

استخدام النموذج الشبكات العصبية الاصطناعية للتنبؤ بإستهلاك الطاقة الكهربائية في الجزائر

¹ صاري حسون صلاح الدين *، ² نعمان محمد عبد الجليل، ³ مليوي عبد الغاني

¹ دكتور، أستاذ محاضر "أ"، المركز الجامعي مغنية، مخبر LEPESE، (الجزائر)

salah.poldeva08@gmail.com ✉

<https://orcid.org/0000-0002-7634-2803> 


² ماستر، المركز الجامعي مغنية، (الجزائر)

namamemohammed@gmail.com ✉

<https://orcid.org/0009-0000-4991-1102> 

³ ماستر، المركز الجامعي مغنية، (الجزائر)

malioui80@gmail.com ✉

<https://orcid.org/0009-0006-5013-798X> 

الملخص:

تعتبر الطاقة بشكل عام من أهم العناصر الأساسية للاقتصاديات العالمية وتصنف كعنصر استراتيجي للتنمية الاقتصادية، إذ أظهرت الأحداث الأخيرة وبالخصوص (الحرب الروسية الأوكرانية) وهذا ما يدل على أهمية هذا المورد الأساسي. في هذه الدراسة تطرقنا إلى دراسة التنبؤ بإستهلاك الطاقة الكهربائية في الجزائر خلال الفترة 1980 إلى 2022 باستخدام الشبكات العصبية الاصطناعية. تم تطرق الى منهجية ذه الطريقة ومرحلة التشخيص وبعدها تم اختيار النموذج الشبكات العصبية الاصطناعية متعددة الطبقات (MLP) تم التوصل إلى أن النموذج الأفضل هو MLP 1-1-3 والقيم المتنبأ بها لسنة 2023 هي 76,83 مليار TWh وشهدت زيادة استهلاك الطاقة بنسبة 3.434% في سنة 2024 بقيمة 79,47 مليار TWh الكلمات المفتاحية: إستهلاك الطاقة الكهربائية، تنبؤ، شبكات عصبية اصطناعية، نموذج متعدد الطبقات

تصنيف JEL: C45، C47، C53

استلم في: 2024/05/22

قبل في: 2024/06/24

نشر في: 2024/06/30

* المؤلف المرسل

كيفية الإحالة: حسون صاري ص. ا.، نعمان م. ع. ا. & مليوي ع. ا. (2024). استخدام النموذج الشبكات العصبية الاصطناعية للتنبؤ بإستهلاك الطاقة الكهربائية في الجزائر. دراسات العدد الاقتصادي-89، (2)، 104.

<https://doi.org/10.34118/djei.v15i2.3900>

2.3900



هذا العمل مرخص بموجب رخصة

المشاع الإبداعي نسب المصنف -

غير تجاري 4.0 دولي.

DOI 10.34118/djei.v15i2.3900

Using Artificial Neural Network Model to Forecast the Electricity Consumption in Algeria

Salaheddine SARI-HASSOUN ^{1*}, Mohamed Abdeldjalil NAMANE ², Abdelghani MALIOUI ³

¹Doctorate, Senior Lecturer, University Centre of Maghnia, LEPESSE Laboratory, Algeria

✉ salah.poldeva08@gmail.com

 <https://orcid.org/0000-0002-7634-2803>

²Master, University Centre of Maghnia, Algeria

✉ namamemohammed@gmail.com

 <https://orcid.org/0009-0000-4991-1102>

³ Master, University Centre of Maghnia, Algeria

✉ malioui80@gmail.com

 <https://orcid.org/0009-0006-5013-798X>

Received: 22/05/2024

Accepted: 24/06/2024

Published: 30/06/2024

* *Corresponding Author*

How to cite: 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>



This work is an open access article, licensed under a [Creative Commons Attribution-Non Commercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/).

DOI 10.34118/djei.v15i2.3900

Abstract

Recent events, especially the Russian-Ukrainian War have demonstrated the significance of energy resource, which is generally regarded as one of the most fundamental components of global economies and is classified as a strategic component of economic development. In this study, we employed the artificial neural networks to predict the electricity consumption of Algeria using annual data 1980 to 2022. After discussing this method's methodology and the diagnostic phase, the model's Multi-Layer Perceptron neural networks (MLP) were chosen. MLP 3-1-1 was found to be the most effective model. In the forecasting phase, the electricity consumption energy in Algeria was predicted to be 76,83 billion TWh in 2023 and 79,47 billion TWh in 2024, an increase of 3,434%.

Keywords: Electricity consumption energy, forecasting, artificial neural networks, Multi-Layer Perceptron

JEL classification codes : C45, C53, Q47

مقدمة:

يعتبر التنبؤ في عصرنا الحالي أحد أهم العمليات التي لا يمكن للمنظمات وصناع القرار الاستغناء عنها، وهو مهم في الحد من عوامل الخطر، فضلاً عن وضع الاستراتيجيات والخطط المستقبلية. من بين المجالات المهمة التي تتطلب التنبؤ بالقيم المستقبلية نجد مجال الطاقة الذي يعتبر عصب الحياة العصرية ومن أهم القطاعات الاقتصادية، حيث أصبح يرهن مستقبل اقتصاديات الدول خصيصاً بعد الصراع بين روسيا وأكرانيا في فبراير 2022 مما أدى إلى تفاقم أزمة الطاقة العالمية الناتجة عن COVID-19 حيث عطلت الحرب تجارة الطاقة العالمية وتسببت في ارتفاع أسعار الطاقة بشكل كبير. وخاصة الطاقة الكهربائية التي تلعب دوراً متزايد الأهمية من حيث التقدم الاقتصادي والاجتماعي، وبالتالي يعد استهلاك الطاقة مؤشراً اقتصادياً مهماً يعكس التنمية الاقتصادية لمدينة أو بلد ما، لقد أدى الدور الحاسم للكهرباء كعنصر أساسي في عملية تطوير أي بلد إلى زيادة كبيرة في الطلب على الكهرباء والطاقة في العالم.

عملت الجزائر جهوداً كبيرة لتطوير البنية التحتية للكهرباء والغاز وتعزيز وصول الكهرباء لشعبها، ووفقاً للبنك الدولي تم تسجيل نسبة 99.8% من سكان الجزائر يستخدمون الكهرباء في عام 2020، حيث شهدت الجزائر في السنوات الأخيرة ارتفاع استهلاك الكهرباء نتيجة النمو السريع في عدد السكان وكون أسعار الكهرباء مدعومة، لكنه يرجع بصورة أكبر إلى زيادة الأخذ بأساليب التكنولوجيا الحديثة في كل مكان.

وخلال كل هذا، لا تولي الجزائر اهتماماً كبيراً للطاقة المتجددة، وأن المصدر الرئيسي لإنتاج الكهرباء هو الغاز الطبيعي وعليه يتعين على أصحاب القرار تطوير خطط واستراتيجيات من خلال التنبؤ بكمية استهلاك الكهرباء في الجزائر للوصول إلى القيم التنبؤية الصحيحة التي سيتم استخدامها في صنع القرار في المؤسسات الاقتصادية، في هذا السياق سنقوم باستعمال النماذج الشبكات العصبية الاصطناعية والتي تعتبر إحدى فروع الذكاء الاصطناعي التي تستخدم في عملية التنبؤ والتي أثبتت العديد من الدراسات كفاءتها في عملية التنبؤ.

ما مدى فعالية استخدام تقنية الشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية في الجزائر خلال الفترة بين 1980 إلى 2022؟

من أجل الإجابة عن الإشكالية الرئيسية، تم صياغة الفرضية التالية بغية اختبارها:

تتميز الشبكات العصبية الاصطناعية بأداء فعال في عملية التنبؤ باستهلاك الطاقة الكهربائية

وعلى هذا الأساس تستمد هذه الدراسة أهمية بالغة في معرفة واقع استهلاك الطاقة الكهربائية في الجزائر وإبراز قدراتها في مجال الطاقة الكهربائية.

الدراسات السابقة

الطلب على الكهرباء هو مؤشر على الأداء الاقتصادي لبلد ما لأن الطلب على الكهرباء يرتبط ارتباطاً وثيقاً بجميع مراحل التنمية. لذلك، يعد التنبؤ بالطلب على الكهرباء أمراً بالغ الأهمية لإدارة نظام الطاقة والإرسال والتشغيل وتقييم سعة الشبكة.

حيث أن التنبؤ بإستهلاك الكهرباء أصبح أمراً ملحاً وهاماً لأي دولة أو منطقة ، (Shah, Hasnain , & Sajid , 2020 ; Li & Zhang, 2018).

في هذا الصدد، سنلخص بعض الدراسات حول التنبؤ الاستهلاك الطاقة الكهربائية في الجدول الآتي:

جدول (1)

ملخص لبعض الدراسات السابقة

الدراسة	المكان والفترة الدراسة	المنهجية	النتائج
Kavaklioglu et al. (2009)	الدراسة على تركيا بين الفترة 1975 إلى 2006	تطبيق تقنية الشبكات العصبية الاصطناعية من خلال استخدام الإدراك متعدد الطبقات مع خوارزمية تدريب الانتشار العكسي كطوبولوجيا الشبكة العصبية	يمكن نمذجة استهلاك الكهرباء باستخدام الشبكات العصبية الاصطناعية، ويمكن استخدام النماذج للتنبؤ باستهلاك الكهرباء في المستقبل ومن المتوقع أن يصل استهلاك الكهرباء في تركيا إلى 279,36 مليار KWh بحلول عام 2027. وهذا يعني أن استهلاك البلاد سيتضاعف تقريبا في السنوات العشرين المقبلة
Khummongkol et al. (2015)	الدراسة على تايلاند بين الفترة 1989 إلى 2008	تقنية الشبكات العصبية الاصطناعية (ANN) والانحدار الخطي المتعدد بمدخلات الغير الخطية	وفقاً لنتائج التنبؤ بنماذج الانحدار و ANN لهذه الدراسة، فإن استهلاك الكهرباء للبلاد في 2010 و 2015 و 2020 سيصل إلى 160.136 و 188.552 و 216.986 GWh على التوالي لنموذج الانحدار بينما سيصل نموذج ANN إلى 155.917 و 174.394 و 188.137 GWh على التوالي
الثعلبي وعمران (2016)	المنطقة الجنوبية (البصرة، ميسان، وذي قار والمثنى) بالعراق في الفترة ما بين 1971 و 2013	اسلوب الانحدار الخطي المتعدد وطريقة Box-Jenkins وأيضا أسلوب شبكة العصبية الاصطناعية (ANN)	وتوصلت الدراسة أن كمية استهلاك الكهرباء في تزايد مستمر في الفترة المتنبأ بها حيث كانت حوالي 13407,526 GWh سنة 2014 وأصبحت 20480,759 GWh سنة 2023.
جباري (2016)	ولاية تلمسان في الجزائر للفترة الممتدة بين جانفي 2011 وديسمبر 2014 و	تقنية الشبكات العصبية الاصطناعية (ANN)	كانت أقصى قيمة لإستهلاك الكهرباء المتنبأ بها هي لشهر جوان 2015 تقدر ب 554547,4003 MWh وكذلك نفس شهر من سنة 2016 حوالي 537861,069 MWh
عروس (2018)	ولاية بسكرة في الجزائر للفترة الممتدة بين جانفي 2014 إلى ديسمبر 2017	تقنية الشبكات العصبية الاصطناعية (ANN)	وتوصلت هذه الدراسة إلى أن شهر أكتوبر من سنة 2018 هو أكثر استهلاكاً لطاقة كهربائية 272354913,09759 KWh.

أن نماذج التهجين كانت أكثر دقة وملائمة من نماذج ARIMA في التنبؤ باستهلاك الكهرباء في الجزائر وأن استهلاك الطاقة المقدرة بطريقة ARIMA-RBFN كانت بقية 69,15 مليار KWh.	نماذج التهجين التي تجمع بين نماذج ARIMA والنماذج الشبكة العصبية في تقدير التغيرات الخطية و الغير الخطية باستعمال النموذج شبكة دالة الأساس الشعاعي (RBFN).	في الجزائر للفترة من (1980-2019)	ساهد وقهوي (2022)
تشير النتائج إلى أن استهلاك الكهرباء في الجزائر سيكون 76.06 و 94.66 مليار KWh في 2020 و 2025 على التوالي.	تقنية الشبكات العصبية الاصطناعية (ANN)	في الجزائر لفترة زمنية ممتدة من 1980 إلى 2016	Chekouri and Sahed (2022)

المصدر: من إعداد الباحثين

تعريف بالدراسة والمنهجية البحث

قبل دراسة كمية الاستهلاك السنوي للكهرباء في الجزائر والتنبؤ بقيمها المستقبلية، يجب أن نعرف المتغير الدراسة والمنهجية المتبعة.

1.3 تعريف بالدراسة:

في هذه الورقة البحثية، تم استعمال السلسلة الزمنية (Cons) المتمثلة في الكمية المستهلكة السنوية من الكهرباء في الجزائر المقدرة بـ 43 مشاهدة خلال فترة 1980 إلى 2022 حيث تم الحصول على هذه المعطيات من خلال الجدول التالي:

جدول (2)

مصدر البيانات الكمية المستهلكة من الكهرباء في الجزائر المقدرة

الموقع	المصدر
https://ourworldindata.org/	OurWorld in Data
https://ember-climate.org	Ember
/https://www.bp.com	British Petroleum
/https://www.theglobaleconomy.com	TheGlobalEconomy.com
/https://www.iea.org	international energy agency

المصدر: من إعداد الباحثين

2.3. المنهجية البحث:

تعتبر الشبكات العصبية الاصطناعية هي أحد مجالات الذكاء الاصطناعي التي حققت تقدما في طريقة تفكير البشري في شتى المجالات، حيث يتم استعماله في بناء بحوث العمليات والنماذج الإحصائية ونجدها أيضا مستخدمة على نطاق واسع في عمليات التنبؤ مثل التنبؤ بالمبيعات والاستهلاك وغيرها، إذ تعتبر وسيلة مؤكدة للوصول إلى تنبؤات بالقيم المستقبلية.

1.2.3. تعريف الشبكات العصبية الاصطناعية (artificial neural network)

تعددت التعاريف حول مفهوم الشبكات العصبية، ومن بينها:


- الشبكات العصبية الاصطناعية هو نظام معالجة المعلومات الذي يتشابه في بعض الخصائص الشبكات العصبية الطبيعية، وعليه تعتبر عبارة عن تطوير نموذج رياضي يحاكي الإدراك البشري والشبكات العصبية الحيوية. (Fausett, 1994, p. 3)
- هو نموذج رياضي يتكون من الخلايا العصبية المترابطة التي تعالج بيانات الإدخال عبر الاتصالات القائمة على الحوسبة. (Jaromir, 2021, p. 35)
- الشبكات العصبية الاصطناعية (ANN) هي طريقة رياضية تهدف إلى محاكاة الدماغ البشري في عملية اكتساب المعرفة، ولديها تطبيقات ناجحة في رسم خرائط غير الخطية بين المتغيرات المدخلة والمخرجة، والتعرف على الأنماط والتصنيف، والتحسين. (Pereira et al., 2018)

2.2.3. الشبكات متعددة الطبقات

تعتبر من أكثر الشبكات التي تستخدم في التنبؤ بالسلاسل الزمنية تقوم فكرة هذه الشبكة على استخدام القيم السابقة للسلسلة الزمنية كمدخلات للشبكة، تتكون شبكة MLP البسيطة من طبقة الإدخال وطبقة إخراج واحدة وتتضمن طبقة واحدة أو أكثر من الطبقات الخفية، ويمكن لهذه الشبكات حل مشاكل أكثر تعقيدا بالمقارنة بالشبكات وحيدة الطبقة ومن الأمثلة عليها طريقة خوارزمية الانتشار الخلفي التي تعتبر الأكثر استخداما. (ساهد وقهوي، 2022، صفحة 88)

شكل (1)

شبكة متعددة الطبقات MLP



المصدر: ساهد، وقهوي. (2022)، ص 88.

حيث النموذج العام لشبكة MLP التي تستخدم للتنبؤ يكون كالآتي: (الثعلبي وموسى، 2016، ص 445)، حيث أن:

$$\hat{X}(t) = W_0 + \sum_{j=1}^h W_j f_j \left[\sum_{i=1}^n W_{ij} X(K-i) \right] + W_{j0}$$

h: عدد وحدات الطبقات الخفية.

n: عدد وحدات المدخلات.

W_{ij}: الأوزان بين المدخلات والطبقات الخفية.

W_j: الأوزان بين الطبقة الخفية وطبقة المخرجات.

f_j: دالة تحفيز سيغمويد (**sigmoid function**) في الوحدات الخفية **Jth**.

3.2.3. عملية التنبؤ باستخدام الشبكات العصبية الاصطناعية:

تتمثل عملية التنبؤ باستخدام الشبكة العصبية الاصطناعية للسلاسل الزمنية حسب مدوري ومكيديش (2017، ص 165) في الخطوات التالية:

الخطوة الأولى: إختيار المتغيرات من خلال اختيار المشاهدات للمتغيرات بحيث تمثل المشكلة تمثيلا جيدا.

الخطوة الثانية: تشمل البيانات المتاحة مجموعتين:

- مجموعة التدريب: مجموعة تعلم وتحديد نموذج للبيانات
 - مجموعة الاختبار: والتي يمكن عن طريقها تقرير مهارة الشبكة الافتراضية وإمكانية استعمالها بصورة عامة.
- الخطوة الثالثة: نموذج الشبكة العصبية، عند القيام بتحديد النموذج يجب اختبار ما يلي:

- عدد العقد العصبية لإدخال يساوي عدد المتغيرات المستقلة.
- عدد الطبقات الخفية يعتمد على قيمة الخطأ المستخدم في الشبكة.
- تحدد عدد العقد العصبية المخفية من خلال التجربة؛
- طبقة الإخراج تساوي واحد عادة.

الخطوة الرابعة: معايير التقييم، حيث أن المعيار المستعمل في شبكة الإنتشار العكسي هو مجموع مربعات الأخطاء (**MSE**) لتقييم الخطأ.

الخطوة الخامسة: تدريب الشبكة، وتشمل هذه الخطوة:

- تعليم النموذج: إيجاد مجموعة الأوزان بين العقد العصبية التي تحدد أقل قيمة لمربع الخطأ.
- خوارزمية شبكة الإنتشار الخلفي للخطأ: تستخدم خوارزمية التدريب لتقليل الميل.

الخطوة السادسة: التنفيذ تعد أهم الخطوات حيث تختبر الشبكة من حيث قدرة التكيف مع إمكانية إعادة التدريب والوصول إلى أقل مربع خطأ عند تغيير البيانات.

نتائج الدراسة التطبيقية

في السنوات الأخيرة، اكتسبت الشبكات العصبية الاصطناعية (ANN) أهمية كبيرة بين الباحثين. ويعود ذلك بشكل رئيسي إلى أن الشبكات العصبية تمثل العلاقات الخطية وغير الخطية بين المتغيرات (Scarborough and Somers, 2006)

وتشمل طرق الذكاء الاصطناعي مثل شبكات التعلم، والانحدار المستقطب، وأنظمة المنطق المضطرب، والخوارزميات الجينية. على سبيل المثال، يمكن رؤية دراسات تالية: Azadeh et al. (2006); Ghomi, Moeti and Azimi (2011); and Sarkar et al. (2015)

وفيما يتعلق بالجزائر، فإن دراسات التجريبية السابقة حول نمذجة طلب استهلاك الكهرباء محدودة على الرغم من دور طلب استهلاك الكهرباء المركزي في الاقتصاد والجدل حول سياسة دعم الطاقة انظر على سبيل المثال دراسة Bouzmit and al. (2018) وتستخدم هذه الدراسة طريقة نموذج شبكات التعلم لنمذجة وتوقع طلب استهلاك الكهرباء في الجزائر.

1.4. نتائج الدراسة

سوف نتعرف على مختلف النتائج فيما يلي:

1.1.4. التعرف على النموذج المثالي بتقدير الثابت والاتجاه العام كمتغيرات مستقلة للنموذج:

جدول (3)

تقدير النموذج بالثابت والاتجاه العام كمتغيرات مستقلة

المتغير التابع CONS				
طريقة المربعات الصغرى				
نموذج: 2022-1980				
الملاحظات: 43				
المتغير	المعامل	Std. Error	t-Statistic	Prob.
الثابت	-4.378314	2.796314	-1.565745	0.1253
الاتجاه العام	***1.444427	0.117417	12.30170	0.0000

المصدر: من اعداد الباحثين باستعمال EViews 12

من خلال الجدول أعلاه يتضح بأن المعلمة الاتجاه العام معنوية عند المستوى الاحصائي 1% (***) وبالتالي يدخل في عملية النمذجة النماذج ARMA والمدخلات الشبكة العصبية (Input Layer).

2.1.4. كشف عن مركبة الإتجاه العام باستخدام إختبار دانيال Daniel

يتم اختبار كشف عن مركبة الإتجاه العام باستخدام إختبار دانيال Daniel، بحيث نضع الفرضيات الأتية: H_0 : عدم وجود مركبة الإتجاه العام أما H_1 : وجود مركبة الإتجاه العام

ثم حسب حجم العينة لدينا $n = 42 > 30$ وبالتالي يمكن إيجاد قيمة الإحصائية الجدولية للمستوى الاحصائي $\alpha = 5\%$ وهي $z^{\alpha/2} = 1,96$

إيجاد قيمة الإحصائية المحسوبة

$$r_s = 1 - \frac{6 \sum d_i^2}{T(T^2 - 1)} \Leftrightarrow r_s = 0.993$$

$$z_{cal} = r_s \sqrt{T - 1} \Leftrightarrow z_{cal} = 0.993 \sqrt{42 - 1}$$

$$z_{cal} = 6.363$$

اذن من خلال النتيجة الاختبار، نلاحظ بأن القيمة الإحصائية المحسوبة (6,363) أكبر من القيمة الإحصائية المجدولة (1,96) و بالتالي نقبل الفرضية البديلة التي تنص على وجود مركبة الاتجاه العام. اذن بالتالي يتم ادخال المتغير الاتجاه العام في النموذج، عند القيام بذلك تصبح النماذج ARMA أكثر استقراراً وأفضل في عملية التنبؤ.

3.1.4. التعرف واختيار النموذج مثالي للسلسلة الاستهلاك الطاقة الكهربائية:

جدول (4)

النموذج المثالي للشبكة العصبية

النموذج	ARMA(2,0,2)	ARMA(2,0,0)	ARMA(0,0,6)
AIC	3,839	3,628	3,888
SC	4,093	3,797	4,219
HQ	3,931	3,69	4,010
R ²	0,995	0,995	0,995
Log likelihood	-70,791	-68,567	-73,663

المصدر: من اعداد الباحثين باستخدام EViews 12

من خلال الجدول أعلاه يظهر بأن النموذج ARMA(2,0,0) الذي فيه المتغيرين الابطاء أي (Const-1 and Const-2) هو النموذج المثالي كون أنه يحقق أدنى قيمة للمعايير الاختيار النموذج الأمثل. ثم يتم ادخال المتغيرات المدخلات الشبكة العصبية (Input Layer) في النموذج الشبكة العصبية والتي تتمثل في الاتجاه العام، المتغير الابطاء من درجة 1 للاستهلاك الطاقة الكهربائية والمتغير الابطاء من درجة 2 للاستهلاك الطاقة الكهربائية.

2.4. تطبيق طريقة الشبكات متعددة الطبقات (MLP) للتنبؤ:

الخطوة الأولى: تتمثل في تحديد المتغير الاستهلاك الطاقة الكهربائية كمتغير تابع ويكون ضمن طبقة المخرجات أو الإخراج (**Output Layer**)، ثم يتم تحديد النموذج الملائم حسب معايير اختيار نموذج الأمثل، فكانت المتغيرات المستقلة كما يلي الاستهلاك الطاقة الكهربائية بدرجة التأخير 1 و 2 و المتغير الاتجاه العام.

الخطوة الثانية: تتمثل في تحديد عينة التدريب والمكونة من 70% من الملاحظات و 30% تترك لعينة الاختبار.

الخطوة الثالثة: يتم تحديد عدد الطبقات المخفية (**Hidden Layers**) وتحديد الأوزان بالنسبة لكل طبقة، حيث يبين الجدول و الشكل الموالي النموذج الأفضل هو من النوع الشبكات متعددة الطبقات **MLP 3-1-1**، إذ أن نسبة الأداء بالنسبة للتدريب و الاختبار قد تجاوزت 99% و نسبة الأخطاء منخفض جدا يدل على جودة النموذج المختار، كما أن تم تحديد طبقة مخفية واحدة بدالة تنشيط دالة الاساس الشعاعية القوسية (**Activation Function Tangente hyperbolique**) ومشابهة للدالة **Sigmoide**، في حين تم اختيار دالة تنشيط خطية بالنسبة للطبقة الإخراج (**Activation Function identité**).

جدول (5)

ملخص البيانات طريقة الشبكات متعددة الطبقات 1-1-3 MLP

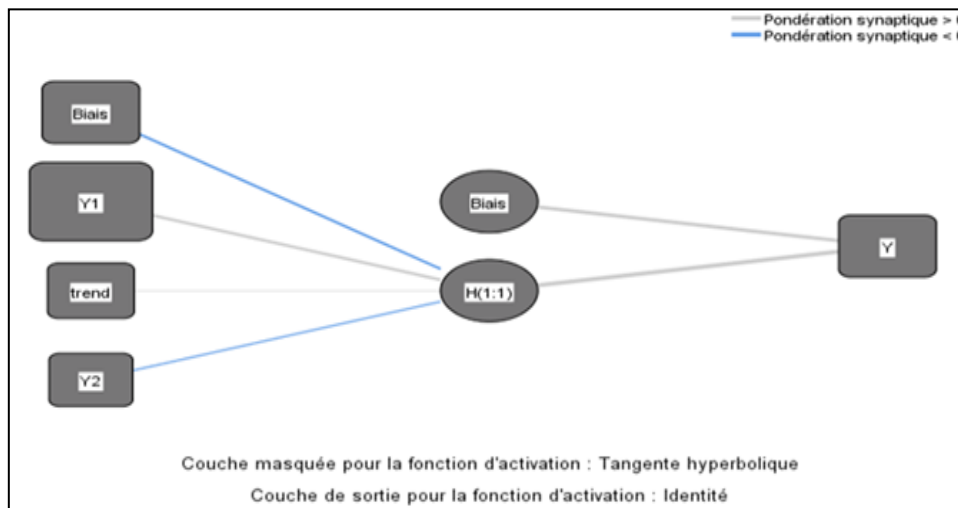
29 (72,5%)	عينة التدريب
99,5%	أداء عينة التدريب
0,056	مجموع مربع الأخطاء
0,004	قيمة مطلقة للخطأ
11 (27,5%)	عينة الاختبار
99%	أداء عينة الاختبار
0,014	مجموع مربع الأخطاء
0,006	قيمة مطلقة للخطأ
دالة الاساس الشعاعية القوسية مشابهة للدالة Sigmoide	دالة طبقة المخفية
دالة خطية	دالة طبقة الإخراج

المصدر: من اعداد الباحثين باعتماد على SPSS 26.

ثم في الشكل الموالي تظهر الشبكة العصبية من النوع الشبكات متعددة الطبقات MLP 3-1-1

شكل (2)

معمارية شبكة دالة متعددة طبقات



المصدر: من اعداد الباحثين باعتماد على SPSS 26

الخطوة الأخيرة: يتم استخراج البيانات المتنبأ بها والتأكد من جودة النموذج، فقد تم تشكيل جدول فيه مخرجات النموذج بدلالة القيم المستهدفة، إذ نلاحظ أن هناك نوعاً ما من تساوي بين قيم مخرجات النموذج أي تساوي بين قيم المستهدفة وقيم المخرجات.

جدول (6)

النتائج طريقة الشبكات متعددة الطبقات

السنوات	الاستهلاك الطاقة الكهربائية	الاستهلاك الطاقة الكهربائية المتنبأ بطريقة شبكات متعددة طبقات
1980	5,92	
1981	6,49734375	
1982	7,0746875	8,23
1983	7,65203125	8,52
1984	8,229375	8,83
1985	8,80671875	9,15
1986	9,3840625	9,5

1987	9,96140625	9,86
1988	10,53875	10,24
1989	11,1160938	10,65
1990	11,6934375	11,07
1991	12,2707813	11,52
1992	12,848125	11,99
1993	13,4254688	12,49
1994	14,0028125	13,01
1995	14,5801563	13,56
1996	14	14,13
1997	14,5773438	13,94
1998	15,1546875	14,87
1999	15,7320313	15,51
2000	16,309375	16,17
2001	16,8867188	16,87
2002	17,4640625	17,6
2003	18,0414063	18,36
2004	18,61875	19,15
2005	19,1960938	19,97
2006	19,7734375	20,82
2007	20,3507813	21,71
2008	19	22,62
2009	24,9675	21,52
2010	30,935	29,78
2011	36,9025	35,32
2012	42,87	41,26
2013	45,2	47,36
2014	49,21	47,97
2015	53,46	53,29
2016	55,82	57,72
2017	60,28	59,27

2018	62,11	64,36
2019	66,65	64,98
2020	69,63375	69,64
2021	72,6175	71,21
2022	74,13	73,59
2023	...	76,83
2024	...	79,47

المصدر: من اعداد الباحثين

من خلال الجدول أعلاه يتبين أنه يوجد ارتفاع في كمية الاستهلاك الكهربائي المتنبأ بها في سنة 2022 بنسبة 2.082% مقارنة مع سنة 2021، وأيضا بالنسبة لكمية الاستهلاك لسنة 2023 ارتفعت بنسبة 3.642% مقارنة مع سنة 2022، ثم زيادة بالنسبة 3.434% بين 2023 و2024.

خاتمة:

تعتبر الطاقة الكهربائية إحدى الدعائم الأساسية لتحقيق التنمية الاقتصادية والاجتماعية على مستوى عالمي في الوقت الحالي والمحرك الأساسي لها، وبالطبع تزداد أهمية هذا المورد خاصة في الجزائر لكونها دولة نامية تسعى لتحقيق تنمية اقتصادية والاجتماعية ومع تعدد الأزمات في مختلف المجالات ولعل أهمها مجال الطاقة الذي أصبح يرهن مستقبل اقتصاديات الدول خاصة كون الطاقة الكهربائية في أغلب الأحوال يتم إنتاجها باستعمال الغاز الطبيعي والذي يعتبر من طاقات غير المتجددة خاصة وباعتبار الجزائر من الدول المنتجة والمصدرة للطاقة الكهربائية يعتبر التنبؤ باستهلاك الكهرباء من النشاطات المهمة جدا خاصة مع تزايد استهلاك الطاقة الكهربائية في الجزائر و هي عملية التي تسبق عملية تخطيط الإنتاج حيث هو نظرة مستقبلية لما ستكون عليه قيم الظاهرة المدروسة وهذا بالاعتماد على قيمها ماضية أو العوامل المؤثرة فيها و هنا تظهر بوضوح أهمية عملية التنبؤ من خلال استعمال الطرق الكمية لضمان فعالية في الإنتاج وتقادي الانقطاعات المتكررة لهذا المورد الاستراتيجي

تم التنبؤ باستهلاك الطاقة الكهربائية بالاعتماد على تقنية الشبكات العصبية (ANN) من خلال أحد أساليبها والتي هي الشبكات العصبية المتعددة الطبقات (MLP)، وكانت مدخلات الشبكة العصبية تتمثل في استهلاك الطاقة الكهربائية عند الفروق الأولى والثانية إضافة إلى الإتجاه العام، تم التوصل إلى أن النوع الشبكات متعددة الطبقات MLP 3-1-1 يتميز بنسبة الأداء تتجاوز 99% بالنسبة لكل من التدريب والاختبار و نسبة الأخطاء منخفض جدا هذا ما يعكس جودة النموذج المختار هو بدوره أثبت قدرته على التنبؤ باستهلاك الطاقة الكهربائية في الجزائر.

باستعمال الشبكات العصبية الاصطناعية متعددة الطبقات (MLP) تم التوصل إلى أن النموذج الأفضل هو -3 MLP
1-1 والقيم المتنبأ بها لسنة 2023 هي 76,83 مليار TWh وشهدت زيادة استهلاك الطاقة بنسبة 3.642% في سنة
2024 بقيمة 79,47 مليار TWh.

كما تم دراسة مختلف العمليات التنبؤ باستعمال تقنية الشبكات العصبية واستنتاج بأنها هي من بين الطرق المثالية في هذا
المجال، ففي هذه الورقة العلمية، وبعد تطبيق تقنية الشبكات العصبية الاصطناعية ومنهجها، تظهر بأنها هي الأنسب
للتنبؤ بالاستهلاك السنوي للطاقة الكهربائية في الجزائر أي أنها تتميز بأداء فعال في عملية التنبؤ باستهلاك الطاقة
الكهربائية، وهذا ما يثبت صحة الفرضية.

قائمة المراجع:

- الثعلبي، ساهرة حسين زين وعمران، خلود موسى. 2016. تحديد أفضل نموذج للتنبؤ باستهلاك الطاقة الكهربائية في المنطقة الجنوبية. مجلة العلوم الاقتصادية والإدارية، مج. 22، ع. 90، ص ص. 437-457.
<https://search.emarefa.net/detail/BIM-699721>
- جباري، ل.(2016). طرق اتخاذ القرار باستخدام الذكاء الاصطناعي: دراسة مقارنة للتنبؤ بالطاقة الكهربائية لولاية تلمسان باستعمال الشبكات العصبية الاصطناعية، العلوم الاقتصادية، أطروحة لنيل شهادة الدكتوراة تخصص بحوث العمليات وتسيير المؤسسات، جامعة أبي بكر بلقايد تلمسان. <http://dspace.univ-tlemcen.dz/bitstream/112/8806/1/sonelgaz-prevision-decision-charge-electrique-intelligence-artificielle-neurones-box-jenkins.Doc.pdf>
- عتروس، سهيلة. (2018). استخدام منهجية جنكز والشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية بمؤسسة سونلغاز - دراسة حالة ولاية بسكرة -، أطروحة دكتوراه في علوم التسيير، جامعة بسكرة، الجزائر. <http://thesis.univ-biskra.dz/4485/1/Th%C3%A8se%20Atrous%20Souheila.pdf>
- ساهد، عبد القادر، وقهوي، حسين. (2022). النهجين بين شبكة دالة الأساس الشعاعية Rbfn ونماذج Arima في التنبؤ باستهلاك الكهرباء في الجزائر للفترة 1980-2019، تنمية الموارد البشرية، 17، 2، (2022)، ص 495-514.
<https://www.asjp.cerist.dz/en/article/192969>
- مدوري، حادة، ومكيديش، محمد. (2017). دراسة مقارنة بين نماذج الطويلة ARFIMA والشبكات العصبية الاصطناعية بالتنبؤ بسعر صرف الدينار الجزائري، مجلة الباحث، 17، 17. <https://www.asjp.cerist.dz/en/article/34422>
- Azadeh, Ghaderi and Gitiforouz. (2006). Estimating Electricity Demand Function in Residential Sector by Fuzzy Regression, IEEE ISIE 2006, July 9-12, Montreal, Quebec, Canada. doi: 10.1109/ISIE.2006.295625.
- Bouznit, Pablo-Romero and Sánchez-Braza. (2018). Residential Electricity Consumption and Economic Growth in Algeria, Energies, 11, 1656. <https://doi.org/10.3390/en11071656>
- Chekouri, S.M, and Sahed, A. (2022). Forecasting Electricity Consumption In Algeria Using Artificial Neural Networks, مجلة روى اقتصادية, 12, 1, p. 247-261. <https://www.asjp.cerist.dz/en/article/205040>
- Fausett, Laurene. (1994). *Fundamentals of neural networks: architectures algorithms, and applications*, USA: Prentice-Hall, Inc. [https://dl.matlabyar.com/siavash/Neural%20Network/Book/Fausett%20L.-Fundamentals%20of%20Neural%20Networks_%20Architectures,%20Algorithms,%20and%20Applications%20\(1994\).pdf](https://dl.matlabyar.com/siavash/Neural%20Network/Book/Fausett%20L.-Fundamentals%20of%20Neural%20Networks_%20Architectures,%20Algorithms,%20and%20Applications%20(1994).pdf)

- Ghomi, Moeti and Azimi. (2011). Introduction of Neural Network Model and Fuzzy Regression Method for Short Term Load Forecasting in The Center Regional of IRAN, 2011 International Conference on Network and Electronics Engineering IPCSIT vol.11 © IACSIT Press, Singapore.
- Jaromir, Vrbka. (2021). Using Artificial Neural Networks for Timeseries Smoothing and Forecating: Case Studies in Economics, Institute of Technology and Business in Ceske, Volume 979. <https://doi.org/10.1007/978-3-030-75649-9>
- Kavaklioglu, K, Ceylan, H, Ozturk, H.K, and Canyurt, O.E. (2009). Modeling and prediction of Turkey's electricity consumption using Artificial Neural Networks, Energy Conversion and Management, Volume 50, Issue 11, Pages 2719-2727, <https://doi.org/10.1016/j.enconman.2009.06.016>
- Li, Kai, and Tao Zhang. (2018). Forecasting Electricity Consumption Using an Improved Grey Prediction Model, Information 9, no. 8, 204. <https://doi.org/10.3390/info9080204>
- Panklib, K, Prakasvudhisarn, C, and Khummongkol, D. (2015). Electricity Consumption Forecasting in Thailand Using an Artificial Neural Network and Multiple Linear Regression, Energy Sources, Part B: Economics, Planning, and Policy, 10, 4, 427-434, <https://doi.org/10.1080/15567249.2011.559520>
- Pereira, F., Lou, B., Pritchett, B. et al. (2018). Toward a universal decoder of linguistic meaning from brain activation. Nat Commun 9, 963. <https://doi.org/10.1038/s41467-018-03068-4>
- Sarkar, Rabbani, Khan and Hossain. (2015). Electricity Demand Forecasting of Rajshahi City in Bangladesh Using Fuzzy Linear Regression Model, 2nd Int'l Conf. on Electrical Engineering and Information & Communication Technology (ICEEICT) Jahangirnagar University, Dhaka-1342, Bangladesh, 21-23 May 2015. <http://dx.doi.org/10.1109/ICEEICT.2015.7307424>
- Scarborough, D., & Somers, M. J. (2006). Neural networks in organizational research: Applying pattern recognition to the analysis of organizational behavior. American Psychological Association. <https://doi.org/10.1037/11465-000>
- Shah, Ismail, Hasnain Iftikhar, and Sajid Ali. (2020). Modeling and Forecasting Medium-Term Electricity Consumption Using Component Estimation Technique, Forecasting, 2, no. 2, 163-179. <https://doi.org/10.3390/forecast2020009>

Transliteration of Arabic References :

- Al-Thaalabī, s.h.z., and Omran, K.M. (2016). taḥdīd afḍal namūdhaj lltbnw' bāsthlāk al-ṭāqah al-kahrabā'iyah fī al-Miṭṭāqah al-janūbīyah. Journal of Economics And Administrative Sciences 22 (90), 437-457. <https://search.emarefa.net/detail/BIM-699721>
- Atrousse, S. (2018). istikhḍām manhajīyah jknz wa-al-shabakāt al-‘aṣabīyah alāṣṭnā‘yh lltbn' bāsthlāk al-ṭāqah al-kahrabā'iyah bi-Mu'assasat swnlghāz-dirāsah ḥālat Wilāyat Baskarah-, uṭrūḥat duktūrāh fī ‘ulūm al-tasyīr, Jāmi‘at Baskarah, al-Jazā'ir. <http://thesis.univ-biskra.dz/4485/1/Th%C3%A8se%20Atrousse%20Souheila.pdf>
- Djabari, L. (2016). Ṭuruq ittikhādh al-qarār bi-istikhḍām al-dhakā' alāṣṭnā'y : dirāsah muqāranah lltbn' bāltāqh al-kahrabā'iyah li-Wilāyat Tilimsān bi-isti'māl al-Shabakāt al-‘aṣabīyah alāṣṭnā'yh, al-‘Ulūm al-iqtisādīyah, uṭrūḥat li-nayl shahādat al-Duktūrāh takhaṣṣuṣ Buḥūth al-‘amalīyāt wtsyyr al-mu'assasāt, Jāmi‘at Abī Bakr Balqāyid Tilimsān. <http://dspace.univ-tlemcen.dz/bitstream/112/8806/1/sonelgaz-prevision-decision-charge-electrique-intelligence-artificielle-neurones-box-jenkins.Doc.pdf>
- Madouri, H., and Mékidiche, M. (2017). dirāsah muqāranah bayna bayna al-namādhij al-Ṭawīlah ARFIMA wa-al-shabakāt al-‘aṣabīyah alāṣṭnā'yh bāltbn' bs'r ṣarf al-dīnār al-Jazā'irī. El-Bahith Review 17 (17), 159-171. <https://www.asjp.cerist.dz/en/article/34422>

-
- Sahed, A., and Kahoui, H. (2022). althjyn bayna Shabakah dāllah al-Asās alsh‘ā‘yh Rbfn wa-namādhij Arima fī al-tanabbu’ bāsthlāk al-kahrabā’ fī al-Jazā’ir lil-fatrah 1980-2019. Human Resources Development 17 (2), 495-514. <https://www.asjp.cerist.dz/en/article/192969>