

المبحث الثاني

الشبكات العصبية الاصطناعية

2-13 نظرة تاريخية الشبكات العصبية الاصطناعية

History of Artificial Neural Network (ANN)

إن دراسة العقل البشري عمرها آلاف السنين ومع ظهور أول حلول التقنيات الإلكترونية الحديثة، نجد أن أولى المحاولات كانت تنصب في كيفية ربط عملية التفكير هذه. لكن الخطوة الأولى باتجاه الشبكات العصبية الاصطناعية جاءت في عام 1943 عندما قدم عالم الأعصاب الفيزيائي McCulloch مع عالم الرياضيات Walter Pitts بحثاً حول عمل العصبونات، حيث أنهما نمذجا أول شبكة عصبية مع دوائر إلكترونية. وقد تعزز هذا المفهوم حول العصبونات وكيفية عملها من خلال الكتاب الذي كتبه Donald Hebb (منظمة السلوك Organization of Behavior) في عام 1949، حيث ركز الكتاب على طرق ومسارات الأعصاب تتفاعل وتتنبه في كل مرة تستخدم فيه (Anderson & McNeil, 1992). بمعنى آخر أنه إذا تم تنشيط عصبونين معاً، فإن قوة الترابط بينهما سوف تزداد. كل ذلك دفع العلماء للربح في فهم الدماغ البشري ومحاكاة جزء من قوته بحالة بدائية متمثلة باستخدام الوسائل والأساليب الذكية لتطوير شبكات عصبية اصطناعية (Artificial Neural Networks ANN) لها القدرة على التعلم بشكل سريع وتتعامل مع أنماط لبيانات خاطئة في العديد من المجالات التطبيقية ومعالجة هذه البيانات للوصول إلى أنموذج لهذه البيانات لأغراض التحليل أو التصنيف أو التكهّن أو أية معالجة أخرى دون الحاجة إلى أنموذج رياضي مقترح لهذه البيانات. (Koskivaara, 2004). بداية الشبكات العصبية كانت بسيطة متمثلة بطبقة واحدة (Single Layer) من الخلايا العصبية الاصطناعية التي يتم تعليمها، أطلق عليها خلية الإدراك الحسي (Perceptrons)، افترضها الباحث (Frank Roseblatt) عام 1958 وكانت عملية التعلم فيها مقتصرة على النماذج الخطية (Linear Models) لأغراض التقدير أو التصنيف أو التبويب أو التكهّن، لهذا قلّ الاهتمام بدراسة الشبكات العصبية لسنوات عدة إلى إن تم التوصل إلى شكل جديد للإدراك الحسي بإضافة مستوى جديد أطلق عليه المستوى المخفي (Hidden Level)، اكسب الإدراك الحسي القدرة على حساب الدوال والعلاقات لنماذج البيانات

الخطية واللاخطية، وتطور هذا المستوى بإضافة أوزان تربط بين مستوى الإدخال و المستوى المخفي من قبل العالم (Priddy & Keller, 2005) حيث لم يُنر هذا التطور اهتمام الباحثين في حقل الشبكات العصبية الاصطناعية إلا في منتصف الثمانينات بعد استخدام خوارزمية الانتشار الخلفي للخطأ (Back propagation Error) كي يساعد الشبكات متعددة الطبقات على التعلم ، من هنا بدأ الاهتمام العام بالشبكات العصبية، فهي غير قادرة على إنجاز المعجزات ولكنها تمتلك خصائص مبهرة ومقدرة عالية على تجاوز قيود الأساليب التقليدية في حل كثير من المسائل المعقدة، أهمها خاصية التوازي (Parallelism) وهو أساس معمارية الشبكة العصبية (Architecture Neural Network) ، حيث تعمل فيها خلايا الشبكة بشكل متزامن، كما إنها تمتلك قدرات عالية في معالجة البيانات الكبيرة وبسرعة عالية وكفاءة في التعلم بوصفها نتيجة تشير إلى قابليتها على الإجابة الدقيقة (للشعور بالحاضر للإدخال)، أي تعرف ماذا سيكون الإخراج لهذا الإدخال ، كما إنها تتميز بقدرتها على التكيف والتنظيم الذاتي (Self-organizing) وبذلك توفر قدرات معالجة موثوقاً بها للتعلم .إن أنواعا من الشبكات العصبية تجهزنا بإجابات فورية، في حين تحتاج أنواع أخرى من الشبكات إلى وقت للإجابة حسب الصفات التي تمتلكها وسلوكها، لذا يشار إليها بالمتحركة غير الثابتة (Dynamics). ويدخل العديد من الخوارزميات (Algorithms) ضمن عمل الشبكات العصبية لكل واحدة أغراض ترتبط بالتحليل (Zurada:1994). وبالرغم من تعدد أنواع او نماذج الشبكات العصبية الا إن جميعها تمتلك ثلاث هيئات مشتركة تشكل إتمودجا للشبكة العصبية وهي: الخلية أو العقدة (Node) ووحدة المعالجة (Processing Unit) تتصف بوجود ارتباطات بينها، أي ترتبط خلية مع أخرى عن طريق الاوزان (Weights)، الشيء الثالث هو قانُون التعلم (Learning Rule) ، تنفرد كل خلية من خلايا الشبكة العصبية بوحدة ذاكرة (Memory Unit) خاصة بها وظيفتها خزن الحقائق (البيانات) وإن فقدان أحد العناصر منها لا يؤدي إلى فقدان كامل البيانات إنما يحدث تغير هامشي على فعالية الخلايا. وتقاس ذاكرة الشبكة العصبية بوساطة الارتباطات في حين تقاس ذاكرة الحاسبات الرقمية بال (Byte)، وتقاس سرعة الشبكات العصبية بارتباط في كل ثانية في حين تقاس سرعة الحاسبات الرقمية بإيعاز في كل ثانية ، إن الشبكات العصبية والحاسبات التقليدية لا تتنافس فيما بينها ولكنها تكمل أحدها الأخرى، فهناك العديد من المهمات تتطلب أنظمة تجمع بينهما لإنجاز مهامهما بكفاءة عالية مستخدمة الحاسبات للإشراف على

الشبكات العصبية (Stergiou & Siganos :1996). وللفترة من (1960 - 1962) طور العالم Bernard Windrow وتلميذه Marcian Hoff من جامعة Stanford، قاعدة للتعلم هي قاعدة المربعات الصغرى، والتي أطلق عليها فيما بعد بقاعدة الـ Delta، حيث أنهما نمذجا شبكات عصبية أطلقا عليها Adaline و Madaline وهذه التسميات جاءت جراء استخدامها عناصر التكيف أو التعديل الخطي المتعدد Multiple Adaptive Linear Elements وكانت (Madeline) أول شبكة عصبية يتم تطبيقها على مشاكل العالم الفعلية. حيث نجحت في تصفية الصدى في خطوط الهاتف وإزالته، وهذه الشبكات لازالت تستخدم بشكل واسع في العالم. بعد ذلك توقفت الأبحاث نوعاً ما حول الشبكات العصبية وبخاصة بعد أن قدم Minsky و Papert دراسة حول الشبكات العصبية، بينما فيها تقويميهما لهذه الشبكات، حيث أظهرتا محدوديتها وعدم إمكانيتها في حل العديد من المشاكل وبخاصة اللاخطية منها، مما حدا بالمؤسسات الصناعية والحكومية للتفكير ملياً قبل تقديم الدعم والإسناد المادي لهذا النوع من الأبحاث، وبالتالي توقف الأبحاث لمدة تزيد عن عشرة أعوام، (الشيخلي 2004). وفي عام 1982 قدم العالم Hopfield والحاصل على جائزة نوبل في الفيزياء من معهد كاليفورنيا للتكنولوجيا، بحثه المشهور (Neural Network & Physical Systems). فقد استعرض Hopfield مدخلاً جديداً في تقديم أجهزة ومعدات مفيدة تتميز بالوضوح والتحليل الرياضي، فقد بين ما الذي يمكن أن تقوم به هذه الشبكات وكيف، إذ إن هذه الشبكات تتميز باعتمادها على الأوزان الثابتة وتوابع التنشيط التكيفية ويمكن لهذه الشبكات أن تستخدم كشبكات ذاكرة مشتركة، وهي قادرة على حل المشاكل المرتبطة بإيجاد القيود المثلى مثل (مسألة البائع المتجول Traveling Sales Man). (Shachmurove, 2004). ومن الفترة 1987 وحتى وقتنا الحاضر ازداد الاهتمام بالشبكات العصبية بشكل ملفت للنظر، إذ أقيم في هذا العام أول مؤتمر دولي حول الشبكات العصبية في المعهد الهندسي للكهرباء والإلكترونيات (IEEE) في الولايات المتحدة، (Nygren, 2004) وقد ضم أكثر من 1800 من المهتمين بهذه الشبكات. بعد ذلك توالى المؤتمرات واللقاءات حول الشبكات العصبية وسبل الاستفادة منها وتطبيقها على مختلف مرافق الحياة، وكان للتطورات المذهلة والكبيرة في تقنيات الحواسيب الشخصية والصغيرة والسعة التخزينية العالية الأثر الكبير في تطوير برامجيات الشبكات العصبية من خلال ابتكار وإضافة أنواع جديدة منها، وتوليد خوارزميات لتعليمها وزيادة كفاءتها (Shachmurove, 2004).

14-2 التعريف والمفهوم

لقد أُطلقت على الشبكات العصبية الاصطناعية تسميات عدة جميعها بنيت على فكرة محاكاة الشبكة العصبية في الكائنات الحية، فقد سميت بالحاسوب الحي (Biological Computer) والدماغ الإلكتروني (Electronic Brain) والمنظومة العصبية (Neuromorphic System) ونماذج الترابط (Connection Models) والتوزيع المتوازي (Parallesim Distribution) ونماذج المعالجة (Processing Models) (ناجي وكاظم: 2016). وهناك تعريف عديدة للشبكات العصبية منها ما يختص بالجانب الحاسوبي والأخر بالجانب الرياضي والأخر بالجانب الهندسي هدفها جميعاً محاولة تقليد القدرة الإدراكية للدماغ بالتعلم والتجربة والخطأ، لتحقيق أداء يشبه أداء الإنسان في حل المسائل المعقدة باستعمال الخوارزمية والمسائل غير التامة (الناقصة) ولليانات المشوشة (الضبابية)، ومن هذه التعاريف ما يأتي:

1- إنَّ الشبكة العصبية الاصطناعية هي تقنيات حاسوب لمعالجة المعلومات، مكونة من عدد كبير جداً من عناصر المعالجة (Processing Elements) المترابطة فيما بينها نوات طبيعة ديناميكية وظيفتها هي التقسيم المتوازي لحسابات الشبكة، وتتكون الشبكة العصبية من عدد من وحدات المعالجة المتداخلة والمتجانسة، كل وحدة بمفردها أداة حسابية يمكن نمذجة سلوكها بمعادلات رياضية بسيطة. (Rao : 1993)

2- أما التعريف الرياضي للشبكة العصبية الاصطناعية فهي بشكل أساس نماذج رياضية لمعالجة المعلومات، أو هي أسلوب رياضي يقوم بمحاكاة شبكة عصبية بيولوجية للحصول على شبكة عصبية اصطناعية، فهي تستخدم بعض الطرائق الرياضية للحصول على الأوزان مثل المشتقات، (Rao: 1993) ولا تزال تعرف على إنها مكملة لطرائق الحساب التقليدية.

3- هندسياً تعرف الشبكة العصبية الاصطناعية بأنها تشكيل لدائرة كهربائية لها اتصالات داخلية وعناصرها البسيطة تسمى العصبونات، كل عصبون يمثل خريطة نموذجية للعديد من الإدخالات مُمثَّلة بالفولتية وإخراج واحد ممثلاً بالتيار، فالإدخال لكل عصبون هو الإخراج الموزون للعصبونات الأخرى، والاتصالات (الارتباطات) الداخلية تسمح بنقل واستبدال البيانات والمعلومات بين العصبونات (Chong and Zak, 2001).

4- ومن وجهة نظر النظم الحركية فإنَّ الشبكات العصبية الاصطناعية هي تقنيات أو طرق معلمية (Parametric Methods)، حيث تستخدم البيانات الخارجية لمعلمات مجموعة من

الإدخالات ويكون إدراك المخرجات من خلال إتجاز التغذية العكسية (Feed Backward) لدالة الكلفة (Cost Function) التي تستخدم بشكل مباشر في تغيير المعلمات خلال التدريب والتعلم (اختيار الأوزان) مما يؤدي إلى تحسين مخرجات النظام، أي تقليل الخطأ خلال التدريب، فالأوزان هي معلمات التعلم، وعلى هذا الأساس يمكن تعرف الشبكة العصبية الاصطناعية وتوظيفها احصائياً (Principe, et, al, 2000).

5- عرفها (Alter: 1999) على أنها نظام معلومات يستطيع تمييز الأشياء أو العينات على الأمثلة التي تكون مستخدمة لتدريبها، مركزاً على كونها نظاماً لمعالجة المعلومات، كغيره من المختصين بنظم المعلومات الإدارية حول ماهية هذه الشبكات لأنهم يستخدمونها نظاماً معلوماتياً من دون الدخول في تفاصيل تصميم هذه الشبكات.

6- عرفها الباحثان (Anderson & McNeil : 1992) الشبكات العصبية على أنها نماذج إلكترونية خام نسبياً، مستندة على التركيب العصبي للدماغ. وهناك من عرف الشبكات بأنها هيكل لمعالجة المعلومات بشكل متوازن ومتناسك.

من هذه التعاريف نجد أن الباحثين قد عرفوا الشبكات مركزين على كونها نماذج أو هياكل لمعالجة المعلومات وذلك من خلال خلفيتهم الهندسية أو الإحصائية أو الرياضية وكونهم مصممين ومبرمجين لهذه الشبكات وغيرها من البرامج الهندسية. في كل ما تقدم من تعاريف والتي صدرت عن مختصين بنظم المعلومات الإدارية ومهندسين ومبرمجين في مجال الذكاء الاصطناعي، نجد أنهم اختلفوا في التعبير عن الشبكات العصبية الاصطناعية ، من خلال تسميتها نظام معالجة، النماذج إلكترونية او نظام معلومات او معالجات مركزية أو هياكل معالجة للمعلومات. ولكن القاسم المشترك في كل هذه التسميات أنها أداة للمعالجة وحل المشكلات تقوم بعملها على أساس عمل الجهاز العصبي في الانسان مستمدة تصميمها من عمل الدماغ البشري. ولذا فإنه يمكننا تعريف الشبكات العصبية الاصطناعية (ANN) بأنها نظام مصمم لمحاكاة الطريقة التي يؤدي بها العقل البشري مهمة معينة، وهو عبارة عن معالج ضخم موزع على التوالي ومكون من وحدات معالجة بسيطة، بحيث يقوم بتخزين المعرفة العملية ليجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان.

15-2 الشبكات العصبية الاصطناعية و علم الإحصاء

Artificial neural networks and statistics

نشأ ووجد حقل الشبكات العصبية نتيجة للاختلافات الحادة والتباينات الكبير بين مختلف العلوم، وتقوم الشبكات العصبية بالتعرف على التحويلات والتغيرات المعرفية من حقل إلى آخر وتمييزها، الأمر الذي ربما يكون ليس بالأمر، (Anderson & McNeil : 1992) إذ حظيت العلاقة بين الإحصاء والشبكات العصبية في السنوات الأخيرة باهتمام متزايد من قبل الباحثين والعاملين في كلا الحقلين، فالكثير من الأفكار التي تراود الباحثين في الشبكات العصبية نجدها مبنية على أساسيات علم الإحصاء، وكثير من الوسائل والطرائق الإحصائية يمكن برمجتها بتوظيف شبكة وبناء خوارزمية لها، ويعود السبب في ذلك إلى التشابه والتطابق الكبيرين بين الطرائق المستخدمة في كلا الحقلين. (Rao : 1993) إذ ان هنالك أنواع عديدة من الشبكات العصبية لها طبقات عديدة، فهناك شبكات التغذية الأمامية ومنها شبكة المدرك (Perceptron) المستخدمة في تمييز الأنماط وشبكات (Hopfield) الدورية (المرتدة) ذات الاتجاه المتعكس، (Shachmurove, 2004) والشبكات الاحتمالية ومنها آلة بولتزمان (Boltzmann Machines) التي توصف في حقل الفيزياء الإحصائية لها توابع تنشيط تستبدل بدوال احتمالية، وشبكات التنظيم الذاتي (Self-organizing Networks) التي تتعلق بطرائق تقدير الكثافة الاحتمالية حرة المعلمات والتحليل العنقودي والتمييزي (Discriminating and Clustering Analysis) وشبكات أخرى .

16-2 الخلية العصبية البيولوجية Biological neuron

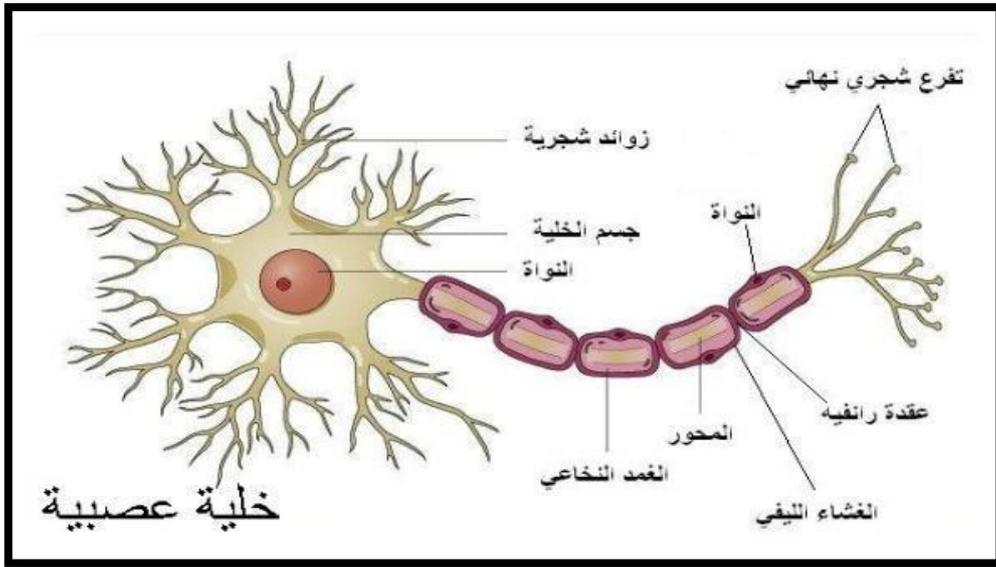
تتميز الخلية العصبية البيولوجية بخصائص حسابية واضحة يتم على أساسها اقتراح معمارية الشبكات العصبية الاصطناعية ، ويتشابه العصبون الاصطناعي والذي هو عنصر المعالجة الرئيس مع العصبون الحيوي. حيث تتألف العصبونات الحيوية من أربعة أجزاء أساسية مهمة هي: (Anderson & McNeil: 1992)

1. التشجرات Dendrites: وهي استطالات أو امتدادات من جسم الخلية تعمل كقنوات إدخال.
2. جسم الخلية Soma: وهو معالج للمدخلات/ المساهمات الداخلة.
3. المحور العصبي Axon: وهو يقوم بتحويل ونقل المدخلات/ المساهمات التي تمت معالجتها إلى مخرجات.

4. التشابكات Synapses: وهي نقاط الارتباط الكهروكيميائي بين الأعصاب وتسمى أحياناً بـ نقاط الارتباط العصبي.

اذ يوضح الشكل (11-2) خلية عصبية البيولوجية بسيطة حيث أن الخلية العصبية تستلم الإشارات العصبية من العصبونات الأخرى عن طريق التشجرات، وهذه الإشارات عبارة عن نبضات كهربائية تبتث عبر التشابكات والتي عملها هو تعديل الإشارة الداخلة بطريقة مشابهة لعمل الأوزان في نظام الشبكات العصبية الاصطناعية. ويقوم جسم الخلية بجمع الإشارات الداخلة ومن ثم معالجتها، بعد ذلك تنطلق هذه الإشارات إلى الخلايا الأخرى من خلال المحور العصبي والتشابكات، وبالنسبة للعصبون الحيوي فإن جسم الخلية يحتوي على سايتوبلازما وفق كثافات معينة وقيم هذه الكثافات تحدد فعالية الخلية وقدرتها على بث الإشارة من خلية لأخرى (Stergiou & Siganos :1996)

شكل (11-2) خلية عصبية حيوية بسيطة



المصدر : Anderson & McNeil : 1992

17-2 الخلية العصبية الاصطناعية Artificial Neuron

صممت الخلية العصبية الاصطناعية لتحاكي الخصائص الأساسية للخلية العصبية البيولوجية، حيث تمثل ترابطات الإدخال بخطوط تقابل التفرعات الشجرية والتي بدورها تمثل الإخراج لعصب آخر، فعندما تأتي الإشارة متمثلة بمتجه الإدخال X من ترابط معين تضرب برقم يسمى وزن الترابط (Weight of Connection) ومجموعة الأوزان تُمثل بالمتجه الذي يقابل اتساع التفرع الشجري البيولوجي وتجمع الإشارات أو الإدخالات الموزونة (Weighted Inputs) في صندوق الجمع الذي يقابل جسم الخلية العصبية لتحديد مستوى التأثير (الفاعلية) (Level activation) لها لتنتج إشارة الإخراج ممثلة الإدخال لخليا أخرى مرتبطة معها، وهكذا تجمع جميع الإدخالات الموزونة جبرياً لإنتاج الإخراج المتحقق المسمى بمصطلح (Net) محسوباً بالصيغة الآتية: (Stergiou & Siganos :1996)

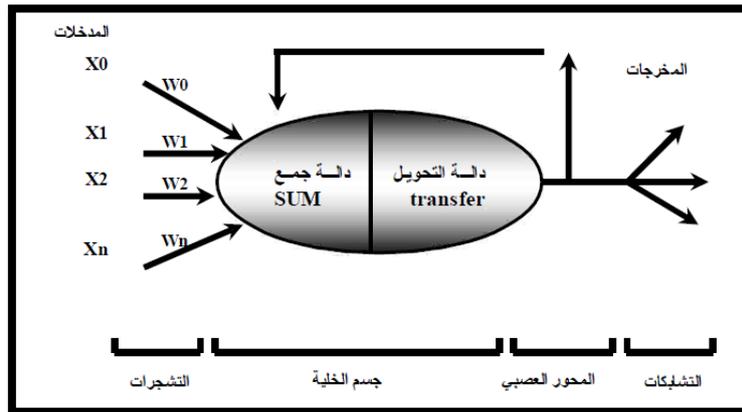
$$Net = \sum X W \quad \dots\dots(57-2)$$

حيث إن :

X : متجه الإدخال الذي يضم مجموعة الإدخال وهي X_1, X_2, \dots, X_n .

W : متجه الأوزان الذي يضم مجموعة الأوزان W_1, W_2, \dots, W_n .

مُشكلةً بذلك العصب الاصطناعي (Artificial Neuron). إذ يتكون العصبون الاصطناعي من أربعة أجزاء مبينة في الشكل (12-2) يوضح مكونات الخلية العصبية البيولوجية وما يناظرها في الخلية العصبية الاصطناعية، (Anderson & McNeil : 1992) شكل (12-2) الخلية العصبية الاصطناعية الأساسية



المصدر: (Stergiou & Siganos :1996)

1- الشجرات/ قنوات الإدخال:

هي بيانات تخص المشكلة المراد حلها والتي يمكن أن تكون على صورة بيانات كمية أو وصفية أو تكون مخرجات لوحدات معالجة أخرى وقد تكون نصوص أو صور أو صوت أو أشكال أو ظواهر معينة ويكون مصدرها البيئة الخارجية أو من نشاط خلايا أخرى؛ ونجد أنها ممثلة بالأنموذج الرياضي X_n والذي يمثل مدخلات عديدة للشبكة كل منها مضروب بوزن الترابط W_n . إذ تعتمد الشبكات العصبونية الاصطناعية على الوزن الترجيحي للعنصر والذي يعبر عن القوة النسبية أو القيمة الحسابية للبيانات من طبقة إلى طبقة، بمعنى أن الوزن يعبر عن الأهمية النسبية لكل مدخل إلى عنصر المعالجة، التي تحدد قوة العلاقة بين اثنين من عناصر المعالجة وقد تشجع أو تمنع إثارة المخرج فالوزن الإيجابي يثير إشارة المخرج والعكس في الوزن السالب، من الممكن تعديل الأوزان من خلال خاصية التعلم في الشبكة والتي تعرف بدالة التجميع، تساعد على إيجاد المجموع المرجح لكل عناصر المدخلات التي تم إدخالها وبذلك يتم الوصول إلى أفضل مجموع مرجح؛

2- جسم الخلية: ونجد أن جسم الخلية في شكله الاصطناعي يتمثل بشقين تمثلان معادلتين لكل منهما وظيفة خاصة، هي:

أ. دالة الجمع SUM Function: والتي هي عبارة عن مجموعة حاصل ضرب كل مدخل X بوزنه W لغرض توحيد الإشارات الداخلة من خلال المعادلة التالية:

$$SUM = \sum x_i w_i \quad \dots\dots(58-2)$$

وتمثل المنشط الداخلي و يطلق عليها بدالة التحفيز فمن خلالها تتم أول معالجة تقوم بها وحدة المعالجة وهي حساب مجموع المدخلات الموزونة، إذ تقوم هذه الدالة بحساب مجموع الأوزان لكل المدخلات وذلك بضرب قيمة كل مدخلة في وزنها، تجمع نواتج الضرب للحصول على إجمالي موزون وتأخذ دالة التجميع لعدد n من المدخلات في عنصر تشغيل واحد وفق الصيغة التالية:

$$Y = b_j + \sum_{j=1}^N w_j x_j \quad \dots\dots(59-2)$$

Y : ناتج مدخلات التركيبة الخطية

b_j : يمثل انحياز (Bias) ويعتبر احد مكونات الإدخال ويأخذ دائما القيمة واحد ($x_0 = 1$) وعمل الانحياز مشابه لعمل الاوزان لذلك يعامل معاملة أي وزن ويمكن ان يرمز له بالرمز ($b_j = w_{0j}$)، وإضافة وحدة انحياز إلى وحدات الإدخال يغير من شكل تابع التنشيط أو دالة التحويل.

w_j : الأوزان المرتبطة بالمدخلات

x_j : متغيرات الإدخال.

N : عدد متغيرات الإدخال والتي تكون مرتبطة بدرجة متعدد الحدود.

ب. دالة التحويل Transfer Function: وظيفة هذه الدالة هي تحويل المدخلات إلى إشارات خرج بعد توحيد إشاراتها على أساس حدود القيمة الخارجة وتأخذ المعادلة التالية :

$$Transfer = y = f(x) \quad \dots\dots(60-2)$$

اذ يحتوي كل عصبون على دالة تنشيط وقيمة عتبة وهذه الأخيرة هي القيمة الدنيا التي يجب أن تكون عليها المدخلات لتنشيط الخلايا العصبية، تم تصميم دالة التنشيط للحد من اخراج الخلايا العصبية، عادة ما تكون قيمة هذه المخرجات محصورة بين 0 إلى 1 أو -1 إلى +1 وفي معظم الحالات يتم استخدام نفس دالة التنشيط لكل الخلايا العصبونية في الشبكة، بمعنى أن كل خلية عصبونية لها مستوى استثارة تقوم دالة التجميع بحسابه وهو ما يعرف بالمحاكاة الداخلية، بناء على هذا المستوى يكون هناك نتيجة خارجة من الخلية أو لا يكون، العلاقة بين مستوى التفاعل الداخلي والقيمة الخارجة يمكن أن تكون خطية أو غير خطية وهي العلاقة التي تمثل باستخدام دالة التحويل، لهذه الأخيرة عدّة أنواع كما هو موضح في الشكل الموالي واختيار أيّ منها يتحكم في عمل الشبكة

3- المحور العصبي: وهو عبارة عن ناقل للإشارات التي تمت معالجتها وإرسالها إلى القسم الأخير من الشبكة لترتبط بالإشارات الأخرى عن طريق التشابكات.

4- التشابكات: وهذه تقوم بإرسال الإشارة الخارجة إلى خلايا عصبية أخرى كإشارة داخلية إليها.

18-2 أنواع دوال التنشيط/ التفعيل Activation Function Types

تتضمن العملية الأساسية في خوارزميات التعلم، جمع الإشارات الداخلة المضروبة بالأوزان، ثم بعد ذلك تطبيق دالة التنشيط. ويوجد هناك نوعان من دوال التنشيط، وهما:

1. الدالة الثنائية Binary Function.
2. الدالة سكمويد Sigmoid Function.

1- الدالة الثنائية Binary Function:

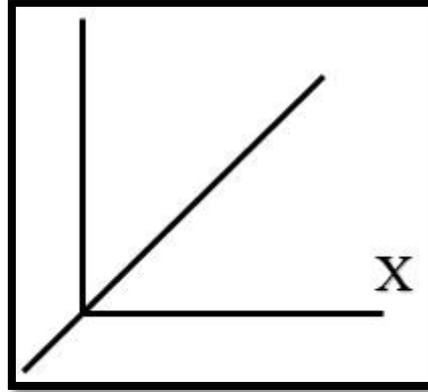
وهذه الدالة يمكن أن تصنف إلى نوعين أساسيين، هما: (القاضي، 2018: 11 - 16)

أ- دالة التطابق، وتأخذ الصيغة الآتية:

$$F(x) = x \text{ for all } x \quad \text{.....(61-2)}$$

وهو تابع خطي يستخدم في الشبكات وحيدة الطبقة، ويستخدم لتحويل دخل الشبكة إلى شكل مناسب لقيمة المخرج. وهو قيمة متغيرة ومستمرة. والشكل (2-13) يوضح هذه الدالة.

شكل (2-13) دالة التطابق



المصدر : (القاضي:2018)

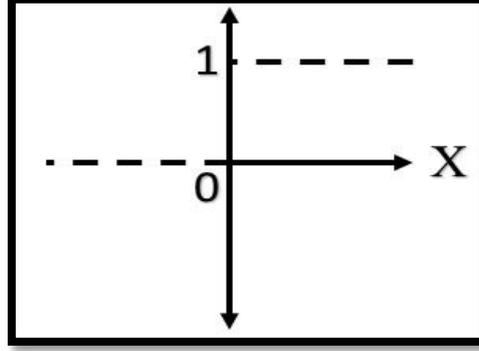
ب- الدالة الثنائية (أحادية القطب) Unipolar Binary Function

وتقوم هذه الدالة بإعطاء مخرجات إما (+1) أو (0) وصيغتها هي:

$$F(x) = \begin{cases} +1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad \text{.....(62-2)}$$

حيث أن X تمثل حاصل ضرب قيمة كل مدخل مع الوزن المناظر له. والشكل (14-2) يوضح رسم الدالة، والتي يطلق عليها في بعض الأحيان (Hard Limiting Function)، (Anderson & McNeil : 1992).

شكل (14-2) الدالة الثنائية (أحادية القطب)



المصدر : (Anderson & McNeil : 1992)

ج- الدالة الثنائية (ثنائية القطب) Biopolar Binary Function

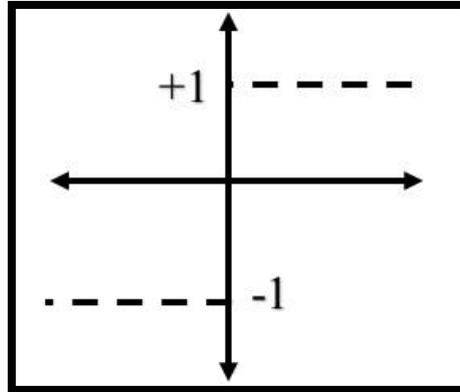
نجد أن مخرجات هذه الدالة تكون ثنائية، أي إما تكون (+1) أو (-1) وصيغتها هي:

(Shachmurove, 2004)

$$F(x) = \begin{cases} +1 & x > 0 \\ -1 & x \leq 0 \end{cases} \quad \dots\dots(63-2)$$

حيث أن X يمثل حاصل ضرب قيمة كل مدخل مع الوزن المناظر له. والشكل (15-2) يوضح هذه الدالة.

شكل (15-2) دالة ثنائية القطب



المصدر : (Shachmurove, 2004)

2- دالة سigmoid **Sigmoid Function**

وتعد من الدوال المهمة والمفيدة بشكل كبير كونها شائعة الاستعمال وتمتلك مزايا خاصة أدت إلى استخدامها في خوارزميات تدريب الشبكات العصبية ذات الانتشار العكسي (Back Propagation). وهذه الدالة تكون على نوعين: (القاضي، 2011)

أ- دالة سigmoid أحادية القطب **Binary Sigmoid Function**

غالباً ما تستخدم هذه الدالة في معالجة الحسابات التي تكون قيمة المخرجات المطلوبة هي قيمة ثنائية أو متغيرة، وضمن المجال $(0, +1)$. والشكل الرياضي لهذه الدالة هو:

$$F(x) = \frac{1}{1 + \exp(-\lambda x)} \quad \dots\dots(64-2)$$

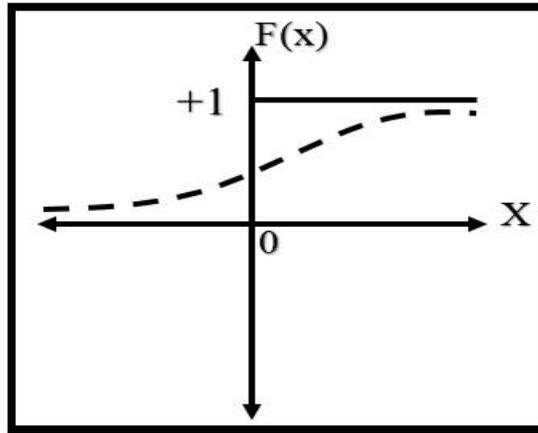
إذ أن:

X : تمثل حاصل ضرب قيمة المدخل مع الوزن المناظر له.

λ : تمثل معامل الانحدار أو ميل الدالة.

ويوضح الشكل (2-16) هذه الدالة. (Shachmurove, 2004).

شكل (2-16) دالة سigmoid أحادية القطب



المصدر : (Shachmurove: 2004).

ب-دالة سكمويد ثنائية القطب Bipolar Sigmoid Function

الشكل الرياضي لهذه الدالة هو:

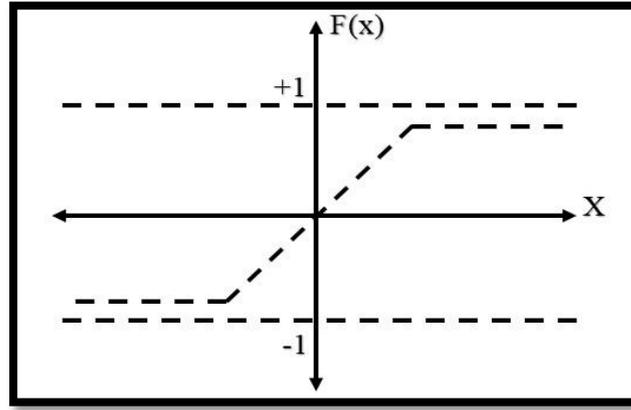
$$F(x) = \frac{2}{1 + \exp(-\lambda x)} \quad \dots\dots(65-2)$$

ومجالها هو:

$$F(x) = \text{Sgn}(x) = \begin{cases} +1 & \text{net} \geq 0 \\ -1 & \text{net} < 0 \end{cases} \quad \dots\dots(66-2)$$

أي أن المجال الأكثر شيوعاً واستخداماً لهذه الدالة هو $(-1, +1)$. والشكل (17-2) يوضح هذه الدالة. (Al-Osaimy: 1998)

شكل (17-2) دالة سكمويد ثنائية القطب



المصدر : (Al-Osaimy: 1998)

19-2 معمارية الشبكات العصبية Neural Network Architecture

نعني بالبنية المعمارية للشبكة او معمارية الشبكة العصبية الطريقة التي ترتبط بها وحدات المعالجة (العصبونات) مع بعضها البعض داخل كل طبقة أو بين الطبقات المختلفة المكونة للشبكة، حيث ترتبط هذه الوحدات بطرق مختلفة ووفقاً لكيفية هذا الترابط وعدد الطبقات المكونة للشبكة تظهر لنا البنية المعمارية العامة للشبكة العصبية، وهذا يرتبط بخوارزمية التدريب، وهنا يجب ملاحظة أن حساب عدد الطبقات يتم في الشبكة بدون حساب طبقة الإدخال لأنها لا تنجز أي حساب، أو يمكن معرفتها من عدد الترابطات بين العصبونات، و يمكن تصنيف تراكيب الشبكات وفقاً لعدد الطبقات الي:

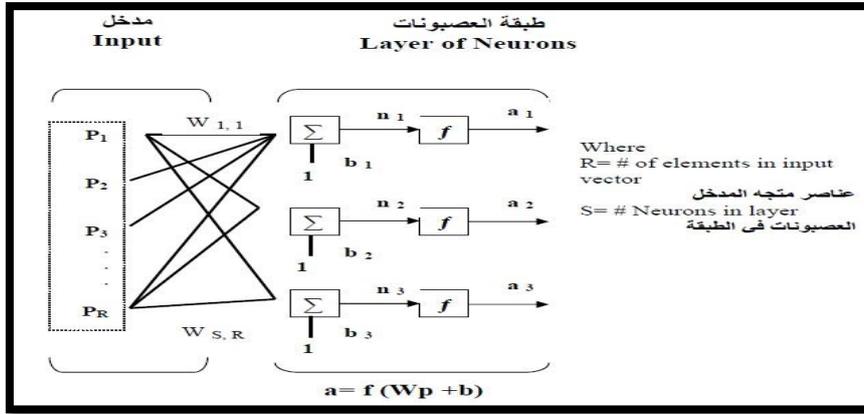
أ. شبكات وحيدة الطبقة Single Layer Network

ب. شبكات متعددة الطبقات Multi-Layer Networks

أ. الشبكات وحيدة الطبقة Single Layer Networks

من أبسط أنواع الشبكات حيث تتألف عادة من طبقة واحدة من عناصر المعالجة ، اذ في هذا النوع من الشبكات توجد طبقة واحدة من ترابطات الأوزان. وتتميز هذه الشبكات بوجود طبقة إدخال واحدة تستقبل الإشارات ، وطبقة المخرجات التي نحصل منها على استجابة الشبكة، وتوضح الترابطات بينهما. ومن أمثلة الشبكات وحيدة الطبقة شبكة Auto وشبكة Herto وشبكة Adaline Perceptron وشبكة Hopfield، حيث تستخدم في حل مسائل تصنيف العينات والتي تكون فيها استجابة المخرجات دليلاً على مطابقة المدخلات. ويجب أن نلاحظ أنه لا يوجد ترابط بين قيم الأوزان بالنسبة لكل ترابط بين وحدات الإدخال ووحدات الإخراج (Demuth & Beale: 1998) والشكل (2-18) يوضح المعمارية أو البنية الهندسية لهذه الشبكات.

شكل (2-18) شبكة عصبية ذو طبقة واحدة



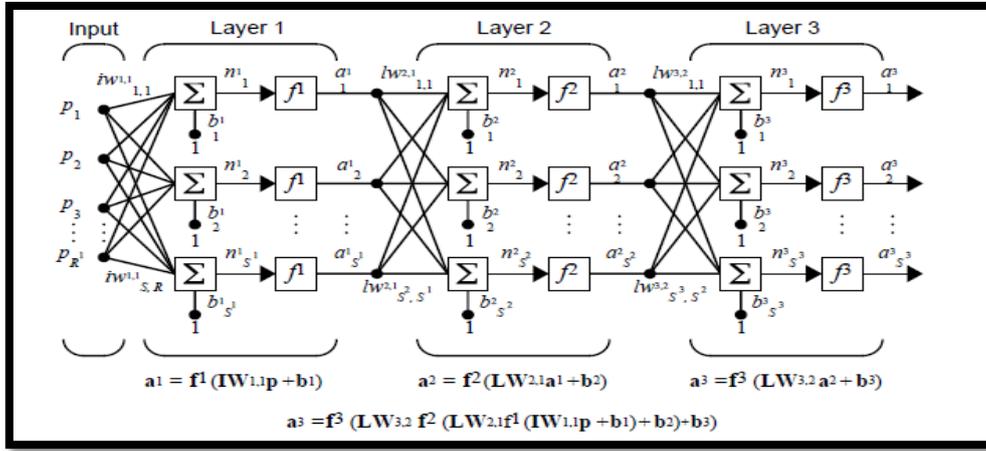
المصدر : (القاضي : 2011)

ب. الشبكات متعددة الطبقات Multi-Layer Networks

تحتوي تراكيب هذه الشبكة على أكثر من طبقة من عناصر المعالجة التي تربط بينها الوصلات البينية (الأوزان) حيث تتكون الشبكة متعددة الطبقات على الأقل من طبقتين طبقة لاستقبال المدخلات وهي غير محسوبة او طبقة المخرجات وبين طبقة المدخلات والمخرجات توجد الطبقات الخفية Hidden Layer ، ويمكن أن تحتوي الشبكة على أكثر من طبقة خفية، و ذلك

وفقاً لنوع التطبيق المستخدم ، وتتمركز بين وحدات الإدخال ووحدات الإخراج (Demuth & Beale: 2001). وتستطيع هذه الشبكات حل العديد من المشاكل المعقدة والتي لا تستطيع حلها الشبكات وحيدة الطبقة، ولكن تدريب الشبكات متعددة الطبقات يستغرق وقتاً أطول، لكنه أكثر نجاحاً من غيره. والشكل (2-19) يوضح البنية الهندسية لهذه الشبكات. إذ تعتبر الشبكات العصبونية الاصطناعية متعددة الطبقات أكثر تعقيداً وتمتلك قدرات حسابية أكبر من تلك الموجودة في الشبكات ذات الطبقة الواحدة وهي بذلك تستطيع حل العديد من المسائل المعقدة التي تعجز عنها الشبكات وحيدة الطبقة

شكل (2-19) شبكة عصبية متعددة الطبقات

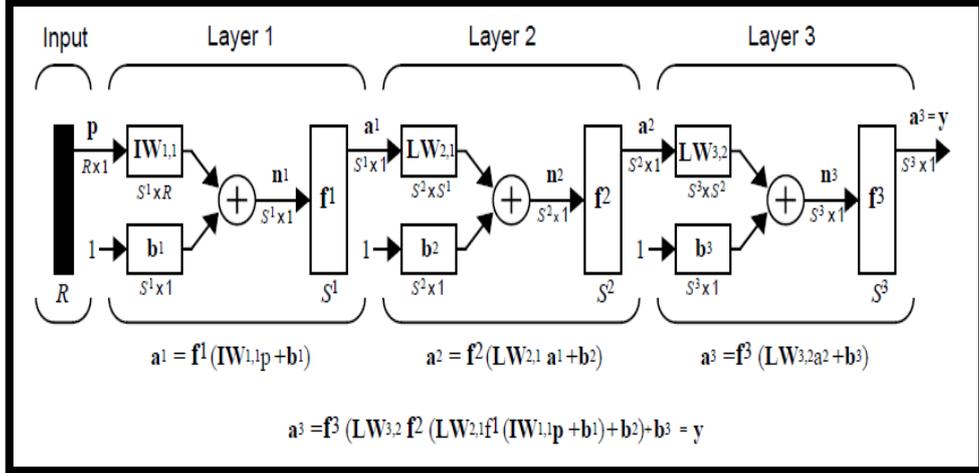


المصدر : (Demuth & Beale: 2001)

ومن أجل التمييز يضاف رقم الطبقة كدليل من المتحولات المستعملة عن طريق الشبكة مركبة المدخل، عصبون في الطبقة الأولى، عصبون في الطبقة الثانية، وهكذا بنفس الأسلوب. ومن الملاحظ أيضاً أن مخرج كل طبقة متوسطة هو مدخل الطبقة التي تليها وبذلك تعد كل طبقة في هذه الشبكة كأنها شبكة ذات طبقة وحيدة. الطبقة التي تعطي المخرج تسمى طبقة المخرج، أما المدخل فلا يعد طبقة، وبقية الطبقات تسمى الطبقات الخفية. (يمكن أن نرسم الشبكة الثلاثية المبينة في الشكل السابق باستخدام الرسم المختصر (2-20)). والشبكات متعددة الطبقات هي شبكات ذات فعالية كبيرة وبخاصة الشبكات بطبقتين فهي مستخدمة بشكل كبير جداً. إذ تستطيع هذه الشبكات حل العديد من المشاكل المعقدة، ولكن تدريبها يستغرق وقتاً أطولاً. يرمز إلى هذا

النوع بالرمز (n2. . . q – m – n1) حيث تشير m إلى عدد المداخل، وتشير n1 إلى عدد العصبونات في الطبقة الأولى وهكذا . . . و q عدد عقد المخرج

شكل (20-2) الشكل المختصر للشبكة متعددة الطبقات الأمامية



المصدر: (Demuth & Beale: 2001)

20-2 خوارزميات تعليم الشبكات العصبية

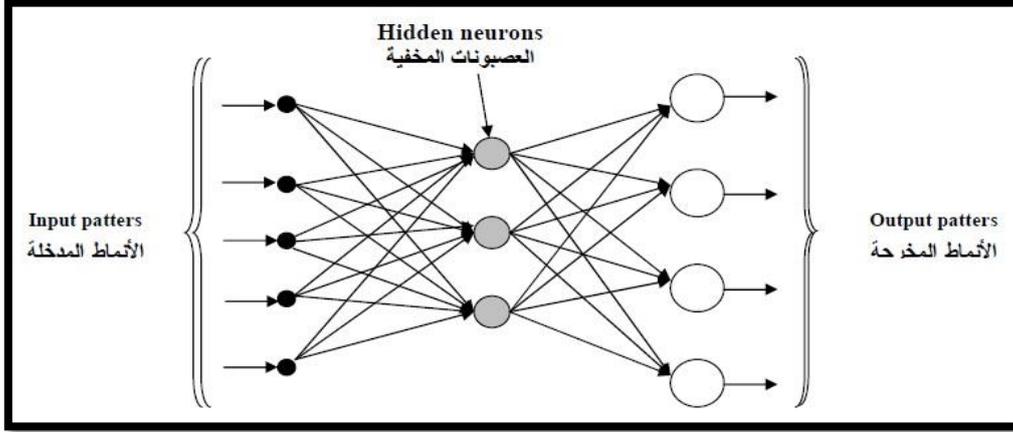
Learning Algorithms Of Neural Networks

الشبكات العصبونية لا تبرمج بل إنها تقوم بالتعلم ،اذ ان الفرق بين الإنسان والشبكات العصبونية هو في أن عملية التعلم واستعمال المتعلم يمكن أن تكون في الوقت نفسه في حين أن الشبكة العصبونية إما أن تكون في وضع المتعلم أو في وضع المنفذ. اذ تمثل الاوزان المعلومات الاولية التي ستتعلم بها الشبكة لذ لا بد من تحديث الاوزان خلال مرحلة التدريب ومن اجل هذا التحديث نستخدم عدة خوارزميات مختلفة حسب نوع الشبكة . ومن أهم هذه الخوارزميات، خوارزمية الانتشار العكسي Back-Propagation Algorithm المستخدمة في تدريب الشبكات العصبونية كاملة الارتباط، والشبكات ذات خوارزمية التغذية الأمامية Feed Forward Algorithm ومتعددة الطبقات MLP وغير الخطية Non Linear (القاضي: 2011) . وتعد هذه الخوارزمية تعميماً لطريقة التدريب بنمط تصحيح الخطأ. ويتم تنفيذ هذه الخوارزمية عن طريق مرحلتين رئيسيتين هما:

1- الشبكات ذات التغذية الأمامية Feed Forward Propagation

عبارة عن شبكات تتميز بمكونات ذات شكل تسلسلي بدا من طبقة المدخلات وانتهاءا بطبقة المخرجات و يبدأ عمل هذا النوع من الشبكات ذات التغذية الأمامية بإعطاء أشعة الدخل X ببعد n ذات القيم الحقيقية إلى كل وحدات الطبقة المخفية الأولى من خلال الأوزان w_{ij} فتقوم الوحدة المستقبلية للإشارة بمعالجة تلك الإشارات الواردة وإرسال مخرجاتها إلى الوحدات في الطبقة المخفية التالية مباشرة (Keller & Priddy:2005) ، وبالمثل تقوم هذه الوحدات بمعالجة الإشارات الواردة إليها (مخرجات الوحدات السابقة) ثم تمرير نتائجها إلى الطبقة التالية ، فتكرر هذه العملية من وحدة إلى أخرى في اتجاه الأمام حتى يتم الحساب النهائي بواسطة وحدات الخرج ومن أشهر وأهم انواع الشبكات العصبية ذات التغذية الأمامية هي شبكة البرسبترون Perceptron، المصممة على محاكاة المخ في التعرف على العينات وذلك باستقبال المدخلات من مصادر الإحساس المتعددة والقيام باستخلاص سمات معينة من هذه المعلومات ومقارنتها مع خبرات الماضي لاستنباط التصرفات و الأفعال الجديدة فيما يعرف بالتعرف على العينات (مع خبرات الماضي لاستنباط التصرفات و الأفعال الجديدة فيما يعرف بالتعرف على العينات (Pattern Recognition) وهي خاصية أو سمة حيوية للمخ الذي يسمح بفهم عالم شديد التعقيد ودائم التغيير ، (القاضي:2011) فشبكة البرسبترون(Perceptron) هي شبكة مصممة على أساس عمل المخ في التعرف على العينات ، وما يميز هذه الشبكة اعتمادها على ترتيب العقد التي تمثل العصبونات الاصطناعية في الطبقات التي من خلالها تتم نقل الاشارات من الطبقة الاولى الى الطبقات النهائية مروراً بالطبقات الخفية في اتجاه الامام فقط ومن اهم استخدامات شبكات البرسبترون (Perceptron) الفصل والتمييز بين المشاهدات والشكل (2-21) يمثل مخططاً لشبكة متعددة الطبقات ذات تغذية امامية وهنا لا يحصل أي تعديل للأوزان الشبكية وتبدأ هذه المرحلة بعرض شكل المدخل للشبكة، ويخصص كل عنصر معالجة من طبقة عناصر الإدخال لأحد مكونات الشعاع الذي يمثل المدخل، وتسبب قيم مكونات متجهة الدخل استثارة لوحدات طبقة الادخال ويعقب ذلك انتشار أمامي لتلك الاستثارة عن طريق بقية طبقات الشبكة.(Keller & Priddy:2005)

شكل (2-21) الشبكة ذات التغذية الأمامية Feed Forward Propagation



المصدر : (Keller & Priddy:2005)

2- الشبكات ذات التغذية الخلفية Feed Back Propagation

تسمى هذه الشبكات أحياناً بالمدرک متعدد الطبقات (Multilayer Perceprons) وهي شبكات عصبية عديدة الطبقات تستخدم فيها خوارزمية الانتشار الخلفي لتدريب الشبكة (قاعدة دلتا العامة للتعلم) وكما هي مبينة في الشكل (2-22). تُدرّب هذه الشبكات بأسلوب التعلم الموجه بهدف التوازن بين الاستجابة على اعطاء نتائج صحيحة للبيانات المستخدمة في عملية التدريب ونتاج استجابات جيدة لبيانات مشابهة كالمستخدمة في عملية التدريب ولكن بصورة غير مطابقة , ويتم في هذه المرحلة ضبط أوزان الشبكة. والتي تسمح لأوزان الشبكة أن تتحرك على الجانب السليبي من تتابع الأداء. إن دور الانتشار العكسي يعود إلى الطريقة التي يتم بها حساب الميل لطبقات الشبكة المتعددة اللاخطية، إذ يتم في أحد مراحل التعليم إعادة انتشار الإشارة من المخرج إلى المدخل بشكل عكسي، ويتم خلالها ضبط أوزان الشبكة، ويمكن تمثيل الخوارزمية لتكرار واحد كما يأتي: (القاضي:2011)

$$x_k + 1 = x_k - a_k * g_k \quad \dots(67-2)$$

حيث:

x_k : شعاع الأوزان والانحيازات الحالية.

a_k : معدل التعلم.

g_k : الميل الحالي.

اذ ان هناك طريقتان لحساب الانحدار التدريجي (Gene : 1991:P.1348)

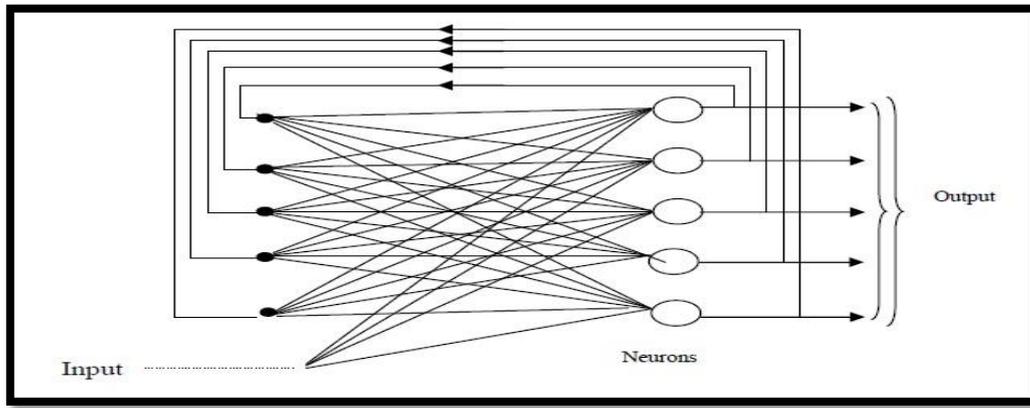
أ. النظام التزايدى Incremental Mode:

يتم وفق هذه الطريقة حساب الميل ومن ثم تعدل الأوزان بعد كل مدخل يعطى للشبكة.

ب. نظام الدفعة الواحدة Batch Mode:

وفقاً لهذا النمط، تزود الشبكة بكل أشعة المدخل قبل القيام بعملية تحديث الأوزان ومن ثم يمكن القول أن الأوزان والانحيازات في هذه الطريقة تعدل بعد تزويد الشبكة بكامل مجموعة التدريب إذ أن الميول المحسوبة في كل مثال تدريبي تضاف لبعضها البعض لتحديد التغيرات في الأوزان. (القاضي: 2011: ص.15)

شكل (2-22) مرحلة التغذية الخلفية Feed Back Propagation



المصدر : (Gene:1991)

2-21 معالجة المعلومات في الشبكة العصبية (التدريب والتعليم)

إنّ الشبكات العصبية الاصطناعية نوعان هما الشبكات الثابتة (Fixed N Nets)، وهي التي لا تتغير أوزانها عند التدريب أو التعلم، والشبكات المكيفة (Adaptive N. Nets) والتي لها القابلية على تغيير أوزانها. ويقصد بمعالجة المعلومات في الشبكات العصبية مرور البيانات في الشبكات العصبية المكيفة بمرحلتين أساسيتين هما: (Zurada , 1994).

- مرحلة التدريب أو التعلم (Learning or Training Step).
- مرحلة العمل (الاسترجاع) (Doing or Recall Step).

2-21-1 مرحلة التدريب أو التعلم

يمكن تعريف التعلم بأنه عملية ضبط الأوزان لجعل الخلية تطلق إشارة استجابة للأمثلة من مجموعة معينة. وكما هو معروف، فإن الشبكة العصبية هي عبارة عن مجموعة عصبونات Neurons واوزان منظمة، والعصبونات منظمة في طبقات، (صادق: 2016) وكل عصبون في كل طبقة له وزن مرتبط مع كل عصبون في الطبقة التالية. والشبكات العصبية الاصطناعية تتعلم عن طريق وسائل معينة تغير قوة الربط الداخلي، وهذا يدعى "تكييف الوزن" ويحدث خلال عملية تدعى "مرحلة التدريب". ومجموعة الإدخال الخارجي تدعى "مجموعة التدريب للشبكة" أو (عينة التدريب) ونموذج الإدخال المنفردة يسمى "متجه التدريب" أو (المشاهدات) فضلاً عن أن الشبكة يمكن أن تستقبل عن طريق التغذية العكسية Feedback، أو يمكن أن تستخدم التغذية العكسية مع معلومات إضافية لتحديد حجم التغير في الأوزان، إذ يمكن تعرّف التعلم عموماً على أنّه تغير دائم ومستمر نسبياً في السلوك الذي يحدث بواسطة التجربة والاختبار. والتعلم في الشبكات العصبية هو تطبيق معطى لعمليات (الإدخال-الإخراج) من خلال مجموعة من الأمثلة، ويكون التعلم ضرورة ملحة عندما يكون هناك نقص في فهم العلاقة بين الإدخال والإخراج بحيث تكون صعبة الوصف، وخلال هذه المرحلة تنتج بيانات جديدة في الشبكة نتيجة لتغير الوزن (Weight) للشبكة (Zurada , 1992). تبدأ عملية تدريب الشبكة العصبية الاصطناعية على التطبيق المعطى بإدخال البيانات إلى الشبكة فتتعلم على خصائص ومزايا هذه البيانات التي تُمثل بشكل متجهات (Vectors) كل متجه يتكون من جزأين، الجزء الأول يمثل مجموعة المتغيرات المستقلة مثلاً (الإدخال)، (Anderson & McNeil, 1992) أما الجزء الثاني فيمثل قيم المعيار (المتغيرات المعتمدة) (الإخراج المطلوب)، إذ يكون الجزءان معاً المتجه الذي يعد الإدخال إلى الشبكة وكل عقدة من عقد الإدخال تمثل إحدى قيم الجزء الأول من المتجه (المتغيرات المستقلة). ويتم إدخال المتجه إلى الشبكة على شكل مصفوفة، وتدريب الشبكة على البيانات أي تتغير أوزانها وفقاً لقوانين محددة وبشكل متسلسل، وبذلك تقترب الأوزان تدريجياً إلى القيم المثالية التي تعطي أفضل تقدير لقيم المعيار والتي تمثل الإخراج المطلوب للشبكة. إذ تقسم بيانات الإدخال والإخراج في الشبكة إلى ما يأتي :

1- مجموعة التدريب : تستخدم لضبط الأوزان

2- مجموعة الاختبار : للتأكد من أداء الشبكة في مختلف مراحل التعلم

3- مجموعة التحقق : تخمين اداء النموذج

اذ يتفق العديد من الباحثين على أن هنالك ثلاث استراتيجيات للتدريب، هي كما يلي: (صادق: 2016)

أ. التدريب بالإشراف.

ب. التدريب بدون إشراف.

ج. التدريب بالتقوية

أ- التدريب بأشراف (عن طريق مشرف أو معلم):

وهو التدريب بإرشاد وعادة ما يستخدم في شبكات التغذية الأمامية (Feed Forward Networks) ،ويتطلب وجود زوج من متجه الإدخال (Input) ومتجه الإخراج المتوقع (Target Output) والتي تمثل زوج التدريب، تدرب الشبكة العصبية على عدد من هذه الأزواج ويقارن الإخراج (Output) لمتجه الإدخال المطبق مع متجه الإخراج المتوقع والاختلاف بينهما يمثل خطأ التدريب (Training Error) يرجع خلال الشبكة كي تتغير الأوزان طبقاً للخوارزمية باتجاه تقليل الخطأ. (صادق: 2016)تطبق جميع متجهات مجموعة التدريب وتتغير الأوزان ويحسب الخطأ إلى إن يصل لمجموعة التدريب المدخلة إلى اقل خطأ تدريب (Minimum Training Error) باستخدام إحدى الطرائق الشائعة في تقليل الخطأ وهي مربعات المتوسطات الصغرى التقاربية (Least Means Squares) ،وبالنتيجة نحصل على الأوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتدريب أو التعلم، وهذا هو الهدف من تدريب الشبكة العصبية الاصطناعية (دخيل:2008)

ب- التدريب بدون إشراف:

هذا النوع من التدريب لا يستخدم المرشد او المعلم الخارجي ويكون الاعتماد فقط على المعلومات الموقعية، ويشار إلى هذا النوع من التدريب بشبكات التنظيم الذاتي (Self-Organizing) أي تنظيم البيانات التي تقدم إلى الشبكة ذاتياً في هذا التدريب تمتلك الشبكة العصبية بعض المعلومات خلال التدريب أي لها إدخلات فقط وليس لها معرفة عما سيكون عليه الجواب الصحيح ولا تعرف ما هو الإخراج المطلوب أي عدم وجود النتيجة المرجوة (Desired Output) للشبكة ليقارن مع النتائج . اكتشف هذا التدريب الباحث كوهين وآخرون،

تتألف فيه مجموعة التدريب من متجه الإدخال وخوارزمية التدريب لتغيير أوزان الشبكة لإنتاج متجه الإخراج الثابت، يطبق الإدخال لإنتاج الإخراج المحدد (Smith: 1997).

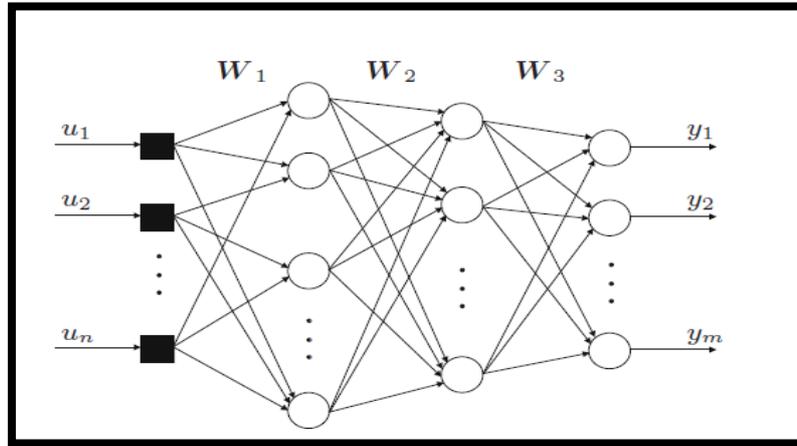
ج- التدريب بالتقوية Reinforcement Training

في هذا النوع من التدريب يتم فرض وجود مدرب للشبكة ولكن المخرجات المرغوبة لا يتم تزويدها أو تقديمها للشبكة وإنما يتم التوضيح للشبكة فيما إذا كانت المخرجات الفعلية لها مطابقة أو غير مطابقة. بعد ذلك تقوم الشبكة باستخدام المعلومات لتحسين أدائها (صادق: 2016). ويتم بعد ذلك تثبيت الأوزان للوحدات التي تكون مخرجاتها مطابقة. وتعديل ذاتي للأوزان التي تكون مخرجاتها غير مطابقة.

2-21-2: مرحلة العمل (الاسترجاع)

وهي المرحلة الثانية لمعالجة (بيانات) الشبكة العصبية الاصطناعية، وفيها يطبق الإدخال المعطى مع الأوزان الناتجة من المرحلة الأولى (مرحلة التدريب) وبخطوة واحدة نحصل على الإخراج المطلوب (Desired Output). إن مرحلة العمل (الاسترجاع) هي تغذية أمامية فقط (Feed Forward)، (Patan : 2008) حيث تكون العصبونات مرتبطة مع الطبقات مما يؤدي إلى إنسيابية البيانات باتجاه واحد فقط، أي إن كل عصبون يستلم المعلومات فقط من العصبونات في الطبقة السابقة، والإدخال لكل عصبون يمثل الإخراج الموزون للعصبونات في الطبقة السابقة (Chong & Zak , 2001) والشكل (2-23) يوضح هيكلية الشبكة العصبية ذات التغذية الأمامية وكما يأتي :

الشكل (23-2) هيكلية الشبكة العصبية الاصطناعية ذات التغذية الامامية



المصدر : (Patan , 2008)

22-2 العوامل المؤثرة في تدريب الشبكات العصبية الاصطناعية

إنّ سرعة وكفاءة تدريب الشبكة العصبية يعتمد على العوامل الآتية :

1- معدل التعلم (Neta)

يعد معدل التعلم من العوامل المؤثرة في تحديث الأوزان في الشبكات العصبية الاصطناعية فهو يحدد حجم الخطوة في عملية تعلم الشبكة العصبية ومقدار تغير الوزن، فهو عبارة عن معادلة رياضية تعمل على اجراء تعديلات للأوزان الترجيحية اعتماداً على قيمة المدخلات حيث تمكن معدل التعلم (n) الشبكة العصبية الاصطناعية من انتاج المخرجات الموثقة كلما زاد حجم المدخلات داخل الشبكة. (الحسيني: 2015)

2- عدد المتجهات في الشبكة العصبية .

إنّ عدد المتجهات له تأثير مباشر في أداء الشبكة العصبية لأنّه يمثل المتغيرات المستقلة فإذا كانّ عددها مناسباً فإنّ الشبكة العصبية تستطيع استخلاص أنموذج يمثل البيانات أما إذا كانت مدخلات الشبكة العصبية (معقدة) فيجب زيادة عدد المتجهات حتى تتعلم الشبكة العصبية على سلوك البيانات. (الزبيدي: 2012)

3- عدد العقد المخفية .

عند تدريب الشبكة العصبية لأول مرة يتم اختيار عدد قليل من العقد المخفية ومقارنة النتائج المطلوبة مع النتائج الحقيقية وبعد ذلك يتم زيادة عدد العقد المخفية إلى إنّ نصل إلى اقل قدر ممكن من الخطأ وأفضل النتائج. (الحسيني: 2015)

4- عدد المستويات المخفية .

يتم تدريب الشبكة العصبية بمستوى مخفي واحد وتستمر عملية التدريب أو التعلم على صفات البيانات إلى إنّ تصل إلى اقل خطأ ممكن وعند عدم تعلم الشبكة العصبية يتم زيادة مستوى مخفي آخر (علي: 2008)

23-2 إجراءات تصميم الشبكة العصبية الاصطناعية

هناك مجموعة من الإجراءات الواجب إتباعها لضمان نجاح تصميم الشبكات العصبية الاصطناعية والتي تتضمن ما يأتي: (Hoffer,et,at: 2008).

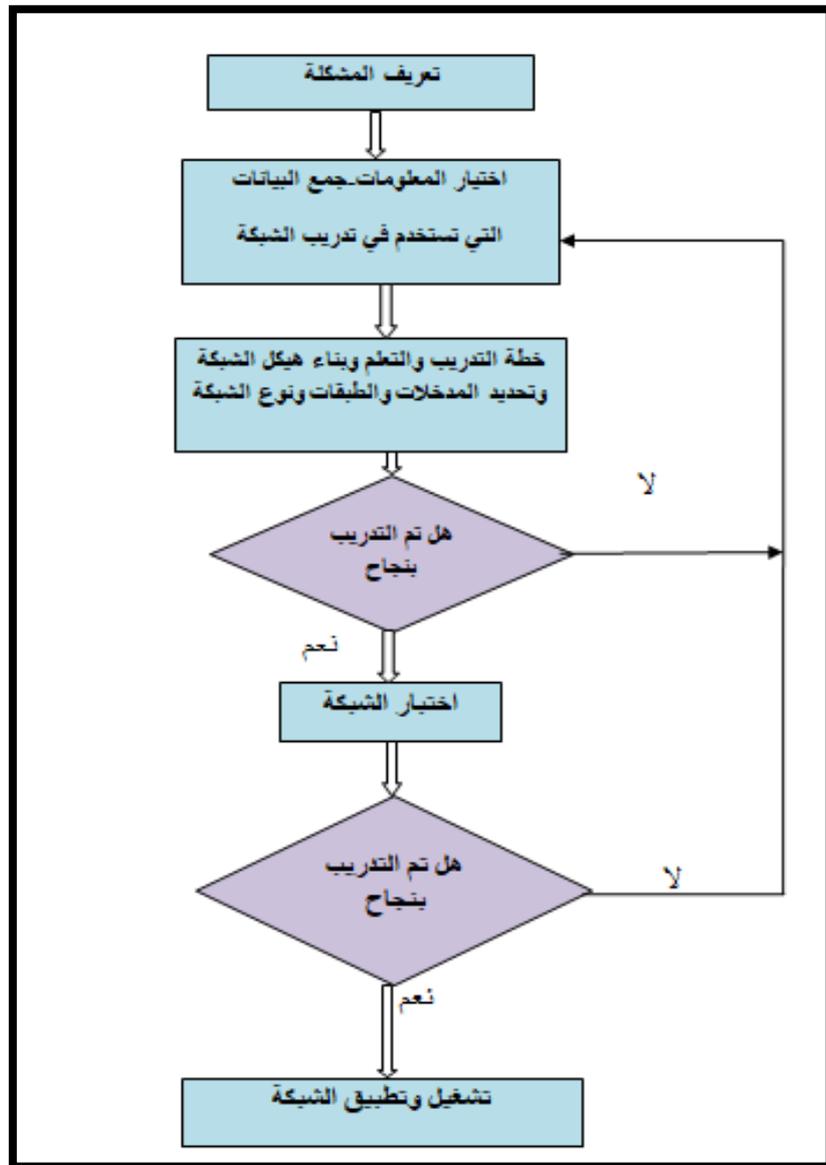
الإجراء الأول: تحديد الشيء المراد الشبكة العصبية الاصطناعية إنّ تتعرف عليه .

الإجراء الثاني: تحديد المعلومات التي يجب على الشبكة العصبية استخدامها والاعتماد عليها في إيجاد المطلوب منها حيث إنّ الشبكات العصبية تتعلم عن طرق ربط المدخلات بالمخرجات

الإجراء الثالث: تجميع بيانات كافية، وكلما كانت بيانات أكثر كإِنَّ تدريب الشبكة العصبية أفضل فيتم تحديد المدخلات والمخرجات التي تستخدم في الشبكة العصبية .

الإجراء الرابع: تحديد الأمور الفنية (عدد الطبقات المخفية المناسبة ،دالة التحويل ومداهها ،معدل التعلم) . والشكل (2-24) يوضح الخطوات المتبعة في تصميم الشبكات العصبية الاصطناعية.

الشكل (2-24) خطوات تصميم الشبكة العصبية الاصطناعية



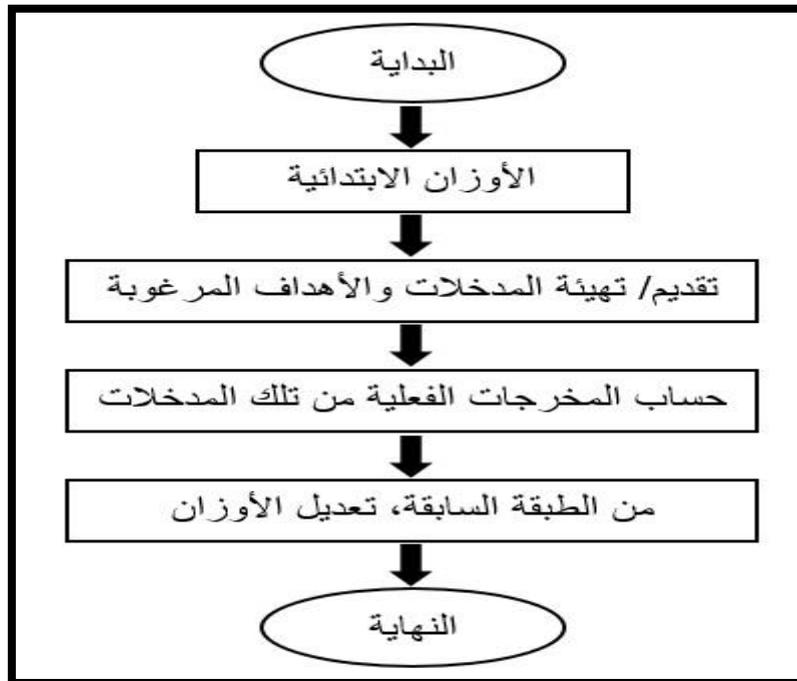
المصدر : (Hoffer,et,at:2008)

24-2 خوارزمية الانتشار العكسي (Bp) Algorithm Back propagation

ان خوارزمية الانتشار العكسي (Bp) للخطأ طورت في عام 1970 من قبل عدة علماء حيث ان الخطوات الأساسية فيها هو حساب خطأ مستوى المخرجات لتحديث اوزان طبقة المستوى المخفي-المخرجات ، ثم حساب خطأ مستوى المخفي لتحديث اوزان طبقة مستوى المدخلات-المخفي، (ar.wikipedia.org/wiki/54k) وبعد ذلك نحسب مخرجات الشبكة بالأوزان الجديدة لتستمر العملية في حساب الخطأ وتحديث الأوزان للوصول الى اقل خطأ في الشبكة العصبية ، اذ تعتبر خوارزمية الانتشار العكسي (Bp) من الخوارزميات المتعلمة بالإشراف، اذ يمكن تمثيل خطوات عمل الخوارزمية كما في الشكل (2-25). حيث أن وحدات الإخراج (Yk) تمتلك الأوزان (Yjk)، والطبقات المخفية تمتلك الأوزان (Vij). وخلال التعلم ، فإن المخرج الفعلي لكل عصبون (Yk) يقارن مع القيمة المرغوبة (dk) لتحديد الخطأ (E) للطبقة مع ذلك العصبون.

$$E = \sum_{(k=1)}^m (dk - yk)^2 \quad \dots(68-2)$$

شكل (2-25) خوارزمية الانتشار العكسي



المصدر : (الحسيني: 2015)

1-24-2 مراحل خوارزمية التعلم في شبكة Back propagation

تتكون هذه الخوارزمية من مرحلتين هما:

المرحلة الاولى: مرحلة التغذية الأمامية Feed Forward Phase

لا يحصل فيها اي تعديل للأوزان وتبدأ هذه المرحلة بعرض الشكل المدخل للشبكة حيث تسبب قيم مكونات المتجه استثارة لوحدات طبقة المدخلات ويعقب ذلك انتشار امامي لتلك الاستثارة عبر بقية طبقات الشبكة اي يتم حساب قيم مخرجات العقد المخفية لأستخدامها في حساب مخرجات الشبكة العصبية (ar.wikipedia.org/wiki/54k) ، اذ في بداية هذه المرحلة يتم إدخال قيم عشوائية كمدخلات للشبكة من أجل الحصول على قيم أوزان أولية من خلال التدريب من أجل الوصول إلى الأوزان المثلى للشبكة. ثم يتم حساب مخرجات الطبقات المخفية كالاتي:

$$h_i = 1 / \left[1 + \exp \left(- \sum_{j=0}^m w_{ij}^h x_j \right) \right] \quad \dots(69-2)$$

$$y_k = 1 / \left[1 + \exp \left(- \sum_{i=0}^n w_{ki} y_i \right) \right] \quad \dots(70-2)$$

$$p_m = 1 / \left[1 + \exp \left(- \sum_{i=0}^n w_{mk} y_k \right) \right] \quad \dots(71-2)$$

حيث أن:

h_i : مخرجات الطبقة المخفية.

w_{ij} : الوزن بين طبقة المدخلات والطبقة المخفية.

x_j : قيمة المدخلات.

y_k : مخرجات الطبقة المخفية.

w_{ki} : الوزن بين الطبقة المخفية وطبقة المخرجات.

p_m : مخرجات طبقة المخرجات.

w_{mk} : وزن طبقة المخرجات.

بعد ذلك نقوم باستحصال المخرج النهائي أو الفعلي من الشبكة، ومن ثم نقارنه مع المخرجات المرغوبة من خلال حساب الفرق بين المرغوب والفعلي من المخرجات للحصول على الخطأ بالمعادلة التالية:

...(72-2)

$$e_m = d_m - p_m$$

حيث أن:

e_m : الخطأ.

d_m : المخرجات المرغوبة.

p_m : المخرجات الفعلية.

ثم بعد ذلك تبدأ المرحلة الثانية من خوارزمية الانتشار العكسي.

المرحلة الثانية : مرحلة الانتشار العكسي للخطأ Error Back Propagation Phase

وهي مرحلة ضبط اوزان الشبكة حيث يتم حساب مشتقة الخطأ من عقد المخرجات والعقد الخفية ، واستخدامها في تحديث اوزان الطبقات (Anderson, et, at, 1992).، اذ في حالة كون المخرجات الفعلية متطابقة مع المخرجات المرغوبة أي أن قيمة الخطأ مساوية للصفر ($e_m = 0$) او قريبة منها ، فإن ذلك يعني أن الشبكة تعمل بشكل جيد و بانتظام، وهذا يعني استقرار الشبكة ونهاية البرنامج والوصول إلى النهاية. وفي حالة وجود خطأ أي أن الفرق بين المخرجات الفعلية والمرغوبة كبير أو غير مقبول، فإن مرحلة الانتشار العكسي للخطأ ستبدأ من خلال حساب الميل وتعديل الأوزان ووضع مقياس تعلم قيمته بين (0 - 1) ورجوع الأوزان المعدلة إلى بداية البرنامج ودخولها كمدخلات للشبكة وتنفيذ للشبكة من جديد.

2- 25 تطبيقات الشبكات العصبية Neural Networks Applications

يعد حقل دراسة ANNs حقلاً متشعباً جداً من ناحيتي التطوير والتطبيق، وقد بدأ بتطبيق اقتراحات الباحثين في مجال الشبكات العصبية على العديد من المجالات والتطبيقات وخصوصاً فيما يتعلق بمشاكل العالم الفعلية. فالشبكات العصبية هي الأفضل في تصنيف العينات أو التوجهات في البيانات، (Shachmurove & Shachmurove & Witkowska: 2001)، (Shachmurove, 2004)، (Fish & others: 1995)، (Demuth & Beale: 1988). ولذا فإنها مناسبة جداً في التنبؤ بالحاجات التي تتضمن:

1- الفضاء Aerospace: الطيار الآلي العالي الأداء، محاكاة اتجاه الطيران، أنظمة السيطرة

على الطائرة، التحسينات على الطيار الآلي، كشف عيوب مكونات الطائرة.

2- الأتمتة Automotive: أنظمة توجيه السيارة آلياً، تحليل فاعلية التحسب.

- 3- الأعمال المصرفية Banking: الصكوك وقراءة الملفات المصرفية الأخرى، تقييم تطبيق ائتمان.
- 4- الدفاع Defense: توجيه السلاح، اقتفاء الهدف، تمييز الأجسام، تقدير الوجوه، أنواع جديدة من المتحسسات، الأمواج فوق الصوتية الرادارية، إشارات تعريف الصورة.
- 5- الإلكترونيات Electronics: التنبؤ بسلسلة الرمز، تخطيط رقابة الدائرة التكاملية، السيطرة على العمليات، تحليل فشل الرقاقة، مكائن الرؤية، توليف الأصوات، النماذج اللاخطية.
- 6- الترفيه والتسلية Entertainment: الصور المتحركة، المؤثرات الخاصة، التنبؤ السوقي.
- 7- المالية Financial: تقييم العقارات، استشاري القروض، فحص الرهن، تقدير سندات الشركة، تحليل حدود استخدام الائتمان، برنامج تجارة المحفظة، تحليل مالية الشركة، التنبؤ بأسعار العملة.
- 8- التأمين Insurance: تقويم تطبيق السياسة، تعظيم أمثاليه المنتج (Product Optimization).
- 9- التصنيع Manufacturing: السيطرة على عمليات التصنيع، تحليل وتصميم المنتج، تشخيص العملية والماكينة، التعريف الفوري للأجزاء، أنظمة التفتيش البصرية الفعالة، تحليل جودة اللحام، التنبؤ بنوعية البحث، تحليل نوعية رقاقة الحاسوب، تحليل عمليات السوق، تحليل التصميم الكيميائي للمنتج، تحليل صيانة الماكينة، تصريح المنتج، التخطيط والإدارة، الأنموذجات المتحركة لنظام العمليات الكيميائية.
- 10- الطب Medical: تحليل خلية سرطان الثدي، تحليلات جهازي تخطيط القلب وتخطيط الدماغ، تصميم الأجزاء التعويضية (Prosthesis)، تقليل وقت عملية الزرع للأعضاء، الاستشاري الفاحص لغرفة الطوارئ.
- 11- صناعة المشتقات النفطية و الاستكشافات Oil & Gas.
- 12- الانسان الآلي Robotics: سيطرة المسير، رفع الانسان الآلي، أجهزة السيطرة على المعالج، أنظمة الرؤية.
- 13- النطق (الكلام) Speak: تمييز الأصوات، تصنيف حروف العلة، إعداد النص للإلقاء.
- 14- الأوراق الآلية Securities: تحليل السوق، تقدير القروض آلياً، الأنظمة الاستشارية بأسهم المتاجرة.

- 15- الاتصالات عن بعد Telecommunications: ضغط البيانات والصور، خدمة المعلومات الآلية، الترجمة الفورية من اللغة المنطوقة، أنظمة معالجة مدفوعات الزبون.
- 16- النقل Transportation: أنظمة تشخيص كابح الشاحنة، جدولة المركبات، تسيير الأنظمة.

17- تنبؤ المبيعات و بحوث المستهلك.

18- إدارة الاستثمار و إدارة المخاطر.

26-2 مميزات الشبكة الاصطناعية

تتمتع الشبكة العصبية الاصطناعية بعدة مزايا منها :

(Stergiou and Siganos: 2001)

1- الاعتماد على اساس رياضي قوي

2- لها القدرة على التعامل مع جميع انواع البيانات نوعية و كمية

3- شمولية التطبيق حيث تمت الاستفادة من الشبكات الصناعية في مختلف حقول العلم والمعرفة.

4- لها الامكانيات والمؤهلات للتعامل مع المعرفة المكتسبة.

5- القدرة على تفسير البيانات الضبابية أو غير الكاملة.

6- القدرة على مواجهة المشكلات ذات النوعيات الجديدة .

7- مرونة وسهولة صيانة النظام.

27-2 نواحي القصور في نظم الشبكات العصبية

(Shachmurove, 2004) (Stergiou and Siganos: 2001)

1- الارتفاع الكبير في تكاليف تصميم و تشغيل و صيانة النظام .

2- بعض المعارف المنشودة قد لا تكون متوافرة دائما أو يصعب استخدامها .

3- منهج حل المشكلة قد يختلف من خبير إلى آخر رغم صحته في الحالتين .

4- احتمال تعارض القواعد الجديدة التي تضاف إلى القاعدة مع القواعد السابقة.

5- بعض القواعد تفقد قيمتها عند وضعها في غير التطبيق الأصلي الذي نشأت في ظلها.