

التنبؤ بالحمل الكهربائي الحساس للطقس بثلاث مكونات باستخدام الشبكة العصبية الاصطناعية

ماجد صالح الحافظ
alhafidms@uomosul.edu.iq

يمامة انور الناصري
yamama.msc@gmail.com

جامعة الموصل - كلية الهندسة - قسم الهندسة الكهربائية

تاريخ القبول: 13/7/2021

تاريخ الاستلام: 26/4/2021

الخلاصة

يتأثر الحمل الكهربائي بشدة بالظروف الجوية في العديد من البلدان ، بما في ذلك العراق. يتم عادة تقسيم الحمل الكهربائي الحساس للطقس إلى مركبتين، مركبة حساسة للطقس ومركبة غير حساسة للطقس (الحمل الأساسي). يشمل تأثير المركبة الحساسة للطقس فترتي الصيف والشتاء، بدون التمييز بينهما. تختلف خصائص ومواصفات هذه المركبة في الصيف والشتاء، نظرا لاختلاف الاحمال في الفصلين. لذلك من الأفضل فصل هذين المكونين في مركبتين مستقلتين. يوفر البحث طريقة لفصل الحمل الكهربائي الحساس للطقس إلى ثلاثة مركبات ، المركبة الصيفية ، والمركبة الشتوية ، والمركبة الأساسية. تم استخدام الشبكة العصبية الاصطناعية للتنبؤ بالحمل الكهربائي الحساس للطقس باستخدام برنامج MATLAB R17a. تم استخدام بيانات الطقس والاحمال لمدة عام لمدينة الموصل. تم تقييم أداء الشبكة العصبية الاصطناعية باستخدام معدل الخطأ التريبيعي ومعدل نسبة الخطأ المطلقة. تشير النتائج الى دقة نموذج التنبؤ المستخدم في البحث.

الكلمات الدالة

التنبؤ بالأحمال الحساسة للطقس، الشبكة العصبية الاصطناعية، معدل مربع الخطأ التريبيعي، احمال العراق.

This is an open access article under the CC BY 4.0 license (<http://creativecommons.org/licenses/by/4.0/>).
<https://rengj.mosuljournals.com>

1. المقدمة

أكثر من عام [10][12]. لم يتم دراسة التنبؤ بالحمل على المدى المتوسط على نطاق واسع ، مقارنةً بالتنبؤ بالأحمال قصيرة الأجل أو طويلة الأجل [15]. تم استخدام العديد من الطرق التقليدية و الذكية للتنبؤ بالحمل الكهربائي مثل تحليل السلاسل الزمنية [17][16]، الشبكات العصبية الاصطناعية [18][12]، تحويل الموجة [19]، آلة المتجهات الداعمة [16][20] ، المنطق الضبابي [11][8] ، والخوارزمية الجينية [21][7].


تتأثر الأحمال الكهربائية في العديد من البلدان، بما في ذلك العراق، بالأحوال الجوية وخاصة درجات الحرارة. تتم دراسة الأحمال الحساسة للطقس من خلال تقسيمها إلى مركبتين، أحدهما حساس للظروف الجوية، والآخر لا يتأثر بالظروف الجوية. ولكن تتزايد معاناة الدول من تأثير الأحمال الكهربائية الحساسة للطقس بسبب اختلاف خواص الأحمال الكهربائية في فصلي الصيف والشتاء ، لذلك يفضل فصل الأحمال إلى ثلاث مكونات. المكون الأول لا يتأثر بالظروف الجوية. المكون الثاني يتأثر بارتفاع درجات الحرارة. المكون الثالث يتأثر بانخفاض درجات الحرارة. يؤدي فصل الأحمال الكهربائية إلى ثلاثة مركبات، إلى إدارة الاحمال بدقة وكفاءة أعلى [24][23][22].

يعد التنبؤ الدقيق بالأحمال الكهربائية أمراً ضرورياً للنظام الكهربائي لأغراض مختلفة، منها إدارة الأحمال ، وتخطيط توسعة المحطة، والتشغيل الذكي، ودقة تحديد سعر الطاقة الكهربائية [2][1]. وتزداد أهمية التنبؤ مع تزايد استخدام الطاقة المتجددة [4][3].

التنبؤ بالحمل هو الحصول على معلومات مستقبلية بناءً على قراءات سابقة والتي تساعد في اتخاذ الإجراء المناسب لتحقيق التوازن بين التوليد والاستهلاك [7][6][5]. بالإضافة الى تجنب اضطراب الأحمال عند التنبؤ المنخفض، ومشاكل الهدر في التوليد عند التنبؤ المرتفع. التقنيات الحديثة مثل إدارة جانب الطلب والشبكة الذكية جعلت التنبؤ الدقيق بالحمل الكهربائي أكثر أهمية [9][8]. ومن جانب آخر، نظراً لزيادة استخدام مصادر الطاقة المتجددة ، فإن التنبؤ الدقيق بالأحمال الكهربائية يضمن توفير الطاقة الأمثل وتشغيل البطاريات وإدارة الطاقة والتخزين [11][10].

يُصنف التنبؤ بالحمل الكهربائي وفقاً لأفق التنبؤ إلى ثلاثة أنواع ، التنبؤ قصير المدى (من بضع ساعات إلى أسبوع واحد) ، والتنبؤ متوسط المدى (من أسابيع إلى عام) ، والتنبؤ طويل الأجل

- طبقة الإخراج، والتي تستخدم لإخراج متغيرات الإخراج (تحوي عقد بعدد متغيرات الإخراج).
- طبقة وسيطة واحدة أو أكثر، والتي تعمل كمجموعة من أجهزة الكشف عن الخواص [27]، كما موضحة في شكل (1).



شكل (1) مخطط الشبكة العصبية الاصطناعية

1.3 إنشاء الشبكة العصبية الاصطناعية

تم إنشاء الشبكة العصبية الاصطناعية باستخدام برنامج MATLAB. بعد تعريف مجموعة التدريب والاختبار، يتم إنشاء الشبكة العصبية وتُحدد مزايا هذه الشبكة وتشمل نوع الشبكة وعدد الطبقات المخفية وعدد خلاياها العصبية ودالة النقل (Transfer Function) ودالة التدريب وطريقة تقييم أداء الشبكة.

تم إنشاء شبكة عصبية من نوع (Feed-forward back propagation). عدد الخلايا العصبية في طبقة الإدخال (13) والتي تمثل بيانات الإدخال. وعدد طبقاتها المخفية (2) وعدد الخلايا العصبية في كل طبقة مخفية (10). أما عدد الخلايا العصبية في طبقة الإخراج (3) والتي تمثل مركبات الحمل الثلاث. الجدول (1) يوضح الإعدادات التي استخدمت في إنشاء الشبكة العصبية، والموضحة في شكل (2).

جدول (1) إعدادات الشبكة العصبية الاصطناعية

Parameter	Value
Network Type	Feed-forward backpropagation
Number of layers (Input-hidden-output)	(13 – 2 – 3)
Number of Neurons	10
Transfer function	sigmoid
Performance function	MSE
Training and testing set	50-50%
Training function	TRAINLM
Number of iterations	1000

2. نظرية الدراسة

تم في هذا البحث، تقسيم الأحمال الكهربائية الحساسة للظروف الجوية إلى ثلاث مركبات. المركبة الأولى غير حساسة للطقس (المركبة الأساسية) وتشمل الإضاءة والأجهزة المنزلية. والمركبة الثانية تكون حساسة لارتفاع درجة الحرارة (مركبة الصيف) وتشمل أجهزة التكييف. والمركبة الثالثة تكون حساسة لانخفاض درجات الحرارة (مركبة الشتاء) وتشمل أجهزة التدفئة وتسخين المياه.

تم استخدام الشبكة العصبية الاصطناعية للتنبؤ بمركبات الحمل الثلاثة، بسبب كفاءتها العالية في التنبؤ بالحمل الكهربائي. تم استخدام بيانات الطقس والأحمال الكهربائية لمدينة الموصل لمدة عام، لتدريب واختبار الشبكة العصبية. ثم اختبار نتائج الشبكة العصبية الاصطناعية باستخدام متوسط الخطأ التربيعي ومتوسط نسبة الخطأ المطلق.

3. الشبكة العصبية الاصطناعية

تعد الشبكات العصبية الاصطناعية *Artificial Neural Network* خيار جيد للتنبؤ بالأحمال الكهربائية، لقدرتها على إيجاد العلاقة المعقدة غير الخطية بين الأحمال الكهربائية والعوامل المؤثر عليها. الشبكة العصبية الاصطناعية مصممة لمحاكاة الطريقة التي يعالج بها الدماغ البشري البيانات. فهي مختلفة تمامًا عن طرق التحليل الإحصائية. حيث تبني الشبكة العصبية الاصطناعية معرفتها عن طريق اكتشاف الأنماط والعلاقات في البيانات والتعلم أو التدريب وليس من خلال البرمجة. تستخدم تقنية ANN لإيجاد العلاقة بين متغيرات متعددة للإدخال ومتغيرات الإخراج، عندما يصعب إيجاد العلاقة بينها رياضياً. حيث تبرز أهمية الشبكات العصبية في التصنيف والتعرف على الأنماط والتنبؤ والنمذجة والتحكم الآلي. لا تتطلب الشبكات العصبية الاصطناعية معرفة مصدر البيانات، ولكن تتطلب مجموعات تدريب كبيرة [26][25]. يتكون هيكل الشبكة العصبية الاصطناعية من مجموعة من العقد (الخلايا العصبية) متصلة بواسطة روابط وعادة ما يتم تنظيمها في عدد من الطبقات. تتلقى كل عقدة في الطبقة، المدخلات الموزونة من طبقة سابقة وتعالجها وتنقل مخرجاتها إلى العقد في الطبقة التالية من خلال الروابط. يتم تعيين وزن لكل رابط، وهو تقدير رقمي لقوة التوصيل. يتم تحويل التجميع الموزون لمدخلات العقدة إلى مخرجات وفقاً لوظيفة النقل (عادةً ما تكون دالة سينية). تحتوي معظم الشبكات على ثلاث طبقات أو أكثر:

- طبقة الإدخال، والتي تُستخدم لتقديم البيانات إلى الشبكة (تحوي عقد بعدد متغيرات الإدخال).

وتسلسل اليوم. أما الإخراج يكون نتيجة التنبؤ أي المركبات الحمل الثلاثة. تم استخدام بيانات الاحمال والطقس لمدينة الموصل لتدريب واختبار الشبكة العصبية، تم تقسيم مجموعة البيانات إلى مجموعتين:


- 50% من مجموعة البيانات تستخدم لتدريب النموذج.
- 50% المتبقية تستخدم لاختبار النموذج.

بعد تدريب الشبكة العصبية والحصول على اقل قيمة خطأ، يتم اختبار دقة النموذج بمجموعة من البيانات. بعد تدريب واختبار الشبكة العصبية، يمكن إعطاؤها معلومات إدخال جديدة للتنبؤ بالمخرجات المطلوبة.

3.3 بيانات الحمل الكهربائي

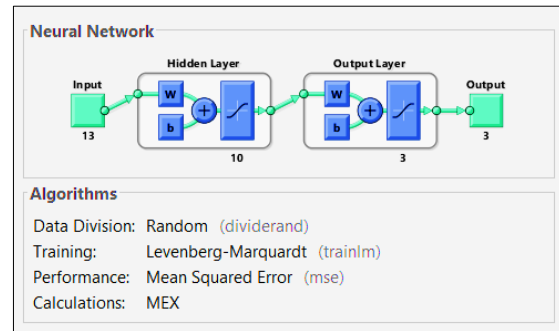
تستهلك الطاقة الكهربائية في القطاع السكني والقطاع الحكومي والقطاع الصناعي والقطاع الزراعي والقطاع التجاري والقطاع السياحي. يمثل القطاع السكني أكبر قطاعات استهلاك الطاقة الكهربائية في العراق. يتكون الحمل الكهربائي السكني من مركبات متعددة. تتغير باستمرار بسبب عوامل كثيرة تؤثر في هذه المكونات. تمثل درجة الحرارة أبرز العوامل المناخية التي تؤثر في تغير الحمل. يوضح الشكل (4) الحمل الكهربائي لمدينة الموصل لسنة كاملة تبدأ في 2010/4/1 وتنتهي في 2011/3/31. تم تسجيل هذه البيانات والحصول عليها من المديرية العامة لتوزيع كهرباء الشمال/ مركز السيطرة الشمالي/ محطة المجموعة الثقافية. يمكن تصنيف الحمل الكهربائي في القطاع السكني إلى خمس مركبات رئيسية حسب مستوى الاستهلاك كالتالي:

- مركبة الإنارة (Lighting)
- مركبة الاجهزة المنزلية (Home Appliances)
- مركبة التبريد (Cooling)
- مركبة التدفئة (Heating)
- مركبة تسخين المياه (Water heater)



شكل (4) الحمل الكهربائي لمدينة الموصل

يوضح جدول (2) وشكل (5) نسب الاستهلاك لمركبات الحمل الكهربائي في القطاع السكني لأشهر مختارة من الصيف والشتاء، شهر أغسطس 2010 ويناير 2011.



شكل (2) مخطط الشبكة العصبية الامامية

تم تقييم أداء الشبكة العصبية الاصطناعية باستخدام متوسط الخطأ التربيعي (Mean Squared Error) ومتوسط نسبة الخطأ المطلق (Mean Absolute Percentage Error) ومتوسط الخطأ المطلق (Mean Absolute Error):

$$MSE = \frac{\sum_{i=1}^n (Y_i - Y'_i)^2}{n} \quad \dots\dots\dots (1)$$

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{Y_i - Y'_i}{Y_i} \right|}{n} \quad \dots\dots\dots (2)$$


$$MAE = \sum_{i=1}^n \left| \frac{Y_i - Y'_i}{n} \right| \quad \dots\dots\dots (3)$$

حيث: Y : الحمل الأصلي، Y' : الحمل المتوقع ،

n : عدد العينات، i : تسلسل اليوم .

2.3 تدريب واختبار الشبكة العصبية


يجب أن يمر نموذج التنبؤ بمرحلة التدريب، وهي المرحلة الثانية بعد انشاء الشبكة. الهدف من عملية التدريب هو ضبط أوزان وتحيزات الشبكة وتقليل الخطأ بين مخرجات الشبكة والمخرجات المرغوبة (الهدف) [19]. تم استخدام الشبكة العصبية الامامية وتدريبها بالخوارزمية Levenberg-Marquardt backpropagation (MLP)، والتي تعدل أوزان الشبكة وانحيازها بسرعة كبيرة.



شكل (3) نموذج الشبكة العصبية الاصطناعية


يوضح الشكل (3) نموذج التنبؤ بالأحمال . بيانات الإدخال تمثل ، درجات الحرارة اليومية العظيمة والصغرى وذروة التحميل اليومي ونسبة مركبات الحمل الخمسة من مجموع الاستهلاك اليومي

للمحمولة من اجمالي الاستهلاك اليومي. تم تقييم أداء الشبكة باستخدام متوسط الخطأ التربيعي (MSE). يوضح الشكل (7) منحنى أداء الشبكة العصبية الاصطناعية في مرحلة التدريب. يستمر تدريب الشبكة لحين الوصول لأقصى تقارب بين قيم الإخراج للشبكة والهدف الذي تم تعيينه. التدريب هو عملية تكرارية تستمر حتى يتم اكتساب مستوى مقبول من الخطأ. يتوقف التدريب عند (1000 iterations).



الشكل (7) منحنى أداء تدريب الشبكة العصبية الاصطناعية

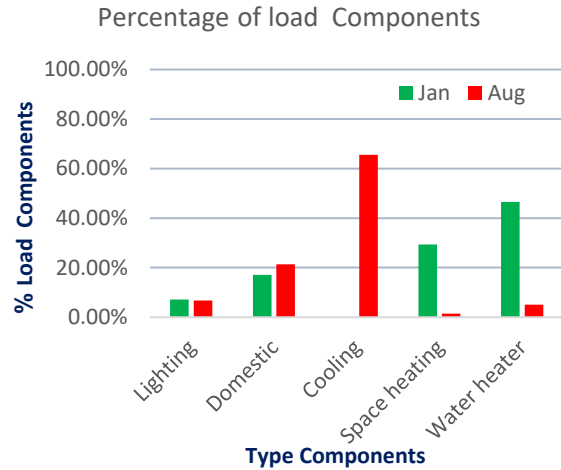
يوضح الشكل (8) انحدار الشبكة العصبية لمراحل التدريب والاختبار، وقيمة معامل الارتباط (R) Correlation coefficient (R) تساوي (0.999). حيث تتناسب نتائج النموذج (Output) مع القيم الاصلية او الهدف (Target) بشكل كبير. تم اختبار الشبكة المدربة بمجموعة من البيانات للتنبؤ بمركبات الحمل الثلاث. الشكل (9) يوضح نتائج الاختبار للشبكة العصبية الاصطناعية. يوضح الجدول



شكل (8) انحدار الشبكة العصبية في مرحلة التدريب والاختبار

جدول (2) النسب المئوية لمركبات الحمل الكهربائي


Type Component	Jan	Aug
Lighting	% 7.09	% 6.71
Domestic	% 17.07	% 21.33
Cooling	% 0.00	% 65.53
heating Space	% 29.31	% 1.40
heater Water	% 46.53	% 5.03



شكل (5) النسب المئوية لمركبات الحمل الكهربائي

4.3 بيانات الطقس

تم استخدام بيانات درجات الحرارة العظمى والصغرى لمدينة الموصل لسنة كاملة تبدأ في 2010/4/1 وتنتهي في 2011/3/31. تم الحصول على هذه المعلومات من الهيئة العامة للأحوال الجوية والرصد الزلزالي (دائرة أنواء الموصل). يوضح الشكل (6) بيانات الطقس.



الشكل (6) درجات الحرارة العظمى والصغرى

4. النتائج والمناقشة

تم تطبيق نموذج الشبكة العصبية الاصطناعية على بيانات الطقس والاحمال لمدينة الموصل للفترة (1 ابريل 2010 - 31 مارس 2011). تشمل بيانات الادخال، درجات الحرارة اليومية العظمى والصغرى وحمل الذروة اليومي ونسبة المركبات الخمسة

جدول (3) نتائج نموذج التنبؤ

Type and structure of ANN	3layers FF BP with structure (12-5-1)
Transfer functions	Tan-sig
No. of epochs	1000
MAPE% for training	3.39 %
MAPE% for testing	4.58 %
MSE for training	20.60
MSE for testing	28.10
Correlation coefficient (R) for training	0.938
Correlation coefficient (R) for testing	0.891

جدول (4) نتائج اختبار نموذج التنبؤ

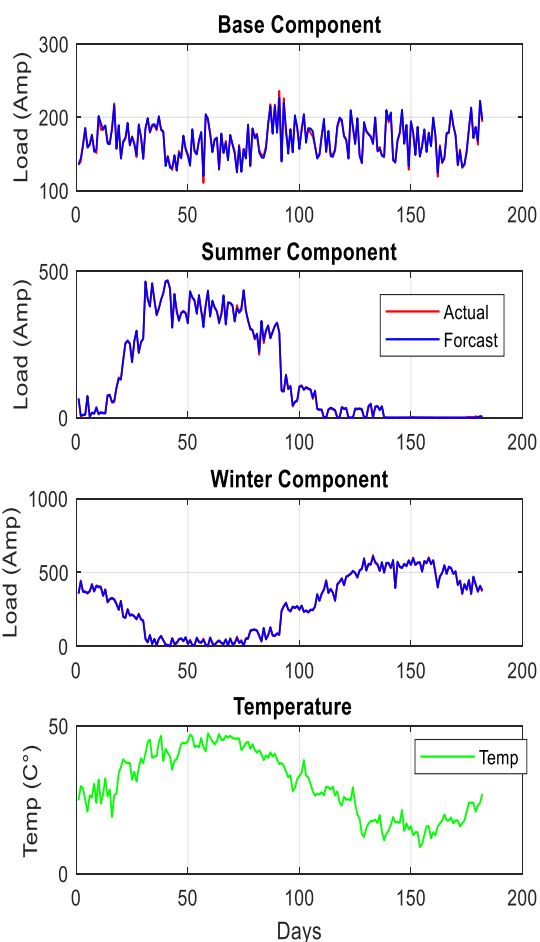
Error	Base	Summer	Winter	Total
MAE	1.80	2.10	2.37	3.98
MSE	6.69	8.57	9.17	28.8

1.4 مقارنة نتائج التنبؤ مع بحث منشور

تم مقارنة نتائج التنبؤ مع نتائج بحث سابق. يقترح البحث في المصدر [19]، التنبؤ بالحمل متوسط المدى باستخدام الشبكة العصبية الاصطناعية للتنبؤ بالحمل في مدينة الموصل شمال العراق. تم استخدام نفس البيانات في كلا البحثين. يوضح الجدول (5) نتائج التنبؤ للبحث المنشور. عند مقارنة نتائج البحث الحالي الموضحة في جدول (4) مع نتائج التنبؤ للبحث المنشور الموضحة في جدول (5) نستنتج ان نموذج التنبؤ الجديد أكثر دقة وكفاءة .

جدول (5) نتائج التنبؤ لبحث سابق

Type and structure of ANN	3layers FF BP with structure (13-2-3)
Transfer functions	Tan-sig
No. of epochs	1000
MAPE% for training	0.51%
MAPE% for testing	0.66%
MSE for training	18.87
MSE for testing	28.8
Correlation coefficient (R) for training	0.9999
Correlation coefficient (R) for testing	0.9999



الشكل (9) نتائج اختبار الشبكة العصبية الاصطناعية

(3) نتائج نموذج التنبؤ في مرحلة التدريب و الاختبار. لشكل (9) نتائج اختبار الشبكة العصبية الاصطناعية

تظهر المركبة الأساس دائما لأنها لا تتأثر بالطقس، بينما مركبة الصيف تظهر بارتفاع درجات الحرارة وتختفي بانخفاض درجات الحرارة، بينما تظهر مركبة الشتاء عند انخفاض درجات الحرارة وتختفي بارتفاع درجات الحرارة. تشير النتائج الى كفاءة الشبكة العصبية الاصطناعية في التنبؤ بمركبات الحمل الحساس للطقس. يوضح الجدول (4) متوسط الخطأ المطلق (MAE) ومتوسط الخطأ التربيعي (MSE) للتنبؤ بمركبات الحمل الثلاثة. نلاحظ ان مركبة الأساس هي الاعلى تقارب بين البيانات الاصلية ونتائج الاختبار تليها مركبة الصيف ثم مركبة الشتاء.

- [7] R. Behera, B. B. Pati, and B. P. Panigrahi, "A Long Term Load Forecasting of an Indian Grid for Power System Planning," *J. Inst. Eng. Ser. B*, vol. 95, no. 4, pp. 279–285, 2014.
- [8] E. Akarslan and F. O. Hocaoglu, "A novel short-term load forecasting approach using Adaptive Neuro-Fuzzy Inference System," *Proc. - 2018 6th Int. Istanbul Smart Grids Cities Congr. Fair, ICSG 2018*, pp. 160–163, 2018.
- [9] N. Shabbir, R. Amadihangar, H. A. Raja, L. Kutt, and A. Rosin, "Residential Load Forecasting Using Recurrent Neural Networks," *Proc. - 2020 IEEE 14th Int. Conf. Compat. Power Electron. Power Eng. CPE-POWERENG 2020*, pp. 478–481, 2020.
- [10] G. Weng, C. Pei, J. Ren, H. Jiang, and J. Xu, "Modeling and Forecasting of Wind Power Output of Urban Regional Energy Internet Based on Deep Learning Modeling and Forecasting of Wind Power Output of Urban Regional Energy Internet Based on Deep Learning," 2021.
- [11] T. Fujiwara and Y. Ueda, "Load forecasting method for Commercial facilities by determination of working time and considering weather information," *7th Int. IEEE Conf. Renew. Energy Res. Appl. ICRERA 2018*, vol. 5, pp. 336–341, 2018.
- [12] H. L. Imam, M. S. Gaya, and G. S. M. Galadanci, "Short term load forecast of Kano zone using artificial intelligent techniques," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 16, no. 2, pp. 562–567, 2019.
- [13] D. Fay and J. V. Ringwood, "On the influence of weather forecast errors in short-term load forecasting models," *IEEE Trans. Power Syst.*, vol. 25, no. 3, pp. 1751–1758, 2010.
- [14] K. B. Sahay, S. Sahu, and P. Singh, "Short-term load forecasting of Toronto Canada by using different ANN algorithms," *2016 IEEE 6th Int. Conf. Power Syst. ICPS 2016*, 2016.
- [15] S. Nuchprayoon, "Forecasting of daily load curve on monthly peak day using load research data and harmonics model," *Proc. - 6th IEEE Int. Conf. Control Syst. Comput. Eng. ICCSCE 2016*, no. November, pp. 338–342, 2017.
- [16] W. Yang, L. Qiuyu, C. Qiuna, L. Sijie, Y. Yun, and Y. Binjie, "Short-term Load Forecasting Based on Load Decomposition and Numerical Weather Forecast," *IEEE Trans. Power Syst.*, 2017.
- [17] M. S. Al-Hafid and G. H. Al-maamary, "Short term electrical load forecasting using holt-winters method," *Al-Rafidain Engineering*, vol. 3, no. 3, pp. 2697–2705, 2011.
- [18] A. O. Hoori, A. Al Kazzaz, R. Khimani, Y. Motai, and A. J. Aved, "Electric Load Forecasting Model Using a Multicolumn Deep Neural Networks," *IEEE Trans. Ind. Electron.*, vol. 67, no. 8, pp. 6473–6482, 2020.

5. الاستنتاج

يتأثر الحمل الكهربائي في العراق وبعض البلدان بالظروف الجوية. عند التنبؤ بالحمل الحساس للطقس يتم تقسيم الحمل إلى مركبتين، مركبة حساسة للطقس ومركبة غير حساسة للطقس. يشمل تأثير المركبة الحساسة للطقس فترتي الصيف والشتاء، بدون التمييز بينهما. بسبب اختلاف خصائص ومواصفات الاحمال في الصيف والشتاء، يفضل فصل هذين المكونين في مركبتين مستقلتين. يستخدم البحث طريقة جديدة للتنبؤ بالحمل الكهربائي الحساس للطقس بثلاث مركبات، المركبة الصيفية، والمركبة الشتوية، والمركبة الأساسية. وباستخدام الشبكة العصبية الاصطناعية. تم التنبؤ بأحمال مدينة الموصل لمدة عام. تشير النتائج الى دقة نموذج التنبؤ باستخدام الشبكة العصبية الاصطناعية عند التنبؤ بمركبات الحمل الثلاث. النسبة 0.66% هي نتيجة اختبار اداء النموذج بواسطة متوسط نسبة الخطأ المطلق. وبمقارنة نتائج النموذج مع بحث سابق تبين ان النموذج المقترح ادق بكثير من البحث السابق. نستنتج من البحث ان فصل الحمل الحساس للطقس الى ثلاث مركبات يزيد من دقة التنبؤ بشكل كبير.

المصادر:

- [1] M. A. Hammad, B. Jereb, B. Rosi, and D. Dragan, "Methods and Models for Electric Load Forecasting: A Comprehensive Review," *Logist. Sustain. Transp.*, vol. 11, no. 1, pp. 51–76, 2020.
- [2] T. Sun, T. Zhang, Y. Teng, Z. Chen, and J. Fang, "Monthly Electricity Consumption Forecasting Method Based on X12 and STL Decomposition Model in an Integrated Energy System," *Math. Probl. Eng.*, vol. 2019, no. 3, 2019.
- [3] M. Selim, R. Zhou, W. Feng, and P. Quinsey, "Estimating Energy Forecasting Uncertainty for Reliable AI Autonomous Smart Grid Design," *Energies*, vol. 14, no. 1, p. 247, 2021.
- [4] M. Q. Raza, N. Mithulanathan, J. Li, and K. Y. Lee, "Multivariate Ensemble Forecast Framework for Demand Prediction of Anomalous Days," *IEEE Trans. Sustain. Energy*, vol. 11, no. 1, pp. 27–36, 2020.
- [5] A. Gupta and P. K. Sarangi, "Electrical load forecasting using genetic algorithm based back-propagation method," *ARN J. Eng. Appl. Sci.*, vol. 7, no. 8, pp. 1017–1020, 2012.
- [6] M. Lekshmi and K. N. Adithya Subramanya, "Short-term load forecasting of 400kV grid substation using R-tool and study of influence of ambient temperature on the forecasted load," *2019 2nd Int. Conf. Adv. Comput. Commun. Paradig. ICACCP 2019*, pp. 1–5, 2019.

- [24] M. S. Al-Hafid, A. S. Al-Fahadi, and Y. A. Mahmoud, "Separating the components of the electrical load in the Iraqi distribution system," in *The Fifth International Arab Libyan Conference on Electrical and Electronic Engineering*, 2010.
- [25] J. P. Teixeira and P. O. Fernandes, "Tourism Time Series Forecast -Different ANN Architectures with Time Index Input," *Procedia Technol.*, vol. 5, pp. 445–454, 2012.
- [26] S. Agatonovic-Kustrin and R. Beresford, "Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research," *J. Pharm. Biomed. Anal.*, vol. 22, no. 5, pp. 717–727, 2000.
- [27] A. R. Senthil Kumar, K. P. Sudheer, S. K. Jain, and P. K. Agarwal, "Rainfall-runoff modelling using artificial neural networks: Comparison of network types," *Hydrol. Process.*, vol. 19, no. 6, pp. 1277–1291, 2005.
- [19] M. S. Al-hafid and M. A. Gasim, "Application of Artificial Neural Networks in Mid-Term Load Forecasting for Residential Sector in Mosul City (Iraq)," in *The Second Engineering Conference Golden Jubilee - University of Mosul*, 2013, vol. 1, pp. 1–10.
- [20] D. Sonika, S. D. S, and K. Daljeet, "LONG-TERM-LOAD-FORECASTING-USING-SOFT-COMPUTING-TECHNIQUES.docx," vol. 6, no. 6, pp. 450–457, 2015.
- [21] F. Li and X. Zhao, "The Application of Genetic Algorithm in Power Short-term Load Forecasting," vol. 50, no. Icivc, 2012.
- [22] M. Al-Hafidh, M. Al-Nama, and A. Al-Fahadi, "Determination of Residential Electrical Load Components In Iraqi North Region," *Iraqi J. Electr. Electron. Eng.*, vol. 13, no. 2, pp. 0–0, 2017.
- [23] M. Al-Hafidh, M. Al-Nama, and A. Al-Fahadi, "Utilization of Solar Water Heaters to Reduce Residential Electrical Load," *UHD J. Sci. Technol.*, vol. 1, no. 1, pp. 23–26, 2017.

Three Component Weather-Sensitive Load Forecast using Artificial Neural Network

Yamama A. I. Al-Nasiri
yamama.msc@gmail.com

Majid S. M. Al-Hafidh
alhafidms@uomosul.edu.iq

Electrical Engineering Department, Collage of Engineering, University of Mosul

Abstract

The electrical load is affected by the weather conditions in many countries as well as in Iraq. The weather-sensitive electrical load is, usually, divided into two components, a weather-sensitive component and a weather-insensitive component (baseload). The impact of the weather-sensitive component includes the summer and winter periods, without distinguishing between them. The characteristics and specifications of this component differ in summer and winter due to the different loads in the seasons, so it is best to separate these two components into two independent components. The research provides a method for separating the weather-sensitive electrical load into three components, the summer component, the winter component, and the base component. The artificial neural network was used to predict the weather-sensitive electrical load using the MATLAB R17a software. Weather data and loads were used for one year for Mosul City. The performance of the artificial neural network was evaluated using the squared error rate and the mean absolute error ratio. The results indicate the accuracy of the prediction model used in the research.

Keywords:

Weather Sensitive Load Forecast, Artificial Neural Network, Mean Squared Error, IRAQI Loads.