

التنبؤ بالإستهلاك المنزلي للطاقة الكهربائية باستخدام تقنيات التنقيب في البيانات
-الشبكات العصبية العميقة LSTM-

**Predicting household electricity consumption using data mining techniques
-Deep neural networks LSTM-**

بن سعدي فتيحة¹

Bensaadi Fatiha¹

¹ جامعة غرداية، bensaadi.fatiha@univ-ghardaia.edu.dz

تاريخ النشر: 2025/12/31

تاريخ القبول: 2025/12/26

تاريخ الاستلام: 2025/10/09

ملخص:

عالجت الدراسة موضوع التنبؤ باستهلاك الطاقة الكهربائية عن طريق الشبكات العصبية العميقة التي تعد من أهم الطرق الفعالة في مجال التنقيب في البيانات كونها تعالج بيانات ضخمة ذات تسلسل زمني، حيث تم تسليط الدراسة على بيانات إستهلاك الطاقة الكهربائية لسكان ولاية غرداية والتعرف على أهم التعريفات الكهربائية التي تسمح بترشيد الاستهلاك وتقليل تكلفة الفاتورة الكهربائية؛

توصلت الدراسة إلى أن الشبكات العصبية العميقة لها دور فعال في إعطاء صورة مستقبلية للوضع الاستهلاكي للكهرباء من 2023Q4 إلى غاية 2025Q4، حيث يعطي معامل القوة التفسيرية R^2 نسبة 75% ومعامل متوسط مربع الأخطاء MSE نسبة 25%، أي أن الاختلاف بين القيم الفعلية والقيم المتوقعة قليل ما يعطي دقة أعلى.

كلمات مفتاحية: الشبكات العصبية الاصطناعية؛ إستهلاك الطاقة الكهربائية؛ التنقيب في البيانات؛ التنبؤ.

تصنيفات JEL: C45، C47، C53.

Abstract:

The study addressed the topic of predicting electricity consumption using deep neural networks, which are one of the most effective methods in the field of data mining, as they process huge data with a time sequence. The study focused on the electricity consumption data of the residents of Ghardaïa State and identified the most important electricity tariffs that allow for rationalizing consumption and reducing the cost of the electricity bill.

The study concluded that deep neural networks play an effective role in providing a future picture of electricity consumption from 2023Q4 to 2025Q4, with an explanatory power coefficient R^2 of 75% and a mean square error (MSE) of 25%. This means that the difference between actual and predicted values is small, resulting in higher accuracy.

Keywords: Artificial neural networks; Electrical energy consumption; Data mining; prediction.

JEL Classification Codes: C45, Q47, C53.

المؤلف المرسل: بن سعدي فتيحة، الإيميل: bensaadi.fatiha@univ-ghardaia.edu.dz

1. مقدمة:

يعد التنبؤ من أهم الطرق القيمة التي لا غنى عنها في مجال البحوث والدراسات، كونها تعد أداة مهمة لوضع الإستراتيجيات والخطط المحكمة في مختلف المجالات التي تتطلب التنبؤ بما يحدث مستقبلاً، حيث يشهد هذا الأخير تنوعاً كبيراً من ناحية الطرق والبرامج المستخدمة مثل الذكاء الاصطناعي، والتعلم العميق، التنقيب في البيانات وغيرها، فلم تقتصر هاته الطرق على معالجة البيانات الرقمية فقط، بل توسع استخدامها لتشمل النصوص والصور ومقاطع الفيديو وغيرها من البيانات التي لا يمكن معالجتها بالطرق التحليلية والقياسية، ليس هذا فحسب بل تستوعب كميات كبيرة من البيانات لمعالجتها في وقت وجيز وفي مختلف الميادين خاصة في مجال الطاقة الكهربائية الذي يشهد تزايد كبير في جميع القطاعات من بينها القطاع العائلي الذي يعد أكثر القطاعات طلباً على الكهرباء.

في هذه الورقة البحثية سوف يتم الاعتماد على أحد تقنيات التنقيب في البيانات للتنبؤ باستهلاك الطاقة الكهربائية لسكان ولاية غرداية، والتعرف على مختلف تقنيات التنقيب في البيانات والشبكات العصبية ذات ذاكرة طويلة قصيرة المدى بالإضافة إلى نظم التعريفات الكهربائية المخصصة للسكان من قبل مؤسسة توزيع الكهرباء والغاز.

إشكالية الدراسة: إنطلاقاً مما سبق نطرح الإشكالية التالية:

ما مدى قدرة الشبكات العصبية العميقة ذات ذاكرة طويلة قصيرة المدى في عملية التنبؤ باستهلاك الطاقة الكهربائية لسكان ولاية غرداية؟

- هل تعد الشبكات العصبية LSTM أداة مناسبة للتنبؤ باستهلاك الطاقة الكهربائية؟

- ماهي التعريفات الكهربائية المناسبة للمستهلكين وهل تؤثر على الإستهلاك؟

- فيما تتمثل مراحل عملية التنبؤ باستخدام الشبكات العصبية LSTM؟

- فيما يكمن دور التعريفات الكهربائية لدى مؤسسة سونلغاز؟

الفرضيات:

- تسمح الشبكات العصبية LSTM بالتنبؤ باستهلاك الطاقة الكهربائية لسكان ولاية غرداية؛
- تشهد مؤسسة سونلغاز ارتفاع كبير في إستهلاك الطاقة الكهربائية لدى سكان ولاية غرداية؛
- تعد التعريفات الكهربائية أساس ضبط وترشيد استهلاك الطاقة الكهربائية لدى المستهلكين؛

أهداف الدراسة:

تهدف الدراسة إلى التعرف على تقنيات التنقيب في البيانات ومدى فعاليتها في معالجة البيانات الضخمة، بالإضافة إلى تحليل إستهلاك الطاقة الكهربائية لدى سكان ولاية غرداية والتنبؤ بما يحدث مستقبلاً، والتطرق إلى مختلف التعريفات الكهربائية الخاصة بالسكان.

المنهج المتبع في الدراسة:

قصد الإجابة على الإشكالية المشار إليها سابقاً والتأكد من صحة الفرضيات تم الاعتماد على المنهج الوصفي والمنهج التجريبي التطبيقي، حيث تمثل الأول في وصف النقاط الأساسية لتقنيات التنقيب في البيانات وعرض خطوات العمل، أما الثاني تمثل في تجسيد منهجية الشبكات العصبية ذات ذاكرة طويلة قصيرة المدى LSTM بواسطة برمجية Python للتوصل إلى نتائج التنبؤ باستهلاك الطاقة الكهربائية لسكان ولاية غرداية.

2. الإطار النظري للتنقيب في البيانات

1.2 مفهوم التنقيب في البيانات Data Mining

هي عملية إستكشاف المعارف والعلاقات والارتباطات والانماط المخبأة داخل كم هائل من البيانات باستخدام عدة تقنيات وبرامج متنوعة، فرضت نفسها في عصر المعلوماتية من أجل حل المشاكل في وقت وجيز ودعم القرارات للحصول على تنبؤات مستقبلية (لكحل و بوهرين ، 2023 ، صفحة 559).

2.2 تقنيات التنقيب في البيانات

تصنف تقنيات التنقيب في البيانات إلى تقنيات وصفية وتنبؤية لكل صنف عدة أنواع كما هو موضح في الشكل (01)، حيث يتم تحديد التقنية المناسبة حسب هدف الدراسة والبيانات المتحصل عليها:

- تقنيات التنقيب التنبؤي Predictive mining techniques :

هي عملية توظيف البيانات من أجل الحصول على تنبؤات مستقبلية عن طريق مختلف التقنيات، لإعطاء صورة مستقبلية عن الظاهرة المدروسة من خلال توظيف البيانات السابقة للحصول على بيانات مستقبلية في شكل نماذج تسمح من تقليل الأخطاء بين القيم الحقيقية والقيم المتوقعة لتكون أكثر دقة وأقرب للواقع، حيث تتضمن عدة تقنيات منها: تقنية التنبؤ، الإنحدار، التصنيف وتحليل السلاسل الزمنية (الحاج كوكو خاطر، 2021، صفحة 10).

(1) التنبؤ Prediction:

هي عملية إيجاد سلوك مستقبلي لبيانات الدراسة تعتمد على عنصر الزمن من أجل التنبؤ بما يحدث مستقبلا، حيث يعد من الطرق المهمة الفعالة في عملية التخطيط واتخاذ القرار لرسم السياسات المستقبلية كونها تعطي تقديرات احتمالية أكثر دقة وموضوعية (سعيد موسى الحتو، 2017، صفحة 19).

(2) تحليل السلاسل الزمنية Time series analysis :

هي طريقة عملية لدراسة عدة ظواهر ذات تسلسل زمني، حيث ظهرت في الدراسات القياسية والذكاء الإصطناعي، التعلم العميق، وتعلم الآلة، هدفها الحصول على نماذج تسمح بتفسير الظواهر مستقبلا إنطلاقا من بيانات ذات تتبع تاريخي قد تكون سنوية أو نصف سنوية، ثلاثية، شهرية، أسبوعية، يومية.

(3) الانحدار Regression:

يعرف الانحدار على أنه عملية إيجاد العلاقات بين مختلف المتغيرات المستقلة والتابعة للظاهرة المدروسة، من أجل وصف العلاقة القائمة بين متغيرات الدراسة ومعرفة مدى تأثير أو تأثر أحدهم على الآخر (أدام محمد عبد الرحمن، 2020، صفحة 17).

(4) التصنيف Classification:

يعد التصنيف أحد أهم التقنيات الشائعة التي تقوم على عملية إسناد الوحدات أو الكائنات إلى فئة معينة من الفئات وهذا من خلال النظر إلى مجموعة البيانات، حيث تحتوي كل مجموعة على عدة سمات تختلف باختلاف الدراسة (علي عزال، 2022، صفحة 49).

- تقنيات التنقيب الوصفي Descriptive mining techniques

يهدف التنقيب الوصفي إلى تنظيم البيانات في شكل صورة تسمح باكتشاف الخصائص المتماثلة والمشاركة داخل مجموعة البيانات، على عكس التنقيب التنبؤي الذي يهدف على إيجاد قيم مستقبلية جديدة (أدام محمد عبد الرحمن، 2020، صفحة 17).

(1) قواعد الارتباط Rule Analysis:

هي أحد الأدوات الواعدة في عملية التنقيب في البيانات التي لها القدرة على إيجاد العلاقات والارتباطات بين العناصر التي تحمل نفس الخصائص المشتركة من خلال معالجة كميات كبيرة من البيانات التي تسمح باستخراج الصفات والقوانين بالإعتماد على الصفات الأخرى، مثل تحليل سلة السوق التي تهدف إلى تعريف بالمنتجات التي من المحتمل شراؤها مع بعض (الحاج كوكو خاطر، 2021، صفحة 11).

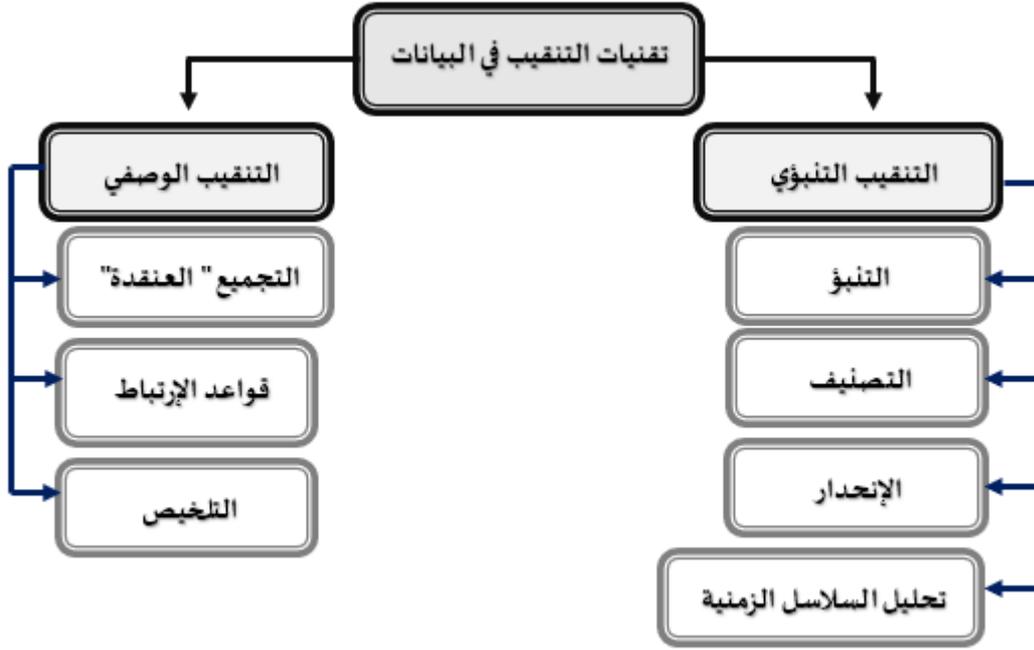
(2) التجميع أو العنقدة Clustering:

تعمل هذه التقنية على تجميع الكيانات المتشابهة مع بعض على أساس حساب المسافة الأقرب بين هذه الكيانات، فمن أهم الخوارزميات التي تستخدم في هذا النوع خوارزمية الجار الأقرب والشبكات العصبية و K-Means (مطلق الدوري و عبد الحسين احمد، 2007، صفحة 46).

(3) التلخيص Summarization:

هي أحد العمليات المهمة في التقنيات الوصفية تنطوي على إيجاد وصفا دقيقا للبيانات في شكل جداول تلخص مجموعة البيانات الكبيرة في صورة بسيطة تسمح بالاستفادة منها، حيث يستخدم فيها مقاييس النزعة المركزية والتشتت (Jogannagari & Manchala, 2020, p. 3916).

الشكل 01: تقنيات التنقيب في البيانات



المصدر: من اعداد الطالبة بالاعتماد على (Zia, et al., 2022, p. 15)

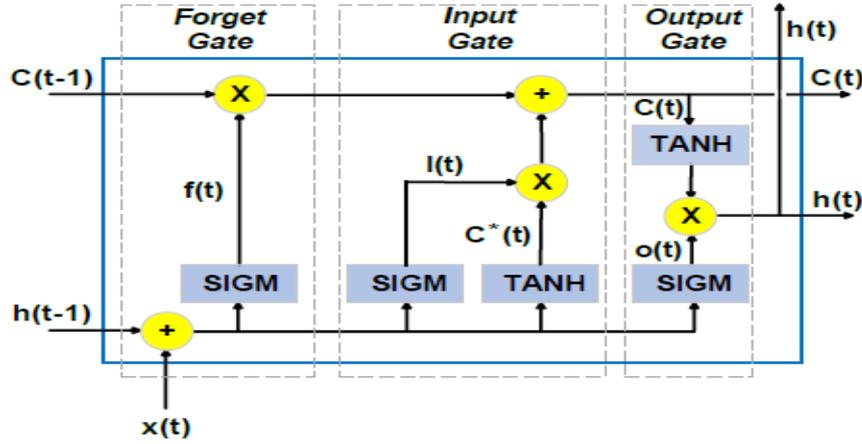
3.2 الشبكات العصبية ذات ذاكرة طويلة قصيرة المدى:

تعد الشبكات LSTM أحد أنواع الشبكات العصبية التكرارية التي لها القدرة على معالجة مشكلة تلاشي وانفجار التدرج عن طريق إدخال ذاكرة طويلة المدى، كما يتميز هذا النوع من الشبكات بمعالجة البيانات المتسلسلة وحفظ المعلومات لفترات زمنية طويلة لأنها تحتوي على بوابات تنظم حركة تدفق المعلومات خلال مرحلة التدريب والاختبار (أحمد منير بطيخ، أيمن نعال، و بوشي، 2022، صفحة 4).
مكونات الشبكة العصبية:

(1) بوابات الشبكات العصبية العميقة ذات الذاكرة طويلة قصيرة المدى LSTM

تتكون الشبكات العصبية من ثلاث أنواع من الطبقات والتي تتمثل في طبقة الإدخال وطبقة الإخراج، والنسيان حيث لكل طبقة بوابة خاصة تقوم بدور معين، والتي هي كالتالي:

الشكل 02: بنية شبكات العصبية ذات ذاكرة طويلة قصيرة المدى LSTM



المصدر: (Bolboaca & Haller, 2023, p. 4)

- بوابة نسيان forget gate:

تعمل بوابة النسيان على تحديد النسب المهمة التي يجب تذكرها والنسب التي يجب نسيانها من الذاكرة القبلية، مع معالجة مشكلة تلاشي وانفجار التدرج أثناء التدريب مما يجعلها تتعلم الآليات التي تمكن الذاكرة طويلة المدى من الاحتفاظ بالمعلومات المهمة وتخطي المعلومات التي لا صلة لها (Waqas & Humphries, 2024, p. 7)، تستند في هذه المرحلة على العلاقة (01)، حيث تبين الرموز ما يلي:

X_t : مدخلات الزمن الحالي للنموذج؛

h_{t-1} : الحالة الخفية للزمن السابق؛

W_f : الأوزان.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \dots \dots \dots (1)$$

- بوابة الإدخال input gate:

يتم في بوابة الإدخال تعيين بيانات X_t من أجل تمريرها في حالة الخفية، حيث تقوم في بداية الأمر على تنظيم القيم التي يستوجب إضافتها لحالة الخلية عن طريق تابع التفعيل الأسّي الجيبي والعمل على إنشاء شعاع للقيم المرشحة الجديدة \tilde{C}_t من خلال طبقة تحتوي على تابع التفعيل الأسّي، حيث تلعب هذه البوابة دوراً مهماً في حماية محتويات الذاكرة من الاضطرابات من خلال المعادلتين (2) و(3)، أما بالنسبة لتعديل قيم حالة الخلية السابقة C_{t-1} إلى قيمة جديدة C_t الموضحة في المعادلة (4) (بن سعدي ، 2025 ، صفحة 152)

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \dots (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \dots (3)$$

$$C_t = f_t \cdot C_{t-1} + \tilde{C}_t \cdot i_t \dots \dots (4)$$

- بوابة الإخراج output gate:

تختص بوابة الإخراج في حساب الذاكرة القصيرة h_t وتحديد المعلومات المستخرجة من خلال المعادلة (5) (المالغ، 2019، صفحة 57):

$$h_t = o_t \cdot \tanh(C_t) \dots \dots (5)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

حيث أن:

(2) الأوزان النسبية:

يكمّن دور الأوزان في اتصال الطبقات مع بعضها البعض من أجل تعيين القيمة الحسابية أو القوة النسبية للبيانات المدخلة، حيث يمكن تعديل الأوزان عن طريق خاصية التعلم في الشبكة العصبية من خلال دالة التجميع ويرمز لها بالرمز W_{k1} ، W_{k2} ، W_{kp} (كردودي و بن قدور، 2016).

3) عناصر المعالجة: تتمثل عناصر المعالجة في دالة التجميع ودالة التحويل، والتي كالتالي:

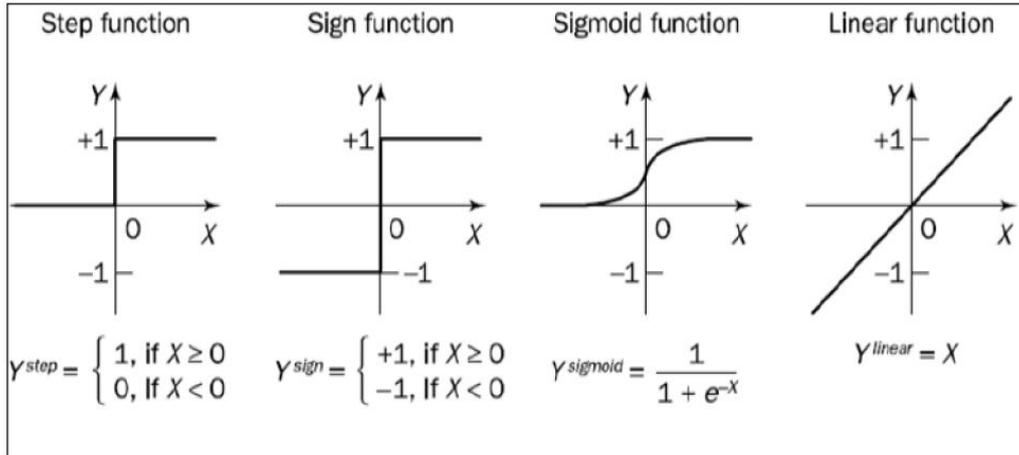
- دالة التجميع: يكمّن دور دالة التجميع في معالجة الشبكة من خلال وحدات المعالجة التي تقوم بحساب متوسط الأوزان للمدخلات من خلال العلاقة التالية: $\sum_{i=1}^n W_{ki}X_i = W_{k1}X_1 + W_{k2}X_2 + \dots + W_{kn}X_n$
 - دالة التحويل (دوال التنشيط): تحدد هذه الدالة نوعية المخرجات التي سوف يتم التوصل إليها مع الأخذ بعين الإعتبار الأوزان والمدخلات الموضحة في الشكل 03 نذكر من أهمها ما يلي:
3. دالة الخطوة: تدعى بدالة العتبة دورها القيام بتحويل القيم المخرجة من وحدات المعالجة إلى الواحد (1) إذا كانت القيم المدخلة $z \geq 0$ ، وتساوي الصفر (0) إذا كانت القيمة المدخلة $z < 0$ (بن سعدي، 2025، صفحة 147)، وهذا من خلال العبارة التالية:

$$f(z) = \begin{cases} 1 & \text{if } z \geq 0 \\ 0 & \text{if } z < 0 \end{cases}$$

4. الدالة الخطية: تكون الدالة في هذه الحالة مخرجات مماثلة للمدخلات الموزونة في وحدة المعالجة، حيث لها تصنيفات متعددة وهي من الشكل: $f(z) = z$
5. الدالة الأسية: وهي دالة غير خطية تدعي كذلك بدالة سيكمويد أو الدالة السينية يقع مداها بين [0, 1].
6. دالة الإشارة: تستعمل في التعرف على الأنماط وتصنيفها تكون صورة الإخراج بين [-1, 1] (صابر قاسم ورستم محمد، 2013، صفحة 186)، تعطي بالعلاقة التالية:

$$f(z) = \begin{cases} +1 & \text{if } z \geq \theta \\ -1 & \text{if } z < \theta \end{cases}$$

الشكل 03: أبرز دوال التنشيط



المصدر: (عتروس، 2017-2018، صفحة 160)

4.2 أنواع التعلم للتنقيب في البيانات: للتنقيب في البيانات ثلاث أنواع من التعلم وهي:

- التعلم المراقب (التعلم بالإشراف)

يقوم هذا النوع من التعلم في وجود مدخلات ومخرجات الدراسة أي في وجود قيم للمتغيرات المدخلة "مستقلة" والمخرجة "تابعة"، لتتم عملية تدريب الخوارزمية عدة مرات إلى غاية الوصول إلى مخرجات ذات قيم جيدة تكون مقارنة

للقيم الفعلية ليتم مقارنتها مع القيم الأصلية المدخلة، حيث يعرف هذا التعلم بالتعلم الموجه لأنه ينتج نماذج عن طريق نظام توجيهه بيانات الدراسة (احمد الشوادفي و السيد حجاج، 2013).

- التعلم الغير المراقب (التعلم بدون إشراف)

يختص هذا النوع من التعلم بوجود متغيرات الإدخال " متغيرات مستقلة " دون متغيرات الإخراج خلال عملية التدريب، دوره القيام باكتشاف المميزات والصفات الغير ظاهرة داخل مجموعة البيانات إنطلاقاً من المدخلات، أي أن الشبكة العصبية تبني أساليب التعلم على أساس قدرتها على إكتشاف الصفات المميزة لها دون معرفة مسبقة للمخرجات (جابر أحمد محمد، 2020، صفحة 156).

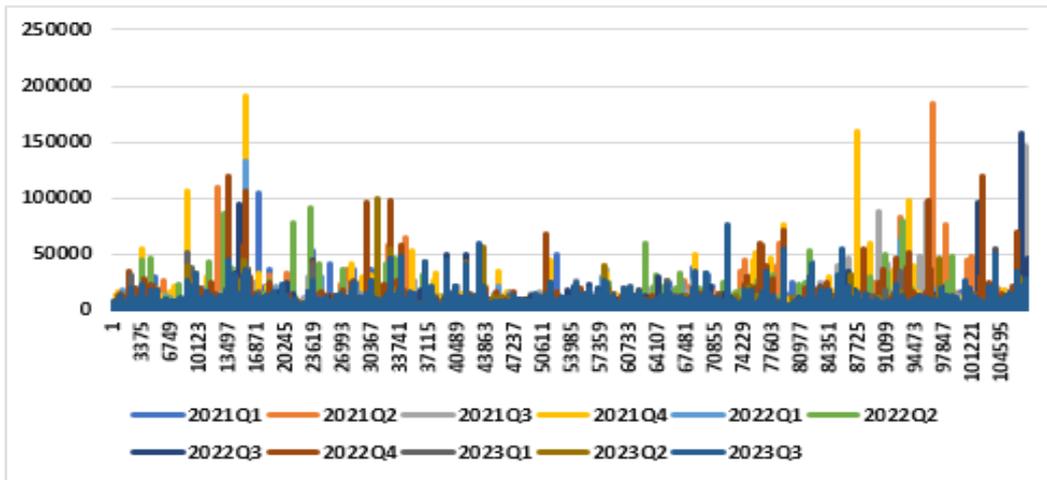
- التعلم بإعادة التدعيم:

تقوم هذه الطريقة بالدمج بين التعلم بالإشراف والتعلم بدون إشراف، حيث لا يتم الإفصاح على القيم الحقيقية للمخرجات، مثل ما هو الحال في التعلم بدون إشراف، بل يشار لصحة نتائجها من عدمه عن طريق التعلم بالإشراف (جابر أحمد محمد، 2020، صفحة 156).

3. إستهلاك الطاقة الكهربائية لسكان ولاية غرداية

تزود مؤسسة سونلغاز السكان والمؤسسات بالطاقة الكهربائية وفقاً لإحتياجاتهم وطبيعة النشاط، إذ يختلف نوع التوتور الكهربائي المسموح للمستهلكين حسب نوع القطاع، من التوتور المنخفض، والمتوسط، والعالي، حيث ركزت الدراسة على التوتور المنخفض الخاص بالقطاع العائلي الذي ينقسم إلى إستهلاك منزلي والذي يشمل السكان وإستهلاك غير منزلي ويمثل النشاطات التجارية والاقتصادية صغيرة، كالمخابز والمقاهي، محلات المواد الغذائية. تم إستعمال بيانات إستهلاك المنزلي للطاقة الكهربائية لدراسة الوضع الاستهلاكي على عينة من السكان تضم 112820 منزل والموضحة في الشكل(04).

الشكل 04: إستهلاك المنزلي للطاقة الكهربائية لولاية غرداية



المصدر: من إعداد الطالبة بالاعتماد على بيانات مؤسسة سونلغاز لولاية غرداية

يوضح الشكل البياني تطور إستهلاك الطاقة الكهربائية لعينة من سكان ولاية غرداية من الفترة 2021 Q1 إلى غاية Q3 2023، حيث نجد تذبذب واضح في إستهلاك الكهرباء بين السكان غير أن أغلب المستهلكين لا يتجاوز استهلاكهم 50000KWH.

التعريفات الكهربائية لإستهلاك السكان

تحتوي مؤسسة سونلغاز لتوزيع الكهرباء والغاز على نظام محكم يسير إستهلاك الطاقة الكهربائية، فهي تعتمد على ضوابط تساهم في ترشيد إستهلاك القدرة الموضوعية تحت تصرف الزبون للطاقة الكهربائية، بالإضافة إلى الإتاوة الثابتة والسعر

المحدد للكمية المستهلكة، حيث تندرج هذه العناصر في أربع تعريفات كهربائية تبين سيرورة حساب الكمية المستهلكة لدى كل زبون، والموضحة في النقاط التالية:

1- التعريف البسيطة:

يطلق عليها بالتعريف الأحادية أو التصاعدية، تضم أربع شرائح يتم حساب الكمية المستهلكة للكهرباء حسب السعر المحدد لكل كمية، حيث تعد من بين أكثر التعريفات الكهربائية طلبا لدى المستهلكين.

الجدول 01: تعريف الكهربائية 54M

القدرة الموضوعة تحت التصرف	الطريف 04	الطريف 03	الطريف 02	الطريف 01	54M
4.37	أكبر من 1000	1000-251	250-126	125-0	كمية المستهلكة (KWH)
	5.4796	4.8120	4.1789	1.7787	السعر (دج)

المصدر: من إعداد الطالبية بالإعتماد على معطيات مؤسسة سونلغاز

2- التعريف الثنائية: لها صنفين هما:

- الصنف الأول: التعريف من نوع 52M وتتضمن فترات الإستهلاك خلال ساعات الذروة وخارج ساعات الذروة لكل فترة سعر محدد للكمية المستهلكة من الطاقة الكهربائية، بالإضافة إلى رسوم ثابتة.

الجدول 02: تعريف الكهربائية الثنائية من النوع M52

القدرة الموضوعة تحت التصرف	الإتاوة الثابتة "رسم ثابتة" (دج/شهر)	السعر (دج)	ساعات	
29.85	66.40	8.1147	21:00-17:00	ساعات الذروة
		1.7807	17:00-21:00	خارج ساعات الذروة

المصدر: من إعداد الطالبية بالإعتماد على معطيات مؤسسة سونلغاز

- الصنف الثاني: تعريف من نوع 53M يندرج في هذه التعريف ساعات النهار والليل لاستهلاك الطاقة الكهربائية لكل فترة والسعر المحدد للوحدات المستهلكة من الطاقة الكهربائية، بالإضافة إلى الإتاوة الثابتة.

الجدول 03: تعريف الكهربائية الثنائية من النوع 53M

القدرة الموضوعة تحت التصرف	الإتاوة "رسوم الثابتة" (دج/شهر)	سعر	ساعات الاستهلاك	
14.81	66.40	4.8698	22:30-6:00	النهار
		1.2050	6:00-22:30	الليل

المصدر: من إعداد الطالبية بالإعتماد على معطيات مؤسسة سونلغاز

3- التعريف الثلاثية:

تقسم ساعات الاستهلاك في هذه التعريف إلى ساعات الكاملة وساعات الذروة، وساعات الليل، لكل فترة سعر مخصص بالإضافة إلى الاتاوة الثابتة.

الجدول 04: التعريف الثلاثية 51M

القدرة الموضوعة تحت التصرف	الإتاوة الثابتة "رسم ثابتة" (دج/شهر)	السعر (دج)	ساعات	
29.85	286.44	2.1645	17:00-6:00	ساعات الكاملة
			22:30-21:00	
		8.1147	21:00-17:00	ساعات الذروة
		1.2050	6:00-22:30	ساعات الليل

المصدر: من إعداد الطالبة بالإعتماد على معطيات مؤسسة سونلغاز

4. الإطار التطبيقي للدراسة:

تتمحور الدراسة حول كيفية استخدام تقنيات التنقيب في البيانات للتنبؤ بإستهلاك الطاقة الكهربائية لسكان ولاية غرداية، حيث تم الإعتماد على بيانات إستهلاك الطاقة الكهربائية لسكان من ثلاثي الأول 2021 إلى غاية ثلاثي الثالث 2023 على عينة تضم 112820 مستهلك.

متغيرات الدراسة:

- متغير التابع: الطاقة الكهربائية المستهلكة للمنازل؛

- متغير المستقل: نوع التعريف الكهربائي والتي يرمز لها وفق مؤسسة سونلغاز M51, M52, M53 , M54.

1.4 خطوات بناء نموذج إستهلاك الطاقة الكهربائية:

(1) العمل على جمع بيانات إستهلاك الطاقة الكهربائية للجهد المنخفض من 2021Q1 إلى غاية 2023Q3 لمؤسسة التوزيع الكهربائي والغاز لولاية غرداية مع تحديد نوع التعريف الكهربائي المدرجة عند كل مستهلك؛

(2) تجهيز البيانات من خلال عملية التنظيف والتنظيم والترتيب، لمعالجتها وجعلها جاهزة للإستعمال؛

(3) إنشاء تسلسل خاص بالبيانات وتقسيمها إلى بيانات التدريب 80% والإختبار 10%، والتنبؤ 10%، والعمل على تحديد طبقات المكونة للشبكة من أجل بناء النموذج والتي كما يلي:

- طبقة الإدخال: تحتوي على طبقة واحدة بمدخلين؛
- الطبقات الخفية: تتكون من أربع طبقات تمثلت في:

- طبقتين من شبكة LSTM: الأولى بها 128 عقدة والثانية بها 64 عقدة؛

- طبقة Flatten: وهي عبارة عن طبقة التسطيح يتم فيها ترتيب المدخلات لجعلها في شكل أحادي البعد (Nazir, et al., 2024, p. 6)

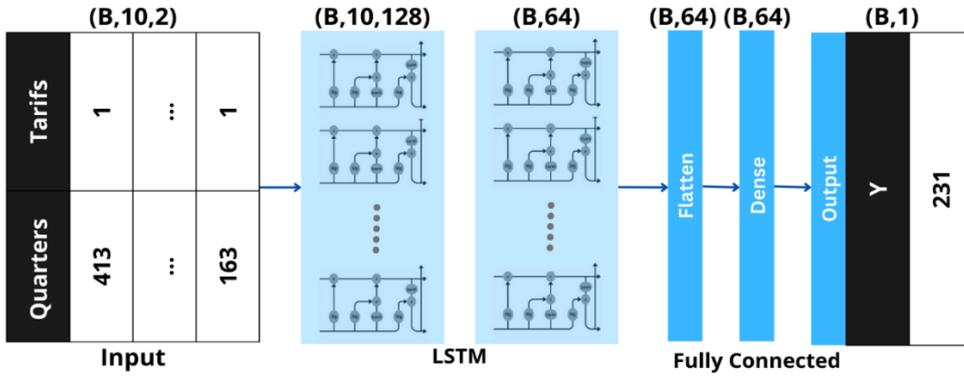
- طبقة Dense: وهي عبارة عن طبقة كثيفة بها عدة خلايا عصبية تتصل بالطبقات السابقة، يكمن دورها في القيام بعمليات حسابية، إنطلاقاً من مصفوفة الأوزان والمتجه، حيث يعتمد فيها كل ناتج على مدخل (زهواني ، 2021-2022، صفحة 133):

- طبقة الإخراج؛ وتتمثل في طبقة واحدة حيث يتم إختيار إستهلاك الثلاثي الأخير للبيانات كمخرج لسلسلة في النموذج؛ (4) في آخر مرحلة يتم تقييم النموذج من خلال معيار متوسط مربع الأخطاء MSE ومعامل التحديد R^2 ، حيث تتمثل عدد التمريرات النموذج في 20 تمريرة.

2.4 عرض وتحليل نتائج نموذج الإستهلاك المنزلي للطاقة الكهربائية

بعد المرور بالخطوات السابقة الخاصة بالنموذج نتحصل على شكل شبكة LSTM لإستهلاك الطاقة الكهربائية لسكان ولاية غرداية والتي توضح ترتيب المدخلات والمخرجات بالإضافة إلى عدد العقد، حيث يتبين أن مدخلات طبقة الإدخال تتمثل في الإستهلاك المنزلي للكهرباء بالإضافة إلى التعريفات الكهربائية M51, M52, M53, M54 ، ثم الطبقات الخفية والتي تتمثل في طبقتين LSTM وطبقة Flatten وDense ، وفي النهاية تأتي طبقة الإخراج التي بها مخرج واحد يتمثل في إستهلاك ثلاثي الأخير للكهرباء (الشكل 05)؛

الشكل 05: شكل الشبكة العصبية العميقة لنموذج الإستهلاك المنزلي للطاقة الكهربائية



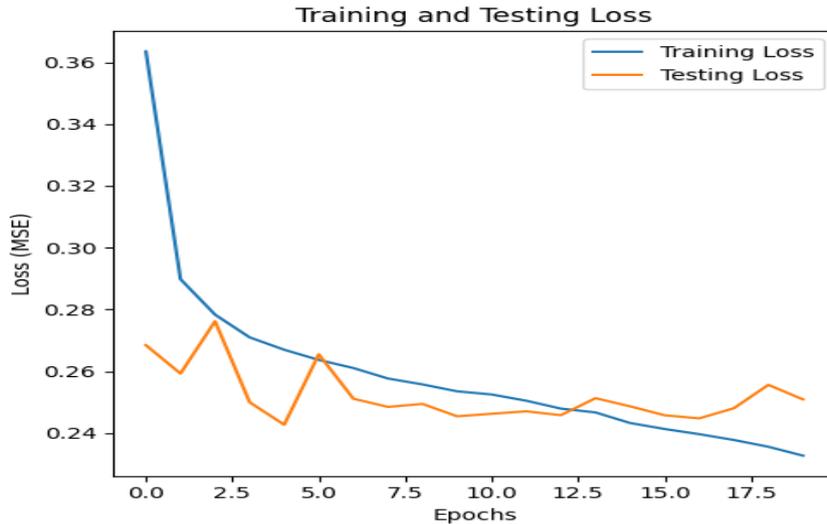
المصدر: من إعداد الطالبة بالإعتماد على برمجية Python

تمثلت نتائج دالة الإختبار والتدريب لمعامل التحديد R^2 ومتوسط مربع الأخطاء MSE فيما يلي:

- نتائج متوسط مربع الأخطاء MSE لنموذج الإستهلاك المنزلي:

يوضح الشكل الموجود في الأسفل نتائج متوسط مربع الأخطاء لنموذج الإستهلاك المنزلي، حيث يتبين لنا أن منحى التدريب يتدرب بشكل سريع على منحى الإختبار ليصل إلى أقل قيمة عند 0.21، أما في مرحلة الإختبار يتدرب بشكل ضعيف ليستقر عند أقل نسبة 0.25 وهذا ما يدل على مدى صحة ودقة النموذج حيث أنه كل ما كانت فترة التدريب أكبر كل ما كان النموذج أفضل.

الشكل 06: متوسط مربع الأخطاء MSE للإستهلاك المنزلي

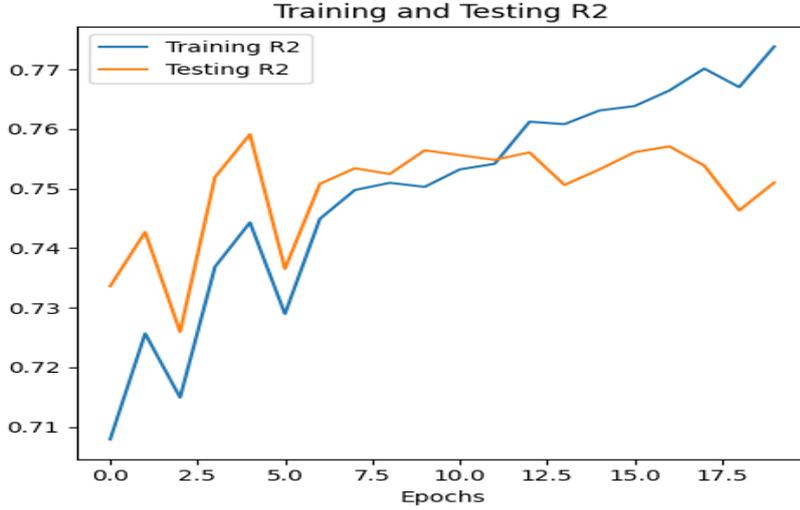


المصدر: من إعداد الطالبة بالإعتماد على برمجية Python

نتائج القوة التفسيرية R^2 لنموذج الإستهلاك المنزلي:

يوضح الشكل البياني الموالي مدى تطور معامل القوة التفسيرية للنموذج أثناء عملية التدريب والإختبار للشبكة LSTM، حيث تبين من خلال الشكل (07) توافق بين منحى التدريب والإختبار مع زيادة القوة التفسيرية للنموذج ليستقر عند 0.78 في مرحلة التدريب و0.75 عند مرحلة الإختبار، وهي نسبة جيدة لدقة النموذج وبالتالي فهو ذو دلالة إحصائية.

الشكل 07: معامل القوة التفسيرية R^2 للإستهلاك المنزلي



المصدر: من إعداد الطالبة بالإعتماد على برمجية Python

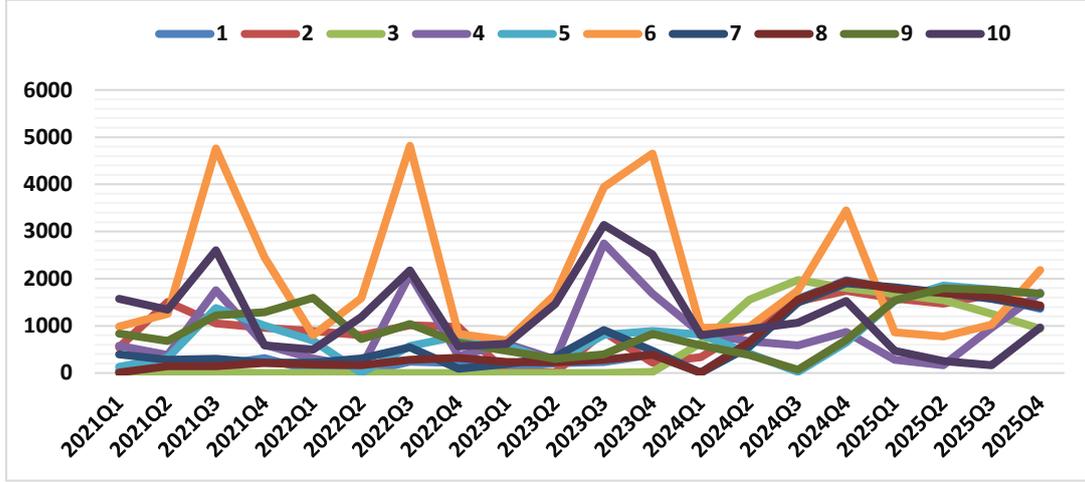
نتائج التنبؤ: بعد الحصول على نتائج مرحلة التدريب والاختبار لمعيار MSE و R^2 تم إستعراض بعض قيم التنبؤ بإستهلاك الطاقة الكهربائية من الفترة 2023Q4 إلى غاية 2025Q4، وكانت النتائج كما يلي:

الجدول (05): نتائج التنبؤ بإستهلاك المنزلي للطاقة الكهربائية

2023Q4	2024Q1	2024Q2	2024Q3	2024Q4	2025Q1	2025Q2	2025Q3	2025Q4
390	6	664	1575	1966	1785	1700	1602	1366
219	337	962	1521	1743	1581	1469	1663	1425
22	634	1553	1971	1803	1671	1546	1256	940
1679	839	676	582	866	283	167	956	1701
891	818	418	25	643	1533	1853	1767	1672
4652	959	975	1750	3446	861	775	1025	2184
472	6	557	1489	1903	1818	1704	1576	1392
388	8	655	1554	1946	1780	1695	1621	1429
828	583	382	68	702	1542	1795	1763	1682
2516	798	927	1067	1527	467	253	165	962

المصدر: من إعداد الطالبة بالإعتماد على مستخرجات Python

الشكل 08: نتائج التنبؤ باستهلاك المنزلي للطاقة الكهربائية



المصدر: من إعداد الطالبة بالإعتماد على مستخرجات Python

تبين نتائج التنبؤ الموضحة في الجدول و المنحنى البياني أن تحليل بيانات استهلاك الكهرباء لسكان ولاية غرداية خلال الفترة الممتدة من الربع الرابع لعام 2023 إلى الربع الرابع لعام 2025 وجود تذبذب موسمي واضح في مستويات الاستهلاك، حيث بلغت الذروة خلال الربعين الثاني والثالث من عام 2024، تزامناً مع فترات الصيف وارتفاع درجة الحرارة لأن ولاية غرداية من المناطق الصحراوية كما تعكس القيم المرتفعة تباين بين مختلف المناطق أو الفئات الاستهلاكية داخل الولاية، وهو ما يشير إلى تأثير عدة عوامل كنمط الاستهلاك داخل كل منزل وعدد المصابيح، عدد الغرف نوع المصابيح عدد الأجهزة الكهربائية وما على ذلك .

خاتمة:

عالجت الدراسة موضوع استخدام الشبكات العصبية LSTM للتنبؤ باستهلاك الطاقة الكهربائية لسكان ولاية غرداية من 2021Q4 إلى غاية 2025Q4، حيث توصلت الدراسة إلى ما يلي:

- نتائج متوسط مربع الأخطاء لنموذج الاستهلاك المنزلي تبين مدى صحة ودقة النموذج، حيث أعطى نسبة 0.25 وهي نسبة منخفضة تُشير إلى أن النموذج يتمتع بدرجة جيدة من الدقة في التنبؤ بالاستهلاك إذ أن الفروق بين القيم المتوقعة والفعلية صغيرة مما تعكس كفاءة النموذج في التقدير.
- تُظهر نتائج النموذج أن الشبكات العصبية العميقة من نوع (LSTM) تمثل أداة فعّالة في التنبؤ باستهلاك الطاقة الكهربائية لسكان ولاية غرداية، نظراً لقدرتها العالية على تحليل الأنماط الزمنية المعقدة والتكيف مع التغيرات الموسمية والسلوكية التي تميز نمط الاستهلاك في المنطقة، وبناءً على ذلك يمكن الاعتماد على هذا النوع من النماذج في تطوير استراتيجيات دقيقة لتخطيط الطلب وإدارة الموارد الطاقوية في الولاية، فضلاً عن تطبيقها في مجالات أخرى متعلقة بالتنبؤ بالطاقة وترشيد استهلاكها.
- إختيار التعريفات الكهربائية عامل مهم في ترشيد وضبط الكمية المستهلكة للكهرباء فهي تؤثر بالزيادة أو بالنقصان على الاستهلاك وبالتالي على مبلغ الفاتورة الكهربائية المستحق للدفع، ما يدل على وجود علاقة عكسية بين الكمية المطلوبة من الطاقة الكهربائية وسعر الوحدات المستهلكة، حيث كلما إرتفعت الأسعار يميل المستهلكون إلى ترشيد الطاقة الكهربائية؛
- التعريفات الأحادية " تصاعدية" M54 تعد من أكثر التعريفات الكهربائية الملائمة لدى المستهلكين حسب الاحصائيات المدونة في مؤسسة سونلغاز والنتائج المتحصل عليها، وهذا يتفق مع نظرية سلوك المستهلك التي تهدف إلى تعظيم المنفعة في حدود الدخل ما يحفز المستهلكين على البقاء ضمن شرائح " التعريفات" الأقل تكلفة وهو ما يؤدي إلى سلوك إستهلاكي أكثر كفاءة وترشيداً؛
- وجود تباين في الكمية المستهلكة بين السكان نتيجة تأثير عدة عوامل كنمط الاستهلاك داخل كل منزل وعدد المصابيح، عدد الغرف، نوع المصابيح، عدد الأجهزة الكهربائية وما على ذلك .

- الجوانب القانونية المسطرة لبعض التعريفات الكهربائية غير مناسبة للمشاركين مما أدى إلى تجاهلها وعدم الاقتناء بها كونها ترفع من سعر الوحدات المستهلكة خاصة التعريفات ثلاثية M51، لأنها تحدد ساعات الذروة التي يكون فيها سعر الوحدات المستهلكة من الكهرباء مرتفع مما يؤدي حتما إلى إرتفاع مبلغ الفاتورة الكهربائية؛
- أظهرت النتائج أن محتوى التعريفات الكهربائية يعكس مدى قدرة الطلب عليها، حيث تبين أن التعريفات الكهربائية الأحادية M54 أكثر طلبا من بين التعريفات الأخرى ويرجع هذا لطريقة حساب الكمية المستهلكة التي تقوم على أساس تقسيم الإستهلاك إلى مجموعات لكل كمية مستهلكة سعر محدد على خلاف الأنواع الأخرى التي تحسب على أساس ساعات الذروة وخارج الذروة، والساعات الكاملة، وساعات الليل والنهار، التي تكون مرتفعة مقارنة مع التعريفات الأحادية بالإضافة إلى الإتاوات الثابتة التي تكون مختلفة من نوع لأخر ما يزيد من تكلفة الفاتورة؛
- تبين نتائج التنبؤ ارتفاع استهلاك الطاقة الكهربائية في فصل الصيف بسبب ارتفاع درجة الحرارة في ولاية غرداية لأنها منطقة صحراوية؛
- توصيات: بناء على ما سبق نقترح التوصيات التالية:
- العمل على تجنيد وسائل التوعية بمدى ضرورة الحفاظ على الطاقة الكهربائية؛
- استقطاب أصحاب الخبرة والكفاءات في مجال البحوث والدراسات لمعالجة البيانات والقيام بالدراسات حول ما يتعلق بالطاقة الكهربائية؛
- الخوض في مجال الرقمنة والابتعاد على التدوين اليدوي أثناء مراقبة الإستهلاك من أجل الحصول على نتائج أكثر دقة ومصداقية؛
- العمل على تعزيز الجهود والامكانيات من أجل مراقبة أصحاب الإستهلاك المفرط.

قائمة المراجع:

- Jogannagari, M., & Manchala, M. (2020). Data Mining: Techniques, Tools and its Challenges. *International Journal of Creative Research Thoughts (IJCRT)*, 8(7), 2320-2882.
- Bolboaca, R., & Haller, P. (2023). Performance Analysis of Long Short-Term Memory Predictive Neural Networks on Time Series Data. *mathematics*, 11(6), 1-35.
- Nazir, A., He, J., Zhu, N., Qureshi, S., Qureshi, S., Ullah, F., . . . Pathan, M. (2024). A deep learning-based novel hybrid CNN-LSTM architecture for efficient detection of threats in the IoT ecosystem. *Ain Shams Engineering Journal*, 15(7), 1-21.
- Waqas, M., & Humphries, W. (2024). A critical review of RNN and LSTM variants in hydrological time series predictions. *MethodsX*, 13, 1-19.
- Zia, A., Aziz, M., Popa, I., Ahmed Khan, S., Fazely Hamedani, A., & R. Asif, A. (2022). Artificial Intelligence-Based Medical Data Mining. *Journal of Personalized Medicine*, 12(9), 1-23.
- جمال احمد الشوادفي، و عبدالوهاب السيد حجاج. (2013). الذكاء الاصطناعي وتحليل السلاسل الزمنية. *المجلة العلمية لقطاع كليات اللجارة - جامعة الأزهر* (10)، 571-612.

- زكريا مطلق الدوري، و داليا عبد الحسين احمد. (2007). دور تنقيب البيانات Data Mining في زيادة اداء المنظمة دراسة تحليلية في المصرف الصناعي. *مجلة العلوم الاقتصادية والادارية*، 13(48)، 62-40.
- سهام كردودي ، و علي بن قدور. (2016). التنبؤ بالشبكات العصبية الاصطناعية كدعامة للمراجعة التحليلية في عملية التدقيق، حالة مركب تكرير الملح E.na.sel (بسكرة) في الفترة 2010- 2014. *مجلة الإستراتيجية والتنمية*، 6(1)، 166-197.
- سهيلة عتروس. (2018-2017). استخدام منهجية بوكس جنكيز والشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية بمؤسسة سونلغاز (دكتوراه). كلية العلوم الاقتصادية والتجارية وعلوم التسيير، الجزائر: محمد خيضر بسكرة.
- طه سعيد موسى الحتو. (2017). دراسة مقارنة نموذج ARIMA وطريقة التمهيد الآسي في التنبؤ بالسلاسل الزمنية (ماجستير). كلية الاقتصاد والعلوم الإدارية، غزة: جامعة الأزهر.
- عائشة آدم محمد عبد الرحمن. (2020). استخدام تقنيات التنقيب في البيانات للتنبؤ بتحصيل الطلاب (دراسة حالة كلية الدراسات العليا جامعة النيلين) (ماجستير). كلية الدراسات العليا، السودان: النيلين.
- عمر صابر قاسم، و إسراء رستم محمد. (2013). دراسة رياضية تحليلية لخوارزميات الشبكات العصبية الاصطناعية في ملاءمة نموذج للتشخيص الطبي. *مجلة الرافدين لعلوم الحاسوب والرياضيات*، 10(1)، 183-194.
- عواطف الحاج كوكو خاطر. (2021). استخدام تقنيات تنقيب البيانات في تطبيقات التجارة الالكترونية للتنبؤ عن المبيعات المستقبلية (ماجستير). كلية الدراسات العليا، السودان: النيلين.
- فاطمة الزهراء لكحل ، و فتيحة بوهرين . (2023). استخدام تقنيات التنقيب عن البيانات لتحليل مؤشرات السيولة لمصرف الكويت الوطني باستخدام برنامج DATAtab خلال الفترة 2017-2021. *مجلة المنهل الاقتصادي*، 6(1)، 555-576.
- فتيحة بن سعدي . (2025). استخدام تقنيات التنقيب في البيانات إستهلاك الطاقة -دراسة حالة مؤسسة سونلغاز ولاية غرداية- . كلية العلوم الاقتصادية والتجارية وعلوم التسيير، الجزائر: غرداية.
- محمد أحمد منير بطيخ، محمد أيمن نعال، و عامر بوشي. (2022). مقارنة أداء الشبكات العصبونية التكرارية في تخفيض بارامترات التدريب لشبكات التلافيف العصبية. *مجلة العلوم الهندسية وتكنولوجيا المعلومات*، 6(1)، 1-14.
- مروان جابر أحمد محمد. (2020). نموذج انحداري موائم بالشبكات العصبية لتقدير معدل السعر للتأمينات العامة. *مجلة الدراسات المالية والمحاسبية والإدارية*، 7(2)، 150-169.
- مروة زهواني . (2021-2022). تطبيقات نماذج الذكاء الاصطناعي للتنبؤ بمخاطر التعثر المالي في المؤسسة الاقتصادية - دراسة حالة- كلية العلوم الاقتصادية والتجارية وعلوم التسيير ، غرداية : غرداية .
- مريم علي عزال. (2022). نظام التنبؤ عن واردات نهر الفرات باستخدام تقنيات تعلم الآلة (ماجستير). الجامعة الافتراضية السورية، سوريا: الجامعة الافتراضية السورية.
- ملهم محمد منير المالح. (2019). تلخيص النصوص العربية المعتمد على التعلم العميق والمعطيات الكبيرة (ماجستير). المعهد العالي للعلوم التطبيقية والتكنولوجيا، سورية: المعهد العالي سورية.
- ناهد محمد حسن احمد. (2018). استخدام تنقيب البيانات لبناء الخطط العلاجية لمرضى السكري (رسالة ماجستير). كلية الدراسات العليا، السودان: النيلين.