



التنبؤ بالتعثر المالي للشركات المصرية المساهمة الصغيرة والمتوسطة باستخدام تقنيات الذكاء الاصطناعي (دراسة تطبيقية)

د. ميسره أحمد فاضل

مدرس إدارة الأعمال

معهد الدلتا العالي لنظم المعلومات الادارية والمحاسبية

ملخص الدراسة

تهدف هذه الدراسة للوصول إلى نموذج للتنبؤ بالتعثر المالي للشركات المساهمة الصغيرة والمتوسطة باستخدام المؤشرات المالية المشتقة من القوائم المالية للشركات والتي تعكس الربحية والسيولة والسلامة المالية ، ومن ناحية أخرى ، تم إجراء مقارنة بين كل من نموذج الشبكات العصبية الاصطناعية Artificial Neural Network ونموذج ألتمان 2016 المعدل ، كأحد نماذج التنبؤ التقليدية الرائدة والشائع استخدامها بالدراسات البحثية السابقة ، لتحديد مدى التحسن في أداء نموذج التنبؤ بالتعثر المالي ، بالنسبة لاستخدام أحد تقنيات الذكاء الاصطناعي ، 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 نموذج الشبكات العصبية الاصطناعية ANNs، ونموذج ألتمان 2016 المعدل ، تتفوق الشبكات العصبية الاصطناعية المتعددة الطبقات على نموذج ألتمان 2016 المعدل خلال فترات التنبؤ كاملة، كما يتميز باستقرار أدائه على المدى البعيد (قبل حدث التعثر بمدة عامين). كما تؤكد نتائج استخدام عينة الاختبار ومقاييس الأداء النتائج التي توصلت إليها الدراسة.

Abstract:

This study, using artificial neural networks, assesses the role of financial ratios in predicting financial distress among Egyptian small and medium-sized firms (SMEs). In addition, this study applied Altman Z''-score on the firms of the study sample. Our empirical findings reveal that combining firms' financial indicators (profitability, liquidity, and solvency) increases the accuracy of predicting financial distress among firms of this kind. Moreover, in a comparison we also assess the predictive accuracy of multilayer perceptrons (MLPs) to other traditional statistical techniques. According to the benchmarking results of Altman Z''-score and MLP model, the neural network model (MLPs) outperforms Altman Z''-score as regards the predictive accuracy of the out-of-sample set.

أولاً: تمهيد

يمثل قطاع الشركات الصغيرة والمتوسطة محركاً أساسياً للتنمية الاقتصادية والاجتماعية في الكثير من دول العالم (Modina, 2015; Ridders and Thibeault, 2012)، كما تشير الإحصاءات إلى أن هذا القطاع من الشركات يصل إلى 90% من إجمالي قطاع الأعمال في معظم اقتصاديات العالم (عبد الحميد وعبود ، 2016) ، فضلاً عن أن نمو هذا القطاع يعتبر مؤشراً هاماً لتطور سوق رأس المال المتعدد المستويات في مصر، نظراً لكونه يعبر عن مدي التوسع الأفقي والرأسي لهذا السوق (Hu, 2011) ، كذلك يتميز هذا القطاع من الشركات بمعدلات نمو سريعة ، الأمر الذي يجعل الهيكل التمويلي والميزة التنافسية لمثل هذه الشركات أكثر عرضة للمخاطر نتيجة للتحديات العديدة والقوي العالمية المتزايدة التي تواجهها، حيث أشادت لجنة بازل (2) في منتصف التسعينات بضرورة سعي المؤسسات المالية نحو اشتقاق نماذج لتقييم المخاطر المالية والتنبؤ بخطر التعثر المالي والإفلاس للشركات الصغيرة والمتوسطة على وجه الخصوص (Altman et al. 2019).

وعلى هذا النحو يعد التحقق من سلامة هذه الشركات وقدرتها على الاستمرار أمراً هاماً، مما يعزز دور نماذج إدارة المخاطر في الكشف عن المخاطر والصعوبات المالية المحتملة التي تواجه هذه الشركات (Chaudhuri and Gosh, 2017) ، بما يساعد الإدارات على تحقيق التوازن بين العائد والخطر الناتج عن الإستثمار في مثل هذه الشركات وبالتالي تعظيم قيمتها السوقية، وجعلها أكثر جذباً للمستثمرين ومن ثم إتاحة الفرصة أمامها للحصول على التمويل اللازم (Guido, 2017) ، فضلاً عن أنه التنبؤ بخطر التعثر المالي للشركات بشكل فعال يساعد على خفض مخاطر الائتمان والحفاظ على اقتصاد الدولة وتجنب الخسائر المستقبلية وحدوث الأزمات (Agostini, 2018; Lee and Choi, 2013)، حيث يمثل ذلك حافزاً أساسياً للعديد من الدراسات البحثية لتطوير كفاءة نماذج التنبؤ بالتعثر المالي للشركات (Lahiani et al. 2017; Chen, 2011). ونتيجة لاعتماد معظم الدراسات السابقة في بناء نماذج التنبؤ على عينة بيانات تغطي فترة زمنية محددة وأيضا 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 وفقا 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).

ويعد ذلك التطوير باستخدام تقنيات الذكاء الاصطناعي (الشبكات العصبية) التي تتغلب على مشكلة فرض تماثل توزيع البيانات محل التنبؤ كما هو الحال بالأساليب الإحصائية التقليدية والتي لا تستطيع التعامل الا 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 لنفادي الخسائر التي تتحملها الدولة والمجتمع والنتيجة عن التعثر المالي للشركات.

ثانياً: الدراسات البحثية السابقة

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

كما 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 وغير 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 وغير متعثرة مالياً بـ **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 وغير 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، 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 مالياً 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 والتحليل التمييزي MDA لبناء نموذج للتنبؤ بالتعثر المالي للشركات الصغيرة في إيطاليا، وأظهرت النتائج أن نموذج الشبكات العصبية BPNN كان متفوقاً على كل نموذج التحليل التمييزي MDA.

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 بالتعثر 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. وفي 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 بنموذج ألتمان 2016 المعدل كأحد نماذج التحليل التمييزي المتعدد والتقليدية؟

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 100 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 وفقا لنوع النشاط وحجم الأصول، وتحتوى عينة الدراسة على مجموعتين من الشركات: (المجموعة الأولى) الشركات الغير متعثرة ماليا بمتوسط قيمة الأصول (124.965.316) جنبيها وتشمل بيانات تغطي نفس الفترة للشركات المتعثرة ماليا (المجموعة الثانية) بمتوسط قيمة الأصول (94.223.356) جنبيها والتي تتوافر بها شروط حالة التعثر في الفترة (2015-2016) , حيث تم الأخذ في الاعتبار عند اختيار مجموعتي الشركات عينة الدراسة أن تكون متجانسة بقدر المستطاع , وتمثل نسبة الشركات المتعثرة ماليا إلى الشركات الغير متعثرة بعينة الدراسة 44% حيث تمثل عدد الشركات المتعثرة 29 شركة بينما عدد الشركات غير المتعثرة ماليا 37 شركة، كما يعرض الجدول (1) وصف لعينة الدراسة ونسبة الشركات بكل مجموعة من عينة الدراسة وفقا لنوع النشاط.

وفي ضوء أهداف الدراسة تم تقسيم العينة الاجمالية إلى عينة التدريب والتقدير Estimation Sample بنسبة (70% من إجمالي العينة) حيث تستخدم في بناء النموذج وتقدير معاملات، وعينة الاختبار Validation Sample والتي تمثل نسبة (30% من إجمالي بيانات عينة الدراسة) بغرض اختبار نماذج الدراسة وقياس أدائها.

يصف الجدول (1) الشركات عينة الدراسة من حيث نوع النشاط وفقا لتصنيف النشاط المستخدم بالبورصة المصرية، حيث تنقسم الشركات عينة الدراسة إلى خمسة أنواع (رعاية صحية، خدمات، تجزئة، تشييد وبناء، تصنيع).

جدول (1) وصف عينة الدراسة (نوع النشاط)

النشاط الشركات	الشركات المتعثرة		الشركات الغير متعثرة	
	العدد	النسبة (%)	العدد	النسبة الاجمالية (%)
رعاية صحية	5	17.2	7	18.9
خدمات	4	13.8	3	8.1
تجزئة	2	6.9	2	5.4
تشييد و بناء	6	20.6	8	21.6
تصنيع	12	41.4	17	45.9
الاجمالي	29	%100	37	%100

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، وأحد تقنيات الذكاء الاصطناعي (الشبكات العصبية الاصطناعية) لبناء نماذج التنبؤ بالتعثر المالي. كما يتم التنبؤ باحتمال التعثر المالي خلال فترتين وهما (ت-1، ت-2)، أي قبل عام أو عامين من حدث التعثر، بالإضافة إلى ذلك، مقارنة الأداء بين نموذج الشبكات العصبية ومن الناحية الأخرى تطبيق نموذج ألتمان 2016 المعدل على عينة الاختبار ومقارنة أدائه بنموذج الدراسة بغرض تحديد مدى التحسن في أداء نموذج التنبؤ بالتعثر المالي.

1- الأساليب المستخدمة في بناء نماذج الدراسة وتقدير معاملاتها

في ضوء ما تم عرضه من الدراسات البحثية السابقة، يعتبر التحليل التمييزي المتعدد بصفه عامة ونموذج التمان z-score بصفة خاصة أكثر الأساليب المستخدمة في التنبؤ بالتعثر المالي، وفيما يلي عرض لكل منهما:

1/1- التحليل التمييزي Discriminant Analysis

يستخدم التحليل التمييزي لتصنيف الحالات والتنبؤ بها داخل مجموعات مختلفة من خلال تحديد الخصائص (المتغيرات) التي تساعد على التمييز بينهما والوصول الى مجموعة من الخصائص تكون فيما بينها توليفة خطية وتعرف هذه التوليفة باسم دالة التمييز الخطية Linear Discriminant function ويعتبر نموذج التحليل التمييزي أبسط الاساليب التي يمكن استخدامها للتمييز بين المجموعات المختلفة، كما أنه يعد أكثر الطرق التقليدية استخداما في بناء نماذج التنبؤ بالتعثر المالي والافلاس، وفيما يلي معادلة التحليل التمييزي:

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n \quad \text{معادلة رقم (1):}$$

حيث إن:

(y) المتغير التابع: الحدث (الحالة) المراد التنبؤ بها أو تصنيفها.

(b) معاملات دالة التمييز.

(x) المتغيرات المستقلة المستخدمة في دالة التمييز، (b₀) ثابت.

تعتمد دالة التحليل التمييزي في تقديرها على طريقة المربعات الصغرى Ordinary Least Squares، ويشمل التحليل التمييزي خطوتين أساسيتين: (الأولى) اختبار (ف) Wilks' lambda ويستخدم لاختبار مستوى المعنوية لنموذج التمييز ككل، (الثانية) في حال كان نموذج التمييز ذو دلالة احصائية معنوية يتم تقييم كل متغير مستقل بالنموذج على حده لتحديد أي المتغيرات يحقق فرق معنوي في المتوسط لتصنيف المتغير التابع، كما يفضل استخدام التحليل التمييزي عندما تتوافر بعض الافتراضات أهمها: (التوزيع الطبيعي للبيانات أو تساوي مصفوفة التباين المشترك للمجموعات عينة الدراسة)، وذلك للحصول على أداء مقبول للنموذج.

2- 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 وغير المتعثرة ماليا بعينة الدراسة، وعادة تستخدم هذه الاساليب مجتمعة معا وليس بمعزل عن بعضهم البعض كما جاء بالدراسات البحثية السابقة، وتشمل الأساليب التالية:

- مقياس (ف) F-measure

يصف مقياس (ف) - أيضا يسمى بمقياس الكفاءة Effectiveness Measure- أداء النموذج لتصنيف الشركات في المدى بين حساسية النموذج ومعدل التنبؤ الايجابي الصحيح، ويتميز مقياس (ف) بأنه يجمع بين قياس معدل التنبؤ الايجابي الصحيح للنموذج وحساسية النموذج (Chen, 2011)، حيث أن معدل التنبؤ الايجابي الصحيح يعكس النسبة الصحيحة للشركات التي تم تصنيفها كشركات متعثرة من إجمالي الشركات التي تم تصنيفها كشركات متعثرة باستخدام

التنبؤ بالتعثر المالي للشركات المصرية المساهمة الصغيرة والمتوسطة باستخدام تقنيات الذكاء الاصطناعي (دراسة تطبيقية)
المعادلة رقم (2)

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

النموذج، ويستخدم مقياس (ف) في تقييم الأداء العام للنموذج في التنبؤ بالشركات المتعثرة، حيث يتم حسابه كما يلي:
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 (0.50) و (1.0).

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 بمنحنى لورينز Lorenz Curve , حيث أن أسلوب المساحة أسفل المنحني (AUC) يقوم على حساب المساحة بالكامل , ويكون الأداء مقبول عندما يساوي معامل ارتباط جيني (0.50) أو أعلى، وفي حالة انخفاض قيمته عن (0.50) 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:

المعادلة رقم (3): $\text{Gini Rank Coefficient} = (2 * \text{AUC}) - 1$

حيث تتراوح قيمته ما بين الصفر والواحد الصحيح، فكلما اقتربت قيمة معامل جيني من الواحد الصحيح كلما كان أداء النموذج جيد.
- كولمجوروف سميرنوف Kolmogorv 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، وفقاً لهذا الأسلوب كلما زادت قيمة زد (Z) وكانت ذات دلالة احصائية معنوية كان ذلك مؤشراً جيداً لأداء النموذج المستخدم في التمييز بين مجموعتي الشركات عينة الدراسة، وفي حالة انخفاض قيمة (Z) ووجود دلالة احصائية غير معنوية يكون ذلك مؤشراً لانخفاض أداء النموذج وعدم قدرته على التمييز بين مجموعتي الشركات عينة الدراسة.

3- متغيرات الدراسة وطرق قياسها

1/3- المتغيرات المستقلة :

تتكون المتغيرات المستقلة المستخدمة في التنبؤ من مجموعة من المؤشرات 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 (2) المتغيرات المستقلة التي تم اختيارها في ضوء الدراسات السابقة وطريقة قياسها ومدلولاتها:

جدول (2) 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 إجمالي 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):

نظرا للانتقادات التي وجهت لاستخدام الإفلاس كمعيار لتحديد الحالة المالية أو الفئة التي تقع فيها الشركة (Jantaej, 2006) , حيث أشارت دراسة (Shumway, 2001) إلى أنه قد تواجه الشركات الخطر المالي للعديد من السنوات قبل الإفلاس وقد تفلس 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 الانذار 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 2016 , بعد تعديل معاملات الارتباط للنموذج باستخدام العينة الكلية بالدراسة (31 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 ألتمان المعدل أداء أفضل لتصنيف الشركات المتعثرة بالعينة الأولى مقارنة بأدائه للتصنيف بالعينة الثانية (عند استخدام معيار الشطب والإفلاس) 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 ادراجها ضمن الشركات المفلسة. كما أنه في معظم الاحيان 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 الانذار المبكر لحدث التعثر المالي) وفي حدود البيانات المتاحة، تم استخدام المعايير (التالية) في هذه الدراسة لتحديد حدث التعثر المالي:

- تحقق الشركة خسائر مالية لمدة عاميين 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 (1) عندما تتوافر المعايير السابقة بالشركات حيث تكون الشركات متعثرة ماليا , ورقم (صفر) للشركات الغير متعثرة ماليا والتي لا تقابل أيأ 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 (3) 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	0.227	0.635	3.146	0.003	4.244-	0.000
السيولة السريعة	9.565	0.003	2.284	0.028	2.991-	0.003
رأس المال العامل	1.434	0.236	3.343	0.001	3.359-	0.001
العائد على حقوق الملكية	5.155	0.027	4.271	0.000	5.019-	0.000
العائد على الأصول	6.088	0.016	5.182	0.000	4.845-	0.000
هامش الربح الإجمالي	0.067	0.796	3.068	0.004	2.913-	0.004
هامش الربح التشغيلي	1.555	0.217	3.649	0.001	4.398-	0.000
العائد على رأس المستثمر	2.872	0.095	4.656	0.000	5.033-	0.000
صافي التدفق النقدي للأصول المتداولة	1.320	0.255	3.803	0.000	3.353-	0.001

تظهر نتائج اختبار ليفين بالجدول (3) تساوي مصفوفة التباين المشترك لأغلب النسب المالية فيما عدا نسبة (السيولة السريعة، العائد على حقوق الملكية، هامش الربح الإجمالي) حيث يقل مستوى المعنوية عن (0.05) الناتج عن قيمة (ف) للاختبار، 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 وغير المتعثرة بعينة الدراسة.

تحديد العلاقات الارتباطية بين المتغيرات والمشكلات الإنحدارية Multicollinearity

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 إنحدارية 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 الإنحدارية بين المتغيرات المستقلة المستخدمة بالنموذج حيث يعتمد معامل تضخم التباين على نسبة التغير التي يشترك فيها متغيرين مستقلين أو أكثر بالنموذج، ويعرض الجدول (4) نتائج اختبار معامل ارتباط بيرسون ومعامل تضخم التباين:

جدول (4) مصفوفة الارتباط ومعامل تضخم التباين

صافي التدفق النقدي	العائد على رأس المال المستثمر	هامش الربح التشغيلي	هامش الربح الإجمالي	العائد على الأصول	العائد على حقوق الملكية	رأس المال العامل	السيولة السريعة	صافي التدفق النقدي	
									صافي التدفق النقدي
									1
						1	**0.327 0.004		السيولة السريعة
						1	**0.685 0.000		رأس المال العامل
				1	**0.310 0.006	0.155 0.106	**0.483 0.00		العائد على حقوق الملكية
			1	**0.850 0.000	**0.365 0.002	*0.267 0.015	**0.582 0.000		العائد على الأصول
			1	**0.452 0.000	**0.424 0.000	0.183. 0.070	*0.277 0.012	**0.496 0.000	هامش الربح الإجمالي
		1	**0.670 0.000	**0.597 0.000	**0.500 0.000	*0.265 0.016	*0.253 0.021	**0.529 0.000	هامش الربح التشغيلي
	1	**0.539 0.000	**0.407 0.000	**0.889 0.000	**0.958 0.000	**0.325 0.004	0.196 0.057	**0.497 0.000	العائد على الاستثمار
1	**0.410 0.000	**0.468 0.000	**0.457 0.000	**0.444 0.000	**0.400 0.000	0.114 0.182	*0.208 0.047	**0.807 0.000	صافي التدفق النقدي
0.597	0.070	0.414	0.281	0.113	0.049	0.254	0.370	0.495	TOLنسبة التفاوت
1.674	14.399	2.415	3.553	8.869	20.477	3.933	2.704	2.018	معامل تضخم التباين VIF

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

تظهر نتائج الاختبار بالجدول السابق وجود بعض المتغيرات المستقلة ذات علاقة ارتباطية قوية حيث تتعدى قيمة معاملات الارتباط لها (80%) 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 (10) وقد يرجع ذلك إلى أن كلاهما يعكس الربحية، وكذلك حيث أشارت بعض الدراسات إلى أنه يجب أن لا تتعدى قيمة معامل تضخم التباين عن (10) مثل دراسة (Kutner et al. (2004، كما أشار (Shumway, 2001) إلى أنه لا يجب أن تتعدى (5) ، في حين أن بعض الدراسات مثل دراسة (Ciampi, 2014; Ciampi and Gordini, 2013) استبعدت المتغيرات ذات قيمة معامل تضخم التباين (VIF) التي تتعدى (3)، كما استخدمت بعض الدراسات مثل (Shmuck, (2013 المتغيرات ذات قيمة لن تتعدى (2) 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 (5).

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 المؤشرات المالية المستخدمة في النموذج، حيث تشترك المؤشرات المالية المتبقية في قياس نفس نواحي الأداء ويعرض الجدول (5) نتائج استخدام الطريقتين:

جدول (5) نتائج استخدام الاختيار الأمامي والاختيار الخلفي

الاختيار الخلفي		الاختيار الأمامي		الطريقة النسب
مستوي المعنوية	قيمة (ت)	مستوي المعنوية	قيمة (ت)	
0.021	2.375-	0.008	2.747-	صافي التدفق النقدي لإجمالي الالتزامات
0.014	2.544-	0.041	2.090-	رأس المال العامل لإجمالي الأصول
0.021	2.371-	--	--	هامش الربح التشغيلي
0.031	2.207-	0.001	3.376-	العائد على رأس المال المستثمر

يتضح من الجدول السابق أنه تتفق نتائج طريقة الاختيار الأمامي والاختيار الخلفي في تحديد عدد (3) 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 المؤشرات 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 (6) مصفوفة الارتباط ومعامل تضخم التباين للمتغيرات المستخدمة في نموذج الدراسة.

جدول (6) مصفوفة الارتباط ومعامل تضخم التباين لمتغيرات الدراسة

المتغيرات	صافي التدفق النقدي	رأس المال العامل لإجمالي الأصول	هامش الربح التشغيلي	العائد على رأس المال المستثمر
صافي التدفق النقدي	1			
رأس المال العامل لإجمالي الأصول	0.112 (0.185)	1		
هامش الربح التشغيلي	0.163 (0.095)	**0.357 (0.002)	1	
العائد على رأس المال المستثمر	*0.217 (0.041)	0.009 (0.472)	**0.403 (0.000)	1
نسبة التفاوت	0.911	0.726	0.721	0.504
معامل تضخم التباين	1.097	1.337	1.387	1.983

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 مستوى 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 (6) أن قيمة معامل تضخم التباين (VIF) لجميع المتغيرات لا تتعدى (2)، مما يشير إلى عدم وجود مشكلات انحدارية بين المتغيرات المستقلة المستخدمة بنموذج الدراسة.

خامسا: الوصف الإحصائي للشركات عينة الدراسة.

يحتوي الجدول (7) 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 (7) الوصف الإحصائي لعينة الدراسة

الحد الأعلى	الحد الأدنى	الانحراف المعياري	الوسيط	الوسط	
(أ) الشركات المتعثرة:					
0.929	5.287-	1.1663	0.014-	0.362	صافي التدفق النقدي لإجمالي الالتزامات المالية
0.752	0.999-	0.32748	0.076	0.0901	رأس المال العامل لإجمالي الأصول
0.407	1.030-	0.029083	0.022	0.289-	هامش الربح التشغيلي
0.324	0.367-	0.100865	0.010	0.0151	العائد على رأس المال المستثمر
(ب) الشركات غير المتعثرة:					
4.214	0.365-	0.933884	0.124	0.451	صافي التدفق النقدي لإجمالي الالتزامات المالية
0.829	0.028-	0.20352	0.300	0.3098	رأس المال العامل لإجمالي الأصول
0.748	0.004	0.16364	0.115	0.1786	هامش الربح التشغيلي
0.387	0.010	0.08994	0.1115	0.1246	العائد على رأس المال المستثمر

يتضح من الجدول (7): 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 (1.176 < 0.934)، (0.327 <

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 غير المتعثرة مالياً مما يعكس الميل الموجب لتوزيع قيم المشاهدات.

أما بالنسبة للشركات غير المتعثرة 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 باستخدام الشبكات العصبية الاصطناعية

تم الاعتماد على عينة التدريب وبناء النموذج In-sample والتي تمثل (70%) من إجمالي البيانات، كما تتكون عينة التدريب المستخدمة في بناء الشبكة العصبية من عدد (43) شركة، وتنقسم إلى مجموعتين من البيانات وهي (فئة التدريب Training، فئة الصلاحية Validation)، وتشمل فئة التدريب عدد (36) شركة، وفئة الصلاحية عدد (7) شركات، وفيما يلي بيانات الشبكة العصبية المستخدمة:

1- 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 (0, 1) 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.

2- طبقة المدخلات: عند إعداد نموذج التنبؤ تم إدخال المتغيرات المستقلة وعددها (4) نسب مالية: (صافي التدفق النقدي لإجمالي الالتزامات المالية، رأس المال العامل لإجمالي الأصول، هامش الربح التشغيلي، العائد على رأس المال المستثمر) والتي تمثل عدد أربعة خلايا بطبقة المدخلات على الترتيب (x_1, x_2, x_3, x_4) .

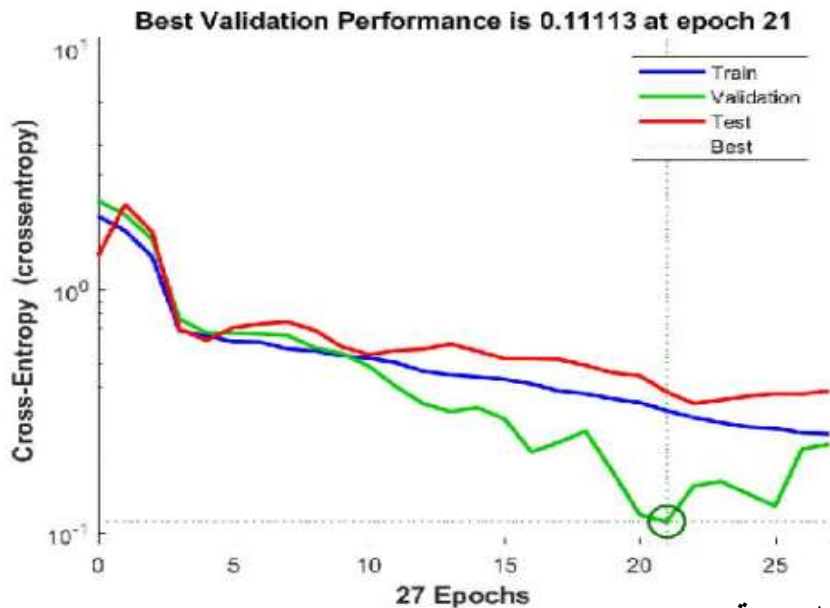
3- الطبقة الخفية: تحتوي هذه الطبقة على العديد من وحدات المعالجة أو الخلايا Neurons حيث تحتوي كل وحدة على دالة تنشيط من النوع Sigmoid وقد تم تحديد عدد وحدات هذه الطبقة بتمرير مجموعة من الشبكات المختلفة على جميع متغيرات الدراسة للوصول إلى أفضل عدد من الطبقات الخفية عن طريق التجربة والخطأ والتي توصلت إلى عدد (2) طبقة خفية , تحتوي الطبقة الأولى على (3) خلايا عصبية والطبق الخفية الثانية على عدد (6) خلايا عصبية كما هو موضح بالشكل رقم (1).

4- طبقة المخرجات: تشمل المتغير التابع وتتكون من عدد (1) خلية، حيث تكون في شكل ثنائي (صفر) للشركات غير المتعثرة مالياً، و (واحد) للشركات المتعثرة.

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

6- 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 (1) أداء عملية التدريب للشبكة العصبية



تدريب الشبكة العصبية

يوضح الشكل (1) 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 الخطأ¹ Cross entropy إلى الأداء الجيد في التصنيف، بينما كلما زاد الخطأ كلما كان أداء التصنيف ضعيف.

¹ Cross entropy error function = $-\sum_{i=0}^n \ln(o_i) * t_i$

هيكل (معمارية) الشبكة العصبية المستخدمة في الدراسة

يوضح الشكل (2) معمارية (هيكل) الشبكة العصبية التي تم التوصل إليها بعد تدريب الشبكة العصبية وتتكون من طبقة المدخلات Input layer والتي تحتوي على عدد 4 خلايا تمثل المتغيرات المستقلة المستخدمة في التنبؤ وتشمل (4) نسب المالية , كما تحتوي الشبكة على عدد (2) طبقة خفية Hidden Layers، تحتوي الطبقة الأولى على عدد (3) خلايا خفية Neurons، بينما تحتوي الطبقة الخفية الثانية على عدد (6) خلايا خفية، وتشمل طبقة المخرجات عدد (1) خلية وتمثل المتغير التابع (نتائج النموذج)، ويأخذ الناتج قيمة (صفر) إذا كانت الشركة غير متعثرة مالياً وقيمة (1) إذا كانت الشركة متعثرة مالياً , كما يوضح الشكل (2) 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 :

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

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

سابعاً: نتائج اختبار صلاحية نماذج الدراسة

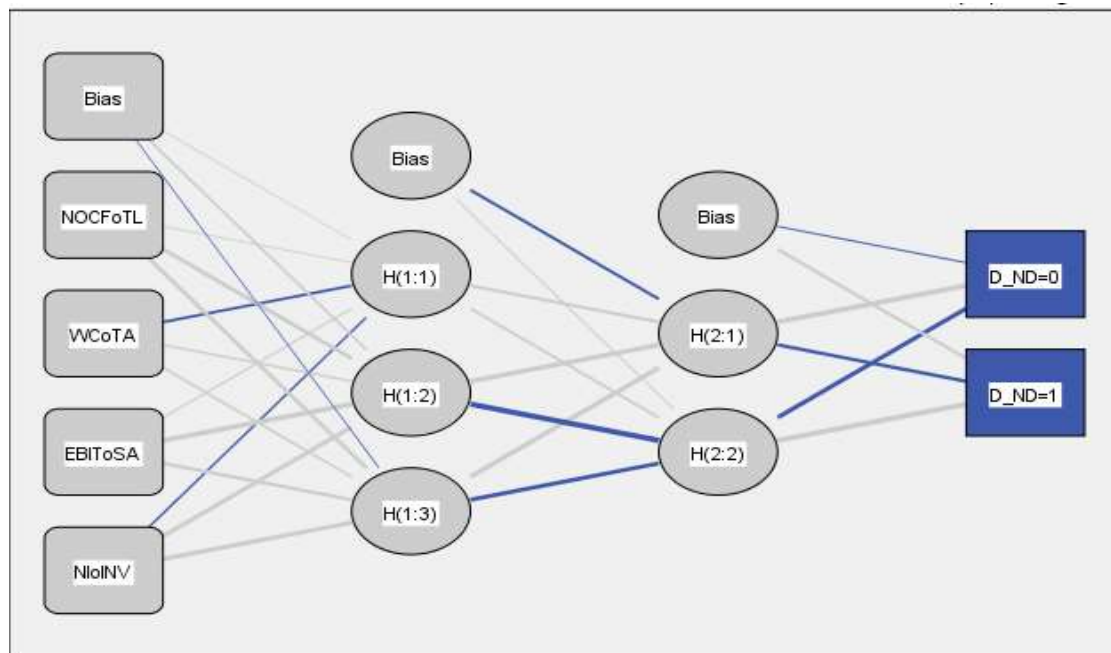
في الجزء السابق تم استخدام عينة التقدير (70% من إجمالي بيانات عينة الدراسة) بغرض بناء نماذج التنبؤ وتقدير معاملاتهما، بالإضافة إلى تحديد أي المتغيرات التي ينتج عن إضافتها تحسن لأداء نموذج التنبؤ بالتعثر المالي. في هذا الجزء تم اختبار أداء نماذج الدراسة باستخدام عينة الاختبار (30% من إجمالي البيانات المستخدمة في هذه الدراسة) من خلال استخدام الاساليب (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 ألتمان Z"-Score المعدل , كأحد النماذج الرائدة والشائعة الاستخدام بالدراسات البحثية السابقة.

يعرض الجدول (9) 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 الشبكات العصبية متعددة الطبقات MLP للمقارنة بنتائج استخدام نموذج ألتمان المعدل.

Where: (n) number of cases.

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

شكل رقم (2) معمارية الشبكة العصبية المستخدمة في الدراسة



Hidden layer activation function: Sigmoid

Output layer activation function: Identity

يتضح من الجدول (٨): تحقق الشبكات العصبية المتعددة الطبقات (MLP) عند استخدام عينة الاختبار أعلى مستوى دقة لتصنيف الشركات المتعثرة والغير متعثرة وكذلك التنبؤ خلال الفترة (ت-1، ت-2) مقارنة بنموذج ألتمان المعدل بنتائج جدول (٩)، حيث تحقق الشبكات العصبية أقل نسبة خطأ النوع الأول Type I Error خلال الفترة (ت-1) بنسبة 10٪، مما يشير إلى أنه أكثر حساسية² Sensitivity (قدرة على تصنيف الشركات المتعثرة) من نموذج ألتمان z-score حيث تساوى (90٪) وفقاً لنتائج اختبار نموذج ألتمان بالجدول (٩)، وكذلك خلال الفترة (ت-2) تحقق الشبكات العصبية مستوى دقة أعلى مقارنة بنموذج ألتمان z-score كما هو موضح بالجدول (٩)، مما يشير إلى أنه تتميز الشبكات العصبية الاصطناعية بانخفاض تكلفة الخطأ مقارنة بنموذج ألتمان z-score نظراً لارتفاع تكلفة خطأ النوع الأول (تصنيف الشركات المتعثرة كشركات غير متعثرة ماليا) مقارنة بتكلفة خطأ النوع الثاني (تصنيف الشركات غير المتعثرة ماليا كشركات متعثرة ماليا) حيث أثبتت دراسة Altman, Narayann and Haldeman, (1977) أن تكلفة خطأ النوع الأول تساوي 35 مرة تكلفة خطأ النوع الثاني، كما يلاحظ استقرار أداء نموذج الشبكات العصبية الاصطناعية خلال فترتي التنبؤ (ت-1، ت-2) بخلاف نموذج ألتمان حيث انخفض مستوى الدقة التصنيف والتنبؤ للنموذج بشكل ملحوظ خلال الفترة (ت-2) إلى 6.6٪ وانعكس

² حساسية النموذج (Sensitivity) = $\frac{TP}{TP+FN} \times 100$

حيث أن: (TP): حالات التنبؤ الايجابي الصحيح, (FN): حالات التنبؤ السلبي الخطأ.

ذلك في زيادة معدل الخطأ من النوع الأول إلى ٧٠٪ مما يعكس إلى انخفاض قدرة النموذج على تصنيف الشركات غير المتعثرة مالياً $Specificity^3$.

جدول (٨) مصفوفة الخطأ لنماذج الدراسة خلال فترات التنبؤ (ت-1، ت-2)

أداء نموذج التنبؤ		الحالة المتوقعة (خطأ النوع الأول والثاني)		الحالة الفعلية للشركات	الاسلوب الاحصائي
مستوي الدقة (معدل الخطأ)	متعثرة %	غير متعثرة %	متعثرة %		
(أ) الفترة (ت - 1)					
(13)	87	(10)	90	1	متعثرة
		85	(15)	0	غير متعثرة
(ب) الفترة (ت-2)					
(8.7)	91.3	(20)	80	1	متعثرة
		100	(0)	0	غير متعثرة

ملحوظة: تمثل الفترة (ت-1) قبل حدث التعثر بمدة عام، الفترة (ت-2) قبل حدث التعثر بمدة عامين، الشركات المتعثرة تأخذ قيمة (1)، الشركات غير المتعثرة تأخذ قيمة (0).

ويلاحظ بشكل عام انخفاض نسبة خطأ النوع الأول الناتجة عن استخدام الشبكات العصبية متعددة الطبقات MLP خلال فترتي التنبؤ مقارنة بنموذج ألتمان، وقد يرجع ذلك إلى أن الشبكات العصبية الاصطناعية تعتمد على ترجيح الأوزان للعلاقات بين الخلايا العصبية Neurons والتي تمثل المتغيرات المستخدمة في التنبؤ بخلاف نموذج ألتمان z-score الذي قد يتأثر بمشكلة تغيير توزيع البيانات حيث أنه تتسم بيانات الشركات المتعثرة بزيادة نسبة الانحراف المعياري للنسب المالية كما هو موضح بالجدول (7) ويشير ذلك لوجود اختلافات بين قيم المشاهدات للشركات المتعثرة أعلى منها في الشركات غير متعثرة ومن ثم انخفاض حساسية نموذج ألتمان (قدرة النموذج في تصنيف الشركات المتعثرة) (Rikkers and Thibeault, 2011) عن نماذج الشبكات العصبية.

ثامناً: تطبيق نموذج ألتمان (2016) على عينة الدراسة

يرجع اختيار نموذج ألتمان (2016) 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 ألتمان Z-score حتى يمكن تطبيق النموذج على شركات الأسواق النامية 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.

$\frac{TN}{TN+FP} \times 100 = \text{Specificity (النوعية)}$ ³
 حيث أن: (TN): حالات التنبؤ السليبي الصحيح.
 (FP): حالات التنبؤ الايجابي الخطأ.

- عدم استخدام المتغيرات السوقية حتى يمكن تطبيق النموذج على الشركات المساهمة وأيضا الشركات ذات الملكية الخاصة في نفس الوقت. وفيما يلي نموذج ألتمان (2016) المعدل والذي تم استخدام التحليل التمييزي (DA) لبنائه وتقدير معاملاته، المعادلة رقم (4):

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

حيث إن:

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 (٩) مصفوفة التصنيف لنموذج ألتمان 2016 المعدل، الناتجة عن تطبيق النموذج على الشركات (عينة الاختبار) باستخدام بيانات الفترة (ت-1) والفترة (ت-2).

جدول (٩) مصفوفة التصنيف لنموذج ألتمان (2016)

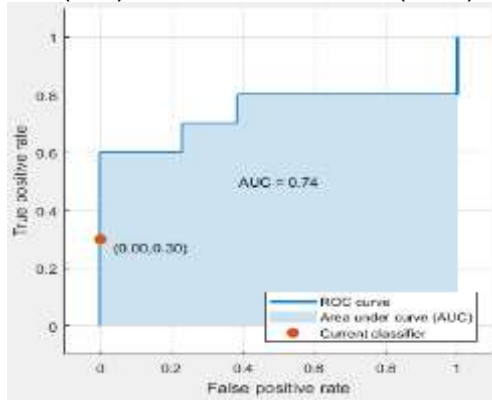
المتوقع الفعلي		قبل حدث التعثر بمدة عام (ت - 1)			قبل حدث التعثر بمدة عامين (ت - 2)		
		المتعثرة	غير المتعثرة	مستوى الدقة	المتعثرة	غير المتعثرة	مستوى الدقة
غير المتعثرة المتعثرة المعدل الإيجابي الصحيح نسبة الخطأ	غير المتعثرة	(%)8	92%	78.3%	(%)0	100%	69.6%
	المتعثرة	60%	(%)40		30%	70%	
	المعدل الإيجابي	86%	75%		100%	65%	
	الصحيح	14%	25%		0%	35%	

يلاحظ من الجدول (٩): يحقق نموذج 2016 Z-Score المعدل على المدى القصير خلال الفترة (ت-1) أداء مقبول بمستوى دقة (78.3%) حيث أن خطأ النوع الأول Type I Error (تصنيف الشركات المتعثرة كشركات غير متعثرة ماليا) 40% وخطأ النوع الثاني Type II Error (تصنيف الشركات الغير متعثرة كشركات متعثرة ماليا) 8%، بينما يحقق النموذج على المدى البعيد خلال الفترة (ت-2) أداء قد يكون غير مقبول بمستوى دقة (69.6%)، ويرجع ذلك إلى أن نسبة خطأ النوع الأول (70%) مما يشير إلى انخفاض مستوى حساسية النموذج Sensitivity (قدرة النموذج على التصنيف والتنبؤ بالشركات المتعثرة) إلى (30%) فقط، في حين أن نسبة خطأ النوع الثاني أصبحت (0%)، مما يشير إلى أن قدرة النموذج على التصنيف والتنبؤ بالشركات الغير متعثرة أصبحت (100%)، وتكمن أهمية مشكلة تدهور أداء النموذج في الفترة (ت-2) 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 35 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

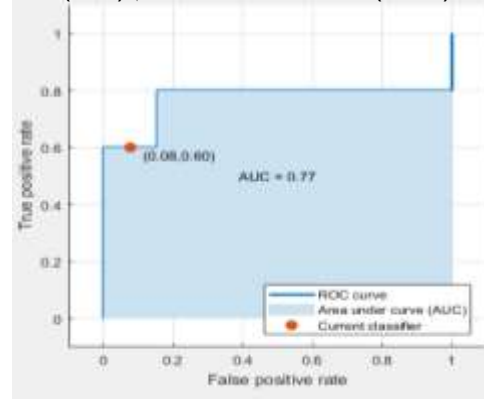
نتائج العديد من الدراسات البحثية السابقة أن نسبة خطأ النوع الأول الناتجة عن استخدام التحليل التمييزي أعلى من الأساليب الانحدار الأخرى وذلك مثل دراسة (Ciampi and Gordini, 2013; Lee and Choi, 2012)، كما أنه قد يرجع ذلك لاختلاف توزيع البيانات للشركات عينة الدراسة عن توزيع البيانات المستخدمة في اعداد نموذج ألتمان (2016 المعدل)، مثلما أشارت دراسة (Altman et al. 2016).

الشكل (3) منحنيات الأداء (المساحة أسفل المنحني AUC) لنموذج ألتمان (2016)

منحنى (3): المساحة أسفل المنحني لنموذج ألتمان (2016) قبل حدث التعثر بمدة عامين (ت-1).



منحنى (2): المساحة أسفل المنحني لنموذج ألتمان (2016) قبل حدث التعثر بمدة عام (ت-2).



تاسعاً: قياس أداء نماذج الدراسة

يعرض الجدول (١٠) نتائج استخدام كلا من الأساليب: (المساحة أسفل المنحني AUC، معامل ارتباط جيني، كولموجوروف سميرنوف KS-Z، مقياس (ف) F-measure كمقاييس لأداء نموذج التنبؤ باستخدام المؤشرات المالية الأربعة، وفي نفس الوقت مقارنة أداء أساليب التقدير المستخدمة في بناء النموذج لكلا من الشبكات العصبية متعددة الطبقات MLP، ونموذج (Altman 2016) المعدل، وذلك باستخدام عينة الاختبار Test Sample لتحديد أي النماذج يحقق أداء أفضل في التصنيف والتنبؤ بالشركات المتعثرة وغير المتعثرة مالياً، خلال الفترتين (ت-1، ت-2).

جدول (١٠) قياس أداء نماذج الدراسة

(ب): الفترة (ت-2)		(أ): الفترة (ت-1)		النماذج مقاييس الأداء
الشبكات العصبية	ألتمان 2016	الشبكات العصبية	ألتمان 2016	
0.89	0.462	0.858	0.707	مقياس F
0.948	0.74	0.969	0.77	المساحة أسفل المنحني (AUC)
0.896	0.48	0.938	0.54	معامل ارتباط جيني
2.195	1.255	2.140	1.591	اختبار كولموجوروف
(0.000)	(0.099)	(0.000)	(0.013)	سميرنوف (KS-Z)

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-1) قبل حدث التعثر بمدة عام، الفترة (ت-2) قبل حدث التعثر بمدة عامين.

يتضح من الجدول (١٠) الجزء (أ) أنه يحقق نموذج الشبكات العصبية المتعددة الطبقات (MLP) خلال فترات التنبؤ (ت-1) و (ت-2) أعلى أداء للتنبؤ بالتعثر المالي مقارنة بنموذج Altman 2016 المعدل وفقاً لنتائج استخدام مقاييس الأداء الأربعة، حيث أنه يحقق أعلى قيمة لمقياس (F) مما يشير إلى أن نموذج الشبكات العصبية يحقق أعلى (حاساسية) قدرة على

تصنيف الشركات المتعثرة وكذلك للمساحة أسفل المنحني (AUC) والتي تساوي (0.981)، كما أنه يحقق أعلى قيمة لمعامل ارتباط جيني للنموذج Gini rank coefficient حيث تقترب قيمته من الواحد الصحيح (0.896) خلال الفترة (ت-1) وكذلك (0.938) خلال الفترة (ت-2)، بالإضافة إلى أنه يحقق أعلى قيمة لـ (Z) 2.195 الناتجة عن اختبار كولمجوروف سميرنوف (KS-Z) حيث يحقق فرق معنوي قوي بين منحني التوزيع الاحتمالي التراكمي *Cumulative Distribution function* عند مستوى معنوية ($P-value < 0.001$) لمجموعتي الشركات عينة الدراسة، كما يلاحظ أن نموذج -ألتمان (2016) المعدل- يحقق مستوى أداء مقبول وفقاً لنتائج مقاييس الأداء الأربعة المستخدمة خلال الفترة (ت-1)، حيث تتعدى قيمة معامل ارتباط جيني (0.50)، بالإضافة إلى أنه يحقق فرق معنوي بين منحني التوزيع الاحتمالي التراكمي CDF لمجموعتي الشركات عينة الدراسة عند مستوى معنوية ($p-value < 0.05$)، وإن كان أقل من نموذج الشبكات العصبية في مستوى الأداء وفقاً للمقاييس الأربعة المستخدمة.

كما يلاحظ الجدول (١٠): أنه يحتفظ نموذج الشبكات العصبية المتعددة الطبقات (MLP) بتحقيق أداء أعلى خلال الفترة (ت-2) مقارنة بنموذج ألتمان، حيث تحقق فرق معنوي قوي بين منحني التوزيع الاحتمالي التراكمي CDF لمجموعتي الشركات المتعثرة وغير المتعثرة بعينة الاختبار عند مستوى معنوية ($P-value < 0.001$) وأعلى قيمة لـ (Z) وفقاً لنتائج اختبار KS-Z، كما أنه يحقق نموذج الشبكات العصبية أعلى قيمة للمساحة أسفل المنحني AUC (0.948)، وكذلك أعلى قيمة لمعامل ارتباط جيني، بالإضافة إلى أن نموذج الشبكات العصبية أكثر حساسية للشركات المتعثرة مالياً وفقاً لمقياس (ف)، كما يلاحظ أن نموذج -ألتمان 2016 المعدل- يحقق أداء ضعيف (غير مقبول) حيث تنخفض قيمة معامل ارتباط جيني عن (0.5)، كما أنه وفقاً لنتائج اختبار (KS-Z) لا يحقق نموذج ألتمان 2016 المعدل فرق معنوي بين منحني التوزيع الاحتمالي التراكمي ($P-value > 0.05$)، مما يشير إلى أن نموذج -ألتمان 2016 المعدل- أداء مقبول على المدى القصير فقط خلال الفترة (ت-1).

كما تشير النتائج إلى أن أداء نموذج الشبكات العصبية يعتبر أكثر استقراراً خلال فترات التنبؤ وتتفق هذه النتيجة مع الدراسات السابقة مثل دراسة (Altman et al., 2016; Ciampi and Gordini 2013).

عاشراً: ملخص النتائج

- توجد علاقة معنوية قوية بين مؤشر الربحية (العائد على رأس المال المستثمر) واحتمال التعثر المالي للشركات حيث يعكس بدوره قدرة الشركة على تحقيق أرباح كافية للوفاء بالتزاماتها المالية، كما توجد أيضاً علاقة معنوية قوية بين (مؤشر رأس المال العامل لإجمالي الأصول) واحتمال التعثر والذي يعكس مستوى 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 نموذج ألتمان 2016 (التحليل التمييزي) 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 ألتمان Z-score المعدل (2016) 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 نظراً لتأثيرها البالغ في دقة نموذج الشبكات العصبية ومن ثم دقة التنبؤ بالحالة المالية للشركات وتقييم الائتمان.

المراجع

- Agostini, M. (2018). Corporate Financial Distress, Going Concern in Both International and U.S. Contexts, Palgrave, Macmillan.
- Alifiah, 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.
- Loffler, 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 Petrovito, 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.
- Rikkers, F. and Thibeault, 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, 52-6

