



**إستخدام الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية
في البيانات المالية: دراسة تطبيقية**

**الأستاذ الدكتور أحمد حلمي جمعة
أستاذ المحاسبة والتدقيق (2009)
جامعة الزيتونة الأردنية**

E-mail:ahmed_gomaa61@hotmail.com.

**المؤتمر العلمي السنوي الحادي عشر
ذكاء الأعمال واقتصاد المعرفة**

**جامعة الزيتونة الأردنية, كلية الاقتصاد والعلوم الإدارية
23 - 26 نيسان (إبريل 2012)
عمان - الأردن**



الملخص

هدف الدراسة: استهدفت الدراسة الحالية إختبار أثر تطبيق الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في البيانات المالية للشركات الصناعية المسجلة في البورصة.

أهم النتائج النظرية: أن هناك أهمية لتطبيق الشبكات العصبية الإصطناعية في التدقيق بشكل عام، وفي قضية إكتشاف الأخطاء الجوهرية عند تدقيق البيانات المالية بشكل خاص، حيث أن كثيراً من قرارات المدققين ترتبط ببعضها البعض بشكل متتابع، لذلك فإن هناك تأثير لتطبيق الشبكات العصبية الإصطناعية ليس في تحديد الأخطاء الجوهرية فحسب بل في تحسين القرار اللاحق والذي يرتبط بتخطيط وأداء عملية التدقيق بكفاءة وفعالية.

أهم النتائج التطبيقية: توجد أخطاء جوهرية على مستوى البيانات المالية ككل للشركات الصناعية المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية كانت لبندي النقدية، والذمم الدائنة وأوراق الدفع، أما على مستوى بنود بيان الدخل المختارة فقد كانت اعلى الأخطاء لبندي مصاريف البيع والتوزيع، والمصاريف التشغيلية.

أهم التوصيات: توصي الدراسة المدققين المستقلين بضرورة الحصول على دورات تدريبية وكجزء من التطوير المهني المستمر الإطلاع على المستجدات المهنية، والإستجابة لمطالب المجتمع المالي العالمية بشأن إكتشاف الإخطاء الجوهرية في البيانات المالية وبشكل خاص متابعة التطورات التكنولوجية في مجال صناعة البرمجيات الجاهزة (برمجية Spss) لتفعيل دورهم المهني من خلال تحسين أحكامهم المهنية، لتكون أكثر موضوعية بالأعتماد على الأساليب العلمية- اساليب الذكاء الإصطناعي- لإستعادة ثقة المجتمع المالي في البيانات المالية المدققة.

المصطلحات الدالة: الشبكات العصبية الإصطناعية- الأخطاء الجوهرية- البيانات المالية- المعايير الدولية للتدقيق- الحكم المهني.

البيانات المتاحة: للحصول على التحليل بإستخدام الشبكات العصبية الإصطناعية يرجى مراجعة الباحث.

المقدمة:

يشير مجلس معايير التدقيق والتأكيد الدولي (IAASB) الى أن القيود الكامنة Inherent Limitation لعملية التدقيق لا تعتبر مبرراً لكي يكتفي المدقق بأدلة تدقيق غير مقنعة تماماً، وبالتالي يتم تحديد ما إذا قام المدقق المستقل بعملية التدقيق وفقاً للمعايير الدولية للتدقيق من خلال تقييم (IFAC, IAASB, 2010) ما يلي:

1- إجراءات التدقيق المؤداة في الظروف القائمة.

2- مدى كفاية ومناسبة أدلة التدقيق التي تم الحصول عليها نتيجة لذلك.

3- مدى ملائمة تقرير المدقق بناء على تقييم تلك الأدلة في ضوء الأهداف الكلية له.

كما يشير المجلس (IAASB) في المعيار الدولي للتدقيق (ISA:200) الى أنه نظراً للقيود الكامنة في عملية تدقيق ما، هناك مخاطر لا يمكن تجنبها تتلخص في أن بعض الأخطاء الجوهرية في البيانات المالية قد لا يتم إكتشافها رغم تخطيط وأداء عملية التدقيق بالشكل المناسب، وبالتالي، فإن الإكتشاف اللاحق لخطأ جوهرى ناتج عن غش أو خطأ لا يدل بحد ذاته على إخفاق المدقق في إجراء عملية تدقيق ما وفقاً للمعايير الدولية للتدقيق (IFAC, IAASB, 2010).

لذلك يرى كل من Rezaee و Crumbley ان المدققين الذين يمتلكون يقظة Alertness وحذر Skepticism أكثر، كان يمكنهم منع بعض من حالات فشل التدقيق الأخيرة (Crumbley & Rezaee, 2007)، كما أجرت PricewaterhouseCoopers في عام 2009 مسح عالمي شمل 3000 مستجيب من 54 دولة من مختلف أقطار العالم، ولقد بين نتائج المسح أن 30% من المستجيبين قد سقط ضحية الغش في البيانات المالية، وأن القطاع الصناعي أكثر عرضة للغش من الصناعات الأخرى (PricewaterhouseCoopers, 2009)، كما أكد Zopiatis & Krambia- Kapardis، أن الإقتصاديات الناشئة Emerging Economies تتدو في الخطر الأعلى Higher Risk بسبب الغش (Krambia- Kapardis & Zopiatis, 2010).

وفي إطار ما تقدم يرى البعض أن المدققين يلعبون دوراً مهماً في حماية المستثمرين In Protecting Investors من إستلام المعلومات المالية الخاطئة False، غير الدقيقة Inaccurate وغير المكتملة Incomplete والمضللة Misleading، بينما ليس دورهم إكتشاف التقرير المالي الإحتيالي، ولكن هذا هو المتوقع من قبل الجمهور (Kapardis, Christodoulou & Agathocleous, 2010)، إلا أن كل من Ozkan Gunay & Ozkan أشارا الى أن الأزمة

المالية العالمية الحالية قد جلبت الإنتباه للحاجة الى هندسة معمارية مالية دولية جديدة New International Financial Architecture تستند الى منع الأزمة والتنبؤ بها وإدارتها (Ozkan-Gunay & Ozkan, 2010).

وعلى الرغم مما تشهده المعايير الدولية للتدقيق من تطورات متلاحقة لوضع حد لقضية إكتشاف الأخطاء الجوهرية ليس لأنها تتعلق بشكل شامل بالبيانات المالية ككل أو أنها من المحتمل أن تؤثر على عدة إثباتات، ومن ثم تحديد طبيعة وتوقيت ونطاق إجراءات التدقيق الإضافية اللازمة للحصول على دليل تدقيق كافٍ ومناسب، ولكن الأكثر إثارة كسب أو إستعادة ثقة المجتمع المالي في المهنة، إلا أن الجهود المبذولة من قبل المجلس (IAASB) عبر تاريخه القصير نسبياً (IFAC, IAASB, 2010: IFAC, IAASB, 1995) لا تزال قاصره على إستخدام المنهج الوصفي وتأسيس الحكم المهني في تحديد وتقييم الأخطاء الجوهرية في البيانات المالية مبتعدة تماماً عن إستخدام تكنولوجيا أو تطبيقات الذكاء الإصطناعي في العمل المهني، مما يكون له أكبر الأثر على كفاءة وفعالية عملية التدقيق، بسبب ضعف القرارات اللاحقة (ISA:300-315-330-450-500) لعملية تحديد الأخطاء الجوهرية في البيانات المالية، والناجمة عن إستخدام العينات (ISA:530)، ومستويات الأهمية النسبية (ISA:320)، بناءً على الإجراءات التحليلية (ISA:520) وفي ظل الحكم والحذر المهني (ISA:200).

مشكلة الدراسة:

لقد خفصت الفضائح الإحتيالية Fraudulent Scandals التي حدثت في منعطف القرن الحادي والعشرون ثقة Trust الجمهور وثقة Confidence المستثمرين في التقارير المالية السنوية وخدمات المُدقِّقين بسبب الطمع Greed والأنشطة المالية الإحتيالية (Crumbley & Rezaee, 2007) Fraudulent Financial Activities.

ومع ذلك - لا تزال - تثير قضية إكتشاف الأخطاء الجوهرية عند مستوى البيانات المالية جدلاً واسعاً من قبل المجتمع المالي ليس فقط على نطاق محلي ولكن على نطاق عالمي، فضلاً عن إثارته على كافة المستويات المهنية والأكاديمية ومن قبل الكثير من المستثمرين والمقرضين والحكومات، لأنها لا تعنى - فقط - وجود غش أو إحتيال في البيانات المالية، ولكن الأكثر من ذلك فإنها تدل على ضعف كفاءة الإدارة وربما عدم نزاهتها في أغلب الأحيان، ولكن الأكثر من ذلك فإنها تؤدي الى الإضرار بالإقتصاد القومي للبلاد.

لذلك تعود الكثير من الدعاوي القضائية الى عدم إكتشاف المدققين المستقلين لحالات الغش الداخلي (غش الإدارة والموظفين)، أو الغش الخارجي (غسل الأموال - الموردين - العملاء) - على سبيل المثال - تشير إحصائيات مكتب التحقيق الفيدرالي الأمريكي الى أن قضية الغش أو الإحتيال تكبد الإقتصاد الأمريكي مايقرب من 186 بليون دولار على الأقل سنوياً (مصطفى، 2000)، كما أنها تؤدي الى تخفيض الناتج المحلي الإجمالي ما بين 3% الى 55% في الدول المتقدمة أو النامية على حد سواء (Eichengreen, 1999-2002).

وعليه يشير مجلس معايير التدقيق والتأكيد الدولي (IAASB) في المعيار الدولي للتدقيق (200) الى أنه يمكن للمدقق أن يستخدم أساليب متنوعة لتحقيق الهدف من تحديد وتقييم مخاطر الأخطاء الجوهرية - على سبيل المثال - قد ينتفع المدقق من نموذج يعبر عن العلاقة العامة لمكونات مخاطر التدقيق بإستخدام نماذج رياضية* للوصول إلى مستوى مقبول من مخاطر الإكتشاف، ويرى بعض المدققين أن مثل هذا النموذج مفيد عند تخطيط إجراءات التدقيق، ولإعتبارات عملية قد يتم التعبير عن مخاطر الأخطاء الجوهرية بإستخدام مصطلحات كمية - مثل - النسب المئوية أو مصطلحات غير كمية، وفي أي حالة من هذه الحالات، تعدّ حاجة المدقق لإجراء تحديد مناسب لمخاطر الأخطاء الجوهرية أكثر أهمية من الأساليب المختلفة التي قد يتم إستخدامها في التقييم (IFAC, IAASB, 2010- IFAC, IAASB, 2009).

ونظراً لل صعوبات التي يعانها المدقق من أجل تحديد الأخطاء الجوهرية في البيانات المالية الناتجة عن إستخدام المنهج الوصفي المتبع في إعداد المعايير الدولية للتدقيق وفي إطار تحقيق المصلحة العامة فقد تجدد إتجاه البحث المحاسبي مع بداية العقد الأول من الألفية الثالثة الى استخدام أساليب الذكاء الإصطناعي Artificial Intelligences Techniques، بسبب الحاجة الى

* ملاحظة: هامة: أول نسخة لمعايير التدقيق الدولية وفق التصنيف الجديد (المجموعات) بدأ في 1994/7، مع العلم بأن أول معيار دولي للتدقيق صدر في 1980/1، أما مقدمة المعايير الدولية فقد صدرت في عام 1979/7.

• The auditor may make use of a model that expresses the general relationship of the components of audit risk in mathematical terms to arrive at an acceptable level of detection risk. Some auditors find such a model to be useful when planning audit procedures.

تشغيل المعلومات بأسلوب يحاكي العقل البشري، ومن أهم أساليب الذكاء الاصطناعي المقترح إستخدامها وأكثرها إنتشاراً أسلوب الشبكات العصبية الاصطناعية (Artificial Neural Network Tool (ANNT) حيث تعتبر الشبكات العصبية الاصطناعية إحدى تطبيقات الذكاء الاصطناعي (عبد الهادي، 2000- جاب الله، 2004 - Ozkan- Gunay& Ozkan, 2007 - Koskivaara, 2004- Krambia-Kapardis, Christodoulou & Agathocleous, 2010)، وبناء علي ما تقدم يمكن صياغة مشكلة الدراسة الرئيسية في الإجابة على التساؤل التالي ما تأثير دور الشبكات العصبية الاصطناعية في إكتشاف الأخطاء الجوهرية في البيانات المالية؟

هدف الدراسة:

تهدف الدراسة الحالية بشكل رئيسي إلي إختبار أثر تطبيق الشبكات العصبية الاصطناعية في إكتشاف الأخطاء الجوهرية في البيانات المالية للشركات الصناعية المسجلة في سوق عمان المالي.

أهمية الدراسة:

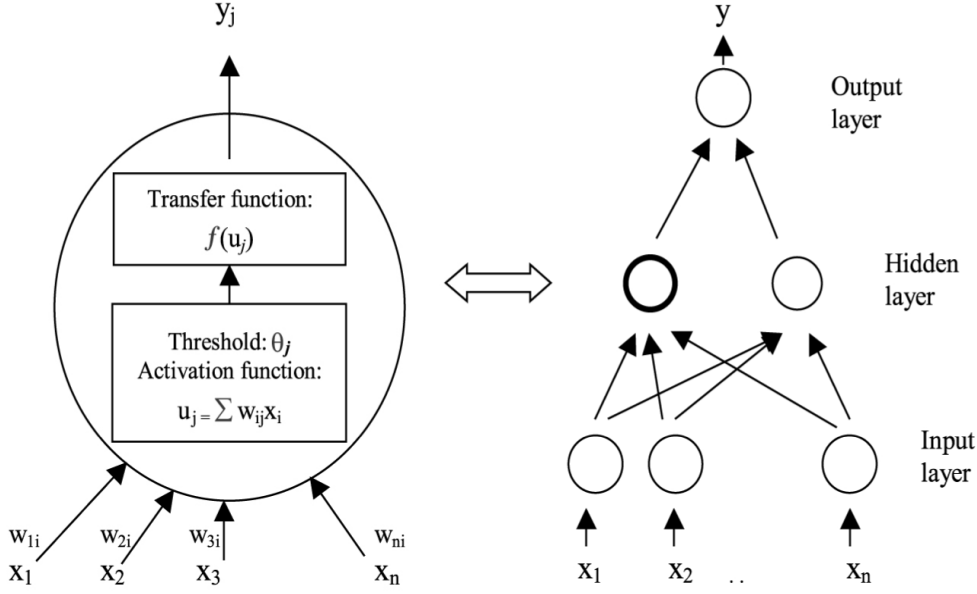
تتبع أهمية الدراسة الحالية من الأهمية التي يستأثر بها موضوع " الأخطاء الجوهرية في البيانات المالية" عالمياً، بالإضافة الي ضعف البناء المعياري المتعلق بهذا الموضوع وعدم قدرة التشريعات المحلية على ردع مثل هذا النوع من الأخطاء، فضلاً عن أن تطوير البحث المحاسبي وتطوير دور المدقق المستقل بشأن إكتشاف الإخطاء الجوهرية مازال يعاني من القصور نتيجة الإلتزام بالمعايير المهنية من جانب أو عدم الإلتزام بها بإعتبارها إرشاد وغير ملزم من جانب آخر، بالإضافة الي أن تطبيق المعايير المهنية ربما لا يؤدي الي أكتشافها على الرغم من الحذر نتيجة للحكم المهني، بالإضافة إلي ما تقدم فإن أهمية الدراسة الحالية تكمن في الأتي:

- 1- جذب إنتباه الباحثين والأكاديمين والمهنيين أو الممارسين الي أهمية إستخدام الشبكات العصبية الاصطناعية عند تدقيق البيانات المالية.
- 2- تقديم منهج لكيفية إستخدام الشبكات العصبية الاصطناعية في الممارسة المهنية.
- 3- إجراء دراسة تطبيقية لإستخدام الشبكات العصبية الاصطناعية على عينة من بنود البيانات المالية في الشركات الصناعية المسجلة في بورصة الأوراق المالية.
- 4- جذب إهتمام المجتمع المالي والمدققين المستقلين ومديري الشركات والمحللين الماليين في شركات الوساطة والباحثين والأكاديمين لدور الشبكات العصبية الاصطناعية في عملية إكتشاف الأخطاء الجوهرية في بنود البيانات المالية.
- 5- إقتراح أفكار جديدة للبحوث المستقبلية.

الخلفية النظرية للدراسة:

طبيعة الشبكات العصبية الاصطناعية:

تعد الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANN) تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة ضخمة موزعة على التوازي، ومكونة من وحدات معالجة بسيطة، هذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات أو عقد (Nodes , Neurons) والتي لها خاصية عصبية حيث أنها تقوم بتخزين المعرفة العملية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان، وحيث أن للإنسان وحدات إدخال توصله بالعالم الخارجي وهي حواسه الخمس، كذلك تحتاج الشبكات العصبية لوحدة إدخال، ووحدات معالجة يتم فيها عمليات حسابية لضبط الأوزان بها، والتي نحصل من خلالها على ردة الفعل المناسبة لكل مدخل من المدخلات للشبكة. لذا تتشابه الشبكة العصبية الاصطناعية مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب وتخزن هذه المعرفة باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية، ولذلك تتكون الشبكات العصبية الاصطناعية من مجموعة من وحدات المعالجة ويسمى أحدها عصبون، والشكل (1) يبين نموذجاً للمعالجة بإستخدام الشبكة العصبية الاصطناعية ذات التغذية الأمامية (Swingler, 2004- Etheridge et al. 2000- Koskivaara, 1996) كما يلي:



a. An artificial neuron

b. A typical feed-forward ANN

الشكل (1) يوضح نموذجاً للمعالجة باستخدام الشبكة العصبية الاصطناعية ذات التغذية الأمامية

نلاحظ من الشكل (1a) أن العصبون أو النيرون يتألف من المدخلات Input : (X_1, X_2, \dots, X_n) ، وقوى الأوزان Weights $W_{1i}, W_{2i}, \dots, W_{ni}$ حيث يعبر الوزن عن شدة الترابط بين عنصر قبله وعنصر بعده؛ والمعالجة Processing : وهذا العنصر يقسم إلى قسمين الأول تابع التنشيط Activation Function أو الجامع أي جمع اشارات المدخلات الموزونة $W_{ij}X_i$ ، وتابع النقل Activation Function، وهذا التابع يحد من مخرجات العصبون لذا قد يسمى بتابع التخميد Squashing حيث يجعل المخرجات ضمن المجال $[0, 1]$ أو ضمن المجال $[-1, 1]$ ، والمخرجات Output : (Y_j) .

أما الشكل (1b) وهوناتج الشكل (1a) فإنه يتألف من طبقة الإدخال (Input Layer) أو المدخلات، و الطبقة الخفية (Hidden Layer) وهذه قد تكون واحدة أو أكثر، وطبقة الإخراج (Output Layer) أو المخرجات.

كما يلاحظ من الشكل (1) أيضاً أن هناك غياب للتغذية العكسية، فضلاً عن عدم وجود تفاعل Interactions بين دوال الطبقات الخفية لذلك تم تسميتها بالشبكات العصبية الاصطناعية ذات التغذية الأمامية (FFANN)، والفكرة هنا ببساطة أن المدخلات تغذي الدوال في الطبقات الخفية، ولا يمكن أن يكون هناك إرجاع خلفي Backward، كما أن دوال الطبقات الخفية تقوم بالتغذية نحو الأعلى إلى طبقة الناتج (المخرجات) وبالتالي لا يوجد أيضاً إرجاع خلفي.

نماذج تعلم الشبكة العصبية Learning modes

تتعلم الشبكة عن طريق إعطائها مجموعة من الحالات، التي يجب أن تكون مختارة بعناية، لأن ذلك سيساهم في سرعة تعلم الشبكة، ومجموعة الحالات هذه تسمى فئة التدريب، لذلك تقسم طرق تعليم شبكة عصبية إلى قسمين حسب فئة التدريب التي تعرض على الشبكة. (Haykin, S., 2009 - Demuth and Beale, 2000- Smith, 1996 - Swingler, 1996- Hertz et al. 1990- Hecht-Nielsen, 1990 - Freeman and Skapura, 1991، هما :

1- طريقة التعلم المراقب (بواسطة معلم) Supervised Learning of ANN's: حيث تقوم طرق التعلم أو التدريب بواسطة معلم للشبكات العصبية الاصطناعية على فكرة عرض البيانات التدريبية أمام الشبكة على هيئة زوج من الأشكال وهما الشكل المدخل Input والشكل المستهدف Target، مع ملاحظة أن التعلم المراقب يمكن أن يتم بواسطة معلم:

1/1 على نمط تصحيح الخطأ: حيث يستخدم هذا النوع من التدريب لتعلم الشبكات الخطية ذات الطبقة الواحدة التي تستخدم لحل مسائل التقابل الخطي بين المدخلات والمخرجات حيث تقوم الشبكة بحساب إشارة الخطأ من خلال الفرق بين مخرجات العصبون والمخرجات المطلوبة، ويتم تعديل قيم الأوزان عن طريق دالة الخطأ المسماة بتابع الكلفة بهدف تصغير الفارق عن طريق اشتقاق هذا التابع بالنسبة للأوزان الشبكية.

2/1 معتمد على الذاكرة : حيث يتم تخزين المعلومات المتوفرة عن البيئة في الشبكة العصبية أي تخزين مجموعة التدريب التي هي شعاع المدخلات وشعاع المخرجات المقابل له ويتطلب هذا النوع من التعلم وجود معيار لتحديد تشابه الأشعاع ووجود قاعدة تعلم.

2- طريقة التعلم غير المراقب (بدون معلم) **Unsupervised learning of ANN's** : حيث تكون فئة التدريب عبارة عن متجه المدخلات فقط دون عرض الهدف على الشبكة، وتسمى هذه الطريقة بالتعلم الذاتي حيث تبني الشبكات العصبية الاصطناعية أساليب التعلم على أساس قدرتها على اكتشاف الصفات المميزة لما يعرض عليها من أشكال وأنساق وقدرتها على تطوير تمثيل داخلي لهذه الأشكال وذلك دون معرفة مسبقة وبدون عرض حالات لما يجب عليها أن تنتجه وذلك على عكس المبدأ المتبع في أسلوب التعلم بواسطة معلم.

إجراءات تصميم الشبكات العصبية الاصطناعية:

يشير بعض الباحثين إلى أن استخدام الشبكات العصبية لا يحتاج إلى المعرفة الكاملة لما يجري بداخلها من أمور فنية حيث أن البرامج المتوفرة في الأسواق حالياً تعطي كل ما يحتاج من قدرة على تصميم وتدريب واختبار وتطبيق الشبكة العصبية (حسين، عبد الباري، 1999- عبد الله، وآخرون، 1995- 1990- Howeel, 1987- Leppmann, 1992- Hart) إلى أن الإجراءات التي يجب إتباعها لنجاح تصميم وبناء الشبكة العصبية الاصطناعية تشمل ما يلي:

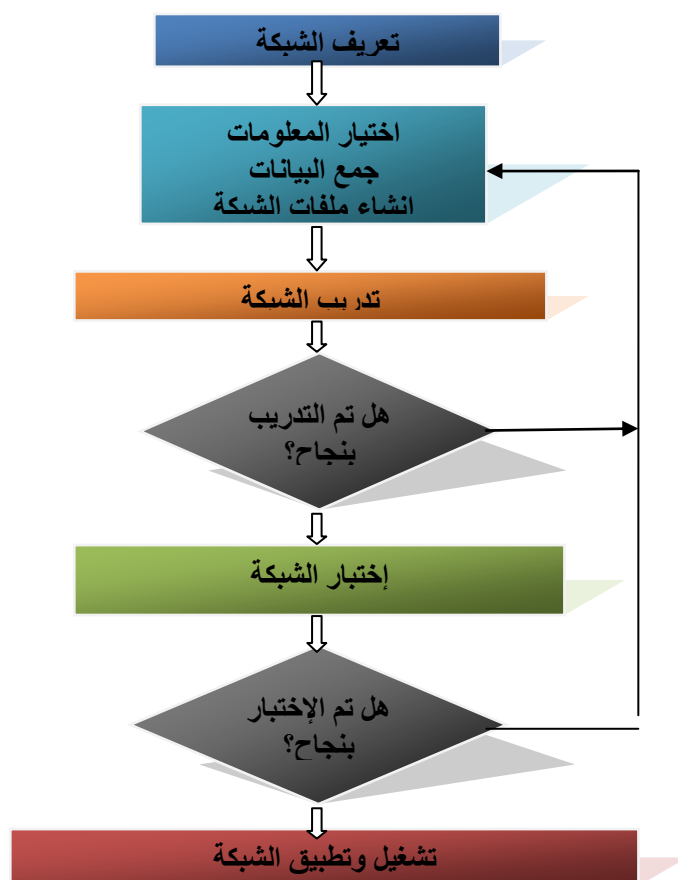
الإجراء الأول: تقرير ما هو الشيء الذي يراد أن تقوم الشبكة العصبية بالتعرف عليه.

الإجراء الثاني: تحديد المعلومات التي يجب على الشبكة إستخدامها والإعتماد عليها في إيجاد المطلوب منها، وهذه المعلومات يجب أن تحتوي عادة على ما هو متوفر ومحدد للمخرج المرغوب حيث أن الشبكات تتعلم عن طريق ربط المدخلات بالمخرجات.

الإجراء الثالث: تجميع معلومات كافية (حالات أو أمثلة) يكون المخرج المرغوب معروف مقدماً، وكلما تم جمع عدد أكبر من الحقائق كلما أمكن تدريب الشبكة بشكل أفضل أي تحديد العدد المناسب من المدخلات والمخرجات لكي تستخدم في الشبكة

الإجراء الرابع: تحديد بعض الأمور الفنية المتصلة بعدد الطبقات الخفية المناسبة، نوع دالة التحويل ومداهها ومعدل التعلم، وأغلب البرامج الجاهزة Spss المتوفرة تقوم هي بالاختيار بشكل عملي ومناسب.

والشكل (5) التالي يوضح الخطوات المتبعة في تصميم الشبكات العصبية كما يلي:



الشكل (2) يوضح خطوات تصميم الشبكة العصبية الاصطناعية

تطبيق الشبكات العصبية الإصطناعية في التدقيق:

لقد تناولت الدراسات المتعلقة بتطبيقات الشبكات العصبية في التدقيق ANN applications in auditing العديد من المناطق الرئيسية، ولقد تمت هذه الدراسات في الولايات المتحدة وفرنلندا وإنجلترا في الفترة من 2000/1990، ومن أهم هذه الدراسات، دراسة (Coakley and Brown, 1991a- Coakley and Brown 1991b - Coakley and Brown, 1993- Wu, 1994 - Coakley,1995, Koskivaara et al., 1996, - Busta and Weinberg, 1998 – Koskivaara, 2000 - Koskivaara, 2000a- Coakley and Brown, 2000)، التي تناولت الأخطاء الجوهرية Material Errors.

ودراسات (Green and Choi, 1997- Fanning and Cogger, 1998- Feroz et al., 2000)، التي تناولت غش الإدارة Management Fraud، ودراسات (Curry & Peel, 1998--Davis, 1996 - Davis, et. Al., 1997- Ramamoorti, et. Al., 1999) التي تناولت تقييم مخاطر الرقابة الداخلية Internal Control Risk Assessment.

وذلك بالإضافة الى دراسات عديدة تناولت موضوع دعم قرارات الإستمرارية Support for Going Concern Decision، والتنبؤ بأتعاب التدقيق Audit Fee Forecasting، ومشكلة الأزمة المالية Financial Distress Problems أو الفشل المالي.

ومع بداية الفترة من عام 2010/2001 ونتيجة لأحداث شركة إنرون للطاقة 2002/2001 وأزمة إفلاس بنك ليمان برازرز 2009/2008، إستعادة ذاكرة الفكر المحاسبي أحداث الغش التي نجمت عنها أزمة الثقة في البيانات المالية، حيث عاد البحث المحاسبي - خاصة - أمريكا - من جديد للمطالبة بتطبيق الشبكات العصبية الإصطناعية في التدقيق فضلاً عن الفشل المالي أهمها دراسات (Spathis, 2002- Lin, et. Al., 2003- Koskivaara, 2004- Wang and Li, 2007- Liou, 2008- Liou and Yang, 2008- Krambia -Kapardis, Christodoulou & Agathocleous, 2010)، أما عربياً فقد ظهر في الأفق دراسات قليلة - حسب علم الباحث- وهي (دراسة جاب الله، 2004- وأرسانيوس، 2006، ولطفي، 2007)، ولعل أهم ما توصلت اليه الدراسات المتعلقة بتطبيق الشبكات العصبية الإصطناعية في التدقيق ما يلي:

- 1- توجد أهمية لإستخدام الشبكات العصبية الإصطناعية في مجالات التنبؤ بالعوائد المتوقعة وتحليل الفرضية المحاسبية الخاصة بالإستمرارية وإكتشاف الغش والخطأ والتنبؤ بحالات الغش المالي، كما أن إستخدام الشبكات العصبية الإصطناعية يحسن من كفاءة عملية التدقيق بشأن أداء إختبارات مراجعة غير ضرورية لشركات لا تحتوى بيانها على غش وهذا بدوره يؤدي الى تحسين كفاءة وفعالية إختبارات التدقيق ومن ثم جودة عملية التدقيق.
- 2- أن هناك تأثير جوهري لإستخدام الشبكات العصبية الإصطناعية في تحسين دقة مخاطر غش الإدارة، كما أن إستخدام الشبكات العصبية له دلالة إحصائية في التنبؤ بحالات الغش في البيانات المالية المضللة، كما أن هناك علاقة بين إستخدام الشبكات العصبية الإصطناعية في التقرير عن البيانات المالية المضللة وبين فجوة التوقعات في التدقيق.
- 3- أن الشبكات العصبية الإصطناعية أكثر قدرة من النماذج الإحصائية التقليدية - مثل- تحليل التمايز في التنبؤ بالأفلاس، وفي التنبؤ بالشركات التي تقاريرها المالية بها تلاعب، وعلى ذلك فأن إستخدام الشبكات العصبية الإصطناعية في مجال المحاسبة والتدقيق يتفوق بصفة عامة على النماذج الإحصائية التقليدية في التعامل مع المشاكل المحاسبية المختلفة.
- 4- أن إستخدام الشبكات العصبية الإصطناعية ذات الطبقات المتعدد في التنبؤ بأرصدة أغلب الحسابات كانت جيدة، كما أن قدرة الشبكات العصبية الإصطناعية على إكتشاف الأخطاء الهامة الناتجة عن المعاملات الوهمية.
- 5- أن إستخدام الشبكات العصبية الإصطناعية غير المحددة (الضبابية) FANN أكثر دقة من الأساليب الإحصائية التقليدية في التنبؤ بالشركات التي يوجد في تقاريرها المالية تلاعب حيث بلغ مستوى الدقة بإستخدام FANN الى 35%، مقابل 5%، كما أن كل من FANN والأساليب الإحصائية التقليدية لها القدرة على تصنيف الشركات التي تخلو تقاريرها المالية من التلاعب.

مما تقدم يتضح أن هناك أهمية لتطبيق الشبكات العصبية الإصطناعية في التدقيق بشكل عام، وفي قضية إكتشاف الأخطاء الجوهرية عند تدقيق البيانات المالية بشكل خاص، ومع ذلك لم يحظى هذا الموضوع في جانبية التطبيقي بإهتمام من قبل الباحثين في المحاسبة في الوطن العربي بقدر ما حظي من إهتمام في الدول المتقدمة خاصة أمريكا، على مدى عقدين من الزمان، مما يزيد من أهمية الدراسة التطبيقية الحالية.

الدراسة التطبيقية:

يجدر - باديء ذي بدء- الإشارة الى أن مجلس معايير التدقيق والتأكيد الدولي (IAASB) قد أكد على أنه يجب على المدقق أن يحدد ويقيم مخاطر الأخطاء الجوهرية عند مستويين الأول على مستوى البيانات المالية؛ والثاني على مستوى الإثبات لفئات الأحداث والمعاملات وأرصدة الحسابات والإفصاحات، وذلك لتوفير أساس لتصميم وأداء المزيد من إجراءات التدقيق، وحيث أن ما تقدم يتم في إطار الحذر المهني والأهمية النسبية، وإعتماداً على الحكم المهني وأخلاقيات المهنة، إلا أنه إستجابة للمتغيرات العالمية والتطورات التكنولوجية في صناعة البرمجيات الرياضية، ومن أجل تحسين الحكم المهني فضلاً عن إكتساب المزيد من ثقة المجتمع المالي، لذلك تم إقتراح إستخدام نماذج الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في البيانات المالية، وهي دوال غير خطية، مع ملاحظة أن الشكل العام لدالة الشبكات العصبية الإصطناعية المستخدمة تتخذ النموذج التالي:

$$Y = F [H[\text{suB}] 1[\text{suB}](X), H[\text{suB}]2[\text{suB}](X), \dots, H_N(X)] + U \dots 1$$

حيث ان: Y: تمثل المتغير التابع Independent Variable - X: تمثل المتغيرات التفسيرية او المستقلة Independent Variable - H - Variable: تمثل دوال الشبكات العصبية (التفعيل - النقل) - u تمثل Error Term حد الخطأ في الدالة، ووفقاً لغة الشبكات العصبية الإصطناعية تسمى مجموعة متغيرات (X) بالمدخلات Input ويسمى المتغير (Y) بالمرجات أوالناتج Output، كما تسمى (H) دلة تنشيط الطبقات الخفية (HLAF) Hidden Layer Activation Function، وتسمى (F) مرجات دالة التحفيز الخفية أو دالة النقل Transfer Function.

مجتمع الدراسة والعينة:

من أجل بيان كيفية تطبيق نموذج الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في البيانات المالية، تم إستخراج البيانات المجمعّة للشركات المساهمة الصناعية والبالغ عددها (85) شركة مقسمة الى (11) قطاع صناعي لخمسة سنوات (2009/2005)، والمنشورة على موقع بورصة عمان عامي 2011/2010، وقد تم إستبعاد (34) شركة لعدم إكمال البيانات المنشورة لها على الموقع منهما قطاعين كاملين، وبالتالي بلغت عينة الدراسة (51) شركة ممثلة لـ (9) قطاعات صناعية حيث تم إجراء الدراسة لجميع القطاعات، ثم لكل قطاع على حده.

أداة ومتغيرات الدراسة:

لقد تم إستخدام نموذج (دالة) Radial Basis Function (RBF)، من نماذج الشبكات العصبية الإصطناعية لأكتشاف الأخطاء الجوهرية في بنود البيانات المالية (بيان الدخل - بيان المركز المالي)، ولذلك فقد تكونت متغيرات الدراسة (10) متغيرات Input (المدخلات) من مجموعتين الأولى تتضمن (5) متغيرات تم إستخراجها من بيانات المركز المالي للشركات، بينما الثانية فقد تضمنت أيضاً (5) متغيرات تم إستخراجها من بيانات الدخل للشركات، وهذه المتغيرات هي:

المجموعة الأولى: متغيرات المركز المالي		المجموعة الثانية: متغيرات الدخل	
X _{bC1}	النقد في الصندوق	X _{iR1}	الإيرادات التشغيلية
X _{bD2}	الذمم المدينة بالصافي	X _{iE2}	المصاريف التشغيلية
X _{bI3}	البضاعة	X _{iMP3}	المصاريف الإدارية والعمومية
X _{bP4}	الذمم الدائنة وأوراق الدفع	X _{iSD4}	مصاريف البيع والتوزيع
X _{bTA5}	إجمالي الأصول	X _{iN5}	صافي الدخل

حيث تم إدخال المتغيرات الخمسة لكل من بيان المركز المالي وبيان الدخل وفقاً للمعادلة التالية:

$$RBF \ x1 \ (MLEVEL=S) \ x2 \ (MLEVEL=S) \ x3 \ (MLEVEL=S) \ x4 \ (MLEVEL=S) \ x5 \ (MLEVEL=S) \\ BY \ company \ / \ RESCALE$$

وأما المتغير التابع (Y) Output الأخطاء الجوهرية في البيانات المالية (الناتج) فقد تضمن المتغيرات التالية:

المجموعة الثانية: متغيرات الدخل		المجموعة الأولى: متغيرات المركز المالي	
الإيرادات التشغيلية	Y_{iR1}	النقد في الصندوق	Y_{bC1}
المصاريف التشغيلية	Y_{iE2}	الذمم المدينة بالصافي	Y_{bD2}
المصاريف الإدارية والعمومية	Y_{iMP3}	البضاعة	Y_{bI3}
مصاريف البيع والتوزيع	Y_{iSD4}	الذمم الدائنة وأوراق الدفع	Y_{bP4}
صافي الدخل	Y_{iN5}	إجمالي الأصول	Y_{bTA5}

مع ملاحظة أنه قد تم إدخال البيانات التاريخية عن الخمسة سنوات لكل شركة © على المحور الرأسي، والمتغيرات (X) Input على المحور الأفقي من خلال برنامج Excel، كما أن البنود المختارة من بيانات المركز المالي هي البنود المتعلقة برأس المال العامل والتي ينعكس تفاعلها معاً سنوياً على البنود المختارة من بيانات الدخل.

فرضيات الدراسة:

على ضوء المتغيرات السابقة تم صياغة فرضيات الدراسة في فرضية رئيسية يتفرع منها فرضيتين فرعيتين، مع مراعاة أنه يمكن إستنباط من كل فرضية فرعية خمسة فرضيات تحليلية وفقاً للبنود، ومن كل فرضية تحليلية يمكن إستنباط خمسة فرضيات لكل قطاع من القطاعات التسعة، وتأسيساً على ما تقدم تم صياغة الفرضية الرئيسية التالية:

الفرضية الرئيسية (H₀): لا يؤثر تطبيق الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في البيانات المالية، ويمكن قياس هذه الفرضية من خلال الفرضيات التالية:

الفرضية الفرعية الأولى (H₀₁): لا يؤثر تطبيق الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في بنود بيانات المركز المالي للشركات الصناعية المسجلة في البورصة.

الفرضية الفرعية الثانية (H₀₂): لا يؤثر تطبيق الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في بنود بيانات الدخل للشركات الصناعية المسجلة في البورصة.

نتائج تطبيق نموذج الشبكات العصبية الإصطناعية:

يجدر - باديء ذي بدء- الإشارة الى أنه إستناداً الى نتائج التحليل باستخدام ANN سيتم تطبيق قاعدة القرار التالية:

قاعدة القرار

The number of hidden units is determined by the testing data criterion: The "best" number of hidden units is the one that yields the smallest error in the testing data.

أي إنَّ عددَ الوحداتِ المخفيةِ مُحدَّدٌ بمعياريِ بياناتِ الإختبارِ: "أفضل" عددٍ في الوحداتِ المخفيةِ الرقمِ الذي أنتجَ الخطأَ الأصغرَ في بياناتِ الإختبارِ.

نتائج تطبيق نموذج الشبكات العصبية الإصطناعية على بنود بيانات المركز المالي:

1- نتائج التطبيق على بنود بيانات المركز المالي لكل الشركات: تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاعات التسعة (51) شركة باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والإختبار للبيانات التاريخية مع مراعاة أن: -Hidden Layer = 9 -Input Layer = 51 -Output Layer -Layer (Dependent Variables) = 5 -Hidden Layer Activation Function: Softmax Activation Function: Identify، والجدول (1) يوضح نتائج التطبيق على بنود بيانات المركز المالي للشركات ككل كما يلي:

الجدول (1) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للشركات ككل

Y_{bTA5}	Y_{bP4}	Y_{bI3}	Y_{bD2}	Y_{bC1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.420	.545	.463	.360	.577	.478	55.091	83	172	255
4	2	3	5	1	Rank	-	%32.5	%67.5	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى الشركات ككل، ولكن أعلى خطأ جوهرية في بند النقدية Y_{bc1} ، وبند الذمم الدائنة وأوراق الدفع Y_{bp4} ، وأقل البنود خطأً بند الذمم المدينة بالصافي Y_{bd2} ، بند إجمالي الأصول Y_{bta5} ، ثم بند البضاعة Y_{bi3} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

2- نتائج التطبيق على بنود بيانات المركز المالي لكل قطاع:

1/2 نتائج التطبيق على بنود بيانات المركز المالي في القطاع (1): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاع (1) والذي شمل بيانات (8) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $Input\ Layer = 8$ -Hidden Layer = 4، والجدول (2) يوضح نتائج التطبيق على بنود بيانات المركز المالي للقطاع (1) كما يلي:

الجدول (2) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للقطاع (1)

Y_{bta5}	Y_{bp4}	Y_{bi3}	Y_{bd2}	Y_{bc1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.047	.711	.205	.482	4.065	.672	22.237	08	32	40
5	2	4	3	1	Rank	-	%20	%80	%100

بناء على قاعدة القرار سالفة الذكر توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى القطاع (1)، ولكن أعلى خطأ جوهرية في بند النقدية Y_{bc1} ، وبند الذمم الدائنة وأوراق الدفع Y_{bp4} ، وأقل البنود خطأً بند إجمالي الأصول Y_{bta5} ، بند البضاعة Y_{bi3} ، ثم بند الذمم المدينة بالصافي Y_{bd2} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

2/2 نتائج التطبيق على بنود بيانات المركز المالي في القطاع (2): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاع (2) والذي شمل بيانات (6) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $Input\ Layer = 6$ -Hidden Layer = 7، والجدول (3) يوضح نتائج التطبيق على بنود بيانات المركز المالي للقطاع (2) كما يلي:

الجدول (3) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للقطاع (2)

Y_{bta5}	Y_{bp4}	Y_{bi3}	Y_{bd2}	Y_{bc1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.090	.353	.704	.282	3.295	.497	4.560	8	22	30
5	3	2	4	1	Rank	-	%26.7	%73.3	%100

بناء على قاعدة القرار سالفة الذكر توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى القطاع (2)، ولكن أعلى خطأ جوهرية في بند النقدية Y_{bc1} ، بند البضاعة Y_{bi3} ، وأقل البنود خطأً بند إجمالي الأصول Y_{bta5} ، وبند الذمم المدينة بالصافي Y_{bd2} ، ثم البند الذمم الدائنة وأوراق الدفع Y_{bp4} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

3/2 نتائج التطبيق على بنود بيانات المركز المالي في القطاع (3): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاع (3) والذي شمل بيانات (5) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $Input\ Layer = 5$ -Hidden Layer = 7، والجدول (4) يوضح نتائج التطبيق على بنود بيانات المركز المالي للقطاع (3) كما يلي:

* ملاحظة هامة: لن يتم ذكر اسم القطاع حفاظاً على سرية البيانات، ولكن سيتم استخدام مصطلح قطاع 1 ... قطاع 9 .

الجدول (4) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للقطاع (3)

Y _{bTA5}	Y _{bP4}	Y _{bI3}	Y _{bD2}	Y _{bC1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.544	.815	.353	.227	3.543	.799	22.943	8	17	25
3	2	4	5	1	Rank	-	%31.4	%68.6	%100

بناء على قاعدة القرار سالفة الذكر توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى القطاع (3) ، ولكن أعلى خطأ جوهرية في بند النقدية Y_{bC1}، وبند الذمم الدائنة وأوراق الدفع Y_{bP4}، وأقل البنود خطأً بند الذمم المدينة بالصافي Y_{bD2}، وبند البضاعة Y_{bI3} ثم بند إجمالي الأصول Y_{bTA5}، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

4/2 نتائج التطبيق على بنود بيانات المركز المالي في القطاع (4): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاع (4) والذي شمل بيانات (7) شركات بإستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن 4 = Hidden Layer - 7 = Input Layer، والجدول (5) يوضح نتائج التطبيق على بنود بيانات المركز المالي للقطاع (4) كما يلي:

الجدول (5) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للقطاع (4)

Y _{bTA5}	Y _{bP4}	Y _{bI3}	Y _{bD2}	Y _{bC1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.051	.778	.221	.275	7.053	.624	30.290	11	24	35
5	2	4	3	1	Rank	-	%31.4	%68.6	%100

بناء على قاعدة القرار سالفة الذكر توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى القطاع (4) ، ولكن أعلى خطأ جوهرية في بند النقدية Y_{bC1}، وبند الذمم الدائنة وأوراق الدفع Y_{bP4}، وأقل البنود خطأً بند إجمالي الأصول Y_{bTA5}، وبند البضاعة Y_{bI3} ثم بند الذمم المدينة بالصافي Y_{bD2}، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

5/2 نتائج التطبيق على بنود بيانات المركز المالي في القطاع (5): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاع (5) والذي شمل بيانات (9) شركات بإستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن 8 = Hidden Layer - 9 = Input Layer، والجدول (6) يوضح نتائج التطبيق على بنود بيانات المركز المالي للقطاع (5) كما يلي:

الجدول (6) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للقطاع (5)

Y _{bTA5}	Y _{bP4}	Y _{bI3}	Y _{bD2}	Y _{bC1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.089	.066	.093	.341	.510	.213	4.042	11	34	45
4	5	3	2	1	Rank	-	%24.4	%75.6	%100

بناء على قاعدة القرار سالفة الذكر توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى القطاع (5) ، ولكن أعلى خطأ جوهرية في بند النقدية Y_{bC1}، بند الذمم المدينة بالصافي Y_{bD2}، وأقل البنود خطأً بند الذمم الدائنة وأوراق الدفع Y_{bP4}، بند إجمالي الأصول Y_{bTA5}، ثم بند البضاعة Y_{bI3}، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

6/2 نتائج التطبيق على بنود بيانات المركز المالي في القطاع (6): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاع (6) والذي شمل بيانات (4) شركات بإستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن 6 = Hidden Layer - 4 = Input Layer، والجدول (7) يوضح نتائج التطبيق على بنود بيانات المركز المالي للقطاع (6) كما يلي:

الجدول (7) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للقطاع (6)

Y _{bTA5}	Y _{bP4}	Y _{bI3}	Y _{bD2}	Y _{bC1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.056	.154	.243	.151	76.705	.419	2.329	7	13	20
5	3	2	4	1	Rank	-	%35	%65	%100

بناء على قاعدة القرار سالفة الذكر توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى القطاع (6)، ولكن أعلى خطأ جوهرية في بند النقدية Y_{bC1}، وأقل البنود خطأً بند إجمالي الأصول Y_{bTA5}، وبند الذمم المدينة بالصافي Y_{bD2}، وبند الذمم الدائنة وأوراق الدفع Y_{bP4}، وأخيراً بند البضاعة Y_{bI3}، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

7/2 نتائج التطبيق على بنود بيانات المركز المالي في القطاع (7): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاع (7) والذي شمل بيانات (7) شركات بإستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن Hidden Layer = 8 - Input Layer = 7، والجدول (8) يوضح نتائج التطبيق على بنود بيانات المركز المالي للقطاع (7) كما يلي:

الجدول (8) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للقطاع (7)

Y _{bTA5}	Y _{bP4}	Y _{bI3}	Y _{bD2}	Y _{bC1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.136	.120	.088	.230	1.124	.296	8.919	10	25	35
3	4	5	2	1	Rank	-	%28.6	%71.4	%100

بناء على قاعدة القرار سالفة الذكر توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى القطاع (7)، ولكن أعلى خطأ جوهرية في بند النقدية Y_{bC1}، وأقل البنود خطأً بند البضاعة Y_{bI3}، وبند الذمم الدائنة وأوراق الدفع Y_{bP4}، بند إجمالي الأصول Y_{bTA5}، وأخيراً بند الذمم المدينة بالصافي Y_{bD2}، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

8/2 نتائج التطبيق على بنود بيانات المركز المالي في القطاع (8): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاع (8) والذي شمل بيانات (3) شركات بإستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن Hidden Layer = 8 - Input Layer = 3، والجدول (9) يوضح نتائج التطبيق على بنود بيانات المركز المالي للقطاع (8) كما يلي:

الجدول (9) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للقطاع (8)

Y _{bTA5}	Y _{bP4}	Y _{bI3}	Y _{bD2}	Y _{bC1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.029	14.485	.073	5.882	.104	.232	.919	3	12	15
5	1	4	2	3	Rank	-	%20	%80	%100

بناء على قاعدة القرار سالفة الذكر توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى القطاع (8)، ولكن أعلى خطأ جوهرية في بند الذمم الدائنة وأوراق الدفع Y_{bP4}، وبند الذمم المدينة بالصافي Y_{bD2}، وأقل البنود خطأً بند إجمالي الأصول Y_{bTA5}، وبند البضاعة Y_{bI3}، وأخيراً بند النقدية Y_{bC1}، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

9/2 نتائج التطبيق على بنود بيانات المركز المالي في القطاع (9): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات المركز المالي للقطاع (9) والذي شمل بيانات (2) شركات بإستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن Hidden Layer = 2 - Input Layer = 2، والجدول (10) يوضح نتائج التطبيق على بنود بيانات المركز المالي للقطاع (9) كما يلي:

الجدول (10) يوضح نتائج تطبيق ANN على بنود بيانات المركز المالي للقطاع (9)

Y_{bTA5}	Y_{bP4}	Y_{bI3}	Y_{bD2}	Y_{bC1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.541	1.184	.834	1.628	1.33	1.223	41.477	4	6	01
5	3	4	1	2	Rank	-	%40	%60	%100

بناء على قاعدة القرار سالفة الذكر توجد أخطاء جوهرية في بنود بيان المركز المالي المذكورة أعلاه على مستوى القطاع (9)، ولكن أعلى خطأ جوهرية في بند الذمم المدينة بالصافي Y_{bD2} ، وبند النقدية Y_{bC1} ، بند الذمم الدائنة وأوراق الدفع Y_{bP4} ، وأقل البنود خطأ بند إجمالي الأصول Y_{bTA5} ، وبند البضاعة Y_{bI3} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

مما تقدم يتضح عدم صحة الفرضية الفرعية الأولى (H_{01}) حيث يؤثر تطبيق الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في بنود بيانات المركز المالي في الشركات الصناعية المسجلة في بورصة عمان.

نتائج تطبيق الشبكات العصبية الإصطناعية على بنود بيانات الدخل

1- نتائج التطبيق على بنود بيانات الدخل لكل الشركات: تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات الدخل للقطاعات التسعة (51) شركة باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن: -Hidden Layer = 10 -Input Layer = 51 -Output Layer = 5 -Hidden Layer Activation Function: Softmax -Output Layer -Layer (Dependent Variables) = 5 -Activation Function: Identify، والجدول (11) يوضح نتائج التطبيق على بنود بيانات الدخل للشركات ككل كما يلي:

الجدول (11) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للشركات ككل

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.158	.438	.229	.380	.135	.286	50.261	72	183	255
4	1	3	2	5	Rank	-	%28.2	%71.8	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى الشركات ككل، ولكن أعلى خطأ جوهرية في بند مصاريف البيع والتوزيع Y_{iSD4} ، وبند المصاريف التشغيلية Y_{iE2} وأقل البنود خطأ بند الإيرادات التشغيلية Y_{iR1} ، وبند صافي الدخل Y_{iN5} ، وأخيراً بند المصاريف الإدارية والعمومية Y_{iMP3} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

2- نتائج التطبيق على بنود بيانات الدخل لكل قطاع:

1/2 نتائج التطبيق على بنود بيانات الدخل في القطاع (1): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات الدخل للقطاع (1) والذي شمل بيانات (8) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن -Hidden Layer = 8 -Input Layer = 8، والجدول (12) يوضح نتائج التطبيق على بنود بيانات الدخل للقطاع (1) كما يلي:

الجدول (12) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للقطاع (1)

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.174	.231	.263	.274	.098	.211	6.952	10	30	40
4	3	2	1	5	Rank	-	%25	%75	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى القطاع (1) ، ولكن أعلى خطأ جوهرية في بند المصاريف التشغيلية Y_{iE2} وبند المصاريف الإدارية والعمومية Y_{iMP3} ، بند مصاريف البيع والتوزيع Y_{iSD4} ، وأقل البنود خطأ بند الإيرادات التشغيلية Y_{iR1} ، وبند صافي الدخل Y_{iN5} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

2/2 نتائج التطبيق على بنود بيانات الدخل في القطاع (2): لقد تم تدريب الشبكة العصبية الاصطناعية ANN بالنسبة لبيانات الدخل للقطاع (2) والذي شمل بيانات (6) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $6 = \text{Hidden Layer} - \text{Input Layer}$ ، والجدول (13) يوضح نتائج التطبيق على بنود بيانات الدخل للقطاع (2) كما يلي:

الجدول (13) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للقطاع (2)

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.502	.338	.163	.425	.421	.392	24.658	10	20	30
1	4	5	2	3	Rank	-	%33.3	%66.7	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى القطاع (2)، ولكن أعلى خطأ جوهرية في بند صافي الدخل Y_{iN5} ، بند المصاريف التشغيلية Y_{iE2} ، ثم بند الإيرادات التشغيلية Y_{iR1} ، وأقل البنود خطأ بند المصاريف الإدارية والعمومية Y_{iMP3} ، وبند مصاريف البيع والتوزيع Y_{iSD4} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي (Average Overall Relative Error (AORE)).

3/2 نتائج التطبيق على بنود بيانات الدخل في القطاع (3): لقد تم تدريب الشبكة العصبية الاصطناعية ANN بالنسبة لبيانات الدخل للقطاع (3) والذي شمل بيانات (5) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $8 = \text{Hidden Layer} - \text{Input Layer} = 5$ ، والجدول (14) يوضح نتائج التطبيق على بنود بيانات الدخل للقطاع (3) كما يلي:

الجدول (14) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للقطاع (3)

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
3.029	.258	5.491	.625	.653	.708	21.074	7	18	25
2	5	1	4	3	Rank	-	%28	%72	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى القطاع (3)، ولكن أعلى خطأ جوهرية في بند المصاريف الإدارية والعمومية Y_{iMP3} ، وبند صافي الدخل Y_{iN5} ، وأقل البنود خطأ بند مصاريف البيع والتوزيع Y_{iSD4} ، وبند المصاريف التشغيلية Y_{iE2} ، وأخيراً بند الإيرادات التشغيلية Y_{iR1} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي (Average Overall Relative Error (AORE)).

4/2 نتائج التطبيق على بنود بيانات الدخل في القطاع (4): لقد تم تدريب الشبكة العصبية الاصطناعية ANN بالنسبة لبيانات الدخل للقطاع (4) والذي شمل بيانات (7) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $9 = \text{Hidden Layer} - \text{Input Layer} = 7$ ، والجدول (15) يوضح نتائج التطبيق على بنود بيانات الدخل للقطاع (4) كما يلي:

الجدول (15) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للقطاع (4)

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.227	.139	.113	1.143	.246	.914	55.755	9	26	35
3	4	5	1	2	Rank	-	%25.7	%74.3	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى القطاع (4)، ولكن أعلى خطأ جوهرية في بند المصاريف التشغيلية Y_{iE2} ، وأقل البنود خطأ بند المصاريف الإدارية والعمومية Y_{iMP3} ، وبند مصاريف البيع والتوزيع Y_{iSD4} ، وبند صافي الدخل Y_{iN5} ، وأخيراً بند الإيرادات التشغيلية Y_{iR1} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي (Average Overall Relative Error (AORE)).

5/2 نتائج تطبيق ANN على بنود بيانات المركز المالي في القطاع (5): لقد تم تدريب الشبكة العصبية الاصطناعية ANN بالنسبة لبيانات الدخل للقطاع (5) والذي شمل بيانات (9) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $Input\ Layer = 9$ - $Hidden\ Layer = 3$ ، والجدول (16) يوضح نتائج التطبيق على بنود بيانات الدخل للقطاع (5) كما يلي:

الجدول (16) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للقطاع (5)

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.639	.323	.275	.251	.287	.430	22.469	21	24	45
1	2	4	5	3	Rank	-	%46.7	%53.3	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى القطاع (5)، ولكن أعلى خطأ جوهرية في بند صافي الدخل Y_{iN5} ، وأقل البنود خطأ بند المصاريف التشغيلية Y_{iE2} ، وبند المصاريف الإدارية والعمومية Y_{iMP3} ، ثم بند الإيرادات التشغيلية Y_{iR1} ، وأخيراً بند مصاريف البيع والتوزيع Y_{iSD4} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

6/2 نتائج التطبيق على بنود بيانات الدخل في القطاع (6): لقد تم تدريب الشبكة العصبية الاصطناعية ANN بالنسبة لبيانات الدخل للقطاع (6) والذي شمل بيانات (4) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $Input\ Layer = 4$ - $Hidden\ Layer = 7$ ، والجدول (17) يوضح نتائج التطبيق على بنود بيانات الدخل للقطاع (6) كما يلي:

الجدول (17) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للقطاع (6)

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
39.810	.016	.691	.134	.103	.540	22.452	5	15	20
1	5	2	3	4	Rank	-	%25	%75	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى القطاع (6)، ولكن أعلى خطأ جوهرية في بند صافي الدخل Y_{iN5} ، وبند المصاريف الإدارية والعمومية Y_{iMP3} ، وأقل البنود خطأ مصاريف البيع والتوزيع Y_{iSD4} ، بند الإيرادات التشغيلية Y_{iR1} ، وأخيراً بند المصاريف التشغيلية Y_{iE2} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

7/2 نتائج التطبيق على بنود بيانات الدخل في القطاع (7): لقد تم تدريب الشبكة العصبية الاصطناعية ANN بالنسبة لبيانات الدخل للقطاع (7) والذي شمل بيانات (7) شركات باستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $Input\ Layer = 7$ - $Hidden\ Layer = 8$ ، والجدول (18) يوضح نتائج التطبيق على بنود بيانات الدخل للقطاع (7) كما يلي:

الجدول (18) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للقطاع (7)

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.875	3.906	1.36	3.249	3.210	2.155	8.294	7	28	35
4	1	5	2	3	Rank	-	%20	%80	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى القطاع (7)، ولكن أعلى خطأ جوهرية في بند مصاريف البيع والتوزيع Y_{iSD4} ، بند المصاريف التشغيلية Y_{iE2} ، وأخيراً بند الإيرادات التشغيلية Y_{iR1} ، وأقل البنود خطأ بند المصاريف الإدارية والعمومية Y_{iMP3} ، وبند صافي الدخل Y_{iN5} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي Average Overall Relative Error (AORE).

8/2 نتائج التطبيق على بنود بيانات الدخل في القطاع (8): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات الدخل للقطاع (8) والذي شمل بيانات (3) شركات بإستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $Input\ Layer = 3$ - $Hidden\ Layer = 3$ ، والجدول (19) يوضح نتائج التطبيق على بنود بيانات الدخل للقطاع (8) كما يلي:

الجدول (19) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للقطاع (8)

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.590	.073	11.518	.184	.196	.337	3.149	5	10	15
2	5	1	4	3	Rank	-	%33.3	%66.7	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى القطاع (4)، ولكن أعلى خطأ جوهرية في بند المصاريف الإدارية والعمومية Y_{iMP3} ، وبند صافي الدخل Y_{iN5} ، وأقل البنود خطأً بند مصاريف البيع والتوزيع Y_{iSD4} ، بند المصاريف التشغيلية Y_{iE2} ، وأخيراً بند الإيرادات التشغيلية Y_{iR1} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي (Average Overall Relative Error (AORE)).

9/2 نتائج التطبيق على بنود بيانات الدخل في القطاع (9): لقد تم تدريب الشبكة العصبية الإصطناعية ANN بالنسبة لبيانات الدخل للقطاع (9) والذي شمل بيانات (2) شركات بإستخدام Radial Basis Function (RBF)، من خلال برنامج (Spss) التي تقوم بعملية التدريب والاختبار للبيانات التاريخية مع مراعاة أن $Input\ Layer = 2$ - $Hidden\ Layer = 5$ ، والجدول (20) يوضح نتائج التطبيق على بنود بيانات الدخل للقطاع (9) كما يلي:

الجدول (20) يوضح نتائج تطبيق ANN على بنود بيانات الدخل للقطاع (9)

Y_{iN5}	Y_{iSD4}	Y_{iMP3}	Y_{iE2}	Y_{iR1}	AORE	Error Fun.	Te. Data	Tr. Data	Total Data
.479	.920	.284	.214	.374	.454	6.844	1	9	10
2	1	4	5	3	Rank	-	%10	%90	%100

بناء على قاعدة القرار توجد أخطاء جوهرية في بنود بيانات الدخل المذكورة أعلاه على مستوى القطاع (4)، ولكن أعلى خطأ جوهرية في بند مصاريف البيع والتوزيع Y_{iSD4} ، وبند صافي الدخل Y_{iN5} ، وأقل البنود خطأً بند المصاريف التشغيلية Y_{iE2} ، وبند المصاريف الإدارية والعمومية Y_{iMP3} ، وأخيراً بند الإيرادات التشغيلية Y_{iR1} ، وذلك بالمقارنة مع المتوسط العام للخطأ النسبي (Average Overall Relative Error (AORE)).

مما تقدم يتضح عدم صحة الفرضية الفرعية الثانية (H_{02}) حيث يؤثر تطبيق الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في بنود بيانات الدخل في الشركات الصناعية المسجلة في بورصة عمان. وبناءً على نتائج إختبار الفرضية الفرعية الأولى (H_{01})، والفرضية الفرعية الثانية (H_{02}) يتضح أيضاً عدم صحة الفرضية الرئيسية (H_0) حيث يؤثر تطبيق الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في بنود البيانات المالية.

الخلاصة والنتائج:

استهدفت الدراسة الحالية إختبار أثر تطبيق الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في البيانات المالية، ولتحقيق هذا الهدف تناولت الدراسة- بالإضافة الى ما ورد في المقدمة- في الإطار النظري طبيعة الشبكات العصبية الإصطناعية، وطرق تعلمها، وإجراءات تصميمها وتطبيقاتها في التدقيق، ولبيان كيفية تطبيق الشبكات العصبية الإصطناعية في إكتشاف الأخطاء الجوهرية في البيانات المالية من خلال الحزمة البرمجية Spss، تم إستخراج البيانات المجمعدة للشركات الصناعية المسجلة في البورصة، والبالغ عددها (85) شركة مقسمة الى (11) قطاع صناعي لخمس سنوات، وقد تم إستبعاد (34) شركة لعدم إكمال البيانات، وبالتالي بلغت عينة الدراسة (51) شركة ممثلة لـ (9) قطاعات صناعية حيث تم إجراء الدراسة لجميع القطاعات، ثم لكل قطاع على حده، كما تم إستخدام نموذج Radial Basis Function (RBF)، وهو أحد نماذج الشبكات العصبية الإصطناعية

لأكتشاف الأخطاء الجوهرية في بنود البيانات المالية (بيان الدخل- بيان المركز المالي)، لمتغيرات الدراسة (10) التي تم إستخراجها من بيانات المركز المالي وبيانات الدخل للشركات، وبعد العرض والتحليل المتقدم فقد بينت الدراسة النتائج التالية:

أولاً: أن هناك أهمية لموضوع إستخدام الشبكات العصبية الإصطناعية في التدقيق بشكل عام، وفي قضية إكتشاف الأخطاء الجوهرية عند تدقيق البيانات المالية بشكل خاص، حيث أن كثيراً من قرارات المدققين ترتبط ببعضها البعض بشكل متتابع، لذلك فإن هناك تأثير لإستخدام الشبكات العصبية الإصطناعية ليس في تحديد الأخطاء الجوهرية فحسب بل في تحسين القرار اللاحق والذي يرتبط بتخطيط وأداء عملية التدقيق بكفاءة وفعالية.

ثانياً: توجد أخطاء جوهرية على مستوى البيانات المالية ككل للشركات الصناعية المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية كانت لبندي النقدية، والذمم الدائنة وأوراق الدفع، أما على مستوى بنود بيان الدخل المختارة فقد كانت اعلى الأخطاء لبندي مصاريف البيع والتوزيع، والمصاريف التشغيلية.

ثالثاً: توجد أخطاء جوهرية على مستوى البيانات المالية في شركات القطاع الصناعي (1) المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية لبندي النقدية، والذمم الدائنة وأوراق الدفع، أما على مستوى بنود بيان الدخل فقد كانت اعلى الأخطاء الجوهرية لبنود مصاريف البيع والتوزيع، والمصاريف الإدارية والعمومية، والمصاريف التشغيلية.

رابعاً: توجد أخطاء جوهرية على مستوى البيانات المالية في شركات القطاع الصناعي (2) المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية لبندي النقدية، والبضاعة، أما على مستوى بنود بيان الدخل فقد كانت اعلى الأخطاء الجوهرية لبنود صافي الدخل، والمصاريف التشغيلية، ومصاريف البيع والتوزيع.

خامساً: توجد أخطاء جوهرية على مستوى البيانات المالية في شركات القطاع الصناعي (3) المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية كانت لبندي النقدية، والذمم الدائنة وأوراق الدفع، أما على مستوى بنود بيان الدخل فقد كانت أعلى الأخطاء الجوهرية لبندي المصاريف الإدارية والعمومية، وصافي الدخل.

سادساً: توجد أخطاء جوهرية على مستوى البيانات المالية في شركات القطاع الصناعي (4) المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية كانت لبندي النقدية، والذمم الدائنة وأوراق الدفع، أما على مستوى بنود بيان الدخل فقد كانت أعلى الأخطاء الجوهرية لبند المصاريف التشغيلية.

سابعاً: توجد أخطاء جوهرية على مستوى البيانات المالية في شركات القطاع الصناعي (5) المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية لبندي النقدية، والذمم المدينة بالصافي، أما على مستوى بنود بيان الدخل فقد كانت أعلى الأخطاء الجوهرية لبند صافي الدخل.

ثامناً: توجد أخطاء جوهرية على مستوى البيانات المالية في شركات القطاع الصناعي (6) المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية بند النقدية، أما على مستوى بنود بيان الدخل فقد كانت أعلى الأخطاء الجوهرية لبندي صافي الدخل، والمصاريف الإدارية والعمومية.

تاسعاً: توجد أخطاء جوهرية على مستوى البيانات المالية في شركات القطاع الصناعي (7) المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية بند النقدية، أما على مستوى بنود بيان الدخل فقد كانت أعلى الأخطاء الجوهرية لبنود مصاريف البيع والتوزيع، والمصاريف التشغيلية، والإيرادات التشغيلية.

عاشراً: توجد أخطاء جوهرية على مستوى البيانات المالية في شركات القطاع الصناعي (8) المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية في بندي الذمم الدائنة وأوراق الدفع، والذمم المدينة بالصافي، أما على مستوى بنود بيان الدخل فقد كانت أعلى الأخطاء الجوهرية لبندي المصاريف الإدارية والعمومية، وصافي الدخل.

حادي عشر: توجد أخطاء جوهرية على مستوى البيانات المالية في شركات القطاع الصناعي (9) المسجلة في البورصة، حيث كشفت نتائج تطبيق الشبكات العصبية الإصطناعية على مستوى بنود بيان المركز المالي المختارة أن أعلى الأخطاء الجوهرية في بنود

الذمم المدينة بالصافي، والنقدية، والذمم الدائنة وأوراق الدفع، أما على مستوى بنود بيان الدخل فقد كانت أعلى الأخطاء الجوهرية لبندى مصاريف البيع والتوزيع، وصافي الدخل.

التوصيات:

بناء على النتائج السابقة تقترح الدراسة التوصيات التالية:

أولاً: توصي الدراسة جمعية المحاسبين القانونيين الأردنيين بضرورة عقد أو إلزام المحاسبين القانونيين (المدققين المستقلين) كجزء من التطوير المهني المستمر اللازم للتجديد السنوي لرخصة مزاوله المهنة ، بالحصول على دورات تدريبية في حزمة البرامج الإحصائية Spss وبشكل خاص نماذج الشبكات العصبية الإصطناعية، وذلك لتحسين أحكامهم المهنية في عملية التدقيق لأن استخدام هذه النماذج يؤثر في تحسين كفاءة وفعالية التدقيق.

ثانياً: توصي الدراسة مكاتب التدقيق بتعيين متخصصين في مجال البرمجيات الإحصائية الجاهزة، أو الإستعانة كخبراء متخصصين وفقاً للمعيار الدولي للتدقيق (610).

ثالثاً: توصي الدراسة المدققين المستقلين بضرورة الحصول على دورات تدريبية وكجزء من التطوير المهني المستمر الإطلاع على المستجدات المهنية، والإستجابة لمطالب المجتمع المالي العالمية بشأن إكتشاف الإخطاء الجوهرية في البيانات المالية وبشكل خاص متابعة التطورات التكنولوجية في مجال صناعة البرمجيات الجاهزة (برمجية Spss) لتفعيل دورهم المهني من خلال تحسين أحكامهم المهنية، لتكون أكثر موضوعية بالأعتماد على الأساليب العلمية، لإستعادة ثقة المجتمع المالي في البيانات المالية المدققة.

رابعاً: توصي الدراسة هيئة الأوراق المالية، وبورصة عمان ولجان الإفصاح في البورصة بضرورة مراقبة ما إذا كانت البيانات المالية المنشورة للشركات المقيدة في البورصة خالية من الأخطاء الجوهرية، وعدم الأكتفاء بالأستلام في المواعيد المحددة فقط، وذلك بتدريب العاملين في الهيئة على إستخدام أساليب الذكاء الأصطناعي من جانب، بالإضافة الى ضرورة نشر البيانات المجمعة للشركات بشكل كامل تحقيقاً للمصلحة العامة، وخدمة المجتمع المالي، والبحث العلمي فضلاً عن ذلك تحسين أداء البورصة.

خامساً: توصي الدراسة أقسام المحاسبة في الجامعات بضرورة الاهتمام بتدريس موضوع الحزمة البرمجية الإحصائية Spss لطلاب المحاسبة وإدراجها ضمن الخطط الدراسية كمنهاج مستقل بدلاً من مناهج الإحصاء التقليدية لكي تواكب الخطط الدراسية التطورات التكنولوجية العالمية في مجال صناعة البرمجيات، حيث أن مهنة التدقيق تعتمد - دائماً- على الحكم المهني، وأن هذا الحكم يحتاج الى التطوير من خلال إستخدام التطورات التكنولوجية الحالية، ومن ثم خلق جيل قادر على مواجهة مطالب المجتمع المالي على نطاق عالمي بشأن قضية أكتشاف الأخطاء الجوهرية عند تدقيق البيانات المالية.

حدود الدراسة والدراسات المستقبلية:

لقد إعتمدت الدراسة الحالية في بناء نتائجها على إستخدام نماذج الشبكات العصبية الإصطناعية، كما تم تطبيقها على البيانات المالية للشركة الصناعية المسجلة في سوق عمان المالي، لذلك تقترح الدراسة تطبيق هذ النماذج على قطاعات إقتصادية - مثل- قطاع التأمين - البنوك- قطاع الخدمات ، وكذلك القطاع الحكومي وبشكل خاص إعداد الموازنة العامة للدولة سواء داخل الأردن أو في أية دولة عربية أخرى.

كما يأمل الباحث إن شاء الله، أو يقترح كنتيجة لعدم إستجابة المعايير الدولية التدقيق لمثل هذه التطورات التكنولوجية والإصرار عبر تاريخها القصير نسبياً (1979-2010) على إستخدام المنهج الوصفي في إكتشاف الأخطاء الجوهرية في البيانات المالية عمل دراسة ميدانية لبحث معوقات تطبيق أساليب الذكاء الأصطناعي في العمل الميداني لمهنة التدقيق.

المراجع:

المراجع العربية:

- أرسانيوس، بدر نبيه، (2006)، تطوير دور المراجع الخارجي التقرير عن القوائم المالية المضللة بإستخدام الشبكات العصبية: دراسة تحليلية، مجلة الدراسات المالية والتجارية، كلية التجارة، جامعة بني سويف، العدد الأول، ص 678-720.
- جاب الله، سامية طلعت عباس، (2004)، إستخدام الشبكات العصبية الإصطناعية في مجال المحاسبة والمرجعة، المجلة العلمية للأقتصاد والتجارة، كلية التجارة، جامعة عين شمس، العدد الثاني، ص 277-310.
- حسين، محمد نادي عزت، وعبد الباري، طارق عزت، (1999) إستخدام التحليل بالشبكات العصبية في تقدير مخصص التعويضات تحت التسوية لفروع التأمينات العامة، المجلة المصرية للدراسات التجارية، كلية التجارة، جاعة المنصورة، العدد الأول، ص 607-37.
- لطفی، أمين السيد أحمد، (2007)، تحسين دقة أحكام المراجعين لأغراض تقييم مخاطر وجود الغش في التقارير المالية بإستخدام وسائل دعم القرار: دراسة إختيارية، مجلة الدراسات المالية والتجارية، كلية التجارة، جامعة بني سويف، العدد الأول، ص 7-30.
- عبدالله، مسعود، وآخرين، (1995)، التحليل بإستخدام الشبكات العصبية، المجلة العربية للإدارة، العدد الأول، صفحات متفرقة.

المراجع الأجنبية:

- Busta, B. and Weinberg, R. (1998), Using Benford's Law and Neural Networks as a Review Procedure, *Managerial Auditing Journal*, Vol. 13, No. 6, pp. 356-66.
- Coakley, J.R. and Brown, C.E. (1991a), Neural Networks Applied to Ratio Analysis in the Analytical Review Process, Paper Presented at Expert Systems Symposium, Pasadena, CA.
- Coakley, J.R. and Brown, C.E. (1991b), Neural Networks for Financial Ratio Analysis, Paper Presented at The World Congress on Expert Systems, Orlando, FL.
- Coakley, J.R. and Brown, C.E. (1993), Artificial Neural Networks Applied to Ratio Analysis in the Analytical Review Process, *Intelligent Systems in Accounting, Finance and Management*, Vol. 2, pp. 19-39.
- Coakley, J.R. (1995), Using Pattern Analysis Methods to Supplement Attention-Directing Analytical Procedures, *Expert Systems with Applications*, Vol. 9, No. 4, pp. 513-28.
- Coakley, J.R. and Brown, C.E., (2000), Artificial Neural Networks in Accounting and Finance: Modeling Issues, *International Journal of Intelligent Systems in Accounting, Finance and Management*, Vol. 9, pp. 119-44.
- Curry, B. and Peel, M.J. (1998), Neural Networks and Business Forecasting: An Application to Cross-sectional Audit Fee Data, *International Journal of Commerce and Management*, Vol. 8, No. 2, pp. 94-120.
- Davis, J.T. (1996), Experience and Auditors' Selection of Relevant Information for Preliminary Control Risk Assessments, *Auditing: A Journal of Practice & Theory*, Vol. 15, No. 1, pp. 16-37.
- Davis, J.T., Massey, A.P. and Lovell, R.E.R. II, (1997), Supporting a Complex Audit Judgement Task: An Expert Network Approach, *European Journal of Operational Research*, Vol. 103, No. 2, pp. 350-72.
- Demuth, H. and Beale, M. (2000), *Neural Network Toolbox*, the Math Works, Inc., Natick, MA.
- Eichengreen, B., (1999), *Towards A New International Financial Architecture*, Institute for International Economics, Washington, DC.
- Eichengreen, B., (2002), *Financial Crises*, Oxford University Press, New York, NY.
- Etheridge, H.L., Sriram, R.S. and Hsu, H.Y.K. (2000), A Comparison of Selected Artificial Neural Networks That Help Auditors Evaluate Client Financial Viability", *Decision Science*, Vol. 31, No. 2, pp. 531-50.
- Fanning, K.M. and Cogger, K.O. (1998), Neural Network Detection of Management Fraud Using Published Financial Data, *International Journal of Intelligent Systems in Accounting, Finance & Management*, Vol. 7, No. 1, pp. 21-41.
- Freeman, J.A. and Skapura, D.M. (1991), *Neural Networks Algorithms, Applications, and Programming Techniques*, Addison-Wesley Publishing Company, Menlo Park, CA.
- Feroz, E.H., Kwon, T.M., Pastena, V.S. and Park, K. (2000), The Efficacy of Red Flags in Predicting the SEC's Targets: An Artificial Neural Networks Approach, *International Journal of Intelligent Systems in Accounting, Finance & Management*, Vol. 9, pp. 145-57.
- Green, B.P. and Choi, J.H. (1997), Assessing the Risk of Management Fraud through Neural Network Technology, *Auditing: A Journal of Practice & Theory*, Vol. 16, No. 1, pp. 14-28.
- Hart, A., (1992), Using Neural Networks for Classification Tasks, Some Experiments on Data Sets and Practical Advice, *Journal of The Operational Research Society*, Vol. 43, No.3.p.p 205-26.

- Haykin, S. (2009), *Neural Networks and Learning Machines*, 3rd ed., Pearson Education, Upper Saddle River, NJ.
- Hecht-Nielsen, R. (1990), *Neurocomputing*, Addison-Wesley Publishing Company, Inc., San Diego, CA.
- Hertz, J., Krogh, A. and Palmer, R.G. (1991), *Introduction to the Theory of Neurocomputing*, Addison-Wesley Publishing Company, Redwood City, CA
- Howeel, J., (1990), *Inside a Neural Network*, AI Expert, Nov.
- IFAC, IAASB, (2010), *Handbook of International Quality Control, Auditing, Review, Other Assurance, and Related Services Pronouncements*, International Federation of Accountants, Jan.
- IFAC, IAASB, (2009), *Handbook of International Auditing Standard and Quality Control Pronouncements*, International Federation of Accountants, Jan.
- IFAC, IAPS, (1995), *IFAC Handbook*, International Federation of Accountants, July.
- Krambia-Kapardis, M. and Zopiatis, A. (2010), *Investigating Incidents of Fraud in Small Economies: The Case for Cyprus*, *Journal of Financial Crime*, Vol. 17, No. 2, pp. 195-209.
- Krambia-Kapardis, M., Christodoulou, C. and Agathocleous, M., (2010), *Neural Networks: The Panacea in Fraud Detection*, *Managerial Auditing Journal*, Vol. 25 No.7, pp. 659-678.
- Koskivaara, E., (2004), *Artificial Neural Networks in Analytical Review Procedures*, *Managerial Auditing Journal*, Vol. 19, No. 2, pp. 191-223
- Koskivaara, E., (2000), *Artificial Neural Network Models for Predicting Patterns in Auditing Monthly Balances*, *Journal of The Operational Research Society*, Vol. 51, No.9.pp.1060 - 69.
- Koskivaara, E. (2000a), *Different Pre-processing Models for Financial Accounts When Using Neural Networks for Auditing*, Paper Presented at European Conference on Information Systems, Vienna.
- Koskivaara, E., Back, B. and Sere, K. (1996), *Modelling Intelligent Information Systems for Auditing*, Paper Presented at the Intelligent Systems in Accounting and Finance Conference, Huelva.
- Lin, J. W., Hwang, M. L. and Becker, J. D., (2003), *A Fuzzy Neural Network for Assessing The Risk of Fraudulent Financial Reporting*, *Managerial Auditing Journal*, Vol.18, No.8, pp. 657-65.
- Liou, Fen-May, (2008), *Fraudulent Financial Reporting Detection and Business Failure Prediction Models: A Comparison*, *Managerial Auditing Journal*, Vol. 23, No. 7, pp. 650-662.
- Liou, Fen-May and Yang, Chien-Hui, (2008), *Predicting Business Failure under the Existence of Fraudulent Financial Reporting*, *International Journal of Accounting and Information Management*, Vol. 16 No. 1, pp. 74-86.
- Leppmann, R., (1987), *An Introduction to Computing with Neural Nets*, *IEEE Assp Magazine*, Vol.4, No.2, pp. 4-22.
- Ozkan-Gunay, E.N. and Gunay, G. (2007), *Potential Insolvency, Prudential Regulation and Supervision in Emerging Market Banking Systems: The Case of Turkey*, *International Journal of Liability and Scientific Enquiry*.
- Ozkan-Gunay, E. Nur and Mehmed Ozkan, Mehmed, (2010), *Prediction of Bank Failures in Emerging Financial Markets: An ANN Approach*, *The Journal of Risk Finance*, Vol. 8, No. 5, pp. 465-80.
- PricewaterhouseCoopers (2009), *Global Economic Crime Survey*, November 2009, PricewaterhouseCoopers, London.
- Ramamoorti, S., Bailey, A.D. Jr and Traver, R.O. (1999), *Risk Assessment in Internal Auditing: A Neural Network Approach*, *International Journal of Intelligent Systems in Accounting, Finance & Management*, Vol. 8, No. 3, pp. 159-80.
- Rezaee, Z. and Crumbley, L., (2007), *The Role of Forensic Auditing Techniques in Restoring Public Trust and Investor Confidence in Financial Information*, *The Forensic Examiner*, Vol. 16, No. 1, pp. 44-9.
- Rumelhart, D.E., Hinton, G.E. and Williams, R.S., (1986), *Learning Representations by Back-propagating Errors*, *Nature*, Vol. 323, pp. 533-6.
- Smith, M. (1996), *Neural Networks for Statistical Modeling*, International Thompson Computer Press, London.
- Spathis, C. T., (2002), *Detecting False Financial Statements Using Published Data: Some Evidence From Greece*, *Managerial Auditing Journal*, Vol. 17, No. 4, pp. 179-191.
- Swingler, K. (1996), *Applying Neural Networks: A Practical Guide*, Academic Press Limited, London.
- Summer, S. and Sweeney, J., (1998), *Fraudulently Misstated Financial Statements and Insider Trading: An Empirical Analysis*, *The Accounting Review*, Jan. pp. 161-46.
- Wang, Zongjun and Li, Hongxia, (2007), *Financial Distress Prediction of Chinese Listed Companies: A Rough Set Methodology*, *Chinese Management Studies*, Vol. 1, No. 2, 2007, pp. 93-110.
- Wu, R. C-F., (1997), *Neural Networks Model: Foundations and Applications to an Audit Decision Problem*, *Annals of Operations Research*, Vol.75, pp. 291-301.

- -----, (1994), Integrating neurocomputing and auditing expertise, *Managerial Auditing Journal*, Vol. 9, No. 3, pp. 20-6.