

تحسين عامل الاستطاعة باستخدام الشبكات العصبونية

احمد صالح¹

(تاريخ الإيداع 10 / 4 / 2016. قُبِلَ للنشر في 27 / 10 / 2016)

□ ملخص □

يقدم هذا البحث تقنية جديدة لتحسين عامل الاستطاعة بالاعتماد على الشبكات العصبونية الاصطناعية. حيث يتم التحكم بمحرك متوافق عن طريق متحكم عصبوني للتعامل مع مشكلة تعويض الاستطاعة الردية للنظام، وذلك بهدف تحسين عامل الاستطاعة.

تم في هذا البحث نمذجة النظام الكهربائي والمتحكم العصبوني باستخدام برنامج ماتلاب، وقد بينت النتائج أن هذه الطريقة قد تغلبت على المشاكل التي تحدث عند استخدام الطرق التقليدية (استخدام المكثفات الساكنة)، كالتأخير الزمني والتغيرات الخطوية في تعويض الاستطاعة الردية، بالإضافة إلى السرعة بالمقارنة مع التعويض باستخدام المكثفات.

الكلمات المفتاحية: الشبكات العصبونية الاصطناعية، تحسين عامل الاستطاعة، المحرك المتوافق، برنامج

ماتلاب MATLAB R2008a.

¹قائم بالأعمال معاون - قسم هندسة الطاقة الكهربائية - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

Power Factor Correction Using Artificial Neural Networks

Ahmad Saleh²

(Received 10 / 4 / 2016. Accepted 27 / 10 / 2016)

□ ABSTRACT □

This paper presents a new technique based on artificial neural networks (ANNs) to correct power factor. A synchronous motor controlled by the neural controller was used to handle the problem of reactive power compensation of the system, in order to correct power factor.

In this paper, the electrical system and the neural controller were simulated using MATLAB. The results have shown that the presented technique overcomes the problems in conventional compensators (using static capacitors) such as time delay and step changes of reactive power besides to the fast compensation compared to the technique with capacitors groups.

Keywords: Artificial neural networks, Power factor correction, Synchronous motor, MATLAB R 2008a.

² Academic Assistant – Department of electrical power – Faculty of Mechanical & Electrical Engineering – Tishreen University – Lattakia – Syria.

مقدمة:

تستجر الأحمال التحريضية المغذاة بتيار متناوب في نظم القدرة الكهربائية استطاعة فعلية وردية. حيث يتم تحويل الاستطاعة الفعلية إلى حرارة، ضوء وطاقة ميكانيكية أو إلى أشكال أخرى من الطاقة، بينما لا يمكن تحويل الاستطاعة الردية. تزيد الاستطاعة الردية من قيمة الاستطاعة الظاهرية المقدره للأحمال، وبذلك فإن تقليل ساعات الانتاج والنقل والتوزيع لخط نقل القدرة هو نتيجة لعامل الاستطاعة المنخفض. ولكي يتم التخلص من هذا الأثر يجب تحسين عامل الاستطاعة.

عموماً يتم تعويض الاستطاعة الردية بواسطة مجموعة من المكثفات الساكنة مزودة بدارة تحكم تحوي ريليهات، مؤقتات زمنية وكونتكتورات. وتعرف هذه الطريقة بالطريقة التقليدية ومن مساوئها: المشاكل الميكانيكية، الاستجابة البطيئة، التعويض الزائد او الناقص والتوافقيات بسبب التغيرات الخطوية في مجموعات المكثفات أثناء الفصل والوصل [1].

من الطرق المستخدمة أيضاً لتعويض الاستطاعة الردية هي المعوضات الساكنة الثايرستورية (SVCs) والتي يمكن أن تعطي تعويضاً بدون التغيرات الخطوية، ويمكن تصنيفها إلى أربعة أنواع:

- المفاعلات ذات القواطع الثايرستورية (TCR Thyristor Controlled Reactor).
- المكثفات ذات القواطع الثايرستورية (TSC Thyristor Switch Capacitor).
- الدمج بين النوعين السابقين (TCR-TSC).
- المعوضات الساكنة المتقدمة (STATCOM).

يتم استخدام المعوضات الساكنة للحصول على الاستقرار المتكامل للجهد وهي أسرع من الطريقة السابقة ولكن تترافق بمشاكل ميكانيكية أيضاً بالإضافة إلى توليد توافقيات في الجهد والتيار ومشاكل في استقرار النظام [2]. بالإضافة إلى الطرق السابقة يمكن استخدام الآلة المتوافقة لتعويض الاستطاعة الردية وبالتالي تحسين عامل الاستطاعة، وتسمى بالمكثفات المتوافقة وقد لعبت المكثفات المتوافقة دوراً أساسياً في التحكم بالجهد والاستطاعة الردية لأكثر من 50 عاماً. حيث تستخدم لتحسين الاستقرار وإبقاء الجهد ضمن الحدود المرغوبة عند الأحمال مختلفة والحالات الطارئة [3].

أهمية البحث وأهدافه:

تكمن أهمية هذا البحث في تقديم تقنية جديدة لتحسين عامل الاستطاعة تعتمد على تقنيات الذكاء الصناعي (الشبكات العصبونية) للتحكم بمعوض متوافق عن طريق تغيير تيار التهيج. حيث تم نمذجة نظام كهربائي باستخدام برنامج Matlab وتم أخذ البيانات الموافقة للعمل عند أحمال مختلفة من هذا النموذج وتدريب المتحكم العصبوني عند قيم عمل تكافئ عامل استطاعة قريب من الواحد وتم اختبار هذا المتحكم عند قيم مختلفة للحمل للحصول على تيار تهيج مناسب. إن استخدام المعوض العصبوني يخلصنا كلياً من المشاكل المذكورة سابقاً. بالإضافة إلى الحصول على تيار التهيج المطلوب تماماً للحمل بدون أي تأخير مقارنة مع الطرق الأخرى المذكورة سابقاً.

طرائق البحث ومواده:

لقد أصبحت الشبكات العصبونية الاصطناعية شائعة الاستخدام في العديد من التطبيقات والمجالات الهندسية بسبب خواصها المميزة مثل قابلية التعلم والتعميم والسرعة في الحسابات (العمليات البرمجية) والسهولة في الإنجاز. وقد أصبحت الشبكات العصبونية تستخدم مؤخراً في أمن النظام الكهربائي، وتقييم استقرار نظام القدرة والسك SVC المثالية والتحكم بالتحريض والتيار المستمر والمحركات المتوافقة [4].

وقد اعتمدت طريقة البحث على:

- نمذجة نظام كهربائي باستخدام برنامج MATLAB.
- أخذ قيم البارومتريات والقياسات من هذا النموذج وإدخالها إلى متحكم عصبوني.
- تصميم المتحكم العصبوني باستخدام أداة NNTOL في MATLAB.
- تدريب هذا المتحكم على القيم المأخوذة من النموذج.
- اختبار المتحكم عند قيم مختلفة للحمل التحريضي وتوضيح كيفية تحسين عامل الاستطاعة.

تحسين عامل الاستطاعة:

يتم نقل وتوزيع الاستطاعة الكهربائية التي تم توليدها بواسطة المولدات ومن ثم استهلاكها في الأحمال. بالإضافة إلى الاستطاعة الفعلية المنقولة في الخط يجب نقل الاستطاعة الردية للأحمال التحريضية. يمكن توليد هذه الاستطاعة الردية من قبل مولد متوافق في محطة التوليد ولكن أيضاً توليد هذه الاستطاعة الردية من أي منبع آخر مثل محرك متوافق أو مجموعة مكثفات موصولة قرب الحمل. منبع الاستطاعة الردية يجب أن يكون قريباً جداً من الحمل من أجل تشغيل فعال للنظام. إذا تم الحصول على الاستطاعة الردية من محرك متوافق أو مجموعة مكثفات يسمى هذا النظام: معوض استطاعة ردية. ولذلك فإن عامل الاستطاعة لهذا النظام يمكن إبقاؤه ضمن القيم المطلوبة [5].

يرمز لعامل الاستطاعة بـ PF أو $\cos\phi$ ، وهو النسبة بين الاستطاعة الفعالة إلى الاستطاعة الظاهرية والذي

يمكن أن يتم حسابه من الشكل (1) بالعلاقة:

$$pf = \frac{\text{Active Power}}{\text{Apparent Power}} = \frac{P}{S} \quad \dots \dots (1)$$

إن الاستطاعة الردية المستجرة عبر الخط من قبل الحمل التحريضي تكون متأخرة بـ 90° . إذا تم وصل مكثف إلى النظام فستقدم استطاعة ردية للنظام، إن اتجاه الاستطاعة الردية السعوية (Qcap) عكس اتجاه الاستطاعة الردية التحريضية (Qind) كما هو موضح في التمثيل البياني لتحسين عامل الاستطاعة الموضح بالشكل (1).

إن الاستطاعة الردية التحريضية المسحوبة من قبل الدارة سيتم تقليلها بواسطة الاستطاعة الردية السعوية، مؤدية إلى إنقاص الاستطاعة الظاهرية من S إلى S1. كذلك فإن زاوية الطور بين الاستطاعة الفعلية والاستطاعة الظاهرية الجديدة ستقلص من ϕ إلى ϕ_1 . لذلك فإن عامل الاستطاعة سيزداد من $\cos\phi$ إلى $\cos\phi_1$ وبذلك يكون عامل الاستطاعة الجديد:


$$\text{New } pf = \cos\phi_1 = \frac{P}{S_1} \quad \dots \dots (2)$$

وباختيار القيمة المناسبة للمكثف يمكن تعويض عامل الاستطاعة إلى قيمة قريبة من الواحد على أية حال عملياً

فإنه يتم تحسين عامل الاستطاعة ليصل إلى قيمة بين 0.9 و 0.95 [6].

الشبكات العصبونية الاصطناعية:

إن الشبكات العصبونية الصناعية مستوحاة من تقنيات الذكاء البشري. تتكون الشبكات العصبونية عموماً من عدد من عناصر معالجة بسيطة ومرتبطة مع بعضها بشكل جيد ومنظمة في طبقات كما هو موضح في الشكل (2). هذه العناصر



الشكل (1): تعويض الاستطاعة الردية بالمكتفات

أو ما يدعى بالنيورونات (العصبونات) تعالج المعلومات بواسطة استجابة الحالة الديناميكية لمدخلات خارجية. ولديها القدرة على التعلم بواسطة عدد من النماذج المعروفة. إن عملية التدريب تقوم بتعديل أوزان وعتبات عناصر المعالجة. عندما يتم التعديل بحيث يكون الفرق بين خرج الشبكة العصبونية والخرج الهدف أصغر ما يمكن نقول هنا بأنه قد تم تدريب الشبكة. يوجد العديد من البنى والهندسات المعمارية للشبكات العصبونية. الشبكات العصبونية ذات الطبقات المخفية (أبسط الأنواع ولذلك هي الأكثر انتشاراً بين كل أنواع بنى الشبكات العصبونية). الشكل (2) يوضح شبكة عصبونية بثلاث طبقات: طبقة الدخل وطبقة الخرج والطبقة الوسطى أو المخفية، تمثل العصبونات بدوائر. العصبونات في طبقة الدخل تعمل على توزيع إشارات الدخل x_i إلى عصبونات الطبقة المخفية بعد ضربها بأوزان الوصلات w_{ji} ويتم حساب الخرج كتابع f للمجموع:

$$y_j = f \left(\sum w_{ij} \cdot x_{ij} \right) \quad \dots \dots (3)$$


التابع f يمكن أن يكون تابع ظل قطعي أو تابع سيغمويد، ويتم حساب خرج العصبونات في طبقة الخرج بنفس الطريقة. يتم تدريب الشبكة العصبونية (تعديل الأوزان) باستخدام مجموعة من الخوارزميات يتيح برنامج ماتلاب استخدام العديد منه [7].

استخدام الشبكات العصبونية الاصطناعية لتحسين عامل الاستطاعة لنظام كهربائي في بيئة

:Matlab

يوضح الشكل (3) المخطط الصندوقي لنظام التعويض المطروح في هذا العمل، ويحتوي هذا المخطط على متحكم عصبوني (Artificial Neural Network ANNC)، أحمال تحريضية متعددة، مقياس عامل استطاعة محرك متوافق موصول مع الشبكة الكهربائية. متغيرات الدخل للمتحكم العصبوني هي تيار الحمل I_L و خطأ عامل

الاستطاعة e وعامل استطاعة النظام $\cos\phi_{system}$. الخرج الوحيد للمتحكم العصبوني هو تيار التهيج I_f أو جهد التهيج V_f .



الشكل (2): شبكة عصبونية متعددة الطبقات

يتم حساب الخطأ في عامل الاستطاعة كما يلي:

$$e = \cos\phi_{ref} - \cos\phi_{system} \quad \dots \dots (4)$$

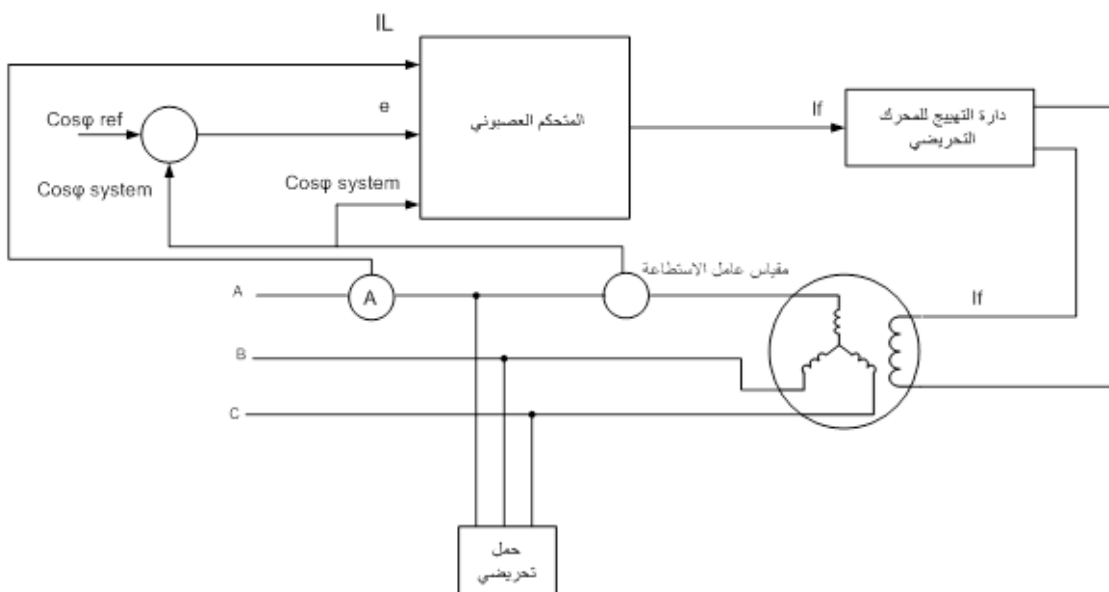
تبدأ عملية التصميم عن طريق تأمين متغيرات الدخل والخرج للمتحكم العصبوني الموضح بالشكل (3). ولكي يتم الحصول على هذه المتغيرات $I_L, e, \cos\phi_{system}, I_f$ يتم نمذجة هذه الدارة في بيئة MATLAB /SIMULINK كما هو موضح في الشكل (4). إن بارامترات الدخل والخرج المستخدمة لتأسيس المتحكم العصبوني يتم الحصول عليه من دارة الاختبار هذه، واجراءات الاختبار المتبعة موضحة كالتالي:

- يتم تطبيق جهد متناوب على ملفات الثابت للمحرك المتوافق.
- يتم تطبيق جهد مستمر على ملفات التهيج للمحرك.
- يتم تعديل تيار الحقل إلى قيمته الأصغرية.
- وبذلك يقوم المحرك المتوافق بسحب تيار أصغري من منبع التغذية ويكون عامل الاستطاعة له يساوي

الواحد.

- يتم اختيار هذه النقطة كمرجع ويتم ابقاء الحمل والجهد المطبق ثابتين.
- يتم تكرار هذه الاختبار لعدة مرات عند أحمال مختلفة.

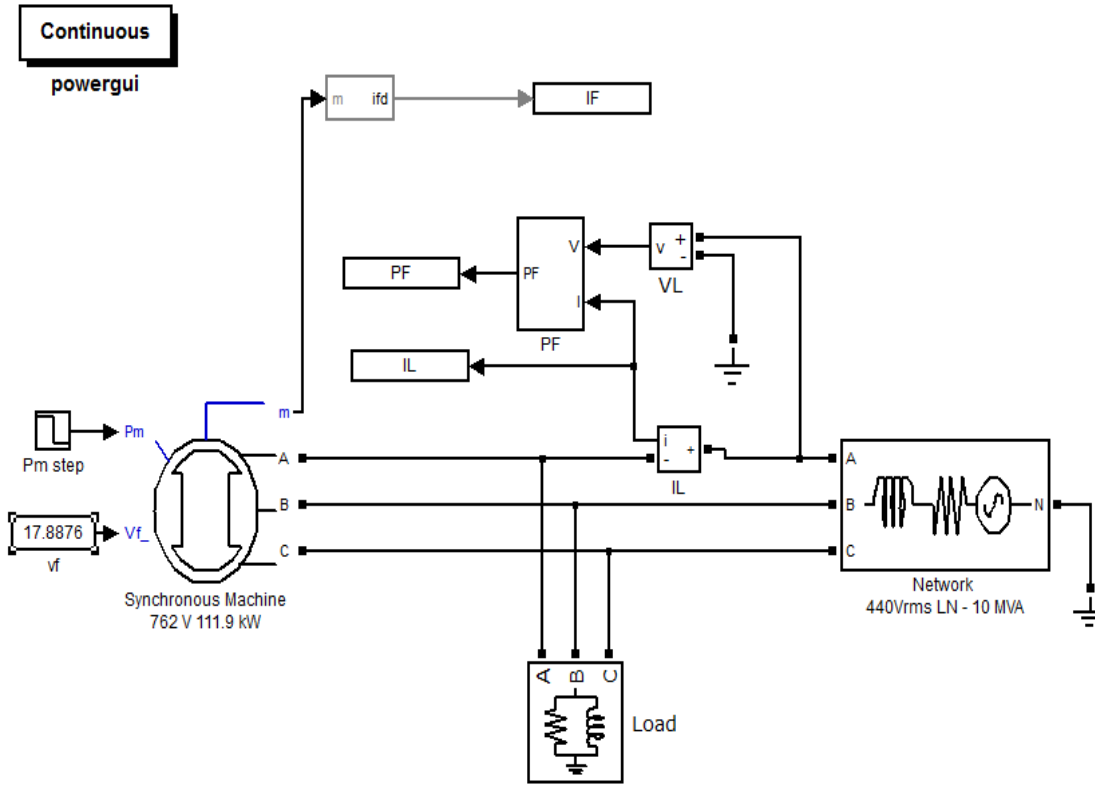
يتم بعد ذلك قياس وتسجيل البارامترات من دائرة الاختبار .



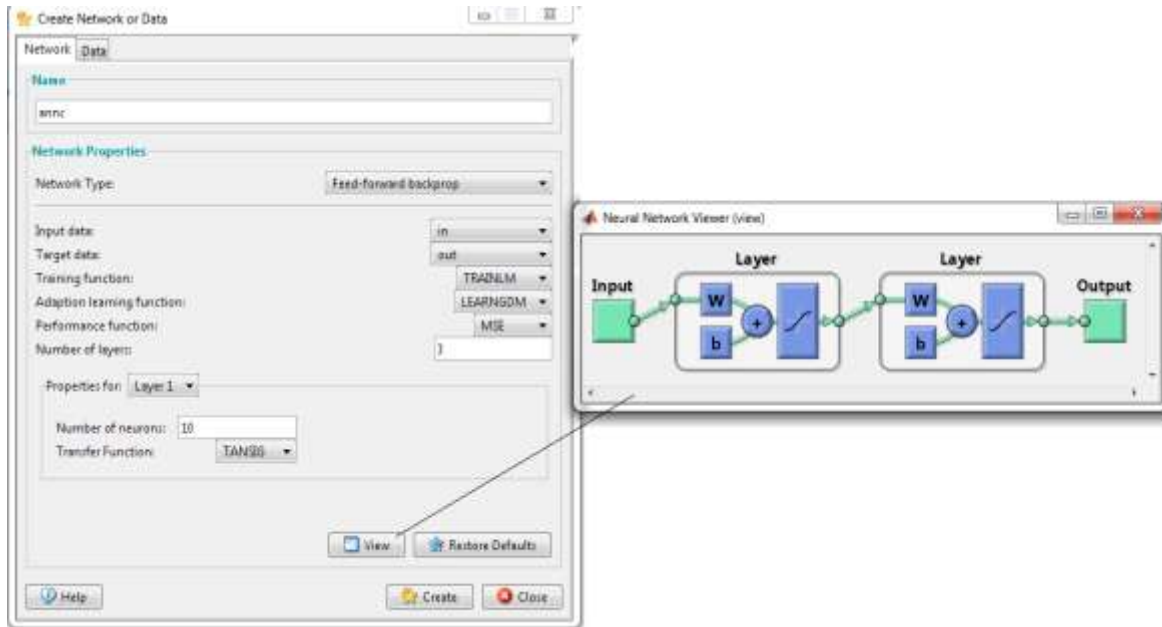
الشكل (3): المخطط الصندوقي لنظام التعويض

يتطلب نظام المتحكم العصبوني فقط إعدادات بارامترات مناسبة للمداخل والأوزان والانحيازات والمخارج. يتم الحصول على بارامترات الدخل والخروج من الاختبارات المستخدمة لتشكيل موديل التعويض المعتمد على الشبكات العصبونية. وبالاعتماد على عدد المدخلات والمخرجات يتم تحديد عدد عصبونات الدخل والخروج. وتم اختيار عدد عصبونات الطبقة المخفية بعد القيام بمجموعة من عمليات التدريب (تجريبياً). وتم استخدام ما مجموعه 100 عينة في التدريب والاختبار (أي نقوم بأخذ البارامترات عند 100 قيمة مختلفة للحمل التحريضي). خمسون عينة استخدمت في التدريب والخمسون عينة المتبقية استخدمت في الاختبار. تبدأ عملية التدريب بتطبيق كل العينات في المجموعة المستخدمة لتدريب الشبكة. نقوم بعملية التدريب في برنامج MATLAB بتشغيل الدارة وإرسال قيم البارامترات إلى WORKSPACE في MATLAB وتخزينها ومن ثم تدريب شبكة عصبونية على هذه القيم باستخدام NNTOOL وهي أداة محاكاة للشبكة العصبونية (على شكل واجهة رسومية) شكل (5). حيث نحدد دخل هذه الشبكة على أنه قيم تيار الحمل وعامل استطاعة النظام والفرق بين عامل الاستطاعة المطلوب وعامل استطاعة النظام، وخروج الشبكة هو تيار أو جهد دائرة التهييج.


الدائرة الموضحة في الشكل (4) تحتوي على محرك متواقت موصول مع الشبكة التي تم تمثيلها بمنبع ثلاثي الطور ومع حمل أومي - تحريضي ثلاثي الطور موصول بشكل نجمي قيمة الحمل الأومي 10Kw وقمنا بتغيير قيمة الحمل التحريضي بقيم تتراوح من 0Kvar إلى 10Kvar. يتم قياس عامل الاستطاعة بواسطة مقياس موضح في الشكل (6)، وهذا المقياس غير متوفر في مكتبة برنامج MATLAB R2008a/Simulink.



الشكل (4): نمذجة دائرة الاختبار باستخدام بيئة MATLAB / SIMULINK



الشكل (5): نمذجة الشبكة العصبونية باستخدام Matlab /NNTOOL



الشكل (6): مقياس عامل الاستطاعة في MATLAB / SIMULINK

يوضح الجدول (1) قيم بارومتريات الدخل والخرج التي تم تدريب المتحكم العصبي عليها.

جدول (1): قيم بارومتريات الدخل والخرج التي تم تدريب المتحكم العصبي عليها

Load KW	Load Kvar	IL	PF	If	Vf
10	0	0.3589	0.9999	137.6025	17.8876
10	0.2	0.1405	1	137.6028	17.8876
10	0.4	0.7234	0.9999	138.3719	17.9876
10	0.6	0.507	0.9999	138.3718	17.9876
10	0.8	0.2976	0.9999	138.372	17.9876
10	1	0.092	1	138.3714	17.9876
10	1.2	0.7629	0.9999	139.236	18.1
10	1.4	0.5466	0.9999	139.2364	18.1
10	1.6	0.3354	0.9999	139.2364	18.1
10	1.8	0.1231	1	139.2362	18.1
10	2	0.7003	0.9999	140.0047	18.2
10	2.2	0.483	0.9999	140.005	18.2
10	2.4	0.2718	0.9999	140.0049	18.2
10	2.6	0.0578	1	140.0058	18.2
10	2.8	0.6363	1	140.774	18.3
10	3	0.4171	0.9999	140.7741	18.3
10	3.2	0.2146	1	140.7737	18.3
10	3.4	0.7818	0.9998	141.5436	18.4
10	3.6	0.5691	0.9999	141.5435	18.4
10	3.8	0.3575	0.9999	141.5429	18.4
10	4	0.1558	1	141.5427	18.4
10	4.2	0.7196	0.9999	142.3119	18.5
10	4.4	0.5023	0.9999	142.3119	18.5
10	4.6	0.2912	0.9999	142.3126	18.5
10	4.8	0.0846	1	142.3117	18.5
10	5	0.6485	0.9999	143.0814	18.6
10	5.2	0.4417	0.9999	143.0813	18.6

10	5.4	0.2224	0.9999	143.0813	18.6
10	5.6	0.0133	1	143.0807	18.6
10	5.8	0.5717	0.9999	143.8497	18.7
10	6	0.3737	0.9999	143.8499	18.7
10	6.2	0.1534	1	143.8499	18.7
10	6.4	0.7269	0.9999	144.619	18.8
10	6.6	0.5171	0.9999	144.6188	18.8
10	6.8	0.3015	0.9999	144.6194	18.8
10	7	0.0908	1	144.619	18.8
10	7.2	0.6551	0.9999	145.3877	18.9
10	7.4	0.4454	0.9999	145.3869	18.9
10	7.6	0.2247	0.9999	145.3877	18.9
10	7.8	0.0208	1	145.3877	18.9
10	8	0.5876	0.9999	146.1568	19
10	8.2	0.3662	0.9999	146.1574	19
10	8.4	0.1665	1	146.1567	19
10	8.6	0.7314	0.9999	146.9258	19.1
10	8.8	0.515	0.9999	146.9262	19.1
10	9	0.298	0.9999	146.926	19.1
10	9.2	0.0946	1	146.9255	19.1
10	9.4	0.6635	0.9999	147.6947	19.2
10	9.6	0.4622	0.9999	147.6948	19.2
10	9.8	0.2263	0.9999	147.695	19.2
10	10	0.015	1	147.6951	19.2

وتم اختبار المتحكم العصبوني على 50 قيمة للحمل، مختلفة عن قيم التدريب وأعطى المتحكم قيم لتيار وجهد التهيج نتج عنها عامل استطاعة قريب من الواحد، كما هو موضح في الجدول (2).

جدول (2): قيم بارومتريات الدخل التي تم اختبار المتحكم العصبوني عليها وقيم الخرج الناتجة


Load KW	Load Kvar	IL	PF	If	Vf
10	0.1	0.2493	0.9999	137.6029	17.8876
10	0.3	0.0333	1	137.6029	17.8876
10	0.5	0.6204	0.9999	138.3727	17.9876
10	0.7	0.3994	0.9999	138.994	17.9876
10	0.9	0.1932	1	138.3721	17.9876
10	1.1	0.8674	0.9998	139.2358	18.1
10	1.3	0.653	0.9999	139.2366	18.1
10	1.5	0.44	0.9999	139.2355	18.1
10	1.7	0.2259	0.9999	139.236	18.1
10	1.9	0.0193	1	139.2359	18.1
10	2.1	0.5918	0.9999	140.005	18.2
10	2.3	0.375	0.9999	140.0051	18.2

10	2.5	0.1654	1	140.0052	18.2
10	2.7	0.741	0.9999	140.7738	18.3
10	2.9	0.5291	0.9999	140.7739	18.3
10	3.1	0.3132	0.9999	140.7747	18.3
10	3.3	0.1057	1	140.774	18.3
10	3.5	0.6767	0.9999	141.543	18.4
10	3.7	0.4602	0.9999	141.5429	18.4
10	3.9	0.2516	0.9999	141.543	18.4
10	4.1	0.0412	1	141.5427	18.4
10	4.3	0.6074	0.9999	142.3123	18.5
10	4.5	0.3998	0.9999	142.312	18.5
10	4.7	0.1826	1	142.3118	18.5
10	4.9	0.7523	0.9999	143.081	18.6
10	5.1	0.549	0.9999	143.0805	18.6
10	5.3	0.3349	0.9999	143.0807	18.6
10	5.5	0.1166	1	143.081	18.6
10	5.7	0.6869	0.9999	143.8497	18.7
10	5.9	0.4752	0.9999	143.8506	18.7
10	6.1	0.2604	0.9999	143.85	18.7
10	6.3	0.0505	1	143.8498	18.7
10	6.5	0.6175	0.9999	144.619	18.8
10	6.7	0.4108	0.9999	144.6188	18.8
10	6.9	0.2004	1	144.6186	18.8
10	7.1	0.7689	0.9999	145.3866	18.9
10	7.3	0.5503	0.9999	145.388	18.9
10	7.5	0.3363	0.9999	145.3879	18.9
10	7.7	0.1235	1	145.3882	18.9
10	7.9	0.6783	0.9999	146.1574	19
10	8.1	0.4769	0.9999	146.1571	19
10	8.3	0.2668	0.9999	146.1568	19
10	8.5	0.0573	1	146.1567	19
10	8.7	0.6224	0.9999	146.9266	19.1
10	8.9	0.4051	0.9999	146.9264	19.1
10	9.1	0.2047	1	146.9256	19.1
10	9.3	0.7502	0.9999	147.6951	19.2
10	9.5	0.5729	0.9999	147.6988	19.2
10	9.7	0.3358	0.9999	147.6952	19.2
10	9.9	0.1201	1	147.6954	19.2
10	10.1	0.6815	0.9999	148.4643	19.3
10	10.2	0.5803	0.9999	148.4642	19.3

إن تصميم المتحكم هو أمر مهم جداً للحصول على تطبيق ناجح، ويشمل عملية التصميم تحديد عدد

عصبونات الدخل

والخرج وعدد الطبقات المخفية للشبكة العصبونية. بالنسبة للمتحكم المستخدم في هذا العمل يحتوي على ثلاثة عصبونات في طبقة الدخل و 10 عصبونات في الطبقة المخفية وعصبون واحد في الخرج. يوضح الشكل (7) تصميم الشبكة العصبونية المستخدمة لتمثيل المتحكم العصبوني.



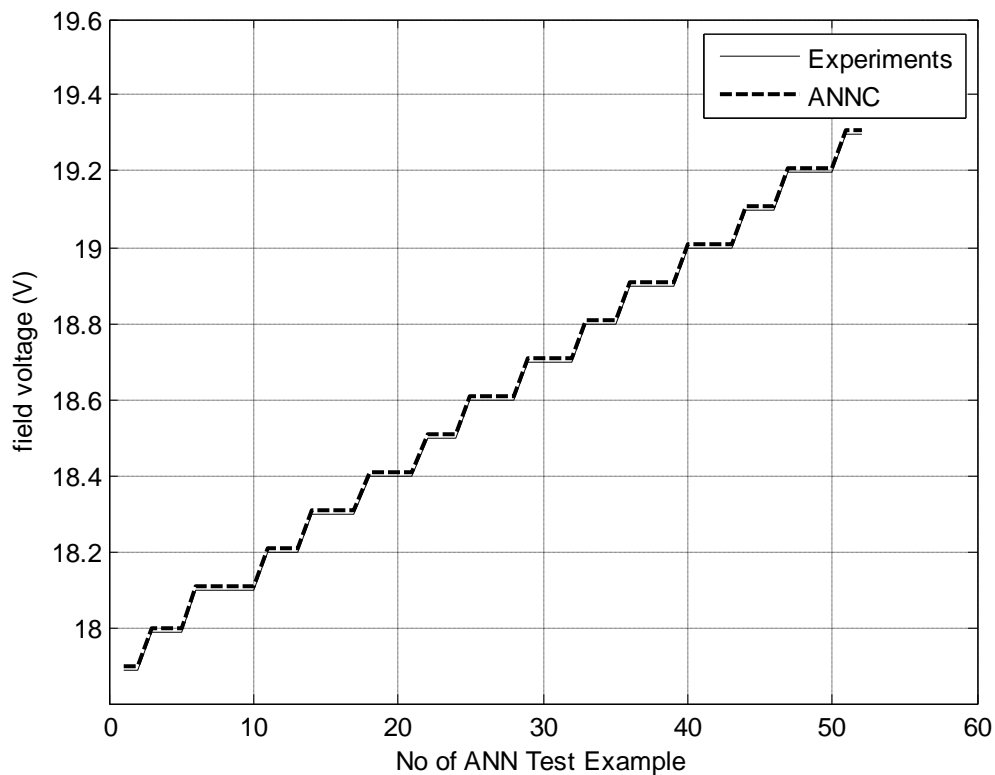
الشكل(7): مخطط المتحكم العصبوني

النتائج والمناقشة:


يوضح الشكل (8) مقارنة نتائج تدريب المتحكم العصبوني مع القيم التجريبية، ونلاحظ من الشكل انه يعطي نتائج مرضية. حيث تبدو القيم متقاربة جداً.

يوضح الشكل (9) النتائج التي يعطيها المتحكم لتحسين عامل الاستطاعة، حيث يبقي المتحكم عامل الاستطاعة عند قيمة ثابتة تقريباً قريبة من الواحد عند الأحمال التحريضية المختلفة.

أي ان هذا المتحكم قد أعطى استجابة سريعة ودقيقة لتغيرات الحمل وقام بإعطاء فعل تحكمي متمثل بتيار تهيج (جهد تهيج) للمحرك المتواقت للحصول على عامل استطاعة قريب من الواحد رغم تغيير قيمة الحمل التحريضي وبدون وجود زيادة أو نقصان في التهيج أو تغيرات خطوية في الاستطاعة الردية أو ظهور للتوافقيات.



الشكل(8): التأكد من نتائج المتحكم العصبوني



الشكل(9): قيم عامل الاستطاعة التي يعطيها المتحكم العصبوني

الاستنتاجات والتوصيات:

في بحثنا المقدم توصلنا إلى الاستنتاجات التالية:

- توضيح نظام التعويض المعتمد على الـ ANNC (Artificial Neural Network Controller) وقد بينت نتائج هذا العمل أن نظام التعويض هذا قد أعطى أداء جيداً. بالإضافة إلى الدقة والمعالجة السريعة لأي نظام تعويض مرغوب.

- إن استخدام ANNC لغرض تحسين عامل الاستطاعة يؤمن الفعالية والموثوقية والكفاءة والنتائج الممتازة.
- إن استخدام ANNC لغرض تحسين عامل الاستطاعة يمكن من تحقيق استقرار في شبكة النقل ويؤمن الاستطاعة العظمى بشكل فعال.
- عندما يتم التحكم بالمحرك المتواقت عن طريق متحكم عصبوني، فإن النظام يصبح قوياً وموثوقاً. ونتيجة لذلك نتخلص من حالتى الزيادة والنقصان في الاستطاعة الردية.
- تمت إزالة مشاكل الطرق التقليدية، مثل المشاكل الميكانيكية والتوافقيات في موجة الجهد والتأخير الزمني والتغيرات الخطوية في جهد التهيج وانزلاق الأقطاب وتحميل الاستطاعة الردية على المحولات وتكلفة الاستطاعة الردية وهبوط الجهد على الخط محسنة بذلك استقرار الجهد ودقة وفعالية النظام.
- الطريقة المقدمة في هذه المقالة مناسبة بشكل كبير في التطبيقات الصناعية طالما أن المحركات المتواقتة موجودة في النظام لأي غرض آخر. ويمكن استخدام هذا النظام لتنظيم الجهد للأحمال المتغيرة.
- نحتاج للعمل أكثر في اختيار البارومترات المناسبة والتدريب المناسب للـ ANNC في عملية الـ Off Line ومن ثم إدخال هذه القيم إلى نظام المتحكم.

المراجع:

- [1] MILLER, T. J. *Reactive Power Control in Electric Systems*. 2nd. ed. John Willey & Sons, Inc New York & London, 1982, 381.
- [2] MEIER, A. *Electric Power Systems: A Conceptual Introduction (Wiley Survival Guides in Engineering and Science)*. s.l. Wiley - IEEE Press, 2006.
- [3] BARKER, S. *Power Management Solutions Exploring Hidden Cost Opportunities*, Siemens, UK, 2010.
- [4] DIXON, J, MORAN, L, RODRIGUEZ, J, DOMKE, R. *Reactive Power Compensation Technologies, State of the Art Review*, CHILE, 2005.
- [5] TENTI, P, MTTAVELLI, P, TEDESCHI, E. *Compensation Techniques Based On Reactive Power Conservation*. Electrical Power Quality and Utilization, Journal ITALY. Vol. XIII, No. 1, 2007, 17-24.
- [6] LIU, F. *Reactive Power Compensation Characteristics of a New SVC for Industry Custom Power System*. Science direct U.S.A 2006.
- [7] SMAGT, P. V. *An Introduction to Neural Networks*, The University of Amsterdam, Eighth edition, November 1996, 450.