

استخدام الشبكات العصبية متعددة الطبقات في التنبؤ بمخاطر الائتمان لمنشآت  
الأعمال: دراسة تطبيقية

بحث مستخرج من رسالة دكتوراه لم تناقش بعد بعنوان  
" قياس قدرة المؤشرات المالية وغير المالية لمنشآت الأعمال باستخدام نماذج الشبكات العصبية:  
دراسة تطبيقية "

المشرف

أ.د. طارق محمد حسانين إسماعيل

أستاذ المراجعة

كلية التجارة - جامعة القاهرة

الباحث

حسام محمد محمد عثمان

مدرس مساعد

المعهد العالي للدراسات المتطورة

[hmmosman@gmail.com](mailto:hmmosman@gmail.com)

01011555378

## استخدام الشبكات العصبية متعددة الطبقات في التنبؤ بمخاطر الائتمان لمنشآت الأعمال: دراسة تطبيقية

### ملخص:

يهدف هذا البحث إلى اختبار قدرة نماذج الشبكات العصبية متعددة الطبقات في تحسين دقة التنبؤ بمخاطر الائتمان التي تواجه منشآت الأعمال مقارنة بالنماذج الإحصائية التقليدية، وذلك من خلال تطوير نموذج للدراسة تعتمد مدخلاته على مجموعة من النسب والمؤشرات المالية التي تم الحصول عليها من عينة من منشآت الأعمال المدرجة بسوق الأوراق المالية المصرية. تم اختبار مدى قدرة الشبكات العصبية متعددة الطبقات على التنبؤ بمخاطر الائتمان من خلال تحليل واختبار نموذج الدراسة باستخدام كل من الانحدار اللوجستي، ونماذج الشبكات العصبية متعددة الطبقات، وذلك للوصول إلى دقة تصنيف المنشآت إلى منشآت معرضة لمخاطر الائتمان وغير معرضة لمخاطر الائتمان بالتطبيق على عينة من منشآت الأعمال المسجلة بسوق الأوراق المالية المصرية وعددها (٨٣) منشأة على مدار عشرة سنوات (٢٠١٠ - ٢٠١٩) بإجمالي (٨٢٤) مشاهدة. خلص البحث إلى تميز نماذج الشبكات العصبية متعددة الطبقات بدقة تنبؤية مرتفعة عن غيرها من النماذج الإحصائية في تحسين قدرة المؤشرات المالية على التنبؤ بمخاطر الائتمان لمنشآت الأعمال، بالإضافة إلى قدرتها على تحديد المزيج الأمثل من النسب والمؤشرات المالية الذي يحقق أفضل كفاءة وفعالية للشبكات العصبية متعددة الطبقات في التنبؤ.

**الكلمات المفتاحية:** الشبكات العصبية، مخاطر الائتمان، التنبؤ.

## Predicting credit risk using multi-layer neural network: an applied study

**Abstract:**

This research aims to test the ability of multi-layer neural network models compared to traditional statistical models to improve credit risk forecasting accuracy, by developing a model whose input depends on a set of financial ratios obtained from a sample of listed corporate in the Egyptian Securities Exchange.

The accuracy of neural network to predict credit risk was tested by analyzing and testing the study model using both logistic regression, and multi-layer neural network models, in order to reach the accuracy of classifying corporates to exposed to credit risk and not exposed to credit risk by a sample of (83) of listed corporate in the Egyptian Securities Exchange over ten years (2010 - 2019) with a total of (824) views.

The research concluded that multi-layer neural networks models are distinguished with high predictive accuracy over other statistical models in improving the ability of financial ratios to predict credit risk, in addition to their ability to determine the optimal mix of financial ratios that achieve the best efficiency and effectiveness of multi-layer neural networks in forecasting.

**Keywords:** Neural Networks, Credit risk, Forecasting.

## ١. مقدمة البحث:

ان التطورات المتسارعة ببيئة الأعمال، وتعدد وتنوع الاستثمارات المالية، وزيادة الحاجة إلى تقييم الأداء الحالي لمنشآت الأعمال والتنبؤ بأدائها المستقبلي، وتخفيض حدة تقلبات أسعار أسهمها، ترتب عليها ضرورة تحليل وقياس والتنبؤ بالمخاطر التي تواجه منشآت الأعمال بصفة عامة والمخاطر المالية بصفة خاصة (Abdullah, et al., 2015; Agustina, and Baroroh, 2016; Aleisa, 2017; Cohen, et al., 2017).

بالتالي يحتاج المستثمرون باستمرار إلى تحديد وتحليل ودقة قياس المخاطر المالية التي تتعرض لها منشآت الأعمال في الوقت الحالي، بالإضافة إلى التنبؤ بالمخاطر المالية المستقبلية، بما يمكنهم من تحديد قيمة هذه المنشآت وتقييم وضعها المالي الحالي والمستقبلي، وبالتالي تحديد مدى قدرتها على البقاء والاستمرار (Giovannoni, et al., 2016; Meidell, and Kaarboe, 2017). من ثم زادت أهمية وضرورة قيام منشآت الأعمال بإدارة مخاطرها المالية بهدف محاولة التحكم في تلك المخاطر التي تواجهها، حيث أن إدارة المخاطر المالية لا تقتصر فقط على التعامل مع المخاطر عند حدوثها، ولكنها يجب أن تسبق ذلك بتوفير إشارات مبدئية للتنبؤ بالمخاطر، وذلك من خلال الاعتماد على طرق وأساليب ونماذج إحصائية ورياضية حديثة في التنبؤ، والتي من بينها الشبكات العصبية (Kokobe, and Gemechu, 2016; Florio, and Leoni, 2017).

## ٢. مشكلة البحث:

أصبحت المخاطر المالية التي تواجه منشآت الأعمال واقعاً حتمياً نتيجة للتغيرات المتلاحقة والمتسارعة التي تتميز بها بيئة الأعمال في الآونة الأخيرة، ولعل من أهم هذه التغيرات زيادة حدة المنافسة، وتطور تكنولوجيا المعلومات، بالإضافة إلى تعقد عمليات المنشآت وهيكل تمويلها، وهو ما ترتب عليه مواجهة منشآت الأعمال لحالة من عدم التأكد المرتبط بالفرص والتهديدات المحتملة والتي يجب أخذها في الاعتبار ومواجهتها (Stulz, 2015; Agustina, and Baroroh, 2016; Giovannoni, et al., 2016; Cohen, et al., 2017).

لذا هدفت العديد من الدراسات السابقة إلى التنبؤ بمخاطر الائتمان ولكن باستخدام العديد من الأساليب والنماذج الإحصائية التقليدية، ومن أهم هذه الأساليب والنماذج المستخدمة: التوزيعات الاحتمالية، والانحراف المعياري، وتحليل الحساسية، وتحليل التمايز، والانحدار اللوجستي (Florio, and Leoni, 2017; Lahmiri, 2017; Khemakhem, and Boujelbene, 2017; Paulinus, and Jones, 2017).

لكن واجهت تلك الأساليب التقليدية العديد من الانتقادات، ومنها: عدم قدرتها على التدريب والتعلم وبالتالي كيفية الاحتفاظ بتحديد مخاطر الائتمان وتقييمها والاجراءات التي اتبعت لتخطيها، وأخيراً صعوبة التحديث المستمر لمستوى المخاطر عند التنبؤ (Chen, et al., 2016; Amani, and Fadlalla, 2017).

للتغلب على تلك الانتقادات اقترحت بعض الدراسات السابقة نماذج متطورة للتنبؤ في مجال التطبيقات المحاسبية، ومنها نماذج الشبكات العصبية كأحد أساليب الذكاء الاصطناعي الحديثة للتنبؤ، وذلك في العديد من الاتجاهات؛ منها ما يتعلق بالتنبؤ بالمخاطر المالية (Omar, et al., 2017)، ومنها ما يتعلق بالتنبؤ بالتعثر والإفلاس المالي لمنشآت الأعمال والتنبؤ بقدرة المنشأة على الاستمرارية (إسماعيل، طارق حسنين، ١٩٩٨)، وكذلك بالتنبؤ بأسعار أسهم منشآت الأعمال في أسواق الأوراق المالية (Uğurlu, and Sevim, 2015).

في حين استخدمت بعض الدراسات السابقة النسب والمؤشرات المالية المستخرجة من واقع البيانات المالية بالقوائم المالية المنشورة في قياس مخاطر الائتمان، وقد توصلت نتائج تلك الدراسات إلى عدم الحاجة إلى الإفراط في عدد النسب والمؤشرات المالية لأنها قد تتسبب في تشتت النتائج النهائية للقياس، كما أوصت هذه الدراسات بضرورة الوصول إلى مزيج أمثل من النسب والمؤشرات المالية التي تحقق مستويات مرتفعة من دقة التنبؤ (Tavana, et al., 2018; Wójcicka, 2018).

هنا يمكن إثارة التساؤل بشأن مدى قدرة المؤشرات المالية باستخدام نموذج الشبكات العصبية متعددة الطبقات في التنبؤ بمخاطر الائتمان التي تواجه منشآت الأعمال؟ لذا يعتبر هذا البحث امتداداً للأبحاث والدراسات السابقة لاستخدام نماذج الشبكات العصبية في التنبؤ، حيث يتعرض الباحثان لكيفية استخدام هذه النماذج في زيادة دقة التنبؤ بمخاطر الائتمان التي تواجه منشآت الأعمال.

في ضوء ما سبق، يمكن صياغة مشكلة البحث في تساؤل رئيس وهو ما مدى قدرة المؤشرات المالية على زيادة دقة التنبؤ بمخاطر الائتمان التي تواجه منشآت الأعمال باستخدام الشبكات العصبية متعددة الطبقات؟

### ٣. أهمية البحث:

يسعى هذا البحث إلى تقديم مساهمة علمية لمدى قدرة المؤشرات المالية على التنبؤ بمخاطر الائتمان باستخدام الشبكات العصبية متعددة الطبقات، من خلال ما يلي:

١. تحديد مدى أهمية التنبؤ بمخاطر الائتمان في تحقيق التوازن بين السعي وراء الفرص ذات العائد الأعلى، وتحديد مقدار أو درجة المخاطرة التي يمكن تقبلها وإدارتها.
٢. تحديد مدى اختلاف وأفضلية الشبكات العصبية متعددة الطبقات عن النماذج الإحصائية الأخرى التي تستخدم في التنبؤ بمخاطر الائتمان التي تواجه منشآت الأعمال.
٣. تحديد كيفية استخدام الشبكات العصبية متعددة الطبقات في الوصول إلى المزيج الأمثل من النسب والمؤشرات المالية التي تستخدم في التنبؤ بمخاطر الائتمان التي تواجه منشآت الأعمال.

### ٤. هدف البحث:

يتمثل الهدف الرئيس لهذا البحث في محاولة زيادة دقة التنبؤ بمخاطر الائتمان باستخدام نموذج الشبكات العصبية متعددة الطبقات من خلال اعتماد مدخلات النموذج على مجموعة من المؤشرات المالية، ويتحقق هذا الهدف من خلال تحقيق الأهداف الفرعية التالية:

١. اختبار مستوى دقة التنبؤ بمخاطر الائتمان باستخدام النماذج المقترحة للتنبؤ (الشبكات العصبية متعددة الطبقات، والانحدار اللوجستي)
٢. اختبار أثر المؤشرات المالية على التنبؤ بمخاطر الائتمان التي تواجه منشآت الأعمال.
٣. تحديد المزيج الأمثل من النسب والمؤشرات المالية لتحقيق دقة التنبؤ بمخاطر الائتمان التي تواجه منشآت الأعمال.

## ٥. منهج وطريقة البحث:

لتحقيق الهدف الرئيس للبحث والأهداف الفرعية المشتقة منه، سوف يعتمد الباحثان على كل من الدراسة النظرية، والدراسة العملية: وفيما يتعلق بالجانب النظري فيكون من خلال مراجعة الكتابات المحاسبية للمشكلة التي يتناولها موضوع البحث، بهدف تكوين الإطار المفاهيمي والنموذج المحاسبي المقترح الخاص بمتغيرات البحث، وتوضيح ما توصلت إليه الدراسات السابقة المرتبطة بهذه المتغيرات، وتحديد كيفية قياس كل متغير من هذه المتغيرات.

أما بالنسبة للجانب العملي فيرى الباحثان الاعتماد على دراسة تطبيقية تهدف إلى اختبار فروض البحث بما يحقق أهدافها من خلال استخدام برنامج البايثون Python نظراً لاحتوائه على إضافات الشبكات العصبية متعددة الطبقات، وسوف يمثل مجتمع البحث في منشآت الأعمال المقيدة بالبورصة المصرية خلال الفترة من عام ٢٠١٠ حتى عام ٢٠١٩، وتمثلت عينة البحث في عدد (٨٣) منشأة، وبلغ عدد المشاهدات عدد (٨٢٤) مشاهدة، وقد تم جمع البيانات من خلال الاعتماد على البيانات الثانوية المستخرجة من التقارير المالية المنشورة.

## ٦. فروض البحث:

- لتحقيق الهدف الرئيس للبحث، سوف يتم اختبار الفروض التالية:
- الفرض الأول ( $H_1$ ): يؤدي استخدام الشبكات العصبية متعددة الطبقات إلى تحسين قدرة المؤشرات المالية في التنبؤ بمخاطر الائتمان لمنشآت الأعمال.
  - الفرض الثاني ( $H_2$ ): يوجد تأثير للمزيج الأمثل من النسب والمؤشرات المالية على دقة الشبكات العصبية متعددة الطبقات للتنبؤ بمخاطر الائتمان لمنشآت الأعمال.

## ٧. خطة البحث:

١. عرض وتحليل الدراسات السابقة.
٢. المخاطر المالية بمنشآت الأعمال والتنبؤ بها.
٣. الشبكات العصبية ومدى ملائمتها للتنبؤ بمخاطر الائتمان.

٤. الدراسة التطبيقية.

٥. الخلاصة والنتائج والتوصيات.

### ١. عرض وتحليل الدراسات السابقة:

ان التنبؤ بمخاطر الائتمان لمنشآت الأعمال يعد تحدياً طويلاً الأمد، فبقاء المنشأة واستمرارها وتعظيم قيمتها هو الهدف الرئيسي الذي تسعى إليه هذه المنشآت، لذا يجب عليها القيام بتحديد وتقييم وإدارة ورقابة والتحكم في مخاطر الائتمان التي تتعرض لها في الوقت الحالي، بالإضافة إلى دقة التنبؤ بالمخاطر المحتملة، بهدف حمايتها من أي خسائر مفاجئة نتيجة للعوامل الداخلية والخارجية التي تؤثر عليها سواء في الأجل القصير أو في الأجل الطويل، ونتيجة لذلك فقد هدفت العديد من الدراسات السابقة إلى قياس وتقييم والتنبؤ بمخاطر الائتمان. وهذا ما يوضحه الباحثان من خلال عرض وتحليل الدراسات السابقة المرتبطة بمخاطر الائتمان والتنبؤ بها، كما هو موضح بالجدول رقم (١) التالي:

جدول رقم (١) الدراسات السابقة المرتبطة بمخاطر الائتمان والتنبؤ به

دراسة	هدف الدراسة	متغيرات الدراسة	الأسلوب الاحصائي	اهم نتائج الدراسة
Bhat and Ryan, 2015	قياس تأثير نمذجة مخاطر الائتمان والسوق على مكاسب وخسائر القيمة العادلة المقدره للبنوك بالنسبة للأدوات المالية.	تحليل مستوى الإفصاح عن أنشطة المخاطر ومخاطر السوق بالتقارير المالية السنوية، وتقارير المحللين الماليين، ونصوص المكالمات الهاتفية الجماعية	تحليل الانحدار المتعدد	- ان نمذجة مخاطر السوق والائتمان تعزز من أهمية عوائد مكاسب وخسائر القيمة العادلة المقدره غير المحققة للبنوك بالنسبة للأدوات المالية. - ان نمذجة مخاطر السوق والائتمان تعزز من أهمية عوائد القيمة العادلة المسجلة بالدخل الشامل والناجحة أساساً عن تحركات أسعار الفائدة.
Zhu, et al., 2016	التنبؤ بمخاطر الائتمان في	متغيرات مالية: نسب الائتمان،	الانحدار اللوجستي	- تفوق دقة التنبؤ باستخدام الشبكات العصبية الاصطناعية عن الانحدار

<p>اللوجستي.</p> <p>– النموذج المختلط لدية قدرة أفضل للتنبؤ بمخاطر الائتمان للشركات الصغيرة والمتوسطة.</p>	<p>والشبكات العصبية الاصطناعية</p>	<p>والسيولة، والربحية، والنشاط.</p> <p>متغيرات غير مالية: اتجاهات الصناعة، والتصنيف الائتماني، وتكرار العمليات.</p>	<p>تمويل سلسلة التوريد بالتطبيق على الشركات الصغيرة والمتوسطة في الصين.</p>	
<p>– تفوق النموذج المقترح بالمقارنة بمجموعة من النماذج الأخرى في التنبؤ بمخاطر الائتمان حتى في ظل السيناريوهات الاقتصادية المختلفة.</p> <p>– يساعد التنبؤ بمخاطر الائتمان في قياس الصحة المالية للشركات والصناديق السيادية، وبالتالي يفيد في صنع القرار المؤسسي والحكومي.</p> <p>– ان تحسن التنبؤ بالمخاطر المالية يحسن من تسعير المشتقات المالية.</p>	<p>الوسط، والانحراف المعياري، انحدار السلاسل الزمنية</p>	<p>التصنيف الائتماني للسندات، طول مدة استحقاق السندات</p>	<p>اقترح نموذج للتنبؤ بمخاطر الائتمان للشركات بالتطبيق على الشركات الصناعية بالولايات المتحدة الأمريكية.</p>	<p>Bu, et al., 2018</p>
<p>– أن تعزيز التدرج العشوائي كان النموذج المتفوق في تصنيف الشركات ذات التصنيف الائتماني الجيد والسيئ.</p> <p>– أن النماذج القائمة على شجرة القرارات هي أكثر دقة وتنوعاً ولها نطاق أوسع من النماذج التقليدية ، مثل الانحدار اللوجستي.</p> <p>– أظهر نموذج الدراسة المتغيرات التي تتمتع بأفضل قوة تفسيرية تتعلق بالتنبؤ بمخاطر الائتمان.</p>	<p>الانحدار اللوجستي وشجرة القرارات والغابات العشوائية والتدرج العشوائي.</p>	<p>متغيرات مالية: نسب الائتمان، والسيولة، والربحية، والنشاط.</p>	<p>نمذجة مخاطر الائتمان لتمكين صانعي القرارات من التصنيف الائتماني والتنبؤ بمخاطر الائتمان للشركات بقطاع التعدين في استراليا.</p>	<p>Halteh, et al., 2018</p>

من خلال عرض وتحليل الدراسات السابقة خلص الباحثان إلى أنه نظراً لاختلاف المخاطر المالية التي تواجه منشآت الأعمال فقد ركزت بعض الدراسات السابقة على مخاطر الائتمان، حيث هدفت كل من دراسة (Bhat and Ryan (2015) دراسة (Zhu, et al. (2016) ودراسة (Bu, et al. (2018) ودراسة (Halteh, et al. (2018) إلى التنبؤ بمخاطر الائتمان، باعتبارها مخاطر تؤثر على كل من البنوك والمنشآت في نفس الوقت، فكلما زادت البنوك من دقة التنبؤ بمستوى مخاطر الائتمان للمنشآت، كلما تمكنت من تصنيف هذه المنشآت تصنيفاً ائتمانياً عادلاً، وبالتالي فإن التنبؤ بمخاطر الائتمان يساعد المقرض والمقترض، من خلال تخفيض عدد القروض المقدمة للمقترضين الذين يعانون من وضع مالي سيئ، وبالتالي تخفيض الخسائر التي قد يتعرض لها البنك، وأيضاً تخفيض عدد المنشآت المتعثرة أو التي تفشل في سداد القروض.

على الرغم من اهتمام العديد من الدراسات السابقة بالتنبؤ بمخاطر الائتمان، إلا أن معظم هذه الدراسات اعتمدت في نماذجها التنبؤية بشكل أساسي على الأساليب الإحصائية التقليدية (Bhat and Ryan, 2015; Al Janabi, 2016; Zhu, et al., 2016; An, 2017; Bu, et al., 2018; Halteh, et al., 2018).

من ثم يرى الباحثان أنه ما زالت هناك مشكلة في التنبؤ بمخاطر الائتمان نظراً لاعتماد النماذج المقترحة بالعديد من الدراسات السابقة على الأساليب الإحصائية التقليدية، وللتغلب على تلك الانتقادات فقد اعتمدت بعض الدراسات الأخرى على التقنيات الحديثة للذكاء الاصطناعي والتعلم الآلي كالشبكات العصبية متعددة الطبقات لتحسين دقة التنبؤ (Zhu, et al., 2016; Khemakhem and Boujelbene, 2018). وهذا ما سيتم يتناوله من خلال عرض وتحليل الدراسات السابقة المرتبطة باستخدام الشبكات العصبية في التنبؤ بمخاطر الائتمان، كما هو موضح بالجدول رقم (٢) التالي:

جدول رقم (٢) الدراسات السابقة التي استخدمت الشبكات العصبية في التنبؤ بمخاطر الائتمان

دراسة	هدف الدراسة	عينة الدراسة	الأسلوب الإحصائي	أهم النتائج
Zhu, et al., 2016	التنبؤ بمخاطر الائتمان في تمويل سلسلة التوريد باستخدام الانحدار اللوجستي والشبكات	عدد ٧٧ شركة صغيرة ومتوسطة مدرجة وعدد ١١ شركة مساهمة	الانحدار اللوجستي والشبكات العصبية	- تفوق دقة التنبؤ باستخدام الشبكات العصبية الاصطناعية عن الانحدار اللوجستي. - النموذج المختلط لديه قدرة أفضل

للتنبؤ بمخاطر الائتمان للشركات الصغيرة والمتوسطة.	الاصطناعية	مدرجة في الفترة من ٢٠١٢ - إلى ٢٠١٣.	العصبية الاصطناعية والنماذج المختلطة بالتطبيق على الشركات الصغيرة والمتوسطة في الصين.	
<ul style="list-style-type: none"> <li>- أن تعزيز التدرج العشوائي كان النموذج المتفوق في تصنيف الشركات ذات التصنيف الائتماني الجيد والسيئ.</li> <li>- أن النماذج القائمة على شجرة القرارات هي أكثر دقة وتنوعاً ولها نطاق أوسع من النماذج التقليدية، مثل الانحدار اللوجستي.</li> <li>- أظهر نموذج الدراسة المتغيرات التي تتمتع بأفضل قوة تفسيرية تتعلق بالتنبؤ بمخاطر الائتمان.</li> </ul>	<ul style="list-style-type: none"> <li>- الانحدار اللوجستي وشجرة القرارات والغابات العشوائية والتدرج العشوائي.</li> </ul>	<ul style="list-style-type: none"> <li>- عدد ٦٣٢ شركة مدرجة لمدة ٥ سنوات (إجمالي ٣١٦٠ مشاهدة) و ١١٨ شركة غير مدرجة لمدة ٥ سنوات (إجمالي ٥٩٠ مشاهدة) في الفترة من ٢٠١١ إلى ٢٠١٥.</li> </ul>	<ul style="list-style-type: none"> <li>- نمذجة مخاطر الائتمان لتمكن صانعي القرارات من التصنيف الائتماني والتنبؤ بمخاطر الائتمان للشركات بقطاع التعدين في استراليا.</li> </ul>	Halteh, et al., 2018
<ul style="list-style-type: none"> <li>- أن نسب الربحية والقدرة على السداد والملاءة المالية هي من بين النسب التي لها قدرة تنبؤية كبيرة لتعثر الشركات.</li> <li>- أهمية مدة الدراسة لتقرير الائتمان والضمانات وحجم الشركة في التقييم الائتماني لها.</li> <li>- أن شجرة القرارات أكثر كفاءة من الشبكات العصبية الاصطناعية من حيث التنبؤ بمخاطر الائتمان باستخدام بيانات متوازنة.</li> <li>- لدقة التنبؤ بمخاطر الائتمان يجب فهم وتقييم المتغيرات واختيار المتغيرات الأكثر صلة قبل إنشاء</li> </ul>	<ul style="list-style-type: none"> <li>- الشبكات العصبية الاصطناعية وشجرة القرارات.</li> </ul>	<ul style="list-style-type: none"> <li>- عدد ٤٠٨ شركة صغيرة ومتوسطة في الفترة من ٢٠١١ إلى ٢٠١٢.</li> </ul>	<ul style="list-style-type: none"> <li>- التنبؤ بمخاطر الائتمان باستخدام المتغيرات مالية وغير مالية بالتطبيق على الشركات الصغيرة ومتوسطة الحجم بتونس.</li> </ul>	Khemakhem and Boujelbene, 2018

نموذج التنبؤ .				
<p>احتلت الشبكات العصبية الاصطناعية المركز الثاني من حيث التوقعات الإجمالية التي تم إجراؤها.</p> <p>أشجار التصنيف والانحدار لديها قدرة كبيرة على التنبؤ، وعلى الرغم من أن دقتها أقل من الغابات العشوائية، إلا أن الاختلاف لم يكن كبيراً.</p> <p>توصي هذه الدراسة باستخدام كل من الغابات العشوائية وأشجار التصنيف والانحدار من أجل تقييم المخاطر المالية بشكل أفضل وتحقيق نتائج أكثر دقة.</p>	<p>الغابات العشوائية الشبكات العصبية أشجار التصنيف والانحدار</p>	<p>البيانات ربع السنوية لعدد ٨٠ بنك من عام ٢٠١٠ إلى عام ٢٠١٨</p>	<p>التنبؤ والتصنيف الائتماني للبنوك في دول مجلس التعاون الخليجي باستخدام تقنيات التعلم الآلي كأحد فروع الذكاء الاصطناعي</p>	<p>Li, et al., 2020</p>
<p>تصميم خوارزمية هجينة لتدريب الشبكات العصبية، باستخدام خوارزميتين من خوارزميات التحسين وهما خوارزمية التحسين المغناطيسي وخوارزمية تحسين حشد الجسيمات.</p> <p>توصلت نتائج تلك الدراسة إلى تفوق الخوارزميات الهجينة من حيث قدرتها على حل مشكلات التحسين بشكل أسرع وبدقة أفضل.</p> <p>ارتفاع القدرة التنبؤية للشبكات العصبية في التنبؤ بالإفلاس.</p>	<p>الشبكات العصبية</p>	<p>٩٨٤ منشأة من المنشآت المتعثرة أو تلك التي تم تصفيتها عام ٢٠٠١ بالولايات المتحدة الأمريكية</p>	<p>استخدام الشبكات العصبية في التنبؤ بإفلاس منشآت الأعمال</p>	<p>Ansari, et al., 2020</p>

بالرجوع إلى تلك الدراسات السابقة فقد تبين للباحثان أن مخاطر الائتمان لا تزال من أكبر المخاطر المالية التي تتعرض لها منشآت الأعمال، لذا أصبحت نماذج تقييم مخاطر الائتمان المستندة إلى البيانات الإحصائية بمثابة أداة التحليل الرئيسية، وبشكل آخر يتم استخدام هذه النماذج على نطاق واسع لتقييم والتنبؤ بمخاطر الائتمان لمنشآت الأعمال، حيث تتمثل مزايا بناء نظام موثوق به لتقييم

مخاطر الائتمان في: تقليل تكلفة تحليل الائتمان، وضمان سرعة اتخاذ القرار، وضمان تحصيل الائتمان وتقليل المخاطر المالية المحتملة. وتوصلت العديد من الدراسات إلى أن تقنية الشبكات العصبية تحقق أداءً أفضل من النماذج الإحصائية التقليدية في تقييم مخاطر الائتمان والتنبؤ بها خاصة عندما يكون تصنيف غير خطي، حيث أنها لا تتطلب افتراض التوزيع الطبيعي، ويمكنها اكتساب المعرفة مباشرة من مجموعات بيانات التدريب والتعلم. وهو ما يتفق مع نتائج كل من دراسة Zhang, et al (2017) ودراسة Huang, et. al., (2018) التي توصلت إلى ارتفاع قدرة وفعالية ودقة الخوارزميات الجينية للشبكات العصبية في تقييم والتنبؤ بمخاطر الائتمان لمنشآت الأعمال، وهو ما سوف يختبره الباحثان بالدراسة التطبيقية.

## ٢. المخاطر المالية بمنشآت الأعمال والتنبؤ بها:

### ١/٢. الإطار المفاهيمي للمخاطر المالية:

تعد المخاطر من الموضوعات محل الجدل، ومن أهم التحديات التي تواجه منشآت الأعمال في السنوات الأخيرة، وسوف يتناول الباحثان فيما يلي الإطار المفاهيمي للمخاطر المالية من حيث التعريفات المختلفة للمخاطر وأنواعها وتصنيفاتها:

تعددت الآراء حول وضع تعريف عام ومحدد للمخاطر حيث عرفت لجنة المنظمات الراعية للجنة توريدواي Committee of Sponsoring Organizations of the Treadway Commission (COSO) مفهوم المخاطر التي تواجه الشركات بأنها " الأحداث التي تؤثر تأثيراً سلبياً على تحقيق الأهداف التنظيمية للمنشأة، نتيجة للعوامل الداخلية والخارجية التي تؤثر على المنشأة، وتمنعها من تحقيق قيمة مضافة أو تؤدي إلى تآكل القيمة الموجودة " (COSO, 2004; 2013).

وعرفت معايير المحاسبة المصرية المخاطر المالية بأنها " الخطر الناشئ عن تغير مستقبلي محتمل على واحد أو أكثر من: معدل فائدة محددة، أو سعر أداة مالية، أو سعر سلعة، أو سعر الصرف الأجنبي، أو جداول ومؤشرات الأسعار أو المعدلات، أو التصنيف الائتماني، أو غير ذلك من المتغيرات، شريطة أنه في حالة ما إذا كان المتغير غير مالي ألا يكون المتغير خاصاً بأي من طرفي العقد " (قائمة تعريفات مصطلحات معايير المحاسبة المصرية، ٢٠١٥).

وعرف (Hillson, 2017) المخاطر بأنها " التهديدات والآثار السلبية التي تتعرض لها المنشآت في الوقت الحالي أو قد تتعرض لها في المستقبل، والناجمة عن أحداث وتصرفات غير مرغوب فيها، قد تعوق تلك المنشآت عن تحقيق أهدافها، سواء قصيرة الأجل والمتمثلة في تقديم سلع وخدمات تحقق لها مستوى ربحية مناسب، أو الأهداف طويلة الأجل والمتمثلة في بقائها واستمرارها". وقد عرف (Hopkin, 2018) المخاطر بأنها " مجموعة من الفرص أو التهديدات التي من شأنها التأثير على تحقيق أهداف المنشأة".

في حين عرف (Ibrahim and Hussainey, 2019) المخاطر بأنها " الخسائر والمكاسب المحتملة الناتجة عن أحداث يصعب التنبؤ بها أو السيطرة عليها ". ومما سبق يتضح أنه بالرغم من تعدد آراء وتعريفات كل من الباحثين والمنظمات المهنية إلا أن معظم هذه التعريفات ركزت على محور أساسي وهو تحقيق أهداف المنشأة، وذلك لتأثرها بحالة عدم التأكد المرتبطة بالأحداث الحالية التي تحدث لمنشآت الأعمال أو الأحداث المستقبلية التي قد تحدث لها، ومن ثم يمكن تعريف المخاطر المالية على أنها:

" الخسائر المحتملة التي تتعرض لها منشآت الأعمال في الوقت الحالي أو قد تتعرض لها في المستقبل، مما قد يكون لها أثر سلبي على قدرة هذه المنشآت على تحقيق أهدافها، ويؤثر على ربحيتها واستمرارها ".

## ٢/٢. أنواع المخاطر المالية التي تواجه منشآت الأعمال:

تتعدد المخاطر المالية التي تتعرض لها منشآت الأعمال، حيث يجب على كل منشأة تحديد وتحليل المخاطر المالية التي قد تتعرض لها بهدف اتخاذ الاجراءات اللازمة لتجاوز آثارها السلبية، وفيما يلي تعريف كل خطر من هذه المخاطر المالية (معيار المحاسبة المصري رقم (٤٠) المعدل: الأدوات المالية - الإفصاحات، ٢٠١٩ ؛ Hull, Hopkin, 2018; Olson, and Wu, 2017):

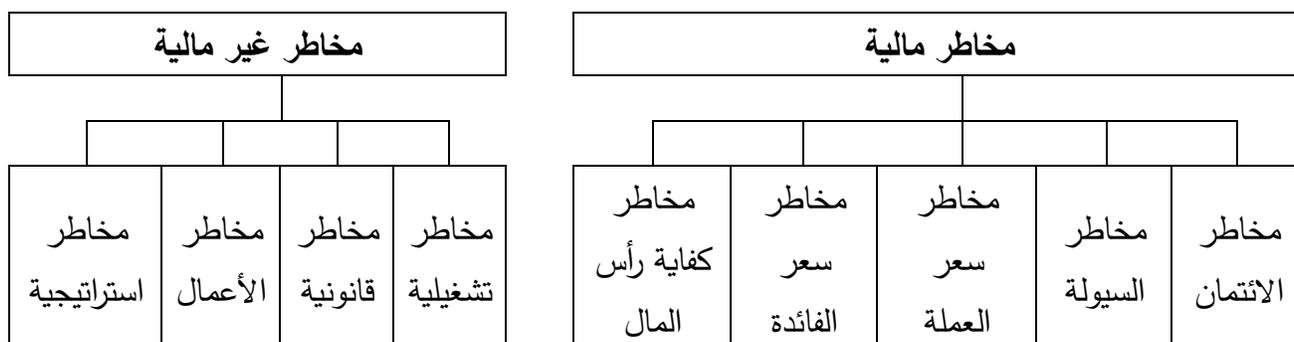
- **مخاطر الائتمان:** هي مخاطر أن يؤدي أحد أطراف أداة مالية إلى خسارة مالية للطرف الآخر عن طريق الإخفاق في الوفاء بالتزاماته، أو هي المخاطر الناتجة عن احتمال عدم وفاء المدينين بسداد ما عليهم من التزامات في الوقت المحدد.
- **مخاطر السيولة:** هي مخاطر أن تواجه المنشأة صعوبة في مقابلة التزاماتها المتعلقة بالالتزامات المالية التي يتم تسويتها بتقديم نقدية أو أصل مالي آخر، أو هي المخاطر الناتجة عن عدم قدرة المنشأة على الوفاء بسداد التزاماتها قصيرة الأجل للدائنين في الوقت المحدد.
- **مخاطر السوق:** هي مخاطر تذبذب القيمة العادلة أو التدفقات النقدية المستقبلية لأداة مالية بسبب التغيرات في أسعار السوق، أو هي المخاطر المرتبطة بالخسارة المالية المحتملة الناتجة عن عدم التأكد من الأسعار المستقبلية للأدوات المالية المستخدمة في عمليات المنشأة. وتنقسم مخاطر السوق إلى مخاطر العملة، ومخاطر سعر الفائدة، ومخاطر الأسعار الأخرى.
- **مخاطر كفاية رأس المال:** هي المخاطر الناتجة عن احتمال عدم كفاية رأس المال الكلي لتنفيذ حجم الأعمال المطلوب تنفيذها وفقاً للوائح كفاية رأس المال بالمنشأة.

### ٣/٢. تصنيف المخاطر التي تواجه منشآت الأعمال:

قامت العديد من الدراسات السابقة والكتابات العلمية بتصنيف المخاطر إلى العديد من التصنيفات، حيث يمكن تصنيف المخاطر إلى مخاطر منتظمة وغير منتظمة، أو تصنيفها إلى مخاطر مالية وغير مالية، أو تصنيفها إلى مخاطر داخلية وخارجية، وكذلك تصنيفها إلى مخاطر مرتبطة ببيئة الأعمال وأخرى غير مرتبطة ببيئة الأعمال (Hillson, 2017; Silva, et al., 2017; Olson, and Wu, 2017; Bushman, et al., 2018; El Bouchti, et al., 2018; Hopkin, 2018; Hull, 2018).

سوف يتبنى هذا البحث تصنيف المخاطر إلى مخاطر مالية وأخرى غير مالية، ثم يركز على المخاطر المالية بمنشآت الأعمال وتحديداً مخاطر الائتمان، حيث يهدف هذا البحث إلى التنبؤ بمخاطر الائتمان.

فالمخاطر المالية تنقسم إلى مخاطر الائتمان، ومخاطر السيولة، ومخاطر سعر العملة، ومخاطر سعر الفائدة، ومخاطر كفاية رأس المال. في حين أن المخاطر غير المالية تنقسم إلى المخاطر التشغيلية، والمخاطر القانونية، ومخاطر الأعمال، والمخاطر الاستراتيجية. ويمكن توضيح هذا التصنيف بالشكل رقم (١) التالي:



شكل رقم (١): تصنيف المخاطر إلى مالية وغير مالية

#### ٤/٢. أهداف ومحددات التنبؤ بمخاطر الائتمان:

يعتبر التنبؤ بصفة عامة هو توقع أو تقدير لما سيحدث في المستقبل، لذا فهو يعد بمثابة حلقة الوصل بين منشآت الأعمال والبيئة المحيطة بها لربط الحاضر بالمستقبل، فالبيئة الخارجية للمنشأة دائمة التغير باستمرار نتيجة للتغيرات البيئية والاقتصادية والتكنولوجية المتلاحقة، والتي ترتب عليها زيادة حالة عدم التأكد، وزيادة المخاطر التي قد تتعرض لها المنشأة (Ruppert and Matteson, 2016; Firoozye and Ariff, 2016).

من ثم يرى الباحثان أن التنبؤ بمخاطر الائتمان يعد من مدخلات عملية اتخاذ القرارات بالمنشأة، ويمكن الاعتماد عليه في اكتشاف النتائج السلبية المحتملة المترتبة على الظروف الداخلية بالمنشأة أو الظروف الاقتصادية والاجتماعية والسياسية الخارجية المحيطة بالمنشأة، والتصدي لها كمحاولة للتخلص منها أو تقليل آثارها السلبية أو تجنب حدوثها في المستقبل. لذا سوف يتناول الباحثان فيما يلي أهداف التنبؤ بمخاطر الائتمان، والعوامل التي تحد من فاعلية هذا التنبؤ:

١/٤/٢. أهداف التنبؤ بمخاطر الائتمان:

يحقق التنبؤ بمخاطر الائتمان المستقبلية التي قد تواجه المنشأة الأهداف التالية (Ruppert and Matteson, 2016; Firoozye and Ariff, 2016):

- تخفيض درجة عدم التأكد التي ستواجه المنشأة في المستقبل.
- التعرف على الأداء المستقبلي للمنشأة بالاعتماد على البيانات التاريخية.
- توفير قاعدة من المعلومات الضرورية لرسم السياسات ووضع الخطط ورقابة تنفيذها.

٢/٤/٢. محددات فاعلية التنبؤ بمخاطر الائتمان:

هناك العديد من العوامل التي تحد من فاعلية التنبؤ بمخاطر الائتمان، وقد تؤثر على صحة ودقة التنبؤات، يمكن تلخيصها فيما يلي (Ruppert and Matteson, 2016; Firoozye and Ariff, 2016):

- صعوبة توقع بعض الأحداث المستقبلية.
- عدم وضوح الافتراضات أو تعقدها.
- التنبؤات غير الرشيدة التي يتم اعدادها على أسس غير موضوعية أو تتجاهل بعض المتغيرات.

بالرغم من الأهداف التي يحققها التنبؤ بمخاطر الائتمان المستقبلية، إلا أن هناك العديد من العوامل التي قد تحد من فاعلية التنبؤ بها، وقد تؤثر على صحة ودقة التنبؤات، ونتيجة لذلك يرى الباحثان ضرورة الاهتمام بالتنبؤ بمخاطر الائتمان، وأن تستند هذه التنبؤات إلى تحليلات وأسس موضوعية أكثر من كونها مجرد تقديرات شخصية، بالإضافة إلى الاعتماد على الأساليب الكمية للقيام بالتنبؤ وترجيح هذه التنبؤات باحتمالات تقديرية تعد على أساس التنبؤات الأكثر توقعاً، وأخيراً الاعتماد على التقنيات الحديثة المستخدمة في التنبؤ، وذلك كمحاولة لتحقيق دقة التنبؤ بمخاطر الائتمان.

### ٣. الشبكات العصبية ومدى ملائمتها للتنبؤ بمخاطر الائتمان:

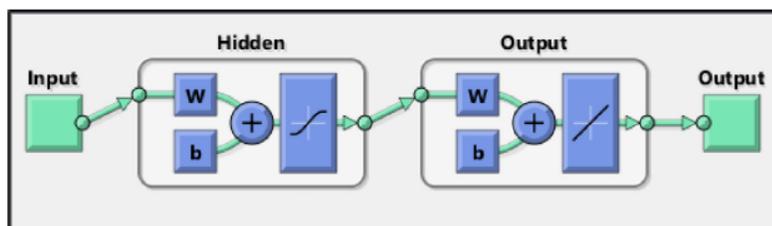
#### ١/٣. الإطار المفاهيمي للشبكات العصبية:

تعد الشبكات العصبية إحدى تقنيات الذكاء الاصطناعي، وتعرف بأنها نماذج أو أنظمة حسابية تحاكي الخلايا العصبية في العقل البشري والروابط بينهما (Singh and Banerjee, 2019). وأصبحت الشبكات العصبية أكثر تطوراً وتعقيداً من الأساليب التقليدية، فهي تعتبر الأسلوب المثالي لتمثيل العلاقات بين المتغيرات، حيث أنها مكونة من مجموعة مركبة من عناصر المعالجة الضخمة التي لها القدرة على إجراء العمليات الحسابية المعقدة، ويطلق عليها عصبونات أو نيورونات (Neurons)، ثم تخزين المعرفة العلمية وجعلها متاحة للاستخدام عن طريق ضبط الأوزان النسبية (Son, et al., 2016; Da Silva, et al., 2017).

#### ٢/٣. مكونات الشبكات العصبية:

سوف يتناول البحث فيما يلي أهم مكونات الشبكات العصبية (Kapanova, et al., 2018;

2018;  
Berry, et al.,  
2020)  
الشكل



Khalil, et al.,  
Berry, et al.,  
وذلك من خلال  
رقم (٢) التالي:

شكل رقم (٢) مكونات الشبكات العصبية

المصدر: Omar, et al., 2017; Tavana, et al., 2018

– طبقة المدخلات **Input Layer**: هي الطبقة الأولى في الشبكات العصبية، وتقوم هذه الطبقة باستقبال بيانات المتغيرات المستقلة من المصادر المختلفة، وتحتوي على عدد من النيورونات أو

- العصبونات أو عناصر المعالجة التي يتوافق عددها مع عدد المتغيرات المستقلة للمدخلات المراد قياسها.
- **الطبقة الخفية Hidden Layer:** هي الطبقة التي تلي طبقة المدخلات، وقد تحتوي الشبكة العصبية على طبقة خفية واحدة أو أكثر، وتقوم هذه الطبقة بتصنيف وتمييز وتحليل المدخلات بإعطاء وزن نسبي لكل منها، ثم استخدام الدوال التحليلية لتعديل هذه الأوزان النسبية، بعد مقارنة النتائج الحالية بالمستهدفة، لتقليل الأخطاء وتحقيق أفضل نتائج.
  - **طبقة المخرجات Output Layer:** هي الطبقة النهائية للشبكات العصبية، وتحتوي على عدد من عناصر المعالجة التي يتوافق عددها مع عدد متغيرات الاستجابة، وتقوم هذه الطبقة بعرض النتائج التي وصلت إليها من الطبقة السابقة إلى المستخدم النهائي، وبالتالي عرض النتائج النهائية للشبكات العصبية.
  - **الأوزان النسبية Weights:** تقوم هذه الأوزان بتحديد القوة النسبية أو الأهمية النسبية لكل مدخل من المدخلات، وبالتالي تحدد قوة العلاقة بين عناصر ووحدات المعالجة ومدى فعالية عقد الاتصال، ويمكن تعديل الأوزان النسبية من خلال التدريب والتعلم.
  - **دالة التجميع Summation Function:** تعد هذه الدالة بمثابة المنشط الداخلي أو المحفز للشبكة العصبية، حيث تقوم بحساب الأوزان النسبية للمدخلات، وذلك بضرب كل مدخل من المدخلات في وزنه النسبي للحصول على المجموع.
  - **دالة التحويل Transfer Function:** يطلق عليها أيضاً دالة التنشيط، حيث تقوم بإجراء المعادلات الرياضية على القيم الخارجة من دالة التجميع، وتعديل الأوزان النسبية باستمرار طوال فترة تدريب الشبكة، وأكثر دوال تنشيط الشبكات العصبية انتشاراً هي الدالة الخطية لتنشيط الشبكات العصبية، ودالة الحد الفاصل لتنشيط الشبكات العصبية، ودالة سيجمويد لتنشيط الشبكات العصبية.

### ٣/٣. تصنيف الشبكات العصبية:

قامت العديد من الدراسات السابقة والكتابات العلمية بتصنيف الشبكات العصبية إلى العديد من التصنيفات، حيث يمكن تصنيف الشبكات العصبية وفقاً لعدد طبقاتها إلى شبكات وحيدة الطبقة وأخرى

متعددة الطبقات، وكذلك تصنيفها وفقاً لطرق انتشارها إلى شبكات ذات التغذية الأمامية وشبكات ذات التغذية الخلفية وشبكات تنافسية وأخرى متكررة (Son, et al., 2016; Barboza, et al., 2017; Singh, and Banerjee, 2019; Liang, and Cai, 2020; Xin, et al., 2020).

### ٣/٤ . تدريب وتعلم الشبكات العصبية:

تعد دراسة Hebb في عام ١٩٤٩ من الدراسات الأولى المبكرة التي اقترحت القاعدة الأساسية لطريقة تعلم النيرون أو العصبون بالعقل البشري، حيث كانت من أوائل الدراسات التي توصلت إلى البنية التوصيلية للعصبونات وكيفية تمثيل المعرفة. ثم قام العديد من الباحثين بتطبيق قاعدة Hebb على الشبكات العصبية، ووجدوا أن التدريب والتعلم هما اللذان يحددان قيم الأوزان النسبية، حيث يعبر الوزن النسبي عن القوة النسبية أو الأهمية النسبية للبيانات المدخلة، فالشبكات العصبية لا تبرمج ولكنها تقوم بالتدريب والتعلم فقط، حيث يتم تدريب الشبكات العصبية على مجموعة من البيانات التاريخية، وهو ما يساهم في سرعة تعلم تلك الشبكات العصبية التي تم تدريبها، وبالتالي ضبط الأوزان النسبية، وتحقيق أفضل نتائج.

يطلق البعض على الشبكات العصبية خوارزميات تعلم الآلة Machine Learning Algorithm، فالشبكات العصبية تتعلم من أخطائها ومعرفتها وخبراتها السابقة، ففي البداية تقوم الشبكات العصبية بتحديد قيم مبدئية لهذه الأوزان النسبية، أو اختيار القيم المبدئية للأوزان النسبية عشوائياً، وترجع أهمية القيم المبدئية للأوزان النسبية في تحديد فعالية وفترة التعلم، وهناك طريقتين لتدريب الشبكات العصبية، وهما التدريب الموجه أو الإشرافي، أو التدريب غير الموجه أو غير الإشرافي (Da Silva, et al., 2017; Alloghani, et al., 2020):

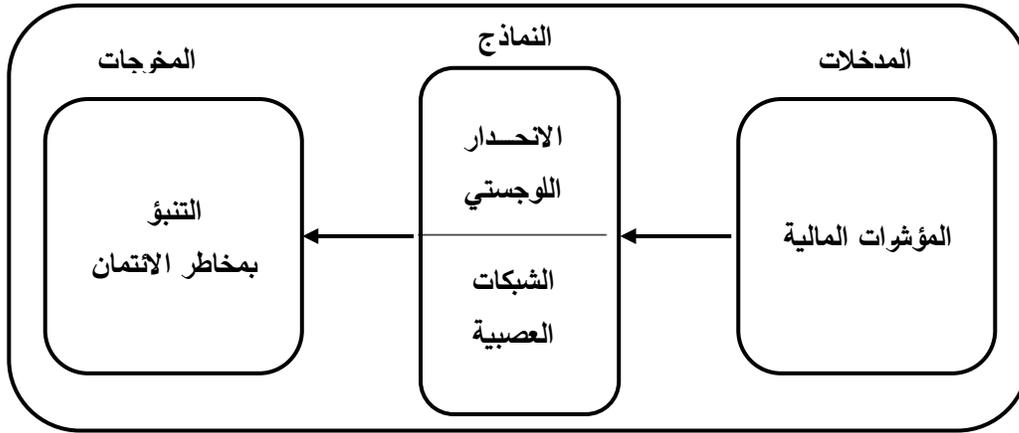
### ٤ . الدراسة التطبيقية:

#### ١/٤ . أهداف ومنهجية الدراسة:

تستهدف الدراسة التطبيقية تحقيق هدف البحث واختبار الفروض، وذلك وفقاً بالخطوات التالية:

- اشتقاق نموذج محاسبي باستخدام المؤشرات المالية التي يمكن استخدامها في التنبؤ بمخاطر الائتمان التي تتعرض لها منشآت الأعمال.
- تحليل واختبار النموذج المحاسبي باستخدام أسلوب الانحدار اللوجستي وحساب معدل الدقة.
- تحليل واختبار النموذج المحاسبي باستخدام تقنية الشبكات العصبية وحساب معدل الدقة.
- تصنيف المنشآت إلى منشآت معرضة لمخاطر الائتمان وغير معرضة لمخاطر الائتمان.

بناءً على ما سبق يمكن تصور مكونات النموذج المقترح لاستخدام الشبكات العصبية متعددة الطبقات في التنبؤ بمخاطر الائتمان لمنشآت الأعمال، من خلال الشكل رقم (٣) التالي:



شكل رقم (٣) مكونات نموذج الدراسة

#### ٢/٤. مجتمع وعينة الدراسة:

يتمثل مجتمع الدراسة في منشآت الأعمال المقيدة ببورصة الأوراق المالية المصرية خلال الفترة من عام ٢٠١٠ حتى عام ٢٠١٩، وتمثلت عينة الدراسة في المنشآت التي تم اختيارها وفقاً للشروط التالية:

- أن تكون المنشأة مدرجة في مؤشر البورصة المصرية EGX 100.
  - استبعاد المنشآت التي تعمل في القطاع المالي كالبنوك وشركات التأمين.
- وبالتالي فإن العينة النهائية لمنشآت الأعمال محل الدراسة تمثلت في عدد (٨٣) منشأة، وذلك كما هو موضح بالجدول رقم (٣) التالي:

جدول رقم (٣) عينة منشآت الأعمال محل الدراسة

البيان	العدد
منشآت الأعمال المدرجة بمؤشر البورصة المصرية EGX 100	١٠٠
(-) استبعاد المنشآت التي تعمل في القطاع المالي	(١٧)
= إجمالي العينة النهائية لمنشآت الأعمال محل الدراسة	٨٣

بينما تمثلت عدد المشاهدات للعينة النهائية لمنشآت الأعمال محل الدراسة في عدد (٨٢٤) مشاهدة كما هو موضح بالجدول رقم (٤) التالي:

جدول رقم (٤) عدد مشاهدات عينة منشآت الأعمال محل الدراسة

إجمالي العينة النهائية لمنشآت الأعمال محل الدراسة	٨٣
× عدد المشاهدات لكل منشأة (١٠ سنوات)	١٠
= إجمالي عدد المشاهدات	٨٣٠
(-) مشاهدات لم تتوفر (٦ سنوات لإحدى المنشآت)	(٦)
= إجمالي عدد المشاهدات النهائية لمنشآت الأعمال محل الدراسة	٨٢٤

ويمكن تبويب العينة النهائية لمنشآت الأعمال محل الدراسة حسب التخصص القطاعي كما هو موضح بالجدول رقم (٥) التالي:

جدول رقم (٥) التخصص القطاعي لعينة منشآت الأعمال محل الدراسة

القطاع	عدد منشآت الأعمال
اتصالات و اعلام و تكنولوجيا المعلومات	٤
أغذية و مشروبات و تبغ	١٣
خدمات النقل والشحن	٤
خدمات و منتجات صناعية وسيارات	٤
رعاية صحية و ادوية	٥
سياحة و ترفيه	٤

٢	طاقة وخدمات مساندة
٢١	عقارات
٤	مقاولات و إنشاءات هندسية
٤	منسوجات و سلع معمرة
٦	مواد البناء
١٢	موارد أساسية
٨٣	إجمالي العينة النهائية لمنشآت الأعمال

#### ٣/٤. توصيف متغيرات الدراسة:

١/٣/٤. المتغير التابع: يعد هذا المتغير المخرجات النهائية لنماذج التنبؤ ويعبر عن مخاطر الائتمان لمنشآت الأعمال، وهو عبارة عن متغير ثنائي، حيث تأخذ الشركات المعرضة لمخاطر الائتمان قيمة (١) بينما الشركات غير المعرضة لمخاطر الائتمان تأخذ القيمة (صفر).

٢/٣/٤. المتغيرات المستقلة: النسب والمؤشرات المالية التي يمكن استخدامها في التنبؤ بمخاطر الائتمان التي تتعرض لها منشآت الأعمال، وتمثلت تلك المؤشرات في عدد (٣٠) مؤشر مالي، وتم اختيارها على أساس المؤشرات المالية الأكثر تداولاً وتكراراً في الدراسات السابقة التي تم تناولها، ويمكن توضيحها في الجدول رقم (٦) التالي:

#### جدول رقم (٦) المؤشرات المالية

م	النسبة أو المؤشر	طريقة القياس	أهم المراجع التي تناولت المؤشر
١	نسبة مجمل الربح	مجمل الربح / الإيرادات	Hai, et al., 2018; Wójcicka, A., 2018; Ansari, et al., 2020
٢	نسبة الربح التشغيلي	الربح التشغيلي / الإيرادات	Hai, et al., 2018; Ansari, et al., 2020; Yang, and Yang, 2020
٣	نسبة صافي الربح قبل الفوائد والضرائب والاهلاك	صافي الربح قبل الفوائد والضرائب والاهلاك / الإيرادات	Addo, et al., 2018; Akbar, et al., 2018; Khemakhem, and Boujelbene, 2018

Tokarski, and Manikowska, 2017; Chalamandaris, and Vlachogiannakis, 2018	صافي الربح قبل الضرائب / الإيرادات	نسبة صافي الربح قبل الضرائب	٤
Akbar, et al., 2018; Wójcicka, A., 2018; Ansari, et al., 2020	صافي الربح / الإيرادات	نسبة صافي الربح	٥
Namazi, et al., 2016; Kluza, 2017; Setiany, 2021	(التدفقات النقدية التشغيلية - المصروفات الرأسمالية) / القيمة السوقية	نسبة التدفق النقدي الحر	٦
Khemakhem, and Boujelbene, 2017; Hai, et al., 2018; Ansari, et al., 2020	صافي الربح / حقوق الملكية	معدل العائد على حقوق الملكية	٧
Hai, et al., 2018; Huang, et al., 2018; Ansari, et al., 2020	صافي الربح / إجمالي الأصول	معدل العائد على الأصول	٨
Zhu, et al., 2016; Halteh, et al., 2018; Ansaria, et al., 2021	صافي الربح / (رأس المال العامل + إجمالي الأصول طويلة الاجل)	معدل العائد على الاستثمار	٩
Omar, et al., 2017; Wang, et al., 2017; Hai, et al., 2018	إجمالي الالتزامات / إجمالي الأصول	نسبة إجمالي الديون إلى إجمالي الأصول	١٠
Omar, et al., 2017; Wang, et al., 2017; Hai, et al., 2018	إجمالي الالتزامات / حقوق الملكية	نسبة إجمالي الديون إلى إجمالي حقوق الملكية	١١
Hai, et al., 2018; Ansaria, et al., 2021; Kitagawa and Shuto, 2021	صافي الربح قبل الفوائد والضرائب / الفوائد المدينة	نسبة تغطية الفوائد	١٢
Qammar, et al., 2017; Yuriy, 2020; Abbas, et al., 2021	صافي الربح / توزيعات الأرباح المعلنة	نسبة تغطية توزيعات الأرباح	١٣
Qammar, et al., 2017; Raza, et al., 2020; Abbas, et al., 2021	١ - نسبة الأرباح المتراكمة	نسبة مدفوعات توزيعات الأرباح	١٤
Qammar, et al., 2017; Raza, et al., 2020; Abbas, et al., 2021	الأرباح المتراكمة / صافي الربح	نسبة الأرباح المتراكمة	١٥

Omar, et al., 2017; Hai, et al., 2018; Ansari, et al., 2020	الإيرادات / إجمالي الأصول	معدل دوران الأصول	١٦
Akbar, et al., 2018; Erika, et al., 2018; Mall, et al., 2019	إجمالي الأصول / حقوق الملكية	مضاعف حقوق الملكية	١٧
Omar, et al., 2017; Ansari, et al., 2020; Yang and Yang, 2020	رأس المال العامل / إجمالي الأصول	نسبة صافي رأس المال العامل	١٨
Hai, et al., 2018; Wójcicka, A., 2018; Yang and Yang, 2020	صافي المبيعات الآجلة / متوسط رصيد المدينون	معدل دوران المدينون	١٩
Akbar, et al., 2018; Hai, et al., 2018; Yang and Yang, 2020	صافي المشتريات الآجلة / متوسط رصيد الدائنين	معدل دوران الدائنين	٢٠
Omar, et al., 2017; Hai, et al., 2018; Yang and Yang, 2020	تكلفة المبيعات / متوسط المخزون	معدل دوران المخزون	٢١
Jin, et al., 2018; Ansari, et al., 2020; Yamin and Gulzar, 2020	القيمة السوقية للسهم / القيمة الدفترية للسهم	القيمة السوقية للسهم إلى القيمة الدفترية للسهم	٢٢
Jin, et al., 2018; Yang and Yang, 2020; Yamin and Gulzar, 2020	القيمة السوقية للسهم / إيرادات السهم	القيمة السوقية للسهم إلى إيرادات السهم	٢٣
Jin, et al., 2018; Ansari, et al., 2020; Yang and Yang, 2020	القيمة السوقية للسهم / التدفق النقدي الحر للسهم	القيمة السوقية للسهم إلى التدفق النقدي الحر للسهم	٢٤
Jin, et al., 2018; Ansari, et al., 2020; Yang, and Yang, 2020	القيمة السوقية للسهم / التدفق النقدي للسهم	القيمة السوقية للسهم إلى التدفق النقدي للسهم	٢٥
Ansari, et al., 2020; Yang, and Yang, 2020; Yamin, and Gulzar, 2020	نسبة القيمة السوقية للسهم إلى ربح السهم	نسبة القيمة السوقية للسهم إلى ربح السهم	٢٦
Aljifri, and Ahmad, 2019; Yamin and Gulzar, 2020; Woo, et al., 2021	نسبة القيمة السوقية / إجمالي الإيرادات	نسبة القيمة السوقية إلى إجمالي الإيرادات	٢٧
Aljifri and Ahmad, 2019; Yamin and Gulzar, 2020; Woo, et al., 2021	نسبة القيمة السوقية / صافي الربح قبل الفوائد والضرائب والاهلاك	نسبة القيمة السوقية إلى صافي الربح قبل الفوائد والضرائب والاهلاك	٢٨

Aljifri and Ahmad, 2019; Martín, 2019; Jaki and Ćwięk, 2021	نسبة القيمة السوقية / التدفقات النقدية	نسبة القيمة السوقية إلى التدفقات النقدية	٢٩
Aljifri and Ahmad, 2019; Martín, 2019; Jaki and Ćwięk, 2021	نسبة القيمة السوقية / التدفقات النقدية الحرة	نسبة القيمة السوقية إلى التدفقات النقدية الحرة	٣٠

#### ٤/٤. تحديد منشآت الأعمال المعرضة لمخاطر الائتمان وغير المعرضة لمخاطر الائتمان:

لاختبار النموذج المقترح للتنبؤ بمخاطر الائتمان يجب تصنيف عينة الدراسة إلى مجموعتين منشآت معرضة لمخاطر الائتمان ومنشآت غير معرضة لمخاطر الائتمان تم الاعتماد على النسب المعيارية المتعارف عليها في مجال التحليل المالي أو افتراضات شائعة بالدراسات السابقة، ويمكن ايضاحها كالتالي: (Halteh, et al., 2018; Valaskova, et al., 2018; Islami and Rio, 2019; Zhu, et al., 2019; Guo, et al., 2020; Ansaria, et al., 2021)

٤/٤/١. تجاوز إجمالي الالتزامات لإجمالي الأصول: حيث يشير معيار المراجعة المصري رقم (٥٧٠) " الاستمرارية" إلى الشك في قدرة المنشأة على الاستمرار وبالتالي تعرضها للمخاطر المالية، ويقصد به زيادة الالتزامات المستحقة للغير عن أصول المنشأة، ومن ثم فإن تجاوز إجمالي الالتزامات لإجمالي أصول المنشأة دليل على تعثر المنشأة وتعرضها للمخاطر المالية لعدم قدرة أصولها على تغطية التزاماتها. (المعايير المصرية للمراجعة والفحص المحدود ومهام التأكد الأخرى، ٢٠٠٨ والمعدلة في ٢٠١٩)

٤/٤/٢. نسبة إجمالي الالتزامات إلى إجمالي الأصول: حيث تشير هذه النسبة إلى مدى اعتماد المنشأة على الديون في تمويل أصولها، وبالتالي يجب تخفيض هذه النسبة إلى أقل ما يمكن، ووفقاً للدراسات السابقة يتم احتساب وسط Median هذه النسبة لعينة الدراسة وما يزيد عن الوسط يعني تعرض المنشأة للمخاطر المالية، ومن ثم توصل الباحثان أن زيادة نسبة إجمالي الالتزامات عن ٤٠٪ من إجمالي الأصول دليل على تعرض المنشأة للمخاطر المالية.

٣/٤/٤. نسبة إجمالي الالتزامات إلى حقوق الملكية: حيث تشير هذه النسبة توازن هيكل التمويل بالمنشأة، أي التوازن بين الديون الداخلية والخارجية، وبالتالي يجب تخفيض هذه النسبة إلى أقل ما يمكن، ووفقاً للدراسات السابقة يتم احتساب وسط هذه النسبة لعينة الدراسة وما يزيد عن الوسط يعني تعرض المنشأة للمخاطر المالية، ومن ثم توصل الباحثان أن زيادة نسبة إجمالي الالتزامات عن ٥٠٪ من حقوق الملكية دليل على تعرض المنشأة للمخاطر المالية.

٤/٤/٤. نسبة صافي الربح: حيث تشير هذه النسبة إلى قدرة المنشأة على تحقيق أرباح صافية من مبيعاتها، وبالتالي يجب زيادة هذه النسبة إلى أكبر ما يمكن، ووفقاً للدراسات السابقة يتم احتساب وسط هذه النسبة لعينة الدراسة وما ينخفض عن الوسط يعني تعرض المنشأة للمخاطر المالية، ومن ثم توصل الباحثان إلى أن انخفاض نسبة صافي الربح عن ٢٠٪ دليل على تعرض المنشأة للمخاطر المالية.

٥/٤/٤. نسبة تغطية الديون: حيث تشير هذه النسبة المنشأة على تغطية ديونها من خلال قدرة أصولها الملموسة بالإضافة إلى رأس المال العامل على تغطية التزاماتها، وبالتالي يجب زيادة هذه النسبة إلى أكبر ما يمكن، ووفقاً للدراسات السابقة يتم احتساب وسط هذه النسبة لعينة الدراسة وما ينخفض عن الوسط يعني تعرض المنشأة للمخاطر المالية، ومن ثم توصل الباحثان إلى أن انخفاض هذه النسبة عن ٢ : ١ دليل على تعرض المنشأة للمخاطر المالية.

٦/٤/٤. نسبة صافي الربح قبل الفوائد والضرائب والإهلاك لتغطية الفوائد: حيث تشير هذه النسبة المنشأة على تحقيق أرباح قادرة على تغطية فوائد القروض والسندات، من خلال قدرة صافي الربح قبل الفوائد والضرائب والإهلاك على تغطية المصروفات التمويلية، وبالتالي يجب زيادة هذه النسبة إلى أكبر ما يمكن، ووفقاً للدراسات السابقة يتم احتساب وسط هذه النسبة لعينة الدراسة وما ينخفض عن الوسط يعني تعرض المنشأة للمخاطر المالية، ومن ثم توصل الباحثان إلى أن انخفاض هذه النسبة عن ١.٥ : ١ دليل على تعرض المنشأة للمخاطر المالية.

٧/٤/٤. نسبة الأرباح التشغيلية لتغطية الفوائد: حيث تشير هذه النسبة المنشأة على تحقيق أرباح تشغيلية قادرة على تغطية فوائد القروض والسندات، من خلال قدرة صافي الربح قبل الفوائد والضرائب على تغطية المصروفات التمويلية، وبالتالي يجب زيادة هذه النسبة إلى أكبر ما يمكن، ووفقاً للدراسات

السابقة يتم احتساب وسط هذه النسبة لعينة الدراسة وما ينخفض عن الوسط يعني تعرض المنشأة للمخاطر المالية، ومن ثم توصل الباحثان إلى أن انخفاض هذه النسبة عن ١.٥ : ١ دليل على تعرض المنشأة للمخاطر المالية.

#### ٥/٤. الأساليب الإحصائية المستخدمة لتقييم نموذج الدراسة:

للوصول إلى مخرجات النموذج المحاسبي للدراسة وهو دقة التنبؤ بمخاطر الائتمان لمنشآت الأعمال، تم الاعتماد على كل من الانحدار اللوجستي، والشبكات العصبية.

#### ١/٥/٤. الانحدار اللوجستي:

شاع استخدام أسلوب الانحدار اللوجستي في النماذج المحاسبية ذات التصنيف الثنائي، حيث يكون المتغير التابع في شكل (١) أو (صفر)، كما هو المتغير التابع بهذه الدراسة، حيث يشير الرقم (١) إلى احتمال تعرض المنشأة لمخاطر الائتمان، بينما يشير الرقم (صفر) إلى عدم تعرضها لمخاطر الائتمان. ويمكن صياغة معادلة الانحدار اللوجستي كما يلي:

$$Y = \text{Log} \left[ \frac{p}{1-p} \right] = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n$$

حيث أن:

Y : تمثل احتمالية تعرض المنشأة لمخاطر الائتمان

$\text{Log} \left[ \frac{p}{1-p} \right]$  : تمثل لوغاريتم المتغير التابع، وهو عبارة لوغاريتم نسبة بين احتمالين

P : تمثل المخرجات

$\alpha$  : تمثل العنصر الثابت

$\beta_n$  : تمثل معامل المتغيرات المستقلة لنموذج الانحدار اللوجستي

$X_n$  : تمثل المتغيرات المستقلة ( عدد ٣٠ مؤشر مالي)

ثم يتم إدخال المتغيرات المستقلة من مؤشرات مالية بنموذج الدراسة وفقاً لمعادلة الانحدار اللوجستي، وإذا كانت Y والتي تمثل احتمالية تعرض المنشأة لمخاطر الائتمان بقيمة ٠,٥٠ أو أكبر كانت الشركة معرضة لمخاطر الائتمان ، أما إذا كانت Y أقل من ٠,٥٠ كانت الشركة غير معرضة لمخاطر الائتمان.

٢/٥/٤. الشبكات العصبية:

قام الباحثان باستخدام لغة بايثون Python لتطبيق الشبكات العصبية، وذلك لتزايد اعتماد الباحثين عليها في الفترة الأخيرة لدقة نتائجها وتوافر العديد من المكتبات الجاهزة للاستدعاء (Lomakin, et al., 2020; Sezer, et al., 2020; Halim, et al., 2021) وقد تم إدخال المتغيرات المستقلة من مؤشرات مالية بنموذج الدراسة باستخدام الشبكات العصبية، وإذا كانت مخرجات نموذج الشبكات العصبية والتي تمثل احتمالية تعرض المنشأة لمخاطر الائتمان بقيمة ٠,٥٠ أو أكبر كانت الشركة معرضة لمخاطر الائتمان ، أما إذا كانت مخرجات نموذج الشبكات العصبية أقل من ٠,٥٠ كانت الشركة غير معرضة لمخاطر الائتمان.

٦/٤. أساليب اختبار نتائج نماذج الدراسة:

يتم اختبار نتائج أداء كل من نموذج الانحدار اللوجستي، والشبكات العصبية باستخدام مصفوفة التصنيف أو التداخل Confusion Matrix، حيث تعد مصفوفة التصنيف من أكثر الأساليب استخداماً في تقييم دقة تصنيفات النماذج المحاسبية، حيث تصنف عدد الحالات الإيجابية من إجمالي عدد الحالات، وعدد الحالات السلبية من إجمالي عدد الحالات، ثم قياس معدل الدقة لكل منهما بنسبة كل من عدد الحالات الإيجابية أو السلبية إلى إجمالي عدد الحالات (An, 2017; Sarkar, et al., 2018; Valaskova, et al., 2020; Zeng, 2020) وذلك كما هو موضح بالجدول رقم (٧) التالي:

جدول رقم (٧) مصفوفة التصنيف

التنبؤ/الفعلي	منشآت معرضة لمخاطر الائتمان	منشآت غير معرضة لمخاطر الائتمان	الإجمالي	دقة التنبؤ
منشآت معرضة لمخاطر الائتمان	تنبؤات إيجابية	تنبؤات سلبية	---	%
منشآت غير معرضة لمخاطر الائتمان	تنبؤات سلبية	تنبؤات إيجابية	---	%
الإجمالي	---	---	---	

٧/٤. تحليل واختبار النتائج:

يهدف هذا الجزء من الدراسة إلى تحليل نتائج التطبيق العملي لكل من الانحدار اللوجستي، والشبكات العصبية لنموذج الدراسة كما يلي:

#### ١/٧/٤. تحليل نتائج تطبيق الانحدار اللوجستي للتنبؤ بمخاطر الائتمان:

تم إدخال المتغيرات المستقلة من مؤشرات مالية وعددهم (٣٠) مؤشر مالي بنموذج الدراسة وفقاً لمعادلة الانحدار اللوجستي للتنبؤ بمخاطر الائتمان، كما هو موضح بالجدول رقم (٨) التالي:

جدول رقم (٨) نموذج الانحدار اللوجستي للتنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية

Sig	Interval	[95% Conf	p- value	t- value	St.Err.	Coef.	المؤشرات المالية
***	.079	.029	0	4.24	.013	.054	نسبة مجمل الربح
***	-.026	-.104	.001	-3.23	.02	-.065	نسبة الربح التشغيلي
**	.082	.004	.031	2.16	.02	.043	نسبة صافي الربح قبل الفوائد والضرائب والاهلاك
	.05	-.046	.938	0.08	.025	.002	نسبة صافي الربح قبل الضرائب
	.013	-.093	.138	-1.48	.027	-.04	نسبة صافي الربح
*	.018	-.001	.073	1.80	.005	.009	نسبة التدفق النقدي الحر
***	.055	.03	0	6.46	.007	.042	معدل العائد على حقوق الملكية
***	-.092	-.194	0	-5.49	.026	-.143	معدل العائد على الأصول
	.03	-.018	.629	0.48	.012	.006	معدل العائد على الاستثمار
***	.066	.019	0	3.58	.012	.043	نسبة إجمالي الديون إلى إجمالي الأصول
***	-.003	-.009	.001	-3.42	.002	-.006	نسبة إجمالي الديون إلى إجمالي حقوق الملكية
**	0	0	.044	-2.01	0	0	نسبة تغطية الفوائد
	.002	-.001	.318	1.00	.001	.001	نسبة تغطية توزيعات الأرباح
	.501	-.354	.735	0.34	.218	.074	نسبة مدفوعات توزيعات الأرباح
	.004	-.004	.964	0.05	.002	0	نسبة الأرباح المتراكمة
**	.902	.098	.015	2.44	.205	.5	معدل دوران الأصول
***	1.266	.663	0	6.27	.154	.965	مضاعف حقوق الملكية
	.836	-	.452	-0.75	.692	-.52	نسبة صافي رأس المال العامل

	1.877						
	.003	-.02	.155	-1.42	.006	-.009	معدل دوران المدينون
	.002	-.004	.39	-0.86	.001	-.001	معدل دوران الدائنون
	.003	-.018	.162	-1.40	.005	-.008	معدل دوران المخزون
	.186	-.072	.384	0.87	.066	.057	القيمة السوقية للسهم إلى القيمة الدفترية للسهم
***	.558	.127	.002	3.12	.11	.342	القيمة السوقية للسهم إلى إيرادات السهم
**	-.001	-.028	.03	-2.17	.007	-.014	القيمة السوقية للسهم إلى التدفق النقدي الحر للسهم
	.008	-.044	.177	-1.35	.013	-.018	القيمة السوقية للسهم إلى التدفق النقدي للسهم
**	.154	.002	.044	2.02	.039	.078	نسبة القيمة السوقية للسهم إلى ربح السهم
***	-.147	-.594	.001	-3.25	.114	-.37	نسبة القيمة السوقية إلى إجمالي الإيرادات
***	.077	.017	.002	3.05	.015	.047	نسبة القيمة السوقية إلى صافي الربح قبل الفوائد والضرائب والإهلاك
	.006	-.001	.166	1.39	.002	.002	نسبة القيمة السوقية إلى التدفقات النقدية
	.017	-.004	.229	1.20	.006	.007	نسبة القيمة السوقية إلى التدفقات النقدية الحرة

وكانت نتائج تطبيق الانحدار اللوجستي للتنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية

كما هو موضح بالجدول رقم (٩) التالي:

رقم (٩) مصفوفة التصنيف لنموذج الانحدار اللوجستي للتنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية

التنبؤ / الفعلي	منشآت معرضة لمخاطر الائتمان	منشآت غير معرضة لمخاطر الائتمان	الإجمالي	دقة التنبؤ
منشآت معرضة لمخاطر الائتمان	٤٢٤	٥٦	٤٨٠	٪ ٨٨.٣٣
منشآت غير معرضة لمخاطر الائتمان	٦٦	٢٧٨	٣٤٤	٪ ٨٠.٨١
الإجمالي	٤٩٠	٣٣٤	٨٢٤	٪ ٨٥.١٩

يتضح من الجدول السابق أن نموذج الانحدار اللوجستي للتنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية صنف منشآت الأعمال المعرضة لمخاطر الائتمان إلى عدد ٤٨٠ منشأة، وكانت التنبؤات الإيجابية والتي تم تصنيفها بشكل صحيح عدد ٤٢٤ منشأة، بينما التنبؤات السلبية والتي تم تصنيفها بشكل خاطئ عدد ٥٦ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٨٨.٣٣٪.

كما نجد أن نموذج الانحدار اللوجستي للتنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية صنف منشآت الأعمال غير المعرضة لمخاطر الائتمان إلى عدد ٣٤٤ منشأة، وكانت التنبؤات الإيجابية والتي تم تصنيفها بشكل صحيح عدد ٢٧٨ منشأة، بينما التنبؤات السلبية والتي تم تصنيفها بشكل خاطئ عدد ٦٦ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٨٠.٨١٪.

كما يتضح أن إجمالي دقة التصنيف النهائية لنموذج الانحدار اللوجستي للتنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية بلغت ٨٥.١٩٪، مما يشير إلى كفاءة نموذج الانحدار اللوجستي باستخدام المؤشرات المالية في التنبؤ بمخاطر الائتمان لمنشآت الأعمال.

#### ٢/٧/٤. تحليل نتائج تطبيق الشبكات العصبية للتنبؤ بمخاطر الائتمان:

تم إدخال المتغيرات المستقلة من مؤشرات مالية وعددهم (٣٠) مؤشر مالي بنموذج الدراسة للتنبؤ بمخاطر الائتمان، ثم قام الباحثان ببناء عدد (٤) نماذج للشبكات العصبية للتنبؤ بمخاطر الائتمان، حيث يمكن تلخيص هذه النماذج الأربعة بالجدول رقم (١٠) التالي:

جدول رقم (١٠) نماذج الشبكات العصبية الأربعة للتنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية

النموذج الرابع	النموذج الثالث	النموذج الثاني	النموذج الأول	البناء الهيكلي للنموذج
٦٤	٣٢	٦٤	٤٧	عدد الطبقات الخفية
١٦	١٦	٣٢	عشوائي	عدد النيورونات في كل طبقة خفية
سيجمويد	سيجمويد	سيجمويد	سيجمويد	دالة التحويل المستخدمة

وتم تدريب كل نموذج من النماذج الأربعة بطريقة متداخلة من خلال تقسيم بيانات النموذج إلى مجموعات، ثم يتم تدريب النموذج على كل هذه المجموعات ما عدا مجموعة وحيدة مكونة من عدد ١٦٥ منشأة (منها عدد ١٠٣ منشأة معرضة لمخاطر الائتمان وعدد ٦٢ منشأة غير معرضة لمخاطر الائتمان) وذلك حتى يتم الاختبار عليها، ثم يتم تكرار هذه العملية بحيث يتم التأكد بأن كل المجموعات تم تدريبها، ومن ثم يتحدد معدل التعلم من خلال قيمة التصحيح التي على أساسها يتم تعديل الأوزان النسبية أثناء عملية التدريب، إلى أن تصل إلى أفضل النتائج.

#### ٤/٧/٢/١. تحليل نتائج تطبيق النموذج الأول للشبكات العصبية للتنبؤ بمخاطر الائتمان:

بعد تدريب النموذج يتم الاختبار على المجموعة الوحيدة التي لم تخضع للتدريب والمكونة من عدد ١٦٥ منشأة، يوضح الجدول رقم (١١) التالي مصفوفة التصنيف للنموذج الأول للشبكات العصبية للتنبؤ بمخاطر الائتمان:

جدول رقم (١١) مصفوفة التصنيف لنموذج الشبكات العصبية الأول للتنبؤ بمخاطر الائتمان

التنبؤ / الفعلي	منشآت معرضة لمخاطر الائتمان	منشآت غير معرضة لمخاطر الائتمان	الإجمالي	دقة التنبؤ
منشآت معرضة لمخاطر الائتمان	٩٥	٨	١٠٣	٪ ٩٢.٢٣
منشآت غير معرضة لمخاطر الائتمان	٢٧	٣٥	٦٢	٪ ٥٦.٤٥
الإجمالي	١٢٢	٤٣	١٦٥	٪ ٧٨.٧٩

بالتالي نجد أن النموذج الأول للشبكات العصبية للتنبؤ بمخاطر الائتمان صنف منشآت الأعمال المعرضة لمخاطر الائتمان بمجموعة الاختبار إلى عدد ١٠٣ منشأة، وكانت التنبؤات الإيجابية عدد ٩٥ منشأة، بينما التنبؤات السلبية عدد ٨ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٩٢.٢٣٪. كما صنف النموذج منشآت الأعمال غير المعرضة لمخاطر الائتمان بمجموعة الاختبار إلى عدد ٦٢ منشأة، وكانت التنبؤات الإيجابية عدد ٣٥ منشأة، بينما

التنبؤات السلبية عدد ٢٧ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٥٦.٤٥٪.

وأخيراً بلغت إجمالي دقة التصنيف النهائية للنموذج الأول للشبكات العصبية للتنبؤ بمخاطر الائتمان ٧٨.٧٩٪.

#### ٢/٢/٧/٤. تحليل نتائج تطبيق النموذج الثاني للشبكات العصبية للتنبؤ بمخاطر الائتمان:

بعد تدريب النموذج يتم الاختبار على المجموعة الوحيدة التي لم تخضع للتدريب والمكونة من عدد ١٦٥ منشأة، يوضح الجدول رقم (١٢) التالي مصفوفة التصنيف أو التداخل للنموذج الثاني للشبكات العصبية للتنبؤ بمخاطر الائتمان:

جدول رقم (١٢) مصفوفة التصنيف لنموذج الشبكات العصبية الثاني للتنبؤ بمخاطر الائتمان

التنبؤ / الفعلي	منشآت معرضة لمخاطر الائتمان	منشآت غير معرضة لمخاطر الائتمان	الإجمالي	دقة التنبؤ
منشآت معرضة لمخاطر الائتمان	٩٢	١١	١٠٣	٪ ٨٩.٣٢
منشآت غير معرضة لمخاطر الائتمان	١١	٥١	٦٢	٪ ٨٢.٢٥
الإجمالي	١٠٣	٦٢	١٦٥	٪ ٨٦.٦٧

بالتالي نجد أن النموذج الثاني للشبكات العصبية للتنبؤ بمخاطر الائتمان صنف منشآت الأعمال المعرضة لمخاطر الائتمان بمجموعة الاختبار إلى عدد ١٠٣ منشأة، وكانت التنبؤات الإيجابية عدد ٩٢ منشأة، بينما التنبؤات السلبية عدد ١١ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٨٩.٣٢٪. كما صنف النموذج منشآت الأعمال غير المعرضة لمخاطر الائتمان بمجموعة الاختبار إلى عدد ٦٢ منشأة، وكانت التنبؤات الإيجابية عدد ٥١ منشأة، بينما التنبؤات السلبية عدد ١١ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٨٢.٢٥٪.

وأخيراً بلغت إجمالي دقة التصنيف النهائية للنموذج الثاني للشبكات العصبية للتنبؤ بمخاطر الائتمان ٨٦.٦٧٪.

٣/٢/٧/٤. تحليل نتائج تطبيق النموذج الثالث للشبكات العصبية للتنبؤ بمخاطر الائتمان:

بعد تدريب النموذج يتم الاختبار على المجموعة الوحيدة التي لم تخضع للتدريب والمكونة من عدد ١٦٥ منشأة، يوضح الجدول رقم (١٣) التالي مصفوفة التصنيف أو التداخل للنموذج الثالث للشبكات العصبية للتنبؤ بمخاطر الائتمان:

جدول رقم (١٣) مصفوفة التصنيف لنموذج الشبكات العصبية الثالث للتنبؤ بمخاطر الائتمان

التنبؤ / الفعلي	منشآت معرضة لمخاطر الائتمان	منشآت غير معرضة لمخاطر الائتمان	الإجمالي	دقة التنبؤ
منشآت معرضة لمخاطر الائتمان	٩٦	٧	١٠٣	٩٣.٢٠ %
منشآت غير معرضة لمخاطر الائتمان	٢٥	٣٧	٦٢	٥٦.٦٧ %
الإجمالي	١٢١	٤٤	١٦٥	٨٠.٦١ %

بالتالي نجد أن النموذج الثالث للشبكات العصبية للتنبؤ بمخاطر الائتمان صنف منشآت الأعمال المعرضة لمخاطر الائتمان بمجموعة الاختبار إلى عدد ١٠٣ منشأة، وكانت التنبؤات الإيجابية عدد ٩٦ منشأة، بينما التنبؤات السلبية عدد ٧ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٩٣.٢٠ %. كما صنف النموذج منشآت الأعمال غير المعرضة لمخاطر الائتمان بمجموعة الاختبار إلى عدد ٦٢ منشأة، وكانت التنبؤات الإيجابية عدد ٣٧ منشأة، بينما التنبؤات السلبية عدد ٢٥ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٥٦.٦٧ %.

وأخيراً بلغت إجمالي دقة التصنيف النهائية للنموذج الثالث للشبكات العصبية للتنبؤ بمخاطر الائتمان ٨٠.٦١ %.

٤/٢/٧/٤. تحليل نتائج تطبيق النموذج الرابع للشبكات العصبية للتنبؤ بمخاطر الائتمان:

بعد تدريب النموذج يتم الاختبار على المجموعة الوحيدة التي لم تخضع للتدريب والمكونة من عدد ١٦٥ منشأة، يوضح الجدول رقم (١٤) التالي مصفوفة التصنيف أو التداخل للنموذج الرابع للشبكات العصبية للتنبؤ بمخاطر الائتمان:

جدول رقم (١٤) مصفوفة التصنيف لنموذج الشبكات العصبية الرابع للتنبؤ بمخاطر الائتمان

التنبؤ / الفعلي	منشآت معرضة لمخاطر الائتمان	منشآت غير معرضة لمخاطر الائتمان	الإجمالي	دقة التنبؤ
منشآت معرضة لمخاطر الائتمان	٩٩	٤	١٠٣	٪ ٩٦.١١
منشآت غير معرضة لمخاطر الائتمان	٣٠	٣٢	٦٢	٪ ٥١.٦١
الإجمالي	١٢٩	٣٦	١٦٥	٪ ٧٩.٣٩

بالتالي نجد أن النموذج الرابع للشبكات العصبية للتنبؤ بمخاطر الائتمان صنف منشآت الأعمال المعرضة لمخاطر الائتمان بمجموعة الاختبار إلى عدد ١٠٣ منشأة، وكانت التنبؤات الإيجابية عدد ٩٩ منشأة، بينما التنبؤات السلبية عدد ٤ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٩٦.١١ ٪. كما صنف النموذج منشآت الأعمال غير المعرضة لمخاطر الائتمان بمجموعة الاختبار إلى عدد ٦٢ منشأة، وكانت التنبؤات الإيجابية عدد ٣٢ منشأة، بينما التنبؤات السلبية عدد ٣٠ منشأة، وبالتالي بلغت دقة التنبؤ بالمنشآت المعرضة لمخاطر الائتمان ٥١.٦١ ٪.

وأخيراً بلغت إجمالي دقة التصنيف النهائية للنموذج الرابع للشبكات العصبية للتنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية ٧٩.٣٩ ٪.

٥/٢/٧/٤. ملخص نتائج تطبيق الشبكات العصبية للتنبؤ بمخاطر الائتمان:

يلخص الجدول التالي رقم (١٥) دقة التصنيف لنماذج للشبكات العصبية الأربعة في التنبؤ بمخاطر الائتمان:

جدول رقم (١٥) دقة نماذج الشبكات العصبية الأربعة للتنبؤ بمخاطر الائتمان

دقة التنبؤ/النموذج	النموذج الأول	النموذج الثاني	النموذج الثالث	النموذج الرابع
دقة التنبؤ بالمخاطر المالية باستخدام المؤشرات المالية	٧٨.٧٩ %	٨٦.٦٧ %	٨٠.٦١ %	٧٩.٣٩ %

يرى الباحثان من تحليل واختبار نتائج النماذج الأربعة للشبكات العصبية للتنبؤ بمخاطر الائتمان، أن هناك تأثير جوهري لعدد الطبقات الخفية بكل نموذج وعدد النيرونات أو العصبونات بكل طبقة على دقة التصنيف النهائية للنموذج، وبالتالي اتضح من مقارنة تحليل واختبار نتائج النماذج الأربعة للشبكات العصبية للتنبؤ بمخاطر الائتمان أن أعلى مستوى دقة للتنبؤ بواقع ٨٦.٦٧ %..

#### ٨/٤. اختبار فروض البحث:

##### ١/٨/٤. اختبار الفرض الرئيس الأول:

الفرض الأول ( $H_1$ ): يؤدي استخدام الشبكات العصبية متعددة الطبقات إلى تحسين قدرة المؤشرات المالية في التنبؤ بمخاطر الائتمان لمنشآت الأعمال.

لاختبار صحة الفرض الرئيس الأول، قام الباحثان بإجراء مقارنة بين معدل دقة الشبكات العصبية وبين معدل دقة الانحدار اللوجستي في التنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية، ويمكن إيضاح ذلك بالجدول رقم (١٦) التالي:

جدول رقم (١٦) مقارنة بين معدل دقة الشبكات العصبية وبين الانحدار اللوجستي في التنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية

دقة التنبؤ/النموذج	الانحدار اللوجستي	الشبكات العصبية
دقة التنبؤ بمخاطر الائتمان باستخدام المؤشرات المالية	٨٥.١٩ %	٨٦.٦٧ %

ويتضح من المقارنة السابقة ارتفاع دقة التنبؤ بمخاطر الائتمان باستخدام الشبكات العصبية مقارنة بالانحدار اللوجستي.

كما قام الباحثان بمقارنة معامل التحديد ( $R^2$ ) باستخدام الشبكات العصبية وبين معامل التحديد باستخدام الانحدار اللوجستي، وتبين تفوق قيمة معامل التحديد باستخدام الشبكات العصبية عن قيمة معامل التحديد باستخدام الانحدار اللوجستي، وذلك يدل على زيادة القدرة التفسيرية للمتغيرات المستقلة (المؤشرات المالية) في تفسير المتغير التابع (مخاطر الائتمان) باستخدام الشبكات العصبية، حيث بلغت قيمته للشبكات العصبية (0.432)، وذلك عند مستوى معنوية أقل من (0.05)، في حين بلغت قيمة معامل التحديد للانحدار اللوجستي (0.413)، وذلك عند مستوى معنوية أقل من (0.05). يتضح مما سبق قبول الفرض الرئيس الأول بأن استخدام الشبكات العصبية متعددة الطبقات يؤدي إلى تحسين قدرة المؤشرات المالية في التنبؤ بمخاطر الائتمان لمنشآت الأعمال.

#### ٢/٨/٤. اختبار الفرض الرئيس الثاني:

**الفرض الثاني ( $H_2$ ):** يوجد تأثير للمزيج الأمثل من النسب والمؤشرات المالية على دقة الشبكات العصبية متعددة الطبقات للتنبؤ بمخاطر الائتمان لمنشآت الأعمال.

بما أن الشبكات العصبية تتميز بإمكانية الاعتماد عليها في تحديد أهم المتغيرات المستقلة التي لها أقوى تأثير على المتغير التابع، وذلك من خلال التجربة والخطأ بعد التدريب والتعلم للوصول إلى أفضل خصائص، وذلك للحصول على أقل عدد من المتغيرات المستقلة الذي يحقق أفضل كفاءة وفعالية للشبكات العصبية (Zhou, Het al., 2019; Teles, et al., 2020). ولاختبار صحة الفرض الرئيس الثاني، قام الباحثان بتطبيق ذلك على مشكلة الدراسة لتحديد أهم المؤشرات المالية التي لها أقوى تأثير على دقة التنبؤ بمخاطر الائتمان لمنشآت الأعمال، وتم الحصول على عدد (10) مؤشرات مالية من بين جميع المؤشرات المالية التي تحقق أفضل كفاءة وفعالية للشبكات العصبية متعددة الطبقات، وقد تم ترتيبها تنازلياً من المؤشر الأكثر أهمية إلى المؤشر الأقل أهمية، ويتضح ذلك من الجدول رقم (17) التالي:

جدول رقم (17) أهم المؤشرات المالية الأكثر تأثيراً على دقة التنبؤ بمخاطر الائتمان

م	النسبة أو المؤشر
١	معدل العائد على الأصول

معدل دوران الدائنون	٢
معدل دوران الأصول	٣
نسبة إجمالي الديون إلى إجمالي الأصول	٤
مضاعف حقوق الملكية	٥
القيمة السوقية للسهم إلى القيمة الدفترية للسهم	٦
نسبة صافي رأس المال العامل	٧
نسبة صافي الربح	٨
معدل العائد على الاستثمار	٩
نسبة إجمالي الديون إلى إجمالي حقوق الملكية	١٠

وعلى ذلك، يتضح مما سبق قبول الفرض الرئيس الثاني بأنه يوجد تأثير للمزيج الأمثل من النسب والمؤشرات المالية على دقة الشبكات العصبية متعددة الطبقات للتنبؤ بمخاطر الائتمان لمنشآت الأعمال.

### الخلاصة والنتائج والتوصيات:

#### ١. الخلاصة والنتائج:

قام الباحثان بقياس قدرة نماذج الشبكات العصبية متعددة الطبقات على دقة التنبؤ بمخاطر الائتمان لمنشآت الأعمال باستخدام النسب والمؤشرات المالية، وقد توصل الباحثان من خلال الدراسة النظرية إلى النتائج التالية:

- باتت مخاطر الائتمان من الموضوعات محل الجدل، ومن أهم التحديات التي تواجه منشآت الأعمال في السنوات الأخيرة، ومن ثم يرى الباحثان أن التنبؤ بمخاطر الائتمان يعد من مدخلات عملية اتخاذ القرارات بالمنشأة، ويمكن الاعتماد عليه في اكتشاف النتائج السلبية المحتملة، والتصدي لها كمحاولة للتخلص منها أو تقليل آثارها السلبية أو تجنب حدوثها في المستقبل.

- بما أن تعثر منشآت الأعمال لا يحدث فجأة، ولكن تمر المنشأة بالعديد من المراحل قبل حدوث التعثر، فقد اهتم العديد من الباحثين بضرورة الوصول إلى نماذج تحليلية تساعد في التنبؤ، وذلك بالاعتماد على البيانات الكمية في تطوير نماذج التنبؤ.
- هناك بعض الانتقادات الموجهة إلى بعض الدراسات السابقة الرائدة في نظراً لاعتماد النماذج المقترحة بتلك الدراسات على الأساليب الإحصائية التقليدية، بالإضافة إلى الحاجة إلى تحديد المزيج الأمثل من تلك البيانات والمؤشرات المالية لتحقيق دقة التنبؤ بمخاطر الائتمان.
- أصبح هناك حاجة لتطوير الأساليب المستخدمة في التنبؤ بمخاطر الائتمان لمواجهة هذا التحدي، وذلك من خلال الاعتماد على أدوات وتقنيات الذكاء الاصطناعي، لذا شهدت الشبكات العصبية والتي تعد أحد تقنيات الذكاء الاصطناعي نمواً ملحوظاً في العديد من الدراسات، حيث تتفوق على النماذج والتقنيات الأخرى في العديد من المجالات، ونتيجة لذلك فهي أكثر قوة ودقة، مع مخاطر تنبؤ أقل، وتباين أقل في أخطائها مقارنة بالأساليب الإحصائية الأخرى.

#### بينما توصل الباحثان من خلال الدراسة التطبيقية إلى النتائج التالية:

- تفوق نماذج الشبكات العصبية متعددة الطبقات على الانحدار اللوجستي باستخدام المؤشرات المالية في التنبؤ بمخاطر الائتمان، حيث بلغت أعلى مستوى دقة للتنبؤ للشبكات العصبية ٨٦.٦٧٪ مقابل ٨٥.١٩٪ لنماذج الانحدار اللوجستي، وهذا يدل على أن هناك تأثير هام وجوهري للشبكات العصبية متعددة الطبقات في تحسين قدرة المؤشرات المالية في التنبؤ بمخاطر الائتمان لمنشآت الأعمال.
- تميز الشبكات العصبية متعددة الطبقات بإمكانية الاعتماد عليها في تحديد أهم المتغيرات المستقلة (المؤشرات المالية) التي لها أقوى تأثير على المتغير التابع (مخاطر الائتمان)، وذلك من خلال التجربة والخطأ بعد التدريب والتعلم للوصول إلى أفضل خصائص، وذلك للحصول على أقل عدد من المتغيرات المستقلة الذي يحقق أفضل كفاءة وفعالية للشبكات العصبية في التنبؤ، وبالتالي فقد تم الحصول على أكثر المؤشرات تأثيراً وعددها (١٠) مؤشرات من بين عدد (٣٠) مؤشر، وقد تم ترتيبها تنازلياً من المؤشر الأكثر أهمية إلى المؤشر الأقل أهمية.

- قبول الفرض الرئيس الأول بأن استخدام الشبكات العصبية متعددة الطبقات يؤدي إلى تحسين قدرة المؤشرات المالية في التنبؤ بمخاطر الائتمان لمنشآت الأعمال.
- قبول الفرض الرئيس الثاني بأنه يوجد تأثير للمزيج الأمثل من النسب والمؤشرات المالية على دقة الشبكات العصبية متعددة الطبقات للتنبؤ بمخاطر الائتمان لمنشآت الأعمال.

## ٢. التوصيات:

في ضوء النتائج التي توصل إليها البحث، يمكن تقديم مجموعة من التوصيات على النحو التالي:

### ١/٢. على المستوى العملي:

- توجيه اهتمام مستخدمي التقارير المالية بضرورة الاعتماد على تقنيات الذكاء الاصطناعي وخاصة الشبكات العصبية في تحليل ومعالجة المشاكل المحاسبية المختلفة خاصة تلك المتعلقة بالتنبؤ بالمخاطر المالية بصفة عامة ومخاطر الائتمان بصفة خاصة.
- توجيه اهتمام البنوك التجارية باستخدام تقنيات الذكاء الاصطناعي كالشبكات العصبية في التنبؤ بمخاطر الائتمان لمنشآت الأعمال، وذلك لترشيد القرارات المصرفية بتلك البنوك، وتقديم خدمات مصرفية على نحو أفضل وأسرع وبتكلفة أقل.
- تشجيع ودعم مكاتب المحاسبة والمراجعة على استخدام تقنيات الذكاء الاصطناعي للاستفادة من مميزاتهما في ظل الكم الهائل من البيانات والتقارير المالية المعقدة ومساعدتهم في اتخاذ القرارات.

### ٢/٢. على المستوى الأكاديمي:

- الاهتمام بإجراء المزيد من الدراسات والبحوث المحاسبية لتطبيق الشبكات العصبية في التنبؤ ببيئة الأعمال المصرية، مثل التنبؤ بالمبيعات والأرباح، واكتشاف الأخطاء والغش بالقوائم المالية، والانتذار المبكر من خطر الإفلاس، والتنبؤ بأسعار الأسهم، وإعداد الموازنات، وذلك لقدرتها الهائلة على التعامل مع البيانات الضخمة بكفاءة ودقة أعلى من الأساليب التقليدية.
- الاهتمام بإجراء المزيد من الدراسات والبحوث المحاسبية المقارنة للتنبؤ باستخدام الشبكات العصبية بين منشآت الأعمال بقطاع الأعمال العام وقطاع الأعمال الخاص في بيئة الأعمال المصرية، أو

التنبؤ باستخدام الشبكات العصبية بين منشآت الأعمال ببيئة الأعمال المصرية وبين منشآت الأعمال ببعض الدول المتشابهة أو المتقدمة، وذلك للوصول إلى مجموعة من النتائج التي قد تساعد في تفسير أسباب اختلاف الأداء المالي بين هذه المنشآت.

مراجع البحث:أولاً: المراجع باللغة العربية:

إسماعيل، طارق حسنين، ١٩٩٨. قياس قدرة التدفقات النقدية على التنبؤ بمدى استمرارية منشآت الأعمال باستخدام نماذج الشبكات العصبية. مجلة البحوث العلمية، جامعة حلوان، العدد الثالث والرابع، القاهرة.

المعايير المصرية للمراجعة والفحص المحدود ومهام التأكد الأخرى الصادرة في يوليو ٢٠٠٨، والمعدلة في ابريل ٢٠١٩، ص ص ١ - ٧٧٠. معيار المراجعة المصري رقم (٥٧٠): الاستمرارية. معايير المحاسبة المصرية الصادرة في يوليو ٢٠١٥، قائمة تعريفات مصطلحات معايير المحاسبة المصرية، الوقائع المصرية، ملحق للجريدة الرسمية، ص ص ١٥٢٣.

معايير المحاسبة المصرية الصادرة في يوليو ٢٠١٥ والمعدلة في ابريل ٢٠١٩، الوقائع المصرية، ملحق للجريدة الرسمية، ص ص ١-١٤٧٩. معيار رقم (٤٠) الأدوات المالية: الإفصاحات

ثانياً: المراجع باللغة الإنجليزية:

- Abbas, U., Farooq, M.I., Kashif, A.R., Hassan, S. and Scholar, S.M.P., 2021. Effect of dividend paying behavior and board size and board composition on firm's performance: Evidence from Pakistan. *Academy of Accounting and Financial Studies Journal*, 25(2), pp.1-17.
- Abdullah, M., Abdul Shukor, Z., Mohamed, Z.M. and Ahmad, A., 2015. Risk management disclosure: A study on the effect of voluntary risk management disclosure toward firm value. *Journal of Applied Accounting Research*, 16(3), pp.400-432.
- Addo, P.M., Guegan, D. and Hassani, B., 2018. Credit risk analysis using machine and deep learning models. *Risks*, 6(2), p.38.
- Agustina, L. and Baroroh, N., 2016. The relationship between enterprise risk management (ERM) and firm value mediated through the financial performance. *Review of Integrative Business & Economics Research*, 5(1), pp. 128-138.

- Akbar, R.F., Musdholifah, M. and Purwohandoko, P., 2018. Neural network prediction analysis: The financial distress case. *Researchers World*, 9(3), pp.119-125.
- Al Janabi, M.A., 2016. Value at risk prediction under illiquid market conditions: A comparison of alternative modeling strategies. *Risk Management in Emerging Markets. Emerald Group Publishing Limited*, pp.253-291.
- Aleisa, Y., 2017. Factors affecting implementation of enterprise risk management (ERM): An exploratory study among Saudi organizations, *Doctoral dissertation, University of Liverpool*.
- Aljifri, K. and Ahmad, H.I., 2019. Preferred valuation techniques in the UAE: A comparative study of financial and nonfinancial sectors. *International Journal of Economics and Financial Issues*, 9(1), p.51.
- Alloghani, M., Al-Jumeily, D., Mustafina, J., Hussain, A. and Aljaaf, A.J., 2020. A systematic review on supervised and unsupervised machine learning algorithms for data science. *Supervised and unsupervised learning for data science*, pp.3-21.
- Amani, F.A. and Fadlalla, A.M., 2017. Data mining applications in accounting: A review of the literature and organizing framework. *International Journal of Accounting Information Systems*, 24, pp.32-58.
- An, C.H., 2017. A study on sstimation of financial liquidity risk prediction model using financial analysis. *International Journal of Applied Engineering Research*, 12(20), pp.9919-9923.
- Ansari, A., Ahmad, I.S., Bakar, A.A. and Yaakub, M.R., 2020. A hybrid metaheuristic method in training artificial neural network for bankruptcy prediction. *IEEE Access*, 8, pp.176640-176650.
- Ansaria, Z., Hejazib, R., Zeraatkishc, Y. and Abadid, Z.K.M., 2021. Financial performance evaluation of companies using decision trees algorithm and multi-criteria decision-making techniques with an emphasis on investor's risk-taking behavior. *Advances in Mathematical Finance and Applications*, 6(3), pp.1-12.

- Barboza, F., Kimura, H. and Altman, E., 2017. Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, pp.405-417.
- Berry, M.W., Mohamed, A. and Yap, B.W. eds., 2020. Supervised and unsupervised learning for data science. Springer Nature.
- Bhat, G. and Ryan, S.G., 2015. The impact of risk modeling on the market perception of banks' estimated fair value gains and losses for financial instruments. *Accounting, Organizations and Society*, 46, pp.81-95.
- Bu, D., Kelly, S., Liao, Y. and Zhou, Q., 2018. A hybrid information approach to predict corporate credit risk. *Journal of Futures Markets*, 38(9), pp.1062-1078.
- Bushman, R.M., Davidson, R.H., Dey, A. and Smith, A., 2018. Bank CEO materialism: Risk controls, culture and tail risk. *Journal of Accounting and Economics*, 65(1), pp.191-220.
- Chalamandaris, G. and Vlachogiannakis, N.E., 2018. Are financial ratios relevant for trading credit risk? Evidence from the CDS market. *Annals of Operations Research*, 266(1), pp.395-440.
- Chen, N., Ribeiro, B. and Chen, A., 2016. Financial credit risk assessment: a recent review. *Artificial Intelligence Review*, 45(1), pp.1-23.
- Cohen, J., Krishnamoorthy, G. and Wright, A., 2017. Enterprise risk management and the financial reporting process: The experiences of audit committee members, CFO's, and external auditors. *Contemporary Accounting Research*, 34(2), pp.1178-1209.
- Committee of Sponsoring Organizations of the Treadway Commission (COSO), 2004. Enterprise risk management–integrated framework: Executive summary, pp. 1-16.
- Committee of Sponsoring Organizations of the Treadway Commission (COSO), 2013. COSO framework & SOX compliance: One approach to an effective transition, pp.1-8.
- Da Silva, I.N., Spatti, D.H., Flauzino, R.A., Liboni, L.H.B. and dos Reis Alves, S.F., 2017. Artificial neural network architectures and training processes. In *Artificial neural networks* (pp. 21-28). Springer, Cham.

- El Bouchti, A., Tribis, Y., Nahhal, T. and Okar, C., 2018, September. Forecasting financial risk using quantum neural networks. In *2018 Thirteenth International Conference on Digital Information Management (ICDIM)* (pp. 386-390). IEEE.
- Erika, A., Nardi, S., Leonardus, S. and A Kadim, K., 2018. The company's performance with the Du Pont system approach of stocks return and Its implications on company value of real estate and property sector listed in IDX. *International Journal of Applied Business and Economic Research (IJABER)*, 16(1), pp.29-40.
- Firoozye, N. and Ariff, F., 2016. Managing uncertainty, mitigating risk: Tackling the unknown in financial risk assessment and decision making. Springer, ISBN 978-1-349-56575-7, pp. 1 – 265.
- Florio, C. and Leoni, G., 2017. Enterprise risk management and firm performance: The Italian case. *The British Accounting Review*, 49(1), pp.56-74.
- Giovannoni, E., Quarchioni, S. and Riccaboni, A., 2016. The role of roles in risk management change: The case of an Italian bank. *European Accounting Review*, 25(1), pp.109-129.
- Guo, G., Hu, Y. and Fang, Y., 2020. Vanke Co., Ltd. financial risk analysis and countermeasures. In *2020 International Conference on Social Sciences and Big Data Application (ICSSBDA 2020)*, pp. 263-267.
- Hai, P.Q., Ngoc, T.T.L. and Phuong, B.D.T., 2018. An Alternate internal credit rating system for construction and timber industries using artificial neural network. In *International Econometric Conference of Vietnam* (pp. 752-791). Springer, Cham.
- Halim, Z., Shuhidan, S.M. and Sanusi, Z.M., 2021. Corporation financial distress prediction with deep learning: analysis of public listed companies in Malaysia. *Business Process Management Journal*. 27(4), pp. 1163-1178.
- Halteh, K., Kumar, K. and Gepp, A., 2018. Using cutting-edge tree-based stochastic models to predict credit risk. *Risks*, 6(2), pp.55 - 68.
- Hebb, D.O., 1949. The organization of behavior: a neuropsychological theory. J. Wiley; Chapman & Hall.
- Hillson, D., 2017. Managing risk in projects. *Routledge*.

- Hopkin, P., 2018. Fundamentals of risk management: understanding, evaluating and implementing effective risk management. 5<sup>th</sup> Edition. *Kogan Page Publishers*.
- Huang, X., Liu, X. and Ren, Y., 2018. Enterprise credit risk evaluation based on neural network algorithm. *Cognitive Systems Research*, 52, pp.317-324.
- Hull, J., 2018. Risk management and financial institutions, *Fifth Edition*. John Wiley & Sons.
- Ibrahim, A.E.A. and Hussainey, K., 2019. Developing the narrative risk disclosure measurement. *International Review of Financial Analysis*, 64, pp.126-144.
- Islami, I.N. and Rio, W., 2019. Financial ratio analysis to predict financial distress on property and real estate company listed in Indonesia stock exchange. *JAAF (Journal of Applied Accounting and Finance)*, 2(2), pp.125-137.
- Jaki, A. and Ćwięk, W., 2021. Bankruptcy prediction models based on value measures. *Journal of Risk and Financial Management*, 14(1), p.6.
- Jin, M., Wang, Y. and Zeng, Y., 2018. Application of data mining technology in financial risk analysis. *Wireless Personal Communications*, 102(4), pp.3699-3713.
- Kapanova, K.G., Dimov, I. and Sellier, J.M., 2018. A genetic approach to automatic neural network architecture optimization. *Neural Computing and Applications*, 29(5), pp.1481-1492.
- Khalil, K., Eldash, O., Kumar, A. and Bayoumi, M., 2018. An efficient approach for neural network architecture. In *2018 25th IEEE International Conference on Electronics, Circuits and Systems (ICECS)* (pp. 745-748). IEEE.
- Khemakhem, S. and Boujelbene, Y., 2018. Predicting credit risk on the basis of financial and non-financial variables and data mining. *Review of Accounting and Finance*, 17(3), pp. 316-340.
- Khemakhem, S., and Boujelbene, Y., 2017. Artificial intelligence for credit risk assessment: Artificial neural network and support vector machines. *ACRN Oxford Journal of Finance and Risk Perspectives*, 6(2), pp.1-17.

- Kitagawa, N. and Shuto, A., 2021. Management earnings forecasts and the cost of debt. *Journal of Accounting, Auditing & Finance*, 36(3), pp.585-612.
- Kluza, K., 2017. Risk assessment of the local government sector based on the ratio analysis and the DEA method. Evidence from Poland. *Eurasian Economic Review*, 7(3), pp.329-351.
- Kokobe, S.A. and Gemechu, D., 2016. Risk management techniques and financial performance of insurance companies. *International Journal of Accounting Research*, 4(1), p.127 - 131.
- Lahmiri, S., 2017. Modeling and predicting historical volatility in exchange rate markets. *Physica A: Statistical Mechanics and its Applications*, 471, pp.387-395.
- Li, J.P., Mirza, N., Rahat, B. and Xiong, D., 2020. Machine learning and credit ratings prediction in the age of fourth industrial revolution. *Technological Forecasting and Social Change*, 161, p.120309.
- Liang, L. and Cai, X., 2020. Forecasting peer-to-peer platform default rate with LSTM neural network. *Electronic Commerce Research and Applications*, 43, p.100997.
- Lomakin, N.I., Popov, I.A., Shohneh, A.B., Maramygin, M.C. and Gorbunova, A.B., 2020, March. AI-System of stock exchange trading robot for financial risk hedging. In *International Scientific Conference "Far East Con" (ISCFEC 2020)*, pp. 3273-3282.
- Mall, S., Panigrahi, T.R. and Thomas, S., 2019. Predicting financial solvency of commercial borrowers: The case of non-banking financial companies. *Accounting and Finance Research*, 8(3), pp. 61-71.
- Martín, G.R., 2019. European valuation multiples: the investors' sentiment about size. *Cuadernos de Economía*, 42(119), pp.173-188.
- Meidell, A. and Kaarboe, K., 2017. How the enterprise risk management function influences decision-making in the organization—A field study of a large, global oil and gas company. *The British Accounting Review*, 49(1), pp.39-55.
- Namazi, M., Shokrolahi, A. and Maharluie, M.S., 2016. Detecting and ranking cash flow risk factors via artificial neural networks technique. *Journal of Business Research*, 69(5), pp.1801-1806.

- Olson, D.L. and Wu, D.D., 2017. Enterprise risk management models. Springer Berlin Heidelberg.
- Omar, N., Johari, Z.A. and Smith, M., 2017. Predicting fraudulent financial reporting using artificial neural network. *Journal of Financial Crime*, 24(2), pp.362-387.
- Paulinus, E.C. and Jones, A.S., 2017. Financial risk management and corporate performance of deposit money banks in Nigeria. *Archives of Business Research*, 5(12). pp. 78 – 87.
- Qammar, R., Ibrahim, Y. and Alam, M.M., 2017. Dividend policy and price volatility: Theory vs practice. *Journal of Advanced Review on Scientific Research*, 35(1), pp.13-23.
- Raza, H., Gillani, S.M.A.H., Ramakrishnan, S., Gillani, S.M.A.H. and Imran, M., 2020. Non-systematic review of financial sustainability and financial distress. *International Journal of Psychosocial Rehabilitation*, 24(06), pp.885-900.
- Ruppert, D. and Matteson, D. S., 2016. Statistics and data analysis for financial engineering, second edition, New York, Springer, ISBN 978-1-4939-2613-8, pp.1-719.
- Sarkar, S.K., Oshiba, K., Giebisch, D. and Singer, Y., 2018. Robust classification of financial risk. *arXiv preprint arXiv:1811.11079*.
- Setiany, E., 2021. The effect of investment, free cash flow, earnings management, and interest coverage ratio on financial distress. *Journal of Social Science*, 2(1), pp.67-73.
- Sezer, O.B., Gudelek, M.U. and Ozbayoglu, A.M., 2020. Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, p.106181.
- Silva, W., Kimura, H. and Sobreiro, V.A., 2017. An analysis of the literature on systemic financial risk: A survey. *Journal of Financial Stability*, 28, pp.91-114.
- Singh, J. and Banerjee, R., 2019. A study on single and multi-layer perceptron neural network. In *2019 3rd International Conference on Computing Methodologies and Communication (ICCMC)* (pp. 35-40). IEEE.

- Son, Y., Byun, H. and Lee, J., 2016. Nonparametric machine learning models for predicting the credit default swaps: An empirical study. *Expert Systems with Applications*, 58, pp.210-220.
- Stulz, R.M., 2015. Risk taking and risk management by banks. *Journal of Applied Corporate Finance*, 27(1), pp.8-18.
- Tavana, M., Abtahi, A.R., Di Caprio, D. and Poortarigh, M., 2018. An artificial neural network and Bayesian network model for liquidity risk assessment in banking. *Neurocomputing*, 275, pp.2525-2554.
- Tokarski, A. and Manikowska, E., 2017. Polish early warning systems in predicting risk of bankruptcy Ff Wawel SA in the years 2013-2015. *Torun Business Review*, 16(1), pp.19-36.
- Uğurlu, M. and Sevim, Ş., 2015. Artificial neural network methodology in fraud risk prediction on financial statements; An empirical study in banking sector. *İşletme Araştırmaları Dergisi*, 7(1), pp.60-89.
- Valaskova, K., Durana, P., Adamko, P. and Jaros, J., 2020. Financial compass for Slovak enterprises: modeling economic stability of agricultural entities. *Journal of Risk and Financial management*, 13(5), p.92.
- Valaskova, K., Kliestik, T. and Kovacova, M., 2018. Management of financial risks in Slovak enterprises using regression analysis. *Oeconomia Copernicana*, 9(1), pp.105-121.
- Wang, L., Yan, C., Li, Y., Liu, W. and Li, M., 2017. Financial risk analytics based on radial basis function neural network. In *2017 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)* (pp. 2897-2903). IEEE.
- Wójcicka, A., 2018. Credit-risk decision process using neural networks in industrial sectors. In *Contemporary Trends in Accounting, Finance and Financial Institutions*, pp. 71-81. Springer, Cham.
- Woo, S.H., Kwon, M.S. and Yuen, K.F., 2021. Financial determinants of credit risk in the logistics and shipping industries. *Maritime Economics & Logistics*, 23(2), pp.268-290.
- Xin, R., Zhang, J. and Shao, Y., 2020. Complex network classification with convolutional neural network. *Tsinghua Science and technology*, 25(4), pp.447-457.

- Yamin, S. and Gulzar, S., 2020. Multiples and stock price, new approach for relative valuation through neural network. *The Singapore Economic Review*, pp.1-19.
- Yang, Y. and Yang, C., 2020. Research on the application of GA improved neural network in the prediction of financial crisis. In *2020 12th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA)* (pp. 625-629). IEEE.
- Yuriy, T., 2020. The analysis of financial stability and profitability of British Petroleum (bp) for the period 2014-2019. *Review of Business and Economics Studies*, (1), pp.27-33.
- Zeng, G., 2020. On the confusion matrix in credit scoring and its analytical properties. *Communications in Statistics-Theory and Methods*, 49(9), pp.2080-2093.
- Zhu, Y., Xie, C., Sun, B., Wang, G.J. and Yan, X.G., 2016. Predicting China's SME credit risk in supply chain financing by logistic regression, artificial neural network and hybrid models. *Sustainability*, 8(5), pp.433- 450.
- Zhu, Y., Zhou, L., Xie, C., Wang, G.J. and Nguyen, T.V., 2019. Forecasting SMEs' credit risk in supply chain finance with an enhanced hybrid ensemble machine learning approach. *International Journal of Production Economics*, 211, pp.22-33.