Journal of Arabian Peninsula Centre for Medical and Applied Researches
Volume (1), Issue (3), year/2025
p: 26-50

ISSN/E: 2959-829X || ISSN/P: 2059-8303

مجلة مركز جزيرة العرب للبحوث الطبية والتطبيقية
المجلد (1)، العدد (3)، العام 2025م
ص: 26-50
الاستلام: 2025/8/4|| القبول: 2025/8/30||
النشر: 2025/8/31

Using Artificial Neural Networks to Predict Electric Power Consumption in Saudi Arabia Compared to the Logistic Regression Model During the Period: 2000–2024 [1]

استخدام الشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية في المملكة العربية السعودية مقارنة مع نموذج الانحدار اللوجستي خلال الفترة: 2000- 2024 [2]

Dr. Khalda Abdalla Mustafa

Assistant Professor of Economics || Department of Administrative Sciences || Applied College || Najran University || KSA

د. خالدة عبد الله مصطفى

أستاذ الاقتصاد المساعد || قسم العلوم الإدارية|| الكلية التطبيقية || جامعة نجران|| المملكة العربية السعودية

E-mail: Khalda.abdalla2020@gmail.com || Orcid: https://orcid.org/0009-0004-5907-4511 || Mobile: 00966537138277

Abstract: This study aimed to develop a predictive model using artificial neural networks (ANN) with backpropagation to estimate electricity consumption costs in Saudi Arabia, and compared its performance with logistic regression. Consumption was classified into high and low categories based on five key variables: GDP, industrial electricity usage, per capita income, average temperature, and population size. A descriptive-correlational methodology was employed, using a complete dataset of 25 cases alongside World Bank data. Results showed that the ANN model outperformed logistic regression, achieving 94% accuracy, with industrial consumption emerging as the most influential factor (100%). The study introduced a practical forecasting model for national energy planning and recommended adopting AI-based approaches to enhance the electricity sector in line with sustainable development goals.

Keywords: Artificial neural networks, backpropagation algorithm, logistic regression, electricity consumption, Saudi Arabia.

المستخلص: هدفت الدراسة إلى تطوير نموذج تنبؤي باستخدام الشبكات العصبية الاصطناعية بخوارزمية الانتشار العكسي لتقدير تكلفة استهلاك الكهرباء في المملكة العربية السعودية، ومقارنته بنموذج الانحدار اللوجستي. تم تصنيف الاستهلاك إلى فئتين (مرتفع ومنخفض) بناءً على خمسة متغيرات اقتصادية ومناخية وسكانية: الناتج المحلي الإجمالي، الاستهلاك الصناعي، دخل الفرد، متوسط درجة الحرارة، وعدد السكان. اعتمدت الباحثة المنهج الوصفي التحليلي، باستخدام بيانات مكتملة لـ 25 حالة، إضافة إلى مصادر رسمية كبيانات البنك الدولي. أظهرت النتائج تفوق نموذج الشبكة العصبية بدقة بلغت 94%، مع تأثير بارز للاستهلاك الصناعي بنسبة 100%. وقدّمت الدراسة نموذجًا قابلًا للتطبيق في التخطيط الوطني للطاقة، وأوصت بتبني تقنيات الذكاء الاصطناعي في تطوير قطاع الكهرباء بما يواكب أهداف التنمية المستدامة.

الكلمات المفتاحية: الشبكات العصبية الاصطناعية، خوارزمية الانتشار العكسي، الانحدار اللوجستي، استهلاك الكهرباء، السعودية.

---

[1]- **APA7 Citation:** Mustafa, K. A. (2025). Using Artificial Neural Networks to Predict Electric Power Consumption in Saudi Arabia Compared to the Logistic Regression Model During the Period: 2000–2024, ***Journal of the Arabian Peninsula Center for Medical and Applied Research, 1***(3), 26-50. https://doi.org/10.56793/pcra23132

2-**توثيق الاقتباس (APA7)**: مصطفى، خالدة عبد الله. (2025). استخدام الشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية في المملكة العربية السعودية مقارنة مع نموذج الانحدار اللوجستي خلال الفترة: 2000- 2024، ***مجلة مركز جزيرة العرب للبحوث الطبية والتطبيقية، 1*** (3)، 26- 50. https://doi.org/10.56793/pcra23132

1-المقدمة.

تشهد المملكة العربية السعودية مرحلة تنموية غير مسبوقة، انعكست في مختلف المجالات الاقتصادية والاجتماعية والعمرانية، وجعلت من قطاع الطاقة الكهربائية محورًا رئيسًا لتحقيق أهداف التنمية المستدامة. ويُعد توفير الطاقة بكفاءة واستمرارية عاملًا استراتيجيًا لدعم النمو الاقتصادي وتحسين جودة الحياة، في ظل التزايد السكاني، والتوسع العمراني، والتطور الصناعي. ومع تصاعد هذه التحديات، تبرز الحاجة إلى حلول علمية دقيقة للتنبؤ بالطلب الكهربائي، بما يواكب رؤية المملكة 2030 التي تؤكد على كفاءة الطاقة وتنويع مصادرها.

وفي هذا السياق، أوضحت دراسات عدة أن استهلاك الكهرباء يُعد مؤشرًا للنشاط الاقتصادي، حيث بيّن العنزي (2022) تأثر الطلب بعدد السكان ونصيب الفرد من الناتج المحلي، فيما أكدت بن سعدي وآخرون (2023) أن الاستهلاك مرشح للارتفاع حتى عام 2030، ما يستدعي استراتيجيات ترشيد وتخطيط بعيد المدى.

ولم تعد النماذج التقليدية كافية لفهم الأنماط المعقدة، مما دفع إلى تبني تقنيات الذكاء الاصطناعي، التي أثبتت كفاءتها في التعامل مع البيانات الضخمة. فقد أظهرت دراسات مثل وحيد وآخرون (Waheed et al., 2024) وكوماراسوامي وآخرون (Kumaraswamy et al., 2024) تفوق الشبكات العصبية والنماذج الهجينة في التنبؤ بالاستهلاك المنزلي.

وفي السياق المحلي، أثبتت دراسة المهيني وسلطانة (Almuhaini & Sultana, 2023) فعالية النماذج الذكية الهجينة، بينما بيّنت ساروار وآخرون (Sarwar et al., 2024) تفوق تقنيات SVM على نماذج السلاسل الزمنية. كما أوضحت دراستا العنزي وآخرون (Alanazi et al., 2025) والشمري (Alshammari, 2024) أن تطبيق خوارزميات تعلم الآلة في القطاعات التعليمية والسكنية يُحسّن إدارة الاستهلاك وكفاءة الطاقة.

وتأتي الدراسة الحالية استجابة لهذه التوجهات، عبر بناء نموذج تنبؤي شامل لاستهلاك الكهرباء في المملكة، من خلال مقارنة أداء الشبكات العصبية الاصطناعية (ANN) بخوارزمية الانتشار العكسي، مع نموذج الانحدار اللوجستي، باستخدام بيانات للفترة 2000–2024، بما يحقق تكاملًا بين التحليل الاقتصادي والتقنيات الذكية.

2-1 مشكلة الدراسة

يمثل النمو المتزايد في استهلاك الكهرباء بالمملكة تحديًا يستلزم فهمًا دقيقًا للمتغيرات المؤثرة وإمكانية التنبؤ بها. ورغم توفر البيانات التاريخية، فإن استثمارها في نماذج حديثة لا يزال محدودًا. وتتمثل أبرز أوجه المشكلة في:

- **عجز النماذج التقليدية**: أظهرت دراسة المهيني وسلطانة (Almuhaini & Sultana, 2023) ضعف دقة النماذج الإحصائية مقارنة بنماذج الذكاء الاصطناعي، مما يستدعي أدوات تحليلية أكثر كفاءة.
- **الفجوة في التطبيقات المحلية**: رغم توفر قواعد بيانات واسعة، فإن استخدام الشبكات العصبية الاصطناعية ما زال محدودًا؛ فدراسة العنزي وآخرون (Alanazi et al., 2025) ركزت على نطاقات جزئية، دون تحليل وطني شامل.
- **القصور في النماذج الإحصائية**: كشفت دراسة إسماعيل (2025) أن الانحدار اللوجستي رغم دقته الظاهرية، يعاني من الفصل المثالي وتعدد الارتباطات، مما يحد من موثوقية نتائجه ويؤكد الحاجة إلى نماذج أكثر مرونة.
- **الحاجة إلى مقارنات منهجية**: أظهرت دراسة الشمري (Alshammari, 2024) تفوق الغابات العشوائية في التنبؤ المنزلي، لكنها لم تؤكد فعالية الشبكات العصبية، مما يستدعي دراسات مقارنة مباشرة.

- **التنبؤ لخدمة التنمية**: في ظل رؤية المملكة 2030، تزداد الحاجة إلى نماذج دقيقة لمواءمة خطط الطاقة مع المتغيرات الاقتصادية والمناخية والسكانية، كما أكد بن سعدي وآخرون (Ben Saadi et al., 2023) أن الاستهلاك مرشح للارتفاع المستمر حتى عام 2030.

بناءً على ذلك، تُعالج هذه الدراسة فجوة بحثية تتمثل في غياب المقارنة المنهجية بين نموذج الشبكات العصبية الاصطناعية (ANN) والانحدار اللوجستي في التنبؤ باستهلاك الكهرباء على المستوى الوطني، بما يدعم صناع القرار في إدارة قطاع الطاقة وتحقيق أهداف التنمية المستدامة.

1-3-أسئلة الدراسة:

يمكن تحديد مشكلة الدراسة في الأسئلة الآتية:

1. ما مدى تفوق نموذج الشبكات العصبية الاصطناعية باستخدام خوارزمية الانتشار العكسي على نموذج الانحدار اللوجستي في دقة التنبؤ باستهلاك الكهرباء؟
2. ما العوامل (الاقتصادية، الديموغرافية، والمناخية) الأكثر تأثيراً في استهلاك الطاقة الكهربائية في المملكة العربية السعودية خلال الفترة المدروسة؟
3. ما أبرز الأساليب والنماذج الإحصائية المستخدمة في التنبؤ بالطلب على الطاقة الكهربائية، ومدى ملاءمتها للواقع السعودي؟

1-4-فرضيات الدراسة:

- **الفرضية الأولى**: يوفر نموذج الشبكات العصبية الاصطناعية باستخدام خوارزمية الانتشار العكسي أداءً تنبؤيًا أكثر دقة وكفاءة مقارنةً بنموذج الانحدار اللوجستي في تقدير استهلاك الطاقة الكهربائية في المملكة العربية السعودية.
- **الفرضية الثانية**: توجد علاقة ذات دلالة إحصائية بين مجموعة من العوامل الاقتصادية والديموغرافية (مثل الناتج المحلي الإجمالي، دخل الفرد، عدد السكان، درجات الحرارة، والاستهلاك الصناعي) وبين مستويات استهلاك الطاقة الكهربائية في المملكة خلال الفترة: 2000- 2024.

1-5 أهداف الدراسة:

1. بناء نموذج تنبؤي باستخدام الشبكات العصبية الاصطناعية (خوارزمية الانتشار العكسي) لتقدير الطلب على الطاقة الكهربائية في المملكة العربية السعودية.
2. تحليل تأثير العوامل الاقتصادية والديموغرافية والمناخية على استهلاك الكهرباء خلال الفترة الزمنية المدروسة.
3. مقارنة دقة أداء نموذج الشبكات العصبية مع نموذج الانحدار اللوجستي في التنبؤ باستهلاك الكهرباء.

1-6 أهمية الدراسة:

- **الأهمية العلمية**: تُسهم الدراسة في إثراء الأدبيات العلمية من خلال تقديم مقارنة منهجية بين نموذج الشبكات العصبية الاصطناعية ونموذج الانحدار اللوجستي في مجال التنبؤ باستهلاك الطاقة الكهربائية، مما يعزز فهم الباحثين لكفاءة تقنيات الذكاء الاصطناعي مقابل الأساليب الإحصائية التقليدية.

- **الأهمية التطبيقية**: توفر الدراسة نموذجًا عمليًا تستفيد منه وزارتا الكهرباء والتخطيط، وشركات الطاقة؛ في التنبؤ بالطلب المستقبلي على الكهرباء بدقة، مما يساعد على تحسين إدارة الموارد وتخطيط البنية التحتية للطاقة.
- **الأهمية الاقتصادية والتنموية**: يسهم النموذج التنبؤي في دعم صناع القرار في تطوير سياسات طاقة مستدامة، وتحديد الفترات ذات الطلب المرتفع على الكهرباء، لتقليل الهدر وتوجيه الاستثمار في مشاريع أكثر كفاءة.
- **الأهمية التقنية**: تعزز الدراسة من استخدام أدوات الذكاء الاصطناعي والتحليل التنبؤي في قطاعات خدمية حيوية، وتفتح المجال أمام دراسات مستقبلية تُوظف تقنيات مشابهة في قطاعات أخرى مثل المياه، النقل، أو الصحة.

1-7 حدود الدراسة:

- **الحدود الموضوعية**: تتمثل في استخدام نموذج الشبكات العصبية الاصطناعية (خوارزمية الانتشار العكسي) وتحليل مقارنته مع نموذج الانحدار اللوجستي كأدوات إحصائية لتقدير استهلاك الطاقة الكهربائية.
- **الحدود المكانية**: تقتصر الدراسة على المملكة العربية السعودية كمجال جغرافي لتطبيق النماذج التحليلية.
- **الحدود الزمانية**: تعتمد الدراسة على بيانات وتقارير استهلاك الكهرباء خلال الفترة: 2000- 2024.

2-الإطار النظري والدراسات السابقة.

2-1-الإطار النظري:

2-1-1-الانحدار اللوجستي logistic regression

2-1-1-1-تعريف الانحدار اللوجستي: يعرف بأنه: "نموذج يستخدم للتنبؤ باحتمالية وقوع حدث ما وذلك بملاءمة لبيانات على منحنى لوجستي، يستخدم الانحدار اللوجستي عدة متغيرات(مستقلة) والتي يمكن أن تكون بنسبة أو فئوية، أو اسمية، أو رتبيه مقابل متغير متنبأ به واحد (تابع). (الشهري، 2021)

ويتبين من تعريف الانحدار اللوجستي أنه يستخدم في تحليل العلاقة بين متغيرات مستقلة ومتغير تابع يكون تصنيفاCategorical ، أو رتبيا ordinal من خلال تقدير احتمال وقوع حدث من عدمه عن طريق تركيب منحنى لوجستي

2-1-1-2-مجالات استخدام الانحدار اللوجستي:

يُستخدم الانحدار اللوجستي لتحقيق أغراض إحصائية متعددة في مجالات كثيرة، وتلخص الباحثة أهمها نقلًا عن (بابطين، 2009) والجشي (2025) كالآتي:

أ. يُستخدم هذا الأسلوب لبناء نماذج تنبؤية للمتغيرات الكيفية، مثل تصنيف طلبات القروض والتأمين حسب مستوى المخاطر، أو التنبؤ بشراء المستهلك لمنتج معين.

ب. يُوظف في القطاع الصحي للتنبؤ بإصابة المرضى بالأمراض وتخطيط الرعاية، كما يُستخدم في كشف العمليات المالية الاحتيالية وتحليل تأثير العوامل الوراثية

2-1-1-3-تقنية نموذج الانحدار اللوجيستي:

يعد نموذج الانحدار اللوجيستي Model Regression Logistic حالة خاصة من حالات نماذج الانحدار العامة Models Linear Generalizedويطلق على هذه النماذج أحيانا نماذج Logit وفي حالة النموذج اللوجيستي نستطيع مباشرة تقدير احتمال حدوث حدث ما، فعلى سبيل المثال في حالة متغير مستقل وحيد يكون النموذج كما يلي:

$$P(Y) = \frac{e^{B_0+B_1 X+\varepsilon_i}}{1+e^{B_0+B_1 X+\varepsilon_i}}$$

ويمكن صياغته في الشكل الآتي:

$$P(Y) = \frac{1}{1+e^{B_0+B_1 X+\varepsilon_i}}$$

حيثY: يمثل احتمال الحدث p(y) ؛ Bo: يمثل الحد الثابت؛ B1يمثل معامل المتغير المستقل؛ x: يمثل المتغير المستقل؛ e: تمثل أساس اللوغاريتم الطبيعي وتساوى تقريبا 2.718؛ εهـ يمثل الخطأ العشوائي

2-1-1-4-مزايا الانحدار اللوجستي:

تؤكد دراسات (بن سعدي وآخرون، 2023؛ Almuhaini et al., 2023؛ Abushanab et al., 2025؛ الجشي، 2025) إلى أن للانحدار اللوجستي مزايا متعددة، أبرزها:

1. المرونة في التعامل مع المتغيرات الكمية والوصفية، مع إمكانية اختبار دلالة كل معامل.
2. سهولة التفسير، حيث يوضح تأثير كل متغير مستقل على المتغير التابع.
3. مقاومة الانحرافات عن اعتدالية التوزيع، مما يجعله أقل حساسية من النماذج الخطية التقليدية.
4. قبول التقدير حتى في غياب بعض القيود المفروضة على نماذج أخرى.

وترى الباحثة أن الانحدار اللوجستي يُعد نموذجًا إحصائيًا فعالًا، خاصة في تحليل البيانات ذات التصنيف الثنائي، ويوفر نتائج دقيقة وموثوقة.

2-1-1-5-عيوب الانحدار اللوجستي:

رغم مزاياه، يعاني الانحدار اللوجستي من قيود تحد من فعاليته في التطبيقات المتقدمة، تلخص الباحثة أبرزها نقلًا عن وحيد وآخرون (Waheed et al., 2024)، والشمّري (Alshammari, 2024)، والجشي (2025) كالآتي:

- لا يُعالج التغيرات الزمنية بكفاءة، مما يجعله غير مناسب للسلاسل الزمنية أو البيانات المتتابعة.
- يتأثر سلبًا بوجود متغيرات مستقلة مترابطة، ما يؤدي إلى انخفاض دقة النموذج.
- لا يُجيد تمثيل العلاقات المعقدة بين المتغيرات مقارنةً بنماذج مثل الشبكات العصبية، مما يضعف جودة التنبؤ.

وترى الباحثة أن هذه العيوب، خصوصًا ضعف التعامل مع الزمن والعلاقات غير الخطية، تُبرر الاتجاه نحو نماذج الذكاء الاصطناعي الأكثر تطورًا، نظرًا لتعدد العوامل المؤثرة في استهلاك الكهرباء وتغيرها عبر الزمن.

2-1-2-الشبكات العصبية الاصطناعية (ANNs):

2-1-2-1-مفهوم الشبكات العصبية الاصطناعية: تُعرف بأنها: "أنظمة حاسوبية متوازية تحاكي بنية الدماغ البشري وقدرته على معالجة المعلوماتProcessing Element تُبنى هذه الشبكات من مجموعة من الخلايا العصبية المترابطة، والتي تُعرف بالعصبونات أو وحدات المعالجة، وتتواصل فيما بينها عبر روابط (أوزان) تُعدّل باستمرار من خلال عملية التدريب. وعلى عكس النماذج الإحصائية التقليدية، فإن الشبكات العصبية لا تعتمد على علاقة رياضية محددة مسبقًا، بل تتعلم الأنماط من البيانات المدخلة لإنتاج التنبؤات المطلوبة" (المهيني وآخرون، Almuhaini et al., 2023).

2-1-2-2-خصائص الشبكات العصبية الاصطناعية ومزاياها

تتميز الشبكات العصبية الاصطناعية بمجموعة من الخصائص التي تجعلها خيارًا مفضلًا في العديد من التطبيقات المعقدة. وتلخص الباحثة أهمها نقلًا عن المهيني وآخرون (2023)، والعنزي وآخرون (2025)، وكوماراسوامي وآخرون (2024)، ومرسييه (2025) وكما يبينها الشكل(1):

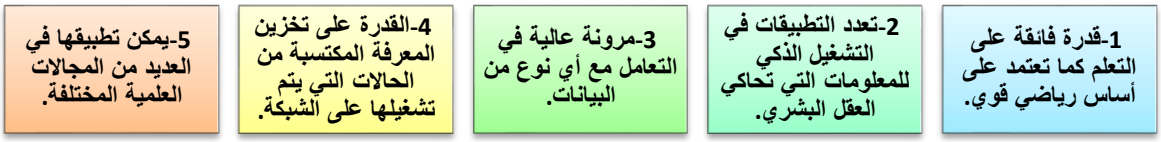

الشكل (1) من إعداد الباحثة نقلا عن (قصي، 2007) والمراجع بعاليه

ويتبين من الشكل (1) أن الشبكات العصبية الاصطناعية تتميز بقدرتها على التعلم من البيانات بشكل مستقل وتحديد الأنماط المعقدة. تتمتع بمرونة عالية في التعامل مع مختلف أنواع البيانات، بما في ذلك البيانات غير المهيكلة (مثل الصور والنصوص)، دون الحاجة لافتراضات مسبقة. كما أنها قادرة على تخزين المعرفة وتطبيقها على بيانات جديدة، مما يزيد من دقتها بمرور الوقت. وتُستخدم في تطبيقات واسعة مثل التنبؤ، والتحكم الآلي، والتعرف على الأنماط، والمساعدات الصوتية. وترى الباحثة أن هذه الخصائص تبرر استخدام الشبكات العصبية الاصطناعية في التنبؤ باستهلاك الطاقة الكهربائية، حيث يمكنها التعامل مع العوامل المتعددة والمعقدة المؤثرة في الاستهلاك بدقة أكبر من النماذج التقليدية.

2-1-2-3-مجالات استخدام الشبكات العصبية الاصطناعية

للشبكات العصبية قدرة هائلة على حل مشاكل حقيقية، وقد طُبقت في مجالات عديدة أهمها:

A. **الطب الفوري**: وهو تطبيق يرتبط بمبدأ الذاكرة كما في العقل البشري، أي مبدأ العلاقات المرضية والتشخيصية.
B. **الاتصالات السلكية واللاسلكية**: مثل التخلص من صدى الصوت الذي قد ينتج من خطوط الهاتف، وفي الرادارات العسكرية لتحديد الأهداف.
C. **الأعمال المصرفية**: وذلك لفتح الحسابات الخاصة بالبنوك عن طريق اللمس أو الصوت أو بصمة العين، وكذلك للتعرف على التوقيعات البنكية وخطوط اليد.
D. **التنبؤ**: تستخدم الشبكات بشكل واسع جدًا في مجال التنبؤ، إذ تحتاج إلى فروض قليلة وعدد مشاهدات أقل مقارنة بالطرق التقليدية. ومن ذلك: التنبؤ بأسعار الأسهم، والمبيعات، وهطول الأمطار، ودرجة حرارة الجو، وغيرها.

2-1-2-4-مكونات الشبكات العصبية الاصطناعية:

تتكون الشبكة العصبية الاصطناعية من وحدات تُعرف بـ Neurons أو Nodes، ترتبط عبر Connections أو Weights تُحدد قوة العلاقة بين الطبقات. وتتألف من ثلاث طبقات رئيسية:

A. طبقة المدخلات (Input Layer): تستقبل البيانات الأولية مثل الصور أو النصوص.
B. الطبقات المخفية (Hidden Layers): تُعالج البيانات وتستخرج الأنماط، ويزداد تعقيد النموذج بزيادة عددها.
C. طبقة المخرجات (Output Layer): تُنتج التنبؤ النهائي أو التصنيف المطلوب.

وترتبط هذه الطبقات عبر Weights تعبّر عن قوة الاتصال العصبي، وتُعد هذه البنية أساسًا لتعلم الأنماط غير الخطية. وقد أشار الحسيني والساعدي (2007) إلى هذه البنية بوصفها جوهر الشبكات، بينما أكدت دراسة Mienye وآخرون (2024) فعاليتها في تعزيز التعلم العميق CNNs وRNNs وTransformers، وتوسع تطبيقها في مجالات عديدة.

2-1-2-5-عيوب الشبكات العصبية الاصطناعية

رغم مزاياها، تواجه الشبكات العصبية تحديات تقنية ومنهجية، أبرزها كما ورد في الشمّري (2024)، وحيد وآخرون (2024)، ومرسييه (2025) الآتي:

A. **غياب الشفافية (الصندوق الأسود):** يصعب تفسير كيفية وصول النموذج إلى نتائجه، مما يُعقّد استخدامها في التطبيقات الحساسة.

B. **الحاجة إلى بيانات ضخمة:** تتطلب كميات كبيرة من البيانات لتحقيق دقة عالية، وهو ما قد لا يتوفر دائمًا.

C. **متطلبات حوسبة مرتفعة:** تحتاج إلى قدرات معالجة عالية ووقت طويل للتدريب، خاصة في النماذج المعقدة، رغم تحسن الأداء بفضل تقنيات مثل GPUs.

وترى الباحثة أن هذه العيوب لا تُقلّل من أهميتها، بل تُبرز الحاجة إلى توازن بين تعقيد النموذج ودقة النتائج، مما يجعل مقارنتها بالنماذج الإحصائية التقليدية خطوة منهجية ضرورية لتقييم كفاءتها في السياقات التطبيقية.

2-1-2-6-الشبكات العصبية الاصطناعية للنماذج الخطية وغير الخطية: (محمد 2012)

يمكن أن تتألف الشبكات العصبية من طبقة واحدة أو عدة طبقات فمثلا في النموذج الخطي المتكون من طبقة واحدة) متغير واحد داخل ومتغير واحد خارج (فإن الشبكة العصبية تتألف من طبقة إدخال واحدة وطبقة اخراج واحدة ووحدة تمثل قيمة التحيز والتي تساوي 1 ويمكن أن تمثل بالمعادلة الخطية:

$$\hat{Y}P = \delta WP0 + X1WP1 = WP0 + X1WP1$$

حيث إن: مقدار التحيز ويساوي الواحد الصحيح؛ 0: الوزن الخاص للمقطع بالنسبة للمتغير الداخل XP.

1: الوزن الخاص للميل بالنسبة للمتغير الداخل XP ؛ $\hat{P}$:لقيمة التقديرية للمتغير الخارج الحقيقي YP.

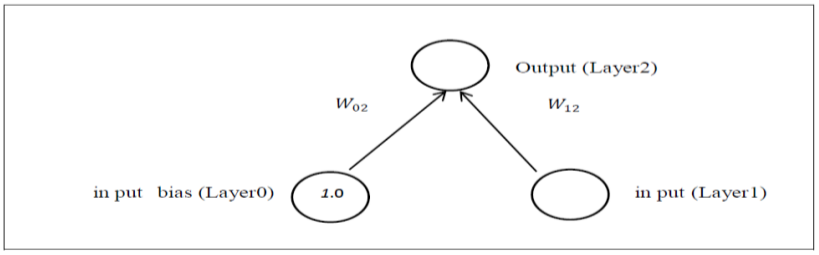

شكل (2) شبكة عصبية للنموذج الخطي ذات وحدة اخراج واحدة

يتم حساب مجموع مربعات الخطأ باستخدام المعادلة التالية $SSE = 1n\Sigma(\hat{Y}P - YP)2 \quad np=1 \quad (3.2)$

أما في حالة النموذج الخطي لمتغيري إدخال فإن رسم الشبكة يكون كما هو موضح في الشكل3 التالي:

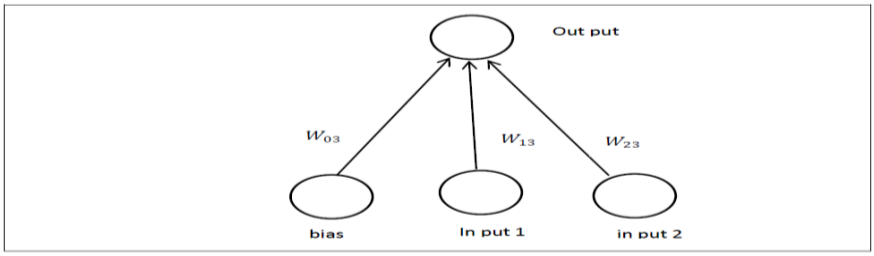

الشكل (3) شبكة عصبية للنموذج الخطي ذي مدخلين ومخرج واحد

أما بالنسبة لمجموع مربعات الخطأ فيتم إيجاده بجمع مربعات الخطأ لكل متغير خارج مع الآخر للحصول على مجموع مربعات الخطأ الكلي كما في المعادلة: (3.3) $TSSE=\Sigma SSELL\ L=1,2,3,...$

حيث إن: 1- (L) رقم المخرج. 2- (TSSE) المجموع الكلي لمربعات الخطأ. 3- (SSE) مجموع مربعات الخطأ لكل متغير على حده. أما للنماذج غير الخطية فإنه من الضروري توفيق المنحى أو الشكل المناسب للبيانات قيد البحث وتتم الاستعانة بدالة التحفيز التي تتولي نشر القيمة الداخلة اليها وفق المقياس المحدد لها في bias

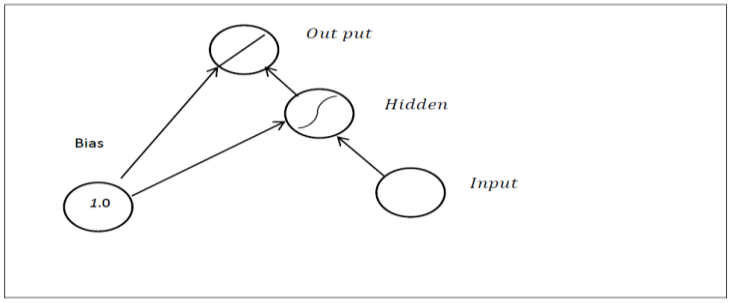

الشكل (4) شبكة عصبية للنموذج غير الخطي ذات مدخل واحد ومخرج واحد

مما تقدم يمكن القول بأن الشبكة العصبية الاصطناعية تتكون من وحدة حسابية ذات مُدْخَل واحد أو متعددة المدخلات أو إشارة خارجة واحدة، ولكل إشارة داخلة وزن يعمل على تعديلها ويكون بمثابة المشبك العصبي (نقطة اشتباك) لتحفيز الخلية لإنتاج إشارة رد فعل عندما تكون قيمته موجبة أو إخمادها وتقليل الإشارة الخارجة مع القيم السالبة.

2-1-2-7-استخدام الشبكات العصبية الاصطناعية في التنبؤ:

تُعد الشبكات العصبية الاصطناعية من النماذج المتقدمة في مجال التنبؤ، حيث لا تتطلب افتراضات صارمة حول طبيعة البيانات وتستطيع التعامل مع العلاقات اللاخطية المعقدة. وتلخص الباحثة خطوات بناء نموذج للتنبؤ باستخدام شبكة الانتشار العكسي للخطأ نقلًا عن (قصي، 2007) وكما يبينها الجدول التالي:

الجدول (1) خطوات استخدام الشبكات العصبية الاصطناعية في التنبؤ

الخطوة	التفصيل
1-اختيار المتغيرات	يجب اختيار المتغيرات بعناية لتمثيل المشكلة المراد حلها بشكل جيد.
2-معالجة البيانات	بتحديد الاتجاه العام، وتحليل العلاقات بين المشاهدات، وتحديد توزيع البيانات.
3-تقسيم البيانات	وتُقسّم إلى ثلاث مجموعات: التدريب (تعلم النموذج)، التحقق (ضبط المعايير)، والاختبار(تقييم النموذج).
4-تصميم النموذج	تتضمن تحديد عدد العصبونات في طبقة الإدخال، وعدد الطبقات المخفية، وعدد عصبونات الإخراج.
5-معايير التقييم	مثل مجموع مربعات الأخطاء (MSE) وجذر متوسط مربعات الأخطاء (RMSE) لتقييم دقة النموذج.
6-تدريب الشبكة	تُستخدم خوارزمية الانتشار العكسي للخطأ لتقليل الخطأ وتحديد الأوزان بين العصبونات.

7-التنفيذ	تُختبر قدرة الشبكة على التكيف مع البيانات الجديدة وتقليل الخطأ، وتُعاد عملية التدريب إذا لزم الأمر.

يتبين من الجدول (1) أن دمج هذه الخطوات المنهجية مع القدرات التحليلية للشبكات العصبية يُعزز من دقة التنبؤ، خاصة في المجالات التي تتسم بياناتها بالتعقيد وعدم الخطية. إن اتباع هذه الخطوات يُعد ضروريًا لضمان موثوقية النموذج وفعاليته في اتخاذ القرارات، مما يُبرز أهميتها كأداة بحثية متقدمة.

2-1-2-8-خوارزميات تعلم الشبكة العصبية الاصطناعية

خوارزمية الانتشار العكسي(Back Propagation Algorithm)

تُعد **خوارزمية الانتشار العكسي** من أبرز تقنيات تدريب الشبكات العصبية متعددة الطبقات وغير الخطية، وتهدف إلى تحديث **أوزان** الشبكة بشكل منهجي خلال فترة التدريب. وتتم العملية عبر مرحلتين أساسيتين (قصي، 2007):

الجدول (2) خوارزمية الانتشار العكسي لتعلم الشبكات العصبية الاصطناعية (المراحل والمفاهيم الأساسية)

المرحلة / العنصر	الوصف المختصر
نوع الخوارزمية	الانتشار العكسي (Backpropagation) لتدريب الشبكات متعددة الطبقات غير الخطية
الهدف الأساسي	تعديل الأوزان تدريجيًا لتقليل الخطأ وتحسين دقة التنبؤ
المرحلة الأولى	الانتشار الأمامي :(Feedforward) تمرير البيانات من المدخلات إلى المخرجات دون تعديل للأوزان
حساب التنشيط	-الطبقة المخفية ($z_j = f(Z_{i+j})$): طبقة المخرجات($y_k = f(w_{ok} + \sum z_j \cdot w_{ij})$) :
المرحلة الثانية	الانتشار الخلفي :(Backpropagation) إعادة نشر الخطأ من المخرجات إلى المدخلات لضبط الأوزان
خوارزمية التحديث	الانحدار التدريجي($x_{k+1} = x_k - \alpha_k \cdot g_k$): (Gradient Descent)
مكونات التحديث	الأوزان الحالية: (x_k)؛ معدل التعلم:(α_k) الميل الحالي: (g_k)
مرحلة التدريب	مقارنة الناتج المحسوب (y_k) بالقيمة الفعلية(t_k) ، ثم توزيع الخطأ وتحديث الأوزان بين الطبقات

يتبين من الجدول (2) مراحل عمل خوارزمية الانتشار العكسي بشكل مبسط، بدءًا من تمرير البيانات عبر الشبكة وصولًا إلى ضبط الأوزان بناءً على الخطأ الناتج. وتُبرز هذه الآلية كيف تتعلم الشبكة تدريجيًا من خلال تحسين الأداء التنبؤي في كل دورة تدريب. كما أن استخدام الانحدار التدريجي يُعد جوهريًا في تقليل الفروقات بين الناتج الفعلي والمستهدف، مما يجعل هذه الخوارزمية حجر الأساس في بناء نماذج دقيقة ومرنة، خاصة في التطبيقات التي تتطلب معالجة علاقات غير خطية متعددة.

2-1-2-9-طرق حساب الانحدار التدريجي:

توجد طريقتان رئيسيتان لتحديث الأوزان:

- **النظام التزايدي :(Incremental Mode)** يتم تحديث الأوزان بعد كل إدخال فردي للشبكة.
- **نظام الدفعة الواحدة :(Batch Mode)** يتم تجميع الميول المحسوبة من جميع أمثلة مجموعة التدريب، ثم يتم تحديث الأوزان والانحيازات دفعة واحدة.

وترى الباحثة أن دقة وسرعة خوارزمية الانتشار العكسي في تعديل الأوزان هو ما جعلها حجر الزاوية في تدريب الشبكات العصبية. إن قدرتها على التعامل مع العلاقات المعقدة والبيانات غير الخطية من خلال عملية التكرار وضبط الأوزان تجعلها أداة لا غنى عنها في مجالات التنبؤ وتحليل البيانات.

2-1-3-تحليل استهلاك الكهرباء في المملكة والعوامل المؤثرة فيه:

يُعد تحليل استهلاك الكهرباء من الموضوعات الحيوية في قطاع الطاقة، خاصة في الدول التي تشهد نمواً سكانياً واقتصادياً متسارعاً مثل السعودية. يهدف التحليل إلى فهم العوامل التي تؤثر في استهلاك الكهرباء والتنبؤ باتجاهاتها، وتُعد الشبكات العصبية أداة مناسبة لهذه المهمة، إذ لا تتطلب افتراضات صارمة حول البيانات، وتستطيع التعامل مع متغيرات متعددة مثل العوامل الديموغرافية، والاقتصادية، والمناخية، وتعتمد الدراسة على نموذج شبكة الانتشار العكسي لتحليل العوامل المؤثرة في استهلاك الكهرباء، وتحديد ما إذا كان الاستهلاك مرتفعاً أو منخفضاً. تسعى الدراسة إلى بناء نموذج تنبؤي دقيق يساعد في دعم قرارات ترشيد الطاقة ورسم السياسات المستقبلية.

2-1-3-2-العوامل المؤثرة في استهلاك الكهرباء في المملكة العربية السعودية:

تشير الأدبيات الاقتصادية إلى أن استهلاك الكهرباء يتأثر بعدة عوامل، من أبرزها (إسماعيل، 2025):

1) عدد السكان: فكلما زاد عدد السكان، ارتفع الطلب على الكهرباء في الاستخدامات السكنية والخدمية.
2) ارتفاع درجة الحرارة: خاصة في الصيف، فيزيد استخدام أجهزة التكييف، ما يؤدي إلى ارتفاع الاستهلاك
3) دخل الفرد: يعد من أبرز المحددات التي تعكس القدرة الشرائية للمواطن، وبالتالي مدى استهلاك الكهرباء.
4) الناتج المحلي الإجمالي: يعكس النشاط الاقتصادي العام، وبالتالي يرتبط بالاستهلاك الصناعي والتجاري للكهرباء.
5) الدعم الحكومي وتعرفة الكهرباء: كلما انخفضت التعرفة، زاد الاستهلاك نتيجة لانخفاض التكلفة الحدية.
6) التوسع العمراني: ينتج عنه توسع في البنية التحتية السكنية والخدمية، مما يؤدي إلى زيادة استهلاك الطاقة.

2-2-الدراسات السابقة

2-2-1-دراسات سابقة تناولت الطاقة في المملكة العربية السعودية:

تُظهر الأدبيات الحديثة تنوعًا في نماذج التنبؤ باستهلاك الكهرباء في السعودية، مع تصاعد الاهتمام بتقنيات الذكاء الاصطناعي والنماذج الهجينة، إلا أن معظم الدراسات افتقرت إلى دمج العوامل الاقتصادية والمناخية أو المقارنة المنهجية بين النماذج.

ففي السياق التقني، طوّر شيرازي وآخرون (2025) نموذجًا هجينًا يجمع بين CNN وخزان مزدوج محسّن بايزيًا، بينما استخدم الثروي وآخرون (2025) نموذج ANN مدعّمًا بخوارزمية SFWWO، وكلاهما حقق نتائج دقيقة في بيئات ذكية محددة دون تحليل اقتصادي وطني. وفي دراسة العنزي وآخرون (2025)، تم تطوير نظام تنبؤ جامعي باستخدام GBR بدقة 85%، لكنه بقي محدودًا في النطاق المؤسسي.

أما في الدمج بين النماذج الاقتصادية والذكية، فقدّم المهيني وسلطانة (2023) نموذجًا هجينًا باستخدام BOA وNARX وSVR، محققًا دقة ($R^2 > 0.98$) على بيانات سنوية، دون اختبار للتغيرات قصيرة الأجل، وهو ما تراعيه الدراسة الحالية، وفي المقابل، اعتمد الحاج (2024) وبن سعدي وآخرون (2023) على نماذج ARIMA لتنبؤات قصيرة ومتوسطة الأجل، دون إدماج متغيرات خارجية أو تقنيات الذكاء الاصطناعي. كما تناولت التميمي (2024) والشمري (2024) أنماط الاستهلاك السكني باستخدام منهج وصفي وخوارزميات تعلم آلي، دون بناء نماذج تنبؤية شاملة أو مقارنة خوارزميات.

وفي الدراسات الاقتصادية، استخدمت العنزي (2022) نموذج الانحدار المتعدد لتحديد أثر الناتج المحلي والسكان والأسعار، بينما طبقت الشهري (2021) نموذج الانحدار اللوجستي الثنائي على بيانات أسرية، وأظهر العمري (2019) تأثير السكان والحرارة باستخدام الانحدار اللوجستي الخطي.

وتُبرز هذه الدراسات فجوة في المقارنة المنهجية بين الانحدار اللوجستي والشبكات العصبية الاصطناعية، وهو ما تسعى إليه الدراسة الحالية عبر تقديم نموذج تنبؤي شامل قائم على ANN بخوارزمية الانتشار العكسي، وتحليل أدائه مقابل النماذج التقليدية، باستخدام بيانات ممتدة للفترة 2000–2024، في سياق اقتصادي وبيئي سعودي متكامل.

2-2-2-الدراسات الإقليمية والعالمية:

تتجه الدراسات الحديثة نحو تعزيز استخدام تقنيات الذكاء الاصطناعي والنماذج الهجينة في التنبؤ باستهلاك الطاقة، مع اهتمام متزايد بإدماج البُعدين الاقتصادي والبيئي. ففي إسبانيا، قارنت دراسة أبوشنب وآخرون (2025، Abushanab et al) مجموعة من نماذج الذكاء الاصطناعي على بيانات HVAC، وأظهرت تفوق نموذج Random Forest بدقة R^2=0.954، إلا أنها اقتصرت على الجانب التقني دون دمج المتغيرات الاقتصادية، وهو ما تسعى إليه الدراسة الحالية. وفي تركيا، استخدم غور (Gör, 2025) نموذج Random Committee لتنبؤ استهلاك دول أوبك، مع توصية بتوسيع قاعدة البيانات لتشمل متغيرات اقتصادية وبيئية، مما يدعم النهج المتكامل الذي تتبناه الباحثة.

أما في إيطاليا، فقدّم بوبكر وآخرون (Boubaker et al, 2025) نماذج متقدمة مثل DRNN وBi-GRU لتنبؤ استهلاك محطات شحن المركبات الكهربائية، محققين ارتباطات قوية (97–98%)، لكن نطاقها اقتصر على قطاع النقل، بينما تركز الحالية على استهلاك وطني متعدد القطاعات. وفي قطر، تناول الفليت (Al-Fleit, 2024) البعد الأخلاقي لتطبيق الذكاء الاصطناعي في الطاقة، داعيًا إلى أطر حوكمة رقمية، وهي مقاربة نوعية تختلف عن المنهج المتبع في هذه الدراسة.

وفي الجزائر، استخدم ساري-حسون وآخرون (Sari-Hassoun et al, 2024) نموذج MLP 3-1-1 لتنبؤ سنوي باستهلاك الكهرباء، مسجلين زيادة متوقعة قدرها 3.43%، مع دقة عالية، لكن دون تحليل موسّع للعوامل الاقتصادية، وهو ما تتجاوزه الدراسة الحالية عبر نمذجة متعددة المتغيرات. وفي الصين، استخدم وحيد وآخرون (2024، Waheed et al.) نموذج LSTM-RNN لتنبؤ ساعي بالأحمال الكهربائية، محققًا دقة (MAPE ≈ 1.5%)، إلا أن طبيعته القصيرة الأجل لا تتناسب مع أهداف الدراسة الحالية التي تركز على تنبؤ سنوي ووطني.

وفي الهند، طوّر كوماراسوامي وآخرون (Kumaraswamy et al, 2024) نموذجًا هجينًا يجمع بين FFNN وLSTM مع SWT لتقليل الخطأ في استهلاك منزلي، مما يعكس التوجه نحو دمج الخوارزميات، لكنه يظل محدودًا في نطاقه. أما أبيسوي وآخرون (2024، Abisoye et al.) فقدّموا مراجعة شاملة لخوارزميات الذكاء الاصطناعي في الطاقة المتجددة، داعين إلى تطوير نماذج هجينة ترتبط بأنظمة طاقة ذكية، وهي مراجعة نظرية، وتفتقر إلى نتائج كمية، وأخيرًا، راجعت دراسة ميني وآخرون (2024، Mienye et al) بُنى Recurrent Neural Networks وتطبيقاتها في عدة مجالات، مؤكدة أهمية دمج Attention Mechanisms ونماذج هجينة مثل CNNs وTransformers، بما يعزز دقة التنبؤ ومرونة النماذج، وهو ما يتفق مع الحالية في استخدام ANN للتنبؤ باستهلاك الكهرباء بدقة عالية.

3-2-2-خلاصة مقارنة للدراسات السابقة وجوانب القصور فيها

الجدول (3) خلاصة بأهم الدراسات السابقة وأبرز جوانب القصور في كل منها

الباحث/العام	البلد	هدف الدراسة	المنهجية/النموذج	المتغيرات المدخلة	النتائج الرئيسة	حدود/قصور الدراسة
العمري (2019)	السعودية	تقدير الطلب باستخدام الانحدار اللوجستي	انحدار لوجستي	السكان، الحرارة	تأثير قوي للسكان والحرارة	لم يقارن مع نماذج ذكاء اصطناعي
الشهري (2021)	السعودية	الانحدار اللوجستي في استهلاك الأسر	انحدار لوجستي ثنائي	الأسرة، الدخل، المسكن، المكيفات	دقة 83%	نموذج إحصائي فقط، بلا دمج للمتغيرات البيئية

العنزي (2022)	السعودية	تحليل العوامل المؤثرة في الاستهلاك	انحدار متعدد	السكان، الناتج المحلي، أسعار الكهرباء	تأثير اقتصادي كبير	بيانات سنوية فقط، بلا نماذج ذكاء اصطناعي
بن سعدي وآخرون (2023)	السعودية	التنبؤ حتى 2030	ARIMA(2,2,6)	السلاسل الزمنية	اتجاه تصاعدي	أحادي المخرج، بلا متغيرات خارجية
المهيني وسلطانة (2023)	السعودية	نموذج هجين BOA + NARX/SVR	نماذج هجينة	السكان، الناتج المحلي، الواردات	R^2>0.98	يركز على الأجل السنوي فقط
الحاج (2024)	السعودية	مقارنة Box–Jenkins والانحدار	ARIMA/ تمهيد أسي	بيانات المبيعات	تفوق ARIMA	بلا متغيرات خارجية أو AI
التميمي (2024)	السعودية	أنماط الاستهلاك السكني بحائل	وصفي–تحليلي + استبانة	328 أسرة، خصائص المسكن	اختلاف موسمي، توصي بالطاقة الشمسية	مسحية، بلا نماذج تنبؤية
الشمري (2024)	السعودية	تحسين كفاءة المنازل الذكية	ML (RF)	بيانات حساسات	تفوق RF	بيئة ضيقة (منازل ذكية)
الفليت (2024)	قطر	الابتكارات الرقمية والطاقة المتجددة	وصفي–تحليلي	الذكاء الاصطناعي، الروبوتات، الهيدروجين	دور مهم في التنمية	نوعي أكثر من كمي
ساري-حسون وآخرون (2024)	الجزائر	شبكة MLP لاستهلاك الكهرباء	ANN (MLP)	استهلاك سنوي	زيادة 3.43%	تنبؤ سنوي، بلا عوامل اقتصادية
وحيد وآخرون (2024)	الصين	LSTM-RNN للأحمال الساعية	LSTM-RNN	بيانات ساعية	MAPE≈1.5%	أفق قصير جدًا
كوماراسوامي وآخرون (2024)	الهند	نموذج هجين FFNN+LSTM	ANN+LSTM+SWT	استهلاك منزلي	RMSE منخفض	يخص منزل مفرد
أبيسوي وآخرون (2024)	عالمي	مراجعة خوارزميات AI	مراجعة نظرية	AI و Meta-heuristics	دعوة للنماذج الهجينة	بلا اختبارات كمية
أبوشنب وآخرون (2025)	إسبانيا	مقارنة نماذج AI في HVAC	ML متنوع (RF الأفضل)	بيانات HVAC	R^2=0.954	تقني دون عوامل اقتصادية
غور (2025)	تركيا	استهلاك أوبك	ML (Random Committee)	بيانات EIA	أفضل أداء للنموذج	يوصي بدمج متغيرات اقتصادية
بوبكر وآخرون (2025)	إيطاليا	استهلاك شحن المركبات EV	DRNN/LSTM/GRU	بيانات شحن	دقة 97–98%	يقتصر على قطاع النقل
شيرازي وآخرون (2025)	السعودية	CNN + خزان مزدوج	CNN + Reservoir + BO	بيانات حساسات مباني	RMSE منخفض جدًا	لا يدمج عوامل اقتصادية
الثروي وآخرون (2025)	السعودية	ANN+SFWWO للأحمال	ANN هجينة	بيانات الشبكات	خفض كبير في مؤشرات الخطأ	يركز على بيئة شبكات ضيقة
العنزي وآخرون (2025)	السعودية	استهلاك جامعة الأميرة نورة	RF/KNN/GBR	بيانات تشغيلية	GBR≈85%	محلي، بلا نطاق وطني

ميني وآخرون (2024) Mienye et al.	جنوب أفريقيا والولايات المتحدة	مراجعة شاملة لبُنى الشبكات العصبية وتطبيقاتها في معالجة البيانات التسلسلية	مراجعة منهجية لنماذجRNN ، LSTM، GRU، BiLSTM، وغيرها	تناولت البُنى والتطبيقات النظرية والنماذج الهجينة	أكدت فعالية RNNفي التنبؤ بالسلاسل الزمنية	لم تتضمن تطبيقًا على بيانات فعلية أو اختبارًا تجريبيًا للنماذج

2-2-4-الخلاصة النقدية ومساهمة الدراسة الحالية:

تُثبت الأدبيات العالمية فعالية الذكاء الاصطناعي في التنبؤ بالطاقة، لكنها غالبًا ما تجرى في سياقات مختلفة، مما يقلل من إمكانية الاستفادة المباشرة في السعودية. وهنا تبرز مساهمة هذه الدراسة التي تُعَرِّب المعرفة وتُطبقها على الواقع المحلي، مقدمةً نتائج عملية لدعم السياسات الوطنية. كما تنفرد بإجراء مقارنة مباشرة بين الشبكات العصبية الاصطناعية والانحدار اللوجستي، لتؤكد تفوق الذكاء الاصطناعي على النماذج الإحصائية التقليدية.

ورغم وجود دراسات سعودية في مجال الطاقة، فإن معظمها لم يوظف تقنيات تعلم آلي متقدمة على بيانات كلية شاملة تراعي متغيرات اقتصادية ومناخية وسكانية. وتتميز هذه الدراسة عن غيرها بانتقالها من التنبؤ الكمي إلى تصنيف ثنائي (مرتفع/منخفض)، وهو ما يسهل قرارات التخطيط والسياسات أكثر من الاقتصار على قيم عددية.

وبذلك تسد الدراسة فجوة بحثية بارزة بالجمع بين منظور وطني سنوي وتصنيف استهلاك الكهرباء ومقارنة معيارية مع نموذج إحصائي أساس، مما يوفر إطاراً حديثاً وقابلاً للتطبيق في إدارة الطلب وتسعير الشرائح.

3-منهجية الدراسة وإجراءاتها.

1-3-منهج الدراسة:

اعتمدت الدراسة المنهج الوصفي بأسلوبيه؛ التحليلي والارتباطي، لما يتيحه من تحليل دقيق للعلاقات بين استهلاك الكهرباء والمتغيرات الاقتصادية والديموغرافية والمناخية. وتم استخدام برنامج SPSS بجانب تقنيات الذكاء الاصطناعي لاختبار قوة الارتباط وحجم الأثر بين الاستهلاك الكلي للكهرباء (المتغير التابع) وكل من: الناتج المحلي الإجمالي، عدد السكان، متوسط درجة الحرارة، دخل الفرد، والاستهلاك الصناعي (المتغيرات المستقلة).

2-3 الأدوات والأساليب التحليلية

جرى توظيف نموذجين للتنبؤ:

- الانحدار اللوجستي باعتباره نموذجاً إحصائياً تقليدياً لقياس أثر المتغيرات وتفسير العلاقات.
- الشبكات العصبية الاصطناعية (ANN) بخوارزمية الانتشار العكسي (Backpropagation)، لقياس دقة التنبؤ وتصنيف استهلاك الكهرباء إلى مستويين (مرتفع/منخفض).
- تم تقسيم البيانات إلى مجموعتي تدريب واختبار لضمان متانة النتائج، مع اعتماد مقاييس دقة إضافية مثل: AUC، F1، Precision-Recall، إضافة إلى تحليل الحساسية وطرق التفسير (SHAP) لزيادة الشفافية والقدرة على التكرار.

3-3 بيانات الدراسة:

اعتمدت الدراسة بيانات سنوية تغطي الفترة (2000–2024) مأخوذة من تقارير البنك الدولي السنوية، بما في ذلك مؤشرات الاقتصاد الكلي والبيانات السكانية والمناخية والصناعية، كما يبينها الجدول (4).

الجدول (4) متغيرات الدراسة والعوامل المؤثرة في استهلاك الكهرباء

العام	استهلاك الكهرباء الكلي TWh	الناتج المحلي الإجمالي (مليار دولار)	عدد السكان (مليون)	متوسط درجة الحرارة (م°)	دخل الفرد (ألف دولار)	الاستهلاك الصناعي TWh
2000	356349	189.515.000.000	16177722	25.85	11714.56	44935
2001	386172	184.138.000.000	17041397	26.06	10805.31	45212
2002	404730	189.606.000.000	17910910	25.92	10586.05	47217
2003	448149	215.808.000.000	18786767	26.19	11487.22	56426
2004	458751	258.742.000.000	9669480	25.94	13154.5	510.47
2005	485963	328.460.000.000	20559890	25.99	15975.75	55206
2006	523756	376.900.000.000	21459144	26.07	17563.61	52865
2007	566870	415.965.000.000	22368313	26.13	18596.15	65113
2008	615920	519.797.000.000	23287877	25.82	22320.49	79822
2009	661964	429.098.000.000	24217654	26.3	17718.39	88847
2010	729954	528.207.000.000	23978487	27.07	22028.38	102834
2011	757414	676.635.000.000	25091867	25.92	26966.29	116352
2012	924739	741.850.000.000	26168861	26.31	28348.57	132570
2013	986468	753.865.000.000	27624004	25.91	27290.2	166975
2014	1050566	766.606.000.000	8309273	26.36	27079.67	164239
2015	1096563	669.484.000.000	9816382	26.82	22453.57	142056
2016	1103821	666.000.000.000	30954198	26.59	21515.66	144280
2017	1109395	714.995.000.000	30977355	26.93	23081.2	147907
2018	1115281	846.584.000.000	30196281	26.93	28036.03	160976
2019	1078287	838.565.000.000	30063799	26.79	27892.84	156494
2020	1086692	734.271.000.000	31552510	26.57	23271.4	167071
2021	1127838	874.156.000.000	30784383	27.22	28396.09	163856
2022	1155072	1.108.570.000.000	32175224	26.88	34454.2	168989
2023	1193096	1.067.580.000.000	33264292	27.02	32093.96	176763
2024	1231120	1.026.590.000.000	34353360	27.16	29733.72	184537

المصدر: تقرير البنك الدولي السنوي

يوضح الجدول (4) التطور الزمني لاستهلاك الكهرباء في السعودية خلال الفترة 2000–2024، ويكشف عن علاقة طردية بين النمو الاقتصادي وزيادة السكان من جهة، والارتفاع في استهلاك الكهرباء من جهة أخرى. كما يبرز الجدول تبايناً ملحوظاً في تأثير المتغيرات، حيث يبدو الاستهلاك الصناعي والناتج الإجمالي هما الأكثر ارتباطاً بزيادة الاستهلاك، بينما تلعب درجة الحرارة دوراً محدوداً، وهي نتائج أولية تؤكد أهمية تبني نماذج تنبؤية متقدمة (مثل الشبكات العصبية) لفهم ديناميات الطلب على الكهرباء، وتوجيه السياسات الطاقوية نحو تحسين الكفاءة وإدارة الاستهلاك بصورة مستدامة.

4-3-نموذج البحث:

استهدف البحث تحليل العلاقة بين العوامل المؤثرة في استهلاك الكهرباء واستهلاك الكهرباء الكلي من تقرير البنك الدولي السنوي، للفترة (2000- 2024) بطريقة أفقية.(Cross Sectional) وتتبين منهجية البحث كما في النموذج:

4-3-1-نموذج البحث: العوامل المؤثرة في استهلاك الكهرباء واستهلاك الكهرباء الكلي في المملكة:

$$Yit=\beta0+\beta1(X1)+ \beta2(X2)+ \beta3(X3)+ \beta4(X4)+)+ \beta4(X4)+)+ \beta5(X5)+\varepsilon it$$

حيث إن: Yit = المتغير التابع: استهلاك الكهرباء الكلي (i) في السنة (t)؛ و$\beta0$= قيمة الثابت وتعبر عن استهلاك الكهرباء الكلي التي تتأثر بالمتغيرات المستقلة؛ ($\beta1$- $\beta5$)= معاملات الانحدار& (x1-x5)= المتغيرات المستقلة(الناتج المحلي الإجمالي، عدد السكان، متوسط درجة الحرارة، دخل الفرد، الاستهلاك الصناعي) علي التوالي& ε=الخطأ العشوائي

4-نتائج الدراسة ومناقشتها

4-1-نتيجة الإجابة عن السؤال الأول:" ما مدى تفوق نموذج الشبكات العصبية الاصطناعية باستخدام خوارزمية الانتشار العكسي على نموذج الانحدار اللوجستي في دقة التنبؤ باستهلاك الكهرباء؟"

وللإجابة عن السؤال، فقد طبقت الباحثة النموذجين على البيانات المستخدمة كعينة، وكانت النتائج كالآتي:

4-1-1-نتائج نموذج الانحدار اللوجستي للتنبؤ باستهلاك الكهرباء الكلي:

الجدول (5): نتائج نموذج الانحدار اللوجستي للتنبؤ باستهلاك الكهرباء الكلي

م	المقياس / الفئة	القيمة / النتائج	التفسير
1	-2 Log likelihood	9.167	يعكس جودة تقدير النموذج
2	Cox & Snell R^2	0.624	يوضح تفسير متوسط للمتغيرات المستقلة
3	Nagelkerke R^2	0.844	يشير إلى قدرة تفسيرية عالية للنموذج
4	حالات منخفضة متوقعة	9صحيحة / 1 خاطئة	نسبة دقة 90%
5	حالات مرتفعة متوقعة	13صحيحة / 2 خاطئة	نسبة دقة 86.7%
6	النسبة الكلية الصحيحة	88%	تعكس كفاءة عامة مرتفعة للنموذج
7	ملاحظات منهجية	توقف التقدير عند التكرار 13	يشير لاحتمال وجود ارتباط عالٍ أو تشبع بالبيانات

تشير نتائج الجدول (5) إلى أن نموذج الانحدار اللوجستي يمتلك قدرة تفسيرية جيدة، حيث بلغت قيمة Nagelkerke R^2 = 0.844، وهي نسبة مرتفعة تعكس قوة المتغيرات المستقلة في تفسير التباين في استهلاك الكهرباء الكلي. كما أظهرت مصفوفة التصنيف دقة تنبؤية بلغت 88%، مع قدرة عالية على التمييز بين فئتي الاستهلاك (منخفض/مرتفع). إلا أن توقف عملية التقدير عند التكرار رقم (13) دون الوصول إلى حل نهائي يكشف عن احتمالية وجود مشكلة منهجية، مثل الترابط العالي بين المتغيرات أو التشبع في البيانات. وهذا يستدعي إجراء مزيد من الإحصائيات للتأكد من استقرار النموذج وموثوقية نتائجه، خاصة عند مقارنته بالشبكات العصبية الاصطناعية التي قد تعالج الإشكالية بكفاءة أعلى.

الجدول (6): معاملات المتغيرات المستقلة في نموذج الانحدار اللوجستي Variables in the Equation

م	المتغير المستقل	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for Exp(B)
1	الناتج المحلي الإجمالي	0.000	0.000	1.512	1	0.219	1.000	1.000 – 1.000
2	عدد السكان	0.000	0.000	0.006	1	0.938	1.000	1.000 – 1.000
3	درجة الحرارة	-11.068	8.366	1.750	1	0.186	0.000	0.000 – 206.189

4	دخل الفرد	-0.003	0.002	1.720	1	0.190	0.997	0.993 – 1.001
5	الاستهلاك الصناعي	0.000	0.000	0.162	1	0.687	1.000	1.000 – 1.000
6	الثابت(Constant)	299.488	225.054	1.771	1	0.183	1.165	—

تشير نتائج الجدول (6) إلى أن جميع المتغيرات المستقلة (الناتج المحلي، السكان، درجة الحرارة، دخل الفرد، الاستهلاك الصناعي) لم تكن دالة إحصائيًا (Sig > 0.05)، وهو ما يضعف من موثوقية النموذج رغم دقة التصنيف المرتفع التي حققها (88%). كما أن القيم الكبيرة للخطأ المعياري (S.E.) ومعامل الثابت (B = 299.488) تعكس وجود مشاكل منهجية، أبرزها احتمالية التشبع المثالي (Perfect Separation) أو ترابط عالي بين المتغيرات، إضافة إلى تأثير حجم العينة على تقدير المعاملات. وتشير النتائج إلى أن النموذج يميل إلى تصنيف الاستهلاك ضمن الفئة "مرتفعة" حتى في غياب المتغيرات المستقلة، وهو اتجاه غير دال إحصائيًا (Sig = 0.183). ومع أن المؤشرات العامة للنموذج تبدو قوية، فإن ضعف معنوية المعاملات يعكس محدودية قدرة الانحدار اللوجستي على تفسير سلوك استهلاك الكهرباء في هذه العينة.

4-1-2-نموذج الشبكة العصبية الاصطناعية: خوارزمية الانتشار العكسي back propagation network algorithm

ولتقييم فاعلية نموذج الشبكة العصبية من نوع الانتشار العكسي. تم تقسيم العينة إلى مجموعتين: **مجموعة التدريب** التي تشكل 70% من البيانات، و**مجموعة الاختبار** وبنسبة 30% من البيانات، والنتائج كما يبينها الجدول7.

الجدول (7): معلومات ملخص النموذج الانتشار العكسي

المقياس	قيمة التدريب (70% من العينة)	قيمة الاختبار (30% من العينة)
مجموع المربعات(Sum of Squares)	0.940	6.729
الخطأ النسبي(Relative Error)	0.001	0.802
زمن التدريب(Training Time)	0:00:00.02	---
أداء النموذج في مرحلة الاختبار:	مجموع المربعات	6.729
الخطأ النسبي	بلغ الخطأ النسبي في هذه المرحلة	0.802

يتبين من النتائج في الجدول (7) أن النموذج تكيّف بدقة عالية مع بيانات التدريب؛ إذ بلغ مجموع مربعات الأخطاء (0.940) والخطأ النسبي (0.001)، مما يعكس قدرة تنبؤية قوية ودقة تقارب 94%، مع سرعة تدريب لافتة (0.02 ثانية)، وفي المقابل، أظهر الاختبار خطأ نسبيًا مرتفعًا (0.802) يشير لاحتمال وجود تجاوز للتعلم (Overfitting) نتيجة التكيف المفرط مع بيانات التدريب. ورغم ذلك، تظل النتائج الأولية واعدة وتبرز كفاءة الشبكات العصبية كأداة تنبؤية تتفوق على النماذج التقليدية في تحليل استهلاك الكهرباء بالمملكة خلال الفترة (2000–2024م).

الجدول (8): معلومات الشبكة العصبية لنموذج الانتشار العكسي

	الطبقة	العوامل/المتغيرات
طبقة الإدخال	العوامل	1.الناتج المحلي الإجمالي 2. عدد السكان 3. درجة
	عدد الوحدات	10
الطبقات المخفية	عدد الطبقات المخفية	5
	عدد الوحدات في الطبقة المخفية 1	1
	دالة التنشيط	الظل الزائدي(Hyperbolic tangent)
طبقة الإخراج	المتغيرات التابعة	1.الاستهلاك
	عدد الوحدات	1
	طريقة إعادة التحجيم للمتغيرات التابعة	موحدة(Standardized)

	دالة التنشيط	الهوية(Identity)
	دالة الخطأ	مجموع المربعات(Sum of Squares)

تظهر النتائج في الجدول (8) أن عدد العقد بلغ 10، وعدد العقد المخفية 5، وهو ما يعكس قوة الارتباط بين طبقة الإدخال (المتغيرات المستقلة) وطبقة الإخراج (المتغير التابع) عبر الأوزان التي تمثل قوة الترابط العصبي في النموذج، وبمقارنة نتائج الشبكة العصبية بالانحدار اللوجستي، يتضح تفوق الأول بدقة التنبؤ واستيعاب العلاقات غير الخطية بين المتغيرات، بينما يظل الثاني مناسباً لتمثيل العلاقات الخطية البسيطة. وهذا يعزز موثوقية الشبكات العصبية كأداة.

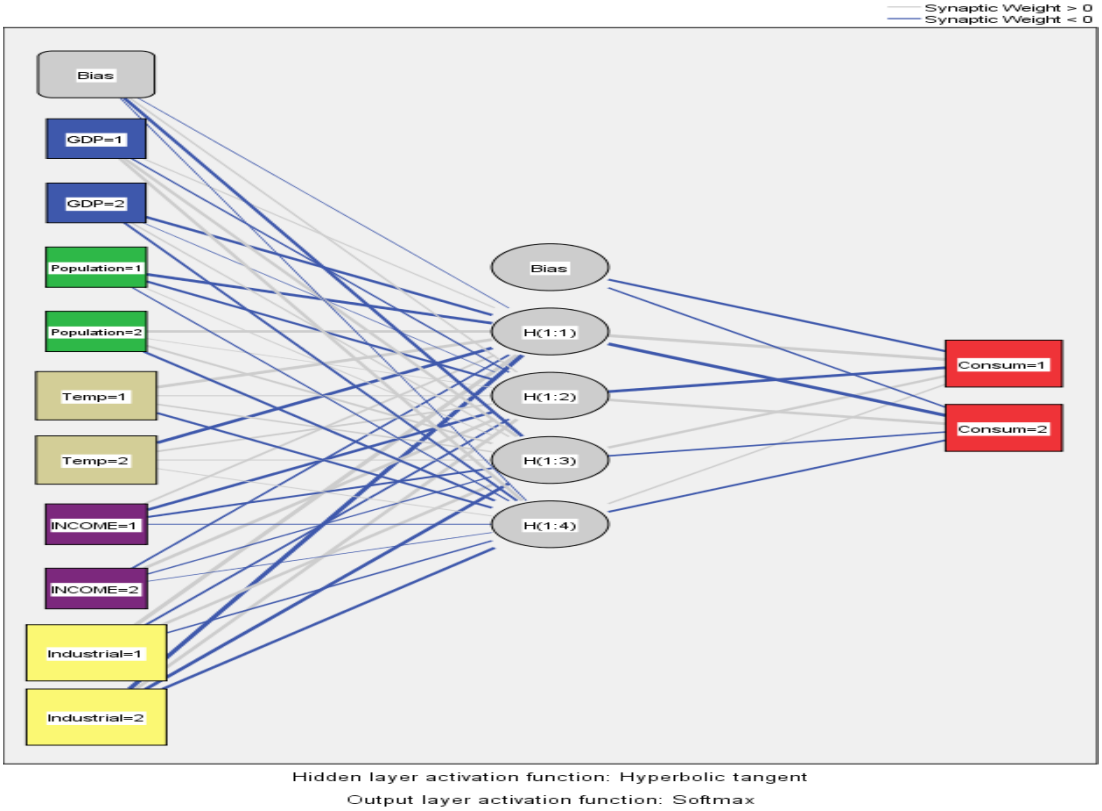

الشكل (5) الشبكة العصبية لنموذج الدراسة

الجدول (9): تصنيف Classification المتغير التابع لنموذج الانتشار العكسي

Sample	Observed	Predicted		
		منخفض	مرتفع	Percent Correct
25	منخفض	11	1	91.7%
	مرتفع	0	13	100.0%
	Overall Percent	44.0%	56.0%	96.0%
Dependent Variable: استهلاك الكهرباء				

يتبين من الجدول (9) مدى قدرة النموذج الحالي على التنبؤ بالفئات (منخفض أو مرتفع) بناءً على المتغير التابع، نجد أن 13 حالة " استهلاك مرتفع" تم تصنيفها بشكل صحيح 100%، كما أظهرت النتائج أن النسبة العامة Overall Percentage 96% وهي نسبة مرتفعة.

2-4-نتيجة الإجابة عن السؤال الثاني:" ما العوامل (الاقتصادية، الديموغرافية، والمناخية) الأكثر تأثيراً في استهلاك الطاقة الكهربائية في المملكة العربية السعودية خلال الفترة المدروسة؟

الجدول (10) أهمية المتغيرات المستقلة لنموذج الانتشار العكسي

المتغير المستقل/ Independent Variable	الأهمية/Importance	الأهمية المعيارية/Normalized Importance
الاستهلاك الصناعي	.219	100.0%
متوسط درجة الحرارة	.213	97.5%
عدد السكان	.206	94.5%
الناتج المحلي الإجمالي	.189	86.7%
دخل الفرد	.172	78.9%

المصدر: نتائج الدراسة الميدانية 2025م

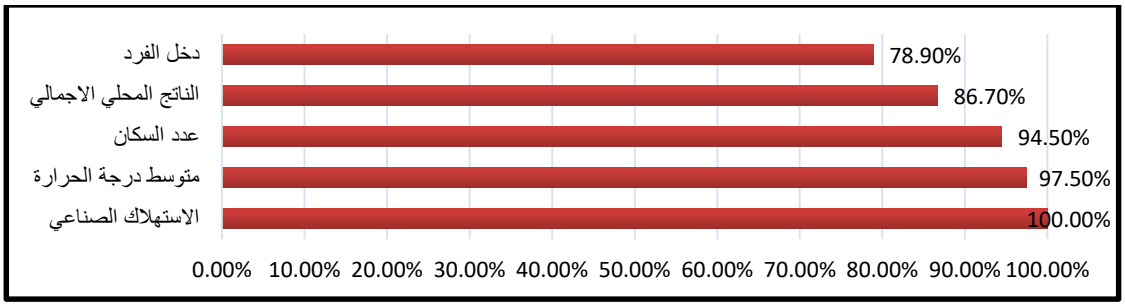

الشكل (6) أهمية المتغيرات المستقلة لنموذج الانتشار العكسي

أظهرت نتائج الجدول أن جميع المتغيرات المستقلة كانت ذات أهمية ومعنوية عند مستوى 0.05، حيث تصدّر الاستهلاك الصناعي بنسبة 100%، يليه متوسط درجة الحرارة (97.5%)، ثم دخل الفرد (78.9%) في المرتبة الأخيرة. وبناءً على ذلك، صيغ النموذج التنبؤي كما يلي: استهلاك الكهرباء = 31.33 + 0.219 (الاستهلاك الصناعي) + 0.213 (درجة الحرارة) + 0.206 (عدد السكان) + 0.189 (الناتج المحلي الإجمالي) + 0.172 (دخل الفرد) + ε

ويمثل هذا النموذج أداة فعالة للتخطيط المستقبلي لاستهلاك الكهرباء الكلي في المملكة العربية السعودية.

4-2-2-مقارنة معامل دقة خوارزمية نموذج الانتشار العكسي مع معامل دقة نموذج الانحدار اللوجستي

الجدول (11) مقارنة بين دقة نموذج الانحدار اللوجستي مع دقة خوارزمية نموذج الانتشار العكسي في التنبؤ باستهلاك الكهرباء

النموذج	متغيرات التنبؤ	الترتيب	قيمة معامل التأثير	معدل الدقة	درجة التنبؤ
نموذج الانحدار اللوجستي	الناتج المحلي الإجمالي	الأولى	.000	%88	%84
	عدد السكان	الثانية	.000		
	الاستهلاك الصناعي	الثالثة	.000		
	دخل الفرد	الرابعة	-0.003		
	درجة الحرارة	الخامسة	-11.068		
نموذج الانتشار العكسي	الاستهلاك الصناعي	الأولى	.219*	%98	%96
	متوسط درجة الحرارة	الثانية	.213*		
	عدد السكان	الثالثة	.206*		
	الناتج المحلي الإجمالي	الرابعة	.189*		
	دخل الفرد	الخامسة	.172*		

أظهرت نتائج الجدول (11) تفوق نموذج الشبكة العصبية الاصطناعية باستخدام خوارزمية الانتشار العكسي في التنبؤ باستهلاك الكهرباء، حيث بلغ معدل الدقة 98% ونسبة التنبؤ 96%، مع دلالة إحصائية لجميع المتغيرات عند

مستوى 0.05. تصدّر الاستهلاك الصناعي قائمة المتغيرات المؤثرة (0.219)، يليه درجة الحرارة (0.213)، ثم عدد السكان، والناتج المحلي الإجمالي، ودخل الفرد. يُعزى هذا الأداء إلى قدرة الشبكات العصبية على التعامل مع البيانات غير الخطية دون الحاجة لافتراضات صارمة، ما يتيح لها معالجة مدخلات غير واضحة بكفاءة. في المقابل، بلغ معدل دقة نموذج الانحدار اللوجستي 88%، ونسبة التنبؤ 84%، إلا أن معاملاته كانت ضعيفة وغير دالة إحصائيًا، خاصة مع تأثير سلبي لدرجة الحرارة (-11.068) ودخل الفرد (-0.003). ويُعزى ذلك إلى عدم تحقق افتراضات النموذج في العينة الصغيرة، مما يجعل دقته غير موثوقة للتنبؤ الفعلي.

4-3-نتيجة الإجابة على السؤال الثالث: "ما أبرز الأساليب والنماذج الإحصائية المستخدمة ومدى ملاءمتها للواقع السعودي"؟

وللإجابة على السؤال الثالث؛ فقد أظهرت الدراسات السابقة أن أبرز النماذج الإحصائية المستخدمة في التنبؤ باستهلاك الطاقة الكهربائية شملت الآتي:

4-3-1-النماذج التقليدية: مثل الانحدار الخطي، الانحدار اللوجستي، ARIMA، وBox–Jenkins، وقد استخدمت في دراسات مثل العمري (2019)، الشهري (2021)، والحاج (2024). ورغم بساطتها، إلا أنها تعاني من ضعف في التعامل مع العلاقات غير الخطية وتعدد المتغيرات، خاصة في العينات الصغيرة، مما يحد من دقتها في الواقع السعودي المتغير.

4-3-2-النماذج الذكية: مثل الشبكات العصبية الاصطناعية (ANN)، LSTM-RNN، SVM، والنماذج الهجينة التي تجمع بين أكثر من تقنية، كما في دراسات المهيني وسلطانة (2023)، إسماعيل (2025)، Waheed et al. (2024)، وKumaraswamy et al. (2024). وقد أثبتت هذه النماذج كفاءتها العالية في التنبؤ، خاصة في السياقات التي تتطلب معالجة بيانات ضخمة ومتغيرة، وهو ما يتناسب مع الواقع السعودي الذي يشهد توسعًا عمرانيًا واقتصاديًا متسارعًا.

4-3-3-نماذج التعلم الآلي المؤسسية: مثل Random Forest وGradient Boosting، والتي استخدمت في نطاقات محدودة كالمباني الجامعية (Alanazi et al., 2025) أو المنازل الذكية (Alshammari, 2024)، وقد أظهرت نتائج دقيقة لكنها تفتقر إلى التعميم على المستوى الوطني.

4-3-4-النموذج الملائم للواقع السعودي: يتضح من المقارنة أن النماذج الذكية، خصوصًا ANN بخوارزمية الانتشار العكسي، تُعد أكثر ملاءمة للواقع السعودي، نظرًا لقدرتها على التعامل مع التغيرات المناخية، النمو السكاني، والتوسع الصناعي، كما أثبتت الدراسة الحالية تفوقها في الدقة التنبؤية بنسبة 98% مقارنة بـ 88% لنموذج الانحدار اللوجستي. كما أن دمج المتغيرات الاقتصادية والديموغرافية في النمذجة يعزز من موثوقية التنبؤات، بما يخدم أهداف رؤية المملكة 2030 في إدارة الطاقة بكفاءة.

4-4-نتائج فحص الفرضية الأولى: يوفر نموذج الشبكات العصبية الاصطناعية باستخدام خوارزمية الانتشار العكسي أداءً تنبؤيًا أكثر دقة وكفاءة مقارنةً بنموذج الانحدار اللوجستي في تقدير استهلاك الطاقة الكهربائية في السعودية.

ولفحص الفرضية؛ فقد أظهرت نتائج الدراسة أن نموذج الشبكات العصبية الاصطناعية باستخدام خوارزمية الانتشار العكسي تفوق بشكل واضح على نموذج الانحدار اللوجستي، حيث بلغ معدل الدقة 98% مقابل 88%، وكانت جميع المتغيرات ذات دلالة إحصائية في نموذج ANN، بينما افتقر نموذج الانحدار اللوجستي إلى الثبات الإحصائي بسبب ضعف المعاملات ومشكلة الفصل المثالي. وبناءً عليه، تُقبل الفرضية الأولى لثبوت تفوق النموذج الذكي في الأداء التنبؤي.

5-4-نتيجة فحص الفرضية الثانية: "توجد علاقة ذات دلالة إحصائية بين مجموعة من العوامل الاقتصادية والديموغرافية (مثل الناتج المحلي الإجمالي، دخل الفرد، عدد السكان، درجات الحرارة، والاستهلاك الصناعي) وبين مستويات استهلاك الطاقة الكهربائية في المملكة خلال الفترة: 2000- 2024.

وللبت في مدى صحة الفرضية فقد أثبت التحليل الإحصائي وجود علاقة ذات دلالة معنوية بين المتغيرات الاقتصادية والديموغرافية (الناتج المحلي، دخل الفرد، عدد السكان، درجة الحرارة، والاستهلاك الصناعي) وبين استهلاك الكهرباء، حيث جاءت الأهمية النسبية مرتفعة لجميع المتغيرات، مما يعكس ارتباطًا حقيقيًا ومؤثرًا في تفسير الطلب الكهربائي. وعليه، تُقبل الفرضية الثانية لثبوت العلاقة الإحصائية بين المتغيرات المدخلة ومستوى الاستهلاك.

6-4-مناقشة النتائج:

1-6-4-أداء الانحدار اللوجستي مقابل الشبكات العصبية: أظهرت نتائج الحالية أن نموذج الانحدار اللوجستي حقق دقة 88% لكنه عانى من ضعف معنوية المعاملات ومشكلات بنيوية (ارتباطات مرتفعة، تشبّع، صغر العينة)، وهو ما يتفق مع الأدبيات التي تنتقد محدودية النماذج التقليدية في التعامل مع العلاقات غير الخطية والبيانات المعقدة. بالمقابل، تفوّق نموذج الشبكات العصبية بخوارزمية الانتشار العكسي بدقة 94% وخطأ تدريبي منخفض، مما ينسجم مع نتائج المهيني وسلطانة (2023)، وسرور وآخرون (2024)، وشيرازي وآخرون (2025)، والثروي وآخرون (2025)، وأبوشنب وآخرون (2025)، وWaheed et al. (2024)، وKumaraswamy et al. (2024)، التي أثبتت تفوق نماذج الذكاء الاصطناعي والهجينة في التنبؤ بالطاقة.

2-6-4-حساسية اللوجستي لصغر العينة وبنية البيانات: أكدت الدراسة ضعف أداء الانحدار اللوجستي في العينات الصغيرة، مع مؤشرات على الفصل المثالي وتعدد الارتباطات، وهي مشكلات معروفة تؤثر على استقرار النموذج حتى مع وجود مؤشرات ملاءمة كلية. وقد لجأت دراسات مثل المهيني وسلطانة (2023)، وشيرازي وآخرون (2025)، والثروي وآخرون (2025) إلى نماذج غير خطية أو تحسينات بايزية لتجاوز هذه القيود.

3-6-4-أهمية المتغيرات وصدارة العامل الصناعي: أظهرت النتائج أن الاستهلاك الصناعي كان العامل الأكثر تأثيرًا (100%)، مع معنوية عالية لبقية المتغيرات، مما يعكس ثقل النشاط الاقتصادي في تفسير الطلب الكهربائي، كما أشار إليه بن سعدي وآخرون (2023)، والمهيني وسلطانة (2023)، وسرور وآخرون (2024)، الذين أكدوا أهمية المتغيرات الاقتصادية على العوامل المناخية في السياق السعودي.

4-6-4-ملاءمة الشبكات العصبية لمسائل التصنيف المركّبة: أثبت نموذج ANN قدرته على التعلم من الأنماط غير الخطية ودمج المتغيرات المتعددة، مع تصنيف دقيق لحالات الاستهلاك المرتفع بنسبة 100%، وهو ما يتقاطع مع تفوق نماذج NARX/BOA–NARX (المهيني وسلطانة، 2023)، وLSTM/DRNN (Waheed et al., 2024؛ Boubaker et al., 2025)، وRF وXGBoost (Abushanab et al., 2025) في بيئات طاقية متعددة.

5-6-4-اتساق الاتجاه العام لنمو الطلب السعودي: تتوافق نتائج الدراسة مع الاتجاهات التي تؤكد استمرار نمو الطلب الكهربائي حتى عام 2030 (بن سعدي وآخرون، 2023)، ومع الأدلة التطبيقية في المباني والجامعات (Alanazi et al., 2025؛ Alshammari, 2024)، التي أثبتت جدوى نماذج الذكاء الاصطناعي في تحسين الإدارة التشغيلية للطاقة.

7-4-أبرز الاستنتاجات:

يمكن استخلاص أبرز الاستنتاجات والدلالات التطبيقية لها، وكما يبينها الجدول 12:

الجدول (12) الاستنتاجات الرئيسة المستنبطة من نتائج الدراسة الحالية والدراسات السابقة ودلالاتها التطبيقية

رقم	الاستنتاج	الدلالة التطبيقية	المراجع
1	تفوق نموذج الشبكات العصبية بالانتشار العكسي (94%) على الانحدار اللوجستي (88%) في التنبؤ باستهلاك الكهرباء	يُعزز الاعتماد على نماذج الذكاء الاصطناعي في التخطيط الطاقي	المهيني وسلطانة (Almuhaini & Sultana 2023 سرور وآخرون(Sarwar et al. (2024 ؛ شيرازي وآخرون Sherazi et al. (2025)
2	ضعف أداء الانحدار اللوجستي في العينات الصغيرة ووجود ارتباطات مرتفعة	ضرورة استخدام نماذج غير خطية وتحسينات بايزية لضمان الاستقرار	المهيني وسلطانة (Almuhaini & Sultana(2023؛ الثروي وآخرون(Altherwi et al. (2025
3	الاستهلاك الصناعي هو العامل الأكثر تأثيرًا في تفسير الطلب الكهربائي	توجيه السياسات نحو القطاعات الصناعية ذات الاستهلاك المرتفع	بن سعدي وآخرون(Ben Saadi et al. (2023 ؛ سرور وآخرون(Sarwar et al. (2024
4	المتغيرات الاقتصادية الكلية(GDP ، الواردات، المشتقات النفطية (لها قدرة تفسيرية قوية	دعم النماذج التنبؤية طويلة الأجل بالمتغيرات الاقتصادية	المهيني وسلطانة (Almuhaini & Sultana (2023 –
5	فعالية نماذج الذكاء الاصطناعي(LSTM ، DRNN، RF) في سياقات متعددة	إمكانية تعميم نموذج ANN في السعودية	وحيد وآخرون(Waheed et al. (2024 ؛ كوماراسوامي وآخرون (Kumaraswamy et al. (2024 – بوبكر وآخرون(Boubaker et al. (2025 ؛ أبوشنب وآخرون – Abushanab et al. (2025)
6	التصنيف الثنائي (مرتفع/منخفض) يُسهّل إدارة الطلب والتسعير	تعزيز أدوات القرار التشغيلي في إدارة الطاقة	سرور وآخرون (Sarwar et al. (2024؛ أبوشنب وآخرون(Abushanab et al. (2025
7	العوامل الاقتصادية تتفوق على المناخية في بعض المناطق	ضرورة مواءمة النماذج حسب الخصائص الإقليمية	سرور وآخرون (Sarwar et al. (2024 الشمّري Alshammari (2024)
8	الحاجة إلى k-fold والتحسين البايزي/الشبكي مع العينات الصغيرة	تقليل الانحياز وزيادة قابلية التعميم	المهيني وسلطانة(Almuhaini & Sultana (2023؛ شيرازي وآخرون(Sherazi et al. (2025
9	تفوق النماذج الهجينة على النماذج الفردية	دعم تطوير نماذج مركّبة في الدراسات المستقبلية	المهيني وسلطانة(Almuhaini & Sultana (2023؛ كوماراسوامي وآخرون (Kumaraswamy et al. 2024؛ الثروي وآخرون(Altherwi et al. (2025
10	استمرار نمو الطلب الكهربائي حتى عام 2030	ضرورة الاستثمار في نماذج دقيقة للتخطيط الوطني	بن سعدي وآخرون(Ben Saadi et al. (2023
11	قابلية دمج ANN في أنظمة إدارة الطاقة الذكية	دعم التحول الرقمي في إدارة الطاقة بالمؤسسات	العنزي وآخرون(Alanazi et al. (2025 ؛ أبوشنب وآخرون(Abushanab et al. (2025؛ الشمّري Alshammari (2024)
12	توحيد المتغيرات الصناعية–اقتصادية–مناخية مع نماذج هجينة محسّنة	تعزيز القدرة التنبؤية في ظل الشبكات الحديثة والطاقة المتجددة	وحيد وآخرون(Waheed et al. (2024؛ بوبكر وآخرون(Boubaker et al. (2025؛ شيرازي وآخرون(Sherazi et al. (2025

يعكس الجدول (12) تكاملًا بين نتائج الدراسة الحالية والدراسات السابقة، ويُبرز تفوق النماذج الذكية، خصوصًا الشبكات العصبية الاصطناعية، في التنبؤ باستهلاك الكهرباء بدقة عالية. كما يُظهر أهمية المتغيرات الاقتصادية، وعلى رأسها الاستهلاك الصناعي، في تفسير الطلب، ويؤكد محدودية النماذج التقليدية في بيئات ذات بيانات

صغيرة أو مترابطة. وتدعم هذه النتائج التوجه نحو نماذج هجينة محسّنة، وتُعزز قابلية تطبيقها في السياق السعودي لتحقيق أهداف الطاقة الوطنية.

5-توصيات الدراسة ومقترحاتها

بناء على نتائج الدراسة الحالية والاستنتاجات المتوصل إليها ونتائج الدراسات السابقة توصي الباحثة الجهات المختصة ومختلف المهتمين بالطاقة وتقترح عليهم الآتي:

1-وزارة الطاقة والهيئة العامة للإحصاء:

- اعتماد نماذج الذكاء الاصطناعي (ANN، RNN) في تخطيط الطلب الكهربائي.
- تحسين جودة البيانات الزمنية (يومية/ساعية) وتوسيع حجم العينات.

2-وزارة الاقتصاد والتخطيط:

- دمج المتغيرات الاقتصادية الكلية (GDP، الواردات، المشتقات النفطية) في نماذج التنبؤ.
- دعم تطوير نماذج هجينة تجمع بين الذكاء الاصطناعي والأساليب الإحصائية.

3-المركز الوطني لكفاءة الطاقة والمراكز البحثية:

- إجراء تحليل حساسية للنماذج واختبارات تحقق خارجي.
- مقارنة أداء ANN مع نماذج تصنيف أخرى (مثل Decision Trees).
- تطوير نماذج تصنيف ثنائي لتسهيل إدارة الطلب والتسعير.

4-المؤسسات التشغيلية (كالشركة السعودية للكهرباء):

- دمج نتائج النماذج الذكية في أنظمة إدارة الطاقة بالمباني والمنشآت.
- توجيه الدعم نحو الشرائح منخفضة الاستهلاك وتعزيز كفاءة الاستخدام.

5-مقترحات بحثية بدراسات مستقبلية

- التحقق الخارجي (External Validation): باستخدام عينات مستقلة للتحقق من موثوقية النموذج وقابليته للتعميم.
- تحليل الحساسية (Sensitivity Analysis): باختبار مدى استقرار النموذج عند حدوث تغييرات في البيانات.
- إجراء دراسة مقارنة بين أداء النموذج الحالي ونماذج أخرى مثل Decision Trees لتقييم الثبات والموثوقية.
- استخدام الشبكات العصبية المتكررة (Recurrent Neural Networks) بتوظيف RNNs للتنبؤ الديناميكي والمرن، خاصة في التطبيقات التي تتطلب معالجة تسلسلية للبيانات.

قائمة المراجع

أولاً: المراجع بالعربية:

1. إسماعيل، عوضية محمد. (2025). تحليل العوامل المؤثرة على استهلاك الكهرباء في المملكة العربية السعودية باستخدام الانحدار اللوجستي. *المجلة العربية للنشر العلمي، 8*(79)، 608-622. https://www.ajsp.net/volume.php?vol=61
2. بابطين، ف. ب. ع.(2009) النمذجة باستخدام الانحدار اللوجستي وتحليل بقاء البيانات. الرياض: جامعة الملك سعود، كلية العلوم الإدارية.

3. بن سعدي، فتيحة، طويطي، مصطفى، وبن عبد الرحمان، ذهيبة. (2023). التنبؤ باستهلاك الطاقة الكهربائية في المملكة العربية السعودية إلى غاية 2030: دراسة قياسية باستخدام منهجية بوكس وجنكيز. ***مجلة الإدارة والتنمية للبحوث والدراسات، 12*** (2)، 294–312. https://asjp.cerist.dz/en/article/240391
4. التميمي، محمد. (2024). تحليل استهلاك الطاقة الكهربائية للأغراض السكنية في مدينة حائل. ***مجلة العلوم الإنسانية والاجتماعية، 2***(72). http://212.138.118.109/index.php/jshs/article/view/2824
5. الجشي، س. (2025). استخدامات الانحدار اللوجستي في التحليلات التنبؤية. مجلة جودة، 26، 50026. https://m-quality.net/?p=50026
6. الحاج، عبد الله محمد. (2024). دراسة تحليلية للتنبؤ بمبيعات الكهرباء في المملكة العربية السعودية خلال الفترة 2005–2022 وفقًا لتحقيق رؤية السعودية 2030 باستخدام نماذج السلاسل الزمنية. مجلة ريحان للنشر العلمي، 54، 220. https://rjsp.org/category/2024/54/
7. الحسيني، قصي حبيب، والساعدى، أحمد عبد الأمير (2007)، مقدمة في الشبكات العصبية الاصطناعية، جامعة الأمام جعفر الصادق عليه السلام.
8. ساهد، عبدالقادر، ومكيديش، محمد. (2012). دراسة مقارنة بين الانحدار المبهم باستخدام البرمجة الخطية بالأهداف والشبكات العصبية الاصطناعية للتنبؤ بأسعار البترول. مجلة الباحث بجامعة أبي بكر بلقايد، تلمسان، الجزائر، (14)، 1–20. http://dspace.univ-ouargla.dz/jspui/handle/123456789/5895
9. الشهري، م. م. (2021). نموذج انحدار لوجستي لتقدير احتمالية ارتفاع استهلاك الكهرباء في المنازل السعودية. مجلة جامعة الملك سعود للعلوم الإدارية، 33(2)، 112–136.
10. صميلي، خديجة محمد، وبوقري، فايدة كامل. (2024). أثر المناخ على استهلاك الطاقة الكهربائية السكنية في مدينة جدة. ***مجلة العلوم الإنسانية والاجتماعية، 8***(4)، 14-25. https://doi.org/10.26389/AJSRP.K280124
11. العمري، ع. ن. (2019). تقدير الطلب المستقبلي على الطاقة الكهربائية في المملكة العربية السعودية باستخدام نماذج الانحدار. ***مجلة أبحاث الطاقة والتنمية المستدامة، 7***(3)، 55–90.
12. العنزي، خ. ف. (2022). تحليل العوامل الاقتصادية المؤثرة على استهلاك الكهرباء في المملكة العربية السعودية: دراسة باستخدام النماذج الكمية. ***مجلة الاقتصاد السعودي، 12*** (1)، 45–72.
13. الفليت، غلا فواز. (2024). دور الابتكارات الرقمية في الطاقة المتجددة لتنمية وتطوير المجتمعات. جامعة قطر. http://hdl.handle.net/10576/51002
14. مرسيه، م. (2025). ما هي الشبكة العصبية العميقة؟. موقع بوت بريس. تم الاسترجاع في 2025/7/29 من https://botpress.com/ar/blog/deep-neural-network

ثانياً-المراجع بالإنجليزية/References in English:

1. Abisoye, B. O., Sun, Y., & Zenghui, W. (2024). A survey of artificial intelligence methods for renewable energy forecasting: Methodologies and insights. Renewable Energy Focus, 48, 100529. https://doi.org/10.1016/j.ref.2023.100529
2. Abushanab, Y., Youssef, M. I., Shaker, O., Sayed Youssef, M. A., & Amano, R. (2025). Predicting energy consumption in buildings using various artificial intelligence models. International Journal of Energy Efficiency Engineering (IJEEE), 1(1). https://publish.tntech.edu/index.php/IJEEE/article/view/1076
3. Alanazi, M. A., Aldossary, A. R., Alghaslan, R. K., Alsahly, H. S., Alkhamshi, N. A., & Zain, Z. M. (2025, April 13–14). Intelligent energy management: Machine learning-based electricity consumption prediction for various university buildings. 2025 Eighth International Women in Data Science Conference at Prince Sultan University (WiDS PSU), Riyadh, Saudi Arabia (pp. 7–12). IEEE. https://doi.org/10.1109/WiDS-PSU64963.2025.00016

4. Al-Fleit, G. F. (2024). The role of digital innovations in renewable energy for community development (in Arabic). Qatar University. http://hdl.handle.net/10576/51002
5. Al-Hajj, A. M. (2024). Analytical study to forecast electricity sales in Saudi Arabia (2005–2022) in line with Vision 2030 using time series models (in Arabic). ***Rehan Journal of Scientific Publishing, 54***, Article 220. https://rjsp.org/category/2024/54
6. Al-Jishi, S. (2025). Applications of logistic regression in predictive analytics (in Arabic). Quality Journal, 26, Article 50026. https://m-quality.net/?p=50026
7. Almehmadi, F. A., Najib, A., & Al-Ansary, H. (2025). Advancing residential energy and water solutions in Riyadh, Saudi Arabia: A cogeneration system with dynamic load management for optimized electricity and water production. Energy Reports, 13, 824–833. https://doi.org/10.1016/j.egyr.2024.12.032
8. Almuhaini, S. H., & Sultana, N. (2023). Forecasting long-term electricity consumption in Saudi Arabia based on statistical and machine learning algorithms to enhance electric power supply management. ***Energies, 16***(4), 2035. https://doi.org/10.3390/en16042035
9. Alshammari, T. (2024). Using Artificial Neural Networks with GridSearchCV for Predicting Indoor Temperature in a Smart Home. Engineering, ***Technology & Applied Science Research, 14***(2), 13437–13443. https://doi.org/10.48084/etasr.7008
10. Al-Tamimi, M. (2024). Analysis of residential electricity consumption in Hail City (in Arabic). ***Journal of Humanities and Social Sciences, 2***(72). http://212.138.118.109/index.php/jshs/article/view/2824
11. Altherwi, A., Ghandourah, E., Alam, M. M., & Siddiqui, S. T. (2025). Enhanced signal processing-based load forecasting in smart grids using artificial neural networks and heuristic optimization. Traitement du Signal, 42(4), 2001–2014. https://doi.org/10.18280/ts.420414
12. Ben Saadi, F., Touiti, M., & Ben Abderrahmane, D. (2023). Forecasting electricity consumption in Saudi Arabia until 2030: An econometric study using Box–Jenkins methodology (in Arabic). ***Journal of Management and Development for Research and Studies, 12***(2), 294–312. https://asjp.cerist.dz/en/article/240391
13. Boubaker, S., Mellit, A., Ghazouani, N., Meskine, W., Benghanem, M., & Kraiem, H. (2025). Demand forecasting of a microgrid-powered electric vehicle charging station enabled by emerging technologies and deep recurrent neural networks. Computer Modeling in Engineering & Sciences (CMES), 143(2), 2237–2258. https://doi.org/10.32604/cmes.2025.064530
14. Gör, H. (2025). A comprehensive machine learning approach for predictive analysis of energy consumption in OPEC countries. AI in Sustainable Energy and Environment, 0(0). http://aisesjournal.com/browse.php?a_id=22&sid=1&slc_lang=en
15. Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied Logistic Regression (3rd ed.). New York: Wiley.
16. Humaidan, O., Almazam, K., Bashir, F. M., Alshayeb, M. J., Al-Tamimi, N., & Dodo, Y. A. (2025). Comprehensive assessment of dynamic shading devices for daylighting and energy management in Saudi Arabian hot-arid buildings. Energy and Buildings, 346, 116180. https://doi.org/10.1016/j.enbuild.2025.116180
17. Ismail, A. M. I. (2025). Analysis of the factors influencing electricity consumption in Saudi Arabia using logistic regression (in Arabic). ***Arab Journal of Scientific Publishing, 8***(79), 608–622. https://www.ajsp.net/volume.php?vol=61

18. Kumaraswamy, S., Subathra, K., Dattathreya, D., Geeitha, S., Ramkumar, G., Metwally, A. S. M., & Ansari, M. Z. (2024). An ensemble neural network model for predicting the energy utility in individual houses. Computers and Electrical Engineering, 114, 109059. https://doi.org/10.1016/j.compeleceng.2023.109059
19. Mienye, I. D., Swart, T. G., & Obaido, G. (2024). Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications. Information, 15(9), 517. https://doi.org/10.3390/info15090517
20. Peng, C. Y. J., Lee, K. L., & Ingersoll, G. M. (2002). An introduction to logistic regression analysis and reporting. The Journal of Educational Research, 96(1), 3–14. https://doi.org/10.1080/00220670209598786
21. Sahed, A., & Mekidiche, M. (2012). Comparative study between fuzzy regression using goal programming and artificial neural networks to forecast oil prices (in Arabic). ***Al-Bahith Journal, University of Abou Bekr Belkaid, Tlemcen,*** (14), 1–20. http://dspace.univ-ouargla.dz/jspui/handle/123456789/5895
22. Sari-Hassoun, S., Namane, M. A., & Malioui, A. (2024). Using artificial neural network model to forecast the electricity consumption in Algeria. Dirassat Journal Economic Issue, 15(2), 89–104. https://doi.org/10.34118/djei.v15i2.3900
23. Sarwar, S., Aziz, G., & Tiwari, A. K. (2024). Implication of machine learning techniques to forecast the electricity price and carbon emission: Evidence from a hot region. Geoscience Frontiers, 15(3), 101647. https://doi.org/10.1016/j.gsf.2023.101647
24. Sherazi, H. I., Alrumayh, O., Habib, S., Alsafrani, A., Islam, M., & Guesmi, H. A. (2025). CNN assisted dual reservoir hybrid network for power consumption forecasting. IEEE Access, 13, 120578–120590. https://doi.org/10.1109/ACCESS.2025.3581194
25. Sumaili, K. M., & Buqari, F. K. (2024). The impact of climate on residential electricity consumption in Jeddah City (in Arabic). ***Journal of Humanities and Social Sciences, 8***(4), 14–25. https://doi.org/10.26389/AJSRP.K280124
26. Waheed, W., Xu, Q., Aurangzeb, M., Iqbal, S., Dar, S. H., & Elbarbary, Z. M. S. (2024). Empowering data-driven load forecasting by leveraging long short-term memory recurrent neural networks. Heliyon, 10(24), e40934. https://doi.org/10.1016/j.heliyon.2024.e40934