



**Tikrit Journal of Administrative  
and Economic 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 College of Administration and Economy,  
Tikrit University. 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 العمارة 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 العمارة 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) يوماً.

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 العمارة 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 STLF أيضاً 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 جارياً 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 الرئيسية 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 أمراً حيوياً 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

**اولاً. 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 الانتاجية وإدارة اعمال 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:


١. هل تتمكن طرق التنبؤ بالطلب باستخدام الشبكات العصبية في الوصول إلى تنبؤات دقيقة مقارنة بالنماذج التقليدية.
٢. هل سيسهم التنبؤ بالطلب على الطاقة الكهربائية على المدى القصير باستخدام تقنيات الذكاء الاصطناعي في التخلص من حالة عدم التأكد بالطلب المستقبلي للطاقة الكهربائية.
٣. ما المعوقات التي تواجهها المنظمة المبحوثة في مجال تبني تطبيقات الذكاء الصناعي للتنبؤ بالطلب؟
٤. 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 خلال الآتي:

1. ستسهم النماذج المستعملة في التنبؤ بالطلب بمساعدة المحطة على إدارة إنتاج 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 والمشاهدة 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

### اولاً. التنبؤ:

١. **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).

٢. **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 (المغربي، ٢٠١٨: ٦٣)، 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).

٣. **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 ٣ 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:

١. **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.

٢. **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:

١. الطريقة التقليدية (ARIMA) باستعمال برنامج SPSS: تم استعمال الطريقة التقليدية المتمثلة بنموذج الانحدار الذاتي والمتوسط المتحرك المتكامل (ARIMA) Autoregressive 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 أفضل ثلاثة نماذج وكما هو موضح في الجدول رقم (١).

الجدول (١): أفضل نتائج التنبؤ باستعمال الطرق التقليدية

| التاريخ    | القيم الحقيقية | أفضل النماذج التقليدية بـ (SPSS)    |                   |                   |
|------------|----------------|-------------------------------------|-------------------|-------------------|
|            |                | EXPERT<br>MODELER-<br>ARIMA (0,1,5) | ARIMA<br>(0,0,20) | ARIMA<br>(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               |

| التاريخ    | القيم الحقيقية | أفضل النماذج التقليدية بـ (SPSS)    |                   |                   |
|------------|----------------|-------------------------------------|-------------------|-------------------|
|            |                | EXPERT<br>MODELER-<br>ARIMA (0,1,5) | ARIMA<br>(0,0,20) | ARIMA<br>(0,0,15) |
|            |                | Forecasted                          | Forecasted        | Forecasted        |
| 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               |
| 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 (١) 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.

## ٢. 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 يمثل 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 حُدد 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 ادراج نتائج التجارب في الجدول رقم (٢) أدناه وكما يأتي:

الجدول (٢): 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                    |

اعداد الباحثين بالاعتماد على برنامج SPSS.


إذ نلاحظ من النتائج المدرجة في الجدول رقم (٢) 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:

١. عدد الطبقات المخفية: 1

٢. عدد العصبونات في الطبقة المخفية: 10

٣. دوال التنشيط المستعملة: Logsig, Purein

ويمكن تمثيل الشبكة العصبية الاصطناعية التي تم اختيارها في الشكل رقم (٢):



الشكل (٢): 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 (٣) يبين أفضل معمارية للشبكة العصبية الاصطناعية المقترحة للتنبؤ ويوضح أيضا الآتي:

١. عملية تقسيم البيانات وهي عشوائية (Random).

٢. الخوارزمية المستخدمة للتدريب وهي Levenberg-Marquardt (trainlm)

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



الشكل (٤): 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 (٣) يوضح نتائج التنبؤ بالطلب للنموذج المقترح والطلب الحقيقي.

الجدول (٣): نتائج التنبؤ بالطلب على الطاقة والقيم الحقيقية للطلب

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

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.

٣. **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 المنتبأ 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 (Kolmogorov-Gabor) كثيرة الحدود كما هو وارد في المعادلة (٦) 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 الإدخال،  $(a_0, a_1, \dots, a_n)$  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 أجل إنتاج العلاقة الرياضية الشاملة لمتغيرات المدخلات والمخرجات الواردة في المعادلة (٦) يتم تنفيذ هذا الهيكل التربيعي الجزئي في مسار معاكس عبر شبكة من الخلايا العصبية المشتركة لتحديد المعاملات الغير معروفة لـ  $(a_i)$  في المعادلة (٧) يتم تنفيذ تقنية الانحدار وهكذا لكل زوج من متغيرات الإدخال  $(x_i \text{ and } x_j)$ ، ويتم توفير الحد الأدنى للفرق بين القيم المقدرة  $(\hat{y})$  والإخراج الفعلي  $(y)$  عن طريق المعادلة (٦) يتم إنشاء مجموعة من كثيرات الحدود، ويتم تطبيق تقنية المربعات الصغرى لتحديد المعاملات غير المحدودة لكثيرات الحدود المذكورة بالنسبة للتوابت لكل دالة تربيعية  $(G_i)$ ، إذ يتم الحصول على المعاملات لتقليل الخطأ الكلي للخلايا العصبية من أجل 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 إجراء GMDH يتم توفير اثنين من معلمات الاحتمالية المستقلة من خلال مجموعة كاملة من معلمات الإدخال 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 (٧) 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  $a$  إلى متجه المعاملات غير المعروفة المقدمة في المعادلة (٣٢) 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 (٧) لمجموعات بيانات M الثلاثية للمدخلات بواسطة المعادلة (١٣) 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 (٤).

الجدول (٤): الخصائص الرئيسية للنموذج المقترح

| Properties<br>الخصائص                             | Selected Option<br>الخيار محدد                       |
|---------------------------------------------------|------------------------------------------------------|
| Reorder Observation<br>إعادة الترتيب المشاهدة     | NO                                                   |
| Validation strategy<br>استراتيجية التحقق من الصحة | Train (90%)<br>Test (10%)                            |
| Validation criterion<br>معيان التحقق من الصحة     | RMSE                                                 |
| Variable ranking<br>ترتيب المتغير                 | NO                                                   |
| Core algorithm<br>الخوارزمية الأساسية             | GMDH neural network<br>الشبكة العصبية GMDH           |
| Neuron function<br>وظيفة الخلايا العصبية          | quadric Polynomial<br>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 لخطأ 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 الأولى، والجدول رقم (٥) يوضح نتائج التجربة المتعلقة بتقسيم البيانات (نسبة التدريب، نسبة الاختبار) وكما يأتي:

الجدول (٥) نتائج التجربة

| ت | نسبة البيانات المخصصة للتدريب | نسبة البيانات المخصصة للاختبار | متوسط الخطأ النسبي المطلق (MAPE) |
|---|-------------------------------|--------------------------------|----------------------------------|
| ١ | 60%                           | 40%                            | 0.226                            |
| ٢ | 70%                           | 30%                            | 0.219                            |
| ٣ | 80%                           | 20%                            | 0.216                            |
| ٤ | 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 (٦) يوضح معايير الأداء التي تم الحصول عليها لمرحلة التطوير للنموذج وعلى النحو الآتي:


الجدول (٦): 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 الايجابي | 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 (٥) ومقارنة نتائج معايير الأداء المشار إليها في الجدول رقم (٦)، 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 (٧) الذي يوضح القيم المقدرة (Forecasted value) والقيم الحقيقية (Actual value). وكما يوضح الشكل رقم (٥) الرسم البياني لقيم التنبؤ والقيم الحقيقية أو الفعلية في برنامج GMDH.



الشكل (٥): القيم الحقيقية وقيم التنبؤ

المصدر: اعداد الباحثين بالاعتماد على برنامج GMDH.

الجدول (٧) القيم الحقيقية وقيم التنبؤ للأحمال الكهربائية (MW) التي تبدأ 2022/1/1 وتنتهي 2022/1/30

| القيم الفعلية<br>MW | القيم الفعلية<br>MW | القيم التنبؤ<br>MW | القيم الفعلية<br>MW | القيم التنبؤ<br>MW | التاريخ    |
|---------------------|---------------------|--------------------|---------------------|--------------------|------------|
| 140                 | 140                 | 126                | 142                 | 140                | 01/01/2022 |
| 140                 | 139                 | 134                | 137                 | 139                | 02/01/2022 |
| 140                 | 140                 | 139                | 143                 | 140                | 03/01/2022 |
| 136                 | 140                 | 139                | 134                 | 140                | 04/01/2022 |
| 140                 | 140                 | 133                | 146                 | 140                | 05/01/2022 |
| 138                 | 139                 | 137                | 131                 | 139                | 06/01/2022 |
| 145                 | 139                 | 139                | 142                 | 139                | 07/01/2022 |
| 135                 | 137                 | 139                | 132                 | 137                | 08/01/2022 |
| 142                 | 115                 | 139                | 137                 | 115                | 09/01/2022 |
| 137                 | 137                 | 139                | 121                 | 137                | 10/01/2022 |
| 137                 | 139                 | 139                | 120                 | 139                | 11/01/2022 |
| 136                 | 139                 | 134                | 118                 | 139                | 12/01/2022 |
| 140                 | 138                 | 139                | 121                 | 138                | 13/01/2022 |
| 138                 | 139                 | 140                | 113                 | 139                | 14/01/2022 |
| 134                 |                     | 139                |                     |                    | 15/01/2022 |
| 137                 |                     | 140                |                     |                    | 16/01/2022 |

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 و 115)، 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.

#### رابعا. مناقشة النتائج:

١. **الطريقة التقليدية (ARIMA) باستعمال برنامج SPSS:** تظهر النتائج الموضحة في الجدول رقم (١) 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.

٢. **مناقشة نتائج طريقة (Feed-forward backprop):** أظهرت النتائج التي تم الحصول عليها من النموذج المقترح وبعد اجراء مجموعة من التجارب المبينة بالجدول رقم (٢) 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 (٣).

٣. **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 (٧).

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 (٨).

## الجدول (٨): 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<br>backprop | Expert Modeler-<br>ARIMA (0,1,5)                | ARIMA<br>(0,0,20) | ARIMA<br>(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 (٨) 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 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:

١. 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.
٢. 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.
٣. لا تحتاج تقنيات الشبكات العصبية إلى شروط صارمة ودقيقة لغرض التنبؤ، فضلاً عن أنها تفسر سلوك البيانات غير الخطية.
٤. إن 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:

١. 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.
٢. 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.
٣. تعميم استعمال أساليب ونماذج الذكاء الاصطناعي ضمن المنظمات وفي جميع المجالات لما لها من أثر ملموس والمساعدة في اتخاذ القرارات ورسم مستقبل المنظمة.
٤. التوعية بأهمية المزايا التي تقدمها تقنيات الذكاء الاصطناعي للمنظمات فيما يتعلق بالجهد والوقت والمال والتي تمكنها من الاستجابة للظروف والتغيرات التي تطرأ عليها.
٥. 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 اللازمة لضمان استمرارية عمل المحطة دون توقف.

### المصادر

#### أولاً. المصادر العربية:

١. المغربي، محمد الفاتح محمود بشير (٢٠١٨)، إدارة الإنتاج والعمليات، ط١، 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.