

استخدام الشبكات العصبية الاصطناعية للتنبؤ بالتعثر المالي للشركات المصرية المساهمة الصغيرة والمتوسطة (دراسة تطبيقية)

أ.م.د/ تامر محمد حسن شهوان
أستاذ إدارة الأعمال المساعد
كلية التجارة - جامعة الزقازيق

أ.د/ محمد غمري الشوافي
أستاذ إدارة الأعمال
وعميد كلية التجارة السابق - جامعة الزقازيق

أ. ميسره احمد فاضل
مدرس مساعد - إدارة الأعمال
معهد الدلتا العالي للحاسبات والعلوم الادارية

ملخص البحث تهدف هذه الدراسة للوصول إلى نموذج للتنبؤ بالتعثر المالي للشركات المساهمة الصغيرة والمتوسطة باستخدام النسب المالية المشتقة من القوائم المالية للشركات والتي تعكس الربحية والسيولة والسلامة المالية ، ومن ناحية أخرى ، تم إجراء مقارنة بين نماذج الانحدار اللوجستي Logistic Regression والشبكات العصبية الاصطناعية Artificial Neural Network ونموذج التمان ٢٠١٦ المعدل ، كأحد نماذج التنبؤ الرائدة والشائع استخدامها بالدراسات البحثية السابقة ، لتحديد مدى التحسن في أداء نموذج التنبؤ بالتعثر المالي ، بالنسبة لمساهمة للنسب المالية ، في ضوء نتائج الدراسة ، يصف نموذج التنبؤ الذي يجمع بين نسب الربحية : (العائد على رأس المال المستثمر ، هامش الربح التشغيلي) ، ونسب السيولة : (صافي رأس المال العامل) وكذلك نسبة السلامة المالية (صافي التدفق النقدي لإجمالي الالتزامات المالية) بشكل أفضل احتمال حدوث التعثر المالي للشركات الصغيرة والمتوسطة المصرية. وفقاً لنتائج قياس أداء نماذج الانحدار اللوجستي LR والشبكات العصبية الاصطناعية ANNs ونموذج التمان ٢٠١٦ المعدل ، تتفوق الشبكات العصبية الاصطناعية المتعددة الطبقات على النماذج الأخرى وتحسن أداء نموذج التنبؤ خلال فترات التنبؤ كاملة ، كما تتميز باستقرار أدائها على المدى البعيد (قبل حدث التعثر بمدة عامين). نتائج استخدام عينة الاختبار ومقاييس الأداء تؤكد النتائج التي توصلت إليها الدراسة.

أولاً: تمهيد

تعد مشكلة قياس المخاطر الائتمانية بقطاع البنوك وكذلك جهات التمويل الأخرى ذات أهمية لما لها من تأثير جوهري على ربحية تلك المؤسسات واستمرارها ، فضلاً عن المخاطر الأخرى التي تواجه هذه القطاعات وذلك لارتباطهما بعدم توافر البيانات الكاملة الجيدة للتقييم الشامل لحجم المخاطر الفعلية للمقترضين وعدم القدرة على التنبؤ بشكل كفاء بخطر الائتمان في فترات مستقبلية تجنباً للخسائر وحوادث الأزمات نظراً لعدم توافر المخصصات الكافية لتلك المخاطر (Loeffler and Posch, 2011) ، حيث أعلن البنك المركزي المصري في تقريره لعام ٢٠١٣م أن القروض المتعثرة في البنوك العاملة بالسوق المحلية ارتفعت بنهاية شهر مارس لتسجل ٥٢ مليار جنيه مقابل ٥٠.٧ مليار جنيه بنهاية شهر ديسمبر من العام السابق بزيادة بلغت قيمتها ١.٣ مليار جنيه خلال ثلاثة أشهر ، كما أنه أصبحت قيمة القروض المتعثرة في نهاية شهر يونيو لعام ٢٠١٦م ٥٥.٢ مليار جنيه أي بلغت قيمة الزيادة ٣.٤ مليار جنيه من القيمة الاجمالية للقروض التي بلغت ٩٣٧ مليار جنيه ، مما يشير إلى تزايد حجم القروض المتعثرة عام تلو الآخر ، حيث تكمن المشكلة في التوسع غير المدروس للائتمان نتيجة لغياب نظام ائتماني فعال يمكن من خلاله التنبؤ بخطر التعثر المالي. حيث اعتمدت معظم الدراسات السابقة في بناء نماذج التنبؤ على عينة بيانات تغطي فترة زمنية محددة وأيضاً نماذج إحصائية تقليدية ومع مرور الوقت تصبح هذه النماذج غير قادرة على التنبؤ بالتعثر المالي بشكل فعال حيث يصبح أداء هذه النماذج غير مستقر وينعكس عدم الاستقرار في معدلات الخطأ (النوع

الأول والثاني) نتيجة لتغير معاملات النماذج وفقاً لتغيرات البيئة الاقتصادية أو التغيرات التي تطرأ على البيئة التشغيلية للشركات (Mensah, 1984)، ومن ناحية أخرى اختلاف طبيعة التعثر المالي مع التغيرات التي تحدث بالبيئة الاقتصادية من فترة زمنية لأخرى، أي أنه مع مرور الوقت تصبح المقاييس المستخدمة بنماذج التنبؤ بالتعثر المالي غير قادرة على التنبؤ حيث تصبح معدلات خطأ النموذج غير مقبولة (Sun and Li, 2010). كما أن تنوع أشكال الاستثمار والتطورات العالمية المتلاحقة تتسبب في تغيرات تطرأ على حاجة متخذي القرار من مستثمرين ومسؤولي الائتمان وإدارات الشركات، الأمر الذي يشير إلى ضرورة التطوير المستمر لنماذج التنبؤ بخطر التعثر المالي حيث يجب بناء نموذج التنبؤ بالتعثر المالي خلال فترة زمنية قريبة من تلك الفترة التي يستخدم فيها النموذج (Kasey and Watson, 1991). وبعد ذلك التطوير باستخدام تقنيات الذكاء الاصطناعي (الشبكات العصبية) التي تغلب على مشكلة فرض تماثل توزيع البيانات محل التنبؤ كما هو الحال بالأساليب الإحصائية التقليدية والتي لا تستطيع التعامل إلا مع عدد محدود من المتغيرات وبالتالي استبعاد بعض البيانات والمعلومات المرتبطة بظاهرة التعثر المالي، ومن ناحية أخرى الاعتماد على مجموعة من المتغيرات التي تعكس صورة أشمل لأنواع المخاطر التي تشكل مصادر للتعثر المالي للشركات والتي تساعد على تحسين عملية التنبؤ بمخاطر الائتمان لتفادي الخسائر التي تحمّلها الدولة والمجتمع والناجمة عن التعثر المالي للشركات.

ثانياً: الدراسات البحثية السابقة

اعتمدت معظم الدراسات البحثية السابقة في اختيار النسب المالية التي استخدمتها كمتغيرات للتنبؤ بالتعثر المالي للشركات، على أساس أكثر النسب المالية ذات دلالة إحصائية معنوية بالدراسات السابقة لها وأيضاً على أساس نظري مثل دراسة (Beaver, 1966) والتي اعتمدت في اختيار بعض النسب على أساس نظرية التدفقات النقدية حيث تعكس النسب المالية: الربحية، السيولة، درجة الرفع المالي والسلامة المالية.

أظهرت نتائج الدراسات (Modina and Pietrovito, 2014; Wolter and Rosch, 2014; Ciampi and Gordini, 2013) التي ركزت على التنبؤ بالتعثر المالي للشركات الصغيرة والمتوسطة أنه تتميز نسب الديون والسلامة المالية بالقدرة على التنبؤ بالتعثر المالي لفترات زمنية طويلة المدى، حيث أنها تمثل فرق معنوي بين الشركات المتعثرة والشركات غير المتعثرة لفترات زمنية تتعدى الثلاثة سنوات السابقة لحدث التعثر، بينما توصلت بعض الدراسات مثل (Alifiah, 2013; Ciampi and Gordini, 2013; Alifiah, 2013; Hu, 2011) والتي ركزت أيضاً على التنبؤ بالتعثر المالي للشركات الصغيرة والمتوسطة والتي تعمل في مجال التجزئة والصناعة والخدمات مستبعد منها الشركات المالية، إلى أنه يحدث تدهور ملحوظ في نسب السيولة بالعامين السابقين فقط لحدث التعثر، حيث لا يوجد فرق معنوي لهذه النسب بين الشركات المتعثرة والغير متعثرة قبل العامين السابقين لحدث التعثر، كما أنه يتغير توزيع المشاهدات لهذه النسب أيضاً.

كما تجدر الإشارة إلى أنه أكدت بعض الدراسات البحثية السابقة ابتداء من دراسة (Beaver, 1966) والعديد من الدراسات اللاحقة لها مثل (Bhimani, Gulamhussen and Lopes, 2013; Ciampi and Gordini, 2013; Tinoco and Wilson, 2013) توصلت إلى أنه تحقق نسبة التدفق النقدي إلى إجمالي الديون والتي تعكس السلامة المالية للشركات فرق معنوي بين الشركات المتعثرة والغير متعثرة مالياً بعينة الاختبار قبل حدث التعثر بمدة تصل إلى خمس سنوات، في حين كانت نسبة السيولة (الأصول المتداولة إلى الخصوم المتداولة) تحقق فرق

معنوي بين الشركات المتعثرة والغير متعثرة قبل حدث التعثر بمدة عام أو عامين على الأكثر ، وقد يرجع ذلك إلى أن نسب السلامة المالية تقيس قدرة الشركة على سداد الالتزامات المالية طويلة الأجل بالإضافة لاستقرار توزيع المشاهدات لها لفترات زمنية طويلة ، بينما تعكس نسب السيولة قدرة الشركة على أداء الالتزامات قصيرة الأجل ، كما يحدث تدهور لهذه النسب قبل حدوث التعثر بعام أو عامين على الأكثر.

ومن ناحية أخرى في دراسة (Figini, Savona and Vezzoli, 2016; Charalambakis, 2015; Ciampi, 2014) تم استخدام نسب الربحية، مثل: (العائد على الأصول ، والعائد على رأس المال المستثمر) والتي تعكس قدرة الشركة على تحقيق الأرباح خلال فترة زمنية محددة، وأظهرت نتائج الدراسات أنه تساعد نسب الربحية على التصنيف والتنبؤ بالشركات المتعثرة لمدة تصل إلى خمسة أعوام قبل حدث التعثر، كما تجدر الإشارة إلى أنه قد يكون نموذج التنبؤ ذو متغير واحد (نسبة مالية واحدة) يحقق مستوى دقة للتنبؤ أعلى من نموذج آخر يحتوي على عدد من المتغيرات (مجموعة من النسب المالية)، على سبيل المثال في دراسة (Shumway, 2001) حققت نسبة صافي الدخل إلى إجمالي الأصول أعلى مستوى دقة للتنبؤ بالإفلاس عند مقارنتها بالنماذج الأخرى ومن بينها نموذج (Zmijewski, 1984) ، ونموذج الخطر باستخدام متغيرات Zmijewski .

تعد الشبكات العصبية الاصطناعية أحد البدائل الأكثر أهمية لطرق التحليل المتعدد المتغيرات ، مثل التحليل التمييزي والانحدار اللوجستي ، نظراً لقدرتها على إيجاد العلاقات المعقدة بين المتغيرات المستخدمة للتنبؤ ، والتغلب على مشاكل الانحدار ، وشروط التوزيع والعلاقات غير الخطية التي تواجه هذه الأساليب. قارن (Odam and Sharda, 1990) بين كل من نموذج الشبكة العصبية ذات الانتشار الخلفي Back-Propagation Neural Nets ونموذج التحليل التمييزي المتعدد MDA ، باستخدام متغيرات نفس نموذج Altman Z-Score ، حيث استخدمت نفس عينة التدريب وأظهرت نتائج الدراسة أن نموذج التنبؤ باستخدام الشبكات العصبية BPNN يحقق معدل خطأ من النوع الأول (تصنيف الشركات المتعثرة ماليا كشركات غير متعثرة) أقل من نموذج التحليل التمييزي MDA ، وتكلفة خطأ منخفضة نسبياً مقارنةً بالتحليل التمييزي. كما استخدمت دراسة (Lee and Choi, 2012) نفس التقنيات للتنبؤ بالشركات الكورية المشطوبة من سوق التداول وأظهرت النتائج أن نماذج الشبكات العصبية ذات الانتشار الخلفي BPNN تتفوق على نماذج التحليل التمييزي MDA وتحقق معدل خطأ أقل من النوع الأول. كما استخدمت دراسة (Gordini and Ciampi, 2013) كلا من الشبكات العصبية ذات الانتشار الخلفي BPNN والانحدار اللوجستي LR والتحليل التمييزي MDA لبناء نموذج للتنبؤ بالتعثر المالي للشركات الصغيرة في إيطاليا ، وأظهرت النتائج أن نموذج الشبكات العصبية BPNN كان متفوقاً على كل من الانحدار اللوجستي LR والتحليل التمييزي MDA. ومع ذلك ، كانت الدقة التنبؤية لنموذج الانحدار اللوجستي أقرب إلى مستوى دقة التنبؤ لنموذج الشبكات العصبية BPNN ، حيث يحقق نموذج الانحدار اللوجستي خطأ النوع الأول أقل من نموذج التحليل التمييزي. بينما أظهرت نتائج (Peat and Jones, 2012) أن الشبكات العصبية ذات خاصية الانتشار الخلفي BPNN تحقق أيضاً مستوى دقة للتنبؤ أعلى من نماذج الانحدار اللوجستي. في ضوء ما سبق يمكن استنتاج أن نماذج الشبكات العصبية الاصطناعية ANN لديها ميزة هامة تتمثل في انخفاض تكلفة الخطأ مقارنة بتقنيات التصنيف والتنبؤ الأخرى. تهدف هذه الدراسة إلى تقييم مساهمة النسب المالية ، من أجل التنبؤ بالصافي المالية للشركات ، ودراسة ما إذا كان الشبكات العصبية ذات خاصية الانتشار الخلفي MLP-BPNN تحقق تحسن

في مستوى دقة التنبؤ للنموذج أم لا، مقارنةً بنماذج التحليل متعدد المتغيرات ممثلاً في الانحدار اللوجستي LR. في ضوء ما تم عرضه من الدراسات البحثية السابقة تسعى هذه الدراسة إلى الإجابة على التساؤلات البحثية التالية:

- هل توجد فروق معنوية بالنسب المالية (الربحية، السيولة، السلامة المالية) بين الشركات الصغيرة والمتوسطة المتعثرة والشركات غير المتعثرة مالياً؟
- هل يحقق استخدام الشبكات العصبية تحسن معنوي في أداء نموذج التنبؤ بالتعثر المالي للشركات الصغيرة والمتوسطة مقارنة الانحدار اللوجستي ونموذج التمان ٢٠١٦ المعدل؟

ثالثاً : عينة الدراسة

تمثل عينة الدراسة الشركات المساهمة الصغيرة والمتوسطة المدرجة بالبورصة المصرية وفقاً لتعريف الهيئة العامة للرقابة المالية (الشركات المساهمة الصغيرة التي لا يقل رأس مالها المصدر والمدفوع عن مليون جنيه. ويقل رأس مالها المصدر والمدفوع عن خمسين مليون جنيه أو ما يعادلها من العملات الأجنبية، والشركات المساهمة المتوسطة لا يزيد رأس مالها المصدر عن ١٠٠ مليون جنيه أو ما يعادلها من العملات الأجنبية)، مستبعد منها شركات التأمين والسمسرة والخدمات المالية نظراً لاختلاف طبيعة النسب المالية لهذه الشركات عن الشركات عينة الدراسة، حيث تم اختيار الشركات عينة الدراسة كالتالي :

٩٦	عدد الشركات المساهمة الصغيرة والمتوسطة المدرجة بالبورصة
١٦	(-) مستبعد منها شركات التأمين والسمسرة والخدمات المالية
١٤	(-) الشركات التي لا تتوافر بها شروط اختيار العينة
٦٦	عدد الشركات عينة الدراسة

تم اختيار عينة عشوائية طبقية مقسمة وفقاً لنوع النشاط وحجم الأصول، وتحتوي عينة الدراسة على مجموعتين من الشركات: (المجموعة الأولى) الشركات الغير متعثرة مالياً بمتوسط قيمة الأصول (١٢٤.٩٦٥.٣١٦) جنيهاً وتشمل بيانات تغطي نفس الفترة للشركات المتعثرة مالياً (المجموعة الثانية) بمتوسط قيمة الأصول (٩٤.٢٢٣.٣٥٦) جنيهاً والتي تتوافر بها شروط حالة التعثر في الفترة (٢٠١٥-٢٠١٦)، حيث تم الأخذ في الاعتبار عند اختيار مجموعتي الشركات عينة الدراسة أن تكون متجانسة بقدر المستطاع، وتمثل نسبة الشركات المتعثرة مالياً إلى الشركات الغير متعثرة بعينة الدراسة ٤٤٪ حيث تمثل عدد الشركات المتعثرة ٢٩ شركة بينما عدد الشركات غير المتعثرة مالياً ٣٧ شركة، كما يعرض الجدول (١) وصف لعينة الدراسة ونسبة الشركات بكل مجموعة من عينة الدراسة وفقاً لنوع النشاط.

وفي ضوء أهداف الدراسة تم تقسيم العينة الإجمالية إلى عينة التدريب والتقدير Estimation Sample بنسبة (٧٠٪ من إجمالي العينة) حيث تستخدم في بناء النموذج وتقدير معاملاته، وعينة الاختبار Validation Sample والتي تمثل نسبة (٣٠٪ من إجمالي بيانات عينة الدراسة) بغرض اختبار نماذج الدراسة وقياس أدائها.

يصف الجدول (١) الشركات عينة الدراسة من حيث نوع النشاط وفقاً لتصنيف النشاط المستخدم بالبورصة المصرية، حيث تنقسم الشركات عينة الدراسة إلى خمسة أنواع (رعاية صحية، خدمات، تجزئة، تشييد وبناء، تصنيع).

جدول (١) وصف عينة الدراسة (نوع النشاط)

النشاط	الشركات	الشركات المتعثرة		الشركات الغير متعثرة	
		العدد	النسبة (%)	العدد	النسبة (%)
رعاية صحية	٥	١٧,٢	١٧,٢	٧	١٨,٩
خدمات	٤	١٣,٨	٣١	٣	٨,١
تجزئة	٢	٦,٩	٣٧,٩	٢	٥,٤
تشبيد وبناء	٦	٢٠,٦	٥٨,٥	٨	٢١,٦
تصنيع	١٢	٤١,٤	١٠٠	١٧	٤٥,٩
الاجمالي	٢٩	%١٠٠		٣٧	%١٠٠

رابعا : منهجية البحث

في هذه الدراسة تم استخدام النسب المالية المشتقة من القوائم المالية للشركات (قائمة المركز المالي، الدخل والتدفقات النقدية) والتي تعكس (الربحية، السيولة، السلامة المالية) للتنبؤ بالتعثر المالي للشركات المساهمة المصرية الصغيرة والمتوسطة بالاعتماد على كلا من : التحليل متعدد المتغيرات باستخدام الانحدار اللوجستي وأحد تقنيات الذكاء الاصطناعي (الشبكات العصبية الاصطناعية) لبناء نماذج التنبؤ بالتعثر المالي. كما يتم التنبؤ باحتمال التعثر المالي خلال فترتين وهما (ت-١، ت-٢) ، أي قبل عام أو عامين من حدث التعثر، بالإضافة إلى ذلك ، مقارنة الأداء بين نموذج الانحدار اللوجستي ونموذج الشبكات العصبية ومن الناحية الأخرى تطبيق نموذج التمان ٢٠١٦ المعدل على عينة الاختبار ومقارنة أدائه بنماذج الدراسة بغرض تحديد مدى التحسن في أداء نموذج التنبؤ بالتعثر المالي.

١- الأساليب المستخدمة في بناء نماذج الدراسة وتقدير معاملاتها

في ضوء ما تم عرضه من الدراسات البحثية السابقة ، يعتبر الانحدار اللوجستي (LR) أكثر الأساليب المستخدمة في بناء نماذج التنبؤ بالتعثر المالي، وفيما يلي عرض لكل منهما:

٢/١- الانحدار اللوجستي Logistic Regression

تقوم فكرة دالة الانحدار اللوجستي على تعظيم نسبة الامكان ، ويتغلب الانحدار اللوجستي على مشكلة عدم توافر شرط التوزيع الطبيعي للبيانات من خلال الحصول على اللوغاريتم الطبيعي لنسبة الامكان Logged odds بدلا من قيمة احتمال الحدوث بشكل مباشر حيث يحول منحنى الانحدار الخطي المستقيم إلى منحنى انحدار غير خطي يأخذ شكل حرف (S)، وفيما يلي دالة الانحدار اللوجستي:

$$p_i = \frac{1}{1 + e^{-(b_0 + b_1x_1 + \dots + b_nx_n)}} \quad (١) \text{ : المعادلة رقم}$$

حيث أن:

(p_i) احتمال التعثر المالي للشركة (i) ، معاملات الارتباط لدالة الانحدار.

(x_n) : قيمة الملاحظة للمتغير (X) للشركة (i) .

٢- أساليب تقييم الأداء لنماذج الدراسة

تم استخدام أربعة أساليب كمقاييس للأداء لنماذج الدراسة حتى يتم مقارنتها في ضوء هذه المقاييس لتحديد أي النماذج يحقق أفضل أداء باستخدام عينة الاختبار ، والذي ينعكس في قدرة النموذج على التمييز بين مجموعة الشركات المتعثرة والغير متعثرة ماليا بعينة الدراسة ، وعادة تستخدم هذه الأساليب مجتمعة معا وليس بمعزل عن بعضهم البعض كما جاء بالدراسات البحثية السابقة ، وتشمل الأساليب التالية:

- مقياس (ف) F-measure

يُصنف مقياس (ف) - أيضا يسمى بمقياس الكفاءة Effectiveness Measure - أداء النموذج لتصنيف الشركات في المدى بين حساسية النموذج ومعدل التنبؤ الإيجابي الصحيح ، ويتميز مقياس (ف) بأنه يجمع بين قياس معدل التنبؤ الإيجابي الصحيح للنموذج وحساسية النموذج (Chen, 2011) ، حيث أن معدل التنبؤ الإيجابي الصحيح يعكس النسبة الصحيحة للشركات التي تم تصنيفها كشركات متعثرة من إجمالي الشركات التي تم تصنيفها كشركات متعثرة باستخدام النموذج ، ويستخدم مقياس (ف) في تقييم الأداء العام للنموذج في التنبؤ بالشركات المتعثرة ، حيث يتم حسابه كما يلي:

$$\text{مقياس (ف)} = 2 * (\text{معدل التنبؤ الإيجابي الصحيح}) * (\text{نسبة حساسية النموذج})$$

$$\text{المعادلة رقم (٢)} \quad (\text{معدل التنبؤ الإيجابي الصحيح} + \text{نسبة حساسية النموذج})$$

حيث أنه : كلما اقتربت قيمة (ف) من الواحد الصحيح كلما دل ذلك على قدرة النموذج على تصنيف الشركات المتعثرة.

- منحنيات الأداء (المساحة أسفل المنحني Area under curve):

هي عبارة عن قياس مصور لأداء النموذج حيث يقيس قدرة النموذج على التمييز بين مجموعتي الشركات المتعثرة وغير المتعثرة ، كلما زادت المساحة أسفل المنحني كلما كان ذلك مؤشر جيد لأداء النموذج المستخدم حيث تتراوح قيمة المساحة أسفل المنحني (AUC) بين الصفر والواحد الصحيح فكلما اقتربت من الواحد الصحيح كلما كان مؤشر جيد لأداء النموذج ، وبالرغم من أنه يمثل أحد أدوات القياس المفيدة لقدرة النماذج على التمييز إلا أنه قياس يعكس بعد واحد فقط لقدرة النموذج على التمييز. حيث ذكرت دراسة (Altman et al. 2016) أنه يحقق النموذج أداء مقبول عندما تكون قيمة المساحة أسفل المنحني (AUC) ما بين (٠.٥٠) و (١.٠).

معامل ارتباط جيني Gini-Rank Coefficient

يتشابه هذا الأسلوب إلى حد كبير مع أسلوب (المساحة أسفل المنحني AUC) حيث يختلف عنه في أنه يحسب فقط المساحة بين المنحني والخط القطري المائل Diagonal Line والذي يسمى بمنحني لورينز Lorenz Curve ، حيث أن أسلوب المساحة أسفل المنحني (AUC) يقوم على حساب المساحة بالكامل ، ويكون الأداء مقبول عندما يساوي معامل ارتباط جيني (٠.٥٠) أو أعلى ، وفي حالة انخفاض قيمته عن (٠.٥٠) يشير ذلك إلى أن النموذج لا يحقق أداء مقبول حيث لا يستطيع التمييز بين الشركات المتعثرة وغير متعثرة مالياً، ويحسب معامل ارتباط جيني من خلال المعادلة التالية:

$$\text{المعادلة رقم (٣)} : \text{Gini Rank Coefficient} = (2 * \text{AUC}) - 1$$

حيث تتراوح قيمته ما بين الصفر والواحد الصحيح، فكلما اقتربت قيمة معامل جيني من الواحد الصحيح كلما كان أداء النموذج جيد.

- كولموجوروف سميرنوف Kolomogorv Samirnov z:

يستخدم هذا الأسلوب لاختبار مدى حسن المطابقة Goodness-of-fit بمعنى أن النموذج المستخدم يحتوي على المتغيرات التي تمثل الخصائص المختلفة بين المجموعتين أم لا، ويتم ذلك من خلال إيجاد الفروق المعنوية بين منحنى التوزيع الاحتمالي التراكمي بين عينتين أو مجموعتين من حيث شكل ومكان منحنى كل مجموعة ، وفقا لهذا الأسلوب كلما زادت قيمة زد (Z) وكانت ذات دلالة إحصائية معنوية كان ذلك مؤشرا جيدا لأداء النموذج المستخدم في التمييز بين مجموعتي الشركات عينة الدراسة ، وفي حالة انخفاض قيمة (Z) ووجود دلالة إحصائية غير معنوية يكون ذلك مؤشر لانخفاض أداء النموذج وعدم قدرته على التمييز بين مجموعتي الشركات عينة الدراسة.

٣- متغيرات الدراسة وطرق قياسها

٣/١- المتغيرات المستقلة :

تتكون المتغيرات المستقلة المستخدمة في التنبؤ من مجموعة من النسب المالية تم اختيارها بالاعتماد على أدائها في الدراسات البحثية السابقة ذات الصلة بالتنبؤ بالتعثر المالي، وكذلك قدرتها على وصف النواحي الأساسية للأداء المالي والتشغيلي للشركة مثل (الربحية، السيولة، النشاط، الديون) وفي حدود البيانات المتاحة بالتقارير والقوائم المالية للشركات عينة الدراسة. ويعرض الجدول (٢) المتغيرات المستقلة التي تم اختيارها في ضوء الدراسات السابقة وطريقة قياسها ومدلولاتها:

جدول (٢) المتغيرات المستخدمة بالدراسة

المتغيرات	طريقة القياس	المدلول
نسبة الرفع المالي	إجمالي الخصوم / إجمالي الأصول	الديون
العائد على الأصول	صافي الدخل / إجمالي قيمة الأصول	
العائد على حقوق الملكية	صافي الدخل / حقوق الملكية	
العائد على رأس المال المستثمر	صافي الدخل / (الأصول الثابتة + صافي رأس المال العامل)	الربحية
هامش الربح التشغيلي	الربح قبل الفوائد والضرائب / المبيعات	
هامش الربح الإجمالي	مجموع الربح / المبيعات	
صافي التدفق النقدي لإجمالي الالتزامات المالية	صافي التدفق النقدي / إجمالي الالتزامات المالية	السلامة المالية
صافي التدفق النقدي للخصوم المتداولة	صافي التدفق النقدي / الخصوم المتداولة	
رأس المال العامل	(الأصول المتداولة - الخصوم المتداولة) / إجمالي الأصول	السيولة
نسبة السيولة السريعة	(الأصول المتداولة - المخزون) / الخصوم المتداولة	

المصدر: من إعداد الباحث بالاعتماد على نتائج الدراسات البحثية السابقة.

- معيار حدث التعثر (المتغير التابع):

نظراً للارتباطات التي وجهت لاستخدام الإفلاس كمعيار لتحديد الحالة المالية أو الفنية التي تقع فيها الشركة (Jantaej, 2006)، حيث أشارت دراسة (Shumway, 2001) إلى أنه قد تواجه الشركات الخطر المالي للعديد من السنوات قبل الإفلاس وقد تقلس بعد أول عام من مواجهة المخاطر المالية، كذلك (Agostini, 2018) التي أشارت إلى أنه قد تواجه الشركات العديد من الصعوبات المالية ولا تستطيع الوفاء بالتزاماتها المالية ولكن لا يؤدي ذلك حتماً للإفلاس، لذلك أصبح الاهتمام ببناء نماذج يمكن من خلالها التنبؤ المبكر لاقتراب حدث التعثر المالي Ex ante approaches بدلاً من التنبؤ بالحدوث Ex post، حيث أصبحت قدرة النموذج لتحقيق علامات الإنذار المبكر تمثل هدف عام لنماذج التنبؤ بالتعثر المالي (Kasey and Watson, 1991). فعلى سبيل المثال في دراسة (Altman et al. 2016) عند استخدام نموذج Z'-Score المعدل ٢٠١٦، بعد تعديل معاملات الارتباط للنموذج باستخدام العينة الكلية بالدراسة (٣١ دولة)، وتطبيقه على عينتين فرعيتين من الشركات المدرجة بسوق التداول بالصين العينة الأولى استخدمت معيار (المعاملة الخاصة (ST): التي تمثل بعض أعراض التعثر المالي للشركات مثل حدوث الخسائر المتتالية لمدة عامين وغيره...) لتحديد الشركات المتعثرة، العينة الثانية استخدم معيار (الشطب من سوق التداول أو الإفلاس) لتحديد الشركات المتعثرة، حيث حقق نموذج التمان المعدل أداء أفضل لتصنيف الشركات المتعثرة بالعينة الأولى مقارنة بأدائه لتصنيف بالعينة الثانية (عند

استخدام معيار الشطب والافلاس) حيث أرجع هذا الفرق في أن الفرق بين قيم الوسيط للنسب المالية بين مجموعتي الشركات بالعينة الأولى أكبر منه بين مجموعتي شركات العينة الثانية ، مما يشير إلى أنه قد تم اختيار شركات تعاني من التعثر ضمن مجموعة الشركات غير المتعثرة بالعينة الثانية نتيجة أنها لم تشطب أو لم يتم إدراجها ضمن الشركات المفلسة.

كما أنه في معظم الأحيان تتوقف الشركات عن نشر القوائم المالية قبل الافلاس لعدد من السنوات (Agostini, 2018) واتباعا للعديد من الدراسات البحثية السابقة وفي ضوء أهداف الدراسة (تحديد علامات الإنذار المبكر لحدث التعثر المالي) وفي حدود البيانات المتاحة ، تم استخدام المعايير (التالية) في هذه الدراسة لتحديد حدث التعثر المالي :

- تحقق الشركة خسائر مالية لمدة عامين متتاليين.

- بالإضافة إلى عدم قيام الشركة بتوزيع الأرباح خلال نفس الفترة.

- القيمة السوقية للشركة أقل من القيمة الاسمية خلال نفس الفترة.

وتأخذ قيمة المتغير التابع (١) عندما تتوافر المعايير السابقة بالشركات حيث تكون الشركات متعثرة ماليا ، ورقم (صفر) للشركات الغير متعثرة ماليا والتي لا تقابل أيا من المعايير السابقة خلال نفس الفترة ، مع العلم بأنه تم استبعاد الشركات التي قد مرت بأي من حالات التعثر المستخدمة لتحديد حالة التعثر قبل أو بعد سنوات التعثر.

اختيار النسب المالية المستخدمة في التنبؤ بالتعثر المالي

تم استخدام اختبار تجانس التباين ليفين Levens' test لتحديد مدى تساوي الاختلافات لقيم المتغيرات المستقلة المستخدمة عن متوسطاتها بكل مجموعة من الشركات عينة الدراسة ، واتباعا للعديد من الدراسات السابقة مثل دراسة (Alifiah, 2013; Lee and Choi, 2012) تم استخدام اختبار (ت) t-test (أحد أساليب الاختبار المعلمي) لإيجاد الفروق المعنوية لمتوسطات النسب المالية بين مجموعتي الشركات عينة الدراسة حيث يفضل استخدامه في حالة تجانس التباين للمجموعتين، كما تم استخدام اختبار مان ويتني Mann-Whitney اللامعلمي ، حيث يفضل في حالة عدم تساوي مصفوفة التباين المشترك للمتغيرات (النسب المالية) المستخدمة بالمجموعتين، ويعرض الجدول التالي نتائج الاختبارات الثلاثة:

جدول (٣) اختبارات مستوى المعنوية للمتغيرات المستقلة

المتغيرات	اختبار ليفين		اختبار (t)		اختبار مان- ويتني	
	قيمة (f)	مستوى المعنوية	قيمة (t)	مستوى المعنوية	قيمة (Z)	مستوى المعنوية
صافي التدفق النقدي لإجمالي الالتزامات	٠.٢٢٧	٠.٦٣٥	٣.١٤٦	٠.٠٠٣	٤.٢٤٤-	٠.٠٠٠
السيولة السريعة	٩.٥٦٥	٠.٠٠٣	٢.٢٨٤	٠.٠٢٨	٢.٩٩١-	٠.٠٠٣
رأس المال العامل	١.٤٣٤	٠.٢٣٦	٣.٣٤٣	٠.٠٠١	٣.٣٥٩-	٠.٠٠١
العائد على حقوق الملكية	٥.١٥٥	٠.٠٢٧	٤.٢٧١	٠.٠٠٠	٥.٠١٩-	٠.٠٠٠
العائد على الأصول	٦.٠٨٨	٠.٠١٦	٥.١٨٢	٠.٠٠٠	٤.٨٤٥-	٠.٠٠٠
هامش الربح الإجمالي	٠.٠٦٧	٠.٧٩٦	٣.٠٦٨	٠.٠٠٤	٢.٩١٣-	٠.٠٠٤
هامش الربح التشغيلي	١.٥٥٥	٠.٢١٧	٣.٦٤٩	٠.٠٠١	٤.٣٩٨-	٠.٠٠٠
العائد على رأس المستثمر	٢.٨٧٢	٠.٠٩٥	٤.٦٥٦	٠.٠٠٠	٥.٠٣٣-	٠.٠٠٠
صافي التدفق النقدي للأصول المتداولة	١.٣٢٠	٠.٢٥٥	٣.٨٠٣	٠.٠٠٠	٣.٣٥٣-	٠.٠٠١

تظهر نتائج اختبار ليفين بالجدول (٣) تساوي مصفوفة التباين المشترك لأغلب النسب المالية فيما عدا نسبة (السيولة السريعة، العائد على حقوق الملكية، هامش الربح الإجمالي) حيث يقل

مستوى المعنوية عن (٠.٠٥) الناتج عن قيمة (ف) لملاخبا، مما يشير إلى عدم تجانس التباين للنسب المالية الثلاثة، كما يلاحظ تشابه نتائج كلا من اختبار (ت) t-test واختبار مان ويتني Mann-Whitney Wilcoxon بالرغم من عدم تساوي مصفوفة التباين المشترك لبعض النسب المالية إلا أنه تظهر نتائج الاختبارات وجود فروق معنوية بين المتوسطات لنفس النسب المالية بالمجموعتين الشركات المتعثرة والغير متعثرة بعينة الدراسة.

Multicollinearity تحديد العلاقات الارتباطية بين المتغيرات والمشكلات الانحدارية

تم استخدام معامل ارتباط بيرسون Pearson Correlation لتحديد المتغيرات ذات علاقة ارتباطية معنوية قوية حيث أنها قد تعكس نفس نواحي الأداء ، والتي قد ينشأ عن استخدامها معا في نموذج الدراسة مشكلات انحدارية تؤدي لعدم استقرار أداء النموذج وزيادة نسبة الخطأ المعياري للمتغيرات المستخدمة في النموذج أو الحصول على اشارات لمعاملات الارتباط (اتجاه العلاقة) غير متوقعة (Serrano and Gutierrez, 2013) ، كما تم استخدام معامل تضخم التباين Variance Inflation Factor لتحديد مستوي المشكلات الانحدارية بين المتغيرات المستقلة المستخدمة بالنموذج حيث يعتمد معامل تضخم التباين على نسبة التغير التي يشترك فيها متغيرين مستقلين أو أكثر بالنموذج ، ويعرض الجدول (٤) نتائج اختبار معامل ارتباط بيرسون ومعامل تضخم التباين:

جدول (٤) مصفوفة الارتباط ومعامل تضخم التباين

صافي التدفق التقدي	العائد على رأس المال المستثمر	هامش الربح التشغيلي	هامش الربح الإجمالي	العائد على الأصول	العائد على حقوق الملكية	رأس المال العامل	المسؤولية السريعة	صافي التدفق التقدي
صافي التدفق التقدي	١							
المسؤولية السريعة	٠,٣٢٧							
رأس المال العامل	٠,٣٣٧							
العائد على حقوق الملكية	٠,٤٨٣							
العائد على الأصول	٠,٥٨٢							
هامش الربح الإجمالي	٠,٤٩٦							
هامش الربح التشغيلي	٠,٥٢٩							
العائد على الاستثمار	٠,٤٩٧							
صافي التدفق التقدي	٠,٨٠٧							
نسبة التفاوت TOL	٠,٤٩٥							
معامل تضخم VIF	٢,٠١٨							

ملحوظة: بالجزء - أولا- من الجدول تمثل الأرقام دون الأقواس معاملات ارتباط بيرسون بين المتغيرات ، يمثل ما بين الأقواس مستوى المعنوية (p -value) لمعاملات الارتباط، كما يحتوي الجزء الثاني- على نتائج اختبار معامل تضخم التباين لتحديد المشكلات الانحدارية.

تظهر نتائج الاختبار بالجدول السابق وجود بعض المتغيرات المستقلة ذات علاقة ارتباطية قوية حيث تتعدى قيمة معاملات الارتباط لها (٨٠٪) مثل نسبة العائد على حقوق الملكية ونسبة العائد على الأصول وكذلك نسبة العائد على الاستثمار بالإضافة إلى زيادة قيمة معامل تضخم التباين (VIF) لهذه المتغيرات عن (١٠) وقد يرجع ذلك إلى أن كلاهما يعكس الربحية ، وكذلك حيث أشارت بعض الدراسات إلى أنه يجب أن لا تتعدى قيمة معامل تضخم التباين عن (١٠) مثل دراسة (Kutner et al. (2004)، كما أشار (Shumway, 2001) إلى أنه لا يجب أن تتعدى (٥) ، في حين أن بعض الدراسات مثل دراسة (Ciampi and Gordini, 2013; Ciampi, 2014) استبعدت المتغيرات ذات قيمة معامل تضخم التباين (VIF) التي تتعدى (٣)، كما استخدمت بعض الدراسات مثل (Shmuck, (2013) المتغيرات ذات قيمة لن تتعدى (٢) مما يشير إلى أنه لن تتفق الدراسات البحثية السابقة على قيمة محددة لمعامل تباين التضخم كقيمة قاطعة Cutoff Point، لذلك اعتمدت هذه الدراسة على قيمة معامل تضخم التباين لا تتعدى (٥).

تم استبعاد كلا من نسبة العائد على الأصول ونسبة العائد على حقوق الملكية ، نظرا لوجود علاقات ارتباطية قوية بمعظم النسب المالية الأخرى، حيث أصبحت النسب المالية المتاحة: نسب السيولة (رأس المال العامل لإجمالي الأصول، السيولة السريعة)، ونسب الربحية (العائد على رأس المال المستثمر، هامش الربح الإجمالي، هامش الربح التشغيلي)، ونسب التدفق النقدي (صافي التدفق النقدي لإجمالي الالتزامات المالية، صافي التدفق النقدي إلى الخصوم المتداولة)، واتباعا للعديد من الدراسات البحثية السابقة مثل دراسة (Orth, 2013; Sun and Li, 2010) تم استخدام كلا من طريقة الاختيار الخلفي والاختيار الأمامي لتخفيض عدد النسب المالية المستخدمة في النموذج، حيث تشترك النسب المالية المتبقية في قياس نفس نواحي الأداء ويعرض الجدول (٥) نتائج استخدام الطريقتين:

جدول (٥) نتائج استخدام الاختيار الأمامي والاختيار الخلفي

النسب	الطريقة	الاختيار الأمامي		الاختيار الخلفي	
		قيمة (ت)	مستوي المعنوية	قيمة (ت)	مستوي المعنوية
صافي التدفق النقدي لإجمالي الالتزامات	٢.٧٤٧-	٠.٠٠٨	٢.٣٧٥-	٠.٠٢١	
رأس المال العامل لإجمالي الأصول	٢.٠٩٠-	٠.٠٤١	٢.٥٤٤-	٠.٠١٤	
هامش الربح التشغيلي	--	--	٢.٣٧١-	٠.٠٢١	
العائد على رأس المال المستثمر	٣.٣٧٦-	٠.٠٠١	٢.٢٠٧-	٠.٠٣١	

يتضح من الجدول السابق أنه تتفق نتائج طريقة الاختيار الأمامي والاختيار الخلفي في تحديد عدد (٣) نسب مالية وهي: (صافي التدفق النقدي لإجمالي الالتزامات المالية، رأس المال العامل لإجمالي الأصول، والعائد على رأس المال المستثمر) تحقق فرق معنوي بين مجموعتي الشركات عينة الدراسة، ولكن تختلف نتيجة الاختيار الخلفي بإضافة نسبة هامش الربح التشغيلي إلى النسب المالية الثلاثة السابقة، كما يلاحظ أن نسبة العائد على رأس المال المستثمر ذات أعلى قيمة (ت) وفقا لنتائج الاختيار الأمامي مما يشير إلى أنها أهم نسبة مالية، بخلاف نتائج الاختيار الخلفي حيث أن نسبة رأس المال العامل لإجمالي الأصول ذات أعلى قيمة (ت) مما يشير إلى أنها أكثرهم أهمية، لذلك سوف يتم استخدام الأربعة نسب مالية في نموذج الدراسة،

ويعرض الجدول (٦) مصفوفة الارتباط ومعامل تضخم التباين للمتغيرات المستخدمة في نموذج الدراسة.

جدول (٦) مصفوفة الارتباط ومعامل تضخم التباين للمتغيرات المستخدمة في الدراسة

المتغيرات	صافي التدفق النقدي	رأس المال العامل لإجمالي الأصول	هامش الربح التشغيلي	العائد على رأس المال المستثمر
صافي التدفق النقدي	١			
رأس المال العامل لإجمالي الأصول	٠,١١٢ (٠,١٨٥)	١		
هامش الربح التشغيلي	٠,١٦٣ (٠,٠٩٥)	٠,٣٥٧ (٠,٠٠٢)	١	
العائد على رأس المال المستثمر	٠,٢١٧ (٠,٠٤١)	٠,٠٠٩ (٠,٤٧٢)	٠,٤٠٣ (٠,٠٠٠)	١
نسبة التفاوت	٠,٩١١	٠,٧٢٦	٠,٧٢١	٠,٥٠٤
معامل تضخم التباين	١,٠٩٧	١,٣٣٧	١,٣٨٧	١,٩٨٣

ملحوظة: يحتوي الجدول على مصفوفة الارتباط لجميع المتغيرات المستخدمة في الدراسة والتي تمثل النسب المشتقة من القوائم المالية. الجزء الأول: تمثل الأرقام دون الأقواس معاملات ارتباط بيرسون بين المتغيرات، ويشير ما بين الأقواس إلى مستوي المعنوية (P-value) لمعاملات الارتباط، الجزء الثاني: نتائج اختبار معامل تضخم التباين (VIF) الصف الأول (نسبة التفاوت) والصف الثاني (معامل تضخم التباين).

يلاحظ من الجدول (٦) أن قيمة معامل تضخم التباين (VIF) لجميع المتغيرات لا تتعدى (٢)، مما يشير إلى عدم وجود مشكلات انحدارية بين المتغيرات المستقلة المستخدمة بنموذج الدراسة.

خامساً: الوصف الإحصائي للشركات عينة الدراسة.

يحتوي الجدول (٧) على الوصف الإحصائي للمتغيرات المستقلة من حيث قيم: (الوسط، الوسيط، الانحراف المعياري، الحد الأدنى والحد الأعلى)، وكذلك عدد المشاهدات لكل مجموعة من الشركات عينة الدراسة، والتي تشمل المتغيرات المالية: (نسبة صافي التدفق النقدي لإجمالي الالتزامات المالية، رأس المال العامل لإجمالي الأصول، هامش الربح التشغيلي، العائد على رأس المال المستثمر).

جدول (٧) الوصف الإحصائي لعينة الدراسة

الوسط	الوسيط	الانحراف المعياري	الحد الأدنى	الحد الأعلى	
(أ) الشركات المتعثرة :					
صافي التدفق النقدي لإجمالي الالتزامات المالية	٠,٣٦٢	٠,٠١٤-	١,١٦٦٣	٠,٢٨٧-	٠,٩٢٩
رأس المال العامل لإجمالي الأصول	٠,٠٩٠١	٠,٠٧٦	٠,٣٢٧٤٨	٠,٩٩٩-	٠,٧٥٢
هامش الربح التشغيلي	٠,٢٨٩-	٠,٠٢٢	٠,٠٢٩٠٨٣	١,٠٣٠-	٠,٤٠٧
العائد على رأس المال المستثمر	٠,٠١٥١	٠,٠١٠	٠,١٠٠٨٦٥	٠,٣٦٧-	٠,٣٢٤
(ب) الشركات الغير متعثرة :					
صافي التدفق النقدي لإجمالي الالتزامات المالية	٠,٤٥١	٠,١٢٤	٠,٩٣٣٨٨٤	٠,٣٦٥-	٤,٢١٤
رأس المال العامل لإجمالي الأصول	٠,٣٠٩٨	٠,٣٠٠	٠,٢٠٣٥٢	٠,٠٢٨-	٠,٨٢٩
هامش الربح التشغيلي	٠,١٧٨٦	٠,١١٥	٠,١٦٣٦٤	٠,٠٠٤	٠,٧٤٨
العائد على رأس المال المستثمر	٠,١٢٤٦	٠,١١١٥	٠,٠٨٩٩٤	٠,٠١٠	٠,٣٨٧

يتضح من الجدول (٧): زيادة نسبة الانحراف المعياري بمجموعة الشركات المتعثرة للنسب المالية: (صافي التدفق النقدي لإجمالي الالتزامات، رأس المال العامل لإجمالي الأصول، هامش الربح التشغيلي) عنها في مجموعة الشركات الغير متعثرة بالترتيب ($0.934 < 1.176$)، ($0.327 < 0.203$)، ($0.164 < 0.327$)، حيث يشير هذا الفرق إلى أن الاختلافات في قيم النسب المالية بين الشركات المتعثرة أعلى من الشركات الغير متعثرة مالياً، مما يزيد من احتمال انخفاض قدرة النموذج (حساسية النموذج) Sensitivity في التصنيف والتنبؤ بالشركات المتعثرة، بخلاف أداء النموذج في التصنيف والتنبؤ بالشركات الغير متعثرة Specificity نظراً لانخفاض الانحراف المعياري لنفس النسب المالية الثلاثة بها.

كما يلاحظ بالنسبة لعينة الشركات المتعثرة مالياً أن قيمة الوسيط Median للنسب المالية (صافي التدفق النقدي لإجمالي الالتزامات المالية، هامش الربح التشغيلي) تتعدى قيمة الوسط Mean مما يشير إلى الميل السالب لتوزيع قيم المشاهدات، بينما تتجاوز قيمة الوسط Mean لنفس النسبتين لقيمة الوسيط Median بالنسبة للشركات الغير متعثرة مالياً مما يعكس الميل الموجب لتوزيع قيم المشاهدات.

أما بالنسبة للشركات الغير متعثرة بالجزء (ب) الجدول، فنلاحظ أنه تتقارب قيمة كلا من الوسط والوسيط بالنسبة إلى كلا من: (نسبة رأس المال العامل لإجمالي الأصول، العائد على رأس المال المستثمر) مما يشير إلى التوزيع الطبيعي لقيم المشاهدات لهذه النسب المالية، وكذلك بالنسبة للشركات المتعثرة بالجزء (أ) من الجدول فنلاحظ تقارب كلا من قيمة الوسط والوسيط لنفس النسب المالية وإن كانت قيم متوسطات هذه النسب للشركات المتعثرة أقل بفارق ملحوظ عن قيم المتوسطات لها عن الشركات الغير متعثرة، بالترتيب ($0.309 < 0.090$)، ($0.127 < 0.015$)، مما يشير إلى أن الشركات الغير متعثرة مالياً لديها مرونة أكثر بهيكل الأصول وكذلك تتمتع بمستوي سيولة أعلى من الشركات المتعثرة مالياً، بالإضافة إلى أنها تحقق عائد على رأس المال المستثمر أعلى من الشركات المتعثرة (كما هو متوقع).

سادساً: بناء نموذج التنبؤ بالتعثر المالي باستخدام الانحدار اللوجستي

يظهر الجدول (٨) من خلال النماذج المعروضة قدرة المتغيرات المستخدمة على التمييز بين الشركات المتعثرة والغير متعثرة وفي نفس الوقت اختيار قدرتها على التنبؤ خلال الفترة (ت-١) قبل حدث التعثر بمدة عام و أيضاً خلال الفترة (ت-٢) قبل حدث التعثر بمدة عامين، وتشمل هذه المتغيرات النسب المالية المشتقة من القوائم المالية للشركات عينة الدراسة عن الفترة (ت-١) وأيضاً خلال الفترة (ت-٢).

جدول (٨) نتائج تحليل الانحدار اللوجستي

المتغيرات	(أ): الفترة (ت-١)			(ب): الفترة (ت-٢)		
	معاملات الارتباط	الخطأ المعياري	قيمة ووالد	معاملات الارتباط	الخطأ المعياري	قيمة ووالد
صافي التدفق النقدي لأجمالي الالتزامات	٠.٦٨٩-	٠.٥٤٣	١.٦١٠	٠.٨٦٥-	٠.٥١٣	٢.٥٢٥
رأس المال العامل لإجمالي الأصول	٣.٠٨٤-	١.٠٥٩	٨.٤٧٢	٢.٣٢١-	١.١٢٢	٤.٢٧٩
هامش الربح التشغيلي	٢.١٢٥-	١.٧٥٦	١.٤٦٤	٣.٣٤٥-	٢.٠٠٨	٢.٧٧٤
العائد على رأس المال المستثمر	١.٠٥٣٨-	٣.٥١٦	٨.٩٨٣	٨.٤٣٩-	٣.٢٨٤	٦.٦٠٢
معامل التحديد R^2	٠.٤٩٨			٠.٤٩٠		
اختبار (HL)	١٤.٣٨٩ (٠.٠٧٨)			٩.٨٧٦ (٠.٢٧٤)		

ملحوظة: ملحوظة: يشمل الجزء (أ) نتائج تحليل الانحدار اللوجستي قبل حدث التعثر بمدة عام (ت-١)، والجزء (ب) قبل حدث التعثر بمدة عامين (ت-٢)، ويشمل الجزء الثاني بالجدول: معامل التفسير (R^2) وقيمة (كا) لاختبار Hosmer-Lamshow بدون الأقواس، بينما القيم بين الأقواس تمثل مستوي المعنوية (P-Value) للاختبار.

ويلاحظ من نتائج تحليل الانحدار اللوجستي أنه تحقق نسبة (العائد على رأس المال المستمر) أعلى قدرة على التمييز بين مجموعتي الشركات المتعثرة والغير متعثرة خلال فترات التنبؤ (ت-١) وأيضاً (ت-٢)، حيث أنها ذات دلالة إحصائية معنوية قوية ($p\text{-value} < 0.05$) بالإضافة إلى أنها تحتوي على أعلى قيمة (χ^2) Wald statistic من بين الأربعة نسب مالية المستخدمة بالنموذج خلال فترتي التنبؤ، ثم تأتي نسبة (رأس المال العامل لإجمالي الأصول) من حيث القدرة على التمييز بين مجموعتي الشركات والتنبؤ خلال الفترة (ت-١) والفترة (ت-٢) كما أنها تحتفظ بنفس مستوى المعنوية خلال فترات التنبؤ ($p\text{-value} < 0.05$)، ويلاحظ أن نموذج التنبؤ يحتفظ بنفس القدرة التفسيرية خلال الفترتين (ت-١، ت-٢) حيث أن معامل التحديد (R^2) للفترة الأولى (٠.٤٩٨)، والفترة الثانية (٠.٤٩٠)، كما يلاحظ أن زيادة قيمة (χ^2) الناتجة عن اختبار (حسن المطابقة) Goodness-of-fit (HL) خلال الفترة (ت-١) عن قيمة (χ^2) للفترة (ت-٢) وكذلك انخفاض مستوى المعنوية الناتج عن اختبار (HL) للفترة (ت-١) ($p\text{-value} < 0.10$) عن مستوى المعنوية ($p\text{-value} > 0.10$) للفترة (ت-٢)، مما يشير إلى أن نموذج التنبؤ أكثر ملائمة للبيانات عينة الدراسة لتفسير حالة التعثر للفترة (ت-٢) قبل حدث التعثر بمدة عامين عن الفترة (ت-١) وقد يرجع ذلك إلى أن نسبة (هامش الربح التشغيلي) أصبحت تمثل فرق معنوي بين مجموعتي الشركات عينة الدراسة خلال الفترة (ت-٢) عند مستوى معنوية ($p\text{-value} < 0.10$)، بالإضافة إلى زيادة قدرة نسبة (صافي التدفق النقدي لإجمالي الالتزامات المالية) حيث زادت قيمة (χ^2) إلى (٢.٥٨) وإن كانت غير معنوية.

سابعاً : بناء نموذج التنبؤ باستخدام الشبكات العصبية الاصطناعية

تم الاعتماد على عينة التدريب وبناء النموذج In-sample والتي تمثل (٧٠٪) من إجمالي البيانات حيث تم استخدامها في بناء وتدريب نموذج الانحدار اللوجستي، كما تتكون عينة التدريب المستخدمة في بناء الشبكة العصبية من عدد (٤٣) شركة، وتنقسم إلى مجموعتين من البيانات وهي (فئة التدريب Training، فئة الصلاحية Validation)، وتشمل فئة التدريب عدد (٣٦) شركة، وفئة الصلاحية عدد (٧) شركات، وفيما يلي بيانات الشبكة العصبية المستخدمة:

١- نوع الشبكة المستخدمة : تم استخدام الشبكات العصبية المتعددة الطبقات ذات خاصية الانتشار الخلفي MLP-Back-propagation في هذه الدراسة والتي تعتمد على مبدأ التعليم المراقب Supervised Learning، حيث تم إدخال (طبقة المدخلات) : المتغيرات المستقلة (النسب المالية) مع الناتج المستهدف (المتغير التابع) حتى تقوم الشبكة بعمل انتشار أمامي Feed Forward للمدخلات للحصول على القيمة (٠-١) حيث تكون الشركة غير متعثرة عندما يكون الناتج (صفر) وتكون الشركة متعثرة عندما تأخذ قيمة (واحد)، ثم المقارنة بين الناتج (المخرجات) والمستهدف (الفعلي) وحساب قيمة الفرق بينهما لكل خلية من طبقة المخرجات والذي يمثل الخطأ Error، ثم بعد ذلك تأتي مرحلة الانتشار الخلفي للأخطاء حيث تعيد الشبكة حساب قيمة الخطأ في كل خلية من الطبقة الخفية ثم تقوم بتحديث قيمة الأوزان ثم تعوضها بالقيم الجديدة المحسوبة.

٢- طبقة المدخلات: عند إعداد نموذج التنبؤ تم إدخال المتغيرات المستقلة وعددها (٤) نسب مالية: (صافي التدفق النقدي لإجمالي الالتزامات المالية، رأس المال العامل لإجمالي الأصول، هامش الربح التشغيلي، العائد على رأس المال المستمر) والتي تمثل عدد أربعة خلايا بطبقة المدخلات على الترتيب (x_1 ، x_2 ، x_3 ، x_4).

٣- الطبقة الخفية: تحتوي هذه الطبقة على العديد من وحدات المعالجة أو الخلايا Neurons حيث تحتوي كل وحدة على دالة تنشيط من النوع Sigmoid وقد تم تحديد عدد وحدات هذه الطبقة


بتمرين مجموعة من الشبكات المختلفة على جميع متغيرات الدراسة للوصول إلى أفضل عدد من الطبقات الخفية عن طريق التجربة والخطأ والتي توصلت إلى عدد (٢) طبقة خفية ، تحتوي الطبقة الأولى على (٣) خلايا عصبية والطبق الخفية الثانية على عدد (١) خلايا عصبية كما هو موضح بالشكل رقم (١).

٤- طبقة المخرجات: تشمل المتغير التابع وتتكون من عدد (١) خلية، حيث تكون في شكل ثنائي (صفر) للشركات الغير متعثرة مالياً، و (واحد) للشركات المتعثرة.

٥- طريقة التعلم: تم الاعتماد في جميع المعماريات على خوارزمية الانتشار الخلفي للتعلم المراقب حيث تكون قيمة المخرجات محددة.

٦- معدل التعلم وقوة الدفع : يحدد معدل التعلم قيمة التصحيح التي على أساسها يتم تعديل في أوزان الخلية العصبية أثناء عملية التدريب ، فهو عبارة عن قيمة صغيرة تزيد مع مرات التعلم تصل إلى حل أقرب إلى الحل الأمثل مما يزيد من دقة النموذج وتقليل الخطأ إلى أدنى حد ممكن، بينما قوة الدفع المعدل الذي يتم اضافته تدريجياً للأوزان النسبية لكل متغير بين الطبقات المختلفة للشبكة العصبية للحصول على أقل معدل خطأ ومنع الوصول إلى أدنى نقطة تدريب في النموذج.

شكل (١) أداء عملية التدريب للشبكة العصبية



تدريب الشبكة العصبية

يوضح الشكل (١) أداء عملية تدريب الشبكة العصبية حيث يتوقف التدريب تلقائياً عندما يتوقف التحسن في عملية التعميم Generalization ، وذلك قبل زيادة معدل الخطأ المتداخل لعينة الصلاحية Validation Set مره أخرى. حيث يشير تدني الخطأ^١ Cross entropy إلى الأداء الجيد في التصنيف ، بينما كلما زاد الخطأ كلما كان أداء التصنيف ضعيف.

^١ Cross entropy error function = $-\sum_{i=0}^n \ln(o_i) * t_i$

Where: (n) number of cases.

∴ case i, o_i computed output, t_i : target output

هيكـل (معمارية) الشبكة العصبية المستخدمة في الدراسة

يوضح الشكل (٢) معمارية (هيكـل) الشبكة العصبية التي تم التوصل إليها بعد تدريب الشبكة العصبية وتتكون من طبقة المدخلات Input layer والتي تحتوي على عدد ٤ خلايا تمثل المتغيرات المستقلة المستخدمة في التنبؤ وتشمل (٤) نسب المالية ، كما تحتوي الشبكة على عدد (٢) طبقة خفية Hidden Layers، تحتوي الطبقة الأولى على عدد (٣) خلايا خفية Neurons ، بينما تحتوي الطبقة الخفية الثانية على عدد (٦) خلايا خفية ، وتشمل طبقة المخرجات عدد (١) خلية وتمثل المتغير التابع (نتائج النموذج) ، ويأخذ الناتج قيمة (صفر) إذا كانت الشركة غير متعثرة مالياً وقيمة (١) إذا كانت الشركة متعثرة مالياً ، كما يوضح الشكل (٢) حيث تم الاعتماد على قيمة الحد Threshold Value بقيمة (0.5) للفرقة بين المجموعتين أي شركة متعثرة أو غير متعثرة مالياً، حيث إذا كانت مخرجات الشبكة العصبية $NN_{(out)}$ أكبر من أو يساوي (0.5) يتم تصنيف الشركة كشركة متعثرة مالياً ، أما إذا كانت أقل من (0.5) تكون الشركة غير متعثرة مالياً كما يلي :

الشركة إذا كانت متعثرة : $0.5 \leq NN_{(out)}$


الشركة غير متعثرة مالياً : $0.5 \geq NN_{(out)}$

ثامناً : نتائج اختبار صلاحية نماذج الدراسة

في الجزء السابق تم استخدام عينة التقدير (٧٠٪ من إجمالي بيانات عينة الدراسة) بغرض بناء نماذج التنبؤ وتقدير معاملاتها ، بالإضافة إلى تحديد أي المتغيرات التي ينتج عن إضافتها تحسن لأداء نموذج التنبؤ بالتعثر المالي. في هذا الجزء تم اختبار أداء نماذج الدراسة باستخدام عينة الاختبار (٣٠٪ من إجمالي البيانات المستخدمة في هذه الدراسة) من خلال استخدام الأساليب (مقاييس الأداء) الأربعة ومقارنتها لتحديد أفضل نموذج يحقق أقل معدلات للخطأ سواء من النوع الأول: (تصنيف الشركة المتعثرة مالياً كشركة غير متعثرة أو ما يسمى تنبؤ سلبي خطأ وغياب حالة التعثر)، أو خطأ النوع الثاني: (تصنيف الشركة الغير متعثرة كشركة متعثرة مالياً، أو ما يسمى بالتنبؤ الإيجابي الخطأ)، بالإضافة إلى مقارنتهما بنموذج التمان Z-Score المعدل ، كأحد النماذج الرائدة والشائعة الاستخدام بالدراسات البحثية السابقة.

يعرض الجدول (٩) مصفوفة الخطأ لنموذج التنبؤ والذي يشمل النسب المالية الأربعة (صافي التدفق النقدي لإجمالي الالتزامات المالية، رأس المال العامل لإجمالي الأصول، هامش الربح التشغيلي، العائد على رأس المال المستثمر)، وذلك باستخدام كلا من: الانحدار اللوجستي LR ، والشبكات العصبية متعددة الطبقات MLP للمقارنة بينهما.

شكل رقم (٢) معمارية الشبكة العصبية المستخدمة في الدراسة



Hidden layer activation function: Sigmoid

Output layer activation function: Identity

يتضح من الجدول (٩): تحقق الشبكات العصبية المتعددة الطبقات (MLP) عند استخدام عينة الاختبار أعلى مستوى دقة لتصنيف الشركات المتعثرة والغير متعثرة وكذلك التنبؤ خلال الفترة (ت-١، ت-٢) مقارنة بنموذج الانحدار اللوجستي، حيث تحقق الشبكات العصبية أقل نسبة خطأ النوع الأول Type I Error خلال الفترة (ت-١) بنسبة ١٠٪، مما يشير إلى أنه أعلى النماذج حساسية^٢ Sensitivity (قدرة على تصنيف الشركات المتعثرة) حيث تساوى (٩٠٪)، وكذلك خلال الفترة (ت-٢) تحقق الشبكات العصبية أعلى مستوى دقة مقارنة بنموذج التنبؤ باستخدام الانحدار اللوجستي، مما يشير إلى أنه تتميز الشبكات العصبية الاصطناعية بانخفاض تكلفة الخطأ مقارنة بنموذج الانحدار اللوجستي نظرا لارتفاع تكلفة خطأ النوع الأول (تصنيف الشركات المتعثرة كشركات غير متعثرة ماليا) مقارنة بتكلفة خطأ النوع الثاني (تصنيف الشركات الغير متعثرة ماليا كشركات متعثرة ماليا) حيث أثبتت دراسة Altman, Narrayann and Haldeman, (1977) أن تكلفة خطأ النوع الأول تساوي ٣٥ مرة تكلفة خطأ النوع الثاني، كما يلاحظ استقرار أداء نموذج الشبكات العصبية الاصطناعية خلال فترتي التنبؤ (ت-١، ت-٢) بخلاف نموذج الانحدار اللوجستي حيث انخفض مستوى الدقة التصنيف والتنبؤ للنموذج بشكل ملحوظ خلال الفترة (ت-٢) إلى ٧٣.٩٪ وانعكس ذلك في زيادة معدل الخطأ من النوع الأول إلى ٢١٪ مما يعكس إلى انخفاض قدرة النموذج على تصنيف الشركات الغير متعثرة ماليا^٣ Specificity.

$$\frac{TP}{TP+FN} \times 100 = (\text{Sensitivity})$$

حيث أن: (TP): حالات التنبؤ الإيجابي الصحيح، (FN): حالات التنبؤ السلبي الخطأ.

$$\frac{TN}{TN+FP} \times 100 = (\text{Specificity})$$

حيث أن: (TN): حالات التنبؤ السلبي الصحيح، (FP): حالات التنبؤ الإيجابي الخطأ.

جدول (٩) مصفوفة الخطأ لنماذج الدارسة خلال فترات التنبؤ (ت-١ ، ت-٢)

اداء نموذج التنبؤ					الاسلوب الاحصائي	الحالة الفعلية للشركات	الحالة المتوقعة (خطا النوع الأول والثاني)	مستوي الدقة (معدل الخطا)	(١ - الفترة (ت - ١)
					متعثرة %	غير متعثرة %			
(أ) الفترة (ت - ١)									
الانحدار اللوجستي	متعثرة	١	٨٠	(٢٠)	٨٢.٦	(١٧.٤)			
	غير متعثرة	٠	(١٥)	٨٥					
الشبكات العصبية	متعثرة	١	٩٠	(١٠)	٨٧	(١٣)			
	غير متعثرة	٠	(١٥)	٨٥					
(ب) الفترة (ت-٢)									
الانحدار اللوجستي	متعثرة	١	٨٠	(٢٠)	٧٣.٩	(٢٦.١)			
	غير متعثرة	٠	(٣١)	٦٩					
الشبكات العصبية	متعثرة	١	٨٠	(٢٠)	٩١.٣	(٨.٧)			
	غير متعثرة	٠	(٠)	١٠٠					

ملحوظة: تمثل الفترة (ت-١) قبل حدث التعثر لمدة عام، الفترة (ت-٢) قبل حدث التعثر لمدة عامين، الشركات المتعثرة تأخذ قيمة (١)، الشركات غير المتعثرة تأخذ قيمة (٠).

وبلاحظ بشكل عام انخفاض نسبة خطأ النوع الأول الناتجة عن استخدام الشبكات العصبية متعددة الطبقات MLP خلال فترتي التنبؤ مقارنة بنموذج الانحدار اللوجستي، وقد يرجع ذلك إلى أن الشبكات العصبية الاصطناعية تعتمد على ترجيح الأوزان للعلاقات بين الخلايا العصبية Neurons والتي تمثل المتغيرات المستخدمة في التنبؤ بخلاف الانحدار اللوجستي الذي قد يتأثر بمشكلة تغير توزيع البيانات حيث أنه تتسم بيانات الشركات المتعثرة بزيادة نسبة الانحراف المعياري للنسب المالية كما هو موضح بالجدول (٧) ويشير ذلك لوجود اختلافات بين قيم المشاهدات للشركات المتعثرة أعلى منها في الشركات الغير متعثرة ومن ثم انخفاض حساسية نموذج الانحدار اللوجستي (قدرة النموذج في تصنيف الشركات المتعثرة)، Rikkers and Thibault (2011) عن نماذج الشبكات العصبية.

تاسعاً : تطبيق نموذج التمان (٢٠١٦) على عينة الدراسة

يرجع اختيار نموذج التمان (٢٠١٦) المعدل للمقارنة بنماذج الدراسة إلى عدة أسباب تمثل محل تركيز دراسة Altman et al. (2016) بغرض تجنب العديد من المحددات التي تواجه تطبيق نماذج التنبؤ بالتعثر المالي والافلاس، مثل القواعد والممارسات المحاسبية، وحماية المستثمرين وحوكمة الشركات وغيرها من العوامل، وفما يلي الأسباب:

- أحد أهم المحفزات الأساسية لتطوير نموذج التمان Z'-score حتى يمكن تطبيق النموذج على شركات الأسواق الناشئة Emerging markets، حيث تم اختيار دول مثل كولومبيا والصين بعينة إعداد النموذج نظراً لاختلاف طبيعتها عن الدول الأوروبية.
- تطبيق النموذج على الشركات الصناعية والغير صناعية وذلك بعد استبعاد نسبة (معدل دوران الأصول: المبيعات لإجمالي الأصول) واستخدام عينة من الشركات الصناعية والغير صناعية بعينة التقدير والبناء للنموذج المعدل.
- عدم استخدام المتغيرات السوقية حتى يمكن تطبيق النموذج على الشركات المساهمة وأيضاً الشركات ذات الملكية الخاصة في نفس الوقت.

وفيما يلي نموذج التمان (٢٠١٦) المعدل والذي تم استخدام التحليل التمييزي (DA) لبنائه وتقدير معاملاته، المعادلة رقم (٤):

$$Z = -0.042 + (-0.561 * x_1) + (-0.724 * x_2) + (-1.791 * x_3) + (-0.021 * x_4)$$

حيث أن:

- x_1 : رأس المال العامل + إجمالي الأصول.
- x_2 : الأرباح المحتجزة + إجمالي الأصول.
- x_3 : الربح قبل الفوائد والضرائب + إجمالي الأصول.
- x_4 : القيمة الدفترية لحقوق الملكية + إجمالي الديون.

يعرض الجدول (١٠) مصفوفة التصنيف لنموذج التمان ٢٠١٦ المعدل، الناتجة عن تطبيق النموذج على الشركات (عينة الاختبار) باستخدام بيانات الفترة (ت-١) والفترة (ت-٢).


جدول (١٠) مصفوفة التصنيف لنموذج التمان (٢٠١٦)

المتوقع / الفعلي	قبل حدث التعثر بمدة عام (ت-١)		قبل حدث التعثر بمدة عامين (ت-٢)	
	المتعثرة	غير المتعثرة	المتعثرة	غير المتعثرة
الغير متعثرة	٨٠٪ (٩٢٪)	٣٠٪ (١٠٠٪)		
المتعثرة	٦٠٪ (٤٠٪)	٣٠٪ (٧٠٪)		
المعدل الإيجابي الصحيح	٨٦٪ (٧٥٪)	١٠٠٪ (٦٥٪)		
نسبة الخطأ	١٤٪ (٢٥٪)	٠٪ (٣٥٪)		

يلاحظ من الجدول (١٠): يحقق نموذج 2016 Score-Z المعدل على المدى القصير خلال الفترة (ت-١) أداء مقبول بمستوى دقة (٧٨,٣٪) حيث أن خطأ النوع الأول Type I Error (تصنيف الشركات المتعثرة كشركات غير متعثرة مالياً) ٤٠٪، وخطأ النوع الثاني Type II Error (تصنيف الشركات الغير متعثرة كشركات متعثرة مالياً) ٨٠٪، بينما يحقق النموذج على المدى البعيد خلال الفترة (ت-٢) أداء قد يكون غير مقبول بمستوى دقة (٦٩,٦٪)، ويرجع ذلك إلى أن نسبة خطأ النوع الأول (٧٠٪) مما يشير إلى انخفاض مستوى حساسية النموذج Sensitivity (قدرة النموذج على التصنيف والتنبؤ بالشركات المتعثرة) إلى (٣٠٪) فقط، في حين أن نسبة خطأ النوع الثاني أصبحت (٠٪)، مما يشير إلى أن قدرة النموذج على التصنيف والتنبؤ بالشركات الغير متعثرة أصبحت (١٠٠٪)، وتكمن أهمية مشكلة تدهور أداء النموذج في الفترة (ت-٢) إلى أن تكلفة خطأ النوع الأول أعلى من تكلفة خطأ النوع الثاني، حيث أثبتت دراسة (Altman, Haldeman and Narayanan, 1977) أن تكلفة خطأ النوع الأول تساوي ٣٥ مرة تكلفة خطأ النوع الثاني، وأشارت دراسة (Tinco and Wilson, 2013) إلى أن تكلفة خطأ النوع الأول أعلى من تكلفة خطأ النوع الثاني، وقد يرجع ذلك نتيجة لاستخدام أسلوب التحليل التمييزي في بناء النموذج وتقدير معاملاته، ففي معظم الأحيان مثلما أظهرت نتائج العديد من الدراسات البحثية السابقة أن نسبة خطأ النوع الأول الناتجة عن استخدام التحليل التمييزي أعلى من الأساليب الأخرى مثل الانحدار اللوجستي LR وذلك مثل دراسة (Ciampi and Gordini, 2013; Lee and Choi, 2012)، كما أنه قد يرجع ذلك لاختلاف توزيع البيانات للشركات عينة الدراسة عن توزيع البيانات المستخدمة في أعداد نموذج التمان ٢٠١٦ (المعدل)، مثلما أشارت دراسة (Altman et al. (2016).

الشكل (٣) منحنيات الأداء (المساحة أسفل المنحني AUC) لنموذج التمان (٢٠١٦)

منحني (٢) : المساحة أسفل المنحني لنموذج التمان
منحني (٣) : المساحة أسفل المنحني لنموذج التمان
(٢٠١٦) قبل حدث التعثر لمدة عام (ت-٢).
(٢٠١٦) قبل حدث التعثر لمدة عامين (ت-١).



عاشراً : قياس أداء نماذج الدراسة

يعرض الجدول (١١) نتائج استخدام كلا من الأساليب : (المساحة أسفل المنحني AUC، معامل ارتباط جيني ، كولموجروف سميرنوف KS-Z ، مقياس (F) كمقاييس لأداء نموذج التنبؤ باستخدام النسب المالية الأربعة، وفي نفس الوقت مقارنة أداء أساليب التقدير المستخدمة في بناء النموذج لكلا من الانحدار اللوجستي LR والشبكات العصبية متعددة الطبقات MLP، بالإضافة إلى نموذج (Altman 2016) المعدل، وذلك باستخدام عينة الاختبار Test Sample لتحديد أي النماذج يحقق أداء أفضل في التصنيف والتنبؤ بالشركات المتعثرة والغير متعثرة مالياً، خلال الفترتين (ت-١، ت-٢).

جدول (١١) قياس أداء نماذج الدراسة

النماذج	(١) : الفترة (ت-١)			(ب) : الفترة (ت-٢)		
	التمان ٢٠١٦	الانحدار اللوجستي	الشبكات العصبية	التمان ٢٠١٦	الانحدار اللوجستي	الشبكات العصبية
مقياس (F)	٧٠.٧	٨٠.٠	٨٥.٨	٤٦.٢	٧٢.٩	٨٩
المساحة أسفل المنحني (AUC)	٠.٧٧	٠.٨٩	٠.٩٦٩	٠.٧٤	٠.٨١	٠.٩٤٨
معامل ارتباط جيني	٠.٥٤	٠.٧٨	٠.٩٣٨	٠.٤٨	٠.٦٢	٠.٨٩٦
اختبار كولموجوروف سميرنوف (KS-Z)	١.٥٩١	٢.٠١٢	٢.١٤٠	١.٢٥٥	١.٤٦٣	٢.١٩٥
	(٠.٠١٣)	(٠.٠٠١)	(٠.٠٠٠)	(٠.٠٩٩)	(٠.٠٢٨)	(٠.٠٠٠)

ملحوظة : يشمل نموذج التنبؤ النسب المالية الأربعة (العائد على الاستثمار، رأس المال العامل لإجمالي الأصول، صافي التدفق النقدي لإجمالي الالتزامات المالية، هامش الربح التشغيلي)، والفترة (ت-١) قبل حدث التعثر لمدة عام، الفترة (ت-٢) قبل حدث التعثر لمدة عامين.

يتضح من الجدول (١١) الجزء (١) أنه يحقق نموذج الشبكات العصبية متعددة الطبقات (MLP) خلال فترات التنبؤ (ت-١) و (ت-٢) أعلى أداء للتنبؤ بالتعثر المالي مقارنة بكل من نموذج الانحدار اللوجستي ونموذج Altman Z-score 2016 المعدل وفقاً لنتائج استخدام مقاييس الأداء الأربعة، حيث أنه يحقق أعلى قيمة لمقياس (F) مما يشير إلى أن نموذج الشبكات العصبية يحقق أعلى (حساسية) قدرة على تصنيف الشركات المتعثرة وكذلك للمساحة أسفل

المنحني (AUC) والتي تساوي (٠.٩٨١) ، كما أنه يحقق أعلى قيمة لمعامل ارتباط جيني للنموذج Gini rank coefficient حيث تقترب قيمته من الواحد الصحيح (٠.٨٩٦) خلال الفترة (ت-١) وكذلك (٠.٩٣٨) خلال الفترة (ت-٢) ، بالإضافة إلى أنه يحقق أعلى قيمة لـ (Z) الناتجة عن اختبار كولمغوروف سميرونوف (KS-Z) حيث يحقق فرق معنوي قوي بين منحيي التوزيع الاحتمالي التراكمي Cumulative Distribution function عند مستوى معنوية ($P\text{-value} < 0.001$) لمجموعتي الشركات عينة الدراسة ، كما يلاحظ أن نموذج -التمان (٢٠١٦) المعدل- يحقق مستوى أداء مقبول وفقا لنتائج مقاييس الأداء الأربعة المستخدمة خلال الفترة (ت-١) ، حيث تتعدى قيمة معامل ارتباط جيني (٠.٥٠) ، بالإضافة إلى أنه يحقق فرق معنوي بين منحيي التوزيع الاحتمالي التراكمي CDF لمجموعتي الشركات عينة الدراسة عند مستوى معنوية ($P\text{-value} < 0.05$) ، وإن كان أقل النماذج في مستوى الأداء وفقا للمقاييس الأربعة المستخدمة.

كما يلاحظ من الجزء (ب) بالجدول (١٠): أنه يحتفظ نموذج الشبكات العصبية المتعددة الطبقات (MLP) بتحقيق أعلى أداء خلال الفترة (ت-٢) مقارنة بجميع النماذج الأخرى ، حيث تحقق فرق معنوي قوي بين منحيي التوزيع الاحتمالي التراكمي CDF لمجموعتي الشركات المتعثرة وغير متعثرة بعينة الاختبار عند مستوى معنوية ($P\text{-value} < 0.001$) وأعلى قيمة لـ (Z) وفقا لنتائج اختبار KS-Z ، كما أنه يحقق نموذج الشبكات العصبية أعلى قيمة للمساحة أسفل المنحني AUC (٠.٩٤٨) ، وكذلك أعلى قيمة لمعامل ارتباط جيني ، بالإضافة إلى أنه أكثر النماذج حساسية للشركات المتعثرة ماليا وفقا لمقياس (ف) ، كما يلاحظ أن نموذج -التمان ٢٠١٦ المعدل- يحقق أداء ضعيف (غير مقبول) حيث تنخفض قيمة معامل ارتباط جيني عن (٠.٥) ، كما أنه وفقا لنتائج اختبار (KS-Z) لا يحقق نموذج التمان ٢٠١٦ المعدل فرق معنوي بين منحيي التوزيع الاحتمالي التراكمي ($P\text{-value} > 0.05$) ، مما يشير إلى أن نموذج -التمان ٢٠١٦ المعدل- أداء مقبول على المدى القصير فقط خلال الفترة (ت-١).

ويلاحظ أيضا انخفاض أداء نموذج الانحدار اللوجستي (LR) خلال الفترة (ت-٢) بشكل ملحوظ إلا أنه لا يزال يحقق أداء مقبول وفقا لمقاييس الأداء الأربعة ، حيث تشير النتائج إلى أن أداء نموذج الشبكات العصبية يعتبر أكثر النماذج استقرارا خلال فترات التنبؤ وتتفق هذه النتيجة مع الدراسات السابقة مثل دراسة (Altman et al., 2016; Ciampi and Gordini, 2013).

إحدى عشر: ملخص النتائج

- توجد علاقة معنوية قوية بين نسبة الربحية (العائد على رأس المال المستثمر) واحتمال التعثر المالي للشركات حيث تعكس بدورها قدرة الشركة على تحقيق أرباح كافية للوفاء بالتزاماتها المالية ، كما توجد أيضا علاقة معنوية قوية بين (نسبة رأس المال العامل لإجمالي الأصول) واحتمال التعثر والتي تعكس مستوي السيولة (قدرة الشركة على سداد الالتزامات المالية قصيرة الأجل ومرونة هيكل رأس المال بالشركة).

- تتفوق الشبكات العصبية الاصطناعية ذات خاصية الانتشار الخلفي المتعددة الطبقات، على كلا من نموذج التمان ٢٠١٦ (التحليل التمييزي) ونموذج الانحدار اللوجستي خلال فترات التنبؤ (مدة عامين) بالتعثر المالي للشركات عينة الدراسة، حيث يتميز باستقرار الأداء والذي ينعكس في انخفاض معدلات الخطأ خاصة خطأ النوع الأول الذي يشكل تكلفة أعلى عند مقارنة بخطأ النوع الثاني.

- يحقق نموذج التمان Z-score المعدل (٢٠١٦) أداء مقبول في التنبؤ بالتعثر المالي للشركات عينة الدراسة على المدى القصير فقط (مدة عام قبل حدوث التعثر)، ولكن أداء النموذج غير مستقر على المدى البعيد (أكثر من عام) حيث يحقق معدلات خطأ غير مقبولة.

- ضرورة الاهتمام بمعمارية الشبكة العصبية من دورات تدريب ومعدل تعلم والطبقات الخفية والخلايا العصبية بها نظرا لتأثيرها البالغ في دقة نموذج الشبكات العصبية ومن ثم دقة التنبؤ بالحالة المالية للشركات وتقييم الائتمان.

اثني عشر: التوصيات

في ضوء نتائج قياس المتغيرات المؤثرة في التنبؤ بالتعثر المالي للشركات عينة الدراسة ، توصى الدراسة بما يلي:

- في ضوء نتائج الدراسة يتعين على الإدارات المالية بالشركات متابعة معدلات الربحية التي تحققها الشركة على مدار الوقت نظرا لأهميتها في قدرة الشركات على جذب الأموال اللازمة لتمويل أنشطتها والتوسع في استثماراتها ، خاصة أنها تتميز بمعدلات أعلى للنمو من الشركات الكبيرة الحجم وفقا لنظرية دورة حياة الشركات.

- استخدام استراتيجيات تأخذ في الاعتبار بالتبادل التجاري وكذلك الائتمان التجاري بين الشركات الصغيرة والمتوسطة لتغطية العجز في رأس المال العامل لهذه الشركات.

- استخدام تقنيات الذكاء الاصطناعي في التحليل المالي ونظم دعم القرار داخل إدارة الشركات لما لها من عظيم الأثر في دقة الأداء وانخفاض تكاليف الخطأ الناتجة عن استخدامها.

- ضرورة قيام مؤسسات الاقراض للشركات الصغيرة والمتوسطة بالتركيز على عملية التحليل المالي للمعلومات والبيانات عن حالة الشركة المتوقعة فضلا عن عدم التركيز على الضمانات العينية والنقدية لأن ذلك سوف يتمشى مع طبيعة الحال بمرحلة دورة حياة هذه الشركات، كما يساعد على خلق القدرة لدى إدارة الائتمان نحو نضج القرار الائتماني بالاعتماد على أساليب الذكاء الاصطناعي لما لها من فائدة عظيمة وقدرة تنبؤية مرتفعة.

- قيام الهيئة العامة للرقابة المالية والمركز المصري للدراسات الاقتصادية، بإنشاء قاعدة بيانات تضم بيانات عن الأداء الائتماني للشركات ومؤشرات عن السندات المتعثرة وقروض البنوك والدراسات الدورية في مجال التقييم المالي للشركات والمخاطر الائتمانية، مثل قاعدة بيانات التمان بجامعة نيويورك بالولايات المتحدة الأمريكية The Altman NYU Salomon Center Defaulted Debt Performance Index.

المراجع

- Agostini, M. (2018). Corporate Financial Distress, Going Concern in Both International and U.S. Contexts, Palgrave, Macmillan.
- Alifah, M.N. (2013). Prediction of Financial Distress Companies in The Trading and Services Sector in Malaysia Using Macroeconomic Variables. Procedia – Social and Behavioral Sciences, Vol. 129 pp. 90-98.
- Altman, E.I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. The Journal of Finance, Vol. 23 4 pp. 589-609.
- Altman, E.I. , Sabato, G., and Wilson, N. (2010). The Value of Non-Financial Information in Small and Medium-Sized Enterprise Risk Management. The Journal of Credit Risk, 6, 1-33.

- Altman, E.I., Iwanic-Drozowska, M., Laitinen, E.K. and Suvas, A. (2016). Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's Z-Score Model. Journal of International Financial Management & Accounting, Vol. Issue 2016 pp. 1-41.
- Amendola, A., Restaino, M. and Sensini, L. (2014). An Analysis of The Determinants of Financial Distress in Italy: A Competing Risk Approach. International Review of Economics and Finance, Vol. 37 pp. 33-41.
- Beaver, W.H. (1966). Financial Ratios as Predictors of Failure. Journal of Accounting Research, Vol. 4 pp. 71-111.
- Bhimani, A., Gulamhussen, M.A. and Lopes, S.D. (2013). The Role of Financial, Macroeconomic, and Non-Financial Information In Bank Loan Default Timing Prediction. European Accounting Review, 22:4, 739-763.
- Charalambakis, E.C. (2015). On The Prediction of Corporate Financial Distress in The Light of Financial Crisis: Empirical Evidence Greek Listed Firms. International Journal of the Economics of Business, Routledge, ISSN: 1357-1516, pp. 1466-1829.
- Charalambakis, E.C. and Garrett, I. (2014). On The Prediction of Financial Distress in Developed and Emerging Markets: Does The Choice of Accounting and Market Information Matter? A Comparison of UK and Indian Firms. Review of Quantitative Finance and Accounting, Springer.
- Chen, M.(2011). Predicting Corporate Financial Distress Based on Integration of Decision Tree Classification and Logistic Regression. Expert Systems with Applications, Vol. 38 pp. 11261-11272.
- Ciampi, F. (2014). Corporate Governance Characteristics and Default Prediction Modeling for Small Enterprises An Empirical analysis of Italian Firms. Journal of Business Research, Elsevier.
- Ciampi, F. and Gordini, N. (2013). Small Enterprise Default Prediction Modeling Through Artificial Neural Networks: An Empirical Analysis of Italian Small Enterprises. Journal of Small Business Management, Vol. 51 1 pp. 23-45.
- Cinca, C. S., Nieto, B. G. (2012). Partial Least Square Discriminant Analysis For Bankruptcy Prediction. Decision Support Systems, 54, 1245-1255.
- Duan, J.C., Sun, J. and Wang, T. (2012). Multi-period Corporate Default Prediction—A Forward Intensity Approach. Journal of Econometrics, Vol. 170 pp. 191-209.
- Hu, H. (2011). A Study of Financial Distress Prediction of Chinese Growth Enterprises. DBA, University of Canberra.
- Jantadej, P. (2006). Using The Combination of Cash Flow Components to Predict Financial Distress. Lincoln, Nebraska.
- Keasey, K. and Watson, R. (1991). Financial Distress Prediction Models: A Review of Their Usefulness. British Journal of Management, Vol. 2, 89-102.
- Kunter, M. H., Nachtsheim, C. J. and Neter, J. (2004). Applied Linear Regression Models. 4th edition. McGraw-Hill Irwin.
- Lee, S., Choi, W.S. (2012). A Multi-Industry Bankruptcy Prediction Model Using Back-Propagation Neural Network and Multivariate Discriminant Analysis. Expert Systems with Applications, Vol. 40: 2941-2946.

- Löffler, G. and Posch, P. (2011). *Credit Risk Modeling Using Excel and VBA*. Second Edition, Wiley Finance.
- Mensah, Y. (1984). An Examination of The Stationarity of Multivariate Bankruptcy Prediction Models: A Methodological Study. Journal of Accounting Research, 22 (1), pp. 380-395.
- Modina, M. and Pietrovito, F. (2014) A Default Prediction Model For Italian SMEs: The Relevance of Capital Structure. Applied Financial Economics, Vol. 24, No. 23, pp. 1537-1554.
- Odam, M.D. and Sharda, R. (1990). A Neural Network Model for Bankruptcy Prediction. International Joint Conference on Neural Network, San Diego, USA.
- Ohlson, J.A. (1980). Financial Ratios and the Probabilistic Prediction of Bankruptcy. Journal of Accounting Research, Vol. 18 1 pp. 109-131.
- Orth, W. (2013). Multi-Period Credit Default Prediction With Time-Varying Covariates. Journal of Empirical Finance, Vol. 21 pp. 214-222.
- Peat, M. and Jones, S. (2012). Using Neural Nets to Combine Information Sets In Corporate Bankruptcy Prediction. Intelligent Systems in Accounting, Finance and Management, Vol. 19, Issue , John Wiley & Sons.
- Qi, M., Zhang, X. and Zhao, X. (2014). Unobserved Systematic Risk Factor and Default Prediction. Journal of Banking & Finance, Vol. 49 pp. 216-227.
- Ridders, F. and Thibault, A.E. (2011). Default Prediction of Small and Medium-Sized Enterprises with Industry Effects. International Journal of Banking, Accounting and Finance, Vol. 3, Nos. 2/3.
- Schmuck, M. (2013). *Financial Distress and Corporate Turnaround, An Empirical Analysis of The Automotive Supplier Industry*. Galber, Verlag.
- Shumway, T. (2001). Forecasting Bankruptcy More Accurately: A Simple Hazard Model. The Journal of Business, Vol. 74, No 1 pp. 101-124.
- Sun, J., Li, H. (2010). Dynamic Financial Distress Prediction in Using Instance Selection For The Disposal of Concept Drift. Expert Systems with Applications, Vol. 38 pp. 2566-2576.
- Tinoco, M.H., Wilson, N. (2013). Financial Distress and Bankruptcy Prediction among Listed Companies using accounting, market and macroeconomic variables. International Review of Financial Analysis, Vol. 30 pp. 394-419.
- Tserng, H.P., Chen, P., Huang, W., Lei, M.C., Tran, Q.H. (2014). Prediction of Default Probability for Construction Firms Using The Logit Model. Journal of Civil Engineering and Management, Vol. 20(2): 247-255.
- Wolter, M., Rosch, D. (2014). Cure Events In Default Prediction. European Journal of Operational Research, Vol. 238 Issue 3.
- Zhou, L., Lu, D., and Fujita, H. (2015). The Performance of Corporate Financial Distress Prediction Models With Features Selection Guided by Domain Knowledge and Data Mining Approaches. Knowledge-Based Systems, 85, 52-61.

