دراسة مقارنة بين الشبكات العصبية الاصطناعية
(تمييز الأرقام الانكليزية المطبوعة)

مناهل عبد الكريم يوسف
كلية طب الأسنان / جامعة الموصل

القبول	الاستلام
2009 / 07 / 15	2009 / 03 / 10

ABSTRACT

This study is aimed to make a comparison between three artificial neural networks, these networks differ from each other in architecture and the method of adaptive the weights. In this research four ANN are used to recognized English number, these ANN are Adaline, Backpropagation, Hopfield, and Kohen ANN. By doing the comparison, we found that, the ability of a network differentiation does not depend on the complexity of the network architecture, the training algorithm or the number of layers, but it depends on the learning rule and increase in the number of the patterns that are used to train the network.

الملخص

تستهدف هذه الدراسة المقارنة بين أربعة شبكات عصبية اصطناعية مختلفة فيما بينها من حيث المعمارية وطريقة تحديث الأوزان للحصول على الإخراج. في هذا البحث الشبكات التي استخدمت هي Adaline, Backpropagation, Hopfield, وKoheng .

وبمقارنة التمييز لوحظ بان قابلية الشبكة على التمييز لا يعتمد على تعقد بنية الشبكة أو على عدد الطبقات، وإنما بزيادة عدد أنماط التدريب وتنوعها.

المقدمة:

الشبكات العصبية علم قائم بحد ذاته اهتم به العلماء لسنوات عديدة بهدف الوصول إلى طريقة أشبه ما تكون بطريقة الإنسان في التعرف على الأنماط باستخدام الأساليب البرمجية

وبخوارزميات مختلفة في عناصر معالجة بسيطة تسمى عصبونات حيث تمر الإشارات بين العصبونات عبر خطوط الربط وكل خط ربط يرفق بوزن معين ثم يطبق دالة تكون غير خطية عادة على كل عصبون (مجموع الإشارات الداخلة الموزونة) لتحديد إشارات الإخراج الناتجة.

وبهذا اشتقت فكرة الشبكات العصبية الاصطناعية من الشبكات العصبية البايولوجية، فهي بأبسط صورة عبارة عن وحدات الإدخال والإخراج وخوارزمية لتوليف الأوزان كما في الشكل (1) حيث $x_1,x_2,\dots x_n$ تمثل الإدخال، w_{nj} تمثل الأوزان، $z_j=\sum x_i*w_{ij}$، $f(z_j)$ دالة التنشيط، وأخيراً y_j هو الإخراج.[1]

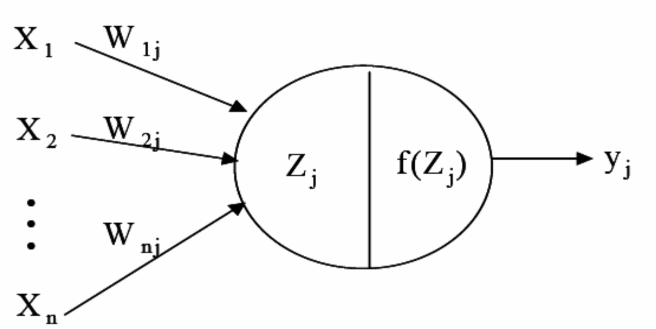

شكل رقم (1): المخطط العام للشبكة العصبية الاصطناعية

ربما تكون هناك صعوبة في الشبكات العصبية الاصطناعية عند التمييز وذلك بسبب نسبة خطأ في التدريب، او قد تكون بعض نماذج الإدخال والإخراج المحتملة غير متوفرة، هذا وفضلاً عن وجود الضوضاء في بعض أنواع البيانات.[2]

هناك عدة أنواع من الشبكات التي تختلف تسميتها وخصائصها اعتماداً على عدد الطبقات مثل الشبكات ذات الطبقة الواحدة والشبكات متعددة الطبقات، وعلى أسلوب بنائها وارتباط الخلايا من طبقة إلى أخرى مثل شبكات ذات التغذية الأمامية والشبكات ذات التغذية الخلفية، وكذلك على نوع الخوارزمية المستخدمة في تعليمها مثل خوارزميات التعليم الموجه (Supervised) والتعليم غير الموجه (Un_supervised) والتعليم القسري (Reinforeement).[3]

تم في هذا البحث وباستخدام البرمجة بلغة Matlab اختيار أربعة شبكات عصبية مختلفة من حيث البنية الهندسية وتوليف الأوزان لإيجاد الإخراج المطلوب وبتطبيق أنماط التدريب والتي عبارة عن صور لنوعين من الخط للأرقام الانكليزية المطبوعة (0-9) يتم قراءتها وتحويلها إلى مصفوفة إدخال للشبكة العصبية كما في الملحق (A) وإجراء الاختبار على الأنماط في الملحق (B1-4) على كل من الشبكات الأربعة (Adaline, Backpropagation, Hopfield, and Kohen) من اجل الحصول على النتائج.[4][5][6]

وفيما يلي توضيح لكل شبكة استخدمت والنتائج التي تم الحصول عليها بعد التدريب.

1. الشبكة العصبية Adaline :

تعد من الشبكات الخطية التكيفية والتي تعمل بمعلم، وهي من ابسط أنواع الشبكات وتستخدم قاعدة دلتا Delta في التعليم والتي تقوم بتعديل الأوزان بحيث تنقص من الاختلاف بين إدخال الشبكة وإخراجها مع الإخراج المطلوب، وهي نموذجاً لشبكات وحيدة الطبقة والتي تشبه شبكة Perceptron المعروفة باستخدامها في تصنيف الأنماط إذ تم استخدامها لتصنيف الأنماط بعد تدريبها مع الإخراج المطلوب وصيغة قاعدة Delta هي:[7][8][9][10]

$$\Delta w = \propto .(t - y).x \qquad \ldots\ldots\ldots\ldots\ldots\ldots (1)$$

حيث ان: Δw الفرق بالوزن، α قيمة معدل التعليم، t الإخراج المطلوب' y الاخراج الحالي، x الإدخال.

1-1 البنية الهندسية لشبكة Adaline:

يوضح الشكل (1-1) البنية الهندسية المستخدمة لشبكة Adaline وحيدة الطبقة مع الانحيازات(b) والتي تستخدم لتصحيح عمل الشبكة وقيمتها تكون 1 لكل عقدة في الإخراج على مصفوفة صور الأرقام المستخدمة في الملحق (A).[7]

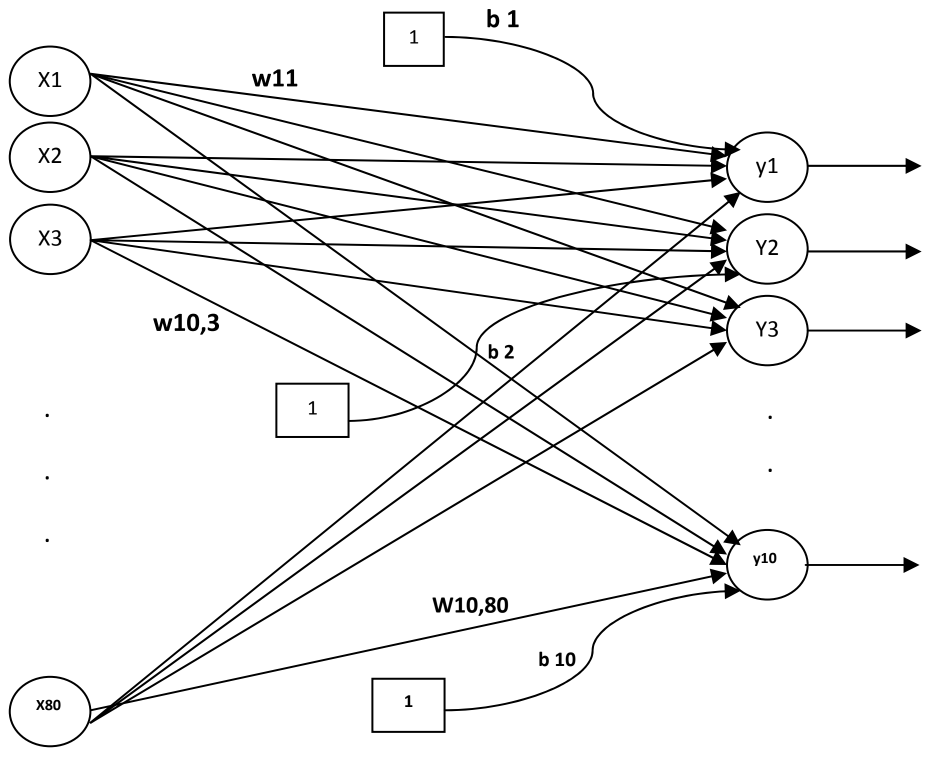

الشكل (1-1): البنية الهندسية لشبكة Adaline

2-1 خوارزمية التدريب: [7]

تتكون هذه الشبكة حسب البيانات في الملحق (A) من (80 عقدة) في الإدخال لان وحدات البيانات تتكون من حجم أبعاد الصور بعد قراءتها وتحويلها إلى مصفوفة (8*10) و (10 عقد) في الإخراج لتصنيف الأرقام (0-9)، وفيما يلي توضيح للخوارزمية المستخدمة لتدريب شبكة Adaline:

1) إعطاء قيم ابتدائية للأوزان W_{ji} و تستخدم عادة قيم عشوائية صغيرة بين (-0.5, 0.5).

حيث J=1….10, i=1….80

2) حساب قيمة وحدات الإخراج من العلاقة التالية:

$$Y\_in_i = b_i + \sum x_i . w_{ji} \quad \dots\dots\dots\dots\dots\dots (2)$$

3) تعديل الأوزان والانحياز(b) بالعلاقات:

$$W_{ji}(new) = w_{ji}(old) + \propto (t - y_{inj}) * x_i \quad \dots\dots\dots (3)$$

$$b_i(new) = b_i(old) + \propto (t - y_{in_j}) \quad \dots\dots\dots\dots (4)$$

حيث: نسبة التعليم (α=0.005) الذي يتم تحديده بقيمة اقل من 1 حسب ملائمة تدريب الشبكة، t: الإخراج المطلوب.

4) اختبار شرط التوقف: عند الحصول على الأوزان التي تجعل الشبكة في حالة الإخراج الحالي مساوي للإخراج المطلوب لانتهاء التدريب.

والشكل (2-1) يبين الرسم البياني لتدريب شبكة Adaline على أنماط التدريب حيث نلاحظ فيه وصول منحني تدريب الشبكة إلى الإخراج المطلوب إلى قيمة الخطأ (0.95636e-006) وهي اقرب قيمة من الخطأ المسموح المتمثل بالخط الأفقي عند نهاية المنحني (10^{-5}) في مرحلة التكرار 1315 خلال مدة (0:02.391) دقيقة لتدريب الشبكة على أنماط الأرقام.

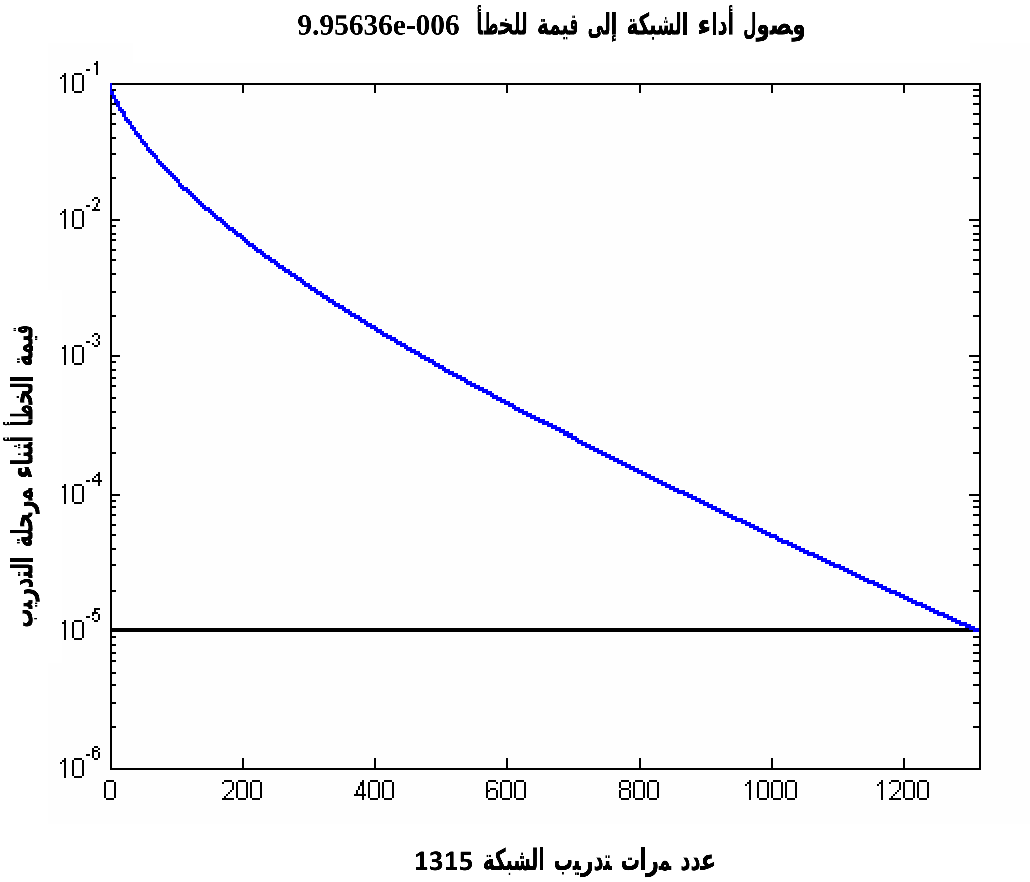

الشكل (1-2): خطوات تدريب شبكة Adaline إلى قيمة الخطأ 10^{-5}

3-1 اختبار شبكة Adaline:

بعد تدريب الشبكة على الأنماط في الملحق (A) تم اختبار شبكة Adaline على أنماط أخرى لصور الأرقام غير الواضحة نسبياً كما موضح في الملحق (B1-4) حيث ان الشبكة تقرب الإدخال إلى اقرب نموذج من نماذج التدريب، وكانت نتيجة تطبيق الشبكة على 60 نمط هي بنسبة 83% مطابقة.

عندما يكون هناك عدد كاف من عينات التدريب فان الشبكة ستكون قادرة على تصنيف عينات غير معروفة للشبكة مسبقا بشكل صحيح.[7]

2. شبكة الانتشار العكسي Backpropagation:

هي من نوع الشبكات التي تتدرب بمعلم (Supervised) ومجالات استخدامها كثيرة ففكرة الانتشار العكسي لتدريب الشبكات العصبية المتعددة الطبقات جاءت بعد الشبكات العصبية وحيدة الطبقة. فهذه الشبكة أعطت مجالات واسعة في التدريب حيث يتضمن تدريب هذه الشبكة بطريقة الانتشار العكسي ثلاثة مراحل:

1. مرحلة التغذية الأمامية لأنماط الإدخال.
2. مرحلة الحساب والانتشار العكسي للخطأ المتعلق بالإخراج.
3. مرحلة توليف الأوزان.

ولكن بعد هذه المراحل الثلاثة تبدأ مرحلة اختبار الشبكة ويكون في طور الانتشار الأمامي.[7][8][11]

2-1 البنية الهندسية:

باستخدام كل من أنماط التدريب وأنماط الاختبار التي استخدمت في الشبكة العصبية Adaline في شبكة (Backpropagation) كما في الشكل (2-1) حيث يوضح البنية الهندسية للشبكة وترفق وحدات طبقة الإخراج (10 عقد) ووحدات الطبقة الخفية بانحيازات (b=1) اما طبقة الإدخال تتألف من 80 عقدة حسب حجم مصفوفة صورة كل نمط (10*8)، إذ تم اختيار عدد العقد في الطبقة الخفية اعتمادا على إجراء عدة اختيارات فعندما يكون عدد العقد (1،6...2) فان الشبكة تصبح غير قادرة على استكمال التدريب للوصول إلى قيمة قريبة من الخطأ المسموح (10^{-5}) إذ تصل إلى حالة مستقرة للخطأ مابين (10^{-3}-10^{-2}) فعند زيادة عدد العقد إلى 20 عقدة خفية فان قيمة الخطأ تنحدر بشكل واضح للوصول إلى الخطأ المسموح ولكن تستغرق وقت أكثر في التدريب بسبب زيادة العمليات الحسابية، ومن اجل الموازنة بين الخطأ والوقت فقد تم اختيار عدد العقد في الطبقة الخفية (10) لوصول أداء الشبكة إلى قيمة الخطأ (9.96592e-006) وهو اقرب قيمة من الخطأ المسموح.[7]

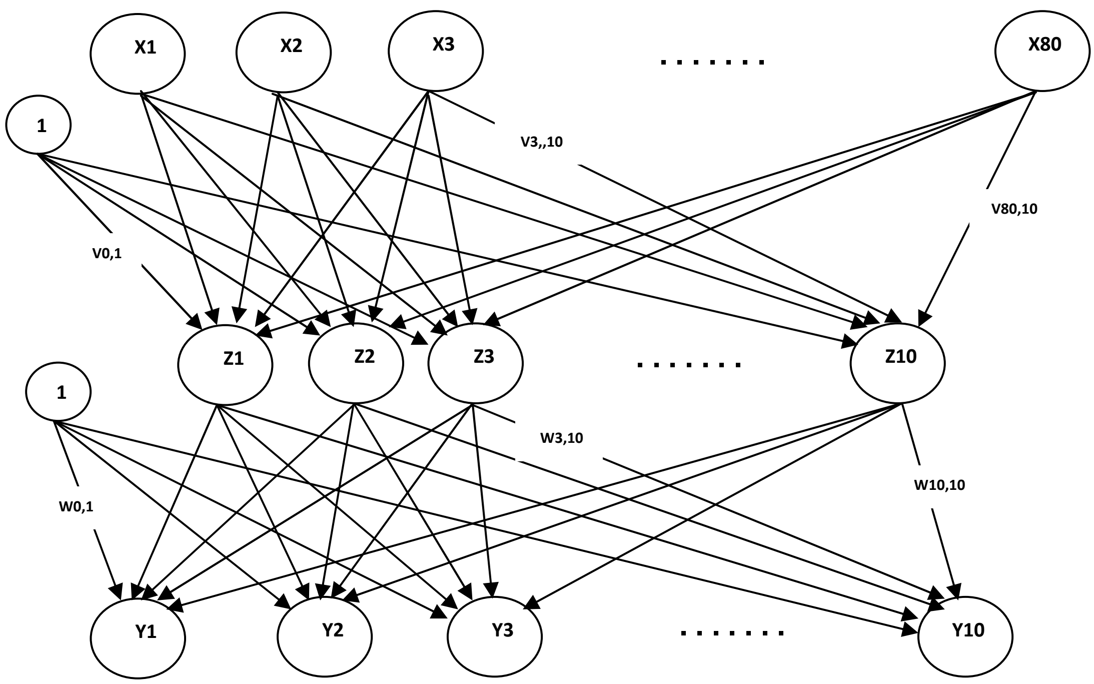

الشكل (2-1): البنية الهندسية لشبكة Backpropagation

2-2 خوارزمية التدريب:[7][12]

1. تهيئة الأوزان (قيم عشوائية صغيرة بين -0.5 و 0.5).
2. تستقبل كل وحدة إدخال (x_i, i=1…n, n=80) إشارة الإدخال xi بعد قراءة الصور وتحويلها إلى مصفوفة، ثم تنتشر إلى جميع وحدات الطبقة الخفية.
3. تجمع كل وحدة خفية (z_j, j=1…p, p=10) قيم الإدخال الموزونة لحساب دالة الطبقة الخفية (Tan sigmoid) كما يلي:

$$Z_{inj} = v_{0j} + \sum_{i=1}^{n} x_i v_{ij} \quad \ldots\ldots\ldots\ldots\ldots\ldots (5)$$

$$z_j = f(z_{inj}) \quad \ldots\ldots\ldots\ldots\ldots\ldots (6)$$

ثم ترسل قيمة الدالة إلى جميع وحدات طبقة الإخراج.

4. إيجاد حاصل جمع كل وحدة إخراج (y_k: k=1…m, m=10) المضروبة بالأوزان كما يلي:

$$y_{in_k} = w_{ok} + \sum_{j=1}^{10} z_j w_{jk} \quad \ldots\ldots\ldots\ldots\ldots\ldots (7)$$

وبتطبيق دالة حساب الإخراج (Tan sigmoid):

$$y_k = f(y_{in_k}) \quad \ldots\ldots\ldots\ldots\ldots\ldots (8)$$

5. حساب الخطأ بين الإخراج الحالي والمرغوب به:

$$\delta_k = (t_k - y_k).y_k \quad \ldots\ldots\ldots\ldots\ldots\ldots (9)$$

حيث t_k الهدف

6. حساب تصحيح الأوزان w_{jk} :

$$\Delta w_{jk} = \propto.\delta_k.z_j \quad \ldots\ldots\ldots\ldots\ldots\ldots (10)$$

وكذلك حساب تصحيح وزن الانحياز w_{0k}

$$\Delta w_{0k} = \propto.\delta_k \quad \ldots\ldots\ldots\ldots\ldots\ldots (11)$$

7. إرسال δ_k إلى الوحدات في الطبقة التي تسبقها

$$\delta\_in_j = \sum_{k=1}^{10} \delta_k.w_{jk} \quad \ldots\ldots\ldots\ldots\ldots\ldots (12)$$

8. ضرب هذه القيمة بمشتقة دالة التنشيط لحساب حد الخطأ

$$\delta_j = \delta\_in_j.z_j \quad \ldots\ldots\ldots\ldots\ldots\ldots (13)$$

9. حساب تصحيح الأوزان V_{ij}

حساب تصحيح الانحياز V_{0j}

$$\Delta V_{0j} = \propto . \delta_j \qquad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (14)$$

10. تحديث الأوزان للإخراج

$$W_{jk}(new) = W_{jk}(old) + \Delta W_{jk} \qquad \dots\dots\dots (15)$$

تحديث أوزان الطبقة الخفية

$$V_{ij}(new) = V_{ij}(old) + \Delta V_{ij} \qquad \dots\dots\dots\dots (16)$$

والشكل (2-2) يمثل الرسم البياني لتدريب شبكة Backpropagation نلاحظ فيه وصول منحني التدريب إلى التكرار 580 خلال فترة مقدارها (4:09.625) دقيقة ليعطي قيمة الخطأ في الشبكة (9.96592e-006) لتثبيت أوزان الشبكة للحصول على الإخراج المطلوب وهي تمثل اقرب قيمة من الخطأ المسموح (10-5) والمتمثلة بالخط الأفقي عند نهاية المنحني.[8]

وصول أداء الشبكة إلى قيمة للخطأ 9.96592e-006

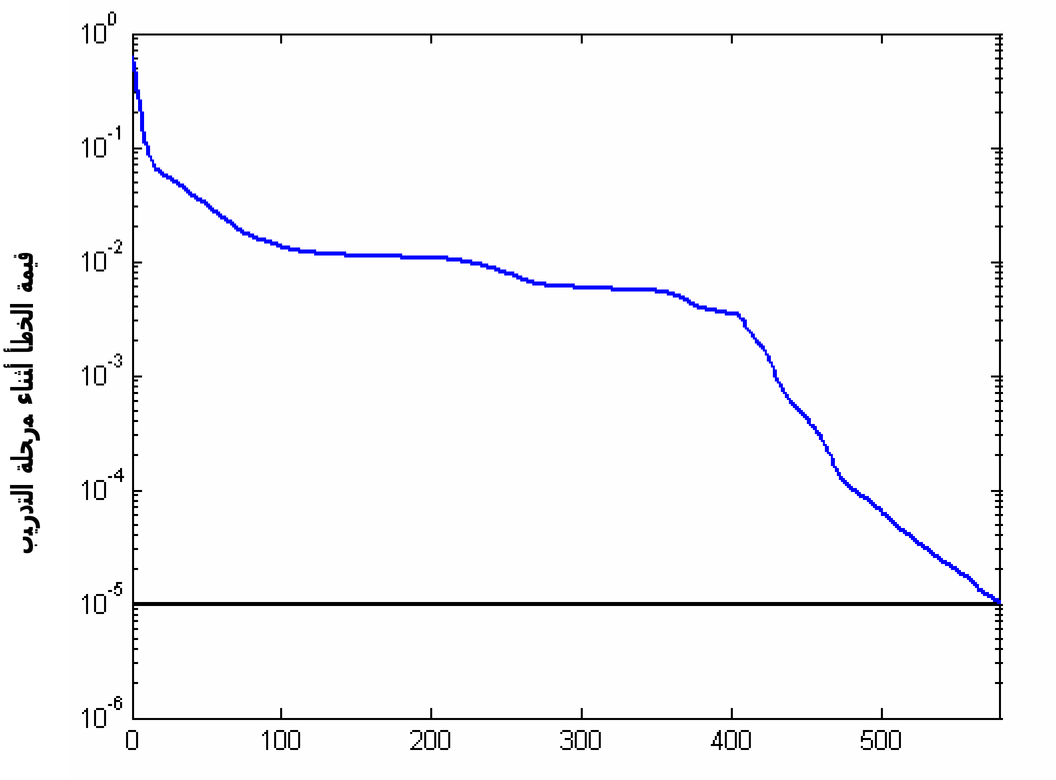

عدد مرات تدريب الشبكة 580

الشكل (2-2): خطوات تدريب شبكة Backpropagation إلى قيمة الخطأ 10^{-5}

3-2 اختبار شبكة B.P:

بعد تدريب شبكة Backpropagation على الأنماط في الملحق (A) تم اختبارها على أنماط للاختبار وكانت النتائج موضحة في الملحق (B1-4) حيث تمثل أنماط الاختبار مصفوفة لصور الأرقام غير المعروفة للشبكة مسبقاً مع تمييز الشبكة لها، وان نتيجة اختبار الشبكة هي 81% نسبة المطابقة في الاختبار.

3. شبكة Hopfield المتقطعة

من مميزات شبكة هوبفيلد بانها متصلة فيما بينها داخليا، وكل وحدة فيها ترتبط مع جميع الوحدات الأخرى وتستخدم مصفوفة الأوزان المتناظرة الناتجة من الإدخال الأولي، أما ثنائية (1،0) أو قد تكون ثنائية القطبية (-1،1)، وتختلف عن الشبكات الأخرى بان كل وحدة تقوم بتحسين دالة التنشيط معتمدة على الإشارة المستقبلة من كل وحدة أخرى. فهي تستخدم دالة الطاقة(E) لتصميم الشبكة والتي تحسن من قدرتها وتجعلها مستقرة: [7][12]

$$E = -\frac{1}{2}\sum_{i}\sum_{j} w_{ij}y_i y_j \qquad \dots\dots\dots\dots\dots (17)$$

فمن خاصية دالة الطاقة تكون في حالة تناقص إلى ان تصل في النهاية إلى أدنى قيمة لتجعل الشبكة العصبية في حالة طاقة ثابتة ومستقرة وبهذا فان عدد الأنماط المخزونة عند هذه القيمة يمكن ان تستخدم بشكل ذاكرة ترابطية والتي تعمل بخطين: خط الخزن وخط الاسترجاع. فالخط الأول يتم فيه تحديد الأوزان عن طريق الأنماط المدخلة، والخط الثاني يستخدم نمط الإدخال كحالة ابتدائية للوصول إلى حالة التوازن. وان عدد الأنماط الثنائية (p) التي يمكن ان تخزن في الشبكة العصبية يساوي: $p<0.15n$ وعدد الأنماط الممثلة بشكل ثنائي القطبية يصل إلى: [7][12]

$$p < n/2log2n \qquad \dots\dots\dots\dots\dots (18)$$

3-1 البنية الهندسية

وبنفس طريقة تمثيل الأرقام التي استخدمت في تدريب الشبكتين السابقتين فقد استخدمت في شبكة (Hopfeild) أيضاً من اجل إجراء المقارنة بين الشبكات الأربعة حيث ان الشكل (3-1) يوضح البنية الهندسية لشبكة Hopheild ولكن باستخدام طريقة الإدخالات الثنائية القطبية (-1،1) لمصفوفة صور الأرقام (مصفوفة الصورة هي 10*8=80 عقدة للإدخال والإخراج) وعلى أساسها يتم حساب الأوزان.[9]

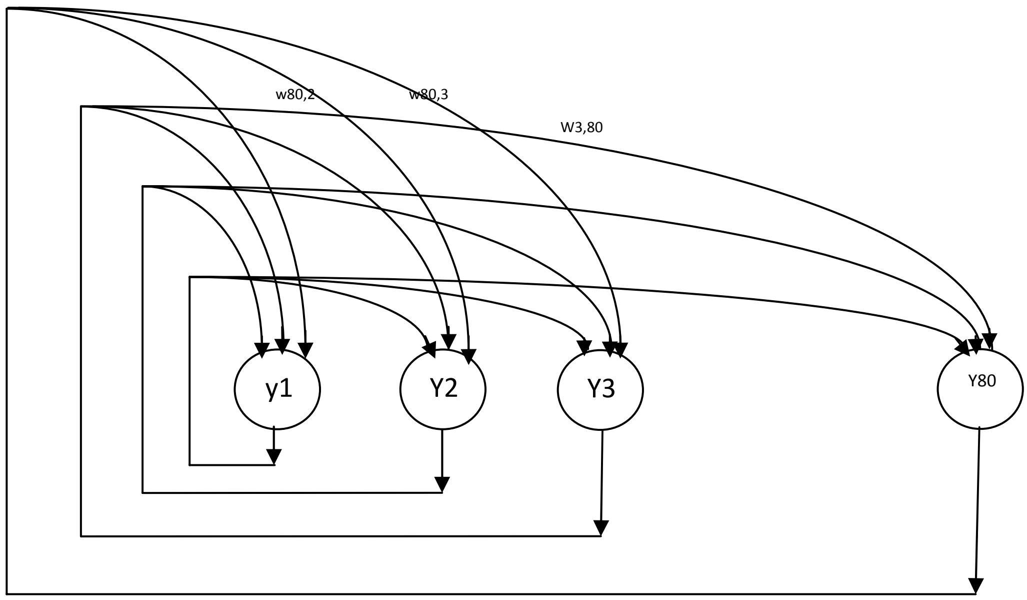

الشكل (3-1): البنية الهندسية لشبكة Hopfeild

3-2 خوارزمية التدريب:[7]

1. تهيئة الإدخال باستخدام التمثيل الثنائي القطبية (-1،1) للإدخال (ملحق A) [s(p) p=1…20] حيث: $(p)=s_1(p),s_2(p)\ldots s_n(p)$
n=80
S تمثل عقدة الإدخال لكل نمط p
وبالنسبة لمصفوفة الأوزان فانها تعرف بالصيغة التالية:

$$w_{ij} = \sum_{p} s_i(p).s_j(p) \quad : i \neq j , w_{ii} = 0 \quad \ldots\ldots (19)$$

2. $Y_i=x_i \quad , \quad i=1\ldots 80$
3. $y_{in_i} = x_i + \sum_j y_j . w_{ji}$ وحساب دالة الإخراج بالعلاقة:

$$y_i = \begin{cases} 1 & if\ y\_in_i > 0 \\ -1 & if\ y\_in_i \leq 0 \end{cases} \quad \ldots\ldots\ldots\ldots (20)$$

4. توزيع القيمة y_i إلى جميع الوحدات الأخرى.

3-3 اختبار الشبكة:

تم اختبار شبكة Hopfield بتطبيق صور الأرقام في الملحق (B1-4) وإيجاد النموذج الذي يقترب من النمط فكانت نسبة المطابقة تساوي 87% مشابه.

4. شبكة Kohen :[12][7]

وهي من شبكات التنظيم الذاتي Self Organizing Map ومن نوع الشبكات التي تعمل بدون معلم Unsupervised حيث لا يوجد لها إخراج محدد يقدم للشبكة كما في الشبكات السابقة، فمن خلال خصائص التنظيم الذاتي انها قادرة على إنتاج علاقة وتعلم لأكثر عدد من الإدخالات المقدمة لها وهذه الخاصية موجودة في الدماغ البشري.

1-4 البنية الهندسية:[7]

تمتلك شبكة kohen طبقة واحدة للإدخال Input Layer وطبقة واحدة للإخراج Output Layer وهذه الطبقة ممكن ان تكون لوحدها في الشبكة أو قد ترتبط مع طبقة أخرى لشبكة عصبية أخرى مثل شبكة Counterpropagation. خلال هذا البحث تم التطرق عندما تكون الطبقة لوحدها فقط كما موضحة في الشكل(4-1) وعدد العقد الموجودة في طبقات الإدخال والإخراج يعتمد على مصمم الشبكة وحسب التطبيق.

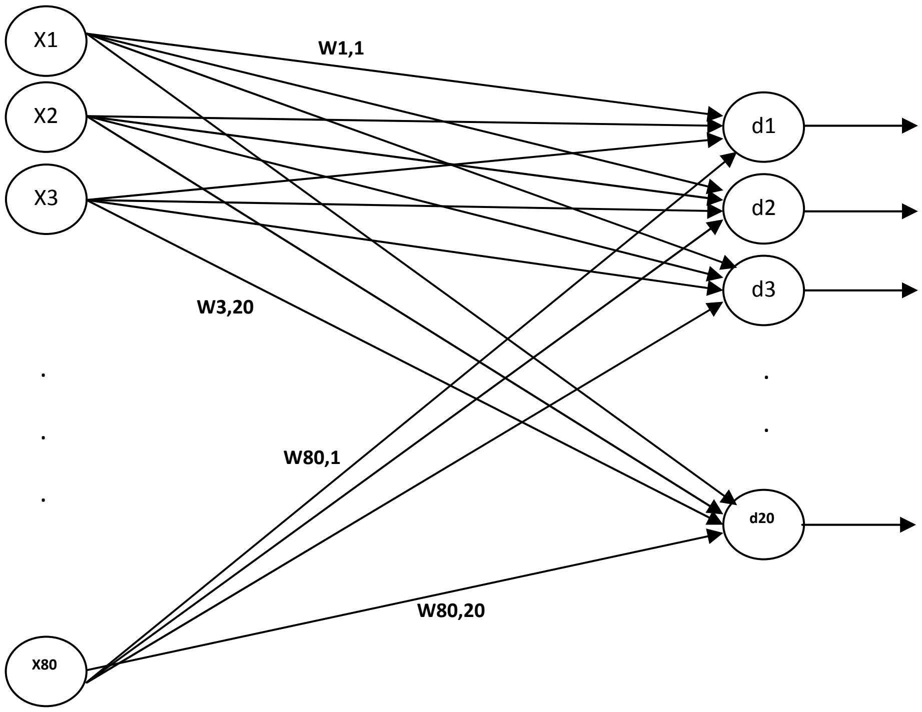

الشكل (4-1): البنية الهندسية لشبكة Kohen

2-4 خوارزمية التدريب: [7][12]

1. تهيئة أنماط التدريب (20 نموذج لصور الأرقام بعد تحويل كل صورة إلى مصفوفة)
2. اختيار الأوزان الابتدائية بقيم عشوائية صغيرة عادة.

3. إدخال قيمة α0.01= وعدد العقد المجاورة للعقدة الرابحة (0≠) ليتم تعديل أوزانها (عدد العقد المجاورة=2).
4. على كل نمط من أنماط التدريب تكرر الخطوات من 5 إلى 7.
5. حساب المسافة بين الإدخال والأوزان حسب المعادلة التالية:

$$D_i = SQR\left(\propto (x_i - w_{ij})^2\right) \qquad \ldots\ldots\ldots\ldots\ldots\ldots (21)$$

حيث j=20 هي عدد عقد الإخراج، و i=80 عدد عقد الإدخال

6. إيجاد اقل مسافة D من عقد الإخراج لتكون العقدة الرابحة.
7. تحديث الأوزان لعقدة الإخراج الرابحة والعقد المجاورة لها فقط والتي حدد عددها في الخطوة 3 حسب المعادلة التالية:

$$W_{ij}new = W_{ij}old + \propto * (X_i - W_{ij}) \qquad \ldots\ldots\ldots (22)$$

8. اختبار شرط التوقف عندما تصل إلى عدد التكرارات المحدد والذي يعطي استقرار للشبكة.

3-4 اختبار الشبكة:

بعد تدريب شبكة Kohen على أنماط التدريب وإيجاد العقدة الرابحة لكل نمط في الملحق (A) تم تطبيق الشبكة على أنماط غير معروفة للشبكة مسبقا كما موضحة في الملحق (B1-4) لإيجاد العقدة الرابحة لها فكانت نتيجة اختبار الشبكة هي 75% مطابقة.

5. الاستنتاجات:

6. بعد تدريب الشبكات الأربعة على نفس الأنماط واختبارهم على أنماط الصور في الملحق (B1-4) كانت نتائج الاختبار والوقت المستغرق في التدريب بالدقائق كما يلي:

الشبكات	1 Adaline	2 Backpropagation	3 Hopfield	4 Kohen
نسبة التطابق	%83	%81	%87	%75
الوقت المستغرق في التدريب	0:02.391	4:09.625	0:01.031	1:45.463

وبهذا استنتجنا ان أفضل شبكة يمكن استخدامها في هذا النوع من الأنماط هي شبكة Hopfield ثم تليها شبكة Adaline وشبكة Backpropagation وأخيراً شبكة Kohen التي تحتاج إلى حالات أكثر للتدريب. فكلما ازداد عدد أنماط التدريب ازدادت كفاءة الشبكات العصبية على التمييز، وكذلك لوحظ بان سمك الخط قد يؤثر في التمييز فكلما كان قليل تكون النتيجة أكثر تطابقاً كما في نوع الخط المستخدم (Bradley Handitic Bold) حيث نلاحظ

في الشبكات العصبية الأربعة لهذا النوع من الخط كانت معظم النتائج صحيحة. وان عدد تكرارات التدريب في تلك الشبكات مختلف لكنه لا يعد اختلافاً كبيراً أو مؤثراً على تعلم الشبكة. اما من حيث الوقت المستغرق في التدريب فيعتمد على البنية الهندسية والعمليات الحسابية في الشبكة لتثبيت الأوزان النهائية للحصول على الإخراج المطلوب.

المصادر:

[1]. Yu-chao C., Applying Neural Networks in Quality Function Deployment Process for Conceptual Design, journal of Chinese Institute of Industrial Engineers, Vol. 21, No.6, pp.587-596, (2004).

[2]. G. Papadopoulos, P. J. Edwards, et al, Confidence Estimation Methods for Neural Networks: A Practical Comparison, European Symposium on Artificial Neural Networks Bruges (Belgium), pp. 75-80, 26-28 April (2000).

[3]. العبيدي، محمود خليل إبراهيم، الشبكات العصبية الاصطناعية، مجلة أبحاث الحاسوب، المجلد 4، العدد 1، 74-89 (2000).

[4]. Brockett, P. L., Golden، L. L., A comparison of neural network, statistical methods, and variable choice for life insurers' financial distress prediction, journal of Risk and Insurance, September 1, (2006).

[5]. Piccinini G., Some Neural Networks Compute, Others don't, Neural Networks, Special Issue, Articale in press, Available online at www.sciencedirect.com, PP. 1-11, (2008).

[6]. الشبول، ياسين احمد، "تطبيقات الـ Matlab"، دار الحامد للنشر والتوزيع، عمان، الاردن، (2004).

[7]. عيسى، علام زكي، "الشبكات العصبية، البنية الهندسية، الخوارزميات، التطبيقات"، شعاع للنشر والاعلام، (2000).

[8]. Lipmann R.P. Introduction to computing with Neural Nets, IEEE Assp Magazine, Vol.4, No.2, PP4-22 (1987).

[9]. Wasserman P. D. Neural computing theory and practice, Van Nostrand Reinhold, New York (1989).

[10]. Paplinsk A. P., Basic structures and properties of Artificial Neural Networks, NNets_L, July 7, (2004).

[11]. Piccolo F., Crespo, M. Gallard R., Prinsta M., A parallel approach for Backpropagation learning of neural networks; journal of computer Science & Technology, March 1, (1999).

[12]. Jain A. K., Mao J., et al, Artificial Neural Networks, IEEE Computer, Vol. 29, No. 3, pp.31-44, March, (1996).

ملحق (A)

أنماط التدريب لصور الأرقام			
نماذج التدريب من نوع الخط **Time New Roman**		نماذج التدريب من نوع الخط **Bradley Handitic Bold**	
0	5	0	5
1	6	1	6
2	7	2	7
3	8	3	8
4	9	4	9

ملحق (B-1)

ت	انماط الاختبار	تمييز شبكة Adaline	تمييز شبكة Back-propagation	تمييز شبكة Hopfield	تمييز شبكة Kohen
1		2	5	5	5
2		1	1	1	7
3		2	2	2	1
4		5	5	5	5
5		4	9	4	1
6		5	5	5	5
7		5	6	5	5
8		1	7	1	1
9		6	3	3	3
10		9	5	9	5

ملحق (B-2)

ت	انماط الاختبار	تمييز شبكة Adaline	تمييز شبكة Back-propagation	تمييز شبكة Hopfield	تمييز شبكة Kohen
11		8	3	0	5
12	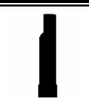	1	1	1	7
13		6	1	2	1
14		5	5	5	5
15		4	7	1	1
16		5	5	5	5
17		6	6	5	5
18		6	3	1	1
19		6	3	8	5
20		4	9	5	5

ملحق (B-3)

ت	انماط الاختبار	تمييز شبكة Adaline	تمييز شبكة Back-propagation	تمييز شبكة Hopfield	تمييز شبكة Kohen
21		0	0	0	0
22		1	1	1	1
23		2	2	2	2
24		3	3	3	3
25		4	4	4	4
26		5	5	5	5
27		6	6	6	6
28	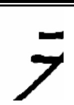	7	7	7	7
29		8	8	8	8
30		9	9	9	9

ملحق (B-4)

ت	انماط الاختبار	تمييز شبكة Adaline	تمييز شبكة Back-propagation	تمييز شبكة Hopfield	تمييز شبكة Kohen
31		0	0	0	0
32		1	1	1	1
33		2	2	2	2
34	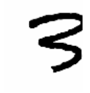	3	3	3	3
35		4	4	4	4
36		5	5	5	5
37		6	6	6	6
38	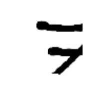	7	7	7	7
39		8	6	8	8
40		9	9	9	9