

## أثر استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في القوائم المالية للشركات المساهمة العامة الصناعية الأردنية (دراسة تطبيقية)

أ.د. أحمد محمد العمري<sup>ii</sup>

تاريخ القبول

2021/12/6

أسامة أحمد برمو<sup>i</sup>

تاريخ الاستلام

2021/5/30

### الملخص

هدفت هذه الدراسة إلى اختبار أثر استخدام تقنية الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في القوائم المالية للشركات المساهمة العامة الصناعية الأردنية المسجلة في بورصة عمان، وذلك باستخدام البيانات الثانوية لعينة الدراسة المكونة من (43) شركة صناعية قسمت إلى (24) شركة كبيرة الحجم، و(19) شركة صغيرة الحجم، وقد تم استخراج البيانات من قائمة الدخل وقائمة المركز المالي للشركات الصناعية، كما تم استخدام دالة من دوال الشبكات العصبية الاصطناعية وهي (Radial Basis Function (RBF) توضح العلاقة بين المتغيرات. بينت نتائج الدراسة وجود أخطاء جوهرية في القوائم المالية للشركات المساهمة العامة الصناعية الأردنية، وأن هناك تأثير لحجم الشركات على تطبيق تقنية الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية وأن هناك أهمية بالغة لاستخدام الشبكات العصبية في التدقيق. وقد تمت التوصية بشكل هام خضوع المدققين لدورات تدريبية من جهة، ومتابعة التطورات التكنولوجية في مجال صناعة البرمجيات من جهة أخرى، وإلى ضرورة التطوير المهني للاستجابة لمطالب المجتمع المالي العالمي بشأن اكتشاف الأخطاء الجوهرية، لتعزيز الثقة في القوائم المالية المدققة.

**الكلمات المفتاحية:** الشبكات العصبية الاصطناعية، الأخطاء الجوهرية، الشركات المساهمة العامة الصناعية الأردنية.

<sup>i</sup> جامعة دمشق  
<sup>ii</sup> جامعة اليرموك

## Effect of Using Artificial Neural Networks in Detecting Material Misstatements in the Financial Statements of Jordanian Manufacturing Corporations: (An Empirical Study)

### Abstract

The aim of this study is to test the impact of using artificial neural network technology in detecting material misstatements in the financial statements of publicly traded industrial companies in Jordan registered on the Amman Stock Exchange. This was done using secondary data from a sample of 43 industrial companies, divided into 24 large companies and 19 small companies. Data were extracted from the income statement and balance sheet of the industrial companies, and a function from artificial neural networks, specifically the Radial Basis Function (RBF), was used to clarify the relationship between the variables.

The results of the study reveal the existence of material misstatements in the financial statements of Jordanian publicly traded industrial companies, and that the size of the companies affects the application of artificial neural network technology in detecting material misstatements. Additionally, there is significant importance in using neural networks in auditing.

The study strongly recommends that auditors undergo training courses and keep up with technological developments in the software industry, as well as the necessity for professional development to respond to the demands of the global financial community regarding the detection of material misstatements, in order to enhance confidence in audited financial statements.

**Keywords:** Artificial Neural Networks, Material Misstatements, Publicly Traded Industrial Companies in Jordan.

## المقدمة

نظراً لتنوع استراتيجيات الشركات في تحقيق أهدافها، وتنوع طبيعة أعمالها، وقطاعاتها، وحجمها، وتعقيدات البيئة التي تعمل بها، فإنها تواجه العديد من المخاطر والمشاكل المتنوعة. ومن هذه المخاطر تلك التي تتعلق بإعداد البيانات والقوائم المالية. وهنا تكون المسؤولية المتعلقة بهذه المخاطر والمشاكل متقاسمة فيها بين الإدارة من حيث إعداد القوائم المالية من جهة، وبين مدقق الحسابات في فحصها واكتشاف الأخطاء من جهة أخرى.

وانطلاقاً من مسؤولية المدقق في اكتشاف الأخطاء فقد طبقت العديد من الأساليب لفحص البيانات المالية التي تهدف إلى كشف المدقق عن الأخطاء الجوهرية في البيانات المالية، سواء كانت هذه الأخطاء ناتجة عن احتيال الإدارة (Earning Management)، أو أخطاء غير مقصودة (Robu, 2012)، إن مخاطر عملية التدقيق هي تلك التي لها علاقة بالأخطاء الجوهرية في البيانات المالية، أي أن البيانات المالية تحتوي على أخطاء جوهرية قبل التدقيق، والخطر هنا أن لا يكتشف المدقق هذه الأخطاء "مخاطرة الاكتشاف"، وهنا يجب على المدقق أن يقوم بإجراءات التدقيق لتقييم الأخطاء الجوهرية ويقلل من مخاطرة الاكتشاف وذلك بالقيام بالمزيد من إجراءات التدقيق بناء على ذلك التقييم، (الاتحاد الدولي للمحاسبين، 2007:219).

ومن هنا جاءت تقنية الشبكات العصبية الاصطناعية كإحدى الطرق الحديثة ذات الكفاءة العالية في إعطاء نتائج دقيقة ومضمونة كونها نوع من أنواع تكنولوجيا الذكاء الاصطناعي والتي تعتمد على استخدام العديد من البرامج المختصة وقواعد المعرفة بطريقة تحاكي طريقة عمل العقل البشري، حيث يهدف الذكاء الاصطناعي إلى محاكاة عمليات الذكاء التي تتم داخل العقل البشري من خلال الحاسوب، بحيث تصبح لدى الحاسوب القدرة على حل المشكلات واتخاذ القرارات بشكل منطقي وبطريقة تفكير العقل البشري (جميل وعثمان، 2012).

وتعتبر الشبكات العصبية الاصطناعية إحدى أهم الطرق والوسائل التي يتم استخدامها في تعزيز وزيادة كفاءة عملية التدقيق من خلال زيادة المعرفة والتأكد، وبيان المعلومات المخفية، حيث أنه يمكن تدريب الشبكات العصبية الاصطناعية على اختيار الرأي الأدق والأرجح للمدقق بناءً على استخدام الخصائص والمعلومات المحاسبية في الشركات (Pourheydari, et.al, 2012).

وبناء عليه جاءت هذه الدراسة للتعرف على أثر استخدام الشبكات العصبية الاصطناعية في عملية اكتشاف الأخطاء الجوهرية في القوائم المالية للشركات الصناعية المساهمة العامة الأردنية حيث إن

تلك الشركات تقوم بعمليات تجارية واسعة ومتنوعة تحتاج إلى دقة كبيرة وعالية في الرقابة والتدقيق والفحص.

### نشأة الشبكات العصبية الصناعية:

تعود جذور البحوث الخاصة بالذكاء الاصطناعي إلى أربعينيات القرن المنصرم، مع انتشار الحاسبات واستخدامها وتركز الاهتمام في بداية الخمسينيات على الشبكات العصبية الاصطناعية، وتم تطويرها والعمل على النظم المبنية على تمثيل المعرفة في الستينات والسبعينات، ومع بداية الثمانينات وبعد إعلان المشروع الياباني الذي تبني الجيل الخامس للحاسبات حدثت طفرة كبيرة في أبحاث الذكاء الاصطناعي.

وبعودة سريعة إلى أربعينيات القرن الماضي، ففي عام 1943، نشرت مقالة هامة لكل من (Icculloch) وزميله (Pitts) حيث وصفوا عصبون بسيط ثنائي الحالة مع مخدم. وفي عام 1949، قام (Donald Hebb) باقتراح قاعدة لطريقة تعليم العصبون، والتي لا تزال ليومنا هذا نموذج يستعمله الباحثون في نماذج التعليم، حيث يعد أول من قام بتعليل أن تجمعات خلوية موزعة عديدة استعملت لتمثيل المعرفة، حيث كانت هذه القاعدة أولى الاقتراحات للوصول إلى البنية التوصيلية للعصبونات (Connectionist Architecture) (راشد وآخرون، 2012).

وفي عام 1956 عقد مؤتمر (Dartmouth)، حيث يعتبر هذا التاريخ البداية الرسمية لعهد الذكاء الاصطناعي (Artificial Intelligence AI)، حيث قام (Rochester) بنشر أول محاكاة (Simulation) بين الشبكات العصبونية والحاسوب. ويعد (Rosentbale) هو أول من بحث الإدراك (Perception) ما بين عامي (1962-1985). والذي يمثل الشبكة الأساسية للمفسر أو المدرك (Perceptron) وحدة منطقية مع عتبة، والتي تتركب من طبقات ثلاث: طبقة دخل حساسة للضوء متصلة عشوائياً مع طبقات مرافقة (Association) والتي تتصل بدورها مع طبقة التصنيف (classification) أو طبقة استجابة الخروج. تستعمل قاعدة تعليم المفسر تعديل الأوزان المتكرر، وهذا يعد أقوى بكثير من قاعدة (Hebb). وقد قام (Anderson) في عام 1977 بتطوير ذاكرة مترافقة قابلة للعنونة بالمحتوى (Content-Addressable Associative Memory). وقد اعتمدت كل نماذج من الشبكات على قاعدة (Hebb). وفي عام 1988 قام الباحث الياباني (Fukushima) باختراع شبكات (Cognitron) و (Neocognitron) وما زالت الأبحاث في مجال

الشبكات العصبية الاصطناعية مستمرة ومتقدمة بخطوات سريعة ووثيقة في التطبيقات العملية في شتى مجالات الحياة. وفيما يتعلق بالشكل العام لنماذج الشبكات العصبية الاصطناعية فهي دوال غير خطية مرنة تكتب وفق شكلها العام التالي (العجال، 2010، ص173):

$$Y = F | H_1 (X), H_2 (X), \dots, H_n (X) | + u \dots \dots \dots (01)$$

وحسب لغة الشبكات العصبية تمثل:

-المتغيرات المستقلة X: المدخلات.

-المتغير التابع Y: المخرجات.

-دوال الشبكات العصبية H: الطبقات الخفية.

-دوال الشبكات العصبية F: مخرجات دالة التحفيز الخفية.

ومن أهم الفروق بين نموذج الانحدار الخطي ونموذج الشبكات العصبية هو أن دالة الانحدار الخطية هي خطية في معلماتها، ولا توجد دوال الطبقات الخفية في نموذج الانحدار، فتأخذ الشكل التالي (العجال، 2010، ص173):

$$Y = X B + u \dots \dots \dots (02)$$

وحسب مفهوم الشبكات العصبية فإن للمعادلة رقم (2) مخرج واحد وبدون طبقات خفية، مع دالة تحفيز خطية لطبقة الناتج.

**التعريفات الإجرائية لمتغيرات الدراسة:**

الشبكات العصبية الاصطناعية: "هي نظام مصمم لمحاكاة الطريقة التي يؤدي بها العقل البشري مهمة معينة، وهو عبارة عن معالج ضخم موزع على التوازي، ومكون من وحدات معالجة بسيطة، هذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات أو عقد لها خاصية عصبونية حيث تقوم

بتخزين المعرفة العلمية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان" (ياسين، 2006، ص127).

**الأخطاء الجوهرية:** "وفقاً لمعايير التدقيق الدولية فإن الخطأ هو الفرق بين مبلغ أو تصنيف أو عرض أو إفصاح عن بند معين في بيان مالي مبلغ عنه والمبلغ أو التصنيف أو العرض أو الإفصاح الذي يقتضيه إطار إعداد التقارير المالية المعمول به لذلك البند" (الرماحي، 2009، ص129).

**القوائم المالية:** "هي المنتج النهائي لنظام معلومات المحاسبة المالية والوسيلة الأساسية لتوصيل المعلومات المحاسبية عن نتائج الأحداث الاقتصادية التي حدثت في المنشأة خلال فترة ما، إلى الأطراف المختلفة، إذ يعتمدون عليها في اتخاذ قراراتهم وتحديد توجهاتهم" (رياض، 2010).

### مشكلة وأسئلة الدراسة

إن للبيانات المالية بالغ الأهمية في تقديم المعلومات المالية والمهمة لمستخدمي تلك المعلومات، سواء كانت الإدارة، أو المساهمين، أو المستثمرين، أو حملة السندات، أو المحللين الماليين، أو الموردين، أو المدققين، وإن من المشاكل التي تواجه الشركات في السوق هي عدم تماثل المعلومات واستغلالها من قبل الإدارة وهنا جاء استخدام الشبكات العصبية الاصطناعية لتساهم في الحد من هذه المشكلة.

وانطلاقاً من تلك الأهمية الكبيرة التي تتمتع بها البيانات والمعلومات المالية كان لا بد من جهة موثوقة ومستقلة تقوم بتدقيق هذه البيانات ومصادقتها ألا وهي مدققي الحسابات، ولما كان من الصعب جداً الوصول إلى رأي مهني واضح وقاطع فيما إذا كانت هذه البيانات عادلة وصحيحة، وما قد تحتوي عليه من تلاعب وغش، أو خطأ، سواء كان مقصوداً أو غير مقصود، كان من الضروري استخدام تقنيات تساعد المدققين في اكتشاف هذه الأخطاء. وبسبب الصعوبات التي تعترض المدققين في تحديد واكتشاف الأخطاء الجوهرية في البيانات المالية فقد توجه البحث والعلم المحاسبي مع بداية العقد المنصرمين إلى استخدام أساليب الذكاء الاصطناعي، والسبب هو

الحاجة الملحة إلى قراءة والتعامل مع المعلومة بطريقة تشابه طريقة العقل البشري، ومن هذه الأساليب اسلوب الشبكات العصبية الاصطناعية.

وبناء على ما سبق يمكن صياغة مشكلة الدراسة في الإجابة على التساؤل الرئيس التالي:  
ما مدى تأثير استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في القوائم المالية للشركات المساهمة العامة الصناعية الأردنية؟  
ويتفرع عنه التساؤلات التالية:

- 1- هل يؤثر استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية؟
- 2- هل يؤثر استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية؟
- 3- هل يؤثر حجم الشركة على تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود القوائم المالية للشركات المساهمة العامة الصناعية الأردنية؟

#### أهمية الدراسة

تتبع أهمية هذه الدراسة من ذات الأهمية التي يحظى بها القطاع الصناعي الأردني في منظومة الاقتصاد الوطني من جهة، ومن الأهمية التي يستأثر بها موضوع الأخطاء الجوهرية في القوائم المالية من جهة أخرى، إضافة إلى عدم قدرة التشريع المحلي على اكتشاف هذا النوع من الأخطاء، إضافة إلى تقصير في البحث المحاسبي، ودور مدقق الحسابات في تطوير إجراءات بشأن اكتشاف الأخطاء الجوهرية، وذلك بسبب الالتزام بالمعايير المهنية من جانب أو عدم الالتزام بها وذلك لأنها تعتبر إرشاداً وغير ملزم من جانب آخر، إضافة إلى ذلك فإن تطبيق المعايير المهنية قد لا يؤدي إلى اكتشاف الأخطاء الجوهرية بالرغم من الحذر نتيجة إلى الحكم المهني.  
وبناءً عليه وبما يتميز به أسلوب الشبكات العصبية الاصطناعية من دقة وإتقان وأسلوب عمل يحاكي أسلوب العقل البشري، والقدرة على التنبؤ والتحليل بصورة دقيقة الأمر الذي ينعكس على جودة المعلومات المالية.

ومما تقدم فإن أهمية الدراسة الحالية تكمن فيما يلي:

- 1- توجيه اهتمام وانتباه الباحثين والأكاديميين والمدققين إلى الأهمية البالغة في استخدام تقنية الشبكات العصبية الاصطناعية في تدقيق القوائم المالية.

- 2- توجيه أنظار القطاع المالي، والمدققين، ومديري الشركات، والمحللين الماليين، والباحثين، والأكاديميين، لدور الشبكات العصبية الاصطناعية في عملية اكتشاف الأخطاء الجوهرية في بنود القوائم المالية.
- 3- شرح وتقديم طريق ومنهج يوضح آلية استخدام الشبكات العصبية الاصطناعية في الممارسات المهنية.

#### أهداف الدراسة:

- تهدف هذه الدراسة بشكل رئيس إلى:
- اختبار أثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في القوائم المالية للشركات المساهمة العامة الصناعية الأردنية.
- ويتفرع عنه الأهداف الفرعية التالية:

- 1- اختبار أثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية.
- 2- اختبار أثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية.
- 3- اختبار أثر حجم الشركة على تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود القوائم المالية للشركات المساهمة العامة الصناعية الأردنية.

#### فرضيات الدراسة

لتحقيق غايات الدراسة فقد تم صياغة الفرضيات التالية على أساس فرضيتين رئيسيتين يتفرع من كل منهما خمس فرضيات فرعية تحليلية وفقاً للبنود (متغيرات الدراسة):

الفرضية الرئيسية الأولى (H01): لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية.



الفرضيات التحليلية للفرضية الرئيسة الأولى:

- (H01a) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (النقد في الصندوق) في قائمة المركز المالي.
- (H01b) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم الدائنة وأوراق الدفع) في قائمة المركز المالي.
- (H01c) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المخزون) في قائمة المركز المالي.
- (H01d) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم المدينة بالصافي) في قائمة المركز المالي.
- (H01e) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (اجمالي الأصول) في قائمة المركز المالي.

الفرضية الرئيسة الثانية (H02): لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية.

الفرضيات التحليلية للفرضية الرئيسة الثانية:

- (H02a) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الإيرادات التشغيلية) في قائمة الدخل.
- (H02b) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف التشغيلية) في قائمة الدخل.
- (H02c) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف الإدارية والعمومية) في قائمة الدخل.
- (H02d) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (مصاريف البيع والتوزيع) في قائمة الدخل.
- (H02e) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (صافي الدخل) في قائمة الدخل.

الفرضية الرئيسية الثالثة (H03): لا يؤثر حجم الشركة على تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في القوائم المالية للشركات المساهمة العامة الصناعية الأردنية.

#### الدراسات السابقة

#### الدراسات باللغة العربية

دراسة الخزعلي وآخرون، (2019)، "استعمال الشبكات العصبية الاصطناعية في تحسين فاعلية القوائم المالية دراسة تطبيقية في مصرف الشرق الأوسط"

هدفت هذه الدراسة إلى توضيح أهمية استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية بالقوائم المالية واستخدمت الدراسة عينة مكونة من مصرف الشرق الأوسط العراقي للاستثمار، وتوصلت إلى وجود أخطاء جوهرية في فقرات مصرف الشرق الأوسط العراقي للاستثمار حيث كشفت نتائج الشبكة العصبية عن مستوى فقرة الأرصدة الاحتياطية وكشفت عن وجود خطأ في بند احتياطي قانوني ثم يليه بالمرتبة الثانية الفائض المتراكم ثم الاحتياطي الرأسمالي ثم احتياطات متنوعة. كما بينت الدراسة وجود أخطاء جوهرية في فقرات مصرف الشرق الأوسط العراقي للاستثمار حيث كشفت نتائج الشبكة العصبية على مستوى فقرة الموازنة التخطيطية للمصروفات وبينت وجود خطأ في الاندثارات ثم يليه بالمرتبة الثانية المصروفات التحويلية ثم يليه بالمرتبة الثالثة المستلزمات الخدمية أما بقية البنود فتكون خالية من أخطاء التدقيق.

دراسة المعموري والحسيني، (2019) "استخدام الشبكات العصبية الاصطناعية في تطوير دور مراقب الحسابات في اكتشاف الأخطاء الجوهرية"

هدفت هذه الدراسة إلى تقديم منهج ل كيفية تطبيق الشبكات العصبية الاصطناعية في الممارسة المهنية، وبيان دورها في دعم قرارات مراقب الحسابات عند التخطيط لعملية التدقيق واكتشاف الأخطاء الجوهرية كونها تقنية داعمة لإبداء الرأي الفني لمراقب الحسابات، وقد توصلت الدراسة إلى أن الشبكات العصبية الاصطناعية تساعد مراقب الحسابات عند اعتماده على تقنيات الذكاء الاصطناعي الحديثة في اكتشاف وتحديد الأخطاء الجوهرية ومدى تأثيرها على القرارات اللاحقة في التخطيط لعملية التدقيق وفي دعم الرأي الفني لمراقب الحسابات، وأوصى الباحثون باستخدام هذه

التقنية لإدارة العمل التدقيقي بالشكل الأفضل من خلال استخدام تقنيات الذكاء الاصطناعي المتطورة التي تتيح جدولة الأعمال والتخطيط للعمل ومتابعة التنفيذ ودعم الرأي المهني لمراقب الحسابات.

### دراسة العلونة (2014) بعنوان: "مدى تطبيق تقنية الشبكات العصبية الصناعية في ضبط عملية الداخلي: (دراسة ميدانية في البنوك التجارية الأردنية)"

هدفت هذه الدراسة إلى التعرف على مدى استخدام البنوك التجارية الأردنية لتقنية الشبكات العصبية الاصطناعية، في عملية التدقيق الداخلي، والتأكد من وجود مقومات، أو معوقات لاستخدامها. وقد جمع البيانات من خلال تطوير استبانة تم توزيعها على (5) يعملون في البنوك التجارية الأردنية، ومن الأساليب الإحصائية في هذه الدراسة معامل الثبات كرونباخ ألفا)، والنسب المئوية والتكرارات، والمتوسطات الحسابية، والانحرافات المعيارية، وتوصلت الدراسة إلى أن البنوك التجارية الأردنية تقوم بتطبيق تقنية الشبكات العصبية الاصطناعية بمستوى متوسط، وتبين أيضاً أن البنوك التجارية الأردنية تتوفر لديها مقومات تطبيق هذه التقنية بمستوى متوسط، وتبين عدم وجود معوقات أو تحديات تشكل عائقاً أمام استخدام تقنية الشبكات العصبية الاصطناعية في عملية التدقيق الداخلي في البنوك التجارية الأردنية.

### دراسة جمعة، (2012) بعنوان: "استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في البيانات المالية: دراسة تطبيقية"

هدفت هذه الدراسة إلى التعرف على دور الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في البيانات المالية للشركات الصناعية المدرجة في سوق عمان المالي خلال الفترة (2005-2009).

وتكونت عينة الدراسة من (51) شركة صناعية متفرعة من (9) قطاعات، وتم صياغة نموذج للانحدار الخطي وهو نموذج Radial Basis Function (RBF)، يوضح العلاقة بين متغيرات الدراسة التي شملت (10) متغيرات، منها (5) متغيرات تم استخراجها من قائمة المركز المالي للشركات، و(5) متغيرات تم استخراجها من قائمة الدخل للشركات عينة الدراسة، وتم تحليل البيانات لجميع القطاعات من ناحية، ثم لكل قطاع على حدة من ناحية أخرى.

أوضحت نتائج الدراسة وجود أخطاء جوهرية على مستوى البيانات المالية ككل للشركات الصناعية عينة الدراسة، ووجود أخطاء جوهرية على مستوى البيانات المالية لكل قطاع على حدة، وأوضحت أن هناك أهمية بالغة لاستخدام الشبكات العصبية الاصطناعية في التدقيق بشكل عام، وفي اكتشاف الأخطاء الجوهرية بشكل خاص. وقد أوصت الدراسة بضرورة أن يحصل المدققون المستقلون على دورات تدريبية بهدف التطور المهني المستقبلي، والاطلاع على المستجدات المهنية، ومتابعة التطورات التكنولوجية في مجال البرمجيات لتحسين أحكامهم المهنية بالاعتماد على تقنيات الذكاء الاصطناعي.

دراسة أرسانيوس، (2012) بعنوان: "دراسة اختبارية لاستخدام الشبكات العصبية لتطوير دور مراقب الحسابات في التقرير عن القوائم المالية المضللة"

هدفت هذه الدراسة إلى اختبار استخدام الشبكات العصبية في تحسين وتطوير دور مدقق الحسابات في التقرير عن القوائم المالية المضللة في الشركات المسجلة في البورصة المصرية. ولقد تكونت عينة الدراسة من (100) حالة من التقارير المالية المنشورة لعدد من الشركات المدرجة في البورصة المصرية، وقد تم اختيارها وتصنيفها على أساس تقارير مدققي الحسابات ومؤشرات الأداء المالي حيث تم تحديد (20) شركة تقوم بحالات غش، و(80) شركة لا تقوم بحالات غش، حيث تم استخدام دالة Fuzzy Neural Network (FNN)، وهي دالة من دوال الشبكات العصبية الاصطناعية.

وبينت أن مدقق الحسابات يواجه صعوبات في تحديد مخاطر غش الإدارة في القوائم المالية، وقد توصلت هذه الدراسة إلى أن استخدام الشبكات العصبية يسهم في اكتشاف حالات الغش في القوائم المالية. كما أوصت بتطوير وإعادة تنظيم مهنة التدقيق وتحقيق التطورات المطلوبة في قواعد وسلوك المهنة.

الدراسات باللغة الإنجليزية

دراسة Etemadi and Moghadam (2014) بعنوان:

“The Competition between Regression and Artificial Neural Network Models in Earning Management Prediction”

هدفت هذه الدراسة إلى مقارنة قوة نموذج الشبكات العصبية الاصطناعية مع الانحدار الخطي المتعدد في تنبؤات إدارة الأرباح. تكونت عينة الدراسة من 107 شركات مسجلة في بورصة طهران (TSE) في الفترة ما بين 2002-2010 وتم استثناء شركات التأمين والشركات المالية. واستخدم الباحثان مقياس إدارة الأرباح ونموذج (Jones) المعدل لحساب المستحقات التقديرية لإدارة الأرباح، كما استخدم الباحثان نموذج الشبكات العصبية الاصطناعية المتعدد الطبقات Multi-layer Perceptron (MLP). وأظهرت نتائج الدراسة أن نموذج الشبكات العصبية الاصطناعية هي أكثر قوة من الانحدار الخطي المتعدد في التنبؤ بإدارة الأرباح. وقد واجهت هذه الدراسة عدد من القيود أهمها هو أن البيانات المالية للشركات المدرجة في بورصة طهران قبل عام 2002 كان لا يمكن الوصول إليها، كما أن هناك نقص في الدراسات التي تركز فقط على تنبؤات إدارة الأرباح ونماذجها.

دراسة (2014) Rezaei and Garkaz بعنوان:

#### “Comparison of Earnings Management Prediction Using Neural Networks Model and Modified Linear Jones Model”

هدفت هذه الدراسة إلى دراسة ومقارنة التنبؤ بإدارة الأرباح وذلك باستخدام كل من نماذج الشبكات العصبية الاصطناعية، ونموذج الانحدار الخطي المعدل (Jones Model). وكان مجتمع الدراسة هو الشركات المسجلة في بورصة طهران (TSE)، وحيث بلغت عينة الدراسة (160) شركة مسجلة في بورصة طهران في الفترة ما بين (2007-2011)، بعد استبعاد الشركات التي لا تحقق المتطلبات النموذجية لغايات هذه الدراسة. وأظهرت نتائج الدراسة أن قوة التنبؤ بإدارة الأرباح قد شكلت فارق كبير ما بين استخدام نموذج الشبكات العصبية الاصطناعية، ونموذج الانحدار الخطي المعدل، فقد بينت أن نموذج الانحدار الخطي المعدل (Jones Model) يمكن أن يتنبأ بـ (51.1%) من التغيرات في إدارة الأرباح، بينما نموذج الشبكات العصبية الاصطناعية فقد تنبأ بـ (92.8%) من التغيرات في إدارة الأرباح.

دراسة (2013) Zhang بعنوان:

**“Evaluation of Machine Learning Tools for Distinguishing Fraud from Error”**

هدفت هذه الدراسة إلى التعرف على تقييم أدوات التعلم الآلي من أجل تمييز الاحتيال من الخطأ. استخدم الباحث أدوات الملاحظة وقام باستخدام عدة نماذج بالتحليل ومنها الانحدار اللوجستي، والشبكات العصبية الاصطناعية، وآلات المتجهات الداعمة (support vector machines)، وشجرة القرار. وتكونت عينة الدراسة من البيانات المالية لـ (195) شركة لفترة زمنية من عام 2001 إلى عام 2010. وأظهرت نتائج الدراسة أنه من الصعب جداً التمييز بين الخطأ والغش، كما أظهرت نتائج الدراسة أن أداء التحزيم كان الأفضل من بين أدوات التعلم الآلي. وأشارت النتائج إلى أن هناك حاجة إلى حلول أكثر تقدماً أو أكثر دقة لتصنيف الاحتيال والخطأ.

دراسة (2012) Taha بعنوان:

**“The Possibility of Using Artificial Neural Networks in Auditing–  
Theoretical Analytical Paper”**

هدفت هذه الدراسة إلى التعرف على إمكانية استخدام الشبكات العصبية الاصطناعية في التدقيق، إلى جانب التعرف على تطبيقات هذه الشبكات في مجال التدقيق المحاسبي. ولتحقيق أهداف الدراسة فقد تم استخدام المفهوم والمنهج النظري من خلال مراجعة الأدبيات السابقة والكتب والمجلات العلمية المتعلقة بموضوع الدراسة ومن ثم مناقشتها وتحليلها في ضوء الأهداف التي تم تحديدها.

أشارت نتائج الدراسة أن الشبكات العصبية الاصطناعية أكثر قدرة على التنبؤ والتخطيط لعملية التدقيق من طرق الإحصاءات التقليدية الأخرى، وقد بينت النتائج أيضاً أن الشبكات العصبية الاصطناعية لها قدرة على اكتشاف الأخطاء والغش وبيان الشركات التي لا تتلاعب في بياناتها المالية الأمر الذي يساعد المدقق الخارجي في إبداء الرأي الصحيح والدقيق.

دراسة (2010) Maria, et al. بعنوان:

**“Neural networks: The Panacea in Fraud Detection?”**

هدفت هذه الدراسة لتحديد امكانية استخدام مدقي الحسابات لتقنية الشبكات العصبية الاصطناعية للتنبؤ والوصول إلى فيما إذا كان هناك غش أو تلاعب في القوائم المالية للشركات، قيد التدقيق واستخدام الشبكات العصبية الاصطناعية كأداة لكشف الاحتيال والغش. وقد توصلت الدراسة إلى أن الدقة وصلت إلى 90% في الاكتشاف، وبناءً عليه توصلت الدراسة أنه يمكن استخدام الشبكات العصبية الاصطناعية لكشف حالات الغش في الشركات.

### ما تتميز به هذه الدراسة عن الدراسات السابقة

على الرغم من تشابه هذه الدراسة مع دراسة (جمعة، 2012)، من حيث استخدام نموذج الدراسة، ومتغيرات الدراسة، إلا أن هذه الدراسة كانت أحدث من حيث سنوات الدراسة، وقد تم جمع بيانات الدراسة وتحليلها بشكل يختلف تماماً فقد تم تقسيم البيانات واختبار الفرضيات على أساس الشركات ككل، وعلى أساس الشركات الكبيرة الحجم، وعلى أساس الشركات صغيرة الحجم، أي أنه تم أخذ تأثير حجم الشركات بعين الاعتبار، فهي ميّزت ما بين الأخطاء الجوهرية في الشركات كبيرة الحجم، والشركات صغيرة الحجم، وهذا ما لم يرد في سابقتها من الدراسات.

### منهجية الدراسة

ولتحقيق غايات الدراسة فقد تم اتباع المنهج الوصفي التحليلي، الذي يقوم على دراسة الظاهرة كما هي في الواقع من دون تدخل الباحث، ويقوم بوصفها وصفاً دقيقاً، ويعبر عنها تعبيراً كمياً من خلال جمع البيانات وتحليلها باستخدام الأساليب الإحصائية والوصول إلى استنتاجات تسهم وتفيد في تحسين الواقع الحالي.

### مصادر جمع البيانات:

لقد تم الاعتماد في هذه الدراسة على البيانات الثانوية المتمثلة بالأرقام المستخرجة من القوائم المالية للشركات المساهمة العامة الصناعية الأردنية، المسجلة في بورصة عمان، والمنشورة على موقع البورصة الإلكتروني، ودليل الشركات الأردني، حيث استخدمت البيانات التجميعية وذلك عن السنوات (2009-2013)، وهي بيانات سنوية مقطعية (Pooled Data) وهذا ما يساهم في زيادة عدد المشاهدات التي يمكن من خلالها معالجة العديد من المشاكل الإحصائية للوصول إلى نتائج أكثر دقة ويمكن تفسيرها إحصائياً، كما تم الاعتماد على المصادر الثانوية المتمثلة بالكتب

والدوريات، والأبحاث العلمية العربية والأجنبية المنشورة، والرسائل الجامعية، في سرد الدراسات السابقة وبناء الإطار النظري لهذه الدراسة.

### مجتمع وبيانات الدراسة

بعد مراجعة الأدبيات المتمثلة بالدراسات السابقة ذات العلاقة بموضوع الدراسة، ولكي يتم تبيان كيفية تطبيق نموذج الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN)، في اكتشاف الأخطاء الجوهرية في القوائم المالية، فقد تم استخراج البيانات المجمعة لمجتمع الدراسة وهو الشركات الصناعية المساهمة العامة الأردنية، المسجلة في بورصة عمان والمنشورة على موقعها الإلكتروني، والبالغ عددها (76) شركة عن السنوات (2009-2013)، وقد تم استبعاد (33) شركة وذلك لعدم اكتمال البيانات، وبالتالي فقد بلغت عينة الدراسة (43) شركة وهذه العينة تشكل (56%) من مجتمع الدراسة، حيث تعتبر هذه النسبة ممثلة بشكل جيد لمجتمع الدراسة، وتم تقسيم الشركات إلى (24) شركة كبيرة الحجم، و(19) شركة صغيرة الحجم، حيث تم اختبار فرضيات الدراسة على جميع الشركات ككل، وعلى الشركات كبيرة الحجم، وعلى الشركات صغيرة الحجم، ولإستقصاء أثر الحجم تم استخدام المتغير الوهمي لتقسيم عينة الدراسة إلى شركات كبيرة وشركات صغيرة على أساس الوسط الحسابي لموجودات الشركة.

### نموذج الدراسة

لقد أكد مجلس معايير التدقيق والتأكيد الدولي (IAASB) على واجب المدقق في تقييم وتحديد مخاطر الأخطاء الجوهرية في القوائم المالية، وعلى الرغم من أن هذه المسؤولية الملقاة على عاتق المدقق في اكتشاف الأخطاء الجوهرية تندرج تحت بند أخلاقيات المهنة، والحكم المهني للمدقق إلا أنه ومع التطور العلمي، والتقدم التكنولوجي في مجال البرمجيات، ومن أجل أن يعزز المدقق رأيه المهني ومن أجل أن يكون هذا الرأي محل ثقة المجتمع المالي، فقد تم استخدام نموذج الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في القوائم المالية، وهي عبارة عن دوال غير خطية ذات الشكل العام التالي: (جمعة، 2012)

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



حيث أن:

Y: تمثل المتغير التابع (Dependent Variable) (الأخطاء الجوهرية في القوائم المالية)

X: تمثل المتغيرات التفسيرية أو المستقلة (Independent Variable)

F-H: تمثل دوال الشبكات العصبية الاصطناعية (التفعيل-النقل)

u: تمثل حد الخطأ في الدالة Error Term

وبلغة الشبكات العصبية الاصطناعية تسمى مجموعة متغيرات (X) بالمدخلات Input، ويسمى المتغير (Y) بالمرجات أو الناتج Output، كما تسمى (H) دالة تنشيط الطبقات الخفية (HLAF) Hidden Layer Activation Function، وتسمى (F) مخرجات دالة التحفيز الخفية أو دله النقل Transfer Function.

#### متغيرات الدراسة:

لقد استخدمت في هذه الدراسة نموذج دالة Radial Basis Function (RBF)، وهي عبارة عن نموذج من نماذج الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في القوائم المالية (قائمة الدخل & قائمة المركز المالي)، حيث تكونت المتغيرات المستقلة Independent Variable والتي تسمى بلغة الشبكات العصبية الاصطناعية (X) أو المدخلات Input، من (10) متغيرات قسمت على مجموعتين، تتكون المجموعة الأولى من خمسة متغيرات من قائمة المركز المالي، وتكونت المجموعة الثانية من خمسة متغيرات من قائمة الدخل، تم استخراجهم من القوائم المالية للشركات الصناعية المساهمة العامة الأردنية، وهذه المتغيرات هي:

المجموعة الثانية: متغيرات قائمة الدخل		المجموعة الأولى: متغيرات قائمة المركز المالي	
الإيرادات التشغيلية	$X_{i1}$	النقد في الصندوق	$X_{b1}$
المصاريف التشغيلية	$X_{i2}$	الذمم الدائنة وأوراق الدفع	$X_{b2}$
المصاريف الإدارية والعمومية	$X_{i3}$	المخزون	$X_{b3}$
مصاريف البيع والتوزيع	$X_{i4}$	الذمم المدينة بالصافي	$X_{b4}$
صافي الدخل	$X_{i5}$	إجمالي الأصول	$X_{b5}$

وقد أدخلت المتغيرات الخمسة لكل مجموعة متغيرات قائمة المركز المالي، ومجموعة متغيرات قائمة الدخل حسب المعادلة التالية:

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

والمتغير التابع الذي نتج لدينا وهو الأخطاء الجوهرية في القوائم المالية، والذي يسمى بلغة الشبكات العصبية الاصطناعية (Y) Output، حيث أنتج رقم لكل بند من البنود العشرة المقسمة على مجموعتي قائمة المركز المالي وقائمة الدخل، فقد تضمن المتغيرات التالية:

المجموعة الثانية: متغيرات قائمة الدخل		المجموعة الأولى: متغيرات قائمة المركز المالي	
الإيرادات التشغيلية	$Y_{i1}$	النقد في الصندوق	$Y_{b1}$
المصاريف التشغيلية	$Y_{i2}$	الذمم الدائنة وأوراق الدفع	$Y_{b2}$
المصاريف الإدارية والعمومية	$Y_{i3}$	المخزون	$Y_{b3}$
مصاريف البيع والتوزيع	$Y_{i4}$	الذمم المدينة بالصافي	$Y_{b4}$
صافي الدخل	$Y_{i5}$	اجمالي الأصول	$Y_{b5}$

اختبار الفرضيات:

نتائج تطبيق تقنية الشبكات العصبية الاصطناعية على بنود قائمة المركز المالي:  
الفرضية الرئيسية الأولى (H01): لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية.

نتائج التطبيق على بنود قائمة المركز المالي للشركات ككل:

لقد تم تدريب الشبكة العصبية الاصطناعية بالنسبة إلى بيانات قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية باستخدام دالة Radial Basis Function (RBF)، حيث تم تدريب واختبار البيانات التاريخية لبيانات قائمة المركز المالي مع مراعاة أن Output- Input Layer = 43، وأن  $Y(\text{Dependent Variables}) = 5$ ، والجدول (1) يبين نتائج تطبيق الشبكات العصبية الاصطناعية على بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية ككل:

الجدول (1): نتائج تطبيق ANN على بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية ككل

$Y_{b1}$	$Y_{b2}$	$Y_{b3}$	$Y_{b4}$	$Y_{b5}$	AORE	Error Fun.	Tested Data	Training Data	Total Data
0.297	0.332	0.492	0.364	0.414	0.428	45.14	83	133	216
1	2	5	3	4	Rank	-	38.4%	61.6%	100%

نلاحظ من الجدول (1) أنه يوجد أخطاء جوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية، أعلاها كان في بند المخزون  $y_{b3}$  حيث بلغ رقم الخطأ في هذا البند (0.492)، يليه في الخطأ بند اجمالي الأصول  $y_{b5}$ ، الذي بلغ (0.414)، ومن ثم بند الذمم المدينة بالصافي  $y_{b4}$  فقد بلغ الخطأ الجوهري في هذا البند (0.364)، يليه بالخطأ الأقل بند الذمم الدائنة وأوراق الدفع  $y_{b2}$  حيث بلغ (0.332)، أما أقل البنود خطأ في قائمة المركز المالي فهو بند

النقد في الصندوق  $y_{b1}$  الذي أنتج أقل خطأ وهو (0.297). وذلك بالمقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.428).

ومن هنا يمكن اختبار الفرضيات الفرعية للفرضية الرئيسية الأولى:

**(H01a)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (النقد في الصندوق) قي قائمة المركز المالي:

أظهرت نتائج الجدول (1) أنه يوجد خطأ جوهري في بند النقد بالصندوق  $y_{b3}$  بلغ نسبياً (0.297) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.428)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (النقد في الصندوق) قي قائمة المركز المالي)

**(H01b)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم الدائنة وأوراق الدفع) قي قائمة المركز المالي:

أظهرت نتائج الجدول (1) أنه يوجد خطأ جوهري في بند الذمم الدائنة وأوراق الدفع  $y_{b2}$  بلغ نسبياً (0.332) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.428)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم الدائنة وأوراق الدفع) قي قائمة المركز المالي).

**(H01c)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المخزون) قي قائمة المركز المالي:

أظهرت نتائج الجدول (1) أنه يوجد خطأ جوهري في بند المخزون  $y_{b3}$  بلغ نسبياً (0.492) وبالتالي يعتبر هذا الخطأ هو الأكبر مقارنة مع باقي البنود ومع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.428)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المخزون) قي قائمة المركز المالي).

**(H01d)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم المدينة بالصافي) قي قائمة المركز المالي.

أظهرت نتائج الجدول (1) أنه يوجد خطأ جوهري في بند الذمم المدينة بالصافي  $y_{b4}$  بلغ نسبياً (0.364) وبالتالي يعتبر هذا الخطأ هو أصغر من بندي المخزون واجمالي الأصول، وأكبر من بندي النقد في الصندوق، والذمم الدائنة وأوراق الدفع، وأصغر من الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.428)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم المدينة بالصافي) في قائمة المركز المالي).  
**(H01e)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (اجمالي الأصول) في قائمة المركز المالي.

أظهرت نتائج الجدول (1) أنه يوجد خطأ جوهري في بند اجمالي الأصول  $y_{b5}$  بلغ نسبياً (0.414) وبالتالي يعتبر هذا الخطأ أصغر من الخطأ النسبي في بند المخزون، وأكبر من الخطأ النسبي في بنود الذمم المدينة بالصافي، والذمم الدائنة وأوراق الدفع، وبند النقد في المخزون، وهو أصغر من الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.428)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (اجمالي الأصول) في قائمة المركز المالي). حيث لم تتفق هذه النتيجة مع دراسة (جمعة، 2012) التي وصلت إلى أن الخطأ الأكبر كان في بند النقد في الصندوق، بينما هنا كان الخطأ الأكبر في بند المخزون.

#### نتائج التطبيق على بنود قائمة المركز المالي للشركات الكبيرة الحجم:

لقد تم تدريب الشبكة العصبية الاصطناعية بالنسبة إلى بيانات قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية، الكبيرة الحجم باستخدام دالة Radial Basis Function (RBF)، حيث تم تدريب واختبار البيانات التاريخية لبيانات قائمة المركز المالي مع مراعاة أن Output- Input Layer = 24، وأن  $Y$  (Dependent Variables) = 5، والجدول (2) يبين نتائج تطبيق الشبكات العصبية الاصطناعية على بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية الكبيرة الحجم:

الجدول (2): نتائج تطبيق ANN على بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية الكبيرة

$Y_{bl1}$	$Y_{bl2}$	$Y_{bl3}$	$Y_{bl4}$	$Y_{bl5}$	AORE	Error Fun.	Tested Data	Training Data	Total Data
0.344	0.294	0.521	0.335	0.442	0.382	33.17	44	78	122
3	1	5	2	4	Rank	-	36.07%	63.93%	100%

نلاحظ من الجدول (2) أنه يوجد أخطاء جوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية، الكبيرة الحجم، أعلاها كان في بند المخزون  $y_{bl3}$  حيث بلغ رقم الخطأ في هذا البند (0.521)، يليه في الخطأ بند إجمالي الأصول  $y_{bl5}$ ، الذي بلغ (0.442)، ومن ثم بند النقد في الصندوق  $y_{bl1}$  فقد بلغ الخطأ الجوهري في هذا البند (0.344)، يليه بالخطأ الأقل بند الذمم المدينة بالصافي  $y_{bl4}$  حيث بلغ (0.335)، أما أقل البنود خطأ في قائمة المركز المالي فهو بند الذمم الدائنة وأوراق الدفع  $y_{bl2}$  الذي أنتج أقل خطأ وهو (0.294). وذلك بالمقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AORE)، الذي بلغ (0.382).

ومن هنا يمكن اختبار الفرضيات الفرعية للفرضية الرئيسية الأولى:

**(H01a)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (النقد في الصندوق) في قائمة المركز المالي للشركات الكبيرة:

أظهرت نتائج الجدول (2) أنه يوجد خطأ جوهري في بند النقد بالصندوق  $y_{bl1}$  بلغ نسبياً (0.344) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.382)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (النقد في الصندوق) في قائمة المركز المالي للشركات الكبيرة)

**(H01b)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم الدائنة وأوراق الدفع) في قائمة المركز المالي للشركات الكبيرة:

أظهرت نتائج الجدول (2) أنه يوجد خطأ جوهري في بند الذمم الدائنة وأوراق الدفع  $y_{b12}$  بلغ نسبياً (0.294) وبالتالي يعتبر هذا الخطأ هو الأصغر مقارنة مع باقي البنود ومع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.382)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم الدائنة وأوراق الدفع) في قائمة المركز المالي للشركات الكبيرة).

**(H01c)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المخزون) في قائمة المركز المالي للشركات الكبيرة:

أظهرت نتائج الجدول (2) أنه يوجد خطأ جوهري في بند المخزون  $y_{b13}$  بلغ نسبياً (0.521) وبالتالي يعتبر هذا الخطأ هو الأكبر مقارنة مع باقي البنود ومع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.382)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المخزون) في قائمة المركز المالي للشركات الكبيرة).

**(H01d)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم المدينة بالصافي) في قائمة المركز المالي للشركات الكبيرة.

أظهرت نتائج الجدول (2) أنه يوجد خطأ جوهري في بند الذمم المدينة بالصافي  $y_{b14}$  بلغ نسبياً (0.335) وبالتالي يعتبر هذا الخطأ هو أكبر من بند الذمم الدائنة وأوراق الدفع، وأصغر من باقي البنود، وأصغر من الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.382)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم المدينة بالصافي) في قائمة المركز المالي للشركات الكبيرة).

**(H01e)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (اجمالي الأصول) في قائمة المركز المالي للشركات الكبيرة.

أظهرت نتائج الجدول (2) أنه يوجد خطأ جوهري في بند إجمالي الأصول  $y_{b15}$  بلغ نسبياً (0.442) وبالتالي يعتبر هذا الخطأ أصغر من الخطأ النسبي في بند المخزون، وأكبر من الخطأ النسبي في بنود الذمم المدينة بالصافي، والذمم الدائنة وأوراق الدفع، وبند النقد في الصندوق، وهو

أكبر من الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.382)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (إجمالي الأصول) في قائمة المركز المالي للشركات الكبيرة).

### نتائج التطبيق على بنود قائمة المركز المالي للشركات الصغيرة الحجم:

لقد تم تدريب الشبكة العصبية الاصطناعية بالنسبة إلى بيانات قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية، الصغيرة الحجم باستخدام دالة Radial Basis Function (RBF)، حيث تم تدريب واختبار البيانات التاريخية لبيانات قائمة المركز المالي مع مراعاة أن Output- Input Layer = 19، وأن  $Y$  (Dependent Variables) = 5، والجدول (3) يبين نتائج تطبيق الشبكات العصبية الاصطناعية على بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية، الصغيرة الحجم:

الجدول (3): نتائج تطبيق ANN على بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية الصغيرة

$Y_{bs1}$	$Y_{bs2}$	$Y_{bs3}$	$Y_{bs4}$	$Y_{bs5}$	AORE	Error Fun.	Tested Data	Training Data	Total Data
0.324	0.488	0.463	0.444	0.517	0.479	54.15	27	67	94
1	4	3	2	5	Rank	-	28.72%	71.28%	100%

نلاحظ من الجدول (3) أنه يوجد أخطاء جوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية، الصغيرة الحجم، أعلاها كان في بند إجمالي الأصول  $y_{bs5}$  حيث بلغ رقم الخطأ في هذا البند (0.517)، يليه في الخطأ بند الذمم الدائنة وأوراق الدفع  $y_{bs2}$ ، الذي بلغ (0.488)، ومن ثم بند المخزون  $y_{bs3}$  فقد بلغ الخطأ الجوهري في هذا البند (0.463)، يليه بالخطأ الأقل بند الذمم المدينة بالصافي  $y_{bs4}$  حيث بلغ (0.444)، أما أقل البنود خطأ في قائمة



المركز المالي فهو بند النقد في الصندوق  $y_{bs1}$  الذي أنتج أقل خطأ وهو (0.324). وذلك بالمقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER) الذي بلغ (0.479).

ومن هنا يمكن اختبار الفرضيات الفرعية للفرضية الرئيسية الأولى:

**(H01a)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند

(النقد في الصندوق) قي قائمة المركز المالي للشركات الصغيرة:

أظهرت نتائج الجدول (3) أنه يوجد خطأ جوهري في بند النقد بالصندوق  $y_{bs1}$  بلغ نسبياً (0.324) وبالتالي يعتبر هذا الخطأ هو الأصغر مقارنة مع باقي البنود ومع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.479)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (النقد في الصندوق) قي قائمة المركز المالي للشركات الصغيرة).

**(H01b)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند

(الذمم الدائنة وأوراق الدفع) قي قائمة المركز المالي للشركات الصغيرة:

أظهرت نتائج الجدول (3) أنه يوجد خطأ جوهري في بند الذمم الدائنة وأوراق الدفع  $y_{bs2}$  بلغ نسبياً (0.488) وبالتالي يعتبر هذا الخطأ هو أصغر من الخطأ في بند إجمالي الأصول، وأكبر من الخطأ في باقي البنود، والوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.479)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم الدائنة وأوراق الدفع) قي قائمة المركز المالي للشركات الصغيرة).

**(H01c)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند

(المخزون) قي قائمة المركز المالي للشركات الصغيرة:

أظهرت نتائج الجدول (3) أنه يوجد خطأ جوهري في بند المخزون  $y_{bs3}$  بلغ نسبياً (0.463) وبالتالي يعتبر هذا الخطأ هو كبير نسبياً مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) (Average Overall Relative Error)، الذي بلغ (0.479)، وهذا ما يقودنا إلى قبول الفرضية

العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المخزون) قي قائمة المركز المالي للشركات الصغيرة).

**(H01d)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم المدينة بالصافي) قي قائمة المركز المالي للشركات الصغيرة:

أظهرت نتائج الجدول (3) أنه يوجد خطأ جوهري في بند الذمم المدينة بالصافي  $y_{bs4}$  بلغ نسبياً (0.444) وبالتالي يعتبر هذا الخطأ هو أكبر من بند النقد في الصندوق، وأصغر من باقي البنود، وأصغر من الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.479)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الذمم المدينة بالصافي) قي قائمة المركز المالي للشركات الصغيرة).

**(H01e)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (اجمالي الأصول) قي قائمة المركز المالي للشركات الصغيرة:

أظهرت نتائج الجدول (3) أنه يوجد خطأ جوهري في بند إجمالي الأصول  $y_{bs5}$  بلغ نسبياً (0.517) وبالتالي يعتبر هذا الخطأ هو الخطأ الأكبر، لأنه بلغ قيمة أكبر من باقي البنود ومن الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.479)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (اجمالي الأصول) قي قائمة المركز المالي للشركات الصغيرة).

من خلال اختبار الفرضيات الفرعية للفرضية الرئيسية الأولى نستنتج عدم صحة الفرضية الرئيسية الأولى، وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية)، وبالتالي فإن تطبيق نماذج الشبكات العصبية الاصطناعية على بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية، أظهر وجود أخطاء جوهرية في تلك القوائم.

نتائج تطبيق تقنية الشبكات العصبية الاصطناعية على بنود قائمة الدخل:  
الفرضية الرئيسية الثانية (H02): لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية.  
نتائج التطبيق على بنود قائمة الدخل للشركات ككل:

لقد تم تدريب الشبكة العصبية الاصطناعية بالنسبة إلى بيانات قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية باستخدام دالة Radial Basis Function (RBF)، حيث تم تدريب واختبار البيانات التاريخية لبيانات قائمة الدخل مع مراعاة أن Output- Input Layer = 43، وأن  $Y$  (Dependent Variables) = 5، والجدول (4) يبين نتائج تطبيق الشبكات العصبية الاصطناعية على بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية ككل:

الجدول (4): نتائج تطبيق ANN على بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية ككل

$Y_{i1}$	$Y_{i2}$	$Y_{i3}$	$Y_{i4}$	$Y_{i5}$	AORE	Error Fun.	Tested Data	Training Data	Total Data
0.214	0.394	0.291	0.243	0.412	0.331	35.54	64	152	216
1	4	3	2	5	Rank	-	29.63	70.73	100%

نلاحظ من الجدول (4) أنه يوجد أخطاء جوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية، أعلاها كان في بند صافي الدخل  $y_{i5}$  حيث بلغ رقم الخطأ في هذا البند (0.412)، يليه في الخطأ بند المصاريف التشغيلية  $y_{i2}$ ، الذي بلغ (0.394)، ومن ثم بند الذمم المصاريف الإدارية والعمومية  $y_{i3}$  فقد بلغ الخطأ الجوهري في هذا البند (0.291)، يليه بالخطأ الأقل بند مصاريف البيع والتوزيع  $y_{i4}$  حيث بلغ (0.243)، أما أقل البنود خطأ في قائمة المركز المالي فهو بند النقد في الإيرادات التشغيلية  $y_{i1}$  الذي أنتج أقل خطأ وهو (0.214). وذلك بالمقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AORE))، الذي بلغ (0.331).

ومن هنا يمكن اختبار الفرضيات الفرعية للفرضية الرئيسية الثانية:

**(H02a)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الإيرادات التشغيلية) في قائمة الدخل.

أظهرت نتائج الجدول (4) أنه يوجد خطأ جوهري في بند الإيرادات التشغيلية  $y_{i1}$  بلغ نسبياً (0.214) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) Average Overall Relative Error، الذي بلغ (0.331)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الإيرادات التشغيلية) في قائمة الدخل).

**(H02b)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف التشغيلية) في قائمة الدخل.

أظهرت نتائج الجدول (4) أنه يوجد خطأ جوهري في بند المصاريف التشغيلية  $y_{i2}$  بلغ نسبياً (0.394) وبالتالي يعتبر هذا الخطأ كبير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) Average Overall Relative Error، الذي بلغ (0.331)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف التشغيلية) في قائمة الدخل).

**(H02c)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف الإدارية والعمومية) في قائمة الدخل.

أظهرت نتائج الجدول (4) أنه يوجد خطأ جوهري في بند المصاريف الإدارية والعمومية  $y_{i3}$  بلغ نسبياً (0.291) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) Average Overall Relative Error، الذي بلغ (0.331)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف الإدارية والعمومية) في قائمة الدخل).

**(H02d)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (مصاريف البيع والتوزيع) في قائمة الدخل.

أظهرت نتائج الجدول (4) أنه يوجد خطأ جوهري في بند مصاريف البيع والتوزيع  $y_{i4}$  بلغ نسبياً (0.243) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER)

Average Overall Relative Error، الذي بلغ (0.331)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (مصاريف البيع والتوزيع) في قائمة الدخل).  
(H02e) لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (صافي الدخل) في قائمة الدخل.

أظهرت نتائج الجدول (4) أنه يوجد خطأ جوهري في بند صافي الدخل  $y_{i5}$  بلغ نسبياً (0.412) وبالتالي يعتبر هذا الخطأ الأكبر مقارنة مع باقي البنود ومع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.331)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (صافي الدخل) في قائمة الدخل). حيث لم تتفق هذه النتيجة مع دراسة (جمعة، 2012) التي وصلت إلى أن الخطأ الأكبر كان في بند مصاريف البيع والتوزيع، بينما هنا كان الخطأ الأكبر في بند صافي الدخل.

#### (5-4-2) نتائج التطبيق على بنود قائمة الدخل للشركات الكبيرة الحجم:

لقد تم تدريب الشبكة العصبية الاصطناعية بالنسبة إلى بيانات قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية، الكبيرة الحجم باستخدام دالة Radial Basis Function (RBF)، حيث تم تدريب واختبار البيانات التاريخية لبيانات قائمة الدخل مع مراعاة أن Output- Input Layer=24، وأن  $Y$  (Dependent Variables) = 5، والجدول (5) يبين نتائج تطبيق الشبكات العصبية الاصطناعية على بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية الكبيرة الحجم:

الجدول (5): نتائج تطبيق ANN على بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية الكبيرة

$Y_{il1}$	$Y_{il2}$	$Y_{il3}$	$Y_{il4}$	$Y_{il5}$	AORE	Error Fun.	Tested Data	Training Data	Total Data
0.284	0.319	0.362	0.233	0.212	0.301	24.66	39	83	122
3	4	5	2	1	Rank	-	31.97%	68.03%	100%

نلاحظ من الجدول (5) أنه يوجد أخطاء جوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية، الكبيرة الحجم، أعلاها كان في بند المصاريف الإدارية والعمومية  $y_{i13}$  حيث بلغ رقم الخطأ في هذا البند (0.362)، يليه في الخطأ بند المصاريف التشغيلية  $y_{i12}$ ، الذي بلغ (0.319)، ومن ثم بند الإيرادات التشغيلية  $y_{i11}$  فقد بلغ الخطأ الجوهري في هذا البند (0.284)، يليه بالخطأ الأقل بند مصاريف البيع والتوزيع  $y_{i14}$  حيث بلغ (0.233)، أما أقل البنود خطأ في قائمة الدخل فهو بند صافي الدخل  $y_{i15}$  الذي أنتج أقل خطأ وهو (0.212). وذلك بالمقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AORE))، الذي بلغ (0.301).

ومن هنا يمكن اختبار الفرضيات الفرعية للفرضية الرئيسية الثانية:

**(H02a)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الإيرادات التشغيلية) في قائمة الدخل للشركات الكبيرة.

أظهرت نتائج الجدول (5) أنه يوجد خطأ جوهري في بند الإيرادات التشغيلية  $y_{i11}$  بلغ نسبياً (0.284) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) Average Overall Relative Error، الذي بلغ (0.301)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الإيرادات التشغيلية) في قائمة الدخل للشركات الكبيرة).

**(H02b)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف التشغيلية) في قائمة الدخل للشركات الكبيرة.

أظهرت نتائج الجدول (5) أنه يوجد خطأ جوهري في بند المصاريف التشغيلية  $y_{i12}$  بلغ نسبياً (0.319) وبالتالي يعتبر هذا الخطأ كبير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) Average Overall Relative Error، الذي بلغ (0.301)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف التشغيلية) في قائمة الدخل للشركات الكبيرة).

**(H02c)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف الإدارية والعمومية) في قائمة الدخل للشركات الكبيرة.

أظهرت نتائج الجدول (5) أنه يوجد خطأ جوهري في بند المصاريف الإدارية والعمومية  $y_{i13}$  بلغ نسبياً (0.362) وبالتالي يعتبر هذا الخطأ الأكبر مقارنة مع باقي البنود ومقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.301)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف الإدارية والعمومية) في قائمة الدخل للشركات الكبيرة).

**(H02d)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (مصاريف البيع والتوزيع) في قائمة الدخل للشركات الكبيرة.

أظهرت نتائج الجدول (5) أنه يوجد خطأ جوهري في بند مصاريف البيع والتوزيع  $y_{i14}$  بلغ نسبياً (0.233) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) Average Overall Relative Error، الذي بلغ (0.301)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (مصاريف البيع والتوزيع) في قائمة الدخل للشركات الكبيرة).

**(H02e)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (صافي الدخل) في قائمة الدخل للشركات الكبيرة.

أظهرت نتائج الجدول (5) أنه يوجد خطأ جوهري في بند صافي الدخل  $y_{i15}$  بلغ نسبياً (0.212) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع باقي البنود ومع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.301)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (صافي الدخل) في قائمة الدخل للشركات الكبيرة).

#### نتائج التطبيق على بنود قائمة الدخل للشركات الصغيرة الحجم:

لقد تم تدريب الشبكة العصبية الاصطناعية بالنسبة إلى بيانات قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية، الصغيرة الحجم باستخدام دالة Radial Basis Function (RBF)، حيث تم تدريب واختبار البيانات التاريخية لبيانات قائمة الدخل مع مراعاة أن Output- Input Layer = 19، وأن  $Y$  (Dependent Variables) = 5، والجدول (6) يبين نتائج تطبيق

الشبكات العصبية الاصطناعية على بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية، الصغيرة الحجم:

الجدول (6): نتائج تطبيق ANN على بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية الصغيرة

$Y_{is1}$	$Y_{is2}$	$Y_{is3}$	$Y_{is4}$	$Y_{is5}$	AORE	Error Fun.	Tested Data	Training Data	Total Data
0.328	0.404	0.379	0.421	0.462	0.391	41.99	32	62	94
1	3	2	4	5	Rank	-	34.04%	65.96%	100%

نلاحظ من الجدول (6) أنه يوجد أخطاء جوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية، الصغيرة الحجم، أعلاها كان في بند صافي الدخل  $y_{is5}$  حيث بلغ رقم الخطأ في هذا البند (0.462)، يليه في الخطأ بند مصاريف البيع والتوزيع  $y_{is4}$ ، الذي بلغ (0.421)، ومن ثم بند المصاريف التشغيلية  $y_{is2}$  فقد بلغ الخطأ الجوهري في هذا البند (0.404)، يليه بالخطأ الأقل بند المصاريف الإدارية والعمومية  $y_{is3}$  حيث بلغ (0.379)، أما أقل البنود خطأ في قائمة المركز المالي فهو بند الإيرادات التشغيلية  $y_{is1}$  الذي أنتج أقل خطأ وهو (0.328). وذلك بالمقارنة مع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER))، الذي بلغ (0.391).

ومن هنا يمكن اختبار الفرضيات الفرعية للفرضية الرئيسية الثانية:

**(H02a)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الإيرادات التشغيلية) في قائمة الدخل للشركات الصغيرة.

أظهرت نتائج الجدول (6) أنه يوجد خطأ جوهري في بند الإيرادات التشغيلية  $y_{is1}$  بلغ نسبياً (0.328) وبالتالي يعتبر هذا الخطأ الأصغر مقارنةً مع باقي البنود ومع الوسط الحسابي للخطأ النسبي (AOER) الذي بلغ (0.391)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية



الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (الإيرادات التشغيلية) في قائمة الدخل للشركات الصغيرة).

**(H02b)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف التشغيلية) في قائمة الدخل للشركات الصغيرة.

أظهرت نتائج الجدول (6) أنه يوجد خطأ جوهري في بند المصاريف التشغيلية  $y_{is2}$  بلغ نسبياً (0.404) وبالتالي يعتبر هذا الخطأ كبير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) Average Overall Relative Error، الذي بلغ (0.391)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف التشغيلية) في قائمة الدخل للشركات الصغيرة).

**(H02c)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف الإدارية والعمومية) في قائمة الدخل للشركات الصغيرة.

أظهرت نتائج الجدول (6) أنه يوجد خطأ جوهري في بند المصاريف الإدارية والعمومية  $y_{is3}$  بلغ نسبياً (0.379) وبالتالي يعتبر هذا الخطأ صغير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) Average Overall Relative Error، الذي بلغ (0.391)، وهذا ما يقودنا إلى قبول الفرضية العدمية ورفض الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (المصاريف الإدارية والعمومية) في قائمة الدخل للشركات الصغيرة).

**(H02d)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (مصاريف البيع والتوزيع) في قائمة الدخل للشركات الصغيرة.

أظهرت نتائج الجدول (6) أنه يوجد خطأ جوهري في بند مصاريف البيع والتوزيع  $y_{is4}$  بلغ نسبياً (0.421) وبالتالي يعتبر هذا الخطأ كبير مقارنة مع الوسط الحسابي للخطأ النسبي (AOER) Average Overall Relative Error، الذي بلغ (0.391)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (مصاريف البيع والتوزيع) في قائمة الدخل للشركات الصغيرة).

**(H02e)** لا يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (صافي الدخل) في قائمة الدخل للشركات الصغيرة.

أظهرت نتائج الجدول (6) أنه يوجد خطأ جوهري في بند صافي الدخل  $y_{is5}$  بلغ نسبياً (0.462) وبالتالي يعتبر هذا الخطأ كبير مقارنةً مع باقي البنود ومع الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، الذي بلغ (0.391)، وهذا ما يقودنا إلى رفض الفرضية العدمية وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بند (صافي الدخل) في قائمة الدخل للشركات الصغيرة). من خلال اختبار الفرضيات الفرعية للفرضية الرئيسية الثانية نستنتج عدم صحة الفرضية الرئيسية الثانية، وقبول الفرضية البديلة وهي (يؤثر تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية)، وبالتالي فإن تطبيق نماذج الشبكات العصبية الاصطناعية على بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية، أظهر وجود أخطاء جوهرية في تلك القوائم.

#### أثر الحجم على اكتشاف الأخطاء الجوهرية:

أشارت الكثير من الدراسات أن حجم الشركة يرتبط ببعض المؤثرات والمشاكل التي قد تواجه الشركة في السوق، مثل عدم تكامل المعلومات وحجم مشاكل الوكالة الناتجة عنها وهو ما يؤثر على درجة تطبيق تقنية الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في قوائم الشركة، فالشركات الكبيرة تواجه اهتمام من قبل مراكز البحث، والمؤسسات الاستثمارية، وهو ما يدفعها إلى تطبيق المعايير والأسس المالية والمحاسبية بشكل دقيق مما يؤدي إلى حدوث أخطاء قليلة، وبالنظر إلى الجدول (2) والجدول (5) نلاحظ أن الوسط الحسابي للخطأ النسبي (Average Overall Relative Error، قد بلغ (0.382) في بنود قائمة المركز المالي، وبلغ (0.301) في بنود قائمة الدخل.

أما بالنسبة للشركات الصغيرة الحجم فهي ذات اهتمام أقل من قبل مراكز البحث والمؤسسات الاستثمارية، وهي لا تطبق الأسس والمعايير المحاسبية بشكل كامل مما يؤدي إلى حدوث أخطاء جوهرية أكبر من تلك التي حدثت في الشركات الكبيرة، وبالنظر إلى الجدول (3) والجدول (6) نلاحظ أن الوسط الحسابي للخطأ النسبي (Average Overall Relative Error (AOER)، قد بلغ (0.479) في بنود قائمة المركز المالي، وبلغ (0.391) في بنود قائمة الدخل، وهذا ما يؤكد

أن القوائم المالية للشركات الصغيرة الحجم تحوي على أخطاء جوهرية أكبر من الأخطاء الجوهرية التي تحويها قوائم الشركات الكبيرة الحجم. وهذا يقودنا إلى استنتاج عدم صحة الفرضية الرئيسية الثالثة، وقبول الفرضية البديلة وهي (يؤثر حجم الشركة على تطبيق الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في القوائم المالية للشركات المساهمة العامة الصناعية الأردنية).

### النتائج والاستنتاجات والتوصيات

#### النتائج:

1- وصلت الدراسة إلى نتيجة تفضي لأهمية بالغة لاستخدام تقنية الشبكات العصبية الاصطناعية في التدقيق بشكل عام، وفي اكتشاف الأخطاء الجوهرية في القوائم المالية شكل خاص، لأن جميع قرارات المدققين والمحاسبين القانونيين مرتبطة ارتباط وثيق ببعضها البعض بشكل متتابع، لذلك إن استخدام الشبكات لا يؤثر فقط على اكتشاف الأخطاء الجوهرية فحسب إنما يساهم في تحسين جودة القرارات اللاحقة التي تضمن كفاءة عملية التدقيق وهذا ما يتفق مع دراسة (زلوم، وآخرون، 2014).

2- اكتشفت تقنية الشبكات العصبية الاصطناعية أخطاء جوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية ككل، كان أعلاها في بند المخزون بينما توصلت دراسة (جمعة، 2012) إلى أخطاء جوهرية أعلاها في بند النقدية.

3- اكتشفت تقنية الشبكات العصبية الاصطناعية أخطاء جوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية الكبيرة الحجم، كان أعلاها في بند المخزون وهذا يدل على قلة الاهتمام بعملية ضبط المخزون بشكل كافي.

4- اكتشفت تقنية الشبكات العصبية الاصطناعية أخطاء جوهرية في بنود قائمة المركز المالي للشركات المساهمة العامة الصناعية الأردنية الصغيرة الحجم، كان أعلاها في بند إجمالي الأصول وهنا يجب تقييم الأصول بشكل دقيق.

5- اكتشفت تقنية الشبكات العصبية الاصطناعية أخطاء جوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية ككل، كان أعلاها في بند صافي الدخل بينما توصلت دراسة (جمعة، 2012) إلى أخطاء جوهرية أعلاها في بند مصاريف البيع والتوزيع.

- 6- اكتشفت تقنية الشبكات العصبية الاصطناعية أخطاء جوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية الكبيرة الحجم، كان أعلاها في بند المصاريف الإدارية والعمومية وهذا من الممكن أن يكون ناتج عن تضخيم المصاريف الإدارة من قبل الإدارة.
- 7- اكتشفت تقنية الشبكات العصبية الاصطناعية أخطاء جوهرية في بنود قائمة الدخل للشركات المساهمة العامة الصناعية الأردنية الصغيرة الحجم، كان أعلاها في بند صافي الدخل.
- 8- يوجد تأثير لحجم الشركة على تطبيق تقنية الشبكات العصبية الاصطناعية في اكتشاف الأخطاء، حيث أن الأخطاء المكتشفة في الشركات الصغيرة كانت أكبر من تلك المكتشفة في الشركات الكبيرة.

#### الاستنتاجات:

- توصلت الدراسة في ضوء النتائج إلى عدد من الاستنتاجات أهمها:
1. يوجد امكانية كبيرة لتطبيق الشبكات العصبية الاصطناعية في التدقيق بشكل عام، فهي تؤثر بشكل إيجابي وتساعد المدققين والمحاسبين القانونيين في تحسين جودة التدقيق.
  2. أدى تطبيق الشبكات العصبية الاصطناعية إلى اكتشاف الأخطاء الجوهرية في القوائم المالية للشركات المساهمة الصناعية الأردنية.
  3. تحوي قوائم الشركات الصغيرة الحجم على أخطاء أكبر من الأخطاء الموجودة في الشركات الكبيرة الحجم.
  4. الشركات الكبيرة الحجم تهتم بشكل كبير بالالتزام بمعايير وأسس إعداد قوائمها المالية وذلك بسبب الميزة التنافسية وبسبب اهتمام المستثمرين والمجتمع المالي فيها.
  5. يجب على الشركات الصناعية المساهمة العامة الأردنية الاهتمام بسياسة ضبط المخزون لديها، وتقييم أصولها بناء على معايير المحاسبة الدولية، وبشكل دقيق.

#### التوصيات:

تقترح الدراسة التوصيات التالية:

- 1- لقد أوصت الدراسة المحاسبين القانونيين والمدققين الذين يزاولون مهنة التدقيق بالحصول على دورات تدريبية في تقنية الشبكات العصبية الاصطناعية، وذلك من أجل التوصل لتحسين جودة

الأحكام والقرارات المهنية التي يطلقونها، لأن الشبكات العصبية الاصطناعية تساهم في تحسين كفاءة وفعالية التدقيق.

2-توصي الدراسة جميع المحاسبين القانونيين والمدققين الاطلاع الدائم والمستمر على التطورات التكنولوجية التي تستجد في عالم التكنولوجيا المحاسبية والإحصائية، والتحديث الدائم للمعلومات والاستفادة الدائمة منها في تحسين جودة التدقيق.

3-توصي الدراسة الجامعات والمؤسسات التعليمية بضرورة إدخال تقنية الشبكات العصبية الاصطناعية ضمن مناهج التدريس من أجل أن يكتسب الطلاب مهارات إضافية وحديثة نسبياً تُزاد إلى معارفهم المحاسبية وتساعدهم في حل المشكلات المحاسبية مستقبلاً كل في موقع عمله.

4-توصي الدراسة الشركات الصغيرة الحجم بضرورة اتباع الأسس والمبادئ المحاسبية الضرورية في سرد وإعداد قوائمها المالية وذلك من أجل الخروج بقوائم مالية أكثر دقة ومن أجل تقليل الأخطاء الجوهرية فيها.

5- توصي الدراسة جميع الباحثين المستقبليين بإجراء دراسات تطبيقية للشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في القوائم المالية في قطاعات أخرى مثل البنوك وشركات التأمين وشركات الخدمات.

## المراجع:

### أ) المراجع باللغة العربية:

- الاتحاد الدولي للمحاسبين "إصدارات المعايير الدولية لممارسة أعمال التدقيق والتأكد وقواعد أخلاقيات المهنة 2007"، ترجمة جمعية المجمع العربي للمحاسبين القانونيين، عمان، الأردن.
- الإتحاد الدولي للمحاسبين (2003). "إصدارات المعايير الدولية لممارسة أعمال التدقيق والتأكد وقواعد أخلاقيات المهنة" - معيار التدقيق الدولي رقم 240 (مسؤولية المدقق في اعتبار الاحتيال والخطأ عند التدقيق).
- أرسانيوس، بدر نبيه، (2012) "دراسة اختبارية لاستخدام الشبكات العصبية لتطوير دور مراقب الحسابات في التقرير عن القوائم المالية المضللة"، المؤتمر العلمي السنوي الحادي عشر: ذكاء الأعمال واقتصاد المعرفة، جامعة الزيتونة الأردنية، عمان: الأردن.
- جمعة، أحمد حلمي. (2012). "استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في البيانات المالية: دراسة تطبيقية"، المؤتمر العلمي السنوي الحادي عشر: ذكاء الأعمال واقتصاد المعرفة، جامعة الزيتونة الأردنية، عمان، الأردن.
- جميل، أحمد، وعثمان، عثمان، (2012). "إمكانية استخدام تقنيات الذكاء الصناعي في ضبط جودة التدقيق الداخلي: دراسة ميدانية في الشركات المساهمة العامة لأردنية"، المؤتمر العلمي السنوي الحادي عشر: ذكاء الأعمال واقتصاد المعرفة، جامعة الزيتونة الأردنية، عمان: الأردن.
- الخرزلي، الاء وعطاء، رشا وغنى، علي، (2019) " استعمال الشبكات العصبية الاصطناعية في تحسين فاعلية القوائم المالية"، مجلة المستنصرية للدراسات العربية والدولية، 6، 39-119.
- راشد، صفوان؛ رشيد، خيرى، وزكي، عزة. (2012)، "مقارنة بين أسلوبى الشبكات العصبية الاصطناعية والمربعات الصغرى للنماذج الخطية وغير الخطية مع التطبيق"، المجلة العراقية للعلوم الإحصائية، العدد (21)، ص ص 246-265.
- الرماحي، نواف، (2009) "مراجعة العمليات المالية" الطبعة الاولى، دار صفاء للنشر والتوزيع، عمان.
- رياض، سامح محمد رضا. (2010)، اكتشاف الغش والتلاعب في القوائم المالية، مكتبة الملك فهد الوطنية، الرياض، السعودية.

- زلوم، عمر زلوم، والعبادي، هيثم ممدوح، وهاشم، فراس نائل، (2014) "دعم رأي المهني للمدقق باستخدام تقنيات البحث عن البيانات في التنبؤ بوجود أخطاء جوهرية في القوائم المالية"، المجلة الأردنية في إدارة الأعمال، المجلد 10، العدد 2.
- العجال، عدالة. (2010). "تمذجة التنبؤ بالمبيعات باستخدام الشبكات العصبية: دراسة حالة الشركة الوطنية للصناعات الميكانيكية ولواحقها"، مجلة العلوم الاجتماعية والإنسانية، العدد (22)، ص ص 167-194.
- العلاونة، مصطفى اشتيوي. (2014). "مدى تطبيق تقنية الشبكات العصبية الصناعية في ضبط عملية التدقيق الداخلي: دراسة ميدانية في البنوك التجارية الأردنية"، رسالة ماجستير، جامعة اليرموك، الأردن.
- المعموري، علي والحُسيني، هدى، (2019)، استخدام الشبكات العصبية الاصطناعية في تطوير دور مراقب الحسابات في اكتشاف الأخطاء الجوهرية، مجلة دراسات محاسبية ومالية.
- 10(31) DOI: 10.34093/jafs. v10i31.373
- ياسين، سعد غالب. (2006). نظم المعلومات الإدارية وتكنولوجيا المعلومات، الطبعة الأولى، دار المناهج، عمان، الأردن.

(ب) المراجع باللغة الأجنبية:

- Etemadi, H., and Moghadam, R. (2014). The Competition between Regression and Artificial Neural Network Models in Earning Management Prediction. *International Review of Business Research Papers* 10 (2): 148–159.
- Maria Krambia-Kapardis, Chris Christodoulou, Michalis Agathocleous, (2010) "Neural Networks: The Panacea in Fraud Detection?", *Managerial Auditing Journal*, Vol. 25 Iss: 7, pp.659 – 678.
- Pourheydari, O., Nezamabadi, H., Aazami, Z., (2012), "Identifying Qualified Audit Opinions by Artificial Neural Networks", *Shahid Bahonar University of Kerman, Pajohesh Square, Kerman, Iran*.
- Rezaei, Ali Ashghar, and Garkaz, Mansour. (2014). "Comparison of Earnings Management Prediction Using Neural Networks Model and Modified Linear Jones Model". *Asian Journal of Research in Social Sciences and Humanities* Vol. 4, No. 7, pp. 456–465.
- Robu, I(2012) "Operspectiva Financiara aAsupra Triunghiului fraudei: A Financial Perspective of Fraud Triangle", *Audit Financiar*, 10, 1, 12–23.
- Taha, R., O., (2012). "The Possibility of Using Artificial Neural Networks in Auditing – Theoretical Analytical Paper", *European Journal of Economics, Finance and Administrative Sciences*, Issue 47, pp. 43–56.
- Zhang, M, (2013). Evaluation of Machine Learning Tools for Distinguishing Fraud from Error. *Journal of Business & Economics Research* 11 (9): 393–400.