

استخدام الشبكة العصبية للتنبؤ بمقدار الطلب على الطاقة الكهربائية

الدكتور المهندس بديع زريفة¹

الملخص

هدف هذا البحث إلى إنشاء طريقة متطرورة للتنبؤ بمقدار الطلب على الطاقة الكهربائية في المحافظات، أو في غيرها من المنشآت والأماكن، وذلك باستخدام الشبكة العصبية ذات الانتشار العكسي للخطأ (Backpropagation Neural Network (BNN)). وقد استخدمت في البحث معطيات خدمة مراقبة استهلاك الطاقة الكهربائية لشركة الكهرباء في محافظة السويداء، مدة 38 أسبوعاً، من أجل تدريب (تعليم) الشبكة العصبية. يُظهر البحث بشكل منظور كيفية تغير منحنى استهلاك الطاقة خلال 24 ساعة، وفي فترة تسعة أشهر تقريباً، وعرض النزوة المسائية اليومية. أظهرت نتائج البحث - ومن خلال مقارنة القيم المتتبّلة بها، بواسطة البرنامج المبني على الشبكة العصبية (المتنبئ العصبي predictor)، والقيم الحقيقة للاستهلاك - بأن المتنبئ العصبي - الذي أُنشئ في هذا البحث - يعطي دقة كبيرة وكافية للتطبيقات العملية.

¹ كلية الهندسة الميكانيكية والكهربائية-جامعة دمشق.

١- مقدمة:

إن لا خطية نظم الطاقة الكهربائية وتعقيداتها - كنظم يُراد التحكم بها - تحدت مصممي نظم التحكم الآلي على مدى عشرات السنين. رغم ذلك فقد تحقق في السنوات الأخيرة تقدماً واضح في هذا المجال، وذلك بفضل النجاح في تطوير نظم التحكم العددية، كالشبكات العصبية والخوارزميات الجينية.

من المعلوم بأن الطاقة الكهربائية لا تخزن - كالماء مثلاً - إلا بكميات محدودة جداً، لذلك فإن إنتاج طاقة كهربائية أكبر من الطاقة المطلوبة للاستهلاك، يجعل بعض مولدات الطاقة تعمل دون فائدة، وكذلك فإن نقص الطاقة المولدة يسبب أضراراً كبيرة للشبكة الكهربائية وللمستهلك بسبب هبوط الجهد عند المستهلك وزيادة تيار الشبكة.

في الوقت الحالي قامت دول عدة (اليونان^[1]، فرنسا^[2]، بريطانيا وبعض الولايات الأمريكية^[3] وتايوان) بتزويد مراكز مراقبة الطاقة بما يسمى بـمتباين عصبي (predictor) للتنبؤ بالحمل الكهربائي، يستخدم للمساعدة في اتخاذ القرار.

تعد غالباً ذروة استطاعة الحمل هي القيمة المراد التنبؤ بها. عندئذ يتراوح عمق التنبؤ من عدة دقائق إلى عدة ساعات. رغم ذلك فما زالت شركات الكهرباء الوطنية تعتمد على خبرة مراقبي الشبكة في موضوع التنبؤ. بعض المراقبين يعرفون نظام الطاقة لدرجة تمكنهم من معرفة سلوكه في المستقبل القريب. آخذين بالحساب وسائل معينة مثل: نوع اليوم (عطلة أو عمل)، يوم الأسبوع (أحد، اثنين،.....) وأوقات اليوم. أما الظروف الجوية فتقدر من خلال درجة حرارة الهواء، وسرعة الرياح والغيوم. وهناك مراقبون آخرون يعتمدون في التنبؤ على أمثلة سابقة ويستخدمون خوارزميات تستقرى وضع النظام حسب التنبؤات الجوية.

هدف هذا البحث إلى إنشاء طريقة تطورية مبنية على الشبكة العصبية ذات الانتشار العكسي (BNN) Back-propagation Neural Network لمعرفة الطلب على الطاقة الكهربائية.

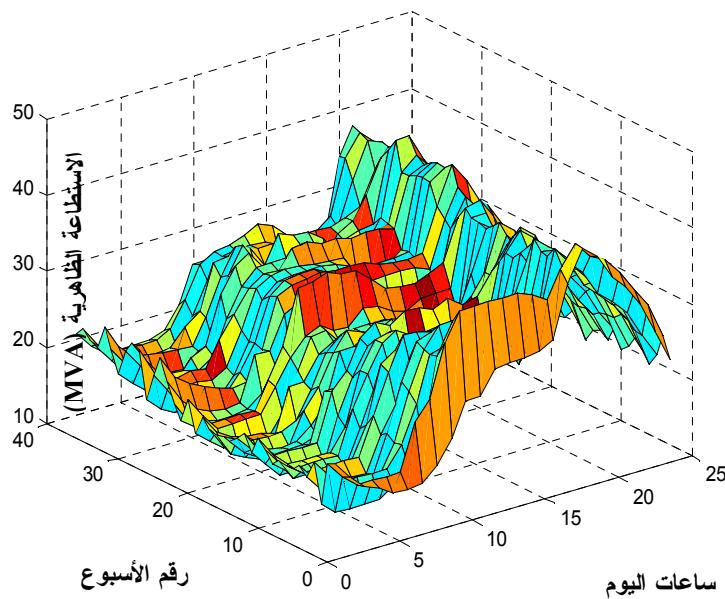
2- تغيرات استهلاك الطاقة الكهربائية مع الزمن:

من أجل إنشاء نموذج للبحث جرى تجميع معطيات خدمة مراقبة استهلاك الطاقة لمدينة السويداء وقرابها، حيث يبلغ عدد سكان هذه المحافظة نحو 330 ألف نسمة، وسُجّلت قيم استطاعة الحمل وتياره - في ملف Excel - كل ساعة من تاريخ 2006/01/01 حتى 2006/09/21 والبالغة 38 أسبوعاً وتحتوي على مدد التوقيت الصيفي والشتوي.

حسب الاستطاعة الظاهرية المستهلكة في المحافظة بضرب قيمة جهد الملف الثانوي لمحولات مراكز التحويل (20 KV) بحاصل جمع التيارات المسحوبة منها وكذلك الأمر لمحطات дизيل ووضعت هذه القيم الناتجة في ملف أسميه D_{w3D} وهو ملف MATLAB. وفيه رُتّب أيام الأسبوع من الأحد وصولاً إلى السبت، فحصلنا، لكل يوم من أيام الأسبوع، على 38 سطراً، وكل سطر يحتوي على 24 قيمة استطاعة ظاهرية بعدد ساعات اليوم. وباستخدام تعليمات:

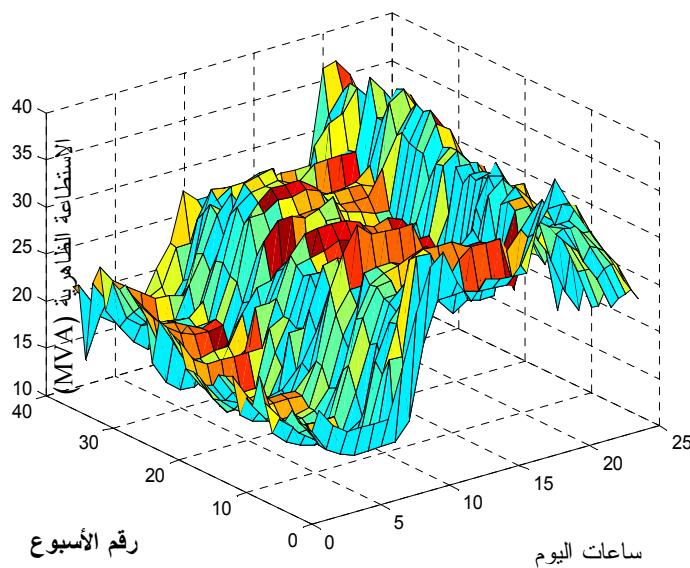
$[Hours, weeks] = meshgrid(1:1:24, 1:1:38)$

قسمت المحاور، ثم باستخدام تعليمات surf حصلنا على أشكال ثلاثية الأبعاد لمختلف أيام الأسبوع.



الشكل 1. تغيرات الاستطاعة الظاهرية للحمل في يوم الأحد خلال 38 أسبوعاً.

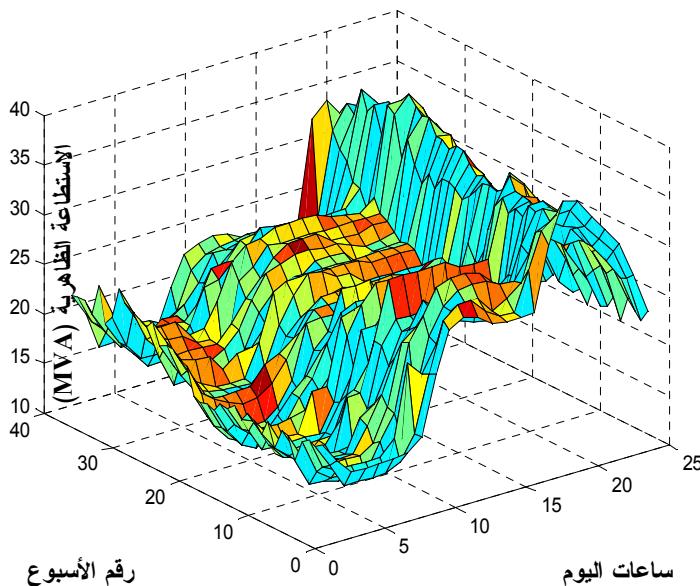
توضح الأشكال المنظورة 3,2,1 كيفية تغير منحنى استهلاك الطاقة الكهربائية خلال أربع وعشرين ساعة ومرة 38 أسبوعاً، في محافظة السويداء، في يوم عمل (الأحد) وفي يوم عطلة (الجمعة) وفي يوم ما قبل العطلة (الخميس)، أما باقي أيام العمل فهي مشابهة لدرجة كبيرة ليوم الأحد. في جميع الحالات تبدو واضحة الذروة المسائية ما بين الساعة السابعة والعشرة والتي تمتد في أيام العطلة وأيام ما قبل العطلة إلى الساعة الحادية عشرة. فضلاً عن ذلك نلاحظ أن يوم العطلة يتصرف بتزايد بطيء لل الحمل الصباحي بالمقارنة بيوم العمل. ونلاحظ أيضاً أن زيادة الحمل في أوقات العمل بالمقارنة بالمدة نفسها في أيام العطلة لا تتجاوز 20%. وتعليق ذلك هو أن المحافظة ليست صناعية بل زراعية-سكنية.



الشكل 2. تغيرات الاستطاعة الظاهرية للحمل في يوم الخميس خلال 38 أسبوعاً

3- الشبكة العصبية:

الشبكة العصبية الصناعية هي نظام معالجة معلومات تفرعي. صممت كنمذاج رياضية من أجل محاكاة تصرف الخلايا العصبية عند الإنسان^[4]. تتألف الشبكة العصبية من عدد كبير من العصبونات. وكل عصبون منها يتصل مع عصبونات أخرى بروابط موزّنة موجّهة. ولكل رابطة من هذه الروابط وزن يُضرب بالإشارة المنقوله عبرها معطية المعلومات اللازمة لحل المسألة المطروحة على الشبكة العصبية.



الشكل 3. تغيرات الاستطاعة الظاهرية للحمل في يوم الجمعة خلال 38 أسبوعاً.

كل عصبون يستقبل دخلاً يمثل المجموع الموزّن لإشارات دخل هذا العصبون، ويُطبق تابع تشبيط على هذا الدخل ليعطي إشارة الخرج. من المسائل النموذجية التي يمكن حلها باستخدام هذه الشبكات مسائل التصنيف والترتيب والتتبّؤ والتحكم الأمثلية.

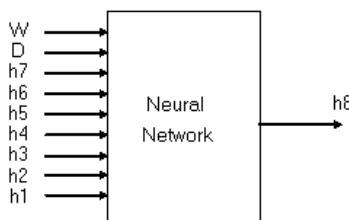
تتميز شبكة عصبية عن أخرى بما يأتي:

- 1- طريقة التوصيل بين العصبونات التي تقرر هيكل الشبكة.
- 2- طريقة تحديد الأوزان وتعديلها وهذا ما يسمى بخوارزمية التعليم.
- 3- تابع التشبيط الذي هو في الغالب تابع لخطي.

عند نشر إشارة الدخل من عصبونات الدخل إلى العصبونات المتصلة بها، يعمل كل من هذه العصبونات التالية على توليد الخرج المناسب، وإرساله على شكل إشارة

وحيدة إلى عدة عصيّونات في وقت واحد. ومن المناسب هنا تصنيف العصيّونات ضمن طبقات، حيث تملك عصيّونات كل طبقة تابع التنشيط نفسه، وطريقة التوصيل بينها.

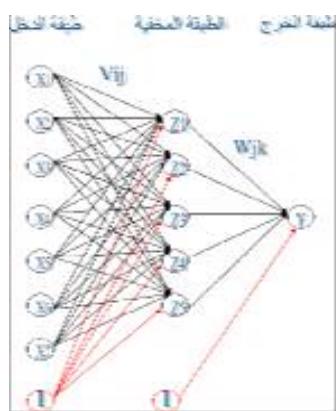
3-1- تحديد بنية الشبكة العصيّونية ومعاملاتها:



الشكل 4. دارة المتتبّع العصيّوني بالحمل الكهربائي.

يبين الشكل 4 دارة المتتبّع العصيّوني بالاستطاعة الظاهيرية المطلوبة لإحدى محافظات القطر (السويداء) أو لجهة ما.

بني المتتبّع العصيّوني (Predictor) على قاعدة شبكة عصيّونية ذات انتشار عكسي BNN كما في الشكل 5. وقد اختيرت وحدّدت المعاملات اللازمة للشبكة العصيّونية كما يأتي:



الشكل 5 الشبكة العصيّونية.

1- عدد طبقات الشبكة: يساوي ثلاثة طبقات من العصيوبنات، أي يساوي طبقتين من الأوزان. فقد أثبتت البحث في هذا المجال أن هذا الخيار كافٍ في كثير من الأحيان لحل مسائل التنبؤ بما فيها هذه المسألة.

2- عدد المدخل: يساوي عدد قيم الاستطاعة السابقة المستخدمة في عملية التعرف $n=7$. أي عدد الساعات السابعة (h1,h2,h3,h4,h5,h6,h7) للساعة التي نريد التنبؤ بمقدار الحمل الكهربائي عندها لليوم المحدد D من الأسبوع W.

إن تخفيض عدد المدخل يؤدي إلى نقصان دقة الجملة، وفي الوقت نفسه فإن زيادة عدد المدخل عن سبعة يؤدي إلى تعقيد الجملة لدرجة غير مبررة، ففي البحث [5] استخدم الباحث، للغرض نفسه، 47 مدخلاً لجملة نوع RBF ورغم ذلك فالدقة الناتجة في هذا البحث ليست أقل من الدقة الناتجة في ذلك البحث كما سنرى لاحقاً. والسبب في ذلك هو ضعف ارتباط مقدار الحمل في الساعات المسائية مثلاً بمقداره في ساعات الليل والصباح أو بالعكس، وإنما هو مرتبطة ارتباطاً كبيراً برقم الأسبوع من السنة وباسم اليوم وبعد محدد من الساعات السابقة لساعة التنبؤ.

3- عدد المخارج: يمثل عدد القيم المطلوب التنبؤ بها $m=1$. وهي مقدار الحمل الكهربائي المراد التنبؤ به بعد ساعة (h8).

4- عدد عصيوبنات الطبقة المخفية: اختياري، ولكن يفترض ألا يكون كبيراً بشكل زائد كي لا يكون التعليم خطأ. كما يجب ألا يكون عدد عصيوبنات الطبقة المخفية صغيراً لدرجة أن أي تغيير صغير نسبياً للدخل قد يؤدي إلى ابتعاد الخرج عن القيمة الصحيحة. وكذلك كي لا يأخذ تعليم الشبكة وقتاً طويلاً.

فقد أظهرت الدراسات والبحوث المختلفة في هذا المجال أنه من الأنساب أن نأخذ في البداية عدد هذه العصيوبنات من جوار القيمة $\frac{n}{2}$ ، ونغير هذا العدد حتى نصل إلى الخيار الأنسب. ووجدنا تجريبياً أن العدد الأنسب هو $l=5$.

5- استخدمنا عصيوبني انجياز (عصيوبنات الواحد) من أجل تعديل اتجاه التعليم.

سنرمز بـ $\{V_{ij}\}$ إلى الأوزان المتوضعة بين طبقة الدخل والطبقة المخفية. ولدينا 35 وزناً بين الدخل والطبقة المخفية.

و بـ $\{W_{jk}\}$ للأوزان المتوضعة بين الطبقة المخفية و طبقة الخرج. ولدينا خمسة أوزان بين الطبقة المخفية و الخرج.

3- طريقة الانتشار العكسي وخوارزمية التعليم:

من الأسس الرياضية للشبكات العصبية [4] يمر تدريب الشبكة العصبية باستخدام طريقة الانتشار العكسي بثلاث مراحل:

1- انتشار مباشر لدخل التدريب عبر طبقات الشبكة وصولاً إلى حساب الخرج:

حيث تستقبل كل وحدة دخل x_i إشارة الدخل x_i وتوزعها عبر وصلاتها المثلثة Z_j بالأوزان V_{ij} إلى كل وحدة في الطبقة المخفية. ومن ثم تقوم كل وحدة مخفية Z_j بحساب خرجها z_j و تنشره عبر وصلاتها المثلثة بالأوزان W_{jk} إلى كل وحدة في طبقة الخرج. وأخيراً فإن كل وحدة خرج Y_k تحسب خرجها y_k ، حيث تعتبر المجموعة $\{y_k\}$ عن استجابة الشبكة للدخل المعطى.

2- انتشار عكسي للخطأ بدءاً من طبقة الخرج:

تمثل إجرائية الانتشار العكسي المرحلة التدريبية للشبكة. حيث يتم أولاً مقارنة كل خرج y_k مع الخرج المرغوب به المقابل t_k ، وهذا يعطي خطأ النموذج من أجل إحدى وحدات الخرج Y_k . بعد ذلك يتم حساب مقدار الخطأ δ_k بهدف توزيع خطأ وحدات الخرج بشكل تراجمي على كل وحدة من وحدات الطبقة المخفية. ومن ثم بشكل مماثل يتم حساب مقدار الخطأ δ_j المرتبط بوحدات الطبقة المخفية Z_j .

3- تعديل أوزان الوصلات بين الوحدات المختلفة:

تعديل كل الأوزان باستخدام خرج وحدات الدخل والوحدات المخفية و القيم δ_k و δ_j حيث:

- يُعدل الوزن W_{jk} باستخدام δ_k و خرج الطبقة المخفية z_j حسب العلاقة الآتية:

$$\Delta W_{jk} = \alpha \delta_k z_j, 0 \leq j \leq l, 1 \leq k \leq m$$

- تُعدَّل الوزن V_{ij} باستخدام δ_j و خرج الطبقة المخفية x_i حسب العلاقة الآتية:

$$\Delta V_{ij} = \alpha \delta_j x_i : 0 \leq i \leq n, 1 \leq j \leq l$$

حيث α هي معدل التعلم ويتم تحديده في بداية الخوارزمية.

إن معدل التعلم يجب أن يحقق تقاربًا صحيحاً وسريعاً إلى حد ما، ولا يجب أن يكون كبيراً بحيث يسبب السقوط في نهاية صغرى محلية ومن ثم يكون التعلم غير صحيح. لذا فقد اخترنا $\alpha = 0.9$ وقمنا بتغييرها عند الحاجة.

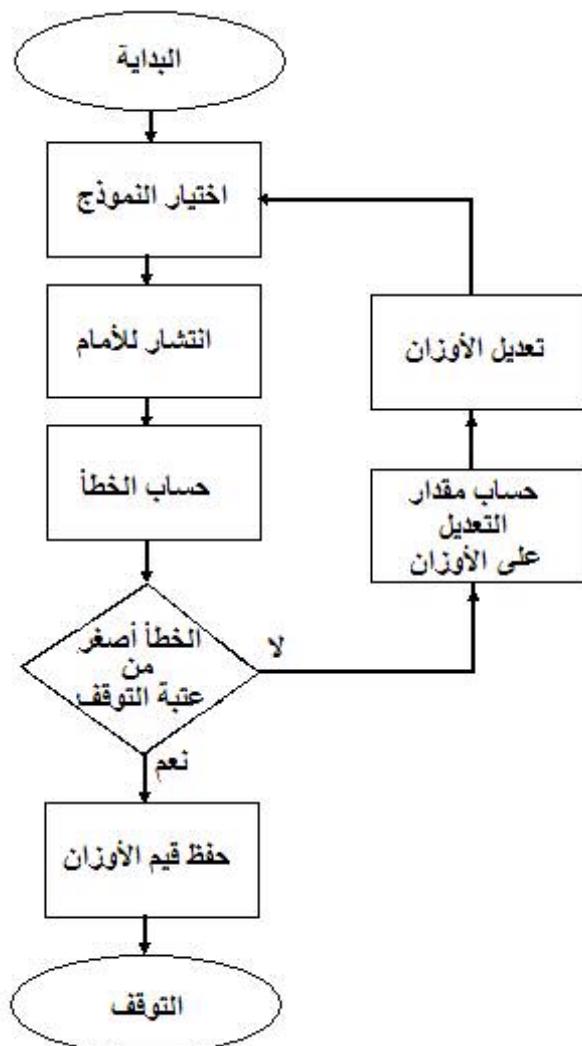
يُطبقُ هذا الإجراء على كل النماذج التدريبية وإذا كان معدل تغير الأوزان أقل من حد معين تتوقف عملية التعلم. يجب أن لا تكون عتبة التوقف كبيرة كي لا يتعرف النظام على دخل ما على أنه أحد الأهداف وهو خلاف ذلك، ولا صغيرة بحيث يحصل تعليم زائد ومن ثم أي تشوّه بسيط لأحد الأهداف يؤدي إلى عدم كشفه. وقد اختبرت القيمة $= 0.005$ كعتبة للتوقف وثبت بالتجربة أنها مناسبة. ويبين الشكل 6 خوارزمية الشبكة.

إن تابع التنشيط المستخدم في هذا البحث هو التابع الحلواني ثالثي القطبية binary sigmoid، المبين في الشكل 7، والذي يعبر عنه بالعلاقة الآتية:

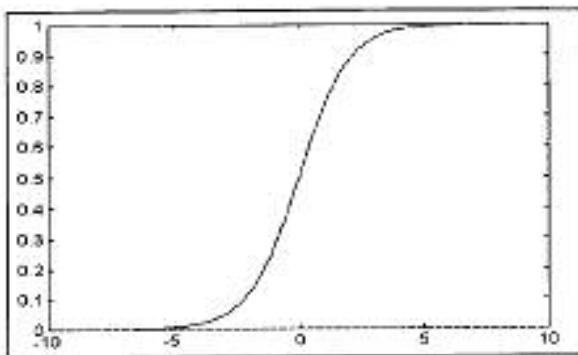
$$f(x) = \frac{1}{1 + e^{-x}}$$

وهو تابع سهل الاستفادة. حيث يتم حساب مشتقه اللازم في خوارزمية الانتشار العكسي كما يأتي:

$$f'(x) = \frac{e^{-x}}{(1 + e^{-x})^2} = \frac{e^{-x}}{1 + e^{-x}} \cdot \frac{1}{1 + e^{-x}} = f(x) \times (1 - f(x))$$



الشكل 6. خوارزمية تدريب الشبكة



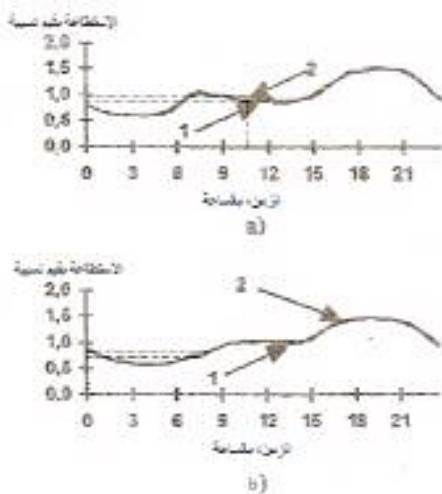
الشكل 7.تابع التنشيط binary sigmoid

أما فيما يتعلق بمجموعة النماذج التعليمية Learning Set، فهي من أجل كل يوم عبارة عن 24 ساعةً كل منها يحوي سبع قيم سابقة للاستطاعة المستهلكة فعلياً. تستخدم في بناء المتنبئ العصبيوني برنامج بلغة C++, الذي يسمح لنا بإجراء عملية التعليم Learn أو التنبؤ Predict. ونظراً إلى تعذر تقديم هذا البرنامج في هذا البحث بسبب كبر حجمه، فسوف يكون بمقدور من يرغب تطوير هذا الاتجاه العلمي المهم للبلد والمجتمع أو الاستفادة منه أن يحصل عليه من الباحث مباشرة.

4- المقارنة وتحليل نتائج التنبؤ والاستنتاجات:

أثبتت البحوث المنشورة في مجال البحث [5,3,2,1] إمكانية التنبؤ بالطلب على الطاقة الكهربائية، ورغم أن هذه البحوث أشارت إلى أن المتنبئات العصبية تسمح بالتنبؤ بمقدار الأحمال الكهربائية خلال الزمن بدقة مقبولة، إلا أنها لم تحدد مقدار الخطأ الأعظمي الحاصل بين القيمة الحقيقة والمتنبأ بها بشكل واضح.

في البحث [5] اختار الباحث أحد أحياط مدينة (خاركيف) المسمى (سالنكا) كموضوع للتنبؤ العصبيوني واستخدم لهذا الغرض معطيات مركز التحويل كل نصف ساعة مدة نصف عام، وقد بنى المتنبئ العصبيوني على أساس الشبكة RBF بسبعة وأربعين مدخلاً ($n=47$) و 40 عصباً في الطبقة المخفية وقدم النتائج على شكل منحنيات بوحدات نسبية للاستطاعة (الشكل 8) ليومي الأحد(b) والأربعاء(a) فقط.



الشكل 8. نتائج التنبؤ بالحمل الكهربائي لحي "سالفاكا" كما وردت في [5]

من الشكل 8 نجد أنَّ أكبر خطأ نسبي مئوي بين القيمة المتتبَّأ بها y (المنحنى 2) والقيمة الحقيقية t (المنحنى 1) هي ليوم الأحد:

$$\frac{y-t}{t} \cdot 100 \cong \frac{0.07}{0.75} \cdot 100 = 9.33\%$$

$$\frac{y-t}{t} \cdot 100 \cong \frac{0.095}{0.85} \cdot 100 = 11.17\% \quad \text{وليوم الأربعاء:}$$

بعد تدريب الشبكة العصبية BNN، وكى تعطى نتائج البحث تصوراً لكامل المدة المدروسة في هذا البحث، أدرجنا في ملف MATLAB (Dw2D) القيم الحقيقة والمتبَّأ بها بواسطة المتتبَّع العصبي، بحيث نبدأ، لكل يوم من أيام الأسبوع (الأحد مثلًا)، بقيمة الاستطاعة في الساعة الثامنة من يوم الأحد للأسبوع الأول، والقيمة التي تليها تمثل قيمة الاستطاعة في الساعة التاسعة ليوم الأحد من الأسبوع الثاني وهكذا... أُدْرِجَت نتائج البحث في الجداول 3، 2، 1 ومبينة في الأشكال 9 حتى 15، التي تُظْهِر تغيرات الاستطاعة الظاهرية لمختلف أيام الأسبوع وفي المدة المدروسة 38 أسبوعاً.

من الجداول 3،2،1، نجد، أنَّ أكبر خطأ نسبي مئوي في المدة المدروسة في هذا البحث (38 أسبوعاً) هو: ل يوم الأحد - (-2.7%)
ل يوم الأربعاء - (-4.69%)
ول يوم الجمعة - (3.84%).

بمقارنة الخطأ النسبي المئوي الناتج في هذا البحث بالخطأ النسبي المئوي الناتج في [5] ل يوم الأربعاء، نجد أنَّ الدقة تحسنت في هذا البحث وانخفاض الخطأ النسبي المئوي بمقدار 58%. ول يوم الأحد بمقدار 71%， ونظراً إلى أنَّ يوم الأحد في خاركيف يقابله يوم الجمعة عندنا فيكون مقدار تخفيف الخطأ النسبي المئوي هو 58% أيضاً. وهذا التحسين ينتج على الرغم من أنَّ هكذا مقارنة (أكبر خطأ يمكن أن يحصل خلال 24 ساعة [5] مع أكبر خطأ يمكن أن يحصل خلال 38 أسبوعاً (في هذا البحث)) هي لصالح [5].

الجدول 1

الأحد			
الخطأ النسبي المنوي	القيمة المقدرة بواسطة الشبكة العصبية (MVA)	القيمة الحقيقة (MVA)	رقم القيمة
0.39	17.91	17.84	1
1.12	33.27	32.90	2
-0.4	32.47	32.60	3
0.71	29.65	29.44	4
-0.97	31.49	31.80	5
-1.62	29.22	29.70	6
-1.57	28.13	28.58	7
0.14	27.82	27.78	8
-0.44	26.70	26.82	9
-1.28	26.24	26.58	10
0.23	34.92	34.84	11
-1.76	36.82	37.48	12
-0.2	33.95	34.02	13
-0.17	34.82	34.88	14
1.64	29.70	29.22	15
-0.75	25.27	25.46	16
-0.47	21.04	21.14	17
-0.55	18.02	18.12	18
-0.96	15.41	15.56	19
-2.7	15.39	15.82	20
1.17	15.62	15.44	21
1.6	16.26	16.00	22
1.11	16.36	16.18	23
-0.35	17.26	17.32	24
1.05	22.17	21.94	25
0.57	28.26	28.10	26
-0.89	28.98	29.24	27
-1.23	27.36	27.70	28
0	29.10	29.10	29
-1.03	30.76	31.08	30
1.73	30.56	30.04	31
0.07	29.60	29.58	32
-0.04	24.85	24.86	33
-0.21	28.00	28.06	34
0.1	29.27	29.24	35
1.66	33.61	33.06	36
-1.16	35.03	35.44	37
1.03	36.15	35.78	38

الجدول 2

الأربعاء			
الخطأ النسبي المنوي	القيمة المقدرة بواسطة الشبكة العصبية	القيمة الحقيقية	رقم القيمة
0.19	26.67	26.62	1
-0.85	25.56	25.78	2
-1.34	33.19	33.64	3
0.01	31.33	31.32	4
1.04	31.14	30.82	5
-0.07	28.78	28.8	6
-4.69	29.85	31.32	7
-2	25.14	25.66	8
-2.18	23.87	23.36	9
-1.96	28.02	28.58	10
0.81	31.68	31.94	11
-1.44	36.21	36.74	12
1.45	35.67	35.16	13
1	34.40	34.06	14
0.2	29.96	29.90	15
-0.95	26.03	26.28	16
0.3	23.49	23.42	17
-3.3	19.32	19.98	18
0.87	16.20	16.06	19
0.6	15.01	14.92	20
1.82	15.62	15.34	21
-1.57	16.28	16.54	22
-2.83	18.54	19.08	23
-0.06	17.11	17.12	24
3.06	21.89	21.24	25
-1.8	27.26	27.76	26
-1.17	28.70	29.04	27
-1.19	28.99	29.34	28
1.47	30.46	30.02	29
-1.24	29.37	29.74	30
-0.5	30.05	30.20	31
1.79	22.8	22.4	32
-2.18	25.16	25.72	33
-0.28	28.30	28.38	34
2.24	26.48	25.90	35
0.26	30.60	30.52	36
-0.76	35.03	35.30	37
1.06	37.11	36.72	38

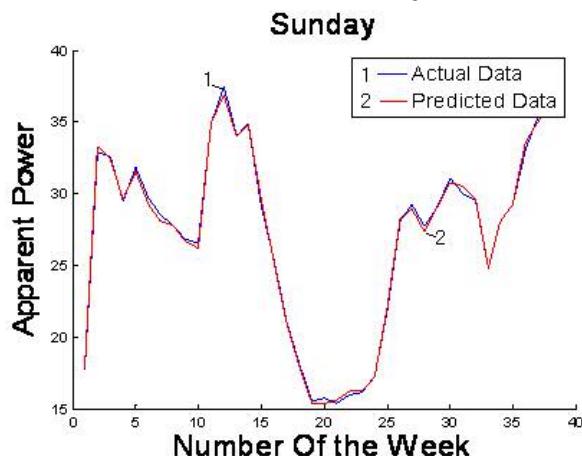
الجدول 3

الجامعة			
رقم القيمة	القيمة الحقيقة	القيمة المقدرة بواسطة الشبكة العصبية	الخطأ النسبي المنوي
1	25.62	25.56	-0.23
2	23.28	23.02	-1.12
3	25.54	25.33	-0.82
4	28.58	28.66	0.28
5	30.66	31.14	1.57
6	29.22	29.77	1.88
7	29.34	28.83	-1.74
8	23.90	24.30	1.67
9	24.30	24.02	-1.15
10	28.70	28.87	0.59
11	33.26	33.16	-0.3
12	33.84	33.68	-0.47
13	35.16	35.09	-0.2
14	32.52	32.34	-0.55
15	29.96	30.07	0.36
16	25.28	25.28	0
17	21.06	20.82	-1.12
18	18.08	18.56	2.65
19	15.16	15.59	2.83
20	14.30	14.53	1.6
21	16.00	15.65	-2.19
22	16.28	16.28	0
23	15.61	16.21	3.84
24	15.62	16.08	2.94
25	18.90	18.79	-0.58
26	19.84	19.74	-0.5
27	22.40	21.87	-2.36
28	24.50	24.36	-0.57
29	27.92	28.30	-1.36
30	25.58	25.30	-1.04
31	26.78	27.14	1.34
32	23.96	24.09	0.54
33	25.36	25.36	0
34	24.54	24.37	-0.69
35	24.18	24.16	-0.08
36	30.08	30.24	0.53
37	33.86	33.62	-0.7
38	29.70	29.40	-1

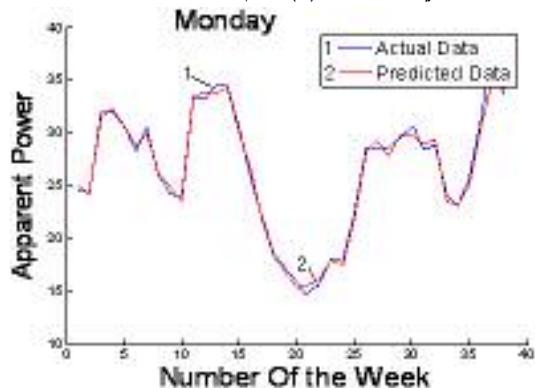
من نتائج البحث المبنية في الأشكال 9 حتى 15 وفي الجداول 1، 2، 3، ومن المقارنة

نلاحظ ما يأتي:

1- من خلال مقارنة التنبؤ بالطلب على الطاقة الكهربائية الناتج كثمرة لهذا البحث والمستوى الحقيقي للاستهلاك نجد أنَّ المتتبُّع العصبيوني المستخدم في هذا البحث يعطي دقة كبيرة وكافية للتطبيقات العملية. وهذه الدقة بالمقارنة بالدقة الناتجة في بحوث سابقة^[5]، تحسنت بمقدار 58%.



الشكل 9. مقارنة منحنى التنبؤ بالطلب على الطاقة الكهربائية (1) ومنحنى المستوى الحقيقي للاستهلاك (2) لأيام الأحد من المدة المدرosa.



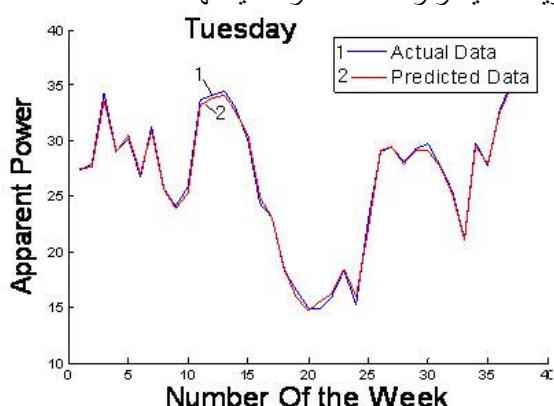
الشكل 10. مقارنة منحنى التنبؤ بالطلب على الطاقة الكهربائية (1) ومنحنى المستوى الحقيقي للاستهلاك (2) لأيام الاثنين من المدة المدرosa.

2- تُظهر المنحيات بشكل واضح تغيرات استهلاك الطاقة في محافظة السويداء بتغير الظروف الجوية. فنلاحظ مثلاً أنَّ استهلاك الطاقة يكون منخفضاً جداً في فصل الربيع وتحديداً في المدة الواقعية بين الأسبوع الخامس عشر وال السادس والعشرين من السنة. ويزداد الاستهلاك في فصل الصيف وفي فصل الشتاء بشكل خاص، باستثناء أيام الصحو المشمسة.

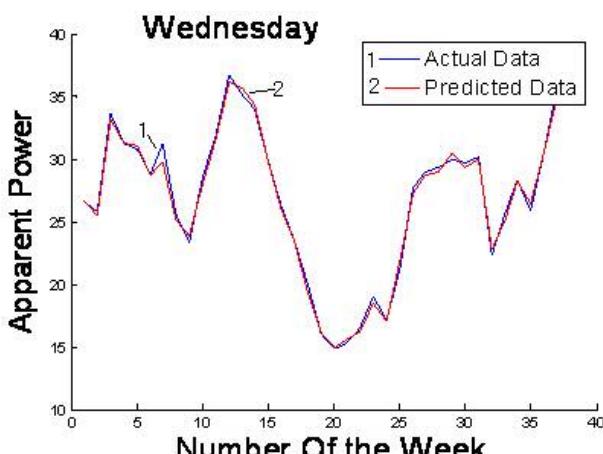
3- رغم أن تدريب الشبكة تم على أساس المعطيات المتوفرة عن استهلاك الطاقة في محافظة السويداء إلا أن البحث والبرامج المستخدمة فيه تصلح لأية مدينة أو منشأة بشرط إدخال المعطيات الجديدة وإجراء عملية تعليم جديدة.

4- يمكن للمتنبئ العصبي التنبؤ بالطلب الكهربائي لساعة القادمة بدقة كبيرة، وبإضافة القيمة المتنبأ بها إلى المعطيات يمكن التنبؤ بالطلب لساعتين قادمتين أو لعدة ساعات قادمة ... وهكذا، ولكن في هذه الحال تتحفظ الدقة قليلاً.

5- بين البحث إمكانية التنبؤ بمقدار استهلاك الطاقة بطريقة متطرفة وبإمكانيات وطنية، لذلك فمن المفيد جداً لشركات الكهرباء افتقاء متنبئ عصبي من أجل توفير الطاقة والمساعدة في اتخاذ القرار السليم عن تشغيل بعض محطات توليد الكهرباء أو فصلها أو عن زيادة كمية وقود العنفات أو تخفيضها.



الشكل 11. مقارنة منحنى التنبؤ بالطلب على الطاقة الكهربائية (1) ومنحنى المستوى الحقيقي للاستهلاك (2) أيام الثلاثاء من المدة المدرسة.



الشكل 12. مقارنة منحني التنبؤ بالطلب على الطاقة الكهربائية (1) ومنحني المستوى الحقيقي للاستهلاك (2) أيام الأربعاء من المدة المدروسة.

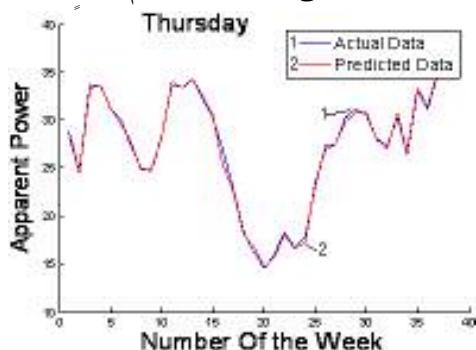
5-الخاتمة والتوصيات والآفاق المستقبلية للبحث:

حاولنا في هذا البحث تقديم متتبع عصبيون سهل الاستعمال، مبني على أساس الشبكة BNN ، كمساعد لمراقبة الشبكة الكهربائية في مراكز تنسيق توزيع الطاقة وتوليدها للمساعدة في اتخاذ القرار، وقد أظهرت نتائج البحث أنَّ دقة هذا النوع من المتتابعات عالية جداً بالمقارنة بالطرق المستخدمة سابقاً، وهذا يشير إلى صوابية الطريقة المتتبعة في هذا البحث، الذي يشكل إسهاماً بحثياً للمهتمين في هذا المجال والراغبين في تطوير هذا الاتجاه العلمي وتطبيقه.

و كآفاق مستقبلية لهذا البحث نوصي بالتنسيق بين وزارة الكهرباء والجامعة من أجل تحقيق الآتي:

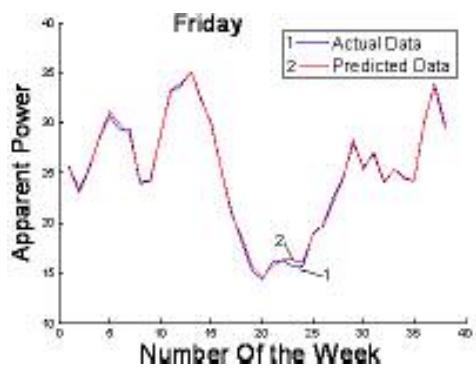
- 1- إجراء بحوث لجميع مراكز تنسيق توزيع الطاقة في القطر، بحيث يتمكن كل مركز من التنبؤ بالطاقة المطلوبة لجميع فروعه.

2- أتمتة عملية تحصيل المعلومات اللازمة لبرنامج التنبؤ، بحيث يتم تحصيل مقدار الاستطاعة المستهلكة في الساعة الحالية فقط وإزاحة باقي المعطيات برمجياً ساعة إلى الخلف. وإظهار القيمة المُتنبأ بها على شاشة ذات حجم كاف.

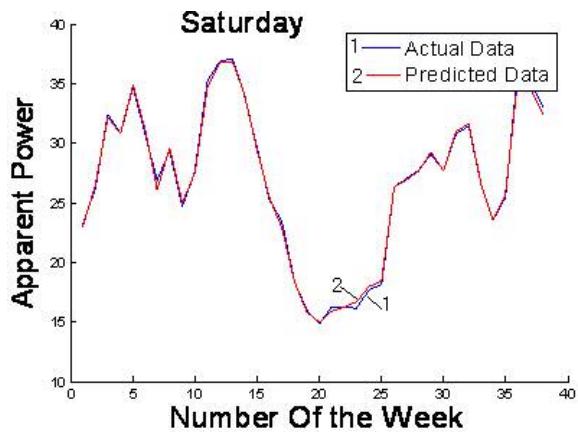


الشكل 13. مقارنة منحنى التنبؤ بالطلب على الطاقة الكهربائية (1) ومنحنى المستوى الحقيقى للاستهلاك (2) أيام الخميس من المدة المدروسة.

3- إجراء بحوث للتنبؤ بمقدار الطاقة الكهربائية المطلوبة لسنوات القادمة، وذلك بعد تجميع معطيات عن الطاقة الكهربائية المستهلكة منذ انتشار الكهرباء في أغلب مناطق القطر، الأمر الذي يساعد في عملية التخطيط للمستقبل.



الشكل 14. مقارنة منحنى التنبؤ بالطلب على الطاقة الكهربائية (1) ومنحنى المستوى الحقيقى للاستهلاك (2) أيام الجمعة من المدة المدروسة.



الشكل 15. مقارنة منحنى التنبؤ بالطلب على الطاقة الكهربائية (1) ومنحنى المستوى الحقيقي للإستهلاك (2) أيام السبت من المدة المدروسة.

شكل مشابه يمكن التنبؤ بالطلب على الطاقة الكهربائية لمدن أخرى أو لقطر كامل أو لمرأكز التنسيق كما ذكرنا سابقاً بشرط توافر المعطيات، وكذلك يمكن بهذه الطريقة التنبؤ بالطلب على المياه والغاز والنفط وكثير من الأمور التي تحتاج إلى بحوث مخصصة لهذه التنبؤات.

المراجع

1. Bakirtzis A.G., Petridis V., Kiartzis S.J., Alexiadis M.C.
Maissis A.H. A Neural Network Short Term Load Forecasting
Model for the Greek Power System //IEEE Trans. on Power Systems.-
1996.-v.11.-N2.-pp.858-863.
2. Caire P., Hatabian G., Muller C. Progress in Forecasting by Neural
Networks //Int. Joint Conf. on Neural Networks.
Baltimore Maryland, June 7-11, 1992.-vol.2.-pp. 540-545.
3. Papalexopoulos A.D., Hao S., Peng T.-M. Implementation of a
Neural Network Based Load Forecasting Model for the
EMS//IEEE Power Eng. Review.- 1994.-Nov.-pp.65-66.
4. Voronovski G.K., Makhotelo K.B., and other. Genetic algorithms and
neural networks. -X.:OSNOVA, 1997.
5. Voronovski G.K., Sergeev S.A., Makhotelo. The prediction of
required electrical loads with the help of Neural Network. Problems of
automated electrodrives Theory and practice. 1997.

تاریخ ورود البحث إلى مجلة جامعة دمشق: 31/7/2009.