IRAQI Academic Scientific Journals
العراقية المجلات الاكاديمية العلمية
مجلة كلية الكوت الجامعة
ISSN (E) : 2616 - 7808 II ISSN (P) : 2414 - 7419
www.kutcollegejournal.alkutcollege.edu.iq
k.u.c.j.sci@alkutcollege.edu.iq
المجلد 7 , العدد 2 , كانون الأول 2022

تصنيف المشاهدات باستعمال الشبكات العصبية الإصطناعية مع تطبيق عملي في مجال الطب

حسين علي شبيب [1] ، أ. م. د. علي ياسين غني [2]

الخلاصة

تهدف الدراسة الى استعمال تقنية الشبكات العصبية الاصطناعية في تصنيف مرضى هشاشة العظام من النساء وتحديد أهم العوامل المؤثرة في المرض ، إذ يعد التصنيف من الاساليب المهمة بسبب الحاجة الضرورية والمتكررة لمعرفة اي مجتمع من بين مجموعة من المجتمعات قد تعود إليه مشاهدة او مفردة ما، وفقاً للقياسات او المعايير التي تم الحصول عليها من المشاهدات او المفردات.

اختصت عينة البحث بالنساء اللواتي أجرين فحص كثافة العظام في مستشفى بغداد التعليمي لعامي 2019 و 2020 وكان حجم العينة 309 مشاهدة، بواقع 144 مشاهدة حجم عينة المجتمع الاول (النساء اللواتي أجرين اختبار كثافة العظام وكانت النتيجة غير مصابات بمرض هشاشة العظام) و165 مشاهدة حجم عينة المجتمع االثاني (النساء اللواتي أجرين اختبار كثافة العظام وكانت النتيجة مصابات بمرض هشاشة العظام)، وهذان المجتمعان يمثلان المتغير المعتمد إذ أُعطي الرمز (0) للمجتمع الاول والرمز (1) للمجتمع الثاني، وكان عدد المتغيرات التوضيحية خمسة متغيرات هي العمر وعدد السنوات التي مضت على سن اليأس والوزن والطول والمتغير النوعي (هل كان سن اليأس مبكرا؟).

بعد ادخال جميع المتغيرات الى الشبكة العصبية الاصطناعية (شبكة البرسبترون متعددة الطبقات ذات التغذية الامامية) وباستعمال البرنامج الجاهز (SPSS.23) تم الحصول على نتائج أهمها ان نسبة التصنيف الصحيح الكلية 78.6 %، وان اهم متغيرين في تمييز وتصنيف مرضى هشاشة العظام من النساء هما متغير الوزن ومتغير عدد السنوات التي مضت على سن اليأس ثم متغيرات الطول والعمر والمتغير النوعي (هل كان سن اليأس مبكرا؟) على التوالي.

الكلمات المفتاحية: الشبكات العصبية الاصطناعية، شبكة البرسبترون متعددة الطبقات، خوارزمية الانتشار العكسي للخطأ، التصنيف

انتساب الباحثين
[2،1] كلية الادارة والاقتصاد، الجامعة المستنصرية، العراق، بغداد، 10001

[1]hussainaliask73@gmail.com
[2]badrawi1966@gmail.com

[1] **المؤلف المراسل**

معلومات البحث
تأريخ النشر : كانون الأول 2022

Classification of Observations Using Artificial Neural Networks with Practical Application in the Field of Medicine

Hussein Ali Shabib [1] ، Assist. Prof. Dr. Ali Yaseen Gani [2]

Abstract

The study aims to use the artificial neural network technology to classify women patients with osteoporosis and to identify the most important factors affecting the disease. Classification is considered as one of the important methods because of the necessary and repeated need to know which community among a group of communities to which a particular an observation or an individual may belong, according to the measurements or criteria obtained from observations or individuals.

The research sample was concerned with women who underwent a bone density test in Baghdad Teaching Hospital for the years 2019 and 2020 and the sample size was 309 observations, 144 observations the size of the first community sample (women who underwent a bone density test and the result was not suffering from osteoporosis) and 165 observations the sample size of the second community (women who underwent a bone density test and the result was suffering from osteoporosis). These two communities represent the dependent variable where the symbol (0) was given to the first community and the symbol (1) to the second community. The number of explanatory variables was five

Affiliation of Authors
[1,2] College of Administration and Economics, University of Mustansiriyah, Iraq, Baghdad, 10001

[1]hussainaliask73@gmail.com
[2]badrawi1966@gmail.com

[1] **Corresponding Author**

Paper Info.
Published: Dec. 2022

variables, namely age and the number of years that have passed since the age menopause, weight, height and qualitative variable (was menopause early?).

After inserting all the variables into the artificial neural network (the multi-layered perceptron network with feed forward) and using the ready-made program (SPSS.23), the most important results were obtained, the total correct classification rate is 78.6%, and that the two most important variables in distinguishing and classifying women with osteoporosis are: Weight variable, number of years since menopause, height, age, and qualitative variable (was the menopause early?) respectively.

Keywords: artificial neural networks, multi-layer perceptron network, reverse error propagation algorithm, classification.

1-المقدمة

في السنوات الأخيرة برزت أهمية استعمال تقنية الشبكات العصبية الاصطناعية لأغراض التمييز والفصل بين المشاهدات، كما تستعمل في مجالات تطبيقية أخرى مثل التنبؤ وتحليل الصور ومحاكاة عمل الرجل الآلي والسيطرة النوعية وغيرها، وذلك بسبب قدرتها على التعامل مع الدوال غير الخطية وعدم تقييدها ببعض القيود المفروضة على الانحدار الخطي، او لاعتمادها على الأسلوب التكراري بهدف جعل الخطأ اقل ما يمكن من خلال التدريب او التعليم للوصول الى الأوزان (weight) المطلوبة التي تؤدي الى تقليل الخطأ **[1]**.

وهناك هيكلية للشبكات العصبية الاصطناعية المقصود منها هو ترتيب العصبونات او العقد في مستويات او طبقات وشكل الترابط ضمن الطبقات او بينها، بمعنى آخر هي عملية تنظيم العصبونات او العقد في طبقات وكيفية الاتصال بين هذه العصبونات لتكوين الشبكة، فهيكلية الشبكة تعد من أهم الخصائص التي توصف على أساسها الشبكة العصبية الاصطناعية **[2]**. وتصنف الشبكات بحسب عدد المستويات او الطبقات الى صنفين رئيسيين هما **[3]**: شبكات وحيدة المستوى او الطبقة (Single-Level or Layer Networks) هي الشبكات التي تتكون من طبقتين فقط طبقة المدخلات التي تستقبل الإشارة من الخارج، وطبقة المخرجات التي نحصل منها على استجابة الشبكة وتوضع الترابطات بينهما، فهي لا تمتلك طبقة مخفية، وتعد من أبسط تراكيب الشبكات، ومن أمثلة هذه الشبكات شبكة البرسبترون (Perceptron) وشبكة هوبفيلد (Hopfield)، وشبكات متعددة المستويات او الطبقات (Multi-Level or Layer Networks) وهي الشبكات التي تتكون من طبقة المدخلات وطبقة المخرجات إضافة الى أنها تمتلك طبقة مخفية واحدة او أكثر تعمل على زيادة قدرة الشبكة على معالجة المعلومات، ومن الأمثلة عليها شبكة التغذية الأمامية (Feed Forward Neural Network). من عيوب هذه الشبكات أنها تأخذ وقتاً أطول في عملية المعالجة، ولكن ميزتها إيجاد الحل للعديد من المشاكل المعقدة .

ونظراً إلى مرونة الشبكات العصبية الاصطناعية الكبيرة مقارنةً بالطرائق التقليدية المعروفة في هذا المجال فضلاً عن قدرتها على التعلم والتكيف ذاتياً مع أي أنموذج **[1]**، تم في هذه الدراسة استعمالها في تمييز تصنيف مرضى هشاشة العظام من النساء. إذ يعد مرض هشاشة العظام (osteoporosis) من الأمراض الشائعة، اذ تصبح فيه العظام خفيفة وقابلة للكسر بسهولة، ويسمى بالمرض الصامت، لعدم ظهور أية أعراض اوعلامات عادةً حتى تصبح العظام ضعيفة للغاية. وتعرف هشاشة العظام بقلة كثافة العظام وتلف نسيجها الى درجة تجعل العظام مسامية وهشة وقابلة للكسر. ويشار إلى أن النساء أكثر عرضة للإصابة بمرض هشاشة العظام بعد انقطاع الطمث.

2-الشبكات العصبية الاصطناعية:

Artificial Neural Networks

تعرّف الشبكات العصبية الاصطناعية بأنها أنظمة حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة موزعة على التوازي، ومكونة من وحدات معالجة بسيطة، هذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات **(Neurons)** او عقد **(Nodes)** وهي التي لها خاصية عصبية، من حيث أنها تقوم بتخزين المعرفة العملية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الاوزان، اما الخلية العصبية البيولوجية فتتكون من الاجزاء الموضحة في الشكل **(1)**:

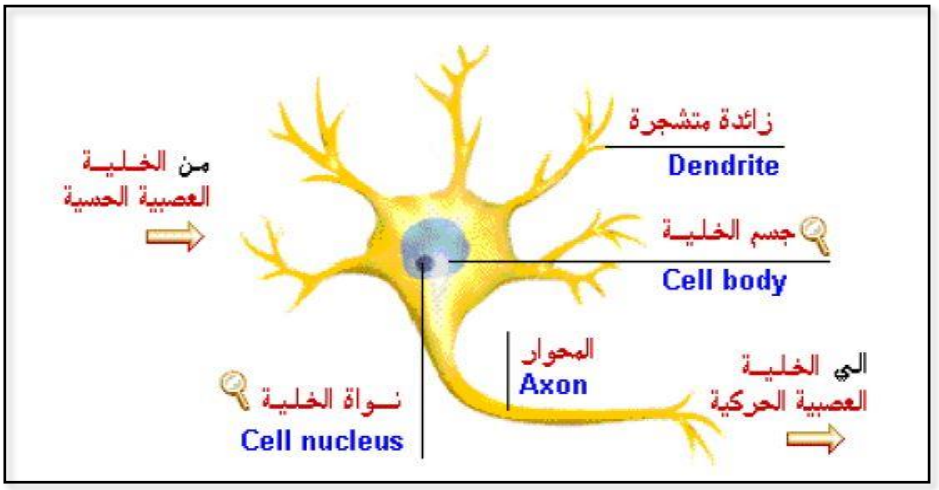

شكل (1) : الخلية العصبية البيولوجية

إذ إن الشبكات العصبية الاصطناعية تتشابه مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب وتخزن هذه المعرفة بإستخدام قوى وصل داخل العصبونات تسمى الاوزان التشابكية، وهناك أيضاً تشابه عصبي حيوي مما يعطي الفرصة لعلماء البيولوجيا في الاعتماد على الشبكات العصبية الاصطناعية لفهم تطور الظواهر الحيوية **[4]**. ومن أهم أهداف الشبكات العصبية الاصطناعية هو فهم كيفية تكوين وتشكيل المميزات الدالية والخصائص الحسابية للدماغ عندما ينجز بعض العمليات مثل الادراك الحسي والتمييز بين الأشياء والتعليم ومحاولة الاستفادة من هذه الخصائص لغرض تحويلها في اتجاه رياضي حسابي قادر على تحليل البيانات والمعلومات ومن ثم التنبؤ . وتستخدم الشبكات العصبية الاصطناعية في عدة مجالات وتطبيقات منها معالجة الاشارة Signal Processing، السيطرة Control ، تمييز الانماط Pattern Recognition، تمييز الكلام Speech Recognition، التنبؤ Forecasting، التصنيف Classification [2] , [3].

(2-1) مكونات الشبكة العصبية الاصطناعية:

Artificial Neural Network Components

إن الشبكة العصبية الاصطناعية تتكون من مجموعة مركبة من عدة عناصر معالجة يطلق عليها اسم عصبونات (Neurons) ولهذه العناصر القدرة على إجراء العمليات الحسابية من خلال مجموعة من الخطوات**[5]**:

تمرّ معالجة البيانات أولا من خلال عناصر المعالجة البسيطة العصبونات (Neurons) .

تمرّ الأشارات بين الأعصاب عبر خطوط الربط الناقلة . يتم إعطاء وزن معين لكل مدخل معين من خلال خطوط الربط ويضرب مع الإشارة الداخلة الى العصبون (Neuron) .ويوضح الشكل (2) أنموذجاً بسيطاً لعصبون اصطناعي .

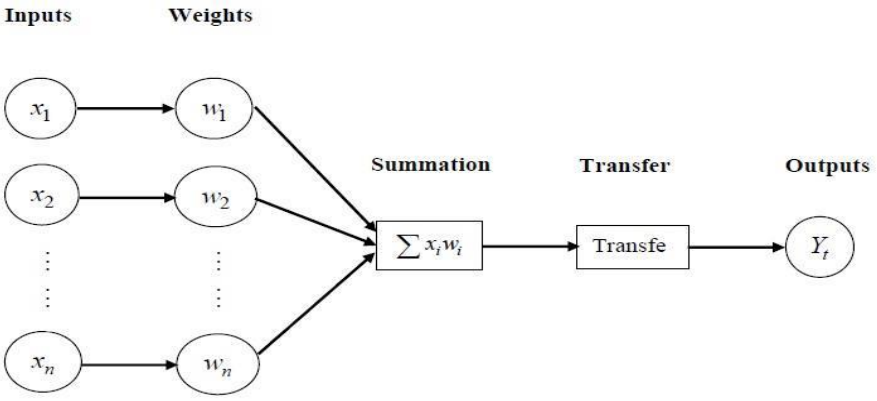

الشكل (2): يوضح أنموذجاً بسيطاً لعصبون اصطناعي

وبمعنى آخر، تتكون الشبكات العصبية الاصطناعية من مجموعة من الخلايا تسمى عصبونات او مجموعة من العقد ترتبط مع بعضها بعضا بوساطة مجموعة موصلات عصبية او مجموعة اوزان، إذ إن الشبكة العصبية الاصطناعية متعددة الطبقات مكونة من ثلاثة مستويات (طبقات)، إذ يمثل المستوى الاول المدخلات والمستوى الثاني يمثل الطبقة او الطبقات المخفية والمستوى الثالث يمثل المخرجات وكل مستوى يتضمن عدداً من العقد وقد ربطت عقد المستويات الثلاثة بخطوط ربط ولكل خط ربط وزن معين[6].

- مستوى المدخلات : (Inputs Level)

هو يمثل المستوى الاول في الشبكة العصبية الاصطناعية ويحتوي على عدد من العصبونات او العقد التي التي تمثل المتغيرات المفسرة (المدخلات) ويتم فيه إدخال المعلومات المراد معالجتها **[7]**. إن عصبونات المعالجة في طبقة المدخلات لا يتم فيها أي معالجة حسابية بل تقوم بنقل المعلومات من هذه الطبقة عبر الوصلات البينية (الاوزان) الى عصبونات المعالجة في الطبقة المخفية او عصبونات المعالجة في طبقة المخرجات إذا كانت الشبكة لا تحتوي على طبقة مخفية، وتحتوي أي شبكة عصبية على طبقة مدخلات واحدة فقط ولكنها قد تحتوي على أكثر من طبقة من طبقات المعالجة [1]. والجدير بالذكر عندما تكون وحدات الإدخال متغيرات توضيحية فأن أنموذج الشبكة العصبية الاصطناعية يكون مشابها لأنموذج الانحدار غير الخطي متعدد المتغيرات وعندما تكون وحدات الإدخال تمثل إزاحات المتغير المعتمد (Lags) فإن أنموذج الشبكة العصبية الاصطناعية سيكون مشابها لأنموذج الانحدار الذاتي غير الخطي **[7]**.

- المستوى المخفي : (Hidden Level)

هو يمثل المستوى الثاني في الشبكة العصبية الاصطناعية وقد يتكون من طبقة واحدة مخفية او عدة طبقات وكل طبقة تحتوي على عدد من العصبونات او العقد ولكل عصبون وزن يربطه مع المستوى السابق (المدخلات) ووزن يربطه مع المستوى اللاحق (المخرجات) إذ يتم في هذا المستوى (الطبقة) معالجة المعلومات ، وقد لا تحتوي بعض تراكيب الشبكات على طبقة مخفية **[7]**.

- مستوى المخرجات : (Output Level)

يُعدّ المستوى الأخير في الشبكة العصبية الاصطناعية ويمثل مخرجات الشبكة العصبية إذ يتم إخراج نتائج المعالجة النهائية الى الوسط الخارجي **[7]**. وقد يحتوي هذا المستوى (الطبقة) على عصبون معالجة واحد او أكثر من عصبون وفقاً للبنية المعمارية للشبكة، إذ تستقبل عصبونات المعالجة في هذه الطبقة الإشارات القادمة من طبقة المدخلات مباشرةً او من الطبقة المخفية وبعد إجراء المعالجات اللازمة ترسل إشارة بالمخرجات كونها مدخلات مرة أخرى للشبكة ذلك عندما لا تتم المعالجة المطلوبة للبيانات، وعادةً تحتوي الشبكة العصبية الاصطناعية على طبقة مخرجات واحدة فقط **[1]**.

- الوصلات البينية (الاوزان) : (Connections)

هي وصلات اتصال بين مستويات (طبقات) الشبكة المختلفة إذ تقوم بربط الطبقات مع بعضها بعضا او ربط العصبونات او العقد داخل كل طبقة عبر الاوزان التي تكون مصاحبة او مرفقة مع كل وصلة بينية، تتمثل وظيفة الوصلات البينية في نقل البيانات او المعلومات او الإشارات بين الطبقات او عصبونات المعالجة **[1]**.

(2-2) مكونات الخلية العصبية الاصطناعية (العصبون):

ان الخلية العصبية الاصطناعية (العصبون) تتألف من **, [4] [1]**.:

1- المدخلات:

تستلم الخلية العصبية الاصطناعية المعلومات من مصادرها المختلفة بحيث يكون لكل مدخل صفة مميزة واحدة، وتحتوي على عدد من وحدات المعالجة مساوٍ لعدد المتغيرات المستقلة التي تعد مدخلات للأنموذج.

2- الاوزان:

يعبر الوزن عن درجة الاهمية النسبية للعنصر المدخل، كما يعدّ الوزن العنصر الرئيسي للشبكة العصبية الاصطناعية في تمثيل الوسائط والروابط المختلفة التي يتم عبرها نقل البيانات من طبقة الى اخرى، وتمثل الاوزان الوسيلة الاساسية لذاكرة الشبكة العصبية من خلال ضبط الاوزان ويرمز للوزن بين وحدتي المعالجة (i) و(j) بالرمز w_{ij}، إذ تؤثر الاوزان في قيم المخرجات ومن الممكن تعديل الاوزان من خلال خاصية التعليم في الشبكة والتي تعرف بدالة التجميع، التي تساعد على ايجاد المجموع المرجح.

3- عنصر المعالجة: وينقسم الى قسمين:

أ- دالة التجميع **(Summation Function)** :

تقوم هذه الدالة بحساب الاوزان النسبية لكل المدخلات الى وحدة المعالجة من خلال ضرب كل مدخل في وزنه، ويتم ايجاد دالة الجمع حسب المعادلة التالية:

$$z_j = \sum_{i=1}^{n} w_{ij}\ x_i \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (1)$$

$$i = 1, 2, \dots\dots, n \qquad\qquad j = 1, 2, \dots\dots, p$$

إذ إن :

z_j : تمثل ناتج الجمع لكل وحدة معالجة **j**.

x_i : تمثل القيمة المدخلة القادمة من الوحدة **i** والداخلة الى الوحدة **j**.

w_{ij} : يمثل الوزن الذي يربط وحدة المعالجة **j** بوحدة المعالجة **i** القادمة من الطبقة السابقة.

ويمكن ان تكتب المعادلة (1) بالشكل التالي:

$$z_j = b_j + \sum_{i=1}^{n} w_{ij}\ x_i \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (2)$$

إذ إن :

b_j : يمثل مقدار التحيز **(bias)** ويعدّ احد مكونات المدخلات إذ إن مدخله يساوي واحداً $(x_0 = 1)$ ويعامل معاملة اي وزن.

ب – دالة التنشيط او التحويل **(Activation Function)** :

هي معادلات رياضـــية تحد من مخرج وحدة المعالجة لذا تسمى بتابع التجميد (Squashing) إذ تجعل المخرج ضمن مدى معين وتتوقف مخرجات الشبكة أساساً على هذه الدوال او التوابع.

4 – دالة المخرجات :

بعد إجراء العمليات الســـابقة تقوم دالة المخرجات باعطاء المخرج النهائي للشـــبكة العصـــبية الاصـــطناعية، وقد تكون المخرجات في أغلب الاحيان مســـاوية لناتج دالة التنشـــيط. ولكن هناك بعض الشـــبكات تقوم وحدة المعالجة فيها بتعديل نتيجة دالة التنشـــيط ويتم ذلك من خلال تنافس وحدات المعالجة المجاورة مع بعضها بعضا ويتم التنافس عادة في وحدات المعالجة التي يكون لها تنشيط أكبر، هذه المنافسة تحدد وحدة المعالجة التي ستكون نشطة والتي تقوم بالاخراج وكذلك تســـاعد المنافســـة في تحديد الوحدات التي سوف تشترك في عملية التعليم والتدريب.

(2-3) دوال التنشيط: (Activation Functions)

هنالك عدة انواع من دوال التنشيط منها **[1]** , **[4]** , **[7]** :

1- الدالة اللوجستية **(Logistic Function)** او دالة السيغمويد **(Sigmoid Function)**

وهي من اكثر الدوال استخداما لسهولة اشتقاقها، إذ تأخذ هذه الدالة قيم المدخلات المحصورة بين $(-\infty , \infty)$ وتجعل المخرجات محصورة بين $(0 , 1)$ وحسب المعادلة التالية:

$$f(z) = (1 + exp(-z))^{-1} \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (3)$$

ومشتقتها:

$$\acute{f}(z) = f(z)[1 - f(z)] \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (4)$$

2- الدالة اللوجستية ثنائية القطب (دالة القطع الزائد المماس)

(Hyperbolic Tangent Function)

وهي مشابهة للدالة اللوجستية وتتمتع بنفس الانسيابية، الا ان قيم المخرجات لها تكون محصورة بين $(-1,1)$ وحسب المعادلة التالية ا:

$$f(z) = tan\, h(z) = \frac{1 - exp(-2z)}{1 + exp(-2z)} \quad \dots\dots\dots\dots\dots\dots\dots\dots (5)$$

ومشتقتها :

$$\acute{f}(z) = sec\, h^2\,(z) = 1 - tan\, h^2\,(z)$$

$$\acute{f}(z) = \left(1 - f^2(z)\right) \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (6)$$

3- دالة العتبة او الخطوة **(Step Function)** :

هذه الدالة تجعل القيمة المخرجة من وحدة المعالجة مساوية للواحد إذا كانت القيمة المدخلة أكبر او مساويةً للصفر وتصبح القيمة المخرجة مساويةً للصفر إذا كانت القيمة المدخلة أصغر من صفر وحسب المعادلة التالية:

$$f(z) = \begin{cases} 1 & if \quad z \geq 0 \\ 0 & if \quad z < 0 \end{cases} \quad \dots\dots\dots\dots\dots\dots\dots\dots (7)$$

4- دالة الاشارة **(Sign Function)** :

وهي دالة من دوال الحد الصلب وتستخدم في وحدات المعالجة للشبكات العصبية المستخدمة في تصنيف وتمييز الانماط، وتستعمل قيمة معينة θ وحسب المعادلة التالية:

$$f(z) = \begin{cases} +1 & if \quad z \geq \theta \\ -1 & if \quad z < \theta \end{cases} \quad \dots\dots\dots\dots\dots\dots\dots (8)$$

5- الدالة الخطية **(Linear Function)**

وهي الدالة التي تكون مخرجاتها مساوية للمدخلات الموزونة لوحدة المعالجة. وحسب المعادلة التالية:

$$f(z) = z \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (9)$$

(2-4) الشبكات العصبية ذات التغذية الأمامية:

Feed Forward Neural Networks

هي مجموعة عصبونات او عقد مرتبة بشكل طبقات، ترتبط هذه العصبونات عادة مع بعضها بحيث يرتبط كل عصبون في طبقة ما بجميع العصبونات في الطبقة التالية إذ تتجه جميع خطوط الربط (الوصلات البينية) في اتجاه واحد نحوالامام دائما من طبقة المدخلات حتى طبقة المخرجات وفي هذه الشبكة لا ترتبط العصبونات مع بعضها في الطبقة نفسها. وهي الشبكات التي تخلومن وجود حلقة مغلقة من الترابطات بين العصبونات المكونة لها، وتتكون من طبقتين على الاقل طبقة مدخلات وطبقة مخرجات وفي كثير من الاحيان توجد طبقة مخفية واحدة على الاقل بينهما، فإذا كانت الشبكات امامية التغذية تحتوي على طبقة مدخلات وطبقة مخرجات فقط يطلق عليها شبكات عصبية امامية التغذية وحيدة الطبقة **[2] , [8] , [9]** وكما في الشكل (3).

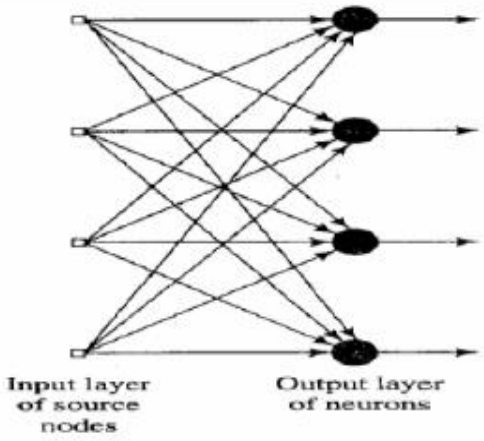

الشكل (3) **: يوضح هيكل شبكة عصبية امامية التغذية وحيدة الطبقة**

وإذا احتوت الشـــبكات امامية التغذية على الاقل طبقة مخفية واحدة فإنها تصـبح شـبكات أمامية التغذية متعددة الطبقات [9] وكما هو موضح في الشكل (4).

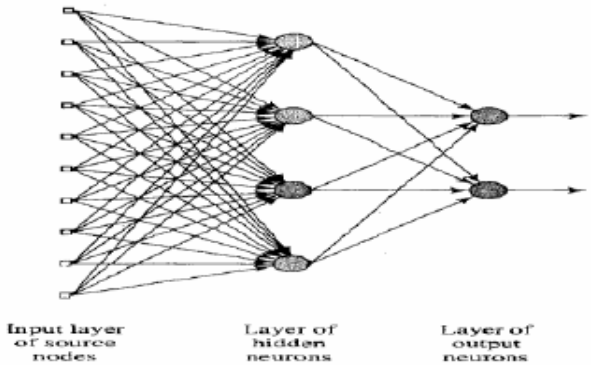

الشكل (4) **: يوضح هيكل شبكة عصبية امامية التغذية متعددة الطبقات.**

ومن امثلة هذه الشبكات شبكة البرسبترون (Perceptron) التي تعد من اهم شبكات التغذية الامامية فهي مصـممة على اسـاس عمل المخ البشـري في التعرف على العينات، واحد اسـتعمالاتها هو تمييز وتصنيف المشاهدات **[1]**، لذا سوف يتم استعمالها في الجانب التطبيقي من هذا البحث.

إن فكرة تعليم او تدريب الشـبكات العصـبية الاصـطناعية تم استيحاؤها من قدرة الانسـان على التعلم والتدرب من التجارب التي يمر بهـا، وبهذا يمكن ان يعلم نفســـه حتى الوصـــول الى حـالـة الاسـتقرار، وتعليم الشـبكات العصـبية وتدريبها بالأسـلوب نفسـه يمكنها من القدرة على التعلم حتى الوصول الى مخرجات باقل خطأ ممكن، وذلك عن طريق إعطائها مجمو عة من الأمثلة التي تكون مختـارة بعنـايـة والتي تســـمى بعينـة التـدريـب. وعمليـة التعليم في الشـــبكات العصـــبية تتم من خلال التغير المســـتمر في قيم اوزان الروابط بين العصبونات وقيم التحيز **[1] , [4]**. وهناك عدة طرائق لتعليم وتـدريـب الشـــبكـات ومنهـا طريقـة التعليم بواســـطـة معلم (Supervised Learning) وهي الاكثر شـــيوعا إذ تعني وجود معلم يعلم الشبكة العصبية الاصطناعية على المخرج المستهدف او المطلوب لكل من المدخلات، ويتم ذلك عن طريق إدخـال بيانـات التدريب على هيئة زوج من الأشـكال، هما الشـكل المدخل Input والشكل المخرج Target، ويتم مقارنة المخرج الفعلي مع المخرج المطلوب من أجل تحديث الاوزان للوصـــول الى مخرجات بأقل خطأ ممكن. ومن أهم الخوارزميات المستعملة لهذا النوع من التعليم او التدريب خوارزمية الانتشار العكسي للخطأ **[4]**.

خوارزمية الانتشار العكسي للخطأ :

Error Back Propagation Algorithm

ان الهدف من خوارزمية الانتشار العكسي للخطأ هوالحصول على اقل خطأ تدريب وبالنتيجة الحصـول على الاوزان المثلى التي يمكن الاعتماد عليها في عملية التنبؤ او التصـنبف لبيانات جديدة لم تخضـــع للتـدريـب او التعليم، مع العلم ان قيم الاوزان الابتـدائيـة (Initializing Weight) عنـد بـدء عمليـة التـدريـب تؤخـذ قيمـاً عشـوائية يتم توليدها من توزيعات احصـائية. ان عملية التدريب او التعليم باسـتعمال خوارزمية الانتشـار العكسـي للخطأ تعد من اكثر الطرائق شيوعا واهمية وتستعمل في تدريب او تعليم الشبكات ذات التغذية الامامية والشبكات ذات التغذية الخلفية **[10]**.

وتتضـمن عملية تدريب الشـبكة العصـبية الاصـطناعية باسـتعمال الانتشار العكسي ثلاث مراحل وهي **[11]**:

1- مرحلة الانتشار الامامي لعينات التدريب Foreword Stage

2- مرحلة الانتشار الخلفي للخطأ Backpass Stage

3- مرحلة تحديث اوزان الشبكة Foreword Stage

ويمكن ايجاز عمل خوارزمية الانتشـار العكسـي للخطأ بالخطوات الآتية **[8]**:

1- توليد قيم اولية للاوزان من إحدى التوزيعات الإحصـــائية او اختيار قيم صغيرة جداً لهذه الاوزان.

2- يسـتقبل كل عصـبون في طبقة المدخلات إشـارة إدخاله، إذ ان $(x_i ; i = 1, 2, \dots \dots, n)$ ثم إرسالها الى جميع عصبونات الطبقة المخفية.

3- يجمع كل عصـــبون في الطبقة المخفية قيم إشـــارات إدخاله الموزونة وحسب المعادلة التالية:

$$z_j = w_{0j} + \sum_{i=1}^{n} x_i \, w_{ij} \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (10)$$

$$j = 1, 2, \dots\dots, p$$

إذ إن:

z_j : يمثل دالة الجمع لكل عصبون في الطبقة المخفية.

w_{0j}: يمثل قيمة التحيز المرتبطة بجميع عصبونات الطبقة المخفية ذات الدليل j.

w_{ij} : اوزان طبقة المدخلات الى الطبقة المخفية .

بعد ذلك تطبق دالة التنشيط لايجاد قيمة اشارة المخرج من كل عصبون في الطبقة المخفية وحسب المعادلة التالية:

$$Z_j = f(z_j - \theta_j) \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (11)$$

إذ إن:

Z_j : يمثل دالة التنشيط لكل عصبون في الطبقة المخفية.

θ : تمثل العتبة Threshold (دالة غير خطية تعرف بدالة التنشيط يتم بواسطتها معالجة مخرجات كل عصبون).

وتتجه قيم دالة التنشيط الى عصبونات طبقة المخرجات جميعها.

4- يجمع كل عصبون في طبقة المخرجات قيم اشارات ادخاله الموزونة $(y_k ; k = 1, 2, \dots\dots, m)$ وحسب المعادلة التالية:

$$y_k = w_{0k} + \sum_{j=1}^{p} z_j \, w_{jk} \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (12)$$

$$k = 1, 2, \dots\dots, m$$

إذ إن:

y_k : يمثل دالة الجمع لكل عصبون في طبقة المخرجات.

w_{0k}: يمثل قيمة التحيز المرتبطة بجميع عصبونات طبقة المخرجات ذات الدليل k.

w_{jk} : اوزان الطبقة المخفية الى طبقة المخرجات.

وبعد ذلك نطبق دالة التنشيط لإيجاد قيمة إشارة المخرج لكل عصبون في طبقة المخرجات وحسب المعادلة التالية:

$$Y_k = f(y_k - \theta_k) \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (13)$$

إذ إن:

Y_k : يمثل دالة التنشيط لكل عصبون في طبقة المخرجات.

5- يحســب الخطأ (E_k) لعصــبونات طبقة المخرجات عن طريق الفرق بين مخرجات العصــبونات(Y_k) والقيمة الحقيقة للعصــبون (a_k) وحسب المعادلة التالية:

$$E_k = (a_k - Y_k) \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (14)$$

ثم مقارنة مخرجات الشبكة العصبية مع القيم الحقيقية لتقدير الخطأ وحسب المعادلة التالية:

$$\delta_k = (a_k - Y_k) * \acute{f}(y_k - \theta_k) \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots (15)$$

إذ إن:

δ_k : عامل تصحيح الخطأ لتوليف الوزن .

ثم نجد التغير في حجم الخطأ Δw_{jk} وحسب المعادلة التالية:

$$\Delta w_{jk} = \eta * \delta_k * Z_j \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (16)$$

إذ أن:

η :تمثل معدل التعليم (Learning Rate)، وتستعمل للتحكم في توليف الوزن خلال كل خطوة في مرحلة التدريب.

ثم ايجاد حد تصحيح التحيز (المستخدم لتحديث الوزن w_{0k}) وحسب المعادلة التالية:

$$\Delta w_{0k} = \eta * \delta_k \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (17)$$

6- يجمع كل عصبون في الطبقة المخفية اشارات المدخلات الموزونة ل(δ) وحسب المعادلة التالية:

$$\Delta_j = \sum_{k=1}^{m} \delta_k \, w_{jk} \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (18)$$

ونضرب هذه القيمة بمشتقة دالة تنشيطها لحساب (δ_j) وحسب المعادلة التالية:

$$\delta_j = \Delta_j * \acute{f}(z_j - \theta_j) \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (19)$$

إذ إن:

δ_j: عامل تصحيح الخطأ لتوليف الوزن .

ثم يتم ايجاد التغير في حجم الخطأ Δw_{ij} وحسب المعادلة التالية:

$$\Delta w_{ij} = \eta \cdot \delta_j \cdot x_i \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (20)$$

بعد ذلك يتم ايجاد حد تصحيح التحيز (المستخدم لتحديث الوزن w_{0j}) وحسب المعادلة التالية:

$$\Delta w_{0j} = \eta \cdot \delta_j \quad \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (21)$$

7- تحدث الاوزان والتحيزات لكل عصبون في طبقة المخرجات وحسب المعادلة التالية:

$$w_{jk}(new) = w_{jk}(old) + \Delta w_{jk} \quad \dots\dots\dots\dots\dots\dots\dots\dots (22)$$

وكذلك تحدث الاوزان والتحيزات بالنسبة لكل عصبون في الطبقة المخفية وحسب المعادلة التالية:

$$w_{ij}(new) = w_{ij}(old) + \Delta w_{ij} \quad \dots\dots\dots\dots\dots\dots\dots\dots (23)$$

وبعد ذلك تطبق دالة تنشيطها لتقدير عصبونات الطبقة المخفية.

8- تستمر الشبكة في تحديث الاوزان لغاية الحصول على الاوزان المثلى، ثم الوصول الى المخرجات المرغوب فيها، اي التوصل الى افضل توفيق للأنموذج قيد البحث.

وان المخطط الانسيابي لخوارزمية الانتشار العكسي للخطأ موضح في الشكل (5).

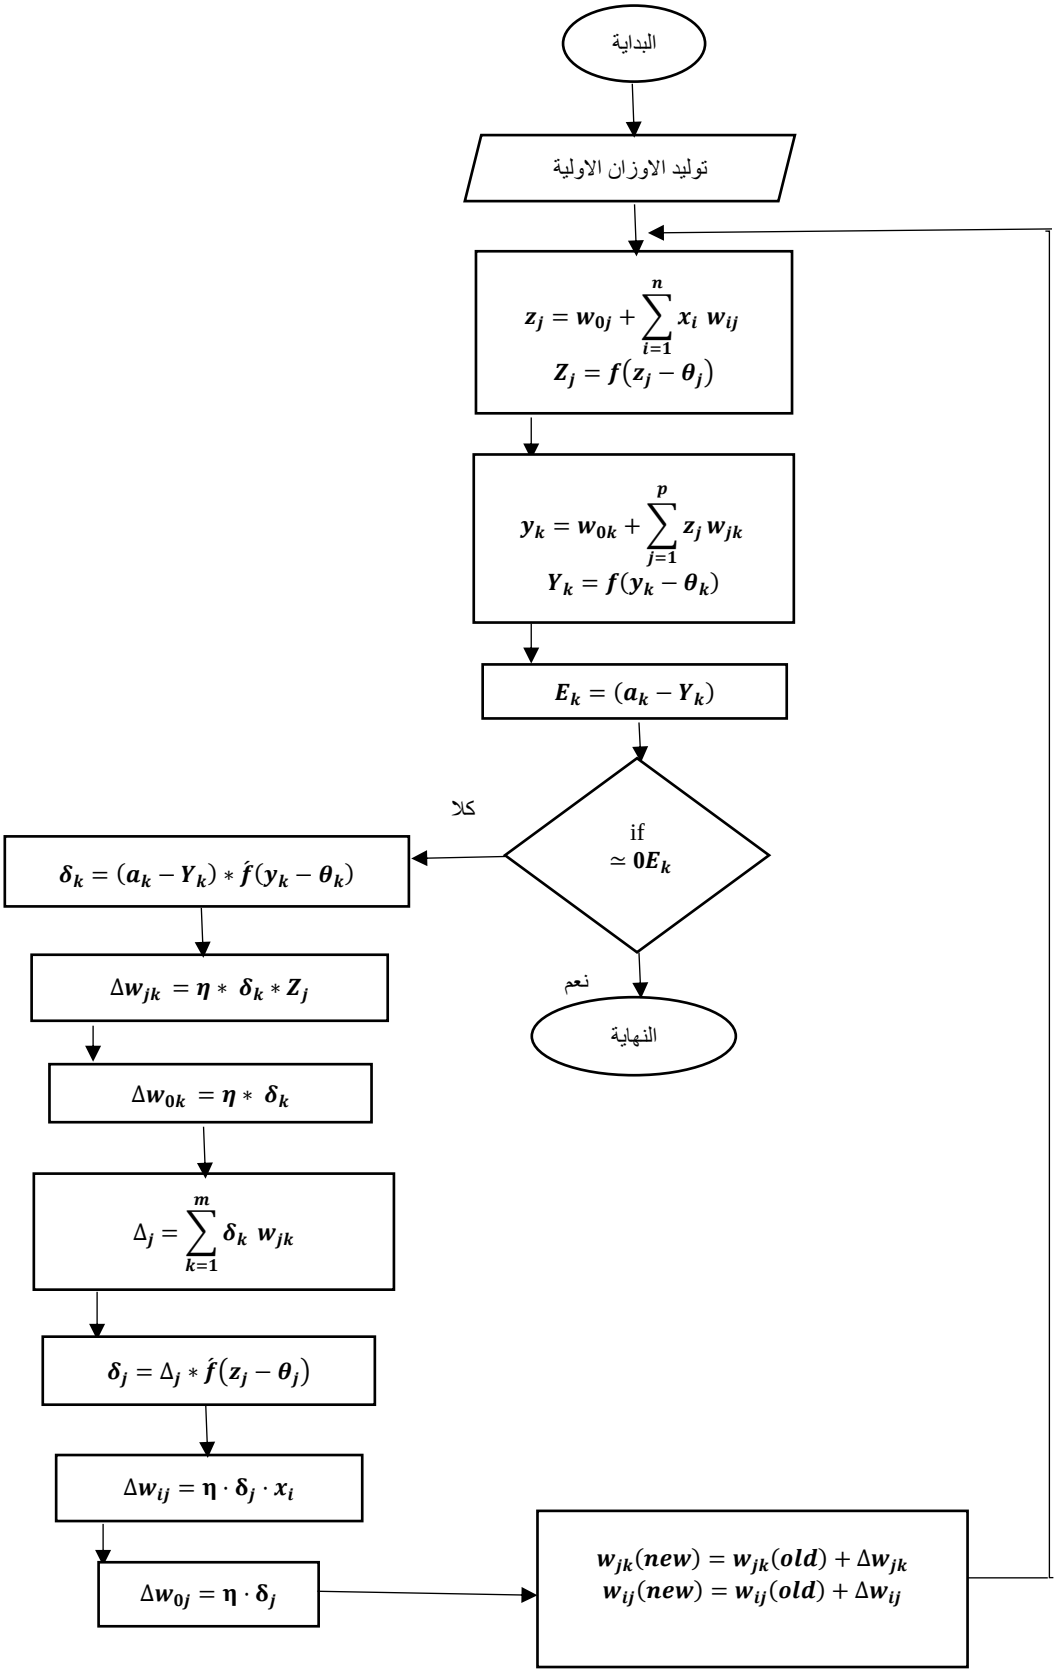

الشكل (5) : يوضح المخطط الانسيابي لخوارزمية الانتشار العكسي للخطأ

3- وصف عينة البحث واسلوب جمع البيانات والمتغيرات المستخدمة:

تم اعتماد نتائج اختبار كثافة العظام عبر مقياس امتصاص الأشعة السينية ثنائي البواعث (DEXA) لمجموعة من النساء في مستشفى بغداد التعليمي العائد الى إدارة مدينة الطب لعامي (2019) و(2020)، واشتملت بيانات البحث على عينة مؤلفة من (309) مشاهدة، إذ تم سحب عينة من المجتمع الاول (النساء اللواتي أجرين اختبار كثافة العظام وكانت النتيجة غير مصابات بمرض هشاشة العظام) بحجم (144) مشاهدة، ومن المجتمع االثاني (النساء اللواتي أجرين اختبار كثافة العظام وكانت النتيجة مصابات بمرض هشاشة العظام) بحجم (165) مشاهدة، وهذان المجتمعان يمثلان المتغير المعتمد (Y) إذ أُعطي الرمز (0) للمجتمع الاول والرمز (1) للمجتمع الثاني، وكان عدد المتغيرات التوضيحية (المستقلة) خمسة متغيرات. ويمكن توضيحها بالنحو الآتي:

X_1: العمر بالسنوات. (متغير كمّي)

X_2: عدد السنوات التي مضت على سن اليأس. (متغير كمّي)

X_3: الوزن (كغم). (متغير كمّي)

X_4: الطول (بالمتر). (متغير كمّي)

X_5 : هل كان سن اليأس مبكراً، (نعم=1)، (كلا=2) ؟ (متغير نوعي)

إذ يعد سن اليأس مبكراً إذا لم يتجاوز عمر المرأة (45) عاماً.

4- تحليل البيانات باستعمال الشبكات العصبية الاصطناعية:

إن الطريقة التي تم استعمالها في بناء أنموذج الشبكة العصبية الاصطناعية من خلال البرنامج الاحصائي الجاهز (SPSS.23) هي (Multilayer Perception) التي تعتمد على خوارزمية الانتشار العكسي للخطأ في تحديث وضبط اوزان الوصلات البينية للحصول على أقل خطأ تصنيف ممكن، وبعد عدة محاولات كان الهدف منها الحصول على أفضل نسبة تصنيف صحيح، تم تحديد حجم عينة التدريب وحجم عينة الاختبار، كما تم تحديد وحدات طبقة المدخلات (المتغيرات التوضيحية) وتهيئة وتحويل بيانات المتغيرات الى الصيغة الطبيعية(Normalized) وتحديد عدد الطبقات المخفية وعدد الوحدات فيها، فضلاً عن تحديد وحدات طبقة المخرجات، كما تم تعيين دوال التنشيط في وحدات الطبقة المخفية وطبقة المخرجات وكما هو موضح في الجدولين (1) و(2) التاليين:

جدول (1) : يبين حجم عينة التدريب وعينة الاختبار

		N	Percent
Sample	Training	211	68.3%
	Testing	98	31.7%
Valid		309	309
Excluded		0	0
Total		309	309

*المصدر : الباحثان من تحليل البيانات

يبيّن الجدول (1) أن حجم عينة التدريب 211 مشاهدة بنسبة 70 % تقريبا وحجم عينة الاختبار 98 مشاهدة بنسبة 30 % تقريبا من حجم العينة الكلي البالغ 309 كما هو يوضح الجدول عدم وجود مشاهدات مستبعدة (Excluded).

جدول (2) : يبين معلومات الشبكة العصبية الاصطناعية

Input Layer	**Factors**	1	X5
	Covariates	1	X1
		2	X2
		3	X3
		4	X4
	Number of Units[a]		6
	Rescaling Method for Covariates		Normalized
Hidden Layer(s)	**Number of Hidden Layers**		1
	Number of Units in Hidden Layer 1[a]		3
	Activation Function		Sigmoid
Output Layer	**Dependent Variables**	**1**	Y
	Number of Units		2
	Activation Function		Sigmoid
	Error Function		Sum of Squares

*المصدر : الباحثان من تحليل البيانات

يبيّن الجدول (2) وفي الجزء الخاص بطبقة المدخلات (Input Layer) أن هناك متغيرا له عدة مستويات اومعامل (Factors) وهو المتغير النوعي (X_5) (هل كان سن اليأس مبكرا؟) اما باقي المتغيرات فهي متغيرات كمية يعبر عنها بـ (Covariate) وهي المتغيرات العمر (X_1) وعدد السنوات التي مضت على سن اليأس (X_2) والوزن (X_3) والطول (X_4)، كما نلاحظ بطبقة المدخلات وجود ست وحدات ادخال (Number of Units) وأن صيغة تحويل البيانات هي الصيغة الطبيعية (Normalized) ، اما الجزء الخاص بالطبقة المخفية فنلاحظ ان هناك طبقة مخفية واحدة (Number of Hidden Layers) تتكون من ثلاث وحدات معالجة (Number of Units in Hidden) وان دالة التنشيط (Activation Function) المستخدمة هي دالة السيغمويد (Sigmoid)، كما يتضح وجود متغير تابع (Y) واحد، اما الجزء الاخير الخاص بطبقة المخرجات فنجد هناك طبقة مخرجات (Output Layer) واحدة تحتوي على وحدتي معالجة، وان دالة التنشيط المستخدمة في وحدتي هذه الطبقة هي دالة السيغمويد (Sigmoid) ايضاً، ودالة خطأ هي (Sum of Squares).

(4-1) اوزان الوصلات البينية بين طبقات الشبكة العصبية الاصطناعية بعد ادخال جميع المتغيرات التوضيحية:

باستعمال خوارزمية الانتشار العكسي للخطأ وبالاعتماد على المعادلات من (10) الى (23) تم تحديث وضبط اوزان الوصلات البينية بين وحدات الطبقات وكما هي موضحة في الجدول (3) التالي:

جدول (3) : يبين اوزان الوصلات البينية بين وحدات الطبقات

تقدير المعلمات						
Predictor		Predicted				
		الطبقة المخفية 1			طبقة المخرجات	
		H(1:1)	H(1:2)	H(1:3)	[Y=.00]	[Y=1.00]
طبقة المدخلات	(Bias)	1.844	-0.448	1.115		
	[X5=1.00]	0.916	-0.113	0.773		
	[X5=2.00]	0.856	-0.859	0.456		
	X1	-2.640	2.247	-0.266		
	X2	-2.713	4.316	3.080		
	X3	2.374	-6.204	-6.261		
	X4	1.482	-3.366-	-1.394		
الطبقة المخفية 1	(Bias)				3.340	-3.177
	H(1:1)				-2.277	2.065
	H(1:2)				-1.462	1.311
	H(1:3)				-5.334	5.232

*المصدر : الباحثان من تحليل البيانات

يبين الجدول (3) اوزان الوصلات البينية بين وحدات طبقة المدخلات ووحدات الطبقة المخفية، كما يبين ايضا اوزان الوصلات البينية بين وحدات الطبقة المخفية ووحدات طبقة المخرجات.

(4-2) معمارية الشبكة العصبية الاصطناعية:

ان الشكل (6) الآتي يوضح معمارية الشبكة العصبية الاصطناعية المستخدمة في هذه الدراسة.

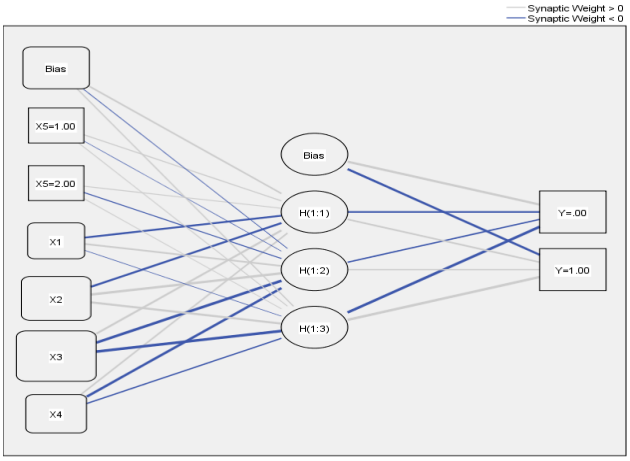

الشكل (6) : يوضح معمارية الشبكة العصبية الاصطناعية

يوضح الشكل (6) ان معمارية الشبكة الاصطناعية المستخدمة في هذا البحث تتكون من ثلاث طبقات وهي طبقة المدخلات (Input Layer) التي تحتوي على ست وحدات معالجة فضلاً عن وحدة التحيز (Bias)، والطبقة المخفية (Hidden Layer) التي تحتوي على ثماني وحدات معالجة فضلاً عن وحدة التحيز (Bias)، وطبقة المخرجات (Output Layer) التي تظهر فيها نتيجتان للشبكة هما (النساء اللواتي أجرين فحص كثافة العظام وكانت النتيجة عدم الاصابة بمرض هشاشة العظام Y=0) و(النساء اللواتي أجرين فحص كثافة العظام وكانت النتيجة الاصابة بمرض هشاشة العظام Y=1).

(4-3) الاهمية النسبية لجميع المتغيرات التوضيحية:

الجدول (4) الآتي يبين الاهمية النسبية للمتغيرات التوضيحية التي تم ادخالها الى الشبكة العصبية الاصطناعية عبر وحدات طبقة المدخلات.

جدول (4) : يبين الاهمية النسبية للمتغيرات التوضيحية

	Importance	Normalized Importance
X5	0.039	8.2%
X1	0.066	13.9%
X2	0.288	60.9%
X3	0.473	100.0%
X4	0.134	28.4%

*المصدر : الباحثان من تحليل االبيانات

يبين الجدول (4) ان المتغير الاكثر اهمية وتأثير في عملية التصنيف باستعمال الشبكة العصبية الاصطناعية هومتغير الوزن (X_3) بنسبة 47.3 % ، ثم يليه متغير عدد السنوات التي مضت على سن اليأس (X_2) بنسبة 28.8 %، ومتغير الطول (X_4) بنسبة 13.4%، ثم يليه متغير العمر (X_1) بنسبة 6.6 %، واخيرا المتغير النوعي (X_5) (هل كان سن اليأس مبكرا؟) بنسبة 3.9 %.

(4-4) تصنيف المشاهدات:

يبين الجدول (5) الآتي نتائج تصنيف المشاهدات الى المجتمع الاول (النساء اللواتي أجرين فحص كثافة العظام وكانت النتيجة عدم الاصابة بمرض هشاشة العظام Y=0) والمجتمع الثاني (النساء اللواتي أجرين فحص كثافة العظام وكانت النتيجة الاصابة بمرض هشاشة العظام Y=1) ونسبة التصنيف الصحيح في عينة التدريب وعينة الاختبار فضلاً عن نسبة التصنيف الصحيح الكلية.

جدول (5) : يبين تصنيف المشاهدات

العينة	المشاهدة	التوقع		
		المجتمع الاول	المجتمع الثاني	النسبة المئوية الصحيحة
التدريب	المجتمع الاول	72	24	75.0%
	المجتمع الثاني	36	79	68.7%
	النسبة المئوية الاجمالية	51.2%	48.8%	71.6%
الاختبار	المجتمع الاول	40	8	83.3%
	المجتمع الثاني	13	37	74.0%
	النسبة المئوية الاجمالية	54.1%	45.9%	78.6%

*المصدر : الباحثان من تحليل البيانات

يبين الجدول (5) ان نسبة تصنيف المشاهدات التي تم تصنيفها بشكل صحيح الى المجتمع الاول بلغت 75.0 % في عينة التدريب فيما بلغت نسبة التصنيف الصحيح في عينة الاختبار 83.3 %، وان نسبة المشاهدات التي تم تصنيفها بشكل صحيح الى المجتمع الثاني بلغت 68.7 % في عينة التدريب فيما بلغت في عينة الاختبار 74.0 %، كما ان نسبة التصنيف الصحيح الكلية قد بلغت 78.6 %.

5- الاستنتاجات: Conclusions

بناءً على ما تم عرضه في الجانب النظري والنتائج التي تم التوصل إليها في الجانب التطبيقي، تم استنتاج ما يلي:

1- امكانية استعمال اسلوب الشبكات العصبية الاصطناعية (شبكة البرسبترون متعددة الطبقات ذات التغذية الامامية) في تمييزوتصنيف مرضى هشاشة العظام من النساء، إذ بلغت نسبة التصنيف الصحيح الكلية 78.6 % .

2- تبين من خلال استعمال الشبكات العصبية الاصطناعية ان اهم متغير له تأثير في عملية تصنيف مرضى هشاشة العظام من النساء هو متغير الوزن، يليه متغير عدد السنوات التي مضت على سن اليأس، ثم المتغيران الطول والعمر بشكل اقل ثم المتغير النوعي (هل كان سن اليأس مبكرا؟).

6- التوصيات: Recommendations

بناءً على الاستنتاجات المذكورة آنفا ندرج فيما يلي اهم التوصيات وكالتالي:

1- نوصي باستعمال تقنية الشبكات العصبية الاصطناعية لاغراض التمييز والتصنيف في المجالات الاقتصادية والاجتماعية والزراعية ومجالات اخرى.

2- نوصي باستعمال الشبكات العصبية الاصطناعية ذات الدالة الشعاعية في عملية التصنيف.

3- نوصي بزيادة عدد المتغيرات في الدراسات المستقبلية التي تخص مرض هشاشة العظام لدى النساء ليشمل (التأريخ العائلي، العرق، طبيعة الرضاعة، عدد الاولاد، الاصابة بمرض السكري، الاصابة بمرض الروماتزم، مشاكل الغدة الدرقية، طبيعة الغذاء، ممارسة الرياضة، التعرض لاشعة الشمس وغيرها).

4- ضرورة انشاء قاعدة بيانات متكاملة في المستشفيات الحكومية والاهلية لتشمل معلومات اضافية عن النساء المصابات بمرض هشاشة العظام.

5- ضرورة اجراء فحص كثافة العظام بعد سن اليأس للتأكد من الاصابة بمرض هشاشة العظام من عدمه كونه مرضاً صامتاً وخطيراً.

المصادر

[1] المولى، علي ابشـــر فضـــل (2015). "المقارنة بين التحليل التمييزي والنموذج اللوجســـتي الثنائي ونماذج الشـــبكات العصـــبية في تصـــنيف المشـــاهدات (بالتطبيق على دراســـة العوامل المؤثرة على كفاية دخل الاســـرة) " ، اطروحة دكتوراه، جامعة السودان للعلوم والتكنولوجيا.

[2] عيســـى، علام زكي (2000). "الشـــبكات العصـــبية، البنية الهندســـية - الخوارزميات -التطبيقات"، الطبعة الاولى، شعاع للنشر والعلوم، حلب، سوريا.

[3] Moreno, J. J.M., Pol, A. P., Gracia. P. M. (2011). " Artificial Neural Networks Applied to Forecasting time series ", niversidad de las Islas Baleares & Universidad Politecnica cte Cataluna. Vol.23-No. 2 PP. 322-329 ISSN 0214-9915.

[4] الحســـيني، قصـــي حبيب و الســـاعدي، احمد عبد الامير **(2011)**. "مقدمة الشـــبكات العصـــبية"، جامعة الامام جعفر الصادق (ع).

[5] العباســـي، عبد الحميد (2013). "مقدمة الشـــبكات العصـــبية الاصطناعية"، معهد الدراسات والبحوث الاحصائية، جامعة القاهرة، مصر.

[6] الناصـــر، عبد المجيد والعبيدي، مروان (2003). "اســـتخدام الشبكات العصبية للتنبؤ المستقبلي لقيم السلاسل الزمنية غير المنتظمـة في طول الموســـميـة"، المجلـة العراقيـة للعلوم الاحصـــائية، المجلد (3)، العدد (6)، جامعة الموصـــل، العراق.

[7] عبد العزيز، بثينة عبد الجادر والوكيل، خولة حسين (2015). "التنبؤ بـالمعدلات الشـــهريـة لـدرجـات الحرارة العظمى و الصـغرى في مدينة بغداد باسـتخدام الشـبكة العصـبية متعددة الطبقات"، مجلة كلية الرافدين الجامعة للعلوم، العدد (16)، الصفحات 62-92.

[8] Gupta, C. (2006). "Implementation of Back Propagation Algorithm (of neural networks) In Vhdl", Department OF Electronics and Communication Engineering, (Deemed University) , Patiala -147004. India.

[9] Haykin, Simon. (1994). "Neural Networks A Comprehensive Foundation" Macmillan College, New York.

[10] عاشـــور، مروان عبد الحميد (2014). "اســـتخدام الشـــبكات العصـــبية الاصـــطناعية المحســـنة ونماذج بوكس-جنكيز في تحليل الســـلاســـل الزمنية"، اطروحة دكتوراه في الاحصـــاء التطبيقي، كلية الدراســـات العليا، جامعة الســـودان للعلوم والتكنولوجيا.

[11] Idown. P. A., Osakwe, C., Kayode, A. A., and Adagunodo, E. R. (2012). "Prediction of Stock Market in Nigeria Using Artificial Neural Network", Published Online October 2012 in MECS (http://www.mecspress.org/), PP. 68-74.