

## استخدام خوارزمية البرمجة التطورية لتصميم نموذج عصبوني صلد لفئة من نظم التحكم

الدكتور بلال شيحا \*

سحر العلي \*\*

(تاريخ الإيداع 31 / 12 / 2013. قُبِلَ للنشر في 15 / 4 / 2014)

### □ ملخص □

يهدف هذا البحث للحصول على نموذج عصبوني لفئة من النظم الخطية واللاخطية وذلك باستخدام خوارزمية البرمجة التطورية (Evolutionary programming (EP) لاختيار التركيب البنوي الأمثل للشبكة العصبونية. استخدمنا برنامج ماتلاب Matlab لتصميم الشبكات العصبونية باستخدام EP، لما يملك من مرونة وسهولة في تمثيل المصفوفات (الأنساق الخلية Cell Arrays والأنساق متعددة الأبعاد Multi Dimension Arrays). و قد أثبتت النتائج العملية كفاءة الخوارزمية المستخدمة في الوصول إلى شبكة عصبونية مثلى. تم اختبار أداء وصلادة النموذج الناتج وذلك بحذف إحدى عصبونات الطبقة المخفية للشبكة التي نتجت عن تطبيق EP ودراسة تأثير هذا الحذف على خرج النموذج الناتج، وقد أكدت الدراسة على فعالية الخوارزمية وذلك بالنسبة لفئة النظم المستخدمة.

**الكلمات المفتاحية:** خوارزمية البرمجة التطورية، الشبكات العصبونية الاصطناعية، برنامج ماتلاب

\* مدرس - قسم الحاسبات والتحكم الآلي - كلية الهندسة الكهربائية و الميكانيكية - جامعة تشرين - اللاذقية - سورية.

\*\* مهندسة - قسم الأتمتة الصناعية - كلية الهندسة التقنية - جامعة تشرين - طرطوس - سورية .

## Using Evolutionary Programming Algorithm for Designing a Robust Neural Model for a Class of Control Systems

Dr. Belal Sheha\*  
Sahar Alali\*\*

(Received 31 / 12 / 2013. Accepted 15 / 4 / 2014)

### □ ABSTRACT □

This study aims to design a neural model for a linear or nonlinear systems by using an Evolutionary Programming algorithm (EP) to choose the optimal structural construction for the network. We have used Matlab to design Neural Networks using (EP), because of its flexibility and ability to represent matrices (Cell Arrays, Multi Dimension Arrays). The experimental results confirm the efficiency with which this algorithm (EP) obtains the optimal network. We have tested the algorithm performance and the resulting model robustness by canceling one of the hidden layer nodes of the best net resulting from applying (EP). The effectiveness of that canceling on the resulting model output is also tested, and this study has shown the efficiency of the algorithm (EP) for the class of systems used.

**Keywords:** Matlab, ANNs, Evolutionary Programming algorithm(EP).

---

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

\*\*Postgraduate Student, Department of Industrial Automation, Faculty of Technical Engineering, Tishreen University, Tartous, Syria.

**مقدمة :**

تتكون الشبكة العصبونية من عناصر بسيطة تعمل على التوازي، مستوحاة من النظام العصبي البيولوجي، حيث بدأ الباحثون منذ أواخر الثمانينات و بداية التسعينات بتطبيق تقنيات مختلفة لتصميم وتطوير الشبكات العصبونية لتلائم كافة التطبيقات، فمنذ عام 1988 قدم FUJITA طريقة إحصائية لتخمين العدد الأمثل للعصبونات في الطبقة المخفية للشبكات العصبونية الأمامية (Feed Forward Neural Networks (FFNNs) بالاعتماد على مبدأ تصغير الخطأ Least-Squares [3]، كما أخذ باحثون آخرون منحى آخر لحل مسائل الأمثلة Optimization فحاولوا تطبيق نظرية التطور (DARWIN – LAMARK)، حيث قام MONTANA و DAVIS عام 1989 بتدريب الشبكات العصبونية الأمامية باستخدام الخوارزمية الجينية GAS [4]. وفي عام 1990 صمم KTANO شبكات عصبونية بالاعتماد على GAS [5]، كما قام كل من SARAVANAN و FOGEL في عام 1994 بدراسة أخرى لتطوير متحكم باستخدام الشبكات العصبونية معتمدين على البرمجة التطورية (EP) [6]، كذلك بحث BRANKE في إيجاد خوارزمية تطويرية لتصميم وتدريب الشبكات العصبونية عام 1995 [7]. تابع HESHAM البحث في عام 1996 باتجاه دمج الشبكات العصبونية مع الخوارزميات الجينية بغية تصميم الشبكة الأفضل لمحاكاة الأنظمة الخطية واللاخطية [8]. نشرت دراسة أخرى لكل من ANGELINE و FOGEL في عام 1997 عندما فيها برنامجاً يعتمد مفهوم التطور لمقاربة الأنظمة الديناميكية [9]. طور FOGEL في عام 2000 فلسفة جديدة لآلية الذكاء الصناعي باستخدام مبادئ الحساب التطوري [10]. تتالت بعد ذلك الدراسات التي تناولت اتجاه هذا البحث، ففي دراسة للباحث SHEHA عام 2001 قدم تصميماً لمراقب Observer للأنظمة الخطية غير المعروفة باستخدام البرمجة التطورية [11]. كما قدم SEIFFERT في عام 2001 دراسة أخرى لتدريب شبكة أمامية متعددة الطبقات المخفية Multi Layer Perceptron باستخدام GAS [12]. تناول كل من EIBEN و SMITH استراتيجيات الحساب التطوري في كتاب عام 2003 [13]. في عام 2005 عرض JUNG طريقة طبوغرافية لتحسين أداء الشبكات العصبونية [14]. قدم SIVANANDAM و DEEPA في عام 2008 كتاب آخر حول الخوارزميات الجينية و البرمجة التطورية و تطبيقاتها العملية المختلفة [15]. نشر CASTELLANI و ROWLANDO عام 2009 دراسة أخرى تناولت البحث عن التصميم الأفضل للشبكات نوع Multi-Layer Perceptron باستخدام تقنيات الحساب التطوري لتصنيف الخشب واعتمدت تقنية ترميز Direct Encoding [16]. طبق YING-PIN CHANG و CHIA-NAN KO عام 2009 خوارزمية PSO-NTVE على الشبكات العصبونية لإيجاد التصميم الأمثل للمرشحات التوافقية وقد استخدمت الترميز الثنائي أيضاً [17].

**أهمية البحث وأهدافه:**

إن تمثيل النظم الحقيقية يتلخص بإيجاد النموذج الرياضي Model الذي يصف سلوك هذه النظم، وذلك عن طريق المعادلات التفاضلية للأنظمة الديناميكية التمثيلية أو بمعادلات الفروق للأنظمة الديناميكية المقطعة زمنياً. يتطلب هذا وقتاً وجهداً كبيرين، والأهم من ذلك أنه يفرض علينا اعتماد تقريبات مهمة (حذف اللاخطية للنظم اللاخطية وحذف أزمنة التأخير لأنها تعقد التمثيل الرياضي عند وضعها بالحسبان)، و بما أنه لا غنى عن إيجاد نموذج يمثل النظام المراد دراسته ويمكن المصمم من تحليل سلوك هذا النظام و تصميمه حسب المتطلبات و وفق الطرق الرياضية المعروفة أو باستخدام الحاسب، كان لا بد من التفكير بطرق أخرى تستطيع تمثيل النظم المطلوبة من دون اللجوء إلى

التقريبات أو الإهمالات لما لها من دور معيق في عملية التحليل و التصميم و أيضاً بأقل جهد ممكن، من هنا ظهرت أهمية الشبكات العصبونية في تمثيل النظم لما لها من مقدرة على تمثيل النظم الخطية و اللاخطية من دون معرفة أية معلومات مسبقة عن النظم وإنما بمعرفة قيم الدخل و ما يقابلها من قيم الخرج فقط، وبالتالي الاستفادة من إمكانيات الحواسيب المتطورة في تصميم النظم.

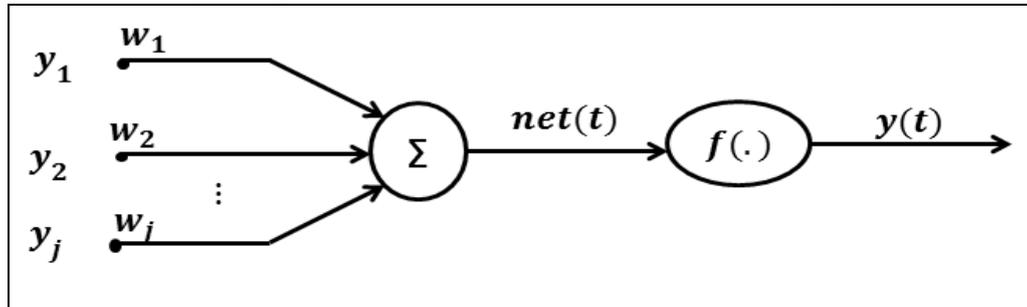
بما أن التحكم بالأنظمة الديناميكية عن طريق الشبكات العصبونية يحتاج إلى بنى خاصة، ليربط فضاء الدخل بفضاء الخرج، أو لحساب المتغيرات الوسيطة لبقية النظام و هذا يتطلب شبكات قابلة لتطوير بنيتها من حيث درجة اللاخطية و الديناميكية لمقاربة مجال واسع من الأنظمة و إذا لم نكن ندرك فيما إذا كان النظام خطياً أو لا خطياً، ستاتيكياً أم ديناميكياً، فإن مشكلة المصمم تكمن في معرفة نوع الشبكات الواجب استخدامها ( أمامية Forward NN أم عودية Recurrent REC)، عدد الطبقات في الشبكة، عدد العقد في الطبقة، خوارزمية التعليم، نوع تابع التفعيل، نسبة التعلم Learning Rate وهذا يتطلب إجراء الكثير من التجارب المملة المعتمدة على مبدأ (تجربة - خطأ) Trial and Error حيث تختبر العشرات من البنى و المئات من البرامترات، و لحل هذه المشكلة استخدمنا خوارزمية البرمجة التطورية EP للحصول على التصميم الأمثل Optimal Design للشبكة العصبونية.

### طرائق البحث ومواده:

تم تطبيق خوارزمية البرمجة التطورية EP لتصميم شبكة عصبونية تكافئ نظام تحكم خطي أو لاخطي، لاختيار التركيب البنوي الأمثل لها و القيم المثالية لبرامتراتنا. بعد ذلك قمنا باختبار الشبكة الناتجة للتأكد من مقدرة هذه الخوارزمية و فعاليتها في الوصول إلى الشبكة العصبونية المثلى باستخدام برنامج ماتلاب MATLAB حيث تمكنا من تمثيل بنية الشبكات العصبونية المكافئة للنظم قيد الدراسة في مصفوفات متعددة الأبعاد ضمن أنساق خلوية و من ثم تعليمها وترتيبها وفقاً لقيمة تابع الخطأ (دليل أداء الشبكة).

### الشبكات العصبونية

يمكن أن تكون الشبكة العصبونية بطبقة مخفية واحدة one Hidden Layer أو متعددة الطبقات المخفية Multi Hidden Layers، وللشبكات العصبونية أنواع عدة أشهرها الشبكات الأمامية Feed Forward Neural Networks(FFNNs) والشبكات العودية Recurrent networks(RECNNs)، حيث تشير الشبكات الأمامية إلى اتجاه سير المعلومات (المعرفة) من طبقة الدخل إلى طبقة الخرج [2]، بينما تتضمن RECNNs تغذية راجعة من خرج الشبكة إلى نقطة ما ضمن بنية الشبكة أو تتضمن عصبون من النوع REC. يبين الشكل (1) عصبون أمامي و هو جزء من شبكة أمامية في الحالة العامة و يمكن كتابة العلاقة بين الدخل و الخرج كما يلي:

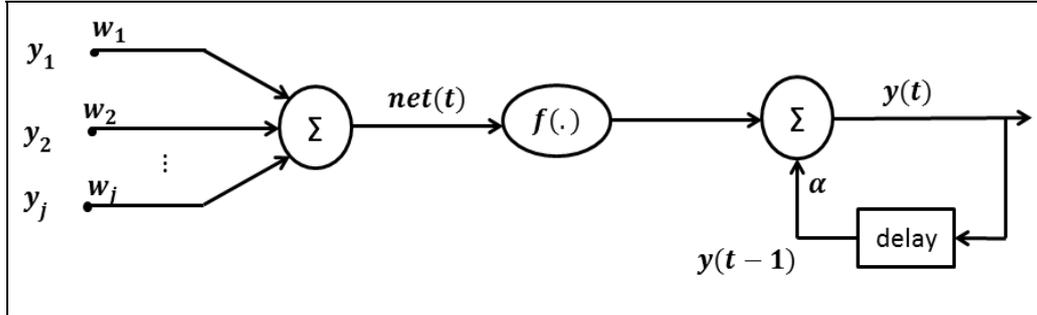


الشكل (1) عصبون أمامي في الحالة العامة

$$net(t) = \sum_{j=1}^N w_j * y_j , \quad y(t) = f(net(t))$$

$N$ : عدد العصبونات في الطبقة المخفية،  $w$ : الأوزان البينية بين الطبقة السابقة و الحالية،  $f$ : تابع التنفيل للعصبون،  $t$ : قيمة التكرار ( اللحظة الزمنية).

يظهر الشكل (2) أحد أشكال العصبونات المستخدمة في الشبكات العودية و هو أحد الأنماط المستخدمة في خوارزمية هذا البحث [18]. يتم وصف سلوك هذه العقدة باستخدام المعادلات التالية :



الشكل (2) أحد العصبونات العودية REC في الحالة العامة.

$$y(t) = \alpha * y(t - 1) + f(net(t))$$

لقد استخدمنا خوارزمية **Back- Propagation** لتدريب الشبكة أي تعديل الأوزان، وفق العلاقات التالية :

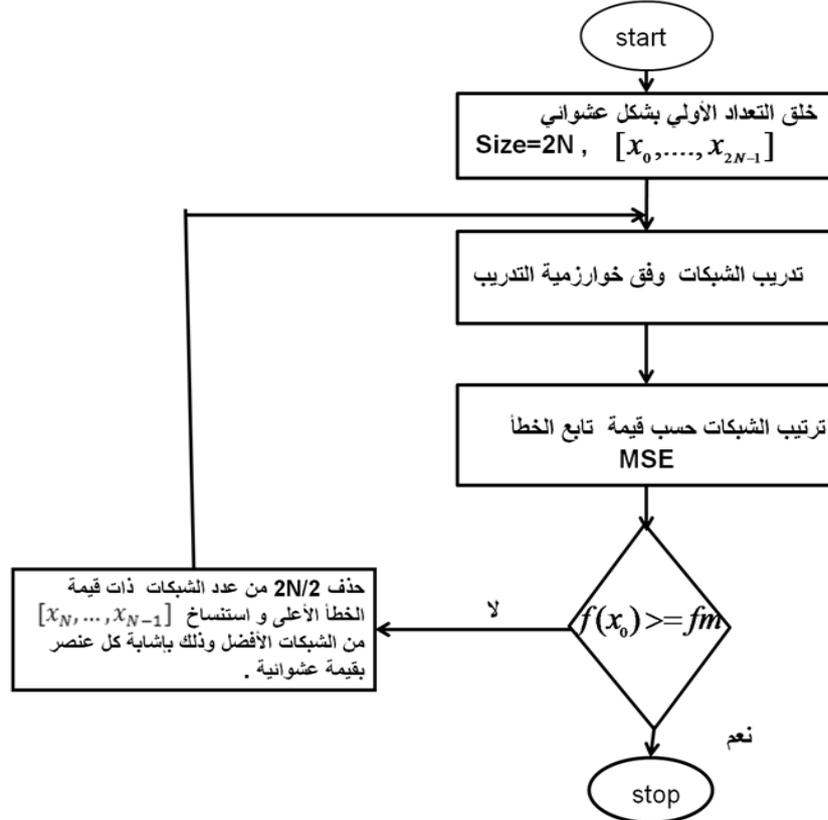
$$\Delta w_j(t) = - \eta \frac{dE(t)}{dw_j}$$

$$E(t) = \frac{1}{2} \sum_{d=1}^L (y_d(t) - y_a(t))^2$$

إذ تشير  $d(.) / d(.)$  إلى المشتقات الكلية،  $\eta$  هي نسبة التعلم Learning Rate،  $E(t)$  تابع الخطأ التربيعي،  $L$  عدد العصبونات في طبقة الخرج، delay تأخير زمني [19], [11].

### البرمجة التطورية (EP) Evolutionary Programming

هي صيغة للحساب التطوري أكثر ملاءمة لاستقراء الشبكات العصبونية، وقد أخذت فكرة إعادة تمثيل الأفراد كآلية قادرة على الاستجابة للتغيرات البيئية و تطوير معاملات للتأثير في التغير البنوي والسلوكي مع الزمن [11], [20-23]، تزداد أهمية الأمثلة باستخدام خوارزمية (EP) يوماً بعد يوم وذلك للتقارب الطبيعي Natural Match بينها وبين التكنولوجيا المعاصرة. إن اختيار نموذج للشبكة العصبونية المثلى متعلق ببنية الشبكة و بعدة برامترات مقترنة بالشبكة، حيث يتم تدريب الشبكة من أجل اختيارات مختلفة للبنية والبرامترات وإنجاز عمليتي أمثلة متداخلتين، تختص الأولى بإيجاد البنية المخصصة الأفضل و قيم برامترات الشبكة بينما تقوم الثانية بتدريب الشبكة وتحديث الأوزان للحصول على أفضل أداء للشبكة وفق معطيات التدريب و هذا ما يسمى الأمثلة بنيوياً و سلوكياً و بالتالي الحصول على شبكة ذات مواصفات عالية قادرة على مقارنة مجال واسع من الأنظمة اللاخطية [24 - 27]. يبين الشكل (3) المخطط المنهجي للخوارزمية المستخدمة و التي تقوم بتصميم شبكة عصبونية صناعية باستخدام تقنية EP.



الشكل (3) المخطط المنهجي لتصميم شبكة عصبونية باستخدام (EP).

### النتائج والمناقشة:

اعتمدنا في هذه الدراسة وجود طبقتين في كل الشبكات المستخدمة، طبقة مخفية وحيدة One Hidden Layer وطبقة خرج Output Layer تحوي عصبوناً وحيداً One Node، دخلاً وحيداً، و تم اعتبار الانحياز Bias وزناً لدخل إضافي ثابت قيمته واحد في التجارب كلها.

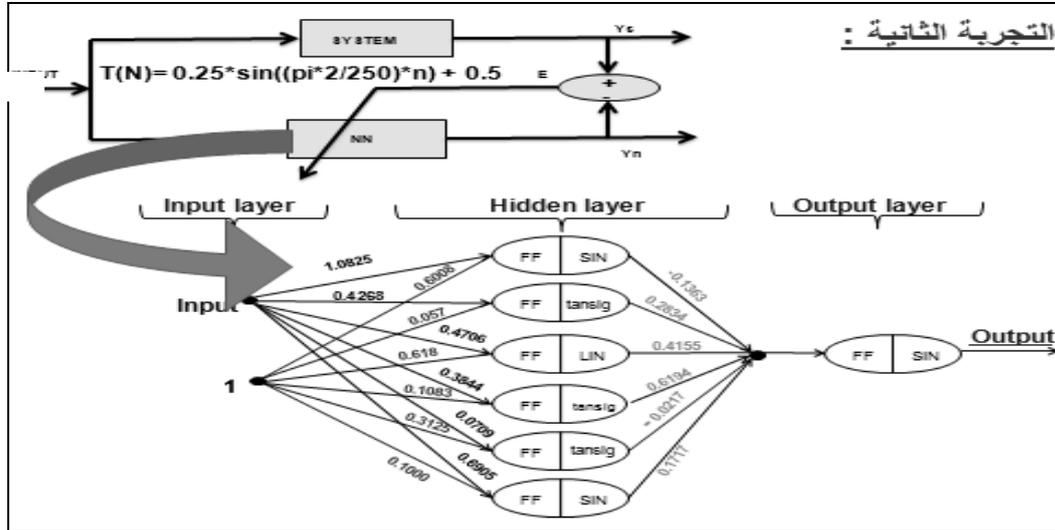
بما أن الهدف هو الوصول إلى الشبكة الأمثلية بنيوياً و سلوكياً وليس سلوكياً فقط من هنا كان من الضروري تطبيق الخوارزمية الجينية وقد وجدنا أن بيئة ماتلاب لم تساعد في هذه الخطوة لأن الخوارزمية المقترحة للعمل ديناميكية في اختيار جميع مكونات الشبكة التي تقوم بأمثلتها لذلك اتجهنا إلى البرمجة وعدم الاعتماد على توابع ماتلاب (newff, train, sim,...) من هنا كان الحل هو تحقيق الخوارزمية المقترحة باستخدام البرمجة بلغة ماتلاب [28-32]، و سنجد من خلال التجربة الأولى و الثانية أهمية تنوع بنية الشبكة.

لقد أجرينا اختباراً للخوارزمية المقترحة على عدد من النظم اللاخطية دون النظر إلى البنية الداخلية لتلك النظم و إنما النظر فقط إلى الدخل والخرج المقابل له، وقد تم تجزئة المجال إلى جزأين الأول يمثل مجال التدريب من (0-250) والثاني بعد إيقاف التدريب (250-500) وقد أعطت هذه التجارب نتائج جيدة نذكرها فيما يلي:

#### التجربة الأولى

قمنا بإيجاد نموذج للنظام الممثل بالمعادلة التالية:  $y(t) = kr(t) + c$

حيث:  $C=0.5$ ,  $k=0.75$ , دخل الشبكة هو تابع له الشكل:  $r(t) = \sin wt$ ، و يبين الشكل (4) و الجدول (1) بنية الشبكة الأفضل الناتجة عن تطبيق الخوارزمية المستخدمة EP،  $\eta = 0.1$ ، و يوضح الشكل (5) خرج هذه الشبكة ونلاحظ أن الشبكة قاربت التابع تماماً بقيمة خطأ  $e=0.0032$ .

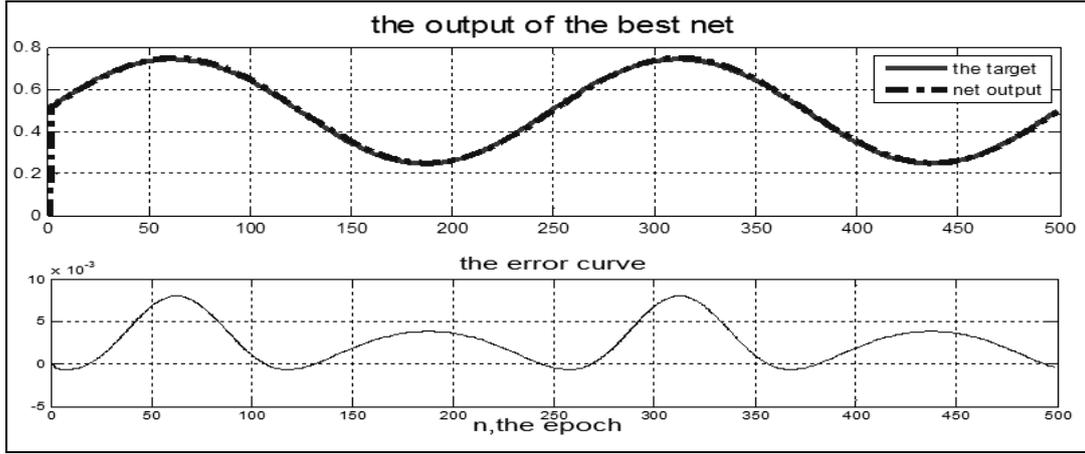


الشكل (4) الشبكة الأفضل للتجربة الأولى

حيث REC: عقدة بتغذية راجعة، FF: عقدة بتغذية أمامية، SIN: تابع تفعيل من النوع الجيبي، LIN: تابع تفعيل من النوع الخطي، TANSIG: hyperbolic tangent sigmoid أحد أهم توابع التفعيل.

الجدول (1) بنية الشبكة الأفضل للتجربة الأولى

رقم العقدة	نمط العقدة	نوع تابع التفعيل	نمط العقدة	نوع تابع التفعيل
1	FF	SIN	FF	SIN
2	FF	TANSIG		
3	FF	LIN		
4	FF	TANSIG		
5	FF	TANSIG		
6	FF	SIN		
لطبقة المخفية			لطبقة الخرج	



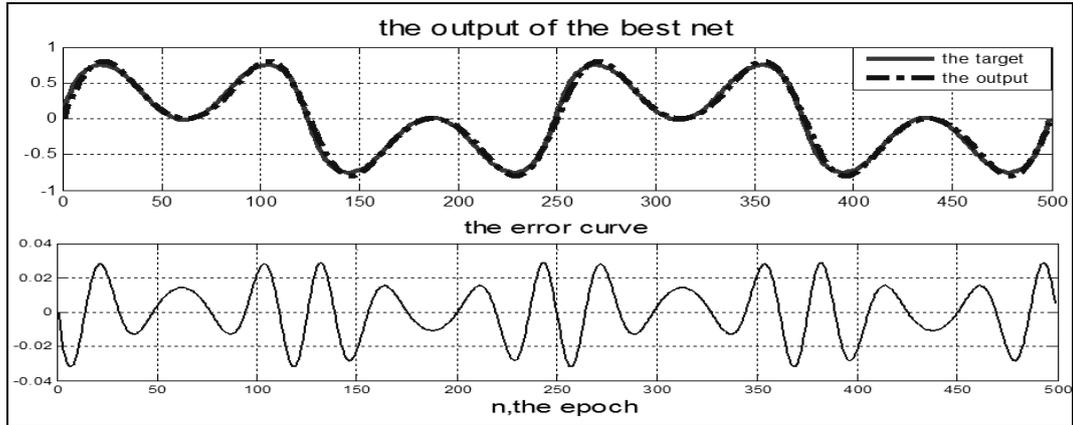
الشكل (5) خرج الشبكة الأفضل للتجربة الأولى باستخدام EP

**التجربة الثانية**

الهدف في هذه التجربة مقارنة النظام المعطى بالمعادلة التالية:

$$y(t) = 0.4 \sin(\pi r(t)) + 0.4 \sin(\pi r(t))$$

من أجل دخل  $r(t) = \sin(\omega t)$ ، و قد أعطت الخوارزمية نتيجة جيدة جداً تظهر في الشكل (6) و يمكن اعتبارها خاصة إذ قاربت النظام السابق بعقدتين فقط  $\text{node}=2$  بخطأ  $e=0.06$  خلال 250 iteration،  $\eta=0.015$ ، بنية هذه الشبكة موضحة في الجدول (2).



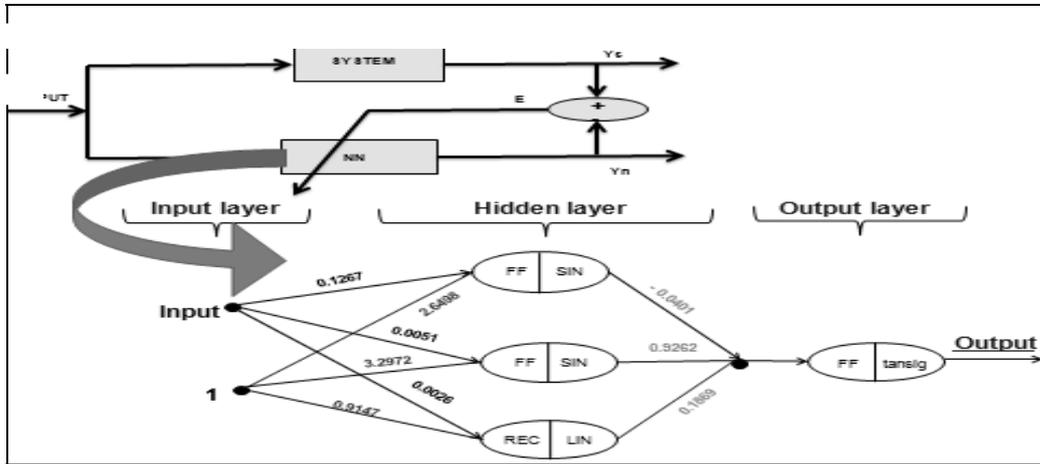
الشكل (6) خرج الشبكة الأفضل للتجربة الثانية باستخدام EP

الجدول (2) بنية الشبكة الأفضل للتجربة الثانية

رقم العقدة	نمط العقدة	نوع تابع التفعيل	نمط العقدة	نوع تابع التفعيل
1	FF	SIN	REC	SIN
2	FF	SIN		
لطبقة المخفية			لطبقة الخرج	

### التجربة الثالثة

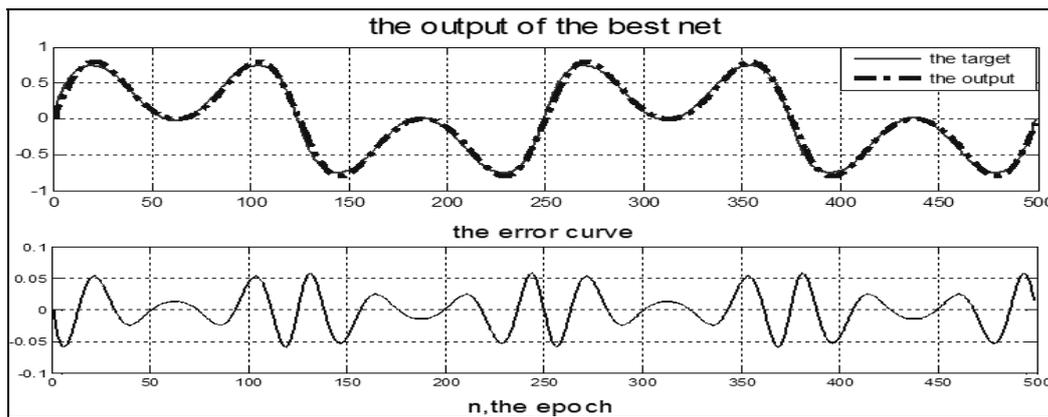
بإعادة التجربة السابقة حصلنا على نتيجة مشابهة، إذ أعطت الخوارزمية شبكة بثلاث عقد، وقيمة للخطأ قدرها  $e=0.2173$ ، و قد استغرقت  $t=1500$  تكرار، و كانت قيمة نسبة التعلم  $\eta$  هي  $0.01$  بنية هذه الشبكة مبينة بالشكل (7) و الجدول (3)، أما خرج هذه الشبكة فهو موضح بالشكل (8)



الشكل (7) بنية الشبكة الأفضل للتجربة الثالثة باستخدام EP

الجدول (3) بنية الشبكة الأفضل للتجربة الثالثة

رقم العقدة	نمط العقدة	نوع تابع التفعيل	نمط العقدة	نوع تابع التفعيل
1	FF	SIN	FF	TANSIG
2	FF	SIN		
3	REC	LIN		
لطبقة المخفية			لطبقة الخرج	



الشكل (8) خرج الشبكة الأفضل للتجربة الثالثة باستخدام EP

عند معاينة نتائج التجريبتين الثانية والثالثة تبين أن عدد العقد في التجربة الثانية هو 2 للطبقة المخفية وعقدة لطبقة الخرج من النمط REC بينما في التجربة الثالثة نتج 3 عقد للطبقة المخفية وواحدة لطبقة الخرج نمطها FF مع

ملاحظة الاختلاف بنوع تابع التفعيل أيضاً لطبقة الخرج، ويُعزى هذا الفرق إلى أنّ الخوارزمية المستخدمة تأخذ اختيارات عشوائية لكافة البرامترات ومنها نمط العقدة ونوع تابع التفعيل وغيرها من البداية، وكذلك لوحظ أن النمط REC قد اختصر عدد مرات التكرار اللازمة للوصول إلى الأمثلية في التجربة الثانية.

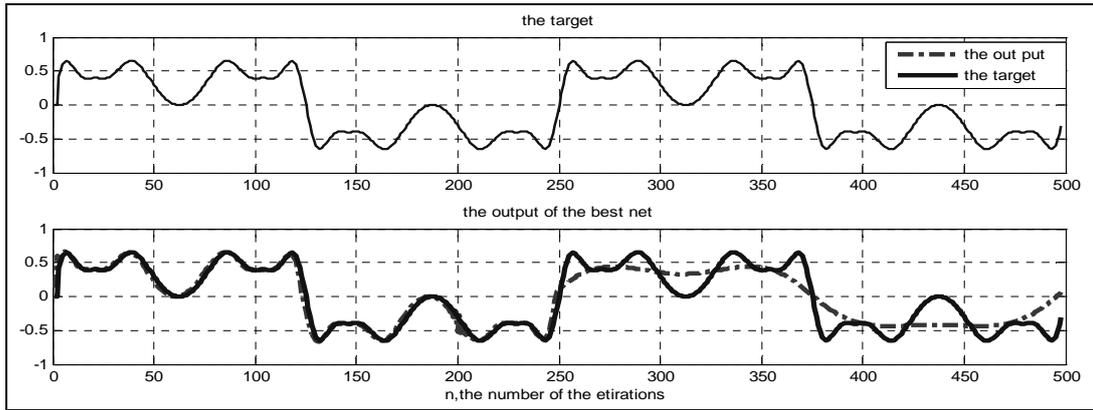
### التجربة الرابعة

تم تطبيق الخوارزمية على النظام المعرف بالمعادلة التالية:

$$y(t) = 0.6 \sin(\pi r(t)) + 0.3 \sin(3\pi r(t)) + 0.1 \sin(5\pi r(t))$$

كهدف، من أجل دخل:  $r(t) = \sin(\omega t)$  لكن وبعد أكثر من  $t=2500$  مرة، حصلنا على النتيجة المبينة

بالشكل (9).



الشكل (9) خرج الشبكة الأفضل للتجربة الرابعة باستخدام EP

نلاحظ من الشكل السابق أنه في الجزء الأول (0-250) استطاعت الشبكة ملاحقة الخرج خلال فترة التدريب الفعلي (0-250) و يبين جزء الشكل من (250-500) المرحلة بعد إيقاف التدريب عدم مقدرة الشبكة ذات الخطأ الأقل على التعلم لمقاربة سلوك النظام المذكور.

### المرحلة الثانية

تم اختبار أداء الخوارزمية المقترحة و صلادة النموذج الشبكي الناتج و ذلك عند حدوث خلل في عقدة ما من الشبكة الناتجة، و يمكن إيجاز خطوات هذه المرحلة بما يلي:

- 1- رسم خرج الشبكة الناتجة عن المرحلة الأولى و ذلك خلال المجال AB من المنحنيات للمقارنة.
- 2 - نزع عقدة بكل عشوائي من عقد الطبقة الخفية و ذلك خلال المجال BC من المنحنيات ( التأكيد من صلادة النموذج ).
- 3 - إعادة التدريب للشبكة بعد حذف عقدة عشوائياً للتأكد هل بإمكان البنية المتبقية أن تصل بالخطأ إلى قيمته قبل نزع العقدة، وهذا يمثل الجزء CD من المنحنيات (التأكد من أداء الخوارزمية ).
- 4 - رسم منحنى الخطأ في المراحل الثلاثة السابقة.
- 5 - حساب مجالات الخطأ عند حذف كل عقدة من عقد الشبكة الناتجة منفردةً.

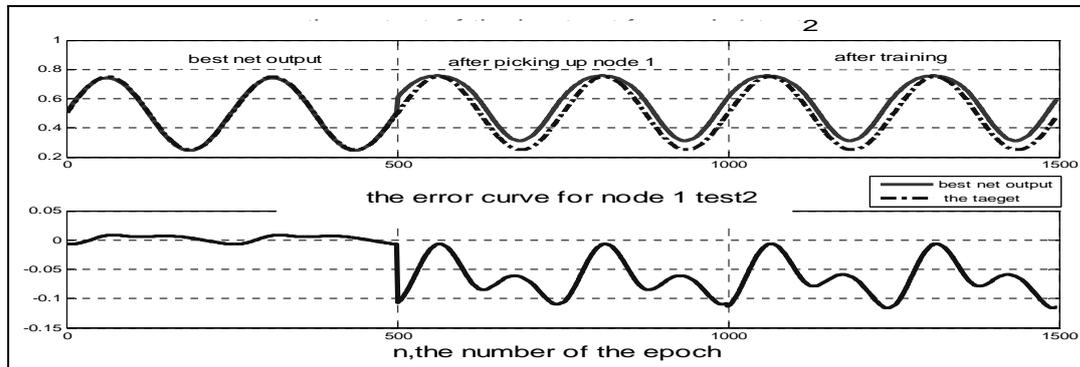
### الاختبار الأول

قمنا باختبار الشبكة الأفضل التي أعطتها الخوارزمية لمقاربة النظام الممثل بالمعادلة التالية:

$$y(t) = 0.25 \sin \omega t + 0.5$$

ويوضح الشكل (10) خرج الشبكة بعد تدريبها  $t=1000$  مرة و منحني الخطأ بمراحله الثلاث و ذلك بعد حذف

العقدة 1.



الشكل (10) منحني الخرج و الخطأ للشبكة الأفضل للتجربة الأولى عند حذف العقدة 1.

ومن الواضح أن قيمة الخطأ لم تتغير حتى بعد تدريب الشبكة، أي أنه لا يمكننا الاستغناء عن هذه العقدة، و قد قمنا بتكرار عملية الاختبار من أجل كل العقد وقد أكدت نتائج الاختبارات السابقة أن الخوارزمية أعطت نتيجة مقنعة. يبين الجدول (5) أعظم وأصغر قيمة للخطأ عند حذف كل عقدة من عقد الطبقة المخفية لهذه الشبكة.

الجدول (5) مجال تغير الخطأ الموافق لانتزاع كل عقدة للشبكة الأفضل للتجربة الأولى.

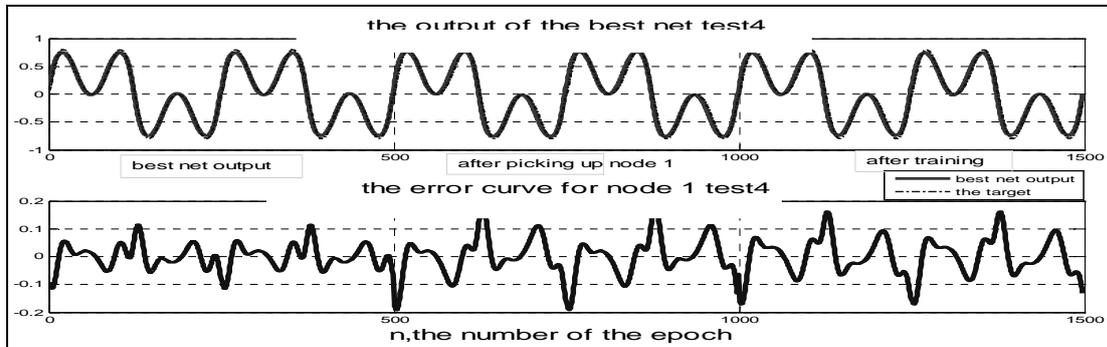
Node_number	emin	emax
1	-0.1232	0
2	0	0.1920
3	-0.0550	0.3757
4	0	0.2246
5	-0.0156	0.0180

#### الاختبار الثاني

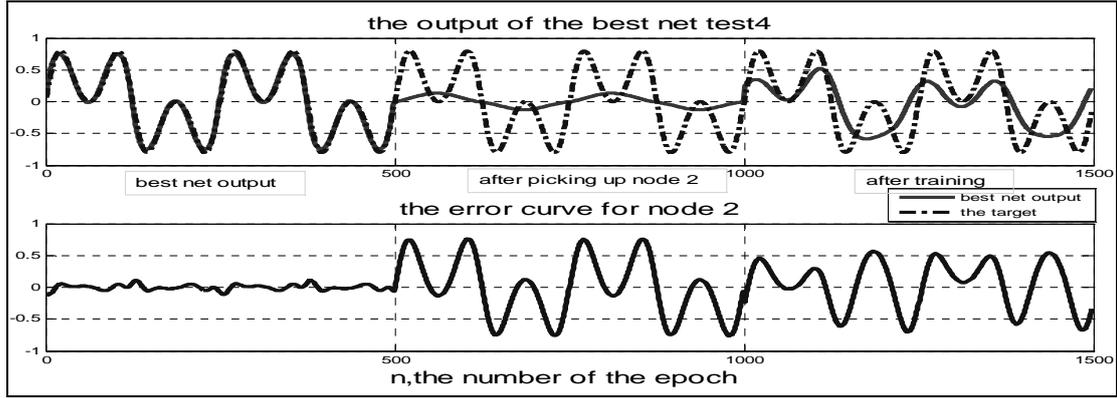
أجرينا اختباراً للشبكة التي قاربت النظام المعطى بالعلاقة:

$$y(t) = 0.4 \sin(\pi \sin(wt)) + 0.4 \sin(\pi \sin wt)$$

بعد نزع العقدة 1 حصلنا على الشكل (11) الذي يبين خرج الشبكة بعد تدريب الشبكة 1000 مرة. نخلص من معاينة الشكل (11) إلى أن الخطأ الذي نتج عن نزع العقدة 1 لم يتم تصغيره بعد التدريب، كما نتج لدينا بعد متابعة الاختبار على العقدة 2 لهذه الشبكة النتيجة الموضحة بالشكل (12).



الشكل (11) منحني الخرج الخطأ للشبكة الأفضل الثانية عند حذف العقدة 1.



الشكل (12) منحني الخرج و الخطأ للشبكة الأفضل للتجربة الثانية عند حذف العقدة 2.

يتضح من الشكل السابق أن نزع العقدة 2 سبب حدوث خطأ كبير و أن التدريب لم يستطع تعويض هذا الخطأ أي أنه لا يمكن الاستغناء عن هذه العقدة و هذا يؤكد أيضاً فعالية الخوارزمية المقترحة، يبين الجدول (6) مجال تغير الخطأ الأعظمي والأصغري عند حذف كل عقدة لهذه الشبكة :

الجدول (6) مجال تغير الخطأ الموافق لانتزاع كل عقدة للشبكة الأفضل للتجربة الثانية.

Node_number	emin	emax
1	-0.1949	0.1780
2	-0.7560	0.7581

### الاستنتاجات و التوصيات:

بينت المرحلة الثانية فعالية أداء الخوارزمية (لفئة نظم الدراسة) و ذلك بالوصول إلى الشبكة العصبونية المثلى، إذ إنه لم يتبين عدم الحاجة لأية عقدة تم اختبارها عند خرج الخوارزمية، وأيضاً يمكن الاستفادة من دراسة مجال الخطأ لمعرفة العقدة التي أصابها عطب من خلال مجال الخطأ الذي نتج عن هذا العطل، و تظهر أهمية هذه الدراسة عند الانتقال بالشبكة العصبونية إلى مكونات صلبة Hardware.

اعتماداً على نتائج هذه الدراسة يمكن استخلاص النقاط الرئيسة الآتية:

- يمكن اعتبار خوارزمية البرمجة التطورية (EP) من أهم طرق الأمثلة مقارنة مع (GA) و تقنيات الأمثلة الإحصائية المعروفة بتجنبها الترميز الثنائي وبالتالي اختصار الكلفة المادية عند التنفيذ العملي باختصار الرموزات ومفككات الترميز و بتوفير الوقت و الجهد و زمن الحساب و التعقيد Complexity.
- تعد النتائج التي أعطتها الخوارزمية فعالة جداً في مقارنة الحل الأمثل لفئة من النظم اللاخطية استناداً إلى معطيات مرحلة الاختبار.

• تعد نتائج هذه الدراسة ذات أهمية كبيرة في تصميم و تحليل أنظمة التحكم اللاخطية المدروسة.

- يمكن استنتاج رقم العقدة التي تعرضت لخلل ما من معاينة جدول الخطأ الذي تم ذكره عند كل تجربة اختبار، وهذا يقدم فائدة كبيرة عند حدوث عطل للدائرة المكافئة للشبكة المصممة.

• لوحظ ضعف في مقارنة النظم الديناميكية المعقدة إذ احتاجت لعدد كبير من العصبونات في الطبقة المخفية حوالي 75 عقدة ولم تقارب تماماً، و هذا يصل بنا إلى القول: إن المكونات المستخدمة في هذه الخوارزمية تحتاج إلى تطوير.

لقد تناولت الدراسة مناقشة البنى الأكثر استخداماً للشبكات العصبونية و قد أظهرت النتائج العملية أنه بإمكان كل من هذه البنى مقارنة صنف من الأنظمة اللاخطية الممثلة بمعادلات، لكن أياً منها لا يمكن اعتبارها شبكة معممة Generalized Architecture باستطاعتها التعرف على أي نوع من النظم اللاخطية، ولتجاوز هذه المشكلة نقترح الاعتماد على أنواع أخرى من العقد.

ونظراً للضعف الذي أظهرته التجربة في مقارنة الخوارزمية المطبقة للأنظمة الديناميكية المعقدة نقترح تطوير بنية الشبكة لطبقتين مخفيتين Tow hidden Layers، بعد تطوير نوع العقدة. كما نقترح تنفيذ هذا التصميم Hardware.

### المراجع:

- [1]-CANGELOSI, A;ELMAN, J.L. *Gene regulation and biological development in neural networks :an exploratory model*. Technical Report, CRL-UCSD, University of California San Diego, 1995.
- [2]- HAYKIN, S. *Neural Networks :A Comprehensive Foundation*. 2<sup>nd</sup>, Ed, London, prentice-Hall, 1999.
- [3]-FUJITA, O. *statistical estimation of the number of hidden units for feed forward neural networks*. neural networks11(5), 1988, 851-859.
- [4]-MONTANA, D; DAVIS, L. *Training feed forward neural networks using genetic algorithms*. In: Proceedings of the 11<sup>th</sup> International Joint Conference on AI, Detroit, MI, 1989,762-767.
- [5]-KITANO, H. *Designing neural networks using genetic algorithms with graph generation system*.Complex Systems4(4), 1990, 461-476.
- [6]-SARAVANAN, N. ; FOGEL, D.B. *Evolving neurocontrollers using evolutionary programming*. In :Proceedings of the First IEEE Conference on Evolutionary Computation (ICEC), Orlando, FL, 1994, 217-222.
- [7]-BRANKE, J. *Evolutionary algorithms for neural network design and training*. Report No.322, Institute AIFB, University Karlsruhe, 1995.
- [8]-SOULTAN, H. E. *A New Developed Algorithm For Neural Network Design With Application To Non Linear System Identification*. thesis, Cairo university, 1996.
- [9]-ANGELINE, P.J;FOGEL, D.B. *An evolutionary program for the identification of dynamical systems*. The International Society for Optical Engineering, Bellingham,WA,1997,409-417.
- [10]-FOGEL, D.B. *Evolutionary Computation :Toward a New Philosophy of Machine Intelligence, 2<sup>nd</sup>, ed*. IEEE Press, New York, 2000.
- [11]- SHIHA, B. *observer design for a class of unknown liner systems using neural networks*. Cairo – 2001.
- [12]-SEIFFERT,U. *Multiple layer perceptron training using genetic algorithms*. In: Proceedings of the Ninth European Symposium on Artificial Neural Networks, BrugesB,2001, 159-164.
- [13]-EIBEN, A.E;SMITH, J.E. *Introduction to Evolutionary Computing*. Springer, New York, 2003.

- [14]-JUNG, S.Y. *A topographical method for the development of neural networks for artificial brain evolution*. Artificial Life(11), 2005, 293–316.
- [15]-SIVANANDAM, S.N ;DEEPA, S.N. *Introduction to Genetic Algorithm*. CSpringer-Verlag, Berlin Heidelberg,2008.
- [16]-CASTELLANI,M;ROWLANDS,H. *Evolutionary Artificial Neural Network Design and Training for wood veneer classification*. Engineering Applications of Artificial Intelligence, 22,2009, 732–741.
- [17]-CHANG,Y.P;KO,C.N. *A PSO method with nonlinear time-varying evolution based on neural network for design of optimal harmonic filters*. Expert Systems with Applications,36, 2009,6809–6816.
- [18]-MEDSKER,L.R. *recurrent neural net works design and application*. BY CRC press LLC, 2001.
- [19]-JOHANSSON,E.M.; DOWLA,F.U.; GOODMAN,D.M. *Back propagation learning for multilayer feed-forward neural networks using the conjugate gradient method*. International Journal Neural Systems2(4), 1991, 291–301.
- [20]-ABOITIZ,F. *Mechanisms of adaptive evolution—Darwinism and Lamarckism restated*. Medical Hypotheses38(3), 1992, 194–202.
- [21]-NIKOLAEV,N.Y. *Learning polynomial feed forward neural networks by genetic programming and back propagation*. IEEE Transactions on Neural Networks14 (2), 2003, 337–350.
- [22]-YU,H; LIANG,W. *Neural network and genetic algorithm-based hybrid approach to expanded job-shop scheduling*. Computers and Industrial engineering,39,2001,337–356.
- [23]-BRAMEIER,M;BANZHAF,W. *Linear genetic programming*. Springer, June, 2006.
- [24]-FOGEL,D.B; FOGEL, L.J ; PORTO, V.W. *Evolutionary programming for training neural networks*. Proceedings International Joint Conference on NNs, San Diego, June, 1990,601–605.
- [25]-PALMES,P; HAYASAKA,T; USUI,S. *Evolution and adaptation of neural networks*. In Proceedings of the international joint conference on neural networks Vol.1,2003, 478–483.
- [26]-ANGELINE,P.J; SAUDERS,G.M; POLLACK, J.B. *An evolutionary algorithm that constructs recurrent neural networks*. IEEE Transactions Neural Networks5 (1),1994,54–65.
- [27]-SCHIFFMANN,W. *Encoding feed forward networks for topology optimization by simulated evolution*. In: Proceedings of the Fourth International Conference on Knowledge-Based Intelligent Engineering Systems & Allied Technologies,vol.1,2000,361–364.
- [28]-HUNT,B ;LIPSMAN,R ; ROSENBERG,J ; COOMBES,K ;OSBORN,J ;STUCK,G . *A guide to Matlab for Beginners and Experienced Users*.1.ed.cambridge university press,2001.
- [29]-KNIGHT,A. *basics of Matlab and beyond*.CRC press LLC, 2000 .
- [30]-HAHN,B.D; VALENTINE,D.T. *Essential MATLAB for Engineers and Scientists*.3<sup>rd</sup>.ed, Elsevier’s Science & Technology, oxford, 2007.
- [31]-MOLER,C. *Numerical Computing with MATLAB*, January ,2004.
- [32]-<http://www.mathworks.com> (2013/11/12 تاريخ المطالعة)