

تصنيف الأعطال في خطوط النقل الكهربائية بالاعتماد على الشبكات العصبونية

الدكتور طارق ابراهيم*

الدكتور تمام حيدر**

علي اسعد***

(تاريخ الإيداع 10 / 12 / 2012. قَبْلُ للنشر في 14 / 1 / 2013)

▽ ملخص ▽

تدرس هذه المقالة منهجية جديدة لتحديد وجود العطل من عدمه، وتصنيف الاعطال في الوقت الحقيقي بالاعتماد على الشبكات العصبونية في خطوط نقل القدرة الكهربائية. تعتمد هذه الخوارزمية على استخدام إشارات الجهود، والتيارات بوصفها يمثل دخل للشبكات العصبونية بعد تقطيعها بتردد تقطيع 1 KHZ، وبدون استخدام نافذة بيانات متحركة، حيث ان إشارات الدخل تعالج لحظياً على شكل سلسلة من البيانات المتلاحقة. يعتمد النموذج على ثلاث شبكات عصبونية يعالج كل منها بيانات طور من الأطوار بالإضافة الى شبكة عصبونية رابعة للجهود والتيار الصفرين. يتمكن هذا النظام من تحديد نوع العطل خلال زمن لا يتجاوز الـ 5 ميلي ثانية. تتطلب أنظمة القدرة الحديثة تقنية دقيقة وسريعة للمعالجة في الوقت الحقيقي. تبين دراسات المحاكاة أن التقنية المقترحة قادرة على تمييز حالات العطل المختلفة بشكل دقيق جداً، وقد نجحت هذه التقنية في تحديد جميع أنواع الأعطال تحت شروط النظام المختلفة، بالتالي فإنها دقيقة بنسبة 100% ومناسبة للتطبيق في الزمن الحقيقي.

الكلمات المفتاحية: نظم القدرة الكهربائية- خطوط نقل القدرة- تصنيف الأعطال- شبكات عصبونية.

* استاذ - قسم هندسة الطاقة الكهربائية - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

** مدرس - قسم هندسة الطاقة الكهربائية - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

*** طالب دراسات عليا (ماجستير) - كلية الهندسة الميكانيكية والكهربائية - قسم هندسة الطاقة الكهربائية - جامعة تشرين - اللاذقية - سورية.

Classification of Faults in Power Transmission Lines Using Artificial Neural Networks

Dr. Tareek Ibrahim ^{*}
Dr. Tammam Hayder ^{**}
Ali Asaad ^{***}

(Received 10 / 12 / 2012. Accepted 14 / 1 / 2013)

▽ ABSTRACT ▽

This paper shows a new approach to determine the presence of defects and to classify the defect type online based on Artificial Neural Networks (ANNs) in electrical power system transmission lines. This algorithm uses current and voltage signals sampled at 1 KHz as an input for the proposed ANNs without the involvement of a moving data window, so input data will be processed as a string of data. The model depends on three neural networks one for each phase and another fourth neural network for the involvement of the ground during the fault. Response time of the classifier is less than 5 ms. Moreover modern power system requires a fast, robust and accurate technique for online processing. Simulation studies show that the proposed technique is able to distinguish the fault type very accurate. Also this technique succeeded in determining of all defect types under all system conditions, so it is 100 percent accurate, so it is suitable for online application.

Keywords: Electrical Power Systems, Power Transmission lines, Fault classification, Artificial Neural Networks.

* Professor, Department of Electrical Power Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria

** Assistant Professor, Department of Electrical Power Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

*** postgraduate assistant, Department of Electrical Power Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

مقدمة:

تتعرض خطوط النقل شأنها شأن كل مكونات نظام القدرة الكهربائية، لأعطال غير متوقعة، وذلك لأسباب متعددة، تقلل هذه الأعطال من موثوقية تشغيل النظام، وتعدّ مصدراً من مصادر تهديد استمرارية التغذية الكهربائية. ولأن تلافى حدوث هذه الأعطال بشكل كامل أمر غير ممكن التحقيق، فإنه من المهم أن يتم تحديد وجود العطل ونوعه وفصله بسرعة بحيث يبقى الضرر الذي يسببه هذا العطل في نظام القدرة في أصغر الحدود الممكنة.

تم تقديم الحماية المسافية عام 1920 وشهدت تطوراً مستمراً مروراً بالريليايات الستاتيكية التماثلية مع المضخمات العملية، وكانت الدقة والموثوقية تتحسن باستمرار مع تطور التقنيات.

تستخدم في أجهزة الحماية في الوقت الراهن معايير ارتفاع التيار، انخفاض التوتر، وتغيير الممانعة لإقلاع الحماية. إذ إن استخدام معيار زيادة التيار يعد الطريقة الأبسط والأسرع لتحديد العطل. ولكن في بعض الحالات فإن تيار العطل قد يكون أصغر من قيمة تيار الإقلاع، وذلك بسبب ممانعة المنبع العالية، بالتالي فإن استخدام الجهود في هذه الحالة يعد معياراً إضافياً لإقلاع الحماية حيث أن قيمة الجهد في موقع الزاغل تعتمد على كل من ممانعة المنبع وممانعة العطل.

في الشبكات الهوائية فإن زاوية العطل تكون أكبر بشكل ملحوظ من زاوية الحمل، لذلك فإن الزاوية بين الجهد والتيار يمكن أن تستخدم أيضاً بوصفها تمثلاً معياراً لإقلاع الحماية مما يسهم في زيادة الحساسية.

إن تقنيات معالجة الإشارة Signal Processing والقياسات الرقمية سمحت بدقة أعلى وزمن استجابة أقصر بكثير مع استخدام خوارزميات الترشيح المناسبة، حيث تم تخفيض زمن فصل العطل من مئات الملي ثانية وصولاً إلى عشرات الملي ثانية في التقنيات الرقمية الحديثة [1].

الجزء الأول في الحماية المسافية هو الكشف عن الأعطال وتحديد أنواعها (أي تصنيفها). يجب تحديد الأعطال وتصنيفها في خطوط النقل بسرعة وبدقة، لهذا الغرض تستخدم تقنيات ذكاء صناعي مختلفة منها ما اعتمد على تصنيف الأعطال باستخدام المنطق الضبابي [2] Fuzzy Logic، ومنها ما اعتمد على الشبكات العصبونية ذات التطبيقات المختلفة في مجال نظم القدرة الكهربائية، وقد كانت هذه التقنيات قيد الدراسة خلال العقدين الأخيرين [3].

في مجال تصنيف الأعطال في الشبكة تم استخدام خوارزميات تصنيف متعددة تعتمد في عملها على الشبكات العصبونية، من هذه الخوارزميات ما استخدم تيارات الأطوار كدخل للشبكات العصبونية، إذ أن قيم التيارات تتغير عند حدوث الأعطال في خطوط النقل، واكتشاف العطل وتصنيفه يعتمد على اكتشاف التغيرات في التيارات [4].

في المرجع [5] تم تصنيف الأعطال في خطوط النقل المزوجة باستخدام شبكات عصبونية تعمل على اكتشاف العطل وتصنيفه وفصله خلال زمن لا يتجاوز الـ 10 ملي ثانية.

أهمية البحث وأهدافه:

تكمن أهمية البحث في أن الطريقة المقترحة لتصنيف الأعطال في خطوط النقل لا تستخدم معادلات رياضية لتحديد وجود ونوع العطل بل يتم العمل كاملاً باستخدام الشبكات العصبونية واعتمدنا فقط على المعادلات الرياضية للشبكات العصبونية من نوع Feed forward، وهو ما أسهم بزيادة سرعة الاستجابة ورفع الموثوقية.

يهدف البحث إلى إعداد دراسة كاملة باستخدام النمذجة والمحاكاة من أجل تصنيف الأعطال في خط نقل بالاعتماد على الشبكات العصبونية، آخذين بالحسبان ما تتمتع به هذه الشبكات من ميزات تمكنها من إنجاز المهمة المطلوبة بأقصر زمن ممكن وبموثوقية عالية.

طرائق البحث ومواده:

لقد اعتمدنا في البحث طريقة النمذجة والمحاكاة لخط نقل باستخدام بيئة Simulink في برنامج MATLAB، وتم الاعتماد على الشبكات العصبونية للتعامل مع البيانات وتحديد حالة حصول عطل من عدمه على خط النقل، ومن ثم التحديد الدقيق للأطوار التي حصل عليها العطل (أي تصنيف العطل).

تتم عملية تدريب الشبكات العصبونية المقترحة باستخدام MATLAB-Code.

بنية مصنف الأعطال المعتمد على الشبكات العصبونية:

تتألف البنية المقترحة لمصنف الأعطال من أربع شبكات عصبونية، شبكة لكل طور من أطوار خط النقل وشبكة من أجل الجهد والتيار الصفرين وهذه الشبكات هي:

▪ الشبكة العصبونية للطور A: ANNA

▪ الشبكة العصبونية للطور B: ANNB

▪ الشبكة العصبونية للطور C: ANNC

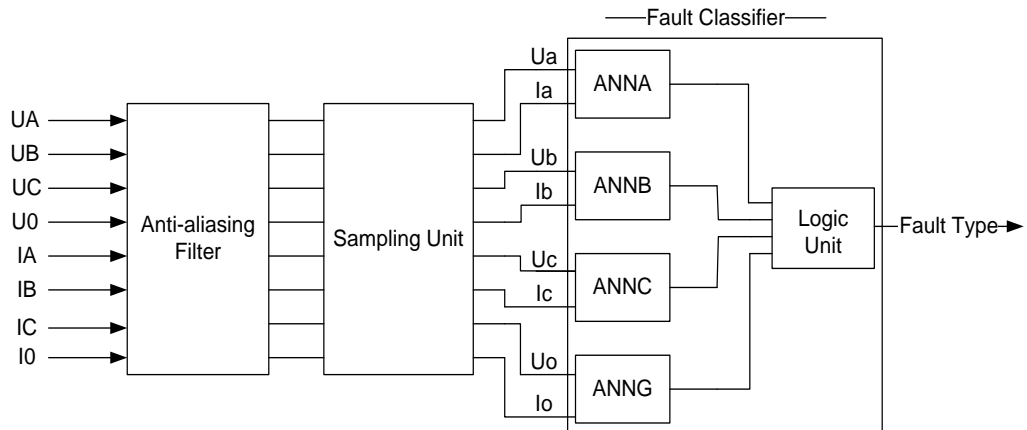
▪ الشبكة العصبونية للتيار والجهد الصفرين G: ANNG

تتحصر وظيفة كل شبكة عصبونية من الشبكات السابقة بتحديد العطل على الطور المربوطة به بغض النظر عن نوعه، وبالنسبة للشبكة العصبونية للتيار والجهد الصفرين فإنه يتم أولاً حساب كل من التيار والجهد الصفرين، ثم إدخالهما إلى الشبكة العصبونية الخاصة بهما.

إشارات الدخل للشبكات العصبونية هي إشارات الجهد والتيار المقابلة، أما الخرج فهو عبارة عن قيم منطقية إما 0 أو 1، حيث تشير القيمة 0 إلى عدم وجود عطل، أما القيمة 1 فتشير إلى حدوث العطل.

تمت معالجة إشارات الدخل (الجهود والتيارات) بإخضاعها لمرشح antialiasing وتقطيعها بتردد تقطيع 1KHz، ثم إدخالها إلى الشبكات العصبونية المقابلة، بعد أن تدخل إشارات الجهود والتيارات جميعاً إلى الشبكات العصبونية المقابلة وتقوم هذه الشبكات بتحديد الأطوار التي حصل عليها العطل ثم تقوم دارة منطقية بتحليل خرج هذه الشبكات لإظهار النتائج.


الأسلوب المعتمد في دراستنا لإدخال البيانات إلى الشبكات العصبونية هو إدخال العينات بشكل لحظي على هيئة سلسلة متتالية من البيانات ومن دون الحاجة إلى استخدام نافذة بيانات متحركة، وهو ما يميز دراستنا عما هو متبع في الدراسات الأخرى، كالمراجع [6] مثلاً، مما أسهم في التقليل من تعقيد النموذج المدروس. يبين الشكل (1) البنية التفصيلية لعملية معالجة الإشارة وتصنيف الأعطال.



الشكل (1) معالجة الاشارات وتسليمها الى مصنف الأعطال

نموذج النظام المدروس:

تمت دراسة خط نقل 230 KV بطول 150 Km، تم بناء نموذج الخط المذكور باستخدام بيئة Simulink في برنامج MATLAB، أخذنا بالحسبان في الدراسة التأثير المتبادل بين الأطوار، حيث تؤخذ بيانات الدخل والخرج التي تم تشكيل عينات التدريب والاختبار منها من قضييب التجميع A، إذ إن إشارات الجهد والتيار المأخوذة من هذا القضييب تمت معالجتها وتجهيزها لتكون دخلاً للشبكة العصبونية، يبين الشكل (2) بنية النظام المدروس.



الشكل (2) بنية النظام وعملية معالجة الإشارة


يتم تقطيع الإشارات بتردد تقطيع 1 KHZ (مع ملاحظة أن الشبكات التي قمنا بتصميمها قادرة على التعامل مع أي تردد تقطيع دون الحاجة إلى إعادة تدريبها من جديد)، ثم تجري ملائمة البيانات لتصبح مناسبة لدخل الشبكة العصبونية، وخرج الشبكة العصبونية يجب أن يكون إما: 0 لايوجد عطل أو 1 يوجد عطل.

بنية الشبكات العصبونية المستخدمة:

ذكرنا أن النموذج المقترح يعتمد في عمله على أربع شبكات عصبونية لمعالجة البيانات، شبكة عصبونية لكل طور (الجهد والتيار) وشبكة لمعالجة الجهد والتيار الصفري، وتم اعتماد الشبكات العصبونية Feed Forward Back [7] propagation بوصفها تمثل نموذجاً لتصنيف العينات إذ إن كل شبكة من الشبكات الأنفة الذكر مؤلفة من ثلاث طبقات: طبقة دخل - طبقات خفية - طبقة خرج

يكون عدد العصبونات في طبقة الدخل تابعاً لعدد الإشارات التي يجري معالجتها، وهي عصبونان (لأن إشارات الدخل هي الجهد والتيار)، أما عدد العصبونات في الطبقة الخفية فيتم تحديده هنا بعد دراسات محاكاة وعملية تدريب

طويلة ومعقدة للوصول إلى الأداء الأفضل، وعدد العصبونات في طبقة الخرج تابع لعدد الإشارات المطلوبة على خرج الشبكة وهي بالطبع عصبون واحد، والشكل (3) يبين البنية العامة للشبكات العصبونية المذكورة أعلاه.




الشكل (3) البنية العامة للشبكات العصبونية

قمنا بتدريب واختبار عدد كبير جداً من الشبكات العصبونية وتغيير بنيتها (عدد الطبقات الخفية - عدد العصبونات في الطبقة الخفية) وبارامتراتنا (مثل توابع التفعيل) للحصول على أفضل أداء، ثم اخترنا الشبكة المناسبة لكل طور من الأطوار.

توابع التفعيل:

تم استخدام تابع $tansig$ إذ إن هذا التابع يستخدم في الشبكات العصبونية عندما تكون السرعة عنصراً مهماً، كما في الشكل (4).



الشكل (4) شكل التابع $tansig$

خوارزمية هذا التابع هي [8]:

$$a = tansig(n) = \frac{2}{(1 + \exp(-2 * n)) - 1}$$

وهو رياضياً مكافئ للتابع $\tanh(n)$ ولكن يختلف عنه بأنه يعمل بسرعة أكبر في بيئة MATLAB، ولكن النتائج يمكن أن تحوي بعض الاختلافات العددية.

تدريب الشبكات العصبونية واختبارها:

تم تجهيز بيانات لكل من عملية التدريب والاختبار حيث قمنا بتجهيز بيانات 960 حالة عطل مختلفة تم فيها تغيير كل من: نوع العطل، مكانه، زاويته، ومقاومته، وهذا موضح في الجدول (1).

الجدول (1) بيانات عملية التدريب

L1-G, L2-G, L3-G, L1-L2-G, L1-L3-G, L2-L3-G, L1-L2, L1-L3, L2-L3, L1-L2-L3-G	نوع العطل
2, 10, 25, 40, 70, 85, 125, 147	مكان حدوث العطل Km
0, 45, 90	زاوية العطل θ
0, 50, 75, 100	مقاومة العطل Ω

ومن أجل عينات الاختبار قمنا بتجهيز 960 حالة عطل مختلفة تم فيها تغيير كل من: نوع العطل، مكانه، زاويته، ومقاومته، وهذا موضح في الجدول (2).

الجدول (2) بيانات عملية الاختبار

L1-G, L2-G, L3-G, L1-L2-G, L1-L3-G, L2-L3-G, L1-L2, L1-L3, L2-L3, L1-L2-L3-G	نوع العطل
3, 30, 50, 90, 130, 147	مكان حدوث العطل Km
0, 30, 60, 90	زاوية العطل θ
0, 10, 40, 100	مقاومة العطل Ω

الجدول (3) زمن استجابة مصنف الأعطال عند حالات عطل مختلفة

نوع العطل	مكان العطل Km	زاوية العطل θ	مقاومة العطل Ω	زمن حدوث العطل ms	زمن اكتشاف المصنف له ms	زمن استجابة مصنف الأعطال ms
L1-G	10	45	50	60	62	2
	10	90	75	60	62	2
L2-G	30	60	75	60	62	2
	30	60	100	70	72	2
L3-G	40	60	10	30	33	3
	50	30	40	30	32	2
L1-L2-G	70	60	40	60	62	2
	90	90	75	60	62	2
L2-L3-G	120	0	50	50	52	2
	130	0	40	50	52	2
L1-L3-G	30	30	40	30	33	3

1	31	30	10	45	50	
2	42	40	10	60	70	L1-L2
2	42	40	50	45	90	
3	63	60	40	90	85	L2-L3
2	62	60	75	30	125	
2	52	50	75	45	40	L1-L3
2	52	50	50	90	125	
5	65	60	100	90	3	L1-L2-L3
3	63	60	100	30	120	

وبنتيجة الاختبار تبين أن نموذج مصنف الأعطال المقترح المنفذ اعتماداً على الشبكات العصبونية نجح بتحديد العطل في جميع حالات الأعطال، وبهذا تكون دقة مصنف الأعطال وقدرته على تحديد العطل بشكل صحيح هي 100% إذ إنه بجميع حالات الاختبار نجح النظام بتحديد العطل.

زمن الاستجابة الدقيقة لحالة العطل هو عبارة عن الفرق بين لحظة حدوث العطل فعلياً ولحظة اكتشاف مصنف الأعطال له وفي جميع حالات الأعطال تراوح هذا الزمن بين 1 إلى 5 ميلي ثانية. يبين الجدول (3) زمن الاستجابة عند حالات مختلفة (الزمن الأطول بين نماذج الاختبار).

تجهيز البيانات:

أخذنا الإشارات المطلوبة من نموذج خط النقل الذي قمنا بتصميمه في بيئة Simulink، ثم تمت معالجة هذه البيانات في بيئة الـ MATLAB وتجهيزها على شكل مصفوفات مناسبة لدخل الشبكات العصبونية وخرجها من أجل البدء بعملية تدريبها.

إن عملية تدريب الشبكة العصبونية واختبارها اختياراً صحيحاً أمر مهم جداً للحصول على الأداء الأفضل، وقد تم تدريب كل شبكة عصبونية باستخدام Back propagation على جميع أنواع الأعطال (عطل طور واحد مع الأرض - عطل طورين مع الأرض - عطل طورين بدون الأرض - عطل ثلاثي الطور).

سنرمز للطور بالرمز L، والرقم بعد الرمز يدل على رقم الطور، أما الأرضي فسنرمز له بـ G، وعليه يكون ترميز الأعطال:

L1-G, L2-G, L3-G, L1-L2-G, L1-L3-G, L2-L3-G, L1-L2, L1-L3, L2-L3, L1-L2-L3-G

وفي كل نوع من أنواع الأعطال السابقة قمنا بتغيير كل من: مكان العطل L_F ، زاوية العطل θ ، ومقاومة العطل R_F .

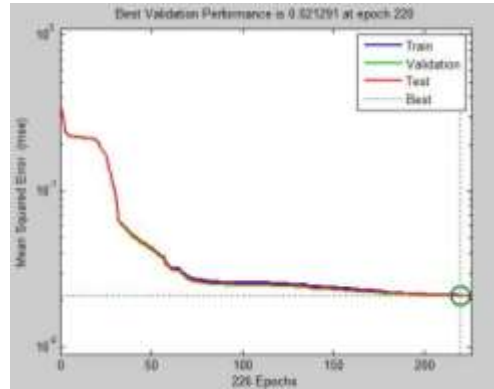
يبين الجدول (4) بنية الشبكات العصبونية المطلوبة:

الجدول (4) بنية الشبكات العصبونية المطلوبة

عدد العصبونات في طبقة			الخرج المطلوب	إشارات الدخل	اسم الشبكة العصبونية
الخرج	الخفية	الدخل			
1	15	2	1,0	U_A, I_A	ANN-A
1	15	2	1,0	U_B, I_B	ANN-B
1	16	2	1,0	U_C, I_C	ANN-C
1	14	2	1,0	U_G, I_G	ANN-G

شبكة الطور الاول ANNA:

زمن التدريب: 7 دقيقة و 39، فزمن التدريب هو الزمن الذي استغرقتة الشبكة للتدرب على بيانات 960 حالة عطل المذكورة في الجدول (1).
يبين الشكل (5) منحنى الاداء للشبكة العصبونية للطور الاول.



الشكل (5) منحنى الأداء لشبكة الطور الاول

نبين في الجداول (5-6-7) مصفوفات كل من الأوزان والانزياحات بعد انتهاء عملية التدريب، حيث الوزن والانزياح هما بارامترا العصبون.

الجدول (5) الأوزان والانزياحات لطبقة الدخل

الانزياحات	الأوزان
$b = \begin{bmatrix} 3.2441 \\ 11.3865 \end{bmatrix}$	$IW = \begin{bmatrix} -5.0624 & -15.7346 \\ -0.5099 & 71.1068 \end{bmatrix}$

الجدول (6) الأوزان والانزياحات للطبقة الخفية

الانزياحات	الأوزان
$b = \begin{bmatrix} -17.9661 \\ 3.1648 \\ 0.73094 \\ -8.7209 \\ -9.5607 \\ -12.2164 \\ 1.2907 \\ 9.5468 \\ -1.1571 \\ -1.8585 \\ -0.054732 \\ -4.8293 \\ -4.6779 \\ 2.137 \\ 16.0227 \end{bmatrix}$	$LW = \begin{bmatrix} 19.1652 & -24.0179 \\ -3.6797 & 10.9421 \\ -7.7805 & -4.2352 \\ 9.9459 & 26.9159 \\ 17.2524 & -4.4008 \\ 6.3024 & -7.3742 \\ -3.3268 & 15.153 \\ -4.7808 & 11.427 \\ 3.5865 & -3.1895 \\ 1.5366 & 12.979 \\ 1.0531 & -7.8639 \\ -3.9258 & 0.98082 \\ -1.792 & -4.5245 \\ 10.5354 & -3.0114 \\ -6.1135 & 0.77991 \end{bmatrix}$


الجدول (7) الأوزان والانزياحات لطبقة الخرج

LW						الأوزان
[14.1715	9.7643	7.3713	-21.5144	5.5188	-1.7519	
= 12.5124	7.9083	0.35009	11.8548	-2.9975	-12.214	
-7.2292	7.7483	-14.6212]				
$b = [6.933]$						الانزياحات

شبكة الطور الثاني ANNB:

زمن التدريب: 13 دقيقة و 10 ثانية.

يبين الشكل (6) منحنى الأداء للشبكة العصبونية للطور الثاني.



الشكل (6) منحنى الاداء لشبكة الطور الثاني

نبين في الجداول (8-9-10) مصفوفات كل من الأوزان والانزياحات بعد انتهاء عملية التدريب، حيث الوزن

والانزياح هما بارمترا العصبون.

الجدول (8) الأوزان والانزياحات لطبقة الدخل

الانزياحات	الأوزان
$b = \begin{bmatrix} 0.27153 \\ 7.7318 \end{bmatrix}$	$IW = \begin{bmatrix} -3.7485 & 0.70053 \\ -0.73857 & 105.6976 \end{bmatrix}$

الجدول (9) الأوزان والانزياحات للطبقة الخفية

الانزياحات		الأوزان	
$b =$	-6.5883	$LW =$	-2.5165 -59.6482
	-0.020817		1.6759 -22.8333
	3.212		-1.1935 -59.4617
	0.30737		1.2871 -51.7661
	-5.0285		-3.5619 5.942
	-3.3338		-2.6103 -31.5665
	6.2092		4.8758 -1.3244
	-0.85551		-3.0724 -7.7109
	-4.8468		-2.9048 4.0454
	5.1332		3.4974 -3.003
	1.8633		2.2196 8.1289
	5.008		3.2442 -3.6945
	4.74		2.6788 4.3074
	-6.3293		-2.1386 -2.7385
	-6.6918		-3.7645 -1.6066

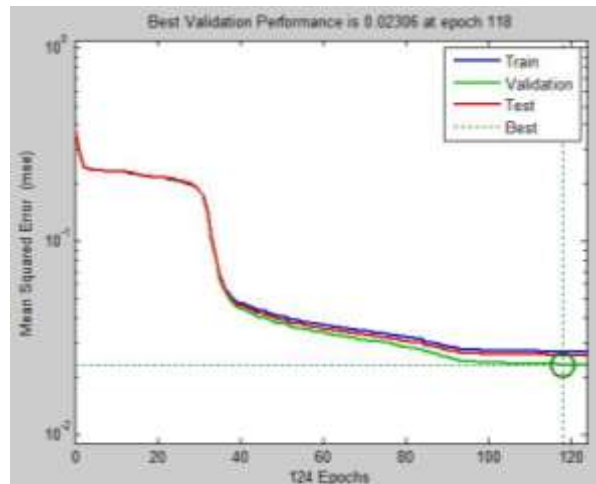
الجدول (10) الأوزان والانزياحات لطبقة الدخل

$LW =$		الأوزان
[31.1737 -11.6192 -31.2465 16.9579 -2.2523 -26.6641	..	
2.237 4.2553 -3.4536 2.6215 4.0153 3.298	..	
2.3793 -3.9243 -4.0559]		
$b = [4.888]$		الانزياحات

شبكة الطور الثالث ANNC:

زمن التدريب: 4 دقيقة و 7 ثانية.

يبين الشكل (7) منحنى الأداء للشبكة العصبونية للطور الثالث.



الشكل (7) منحنى الأداء لشبكة الطور الثالث

نبين في الجداول (11-12-13) مصفوفات كل من الأوزان والانزياحات بعد انتهاء عملية التدريب، حيث الوزن والانزياح هما بارامترا العصبون.

الجدول(11) الأوزان والانزياحات لطبقة الدخل

الانزياحات	الأوزان
$b = \begin{bmatrix} 6.0667 \\ 0.9371 \end{bmatrix}$	$IW = \begin{bmatrix} 0.23825 & -29.1586 \\ 0.0041784 & -2.7957 \end{bmatrix}$

الجدول (12) الأوزان والانزياحات للطبقة الخفية

الانزياحات	الأوزان
$b = \begin{bmatrix} 5.5957 \\ -6.5499 \\ -0.11994 \\ -0.22089 \\ 0.62387 \\ -6.0331 \\ -0.61753 \\ 1.4692 \\ 0.55219 \\ -1.2144 \\ -1.963 \\ 0.69559 \\ 4.215 \\ 4.403 \\ 6.3142 \\ -6.841 \end{bmatrix}$	$LW = \begin{bmatrix} -3.003 & 4.7403 \\ -3.6407 & 3.7467 \\ 10.655 & 3.5321 \\ 23.244 & 4.3074 \\ -15.8954 & -0.87453 \\ 0.14215 & -5.0145 \\ 8.9798 & 1.0423 \\ -8.7131 & -3.0165 \\ 4.6516 & 3.1869 \\ -3.4051 & -4.4404 \\ -1.7939 & -5.2717 \\ -0.21775 & -9.3357 \\ 6.9629 & -1.2455 \\ 4.2914 & 3.1718 \\ 2.0348 & 3.5072 \\ -3.9744 & -1.4785 \end{bmatrix}$

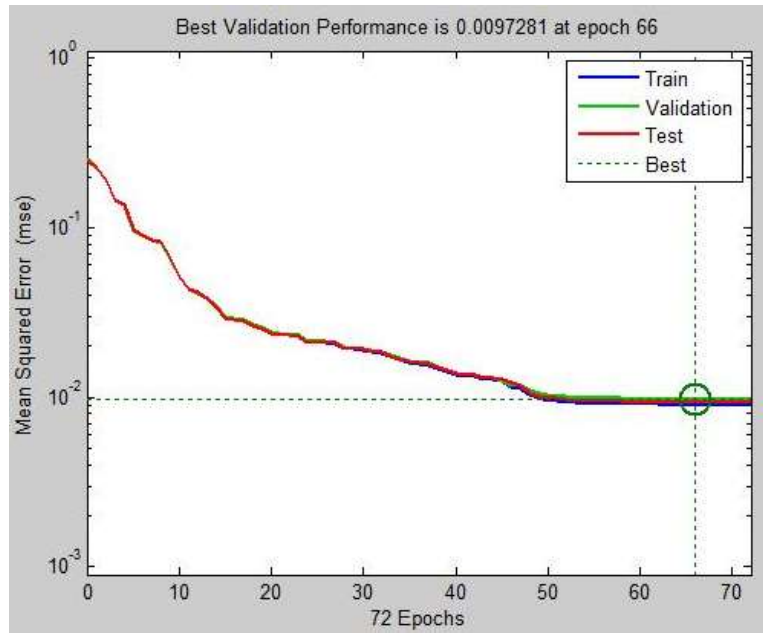
الجدول(13) الأوزان والانزياحات لطبقة الخرج

الأوزان
$LW = \begin{bmatrix} 4.1994 & -0.83173 & -3.3511 & -13.4642 & -11.1988 & 0.025712 \\ 5.2197 & -6.0732 & 0.30026 & -0.29144 & -0.54935 & -5.6028 \\ -1.9871 & 1.0709 & 2.8813 & -3.4407 \end{bmatrix}$
الانزياحات
$b = [3.5781]$

شبكة الجهد والتيار الصفري ANNG:

زمن التدريب: 2 دقيقة و 19 ثانية.

يبين الشكل(8) منحنى الاداء للشبكة العصبونية للتيار والجهد الصفريين.



الشكل (8) منحنى الأداء لشبكة التيار والجهد الصفرين

نبين في الجداول (14-15-16) مصفوفات كل من الأوزان والانزياحات بعد انتهاء عملية التدريب، حيث الوزن والانزياح هما بارامترا العصبون.

الجدول (14) الأوزان والانزياحات لطبقة الدخل

الانزياحات	الأوزان
$b\{1\} = \begin{bmatrix} 0.12941 \\ -0.11491 \end{bmatrix}$	$IW\{1,1\} = \begin{bmatrix} 5.8908 & 9.4153 \\ -15.4586 & -10.867 \end{bmatrix}$

الجدول (15) الأوزان والانزياحات للطبقة الخفية

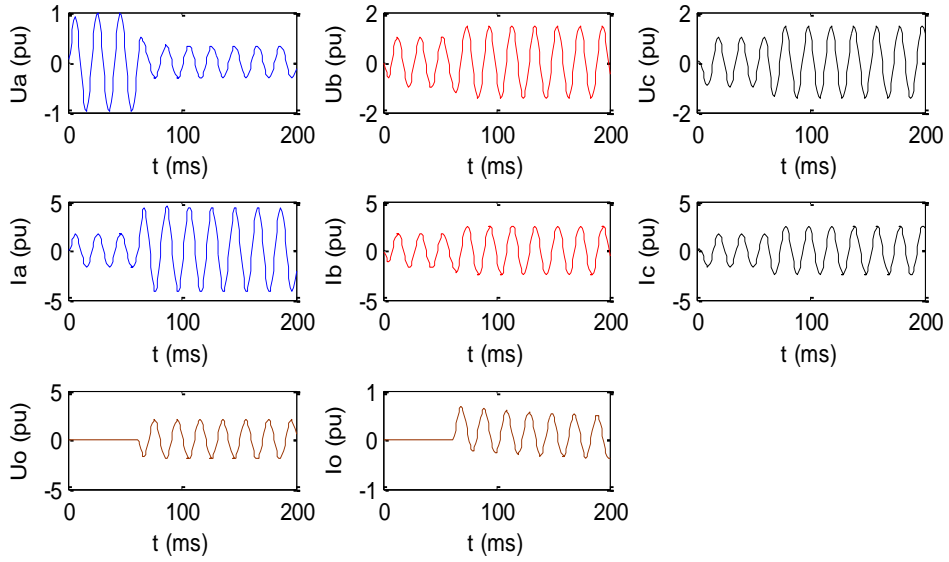
الانزياحات	الأوزان
$b = \begin{bmatrix} 5.4562 \\ 4.5678 \\ 0.46524 \\ 0.77146 \\ -0.7748 \\ -2.3136 \\ -0.52994 \\ -0.57645 \\ 0.44498 \\ 0.88139 \\ 3.2933 \\ -4.774 \\ -4.4787 \\ 5.3274 \end{bmatrix}$	$LW = \begin{bmatrix} -5.0064 & -0.41706 \\ -4.9193 & 1.4928 \\ 4.5584 & -15.0494 \\ -4.575 & 10.7293 \\ 3.2668 & -9.0009 \\ 4.1332 & 2.7106 \\ -3.0319 & -4.3866 \\ -5.6518 & -1.1295 \\ 6.4391 & -5.5056 \\ -9.1534 & 2.26 \\ 3.5013 & 3.5423 \\ -3.3164 & -2.8194 \\ -2.4719 & 4.5748 \\ 3.8356 & -3.4347 \end{bmatrix}$


الجدول (16) الأوزان والانزاحات لطبقة الخرج

$LW =$								الأوزان
[2.9915	2.5098	-9.4715	-6.8544	5.1156	-2.4015	...		
1.7126	2.19	-4.8506	-4.5704	0.65313	-1.8827	...		
-2.2418	2.3776]							
			$b = [2.5622]$					الانزاحات

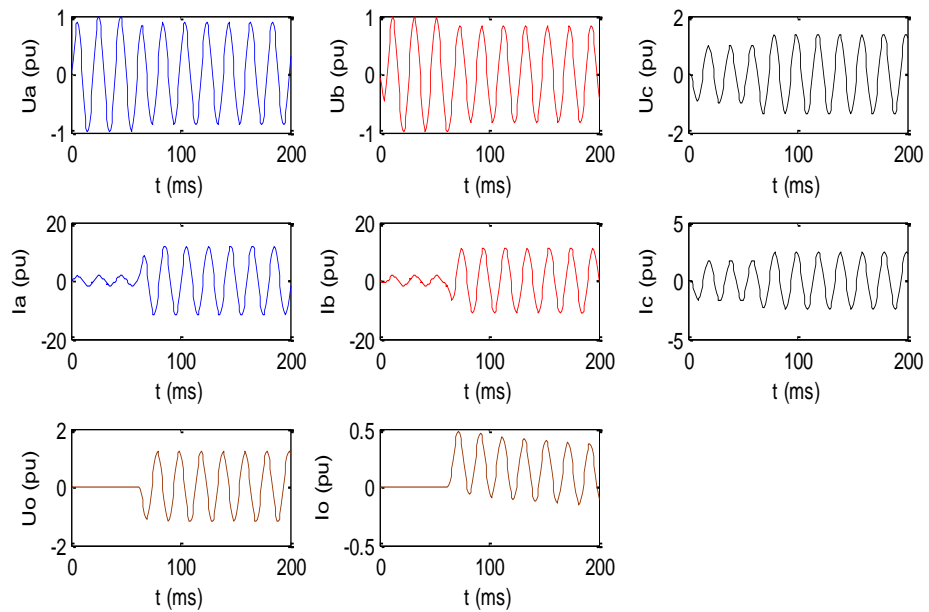
النتائج والمناقشة:

تبين الأشكال (9-10-11-12) إشارات الجهود والتيارات وخرج الشبكات العصبونية الموافقة عند بارامترات عطل مختلفة، ويظهر فيها كيف استجابت الشبكة عند حدوث العطل.

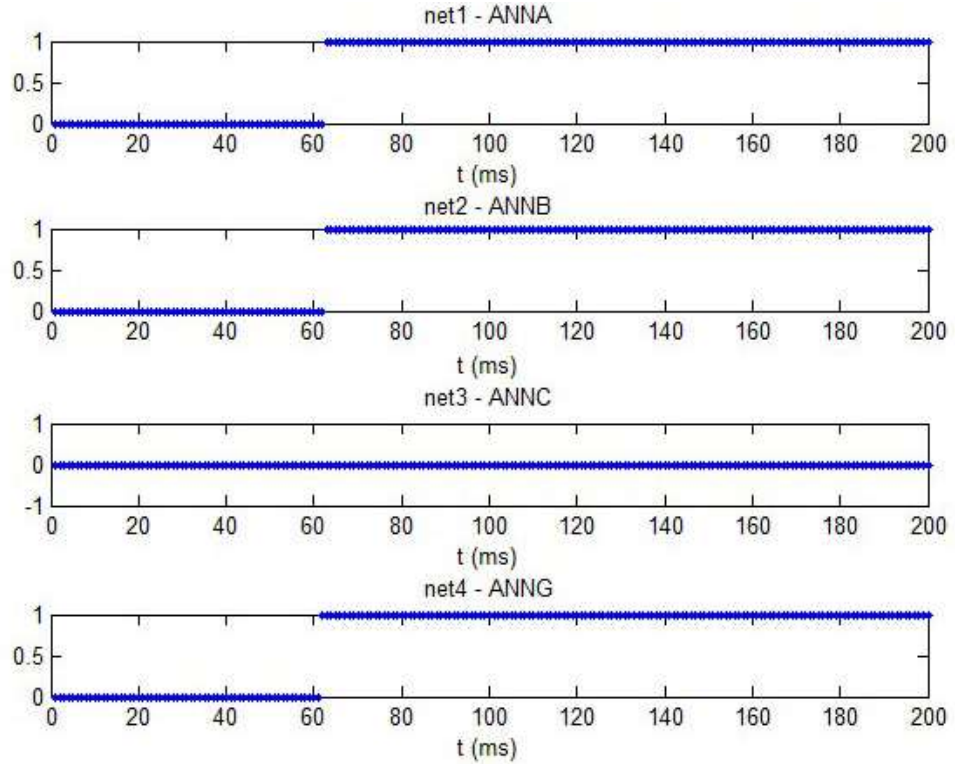
الشكل (9) إشارات الجهود والتيارات عند عطل L1-G، $L_F = 10 k_m$ ، $\theta_f = 45^\circ$ ، $R_f = 50 \Omega$ ، $t = 60 ms$



الشكل (10) خرج مصنف الاعطال عند عطل L1-G ، $t = 60 \text{ ms}$ ، $R_f = 50 \Omega$ ، $\theta_f = 45^\circ$ ، $I_F = 10 \text{ k}_m$ ، L1-G



الشكل (11) إشارات الجهود والتيارات عند عطل L1-L2-G ، $t = 60 \text{ ms}$ ، $R_f = 40 \Omega$ ، $\theta_f = 60^\circ$ ، $I_F = 70 \text{ k}_m$ ، L1-L2-G



الشكل (12) خرج مصنف الأعطال عند عطل L1-L2-G، $t = 60 \text{ ms}$ ، $R_f = 40 \Omega$ ، $\theta_f = 60^\circ$ ، $I_f = 70 \text{ k}_m$

الدارة المنطقية المستخدمة لتحديد نوع العطل:

بعد الحصول على إشارات خرج الشبكات العصبونية تدخل هذه الإشارات إلى دارة منطقية لتحديد نوع العطل حيث يشير خرج الشبكة العصبونية عندما يتحول من 0 إلى 1 إلى أن عطلاً قد حدث على هذا الطور، فنقوم الدارة المنطقية بتحليل إشارات خرج شبكات الأطوار الثلاثة وشبكة الجهد والتيار الصفري وتنتج منه نوع العطل بشكل دقيق. يبين الجدول (17) خرج الدارة المنطقية مبيناً نوع العطل اعتماداً على الخرج المقدم من قبل الشبكات العصبونية.

الجدول (17) تحديد نوع العطل

خرج ANNG	خرج ANNC	خرج ANNB	خرج ANNA	نوع العطل
1	0	0	1	L1-G
1	0	1	0	L2-G
1	1	0	0	L3-G
1	0	1	1	L1-L2-G
1	1	1	0	L2-L3-G
1	1	0	1	L1-L3-G
0	0	1	1	L1-L2
0	1	1	0	L2-L3
0	1	0	1	L1-L3
0	1	1	1	L1-L2-L3

الاستنتاجات والتوصيات:

- تم تقديم تقنية جديدة لتصنيف الأعطال في خطوط نقل القدرة الكهربائية في هذه المقالة بالاعتماد على الشبكات العصبونية، تتميز بالدقة والسرعة وزمن استجابة مصنف الأعطال لم يتجاوز الـ 5 ميلي ثانية مما يسمح باستخدامها في الحماية الرقمية.
- تم الاعتماد على بيانات جهود وتيارات الأطوار الثلاثة بالإضافة إلى الجهد والتيار الصفرين، يتألف مصنف الاعطال المقترح من أربع شبكات عصبونية.
- تم إدخال خرج الشبكات العصبونية الموضح في الأشكال (10 - 12) إلى دارة منطقية لتحديد نوع العطل.
- تم اختبار النظام عند شروط عطل مختلفة حيث أظهرت نتائج الاختبار فعالية ودقة النظام وهذا مايسمح باستخدام هذه التقنية في الحماية عالية السرعة.

المراجع

1. Ziegler G., "Numerical Distance Protection Principles and Applications", Siemens, Third Edition, 400, 2008.
2. R. N. Mahanty; P.B. Dutta Gupta, "A fuzzy logic based fault classification approach using current samples only", Electric Power Systems Research 77, 2007, 501-507, Elsevier Ltd 2007 .Available at: www.sciencedirect.com.
3. Kola VenkataramanaBabu; et al. , "Recent techniques used in transmission line protection: a review", International Journal of Engineering, Science and Technology, Vol. 3, No. 3, 2011, 1-8. Available at: www.ijest-ng.com
4. M. Sanaye-Pasand; H. Khorashadi-Zadeh, " Transmission Line Fault Detection & Phase Selection using ANN ", International Conference on Power Systems Transients – IPST, New Orleans, USA,1-2, 2003.
5. V. S. Kale; et al. "Detection and Classification of Faults on Parallel Transmission Lines using Wavelet Transform and Neural", International Journal of Electrical and Computer Engineering 3:16, 2008.
6. T. Bouthiba, "Fault Classification in EHV Transmission Lines Using Artificial Neural Networks", University of Science and Technology of Oran, Faculty of Electrical Engineering, B.P. 1505 El-Mnaouar, Oran 31000, Algeria, 2004.
7. Martin T. Hagan; Howard B. Demuth, "Neural Network Design", PWS Publishing Company, 734, 1996.
8. Howard Demuth; Mark Beale, "Neural Network Toolbox for use with MATLAB", MathWorks Inc., September, 840, 2000.