



**Tikrit Journal of Administrative
and Economics Sciences**
مجلة تكريت للعلوم الإدارية والاقتصادية

ISSN: 1813-1719 (Print)



**Comparison between prediction of demand for electric power using
artificial intelligence techniques and traditional methods (ARIMA)
A case study in the diesel station north of Al-Amarah to generate
electric power**

Salah Kadim Abd-AlHassin*, Nagham Yousif Abd-Alreda

College of Administration and Economics, University of Baghdad

Keywords:

Forecasting, Artificial Intelligence
Techniques, North Amara Diesel Power
Plant.

ARTICLE INFO

Article history:

Received 09 Dec. 2022

Accepted 18 Dec. 2022

Available online 31 Mar. 2023

©2023 THIS IS AN OPEN ACCESS ARTICLE
UNDER THE CC BY LICENSE

<http://creativecommons.org/licenses/by/4.0/>



***Corresponding author:**

Salah Kadim Abd-AlHassin

College of Administration and
Economics, University of Baghdad



Abstract: The research aims to predict the demand for electric energy through the use of artificial intelligence techniques to predict the future demand for energy in the diesel station north of Al-Amarah to generate electric power. Which suffers from the problem of uncertainty in the demand for future energy, due to weakness in knowing future loads, which leads to lack of planning Correct scheduling of productive operations and management of maintenance work, and thus a decrease in the reliability of the system.

Especially since it is boosting the capacity of the national network in the main roles (continuous, peak, and reserve), and this made it more difficult to predict the demand for future loads with high accuracy. As artificial intelligence techniques and traditional techniques were used in the completion of the study. As the researcher used the traditional model ARIMA in the program SPSS and the neural group data processing model (GMDH) of the type of neural network (ANN), and the neural network model of the feed-forward backprop type to predict energy. Demand based on historical data of daily electrical loads for the period from 1/1/2019 to 31/12/ 2021, as the data volume reached (1096) per day.

The research reached a set of results, the most important of which is obtaining prediction values for the future demand for energy for a month starting from 1/1/2022 to 31/1/2022 for the station, as the neural network model GMDH gave the lowest value of the mean absolute relative error (MAPE) of 0.0567. While the feed-forward backprop method gave a mean absolute relative error (MAPE) of 0.0648, and the traditional ARIMA model gave a mean absolute relative error (MAPE) of 0.0654, as the obtained results show the effectiveness of the GMDH-type neural network model in prediction.

المقارنة بين التنبؤ بالطلب على الطاقة الكهربائية باستخدام تقنيات الذكاء الاصطناعي والطرق التقليدية (ARIMA) دراسة حالة في محطة ديزلات شمال العماره لتوليد الطاقة الكهربائية

نغم يوسف عبدالرضا

صلاح كاظم عبدالحسن

كلية الإدارة والاقتصاد، جامعة بغداد

المستخلص

يهدف البحث إلى التنبؤ بالطلب على الطاقة الكهربائية من خلال استخدام تقنيات الذكاء الاصطناعي للتنبؤ بالطلب المستقبلي على الطاقة في محطة ديزلات شمال العماره لتوليد الطاقة الكهربائية والتي تواجه مشكلة عدم التأكد بالطلب على الطاقة المستقبلية، بسبب ضعف في معرفة الاحمال المستقبلية، الذي يؤدي إلى عدم التخطيط الصحيح لجدولة العمليات الإنتاجية وإدارة أعمال الصيانة وبالتالي انخفاض في موثوقية النظام.

سيما أنها معززة لطاقة الشبكة الوطنية في الأدوار الرئيسية (المستمرة، والذروة، والاحتياطي)، وهذا ما زاد من صعوبة التنبؤ بالطلب على الاحمال المستقبلية بدقة عالية، إذ تم استعمال تقنيات الذكاء الاصطناعي والتقنيات التقليدية في انجاز الدراسة، إذ استخدم الباحث النموذج التقليدي ARIMA في برنامج SPSS ونموذج المجموعة العصبية لمعالجة البيانات (GMDH) من نوع الشبكة العصبية (ANN)، ونموذج الشبكة العصبية من نوع Feed-forward backprop للتنبؤ بالطلب على الطاقة بالاعتماد على البيانات التاريخية للأحمال الكهربائية اليومية للفترة من 2019/1/1 وتنتهي بالفترة 2021/12/31 إذ بلغ حجم البيانات (1096) يومياً.

توصل البحث إلى مجموعة من النتائج أهمها الحصول على قيم التنبؤ بالطلب المستقبلي للطاقة لمدة شهر يبدأ بالفترة من 2022/1/1 ولغاية 2022/1/30 للمحطة، إذ أعطى نموذج الشبكة العصبية GMDH أقل قيمة لمتوسط الخطأ النسبي المطلق (MAPE) مقداره 0.0567 بينما أعطت طريقة Feed-forward backprop متوسط الخطأ النسبي المطلق (MAPE) مقداره 0.0648، وكما أعطى النموذج التقليدي ARIMA متوسط الخطأ النسبي المطلق (MAPE) مقداره 0.0654. إذ تظهر النتائج التي تم الحصول عليها فعالية نموذج الشبكة العصبية من نوع GMDH في التنبؤ. **الكلمات المفتاحية:** التنبؤ، تقنيات الذكاء الاصطناعي، محطة ديزلات شمال العماره لإنتاج الطاقة الكهربائية.

المقدمة:

أصبحت دراسة استهلاك الطاقة موضوع بحث مهم في السنوات الأخيرة، إذ تعد قضايا الطاقة حيوية لأمن ورفاهية المجتمع، ووفقاً للنظرية الاقتصادية، تعد الطاقة أحد أهم موارد الإنتاج الصناعي، ويعد التنبؤ باستهلاك الطاقة مرحلة مهمة في التخطيط الشامل لقطاعي الصناعة والطاقة، ويجب أن يفي التخطيط طويل الأجل للعرض والطلب على الطاقة بمتطلبات التنمية المستدامة للبلدان، ويمكن أن تساعد التنبؤات الدقيقة صانعي القرار على فهم حجم واتجاه استهلاك الطاقة في المستقبل، وحتى يتمكنوا من جدولة وتخطيط تشغيل أنظمة الإمداد بشكل أفضل، وأيضاً أهمية التنبؤ بالحمل على المدى القصير (Short Time Load Forecasting (STLF)، كونه أحد العوامل المهمة في إدارة أنظمة الطاقة الكهربائية، إذ يمكن أن يؤدي التنبؤ الدقيق بالحمل على المدى القصير (STLF)

إلى الاختيار الصحيح لمقدار الهامش الاحتياطي للطاقة، مما يساهم في تحسين كفاءة مصدر الطاقة، ويساعد STL في التحكم في أنظمة الطاقة وجدولتها. لذلك، فإن استخدام النماذج للتنبؤ بدقة باتجاهات استهلاك الطاقة في المستقبل وخاصة البيانات غير الخطية، يعد قضية مهمة لإنتاج الطاقة وأنظمة التوزيع.

إذ تتنافس نماذج الشبكة العصبية مع طرق التنبؤ التقليدية للتنبؤ بالطلب على الطاقة، كونها تعطي نتائج دقة أفضل في كثير من الحالات، إذ اهتم الباحثون بتطوير طرق مختلفة لعمل تنبؤات باستخدام الشبكات العصبية كواحدة من أحدث الطرق المستخدمة، ولا يزال البحث في هذا المجال جاريًا لتحقيق في فعالية هذا النهج، إذ تسمح معظم الشبكات العصبية بالتعلم من الخبرات والتجارب السابقة لاستنتاج خبرات جديدة، وتستخدم كأدوات لتحليل البيانات في نفس المجالات التي تغطيها الأساليب الإحصائية التقليدية، إذ توفر الشبكات العصبية طريقة مناسبة لتمثيل العلاقات بين المتغيرات والتي تختلف عن الطرق التقليدية وتعد أداة إحصائية حديثة، والتحليلات التنبؤية تدرس البيانات السابقة للظاهرة لتحديد النمط العام للظاهرة في المستقبل، وهذه إحدى العمليات الأساسية للشبكات العصبية، التعرف على الأنماط وتحليلها.

لذلك ظهرت فكرة البحث الرئيسة باستعمال تقنيات الذكاء الاصطناعي والتقنيات التقليدية للتنبؤ بالطلب اليومي على الطاقة الكهربائية لمحطة ديزلات شمال العمارة لإنتاج الطاقة الكهربائية ومقارنة النتائج واختيار النموذج الأكثر دقة، إذ يعد التنبؤ بمتغيرات نظام الطاقة الكهربائية أمرًا حيويًا للعديد من الوظائف التشغيلية والتخطيطية. وسيتم تقسيم البحث على: المبحث الأول: منهجية البحث، المبحث الثاني: الإطار النظري، المبحث الثالث: الجانب العملي، المبحث الرابع: الاستنتاجات والتوصيات وكالاتي:

المبحث الأول: منهجية البحث

أولاً. المشكلة البحث: تتجسد مشكلة البحث الرئيسية في عدم التأكد بالطلب على الطاقة المستقبلية ومشكلة جدولة العمليات الانتاجية (التزام الوحدة)، بسبب الضعف في معرفة الاحمال المستقبلية في محطة ديزلات شمال العمارة (عينة الدراسة)، والذي يؤدي بدوره إلى عدم التخطيط الصحيح لجدولة العمليات الإنتاجية وإدارة أعمال الصيانة وبالتالي انخفاض في موثوقية النظام وعدم توفر احتياطي مناسب في المحطة، بسبب عدم التأكد بالطلب على الطاقة الكهربائية وما يترتب عليه عدم الدقة بنتائج التنبؤ بالطاقة الكهربائية للمحافظة. ويمكن أن تلخص مشكلة البحث من خلال اثاره الأسئلة الآتية:

1. هل تتمكن طرق التنبؤ بالطلب باستخدام الشبكات العصبية في الوصول إلى تنبؤات دقيقة مقارنة بالنماذج التقليدية.
2. هل سيسهم التنبؤ بالطلب على الطاقة الكهربائية على المدى القصير باستخدام تقنيات الذكاء الاصطناعي في التخلص من حالة عدم التأكد بالطلب المستقبلي للطاقة الكهربائية.
3. ما المعوقات التي تواجهها المنظمة المبحوثة في مجال تبني تطبيقات الذكاء الصناعي للتنبؤ بالطلب؟
4. ما نوع أسلوب التنبؤ بالطلب المستعمل حالياً في المنظمة المبحوثة؟

ثانياً. أهمية البحث: تتجسد أهمية البحث من كونها تعالج مشكلة أساسية تمس كل مواطن عراقي ألا وهي التذبذب في تجهيز الطاقة الكهربائية والانقطاعات المستمرة، لذا تناول البحث التنبؤ بالطلب لما له من دور مهم في إدارة أنظمة الطاقة، ولتساعد محطة ديزلات شمال العمارة لإنتاج الطاقة الكهربائية (عينة البحث) في التخلص من حالة عدم التأكد، ومواجهة التذبذب والانقطاع المستمر كون عينة


البحث معززة للشبكة الوطنية للأدوار الرئيسية (الذروة، المستمرة، الاحتياطي)، وتتجلى أهمية البحث الحالي من الآتي:

1. ستسهم النماذج المستعملة في التنبؤ بالطلب بمساعدة المحطة على إدارة انتاج الطاقة الكهربائية لتلبية متطلبات الذروة دون الحاجة إلى فصل الاحمال أو انقطاع التيار الكهربائي.
2. ستكون المحطة قادرة على التخلص من عدم التأكد وتصبح قادرة على فهم متطلبات الاحمال الحالية والمستقبلية لتكون قادرة على وضع الخطط والاستثمارات المناسبة.

ثالثاً. أهداف البحث: يهدف البحث إلى ما يأتي:

1. الحصول على تنبؤات دقيقة للحمل قصير المدى بأجراء مقارنة بين نماذج الشبكات العصبية الاصطناعية والنماذج التقليدية.
2. تقليل مستوى عدم التأكد بالطلب على الطاقة الكهربائية على المدى القصير.
3. الحفاظ على قدرة النظام لتلبية الطلب على الطاقة.

رابعاً. المخطط الاجرائي للبحث:



الشكل (1) المخطط الاجرائي للبحث

المصدر: اعداد الباحثين.

خامساً. الأساليب المستخدمة للتنبؤ بالطلب على الطاقة:

1. الطريقة التقليدية (ARIMA) باستعمال برنامج SPSS
 2. طريقة (Feed-forward backprop) باستخدام أداة (nntool Box) في برنامج MATLAB
 3. طريقة المجموعات العصبية لمعالجة البيانات GMDH من نوع ANN.
- سادساً. أدوات جمع البيانات:** اعتمد الباحث على عدد من الوسائل للحصول على البيانات والمعلومات المطلوبة وأهمها:

أ. **المقابلات الشخصية:** تمثل المقابلات الشخصية من الأدوات الفاعلة في جمع البيانات والمعلومات لأنها تساعد الباحث في الحصول على المعلومات بصورة مباشرة من المهندسين والفنيين العاملين

في المحطة، وكذلك تفسح المجال في الوقت نفسه أمام الباحث في معرفة واكتشاف معلومات جديدة تسهم في التعرف على مواطن الخلل في المحطة المبحوثة في تطبيق موضوع البحث.

ب. **الملاحظة:** تعد وسيلة من وسائل الدراسة العلمي وهي المراقبة والملاحظة الدقيقة لسلوك أو ظاهرة معينة في ظل ظروف العمل من أجل الحصول على المعلومات المطلوبة، اعتمد الباحث على الملاحظة وتسجيل المعلومات المهمة الداعمة للبحث إلى جانب المقابلات الشخصية.

ج. **السجلات والتقارير الصناعية:** تتمثل بالسجلات والتقارير السنوية أو الشهرية أو اليومية المتعلقة باستهلاك الطاقة الكهربائية والوقود (البيانات التاريخية) لمحطة ديزلات شمال العمارة الواقعة في محافظة ميسان.

سابعاً. **الحدود الزمانية:** تشمل المدة التي قضاها الباحث في اعداد الدراسة، وتمثل بالمدة الزمنية منذ تاريخ تسمية مشرف وتحديد عنوان بتاريخ 2021/11/26 لغاية تاريخ تسليم الرسالة 2022/11/14، والمتضمنة متطلبات الدراسة بدءاً من اعداد الجانب النظري مروراً بالجانب التطبيقي.

ثامناً. **مجتمع وعينة البحث:** تمثل الشركة العامة لإنتاج الطاقة الكهربائية للمنطقة الجنوبية الواقعة في محافظة البصرة والتي هي مسؤولة على جميع محطات انتاج الطاقة في المنطقة الجنوبية مجتمعاً للدراسة وبضمنها محطة ديزلات شمال العمارة (STX) الواقعة في محافظة ميسان، والتي تم اختيارها عينة للبحث.

المبحث الثاني: الإطار النظري

أولاً. التنبؤ:

1. **مفهوم التنبؤ:** التنبؤات هي مدخلات أساسية في عمليات اتخاذ القرار لإدارة العمليات لأنها توفر معلومات عن الطلب المستقبلي، الهدف الأساسي لإدارة العمليات هو مطابقة العرض مع الطلب، ويعد التنبؤ بالطلب أمراً ضرورياً لتحديد مقدار الطاقة أو العرض المطلوب لتلبية الطلب. (Stevenson, 2015: 75) وهو توقع للأحداث المستقبلية المستخدمة لأغراض التخطيط، والتخطيط، في المقابل، هو عملية اتخاذ قرارات الإدارة حول كيفية توزيع الموارد للاستجابة بشكل أفضل لتوقعات الطلب، إذ تعتمد طرق التنبؤ على النماذج الرياضية التي تستخدم البيانات التاريخية المتاحة، أو على الأساليب النوعية التي تعتمد على الخبرة الإدارية والأحكام، أو مزيج من الاثنين معاً (Krajewski & Malhotra, 2022: 314).
2. **أهمية التنبؤ:** يعتبر التنبؤ بالطلب المنتج هو الخطوة الأولى والتي تمثل حجر الزاوية لبناء التخطيط السليم للإنتاج والرقابة عليه، حيث إنه إذا كان التنبؤ بالطلب قد بني بأسس علمية وموضوعية تمت عملية التخطيط والرقابة بذات الموضوعية والدقة، وأما في حالة ما بُني التقدير على أسس خاطئة فسوف ينعكس ذلك سلباً على عمليات التخطيط والرقابة، ولا شك أن تسلسل خطوات العملية التخطيطية للإنتاج نجده اتسم بالتدرج من تقدير الطلب ودراسة حجم المخزون الحالي، ومن ثم تحديد رقم الإنتاج المتوقع (المعربي، 2018: 63)، يوفر التنبؤ لمدير العمليات الأساس لاتخاذ القرارات فيما يتعلق بالتخطيط المستقل للطلب والجدولة ولتخفيف المخاطر وعدم التأكد، وتعد التنبؤات ضرورية لكل عمل وتساهم في كل قرار إداري مهم تقريباً، يوفر التنبؤ الأساس للتخطيط المؤسسي طويل الأجل وللإجراءات قصيرة المدى (Kamauff, 2010: 147).
3. **الأفق الزمني للتنبؤ:** يعتمد نوع طريقة التنبؤ التي يجب استخدامها على عوامل عدة، بما في ذلك الأفق الزمني للتنبؤ (أي إلى أي مدى يتم التنبؤ في المستقبل) وسلوك الطلب والوجود المحتمل

للأنماط (الاتجاهات، الموسمية، وهكذا) وعادة ما يتم تصنيف التنبؤات حسب الأفق الزمني المستقبلي الذي تغطيه (Russel&Taylor, 2011: 499).

وقد أوضح (Heizer et al., 2020: 140) أن الأفق الزمني ينقسم على ثلاث فئات:
 أ. **التنبؤ قصير المدى Short Term**: يمتد لفترة زمنية تصل إلى سنة واحدة ولكن بشكل عام أقل من 3 أشهر، إذ يتم استخدامه لتخطيط الشراء وجدولة الوظائف ومستويات القوى العاملة وتعيينات الوظائف ومستويات الإنتاج.

ب. **التنبؤ متوسط المدى Medium Term**: يمتد بشكل عام من 3 أشهر إلى 3 سنوات، لذلك يعد مفيد في تخطيط المبيعات وتخطيط الإنتاج والميزنة النقدية وتحليل خطط التشغيل المختلفة.

ج. **التنبؤ بعيد المدى Long Term**: التنبؤ بعيد المدى يمتد بشكل عام من 3 سنوات أو أكثر في المدى الزمني، إذ يتم استخدام التنبؤات بعيدة المدى في التخطيط لمنتجات جديدة، والنفقات الرأسمالية، وموقع المنشأة أو التوسع، والبحث والتطوير.

ثانياً. الذكاء الاصطناعي:

1. **مفهوم الذكاء الاصطناعي**: هو قدرة الآلة على تقليد السلوك البشري الذكي، وتحديد معنى الذكاء هو التحدي الأكبر، بينما نتفق جميعاً على أن الذكاء له علاقة بالمعرفة والقدرة على التفكير، وهو مجموع القدرات العقلية التي يستخدمها الفرد لمواجهة المواقف الجديدة، والتفكير المنظم في البحث المؤدي إلى المعرفة الاستدلالية. (Rose, D, 2018: 20).

من هذا المنطلق، يعرف الباحثين مفهوم الذكاء الاصطناعي هو القدرة في الحصول على المعلومات واستخدامها لتحقيق الأهداف استناداً إلى مجموعة محددة من القواعد (الخوارزميات) لحل مشكلة ما.

2. **أهمية الذكاء الاصطناعي**: يحظى الذكاء الاصطناعي (AI) في الوقت الحالي باهتمام كبير من الباحثين وصانعي السياسات، ويصف الذكاء الاصطناعي سلسلة من التقنيات التي يستخدمها البشر للقيام بالأعباء الثقيلة المطلوبة في عصر مجموعات البيانات الكبيرة والتحليلات الحسابية. وتتراوح إمكاناته من تحديد الارتباطات في مجموعات البيانات التي يتعذر إدراكها للعقل البشري إلى زيادة كفاءة الإنتاج عبر مجموعة من التطبيقات الاصطناعية (Pihlajarinne & Savikko, 2022: 8). وتكمن أهمية عندما تكون هناك حاجة لاتخاذ قرارات العمل الحاسمة، إذ إن الذكاء الاصطناعي يمكن أن يلعب دوراً حيوياً في هذه العملية، ومع كل تطبيق أو حالة استخدام، يصبح الذكاء الاصطناعي أفضل وأفضل، ويتعلم المزيد من أجل اتخاذ القرارات الصائبة، إذ إن هناك حاجة إلى الذكاء الاصطناعي لإدارة أنظمة الطاقة الكهربائية.

المبحث الثالث: الجانب العملي

أولاً: الطرق المستخدمة للتنبؤ بالطلب على الطاقة هي:

1. **الطريقة التقليدية (ARIMA)** باستعمال برنامج SPSS: تم استعمال الطريقة التقليدية المتمثلة بنموذج الانحدار الذاتي والمتوسط المتحرك المتكامل (Autoregressive (ARIMA) Integrated Moving Average Model للتنبؤ بالطلب على الطاقة الكهربائية في برنامج SPSS، بعد ادخال البيانات التاريخية للطلب على الطاقة وبيانات الأنواء الجوية والبالغة (1096

مشاهدة) في برنامج SPSS، إذ تم تطبيق العديد من التجارب للاختيار بين النماذج باستعمال مقياس متوسط الخطأ النسبي المطلق MAPE للمقارنة بين قيم التنبؤ والقيم الفعلية للنماذج واختيار أفضل النماذج الذي يحقق أقل MAPE، وبعد اجراء التجارب تم اختيار افضل ثلاثة نماذج وكما هو موضح في الجدول رقم (1).

الجدول (1): أفضل نتائج التنبؤ باستعمال الطرق التقليدية

التاريخ	القيم الحقيقية	أفضل النماذج التقليدية بـ (SPSS)		
		EXPERT MODELER- ARIMA (0,1,5)	ARIMA (0,0,20)	ARIMA (0,0,15)
		Forecasted	Forecasted	Forecasted
01/01/2022	140	145	144	144
02/01/2022	140	145	141	140
03/01/2022	140	145	141	137
04/01/2022	136	145	138	135
05/01/2022	140	144	137	133
06/01/2022	138	144	135	131
07/01/2022	145	144	136	129
08/01/2022	135	144	132	126
09/01/2022	142	144	132	125
10/01/2022	137	144	129	123
11/01/2022	137	143	129	123
12/01/2022	136	143	127	122
13/01/2022	140	143	127	121
14/01/2022	138	143	125	120
15/01/2022	134	143	125	118
16/01/2022	137	142	123	118
17/01/2022	142	142	122	118
18/01/2022	137	142	120	117
19/01/2022	143	142	120	118
20/01/2022	134	142	119	118
21/01/2022	146	142	119	118
22/01/2022	131	142	118	118
23/01/2022	142	142	119	118
24/01/2022	132	142	119	118
25/01/2022	137	142	118	118

التاريخ	القيم الحقيقية	أفضل النماذج التقليدية بـ (SPSS)		
		EXPERT MODELER- ARIMA (0,1,5)	ARIMA (0,0,20)	ARIMA (0,0,15)
		Forecasted	Forecasted	Forecasted
26/01/2022	121	142	118	118
27/01/2022	120	142	118	118
28/01/2022	118	142	118	118
29/01/2022	121	142	118	118
30/01/2022	113	142	118	118
نسبة الخطأ	MAPE	0.0654	0.0709	0.0904

اعداد الباحثين بالاعتماد على برنامج SPSS.

يظهر الجدول رقم (1) أفضل النماذج التقليدية بعد اجراء مجموعة من التجارب باستعمال برنامج SPSS، إذ يظهر النموذج Expert Modeler-ARIMA (0,1,5) أفضل أداء من خلال مقياس متوسط الخطأ النسبي المطلق MAPE بين قيم التنبؤ والقيم الفعلية بمقدار (0.0654) ويسمى هذا النموذج مصمم النماذج الخبير في SPSS هو أداة يمكن استخدامها لتحديد نموذج ARIMA المناسب بناءً على البيانات تلقائياً، إذ تتبع الأداة سلسلة من الخطوات للعثور على نموذج ARIMA المناسب للسلسلة الزمنية الأساسية.

2. طريقة (Feed-forward backprop) باستعمال أداة (nntool Box) في برنامج MATLAB:

بُنيت الشبكة العصبية الاصطناعية في هذه الدراسة بالاعتماد على برنامج MATLAB والأدوات الملحقة به nntool Box، ولغرض الحصول على أفضل هيكلية للشبكة العصبية الاصطناعية يجب تحديد عدد عصبونات الطبقة الخفية، وبناء طبقات المدخلات والمخرجات والطبقات الخفية. والقياسات الأكثر أهمية في محاكاة أداء النموذج المستخدمة في هذه الدراسة هي متوسط مربع الخطأ (MSE.)

$$MSE = \frac{\sum (Forecast\ errors)^2}{n} \dots \dots \dots (1)$$

في بداية كل محاولة تدريب على الشبكة، يجب إعادة إدخال القيم الأولية لأوزان وتحيزات الشبكة والطريقة الأكثر قابلية للتطبيق هي التهيئة العشوائية، وسيتم التطرق إلى خطوات عملية التنبؤ المتبعة في هذه الطريقة وكما يأتي:

أ. **ادخال البيانات:** لغرض الحصول على أفضل هيكلية للشبكة العصبية الاصطناعية، أدخلت البيانات المتوافرة لمحطة ديزلات شمال العمارة /ميسان، وعلى شكل مصفوفة مكونة من ثلاثة صفوف يمثل الصف الأول درجة الحرارة، والصف الثاني سرعة الرياح، فيما مثل الصف الثالث الرطوبة والتي تمثلت بـ 1096 عموداً، وكما أدخلت بيانات على شكل مصفوفة مكونة من صف واحد يتضمن قيم البيانات التاريخية للطاقة الكهربائية اليومية و1096 عموداً. ثم شكلت شبكة عصبية صناعية تتضمن طبقة مدخلات مكونة من ثلاث عصبونات تمثل (درجة الحرارة، سرعة الرياح، الرطوبة)، وطبقة مخرجات مكونة من عصبون واحد يمثل الهدف وهو الطلب على الطاقة الكهربائية، في حين حدد

عدد العصبونات في الطبقة الخفية بالتجريب، وذلك بتغيير عدد عصبونات الطبقة الخفية وتدريب الشبكة لغاية الحصول على أقل معدل مربع خطأ معياري لدورات تكرارية Epochs متغيرة العدد مقدارها (1000, 5000, 10000).

ب. تدريب الشبكة العصبية الاصطناعية المقترحة: الهدف من تدريب الشبكة هو تغيير أوزان الشبكة للحصول على المخرجات المطلوبة لمدخلات معينة. ولتحقيق ذلك، يجب تحقيق توازن بين قدرتها على الاستجابة بشكل صحيح لبيانات الإدخال المستخدمة في حالة التدريب المخزنة في الشبكة لعملية الاستدعاء، وقدرتها على إعطاء استجابة جيدة لمدخلات مشابهة، لكنها غير مطابقة لتلك المدخلات المستخدمة في عملية التدريب (عملية التنبؤ)، إذ تم إجراء عدد كبير من التجارب عبر تغيير دوال التنشيط وعدد الطبقات المخفية المستخدمة وحساب قيم MSE لكل تجربة، وقد استخدمت أداة nntool في برنامج MATLAB لعملية الحساب والتجربة، وتم إدراج نتائج التجارب في الجدول رقم (2) أدناه وكما يأتي:


الجدول (2): نتائج التجارب لاختيار النموذج المناسب

ت	بنية الشبكة العصبية	دوال التنشيط المستعملة	التكرار (Epoch)	تقييم الأداء بمقياس (MSE)
1	(3,7,1)	Logsig,Logsig	1000	713.74
			5000	631.31
			10000	613
2	(3,10,1)	Logsig,Logsig	1000	586.7
			5000	572.4
			10000	568.48
3	(3,10,1)	Logsig,Purein	1000	661.48
			5000	628.74
			10000	466.69
4	(3,15,1)	Logsig,Logsig	1000	644
			5000	609.45
			10000	602.34
5	(3,25,1)	Logsig,Logsig	1000	593.98
			5000	580.95
			10000	571.59
6	(3,25,1)	Logsig,Purein	1000	665.14
			5000	608.24
			10000	606.95

أعداد الباحثين بالاعتماد على برنامج SPSS.


إذ نلاحظ من النتائج المدرجة في الجدول رقم (2) أن أفضل نموذج هو الذي لديه أقل قيمة لمتوسط مربعات الخطأ MSE (466.69) وهو النموذج (3,10,1) بالتسلسل رقم (3) عند تكرار (epoch 10000) والذي يتميز بالخصائص الآتية:

1. عدد الطبقات المخفية: 1
 2. عدد العصبونات في الطبقة المخفية: 10
 3. دوال التنشيط المستعملة: Logsig, Purein
- ويمكن تمثيل الشبكة العصبية الاصطناعية التي تم اختيارها في الشكل رقم (2):



الشكل (2): التمثيل البياني للشبكة العصبية المقترحة

- المصدر: اعداد الباحثين بالاعتماد على برنامج MATLAB.
- تم استخدام النموذج المقترح الذي اظهر اقل قيمة لمتوسط مربع الخطأ MSE للتنبؤ بالطلب على الطاقة الكهربائية للفترة التي تبدأ من 2022/1/1 وتنتهي 2022/1/30، إذ تم تنفيذ النموذج في بيئة MATLAB وباستخدام أداة nntool، والشكل رقم (3) يبين أفضل معمارية للشبكة العصبية الاصطناعية المقترحة للتنبؤ ويوضح أيضاً الآتي:
1. عملية تقسيم البيانات وهي عشوائية (Random).
 2. الخوارزمية المستخدمة للتدريب وهي Levenberg-Marquardt (trainlm).



3. مقياس الأداء وهو متوسط مربع الخطأ (MSE).

الشكل (4): معمارية الشبكة العصبية في برنامج MATLAB

- المصدر: اعداد الباحثين بالاعتماد على برنامج MATLAB.
- وبعد اجراء تجارب التدريب للنماذج المقترحة واختيار النموذج الأفضل تم استخدامه للتنبؤ بالطلب على الطاقة الكهربائية لعينة الدراسة والجدول رقم (3) يوضح نتائج التنبؤ بالطلب للنموذج المقترح والطلب الحقيقي.

الجدول (3): نتائج التنبؤ بالطلب على الطاقة والقيم الحقيقية للطلب

التاريخ	القيم الحقيقية	قيم التنبؤ
---------	----------------	------------

130	140	01/01/2022
121	140	02/01/2022
135	140	03/01/2022
137	136	04/01/2022
136	140	05/01/2022
139	138	06/01/2022
128	145	07/01/2022
132	135	08/01/2022
122	142	09/01/2022
120	137	10/01/2022
135	137	11/01/2022
115	136	12/01/2022
139	140	13/01/2022
123	138	14/01/2022
138	134	15/01/2022
145	137	16/01/2022
147	142	17/01/2022
141	137	18/01/2022
121	143	19/01/2022
131	134	20/01/2022
136	146	21/01/2022
138	131	22/01/2022
134	142	23/01/2022
123	132	24/01/2022
136	137	25/01/2022
120	121	26/01/2022
132	120	27/01/2022
120	118	28/01/2022
132	121	29/01/2022
133	113	30/01/2022

اعداد الباحثين بالاعتماد على برنامج SPSS.

إذ تم حساب متوسط الخطأ النسبي المطلق (MAPE) بين القيم الحقيقية وقيم التنبؤ وهو (0.0648)، وسيتم مقارنة لاحقاً مع الطرق الأخرى المقترحة للتنبؤ بالطلب.

3. طريقة المجموعة العصبية لمعالجة البيانات (GMDH) من ANN المقترحة: طريقة المجموعة لمعالجة البيانات (The Group Method of Data Handling (GMDH) هي عائلة من الخوارزميات للنمذجة الرياضية المعتمدة على الكمبيوتر والتعرف الهيكلي، وتتميز معظم

خوارزميات GMDH بإجراء استقرائي للتنظيم الذاتي يستخدم للحصول على نموذج متعدد العوامل، إذ مكنت الخصائص السلوكية المحددة لـ GMDH من استخدامها بنجاح في مجالات مثل التنقيب عن البيانات واكتشاف المعرفة والتنبؤ ونمذجة الأنظمة المعقدة والتحسين والتعرف على الأنماط، ومن المفترض أن يتم تمثيل الكائن الذي تم فحصه باستخدام GMDH من خلال مدخلات متعددة ومخرج واحد على الأقل، ومن المفترض أيضاً أنه يمكن النمذجة بواسطة مجموعة فرعية معينة من مكونات الوظيفة الأساسية في المعادلة (2):

$$Y(X_1, \dots, X_N) = \sum_{i=1}^K a_i f_i \dots \dots \dots (2)$$

حيث إن: X = المدخلات، Y = الإخراج، a = المعاملات، f = الوظائف الأولية التي تعتمد على مجموعات مختلفة من المدخلات و k = عدد مكونات الوظيفة الأساسية.

وتم استخدام مجموعة البيانات اليومية للفترة من 2019/1/1 وانتهاء بالفترة 2021/12/31 للوصول لتنبؤات دقيقة، ويتم تحديد الوظيفة التقريبية لـ $\hat{f}$ من خلال الإخراج المتوقع لـ $\hat{y}$ بأقل خطأ، ولمجموعة من المدخلات المتعددة ($x = x_{i1}, x_{i2}, x_{i3} \dots x_{in}$) ويتم مقارنة المخرجات المتنبأ بها مع الإخراج الأحادي الفعلي لـ y لذلك يمكن تحديد النتائج الفعلية لبيانات M المقاسة تجريبياً والتي تتكون من مدخلات n ومخرج احادي على النحو الآتي:

$$y_i = f(x_{i1}, x_{i2}, x_{i3} \dots x_{in}) (i = 1, 2, 3, \dots, M) \dots \dots \dots (3)$$

ولتقدير قيمة $\hat{y}$ لمتجه الادخال x تم تطوير (GMDH) من ANN على النحو الآتي:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3} \dots x_{in}) (i = 1, 2, 3, \dots, M) \dots \dots \dots (4)$$

يتعين على GMDH تقليل الخطأ التربيعي بين القيم المقدرة والقيم الفعلية المعطاة على النحو التالي:

$$\sum_{i=1}^M (\hat{y}_i - y_i)^2 \rightarrow \min \dots \dots \dots (5)$$

وعند اكتمال شبكة GMDH، يتم تصفية مجموعة من المدخلات الأصلية من خلال الطبقات إلى عقدة الإخراج المثلى، إذ يتم صياغة الوصف الرياضي بين المخرجات ومتغيرات المدخلات باستخدام اجراء منفصل معقد للسلسلة الوظيفية المعترف بها على أنها (Kolmogorv-Gabor) كثيرة الحدود كما هو وارد في المعادلة (6) على النحو الآتي:

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots (6)$$

حيث إن n عدد المتغيرات من المدخلات، ($x_1, x_2, \dots, x_n$) هي معلمات الادخال، ($a_0, a_1, \dots, a_n$) هي المعاملات، وعادة ما يتم استخدام الهيكل التربيعي والمتغير الثنائي لهذا التعبير متعدد الحدود من خلال الترتيب الجبري الكلي على النحو الآتي:

$$\hat{y}_i = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \dots (7)$$

ومن اجل انتاج العلاقة الرياضية الشاملة لمتغيرات المدخلات والمخرجات الواردة في المعادلة (6) يتم تنفيذ هذا الهيكل التربيعي الجزئي في مسار معاكس عبر شبكة من الخلايا العصبية

المشتركة لتحديد المعاملات الغير معروفة لـ (a_i) في المعادلة (7) يتم تنفيذ تقنية الانحدار وهكذا لكل زوج من متغيرات الادخال $(x_i \text{ and } x_j)$ ، ويتم توفير الحد الأدنى للفرق بين القيم المقدرة $(\hat{y})$ والإخراج الفعلي (y) عن طريق المعادلة (6) يتم انشاء مجموعة من كثيرات الحدود، ويتم تطبيق تقنية المربعات الصغرى لتحديد المعاملات غير المحدودة لكثيرات الحدود المذكورة بالنسبة للثوابت لكل دالة تربيعية (G_i) ، إذ يتم الحصول على المعاملات لتقليل الخطأ الكلي للخلايا العصبية من اجل تحقيق التوافق الأمثل للمدخلات على النحو الآتي:

$$E = \frac{\sum_{i=1}^M (y_i - G_i)^2}{M} \rightarrow \min \dots \dots \dots (8)$$

مع الأخذ في الاعتبار اجراء GMDH يتم توفير اثنين من معلمات الاحتمالية المستقلة من خلال مجموعة كاملة من معلمات الادخال المختارة، وبالمثل فإن التقنية المذكورة $\frac{n(n-1)}{2}$ سيتم تعيين الخلايا العصبية من خلال الطبقة المخفية الأولى المحسوبة من:

$\{(y_i, x_{ip}, x_{iq}); (i = 1, 2, \dots, M)\}$ و $p, q \in \{1, 2, \dots, n\}$ ومن ثم، تتضاعف بيانات M ثلاث مرات $\{(y_i, x_{ip}, x_{iq}); (i = 1, 2, \dots, M)\}$ يتم تحديده من خلال $p, q \in \{1, 2, \dots, n\}$ من الملاحظة على النحو الآتي:

$$\begin{bmatrix} x_{1p} & x_{1q} & y_1 \\ x_{2p} & x_{2q} & y_2 \\ x_{3p} & x_{3q} & y_3 \end{bmatrix} \dots \dots \dots (9)$$

ويتم استخدام الدالة من الدرجة الثانية المعبر عنها في المعادلة (7) لكل صف ثلاثي M ويتم التعبير عن هذه المعادلات في شكل المصفوفة الآتية:

$$A_a = Y \dots \dots \dots (10)$$

$$a = \{a_0, a_1, a_2, a_3, a_4, a_5\} \dots \dots \dots (11)$$

$$Y = \{y_1, y_2, y_3, \dots, y_M\}^T \dots \dots \dots (12)$$

حيث يشير a الى متجه المعاملات غير المعروفة المقدمة في المعادلة (32) ويشير Y إلى متجه المخرجات وبالتالي يتم إعطاء الارتباط على النحو الآتي:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}^2 & x_{1q}^2 & x_{1p} & x_{1q} \\ 1 & x_{2p} & x_{2q} & x_{2p}^2 & x_{2q}^2 & x_{2p} & x_{2q} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}^2 & x_{Mq}^2 & x_{Mp} & x_{Mq} \end{bmatrix}$$

ومع فحص نتيجة الانحدار المتعدد يتم اكمال تقنية المربع الصغرى بواسطة المعادلة الآتية:

$$a = (A^T A)^{-1} A^T \dots \dots \dots (13)$$

يتم تحديد القيم الأكثر دقة للمعاملات الواردة في المعادلة (7) لمجموعات بيانات M الثلاثية للمدخلات بواسطة المعادلة (13) في هذه البنية يتم بدء خوارزمية التدريب بواسطة طبقة الادخال التي تكون مجرد طبقة بداية ولا تشمل على أي عملية في الطبقة الأولى، وبناءً على الترتيبات المحتملة لمتغيرات الادخال يتم انتاج الخلايا العصبية المرشحة بعد ذلك يتم تحديد معاملات المعادلة (7) لكل خلية عصبية على حده عن طريق كل من المعاملات المحددة ومتغيرات الادخال للخلايا العصبية المخزنة مؤقتاً ويتم تقدير الإخراج المطلوب، إذ يتم اختيار بعض الخلايا ذات القدرة على التنبؤ بشكل جيد وفقاً لمعايير خارجية ويتم تغذيتها الى الامام لتدريب الطبقة الآتية، ويتم تجاهل الخلايا العصبية التي لا تعطي الحالة المدروسة من الشبكة النتائج المحققة مع الخلايا المختارة وتتحول الى مدخلات للطبقة اللاحقة ويستمر هذا الاجراء حتى الطبقة النهائية، ويتم اختيار خلية عصبية واحدة فقط للنتيجة المحققة في الطبقة النهائية وهي القيم المقدرة. ويتم عرض الخصائص الرئيسية المحددة للنموذج في الجدول رقم (4).

الجدول (4): الخصائص الرئيسية للنموذج المقترح

Properties الخصائص	Selected Option الخيار محدد
Reorder Observation إعادة الترتيب المشاهدة	NO
Validation strategy استراتيجية التحقق من الصحة	Train (90%) Test (10%)
Validation criterion معيان التحقق من الصحة	RMSE
Variable ranking ترتيب المتغير	NO
Core algorithm الخوارزمية الأساسية	GMDH neural network الشبكة العصبية GMDH
Neuron function وظيفة الخلايا العصبية	quadric Polynomial متعدد الحدود من الدرجة الثانية

اعداد الباحثين بالاعتماد على برنامج SPSS.

نتوقع من النموذج أن تكون القيم المقدرة قريبة من القيم الفعلية قدر الإمكان لذلك فإن الهدف هو تقليل الخطأ وبعبارة أخرى تقليل الفرق بين القيم الفعلية والقيم المقدرة. في هذا العمل تم تقييم نتائج أداء التنبؤ لنموذج GMDH من نوع ANN المستند إلى السلاسل الزمنية لكل من تطوير النموذج ومراحل الاختبار باستخدام بعض معايير الأداء وكما يأتي:

أ. الحد الأقصى لخطأ النسبة المئوية السلبية (MNPE).

ب. الحد الأقصى للخطأ النسبة المئوية الإيجابي (MPPE).

ج. متوسط الخطأ النسبي المطلق (MAPE).

د. جذر النسبة المئوية التربيعية للخطأ (RMPSE).

اذ يتم تعيين بعض معلمات نموذج GMDH بواسطة طريقة الخطأ التجريبي لتحقيق أفضل النتائج للنموذج، ولهذا الغرض تم تنفيذ عدد من التجارب من خلال نسبة التدريب إلى الاختبار في استراتيجية التحقق من الصحة، ووظيفة الخلايا العصبية، والحد الأقصى لعدد الطبقات وعرض الطبقة الاولى، والجدول رقم (5) يوضح نتائج التجربة المتعلقة بتقسيم البيانات (نسبة التدريب، نسبة الاختبار) وكما يأتي:

الجدول (5) نتائج التجربة

ت	نسبة البيانات المخصصة للتدريب	نسبة البيانات المخصصة للاختبار	متوسط الخطأ النسبي المطلق (MAPE)
1	60%	40%	0.226
2	70%	30%	0.219
3	80%	20%	0.216
4	90%	10%	0.147

اعداد الباحثين بالاعتماد على برنامج SPSS.


إذ تم الحصول على أفضل النتائج عند تقسيم البيانات إلى نسبة (90%) للتدريب و(10%) للاختبار، ووظيفة الخلايا العصبية متعددة الحدود الطبقة القصوى (100) وعرض الطبقة الأولى (10)، والجدول رقم (6) يوضح معايير الأداء التي تم الحصول عليها لمرحلة التطوير للنموذج وعلى النحو الآتي:

الجدول (6): يوضح نتائج معايير الأداء للنموذج المقترح

معايير الاداء	المختصر	أفضل نتائج للنموذج
عدد المشاهدات	-	1096
الحد الأقصى لخطأ النسبة المئوية المطلقة السلبية	MNPE	-3.32
الحد الأقصى لخطأ النسبة المئوية المطلقة الايجابية	MPPE	1.98
متوسط الخطأ النسبي المطلق	MAPE	0.147
جذر متوسط مربع خطأ النسبة المئوية	RMSPE	0.226

اعداد الباحثين بالاعتماد على برنامج SPSS.

بعد عملية التدريب وفق خصائص النموذج المذكورة في الجدول رقم (5) ومقارنة نتائج معايير الأداء المشار إليها في الجدول رقم (6)، إذ تم استخدام النموذج GMDH للحصول على تنبؤ بالأحمال الكهربائية المستقبلية للفترة التي تبدأ من 2022/01/01 وتنتهي إلى الفترة 2022/01/30 والمبينة في الجدول رقم (7) الذي يوضح القيم المقدرة (Forecasted value) والقيم الحقيقية (Actual value). وكما يوضح الشكل رقم (5) الرسم البياني لقيم التنبؤ والقيم الحقيقية أو الفعلية في برنامج GMDH.



الشكل (5): القيم الحقيقية وقيم التنبؤ

المصدر: اعداد الباحثين بالاعتماد على برنامج GMDH.

الجدول (7) القيم الحقيقية وقيم التنبؤ للأحمال الكهربائية (MW) التي تبدأ 2022/1/1 وتنتهي 2022/1/30

القيم الفعلية MW	القيم الفعلية MW	القيم الفعلية MW	القيم الفعلية MW	القيم الفعلية MW
التاريخ	القيم الفعلية MW	القيم الفعلية MW	التاريخ	القيم الفعلية MW
01/01/2022	140	126	17/01/2022	142
02/01/2022	140	134	18/01/2022	137
03/01/2022	140	139	19/01/2022	143
04/01/2022	136	139	20/01/2022	134
05/01/2022	140	133	21/01/2022	146
06/01/2022	138	137	22/01/2022	131
07/01/2022	145	139	23/01/2022	142
08/01/2022	135	139	24/01/2022	132
09/01/2022	142	139	25/01/2022	137
10/01/2022	137	139	26/01/2022	121
11/01/2022	137	139	27/01/2022	120
12/01/2022	136	134	28/01/2022	118
13/01/2022	140	139	29/01/2022	121
14/01/2022	138	140	30/01/2022	113
15/01/2022	134	139		
16/01/2022	137	140		

اعداد الباحثين بالاعتماد على برنامج SPSS.

أظهرت النتائج أعلاه أن هناك تقارب بين قيم التنبؤ والقيم الفعلية وهذا يدل على دقة بيانات التنبؤ باستعمال نهج المجموعة العصبية لمعالجة البيانات، ما عدا بعض القيم التي أظهرت فارق بين قيم التنبؤ والقيم الفعلية بالتسلسل (1) و(25) وهي (126 و115)، والسبب يعود كون المحطة معززة

لطاقة الشبكة الوطنية والتي لا تظهر شكل نمطي للأشهر خلال السنوات الثلاث المستخدمة لتدريب الشبكة، على سبيل المثال، لو اخذنا الشهر السابع من كل سنة وهو يعتبر فيه ذروة الطلب على الطاقة نجده مختلف من سنة إلى أخرى وهذا يعود السبب كون المحطة معززة للطاقة وليست مستمرة أو مركزية.

رابعاً. مناقشة النتائج:

1. **الطريقة التقليدية (ARIMA) باستعمال برنامج SPSS:** تظهر النتائج الموضحة في الجدول رقم (1) أفضل النماذج التقليدية بعد اجراء مجموعة من التجارب باستعمال برنامج SPSS، إذ يظهر الجدول تفوق النموذج Expert Modeler-ARIMA (0,1,5) من خلال مقياس متوسط الخطأ النسبي المطلق MAPE بين قيم التنبؤ والقيم الفعلية بمقدار (0.0654) ويسمى هذا النموذج مصمم النماذج الخبير في SPSS.
 2. **مناقشة نتائج طريقة (Feed-forward backprop):** أظهرت النتائج التي تم الحصول عليها من النموذج المقترح وبعد اجراء مجموعة من التجارب المبينة بالجدول رقم (2) تبين أن أفضل نموذج تم الحصول عليه هو (3,10,1) عند تكرار مقداره (10000epoch) ودالة التنشيط المستعملة في الطبقة المخفية وطبقة الإخراج هي (Logsig, Purein) وأقل قيمة لمتوسط مربعات الخطأ MSE (466.69)، إذ استخدم للتنبؤ بالطلب على الطاقة للفترة التي تبدأ من 2022/1/1 وتنتهي 2022/1/30 كما هو موضح بالجدول رقم (3).
 3. **مناقشة نتائج طريقة المجموعة العصبية لمعالجة البيانات (GMDH) من ANN المقترحة:** أظهرت النتائج التي تم الحصول عليها من النموذج المدرب باستخدام الشبكة العصبية من نوع GMDH، تم تنفيذ عدد من التجارب من خلال نسبة التدريب إلى الاختبار في استراتيجية التحقق من الصحة، إذ تم الحصول على أفضل النتائج عند تقسيم البيانات إلى نسبة (90%) للتدريب و(10%) للاختبار كما هو موضح بالجدول رقم (20)، ووظيفة الخلايا العصبية متعددة الحدود الطبقة القصوى (100) وعرض الطبقة الأولية (10)، ومتوسط الخطأ النسبي المطلق (MAPE) الذي تم الحصول قدره (0.147) بين قيم التنبؤ والقيم الفعلية وبالتالي تم استخدام النموذج للتنبؤ بالطلب على الاحمال المستقبلية للفترة من 2022/1/1 إلى 2022/1/30 وكما هو موضح في الجدول رقم (7).
- إذ تم مقارنة النتائج التي تم الحصول عليها بالطرق المبينة أعلاه من خلال مقياس متوسط الخطأ النسبي المطلق (MAPE) بين قيم التنبؤ والقيم الفعلية للفترة من 2022/1/1 إلى 2022/1/30، كما هو موضح بالجدول رقم (8).

الجدول (8): مقارنة نتائج التنبؤ مع القيم الفعلية لجميع الطرق المستعملة

التاريخ	القيم الحقيقية	قيم التنبؤ نماذج الشبكات العصبية		قيم التنبؤ باستعمال النماذج التقليدية بـ (SPSS)		
		GMDH	Feed-forward backprop	Expert Modeler-ARIMA (0,1,5)	ARIMA (0,0,20)	ARIMA (0,0,15)
01/01/2022	140	126	130	145	144	144
02/01/2022	140	134	121	145	141	140
03/01/2022	140	139	135	145	141	137
04/01/2022	136	139	137	145	138	135
05/01/2022	140	133	136	144	137	133
06/01/2022	138	137	139	144	135	131
07/01/2022	145	139	128	144	136	129
08/01/2022	135	139	132	144	132	126
09/01/2022	142	139	122	144	132	125
10/01/2022	137	139	120	144	129	123
11/01/2022	137	139	135	143	129	123
12/01/2022	136	134	115	143	127	122
13/01/2022	140	139	139	143	127	121
14/01/2022	138	140	123	143	125	120
15/01/2022	134	139	138	143	125	118
16/01/2022	137	140	145	142	123	118
17/01/2022	142	140	147	142	122	118
18/01/2022	137	139	141	142	120	117
19/01/2022	143	140	121	142	120	118
20/01/2022	134	140	131	142	119	118
21/01/2022	146	140	136	142	119	118
22/01/2022	131	139	138	142	118	118
23/01/2022	142	139	134	142	119	118
24/01/2022	132	137	123	142	119	118
25/01/2022	137	115	136	142	118	118
26/01/2022	121	137	120	142	118	118
27/01/2022	120	139	132	142	118	118
28/01/2022	118	139	120	142	118	118
29/01/2022	121	138	132	142	118	118
30/01/2022	113	139	133	142	118	118
نسبة الخطأ	MAPE	0.0567	0.0648	0.0654	0.0709	0.0904

اعداد الباحثين بالاعتماد على برنامج SPSS.

تظهر النتائج في الجدول رقم (8) تفوق نماذج الشبكات العصبية على النماذج التقليدية، إذ تم حساب متوسط الخطأ النسبي المطلق (MAPE) للطرق المقترحة بين قيم التنبؤ والقيم الفعلية للطلب على الطاقة الكهربائية للفترة من 2022/1/1 الى 2022/1/30، إذ إن مقدار متوسط الخطأ النسبي المطلق لأفضل نموذج مقترح بالطريقة التقليدية Expert Modeler-ARIMA (0,1,5) هو (0.0654)، ومقدار متوسط الخطأ النسبي المطلق لنموذج الشبكات العصبية المقترح (Feed-forward) هو (0.0648)، بينما مقدار متوسط الخطأ النسبي المطلق لنموذج الشبكات العصبية المقترح GMDH هو (0.0567)، وهذا يبين أفضلية نماذج الشبكات العصبية المقترح وبالأخص طريقة المجموعة العصبية لمعالجة البيانات GMDH من نوع الشبكة العصبية ANN.

المبحث الرابع: الاستنتاجات والتوصيات

أولاً. الاستنتاجات:

1. يوجد ضعف من قبل محطة ديزلات شمال العمارة لإنتاج الطاقة الكهربائية في تقدير الطلب على الكهرباء (حالة عدم التأكد) وعدم استخدام أي تقنيات للتنبؤ بالطلب المتاحة سواء التقليدية أو باستعمال الذكاء الاصطناعي.
2. تعد الشبكات العصبية من الطرائق الحديثة التي لها قدرة على التنبؤ وإعطاء نتائج جيدة، من خلال قدرتها على تحليل السلاسل الزمنية وتميزها بمرونة تحديد نوعية وعدد المدخلات، وعدد العقد المخفية وعدد الطبقات للشبكة إلى أن تصل إلى النموذج الأمثل.
3. لا تحتاج تقنيات الشبكات العصبية إلى شروط صارمة ودقيقة لغرض التنبؤ، فضلاً عن أنها تفسر سلوك البيانات غير الخطية.
4. ان عملية التنبؤ بالطلب على الطاقة على المدى القصير باستعمال تقنيات الذكاء الاصطناعي أعطت نتائج تنبؤ بدقة جيدة مقارنة بالنماذج التقليدية.

ثانياً. التوصيات: من خلال الاستنتاجات يمكن ادراج اهم التوصيات:

1. يتطلب من محطة ديزلات شمال العمارة زيادة الاهتمام والاستعانة بتقنيات الذكاء الاصطناعي (GMDH & Feed-Forward Backprop by MATLAB) في اجراء عملية التنبؤ، إذ يجب على إدارة المحطة تطوير وتدريب العاملين فيها على استعمال تقنيات الذكاء الاصطناعي من خلال اشراكهم في دورات تدريبية متخصصة بالذكاء الاصطناعي.
2. التأكيد على أهمية عملية التنبؤ لإدارة أنظمة الطاقة على المدى القصير وباقي الآفاق الزمنية الأخرى لما لها من دور في اتخاذ العديد من القرارات، إذ يجب أن تعمل إدارة المحطة على إقامة ندوات وورش عمل للعاملين فيها لتعريفهم بعملية التنبؤ والآفاق الزمنية له، وأهميته في إدارة أنظمة الطاقة.
3. تعميم استعمال أساليب ونماذج الذكاء الاصطناعي ضمن المنظمات وفي جميع المجالات لما لها من أثر ملموس والمساعدة في اتخاذ القرارات ورسم مستقبل المنظمة.
4. التوعية بأهمية المزايا التي تقدمها تقنيات الذكاء الاصطناعي للمنظمات فيما يتعلق بالجهد والوقت والمال والتي تمكنها من الاستجابة للظروف والتغيرات التي تطرأ عليها.
5. بالعمل على اجراء تنبؤ بالأحمال الكهربائية على المدى المتوسط (شهري) باستعمال الشبكات العصبية للمحطة ليساعد للتخطيط متوسط المدى فيما يخص تجهيز الوقود للمحطة والأدوات الاحتياطية للضرورة لضمان استمرارية عمل المحطة دون توقف.

المصادر**أولاً. المصادر العربية:**

1. المغربي، محمد الفاتح محمود بشير (2018)، إدارة الإنتاج والعمليات، ط1، مصر، الأكاديمية الحديثة للكتاب الجامعي.

ثانياً. المصادر الأجنبية:

1. Krajewski, Lee J. & Malhotra. Manoj K., (2022), Operations Management: Processes and Supply Chains, United Kingdom. Pearson Education Limited 2022.
2. Pihlajarinne, T., & Alén-Savikko, A., (2022). Introduction to Artificial Intelligence and the Media. In Artificial Intelligence and the Media. Edward Elgar Publishing.
3. Rose, D., (2018), Artificial Intelligence for Business What You Need to Know about Machine Learning and Neural Networks.

4. Russell, R. S., & Taylor, B. W., (2011), Operations Management: Creating Value.
5. Stevenson, William J., (2015), operations management, McGraw-Hill Education. New York.