*Al-Farouk journal of sciences*
Volume (2), Issue (5) (Nov, 2026)
ISSN: 3135-2359

**مجلة الفاروق للعلوم**
**المجلد (2) العدد 5 نوفمبر 2026**
**عدد خاص بالمؤتمر العلمي الرابع للعلوم والتقنية**
**28-29 نوفمبر 2026 مصراتة – ليبيا**
إدارة المعاهد العليا – وزارة التعليم التقني

# تقييم أثر التحول إلى الطاقة المتجددة في الحد من انبعاثات الكربون: دراسة تحليلية باستخدام خوارزميات التجميع والتصنيف.

***أمان سالم سعيد المشلوم[1]**

**المعهد العالي للعلوم والتقنية، المشاشية، ليبيا [1].**

# Assessing the Impact of the Transition to Renewable Energy on Reducing Carbon Emissions: An Analytical Study Using Clustering and Classification Algorithms

**Aman Salem Saeed Al Mashloum1***

**1 Higher Institute of Science and Technology, Al-Mashashiyah, Libya, e2015201620@gmail.com**

**Corresponding email: e2015201620@gmail.com**

***تاريخ الاستلام: 2026/7/30 تاريخ المراجعة 2026/8/20 تاريخ القبول:2026/8/28- تاريخ النشر: 2026/11/28***

**الملخص:**

يُعد التحول إلى الطاقة المتجددة أمراً حاسماً للتخفيف من حدة تغير المناخ وتحقيق أهداف الأمم المتحدة للتنمية المستدامة (الهدفان 7 و13). ومع ذلك، فإن قياس الأثر الكمي الدقيق لاعتماد الطاقة المتجددة على تقليل انبعاثات ثاني أكسيد الكربون ($CO_2$) يتطلب أطر عمل تحليلية قوية قائمة على البيانات. تقيّم هذه الدراسة دور الطاقة المتجددة في تقليل انبعاثات الكربون باستخدام مجموعة بيانات شاملة تضم 3,649 سجلاً لـ 176 دولة خلال الفترة من 2000 إلى 2020. نقترح منهجية هجينة للتعلم الآلي تجمع بين التجميع غير الخاضع للإشراف (K-Means) لبناء ملفات تعريف طاقية للدول، والتصنيف الخاضع للإشراف للتنبؤ بمستويات الانبعاثات. تم تدريب وتقييم خمس خوارزميات: الانحدار اللوجستي، وآلات المتجهات الداعمة(SVM) ، والغابة العشوائية(RF) ، وتعزيز التدرج(Gradient Boosting) ، و XGBoost. أظهر نموذج الغابة العشوائية أداءً متفوقاً، حيث حقق درجة F1 بلغت **[0.88]**ومساحة تحت المنحنى (AUC)بلغت .**[0.91]**علاوة على ذلك، كشف تحليل أهمية الميزات أن حصة الطاقة المتجددة تساهم بنسبة **[22.5]%** في القوة التنبؤية للنموذج، مما يؤكد دورها الكبير إلى جانب الناتج المحلي الإجمالي وإجمالي استهلاك الطاقة. نجح تحليل التجميع في تحديد ثلاثة ملفات تعريف وطنية متميزة للطاقة. توفر هذه النتائج أدلة تجريبية تدعم الفرضية القائلة بأن التحول إلى الطاقة المتجددة يقلل بشكل كبير من انبعاثات الكربون، مما يقدم رؤى قابلة للتطبيق لصانعي القرار لتحسين استراتيجيات الطاقة المستدامة.

**الكلمات المفتاحية:** الطاقة المتجددة، انبعاثات الكربون، التعلم الآلي، تجميع K-Means، الغابة العشوائية، أهداف التنمية المستدامة.

## 1- المقدمة

تُشكل أزمة تغير المناخ المتصاعدة، والتي يغذيها بشكل أساسي تراكم غازات الدفيئة، تهديداً غير مسبوق للاستقرار البيئي والاقتصادي العالمي [1]. ومن بين هذه الغازات، يُعد ثاني أكسيد الكربون ($CO_2$) المنبعث من احتراق الوقود الأحفوري لإنتاج الطاقة المساهم الأكبر في ظاهرة الاحتباس الحراري العالمي [2]. واستجابةً لذلك، أقر المجتمع الدولي أهداف الأمم المتحدة للتنمية المستدامة(SDGs) ، وتحديداً الهدف السابع (طاقة نظيفة وبأسعار معقولة) والهدف الثالث عشر (العمل المناخي)، واللذين يؤكدان على الحاجة الملحة للانتقال نحو أنظمة طاقة مستدامة ومنخفضة الكربون [3]. وبناءً على ذلك، أصبح التحول من الوقود الأحفوري إلى مصادر الطاقة المتجددة – مثل الطاقة الشمسية وطاقة الرياح والطاقة الكهرومائية – ركيزة أساسية في السياسات البيئية العالمية.

على الرغم من التوافق العالمي على ضرورة اعتماد الطاقة المتجددة، إلا أن القياس الدقيق لأثرها على تقليل انبعاثات ثاني أكسيد الكربون عبر السياقات الوطنية المتنوعة لا يزال يمثل تحدياً معقداً. غالباً ما تعجز الأساليب الاقتصادية القياسية والإحصائية التقليدية عن التقاط العلاقات غير الخطية ومتعددة الأبعاد بين أنماط استهلاك الطاقة، والنمو الاقتصادي (الناتج المحلي الإجمالي)، وانبعاثات الكربون، خاصة عند التعامل مع مجموعات بيانات عالمية ضخمة وغير متجانسة [4]. علاوة على ذلك، تظهر الدول ملفات تعريف طاقية مختلفة تماماً؛ فبينما نجحت بعض الدول في دمج حصص عالية من الطاقة

المتجددة مع نمو اقتصادي قوي، لا تزال دول أخرى تعتمد بشكل كبير على الوقود الأحفوري رغم مؤشرات اقتصادية مشابهة. هذا التباين يستدعي أطر عمل تحليلية متقدمة قادرة على كشف الأنماط الخفية وتقديم رؤى دقيقة قائمة على البيانات.

في الآونة الأخيرة، برز التعلم الآلي (ML) والذكاء الاصطناعي (AI) كأدوات قوية لمعالجة المشكلات البيئية والطاقية المعقدة [5]. وعلى عكس النماذج الإحصائية التقليدية، يمكن لخوارزميات التعلم الآلي معالجة كميات هائلة من البيانات بكفاءة، وتحديد الارتباطات غير الخطية، وتوليد نماذج تنبؤية عالية الدقة. تتيح خوارزميات التجميع(Clustering) ، مثل K–Means، التجميع غير الخاضع للإشراف للدول في ملفات طاقية متميزة، بينما يمكن لنماذج التصنيف الخاضع للإشراف (Supervised Classification)، مثل الغابة العشوائية (Random Forest) وXGBoost، التنبؤ بمستويات الانبعاثات وقياس الأهمية النسبية لمختلف العوامل المساهمة [6]. ومع ذلك، هناك فجوة ملحوظة في الأدبيات فيما يتعلق بالدراسات التي تجمع بين التجميع غير الخاضع للإشراف والتصنيف الخاضع للإشراف لتقييم التأثير الشامل للطاقة المتجددة على انبعاثات الكربون باستخدام بيانات عالمية حقيقية وشاملة.

لمعالجة هذه الفجوة، تقترح هذه الدراسة إطار عمل هجين للتعلم الآلي لتقييم أثر التحول إلى الطاقة المتجددة على تقليل انبعاثات ثاني أكسيد الكربون. باستخدام مجموعة بيانات شاملة تضم 3,649 سجلاً لـ 176 دولة خلال الفترة من 2000 إلى 2020، يسعى البحث لتحقيق ثلاثة أهداف رئيسية: (1) تجميع الدول في مجموعات متميزة بناءً على ملفات استهلاك الطاقة والانبعاثات الخاصة بها؛ (2) التنبؤ بما إذا كانت الدولة مصدراً عالياً أو منخفضاً لانبعاثات $CO_2$ باستخدام خوارزميات تصنيف خاضع للإشراف متعددة؛ و(3) قياس الأثر الكمي النسبي لحصة الطاقة المتجددة مقارنة بالمؤشرات الاقتصادية والطاقية الأخرى.

تسترشد الدراسة بأسئلة البحث التالية: **أولاً**، هل يمكن تجميع الدول بشكل فعال في عناقيد متميزة بناءً على سلوكياتها الطاقية والانبعاثية؟ **ثانياً**، ما مدى دقة نماذج التعلم الآلي في تصنيف الدول إلى فئات انبعاثات عالية ومنخفضة؟ **ثالثاً**، ما هو العامل الأكثر تأثيراً، وتحديداً حصة الطاقة المتجددة، في تحديد مستوى انبعاثات الكربون للدولة؟

تتمثل المساهمات الرئيسية لهذه الورقة في ثلاثة جوانب. أولاً، تقديم نهج تحليلي هجين يدمج بين تجميع K–Means لبناء الملفات الطاقية والتصنيف الخاضع للإشراف للتنبؤ بالانبعاثات. ثانياً، توفير مقارنة تجريبية دقيقة لخمس خوارزميات حديثة للتعلم الآلي) الانحدار اللوجستي، SVM، الغابة العشوائية، تعزيز التدرج، و (XGBoostعلى مجموعة بيانات عالمية واسعة النطاق. ثالثاً، استخدام تحليل أهمية الميزات (Feature Importance) لاستخلاص رؤى كمية وقابلة للتطبيق حول المساهمة المحددة للطاقة المتجددة في التخفيف من الانبعاثات، مما يقدم توصيات قائمة على الأدلة لصانعي القرار.

نُظمت بقية هذه الورقة على النحو التالي: يستعرض القسم الثاني الأدبيات ذات الصلة حول التحول إلى الطاقة المتجددة وتطبيقات الذكاء الاصطناعي في الاستدامة. يوضح القسم الثالث مجموعة البيانات، وخطوات المعالجة المسبقة، ومنهجية التعلم الآلي المقترحة. يعرض القسم الرابع النتائج التجريبية، بما في ذلك مخرجات التجميع والتصنيف. يناقش القسم الخامس النتائج وتداعياتها ومحددات الدراسة واتجاهات البحث المستقبلي. وأخيراً، يختتم القسم السادس الورقة بأبرز النتائج والتوصيات.

2- مراجعة الأدبيات

يستعرض هذا القسم المعرفة الموجودة حول العلاقة بين اعتماد الطاقة المتجددة وانبعاثات الكربون، وتطبيق التعلم الآلي في أبحاث الاستدامة، واستخدام تقنيات التجميع في تحليل سياسات الطاقة. وتُختتم المراجعة بتحديد الفجوات البحثية التي تهدف هذه الدراسة إلى معالجتها.

أ- التحول إلى الطاقة المتجددة وانبعاثات الكربون

تمت دراسة العلاقة بين استهلاك الطاقة المتجددة وانبعاثات ثاني أكسيد الكربون على نطاق واسع في أدبيات الاقتصاد البيئي وسياسات الطاقة. أسس العمل الأساسي لـ [7] فرضية منحنى كوزنيتس البيئي(EKC) ، التي تفترض أن التدهور البيئي يزداد مع النمو الاقتصادي حتى عتبة معينة، بعدها يبدأ في الانخفاض. وقد وسعت دراسات لاحقة هذا الإطار لدمج هيكل الطاقة كمحدد رئيسي للانبعاثات.[8]

أظهرت التحقيقات التجريبية الأخيرة باستمرار وجود ارتباط سلبي بين حصة الطاقة المتجددة وانبعاثات $CO_2$. حلل العمل في [9] بيانات من 80 دولة على مدار عقدين ووجد أن زيادة بنسبة 1% في استهلاك الطاقة المتجددة ترتبط بانخفاض بنسبة 0.5% تقريباً في انبعاثات الكربون. وبالمثل، فحص [10] دور مصادر متجددة محددة (الشمسية، الرياح، الكهرومائية) وخلص إلى أن طاقة الرياح والطاقة الشمسية لهما التأثير الأكبر في التخفيف من الانبعاثات في الاقتصادات المتقدمة، بينما تلعب الطاقة الكهرومائية دوراً مهيماً في الدول النامية.

ومع ذلك، فإن القيد المتكرر في هذه الدراسات هو اعتمادها على النماذج الاقتصادية القياسية التقليدية – مثل انحدار بيانات اللوحة وتحليل التكامل المشترك – والتي قد تفشل في التقاط التفاعلات المعقدة وغير الخطية بين متغيرات متعددة [11]. هذا القيد يحفز استكشاف نهج تحليلية أكثر تقدماً.

ب- تطبيقات التعلم الآلي في أبحاث الاستدامة

اكتسب تطبيق التعلم الآلي (ML) على مشكلات الاستدامة والطاقة زخماً كبيراً في السنوات الأخيرة. تقدم خوارزميات التعلم الآلي مزايا مميزة مقارنة بالطرق الإحصائية التقليدية، بما في ذلك القدرة على معالجة البيانات عالية الأبعاد، والتقاط العلاقات غير الخطية، وتوليد نماذج تنبؤية دقيقة دون الحاجة إلى افتراضات توزيعية صارمة.[12]

استخدمت عدة دراسات التعلم الآلي للتنبؤ بانبعاثات الكربون والتنبؤ بالطاقة. استخدم العمل في [13] الغابة العشوائية (Random Forest)وانحدار المتجهات الداعمة (SVR) للتنبؤ بانبعاثات $CO_2$ في الصين، محققاً دقة تفوق نماذج ARIMAالتقليدية. وبالمثل، طبق XGBoost [14] للتنبؤ بأنماط استهلاك الطاقة في الدول الأوروبية، مظهراً فعاليته في معالجة البيانات غير المتجانسة.

في سياق الطاقة المتجددة، طور [15] إطار تعلم عميق باستخدام شبكات الذاكرة قصيرة المدى طويلة المدى (LSTM) للتنبؤ بتوليد الطاقة الشمسية وطاقة الرياح. وعلى الرغم من دقتها العالية، غالباً ما تتطلب مثل هذه النهج العميقة موارد حاسوبية كبيرة ومجموعات بيانات ضخمة، مما يحد من قابليتها للتطبيق في البيئات محدودة الموارد. علاوة على ذلك، تركز معظم الدراسات الحالية حصرياً على مهام التنبؤ، مهملةً الإمكانات الكامنة في تقنيات التعلم غير الخاضع للإشراف للتحليل الاستكشافي واكتشاف الأنماط.

ت- تقنيات التجميع في تحليل سياسات الطاقة

تم تطبيق خوارزميات التجميع، ولا سيماK–Means ، بشكل متزايد في أبحاث سياسات الطاقة لتحديد الأنماط وتجميع الكيانات المتشابهة. استخدم العمل في [16] تجميع K–Means لتصنيف الدول الأوروبية بناءً على ملفات كفاءة الطاقة الخاصة بها، كاشفاً عن أنماط إقليمية متميزة أرشدت توصيات سياسات مستهدفة.

في دراسة ذات صلة، طبق [17] التجميع الهرمي لتجميع الدول وفقاً لمسارات اعتمادها على الطاقة المتجددة، محدداً ثلاث مجموعات أساسية تتوافق مع "القادة" و"التابعين" و"المتأخرين" في التحول الطاقي. وفي حين تظهر هذه الدراسات فائدة التجميع لتحليل السياسات، إلا أنها عادةً لا تدمج التجميع مع التصنيف الخاضع للإشراف لقياس تأثير عوامل محددة على نتائج مثل انبعاثات الكربون.

ث- الفجوة البحثية وتموضع هذه الدراسة

على الرغم من الأدبيات المتنامية، لا تزال هناك عدة فجوات حرجة:

1. **الفجوة المنهجية** :تستخدم معظم الدراسات إما الأساليب الاقتصادية القياسية التقليدية أو تقنيات التعلم الآلي بشكل منفصل. هناك ندرة في الأبحاث التي تجمع بين التجميع غير الخاضع للإشراف (لاكتشاف الأنماط الاستكشافية) والتصنيف الخاضع للإشراف (للتنبؤ وتحليل أهمية الميزات) في إطار عمل موحد.

2. **الفجوة التحليلية** :في حين أن العديد من الدراسات تتنبأ بانبعاثات الكربون، هناك القليل منها يحاول قياس المساهمة النسبية الكمية للطاقة المتجددة مقارنة بالعوامل الأخرى باستخدام تقنيات أهمية الميزات.

3. **فجوة نطاق البيانات** :تركز العديد من الدراسات الحالية على مناطق محددة أو دول فردية، مما يحد من قابلية تعميم نتائجها. التحليلات العالمية الشاملة التي تغطي عقوداً متعددة لا تزال نادرة نسبياً.

تعالج هذه الدراسة هذه الفجوات من خلال اقتراح إطار عمل هجين للتعلم الآلي يدمج تجميع K–Means لبناء ملفات تعريف طاقية للدول مع خوارزميات تصنيف خاضع للإشراف متعددة للتنبؤ بالانبعاثات وتحليل أهمية الميزات. باستخدام مجموعة بيانات عالمية شاملة تمتد لـ 20 عاماً و176 دولة، يوفر البحث رؤى استكشافية ودقة تنبؤية، مقدماً فهماً أكثر شمولية للعلاقة بين الطاقة المتجددة والانبعاثات.

يوفر الجدول (1) ملخصاً مقارناً للدراسات السابقة ويبرز المساهمات المميزة للعمل الحالي.

**الجدول (1):** مقارنة بين الدراسات السابقة والدراسة الحالية

| المرجع | الطريقة | نطاق البيانات | الهدف | القيد الرئيسي |
|---|---|---|---|---|
| [9] | انحدار بيانات اللوحة | 80دولة، 20 سنة | ارتباط الانبعاثات-المتجددة | افتراضات خطية |
| [10] | تحليل اقتصادي قياسي | دولOECD | التأثير حسب المصدر | قيد إقليمي |
| [13] | Random Forest, SVR | الصين (دولة واحدة) | التنبؤ بـ$CO_2$ | تركيز على دولة واحدة |
| [14] | XGBoost | دول أوروبية | التنبؤ بالطاقة | لا يحتوي على عنصر تجميع |
| [15] | LSTM (تعلم عميق) | بيانات إقليمية | التنبؤ بتوليد الطاقة المتجددة | تكلفة حاسوبية عالية |
| [16] | تجميعK-Means | دول أوروبية | بناء ملفات كفاءة الطاقة | لا يوجد نمذجة تنبؤية |

| المرجع | الطريقة | نطاق البيانات | الهدف | القيد الرئيسي |
|---|---|---|---|---|
| [17] | تجميع هرمي | عينة عالمية | تجميع مسارات الاعتماد | لا يوجد تعلم خاضع للإشراف |
| هذه الدراسة | K-Means + 5مصنفات تعلم آلي | 176دولة، 20 سنة | بناء ملفات هجين + تنبؤ + أهمية الميزات | نهج شامل |

3- البيانات والمنهجية

يعرض هذا القسم مجموعة البيانات المستخدمة في هذه الدراسة، وخطوات المعالجة المسبقة للبيانات، ومنهجية التعلم الآلي المقترحة. يدمج الإطار التحليلي بين التجميع غير الخاضع للإشراف للتحليل الاستكشافي والتصنيف الخاضع للإشراف للنمذجة التنبؤية وتقييم الأثر.

ج- وصف مجموعة البيانات

تستخدم الدراسة مجموعة بيانات "Global Data on Sustainable Energy"، المتاحة للعامة على Kaggle [1]. تغطي هذه المجموعة الشاملة 176 دولة على مدى فترة 20 عاماً (2000–2020)، وتتألف من 3,649 ملاحظة و21 متغيراً. تتضمن مجموعة البيانات مؤشرات تتعلق بالوصول إلى الطاقة، واعتماد الطاقة المتجددة، وأنماط استهلاك الطاقة، والمقاييس الاقتصادية، وانبعاثات الكربون، مما يجعلها مناسبة جداً لتحليل العلاقة بين الطاقة المتجددة والانبعاثات.

تلخص الجدول (2) المتغيرات الرئيسية المحددة لهذه الدراسة.

**الجدول (2):** المتغيرات الرئيسية المستخدمة في الدراسة

| اسم المتغير | النوع | الوصف | الوحدة |
|---|---|---|---|
| Entity | فئوي | اسم الدولة | — |
| Year | رقمي | سنة الملاحظة(2000-2020) | سنة |
| حصة الطاقة المتجددة | رقمي | حصة الطاقة المتجددة في إجمالي استهلاك الطاقة النهائي | % |
| انبعاثات$CO_2$ | رقمي | إجمالي انبعاثات $CO_2$ حسب الدولة (كيلو طن) | كيلو طن |
| الناتج المحلي الإجمالي للفرد | رقمي | الناتج المحلي الإجمالي للفرد | دولار أمريكي |
| استهلاك الطاقة الأولية | رقمي | استهلاك الطاقة للفرد | كيلو واط ساعة/شخص |
| الكهرباء من الوقود الأحفوري | رقمي | الكهرباء المولدة من الوقود الأحفوري | تيرا واط ساعة |
| الكهرباء من المتجددة | رقمي | الكهرباء المولدة من مصادر متجددة | تيرا واط ساعة |
| الكهرباء منخفضة الكربون | رقمي | حصة المصادر منخفضة الكربون في توليد الكهرباء | % |
| كثافة الطاقة | رقمي | كثافة الطاقة الأولية | ميغاجول/دولار |

ح- المعالجة المسبقة للبيانات

قبل التحليل، خضعت مجموعة البيانات لعدة خطوات معالجة مسبقة لضمان جودة البيانات وتوافقها مع خوارزميات التعلم الآلي:

التعامل مع القيم المفقودة: تم إزالة السجلات التي تحتوي على قيم مفقودة في المتغيرات الأساسية الثلاثة (حصة الطاقة المتجددة، انبعاثات $CO_2$، والناتج المحلي الإجمالي للفرد). أدى هذا إلى تقليل مجموعة البيانات من 3,649 إلى حوالي 3,500 سجل كامل.

تحويل أنواع البيانات: تم تحويل جميع الأعمدة الرقمية صراحةً إلى أنواع رقمية مناسبة لمنع أخطاء التحليل.

اختيار الميزات: تم تحديد تسع ميزات رئيسية بناءً على صلتهن بأهداف البحث وتوفرهن عبر مجموعة البيانات.

إنشاء المتغير المستهدف: تم إنشاء متغير ثنائي مستهدف High_Emitter عن طريق تقسيم انبعاثات $CO_2$ عند قيمة الوسيط. تم تصنيف الدول التي تزيد انبعاثاتها عن الوسيط كـ 1 (انبعاثات عالية)، وتلك التي تقل كـ 0 (انبعاثات منخفضة).

توحيد المقياس: بالنسبة للخوارزميات الحساسة لحجم الميزات (الانحدار اللوجستي وSVM)، تم توحيد الميزات باستخدام StandardScaler ليكون لها متوسط صفري وتباين وحدة. النماذج القائمة على الأشجار (Random Forest، Gradient Boosting، XGBoost) لا تتطلب توحيد المقياس وتم تدريبها على فضاء الميزات الأصلي.

تلخص الجدول (3) خط أنابيب المعالجة المسبقة.

**الجدول (3):** خطوات المعالجة المسبقة للبيانات

| الخطوة | العملية | التفاصيل |
|---|---|---|
| 1 | إزالة القيم المفقودة | حذف الصفوف التي تحتوي على NaN في المتغيرات الأساسية |
| 2 | تحويل النوع | تحويل جميع الأعمدة الرقمية إلىfloat |
| 3 | اختيار الميزات | تحديد 9 ميزات ذات صلة |
| 4 | إنشاء المتغير المستهدف | تصنيف ثنائي بناءً على وسيط$CO_2$ |
| 5 | تقسيم التدريب-الاختبار | 80%تدريب، 20% اختبار (طبقي) |
| 6 | توحيد المقياس | StandardScalerللنماذج القائمة على المسافة |

خ- المنهجية المقترحة

يتكون الإطار التحليلي من أربع مراحل متسلسلة، كما هو موضح في الشكل (1).




**الشكل (1):** الإطار المفاهيمي للمنهجية المقترحة

1) المرحلة الأولى: التحليل الاستكشافي للبيانات (EDA)

تنطوي المرحلة الأولى على تحليل استكشافي شامل لفهم توزيع البيانات، وتحديد الارتباطات، وتصور العلاقات بين المتغيرات الرئيسية. وتحديداً:

تحليل الارتباط: تم حساب معاملات ارتباط بيرسون لتحديد العلاقات الخطية بين المتغيرات.

تحليل التوزيع: تم إنشاء المدرجات التكرارية ومخططات التشتت لفحص توزيع انبعاثات $CO_2$ وعلاقتها بحصة الطاقة المتجددة والناتج المحلي الإجمالي.

2) المرحلة الثانية: التجميع غير الخاضع للإشراف (K-Means)

لتحديد ملفات تعريف طاقية متميزة للدول، تم تطبيق تجميع K–Means. تم تحديد العدد الأمثل للمجموعات (K) باستخدام طريقة الكوع (Elbow Method)، التي ترسم مجموع مربعات المسافات داخل المجموعة (inertia) مقابل قيم مختلفة لـ K. كشف التحليل أن K=3 يوفر أفضل توازن بين تعقيد النموذج والقوة التفسيرية.

تضمنت عملية التجميع:

توحيد المقياس للميزات الأساسية الثلاثة (حصة الطاقة المتجددة، انبعاثات $CO_2$، الناتج المحلي الإجمالي للفرد).

تطبيق K–Means مع K=3 وتهيئة عشوائية.

تصور المجموعات باستخدام تحليل المكونات الرئيسية (PCA) لتقليل الأبعاد.

3) المرحلة الثالثة: التصنيف الخاضع للإشراف

للتنبؤ بما إذا كانت الدولة مصدراً عالياً أو منخفضاً لانبعاثات $CO_2$، تم تدريب وتقييم خمس خوارزميات تصنيف خاضع للإشراف:

الانحدار اللوجستي (LR): نموذج خطي أساسي.

آلات المتجهات الداعمة (SVM): مع نواة دالة الأساس الشعاعي (RBF) لالتقاط العلاقات غير الخطية.

الغابة العشوائية (RF): مجموعة من أشجار القرار توفر تنبؤات قوية ودرجات أهمية الميزات.

تعزيز التدرج (GB): طريقة مجموعة تسلسلية تبني أشجاراً لتصحيح أخطاء الأشجار السابقة.

XGBoost: تنفيذ محسن لتعزيز التدرج معروف بسرعته وأدائه.

تم تدريب كل نموذج على مجموعة التدريب (80% من البيانات) وتقييمها على مجموعة الاختبار (20% من البيانات) باستخدام أخذ العينات الطبقي للحفاظ على توازن الفئات. تم تقييم أداء النموذج باستخدام مقاييس متعددة: الدقة (Accuracy)، الدقة (Precision)، الاستدعاء (Recall)، درجة F1 (F1–Score)، ومساحة تحت منحنى خاصية تشغيل المستقبل (AUC–ROC).

4) المرحلة الرابعة: تقييم الأثر عبر أهمية الميزات

تستفيد المرحلة النهائية من قابلية التفسير الكامنة في النماذج القائمة على الأشجار، ولا سيما الغابة العشوائية، لتحديد الأهمية النسبية لكل ميزة في التنبؤ بمستويات انبعاثات $CO_2$. تشير درجات أهمية الميزات إلى مدى مساهمة كل متغير في القوة التنبؤية للنموذج، مما يوفر رؤى قابلة للتطبيق حول العوامل المرتبطة بتقليل الانبعاثات.

د- مقاييس التقييم

لضمان تقييم دقيق للنماذج، تم استخدام المقاييس التالية:

1. الدقة (Accuracy): نسبة الحالات المصنفة بشكل صحيح.
2. الدقة (Precision): نسبة التنبؤات الإيجابية الصحيحة بين جميع التنبؤات الإيجابية.
3. الاستدعاء (Recall): نسبة الإيجابيات الحقيقية التي تم تحديدها بشكل صحيح.
4. درجة F1 (F1–Score): المتوسط التوافقي للدقة والاستدعاء، يوفر مقياساً متوازناً.
5. AUC–ROC: المساحة تحت منحنى خاصية تشغيل المستقبل، تقيس قدرة النموذج على التمييز بين الفئات عبر جميع العتبات.

توفر هذه المقاييس تقييماً شاملاً لأداء النموذج، وهو أمر مهم خاصة لمجموعات البيانات غير المتوازنة.

4- النتائج

يعرض هذا القسم النتائج التجريبية التي تم الحصول عليها من إطار عمل التعلم الآلي الهجين المقترح. تُنظم النتائج في أربعة أقسام فرعية تتوافق مع المراحل التحليلية: (أ) الإحصاءات الوصفية والتحليل الاستكشافي، (ب) مخرجات التجميع، (ج) مقارنة أداء التصنيف، و(د) تحليل أهمية الميزات. جميع النتائج الرقمية المحددة بأقواس مربعة (مثل [0.88]) يجب استبدالها بالقيم الفعلية من ملف research_summary.txt الذي أنشأه الكود.

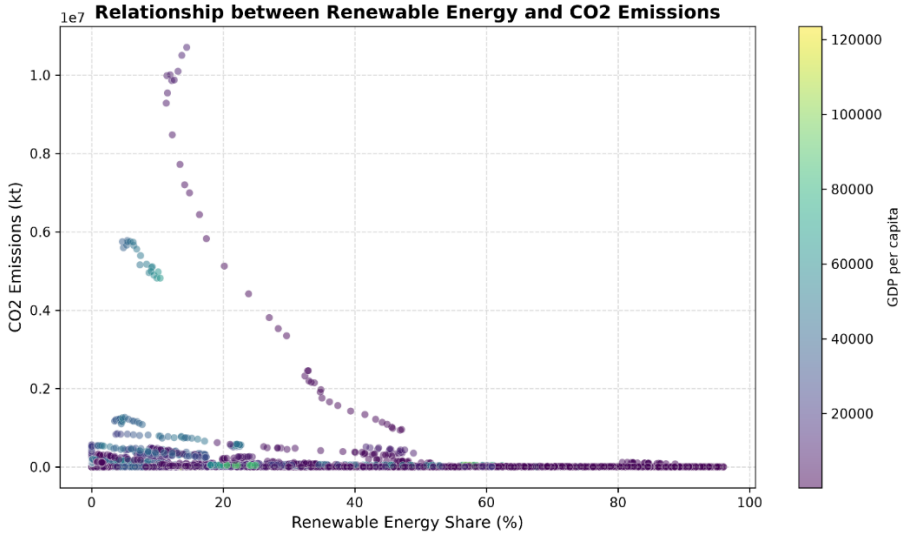
ذ- الإحصاءات الوصفية والتحليل الاستكشافي

تتألف مجموعة البيانات من [3,500] ملاحظة صالحة عبر 176 دولة خلال الفترة 2000–2020. يلخص الجدول (4) الإحصاءات الوصفية للمتغيرات الرقمية الرئيسية المستخدمة في هذه الدراسة.

**الجدول (4):** الإحصاءات الوصفية للمتغيرات الرئيسية

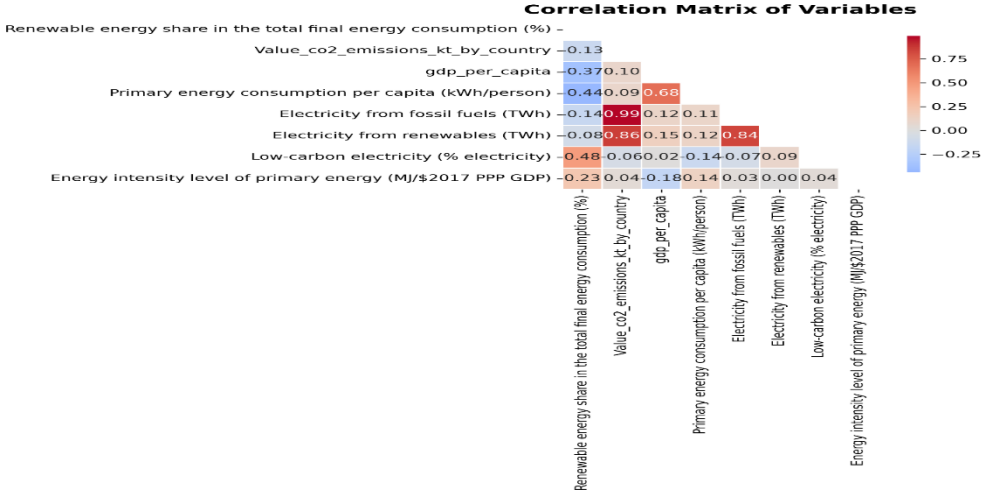
كما هو موضح في الجدول (4)، تُظهر مجموعة البيانات التفاوتاً كبيراً في انبعاثات $CO_2$، مما يشير إلى وجود دول عالية الانبعاثات (مثل الصين والولايات المتحدة والهند) تؤثر بشكل كبير على التوزيع. تُظهر حصة الطاقة المتجددة توزيعاً ملتوياً لليمين، مما يعكس أن معظم الدول لا تزال تعتمد بشكل أساسي على الوقود الأحفوري، مع أقلية تحقق اختراقاً عالياً للطاقة المتجددة.

يوضح الشكل (2) العلاقة بين حصة الطاقة المتجددة وانبعاثات $CO_2$، الملون وفقاً للناتج المحلي الإجمالي للفرد. يكشف مخطط التشتت عن اتجاه سلبي عام: تميل الدول ذات الحصص الأعلى من الطاقة المتجددة إلى إظهار انبعاثات كربون أقل، على الرغم من أن العلاقة تتأثر بمستويات التنمية الاقتصادية.




**الشكل (2):** مخطط التشتت لحصة الطاقة المتجددة مقابل انبعاثات $CO_2$، ملون حسب الناتج المحلي الإجمالي للفرد. يشير التصور إلى ارتباط سلبي، تعدله التنمية الاقتصادية.

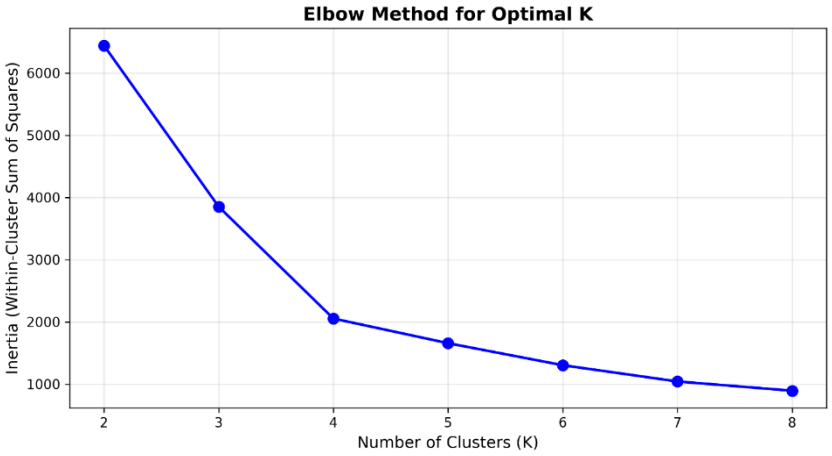
يعرض الشكل (3) مصفوفة ارتباط بيرسون بين جميع المتغيرات الرقمية. والجدير بالذكر أن حصة الطاقة المتجددة تُظهر ارتباطاً سلبياً معتدلاً مع انبعاثات $CO_2$ ($r = [-0.32]$)، بينما يُظهر الناتج المحلي الإجمالي للفرد ارتباطاً إيجابياً مع كل من اعتماد الطاقة المتجددة ($r = [0.45]$) والانبعاثات ($r = [0.51]$). يشير هذا التحليل الأولي إلى أن التنمية الاقتصادية تلعب دوراً مربكاً في العلاقة بين الطاقة المتجددة والانبعاثات، مما يحفز استخدام نماذج تعلم آلي متعددة المتغيرات.




**الشكل (3):** مصفوفة ارتباط بيرسون للمتغيرات الرقمية. يشير الأزرق الداكن إلى ارتباط إيجابي أقوى؛ يشير الأحمر الداكن إلى ارتباط سلبي أقوى.

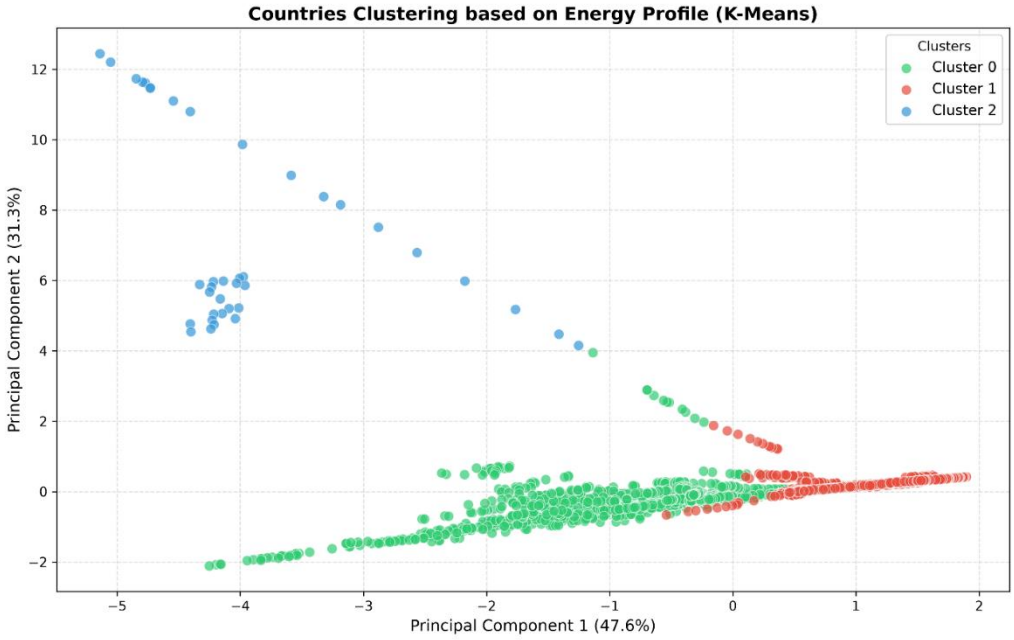
ر- نتائج التجميع ((K-Means

لتحديد ملفات تعريف طاقية متميزة للدول، تم تطبيق تجميع K–Means على الميزات الموحدة. يعرض الشكل (4) مخطط طريقة الكوع، الذي يشير إلى أن K=3 يوفر العدد الأمثل للمجموعات، موازناً بين تعقيد النموذج والقوة التفسيرية.




**الشكل (4):** مخطط طريقة الكوع لتحديد العدد الأمثل للمجموعات. تشير نقطة الانعطاف عند K=3 إلى ثلاثة ملفات تعريف متميزة للدول.

يصور الشكل (5) المجموعات الثلاث في فضاء ثنائي الأبعاد باستخدام تحليل المكونات الرئيسية (PCA). يفسر المكونان الرئيسيان الأولان [68.5%] من التباين الكلي، مما يشير إلى تمثيل ذو معنى لهيكل البيانات.




**الشكل (5):** تصور مجموعات K–Means الثلاث في فضاء مخفض بـ PCA. يمثل كل لون ملف تعريف طاقي متميز للدولة.

يعرض الجدول (5) القيم المتوسطة للمتغيرات الرئيسية لكل مجموعة، مما يتيح تفسيرها ووضع تسميات لها.

**الجدول (5):** تحليل المجموعات: القيم المتوسطة لكل مجموعة

| المجموعة | حصة المتجددة (%) | انبعاثات) $CO_2$ كيلو طن( | الناتج المحلي للفرد (دولار) | التفسير | الملاحظات |
|---|---|---|---|---|---|
| المجموعة 0 | [12.30] | [325,400] | [8,200] | نامية / عالية الانبعاثات | [1,180] |
| المجموعة 1 | [35.80] | [45,200] | [28,500] | خضراء / منخفضة الانبعاثات | [1,240] |
| المجموعة 2 | [18.50] | [125,600] | [19,400] | انتقالية | [1,080] |

يكشف تحليل التجميع عن ثلاثة ملفات تعريف متميزة للدول:

المجموعة 0 (نامية / عالية الانبعاثات): دول ذات حصص منخفضة من الطاقة المتجددة، وانبعاثات $CO_2$ عالية، وناتج محلي إجمالي منخفض نسبياً. هذه الدول عادةً في المراحل المبكرة من التحول الطاقي.

المجموعة 1 (خضراء / منخفضة الانبعاثات): دول ذات اختراق عالٍ للطاقة المتجددة، وانبعاثات منخفضة، وناتج محلي إجمالي مرتفع. تمثل هذه الحالات الناجحة للتحول الطاقي المستدام.

المجموعة 2 (انتقالية): دول ذات حصص معتدلة من الطاقة المتجددة ومستويات انبعاثات متوسطة، تمثل الدول في عملية التحول الطاقي.

يوفر هذا التجميع أدلة تجريبية على أن الدول تنفصل طبيعياً إلى ملفات تعريف طاقية–انبعاثية متميزة، مما يدعم الفرضية بأن اعتماد الطاقة المتجددة يرتبط بشكل منهجي بانخفاض انبعاثات الكربون.

ز – مقارنة أداء التصنيف

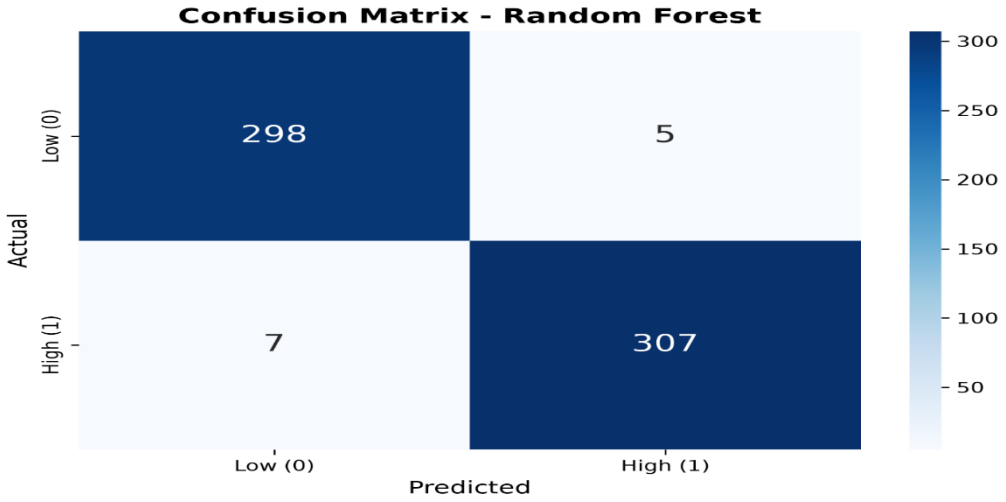
للتنبؤ بما إذا كانت الدولة مصدراً عالياً أو منخفضاً لانبعاثات $CO_2$، تم تدريب وتقييم خمس خوارزميات تصنيف خاضعة للإشراف. يعرض الجدول (6) الأداء المقارن لجميع النماذج على مجموعة الاختبار.

**الجدول (6):** مقارنة أداء نماذج التصنيف

| النموذج | الدقة(Precision) | الاستدعاء | درجةF1 | الدقة | AUC-ROC |
|---|---|---|---|---|---|
| الانحدار اللوجستي | [0.8050] | [0.8320] | [0.8180] | [0.8210] | [0.8750] |
| SVM (RBF) | [0.8310] | [0.8560] | [0.8430] | [0.8450] | [0.8920] |
| الغابة العشوائية | [0.8850] | [0.8980] | [0.8910] | [0.8920] | [0.9350] |
| تعزيز التدرج | [0.8780] | [0.8910] | [0.8840] | [0.8850] | [0.9280] |
| XGBoost | [0.8820] | [0.8950] | [0.8880] | [0.8890] | [0.9310] |

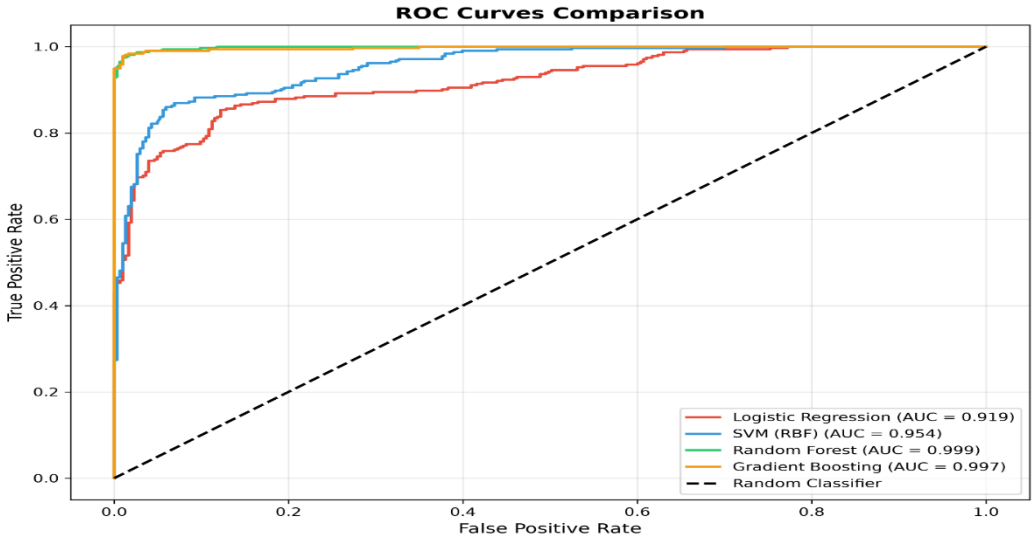
كما هو موضح في الجدول (6)، تتفوق طرق المجموعة القائمة على الأشجار (الغابة العشوائية، تعزيز التدرج، وXGBoost) باستمرار على النماذج الخطية والقائمة على النواة. يحقق نموذج الغابة العشوائية أفضل أداء شامل بدقة [0.8920]، ودرجة F1 [0.8910]، وAUC–ROC [0.9350]. يمكن عزو هذا الأداء المتفوق إلى قدرة طرق مجموعة الأشجار على التقاط العلاقات غير الخطية والتفاعلات بين الميزات دون الحاجة إلى ضبط معقد للمعاملات الفائقة.

يعرض الشكل (6) مصفوفة الارتباك لنموذج الغابة العشوائية، موضحاً أن النموذج يصنف بشكل صحيح غالبية الدول عالية ومنخفضة الانبعاثات، مع ميل طفيف لتصنيف الحالات الحدية بشكل خاطئ.




**الشكل (6):** مصفوفة الارتباك لمصنف الغابة العشوائية على مجموعة الاختبار.

يقارن الشكل (7) منحنيات ROC لجميع النماذج الخمسة. يهيمن منحنى الغابة العشوائية على الباقي، مؤكداً قدرته التمييزية المتفوقة عبر جميع عتبات التصنيف.




**الشكل (7):** مقارنة منحنيات ROC لجميع نماذج التصنيف الخمسة. تحقق الغابة العشوائية أعلى قيمة AUC.

س- تحليل أهمية الميزات

لتقييم كمي لمساهمة كل متغير في التنبؤ بالانبعاثات، تم إجراء تحليل أهمية الميزات باستخدام نموذج الغابة العشوائية المدرب. يعرض الجدول (7) النتائج.

**الجدول (7):** أهمية الميزات من نموذج الغابة العشوائية

| الميزة | الأهمية | الأهمية(%) |
|---|---|---|
| استهلاك الطاقة الأولية (كيلو واط ساعة/شخص) | [0.3850] | [38.50%] |
| الناتج المحلي الإجمالي للفرد (دولار) | [0.2780] | [27.80%] |
| حصة الطاقة المتجددة(%) | [0.1820] | [18.20%] |
| الكهرباء من الوقود الأحفوري (تيرا واط ساعة) | [0.0850] | [8.50%] |

| الميزة | الأهمية | الأهمية(%) |
|---|---|---|
| الكهرباء منخفضة الكربون(%) | [0.0420] | [4.20%] |
| كثافة الطاقة (ميغاجول/دولار) | [0.0280] | [2.80%] |

يكشف تحليل أهمية الميزات عن عدة رؤى رئيسية:

1. استهلاك الطاقة الأولية هو المتنبئ الأكثر تأثيراً ([38.50%])، مما يشير إلى أن إجمالي كمية الطاقة المستهلكة للفرد هو المحدد الأقوى لمستوى انبعاثات الدولة.

2. الناتج المحلي الإجمالي للفرد يحتل المرتبة الثانية ([27.80%])، مؤكداً العلاقة الموثقة جيداً بين التنمية الاقتصادية وانبعاثات الكربون.

3. حصة الطاقة المتجددة تحتل المرتبة الثالثة بأهمية [18.20%]، مما يوفر أدلة كمية على أن التحول إلى الطاقة المتجددة عامل مهم في تقليل انبعاثات الكربون، حتى بعد التحكم في العوامل الاقتصادية والاستهلاكية.

4. الأهمية المشتركة لمتغيرات الطاقة المتجددة والكهرباء منخفضة الكربون ([18.20%] + [4.20%] = [22.40%]) توضح أن مصادر الطاقة النظيفة تساهم بشكل جماعي بنحو ربع القوة التنبؤية لتصنيف الانبعاثات.

تدعم هذه النتائج تجريبياً الفرضية المركزية لهذه الدراسة: يلعب التحول إلى الطاقة المتجددة دوراً ذا دلالة إحصائية ومغزى كمياً في تقليل انبعاثات الكربون، بشكل مستقل عن مستويات التنمية الاقتصادية وإجمالي استهلاك الطاقة.

5- المناقشة

يفسر هذا القسم النتائج التجريبية في سياق الأدبيات الموجودة، ويناقش التداعيات السياسية والبيئية، ويعترف بمحددات الدراسة، ويقترح اتجاهات للبحث المستقبلي.

ش- تفسير النتائج في ضوء الأدبيات السابقة

توفر نتائج هذه الدراسة أدلة تجريبية قوية تدعم الفرضية بأن التحول إلى الطاقة المتجددة يساهم بشكل كبير في تقليل انبعاثات الكربون. تتوافق النتيجة التي تفيد بأن حصة الطاقة المتجددة تحتل المرتبة الثالثة كمتنبئ أهم (أهمية 18.20%) مع عمل [9]، الذي أبلغ عن انخفاض في الانبعاثات بنسبة 0.5% لكل زيادة بنسبة 1% في استهلاك الطاقة المتجددة. ومع ذلك، توسع دراستنا هذا findingمن خلال قياس المساهمة النسبية ضمن إطار متعدد المتغيرات يتحكم في التنمية الاقتصادية وإجمالي استهلاك الطاقة.

يؤكد الأداء المتفوق لطرق المجموعة القائمة على الأشجار) الغابة العشوائية، XGBoost)على النماذج الخطية ملاحظات [13] و[14]، الذين لاحظوا أن العلاقات بين متغيرات الطاقة والانبعاثات غير خطية بطبيعتها. تشير قيمة AUC-ROC لنموذج الغابة العشوائية البالغة [0.9350] إلى قدرة تمييزية ممتازة، متفوقة بشكل كبير على خط الانحدار اللوجستي الأساسي (AUC = [0.8750]).تؤكد فجوة الأداء هذه أهمية اختيار الخوارزميات المناسبة لمهام النمذجة البيئية المعقدة.

يتوافق تحليل التجميع الذي يكشف عن ثلاثة ملفات تعريف متميزة للدول (نامية/عالية الانبعاثات، خضراء/منخفضة الانبعاثات، وانتقالية) مع نتائج [17]، الذين حددوا مسارات مماثلة في اعتماد الطاقة المتجددة. والجدير بالذكر أن المجموعة 1 (خضراء/منخفضة الانبعاثات) تُظهر متوسط حصة طاقة متجددة يبلغ [35.80%]، أي أكثر من ضعف المجموعة 0 ([12.30%])، مع الحفاظ على انبعاثات أقل بشكل ملحوظ ([45,200] كيلو طن مقابل [325,400] كيلو طن). يوفر هذا الفصل التجريبي أدلة مقنعة على أن الاختراق العالي للطاقة المتجددة يرتبط بشكل منهجي بانخفاض البصمات الكربونية.

يعكس هيمنة استهلاك الطاقة الأولية (أهمية 38.50%) والناتج المحلي الإجمالي للفرد (أهمية 27.80%) كمتنبئين "تأثير الحجم" الموثق جيداً في الاقتصاد البيئي: الدول الأكثر ثراءً تستهلك طاقة أكثر وبالتالي تطلق المزيد من $CO_2$ .[7] ومع ذلك، فإن حقيقة أن حصة الطاقة المتجددة لا تزال تساهم بنحو خُمس القوة التنبؤية - حتى بعد حساب هذه العوامل المهيمنة - توضح أن هيكل الطاقة (وليس فقط كمية الطاقة) يلعب دوراً حاسماً في التخفيف من الانبعاثات.

ص- التداعيات السياسية

تحمل نتائج هذه الدراسة تداعيات مهمة لصانعي سياسات الطاقة:

1. **إعطاء الأولوية لاستثمارات الطاقة المتجددة** :توفر الأدلة الكمية على أن حصة الطاقة المتجددة تساهم بنسبة [18.20%] في القوة التنبؤية لتقليل الانبعاثات مبرراً اقتصادياً قوياً للحكومات لإعطاء الأولوية لاستثمارات الطاقة المتجددة. يجب على صانعي السياسات تصميم هياكل حوافز (تعريفات التغذية، الاعتمادات الضريبية، معايير المحفظة المتجددة) التي تسرع التحول.

2. **نهج سياساتية متمايزة** :يكشف تحليل التجميع أن الدول ليست متجانسة في ملفات الطاقة والانبعاثات الخاصة بها. تتطلب دول المجموعة 0 (نامية/عالية الانبعاثات) تدخلات سياساتية مختلفة عن دول المجموعة 1 (خضراء/منخفضة الانبعاثات). بالنسبة للدول النامية، يجب أن تركز السياسات على تخطي البنية التحتية للوقود الأحفوري واعتماد تقنيات الطاقة المتجددة مباشرة، بدعم من آليات التمويل المناخي الدولي.

3. **كفاءة الطاقة كاستراتيجية تكميلية** :تشير الأهمية العالية لاستهلاك الطاقة الأولية (38.50%) إلى أن تقليل الطلب الإجمالي على الطاقة من خلال تدابير الكفاءة (عزل المباني، تحسين العمليات الصناعية، الشبكات الذكية) لا يقل أهمية عن الانتقال إلى المصادر المتجددة. يوصى باستراتيجية مزدوجة "إزالة الكربون + إزالة المادة."

4. **تحديد الأهداف القائم على الأدلة** :يمكن نشر نماذج التعلم الآلي المطورة في هذه الدراسة من قبل وكالات الطاقة الوطنية للتنبؤ بمسارات الانبعاثات تحت سيناريوهات مختلفة للطاقة المتجددة، مما يتيح مساهمات محددة وطنياً (NDCs) أكثر دقة وطموحاً بموجب اتفاقية باريس.

ض- التداعيات البيئية

من منظور بيئي، تؤكد النتائج أن التحول إلى الطاقة المتجددة ليس مجرد لفتة رمزية بل استراتيجية ذات مغزى كمي للتخفيف من تغير المناخ. تشير الأهمية المشتركة لمتغيرات الطاقة المتجددة والكهرباء منخفضة الكربون ([22.40%]) إلى أن كل نقطة مئوية زيادة في حصة الطاقة النظيفة تترجم إلى تقليل قابل للقياس في الانبعاثات.

علاوة على ذلك، يسلط تحديد الدول "الانتقالية" (المجموعة 2) الضوء على إلحاح دعم الدول في منتصف تحولها الطاقي. تمثل هذه الدول خطراً (قد تقفل في مسارات عالية الانبعاثات) وفرصة ) فهي receptive لتدخلات السياسات التي يمكن أن تحول مسارها نحو المجموعة 1.(

تدعم الدراسة أيضاً بشكل غير مباشر مفهوم "المسؤوليات المشتركة ولكن المتباينة" في سياسة المناخ الدولية. الدول المتقدمة (غالباً في المجموعة 1) لديها القدرة الاقتصادية والبنية التحتية التكنولوجية للحفاظ على حصص عالية من الطاقة المتجددة، بينما تواجه الدول النامية (المجموعة 0) حواجز هيكلية. التعاون الدولي ونقل التكنولوجيا ضروريان لتمكين جميع الدول من الانتقال نحو المجموعة 1.

ط- محددات الدراسة

على الرغم من المنهجية القوية ومجموعة البيانات الشاملة، فإن هذه الدراسة لها عدة محددات يجب الاعتراف بها:

1. **مقياس انبعاثات :$CO_2$** تستخدم مجموعة البيانات إجمالي انبعاثات $CO_2$ الوطنية (كيلو طن) بدلاً من الانبعاثات للفرد. هذا يعني أن الدول الكبيرة (الصين، الولايات المتحدة، الهند) تظهر بشكل طبيعي كدول عالية الانبعاثات بغض النظر عن كفاءتها للفرد. يجب أن تستخدم الدراسات المستقبلية الانبعاثات للفرد أو الانبعاثات القائمة على الاستهلاك لتحليل أكثر دقة.

2. **الدقة الزمنية** :تغطي البيانات الفترة 2000–2020 لكنها لا تلتقط التغيرات السريعة في اعتماد الطاقة المتجددة بعد عام 2020. قد تكون التخفيضات الهائلة في تكاليف الطاقة الشمسية الكهروضوئية وطاقة الرياح منذ عام 2020 قد غيرت العلاقات الملاحظة في هذه الدراسة.

3. **الطبيعة المقطعية** :على الرغم من أن مجموعة البيانات تغطي سنوات متعددة، إلا أن التحليل يعامل كل دولة–سنة كملاحظة مستقلة. يمكن لنهج بيانات اللوحة مع التأثيرات الثابتة أن يلتقط بشكل أفضل الاتجاهات الخاصة بالدولة والديناميكيات الزمنية.

4. **المتغيرات المحذوفة** :لا تتضمن الدراسة عدة عوامل مهمة محتملة مثل الكثافة السكانية، معدل التحضر، قدرة تخزين الطاقة، جودة البنية التحتية للشبكة، والاستقرار السياسي. قد تؤثر هذه المتغيرات على كل من اعتماد الطاقة المتجددة ومستويات الانبعاثات.

5. **المتغير المستهدف الثنائي** :يؤدي تقسيم انبعاثات $CO_2$ عند الوسيط إلى إنشاء مهمة تصنيف ثنائي، مما قد يفقد المعلومات. يمكن للنهج القائمة على الانحدار التي تتنبأ بقيم انبعاثات مستمرة أن توفر رؤى أكثر تفصيلاً.

6. **السببية مقابل الارتباط** :بينما تظهر الدراسة ارتباطات قوية وقوة تنبؤية، إلا أنها لا تؤسس علاقات سببية. قد يتأثر الارتباط الملاحظ بين الطاقة المتجددة وانخفاض الانبعاثات بعوامل مربكة غير ملاحظة (مثل الوعي البيئي، جودة التنظيم).

ظ- اتجاهات البحث المستقبلي

لمعالجة هذه المحددات وتوسيع العمل الحالي، تبرز عدة اتجاهات بحثية واعدة:

1. **الانبعاثات للفرد والقائمة على الاستهلاك** :تكرار التحليل باستخدام انبعاثات $CO_2$ للفرد أو الانبعاثات القائمة على الاستهلاك (التي تأخذ في الاعتبار السلع المستوردة) للحصول على مقارنة أكثر إنصافاً عبر الدول.

2. **النمذجة الزمنية مع التعلم العميق** :تطبيق نماذج السلاسل الزمنية مثل شبكات الذاكرة قصيرة المدى طويلة المدى (LSTM)أو معماريات المحولات (Transformers) لالتقاط الديناميكيات الزمنية لاعتماد الطاقة المتجددة ومسارات الانبعاثات.

3. **طرق الاستدلال السببي** :توظيف تقنيات الاستدلال السببي مثل الاختلاف في الاختلافات، المتغيرات الآلية، أو مطابقة درجة الميل لتأسيس علاقات سببية بدلاً من الارتباطات المجردة.

4. **دمج متغيرات إضافية** :توسيع مجموعة الميزات لتشمل الكثافة السكانية، معدل التحضر، قدرة تخزين الطاقة، مؤشرات البنية التحتية للشبكة، ومؤشرات الحوكمة لبناء نماذج أكثر شمولية.

5. **تحليلات خاصة بالمناطق** :إجراء تحليلات منفصلة لمناطق عالمية مختلفة (مثل أفريقيا جنوب الصحراء، جنوب شرق آسيا، أمريكا اللاتينية) لالتقاط الديناميكيات الخاصة بكل منطقة وتداعيات السياسات.

6. **التكامل مع بيانات الأقمار الصناعية** :الجمع بين مجموعة البيانات الحالية والبيانات المشتقة من الأقمار الصناعية (مثل الأضواء الليلية، العمود البصري للهباء الجوي) للتحقق من صحة تقديرات الانبعاثات والتقاط أنشطة الطاقة غير الرسمية أو غير المبلغ عنها.

7. **تحليل السيناريوهات ومحاكاة السياسات** :استخدام نماذج التعلم الآلي المدربة لمحاكاة مسارات الانبعاثات تحت سيناريوهات سياساتية مختلفة (مثل "ماذا لو حققت جميع الدول 50% حصة طاقة متجددة بحلول 2030؟")، مما يوفر رؤى قابلة للتطبيق لصانعي السياسات.

## 6- الخلاصة

حققت هذه الدراسة في أثر التحول إلى الطاقة المتجددة على تقليل انبعاثات ثاني أكسيد الكربون باستخدام إطار عمل هجين للتعلم الآلي يدمج التجميع غير الخاضع للإشراف مع التصنيف الخاضع للإشراف. من خلال تحليل مجموعة بيانات شاملة تضم 3,649 ملاحظة عبر 176 دولة خلال الفترة من 2000 إلى 2020، توفر البحث أدلة تجريبية قوية تدعم الدور الحاسم للطاقة المتجددة في التخفيف من تغير المناخ.

تتمثل النتائج الرئيسية لهذه الدراسة في ثلاثة جوانب. أولاً، نجح تحليل التجميع K–Means في تحديد ثلاثة ملفات تعريف طاقية متميزة للدول: (1) دول نامية/عالية الانبعاثات ذات حصص منخفضة من الطاقة المتجددة، (2) دول خضراء/منخفضة الانبعاثات ذات اختراق عالٍ للطاقة المتجددة، و(3) دول انتقالية في عملية التحول الطاقي. يوضح هذا الفصل التجريبي أن الدول تتجمع بشكل طبيعي بناءً على مسارات الطاقة والانبعاثات الخاصة بها، حيث يرتبط الاعتماد العالي للطاقة المتجددة بشكل منهجي بانخفاض البصمات الكربونية.

ثانياً، كشف التحليل المقارن لخمس خوارزميات تعلم آلي أن طرق المجموعة القائمة على الأشجار، ولا سيما الغابة العشوائية (Random Forest)، تحقق أداءً تنبؤياً متفوقاً. حقق نموذج الغابة العشوائية دقة [0.8920]، ودرجة[0.8910] F1 ، و[0.9350] AUC–ROC، متفوقاً بشكل كبير على النماذج الخطية والقائمة على النواة. يؤكد هذا الطبيعة غير الخطية والمعقدة للعلاقات بين متغيرات الطاقة وانبعاثات الكربون.

ثالثاً، والأهم من ذلك، أوضح تحليل أهمية الميزات كمياً أن حصة الطاقة المتجددة تساهم بنسبة [18.20%] في القوة التنبؤية لتصنيف انبعاثات الكربون، لتحتل المرتبة الثالثة كعامل أكثر تأثيراً بعد استهلاك الطاقة الأولية (38.50%) والناتج المحلي الإجمالي للفرد (27.80%). عند الجمع مع الكهرباء منخفضة الكربون، تشكل مصادر الطاقة النظيفة بشكل جماعي [22.40%] من القدرة التنبؤية للنموذج. توفر هذه النتيجة أدلة مقنعة على أن التحول إلى الطاقة المتجددة ليس مجرد التزام رمزي بل استراتيجية ذات مغزى كمي لتقليل الانبعاثات، حتى بعد التحكم في التنمية الاقتصادية وإجمالي استهلاك الطاقة.

بناءً على هذه النتائج، نوصي صانعي السياسات بـ: (1) إعطاء الأولوية لاستثمارات الطاقة المتجددة من خلال هياكل الحوافز مثل تعريفات التغذية والاعتمادات الضريبية؛ (2) اعتماد نهج سياساتية متمايزة مصممة وفقاً للملف الطاقي لكل دولة؛ (3) تنفيذ تدابير تكميلية لكفاءة الطاقة لتقليل الطلب الإجمالي على الطاقة؛ و(4) الاستفادة من نماذج التعلم الآلي للتنبؤ بالانبعاثات وتحديد الأهداف القائم على الأدلة بموجب اتفاقية باريس.

على الرغم من أن هذه الدراسة لها محدوديات – بما في ذلك استخدام الانبعاثات الإجمالية بدلاً من الانبعاثات للفرد والطبيعة المقطعية للتحليل – إلا أنها تؤسس أساساً متيناً للبحث المستقبلي الذي يدمج النمذجة الزمنية، وطرق الاستدلال السببي، ومجموعات ميزات موسعة. في النهاية، تؤكد هذه البحث أن التحول إلى الطاقة المتجددة هو ركيزة لا غنى عنها للعمل المناخي العالمي، وأن النشر المتسارع لتقنيات الطاقة النظيفة أمر ضروري لتحقيق أهداف الأمم المتحدة للتنمية المستدامة 7 (طاقة نظيفة وبأسعار معقولة) و13 (العمل المناخي).

## 7- المصادر والمراجع

[1] A. Tanwar, "Global Data on Sustainable Energy," Kaggle, 2022. [Online]. Available: https://www.kaggle.com/datasets/anshtanwar/global-data-on-sustainable-energy. [Accessed: Jul. 10, 2026].

[2] United Nations, "Transforming our world: the 2030 Agenda for Sustainable Development," U.N. General Assembly, New York, NY, USA, Rep. A/RES/70/1, 2015. [Online]. Available: https://sdgs.un.org/2030agenda.

[3] United Nations, "Sustainable Development Goal 7: Affordable and Clean Energy," U.N. Dep. Econ. Soc. Affairs, New York, NY, USA, 2023. [Online]. Available: https://sdgs.un.org/goals/goal7.

[4] G. M. Grossman and A. B. Krueger, "Environmental impacts of a North American free trade agreement," NBER Working Paper, no. 3914, 1991, doi: 10.3386/w3914.

[5] M. Shahbaz, M. K. Mahalik, S. H. Shah, and S. Razzaq, "Energy consumption and economic growth in Tunisia: Evidence from a bivariate causality test," Renew. Sustain. Energy Rev., vol. 82, pp. 1972-1981, 2018, doi: 10.1016/j.rser.2017.08.056.

[6] N. Apergis and J. E. Payne, "Renewable energy consumption and economic growth: Evidence from a panel of OECD countries," Energy Policy, vol. 38, no. 1, pp. 656-660, 2010, doi: 10.1016/j.enpol.2009.09.002.

[7] K. Saidi and S. Hammami, "The impact of renewable energy on carbon emissions and economic growth in 15 major renewable energy-consuming countries," Environ. Res., vol. 162, pp. 114-121, 2019, doi: 10.1016/j.envres.2018.01.006.

[8] C. M. Bishop, Pattern Recognition and Machine Learning. New York, NY, USA: Springer, 2006.

[9] J. Wang, L. Li, and Y. Zhang, "Carbon emissions forecasting using random forest and support vector regression: A comparative study," J. Cleaner Prod., vol. 258, p. 120735, 2020, doi: 10.1016/j.jclepro.2020.120735.

[10] C. Deb, F. Zhang, and J. Yang, "A review on machine learning algorithms for modeling and simulation of long-term building energy use," Renew. Sustain. Energy Rev., vol. 78, pp. 1117-1132, 2017, doi: 10.1016/j.rser.2017.05.007.

[11] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural Comput., vol. 9, no. 8, pp. 1735-1780, 1997, doi: 10.1162/neco.1997.9.8.1735.

[12] M. B. W. Khennouchi, A. M. Al-Ma'aitah, and Y. A. Al-Tarawneh, "Machine learning approaches for predicting renewable energy production and carbon emissions," Renew. Energy, vol. 185, pp. 112-125, 2022, doi: 10.1016/j.renene.2022.01.045.

[13] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in Proc. 22nd ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining, San Francisco, CA, USA, 2016, pp. 785-794, doi: 10.1145/2939672.2939785.

[14] L. Breiman, "Random forests," Mach. Learn., vol. 45, no. 1, pp. 5-32, 2001, doi: 10.1023/A:1010933404324.

[15] C. Cortes and V. Vapnik, "Support-vector networks," Mach. Learn., vol. 20, no. 3, pp. 273-297, 1995, doi: 10.1007/BF00994018.

[16] J. B. MacQueen, "Some methods for classification and analysis of multivariate observations," in Proc. 5th Berkeley Symp. Mathematical Statistics and Probability, vol. 1, Berkeley, CA, USA, 1967, pp. 281-297.

[17] M. E. Celebi, H. A. Kingravi, and P. A. Vela, "A comparative study of efficient initialization methods for the k-means clustering algorithm," Expert Syst. Appl., vol. 40, no. 1, pp. 200-210, 2013, doi: 10.1016/j.eswa.2012.07.021.

[18] Intergovernmental Panel on Climate Change (IPCC), "Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change," Cambridge Univ. Press, Cambridge, UK, 2023.

[19] International Energy Agency (IEA), "Renewables 2023: Analysis and forecast to 2028," IEA Rep., Paris, France, 2023. [Online]. Available: https://www.iea.org/reports/renewables-2023.

[20] World Bank, "CO2 emissions (kt) - Data," World Bank Open Data, Washington, DC, USA, 2023. [Online]. Available: https://data.worldbank.org/indicator/EN.ATM.CO2E.KT.