماذج التعزيز للتنبؤ بجاهزية الشركات مقارنة بالنماذج الخطية أو النماذج الأبسط.

ولمزيد من التحقق من جودة النموذج، تمت مقارنة القيم الفعلية لمؤشر الجاهزية في السنة التالية بالقيم التي تنبأ بها أفضل نموذج انحدار. وقد أظهر الشكل الخاص بالقيم الفعلية والمنتبأ بها أن النقاط تتركز عمومًا حول خط المطابقة، وهو ما يدل على قدرة النموذج على تقدير الاتجاه العام للمؤشر بصورة جيدة. ومع ذلك، تظهر بعض الانحرافات عند القيم المتوسطة والمرتفعة، وهو أمر متوقع في بيانات عالمية متعددة الدول تحتوي على تفاوتات اقتصادية وطاقيّة كبيرة.



الشكل 7: القيم الفعلية والمنتبأ بها لمؤشر الجاهزية في السنة التالية

يبين الشكل مدى تقارب تنبؤات نموذج Gradient Boosting مع القيم الفعلية لمؤشر جاهزية الشراكات الخضراء. ويُظهر تمركز أغلب النقاط حول خط المطابقة أن النموذج قادر على التقاط النمط العام لتغير الجاهزية المستقبلية، مع وجود بعض الأخطاء في الحالات ذات الخصائص الأكثر تباينًا.

4.3 نتائج التحقق المتقاطع الزمني

إلى جانب تقييم النماذج على مجموعة الاختبار، تم استخدام التحقق المتقاطع الزمني لاختبار ثبات الأداء عبر طيات زمنية متعددة. وقد أظهرت النتائج أن XGBoost حقق أعلى متوسط R^2 في التحقق المتقاطع الزمني بقيمة 0.964، يليه Gradient Boosting بقيمة 0.964 تقريبًا، ثم LightGBM بقيمة 0.962. كما حققت Ridge Regression و Extra Trees و Random Forest قيمًا مرتفعة نسبيًا، بينما كان أداء SVR أقل من النماذج الشجرية، وكان Linear Regression غير مستقر في هذا الاختبار.

الجدول 2. نتائج التحقق المتقاطع الزمني لنماذج الانحدار

النموذج	متوسط R^2	الانحراف المعياري
XGBoost	0.964	0.026
Gradient Boosting	0.964	0.028
LightGBM	0.962	0.030
Ridge Regression	0.959	0.044
Extra Trees	0.951	0.055
Random Forest	0.937	0.049
KNN	0.902	0.058
Decision Tree	0.896	0.089
SVR	0.840	0.119
Linear Regression	-5.056e+11	1.011e+12

تعزز هذه النتائج موثوقية النماذج غير الخطية في التقاط الاتجاهات الزمنية العامة للجاهزية الخضراء. كما أن التوافق النسبي بين نتائج مجموعة الاختبار ونتائج التحقق المتقاطع الزمني يشير إلى أن أداء النماذج المتقدمة لا يعتمد فقط على تقسيم واحد للبيانات، بل يمتد عبر طيات زمنية متعددة. ومن الناحية التطبيقية، يعني ذلك أن النموذج المقترح يمكن أن يقدم دعمًا استشرافيًا لصناع القرار عند تقييم الشراكات المستقبلية، خاصة عندما يكون الهدف هو التنبؤ بالجاهزية في السنوات القادمة وليس فقط تحليل الوضع الحالي.


4.4 نتائج نماذج التصنيف

سعت نماذج التصنيف إلى تحديد فئة جاهزية الدولة في السنة التالية، سواء كانت منخفضة أو متوسطة أو مرتفعة. وقد أظهرت النتائج أن نموذج LightGBM حقق أفضل أداء تصنيفي، إذ بلغت دقته 0.855، وبلغت قيمة F1 الموزونة 0.855 تقريبًا. ويشير ذلك إلى أن النموذج كان قادرًا على التمييز بين فئات الجاهزية الثلاث بدرجة جيدة. وجاء XGBoost في المرتبة الثانية بدقة بلغت 0.850 و F1 مقدارها 0.849، تلاه Gradient Boosting بدقة 0.844 و F1 مقدارها 0.843.

الجدول 3. أداء نماذج التصنيف في تحديد فئات جاهزية الشركات الخضراء

النموذج	Accuracy	Precision	Recall	F1-score
LightGBM	0.855	0.862	0.855	0.855
XGBoost	0.850	0.857	0.850	0.849
Gradient Boosting	0.844	0.850	0.844	0.843
Random Forest	0.827	0.840	0.827	0.829
Extra Trees	0.792	0.803	0.792	0.789
Decision Tree	0.778	0.780	0.778	0.773
Logistic Regression	0.727	0.739	0.727	0.713
SVC	0.660	0.741	0.660	0.661
KNN	0.647	0.692	0.647	0.641

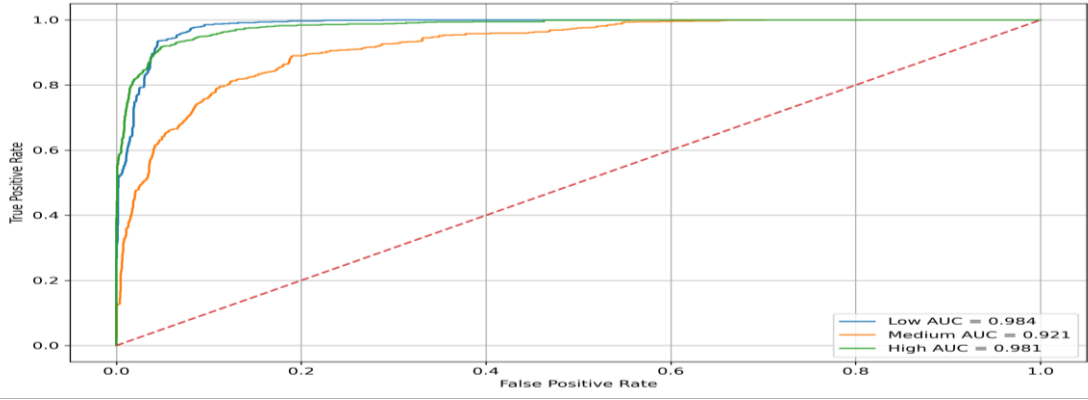
تكشف هذه النتائج أن النماذج المعززة تفوقت أيضًا في مهمة التصنيف، كما حدث في مهمة الانحدار. ويعود ذلك إلى قدرة هذه النماذج على التعامل مع العلاقات غير الخطية والتفاعلات بين مؤشرات الطاقة والانبعاثات. أما النماذج الأبسط مثل KNN و SVC فقد حققت أداءً أقل، مما يشير إلى أن الحدود الفاصلة بين فئات الجاهزية ليست بسيطة أو منتظمة بما يكفي لكي تلتقطها النماذج الأقل مرونة.



الشكل 8: مقارنة أداء نماذج التصنيف وفق الدقة

يوضح الشكل الفروق بين نماذج التصنيف من حيث الدقة. ويظهر أن *LightGBM* و *XGBoost* و *Gradient Boosting* كانت النماذج الأعلى أداءً، مما يؤكد قدرة خوارزميات التعزيز على تصنيف مستويات الجاهزية الخضراء بصورة أكثر كفاءة.

كما أظهر منحني ROC متعدد الفئات لأفضل نموذج تصنيف أن *LightGBM* يمتلك قدرة تمييز مرتفعة بين الفئات الثلاث. فقد بلغت قيمة AUC لفئة الجاهزية المنخفضة 0,984، ولفئة الجاهزية المتوسطة 0,921، ولفئة الجاهزية المرتفعة 0,981. وتشير هذه القيم إلى أن النموذج لا يكتفي بتحقيق دقة جيدة، بل يمتلك أيضاً قدرة عالية على التمييز الاحتمالي بين مستويات الجاهزية، خصوصاً في فئتي الجاهزية المنخفضة والمرتفعة.



الشكل 9. منحني ROC متعدد الفئات لنموذج LightGBM

يعرض الشكل أداء نموذج LightGBM في التمييز بين فئات الجاهزية الثلاث. وتدل قيم AUC المرتفعة على أن النموذج قادر على الفصل بين الدول ذات الجاهزية المنخفضة والمتوسطة والمرتفعة بدرجة قوية، وهو ما يعزز موثوقية استخدامه في دعم قرارات اختيار الشركاء الدوليين.

4.5 تفسير النموذج وأهمية الخصائص

أظهر تحليل أهمية الخصائص أن بعض متغيرات هيكل إنتاج الكهرباء ومصادر الطاقة لعبت دورًا محوريًا في تشكيل تنبؤات النموذج. ففي نموذج الانحدار، برزت خصائص مثل حصة الكهرباء الكهرومائية، حصة الفحم في الكهرباء، عدد السكان، حصة الكهرباء النووية، السنة، الكهرباء منخفضة الكربون للفرد، وحصة النفط والغاز في الكهرباء بوصفها من أكثر المتغيرات تأثيرًا. أما في نموذج التصنيف، فقد جاءت حصة الكهرباء الكهرومائية في المرتبة الأولى بأهمية مرتفعة جدًا، تلتها حصة الطاقة الكهرومائية، حصة الكهرباء النووية، حصة الكهرباء من إجمالي الطاقة، والكهرباء منخفضة الكربون للفرد.

تدعم هذه النتيجة المنطق النظري للدراسة؛ إذ إن جاهزية الدولة للشراكات الخضراء ترتبط بدرجة كبيرة بطبيعة مزيج الكهرباء لديها، وليس فقط بحجم الاقتصاد أو عدد السكان. فالدول التي تمتلك حصة أعلى من الكهرباء منخفضة الكربون أو مصادر الطاقة المتجددة تكون غالبًا أكثر قدرة على الدخول في شراكات تعليمية وبحثية مرتبطة بالتحول الأخضر. وفي المقابل، تعكس حصة الفحم أو النفط في الكهرباء درجة الاعتماد على مصادر طاقة تقليدية، وهو ما قد يخفض من مستوى الجاهزية أو يجعل الحاجة إلى الشراكات الخضراء أكثر إلحاحًا.


الجدول 4. أهم الخصائص في نموذج الانحدار

الأهمية	الخاصية
907	hydro_share_elec
503	coal_share_elec
419	population
377	nuclear_share_elec
284	year
258	low_carbon_elec_per_capita
228	hydro_share_energy
191	oil_share_elec
186	gas_share_elec
183	electricity_generation_per_capita_calc

الجدول 5. أهم الخصائص في نموذج التصنيف

الأهمية	الخاصية
0.766	hydro_share_elec
0.075	hydro_share_energy
0.043	nuclear_share_elec
0.039	electricity_share_energy
0.014	low_carbon_elec_per_capita
0.010	fossil_elec_per_capita
0.009	biofuel_elec_per_capita
0.009	oil_share_elec
0.006	other_renewables_share_elec
0.006	coal_share_elec

وقد وفر تحليل SHAP تفسيرًا إضافيًا لطبيعة تأثير الخصائص في مخرجات النموذج. أظهر المخطط أن ارتفاع بعض مؤشرات الكهرباء منخفضة الكربون، خاصة الكهرباء الكهرومائية والنوية، يرتبط غالبًا بزيادة تنبؤات النموذج لمؤشر الجاهزية. في المقابل، ظهرت بعض مؤشرات الوقود الأحفوري، مثل الكهرباء المعتمدة على النفط أو الفحم، بوصفها مؤشرات ذات أثر تفسيري مهم، لأنها تساعد النموذج على تحديد الفروق بين الدول ذات التحول الأخضر المتقدم والدول الأكثر اعتمادًا على الطاقة التقليدية.



الشكل 10: تفسير أثر الخصائص في مخرجات النموذج باستخدام SHAP

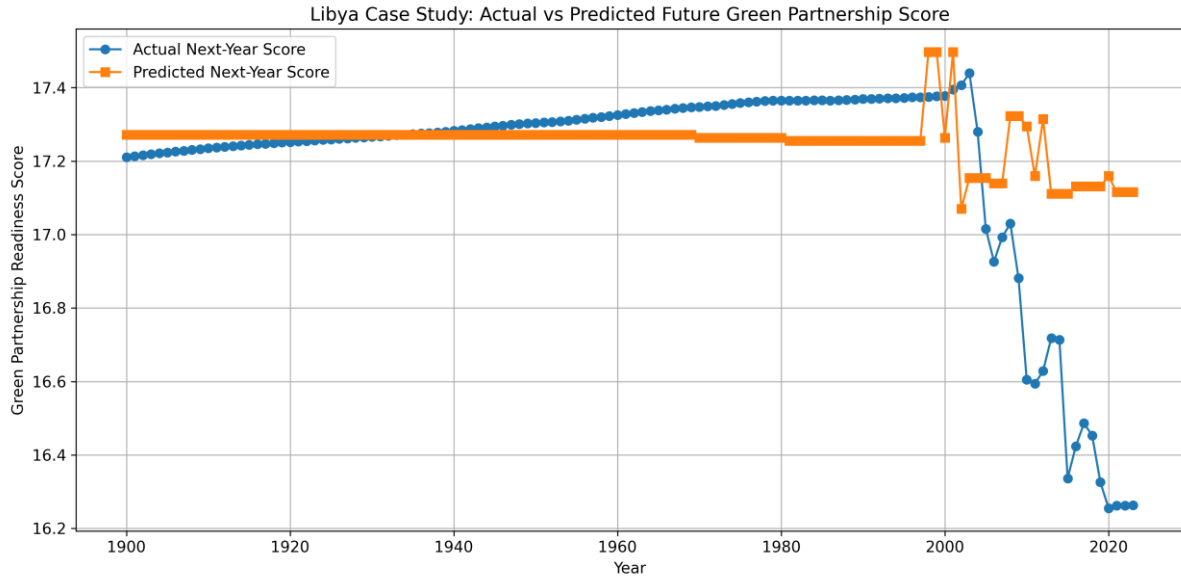
يوضح الشكل أهم المتغيرات التي أثرت في تنبؤات أفضل نموذج انحدار. وتشير القيم الموجبة إلى زيادة متوقعة في مؤشر الجاهزية، بينما تشير القيم السالبة إلى انخفاض متوقع. ويساعد هذا التحليل على فهم العوامل التي يستند إليها النموذج بدلاً من التعامل معه كصندوق أسود.

من الناحية البحثية، تعد هذه النتيجة مهمة لأنها تربط الذكاء الاصطناعي بمتطلبات الحوكمة وصنع القرار. فالنموذج لا يقدم رقمًا نهائيًا فقط، بل يوضح أيضًا العوامل التي ينبغي أن يركز عليها صانع القرار عند تقييم الشراكات الدولية، مثل هيكل الكهرباء، مستوى الاعتماد على الطاقة منخفضة الكربون، واتجاه التحول في مزيج الطاقة. وهذا يعزز قابلية النموذج للاستخدام في مؤسسات التعليم العالي، حيث تتطلب قرارات الشراكة قدرًا من الشفافية والتفسير.

4.6 نتائج دراسة حالة ليبيا

أظهرت نتائج دراسة حالة ليبيا أن مؤشر جاهزية الشراكات الخضراء بقي ضمن فئة الجاهزية المنخفضة خلال الفترة المتاحة في البيانات. فقد تراوحت القيم في السنوات الحديثة حول 16 إلى 17 نقطة تقريبًا على مقياس من 0 إلى 100، وهي قيمة منخفضة مقارنة بالمتوسط العالمي. كما أظهرت النتائج أن نموذج التصنيف صنف ليبيا باستمرار ضمن فئة الجاهزية المنخفضة، سواء في القيم الفعلية أو المتنبأ بها.

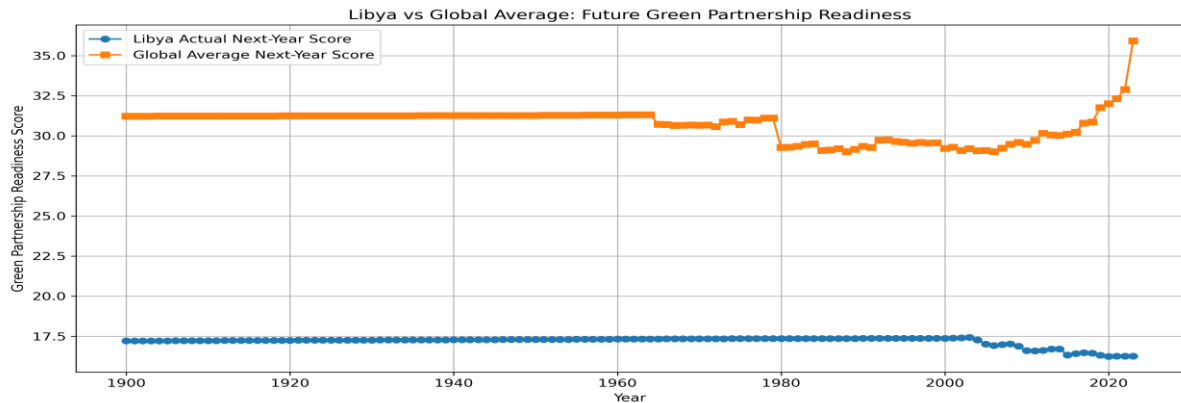
وتشير القيم المستخرجة إلى أن ليبيا سجلت في عام 2019 قيمة فعلية لاحقة بلغت 16.326 تقريباً، بينما توقع النموذج قيمة 17.131. وفي عام 2020 بلغت القيمة الفعلية اللاحقة 16.255، في حين توقع النموذج 17.159. أما في السنوات 2021 إلى 2023، فبقيت القيم الفعلية حول 16.26 تقريباً، بينما ظلت التنبؤات حول 17.12. ويعني ذلك أن النموذج التقط الاتجاه العام لليبيا بوصفها حالة منخفضة الجاهزية، لكنه مال إلى تقدير أعلى قليلاً من القيمة الفعلية في السنوات الحديثة.



الشكل 11: القيم الفعلية والمنتبأ بها لمؤشر جاهزية الشراكات الخضراء في ليبيا

يوضح الشكل مقارنة بين القيم الفعلية لمؤشر جاهزية الشراكات الخضراء في ليبيا والقيم التي تنبأ بها النموذج للسنة اللاحقة. ويظهر أن النموذج حافظ على تصنيف ليبيا ضمن مستوى الجاهزية المنخفضة، مع وجود فرق محدود بين القيم الفعلية والمنتبأ بها في السنوات الحديثة.

وتظهر مقارنة ليبيا بالمتوسط العالمي فجوة واضحة في مستوى الجاهزية. فقد بقي متوسط الجاهزية العالمي أعلى من ليبيا عبر الفترة الزمنية المعروضة، مع اتساع الفجوة في السنوات الأخيرة. وتشير هذه النتيجة إلى أن ليبيا تحتاج إلى تدخلات مؤسسية وتعليمية وبحثية موجهة لتعزيز قدرتها على الدخول في شراكات خضراء أكثر فاعلية. ولا ينبغي تفسير هذه النتيجة بوصفها حكماً نهائياً على قدرة ليبيا، بل بوصفها مؤشراً كمياً يكشف الحاجة إلى سياسات داعمة للتحويل الأخضر، خاصة في مجالات التعليم العالي، البحث التطبيقي، بناء قواعد بيانات وطنية، وتطوير برامج تدريبية مرتبطة بالطاقة النظيفة وإدارة الانبعاثات.




الشكل 12: مقارنة ليبيا بالمتوسط العالمي في جاهزية الشراكات الخضراء

يعرض الشكل الفجوة بين مؤشر جاهزية الشراكات الخضراء في ليبيا والمتوسط العالمي. ويوضح أن ليبيا بقيت دون المتوسط العالمي خلال الفترة المتاحة، مما يدعم الحاجة إلى توظيف الدبلوماسية الاقتصادية الخضراء في بناء شراكات تعليمية وبحثية تساعد على تعزيز التحول المستدام.

من منظور الدبلوماسية الاقتصادية الخضراء، تكشف حالة ليبيا عن أهمية استخدام الذكاء الاصطناعي في تحديد المجالات ذات الأولوية للشراكة. فبدلاً من الاكتفاء بدعوات عامة للتعاون الدولي، يمكن للنموذج أن يساعد مؤسسات التعليم العالي وصناع القرار على توجيه الشراكات نحو المجالات التي تظهر فيها الفجوة الأكبر، مثل الطاقة المتجددة، الكهرباء منخفضة الكربون، إدارة الانبعاثات، وبناء القدرات الفنية. وهذا يعزز القيمة العملية للبحث، إذ يربط التحليل الكمي باحتياجات واقعية في دولة نامية ذات اقتصاد مرتبط بقطاع الطاقة.

4.7 الدول الأعلى جاهزية للشراكات الخضراء المستقبلية

أظهرت نتائج التنبؤ على السجلات الأحدث أن الدول ذات البنية المتقدمة في الطاقة النظيفة ومنخفضة الكربون جاءت في مقدمة الدول المرشحة للشراكات الخضراء المستقبلية. وقد تضمنت المراتب المتقدمة دولاً مثل آيسلندا، النرويج، السويد، سويسرا، فنلندا، البرازيل، والدنمارك. وتعكس هذه النتيجة أن الدول التي تمتلك نسباً مرتفعة من الكهرباء المتجددة أو منخفضة الكربون تظهر بوصفها أكثر جاهزية للشراكات المستدامة، ولا سيما في مجالات التعليم الأخضر، البحث العلمي، ونقل الخبرات الفنية.



الشكل 13: أعلى الدول المتوقعة لجاهزية الشراكات الخضراء المستقبلية

يعرض الشكل أعلى الدول من حيث مؤشر الجاهزية المتوقع للشراكات الخضراء المستقبلية. وتوفر هذه النتائج أساساً عملياً يمكن أن تستفيد منه مؤسسات التعليم العالي عند البحث عن شركاء دوليين في مجالات الاستدامة والطاقة النظيفة وبناء القدرات.

وتشير هذه النتيجة إلى أن النموذج المقترح يمكن أن يعمل كأداة أولية لفرز الشركاء الدوليين المحتملين. فالمؤسسات التعليمية التي ترغب في بناء برامج مشتركة في الاستدامة أو الطاقة المتجددة يمكنها استخدام مثل هذا المؤشر لتحديد الدول الأكثر ملاءمة، ثم الانتقال إلى تقييمات نوعية أعمق تشمل السياسات التعليمية، فرص التمويل، الاتفاقيات الثنائية، والقدرات البحثية. وبذلك، لا يحل النموذج محل القرار البشري أو الدبلوماسي، ولكنه يقدم طبقة تحليلية قائمة على البيانات يمكن أن تجعل القرار أكثر شفافية واتساقاً.

4.8 مناقشة عامة للنتائج

تؤكد النتائج العامة للدراسة أن الذكاء الاصطناعي يمكن أن يؤدي دورًا مهمًا في دعم الدبلوماسية الاقتصادية الخضراء داخل مؤسسات التعليم العالي. فقد أظهرت النماذج المتقدمة قدرة جيدة على التنبؤ بمؤشر جاهزية الشركات الخضراء وتصنيف الدول إلى مستويات مختلفة من الجاهزية. وهذا يعني أن البيانات العالمية المرتبطة بالطاقة والانبعاثات يمكن تحويلها إلى أدوات عملية تساعد في توجيه قرارات الشراكة الدولية، بدلًا من استخدامها فقط في التحليل الوصفي أو التقارير العامة.

كما تكشف النتائج أن نماذج التعزيز مثل Gradient Boosting و LightGBM و XGBoost كانت الأكثر ملاءمة لطبيعة المشكلة. ويرجع ذلك إلى أن جاهزية الشركات الخضراء لا تعتمد على متغير واحد، بل تتشكل من تفاعل عدة مؤشرات، مثل مصادر الكهرباء، الطاقة منخفضة الكربون، الوقود الأحفوري، السكان، وكفاءة الطاقة. وهذه العلاقات غالبًا غير خطية، وهو ما يفسر تفوق النماذج المعززة مقارنة بالانحدار الخطي والنماذج الأبسط.

وتحمل هذه النتائج دلالة مهمة لمؤسسات التعليم العالي. فاختيار الشركاء الدوليين في مجال الاستدامة لا ينبغي أن يكون قرارًا عامًا أو قائمًا فقط على السمعة الأكاديمية، بل يمكن دعمه بمؤشرات كمية تساعد على تحديد الدول الأكثر قدرة على توفير خبرة عملية في التحول الأخضر. ومن هنا، يمكن للجامعات أن تستخدم النموذج المقترح لدعم بناء اتفاقيات تعاون دولية، برامج تدريبية مشتركة، مشروعات بحثية في الطاقة النظيفة، ومبادرات لبناء القدرات في قياس البصمة الكربونية وإدارة الانبعاثات.

أما فيما يتعلق بلبيبا، فتوضح النتائج أن هناك فجوة واضحة بين مستوى الجاهزية المحلي والمتوسط العالمي. وهذه الفجوة لا تعني غياب فرص الشراكة، بل تشير إلى ضرورة توجيه الشركات نحو بناء القدرة المؤسسية والمعرفية أولاً. ويمكن أن تستفيد ليبيا من هذا النوع من النماذج في تحديد الدول الأكثر ملاءمة للتعاون، وفي ترتيب أولويات الشركات التعليمية والبحثية، خاصة في المجالات التي ترتبط بالطاقة المتجددة، التحول منخفض الكربون، وتطوير قواعد بيانات وطنية للطاقة والانبعاثات.

بناءً على ذلك، تقدم الدراسة إسهامًا مزدوجًا. فمن الناحية المنهجية، تقترح إطارًا قابلاً للتكرار لبناء مؤشر جاهزية الشركات الخضراء باستخدام البيانات العالمية وتقنيات الذكاء الاصطناعي. ومن الناحية التطبيقية، تقدم أداة يمكن أن تساعد مؤسسات التعليم العالي وصناع القرار على اتخاذ قرارات أكثر استنادًا إلى البيانات عند تصميم الشركات الدولية المستدامة. وبذلك، تنتقل الدبلوماسية الاقتصادية الخضراء من مستوى الخطاب العام إلى مستوى التحليل الكمي القابل للتطبيق.

الخاتمة

خلصت هذه الدراسة إلى أن الذكاء الاصطناعي يمكن أن يشكل مدخلًا واعدًا لدعم الحوكمة التعليمية الخضراء وتعزيز قدرة مؤسسات التعليم العالي على بناء شراكات دولية مستدامة قائمة على الأدلة. فقد انطلقت الدراسة من الحاجة إلى تجاوز الرؤية التقليدية للشركات التعليمية، التي غالبًا ما تُبنى على الاعتبارات المؤسسية أو الأكاديمية العامة، نحو نموذج أكثر وعيًا بالتحويلات البيئية والاقتصادية العالمية. ومن خلال بناء مؤشر جاهزية الشركات الخضراء، وتوظيف نماذج تنبؤية وتصنيفية، أظهرت النتائج أن البيانات المرتبطة بالطاقة والانبعاثات والتحول منخفض الكربون يمكن تحويلها إلى أداة عملية تساعد في دعم القرار التعليمي والدبلوماسي.

أظهرت النتائج أن النماذج المعززة، ولا سيما Gradient Boosting و LightGBM و XGBoost، كانت الأكثر قدرة على التنبؤ بمستويات الجاهزية المستقبلية وتصنيفها، مما يؤكد أن العلاقات بين مؤشرات الطاقة والاستدامة والشركات الخضراء ذات طبيعة مركبة وغير خطية. كما بينت دراسة حالة ليبيا أن مستوى الجاهزية ظل ضمن الفئة المنخفضة مقارنة بالمتوسط العالمي، وهو ما يبرز الحاجة إلى شراكات تعليمية وبحثية موجهة نحو بناء القدرات المؤسسية، وتطوير قواعد بيانات وطنية، وتعزيز برامج الطاقة النظيفة وإدارة الانبعاثات.

وعلى الرغم من أهمية النتائج، واجهت الدراسة بعض التحديات، أبرزها تفاوت جودة البيانات بين الدول، ووجود قيم مفقودة في عدد من المؤشرات، إضافة إلى محدودية بعض البيانات الخاصة بلبيبا مقارنة بالسياق العالمي. لذلك توصي الدراسة بضرورة تطوير قواعد بيانات وطنية دقيقة ومحدثة حول الطاقة والانبعاثات، ودمج مفاهيم الاستدامة والذكاء الاصطناعي في سياسات التعليم العالي، وتوجيه الشركات الدولية نحو بناء القدرات البحثية والتقنية في مجالات التحول الأخضر. كما توصي مؤسسات التعليم العالي باستخدام النماذج الذكية كأدوات مساندة، لا كبديل عن القرار البشري، لضمان توازن التحليل الكمي مع الرؤية المؤسسية والاستراتيجية.

أما الأعمال المستقبلية، فيمكن أن تتجه إلى توسيع النموذج بإضافة مؤشرات تعليمية مباشرة، مثل جودة التعليم، الإنفاق على البحث العلمي، وبراءات الاختراع الخضراء، إضافة إلى اختبار النموذج على دول عربية أخرى للمقارنة. كما يمكن تطوير منصة ذكية تفاعلية تساعد الجامعات وصناع القرار على تقييم الشركاء الدوليين المحتملين في ضوء أهداف الاستدامة. وبذلك

تقدم هذه الدراسة إسهامًا علميًا وتطبيقيًا يتمثل في ربط الذكاء الاصطناعي بالحوكمة التعليمية الخضراء، وتحويل الدبلوماسية الاقتصادية المستدامة من مفهوم عام إلى إطار قابل للقياس والتطبيق.

المراجع

- AlSagri, H. S., & Sohail, S. S. (2024). Evaluating the role of artificial intelligence in sustainable development goals with an emphasis on “quality education”. *Discover Sustainability*. <https://doi.org/10.1007/s43621-024-00682-9>
- Blasco, N., Brusca, I., & Labrador, M. (2021). Drivers for universities' contribution to the sustainable development goals: An analysis of Spanish public universities. *Sustainability*, 13(1), 89. <https://doi.org/10.3390/su13010089>
- Bond, M., Khosravi, H., De Laat, M., Bergdahl, N., Negrea, V., Oxley, E., Pham, P., Chong, S. W., & Siemens, G. (2024). A meta systematic review of artificial intelligence in higher education: A call for increased ethics, collaboration, and rigour. *International Journal of Educational Technology in Higher Education*, 21, 4. <https://doi.org/10.1186/s41239-023-00436-z>
- Budenny, S., Lazarev, V., Zakharenko, N., Korovin, A., Plosskaya, O., Dimitrov, D., Arkhipkin, V., Oseledets, I., Barsola, I., Egorov, I., Kosterina, A., & Zhukov, L. (2022). Eco2AI: Carbon emissions tracking of machine learning models as the first step towards sustainable AI. *arXiv*. <https://doi.org/10.48550/arXiv.2208.00406>
- Caldarola, B., Mazzilli, D., Napolitano, L., Patelli, A., & Sbardella, A. (2023). Economic complexity and the sustainability transition: A review of data, methods, and literature. *arXiv*. <https://doi.org/10.48550/arXiv.2308.07172>
- Chang, Y. C., Lien, H. L., & Chen, C. Y. (2020). Mapping course sustainability by embedding the SDGs inventory into the university curriculum: A case study from National University of Kaohsiung in Taiwan. *Sustainability*, 12(10), 4274. <https://doi.org/10.3390/su12104274>
- Chankseliani, M., & McCowan, T. (2021). Higher education and the sustainable development goals. *Higher Education*, 81, 1–8. <https://doi.org/10.1007/s10734-020-00652-w>
- Chiu, T. K. F., Xia, Q., Zhou, X., Chai, C. S., & Cheng, M. (2023). Systematic literature review on opportunities, challenges, and future research recommendations of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 4, 100118. <https://doi.org/10.1016/j.caeai.2022.100118>
- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: The state of the field. *International Journal of Educational Technology in Higher Education*, 20, 22. <https://doi.org/10.1186/s41239-023-00392-8>
- De la Poza, E., Merello, P., Barberá, A., & Celani, A. (2021). Universities' reporting on SDGs: Using the impact rankings to model and measure their contribution to sustainability. *Sustainability*, 13(4), 2038. <https://doi.org/10.3390/su13042038>
- Efficacy of Curcumin on Inflammatory Biomarkers in Type 2 Diabetes: A Meta-Analysis of Clinical Trials and Animal Studies Systematic Review & Meta-Analysis (PRISMA 2020) Field: Botany & Complementary Medicine. (2026). *مجلة الفاروق للعلوم*, 2(2), 15-35. <https://doi.org/10.65405/9wp1fk50>
- Ecological Assessment and Local Knowledge of the Invasive Lionfish (*Pterois miles*) in the Coastal Waters of Derna, Eastern Libya. (2026). *مجلة الفاروق للعلوم*, 2(2), 1-14. <https://doi.org/10.65405/mf6ss418>
- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, P. V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. D. (2021). Artificial intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57, 101994. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>

- Ferk Savec, V., & Jedrinović, S. (2025). The role of AI implementation in higher education in achieving the sustainable development goals: A case study from Slovenia. *Sustainability*, *17*(1), 183. <https://doi.org/10.3390/su17010183>
- García-Feijoo, M., Eizaguirre, A., & Rica-Aspiunza, A. (2020). Systematic review of sustainable-development-goal deployment in business schools. *Sustainability*, *12*(1), 440. <https://doi.org/10.3390/su12010440>
- Henderson, P., Hu, J., Romoff, J., Brunskill, E., Jurafsky, D., & Pineau, J. (2020). Towards the systematic reporting of the energy and carbon footprints of machine learning. *Journal of Machine Learning Research*, *21*(248), 1–43.
- Horan, D. (2022). A framework to harness effective partnerships for the sustainable development goals. *Sustainability Science*, *17*, 1573–1587. <https://doi.org/10.1007/s11625-021-01070-2>
- Katsamakas, E., Pavlov, O. V., & Saklad, R. (2024). Artificial intelligence and the transformation of higher education institutions: A systems approach. *Sustainability*, *16*(14), 6118. <https://doi.org/10.3390/su16146118>
- Leal Filho, W., Lange Salvia, A., Frankenberger, F., Akib, N. A. M., Sen, S. K., Sivapalan, S., Novo-Corti, I., Venkatesan, M., & Emblen-Perry, K. (2021). Governance and sustainable development at higher education institutions. *Environment, Development and Sustainability*, *23*, 6002–6020. <https://doi.org/10.1007/s10668-020-00859-y>
- Leal Filho, W., Ribeiro, P. C. C., Mazutti, J., Lange Salvia, A., Marcolin, C. B., Borsatto, J. M. L. S., Sharifi, A., Sierra, J., Luetz, J., Pretorius, R., & Trevisan, L. V. (2024). Using artificial intelligence to implement the UN sustainable development goals at higher education institutions. *International Journal of Sustainable Development & World Ecology*, *31*(6), 1–20. <https://doi.org/10.1080/13504509.2024.2327584>
- Mhlanga, D. (2021). Artificial intelligence in the Industry 4.0, and its impact on poverty, innovation, infrastructure development, and the sustainable development goals: Lessons from emerging economies? *Sustainability*, *13*(11), 5788. <https://doi.org/10.3390/su13115788>
- Serafini, P. G., de Moura, J. M., de Almeida, M. R., & de Rezende, J. F. D. (2022). Sustainable development goals in higher education institutions: A systematic literature review. *Journal of Cleaner Production*, *370*, 133473. <https://doi.org/10.1016/j.jclepro.2022.133473>
- Trevisan, L. V., Eustachio, J. H. P. P., Dias, B. G., Leal Filho, W., & Pedrozo, E. A. (2023). Digital transformation towards sustainability in higher education: State-of-the-art and future research insights. *Environment, Development and Sustainability*. <https://doi.org/10.1007/s10668-022-02874-7>
- Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., Felländer, A., Langhans, S. D., Tegmark, M., & Fuso Nerini, F. (2020). The role of artificial intelligence in achieving the sustainable development goals. *Nature Communications*, *11*, 233. <https://doi.org/10.1038/s41467-019-14108-y>