



نموذج محاسبي مقترح لقياس مستوى التصنيف الائتماني باستخدام تقنيات الذكاء الاصطناعي

دراسة تطبيقية على الشركات المصرية المسجلة بسوق الأوراق المالية

بحث مُستل من رسالة دكتوراه في المحاسبة

إعداد

د. داليا عادل عباس السيد

أستاذ المحاسبة المالية

كلية التجارة- جامعة دمياط

daliaadel2000@du.edu.eg

أ.محمد طلعت محمد سالم

مدرس مساعد المحاسبة

بالمعهد العالي للعلوم الإدارية بالمنزلة

mohamedtalaatfouda@gmail.com

د. وائل عبد القادر عوض

أستاذ بقسم علوم الحاسب

كلية الحاسبات والذكاء الاصطناعي – جامعة دمياط

wael_abdelkader@du.edu.eg

المجلة العلمية للدراسات والبحوث المالية والتجارية

كلية التجارة – جامعة دمياط

المجلد السادس - العدد الأول – الجزء الثاني - يناير ٢٠٢٥

التوثيق المقترح وفقاً لنظام APA:

سالم، محمد طلعت محمد؛ السيد، داليا عادل عباس؛ عوض، وائل عبد القادر (٢٠٢٥). نموذج محاسبي مقترح لقياس مستوى التصنيف الائتماني باستخدام تقنيات الذكاء الاصطناعي: دراسة تطبيقية على الشركات المصرية المسجلة بسوق الأوراق المالية، المجلة العلمية للدراسات والبحوث المالية والتجارية، كلية التجارة، جامعة دمياط، ٦(١) ج٢، ٥٠١-٥٤٧.

رابط المجلة: <https://cfdj.journals.ekb.eg/>

نموذج محاسبي مقترح لقياس مستوى التصنيف الائتماني باستخدام تقنيات الذكاء الاصطناعي

دراسة تطبيقية على الشركات المصرية المسجلة بسوق الأوراق المالية
أ.محمد طلعت محمد سالم؛ د. داليا عادل عباس السيد؛ د. وائل عبد القادر عوض

الملخص

يستهدف هذا البحث بناء نموذج محاسبي لقياس التصنيف الائتماني للشركات المصرية المسجلة بالبورصة المصرية باستخدام البيانات المحاسبية الواردة بالقوائم المالية، حيث يعتمد الباحثون على تقنيات الذكاء الاصطناعي الحديثة (نموذج الشبكات العصبية الاصطناعية ANN، متجهات الدعم الآلي SVM، ونموذج الغابة العشوائية RF)، ولقد اعتمدت الدراسة على عدد (٣٤) متغير محاسبي، ولقد أجريت هذه الدراسة على عدد (١٠٣) شركة من الشركات المصرية المسجلة في البورصة المصرية في الفترة من (٢٠١٦ - ٢٠٢١)، ولقد توصلت الدراسة أن نتائج معدلات الدقة لإختبار نماذج الدراسة تشير إلى تفوق نموذج الشبكات العصبية الاصطناعية ANN بمعدل دقة قدره ٨٩,٢٪، وحقق نموذج متجهات الدعم الآلي SVM معدل دقة قدره ٨٧,٨٪، وحقق نموذج الغابة العشوائية RF معدل دقة قدره ٨٧,٦٪، وتوصي الدراسة بأن يعتمد المستثمرون على نماذج تصنيف الائتمان لضمان الإنذار المبكر وتجنب المخاطر المرتبطة باتخاذ قرارات استثمارية غير صحيحة.

الكلمات الإفتتاحية: التصنيف الائتماني، تقنيات الذكاء الاصطناعي، البيانات المحاسبية

١. المقدمة

لقد أحدثت الثورة الصناعية ثورة هائلة في طريقة عمل الأنظمة المالية، مُخَلِّفَةً وراءها سلسلة من الفرص والتحديات التي تواجه القطاع المالي (Li, 2020)، وتُعدّ المخاطر التي تواجه القرارات الائتمانية من أهم تلك التحديات، التي أدت إلى خسائر مالية جسيمة، لم تقتصر آثارها على الأسواق المالية المتقدمة فقط، بل امتدّت لتشمل أيضاً الأسواق المالية الناشئة (Al Naggar, 2014).

تقوم العديد من الوكالات المحلية والإقليمية والعالمية بقياس التصنيف الائتماني وإصدار درجات التصنيف الائتمانية من أبرزها "الثلاثة الكبار" (وكالة مودز لخدمة المستثمرين Moody's، ووكالة استاندارد اند بورر Standard & Poor's، ووكالة فيتش للتصنيف Fitch Rating)، حيث تنتشر فروع تلك الوكالات في عالم الأعمال والتي تتميز بتأثيرها القوي بالإضافة إلى أنها اكتسبت ثقة الحكومات والمستثمرين في كثير من دول العالم (Bonsall et al., 2017); (Ma&Yinduo., 2018) ولكن تعرضت التصنيفات الائتمانية التي تصدرها هذه الوكالات للعديد من الإنتقادات خاصة بعد إعلان إفلاس كلا من Parmalat و Enron ومؤخراً Lehman Brothers وبعد الأزمة المالية في عام ٢٠٠٨، حيث أصبحت التصنيفات الائتمانية موضع إهتمام واسع النطاق وتساءل المجتمع المالي عما إذا كانت إجراءات وكالات التصنيف الائتماني قادرة على التكيف مع التغيرات في الأسواق المالية (Cafarelli et al., 2020).

ولقد قادت الإنتقادات التي تم توجيهها لوكالات التصنيف الائتماني Credit Rating Agencies (CRAS) جهات التحقيق في الأزمة المالية إلى إستنتاج أن "إخفاقات وكالات التصنيف الائتماني CRAS تعد من الأسباب الرئيسية في حدوث الأزمة المالية، حيث تم منح تصنيفات إئتمانية مبالغ فيها، لذلك إتجهت العديد من الدراسات إلى تحليل المحددات الأساسية في عملية قياس التصنيف الائتماني للشركات

(Goldstein et al., 2020)، ويتمثل المحدد الأساسي في عملية التصنيف الائتماني للشركات في البيانات التي تحويها التقارير المالية المعدة وفقاً للمعايير الدولية لإعداد التقارير المالية، حيث يتم تعديل هذه البيانات من قبل وكالات التصنيف الائتماني لتعكس بشكل أفضل الجوهر الإقتصادي للمعاملات والأحداث قبل إستخدامها كمدخلات في نماذج كمية مستخدمة لحساب التصنيف الائتماني للشركات (Standard & Poor's, Moody's., 2006, 2008)

كما أن فهم العلاقة الأساسية بين المتغيرات المحاسبية والنسب المالية والتصنيف الائتماني للشركات يمكن أن يساعد المستثمرين على إتخاذ قرارات إئتمانية صحيحة (Wang et al., 2020) وتوضح أهمية قياس مستوي التصنيفات الائتمانية في العلاقة الوثيقة بين مفهوم التحليل المالي للنسب المحاسبية بالقوائم المالية وتقييم أداء الشركات (Jackson & Wood., 2013)، من خلال الدور الذي تلعبه المعلومات المحاسبية الواردة بالقوائم المالية في تقييم الجدارة الائتمانية للشركات (Batta., 2011; Kaplan & Urwitz., 1979; Ahmed & Billings., 2002)

ولقد إعتمدت العديد من الدراسات في تقييم الجدارة الائتمانية للشركات علي تحليل النسب المحاسبية باستخدام الأساليب الإحصائية لقياس مستوي التصنيفات الائتمانية، على سبيل المثال، يستخدم (West., 1970) تحليل الانحدار الخطي، وكذلك يستخدم (Ederington., 1985) تحليل الإنحدار اللوجستي، من ناحية أخرى، يتبنى (Henley et al., 1996) ; (Belkaoui., 1980) تحليل التمييز الخطي، ولكن وجهت العديد من الإنتقادات لمثل هذا النهج حيث يرتبط بها قوة محدودة في قياس مستوي التصنيفات الائتمانية (Dutta et al., (Kaplan & Urwitz., 1979) (Ederington., 1985); (1988) ونتيجة هذه الإنتقادات فقد إتجهت العديد من الدراسات بعد ذلك إلي إستخدام تقنيات الذكاء الاصطناعي على نطاق واسع للتنبؤ بالتصنيفات الائتمانية للشركات (Chen., 2013 ; Lee., 2013 ; Fedorova et al., 2013)، وتعد طرق التعلم الآلي Machine learning إحدى تقنيات الذكاء الاصطناعي والتي تم إستخدامها على نطاق واسع لقياس التصنيفات الائتمانية للشركات حيث تسمح ببنية هذه النماذج- طرق التعلم الآلي Machine learning- (ML) إستكشاف الإتجاهات المعقدة غير الخطية في البيانات (Elbel, et al., 2017):

(Fu et al., 2016): (Golbayani et al., 2020)، حيث يمكن لخوارزميات التعلم الآلي أن تتدرب على كميات كبيرة من البيانات الكمية والنوعية، وأيضاً يمكن أن يؤدي إستخدام طرق التعلم الآلي ML لقياس مستوي التصنيفات الائتمانية إلى خفض التكاليف ومتطلبات الوقت للعملية بشكل كبير، مما يجعل التقييمات أكثر سهولة ويمكن لجميع أنواع الشركات الوصول إليها، وهذا له فوائد ليس فقط على مستوى الإقتصاد الجزئي، ولكن أيضاً على مستوى الإقتصاد الكلي (Balios et al., 2016) حيث يمكن أن يؤدي زيادة نسبة الشركات التي تتمتع بإمكانية الوصول إلى التصنيفات إلى فوائد من حيث إتخاذ قرارات ائتمانية أفضل ومؤسسات مالية أكثر استقراراً، والتي تؤدي بالتبعية إلى تخصيص أكثر كفاءة للموارد الخاصة والعامة وفي النهاية معدلات أعلى للنمو الإقتصادي.

لذا يقترح الباحثون بناء نموذج لقياس مستوى التصنيف الائتماني يعتمد على البيانات المحاسبية بهدف تقييم التصنيف الائتماني للشركات المصرية المسجلة بالبورصة المصرية باستخدام تقنيات الذكاء الاصطناعي الحديثة، ويتمثل التساؤل الرئيسي للدراسة في هل يمكن بناء نموذج محاسبي لقياس مستوى التصنيف الائتماني باستخدام تقنيات الذكاء الاصطناعي وذلك بالتطبيق على الشركات المقيدة بالبورصة المصرية؟

٢. أهداف الدراسة

يتمثل الهدف الرئيسي للدراسة في بناء نموذج محاسبي لقياس مستوى التصنيف الائتماني بالإعتماد على تقنيات الذكاء الاصطناعي الحديثة وذلك بالتطبيق على الشركات المصرية المسجلة بسوق الأوراق المالية.

٣. أهمية الدراسة

تظهر أهمية الدراسة الحالية في أن قياس مستوى التصنيف الائتماني يوفر معلومات وقيمة للمستثمرين وأصحاب المصالح وموظفي الائتمان لاتخاذ القرارات المالية لتجنب أي خسائر متوقعة لضمان إستقرار الأسواق المالية وإزدهار الإقتصاد، ويمكن النظر لتلك الأهمية من جانبين :-

٣-١ الأهمية العلمية

هذه الدراسة تعد إضافة إلي أدبيات المحاسبة ولا سيما العربية نتيجة ندرة الأبحاث العربية التي تناولت قياس مستوى التصنيف الائتماني للشركات على حد علم الباحثين وذلك في محاولة بناء نموذج محاسبي لقياس مستوى التصنيف الائتماني للشركات المصرية بالإعتماد على تقنيات الذكاء الاصطناعي الحديثة

٣-٢ الأهمية العملية

مساعدة سوق المال المصري والبورصة المصرية في قياس مستوى التصنيف الائتماني مع عدم توفر نموذج لقياس هذا التصنيف، وما يرتبط به من تحديد مخاطر الائتمان والتي تؤثر على مناخ الإستثمار بشكل عام، بالإضافة إلي تحسين قدرة البنوك في تقييم عملاء القروض فضلاً عن أهميتها للمستثمر لاتخاذ قرارات الإستثمار.

٤. الدراسات السابقة

تعد الطريقة الإحصائية أقدم الحلول المستخدمة في تصميم نماذج قياس مستوى التصنيف الائتماني، نظراً لسهولة تنفيذها ودقتها، حيث أدي الإعتماد على الأساليب الإحصائية في قياس مستوى التصنيف الائتماني إلي ظهور مشكلة فرض تماثل توزيع البيانات محل التصنيف، وأيضاً التعامل مع عدد محدود من المتغيرات وبالتالي يتم إستبعاد بعض البيانات والمعلومات، من هنا زاد الإهتمام بتقنيات الذكاء الاصطناعي حيث يوجد العديد من الفوائد التي يمكن تحقيقها من خلال الإعتماد علي تقنيات الذكاء الاصطناعي الحديثة في إنشاء أنظمة التصنيفات الائتمانية (Carlenius et al., 2017) وهي:

(١) إمكانية تحسين الجودة التصنيفات الانتمانية حيث يمكن لخوارزميات التعلم الآلي أن تتدرب على كميات كبيرة من البيانات الكمية والنوعية، وأيضاً تكتشف تقنيات الذكاء الاصطناعي الأنماط وعوامل الخطر التي قد يتجاهلها العقل البشري عند إجراء التقييمات يدوياً .

(٢) يضمن استخدام خوارزميات التعلم الآلي تقييمات موضوعية حيث يمكن تفسير التباين في التصنيفات الانتمانية على سبيل المثال من خلال الاختلافات في تفاؤل المحللين الذين يؤدون التصنيفات (Fu, et al., 2016)

(٣) يمكن أن يؤدي استخدام تقنيات التعلم الآلي لأداء التصنيفات الانتمانية إلى خفض تكاليف ومتطلبات الوقت لعملية التصنيف بشكل كبير، مما يجعل التصنيفات أكثر سهولة ويمكن لجميع أنواع الشركات الوصول إليها. (Balios et al., 2016).

(٤) يمكن أن يؤدي زيادة نسبة الشركات التي تتمتع بإمكانية الوصول إلى التصنيفات إلى العديد من المزايا أهمها إتخاذ قرارات إنتمانية أفضل وبالتالي مؤسسات مالية أكثر استقراراً، مما يؤدي إلى تخصيص أكثر كفاءة للموارد الخاصة والعامة وفي النهاية معدلات أعلى للنمو الإقتصادي.

وفي سياق توضيح أهمية استخدام تقنيات التعلم الآلي في تحسين معدل دقة نماذج التصنيف الانتماني فقد أوضحت العديد من الدراسات إمكانية استخدام تقنيات الذكاء الاصطناعي في قياس مستوى التصنيف الانتماني، حيث قامت دراسة (Lee and Choi., 2013) بفحص إختبار الشبكات العصبية ذات خوارزمية الإنتشار الخفي على عدد من القطاعات الكورية والتي تضمنت قطاع البناء، قطاع التجزئة والقطاع الصناعي ومقارنتها بالتحليل التمييزي متعدد المتغيرات بالاعتماد على (٢٧) نسبة محاسبية وتوصلت الدراسة إلي تفوق الشبكات العصبية على الإنحدار التمييزي في قياس مستوى التصنيف الانتماني بمعدل دقة يتراوح بين (٨٩٪-٩٢٪) وكان أعلاها قطاع البناء ثم القطاع الصناعي، في حين أن التحليل التمييزي متعدد المتغيرات حقق معدل منخفض وصل (٨٢٪) في قطاع البناء ثم القطاع الصناعي.

بالإضافة إلي قيام (Blanco et al., 2013) باستخدام الشبكات العصبية متعددة الطبقات لتطوير نموذج محاسبي لقياس مستوى التصنيف الانتماني، ثم مقارنة أدائها بالإنحدار اللوجستي والتحليل التمييزي، وفي الأردن، تناولت دراسة (Al-Najjar & Al-najjar., 2014) بناء نموذج للشبكات العصبية قياس مستوى التصنيف الانتماني للشركات الأردنية بالاعتماد على (١٩) نسبة محاسبية مثل الربحية، السيولة، والأداء وقد إعمدت الدراسة على نوعان من التعلم من الشبكات العصبية النوع الأول خوارزمية الإنتشار التعليم الخفي، والثاني خوارزمية التنظيم الذاتي وذلك بالتطبيق على الشركات الصناعية الأردنية المسجلة في سوق الأوراق المالية الأردنية حيث قامت بتقسيم فترة الدراسة (٢٠٠٠-٢٠٠٤) فترة تدريب للشبكات العصبية، بينما من عام (٢٠٠٥-٢٠٠٧) فترة إختبار، وتوصلت الدراسة إلي أن خوارزمية الإنتشار الخفي للشبكات العصبية لها أداء أعلي في تصنيف الشركات مقارنة بخوارزمية التنظيم الذاتي.

وأيضاً قامت دراسة (Hajek & Olej., 2014) بإجراء مقارنة للتقنيات التعلم الآلي (MLP ، SVM ، DT ، RBF) بالتطبيق على (٥٢٠) شركة أمريكية، ولقد توصلت إلي أن MLP و DT تمثل أفضل النماذج حيث توفر أعلى دقة وأقل تكلفة خطأ في التصنيف على التوالي، وفي نفس السياق قامت دراسة (Zhong. et. al, 2014) بإجراء مقارنة للتقنيات التعلم الآلي (I-ELM ،

ELM، SVM، BP)، ولقد توصلت إلي أن SVM تقدم أفضل النماذج التصنيف الائتماني حيث توفر أعلى دقة وأقل تكلفة خطأ في التصنيف على التوالي .

وهذا ما إتفقت عليه أيضاً دراسة (Khemakhem., 2015) في تونس حيث إعتمدت على (١٥) نسبة محاسبية في مقارنة الشبكات العصبية بالتحليل التمييزي متعدد المتغيرات لعينة مكونة من (٨٦) شركة تونسية للفترة من ٢٠٠٥-٢٠٠٧، وقد توصلت إلي تفوق الشبكات العصبية على الإنحدار التمييزي متعدد المتغيرات بفارق (٨٪) .

وباختبار خصائص أو معايير تصنيف الشركات ذات الجدارة الائتمانية المرتفعة والمنخفضة على أداء الشبكات العصبية، فقد قامت دراسة (Akar & Gokdemir, 2015) باختبار معايير تصنيف الشركات ذات الجدارة الائتمانية المرتفعة والمنخفضة على أداء الشبكات العصبية ومقارنتها بالإنحدار اللوجستي وذلك بالتطبيق على الشركات الصناعية المسجلة بهيئة سوق الأوراق المالية بتركيا، ولقد توصلت الدراسة إلي أن الشبكات العصبية تفوقت على الإنحدار اللوجستي بمعدل دقة (٩٣٪) مقارنة بمعدل دقة (٩٠٪) للإنحدار اللوجستي .

وفي نفس السياق، قامت دراسة (Du Jardin., 2016) بإجراء دراسة مقارنة للشبكات العصبية والتحليل متعدد المتغيرات وتحليل الإنحدار وشجرة القرارات وذلك بالإعتماد على (٣٥) نسبة محاسبية وذلك للفترة من ٢٠٠٣- ٢٠١٢ بالتطبيق على (٢٢) شركة فرنسية وقد تم تقسيم عينة التدريب بواسطة النسب (٥٠٪) وقد توصلت الدراسة إلي تفوق الشبكات العصبية على باقي النماذج حيث حققت معدل دقة (٨٨٪)، في حين حقق الإنحدار اللوجستي معدل دقة (٨٦٪) .

وفي إطار أهمية الدمج بين النماذج المختلفة مع الشبكات العصبية، قامت دراسة (Li et al., 2016) بتقديم مدخل أكثر دقة لقياس مستوي التصنيف الائتماني للشركات صغيرة الحجم الفنلندية من خلال الإعتماد على النماذج المختلطة حيث قامت بالدمج بين الإنحدار اللوجستي كأحد التقنيات التقليدية والشبكات العصبية كأحد تقنيات الذكاء الاصطناعي، حيث إعتمدت الدراسة على (٢٢) نسبة محاسبية للفترة من (٢٠٠٤-٢٠١٢)، ولقد توصلت إلي أن الدمج يؤدي إلي إعطاء دقة أكثر مقارنة بكل نموذج على حدي، وأيضاً تقترح دراسة (Feng et al., 2018) تصنيفاً جديداً يعتمد فيه على الدمج بين تقنيات الذكاء الاصطناعي بين (Artificial Bee Colony(ABC) و (Support Vector Machine(SVM) بالتطبيق على (٥٥٦) شركة للفترة من ٢٠٠١-٢٠١٠، وتشير النتائج إلي أن النموذج المقترح يوفر دقة أفضل من الأساليب الإحصائية التقليدية الأخرى مما يشير إلي أن النموذج المقترح مصمم جيداً لقياس مستوي التصنيف الائتماني للشركات .

أيضاً هدفت دراسة (Dastile et al., 2020) إلي إجراء مسح أدبي لنماذج التعلم الإحصائي والآلي المستخدمة في قياس التصنيف الائتماني، إستناداً إلي (٧٤) دراسة تم نشرها في الفترة بين ٢٠١٠-٢٠١٨، وقد توصلت الدراسة إلي عدم وجود توافق في الآراء بشأن تحديد أفضل نموذج أداء، حيث تم إستعراض الدراسات السابقة بشكل منهجي الأكثر إستخداماً في قياس التصنيف الائتماني باستخدام النماذج الإحصائية ونماذج التعلم الآلي التقليدية، حيث تمت مقارنة الأداء (على مجموعات البيانات الائتمانية الألمانية والأسترالية) للنماذج الإحصائية والتعلم الآلي التي تم

إستخدامها في الأدبيات التي تناولت هذا المسح الأدبي، ولقد أظهرت نماذج التعلم الآلي نتائج أفضل مقارنة بالنماذج الإحصائية.

وإستكمالاً لمجموعة الدراسات التي توضح أهمية إستخدام تقنيات التعلم الآلي في التصنيف الائتماني فقد قدمت دراسة (Wallis et al., 2019) تحليلاً مقارناً للنماذج الإحصائية التقليدية ونماذج التعلم الآلي Artificial Neural Networks(ANN), Random Forest (RF) Networks(ANN) لقياس التصنيفات الائتمانية لعينة مكونة من (٣٠٨) شركة، وقد توصلت هذه الدراسة إلي تفوق النماذج الثلاثة SVM, ANN, RF بمتوسط دقة (٦٤,٦٪، ٦٣,٦٪، ٦٠,١٪) على التوالي، حيث أشارت هذه الدراسة إلي مرونة نماذج التعلم الآلي على عكس النماذج الإحصائية من حيث القدرة على التعامل مع العلاقات الخطية المتداخلة بين المتغيرات.

وفي ذات السياق قامت دراسة (Moscatelli et al., 2020) بمقارنة النماذج الإحصائية (الإنحدار اللوجستي والإنحدار التمييزي) مع تقنيات التعلم الآلي (Gradient Boosted Tree (GBT) Random Forest (RF)، للفترة من ٢٠١١-٢٠١٧، بالتطبيق على الشركات الإيطالية باستخدام (٢٤) متغير محاسبي، وقد توصلت إلي تفوق نماذج التعلم الآلي على النماذج الإحصائية في قياس مستوى التصنيف الائتماني.

كما قدمت دراسة (Golbayani., et al., 2020) تحليلاً مقارناً للدراسات التي تناولت قياس التصنيف الائتماني باستخدام تقنيات التعلم الآلي (Decision Trees, Random Forest,) لقياس مستوى التصنيف الائتماني للشركات، حيث تم التطبيق على قطاعات مختلفة (٥٢ شركة قطاع طاقة، ٢٨ شركة قطاع مالي، ٤٤ شركة قطاع رعاية صحية) للفترة من ١٩٩٠-٢٠١٨ للقطاع المالي، للفترة من ٢٠٠٩-٢٠١٨ للقطاع الطاقة والرعاية الصحية، ولقد توصلت الدراسة إلي أن تقنيات شجرة القرار DT تتفوق في الواقع على SVM و MLP. وللتحقق من النتائج تم الإعتماد على مقياس Notches Distance، والذي يساعد في تحديد مدى بُعد التنبؤات عن القيم الحقيقية عندما تفشل الخوارزمية في الوصول إلي التنبؤ الصحيح.

أيضاً قامت دراسة (Jiang., 2022) بمقارنة إستخدام أساليب التعلم الآلي النموذج اللوغاريتمي المطلوب (OL)، والشبكة العصبية الاصطناعية (ANN)، ومتجهات الدعم الآلي (SVM)، وأشجار القرار (DT)، والغابة العشوائية (RF) لقياس مستوى التصنيف الائتماني للشركات خلال الفترة من ٢٠٠١ حتى ٢٠١٧ باستخدام النسب المالية وتوصلت الدراسة إلي أن نموذج الغابة العشوائية (RF) يحقق أداءً أفضل بكثير من باقي النماذج الأخرى، في نفس السياق تناولت دراسة (Galil, K., Hauptman. Et. Al. 2023) قياس التصنيفات الائتمانية للشركات باستخدام بيانات من قاعدة بيانات COMPUSTAT للفترة من عام ٢٠٠٥ حتى عام ٢٠١٦، مستخدمة تقنيات الذكاء الاصطناعي شجرة القرارات DT ومتجهات الدعم الآلي SVM، وتوصلت نتائج الدراسة إلي تفوق نموذج شجرة القرارات DT على نموذج متجهات الدعم الآلي SVM.

ويمكن للباحثين التعليق على الدراسات السابقة من خلال :

- أدت الإنتقادات التي وجهت إلي الأساليب الإحصائية في تصميم نماذج قياس التصنيف الائتماني إلي زيادة الإهتمام بتقنيات الذكاء الاصطناعي الحديثة.
- قامت العديد من الدراسات باستخدام تقنيات الذكاء الاصطناعي المختلفة في قياس مستوي التصنيف الائتماني للشركات.
- أكدت معظم الدراسات على دور النسب المحاسبية في التنبؤ بالتحليل المالي عامة وفي قياس التصنيف الائتماني خاصة.
- تناول العديد من الدراسات إجراء مقارنة بين الأساليب الإحصائية وأساليب الذكاء الاصطناعي وبيان مدي تفوق الأساليب الذكاء الاصطناعي على الأساليب الإحصائية التقليدية فيما يخص قياس مستوي التصنيف الائتماني.
- ويمكن للباحثين من خلال عرض الدراسات السابقة إشتقاق فروض الدراسة حيث يتمثل الفرض الرئيسي في

الفرض الرئيسي:

يمكن بناء نموذج محاسبي لقياس مستوى التصنيف الائتماني باستخدام تقنيات الذكاء الاصطناعي بالتطبيق علي الشركات المقيدة بالبورصة المصرية"

ويمكن إستخراج الفرض الفرعي التالي من الفرض الرئيسي:

الفرض الفرعي الأول:

يؤدي النموذج المحاسبي باستخدام خوارزمية الشبكات العصبية الاصطناعية ANN إلي تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية الغابة العشوائية RF (Random Forest) في عملية قياس مستوي التصنيف الائتماني للشركات المقيدة بالبورصة المصرية"

الفرض الفرعي الثاني:

يؤدي النموذج المحاسبي باستخدام خوارزمية الشبكات العصبية الاصطناعية ANN إلي تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية متجهات الدعم الآلي (Support Vector Machine) في عملية قياس مستوي التصنيف الائتماني للشركات المقيدة بالبورصة المصرية"

الفرض الفرعي الثالث:

يؤدي النموذج المحاسبي باستخدام خوارزمية متجهات الدعم الآلي (Support Vector Machine) إلي تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية الغابة العشوائية RF (Random Forest) في عملية قياس مستوي التصنيف الائتماني للشركات المقيدة بالبورصة المصرية"

٥. الإطار النظري:

٥-١ مفهوم التصنيف الائتماني وأهميته:

يعد التصنيف الائتماني أداة هامة لتقييم الجدارة الائتمانية وتخفيض الخسائر حيث يهدف التصنيف الائتماني إلى توفير معلومات مهمة لأصحاب المصلحة في الشركة، حيث تتيح القدرة على قياس التصنيفات الائتمانية إمكانية إكتشاف مشاكل الشركة محل الاهتمام في مرحلة مبكرة. (Koh et al.2006) : (Li et al.2016)

ويعرف التصنيف الائتماني بأنه عملية يتم من خلالها قياس مدي قدرة الشركة على الوفاء بالتزاماتها لدي الجهة المقرضة، ويعرفها أيضاً (Jones, et. Al., 2015) على أنه عبارة عن عملية تهدف إلي توفير المعلومات والتقييم المستقل بشأن مدي الملاءة المالية للشركة وقدراتها على الوفاء بالتزاماتها التعاقدية، ويعرفها أيضاً (Hung, et.al. 2020) بأنها عبارة عن رأي محلل متخصص أو هيئة متخصصة في تقييم الجدارة الائتمانية العامة للشركة، أي قدراتها ورغبتها في الوفاء بالتزاماتها المالية ودرجة المخاطر المالية التي تواجهها أو الجدارة الائتمانية لإصدار معين من السندات أو أي التزامات مالية أخرى.

ولعل من أهم مفاهيم التصنيف الائتماني تلك الصادرة عن وكالات التصنيف الائتماني حيث عرفت مؤسسة **Standard & Poor 's** التصنيف الائتماني على أنه دراسات تقوم بها الوكالة حول مخاطر الإئتمان وتتمثل في رغبة وقدرة المقترض سواء كان شركة أو حكومة أو دولة حول الوفاء بالتزاماتها المالية بالكامل في الوقت المحدد، كما يأخذ في الإعتبار الجدارة الائتمانية للمقترض، وإعتبرت هذه الوكالة التصنيف الائتماني على أنه واحد من العديد من الأدوات التي يمكن للمستثمرين إستخدامها عند إتخاذ القرارات الإستثمارية، وإعتبرته ليس مقياساً مطلقاً ولكن هناك أحداث وتطورات مستقبلية يمكن التنبؤ بها

(Mock .T, 2012)

وعرفت مؤسسة **Fitch Rating's** التصنيف الائتماني على أنه "دراسات تحليلية يتم إصدارها بناء على معايير ومنهجية تتبعها المؤسسة، وقد يكون نتاج فرد أو مجموعة من الأفراد، والتصنيف الائتماني يعتمد على جميع المعلومات المعروفة لدي المؤسسة ولدي السوق، ويعبر عن قدرة المقترض على الوفاء بالتزاماتها المالية مثل أسعار الفائدة، سداد أصل القرض، وقد يكون التصنيف سيادياً فيما يخص الدولة، أو للبنوك أو للشركات". (<http://www.fitchratings.com>)

وعرفت مؤسسة **Moody's** التصنيف الائتماني على أنه "الأراء الراهنة التي تبديها المؤسسة حول المخاطر الائتمانية النسبية المتوقعة في المستقبل لكل من الكيانات والإلتزامات الائتمانية أو الديون أو الأوراق المالية الشبيهة بالديون، وتعرف المؤسسة مخاطر الإئتمان بأنها المخاطر الناشئة عن عدم وفاء أحد الكيانات بالإلتزامات التعاقدية والمالية عند إستحقاقها وتعرضه للخسارة المالية في حالة تعذر عليه الوفاء". (www.mood's.com)

ولذلك يري الباحثين أنه يمكن تعريف التصنيف الائتماني على أنه " رأي تحليلي متخصص أو هيئة متخصصة يعتمد على التحليل المالي والفني للبيانات المالية للشركة يُمكن من قياس مدي قدرة ورغبة الشركات على الوفاء بالتزاماتها التعاقدية خلال فترة زمنية معينة "

٥-٢ أهمية التصنيف الائتماني

لقد تناولت العديد من الدراسات (Chen and Cheng, 2013): (Asgharian, 2005) أهمية التصنيف الائتماني والتي تتمثل في النفاذ إلى أسواق رأس المال، وبناء سمعة حسنة في السوق تنعكس على مختلف الأطراف المتعاملة فيه، مع تخفيض تكاليف التمويل، بالإضافة إلى التميز عن المنافسين: (١) يساعد الشركات في الحصول على التمويل اللازم من خلال الأسواق المحلية والخارجية، وذلك لإعتماد الكثير من الجهات الممولة (منشآت، أفراد) على معرفة التصنيف الائتماني للجهة طالبة الأقرض .

(٢) يساعد في تحديد مستوى وجودة إدارة الشركة ومدى وفعاليتها في تسيير أمور الشركة .

(٣) يعكس قوة المركز المالي للشركة وقدرتها على الوفاء بالتزاماتها المالية .

(٤) يمنح المستثمرين المزيد من الثقة في التعامل مع الشركة المصنفة بدرجة عالية .

(٥) تعد مصداقية التصنيفات الائتمانية هامة بالنسبة لصغار المستثمرين الذين لا تتوافر لديهم مصادر أخرى للمعلومات تساعد على إتخاذ القرارات الإستثمارية .

٣-٥ دور النسب المحاسبية في قياس التصنيف الائتماني.

تطورت صناعة التصنيف الائتماني إلى حد كبير حتى ظهرت الأزمات المالية، حيث قدمت وكالات التصنيف الائتماني العديد من التصنيفات الائتمانية غير الدقيقة جزئياً (Ferri et al., 1999 for the East Asian crisis in 1997) بما في ذلك الأزمة الأخيرة -الرهن العقاري-، والجدير بالذكر أن جميع وكالات التصنيف الائتماني تمنح إمكانية الوصول الحر (أو بعد الاشتراك) إلى العناصر الأساسية لمنهجية التصنيف الائتماني (Dimities .al.et. 2016)، حيث يتم الإفصاح عن الكيفية التي يتبعونها في عملية منح الدرجات الائتمانية ولكن لا يتم الإفصاح عن الطريقة الكمية التي يستخدمونها لإجراء عملية التقييم وتحديد الأوزان المحتملة بشكل عام، من المعروف أن جميع وكالات التصنيف الائتماني تستخدم المقاييس الكمية والنوعية لتقييم مختلف مصادر الخطر على القوة المالية للمؤسسة، بما في ذلك معلومات من مواردها المالية، التوقعات بشأن مخاطر الأداء والبلد والسوق المستقبلية، وكذلك العوامل الإقتصادية والتنظيمية.

على وجه الخصوص، لا توجد معلومات كمية محددة متاحة حول الإجراء الدقيق للتصنيف الائتماني، على سبيل المثال. النموذج، متغيراته، الأوزان، المصادقة الإقتصادية المحتملة وصياغة الدرجات في مقياس التصنيف الائتماني، وتحافظ وكالات التصنيف الائتماني على ملكية معرفتها الفنية ولا تلتزم بقواعد الإفصاح عن المعلومات من أجل الحفاظ على هيمنتها في السوق (Dimities .al.et. 2016).

ومع ذلك، يستمر المستثمرون والمؤسسات المالية والهيئات التنظيمية في طلب الخدمات من نفس وكالات التصنيف الائتماني، ويرجع ذلك جزئياً إلى خبرتهم الطويلة، وإلى عدم وجود بديل موثوق به في السوق، وبالتالي بدأ الباحثون في توجيه الإنتقادات إلى نماذج التصنيف الائتماني التي تستخدمها هذه الوكالات (Frost, 2007; White, 2009; Orth, 2012; Pagano and Volpin, 2010;) (Tichy et al.2011)

ولقد قادت الإنتقادات التي تم توجيهها لوكالات التصنيف الائتماني Credit Rating Agencies (CRAS) جهات التحقيق في الأزمة المالية إلى إستنتاج أن "إخفاقات وكالات التصنيف الائتماني CRAS تعد من الأسباب الرئيسية في حدوث الأزمة المالية، حيث تم منح تصنيفات إئتمانية

مبالغ فيها، لذلك إتجهت العديد من الدراسات إلى تحليل المحددات الأساسية في عملية التصنيف الائتماني للشركات (Goldstein et al., 2020).

على الرغم من وجود صعوبات منهجية كبيرة في تطوير نموذج التصنيف الائتماني إلا أن العديد من الدراسات قاموا بالعمل على تطوير نظام تصنيف داخلي، يتم التعامل فيه مع التصنيف الائتماني على أنه تحليل لمخاطر الائتمان المرتبطة بأداة مالية أو كيان مالي، ويتم تحديد قدرة المدين على سداد ديونه، ومن ثم يمكن أن يرتبط التصنيف الائتماني بإحتمال تخلف المدين عن السداد، من هنا قدمت العديد من الدراسات (Altman (1968), Martin (1977), Ohlson (1980), Zmijewski (1984), Altman and Sabato (2007) Campbell et al., 2008, and Bharath and Shumway (2008) نماذج التنبؤ أو الافتراضية باستخدام النسب المحاسبية والتي إعتمدت على التصنيف الثنائي (متعثرة أو غير متعثرة) ولكنها نماذج للتعثر المالي والتي تختلف عن نماذج التصنيف الائتماني لأنها تركز على إحتمال التخلف عن السداد فقط، وهو واحد من بين العديد من المخاطر التي يتعرض لها المستثمرون حيال فقد إستثماراتهم جزء منها.

سواء كانت تلك النماذج تجريبية أو أكاديمية، فإنها فتحت الباب أمام الباحثين في إستخدام المعلومات المحاسبية في قياس التصنيف الائتماني، حيث حاول العديد من الباحثين قياس مستوى التصنيف الائتماني باستخدام المعلومات المحاسبية (Huang et al., 2004; Pasiouras et al., 2006; Hwang et al., 2010; Mizzen and Tsoukas, 2012; Hwang, 2013; Doumpos et al., 2015)، حيث أوضحت تلك الدراسات أهمية دلالة المعلومات المحاسبية في تكوين نماذج قياس التصنيف الائتماني .

على الجانب الأخر أوضح (الدهراوي، ٢٠١٦) أن البحث في المحاسبة يركز على قدرة الأرقام المحاسبية على التنبؤ، حيث أشارت دراسة (Batta, 2011) ; (Ahmed and Billings, 2002) إلي الدور الرئيسي الذي تلعبه المعلومات المحاسبية الواردة بالقوائم المالية على تقييم الجدارة الائتمانية للشركات، تأكيداً على ذلك أوضح كلا من مجلس معايير المحاسبة الأمريكي ومجلس معايير المحاسبة الدولية في ١٦ أكتوبر عام ٢٠٠٨ في ورقة مناقشة بعنوان " الآراء الأولية لعرض القوائم المالية" والتي تتفق مع معيار المحاسبة الدولي رقم (١) (IASB, 2007) أن الغرض من إعداد القوائم المالية هو توفير المعلومات عن المركز المالي ونتائج النشاط والتدفقات النقدية حيث تفيد قطاعاً عريضاً من مستخدمي القوائم المالية علي إتخاذ القرارات، كما تساعد علي التنبؤ بالتدفقات النقدية المستقبلية للمنشأة وخاصة توقيت وإحتمالية توليد هذه التدفقات النقدية، وقد أوضحت المناقشة أن الهدف من هذا المعيار المقترح أن البيانات الواردة بالقوائم المالية يجب أن تساعد المستخدمين في الحصول على صورة كاملة عن الوضع المالي للوحدة من خلال العلاقات بين عناصر القوائم المالية، وتقسيم المعلومات بحيث تكون مفيدة للتحليل المالي للقوائم المالية للتنبؤ بالتدفقات النقدية المستقبلية للوحدة وأخيراً مساعدة المستخدمين في تقدير سيولة الوحدة لمقابلة إلتزاماتها المالية (FASB 2008)، وتنقسم النسب المحاسبية بطبيعة الحال إلي أربعة أنواع رئيسية وفقاً (Curtis.1978): (الدهراوي، ٢٠١٦) وهي:

أولاً : نسب السيولة :

تستخدم أقسام الائتمان نسب السيولة لقياس مقدرة الشركة على الوفاء بالتزاماتها قصيرة الأجل، أي مقدرة العميل من ناحية الملاءة المالية والإقراضية فإذا كانت نسبة السيولة قليلة فهذا يعني عدم قدرة الشركة على الوفاء بتسديد ديونها قصيرة الأجل، وإذا كانت النسبة مرتفعة يعني ذلك أن الشركة غير قادرة على إستغلال أموالها بشكل صحيح ويتضمن هذا النوع من النسب على نسب فرعية منها (نسب التداول، نسب السيولة السريعة، نسبة المخزون إلي رأس المال العامل،).

ثانياً: نسب المديونية ورأس المال:

تقيس مقدرة الشركة على سداد كافة الديون عندما يحين أجل إستحقاقها لذا تستخدم إدارة الائتمان هذه النسب لإبراز العلاقة بين أموال الملاك والأموال المقدمة من المقرضين (البنوك) وعمل توازن بينهما ومدى كفاءة الأصول الثابتة لتغطية إلتزامات القروض طويلة الأجل، ويشتمل هذا النوع من النسب على نسب فرعية منها (نسبة الإقتراض إلي مجموع الإلتزامات، نسبة الإلتزامات المتداولة إلي حقوق الملكية، نسبة الإلتزامات إلي حقوق الملكية، ونسبة الإلتزامات المتداولة إلي إجمالي القروض....).

ثالثاً نسب النشاط:

أكثر ما تهتم به دوائر الائتمان عندما يتقدم لها عميل بطلب الائتمان هو ربحية ذلك العميل، وتستخدم كمؤشرات لتقييم ربحية الوحدة، وبها يضمن عدم وجود عسر مالي، وعليه تطمئن إدارة الائتمان إلي أن هذا العميل قادر على سداد إلتزاماته تجاه المصرف، ويشتمل هذا النوع من النسب على نسب فرعية منها (نسبة العائد على الإستثمار، نسبة إجمالي العائد على المبيعات، نسبة صافي العائد على المبيعات).

٦. الدراسة التطبيقية

يستهدف هذا القسم توصيف الإطار التطبيقي للبحث للوقوف على أهمية تصميم نموذج محاسبي لقياس التصنيف الائتماني للشركات بالإعتماد على تقنيات الذكاء الاصطناعي باستخدام البيانات المحاسبية الواردة بالقوائم المالية للشركات المصرية لزيادة دقة النموذج المحاسبي وتقليل الخطأ وذلك عن طريق إختبار فروض البحث، وفي سبيل تحقيق هذا الهدف سوف تركز الدراسة التطبيقية على النقاط الآتية:

٦-١ أهداف ومنهجية الدراسة:

٦-١-١ فروض الدراسة.

٦-١-٢ مجتمع وعينة الدراسة.

٦-١-٣ توصيف متغيرات الدراسة.

٦-٢ خطوات إعداد النموذج:

٦-٢-١ طرق جميع البيانات وأدوات التحليل.

٦-٢-٢ مرحلة معالجة البيانات

٦-٢-٣ مرحلة تخفيض المتغيرات

٦-٢-٥ مرحلة إختيار الخوارزميات ML

٦-٢-٥ أساليب تقييم النماذج.

٦-٣ إختبار فروض الدراسة

٦-٤ إختيار النموذج الدراسة

٦-١ أهداف ومنهجية الدراسة.

في ضوء الدراسات البحثية السابقة التي تم عرضها في الفصل السابق، فإنه يمكن الكشف عن أهداف ومنهجية الدراسة من خلال أولاً الكشف عن المتغيرات المحاسبية المستخدمة في قياس التصنيف الائتماني للشركات، ثانياً الكشف عن تقنيات الذكاء الإصطناعي كأحد مداخل تطوير نماذج قياس التصنيف الائتماني للشركات والتي أثبتت تفوق أدائها مقارنة بالأساليب الإحصائية التقليدية الأخرى، لذلك يمكن للباحث صياغة أهداف ومنهجية الدراسة في التساؤلات البحثية التالية:

ما هي المتغيرات المحاسبية الأكثر استخداماً في قياس مستوي التصنيف الائتماني للشركات ؟

للإجابة علي هذا التساؤل، إستخدمت الدراسة عدد من المتغيرات المحاسبية حيث قام الباحث بالإعتماد على الدراسات السابقة (Ahmed and Billings, 2002): (Dimitris et al., (Batta, 2011); (2016) ونماذج قياس مستوي التصنيف الائتماني في الحصول على المؤشرات الأكثر استخداماً في قياس مستوي التصنيف الائتماني للشركات ملحق رقم (٢)، ولقد قام الباحث بإتباع هذه المنهجية نظراً لإستخدامها في الدراسات السابقة المنشورة في المجالات العلمية المرموقة ذات التأثير المرتفع والمصنفة في **Web of Science & Scopus** والتي تأخذ أكثرها تصنيف

Q1

هل يحقق إستخدام تقنيات الذكاء الإصطناعي معدلات دقة أعلي في قياس مستوي التصنيف الائتماني للشركات المقيدة بسوق الأوراق المالية المصري؟

للإجابة علي هذا التساؤل تم بناء وتقدير نماذج قياس التصنيف الائتماني بإستخدام المتغيرات المحاسبية بالإعتماد على تقنيات الذكاء الإصطناعي (شجرة القرار Decision trees (DT)، الغابة العشوائية Random Forest (RF)، متجهات الدعم الآلي Support Vector Machines (SVM)، خوارزمية الجار الأقرب "K nearest neighbor" KNN، الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN)، تم تطبيق هذه النماذج على عينة الدراسة، ومقارنة النتائج عن طريق مصفوفة التداخل (الخطأ) لكل نموذج، ومن ناحية أخرى المقارنة بين أداء هذه النماذج في ضوء أربعة مقاييس للأداء (معدل الدقة Accuracy (%))، Precision (%))، Recall (%))، F1-Score (%)) لتحديد مدي الدقة في أداء كل نموذج وللوصول للنموذج النهائي الأكثر دقة لقياس مستوي التصنيف الائتماني للشركات المقيدة بسوق الأوراق المالية المصري، ولقد قام الباحث بإتباع هذه المنهجية نظراً لإستخدامها في الدراسات السابقة المنشورة في المجالات العلمية المرموقة ذات التأثير المرتفع والمصنفة في **Web of Science & Scopus** والتي تأخذ أكثرها تصنيف **Q1** .

٦-١-١ فروض الدراسة :

الفرض الرئيسي :

يمكن بناء نموذج محاسبي لقياس مستوى التصنيف الائتماني باستخدام تقنيات الذكاء الاصطناعي بالتطبيق علي الشركات المقيدة بالبورصة المصرية"

ويمكن إستخراج الفرض الفرعي التالي من الفرض الرئيسي:

الفرض الفرعي الأول:

يؤدي النموذج المحاسبي باستخدام خوارزمية الشبكات العصبية الاصطناعية ANN إلي تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية الغابة العشوائية (Random Forest) RF في عملية قياس مستوى التصنيف الائتماني للشركات المقيدة بالبورصة المصرية"

الفرض الفرعي الثاني:

يؤدي النموذج المحاسبي باستخدام خوارزمية الشبكات العصبية الاصطناعية ANN إلي تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية متجهات الدعم الآلي (Suport Vector Machine) SVM في عملية قياس مستوى التصنيف الائتماني للشركات المقيدة بالبورصة المصرية"

الفرض الفرعي الثالث:

يؤدي النموذج المحاسبي باستخدام خوارزمية متجهات الدعم الآلي (Suport Vector Machine) SVM إلي تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية الغابة العشوائية (Random Forest) RF في عملية قياس مستوى التصنيف الائتماني للشركات المقيدة بالبورصة المصرية"

٦-١-٢ مجتمع الدراسة :

يتمثل مجتمع الدراسة من الشركات المقيدة في بورصة الأوراق المالية المصرية والتي تضمنت ٢١٨ شركة يتم تداول أسهمها في سوق الأوراق المالية المصرية (التقرير السنوي للبورصة المصرية، ٢٠٢٢) وتمثلت عينة البحث كعينة حكمية من الشركات المصرية والتي تم إختيارها وفقاً لمجموعة من الشروط ألا وهي:

- تستبعد الشركات التي تمسك حساباتها بعملة أجنبية.
- تضم العينة الشركات التي تقدم قوائمها المالية في ١٢/٣١ .
- تستبعد الشركات التي تقدم قوائمها المالية في ٦/٣٠ .
- توافر المعلومات والبيانات المالية لإستخلاص النسب والمؤشرات التي سوف يتم إستخدامها في التحليل.
- تستبعد الشركات التي تعمل في القطاع المالي، البنوك، وشركات التأمين.
- إستمرار عمل الشركات لمدة تتجاوز الست سنوات ٢٠١٦ حتي ٢٠٢١ .

وبالتالي تتمثل عينة الدراسة من (١٠٣) شركة مصرية مقيدة بسوق الأوراق المالية المصري كما يوضح الجدول رقم (١).

جدول (١) بيان بإجمالي العينة الأولية للشركات المصرية قيد الدراسة

العدد	بيان
٢١٨	مجتمع الدراسة
(٥) (٣٨) (٤٣) (٢٩)	الشركات المستبعدة الشركات التي تمسك حساباتها بعملة أجنبية. الشركات التي تقدم قوائمها المالية في ٦/٣٠ . (شركات القطاع المالي- البنوك وشركات التأمين الشركات التي لم تتوافر قوائم ماليه لها خلال فترة الدراسة
١٠٣	عينة الدراسة

المصدر: الباحثين بالإعتماد على بيانات الشركات المسجلة بسوق الأوراق المصري
٦-١-٣ توصيف متغيرات الدراسة:

٦-١-٣-١ المتغير التابع:

يعد المتغير التابع هو درجات التصنيف الائتماني الممنوحة للشركات المصرية المقيدة بسوق الأوراق المالية المصرية، ويعتمد الباحث على تطبيق نموذج (Altman and Hotchkiss, 2006) في الحصول على درجات التصنيف للشركات المصرية، حيث يعاني سوق الأوراق المالية المصري من ندرة التصنيفات الائتمانية المعلنة، أيضاً يصنف Altman الشركات بناءً على نموذج Z-Score الذي يقدم درجات التصنيف الائتماني، والتي تعادل درجات التصنيف لوكالة التصنيف الائتماني Standard & Poor's Rating

ويرجع أهمية إختيار نموذج Altman (Altman, Hotchkiss, 2006) ومقارنة أدائه بنماذج الدراسة إلى عدة أسباب تمثل:

- ١- أحد أهم المحفزات الأساسية لإستخدام نموذج Altman هو تصميم النموذج للتطبيق على شركات الأسواق الناشئة Emerging markets، حيث تم إختيار دول مثل كولومبيا والصين والمكسيك بعينة إعداد النموذج نظراً لإختلاف طبيعتها عن الدول الأوروبية.
- ٢- تطبيق النموذج على الشركات الصناعية وغير الصناعية وذلك بعد إستبعاد نسبة (المبيعات ÷ إجمالي الأصول) وإستخدام عينة من الشركات الصناعية وغير الصناعية بعينة التقدير والبناء للنموذج المعدل.
- ٣- عدم إستخدام المتغيرات السوقية حتى يمكن تطبيق النموذج على الشركات المساهمة وذات الملكية الخاصة في نفس الوقت (Altman et al.2019).
- ٤- عدم وجود تصنيفات إئتمانية معلنة للشركات المصرية المقيدة بالبورصة المصرية .

ويوضح الجدول رقم (٢) نموذج (Altman, Hotchkiss, 2006) حيث قام Altman بحساب التصنيف الائتماني من خلال المعادلة التالية :

جدول رقم (٢) نموذج (Altman, Hotchkiss, 2006)

$Z\text{-Score} = 3.25 + 6.56X1 + 3.26X2 + 6.72X3 + 1.05X4$	
X1: Working Capital/Total Assets	X1: رأس المال العامل / إجمالي الأصول
X2: Retained Earnings/Total Assets	X2: الأرباح المحتجزة / إجمالي الأصول
X3: EBIT/Total Assets	X3: العائد قبل احتساب الفوائد والضرائب / إجمالي الأصول
X4: Book Value Equity/Total liabilities	X4: القيمة الدفترية لحقوق الملكية / إجمالي الإلتزامات

Source: (Altman and Hotchkiss, 2006)

ويوضح الجدول رقم(٣) درجات التصنيف الائتماني كما يوضحها نموذج (Altman, Hotchkiss, 2006) وهي تعادل درجات وكالة التصنيف الائتماني Standard & Poor's Rating .

جدول رقم (٣) درجات التصنيف الائتماني طبقاً لنموذج (Altman, 2006):

Zone	Rating	Z" score – Treshold
Safe zone	AAA	>8,15
	AA+	8,15
	AA	7,60
	AA-	7,30
	A+	7,00
	A	6,85
	A-	6,65
	BBB+	6,40
	BBB	6,25
Grey zone	BBB-	5,85
	BB+	5,65
	BB	5,25
	BB-	4,95
	B+	4,75
Distress zone	B	4,50
	B-	4,15
	CCC+	3,75

المجلة العلمية للدراسات والبحوث المالية والتجارية (م ٦، ع ١٤، ج ٢، يناير ٢٠٢٥)
أ.محمد طلعت محمد سالم؛ د. داليا عادل عباس السيد؛ د. وائل عبد القادر عوض

	CCC	3,20
	CCC-	2,50
	D	1,75

Source:(Altman, Hotchkiss, 2006)

ويوضح الجدول (٤) بيان بالتصنيف الائتماني لعينة الدراسة خلال الفترة من ٢٠١٦ حتى ٢٠٢١ طبقاً لنموذج (Altman, Hotchkiss, 2006) الذي تم الإعتماد عليه لقياس مستوي التصنيف الائتماني لعينة الدراسة .

جدول (٤) بيان بالتصنيف الائتماني لعينة الدراسة طبقاً لنموذج (Altman, Hotchkiss, 2006)

٢٠٢١	٢٠٢٠	٢٠١٩	٢٠١٨	٢٠١٧	٢٠١٦	Score
٣٦	٣٨	٣٩	٣٥	٣٦	٣٦	AAA
٦	٥	٨	١٠	٩	٤	AA+
٦	٧	٣	٥	١	٣	AA
٥	٢	٢	٣	٣	٢	AA-
٢	٥	١	٠	٢	٥	A+
١	١	٤	٥	٢	٣	A
٣	٣	١	٢	٢	٥	A-
٢	٢	٢	١	٥	٢	BBB+
٥	١	٥	٥	٦	٠	BBB
١	٦	٣	٢	٢	٠	BBB-
٥	٢	٢	٦	٤	٩	BB+
٥	٢	٤	٥	١	٤	BB
١	٢	٤	١	٤	١	BB-
٤	٢	٤	٤	٢	٢	B+
٤	٤	٦	٣	٣	٦	B
٠	١	٤	٢	٤	٣	B-

المجلة العلمية للدراسات والبحوث المالية والتجارية (م٦، ع١٤، ج٢، يناير ٢٠٢٥)
أ.محمد طلعت محمد سالم؛ د. داليا عادل عباس السيد؛ د. وائل عبد القادر عوض

٦	٣	٢	٥	٥	٤	CCC+
٥	٦	٣	٤	٣	٣	CCC
١	٤	١	٢	٤	٣	CCC-
٥	٧	٥	٣	٥	٨	D
١٠٣	١٠٣	١٠٣	١٠٣	١٠٣	١٠٣	إجمالي عدد الشركات

المصدر : اعداد الباحثين

٦-١-٣-٢ المتغيرات المستقلة:

في ضوء تحديد أفضل المتغيرات المحاسبية التي يمكن إستخدامها في قياس مستوي التصنيف الإئتماني للشركات، فقد تم إختيار عدد من المتغيرات المستقلة والتي تمثل مدخلات النموذج والتي تم تكرارها في الدراسات السابقة، والمتعلقة بقياس مستوي التصنيف الإئتماني، ولقد قام الباحث بإتباع هذه المنهجية نظراً لإستخدامها في الدراسات السابقة المنشورة في المجالات العلمية المرموقة ذات التأثير المرتفع والمصنفة في **Web of Science & Scopus** والتي تأخذ أكثرها تصنيف **Q1**، (Dimitities al et., 2015): (Ma, Yinduo,2018): (Golbayani, et. Al. 2020): (Wallis et al., 2020): (Moscatelli et al., 2020) وتمثلت تلك المتغيرات في (٣٤) نسبة محاسبية والتي يمكن توضيحها في الجدول رقم (٥).

جدول رقم (٥)

المتغيرات المحاسبية المستخدمة في إشتقاق النموذج المحاسبي

المصدر : اعداد الباحثون

-	النسبة أو المؤشر	النسبة أو المؤشر
1	التدفق النقدي من الأنشطة التشغيلية	• تجميع البيانات الأساسية (Data Collection)
2	التدفق النقدي من الأنشطة التشغيلية	• معالجة البيانات (Data Pre- Processing)
3	التدفقات النقدية التشغيلية/صافي المبيعات	• مرحلة تخفيض المتغيرات (Feature Reduction)
4	التدفقات النقدية التشغيلية / الفوائد	• مرحلة تخفيض المتغيرات (Feature Reduction)
5	التدفق النقدي من الأنشطة التشغيلية	• مرحلة تخفيض المتغيرات (Feature Reduction)
6	صافي الربح/إجمالي الأصول	(ANN - SVM - RF)
7	صافي الربح/إجمالي حقوق الملكية	• اختيار معدل دقة وقدرة تقنيات الذكاء الاصطناعي على قياس مستوي التصنيف
8	صافي الربح /إجمالي الأرباح	• اختيار معدل دقة وقدرة تقنيات الذكاء الاصطناعي على قياس مستوي التصنيف
9	الأرباح المحتجزة /	• اختيار النموذج الأفضل
10	الأصول المتداولة/الالتزامات المتداولة	• اختيار النموذج الأفضل
11	رأس المال العامل/إجمالي الأصول	إجمالي المبيعات / إجمالي حقوق الملكية
12	تكلفة البضاعة المباعة / متوسط المخزون	إلتزامات طويلة الاجل / إجمالي الأصول
13	الأصول المتداولة إلي إجمالي الأصول	رأس المال العامل / المبيعات
14	إجمالي الإلتزامات /إجمالي الأصول	معدل نمو المبيعات
15	إجمالي الأصول / حقوق الملكية	معدل نمو إجمالي الأصول
16	إجمالي الإلتزامات المتداولة / حقوق الملكية	معدل نمو صافي الدخل
17	رأس المال العامل / إجمالي الإلتزامات	العائد على السهم

٦-٢ خطوات إعداد النموذج

قام الباحث بإتباع مجموعة من الخطوات لبناء النموذج المحاسبي لقياس مستوي التصنيف الإئتماني للشركات المقيدة بسوق الأوراق المالية المصري والتي تتكون من مرحلة تجميع البيانات الأساسية للدراسة، ثم مرحلة معالجة هذه البيانات، ثم يتبعها مرحلة تخفيض المتغيرات، من خلال الإعتداع على خوارزمية تحليل المكونات الرئيسية Principal Component Analysis Algorithm ثم يتبعها مرحلة إختيار تقنيات الذكاء الاصطناعي المستخدمة في بناء النموذج، ثم يتبعها مرحلة إختبار معدل دقة وقدرة تقنيات الذكاء الاصطناعي المختارة على قياس مستوي التصنيف الإئتماني عن طريق مجموعة من أساليب التقييم منها (Cvaluation Matrix)، ثم يتبعها إختيار أفضل نموذج (Yinduo, 2018) (Golbayani., 2020) (Feng et al., 2020): (Jiang, Yixiao., 2022): (Galil, et. al., 2023) ويوضح الشكل رقم (١) خطوات إعداد النموذج كما يلي:

شكل رقم (١) خطوات إعداد النموذج المصدر : إعداد الباحثون

٦-٢-٦ مرحلة جمع البيانات وأدوات التحليل.

تنقسم تلك المرحلة إلي قسمين

- القسم الأول : هو مرحلة جمع البيانات الدراسة وتم الحصول على تلك البيانات من خلال
- مواقع الشركات
- موقع مباشر مصر
- موقع investing.com
- شركة مصر لنشر المعلومات
- القسم الثاني : هو أدوات التحليل التي إعتد عليها الباحثون

وقد تم الإعتداد على برنامج **Python** فهو برنامج مفتوح المصدر يتضمن تقنيات الذكاء الاصطناعي والتعلم الآلي، يتم الإعتداد عليه في العديد من التطبيقات التجارية والبحوث والتعلم والتدريب، وأيضاً برنامج **Microsoft office Excel 2013** لمقارنة الحالات المتنبأ بها بواسطة الخوارزميات والحالة الواقعية للشركات في مرحلة الإختبار العملي للنموذج. (الجبالي، ٢٠٢٠)

٦-٢-٢ مرحلة معالجة البيانات Data Pre-Processing

معالجة البيانات أو تنظيف البيانات هو عملية فرز وتصفية البيانات الأولية لإزالة البيانات غير الضرورية وغير الدقيقة، وتعد مرحلة معالجة البيانات خطوة ضرورية لعملية التصنيف، حيث يتم فحص البيانات الأولية بحثاً عن البيانات المفقودة، وتحويلها إلى نموذج مناسب يسمح بمزيد من التحليل والمعالجة، ويتم ذلك لضمان إدخال بيانات عالية الجودة فقط لوحدة المعالجة، في هذه الخطوة، يتم تحويل البيانات الأولية إلى نموذج يمكن قراءته آلياً ويتم إدخالها لوحدة المعالجة حيث تعد من المهام اللازمة لإعداد بيانات الإدخال وجعلها مناسبة للتطبيق من قبل تقنيات الذكاء الاصطناعي المختلفة، وبالتالي يزيد أيضاً من دقة وكفاءة نموذج التصنيف الإئتماني، أيضاً تم تقسيم مجموعة البيانات إلى ٨٠٪ لمجموعة التدريب و ٢٠٪ لمجموعة الإختبار (García et al., 2015): (Yinduo, 2018): (Golbayani., 2020).

٦-٢-٣ مرحلة تخفيض المتغيرات Feature Reduction:

تخفيض المتغيرات (**Feature Reduction**) هو أسلوب من أساليب التعلم بدون الإشراف، ففي مسائل تصنيف التعلم الآلي، غالباً ما يكون هناك العديد من العوامل التي يتم على أساسها التصنيف النهائي، هذه العوامل هي في الأساس متغيرات، كلما زاد عدد المتغيرات، زادت صعوبة العمل على مجموعة التدريب، وبالتالي فهناك مجموعة متغيرات زائدة عن الحاجة، في هذه الحالة تتدخل خوارزميات تخفيض الأبعاد، من خلال تخفيض عدد المتغيرات العشوائية قيد الدراسة، للحصول على مجموعة من المتغيرات الرئيسية، ويتم استخدام تخفيض المتغيرات كخطوة معالجة مسبقة لتحويل البيانات لـ **خوارزميات التعلم الآلي**، وهناك العديد من خوارزميات تخفيض الأبعاد للإختبار من بينها، ويعد من أشهر خوارزميات تقليل المتغيرات خوارزمية تحليل المكونات الرئيسية (PCA) (Yinduo, 2018)

خوارزمية تحليل المكونات الرئيسية Principal Component Analysis Algorithm :

تحليل المكونات الرئيسية (PCA) هي عبارة عن خوارزمية تعلم غير خاضعة للإشراف تستخدم لتقليل أبعاد مجموعة البيانات، ويعد تحليل المكونات الرئيسية (PCA) هو الأسس العام للنموذج التي تستخدم المبادئ الرياضية الأساسية المعقدة لتحويل عدد من المتغيرات المحتمل إرتباطها إلى عدد أقل من المتغيرات وتسمى المكونات الرئيسية، حيث تستخدم لفحص العلاقات المتبادلة بين مجموعة من المتغيرات، غالبًا ما يتم استخدام PCA لتقليل أبعاد مجموعات البيانات الكبيرة عن طريق تحويل مجموعة كبيرة من المتغيرات إلى مجموعة أصغر لا تزال تحتوي على معظم المعلومات في المجموعة الكبيرة (Mark et al., 2013).

بشكل عام، تستخدم PCA لتقليل أبعاد مجموعات المعطيات الكبيرة، باستخدام الإسقاط الرياضي، ويمكن تفسير مجموعة المعطيات الأصلية التي ربما تضمنت العديد من المتغيرات في عدد أقل من المتغيرات (المكونات الرئيسية) ولذلك، غالبًا ما يسمح فحص مجموعة معطيات الأبعاد للمستخدم بتحديد الاتجاهات والأنماط والقيم المتطرفة في المعطيات، وتعتمد بشكل أساسي على التباين بين قيم العينة المدروسة، ويعد الهدف من PCA هو تقليل عدد المتغيرات في مجموعة البيانات مع الاحتفاظ بأكبر قدر ممكن من المعلومات. (Yang, S., et. al. 2020)

وتتمثل الخطوات العامة لخوارزمية تحليل المكونات الرئيسية فيما يلي:

الخطوات العامة لخوارزمية تحليل المكونات الرئيسية PCA: (Yang, S., et. al. 2020):

(١) الخطوة ١: التوحيد القياسي

يتم حساب نطاق المتغيرات وتوحيده في هذه العملية لتحليل مساهمة كل متغير بالتساوي، وتسمى بالتوحيد القياسي، ويعد الهدف من هذه الخطوة هو توحيد البيانات بطرح المتوسط والقسم على الإنحراف المعياري لكل متغير، من أجل الحصول على نتائج غير متحيزة في نهاية التحليل، من خلال إتباع المعادلة التالية:

$$Z = \frac{VALUE - MEAN}{STANDARD DETATION}$$

where.

$$MEAN = \frac{\text{sum of the terms}}{\text{Total member of terms}}$$

X = القيمة في مجموعة البيانات n = عدد القيم في مجموعة البيانات

(٢) الخطوة الثانية: حساب مصفوفة التباين COVARIANCE MATRIX COMPUTATION

يتم في هذه الخطوة التعرف على كيفية إختلاف متغيرات البيانات المقدمة مع متوسط القيمة المحسوبة، حيث يتم فرز المتغيرات المترابطة في نهاية هذه الخطوة، لفصل المتغيرات شديدة الترابط، ويمكن حساب مصفوفة التباين من خلال إتباع المعادلة التالية:

$$\text{Covariance Matrix} = \begin{bmatrix} \text{COV}(X, X) & \text{COV}(X, Y) \\ \text{COV}(Y, X) & \text{COV}(Y, Y) \end{bmatrix}$$

WHERE

$$\text{Covariance} = \frac{\text{Sum } (X - (\text{Mean of } X))(Y - (\text{Mean of } Y))}{\text{Number of data points}}$$


(٣) الخطوة الثالثة: تحليل المتجهات الذاتية k

يتم حساب المتجهات الذاتية k والقيم الذاتية لمصفوفة التباين حيث تمثل المتجهات الذاتية أقصى إتجاهات التباين في البيانات، بينما تمثل القيم الذاتية حجم التباين في تلك الإتجاهات، كما يوضحها الشكل رقم (٢) حيث يوضح أقصى إتجاهات التباين في البيانات وحجم ذلك التباين .

شكل رقم (٢) تحليل المكون الأساسي المصدر : مخرجات برنامج Python

(٤) الخطوة الرابعة : اختيار المكونات الرئيسية:

يتم فرز المتجهات الذاتية حسب قيمها الذاتية المقابلة بترتيب تنازلي، ويتم إختيار المتجهات الذاتية



k الأعلى
مكونات
رئيسية،
وبالنظر
للمنحني
الشكل رقم
(٢) حيث
نقاط
أفضل
منحني
يمر بنقاط
العينة
(٠,٠١٦):

(٥٥١)، ويعتبر PCA أفضل منحني يمر بنقاط العينة، وتهتم هذه الخوارزمية بشكل أساسي بمدي إبتعاد نقاط العينة عن هذا المستقيم، أي كلما كانت هذه النقاط بعيدة عن هذا الخط كلما كان تقليل البعد غير مناسب، وكلما كانت نقاط العينة قريبة من هذا المنحني كلما كان أفضل، نقوم بإسقاط نقاط العينة على هذا المنحني، وتسمى المسافة بين النقطة ومسقطها خطأ الإسقاط، لذا من أجل تقليل هذا الخطأ، تقوم PCA بإيجاد متجه ليمثل أفضل منحني مناسب لهذه القيم بحيث يبقى الخطأ في الحدود المقبولة، لأن هذا الخطأ يعني خسارة في المعلومات التي تحملها العينة، بالنظر في الجدول رقم (٥) حيث كانت عدد المتغيرات الدراسة (٣٤) متغير، حيث تم تقليل الأبعاد ليصبح عدد المتغيرات (١٧) متغير تمثل المكون الرئيسي لتلك المتغيرات كما يوضحها الجدول رقم (٦) والذي يمثل مخرجات خوارزمية PCA .

الجدول رقم (٦) مخرجات خوارزمية PCA

Class	PC1 0.088203	PC2 0.064668	PC3 0.043279	PC4 0.041094	PC5 0.037919	PC6 0.032199	PC7 0.031865
A	-3.47047	-1.89746	0.265384	4.3685	0.183631	-0.731431	-3.47965
AAA	5.01479	5.46808	-0.324924	-1.91984	1.43626	-0.149434	-2.51355
CCC-	-4.30884	2.22395	1.45909	3.24109	-1.03629	-1.98755	3.18837
AAA	1.44282	-4.96428	0.0855098	-0.783142	1.33626	-1.49366	-1.60239
CCC+	-3.35781	-1.57067	1.1094	0.715469	-3.46864	-1.62341	1.16491
CCC-	-4.94938	2.15262	-2.54623	2.04136	-0.124419	-1.17078	2.96934
AAA	0.952076	-1.9427	-0.411753	0.309569	0.983758	-1.34753	-0.454128
A	0.757289	-4.03048	3.11305	-1.38955	-0.568099	0.168087	4.6055
AA+	-0.779682	-4.17119	1.4531	-3.0326	1.66008	-3.95876	-0.724613
BB+	-2.37401	-2.20087	-0.40683	4.56214	2.42244	-0.149731	-2.40975
BB+	-1.58625	4.34383	2.79799	0.631025	1.22525	-0.4204	-3.15393
AAA	6.19227	-2.60384	-2.17112	1.73628	0.171918	-0.423356	-0.255472
A-	-4.85808	-0.861621	-3.11951	-0.698367	-2.31453	1.71932	-0.912023
D	-4.55188	1.26807	1.08647	3.92947	-1.33487	-1.47392	2.79361
A+	-0.916832	-4.48016	-0.710964	-2.22152	1.82133	-2.94685	1.47105
BB	-5.05592	-0.550013	-2.33717	-2.12544	-2.26343	0.606607	-0.386954
AAA	2.67367	-5.21857	2.38466	0.75436	4.15352	0.90671	-0.454911
BB+	1.00674	3.85728	2.92038	-4.59139	2.76954	-1.25489	0.990761
AA+	-2.16373	-1.34572	1.30139	-0.927113	-2.21623	2.76041	-2.9164
BB-	-2.98339	-0.329676	1.55192	-2.8815	-3.60543	0.647737	-0.98839
AAA	5.98462	-3.31585	-2.71419	3.67298	-1.09542	0.578576	1.32264
BB+	-1.77337	-0.0536475	2.19911	-2.89818	-1.65329	0.978121	-3.16759
AAA	6.7755	4.27592	-4.22001	-0.458045	1.26745	-0.235161	0.0107155
AAA	-1.25602	-3.64711	-2.12515	1.75043	1.23827	1.75438	-0.365917
AA	-2.34088	-2.88386	-1.70014	0.610974	-0.25898	0.143806	-4.46143
D	-4.57188	2.65843	1.18137	2.27971	-2.35295	-2.62426	2.40766
BB+	-2.05891	1.81099	-1.29724	-0.438734	0.985986	2.18405	-1.83779
AA+	-1.41783	-2.671	-1.64054	0.817226	-0.633219	0.155069	-3.92493
AAA	1.97089	-0.847361	-0.859266	-1.67543	-3.35205	-4.48665	-1.43895
AAA	4.94836	-3.07906	-3.94093	1.89637	-1.11393	-1.5669	-0.294067
A+	-1.25186	-0.807267	3.28198	5.18249	-0.208299	2.27182	1.40858
A	2.95135	4.4461	1.70413	-2.63299	-0.476338	-0.682034	-1.50716
D	-3.81667	1.99326	1.57644	0.849523	-3.11422	-3.55468	2.58129
BB	0.238891	-4.2752	-0.960729	0.904795	1.15968	3.39633	-0.771869
B	-1.11839	0.914259	5.80177	2.41126	-2.6683	-1.22924	-0.954004
AA-	-1.60586	2.2302	0.955058	-2.41463	0.886802	3.96144	-3.84301
AAA	4.80072	3.63181	-2.25885	-2.10672	-1.59414	-1.03735	-0.125756

المصدر :
مخرجات
برنامج
Python

المجلة العلمية للدراسات والبحوث المالية والتجارية (م٦، ع١٤، ج٢، يناير ٢٠٢٥)
 أ.محمد طلعت محمد سالم؛ د. داليا عادل عباس السيد؛ د. وائل عبد القادر عوض

تابع الجدول رقم (٦) مخرجات خوارزمية PCA

PC8	PC9	PC10	PC11	PC12	PC13	PC14	PC15	PC16	PC17
0.029803	0.027156	0.023454	0.022061	0.020938	0.019423	0.018426	0.017451	0.016463	0.015126
-0.240038	0.513703	-0.228242	-1.65892	-2.16463	3.64666	-1.40806	0.583115	2.94991	1.747
-1.80544	1.50331	2.20182	0.733563	-1.59769	-1.43601	-2.06067	-0.33338	-0.599883	0.9374
3.87589	-4.23545	-0.233436	0.483733	0.5937	-0.652281	1.71904	-0.278106	1.7096	1.544
0.850447	0.0967399	6.07879	0.658558	0.533478	-0.500398	-3.29865	-2.37808	-0.768583	-1.9202
-1.58841	-3.01045	4.83743	-0.180362	2.33665	-0.956797	1.01947	-0.83804	1.09268	-1.877
0.87401	0.536236	1.11115	-1.02997	0.959891	1.20581	1.19894	-0.368312	-2.00473	-0.3933
1.94667	2.3111	5.33518	3.43854	1.58753	-0.0117036	-1.89246	-0.154474	-1.69224	1.273
-2.93634	-2.95128	0.270815	0.0681239	-2.8159	-1.92909	1.17796	-0.596328	-0.271537	0.3815
0.433201	-1.26318	-0.249292	-1.29109	-1.26006	-0.466802	2.18511	-1.11784	2.18594	2.558
-3.67564	-0.654336	-1.57069	-1.07949	-0.768485	-1.6175	-2.56037	2.30961	2.79411	-3.005
-1.33063	2.93545	1.11834	3.1542	-0.0493623	2.5405	0.568198	1.647	2.41169	0.353
-2.26245	0.455932	-0.868297	1.48314	1.64601	-0.691477	2.20682	0.832442	-0.873665	2.484
0.781711	1.46699	0.793416	-2.05028	-1.291	1.09661	-0.0601647	1.4797	1.06889	0.6438
-0.255113	-3.15364	0.513202	1.86411	-0.0271623	0.479161	-0.109208	0.746495	1.34478	3.123
-0.820131	0.345598	-0.513606	-1.2028	-4.15801	-2.80175	1.04398	2.64255	1.23084	-1.677
2.07296	0.0612392	-1.37972	3.45782	-3.24863	-0.564918	0.290601	3.19672	-0.323897	0.2023
-3.33273	-2.49279	-0.38361	-2.05194	1.26319	2.16198	-1.13354	0.559038	-0.62811	0.0317
-2.24727	3.25517	1.35557	0.730651	-0.0209096	-3.56504	-0.399958	0.500682	0.761405	0.9865
-2.75348	-3.28846	-1.39081	2.75396	0.100211	-1.1959	1.17511	-1.18362	0.173016	-1.971
0.531241	1.77121	-1.73858	0.747188	1.3924	0.256829	-0.447453	3.26488	-2.96625	-0.489
-1.99851	-0.878409	-1.33896	0.475481	-0.968201	-1.35352	2.12935	0.285937	-1.85562	3.413
0.138815	1.64639	-1.52688	3.60729	4.73935	1.55596	0.281094	3.21999	-0.897321	-0.4307
-3.065	-0.141149	-0.11802	-1.20434	-0.344343	0.781882	1.22968	1.29748	0.671408	-0.07551
-4.91862	0.577122	-1.189	2.01907	3.49592	-1.52354	-1.09681	3.06184	1.03744	-1.387
-0.630392	-0.908043	-1.02092	-3.33772	-0.369719	-2.14774	1.15428	-0.668406	2.12565	3.423
1.5088	-3.88881	0.785565	0.274481	0.793861	1.13709	-0.234894	2.03706	1.18416	-0.08563
2.00317	-3.8104	-3.82317	0.454105	-0.526669	-2.72843	1.35514	-0.239289	-1.50534	-0.0547
-0.926077	-1.16792	2.33309	-1.81707	1.42696	1.0488	1.30178	-1.2612	-2.14333	0.5015
-0.271406	0.289077	-2.2376	-0.870119	3.19381	2.08271	-0.214418	-1.4077	2.11032	1.675
-0.130592	0.193418	2.28688	1.42203	0.948375	-2.37488	3.45017	1.30793	-2.57809	-0.7684
0.344159	-2.18914	-0.625638	0.71482	-0.857231	0.593384	1.06848	-3.2474	2.26982	-1.223
-1.83258	3.16993	-1.54688	1.94961	-0.61976	0.195937	0.592263	2.51102	3.2496	0.2057
0.545807	-4.37789	1.32189	0.633122	1.89288	-0.844491	-1.03382	1.2889	1.36884	2.233
-4.16024	-2.82228	-1.48877	0.352108	0.312266	-0.255387	-0.236501	3.47846	0.2897	1.818

المصدر : مخرجات برنامج Python

٤-٢-٦ مرحلة إختيار الخوارزميات .

لقد قام الباحثون بإختيار تقنيات الذكاء الاصطناعي التالية (الشبكات العصبية الاصطناعية ANN، الغابة العشوائية Random Forest (RF)، متجهات الدعم الآلي Support Vector Machines (SVM) للحصول على النموذج النهائي لقياس التصنيف الائتماني.

(١) الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN).

تعتبر الشبكات العصبية الاصطناعية إحدى التقنيات الحديثة للذكاء الاصطناعي التي تستخدم في العديد من المجالات نظراً للمزايا العديدة التي تتمتع بها (Chirita, 2012)، حيث يمكن إستخدامها كبديل للعديد من الأساليب الإحصائية مثل الإنحدار المتعدد والأساليب غير الخطية الأخرى، ويتميز هذا الأسلوب بأن نتائجه لا تحتاج إلى تحليل مكمل آخر للنتائج analytical solution (مبسرة، ٢٠٢٠).

وتتشابه الشبكات العصبية في عمل الدماغ البشري لأنها تكتسب المعرفة بالتدريب وتستطيع التعلم من الماضي من خلال نظام معقد من إرسال وإستقبال النبضات الكهربائية بين الخلايا العصبية للدماغ البشري (Zurada, 1992): (Wanke et al, 2016) وتعد هذه الشبكات نموذجاً معرفياً لكونها تستطيع أن تتعلم من المعلومات التي قامت بمعالجتها، فهي تستطيع أن تحلل كمية كبيرة من البيانات، وبواسطتها يمكن تصميم برامج للحاسبات تحاكي أسلوب الذكاء الإنساني لكي يتمكن الحاسب من أداء بعض المهام بدلاً من الإنسان(الشرقاوي، ١٩٩٦): (عصام، ٢٠١٧).

١ - مفهوم الشبكات العصبية:

تعرف تقنية الشبكات العصبية الاصطناعية (Dilek & Cvadar, 2015) "بأنها عبارة عن مجموعة من النماذج الرياضية التي تحاكي بعض خواص أنظمة الأعصاب البشرية، والمصممة بالتناظر الوظيفي مع القدرة على التعلم البشري، فهي تستخدم لحل المشكلات التي لا يمكن تمثيلها في سلسلة من الخطوات، مثل سلسلة التنبؤات أو التنقيب للبيانات"، وتعد الشبكات العصبية أفضل الإختيارات عندما يكون هناك كمية ضخمة من البيانات أو المعلومات، والتي لا يمكن معالجتها بالسرعة والدقة الكافية في ظل ظروف الأساليب الإحصائية التقليدية.


٢ - أنواع الشبكات العصبية:

تعالج الشبكات العصبية بصفة عامة المدخلات إلى مخرجات من خلال إستخدام الطبقات Layers والخلايا العصبية المتصلة ببعضها البعض بشكل منظم وعشوائي، وتحدد أنواع الشبكات العصبية طبقاً لترتيب مدخلات الخلايا العصبية في الطبقات أو المستويات وطبقاً لشكل الترابطات بين الطبقات وهو ما يسمى بهيكل الشبكات العصبية، ومن أكثر أنواع الشبكات العصبية إنتشاراً الشبكات العصبية ذات الطبقة الواحدة Single Layer Network والشبكات العصبية متعددة الطبقات Multi-Layer Network

(Paliwal & Kumer, 2009); (Moseley, 2003); (Nelson & Zilingworth, 1991)

(أ) العصبية ذات الطبقة الواحدة Single Layer Network


تسمى بالشبكات العصبية ذات التغذية الأمامية وتعد أبسط أنواع الشبكات العصبية الاصطناعية، حيث تتدفق فيها المعلومات في إتجاه واحد فقط (المسار الأمامي فقط) من خلال طبقة المدخلات عبر الطبقة الخفية وإلى خلايا طبقة المخرجات، حيث تستقبل كل طبقة مدخلات من الطبقة السابقة لها وتعطي مخرجاتها للطبقة التالية لها بالشبكة العصبية، حيث لا يوجد تغذية مرتدة للأوزان من الخلايا العصبية بكل طبقة لنفسها مرة أخرى أو للطبقة السابقة لها كما تظهر بالشكل رقم (٣) (ميسرة،



A single layer Artificial Neural Network

. (٢٠٢٠)

الشكل رقم (٣) الشبكات العصبية ذات الطبقة الواحدة Single Layer Network



Source: Gangol et al., 2016)

(ب) الشبكات العصبية متعددة الطبقات Multi-Layer Network

تحتوي الشبكات العصبية متعددة الطبقات على أكثر من طبقة من الطبقات الخفية الوسيطة، فضلاً عن طبقة المدخلات وطبقة المخرجات، وتكون الطبقات المرئية هي طبقة المدخلات والمخرجات بينما توجد بينهما طبقات مخفية كما تظهر بالشكل رقم (٤)، تكون جميع الطبقات متصلة ببعضها البعض بوزن معين لكل خلية عصبية وفي هذه الشبكة توجد ثلاث طبقات من الأوزان:

- طبقة الوزن بين مستوي المدخلات والمستوي الخفي .
- طبقات الأوزان بين المستويات الخفية .
- طبقة الأوزان بين المستوي الخفي والمخرجات.

الشكل رقم (٤) الشبكات العصبية متعددة الطبقات Multi-Layer Network

Source: (Desheng Wu et . al., 2022)

وفي كلا النوعين من الشبكات العصبية الاصطناعية يتم المقارنة بين المخرجات الفعلية والمخرجات المعيارية والعمل على تعديل الأوزان بهدف تقليل الخطأ ثم إعادة المعالجة وتبدأ المعالجة بوضع قيم عشوائية للأوزان وحساب قيمة الانحراف وهو الفرق بين المخرجات الفعلية والمعيارية وتعديل قيم الانحراف إلى أدنى قيمة وهي عملية متكررة حتي يتم الوصول إلي مجموعة الأوزان التي تسمح للشبكة بتقديم مخرجات صحيحة بدرجة معقولة من الدقة. (Rajasekaran & Vijayalakshmi., 2003) : (Desheng Wu et . al., 2022) وسيتم فيما يلي عرض الجوانب الرئيسية لبناء وتركيب الشبكات العصبية الاصطناعية وهي:

٢/١ - طبقة المدخلات The Input Layer

الطبقة المسؤولة عن تحويل المتغيرات التي يتم إدخالها إلى الطبقة الخفية Hidden Layer وذلك بدون معالجتها، وتحتوي هذه الطبقة على المدخلات (x_1, x_2, \dots, x_i) وتكون متصلة بالخلية (j) بالأوزان (W_{1j1}, W_{2j2}) حيث تستقبل الخلية العصبية (بالطبقة الخفية) الإشارات المجمعة بكل إشارة تكون مضروبة في الوزن المرتبط بها Weight بالاتصال من خلال الدالة التجميعية التالية. (Desheng Wu et . al., 2022)

$$h_j = \sum_{i=1}^i w_{ij}x_j$$

حيث تشير (h_j): إلى ناتج الدالة التجميعية (إشارة) تحمل وزن الرابط للمدخلات (x_j).

٢/٢ - الطبقة الخفية Hidden Layer

تتكون الطبقة الخفية من خلية واحدة أو أكثر وتقع بين طبقتي المدخلات والمخرجات، وتكون هذه الطبقة مسؤولة عن معالجة المتغيرات التي يتم إدخالها ويتم ذلك بعد ترجيح المدخلات بأوزان معينة تعكس قوة الترابط والعلاقات بين هذه المدخلات ووحدات التشغيل، كما تعطي هذه الطبقة القدرة على التعامل مع البيانات بصورة خطية وغير خطية تمكنها من أداء رياضي واحصائي عالي الكفاءة، حيث يتم الحصول على الناتج (n_j) من طبقة المدخلات ثم بعد ذلك تمر من خلال دالة التحويل Transler function حيث تكون دالة التحويل غير خطية لتعطي الناتج النهائي كما أنه قد يكون هناك أكثر من طبقة خفية للشبكة العصبية الواحدة. (Desheng Wu et . al., 2022)

$$o_j = f(\sum_{i=1}^1 w_{ij}, x_j, \theta_j)$$

وتكون الدالة التحويلية بطبقة المخرجات كما يلي:

$$o_j = g(h_j) = f(h_j, \theta_j)$$

حيث ان (w_j) تمثل وزن الرابط بين الخلية (i) والخلية $(0j)$ - كمان تمثل (x_j) المدخلات بالخلية $(0j)$ ، وكذلك $(0j)$ الناتج النهائي .

٢/٣ - طبقة المخرجات The Output Layer

تتشابه وظائف طبقة المخرجات مع وظائف الطبقة الخفية، حيث تحتوي على دالة خطية Linear Function، فمدخلات هذه الطبقة التي تمثل مخرجات الطبقة الخفية يتم معالجتها مرة أخرى بطبقة المخرجات، حيث أن تتصل الخلايا العصبية في طبقة المخرجات والطبقة الخفية ببعضها البعض، ولقد قامت العديد من الدراسات بالإعتماد على خوارزمية الشبكات العصبية متعددة الطبقات **Multi-Layer Network** في بناء نموذج قياس التصنيف الإئتماني حيث قدم (Pacelli et al., 2011) نظرة عامة على أنواع مختلفة من الشبكات العصبية المستخدمة في أدبيات التصنيف الإئتماني، أيضاً قام كل من (Wallis et al., 2019)، (Huang et al., 2004) بالإعتماد على الشبكات العصبية الإصطناعية من خلال النسب المالية من أجل بناء نموذج تصنيف إئتماني، وأيضاً قام (Khemakhem & Boujelbene, 2015) باستخدام ANN بإستخدام عدد ١٥ متغيرات وتوصلت لبناء نموذج التصنيف الإئتماني بمعدل دقة ٨٢,٥٥٪. أيضاً (Hájek & Olej, 2014) بإستخدام ٢٠ متغير محاسبي وتوصلت لبناء نموذج التصنيف الإئتماني بمعدل دقة ٨٨,٤٤٪، وفي نفس السياق قام (Daniel et al., 2019) بإستخدام ١٧ متغير محاسبي وتوصلت لبناء نموذج للتصنيف الإئتماني بمعدل دقة ٨٣٪.

(٢) الغابة العشوائية (RF) Random Forest

هي إحدى تقنيات التعلم الآلي التي يمكن إستخدامها للتصنيف وبناء نماذج تنبؤية جيدة، مثل طريقة إتخاذ القرار، وتتطلب الغابات العشوائية (RF) كمية كبيرة من البيانات، وتتميز بالقدرة على التنبؤ ودقة التصنيف، حيث تستخدم Random Forest أشجار قرارات متعددة لتقدير النتيجة، ويتم تشكيل أشجار القرار عن طريق تقسيم البيانات بشكل متكرر إلى قسمين، الهدف هو أن كل مجموعة من المجموعات الناتجة تتماشى مع فئة واحدة؛ من الشائع أن يتم تخصيص نفس الفئة لمجموعات متعددة في كل خطوة من خطوات بناء الشجرة (Perez et al., 2012) .

وتتمثل إحدى مميزات Random Forests في أنه يتم أخذ في الإعتبار مجموعة فرعية عشوائية فقط من المتغيرات عند كل تقسيم، وتعد الميزة الرئيسية الأخرى هي أن كل شجرة تنمو إلى أقصى حجم لها، مما يعني أنها مفرطة في التعقيد، وتناسب بشكل كبير التنبؤات في المستقبل، وتحسن فيها الدقة بشكل كبير ثم يتم الجمع بين التنبؤات الفردية، ويعني جمع التنبؤات الفردية الطريقة التي يتم بها جمع التنبؤ المنفصل لكل شجرة فردية ومن ثم يتم تعيين الفئة التي حصلت على أكبر عدد من الأصوات (التنبؤات).

ينتج نموذج الغابات العشوائية أداءً تبايناً أفضل مقارنة بطريقة شجرة القرار البسيطة، بل يحسن أيضاً التنبؤ ويتجنب التجهيز الزائد عن طريق ربط الأشجار، ويحمي نماذج الأشجار المجمع من مخاطر الخطأ الفردية غير الضرورية حيث أن الإرتباط المنخفض بين النماذج هو المحرك الرئيسي لتحسين دقة التنبؤ. (Kulkarni, v,v, Sinha, P.K, 2012) ويمكن صياغة خوارزمية الغابة العشوائية **RF Forest Random** للتصنيف على النحو التالي:

$$c = \arg \max_{c \in \{1, 2, \dots, C\}} \sum_{m=1}^M I(T_m(x) = \hat{y})$$


- \hat{y} التصنيف النهائي الذي تم التوصل إليه بعد التصويت.
- $\arg \max$ ترمز إلى الفئة c التي تحقق أقصى قيمة للمجموع.
- $c \in \{1, 2, \dots, C\}$ الفئات الممكنة.
- m : عدد الأشجار في الغابة.
- $(T_m(x))$ التنبؤ الذي تقدمه الشجرة m للعينة x .
- $c = I(T_m(x))$ دالة المؤشر التي تساوي ١ إذا كانت الشجرة m تصنف العينة x على أنها من الفئة c ، وتساوي ٠.

يناسب نموذج الغابات العشوائية مجموعات البيانات الكبيرة مع عدد كبير من المتغيرات (أبعاد عالية)، وتتعامل بشكل جيد مع البيانات المفقودة والموجودة في البيانات، ولديها طرق للتكيف مع البيانات غير المتوازنة، ويطبق نموذج Random Forest على بيانات التصنيف الإئتماني بنجاح في السنوات الأخيرة، (Xia et al., 2018) كما يتضح من الشكل التالي رقم (٥)

شكل رقم (٥) نموذج الغابة العشوائية

Source:(Hamori et al., 2018)

ولقد قامت العديد من الدراسات بالإعتماد على خوارزمية الغابة العشوائية Random Forest في بناء نموذج التصنيف الإئتماني، حيث إعتمدت دراسة (Lessmann et al., 2015) على مقارنة بين عدة تقنيات ذكاء الإصطناعي بإستخدام معايير تقييم مختلفة ومجموعات بيانات تصنيف إئتماني مختلفة وتوصلت إلي أن خوارزمية الغابة العشوائية Random Forest كانت متفوقة في القدرة على التمييز الإفتراضي بين العديد من طرق التنبؤ الافتراضية وتطورت تدريجياً لتصبح واحدة من الطرق الرئيسية في مجال التصنيف الإئتماني، أيضاً قام (Pedro Veronezi, 2016) بتطبيق



Random Forest (RF) لقياس التصنيفات الإئتمانية للشركات بإستخدام بياناتهم المالية ولقد توصل إلي أن خوارزمية الغابة العشوائية Random Forest يوفر نتائج أكثر دقة واستقراراً في فترة زمنية أقصر، أيضاً دراسة (Uddin et al., 2022) أكدت على أن خوارزمية الغابة العشوائية Random Forest لديها قابلية تفسير أكبر مقارنة بخوارزميات التعلم الآلي المتقدمة الأخرى،

وفي نفس السياق قام (Parisa et al., 2020) ببناء نموذج للتصنيف الإئتماني باستخدام عدد ٢٠ متغير محاسبي ولقد حقق نموذج RF معدل دقة قدره 88,33%.

(٣) متجهات الدعم الآلي (SVM) Support Vector Machines

تعد (Support Vector Machine) (SVM) نموذج متقدم للتعلم الآلي حيث تتفوق على العديد من تقنيات التعلم الآلي الأخرى في مختلف المجالات، حيث قدم هذا النموذج من قبل (Vapnik, 1992) وهو عبارة عن أنظمة تستند إلى نظرية التعلم الإحصائية (statistical learning theory)، وتعد من خوارزميات التعلم عن طريق موجه (خاضع للإشراف) (supervised)، وهو نموذج التعرف على الأنماط باستخدام التعلم تحت الإشراف، وهي طريقة لإنشاء مصنفين للفئة باستخدام عنصر الإدخال الخطي، فهي تعتمد على إيجاد منحنى أو مستوى فائق يفصل العينات عن بعضها البعض.

(Paul, Y., Goyal, V., & Jaswal, R. A., 2017).

يمكن صياغة معادلة أفضل مستوى فاصل على النحو التالي:

$$w^T x + b = 0$$

—يمثل W المتجه الطبيعي للمستوى الفاصل أي الإتجاه العمودي وتمثل المعلمة b في المعادلة مسافة المستوى الفاصل من الأصل على طول المتجه الطبيعي w

—يمكن حساب المسافة بين نقطة البيانات x_i وحدود القرار على النحو التالي:

$$d_i = \frac{w^T x_i + b}{\|w\|}$$

—ويمكن صياغة دالة تصنيف SVM على النحو التالي

$$\hat{y} = \begin{cases} 1 & : w^T x + b \geq 0 \\ 0 & : w^T x + b < 0 \end{cases}$$

وتهدف إلى إيجاد أفضل مستوى فاصل (hyperplane) يصنف البيانات بشكل صحيح قدر الإمكان ويفصل العينات عن بعضها البعض، ثم تفصل الفئات بطريقة خطية عن طريق الـ hyperplane الذي ينشئ مصنفاً يقوم بتصنيف البيانات خطياً، وفي بعض الأحيان يوجد بعض المشكلات التي لا يمكن فصلها في مجال بيانات الإدخال الأصلية، ومما سبق يتبين أن الـ SVM تحول البيانات إلى فضاء البحث feature space الذي عادة ما يكون ضخماً الأبعاد، ومن الملاحظات المهمة حول الـ SVM أنها تعتمد على الخصائص الهندسية لبيانات التدريب وليس على أبعاد البيانات المدخلة، ويعتمد بناء النموذج على عدد من المعلمات مثل المستوى الفاصل (hyperplane)، وتحدد دقة النموذج بقدرته على الفصل بين الفئات بحيث تكون أقرب عينه من كلا الفئتين أبعد ما يكون عن بعضهما البعض (Golbayani, et al., 2020)


ولقد قامت العديد من الدراسات بالإعتماد على خوارزمية متجهات الدعم الآلي Support Vector Machines في بناء نموذج التصنيف الإئتماني حيث أشارت العديد من الدراسات إلى قدرة تصنيف قوية (Kim and Cortes and Vapnik, 1995);(Xiao et al., 2016); (Vapnik, 2013);(Sohn, 2010)، أيضاً يدرس (Hájek & Olej, 2014) دعم Vector Machines من أجل قياس التصنيفات الإئتمانية للشركات، باستخدام عدد ٢٠ متغير محاسبي

وتوصلت الدراسة إلي بناء نموذج محاسبي للتصنيف الإئتماني بمعدل دقة ٨٧,٢٨٪، وفي نفس السياق قام (Golbayani, et al., 2020) ببناء نموذج للتصنيف الإئتماني باستخدام عدد ٢٠ متغير محاسبي حيث حقق معدل دقة قدره ٧٧% كما يتضح من الشكل التالي رقم (٦).

شكل رقم (٦) متجهات الدعم الآلي

Source: (Golbayani, et al., 2020)

٦-٢-٥ أساليب قياس أداء النماذج المستخدمة :



الإعتماد على العديد من المقاييس لقياس أداء كلا من الخوارزميات المستخدمة في قياس التصنيف الإئتماني، وتتضمن هذه المقاييس مصفوفة التداخل والتي تضمن كلا من معدل الخطأ من النوع الأول والنوع الثاني بالإضافة إلي إجمالي دقة التصنيف ACC rate والمساحة تحت منحنى الخاصية التشغيلية للمستقبل Reciving operating Area Under Charachtersitics Curve، حيث تم الإعتماد عليهم كمقاييس لتقييم أداء النماذج في كل نموذج للقياس التصنيف الإئتماني (Tinoco et. Al. 2013)

٦-٣ إختبار فروض البحث :

سوف يقوم الباحثون بإختبار الفروض الفرعية للدراسة ثم بعد ذلك إختبار الفرض الرئيسي للدراسة:

إختبار الفرض الفرعي الأول:

يؤدي النموذج المحاسبي باستخدام خوارزمية الشبكات العصبية الإصطناعية ANN إلي تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية الغابة العشوائية RF (Random Forest) في عملية قياس مستوي التصنيف الإئتماني للشركات المقيدة بسوق الأوراق المالية المصري"

لإختبار صحة الفرض، قام الباحث بإجراء تشغيل لبيانات الدراسة باستخدام خوارزمية الشبكات العصبية الإصطناعية ANN وخوارزمية الغابة العشوائية RF، ثم إجراء مقارنة بين أداء نموذج الشبكات العصبية الإصطناعية ANN ونموذج الغابة العشوائية RF المستخدم في عملية قياس مستوي التصنيف الإئتماني للشركات المقيدة بسوق الأوراق المالية المصري، كما يوضح الجدول

رقم (٨) مقارنة أداء نموذج الشبكات العصبية الاصطناعية ونموذج الغابة العشوائية المستخدم في عملية القياس مستوي التصنيف الائتماني كما يلي .

الجدول (٨) مقارنة أداء نموذج الشبكات العصبية الاصطناعية ANN و نموذج الغابة العشوائية RF

Model	ANN	RF
Accuracy (%)	89.2%	87.6%
Recall (%)	89.2%	87.6%
Precision (%)	89.1%	87.4%
F1-Score (%)	89%	87.2%
AUC	0.98	0.97

يبين الجدول رقم (٨) السابق، تفوق نموذج الشبكات العصبية الاصطناعية ANN على الغابة العشوائية RF، حيث حقق نموذج الشبكات العصبية الاصطناعية ANN أعلى معدل دقة في التصنيف يساوي (٨٩,٢٪)، وأيضاً حقق نموذج الشبكات العصبية الاصطناعية ANN قيمة Recall (٨٩,٢٪) وقيمة Precision (٨٩,١٪)، وقيمة F1-Score (٨٩٪)، كما يتضح من الجدول أن الشبكات العصبية الاصطناعية حققت مساحة تحت المنحني AUC معدل ما يقرب إلي (٩٨٪)، بينما حقق نموذج الغابة العشوائية RF معدل دقة في التصنيف يساوي (٨٧,٦٪)، وأيضاً حقق نموذج الغابة العشوائية RF قيمة Recall (٨٧,٦٪) وقيمة Precision (٨٧,٤٪)، وقيمة F1-Score (٨٧,٢٪)، كما يتضح من الجدول أن نموذج الغابة العشوائية RF حقق مساحة تحت المنحني AUC معدل ما يقرب إلي (٩٧٪)، ويتضح مما سبق، تفوق نموذج الشبكات العصبية الاصطناعية ANN بمعدلات دقة مرتفعة لكل من معدل الدقة، وقيمة Recall، وقيمة Precision، والمساحي تحت المنحني AUC مقارنة بالخوارزمية الغابة العشوائية RF، وعليه يمكن قبول الفرض الأول القائل:

يؤدي النموذج المحاسبي باستخدام خوارزمية الشبكات العصبية الاصطناعية ANN إلي تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية الغابة العشوائية (Random Forest) RF في عملية قياس مستوي التصنيف الائتماني للشركات المقيدة بسوق الأوراق المالية المصري

إختبار الفرض الفرعي الثاني:

يؤدي النموذج المحاسبي باستخدام خوارزمية الشبكات العصبية الاصطناعية ANN إلي تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية متجهات الدعم الآلي (Support Vector Machine) SVM في عملية قياس مستوي التصنيف الائتماني للشركات المقيدة بالبورصة المصرية

لإختبار صحة الفرض، قام الباحث بإجراء تشغيل لبيانات الدراسة باستخدام خوارزمية الشبكات العصبية الاصطناعية ANN وخوارزمية متجهات الدعم الآلي SVM، ثم إجراء مقارنة بين أداء نموذج الشبكات العصبية الاصطناعية ANN ونموذج متجهات الدعم الآلي SVM

المستخدم في عملية قياس مستوي التصنيف الائتماني للشركات المقيدة بسوق الأوراق المالية المصري، كما يوضح الجدول رقم (٩) مقارنة أداء نموذج نموذج الشبكات العصبية الاصطناعية ANN ونموذج متجهات الدعم الآلي SVM والمستخدم في عملية القياس التصنيف الائتماني كما يلي .

الجدول (٩) مقارنة أداء نموذج الشبكات العصبية الاصطناعية ANN ونموذج متجهات الدعم الآلي SVM

Model	ANN	SVM
Accuracy (%)	89.2%	87.8%
Recall (%)	89.2%	87.8%
Precision (%)	89.1%	88.2%
F1-Score (%)	89%	87.4%
AUC	0.98	0.98

يبين الجدول رقم (٩) السابق، تفوق نموذج الشبكات العصبية الاصطناعية ANN على نموذج متجهات الدعم الآلي SVM، حيث حقق نموذج الشبكات العصبية الاصطناعية ANN أعلى معدل دقة في التصنيف يساوي (٨٩,٢٪)، وأيضاً حقق نموذج الشبكات العصبية الاصطناعية ANN قيمة Recall (٨٩,٢٪) وقيمة Precision (٨٩,١٪)، وقيمة F1-Score (٨٩٪)، كما يتضح من الجدول أن الشبكات العصبية الاصطناعية حققت مساحة تحت المنحني AUC معدل ما يقرب إلي (٩٨٪)، بينما حقق متجهات الدعم الآلي SVM معدل دقة في التصنيف يساوي (٨٧,٨٪)، وأيضاً حقق متجهات الدعم الآلي SVM قيمة Recall (٨٧,٨٪) وقيمة Precision (٨٨,٢٪)، وقيمة F1-Score (٨٧,٤٪)، كما يتضح من الجدول أن متجهات الدعم الآلي SVM حققت مساحة تحت المنحني AUC معدل ما يقرب إلي (٩٨٪)، ويتضح مما سبق، تفوق نموذج الشبكات العصبية الاصطناعية ANN بمعدلات دقة مرتفعة لكل من معدل الدقة، وقيمة Recall، وقيمة Precision، والمساحة تحت المنحني AUC مقارنة بخوارزمية متجهات الدعم الآلي SVM، وعليه يمكن قبول الفرض الثاني القائل:

يؤدي النموذج المحاسبي باستخدام خوارزمية الشبكات العصبية الاصطناعية ANN إلى تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية متجهات الدعم الآلي (Support Vector Machine) في عملية قياس مستوي التصنيف الائتماني للشركات المقيدة بالبورصة المصرية"

إختبار الفرض الفرعي الثالث:

يؤدي النموذج المحاسبي باستخدام خوارزمية متجهات الدعم الآلي (Suport Vector Machine) إلى تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية الغابة العشوائية (Random Forest) في عملية قياس مستوى التصنيف الائتماني للشركات المقيدة بالبورصة المصرية"

لإختبار صحة الفرض، قام الباحث بإجراء تشغيل لبيانات الدراسة باستخدام خوارزمية متجهات الدعم الآلي (Suport Vector Machine) وخوارزمية الغابة العشوائية (Random Forest) ، ثم إجراء مقارنة بين أداء نموذج متجهات الدعم الآلي (Suport Vector Machine) ونموذج الغابة العشوائية (Random Forest) المستخدم في عملية قياس مستوى التصنيف الائتماني للشركات المقيدة بسوق الأوراق المالية المصري، كما يوضح الجدول رقم (١٠) مقارنة أداء نموذج متجهات الدعم الآلي SVM ونموذج الغابة العشوائية RF والمستخدم في عملية قياس التصنيف الائتماني كما يلي .

الجدول (١٠) مقارنة أداء نموذج متجهات الدعم الآلي SVM ونموذج الغابة العشوائية RF

Model	SVM	RF
Accuracy (%)	87.8%	87.6%
Recall (%)	87.8%	87.6%
Precision (%)	88.2%	87.4%
F1-Score (%)	87.4%	87.2%
AUC	0.98	0.97

يبين الجدول رقم (١٠) السابق، تفوق متجهات الدعم الآلي SVM على نموذج الغابة العشوائية RF حيث حقق متجهات الدعم الآلي SVM أعلى معدل دقة في التصنيف يساوي (٨٧,٨٪)، وأيضاً حقق متجهات الدعم الآلي SVM قيمة Recall (٨٧,٨٪) وقيمة Precision (٨٨,٢٪)، وقيمة F1-Score (٨٧,٤٪)، كما يتضح من الجدول أن متجهات الدعم الآلي SVM حققت مساحة تحت المنحنى AUC معدل ما يقرب إلي (٩٨٪)، بينما حقق نموذج الغابة العشوائية RF قيمة Recall (٨٧,٦٪) وقيمة Precision (٨٧,٤٪)، وقيمة F1-Score (٨٧,٢٪)، كما يتضح من الجدول أن نموذج الغابة العشوائية RF حقق مساحة تحت المنحنى AUC معدل ما يقرب إلي (٩٧٪)،

ويتضح مما سبق، تفوق نموذج متجهات الدعم الآلي SVM بمعدلات دقة مرتفعة لكل من معدل الدقة، وقيمة Recall، وقيمة Precision، والمساحى تحت المنحنى AUC مقارنة بالخوارزمية الغابة العشوائية RF، وعليه يمكن قبول الفرض الثالث القائل:

يؤدي النموذج المحاسبي باستخدام خوارزمية متجهات الدعم الآلي (Suport Vector Machine) إلى تحقيق معدلات دقة أعلى مقارنة باستخدام خوارزمية الغابة العشوائية (Random Forest) في عملية قياس مستوى التصنيف الائتماني للشركات المقيدة بالبورصة المصرية"

إختبار الفرض الرئيسي

يمكن بناء نموذج محاسبي لقياس مستوى التصنيف الائتماني باستخدام تقنيات الذكاء الاصطناعي بالتطبيق علي الشركات المقيدة بالبورصة المصرية"

يعرض الجدول رقم (١١) نتائج استخدام كل من أساليب تقييم النماذج: (معدل الدقة Accuracy (%))، (دقة الاسترجاع Recall (%))، (دقة الدقة Precision (%))، (F1-Score (%)) كمقاييس لتقييم أداء نماذج الدراسة، وفي نفس الوقت مقارنة أداء تقنيات الذكاء الاصطناعي المستخدمة في بناء نماذج التصنيف الائتماني (نموذج الشبكات العصبية الاصطناعية ANN، متجهات الدعم الآلي SVM، نموذج الغابة العشوائية RF)

الجدول (١١)

مقارنة أداء تقنيات الذكاء الاصطناعي المستخدمة في عملية قياس مستوي التصنيف الائتماني

Model	Accuracy (%)	Recall (%)	Precision (%)	F1-Score (%)	AUC
ANN	89.2%	89.2%	89.1%	89%	0.98
SVM	87.8%	87.8%	88.2%	87.4%	0.98
RF	87.6%	87.6%	87.4%	87.2%	0.97

يبين الجدول رقم (١١) السابق، تفوق نموذج الشبكات العصبية الاصطناعية ANN يليها متجهات الدعم الآلي SVM يليها نموذج الغابة العشوائية RF بمعدل دقة Accuracy (%) في التصنيف يساوي (٨٩,٢٪، ٨٧,٨٪، ٨٧,٦٪) على التوالي، أيضاً بالنسبة لباقي الأساليب التقييم (Recall، Precision، F1-Score، AUC)، وعليه يمكن قبول الفرض الرئيسي القائل

" يمكن بناء نموذج محاسبي لقياس مستوى التصنيف الائتماني باستخدام تقنيات الذكاء الاصطناعي بالتطبيق علي الشركات المقيدة بالبورصة المصرية"

٤-٦ إختيار نموذج الدراسة :

يبين الجدول رقم (١٢) نتائج معدلات الدقة التي توصلت إليها بعض الدراسات السابقة في بناء نماذج قياس التصنيف الائتماني باستخدام تقنيات الذكاء الاصطناعي المختلفة، حيث وجد الباحثون أن معدلات الدقة التي توصلت لها الدراسة تتراوح من (٨٩,٢٪) لنموذج الشبكات العصبية الاصطناعية ANN، ٨٧,٨٪ لنموذج متجهات الدعم الآلي SVM، و٨٧,٦٪ لنموذج الغابة العشوائية RF.

المجلة العلمية للدراسات والبحوث المالية والتجارية (م٦، ع١٤، ج٢، يناير ٢٠٢٥)
أ.محمد طلعت محمد سالم؛ د. داليا عادل عباس السيد؛ د. وائل عبد القادر عوض

جدول رقم (١٢) ملخص ما توصلت إليه الدراسات السابقة

تقنيات الذكاء الاصطناعي		عدد المتغيرات	الدراسة	م
Classification Accuracy	Method			
85%	ANN	87	(Garavaglia, 1991)	1
36%	ANN	10	(Moody & Utans, 1994)	2
60 %	MDA	16	(Shin and Han., 2001)	3
62 %	CBR			
75.5%	GA-CBR			
69.1%	LVQ+CBR	32	(K.S. Kim, Han, 2001)	4
67.1%	SOM+CBR			
61.1%	CBR			
55%	MDA			
84%	MLP	8	(D. Brennan, A.Brabazon., 2004)	5
79.3%	MLP	12	(Z. Huang, et. al., 2004)	6
80%	SVM			
80%	ANN			
83.8%	ALN	26	(K.S. Kim., 2005)	7
84%	ANN			
84.9%	GE	8	(A. Brabazon. et. al., 2006)	8
85%	ANN			
83.3%	MLP			
85.2%	MDA			
84.6%	SVM	17	(L. Cao, et. Al. 2006)	9
80.3%	ANN			
77.9%	LR			
67.2%	SVM	29	(Y.C Lee et al., 2007)	10
63.4%	CBR			
58.8	MDA			
72.8%	OLR	24	(R.C. Hwang. et. al., 2009)	11
85.9%	ANN	24	(Khashman, 2010)	12
64.23%	ANN	10	(Kim & Sohn, 2010)	13
66.16%	SVM			
88.5%	PNN	6	(P. Hajek, 2010)	14
85.6%	RBF			
87.4%	SVM			
76%	OPM	4	(R.C. Hwang. et. al. 2010)	16
81.1%	OSPM			

68%	SVM	14	(K. Kim, et. al. 2012)	17
67.3%	SVM			
65.7%	FFNN			
83.7%	GCM	6	(P. Hajek. et. al. 2011)	18
85.8%	HGM			
89.76%	SVM			
59.6%	AFRBS	11	(P. Hajek. et. al. 2012)	19
84%	DT	18	(Ch. et. al. 2012)	20
74.4%	SVM			
74.4%	SVM	18	(Yeh et al., 2012)	21
88.44%	ANN	20	(Hajek & Olej, 2014)	22
87.28%	SVM			
86%	SVM	18	(Pai et al., 2015)	23
82.55%	ANN	15	(Khemakhem & Boujelbene, 2015)	24
87%	ANN	20	(Zhao et al., 2015)	25
70%	DT	33	(Veronezi, 2016)	26
83%	ANN	17	(Daniel et al., 2019)	27
63.6%	ANN	27	(Wallis et al., 2019)	28
60.1%	SVM			
64.6%	DT			
84%	DT	26	(Moscatelli et al., 2019)	29
84.21%	DT	20	(Parisa et al., 2020)	30
82.83%	RF			
73.95%	MLP			
42.12%	ONE-SVM			
40.14%	ALL-SVM			

مما سبق يتضح للباحثين أن نموذج الشبكات العصبية هو النموذج الأفضل في قياس مستوى التصنيف الإئتماني بالتطبيق علي الشركات المقيدة بسوق الأوراق المالية المصري حيث حقق معدل دقة قدره ٢, ٨٩٪ وهو أعلى معدل دقة بالنسبة لمعدلات الدقة المحققة لنماذج الدراسة وهو تقريباً في حدود نفس المعدلات الدقة التي توصلت إليها الدراسات السابقة.

نتائج البحث :

- يعد التصنيف الائتماني للشركات أحد المهام الرئيسية للتنبؤ المتعلقة بالقطاع المالي، الذي يعتمد على التحليل المالي في تقييم الجدارة الائتمانية.
- هناك العديد من الجهات المستفيدة من عملية التصنيف الائتماني حيث يعتبر هدفاً في حد ذاته تسعى الكثير من المؤسسات والشركات المالية المختلفة للحصول عليه، وذلك لضرورة الحفاظ على إستقرار الأسواق المالية ولأداء دورها بشكل فعال ولتلاشي ما يمكن أن يزعزع هذا الإستقرار.
- تزايدت أهمية التصنيف الائتماني في النظام الإقتصادي العالمي، لاسيما بعد إنفتاح الأسواق وإنماجها، وتغير دور البنوك، وتوجه المستثمرين نحو إستخدام أدوات مالية جديدة في الحصول على التمويل، وتزايد الإصدارات من المنتجات المالية المركبة ذات المخاطر المرتفعة، كما يستخدم التصنيف الائتماني في قياس وزن المخاطر المالية، والتي من خلالها تتحدد المتطلبات القانونية لرأس المال، حسب مقررات لجنة بازل .
- الدرجات الائتمانية التي يوفرها نظام التصنيف الائتماني تساعد في إتخاذ القرارات التمويلية الصحيحة مما يسهم في الحد من مخاطر الإئتمان حيث تتمثل أهمية التصنيف الائتماني في تسهيل الدخول إلي أسواق رأس المال، وبناء سمعة حسنة في السوق تنعكس على مختلف الأطراف المتعاملة فيه، مع تخفيض تكاليف التمويل، بالإضافة إلي التمييز عن المنافسين.
- يعد إستخدام المعلومات المحاسبية في قياس التصنيف الائتماني له أهمية كبيرة لما له من دلالة في تكوين نماذج لقياس التصنيف الائتماني حيث وجدت إرتباط معنوي بين قياس التصنيف الائتماني والمعلومات المحاسبية.
- يعتبر تقنيات الذكاء الاصطناعي أحد المداخل الواعدة في مجال التصنيف الائتماني والتي إعتمدت عليها العديد من الدراسات البحثية في مجال قياس والتصنيف الائتماني للشركات في تطوير نماذج التنبؤ لما لها من أثر إيجابي على أداء هذه النماذج من ناحية الكفاءة والقدرة على التكيف ومستوي الدقة.
- تتمثل فاعلية الذكاء الاصطناعي على دعم عملية إتخاذ القرار داخل المنظمة وتزويد متخذي القرار بمعلومات ذات صلة في الوقت المناسب.
- يسعى الذكاء الاصطناعي إلي معالجة كم هائل من المعلومات إلكترونياً، والإستثمار الأمثل للخبرات والمعرفة وتخزين المعلومات المرتبطة بالذكاء الاصطناعي مما يؤدي إلي تقديم تلك المعلومات لمستخدميها بسرعة فائقة وتطوير خبرات ومعارف حديثة وإستخدامها في عملية إتخاذ القرارات.
- تكمن أهمية تطبيقات الذكاء الاصطناعي في علم المحاسبة من خلال إيجاد آلات وبرامج تعمل على تسهيل وتسريع مهام المحاسب وأصحاب المنشآت حيث تعمل هذه التطبيقات على توفير الوقت والجهد المبذول في المهام المحاسبية المتكررة من خلال إستخدام الآلات للقيام بها مثل عملية إدخال البيانات.
- تفوق نموذج الشبكات العصبية الاصطناعية ANN بمعدل دقة ٨٩,٢٪، على نموذج منجهاث الدعم الآلي SVM بمعدل دقة ٨٧,٨٪، وعلى نموذج الغابة العشوائية RF بمعدل دقة ٨٧,٦٪ .

- جميع جوانب المحاسبة تهتم بشكل رئيسي بالمعلومات وبالتالي تتأثر بتقنيات الذكاء الاصطناعي حيث يمكن تطبيق أنواع منها على أنشطة المعلومات المختلفة للمحاسبة، حيث توفر تقنيات الذكاء الاصطناعي القدرة على معالجة وتخزين كميات هائلة من البيانات وتقصير دورة المعالجة .
- توفر تقنيات الذكاء الاصطناعي القدرة على تحليل البيانات وعمل التنبؤات بدرجة عالية من الدقة والصدق، مما يعني قدرة تقنيات الذكاء الاصطناعي على استخدام إجراءات التحليل المالي من أجل بناء نموذج التصنيف الائتماني

٣-٥ التوصيات

- ضرورة تبني التوجه القائم على أن التصنيف الائتماني كمدخل مهم من مداخل الهندسة المالية .
- ضرورة مواكبة التطورات وملاحقة الأنظمة الحديثة وخاصة في مجالات تقنيات الذكاء الاصطناعي في مجال التحليل المالي والهندسة المالية، وتدريب القائمين عليها من خلال رفع الكفاءة لديهم، باعتبار تطبيق تقنيات الذكاء الاصطناعي من المتطلبات الأساسية للرقابة على الجودة.
- ضرورة قيام الهيئة العامة للرقابة والمركز المصري للدراسات الإقتصادية، بإنشاء قاعدة بيانات تضم تاريخية عن درجات التصنيف الائتماني للشركات تمثل قاعدة بيانات للشركات، تساعد في كسب ثقة المستثمرين وتحسين وتعزيز سمعة الشركات.
- ضرورة قيام الجمعيات المهنية بتصميم ضوابط أخلاقيه لإستخدام تقنيات الذكاء الاصطناعي وأثرها في تحسين جودة عمليات التحليل المالي، من خلال إصدار قوانين وتعليمات تساعد على عدم إختراق المعلومات.
- العمل على زيادة مساهمة المؤسسات التعليمية والجهات الحكومية المعنية بجانب التدريب، مع العمل على إخراج كوادر قادرة ومتخصصة في تقنيات الذكاء الاصطناعي.

المراجع:

المراجع العربية:

- أمين ، عصام ، (٢٠١٧) " تصميم نموذج محاسبي لتقييم مخاطر الإئتمان باستخدام الشبكات العصبية الجينات الوراثية والإستدلال المبني على الحالات السابقة - دراسة تطبيقية .، رسالة دكتوراة ، كلية التجارة ، جامعة الإسكندرية.
- الجبالي & ,عصام الدين. (٢٠٢٠). العلاقة بين التعثر المالي ودورة الأعمال: دراسة تطبيقية على السوق المصري .مجلة جامعة الإسكندرية للعلوم الإدارية. 31-54, (3)57 ,
- الدهراوي ، كمال الدين ، (٢٠١٦) . " تحليل القوائم المالية لأغراض الإستثمار " المكتب الجامعي الحديث ، دار وائل للنشر ، الإسكندرية ، ص.ص ٢٠٥-٢٤٠ .
- فاضل، أحمد، (٢٠٢٠). " نموذج مقترح للتنبؤ بالتعثر المالي للشركات باستخدام الشبكات العصبية " دراسة تطبيقية على الشركات الصغيرة والمتوسطة في قطاع الأعمال المصري " رسالة دكتوراه ، كلية التجارة، جامعة الزقازيق .
- مداني أحمد، (٢٠١٣). " دور وكالات التصنيف الإئتماني في صناعة الأزمات في الأسواق المالية ومتطلبات إصلاحها " مجلة الأكااديمية للدراسات الاجتماعية والإنسانية ، قسم العلوم الإقتصادية والقانونية ، العدد ١٠، ص.ص ٥٣-٦١ .
- هندي ، منير ابراهيم، (٢٠٠٤) . " الفكر الحديث في مجال الإستثمار ، دار المعرفة الجامعية ، الإسكندرية.

English References:

- Ahmed, A. S., Billings, B. K., Morton, R. M., & Stanford-Harris, M. (2002). The role of accounting conservatism in mitigating bondholder-shareholder conflicts over dividend policy and in reducing debt costs. *The Accounting Review*, 77(4), 867-890.
- Akar, E. C., & Gokdemir, T. (2015). The Comparision of the financial failure with artificial neural network and logit models. *Journal of Business Economics and Finance*, 4(3).
- Al-Najjar, D., & Al-Najjar, B. (2014). Developing a multi stage predicting system for corporate credit rating in emerging markets. *Journal of Enterprise Information Management*.
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance*, 23(4), 589-609.

- Altman, E. I., & Sabato, G. (2007). Modelling credit risk for SMEs: Evidence from the US market. *Abacus*, 43(3), 332-357.
- Altman, E.I. Hotchkiss, E. Wang, W. (2019). *Corporate Financial Distress Restructuring, and Bankruptcy. Analyze Leveraged Finance, Distressed Debt, and Bankruptcy. 4th Edition. Page 189-216. United States of America: Wiley Finance Series.*
- Altman, Edward I., Edith Hotchkiss,. 2006. *Corporate Financial Distress and Bankruptcy. 3 th edition. New Jersey: John Wiley & Sons*
- Asgharian, H. (2005). *Reformation of the credit rating industry-is there a need (Doctoral dissertation, Master Thesis, Institution of Business Studies).*
- Balios, D., Thomadakis, S., & Tsiouri, L. (2016). Credit rating model development: An ordered analysis based on accounting data. *Research in International Business and Finance*, 38, 122-136.
- Batta, G. (2011). The direct relevance of accounting information for credit default swap pricing. *Journal of Business Finance & Accounting*, 38(9-10), 1096-1122.
- Belkaoui, A. (1980). The impact of socio-economic accounting statements on the investment decision: An empirical study. *Accounting, Organizations and Society*, 5(3), 263-283.
- Bharath, S. T., & Shumway, T. (2008). Forecasting default with the Merton distance to default model. *The Review of Financial Studies*, 21(3), 1339-1369.
- Bonsall, S. B., & Miller, B. P. (2017). The impact of narrative disclosure readability on bond ratings and the cost of debt. *Review of Accounting Studies*, 22, 608-643.
- Brabazon, A., & O'Neill, M. (2006). Credit classification using grammatical evolution. *Informatica*, 30(3).
- Brennan, D., & Brabazon, A. (2004). *Corporate Bond Rating Using Neural Networks. In IC-AI (pp. 161-167).*
- Cafarelli, A..(2020) . Creditworthiness risk over years: The evolution of credit rating standards. *Journal of Corporate Accounting & Finance. DOI: 10.1002/jcaf.22461*
- Campbell, J. Y., Hilscher, J., & Szilagyi, J. (2008). In search of distress risk. *The Journal of finance*, 63(6), 2899-2939.
- Cao, L., Guan, L. K., & Jingqing, Z. (2006). Bond rating using support vector machine. *Intelligent Data Analysis*, 10(3), 285-296.

-
-
- Carlenius, B., Døvik, E. K., Kolberg, J. K., Waage, K., & Aanes, B. (2017). Corporate Credit Rating using Deep Learning with Genetic Algorithms.
 - Chen, W., & Shi, L. (2013, December). Credit scoring with F-score based on support vector machine. In Proceedings 2013 International Conference on Mechatronic Sciences, Electric Engineering and Computer (MEC) (pp. 1512-1516). IEEE.
 - Chen, Y. S., & Cheng, C. H. (2013). Hybrid models based on rough set classifiers for setting credit rating decision rules in the global banking industry. *Knowledge-Based Systems*, 39, 224-239.
 - Choubey, D. K., & Paul, S. (2017). GA_SVM: A classification system for diagnosis of diabetes. In *Handbook of research on soft computing and nature-inspired algorithms* (pp. 359-397). IGI Global.
 - Cortes, C. (1995). Support-Vector Networks. *Machine Learning*.
 - Courtis, J. K. (1978). Modelling a financial ratios categoric framework. *Journal of Business Finance & Accounting*, 5(4), 371-386.
 - Daniel, S. A. A., Pugazhenthii, R., Kumar, R., & Vijayananth, S. (2019). Multi objective prediction and optimization of control parameters in the milling of aluminium hybrid metal matrix composites using ANN and Taguchi-grey relational analysis. *Defence Technology*, 15(4), 545-556.
 - Dastile, X., Celik, T., & Potsane, M. (2020). Statistical and machine learning models in credit scoring: A systematic literature survey. *Applied Soft Computing*, 106263.
 - Dimitris Balios, Stavros Thomadakis, Lena Tsipouri (2016) , Credit rating model development: An ordered analysis based on accounting data, *Research in International Business and Finance* 38 (2016) 122–136 <https://doi.org/10.1016/j.ribaf.2016.03.011>
 - Doumpos, M., Niklis, D., Zopounidis, C., & Andriosopoulos, K. (2015). Combining accounting data and a structural model for predicting credit ratings: Empirical evidence from European listed firms. *Journal of Banking & Finance*, 50, 599-607.
 - Du Jardin, P. (2016). A two-stage classification technique for bankruptcy prediction. *European Journal of Operational Research*, 254(1), 236-252.
 - Dutta, & Shekhar. (1988, July). Bond rating: a nonconservative application of neural networks. In *IEEE 1988 International Conference on Neural Networks* (pp. 443-450). IEEE.
 - Ederington, L. H. (1985). Classification models and bond ratings. *Financial review*, 20(4), 237-262.

- Elbel, B., Mijanovich, T., Kiszko, K., Abrams, C., Cantor, J., & Dixon, L. B. (2017). The introduction of a supermarket via tax-credits in a low-income area: the influence on purchasing and consumption. *American Journal of Health Promotion*, 31(1), 59-66.
- Fedorova, E., Gilenko, E., & Dovzhenko, S. (2013). Bankruptcy prediction for Russian companies: Application of combined classifiers. *Expert systems with applications*, 40(18), 7285-7293.
- Feng, X., Xiao, Z., Zhong, B., Qiu, J., & Dong, Y. (2018). Dynamic ensemble classification for credit scoring using soft probability. *Applied Soft Computing*, 65, 139-151.
- Ferri, G., Liu, L. G., & Stiglitz, J. E. (1999). The procyclical role of rating agencies: Evidence from the East Asian crisis. *Economic notes*, 28(3), 335-355.
- Frost, C. A. (2007). Credit rating agencies in capital markets: A review of research evidence on selected criticisms of the agencies. *Journal of Accounting, Auditing & Finance*, 22(3), 469-492.
- Fu, K., Cheng, D., Tu, Y., & Zhang, L. (2016, October). Credit card fraud detection using convolutional neural networks. In *International Conference on Neural Information Processing* (pp. 483-490). Springer, Cham.
- Galil, K., Hauptman, A., & Rosenboim, R. L. (2023). Prediction of corporate credit ratings with machine learning: Simple interpretative models. *Finance Research Letters*, 58, 104648.
- Garavaglia, S. (1991). An application of a counter-propagation neural network: Simulating the standard and poor's corporate bond rating system. In *First international conference on artificial intelligence applications on Wall Street, 1991. Proceedings* (pp. 278-287). IEEE
- García, S., Luengo, J., & Herrera, F. (2015). Data preprocessing in data mining (Vol. 72, pp. 59-139). Cham, Switzerland: Springer International Publishing.
- Golbayani, P., Florescu, I., & Chatterjee, R. (2020). A comparative study of forecasting corporate credit ratings using neural networks, support vector machines, and decision trees. *The North American Journal of Economics and Finance*, 54, 101251.
- Golbayani, P., Wang, D., & Florescu, I. (2020). Application of deep neural networks to assess corporate credit rating. *arXiv preprint arXiv:2003.02334*.

- Goldstein, I., & Huang, C. (2020). Credit rating inflation and firms' investments. *The Journal of Finance*, 75(6), 2929-2972
- Hajek, P. (2012). Credit rating analysis using adaptive fuzzy rule-based systems: An industry-specific approach. *Central European Journal of Operations Research*, 20(3), 421-434.
- Hajek, P., & Olej, V. (2011). Credit rating modelling by kernel-based approaches with supervised and semi-supervised learning. *Neural Computing and Applications*, 20(6), 761-773.
- Hajek, P., & Olej, V. (2014). Predicting firms' credit ratings using ensembles of artificial immune systems and machine learning—an over-sampling approach. *IFIP international conference on artificial intelligence applications and innovations* (pp. 29-38). Springer.
- Henley, W. E., & Hand D. J., 1996. A k nearest-neighbour classifier assessing consumer credit risk. *The Statistician*, 45(1), 77-95.
- <http://www.fitchratings.com>
- Huang, Z., Chen, H., Hsu, C.-J., Chen, W.-H., & Wu, S. (2004). Credit rating analysis with support vector machines and neural networks: A market comparative study. *Decision Support Systems*, 37(4), 543-558.
- Huang, Z., Chen, H., Hsu, C.-J., Chen, W.-H., & Wu, S. (2004). Credit rating analysis with support vector machines and neural networks: A market comparative study. *Decision Support Systems*, 37(4), 543-558.
- Hung, J. L., He, W., & Shen, J. (2020). Big data analytics for supply chain relationship in banking. *Industrial Marketing Management*, 86, 144-153.
- Hwang, R. C., Cheng, K. F., & Lee, C. F. (2009). On multiple-class prediction of issuer credit ratings. *Applied stochastic Models in business and industry*, 25(5), 535-550.
- Hwang, R. C., Chung, H., & Chu, C. K. (2010). Predicting issuer credit ratings using a semiparametric method. *Journal of Empirical Finance*, 17(1), 120-137.
- Jackson, R. H., & Wood, A. (2013). The performance of insolvency prediction and credit risk models in the UK: A comparative study. *The British Accounting Review*, 45(3), 183-202.
- James, G. M., & Sugar, C. A. (2003). Clustering for sparsely sampled functional data. *Journal of the American Statistical Association*, 98(462), 397-408.

- Jiang, Y. (2022). Credit ratings, financial ratios, and equity risk: A decomposition analysis based on Moody's, Standard & Poor's and Fitch's ratings. *Finance Research Letters*, 46, 102512.
- Jones, S., Johnstone, D., & Wilson, R. (2015). An empirical evaluation of the performance of binary classifiers in the prediction of credit ratings changes. *Journal of Banking & Finance*, 56, 72-85.
- Kaplan, R. S., & Urwitz, G. (1979). Statistical models of bond ratings: A methodological inquiry. *Journal of business*, 231-261.
- Khashman, A. (2010). Neural networks for credit risk evaluation: Investigation of different neural models and learning schemes. *Expert Systems with Applications*, 37(9), 6233-6239.
- Khemakhem, S., & Boujelbene, Y. (2015). Credit risk prediction: A comparative study between discriminant analysis and the neural network approach. *Accounting and Management Information Systems*, 14(1), 60.
- Kim, H. S., & Sohn, S. Y. (2010). Support vector machines for default prediction of SMEs based on technology credit. *European Journal of Operational Research*, 201(3), 838-846.
- Kim, K. J., & Ahn, H. (2012). A corporate credit rating model using multi-class support vector machines with an ordinal pairwise partitioning approach. *Computers & Operations Research*, 39(8), 1800-1811.
- Kim, K. S. (2005). Predicting bond ratings using publicly available information. *Expert Systems with Applications*, 29(1), 75-81.
- Kim, K. S., & Han, I. (2001). The cluster-indexing method for case-based reasoning using self-organizing maps and learning vector quantization for bond rating cases. *Expert systems with applications*, 21(3), 147-156.
- Koh, H. C., Tan, W. C., & Peng, G. C. (2004). Credit scoring using data mining techniques. *Singapore Management Review*, 26(2), 25.
- Kulkarni, V. Y., & Sinha, P. K. (2012, July). Pruning of random forest classifiers: A survey and future directions. In *2012 International Conference on Data Science & Engineering (ICDSE)* (pp. 64-68). IEEE.
- Lee, S., & Choi, W. S. (2013). A multi-industry bankruptcy prediction model using back-propagation neural network and multivariate discriminant analysis. *Expert Systems with Applications*, 40(8), 2941-2946.
- Lee, Y. C. (2007). Application of support vector machines to corporate credit rating prediction. *Expert Systems with Applications*, 33(1), 67-74.

- Lessmann, S., Baesens, B., Seow, H. V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, 247(1), 124-136.
- Li, D., Lu, Y., Ng, T., & Yang, J. (2016). Does trade credit boost firm performance?. *Economic Development and Cultural Change*, 64(3), 573-602.
- Li, J. P., Mirza, N., Rahat, B., & Xiong, D. (2020). Machine learning and credit ratings prediction in the age of fourth industrial revolution. *Technological Forecasting and Social Change*, 161, 120309.
- Ma, Y. (2018). Predicting Credit Ratings with Statistical Learning Methods.
- Martin, D. (1977). Early warning of bank failure: A logit regression approach. *Journal of banking & finance*, 1(3), 249-276.
- Mizen, P., & Tsoukas, S. (2012). Forecasting US bond default ratings allowing for previous and initial state dependence in an ordered probit model. *International Journal of Forecasting*, 28(1), 273-287.
- Mock, T. (2012). "Standard & Poor's Ratings Definitions, Process, Methodology and Performance". Standard & Poor's. PP.7. for more information, refer to, www.understandingratings.com
- Moody, J. & Utans, J. (1994). Architecture selection strategies for neural networks: Application to corporate bond rating prediction. In *Neural networks in the capital markets* (pp. 277-300). Citeseer
- Moscatelli, M., Parlapiano, F., Narizzano, S., & Viggiano, G. (2020). Corporate default forecasting with machine learning. *Expert Systems with Applications*, 161, 113567.
- Moseley, N. (2003). Modeling economic time series using a focused time lagged feedforward neural network. *Proceedings of Student Research Day*, CSIS, Pace University.
- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of accounting research*, 109-131.
- Ortíz Rodríguez, J. M., Martínez Blanco, M. D. R., Cervantes Miramontes, J. M., & Vega Carrillo, H. R. (2013). Robust design of artificial neural networks methodology in neutron spectrometry. *IntechOpen*.
- Oshiro, T. M., Perez, P. S., & Baranauskas, J. A. (2012). How many trees in a random forest?. In *Machine Learning and Data Mining in Pattern Recognition: 8th International Conference, MLDM 2012, Berlin*,

- Germany, July 13-20, 2012. Proceedings 8 (pp. 154-168). Springer Berlin Heidelberg.
- Pacelli, V., Bevilacqua, V., & Azzollini, M. (2011). An artificial neural network model to forecast exchange rates. *Journal of Intelligent Learning Systems and Applications*, 3(02), 57.
 - Pagano, M., & Volpin, P. (2010). Credit ratings failures and policy options. *Economic Policy*, 25(62), 401-431.
 - Pai, P.-F., Tan, Y.-S., & Hsu, M.-F. (2015). Credit rating analysis by the decision-tree support vector machine with ensemble strategies. *International Journal of Fuzzy Systems*, 17(4), 521-530.
 - Paliwal, M., & Kumar, U. A. (2009). Neural networks and statistical techniques: A review of applications. *Expert Systems with Applications*, 36(1), 2-17.
 - Pasiouras, F., Gaganis, C., & Zopounidis, C. (2006). The impact of bank regulations, supervision, market structure, and bank characteristics on individual bank ratings: A cross-country analysis. *Review of Quantitative Finance and Accounting*, 27, 403-438.
 - Ruiter-Gangol, M., Krutzer, S., & Oberwart, V. S. (2016). FLIP YOUR CLASSROOM!.
 - Shin, K. S., & Han, I. (2001). A case-based approach using inductive indexing for corporate bond rating. *Decision Support Systems*, 32(1), 41-52.
 - Standard & Poor's, "Commentary Report- Recovery Analytics Update: Enhanced Recovery Scale And Issue Ratings Framework", Standard & Poor's, NY, 2007, P. 1.
 - Standard & Poor's, "Sovereign Credit Ratings: A Primer", The McGraw-Hill Companies, NY, 2006, P. 1.
 - Tichy, G., Lannoo, K., Ap Gwilym, O., Alsakka, R., Masciandaro, D., & Paudyn, B. (2011). Credit rating agencies: Part of the solution or part of the problem?. *Intereconomics*, 46(5), 232-262.
 - Tinoco, R. O., & Coco, G. (2014). Observations of the effect of emergent vegetation on sediment resuspension under unidirectional currents and waves. *Earth Surface Dynamics*, 2(1), 83-96.
 - Uddin, M. S., Chi, G., Al Janabi, M. A., & Habib, T. (2022). Leveraging random forest in micro-enterprises credit risk modelling for accuracy and interpretability. *International Journal of Finance & Economics*, 27(3), 3713-3729.

-
-
- Vapnik, V. (2013). The nature of statistical learning theory. Springer science & business media.
 - Veronezi, P. H. (2016). Corporate credit rating prediction using machine learning techniques (Doctoral dissertation, Stevens Institute of Technology).
 - Wallis, M., Kumar, K., & Gepp, A. (2019). Credit Rating Forecasting Using Machine Learning Techniques. In Managerial Perspectives on Intelligent Big Data Analytics (pp. 180-198). IGI Global.
 - Wang, D., Wang, T., & Florescu, I. (2020). Is Image Encoding Beneficial for Deep Learning in Finance?. IEEE Internet of Things Journal.
 - Wanke, P., Azad, M. A. K., Barros, C. P., & Hassan, M. K. (2016). Predicting efficiency in Islamic banks: An integrated multicriteria decision making (MCDM) approach. Journal of International Financial Markets, Institutions and Money, 45, 126-141.
 - West, R. R. (1970). An alternative approach to predicting corporate bond ratings. Journal of Accounting Research, 118-125.
 - White, L. J. (2009). The credit-rating agencies and the subprime debacle. Critical Review, 21(2-3), 389-399.
 - WU, Desheng; MA, Xiyuan & Olson, D. L. (2022). Financial distress prediction using integrated Z-score and multilayer perceptron neural networks. Decision Support Systems, 159, 113814.
 - www.mood's.com
 - www.mood's.com
 - Xia, Y., Liu, C., Da, B., & Xie, F. (2018). A novel heterogeneous ensemble credit scoring model based on bstacking approach. Expert Systems with Applications, 93, 182-199.
 - Xiao, Y., Wang, H., Xu, W., & Zhou, J. (2016). Robust one-class SVM for fault detection. Chemometrics and Intelligent Laboratory Systems, 151, 15-25.
 - Yang, S., & Islam, M. T. (2020). Principal component analysis and factor analysis for feature selection in credit rating. arXiv preprint arXiv:2011.09137.
 - Yeh, C. C., Lin, F., & Hsu, C. Y. (2012). A hybrid KMV model, random forests and rough set theory approach for credit rating. Knowledge-Based Systems, 33, 166-172.
 - Zhao, Z., Xu, S., Kang, B. H., Kabir, M. M. J., Liu, Y., & Wasinger, R. (2015). Investigation and improvement of multi-layer perceptron neural

networks for credit scoring. *Expert Systems with Applications*, 42(7), 3508–3516.

- Zhong, H., Miao, C., Shen, Z., & Feng, Y. (2014). Comparing the learning effectiveness of BP, ELM, I-ELM, and SVM for corporate credit ratings. *Neurocomputing*, 128, 285-295.
- Zmijewski, M. E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting research*, 59-82
- Zurada, J. (1992). Introduction to artificial neural systems. West Publishing Co. Akar, E. C., & Gokdemir, T. (2015). The Comparison Of The Financial Failure With Artificial Neural Network And Logit Models. *Journal of Business Economics and Finance*, 4(3).

A Proposed Accounting Model to Measure the Level of Credit Rating Using Artificial Intelligence Techniques - An Empirical Study on the Egyptian Listed companies

Abstract

This research aims to build an accounting model to measure the credit rating of Egyptian companies listed on the Egyptian Stock Exchange using accounting data from financial statements. The researchers rely on modern artificial intelligence techniques (Artificial Neural Networks (ANN), Support Vector Machines (SVM), and Random Forest (RF) models). The study is based on 34 accounting variables and was conducted on 103 companies registered on the Egyptian Stock Exchange during the period from 2016 to 2021. The study found that the accuracy rates of the models indicate that the Artificial Neural Networks (ANN) model outperformed the others with an accuracy rate of 89.2%, while the Support Vector Machines (SVM) model achieved an accuracy rate of 87.8%, and the Random Forest (RF) model achieved an accuracy rate of 87.6%. The study recommends that investors rely on credit rating models to ensure early warning and avoid the risks associated with making incorrect investment decisions.

Keywords:

Credit Rating, Artificial Intelligence Techniques, Accounting Data