



جمهورية العراق
وزارة التعليم العالي والبحث العلمي
جامعة القادسية
كلية علوم الحاسوب وتكنولوجيا المعلومات
قسم الحاسوب / الدراسة الصباحية

الشبكات العصبية

الاصطناعية

(لتمييز الأحرف الانكليزية)

مشروع بحث تخرج

مقدم إلى كلية علوم الحاسوب وتكنولوجيا المعلومات - جامعة القادسية وهو جزء من متطلبات نيل درجة

البكالوريوس في علوم الحاسوب

من قبل الطالبات

فاطمة فخر الدين محمد مريم جاسم مصطفى

إشراف

ا.م.د. محمد عباس كاظم

2016 2017

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

(رَبِّ أَوْزِرْ عَنِّي أَنْ أَشْكُرَ نِعْمَتَكَ الَّتِي أَنْعَمْتَ عَلَيَّ وَعَلَىٰ وَالِدَيَّ وَأَنْ أَعْمَلَ
صَالِحًا تَرْضَاهُ وَأَصْلِحْ لِي فِي ذُرِّيَّتِي إِنِّي تُبْتُ إِلَيْكَ وَإِنِّي مِنَ الْمُسْلِمِينَ)
صدق الله العليُّ العظيم

(الاحقاف - ٣٠)

الاهداء

الى مدرستي الكبرى

أمي وأبي

لدقات قلبي وسندي ان اوجعني الزمان

أخي

للنخلة التي احتميت بظلها عند حلول الضياع

جامعة القادسية

لمن حرمني الارهاب منها ها انا اعود لك حبيبتني

جامعة الموصل

شكر وتقدير

بعد ان تر بفضل من الله سبحانه وتعالى انجانر مشروعا نتصفح افكارنا ونستجمع عباراتنا حتى

نجمع احلى كلمات التقدير لنصوغ اجمل عبارة امتنان للأستاذ الفاضل

أ.م.د محمد عباس كاظم

لما ابداه من مساعدة حثيثة وتوجيهات قيمة وسديدة مما كان له الاثر البالغ في انجانر مشروعا

هذا

المحتويات

الفصل الاول

- ١-١ المقدمة ١
- ١-٢ الخلفية التاريخية للشبكات العصبية الاصطناعية ١
- ١-٣ مكونات اخلية العصبية المفردة ٢
- ١-٤ ماهي مميزات وعيوب الشبكة العصبية الاصطناعية ٤

الفصل الثاني

- ٢-١ هيكلية الشبكة العصبية الاصطناعية ٥
- ٢-٢ دوال الفعالية ٦
- ٢-٣ الية التعلم في الشبكات العصبية الاصطناعية ١٠
- ٢-٤ خواص وامكانيات الشبكة العصبية الاصطناعية ١٢
- ٢-٥ التعميم والتقريب وحساب نسبة الخطأ ١٤
- ٢-٦ تطبيقات الشبكات العصبية الاصطناعية واستخداماتها المختلفة ١٩
- ٢-٧ تصنيفات الشبكات العصبية الاصطناعية ٢٠

الفصل الثالث

- ٣-١ طرق التعلم في الشبكات العصبية الاصطناعية ٢١
- ٣-٢ الشبكات العصبية الاصطناعية من دون مشرف عليها ٢٢
- (Unsupervised Neural Networks)
- ٣-٣ شبكات Hop field العصبية الاصطناعية ٢٢

المصادر

- ١- الأستاذ الدكتور أحمد طارق صادق ، "الانظمة الذكية وتعلم الماكنة".
- ٢- الأستاذ الدكتور محمد علي الشراوي ، "الذكاء الاصطناعي والشبكات العصبية".
- ٣- عنزة حانم امين بك ، "تصميم العصبية والتكهن بالسلاسل الرمزية" رسالة ماجستير في علوم الاحصاء ، جامعة الموصل ، كلية علوم الحاسوب والرياضيات . الموصل.
- ٤- الدكتور نزياد عبد الكريم القاضي ، "الدليل العلمي لتطبيقات الشبكات العصبونية"
- ٥- Kose, Ben & van der smagt ,Patrick "an introduction to neural network "URL://http://www.fwi.uva.nl/research/neuron/, (1996).
- ٦- Christos Stergiou and Dimitrios Siganos "neural networks"http://www.doc.ic.uk/nd/report., 2009.
- ٧- Skapura ,David M. and freeman, james A." Neural Networks: algorithms ,applications and programming techniques"http://www.artificial intelligence.com ,1991.

الفصل الاول

1- 1 المقدمة

تعد الشبكات العصبية الاصطناعية أهم التطبيقات الذكاء الاصطناعي في مجال تعلم الماكنة، ولربما تحتل مركز الصدارة في هذا المجال من بين التقنيات المختلفة في مجال تعلم الماكنة بالنظر لحجم المجالات والتطبيقات التي استخدمت فيها هذه التقنية من النوع الواضح (Explicit learning). يسلط هذا البحث الضوء على أهم الأمور الأساسية المتعلقة بهذه التقنية بدء من تاريخ نشوئها وماهية الخلية العصبية الاصطناعية ومكونات الشبكات العصبية الاصطناعية وهيكليتها مرورا بالية التعليم، تصنيفات هذه التقنية وتطبيقاتها، ثم الدخول في التفاصيل أهم خوارزميات هذه التقنية، فقد اختيرت 7 خوارزميات مهمة هي الاوسع استخداما والا هم من الناحية النظرية و العلمية لذوي الاختصاص. واختيرت خوارزميات متنوعة حسب طريقة التعلم فهناك خوارزميات لا تعتمد على وجود مشرف (Supervised) مثل خوارزمية شبكة (Hopfield) وخوارزمية شبكة الذاكرة المرتبطة الثنائية (BAM) وهناك خوارزميات تشترط وجود المشرف في عملها (Unsupervised) مثل خوارزمية الطبقة الواحدة (Single-Layer) وخوارزمية الانتشار الخلفي (Back-Propagation) ذائعة الصيت وخوارزمية تعليم المتجه المقسم (LVQ) والنوع الاخير من الخوارزميات التي اختيرت هي من النوع ذاتية التنظيم (Self-Organization) مثل خوارزمية (Kohonen) وخوارزمية نظرية الرنين التطوعية العصبية الاصطناعية (ART). [1]

2-1 الخلفية التاريخية للشبكات العصبية الاصطناعية

يمكن القول ان بداية التفكير في الشبكات العصبية الاصطناعية قد بدا في القرن الماضي حيث قام فرويد (Freud) بالتعرض الفلسفي للفكرة العامة لها. وفي عام 1913 حيث نفذ روسل (Russel) جهازا هيدوليكيًا معتمدا على الفكرة العامة للشبكات. وفي عام 1943 ابتكر العلمان (Warren) و (Walter) نموذجا احتسابيا للشبكات العصبية بالاعتماد على الرياضيات والخوارزميات، وسمي بنموذج منطق العتبة (Threshold Logic Model). وقد مهد الطريق الى ابحاث الشبكات العصبية الاصطناعية، وتضمن جزئين، الاول ركز على العمليات الاحيائية في الدماغ، والثاني بحث في تطبيقات الشبكات العصبية

الاصطناعية في مجال الذكاء الاصطناعي. تعتبر التسعينات من هذا القرن هي القفزة الحقيقية في التطوير، حيث اعلن البيت الابيض الامريكي ان العقد الحالي(1900-2000 م) هو عقد المخ والشبكات العصبية الحساب العصبي ،وذلك نظرا لزيادة الكبيرة في عدد المهتمين بها والذين حضروا مؤتمرات الجمعية الامريكية الفيزيائية (American Physical Society)اعوام(1985-1986-1987)والذي ارتفع عددهم من 60شخصا الى اكثر من 2000شخص في الاعوام(1988-1990). [2]

3-1 مكونات الخلية العصبية المفردة

قام الباحثون والعلماء بدراسة الية عمل الدماغ الانسان ،وطريقة التنظيم العجيب لهذا الجزء من الانسان الذي اصنعه قدرة الله (عز وجل في علاه) .فسبحان الله الذي خلق الدماغ وجعل فيه قدرة التفكير والتعليم والاستنتاج وما الى ذلك من خواص عقلية .ومن خلال دراسة العلماء تبين ان دماغ الانسان يحوي عددا هائلا من الخلايا العصبية تقدر بالملايين ترتبط بدورها بشبكة اعصاب هائلة تعد بمئات الملايين ،وظيفة هذه الشبكة الهائلة من الاعصاب هي اقبال الاشارة العصبية بين خلايا الدماغ والخلايا العصبية الاخرى المنتشرة في جسم الانسان .وهذه الشبكة الهائلة من الاعصاب هي التي تسبب سرعة الاستجابة للاشارة العصبية (وفق اعتقاد العلماء المختصون) علاوة على ما وضعه الله (عزة وجل في علاه)من الخواص تجعل من الاعصاب ناقلا سريعا جدا لاشارة العصبية .

تتكون الخلية العصبية في جسم الانسان من:

1. جسم الخلية ويحوي بدوره نواة الخلية (Cell Body and Nucleus)
2. محور الخلية العصبية (Axon)
3. الوصلة العصبية (Synapse)
4. التشعب العصبي (Dendrites)


جسم الخلية العصبية يحوي بدوره نواة الخلية العصبية التي تمثل الجزء الاساسي فيها،اما محور الخلية العصبية فهو الجزء الذي ينقل الاشارة العصبية داخل النظام العصبي للدماغ

الشكل(1-1) يبين مكونات الخلية العصبية البايولوجية.



نأتي الآن إلى الخلية العصبية الاصطناعية التي استمدت فكرتها من الخلية العصبية في دماغ الإنسان وكما يلي "اعتبرت الإشارة الداخلة إلى الخلية العصبية بمثابة مدخلات رقمية (Input) إلى الخلية العصبية الاصطناعية واعتبرت التشعبات والوصلات العصبية بمثابة وزن (Weight) أو وحدة تعبر عن قوة الإشارة المدخلات وتم الحصول على مجمل الإشارة من خلال حاصل ضرب الإشارة في قوة (وزن) كل إشارة ومن ثم جمع الناتج ليعبر عن قوة الإشارات الداخلة إلى الخلية العصبية الاصطناعية ولكن هل إن كل إشارة تصل إلى الدماغ يستجاب لها؟ بالتأكيد كلا، إذا فهناك محدد أو حد عتبة (Threshold) كما يسمى وهو الذي يكون مسؤولاً عن تحديد قوة أو أهمية الإشارة الواردة، يمثل في الخلية العصبية الاصطناعية بدالة رقمية سميت دالة الفعالية (Activation Function)

وستكون القيمة الخارجة من هذه الدالة هي قيمة الخلية العصبية الاصطناعية.
الشكل (2-1) يمثل مكونات الخلية العصبية الاصطناعية.



إذا نستنتج مما تقدم أن مكونات الخلية العصبية الاصطناعية هي كالآتي:

1. مدخلات رقمية (Inputs)
 2. أوزان حسب المدخلات (Weights)
 3. دالة الفعالية (Activation Function)
 4. مخرجات رقمية (Outputs)
- المدخلات تكون عبارة عن متجه $(X_1, X_2, \dots, X_n)$ من الإشارات الداخلة إلى الخلية العصبية الاصطناعية والأوزان عبارة عن متجه $(W_1, W_2, \dots, W_n)$ يمثل الأوزان ودالة

الفعالية وهي دالة رقمية تكون اما خطية او غير خطية (Linear or Non-Linear) واما المخرجات فتكون عبارة عن قيمة رياضية ($Y_1, Y_2, \dots, Y_M$) تمثل ناتج حد العتبة الذي تحويه دالة الفعالية (F). [1][4]

4-1 ماهي مميزات وعيوب الشبكة العصبية الاصطناعية

شبكة العصبية الاصطناعية هي نظام تعتمد على عمليات اشبكه العصبية البيولوجية ،وبعبارة الاخرى ،هي محاكاة نظام العصبية البيولوجية.حيث لها مميزات وكما تحوي على عيوب [3][5].

المميزات:

- ان الشبكة العصبية الاصطناعية يمكن أن تؤدي المهام التي لا يمكن للبرنامج الخطي ان ينفذها .
- لا تحدث مشكله اذا حدث فشل في احدى عناصر الخليه العصبية .
- ان الشبكة العصبية تتعلم وليس بحاجة الى اعادة برمجة.
- يمكن ان ينفذها في أي تطبيق.
- يمكن تنفيذها دون أي مشكلة. [3][5]

العيوب:

- الشبكة العصبية الاصطناعية تحتاج الى التدريب لكي تنفذ وظيفتها.
- بنية الشبكة العصبية تختلف عن بنية المعالجات لذا يجب ان تستخدم المحاكات
- الشبكات العصبية الاصطناعية تتطلب وقت معالجة عالية. [3][5]

الفصل الثاني

1-2 هيكلة الشبكة العصبية الاصطناعية

بعد ان تم بناء الخلية العصبية الاصطناعية واستكمال مفهومها كخلية عصبية رقمية (Digital Neuron) ، نأتي الان الى بناء الشبكة العصبية الاصطناعية ، التي تتكون عادة من مجموعة من الخلايا العصبية الاصطناعية متصلة فيما بينها بنسق معين أو بأسلوب معين وعلى العموم تقسم انواع الخلايا العصبية الاصطناعية في الشبكات العصبية الاصطناعية الى اربعة انواع رئيسية هي :

- 1- خلايا مدخلات (Input Neurons) وهي المسؤولة عن قيم المدخلات الى الشبكة العصبية الاصطناعية
 - 2- خلايا مخرجات (Output Neurons) وهي المسؤولة عن قيم المخرجات من الشبكة العصبية الاصطناعية
 - 3- خلايا مخفية (Hidden Neurons) وهي موجودة في انواع كثيرة من الشبكات العصبية الاصطناعية وهي متعلقة بالشبكة نفسها ولادخل لمدخلات المشكلة ومخرجاتها بها. وظيفتها: تكمن في تحسين اداء الشبكة العصبية الاصطناعية بالتعلم في حالات المشاكل المعقدة.
 - 4- الخلايا الثابتة (متحيزة) القيمة (Bias) وعادة ما تحمل قيمة وحيدة ، وفائدتها تحسين الشبكة العصبية الاصطناعية في حال تعذر او بطء عملية التعلم.
- وهكذا تم استطراد انواع الخلايا العصبية الاصطناعية بأنواعها الاساسية ، نأتي الان الى هيكلة الشبكات العصبية الاصطناعية ، فهنا توجد العديد من التشكيلات الشبكات العصبية الاصطناعية وأهمها كما يلي:

- 1- شبكة عصبية اصطناعية ذات اتصال متكامل مع تغذية خلفية (Full Connection & Feedback) : وهي الشبكة العصبية الاصطناعية التي تكون فيها كل خلية عصبية مرتبطة بباقي الخلايا ، كما نلاحظ في الشكل (أ-1-2)
- 2- شبكة عصبية اصطناعية ذات طبقة واحدة (Single Layer): وهي الشبكة العصبية الاصطناعية مكونة من طبقتين وتكون فيها كل خلية عصبية في طبقة المدخلات (Input Layer) مرتبطة بكل خلية موجودة في طبقة المخرجات (Output Layer) كما نلاحظ في الشكل (ب-1-2)

3- شبكة عصبية اصطناعية متعددة الطبقات (Multi-Layers): وهي الشبكة العصبية الاصطناعية مكونة من عدة طبقات وتكون فيها كل خلية عصبية في كل طبقة مرتبطة بكل خلية موجودة في الطبقة التي تليها ، كما نلاحظ في الشكل (ج-2-1) وتكون الطبقة الاولى مخصصة للمدخلات والطبقة الاخيرة مخصصة للمخرجات والطبقات التي بينهما تعد طبقات مخفية (Hidden Layers).

4- شبكة عصبية اصطناعية من النوع التنافسي (Competitive) : وهي الشبكة العصبية الاصطناعية مكونة من طبقتين وليس شرطاً ان تكون فيها كل خلية عصبية في طبقة المدخلات مرتبطة بكل خلية موجودة في طبقة المخرجات ، كما نلاحظ في الشكل (د-2-1)

5- شبكة عصبية اصطناعية من نوع التنظيم الذاتي (Self-Organization) وهي الشبكة العصبية الاصطناعية مكونة من طبقتين وتكون فيها كل خلية عصبية في طبقة المدخلات مرتبطة بكل خلية موجودة في طبقة المخرجات، ولكنها مرتبة بطريقة هندسية او رياضية معينة لتتفع في تطبيقات هذا النوع من الشبكات العصبية الاصطناعية كما نلاحظ في الشكل (ب-2-1). [7]

2-2 دوال الفعالية


كما اشرنا سابقاً فإن دالة الفعالية تمثل جزءاً مهماً من اجزاء الخلية العصبية الاصطناعية وهي المسؤولة عن تحديد القيمة الخارجة من الخلية .


فُسمت الفعالية الى نوعين هما:

1- دوال الفعالية الخطية (Linear).

2- دوال الفعالية اللاخطية (Non-Linear).

الشكل (2-2) يمثل انواع من دوال الفعالية الخطية واللاخطية الواسعة الاستخدام وبالطبع هناك العديد من هذه الدوال غير التي يسيرد ذكرها وهي محدودة الاستخدام.







$$f(x) = x$$




$$f(x) = \begin{cases} 1 & \text{if } x > 0 \\ 0 & \text{if } x \leq 0 \end{cases}$$




$$\begin{cases} 1 & \text{if } x > 0 \\ -1 & \text{if } x \leq 0 \end{cases}$$



$$f(x) = \begin{cases} 0 & \text{if } 0 \leq x < a \\ 1 & \text{if } a \leq x < b \\ 2 & \text{if } b \leq x < c \\ 3 & \text{if } x \geq c \end{cases}$$



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



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

الشكل (2-2)


أنواع متعددة من دوال الفعالية المستخدمة في الشبكات العصبية الاصطناعية

فهناك شبكات عصبية تستخدم دوال خطية وهناك شبكات عصبية تستخدم دوال لاقطية ، والسؤال المهم هو : متى نستخدم دوال خطية او دوال لا خطية؟ والجواب ببساطة هو ان الدوال الخطية تستخدم عندما تمثل المشكلة التي نريد حلها بدالة خطية ، مثل مشكلة (بوابة – أو المنطقية) (OR-Gate) التي يمثل الجدول (1-2) قيمها والشكل (3-2) يظهر الرسم الذي يمثل جدولها .

جدول (1-2)


قيم (بوابة- أو المنطقية)

X1	X2	Y
0	0	0
0	1	1
1	0	1
1	1	1



ان نقاط قيم (بوابة أو المنطقية) قسمت الى قسمين حسب قيمها (صفر ، واحد) بخط مستقيم واحد وهذا يعني انها تمثل بدالة خطية .

اما مشكلة (بوابة -أو الخاصة المنطقية) (XOR-Gate) التي يمثل الجدول (2-2) قيمها والشكل (4-2) يظهر الرسم الذي يمثل جدولها ، نرى ان نقاط قيمها فصلت بأستخدام خطين مستقيمين ، وهذا يعني أنها تمثل بدالة لا خطية.



وبالطبع فان الغالبية الساحقة من المشاكل التي تُحل باستخدام تقنية الشبكات العصبية الاصطناعية هي مشاكل معقدة وبالتالي فهي مشاكل تحتاج الى دوال فعالية لا خطية. [7][1]

3-2 الية التعلم في الشبكات العصبية الاصطناعية

تعتبر عملية التعلم للشبكات العصبية هي الاساس في تحويل هذه الشبكات لأداء عمليات التعرف على الاشياء المختلفة والتي يتم بأستخدام اسلوب التعليم و التدريب (Training) للشبكة والتي تماثل عملية التعليم والتدريب التي تجري للأطفال لكي يتمكنوا من التعرف على الاشياء

فأذا فرضنا أن هناك شبكة عصبية وهذه الشبكة العصبية متصلة بألة تصوير وسوف يتم عرض مجموعتين من الالواح المكتوبة عليها حرف من الحروف. وأن هذه الحروف عبارة عن مجموعتان تمثل المجموعة الاولى الحرف (A) وتمثل المجموعة الثانية الحرف (B) ويراد تعليم الشبكة لكي تتعرف على هذه المجموعة وذلك بأن تقوم الشبكة بأعطاء مخرج يساوي 1 اذا وضع الحرف (A) اما الة التصوير وتعطي صفراً اذا كانت الصورة للحرف (B).

وبدراسة النموذج الحسابي للخلية العصبية نجد انه من المناسب ان نجعل العصبونة تتعلم من أخطاءها وذلك بأعطاءها في البداية اوزان عشوائية عند المدخل حيث تقوم العصبونة بأجراء عملية جمع الاوزان للمدخل ثم مقارنة المجموع بالقيم الحدية. فإذا كان المجموع اكبر من القيمة الحدية فأن المخرج يساوي 1 ويصبح التعرف على الحرف (A) ممكناً واذا كان المجموع اقل من القيمة الحدية فأن المخرج يكون صفر ولا يتم التعرف.

من المعروف احصائياً أن الفرصة سوف تكون 50% : 50% في عملية التعرف الاولى فإذا فرضنا ان المجموع للأوزان اقل من القيمة الحدية وبذلك لايعطي للمخرج 1 ويكون المطلوب تعليم النموذج مرة ثانية . وذلك بمحاولة زيادة الاوزان لكي يصبح مجموع الاوزان اكبر من القيمة الحدية ويكون المخرج 1. وتكرار العملية عدة مرات اخرى في اتجاه زيادة مجموعة الاوزان الى ان يتم الحصول على 1 في المخرج. وعلى العكس عند محاولة التعرف على الحرف (B) والتي تتطلب ان يكون المجموع للأوزان عند المدخل اقل من القيمة الحدية وبذلك نحصل على 0 عند المخرج والذي يمثل الحرف (B) ، فاذا كان المجموع اكبر من القيمة الحدية يلزم التدريب مرة ثانية في اتجاه تقليل الاوزان ويتم التدريب عدة مرات في هذا الاتجاه الى ان نحصل على 0 للمخرج والذي يعتبر التعريف الصحيح على الحرف (B)

هذا يعني اننا اذا اردنا ان نعلم احدى الشبكات العصبية فأننا نتبع الاتي :

1- زيادة الاوزان في المداخل النشطة (Active inputs) والتي تتطلب ان يكون المخرج نشطاً ايضاً (المخرج=1) ويجري تنفيذ ذلك بتقليل قيم المداخل الى الاوزان .

2- تقليل الاوزان في المداخل الغير نشطة (in active inputs) والتي تتطلب ان يكون المخرج غير نشطاً ايضاً (المخرج=0) ويجري تنفيذ ذلك بتقليل قيم المداخل في الاوزان .

وتعتبر مراحل التعلم للشبكة هو تنفيذ الخطوة الاولى فقط حيث ان الخطوة الثانية لا تؤثر على النتيجة ، ويعتبر دونالد هيب اول من وضع نظرية التعلم وذلك بتطوير نظام رياضي للتعلم للشبكات العصبية والذي يسمى التعليم الهيباني (Hebbian Learning) وتقول هذه النظرية ما يلي

تؤثر حالة النشاط السابق (Postsynaptic activity) للمشابك (Synapses) عند اعادة تنشيطها فتزداد كفاءة التوصيل او الشدة (Strength) لهذه المشابك اذا استقبلت نبضة جديدة ملاحقة لنبضة اخرى.

ويمكن تلخيص عملية التعليم للشبكة كما يلي:

- 1- الاختيار العشوائي (Random Selection) للأوزان (Weight) والقيم الحدية (Thershold)
- 2- ضع قيم للمداخل (Present inputs)
- 3- احسب المخرج الحقيقي (Actual) وذلك بطرح القيمة الحدية (Thershold) من المجموع الموزن للمداخل (Weighted Sum)
- 4- يتم تغيير الاوزان مرة اخرى في اتجاه التعرف (Correct Decisions) (اي الحصول على الواحد) وازعاف الاتجاه الاخير (in Correct Decisions) اي العمل على تقليل الخطأ (Error Reduction)
- 5- وضع قيم اخرى للمداخل وتكرار الخطوات السابقة.[2]

4-2 خواص وامكانيات الشبكة العصبية الاصطناعية

- 1- التوازي (Parallelism) أو التزامن في العمل : وهي ميزة اساسية من مزايا الشبكات العصبية الاصطناعية ، أي اذا عُدت كل خلية تمثل وحدة معالجة (Processor Element) بحد ذاتها مرتبطة بدورها بعدد كبير من وحدات المعالجة المماثلة لها فسوف يمكننا زيادة سرعة معالجة الحاسبة للأوامر بشكل هائل وهذا ما عملته شركات الحاسبات الكبرى التي انتجت حاسبات هائلة السرعة بأستخدام تقنية الشبكات العصبية الاصطناعية لتتمكن من حل المشاكل المعقدة جداً بوقت قياسي.
- 2- القابلية على التكيف (Adaptation): وهي خاصية مهمة جداً من خصائص الشبكات العصبية الاصطناعية ، اذ انها تقوم بحل المشكلة من خلال خوارزمية معينة لا من خلال برمجة المشكلة اي انها كيفت نفسها لحل المشكلة من خلال معطيات خاصة بالمشكلة. وبمعنى اخر لا توجد برمجة

حقيقية لحل المشكلة بل يوجد تطبيق لخوارزمية تعلم معينة وظيفتها التأقلم مع معطيات المشكلة و التكيف معها.

3- الذاكرة الموزعة (Distributed Memory): عندما تتعلم الشبكة العصبية الاصطناعية على معطيات المشكلة فانها بالتاكيد ستقوم بخزن المعطيات او الاحتفاظ بها بطريقتها الخاصة اي حسب قاعدة التعلم ،اي انها اصبحت تمثل ذاكرة حقيقية لمعطيات المشكلة موزعة حسب نوع الشبكة العصبية الاصطناعية . وهناك انواع من الشبكات العصبية الاصطناعية تستخدم لأغراض الخزن فقط أي تعمل مقام الذاكرة.

4- قابلية التعميم (Generalization): اذا دربت الشبكة العصبية الاصطناعية على مجموعة معينة من النماذج في تطبيق معين ، ومن ثم جرى اختبار هذه الشبكة على نماذج اخرى غير التي قد تدربت عليها وكانت نتائج الاختبار ناجحة أي ان الشبكة العصبية الاصطناعية تعرفت على النماذج الجديدة وهذا يعني انها قامت بتعميم القاعدة التي خرجت بها من خلال تدريبها على النماذج المعطاة ، على النماذج الجديدة وهذه خاصية مهمة جداً من خواص الشبكات العصبية الاصطناعية . وبمعنى اخر فأنها الغت مفهوم قاعدة "اذا....فإن..." أي (If ...Then) من خلال خاصية التعميم.

5- تحمل الخطأ (Fault Tolerance): كما معروف فإن معمارية Von Neumann تعتمد على التنفيذ التسلسلي للعمليات (Sequential Processing) اي ان الاخطاء التي تحدث في ايعازات (خطوات) البرنامج تؤثر على ما بعدها من اليعازات ، بينما في معمارية الشبكات العصبية الاصطناعية الحال يختلف تماماً، فبإمكان لهذا النوع من المعمارية ان يتحمل الاخطاء التي تحدث في مدخلاته ويقوم بتصحيحها او ما شابه ذلك بحيث انها لن تؤثر على عمل الشبكة العصبية الاصطناعية ، كذلك بالنسبة لبرامجيات حلول المشاكل باستخدام تقنية الشبكات العصبية الاصطناعية .

6- تعريف المشكلة: كما عرفنا بأن اساس عمل الشبكات العصبية الاصطناعية هو التعلم على مجموعة من نماذج مدخلات او حالات المشكلة من خلال خوارزميات معينة ، وبالتالي تم تجاوز فقرة تعريف المشكلة وما له علاقة بذلك في حالات البرمجة التقليدية لحل المشكلة ، وهذا الشيء مهم جداً في كثير من التطبيقات اذ ان من الصعب فهم الية تعريف المشكلة.

7- حل المشاكل ذات البيانات المشوشة (Noisy Data): باستخدام تقنية الشبكات العصبية الاصطناعية يمكن التعامل مع البيانات المشوشة ونقصد بذلك مثلاً البيانات التي تكون بعض قيمها غير حقيقية (ناتجة من خطأ معين او اهمال ما) وبيانات غير كاملة (ربما تكون مفقودة القيمة) وهذه الخاصية ناتجة من خاصية تحمل الخطأ الانفة الذكر.

8- سهولة البناء والتعلم: كما سنرى لاحقاً فإن بناء وبرمجة وتعلم الشبكات العصبية الاصطناعية يتم بصورة غير معقدة في كثير من الاحيان بسبب قياسية (Standard) خوارزميتها وقواعد تعلمها وهذا ما جعل هذه التقنية مرغوبة في حل الكثر من المشاكل البسيطة منها والمعقدة. [1]

5-2 التعميم والتقريب وحساب نسبة الخطا

كما ورد ذكره في خواص الشبكات العصبية الاصطناعية ، فإن خاصية التعميم تعد من الخواص المهمة ، فأدُرِبت أو جرى تعليم الشبكة على مجموعة من نماذج التطبيق التي بصدد حلها ، تقوم الشبكة العصبية الاصطناعية بتعميم الحل على النماذج جديدة لم تتعلم عليها من قبل فهذا يعني ان الشبكة عممت الحالة على باقي النماذج وهذا شيء مهم جداً ومفيد لعدة اسباب منها:

1- تقليل عدد نماذج التطبيق في مرحلة التعلم (وأحياناً لايمكن الحصول على عدة نماذج بسهولة).

2- ينتج من تقليل عدد نماذج التطبيق، تقليل الوقت المستغرق في عملية التعلم.

3- التعميم الشديد يعني ان الشبكة العصبية الاصطناعية ناجحة في التعليم ونستطيع القول بانها ذكية (لأن الشخص الذي يتعلم من خلال نماذج قليلة في وقت قليل نقول عنه انه شخص ذكي).

4- اذا عدنا الى خاصية الذاكرة الموزعة، فإن خاصية التعميم تؤدي الى تقليل الذاكرة مع الحفاظ على نفس مستوى الاداء.

5- التعميم يزيد من نجاح العديد من خواص الشبكات العصبية الاصطناعية مثل التعامل مع البيانات المشوشة و تحمل الاخطاء.

ولتوضيح خاصية التعميم بشكل ادق ، نفترض ان لدينا شبكة عصبية اصطناعية نريدها ان تتعلم على تمييز نماذج من حرف معين في اللغة الانكليزية وليكن حرف (G) فنعطيهما ثلاثة نماذج مثلاً ، كما موضح في الشكل (5-2)





والان بعد أن ننجز تعليم الشبكة العصبية الاصطناعية التي سنختارها لهذا الغرض، ستختبر الشبكة العصبية الاصطناعية على عدة نماذج ولنأخذ مثلاً الأحرف التي في الشكل (6-2)




6 نماذج مختلفة من حرف G لغرض الاختبار

فكما نرى في الشكل (6-2) هناك نماذج ليست غريبة عن تلك التي تعلم عليها وهناك نماذج جديدة وغريبة ، فأذا نجحت الشبكة العصبية الاصطناعية في التعرف على كل النماذج أو أغلبها في الأقل فنستطيع الاعتراف بنجاح خاصية التعميم لأنها عممت القاعدة على النماذج التي لم تتعلم عليها. ولكن بالتأكيد تقل أهمية خاصية التعميم مع زيادة عدد نماذج التعلم أي ان العلاقة بين عدد نماذج التعلم والتعميم علاقة عكسية. اما نسبة اداء الشبكة العصبية الاصطناعية فيزداد عدد نماذج التعلم ، وهذه نتيجة طبيعية لأن التعلم مرهون بعدد النماذج التي يعتمد عليها المتلقي ، اذا فالعلاقة بين عدد نماذج التعلم والاداء علاقة طردية والشكل (7-2) يوضح علاقة التعميم والاداء مع عدد نماذج

ان زيادة عدد نماذج التعلم لا يضر التعميم فحسب إنما أحياناً حتى ادائها، أذ ان زيادة عدد نماذج التعلم تؤدي الى حالة الاشباع (Saturation) داخل الشبكة العصبية الاصطناعية من خلال حالات التشابه التي تظهر بين نماذج الحالات المختلفة. ولتوضيح ذلك لفترض أننا نريد أن نعلم الشبكة العصبية الاصطناعية على تمييز نماذج من حرفين في اللغة الانكليزية وهما (C,G) فسنهئ 6 نماذج من كل حرف وكما مبين في الشكل (8-2)



نلاحظ من الشكل (8-2) ان زيادة عدد نماذج أشكال الحرف سيؤدي الى زيادة حالات التشابه بين الحرفين وبالتالي تحدث حالة الاشتباه أو الاضطراب في الشبكة العصبية الاصطناعية اذ انها لن تستطيع التمييز بين حرفي (C, G) هذا ما نسميه بحالة الاشباع أي ان الشبكة العصبية الاصطناعية مشبعة بالنماذج بحيث انها لا تستطيع التمييز بينها ، لذا يجب اخذ الحذر كل الحذر عند اختيار النماذج للتعلم علاوة على الحذر في اختيار عدد تلك النماذج. والشكل (9-2) يوضح العلاقة بين مجموعتين من النماذج لحرفي (C,G)



نلاحظ من الشكل (2-9) أن مجموعتي أحرف (G,C) كلما كبرت كبرت معهما مجموعة تقاطعهما نتيجة زيادة حالات التشابه.

نأتي الان الى ما يصطلح عليه بالتقريب (Convergence) والمقصود به هنا كيفية تحديد وصول قيم الشبكة العصبية الاصطناعية على القيم التي يريدتها التطبيق. هناك طريقتان للتوصل الى نقطة التوقف ، اي النقطة التي نقول عندها ان الشبكة العصبية الاصطناعية قد تعلمت، وهما:

1- طريقة فحص قيمة مقابل قيمة.

2- طريقة الجذر التربيعي لمعدل الخطأ (Root Square Mean Error)

(الطريقتان أعلاه الأكثر شيوعاً وتوجد طرائق أخرى ولكن أقل استخداماً)

ومن المؤكد وكما قلنا سابقاً ، ، لا يمكن الوصول الى تعلم مثاليا جدا اي 100% بالتأكيد ستكون هناك نسبة خطأ معينة ، والان كم هي نسبة الخطأ؟ هذا يتحدد طبقاً لعدة عوامل ابرزها:

1- طبيعة التطبيق الذي يعالج ، فهناك تطبيقات تتحمل نسبة خطأ متوسطة وهناك تطبيقات لا تتحمل سوى نسبة ضئيلة جداً، أذن طبيعة التطبيق ومجاله يلعبان دوراً مهماً في عملية تحديد نسبة الخطأ المسموح بها في الشبكة العصبية الاصطناعية.

2- طبيعية نماذج التطبيق المعطاة فلربما تكون النماذج جيدة فنصل الى نسبة خطأ قليل جداً وربما تكون نماذج رديئة فلا يمكننا الوصول الى نسبة الخطأ المطلوبة.

3- نوع الشبكة العصبية الاصطناعية المستخدمة في عملية التعلم.

4- قاعدة التعلم التي تعمل على الية التعلم.

5- معدل التعلم المعتمد في قاعدة التعلم.

والان لناخذ المثال التالي لبيان الفرق بين طريقتي حساب الانفتي الذكر . الجدول (3-2) يبين القيم المطلوبة والقيم الفعلية اي تلك التي حصلت عليها الشبكة العصبية الاصطناعية ، وعلى افتراض ان نسبة الخطأ المسموح بها هي (0.1)

جدول (3-2)

قيم افتراضية لحساب نسبة الخطأ

القيم الفعلية للشبكة O(i)	القيم المطلوبة Y(i)
0.9	1
0.2	0
0.98	1
0.95	1
0.01	0

ووفق الطريقة الاولى أي مقارنة قيمة بقيمة نجد أن القيمة الثانية التي هي (0) والتي حصلت عليها الشبكة هي (0.2) هي اكبر من قيمة الخطأ التي حددت وهي (0,1) بينما باقي القيم مسموحة لكونها تساوي أو أقل من نسبة الخطأ المسموحة . بينما وفق الطريقة الثانية تحسب نسبة الخطأ وفق المعادلة الاتية:

$$Error = \sqrt{(Y(i) - O(i))^2}$$

بهذه الطريقة التي تعد الاكثر شيوعاً على الاطلاق يمكن ان نتجاوز المشكلة التي حصلت في الطريقة الاولى وكذلك يمكن تقليل نسبة الخطأ المطلوبة في الشبكات العصبية الاصطناعية . وهذه

الطريقة تعتمد على مبدأ هو أن القيمة القريبة جداً من المطلوب يمكن أن تتجاوز أو تساعد القيمة التي تُعد بعيدة عن المطلوب.[1]

6-2 تطبيقات الشبكات العصبية الاصطناعية واستخداماتها المختلفة

للشبكات العصبية الاصطناعية تطبيقات كثيرة ومتنوعة وفي مجالات مختلفة للاستفادة من الامكانيات الهائلة التي توفرها؛ حيث تستخدم في التعرف على الاشكال "الانماط" (Pattern Recognition) ، ويتم استخدام ذلك في عدة تطبيقات مثل التعرف على الوجود او الصور والتعرف على الكلام وفهم اللغات الطبيعية (الحية) وتشخيص الامراض ، كما تستخدم في حل المسائل الرياضية والفيزيائية المعقدة والتي لا يمكن حلها بالطرق العادية ، وايضاً تستخدم في التنبؤ بسلوك العناصر في بيئة محددة والتحكم الالي (التكيف الالي في الروبوتات)؛ ومختلف ذلك من التطبيقات التي لا يمكن حصرها .

ومن امثلة التطبيقات العملية :

1-نظام NeT TALK: الذي يقوم بتحويل الكلام المكتوب الى كلام منطوق بأستخدام الشبكات العصبية وتم تدريبها لفترة اسبوعين فقط، وبعد انتهاء الفترة التدريبية تجاوز مستوى اداء الشبكة نسبة 90% وقد تم تصميم هذا النظام عام 1987 م وفي جامعة هوبنكر الامريكية.

2-نظام DESKNET : وهو نظام شبكات عصبية لتشخيص الامراض الجلدية المختلفة بدقة ممتازة (عشرة امراض جلدية مختلفة).

3-نظام DARPA : ويستخدم في الولايات المتحدة للتعرف على الاشكال التي يتم التقاطها (تصويرها) بواسطة الاقمار الاصطناعية. حيث يتم تدريب الشبكة على الاشكال المختلفة للاهداف المحتملة بحيث تتمكن بعد ذلك من التعرف عليها عن النقاط صوراً لها بواسطة القمر حتى وان كانت هذه الصور ناقصة او غير واضحة.

4-انظمة التحليل المالي التي تقوم بالتنبؤ بأسعار السلع وحركة السوق في المستقبل القريب بعد تغذيتها بالاسعار السابقة وكل المؤشرات المالية والتسويقية الاخرى ، وقد اثبتت هذه الانظمة جدواها الاقتصادية الفائضة بما وفرته لمستخدميها من اموال كان من المحتمل خسارتها لولا التوقعات الصحيحة التي قدمتها.[3]

7-2 تصنيفات الشبكات العصبية الاصطناعية

فيما يخص تصنيفات الشبكات العصبية الاصطناعية ، فإن هذا الموضوع كثر فيه الاخذ والرد وتباينت فيه الاراء حول الطريقة المثلى لتصنيف أنواع الشبكات العصبية الاصطناعية

ولكن سنسرد أهم الطرائق التي صُنفت الشبكات على اساسها وكما يلي:

- طريقة التعلم: هناك 4 انواع رئيسية للتعلم هي: التعلم بوجود مشرف (Supervised) ، التعلم بغير مشرف (Unsupervised)، تعلم ذاتي التنظيم (Self-Organization)، التعلم التعزيزي (Reinforcement)، ولكل نوع خصائصه وعلى اساس هذه الانواع تُصنف أنواع الشبكات العصبية الاصطناعية وخوارزمياتها ، فكل نوع من انواع التعلم شبكات عصبية تسلك سلوكه، وفي اعتقادنا أن هذا النوع يُعد من افضل انواع التصنيفات لانه يعكس النظرة الحقيقية والواقعية لسلوك أداء الشبكات العصبية الاصطناعية.
- عدد الطبقات (Layers): في هذا النوع يتم التصنيف على اساس عدد طبقات الشبكة العصبية الاصطناعية، فهناك شبكة ذات طبقة واحدة وهناك شبكات تملك عدة طبقات متصلة فيما بينها. هو تصنيف جيد ولكن هناك شبكات العصبية الاصطناعية لاينعكس فيها العدد الحقيقي للطبقات أو قد تعتمد على مفهوم الطبقات.
- المعالجة الامامية (Feed Forward) والتغذية الخلفية (Feedback): يتم التصنيف على اساس هاتين الميزتين ، فهناك من الشبكات العصبية الاصطناعية من يستعمل المعالجة الامامية فقط وهناك من يستخدم معها التغذية الخلفية.
- دوال الفعالية : يوجد نوعان من دوال الفعالية (خطي ولاخطي) وهناك انواع من الشبكة العصبية الاصطناعية تستخدم النوعين وهناك أنواع تستخدم نوع واحد وعلى هذا الاساس يتم التصنيف.
- طبيعة المدخلات والمخرجات: توجد أنواع الشبكات العصبية الاصطناعية تستخدم المدخلات والمخرجات المتقطعة (Discrete) وهناك التي تستخدم البيانات المستمرة (Continuous) وهناك من يستخدم الطريقتين.[1]

الفصل الثالث

1-3 طرق تعليم الشبكات العصبية الاصطناعية

ان التعلم في الشبكات العصبية الاصطناعية يكون على نوعين هما:

١- تعلم بوجود مشرف (Supervised).

٢- تعلم بغياب مشرف (Unsupervised).

يستند النوع الاول (بوجود مشرف) الى معطيات المشكلة والمتضمنة مدخلات ومخرجات (Inputs/Outputs)، فهنا تتم عملية التعلم عندما تتعلم الشبكة العصبية على مدخلات ومخرجات المشكلة. أما النوع الثاني (غياب المشرف) فيستند الى مدخلات المشكلة فقط (Input) والشبكة هنا تتعلم عندما تصل أوزانها الى حالة الاستقرار (Stability)، وهذا النوع بدوره يقسم الى نوعين هما:

أ- التعلم التدريجي (Graded Training): ولكن نجد ان الغالبية يسمونه بتسمية الاصل أي تعلم بغياب المشرف (Unsupervised).

ب- التنظيم الذاتي (Self-Organization): وهنا تضاف مهام اخرى الى خوارزميات تتعلق بتصنيف او توزيع النماذج المعطاة تصنيفاً ذاتياً أي بدون تدخل ذوي العلاقة من اختصاصي التطبيق أو مطوري الانظمة.

وعلى العموم فان لكل نوع من الانواع أعلاه طرائقه وخوارزمياته الخاصة، وكذلك لكل نوع قاعدة تعلم خاصة به. وهناك قواعد للتعلم معتمدة في اكثر من طريقة او خوارزمية ونرى من المهم هنا أن نعطي أهم قواعد التعلم المعتمدة في الشبكات العصبية الاصطناعية على اختلاف انواعها. وفيما يلي اولاً المعاملات الخاصة بقواعد التعلم:

$X(i)$: المدخلات (Inputs).

$Y(i)$: المخرجات الاصلية (Target Output).

$O(i)$: المخرجات الفعلية (Actual Output).

$W(i,j)$: قيمة الوزن الحالي للمدخل الى الخلية العصبية (Current Weight).

$\Delta W(i,j)$: قيمة الوزن الجديد (المعدل) للمدخل الى الخلية العصبية (New Weight).

(j) δ نسبة الخطأ أي بين القيمة المطلوبة والقيمة الفعلية للخلاية العصبية

η : قيمة نسبة التعلم في القاعدة.

α : قيمة التعجيل في القاعدة.

والان فيما يلي اهم الانواع قواعد التعلم في الشبكات العصبية الاصطناعية على اختلاف أنواعها:

١- قاعدة Hebb بدون مشرف: $\Delta W(i, j) = \eta X(i)O(i)$

٢- قاعدة Widrow-Hoff بوجود مشرف: $\Delta W(i, j) = \eta[Y(i) - o(i)]x(i)$

ان هذه القواعد أساس التعلم في الشبكات العصبية الاصطناعية وبالتالي فهي أساس عمل الشبكات العصبية الاصطناعية لذا يجب تطبيقها بحذر لأنها مشتقة اشتقاقاً دقيقاً، لن نتطرق الى اشتقاقها لأنها موضوعاً قائماً بحد ذاته. [1][4]

٢-٣ الشبكات العصبية الاصطناعية من دون مشرف عليها (Unsupervised)

Neural Networks)

أن التعلم بعدم وجود مشرف (Unsupervised) يعني ان هناك مدخلات للمشكلة وأن توجد مخرجات معلومة ، وبالتالي لا يكون هناك تصحيح للمخرجات أو مقارنة مع مخرجات مطلوبة، وبالتالي تكون هذه الطرائق أسرع وأكفأ من غيرها ، ولكن على الجانب الآخر لايمكنها حل جميع المشاكل التي تحتاج الى تقنية الشبكات العصبية الاصطناعية . ويجب ان تكون النماذج معروفة الاصناف (مجازاً وليس فعلاً) في هذا النوع من التعلم. ومن أشهر أنواع الشبكات العصبية التي لا تستخدم مشرفاً في عملها هي شبكة (HopField) وشبكة الذاكرة المرتبطة الثنائية (BAM) سنستخدم في بحثنا شبكة (HopField) لتمييز الحروف الانكليزية. [6]

3-3 شبكة (Hopfield) العصبية الاصطناعية

سميت بهذا الاسم نسبة الى مطور هذه الخوارزمية العالم (John Hopfield) وهو عالم فيزياء حاصل على جائزة نوبل في العلوم ، وقد طور هذه الخوارزمية بين عامي (1984-1982) وتتصف هذه الشبكة بالموصفات الاتية:

- ١- ذاكرة تجميعية (Associative).
- ٢- ثنائية التعامل (Bidirectional)
- ٣- اتصال كامل (Full Connection).
- ٤- ذات تغذية خلفية (Feedback).
- ٥- الاوزان الثابتة (Fixed Weights).
- ٦- حل مشاكل معقدة باستخدام دوال خطية (Linear Function).

والشكل (٢-٢-أ) يمثل هيكلية شبكة Hopfield العصبية الاصطناعية . وفيما يلي خطوات عمل هذه الخوارزمية:

- ١- تهيئة المدخلات بطول (N) وبعده نماذج (P).
- ٢- تحويل كل 0 الى 1- في مصفوفة المدخلات.
- ٣- تهيئة دالة الفعالية التي غالباً ما تكون الدالة الاتية:

$$f(x) = \begin{cases} 1 & \text{if } x > 0 \\ -1 & \text{if } x \leq 0 \end{cases}$$

- ٤- استخراج مصفوفة الاوزان للمدخلات وفق المعادلة التالية:

$$W_{i,j} = \begin{cases} 0 & \text{if } i = j \\ \sum_{i=1}^p X_i X_i & \text{otherwise} \end{cases} \text{ where } i, j = 1, 2, \dots, N$$

نلاحظ ان مصفوفة الاوزان مصفوفة مربعة (N*N) ومن النوع المتناظر (Symmetric) أي ان المثلث الاعلى يساوي المثلث الاسفل وجميع عناصر القطر (Diagonal) مساوية للصفر. فيما يخص مرحلة الاختبار أو التشغيل الفعلي لشبكة (Hopfield) فتتضمن الخطوات الاتية:

- ١- الحصول على النموذج المراد التعرف عليه ، ولابد أن يكون متوافقاً مع حجم البيانات التي تدربت عليها الشبكة أي طول النموذج N وتحول الاصفار فيه الى 1- كما سبق.
 - ٢- ضرب نموذج مصفوفة الاوزان نموذج المدخلات (الذي نريد التعرف عليه) ثم ادخال الناتج الى دالة الفاعلية ، وتكرر هذه الخطوة (اي الخطوة 2) الى ان يتم الحصول على ناتج متكرر ضمن سلسلة التنفيذات ، بمعنى الى ان تستقر حالة المخرجات.
- عادة تخبر عدة نماذج لبيان مستوى التعلم الحالي فاذا كانت النتائج مرضية نتوقف ونعتمد مصفوفة الاوزان الحالية ، واذا لم تكن مرضية فيتم الاعداد من الخطوة الاولى مع زيادة (و ، أو) تغيير نماذج التعلم لتصبح أكثر شمولية وفعالية. [1]

مثال توضيحي

لفترض ان لدينا 3 نماذج من البيانات وطول كل نموذج 4 وكما يلي:

$$\begin{pmatrix} 1 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 \end{pmatrix}$$

وبعد تحويل الاصفار الى 1- تصبح المصفوفة كما يلي:

$$\begin{pmatrix} 1 & 1 & 1 & -1 \\ -1 & -1 & -1 & -1 \\ 1 & 1 & -1 & -1 \end{pmatrix}$$

وبعد تطبيق معادلة استخراج مصفوفة الاوزان المذكورة أعلاه (أي ضرب عمود i في عمود j وجمع نواتج الضرب وتصبح هي قيمة العنصر $W_{i,j}$ اذا كان $i \neq j$ وبخلافه فأن قيمة $W_{i,j}$ تساوي صفراً حسب المعادلة المذكورة) وبالتالي تكون قيم مصفوفة الاوزان كما يلي:

$$W_{1,2} = 1 * 1 + -1 * -1 + 1 * 1 = 3 = W_{2,1}$$

$$W_{1,3} = 1 * 1 + -1 * -1 + 1 * -1 = 1 = W_{3,1}$$

$$W_{1,4} = 1 * -1 + -1 * -1 + 1 * -1 = -1 = W_{4,1}$$

$$W_{2,3} = 1 * 1 + -1 * -1 + 1 * -1 = 1 = W_{3,2}$$

$$W_{2,4} = 1 * -1 + -1 * -1 + 1 * -1 = -1 = W_{4,2}$$

$$W_{3,4} = 1 * -1 + -1 * -1 + -1 * -1 = 1 = W_{4,3}$$

هذه نتائج المثلث الاعلى ونفس القيم للمثلث الاسفل كما قلنا لان المصفوفة متناظرة ، فتصبح مصفوفة الاوزان للنماذج أعلاه هي:

$$W = \begin{pmatrix} 0 & 3 & 1 & -1 \\ 3 & 0 & 1 & -1 \\ 1 & 1 & 0 & 1 \\ -1 & -1 & 1 & 0 \end{pmatrix}$$

الى هنا انتهت مرحلة التعليم، ونأتي الان الى مرحلة الاختبار ولنأخذ مثلاً النموذج الاتي:

$$\begin{pmatrix} 1 & 1 & 1 & 1 \end{pmatrix}$$

وبعد تحويل كل صفر الى 1- نقوم بتطبيق المعادلة التالية لاستخراج قيم المخرجات

$$O_i = f(Z_i + \sum_{j=1}^J Z_j * W_{i,j}) \text{ where } i, j = 1, 2, \dots, N$$

وتمثل f دالة الفعالية ، وتكون النتائج هي:

$$O_1 = f(1 + (1 * 0 + 1 * 3 + 1 * 1 + 1 * -1)) = f(4) = 1$$

$$O_2 = f(1 + (1 * 3 + 1 * 0 + 1 * 1 + 1 * -1)) = f(4) = 1$$

$$O_3 = f(1 + (1 * 1 + 1 * 1 + 1 * 0 + 1 * 1)) = f(4) = 1$$

$$O_4 = f(1 + (1 * -1 + 1 * -1 + 1 * 1 + 1 * 0)) = f(0) = -1$$

1 1 1 -1

اذن ناتج الاختبار (1111) هو (111-1) او بمعنى اخر (0111) ثم نعيد ضرب هذا الناتج كما سبق؛

$$O_1 = f(1 + (1 * 0 + 1 * 3 + 1 * 1 + -1 * -1)) = f(6) = 1$$

$$O_2 = f(1 + (1 * 3 + 1 * 0 + 1 * 1 + -1 * -1)) = f(6) = 1$$

$$O_3 = f(1 + (1 * 1 + 1 * 1 + 1 * 0 + 1 * 1)) = f(6) = 1$$

$$O_4 = f(0 + (1 + -1 + 1 * -1 + 1 * 1 + -1 * 0)) = f(-1) = -1$$

111-1

اذن ناتج اختبار (111-1) هو (111-1) أي حصلت استقرارية بالمخرجات ، وهنا نتوقف ، ونتبين ان الحل منطقي لان اقرب نموذج الى () هو () من النماذج الثلاثة المعطاة . وهنا نستطيع القول ان الشبكة تعلمت على النموذج الجديد الذي لم يتعلمه سابقا ولكنها تعرفت على ماهو اقرب اليه. ولو لم تتعرف الشبكة على النموذج الجديد لقلنا انها لم تتعلم من النماذج السابقة ولاعدنا التدريب من خلال زيلدة اعداد النماذج واستخراج الوزن من جديد والاختبار من جديد. [١]

مثال تطبيقي

لنفترض اننا نريد ان نعمل شبكة عصبية اصطناعية من نوع (Hopfield) نتعرف على اشكال حروف اللغة الانكليزية مثلا، ولتكن في بادئ الامر ٣ احرف هي :

على أشكال حروف اللغة الانكليزية مثلاً، ولتكن في بادئ الامر 3 أحرف هي:

A C L

نقوم أولاً بتحويل بتمثيل هذه الاحرف على شكل مصفوفة ثنائية الأرقام (وكانها مصفوفة رسمها) ولتكن على سبيل ذات ابعاد (5x5)، وتكون مصفوفات الاحرف الثلاثة

كما يلي:

0 0 1 0 0	1 1 1 1 1	1 0 0 0 0
0 1 0 1 0	1 0 0 0 0	1 0 0 0 0
1 0 0 0 1	1 0 0 0 0	1 0 0 0 0
1 1 1 1 1	1 0 0 0 0	1 0 0 0 0
1 0 0 0 1	1 1 1 1 1	1 1 1 1 1

ثم نقوم بتحويل كل صفر إلى 1- فتصبح مصفوفات الاحرف الثلاثة كما يلي :

-1 -1 1 -1 -1	1 1 1 1 1	1 -1 -1 -1 -1
-1 1 -1 1 -1	1 -1 -1 -1 -1	1 -1 -1 -1 -1
1 -1 -1 -1 1	1 -1 -1 -1 -1	1 -1 -1 -1 -1
1 1 1 1 1	1 -1 -1 -1 -1	1 -1 -1 -1 -1
1 -1 -1 -1 1	1 1 1 1 1	1 1 1 1 1

ثم نقوم برص قيم كل مصفوفة على سطر واحد (أي تحويلها من ثنائية الابعاد إلى

بعد واحد) وكما يلي:

A: -1,-1,1,-1,-1,1,-1,1,-1,1,-1,1,-1,1,1,1,1,1,-1,-1,1,1

C: 1,1,1,1,1,-1,-1,-1,-1,1,-1,-1,-1,1,-1,-1,-1,1,1,1,1,1

L: 1,-1,-1,-1,-1,1,-1,-1,-1,-1,1,-1,-1,-1,1,-1,-1,-1,1,1,1,1,1

ثم نقوم بحساب مصفوفة الاوزان للقيم أعلاه والتي ستكون ذات بُعد (25x25)


وكما يلي:

0 1 -1 1 1 3 -3 -1 -3 -1 1 -1 -1 -1 -3 1 -3 -3 -3 -3 1 3 3 3 1

1 0 1 3 3 1 -1 1 -1 1 -1 1 1 1 -1 -1 -1 -1 -1 1 1 1 -1
 -1 1 0 1 1 -1 1 -1 1 -1 1 -1 -1 1 1 1 1 1 1 -1 -1 -1 1
 1 3 1 0 3 1 -1 1 -1 1 -1 1 1 1 -1 -1 -1 -1 -1 -1 1 1 1 -1
 1 3 1 3 0 1 -1 1 -1 1 -1 1 1 1 -1 -1 -1 -1 -1 -1 1 1 1 -1
 3 1 -1 1 1 0 -3 -1 -3 -1 1 -1 -1 -1 -3 1 -3 -3 -3 -3 1 3 3 3 1
 -3 -1 1 -1 -1 -3 0 1 3 1 -1 1 1 1 3 -1 3 3 3 3 -1 -3 -3 -3 -1
 -1 1 -1 1 1 -1 1 0 1 3 -3 3 3 3 1 -3 1 1 1 1 -3 -1 -1 -1 -3
 -3 -1 1 -1 -1 -3 3 1 0 1 -1 1 1 1 3 -1 3 3 3 3 -1 -3 -3 -3 -1
 -1 1 -1 1 1 -1 1 3 1 0 -3 3 3 3 1 -3 1 1 1 1 -3 -1 -1 -1 -3
 1 -1 1 -1 -1 1 -1 -3 -1 -3 0 -3 -3 -3 -1 3 -1 -1 -1 -1 3 1 1 1 3
 -1 1 -1 1 1 -1 1 3 1 3 -3 0 3 3 1 -3 1 1 1 1 -3 -1 -1 -1 -3
 -1 1 -1 1 1 -1 1 3 1 3 -3 3 0 3 1 -3 1 1 1 1 -3 -1 -1 -1 -3
 -1 1 -1 1 1 -1 1 3 1 3 -3 3 3 0 1 -3 1 1 1 1 -3 -1 -1 -1 -3
 -3 -1 1 -1 -1 -3 3 1 3 1 -1 1 1 1 0 -1 3 3 3 3 -1 -3 -3 -3 -1
 1 -1 1 -1 -1 1 -1 -3 -1 -3 3 -3 -3 -3 -1 0 -1 -1 -1 -1 3 1 1 1 3
 -3 -1 1 -1 -1 -3 3 1 3 1 -1 1 1 1 3 -1 0 3 3 3 -1 -3 -3 -3 -1
 -3 -1 1 -1 -1 -3 3 1 3 1 -1 1 1 1 3 -1 3 0 3 3 -1 -3 -3 -3 -1
 -3 -1 1 -1 -1 -3 3 1 3 1 -1 1 1 1 3 -1 3 3 0 3 -1 -3 -3 -3 -1
 -3 -1 1 -1 -1 -3 3 1 3 1 -1 1 1 1 3 -1 3 3 3 0 -1 -3 -3 -3 -1
 1 -1 1 -1 -1 1 -1 -3 -1 -3 3 -3 -3 -3 -1 3 -1 -1 -1 -1 0 1 1 1 3
 3 1 -1 1 1 3 -3 -1 -3 -1 1 -1 -1 -1 -3 1 -3 -3 -3 -3 1 0 3 3 1
 3 1 -1 1 1 3 -3 -1 -3 -1 1 -1 -1 -1 -3 1 -3 -3 -3 -3 1 3 0 3 1
 3 1 -1 1 1 3 -3 -1 -3 -1 1 -1 -1 -1 -3 1 -3 -3 -3 -3 1 3 3 0 1
 1 -1 1 -1 -1 1 -1 -3 -1 -3 3 -3 -3 -3 -1 3 -1 -1 -1 -1 3 1 1 1 0

وعند اختبار الشبكة ذات الاوزان اعلاه وفق الطريقة المبينة في المثال السابق تبين ان هناك تعلم
 جديد فيما يخص التعرف على الاحرف الثلاثة التي تدربت عليها الشبكة، والشكل (٣-١) يوضح
 بعض الامثلة التي اختبرت على الشبكة ونتائجها

وعند اختيار الشبكة ذات الاوزان اعلاه وفق الطريقة الميينة في المثال السابق نبين أن هناك تعلم جيد فيما يخص للتعرف على الاحرف الثلاثة التي تدربت عليها الشبكة ، والشكل (1,3) يوضح بعض الامثلة التي اختبرت على الشبكة ونتائجها.



الشكل (1-3)

Hopfield

ومن خلال التجارب والتطبيقات التي استخدمت شبكة (*Hopfield*) فيها توصل الباحثون الى وجود علاقة بين عدد العقد في هذه الشبكة وعدد النماذج المستخدمة للتعلم، يفضل الا يتجاوز عدد النماذج مرة ونصف عدد العقد لكي تضمن أفضل أداء لشبكة (*Hopfield*) وهذا الرقم ليس قاعدة إنما لأجل الوصول الى افضل أداء من ناحية التعلم واختبار النماذج الجديدة.