

تقييم أداء نماذج الذكاء الاصطناعي في التنبؤ بالتعثر المالي

دراسة تطبيقية على الشركات المقيدة في البورصة خلال الفترة من 2007-2022¹

أ.د. إيمان محب زكي

أستاذ الإقتصاد- كلية الإدارة والتكنولوجيا
الأكاديمية العربية للعلوم والتكنولوجيا والنقل
البحري - جمهورية مصر العربية
imanzaki@asst.edu

مروة محمد عبد الرازق

باحثة دكتوراه- كلية الدراسات العليا
الأكاديمية العربية للعلوم والتكنولوجيا والنقل
البحري - جمهورية مصر العربية
m1721979@gmail.com

د. وائل مصطفى حسن

أستاذ مساعد الإستثمار والتمويل
وكيل كلية العلوم المالية - جامعة فاروس
جمهورية مصر العربية
dr.wael.moustafa@pua.edu.eg

ملخص البحث

تهدف هذه الدراسة إلى تقييم أداء نماذج الذكاء الاصطناعي، مع التركيز على نماذج تعلم الآلة الخاضع للإشراف وغير الخاضع له، وذلك في التنبؤ بالتعثر المالي، ولتحقيق هدف الدراسة تم اختيار نماذج تعلم الجماعي Ensemble Learning كأحد أنواع تعلم الآلة الخاضع للإشراف، وخوارزميات التجميع Clustering Algorithm كأحد أنواع تعلم الآلة غير الخاضع للإشراف، وذلك على 44 شركة مقيدة في البورصة المصرية تعمل في القطاع العقاري والتشييد ومواد البناء خلال الفترة من 2007 حتى 2022. أسفرت نتائج الدراسة عن تفوق أداء مجموعة التعلم الجماعي (ENSEMBLELEARNING) الخاضعة للإشراف على نموذج (CLUSTERING ALGORITHM) غير الخاضع للإشراف.

الكلمات الدالة

نماذج التعلم الجماعي Ensemble Learning - خوارزميات التعلم Clustering Algorithm - التنبؤ بالتعثر المالي (EM- Z - SCORE) - الذكاء الاصطناعي.

¹ تم تقديم البحث في 2024/9/23، وتم قبوله للنشر في 2024/11/26.

(1) المقدمة

بدأ الاهتمام بالتعثر المالي منذ الثلاثينيات من القرن العشرين بعد تعرض العديد من الشركات الأمريكية للتعثر والإفلاس، وظهرت نماذج التنبؤ بالتعثر المالي، والتي اعتمدت على النسب المالية، مثل: نموذج (Altman, 1968; Beaver, 1966; Kida, 1980; OLson, 1980).

ومع مرور الوقت شغل التنبؤ بالتعثر المالي جانبًا من اهتمام الباحثين، وأدرجت العديد من الدراسات العوامل الاقتصادية وأليات الحوكمة مثل دراسات (Dewin et al., 2023; Souse et al., 2022) عند التنبؤ بالتعثر المالي. ومع تطور تكنولوجيا المعلومات اقترح عدد من الباحثين (Aly et al., 2022; Anong & Kamsami, Wu et al., 2024) (2023).

استخدام نماذج الذكاء الاصطناعي وخاصة التعلم الجماعي Ensemble Learning الذي أثبت تفوقه على باقي نماذج تعلم الآلة الخاضعة للإشراف، مثل: SVM, DT, ANN، كما أثبت نموذج التعلم الجماعي تفوقه على النماذج الإحصائية التقليدية، مثل: نموذج تحليل التمايز الخطي، ونموذج تحليل التمايز المتعدد، وتحليل الانحدار الخطي، وتحليل الانحدار اللوجستي عند التنبؤ بالتعثر المالي.

تعد خوارزميات التجميع CLUSTEING ALGORITHM أحد آليات الذكاء الاصطناعي المستخدمة في التنبؤ بالتعثر المالي في عدد من الدراسات، مثل: دراسة (Justin et al. (2020)، والذي أثبت تفوقه على باقي نماذج تعلم الآلة الخاضعة للإشراف مثل SVM, DT, ANN. كما أثبت نموذج خوارزميات التجميع تفوقه على النماذج الإحصائية التقليدية مثل: نموذج تحليل التمايز الخطي، ونموذج تحليل التمايز المتعدد، وتحليل الانحدار الخطي، وتحليل الانحدار اللوجستي عند التنبؤ بالتعثر المالي. إلا أنه ما زال ليس من الواضح أي من نماذج تعلم الآلة (التعلم الجماعي أم خوارزميات التجميع Clustering Algorithm أكثر فعالية في التنبؤ بالتعثر المالي؛ ومن ثمَّ تستهدف هذه الدراسة تقييم أداء خوارزميات التجميع Clustering Algorithm ونماذج التعلم الجماعي في التنبؤ بالتعثر المالي.

تشكل هذه الدراسة إضافة مهمة للأدبيات الحالية من خلال تقديم تحليل عميق لأداء نماذج التعلم الجماعي وخوارزميات التجميع في التنبؤ بالتعثر المالي، وتعد نماذج التعلم الجماعي من الأساليب الحديثة التي تعتمد على دمج عدة نماذج التعلم الآلي لتحقيق دقة تنبؤ عالية من خلال هذه الدراسة، والتي تسعى إلى توضيح كيفية استخدام هذه النماذج بكفاءة لفهم العوامل المؤثرة في التعثر المالي للشركات.

وتساعد نتائج هذه الدراسة في تحسين دقة التنبؤ بالتعثر المالي من خلال استخدام نماذج التعلم الجماعي؛ مما يوفر للمؤسسات والشركات أداة قوية لتحليل المخاطر المالية واتخاذ القرارات المستنيرة، كما توفر الدراسة رؤى عملية حول كيفية تطبيق خوارزميات التجميع في السياق المالي؛ مما يساعد الشركات على تحسين استراتيجيتها المالية وتقليل مخاطر التعثر المالي.

وبناء على ما تقدم تنقسم الدراسة إلى سبعة أجزاء: الجزء الأول المقدمة، الجزء الثاني أدبيات الدراسة، الجزء الثالث مشكلة الدراسة، الجزء الرابع المنهجية، الجزء الخامس نتائج الدراسة، الجزء السادس المناقشة، الجزء السابع التوصيات ومقترحات للأبحاث اللاحقة.

(2) أدبيات الدراسة

تستعرض الدراسة في هذا الجزء أدبيات الدراسة التي تتضمن الإطار النظري والدراسات السابقة، وذلك كما يلي:
الإطار النظري: تتضمن الدراسة في هذا الجزء المفاهيم الأساسية وأنواع الذكاء الاصطناعي، كما تتطرق الدراسة إلى مفهوم التعثر المالي ومقاييسه ومحدداته، وذلك على النحو التالي:

(1-2) التعثر المالي

(1-1-2) تعريف التعثر المالي

عرفت (Maya et al. (2021) التعثر المالي بأنه المرحلة التي تسبق إفلاس أو تصفية الشركات، وتبدو حالات التعثر المالي في تحقيق صافي خسارة من العمليات التشغيلية أو تحقيق صافي ربح وانخفاض القيمة الدفترية. كما تواجه الشركات المتعثرة مشاكل في السيولة؛ مما يؤدي إلى عدم القدرة على سداد التزاماتها تجاه الدائنين، وعدم قدراتها على تحصيل مستحقاتها لطرف الغير، وعدم وجود سياسات واضحة وجيدة للتمويل، وعدم كفاية رأس المال العامل وضعف إدارة الشركة. ويحدث التعثر أحياناً نتيجة الظروف الاقتصادية في دولة ما كالتقلبات في سعر الصرف، والانخفاض المستمر في قيمة العملاء، وتغيير السياسات والقوانين، وفرض الضرائب، وحوادث كوارث طبيعية أو حدوث حروب وثورات.

اختلف الباحثون في تقسيم الشركات إلى شركات متعثرة وغير متعثرة، واستند البعض الآخر إلى نموذج Altman - Z-Score وإصدارته المختلفة، والذي يعد من أكثر النماذج انتشاراً في تصنيف الشركات إلى متعثرة وغير متعثرة، وشركات قد تقع في التعثر المالي (المنطقة الرمادية).

واستخدم بوجلخة (2021) نموذج ALTMAN الخاص بالأسواق الناشئة لتحديد مدى استقرار البنوك الإسلامية والبنوك التقليدية خلال الفترة من 2008 حتى 2015. وتوصلت الدراسة إلى أن البنوك الإسلامية محل الدراسة تقع في المنطقة الرمادية، وذلك بخلاف البنوك التقليدية التي تتواجد في منطقة الاستقرار المالي.

وتناولت دراسة (Gyarteng (2021) تحديد العوامل المؤثرة في التعثر المالي مستخدماً نموذج Altman Z Score، وذلك على شركات التعدين الأمريكية المتعثرة خلال الفترة من 2006-2016. واستخدمت الدراسة معادلة الانحدار الخطي ومعامل الارتباط في تحديد العلاقة بين النسب المالية الخاصة بالربحية والإنتاجية والسيولة والملائمة المالية ومعدلات النشاط، حيث أوضحت الدراسة أن مؤشرات الربحية (الأرباح المحتجزة/إجمالي الأصول)، والإنتاجية (صافي الربح قبل الفائدة والضرائب/إجمالي الأصول)، ونسب السيولة (رأس المال العامل/إجمالي الأصول)، والملائمة المالية (القيمة السوقية لحقوق الملكية/إجمالي الالتزامات)؛ ترتبط بعلاقة ذات دلالة إحصائية بالتعثر المالي للشركات، أما معدلات النشاط (المبيعات/إجمالي الأصول) لا تؤثر في التعثر المالي للشركات.

وفي باكستان استهدفت دراسة (Younas et al. (2021) تحديد تأثير عناصر الحوكمة، مثل: ملكية الأسهم ومجلس الإدارة وحجم الشركة، في التعثر المالي للشركة، وذلك على 152 شركة غير مالية مقيدة في البورصة خلال الفترة من 2003 إلى 2017، واستخدمت الدراسة نموذج Altman Z Score 1968 لقياس التعثر المالي، وبناء على التحليل الإحصائي للبيانات استخلصت الدراسة وجود علاقة ذات دلالة إحصائية بين عامل مجلس الإدارة وهو الحجم

والوظيفة الأزواجية للعضو التنفيذي وبين التعثر المالي، وأشارت الدراسة إلى أن ملكية الأسهم تؤثر في التعثر المالي للشركات.

واستخدمت دراسة Rashid et al. (2021) في تحديد حالات EM-SCORE MODEL في تحديد التعثر المالي في البنوك الهندية المقيدة بالبورصة خلال الفترة من 2013-2014 و 2019-2020، وتتكون العينة من خمسة بنوك خاصة وخمسة بنوك عامة، وأشارت الدراسة إلى أن البنوك الهندية محل الدراسة غير متعثرة، وكما استخلصت الدراسة من نتائج T-TEST, ANOVA على تباين Z SCORE في البنوك العامة عن البنوك الخاصة. حيث تظهر Z-Score استقراراً مادياً في البنوك الخاصة أعلى من البنوك العامة.

استخدمت دراسة Justin et al. (2020) نموذج التعلم الآلي غير الخاضع للإشراف k-Means Clustering في تصنيف الشركات الخاصة بالرعاية الصحية في الولايات المتحدة الأمريكية إلى متعثرة معرضة للتعثر وغير معرضة للتعثر، وذلك على 255269 مستشفى خلال الفترة من 2000 حتى 2015. واعتمدت على متغيرات نموذج Altman المعدل 1993 والخاص بالشركات الصناعية والشركات غير الصناعية في تحديد العوامل الخاصة بالتعثر المالي، كما استخدمت منحنى تحليل التمايز لتحديد السمات التي تؤثر في تصنيف الشركات الثلاثي. وأوضحت الدراسة أن معدلات الربحية والسيولة لها تأثير جوهري في التعثر المالي للشركات، واختبرت الدراسة دقة النموذج المستخدم، حيث أثبتت الدراسة قدرة k-Means Clustering على تصنيف الشركات إلى متعثرة ومعرضة للتعثر وغير معرضة للتعثر بنسبة 44%، بل حدوث التعثر بسنة، و41% قبل حدوث التعثر بستين، و39% قبل حدوثه بثلاث سنوات. وتقرن الدراسة الحالية k-Means Clustering النماذج غير الخاضعة للإشراف والنماذج الخاضعة للإشراف التعلم الجماعي. وتعتمد الدراسة الحالية على نموذج EM-ZSCORE.

(2-1-2) نموذج EM- Z Score التعثر المالي

وفي عام 2005 طور Altman نموذج "z" أطلق عليه EM-ZSCORE ليتماشى مع الدول النامية، حيث يستدل على هذا المؤشر بمدى قدرة الشركة على مواجهة التدهور في العملة وطبيعة الصناعة وقدراتها على المنافسة. وتأخذ معادلة score "z" الشكل التالي:

$$Z''=3.25+6.56X_1+3.26X_2+6.72X_3+1.05X_4$$

فإذا كانت $z'' < 1.1$ فإن الشركات في حالة تعثر، $z'' > 2.6$ تكون الشركة في حالة عدم تعثر، وفي حالة وجود z'' 1.10 و 2.60 تكون الشركة في مرحلة الرمادية GREY AREA حيث إن:

$$X_1 = \text{رأس المال العامل/إجمالي الأصول}$$

$$X_2 = \text{الأرباح المحتجزة/إجمالي الأصول}$$

$$X_3 = \text{صافي الربح قبل الفائدة والضريبة/إجمالي الأصول}$$

$$X_4 = \text{القيمة الدفترية لحقوق الملكية/إجمالي الالتزامات}$$

أما 3.25 فهو الحد الثابت في النموذج المشتق من متوسط درجة "Z"، حيث عرفه ALTMAN كما يلي:
{The constant term in the model 3.25 which is derived from the median z" score for Bankrupt US entities, enable US to standardized the analysis so that a default equivalent rating (D) is consistent with the score below zero}, (Altman, 2005)

(3-1-2) محددات التعثر المالي

يرى العديد من الباحثين (Dewin et al., (2022); Mohamed, (2022); Rasheed et al. (2023) Souse et al. (2022) في العصر الحديث ضرورة دمج مؤشرات الاقتصاد الكلي مع المعلومات غير المالية، مثل الحوكمة وخصائص مع المؤشرات المالية، عند التنبؤ بالتعثر المالي، ويمكن شرح بإيجاز كل هذه العوامل:

- مؤشرات الاقتصاد الكلي

يرى الشوادفي وآخرون (2019) أن المتغيرات الاقتصادية تمثل المؤشرات التي تعكس الحالة الاجتماعية التي يتأثر بها الأداء المالي والتشغيلي للشركات، إضافة إلى أن المتغيرات الاقتصادية تؤدي إلى تحسن في أداء نماذج التنبؤ بالتعثر المالي، وتتمثل هذه المتغيرات في أسعار الفائدة ومعدل التضخم والناتج القومي الإجمالي وأسعار الصرف ومعدل النمو وغيرها.

- حوكمة الشركات (المفهوم والآليات)

أما الحوكمة فعرّفها عيد(2015) بأنها مجموعة من المبادئ التي تستهدف توفير إجراءات داخلية فاعلة وأدوات ضبط وتشريعات خارجية قوية؛ ولهذا فإن مفهوم الحوكمة يغطي بعدين: الأول هو الالتزام، حيث تكون الغاية في التحقق من مواجهة وتنفيذ المتطلبات والالتزامات والسياسات التشريعية والقانونية والإدارية، فضلاً عن تلبية توقعات المساهمين وأصحاب المصلحة بأكبر قدر من الأمانة والشفافية، والبعد الثاني: فيتمثل في الأداء، وذلك باستخدام كافة الوسائل لرفع مستوى الأداء الشامل للشركة، والسعي إلى استغلال الفرص الإيجابية المحيطة بها. ويعد من أهم آليات حوكمة الشركات خصائص مجلس الإدارة، مثل: الحجم، والوظيفية المزدوجة للعضو المنتدب، ونسبة أعضاء مجلس الإدارة التنفيذيين في المجلس، وحجم مجلس الإدارة، كما تُعد لجان المراجعة وجودة المراجع الخارجي إحدى آليات الحوكمة.

- المؤشرات المالية

تُعد النسب المالية مؤشراً على مدى قوة أو ضعف المركز المالي للشركة، وتعمل على التنبؤ بالتعثر المالي قبل حدوثه، وتعد من أهم النسب التي تم استخدامها للتنبؤ بالتعثر المالي، وهي:

- نسب السيولة: تهدف هذه النسبة إلى تحليل الأصول المتداولة وتقييمها، وتهدف إلى الحكم على مدى قدرة الشركة في الوفاء بالتزاماتها الحالية والمتداولة قصيرة الأجل، وتتضمن هذه المجموعة نسبة الأصول المتداولة/الخصوم المتداولة، نسبة النقدية/إجمالي الخصوم المتداولة، ومن أشهر نسب السيولة المستخدمة في النماذج الخاصة بالتعثر المالي منذ نموذج Altman, 1968 هي: نسبة الأرباح المحتجزة/إجمالي الأصول.

- نسب النشاط: تستخدم هذه النسب لتقييم مدى نجاح الشركة في إدارة أصولها، وكذلك تقييم دوران المخزون، ومن أشهر هذه النسب المستخدمة في نماذج التعثر المالي (Kida, 1981; Altman, 1968 نسبة المبيعات/إجمالي الأصول).

- نسب المديونية والرفع المالي: تقيس مدى اعتماد الشركة على الديون في تمويل استثماراتها بالمقارنة بالتمويل الذي يقوم به أصحاب المشروع وحملة الأسهم، ومن هذه النسب: القيمة الدفترية لحقوق الملكية/إجمالي الالتزامات.

- نسب الربحية: تقيس هذه النسب نتائج أعمال الشركة ومدى كفاءة السياسات والقرارات الاستثمارية التي اتخذتها إدارة الشركة، ومن أهم هذه النسب المستخدمة في نماذج التعثر المالي: العائد على الأصول (ROA)، (2016).

(2-2) الذكاء الاصطناعي وأنواعه

(1-2-2) تعريف الذكاء الاصطناعي

يعرف الذكاء الاصطناعي بأنه علم وهندسة صناعة الآلات الذكية، وهو علم من علوم الحاسب الآلي التي تعمل على محاكاة السلوك الذكي في أجهزة الحاسب الآلي، ويعد التعلم الآلي فرعًا من فروع الذكاء الاصطناعي الذي يسمح لأنظمة الحاسب بالتعلم مباشرة من الأمثلة والبيانات والخبرة، وذلك من خلال تمكين أجهزة الحاسب من أداء مهام محددة بذكاء. ويمكن للتعلم الآلي تنفيذ عمليات معقدة من خلال التعلم من البيانات بدلًا من اتباع القواعد المبرجة مسبقًا (Tanya et al., 2018)، ويعد التعلم الآلي مزيجًا من الحاسب الآلي والإحصاء مما يتطلب الأمر الكثير من قوة الحاسب الآلي لتشغيل برنامج التدريب، والذي قد يستغرق أسابيع حتى على المعالجات المطورة خصيصًا لمهمة الاشتقاق الرياضي التي تدعم نماذج التعلم الآلي. هناك حاجة إلى الإحصاءات، ويمكن الإشارة إلى قدرة المعالجة المحسنة لأجهزة الكمبيوتر المعاصرة والبيانات الضخمة المتاحة بسهولة في عالم اليوم الرقمي باعتبارها الأسباب الرئيسية للتعلم الآلي التي حظيت باهتمام كبير مؤخرًا، ويتضمن التعلم الآلي استخلاص استنتاجات من الكثير من البيانات، حيث يحدد النموذج الهياكل والعلاقات في البيانات للقيام بذلك، وتكشف الخوارزمية الارتباطات والأنماط الخفية في البيانات من خلال تقديمها عينات من جمع البيانات، وعادة ما يشار إلى هذه المرحلة بمرحلة التدريب لتعميم ما تعلمته، ويجب تدريب الخوارزمية على بيانات جديدة غير معروفة عندما يتعلق الأمر بالتعلم الآلي. ويهتم الباحثون بشكل أساسي بمدى جودة تعميم النماذج على مجموعة البيانات الجديدة (2021) Noviantoro & Huang، وتنقسم تعلم الآلة إلى أربعة أنواع، وهي: تعلم الآلة الخاضع للإشراف، وتعلم الآلة غير الخاضع للإشراف، وتعلم الآلة شبه الخاضع للإشراف، وتعلم الآلة المعزز.

(2-2-2) أنواع الذكاء الاصطناعي

وتعتمد هذه الدراسة على نوعين فقط من التعلم الآلي: وهما تعلم الآلة الخاضع للإشراف، وتعلم الآلة غير الخاضع للإشراف.

○ تعلم الآلة الخاضع للإشراف Supervised Machine: تستند على معلومات مفيدة مع بيانات مصنفة، ويطلق عليها المهمة التي تحركها نظرًا لأنه يستخدم عينة من أزواج المدخلات والمخرجات لتحويل المدخلات في الناتج، ويشترط لذلك أن تكون البيانات مستمرة أو تصنف على أنها مهمة (بيانات منفصلة). (Dovile et al., 2022).

○ أما تعلم الآلة غير الخاضع للإشراف Unsupervised machine: يدور حول العثور على أفضل رسم خرائط مجدية بين المدخلات والمخرجات غير المعروفة. على سبيل المثال: (القابلية للمقارنة)، حيث تستخدم الخوارزمية البيانات لإنشاء تنبؤات، وهناك العديد من الأنماط المختلفة في البيانات التي تمكن إعادة إنشائها بواسطة نماذج التعلم الآلي؛ لأن النماذج عادة ما تكون قابلة للتكيف للغاية، ولا تحصل خوارزميات التعلم غير الخاضع للإشراف على أسماء Labels، وتعد مشكلة التعلم غير الخاضع للإشراف هي العثور على مدخلات (Noviantoro & Huang, 2021).

تقتصر الدراسة الحالية على تقييم أداء نوعين فقط من التعلم الآلي، وهما التعلم الجماعي (Ensemble Learning)، وهو أحد أنواع تعلم الآلة الخاضع للإشراف، وخوارزميات التجميع (Clustering Algorithm)

- التعلم الجماعي Ensemble Learning

يعد تعلم الجماعي Ensemble Learning من نماذج تعلم الآلة الخاضع للإشراف، ويعرف بأنه مصطلح شامل للطرق التي تجمع بين تنبؤات متعددة من خلال مخطط مختلف للتصويت والتجميع، حيث يتم وضع كل تنبؤ بواسطة نموذج أو طريقة مختلفة يشار إليها باسم المتعلم الأساسي، ومنذ تقديمه في أول السبعينيات طورت العديد من النماذج منه في التنبؤ بالتعثر المالي (Zhao et al., 2023)، والتي تفوق أداؤها على النماذج الأخرى من التعلم الخاضع للإشراف مثل SVM. وينقسم تعلم المجموعات Ensemble Learning إلى ثلاث أنواع وهي Boosting و Bagging و Stacking، وستناول الدراسة شرح هذه الأنواع في الجزء التالي:

○ التعزيز Boosting

وهو عبارة عن مجموعة فرعية من أساليب تعلم المجموعات، حيث يتم تدريب مجموعة من النماذج بشكل تسلسلي للسماح لكل نموذج بالتحسين والتعويض عن ضعف سابقة. وتختلف خوارزميات التعزيز في كيفية إنشاء المتعلمين الضعفاء أثناء التعلم عملية التزامي التسلسلي. (Lombarda et al., 2022)

ومن نماذجه التي تتناولها الدراسة نموذج EXTREME GRADIENT BOOSTING: حيث طور هذا النموذج من قبل (Chen & Gustrien, 2016)، وتُعد من مجموعة K-Classification، وهي عبارة عن مجموعة أشجار التصنيف والانحدار، حيث يتم تعيين درجة مرجحة لكل شجرة، وتمثل كل ورقة من الشجرة تكون نتيجة مستهدفة، حيث يتم احتساب التقدير النهائي من خلال جمع k- Fuction الذي يمثل (k- Tree). (Zhao et al., 2023) وتُعد XGBoost أو Extreme Gradient Boosting هي مكتبة محسنة لتعزيز التدرج الموزع مصممة لتكون عالية الكفاءة والمرونة وقابلة للحمل. وينفذ خوارزميات التعلم الآلي في إطار تعزيز التدرج؛ مما يوفر تعزيزًا موازنًا للشجرة يحل العديد من مشاكل علم البيانات بطريقة سريعة ودقيقة، ويحسن XGBoost طريقة تعزيز التدرج الأساسي من خلال إدخال مصطلح تسوية في الوظيفة الموضوعية للتحكم في التركيب الزائد؛ مما يجعله قويًا لمساحات الميزات عالية الأبعاد:

$$Y_{XGB}(x) = \sum_{k=1}^K f_k(x), f_k \in \mathcal{F}$$

حيث F هي مساحة الأشجار، f_k تمثل شجرة فردية، و K هي عدد الأشجار، الوظيفة الموضوعية التي يحسنها XGBoost.

ويتمتع XGBoos بعدد من الميزات يمكن إيجازها فيما يلي:

- يتمتع XG BOOST بميزة المعالجة المتوازنة للبيانات والتي تستخدم جميع مراكز الجهاز قيد التشغيل، حيث إنه قابل للتطوير بشكل كبير ويولد مليارات الأمثلة باستخدام الموزعة أو المتوازنة -عمليات الحساب والتحسين الخوازمي، وجميعها تستخدم الحد الأدنى من الموارد- أنها فعالة للغاية في التعامل مع قضايا، مثل: تصنيف البيانات والمعالجة المسبقة عالية المستوى.
- إن قابلية نقل XG BOOST تجعله متاحًا وسهل الدمج مع العديد من الأنظمة الأساسية.
- ويمكن التعامل مع XG BOOST من خلال لغات البرمجة المتعددة، مثل: Python, Jjava, c++.
- يسمح XG BOOST باستخدام مجموعة واسعة من بيانات الحوسبة، مثل بناء الأشجار عبر مراكز وحدة المعالجة المركزية المتعددة خارج الحوسبة الموزعة للتعامل مع النماذج الكبيرة، وتحسين ذاكرة التخزين المؤقت للاستخدام الفعال للأجهزة.
- مجهز جيدًا للاكتشاف القيم المفقودة والتعامل معها.
- XG BOOST هو مصنف مرن؛ لأنه يمنح المستخدم خيار ضبط الوظيفة على أنها المطلوبة عن طريق تحديد معلمات النموذج.
- يدعم مقاييس التقييم المحددة من قبل المستخدم، بالإضافة إلى التعامل مع مشاكل الانحدار والتصنيف.
- إن توفر XG BOOST على منصات مختلفة يجعل من السهل الوصول إليه واستخدامه.
- تتوفر وظائف الحفظ وإعادة التحميل، حيث يوفر XG BOOST خيار حفظ مصفوفة البيانات وإعادة تشغيله عند الحاجة، وهذا يلغي الحاجة إلى مساحة خارجية.
- التقليل الممتد للأشجار أي إنه في النماذج العادية يتوقف تقليل الأشجار بمجرد حدوث خسارة سلبية تمت بمواجهته، ولكن XG BOOST يتم تقليل الشجرة حتى أقصى عمق للشجرة، كما هو محدد بواسطة المستخدم؛ ومن ثم يتم إجراء التعليم العكسي على نفس الشجرة حتى يتم التحسين وظيفة الخسارة أقل من القيمة المحددة (Dhaliwal, et al. 2018).

نموذج **Adapboost**: تم تطويره من قبل Freund et al. (1996) يولد Adapboost تدريب فرضيات متعددة يعمل على مبدأ الترجيح، فكل نموذج يصحح خطأ الوضع السابق، حيث يكون هذا النموذج قيمة التوزيع الاحتمالي هي أبقى على بيانات التدريب، وتنتج مجموعة تدريب متعددة الأبعاد بشكل متكرر عن طريق أخذ العينات مع الاختلاف وفقًا لهذه القيمة. وبلي ذلك استخدام خوارزمية التعلم من أجل إنشاء مصنف، ويتم احتساب معدل خطأ المصنف الذي أنشئ باستخدام بيانات التدريب، ويتم إعطاء الأوزان باستخدام الخطأ والمزيد من الوزن لبيانات النقاط التي صُنفت بشكل خاطئ، بهذه الطريقة سيتم تصحيح الخطأ في النماذج اللاحقة.

يبدأ التعزيز التكيفي أو AdaBoost بتدريب مصنف أساسي (مثل شجرة القرار) على مجموعة البيانات الأولية، ثم يضبط بشكل متكرر أوزان الحالات المصنفة بشكل غير صحيح، بحيث تركز المصنفات اللاحقة بشكل أكبر على

الحالات الصعبة، النموذج النهائي هو مجموع مرجح لهؤلاء المتعلمين الضعفاء، ويهدف إلى تقليل كل من التحيز والتباين:

$$Y_{AB}(x) = \text{sign}\left(\sum_{i=1}^N \alpha_i h_i(x)\right)$$

حيث $h_i(x)$ هو تنبؤ المتعلم الضعيف و α_i هو وزنه في القرار النهائي. يتم حساب الأوزان α بناءً على معدل الخطأ لكل متعلم ضعيف (Freund & Schapire, 1997).

التعزيز القاطع Cat boost: هو وضع خوارزمية إلى الأمام بواسطة Yandex للتعامل مع البيانات الفئوية بشكل أكثر سهولة، ويقوم على خوارزمية تعزيز التدرج على أشجار القرار المصممة لميزات الإدخال القاطعة، يتعامل مع المتغيرات القاطعة باستخدام خوارزمية مبتكرة لمجموعات الميزات الفئوية عالية الترتيب، ويوفر حلولاً قوية لمنع التجهيز المفرط، ويتم تعريف نموذج CatBoost من خلال مجموع أشجار القرار المضافة بالتتابع، ويتميز Cat boost بقدرته الفريدة، حيث يجعل قدرة السمات الفئوية مفيدة في المعالجة المسبقة للبيانات، ويستخدم التعزيز المطلوب باستخدام إحصائيات الهدف المطلوبة تقنية لحل مشكلة التنبؤ.

CatBoost: هي خوارزمية تستخدم تعزيز التدرج

$$Y_{GB}(x) = \sum_{i=1}^N f_i(x)$$

حيث إن f_i هي شجرة القرارات و N هي عدد الأشجار، وتتضمن خوارزمية Cat boost التعزيز المطلوب.

نموذج Gradient Boosting: طور (Friedman, 2001) النموذج واستخدمه في مشكلة الانحدار والتصنيف، حيث إنه عملية تكرارية لبناء مصنف فرق قوية، وهدفه الجمع بين النماذج الضعيفة للحصول على مقدرين أقوى. وعند عمل النموذج يتم إنشاء أشجار جديدة على أساس في خطأ التنبؤ بالأشجار السابقة، علاوة على ذلك أخذ عينات فرعية عشوائية من التدريب، ويعمل على تسريع البيانات وتحسين دقتها وتعزيز التدرج للتنفيذ، ويساعد أيضاً على التجهيز الزائد والضبط التالي للمعلمات المطلوبة في تعزيز التدرج الانحداري.

يبني Gradient Boosting المجموعة بطريقة حكيمة مثل AdaBoost، ولكنه يسمح بتحسين وظائف الخسارة التعسفية القابلة للتمييز. في كل مرحلة يتم تركيب شجرة الانحدار على التدرج السالب لدالة الخسارة المستخدمة في النموذج. بالنسبة لمشاكل التصنيف عادة ما يكون هذا هو فقدان السجل:

$$Y_{GB}(x) = \sum_{i=1}^N \gamma_i h_i(x)$$

حيث $h_i(x)$ هو التنبؤ لشجرة الانحدار، و γ_i هو حجم الخطوة في التكرار (Friedman, 2001)

نموذج Cart, Classification and Regression Tree: اقترح (Breiman (1984) نموذجاً يُستخدم على نطاق واسع في الإجراءات الإحصائية وخاصة في التصنيف ونماذج الانحدار القائمة على الأشجار، حيث إنه يقوم على التسلسل الهرمي، ويعمل على اختيار أفضل متغير لتقسيم البيانات إلى مجموعتين عند العقدة الجذرية، وهو شكل من أشكال التقسيم التكراري الثنائي، حيث يمكن تقسيم الفواصل إلى أقسام فرعية، ويعين هذا المصنف عضوية فئة تم الحصول عليها بموجب قياس محدد. وتعد Cart إحدى طرق التعلم الآلي والقائمة على التعلم الذاتي من البيانات،

ولها القدرة على اكتشاف العلاقات الخطية بشكل أساسي وجيد في البيانات (Durica et al., 2021). وتأخذ Cart المعادلة التالية:

$$Gini(p) = 1 - \sum_{j=1}^J p_j^2$$

حيث p_j هي نسبة العينات التي تنتمي إلى الفئة z في عقدة معينة، و J هي عدد الفئات. ستختار خوارزمية CART الانقسامات التي تقلل من شوائب Gini أكثر في كل خطوة، وتقسم البيانات بشكل متكرر حتى تفي بمعيار التوقف، أو حتى لا يوفر المزيد من الانقسام مكاسب كبيرة.

نموذج Stacking: اقترح هذا النموذج رولبرت (1992)، وتعتمد Stacking models على بيانات ذات مستويين أساسيين الذين تستخدم المخرجات لتدريب مصنف المخرجات لتدريب مصنف المستوى الثاني (إلى المتعلم الفوقي) للحصول على نتيجة التنبؤ النهائية Liang et al. 2020. كما يعرف The Stacking Classifier بأنه أسلوب تعلم جماعي يجمع بين نماذج التصنيف المتعددة عبر مصنف فوقي. يتم تدريب نماذج المستوى الأساسي بناءً على مجموعة التدريب الكاملة، ثم يتم تدريب النموذج الفوقي على نواتج النموذج الأساسي كميزات. ويتميز Stacking بقدرته الفائقة على الاستفادة من عمل عدد من النماذج الأخرى، والتي تعمل بصورة جيدة في مهام التصنيف والانحدار، وتجعل التنبؤات بالتعثر المالي أفضل من العمل على نموذج فردي من Ensemble—Learning. Muslim & Daszil, (2021)

$$Y_{SC}(x) = f_{meta}(Z)$$

حيث Z هي مصفوفة التنبؤات من التقديرات الأساسية، و F -Meta هي الدالة التي تعلمها المقدر الفوقي. إن استراتيجية التحقق المتبادل المستخدمة في تدريب مصنف Stacking، وخاصة الميزة الذاتية ذات 5 أضعاف في هذه الحالة؛ ضرورة لمنع تسرب المعلومات وضمان بقاء التعميم قويًا (Wolpert, 1992).

وتأخذ الدراسة الحالية نماذج Random Forest و AdaBoost و Gradient Boosting و XGBoost و CatBoost في المستوى الأساسي BASE LEARNING. أما التصنيف الفوقي (META LEARNING) فهو الانحدار اللوجستي، والذي تم تدريبه على الجمع الأمثل بين تنبؤات النماذج الأساسية، وتستخدم التنبؤات التي تم التحقق من صحتها لتعلمي القاعدة كميزات مدخلات للمقدر النهائي.

- التبعيئية (Bagging) (Bootstrap Aggregation)

التبعيئية هي نوع من أنواع Ensemble Learning التي يتم فيها عمل العديد من المتنبئين بشكل مستقل، ويتم دمجها باستخدام بعض من أساليب نماذج المتوسطات مثل المتوسط المرجح أو أغلبية التصويت، ويختلف (Bggging) عن (Boosting) كما في الجدول التالي:

جدول 1: مقارنة بين Boosting و Bggging

التبعيئية Bggging	التعزيز Boosting
التنبؤات/النماذج مستقلة عن بعضها البعض.	المتنبئون/النماذج ليست مستقلة عن بعضها البعض.
لا يوجد التعلم من بعضهم البعض.	يتعلم كل من المتنبئين الفردين في السلسلة إصلاح أخطاء التنبؤ السابقة أو تقليلها بينما يتحرك للأمام بشكل تسلسلي.
يهدف إلى تقليل التباين.	يسعى إلى تقليل التحيز.

ومن أمثلة نماذج التعبئة التي يتم تقييمها في هذه الدراسة هي نموذج الغابات العشوائية (Random Forest).

نموذج الغابات العشوائية: طور هذا النموذج (Breiman, 2001). وهي خوارزمية تعليمية قائمة على الأشجار وعلى وجه الخصوص شجرة القرارات. كما يمكن تعريف الغابات العشوائية بأنها مجموعة من أشجار القرارات التي يتم تدريبها باستخدام عشوائي لمجموعة فرعية مختارة من مجموعة التدريب، ومجموعة مختارة عشوائيًا من المميزات (Lombarda et al., 2022). ويتميز هذا النموذج بالجمع بين نظامي التعبئية والتعزيز لدمج أشجار القرارات الفردية. ويمر نظام الغابات العشوائية على مرحلتين، حيث يتم تحديد المجموعات الفرعية عشوائيًا من مجموعة البيانات الأصلية، ويحدد عشوائيًا مجموعات فرعية من الميزات المستمدة من الميزة الكاملة الأصلية، وبهذه الطريقة يتم تقليل الارتباط بين أشجار القرارات. ويتم اتخاذ القرار النهائي بناء على التصويت، حيث سيتم تصنيف عينة الإدخال على أنها الفئة ذات أغلبية الأصوات (Bao et al., 2019)، وتأخذ (RF) المعادلة.

حيث (x) (Yti) هو التنبؤ بالشجرة: (Breiman, 2001).

$$Y_{RF}(x) = \text{mode} \{Y_{t1}(x), Y_{t2}(x), \dots, Y_{tn}(x)\}$$

- خوارزميات التجميع Clustering Algorithm

يعرف التجميع على أنه طريقة تجميع بيانات غير مسماة unlabeled مع إشراف ضئيل أو معدوم في فئات مختلفة، بحيث تتميز هذه الفئات بصفات متشابهة داخل المجموعة ومختلفة في فئات الأخرى. ويوصف التجميع أيضًا مجموعة البيانات التي تم الحصول عليها إما من الملاحظة المباشرة أو بيانات المحاكاة. كما يوصف بأنه محاولات لتصنيف ملاحظات أو متغيرات مستقلة دون معرفة المتغير المستهدف، ويعد التجميع أحد تقنيات التعلم الآلي غير الخاضع للإشراف، ويهدف خوارزميات التجميع clustering إلى تطوير تقنية من شأنها تحديد التجمعات الطبيعية في البيانات غير المسماة، وتستخدم Clustering للأغراض الرئيسية التالية: اكتساب معرفة مفيدة من البيانات؛ أي توليد الفرضيات والكشف عن الحالات الشاذة وتحديد السمات البارزة ضمن البيانات المغطاة، والتعرف على درجة التشابه بين الأشكال أو الكائنات الحية أو النقاط التي تشمل البيانات. وكوسيلة لتنظيم البيانات وتليخصها من خلال النماذج العنقودية، وبصفة عامة يمر التجميع بعدد من الخطوات، وهي:

- إدخال البيانات.

- تمثيل النمط (استخراج الميزة واختبارها).

- عملية التجميع الاختياري (اختيار خوارزمية التجميع وحساب التشابه والاختلاف).

- تشكيل الكتلة.

- تقييم الأداء (التحقق من صحة المجموعات) (Oyewole&Thopil, 2023).

وتنقسم (Clustering) إلى عدد من الأنواع:

- **Partitional clustering**: هذا هو النهج التكراري الذي يجد التشابه بين النقاط داخل المجموعة إضافة إلى ما يتعلق بمساواتها من الكتلة النفطية الوسطى، بحيث يجب أن تحتوي كل مجموعة على نقطة بيانات وحدة على الأقل. ويجب تخصيص لكل نقطة بيانات لمجموعة واحدة على الأقل. وفي هذه الطريقة تتم تهيئة مراكز الكتلة

أولاً بناء على مقياس معين، ويتم حساب معرفة نقطة البيانات من جميع المراكز ونقطة البيانات المحددة، ويتم تعيينه إلى الكتلة التي تقع مركزها الأوسط على الأقل على مسافة من النقطة الوسطى في النموذج الأصلي، ويتميز هذا النوع من الخوارزميات بالقوة والقابلية للتطوير والبساطة وسهولة الفهم، ولا تتطلب مجال المعرفة وتغيير المجموعات عند إعادة حساب النقطة الوسطى، ومن الأمثلة k- Means, k- Modes, k- Medoids. وتكتفي الدراسة الحالية باستخدام k- means للتنبؤ بالتعثر المالي.

- خوارزمية k- Means: هي خوارزمية تجميع فعالة تخفض مجموع مربعات المسافة، وهي خوارزمية بسيطة تقسم نقاط البيانات إلى نقاط محددة وعدد مجموعات فرعية منفصلة، وبما أن مجموع المربعات هو مربع المسافة الإقليدية المعنى البديهي الأقرب، ويمكن التعبير منها إلى مجموع مربعات مسافة كل قيمة للمتغير إلى قيمة المتوسطة للمتغير.

وتمر k- Means بخطوات الآتية: يتم تعيين البيانات (النقاط) إلى المجموعة التي ينتمي إليها الكتلة الأقرب وإعادة حساب كل كتلة ليكون مركزاً لجميع النقاط المخصصة، ويتم تكرار الخوارزمية حتى يتم استيفاء معيار التوقف، مثل: عدم تغيير في المجموعات Serkan et al 2023، وتأخذ k- Means المعادلة التالية:

$$W(Ck) = \sum_{i=1}^n \min_{j \in C} (\|x_i - \mu_j\|^2)$$

حيث إن $\|x_i - \mu_j\|^2$ هي المسافة الإقليدية بين نقطة البيانات x_i ، ومركز المجموعة μ_j ، و $W(Ck)$ هو مجموع المربعات داخل المجموعة k. تعتبر K-Means حساسة للاختيار الأولي للكتلة المركزية، وقد تتقارب مع الشكل الأمثل؛ لذلك من الشائع تشغيل الخوارزمية عدة مرات مع تكوينات أولية مختلفة (Ja, H., 1979).

- المجموعات الهرمية: يتبع هذا النموذج منهجية التكتل من أعلى إلى أسفل Agglomerative. حيث تُعد كل نقطة بيانات مجموعة منفصلة تامة عن طريق تحديد مقياس مسافة معين يكون القرب بين نقطتين يتم حسابها، ويتم تجميع الأزواج الأقرب معاً في مجموعة واحدة، هذه العملية تستمر بشكل متكرر حتى يتم دمج جميع نقاط البيانات معاً لتكوين نقطة واحدة.

أما النهج الثاني بمجموعة واحدة تحتوي على جميع النقاط، وبعد ذلك يتم تقسيمهم إلى مجموعات منفصلة مع زيادة المسافة بينهم، ويطلق على هذا النهج Divisive (TopDown). تتميز المجموعات الهرمية بأنها لا تحتاج إلى معرفة عدد المجموعات المطلوبة في المرحلة الأولى، ولا توجد معلمات إدخال ضرورية وسهلة التنفيذ.

وتعتمد الدراسة الحالية على نهج Agglomerative في التنبؤ بالتعثر المالي.

- التكتل التجمعي Clustering Agglomerative: هو نهج تجمعي هرمي يبني التجمعات المتداخلة عن طريق الدمج التدريجي للأزواج من التجمعات، وتبدأ هذه الطريقة بكل نقطة بيانات حيث تجمع مجموعاتهما الخاصة، وتجمع بشكل متكرر المجموعات بناء على الحد الأدنى للمسافة الارتباط، حيث يتم دمج جميع النقاط في مجموعة واحدة طبقاً لمعايير الربط مثل طريقة Ward Method التي تقلل من إجمالي التباين داخل المجموعة في كل خطوة، ويتم دمج زوج من المجموعات مع الحد الأدنى من المسافة بين المجموعات؛ مما يساعد في تحديد عدد المجموعات عن طريق فحص مستوى الارتباط الذي يتم فيه دمج المعلومات (Müllner, 2011).

- التجميع على أساس الكثافة **Density Based Clustering**: تعرف هذه الخوارزمية المجموعات بأنها مناطق مستمرة ذات كثافة عالية وتتميز بمعلمتين ϵ (eps): و MinPts تُعد النقطة نقطة أساسية إذا كان لديها أكثر من MinPts داخل ϵ ، وهي نقطة حدودية إذا كان لديها أقل من MinPts داخل ϵ ، ولكنها تقع في نقطة أساسية، ونقطة ضوضاء بخلاف ذلك. لا تتطلب DBSCAN تحديد عدد المجموعات مسبقاً، مما يجعلها مفيدة لمجموعات البيانات ذات المجموعات ذات الأشكال والأحجام المختلفة. تستند الفكرة الرياضية الأساسية إلى مفاهيم إمكانية الوصول إلى الكثافة والاتصال (Ester et al., 1996).

- **Model-Based Clustering**: تستخدم هذه الخوارزميات العديد من النماذج الإحصائية أو الرياضية المحددة مسبقاً لتكوين عناقيد المجموعات. قد يتم تحديد عدد المجموعات مسبقاً على الرغم من أن ذلك ليس ضرورياً، تعمل هذه الخوارزمية على مزيج من الاحتمالية الأساسية وتنشأ مجموعات، ومن أمثلة هذه المجموعة GMM, (Ghosal et al., 2020) COBWEB, NN.

وتتميز هذه الخوارزميات بأنه يمكن تفسير القسم الذي تم الحصول عليه من وجهة نظر إحصائية Vector Quantization (Benabdella et al 2019). وتقتصر هذه الدراسة على نوع واحد من هذه الخوارزميات وهو GMM.

- يعرف **Gaussian Mixed Models (GMM)**: بأنه نموذج احتمالي يفترض أن جميع نقاط البيانات يتم إنشاؤها من خليط لعدد محدود من التوزيعات الغوسية غير معروفة الحدود. والميزة الأساسية للنموذج أنها تولد مجموعات من فرط القطع الناقص (HYPERELLIPSOIDS)، وأخذ الارتباطات الخطية في الاعتبار (Li et al., 2022).

تفترض نماذج Gaussian Mixture أن البيانات يتم إنشاؤها من مزيج من العديد من توزيعات Gaussian مع معلمات غير معروفة GMMs، كما تعرف Gaussian Mixture أنها نماذج احتمالية تسمح بالتجميع الناعم، مما يعني أنه بدلاً من تعيين كل نقطة بيانات لمجموعة واحدة كما تفعل K-Means، فإنها تعطي احتمالية أن تكون نقطة البيانات تنتمي إلى كل مجموعة من المجموعات المحتملة. يتم تقدير معلمات النموذج باستخدام خوارزمية التوقع والتعظيم (EM)، والتي تحدت بشكل متكرر المعلمات لزيادة احتمالية البيانات المعطاة للنموذج، تتمثل الوظيفة الموضوعية ل GMM في وظيفة احتمال اللوغاريتم:

$$\ell(\theta) = \sum_{i=1}^n \log \left(\sum_{k=1}^K \pi_k \mathcal{N}(x_i | \mu_k, \Sigma_k) \right)$$

حيث π_k هو معامل الخلط للمجموعة k ، $\mathcal{N}(x_i | \mu_k, \Sigma_k)$ هو دالة الكثافة الغاوسية للمجموعة k مع متوسط μ_k ومصفوفة التباين Σ_k . θ يمثل بارامترات نموذج المخلوط. وتتسم هذه الآليات بالمرونة بوجه خاص نظراً لقدرتها على تصميم مجموعات ذات أحجام وهيكل ارتباطات مختلفة داخل البيانات (Reynolds, 2009).

(3-2-2) خطوات عمل الذكاء الاصطناعي

تتمثل دورة عمل الذكاء الاصطناعي في سبع خطوات رئيسية:

- جمع البيانات: Data Collection، وتتضمن هذه المرحلة الحصول على البيانات الأولية.

- تنظيف البيانات: وتتم في هذه المرحلة التنظيف الأولي للبيانات، مثل: إزالة الصفوف الفارغة وتحويلها إلى الصيغة التي يستطيع النموذج التعامل معها جعلها جاهزة للاستخدام.
- المعالجة المسبقة للبيانات: وهي ضرورية لأي مشروع كبير أو صغير لأن البيانات الأولية هي بيانات غير منظمة وليست جاهزة لتغذية النموذج، وعادة ما تتضمن المعالجة المسبقة، مثل: التكويد واختيار السمات والميزات والنماذج الذي سيتم تدريبها وتحليل الارتباط.
- تدريب البيانات: حيث يتم في العادة تقسيم البيانات إلى بيانات للاختبار وبيانات للتدريب.
- تقييم النموذج: وذلك من خلال عدد من الاختبارات. (عبد الغني، 2024)، وستوضح الدراسة في الجزء التالي بعض أنواع اختبارات تقييم التعلم الآلي والذي سيتم استخدامها.

(2-2-4) الاختبارات المستخدمة في تقييم النماذج المختلفة

- الدقة - Accuracy: نسبة الملاحظات المتوقعة بشكل صحيح إلى إجمالي الملاحظات، إنه مقياس مفيد عندما تكون الفئات المستهدفة متوازنة بشكل جيد.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

- الاستدعاء - Re call

$$Recall = \frac{TP}{FN + TP}$$

- التذكير الحساسية: نسبة الملاحظات الإيجابية المتوقعة بشكل صحيح إلى جميع الملاحظات في الفئة الفعلية، من المهم بشكل خاص عندما تكون تكاليف الأخطاء السلبية المرتفعة.
- الضبط أو (القيمة التنبؤية الإيجابية) positive predictive value: نسبة الملاحظات الإيجابية المتوقعة بشكل صحيح إلى إجمالي الملاحظات الإيجابية المتوقعة، ترتبط الدقة العالية بمعدل إيجابي زائف منخفض.

$$Precision = \frac{TP}{TP + FP}$$

- درجة F1-Score: المتوسط المرجح للقيم التنبؤية الإيجابية (الضبط) والاستدعاء. تأخذ هذه النتيجة الإيجابيات الخاطئة والسلبيات الخطأ في الاعتبار، تعد هذه الطريقة جيدة للتعبير عن أداء النموذج العام عند التعامل مع الفئات غير المتوازنة.

$$F1 = 2 \times \frac{Precision * Recall}{Precision + Recall}$$

- بالمنطقة الواقعة تحت الخط ROC-AUC: يستخدم هذا المقياس في تقييم أداء نماذج التصنيف، حيث إن الخط ROC هو منحنى احتمالي وAUC هي المنطقة الواقعة تحت المنحنى، ففي حالة أن تبلغ AUC - واحد يكون أداء النموذج مثاليًا، أما في حالة بلوغ AUC-0.5 فيشير ذلك إلى عدم القوة التمييزية للنموذج التصنيف المختبر.

$$AUC = \int_0^1 TPR(t) dFPR\{t\}$$

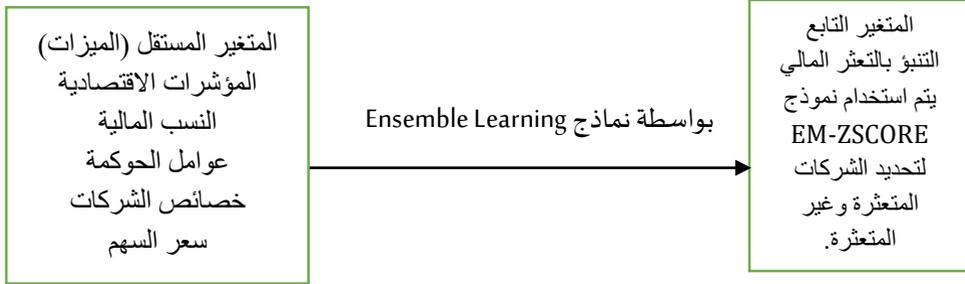
مصفوفة الارتباك CONFUSION MATRIX: هو جدول يستخدم غالبًا لوصف أداء نموذج التصنيف على مجموعة من بيانات الاختبار التي تُعرف القيم الحقيقية لها. إنه جدول عدد الإيجابيات الخاطئة والسلبيات الخاطئة والإيجابيات الحقيقية والسلبيات الحقيقية، مما يسمح بتحليل أكثر تفصيلاً من مجرد نسبة التصنيفات الصحيحة (الدقة).

سيتم تقييم النماذج بناءً على الدقة والدقة والاستدعاء ودرجة F1 وقيم ROC AUC، وستوظف الدراسة أيضًا مصفوفات الارتباك CONFUSION MATRIX لتقييم قابلية تطبيق النماذج التنبؤية في الواقع.

وبناءً على أهداف الدراسة الحالية وهي تقييم أداء نموذجي التعلم الجماعي وخوارزميات التجميع يمكن وضع الإطار العام للدراسة التي تتضمن الخطوات التالية:

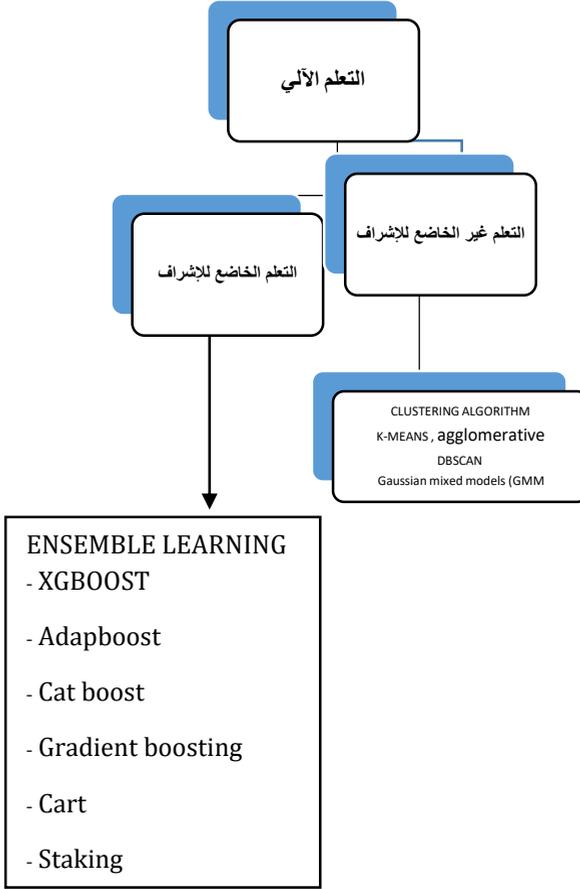
- تحديد العوامل المؤثرة في التعثر المالي

وعليه يمكن تحديد العوامل المؤثرة في التنبؤ بالتعثر المالي وفقاً للشكل التالي:



شكل 1: محددات التعثر المالي

المصدر: من إعداد الباحث



شكل 2: أنواع الذكاء الاصطناعي المختارة وتدريبها

المصدر: من إعداد الباحثة

تقييم أداء النماذج المختارة من خلال اختبارات الدقة و الاستدعاء و المنطقة الواقعة اسفل الخط و F- SCORE

(2-3) الدراسات السابقة

تنقسم الدراسات السابقة إلى جزأين، ذلك بناء على الإطار العام السابق، حيث تركز الدراسة في الجزء الأول على العوامل المؤثرة في التعثر المالي، وتستعرض في الجزء الثاني الدراسات الخاصة بتقييم أداء نماذج التعلم الجماعي وخوارزميات التجميع في التنبؤ بالتعثر المالي على النحو التالي:

- الدراسات الخاصة بالتعثر المالي ومحدداته

○ تأثير خصائص الشركات في التعثر المالي

ففي البرتغال، اعتمدت دراسة Wang & Guedes (2024) على تحليل الانحدار اللوجستي للشركات الصغيرة ومتوسطة الحجم في تحديد العوامل المؤثرة في التعثر المالي، وذلك خلال الفترة من 2010 حتى 2018، واعتمدت الدراسة على بعض النسب المالية، مثل: الربحية والمديونية ومعدلات تغطية الفائدة وخصائص الشركات كالحجم

والعمر، واستخلصت الدراسة أهمية دور حجم الشركة وعمرها في التعثر المالي للشركات، علاوة على مؤشرات الربحية.

واستخدم Hidayat & Yuniati (2024) تحليل الانحدار المتعدد في تحديد العوامل المؤثرة في التعثر المالي، وذلك على شركات معدات النقل المقيمة في إندونيسيا خلال الفترة من 2018-2020، واعتمدت الدراسة على النسب المالية وخصائص الشركات (حجم الشركات)، وخلصت الدراسة إلى وجود علاقة بين نسب التداول وحجم الشركات وربح النشاط وتكاليف النشاط وبين التعثر المالي للشركات، كما أوضحت الدراسة وجود علاقة عكسية بين نسبة الرفع المالي ومعدل نمو المبيعات وبين التعثر المالي للشركات.

واستهدفت دراسة Sponerova et al. (2021) تحديد تأثير حجم الشركات في محددات التعثر المالي في التشيك، وطبقت الدراسة على 2800 شركة صغيرة ومتوسطة الحجم باستخدام تحليل الانحدار اللوجستي. كما استخدمت بعض النسب المالية مثل الربحية: العائد على الأصول/صافي الربح قبل الضريبة/إجمالي الالتزامات والرفع المالي إجمالي الالتزامات/حقوق الملكية، إجمالي الالتزامات/الأصول، ومعدل دوران الأصول ورأس المال العامل/إجمالي الأصول. وأكدت الدراسة أن النسب المالية الخاصة بالرفع المالي والربحية تؤثر تأثيراً جوهرياً في التعثر المالي للشركات، كما أن الشركات متوسطة الحجم تؤثر فيها نسب الرفع المالي والسيولة والنشاط في التعثر المالي.

وأجريت دراسة Dirman (2020) على الشركات الصناعية والكيميائية في إندونيسيا خلال الفترة من 2016-2018، حيث استخدمت مؤشرات الربحية (صافي الربح/إجمالي الأصول) والسيولة (الأصول المتداولة/الخصوم المتداولة، ونسب الرفع المالي: إجمالي الديون/حقوق الملكية) وحجم الشركات (لوغتم الأصول) والتدفقات النقدية الحرة لتحديد العوامل المؤثرة في التعثر المالي، واعتمدت الدراسة على تحليل الانحدار المتعدد، حيث استخلصت وجود علاقة موجبة بين مؤشر الربحية والتعثر المالي، وعلاقة عكسية بين حجم الشركات والتعثر المالي، أما معدلات السيولة ونسب الرفع المالي وصافي التدفق الحر لا تؤثر في التعثر المالي.

وكذلك دراسة Souse et al. (2022) للتنبؤ بالتعثر المالي، وذلك في قطاع التشييد في بلغاريا جمعت بيانات الشركات خلال الفترة من 2009 حتى 2019. واعتمد الباحثون في تطوير الإطار المقترح على دمج المعلومات المالية والاقتصادية مثل الناتج القومي الإجمالي والتضخم وحجم الشركة وعمرها؛ ومن ثم أظهرت الدراسة أن المعلومات الاقتصادية، وخاصة الناتج القومي الإجمالي وخصائص الشركات (عمر الشركة)، تؤثر في التعثر المالي.

استهدفت دراسة El Ansary & Bassam (2019) تحديد العوامل المؤثرة في التنبؤ بالتعثر المالي على الشركات العاملة في دول الشرق الأوسط وشمال أفريقيا، واعتمدت الدراسة على النسب المالية (رأس المال العامل/إجمالي الأصول، صافي الربح قبل الضريبة/إجمالي الالتزامات، الأرباح المحتجزة/إجمالي الأصول، معدل دوران الأصول الثابتة، التدفقات النقدية من العمليات التشغيلية/الربح التشغيلي، التدفقات النقدية/إجمالي الأصول). كما استخدمت الدراسة متغيرات الاقتصاد بالدول، مثل: التضخم ومعدل الاستقرار الأممي، واعتمدت على خصائص الشركات، وهي حجم الشركات، واستخدمت الدراسة تحليل الانحدار اللوجستي؛ وبناء على تحليل الانحدار اللوجستي أكدت الدراسة أن الشركات المتعثرة التي تعاني من عدم كفاءة رأس المال أو خسائر في نتائج الأعمال، أو تعاني من انخفاض شديد في التدفقات النقدية من العمليات التشغيلية (تدفقات نقدية بالسالب) أو أرباح محتجزة منخفضة أو

خسائر مرحلة معرضة للتعثر المالي، كما أكدت الدراسة أن الشركات صغيرة الحجم معرضة بشكل كبير إلى وقوعها في التعثر المالي في حالات التضخم المرتفع وعدم الاستقرار الأمني في الدول التي تعمل فيها هذه الشركات.

وعلى خلاف نتائج الدراسات السابقة أظهرت نتائج بعض الدراسات أن خصائص الشركات ليس لها تأثير جوهري في التعثر المالي للشركات. وفي نيجيريا استهدفت دراسة Appah et al. (2024) تحديد تأثير النسب المالية وخصائص الشركات (الحجم) في التعثر المالي لعدد 60 شركة صناعية مقيدة في البورصة خلال الفترة من 2018-2022. واستخدمت الدراسة تحليل الانحدار و (Generalized Method of Moments (GMM). وتوصلت نتيجة الدراسة إلى وجود علاقة موجبة ذات دلالة إحصائية بين الربحية والتعثر المالي، ووجود علاقة عكسية ذات دلالة إحصائية بين الرفع المالي والتعثر المالي، ووجود علاقة موجبة ليست ذات دلالة إحصائية بين السيولة والتعثر المالي للشركات، ووجود علاقة موجبة ليست ذات دلالة إحصائية بين الحجم والتعثر المالي للشركات.

واستخدمت دراسة Trisandi & Syifa (2024) تأثير نسب السيولة والرفع المالي ومعدل نمو الأرباح وخصائص الشركات (حجم المنظمات) في التعثر المالي لشركات التشيد في إندونيسيا وماليزيا خلال الفترة من 2020-2022، واستخدمت الدراسة تحليل الانحدار المتعدد، وتوصلت إلى وجود علاقة عكسية ذات دلالة إحصائية بين السيولة ومعدل النمو في صافي الربح على التعثر المالي للشركات. وأكدت الدراسة وجود تأثير إيجابي معنوي لنسبة الرفع المالي في التعثر المالي، في حين لم تثبت الدراسة تأثير حجم الشركات في التعثر المالي في شركات التشيد في ماليزيا وإندونيسيا.

- تأثير عوامل الاقتصاد الكلي في التعثر المالي

○ تحديد تأثير عوامل الاقتصاد (مثل التضخم وسعر الصرف وسعر الفائدة والنتائج القومي الإجمالي) في التعثر المالي في الشركات

اهتم العديد من الباحثين بدراسة تأثير عوامل الاقتصاد في التعثر المالي للشركات وخاصة التضخم وسعر الفائدة، وبالمثل استهدفت دراسة Kebede et al. (2024) تحديد العوامل المؤثرة في التعثر المالي للشركات في شركات التأمين الإثيوبية، واعتمدت الدراسة على معلومات الاقتصاد بخلاف النسب المالية، واستخدمت الدراسة تحليل الانحدار الخطي، حيث أثبتت الدراسة وجود علاقة عكسية ذات دلالة إحصائية بين التعثر المالي والعائد على الأصول وحجم الشركة ومعدل النمو في الأرباح، وذلك بخلاف نسبة الرفع المالي، حيث كشفت الدراسة عن وجود علاقة طردية بين نسب الرفع المالي والتعثر المالي، وأشارت الدراسة إلى وجود تأثير جوهري لمعدل التضخم في التعثر المالي.

وفي إندونيسيا استخدمت دراسة Evi and Indra (2022) البيانات المالية لعدد 29 شركة عقارية مقيدة في البورصة خلال الفترة من 2010-2019، لدراسة أثر عوامل الاقتصاد الكلي (التضخم، سعر الصرف، سعر الفائدة، إجمالي الناتج المحلي الإجمالي) في التعثر المالي للشركات محل الدراسة. وأوضحت نتيجة الدراسة أن سعر الصرف يرتبط بعلاقة ذات دلالة إحصائية بالتعثر المالي، في حين سعر الفائدة والنتائج المحلي الإجمالي والتضخم لا تؤثر في التعثر المالي للشركات العقارية في إندونيسيا.

واستهدفت دراسة Zizi et al. (2022) تحديد مدى تأثير عوامل الاقتصاد الكلي (التضخم، سعر الصرف، سعر الفائدة، الناتج القومي الإجمالي) في التعثر المالي في المغرب خلال الفترة من 2010 - 2021. واستخدمت الدراسة تحليل الانحدار الخطي، حيث انتهت إلى أن الناتج القومي الإجمالي والتضخم لا يؤثران في التعثر المالي للشركات،

في حين توجد علاقة طردية ذات دلالة إحصائية بين سعر الفائدة والتعثر المالي، كما أن سعر الصرف يؤثر تأثيراً عكسياً معنوياً في التعثر المالي للشركات.

وكذلك استخدمت دراسة Valentine et al. (2023) في تحديد العوامل المؤثرة في التعثر المالي للمنظمات غير المالية المقيدة في بورصة إندونيسيا خلال الفترة من 2005 حتى 2020، وتوصلت الدراسة إلى أن النقدية/إجمالي الأصول، الأرباح المحتجزة/إجمالي الأصول، الأصول المتداولة- المخزون/إجمالي الأصول؛ ذات تأثير سلبي جوهري في التعثر المالي للشركات، في حين أن الأصول المتداولة/إجمالي الأصول، ونسبة التداول السريع، وسعر الفائدة لها؛ تأثير إيجابي في التعثر المالي للشركات. واستخلصت الدراسة أنه يجب لتفادي التعثر المالي أن تحقق الشركات قدرًا عاليًا من المبيعات، مع توفير السيولة النقدية لسداد الالتزامات قصيرة الأجل مع العمل من أجل الاستمرار في النمو وكبر حجم المنظمات، والحد من الاقتراض لتفادي الفوائد وخدمة الدين الباهظة، ومن الملاحظ أن هذه الدراسة اعتمدت على استخدام أدوات الذكاء الاصطناعي بتطوير نموذج يجمع بين الغابات العشوائية RF ونموذج الانحدار اللوجستي.

اختلفت هذه الدراسة مع دراسة Zizi et al. (2022) في المنهجية المستخدمة، حيث اعتمدت هذه الدراسة أدوات الذكاء الاصطناعي بتطوير نموذج يجمع بين الغابات العشوائية RF ونموذج الانحدار اللوجستي. في حين اعتمدت (Zizi et al. 2022) على أسلوب (تحليل الانحدار الخطي) الإحصائي.

وتختلف الدراسة الحالية مع دراسة Valentine et al, (2023)، حيث إن الدراسة الحالية تستخدم منهجية تحليل الارتباط ونماذج Ensemble Learning، وتتفق معها في استخدامها لنموذج RF. وفي تركيا استخدمت دراسة Isil (2021) أسلوب التعميم للحظات الإحصائية (GMM) لتحديد العلاقة بين النسب المالية وعوامل الاقتصاد، وذلك خلال الفترة 2010-2019. واستخلصت الدراسة أن مؤشرات المالية (نسبة السيولة، التداول السريع، ومعدل دوران الأصول، نسبة الديون، ونسبة الرفع المالي ومعدل دوران الأصول) لها علاقة موجبة ذات دلالة إحصائية بالتعثر المالي، وأنه يوجد علاقة عكسية ذات دلالة إحصائية بين التعثر المالي وعوامل الاقتصاد الكلي.

وفي تركيا استهدفت دراسة Ece and Guven (2020) تحديد أثر عوامل الاقتصاد الكلي في التعثر المالي للشركات، وذلك باستخدام معادلة الانحدار الخطي، حيث أسفرت نتائج الدراسة عن وجود علاقة موجبة ذات دلالة إحصائية بين معدل الفائدة الحقيقي وبين التعثر المالي، وعلاقة عكسية ذات دلالة إحصائية بين معدل النمو الاقتصادي وعرض النقود وبين التعثر المالي، وأشارت الدراسة إلى وجود علاقة عكسية ليست ذات دلالة إحصائية بين معدل البطالة والتعثر المالي للشركات.

واستهدفت دراسة Sairin et al. (2019) تحديد العلاقة بين عوامل الاقتصاد الكلي متمثلة في الناتج القومي الإجمالي ومعدلات التضخم والطلب على النقود وسعر الفائدة، وبين التنبؤ بالتعثر المالي خلال الفترة من 2008-2017 على عدد 21 شركة ماليزية، واستخدم الباحثون معادلة الانحدار الخطي، حيث أظهرت نتائج الدراسة وجود علاقة قوية بين كل من سعر الفائدة والطلب على النقود والتضخم وبين التنبؤ بالتعثر المالي.

وعلى خلاف من نتائج الدراسات السابقة التي اقترحت وجود تأثير قوي لعوامل الاقتصاد الكلي في التعثر المالي، استهدفت دراسة Rinofah et al. (2022) تحديد العوامل المؤثرة في التعثر المالي للشركات في إندونيسيا، واستخدمت الدراسة المؤشرات المالية (معدل التداول، ونسبة الديون/إجمالي الأصول، والعائد على الأصول ومعدل دوران الأصول ومعدل نمو المبيعات)، وكذلك العوامل الاقتصادية (معدلات التضخم، سعر الصرف، سعر الفائدة، معدل النمو الاقتصادي على التعثر المالي). واستخدمت الدراسة أسلوب تحليل الانحدار المتعدد، وأسفرت الدراسة عن وجود علاقة موجبة ذات دلالة إحصائية بين معدلات التداول ودوران الأصول ونمو المبيعات وبين التعثر المالي للشركات، ووجود علاقة عكسية بين نسبة الديون/إجمالي الأصول والتعثر المالي، في حين استنتجت الدراسة عدم وجود علاقة بين المؤشرات الاقتصادية والتعثر المالي للشركات.

كما استهدفت دراسة الطويل، مهنا (2020) تحديد أثر المعلومات المالية (المحاسبية ومعلومات السوق) والعوامل الاقتصادية وخصائص الشركات (عمر وحجم الشركة وطبيعة الصناعة)، ولتحقيق غرض الدراسة تم تجميع بيانات مالية وغير مالية لعدد 62 شركة غير مالية مقيمة في بورصة الكويت ومسقط، واستخدمت الدراسة عددًا من المعلومات المالية الخاصة بالتدفقات النقدية (التدفقات النقدية من العمليات التشغيلية/إجمالي الأصول، التدفقات النقدية من العمليات التشغيلية/إجمالي الالتزامات، التدفقات النقدية من العمليات التشغيلية/الخصوم المتداولة، التدفقات النقدية من العمليات التشغيلية/صافي المبيعات) والربحية (العائد على الأصول/رأس المال العامل/إجمالي الأصول، الأرباح المحتجزة/إجمالي الأصول، بخلاف القيمة السوقية للسهم وربحية السهم) والمعلومات الاقتصادية مثل الناتج القومي الإجمالي. واستخدم الباحثان أسلوب تحليل الانحدار اللوجستي، وتوصلت الدراسة إلى أن المعلومات المالية التي تؤثر في التعثر المالي للشركات هي النسب الخاصة بالتدفقات النقدية والربحية، كما أن المعلومات عن السوق تؤثر في التعثر المالي للشركات، غير أنها أقل تأثيرًا من المعلومات المالية، وأثبتت الدراسة وجود تأثير جوهري لحجم وعمر الشركة في التعثر المالي للشركات، غير أن الدراسة لم تثبت تأثيرًا جوهريًا للمعلومات عن الاقتصاد في التعثر المالي للشركات.

○ تأثير آليات الحوكمة في التعثر المالي للشركات

واستهدف العديد من الباحثين تحديد تأثير عناصر الحوكمة، مثل: مجلس الإدارة (من حيث الحجم – الخبرة – الوظيفة المزدوجة لعضو المنصب – العمر – الأعضاء المستقلين في المجلس – التنوع – عدد مرات انعقاد مجلس الإدارة)، ولجان المراجعة، مثل: عدد مرات انعقاد لجان المراجعة، الأعضاء المستقلين – تبعية لجان المراجعة)، وهيكل الملكية (ملكية المديرين، ملكية المؤسسات)، والمراجع الخارجي من حيث الجودة، غير أن هذه الدراسات اتفقت في حين واختلفت في حين آخر عن تأثير كل أداة من أدوات الحوكمة.

وفي مصر، استهدفت دراسة Rasheed (2023) تحديد أثر الحوكمة في التعثر المالي للشركات المصرية، واستخدمت الدراسة آليات الحوكمة الداخلية متمثلة في لجان المراجعة ومجلس الإدارة وأسلوب تحليل الانحدار الخطي على التعثر المالي، وذلك على 71 شركة مقيمة في مؤشر EGX 100 خلال الفترة من 2017-2021. وأوضحت نتيجة تحليل البيانات وجود علاقة عكسية ذات دلالة إحصائية بين حجم مجلس الإدارة واستقلالية أعضاء مجلس الإدارة وعدد مرات اجتماع المجلس، وبين التعثر المالي للشركات المصرية، وأشارت الدراسة إلى أن وجود حوكمة جيدة بالشركة تخفف من فرص تعرضها للتعثر المالي.

كما استهدفت تحديد متغيرات الحوكمة ورأس المال البشري في الشركات المصرية، واستخدمت (Rasheed (2023) مؤشر EM-Z SCORE على الشركة المقيمة في البورصة، واعتمدت على تحليل الانحدار الخطي، وتختلف الدراسة الحالية عن دراسة (Rasheed (2023) في المنهجية المستخدمة، حيث إنها تعتمد على نماذج التعثر المالي من ناحية ومن ناحية أخرى تقتصر فقط على شركات القطاع العقاري ومواد البناء وقطاع التشييد والمقاولات، كما تختلف دراسة الحالية عن دراسة (Rasheed (2023) في الفترة الزمنية، إذ إن دراسة (Rasheed (2023) تغطي الفترة من 2017-2021، بينما الدراسة الحالية تغطي الفترة الزمنية من 2007-2022.

كذلك استهدفت دراسة (Sakulpolphaisan & Hensawang (2022) تحديد تأثير لجان المراجعة والمعلومات المالية في التنبؤ بالتعثر المالي على الشركات التايلاندية خلال الفترة من 2017-2019 بواقع 161 شركة. وتم تجميع بيانات عن لجان المراجعة في الشركات محل الدراسة (وهي: حجم لجان المراجعة، تمثيل المرأة في لجان المراجعة، خبرة أعضاء لجان المراجعة، عدد الأعضاء المستقلين باللجان المراجعة، عدد مرات انعقاد لجان المراجعة). كما استخدمت الدراسة عددًا من النسب المالية، مثل: السيولة والربحية ونسبة المتعلقة بالسوق، مثل: مضاعف الربحية، واستخدمت الدراسة عمر الشركة وطبيعة الصناعة؛ وبناء على استخدام تحليل الانحدار اللوجستي، واستخلصت الدراسة أن كل عدد مرات انعقاد لجان المراجعة ونسبة إجمالي الالتزامات/إجمالي الأصول: تؤثر في التعثر المالي للشركات محل الدراسة، كما استنتجت الدراسة وجود علاقة سلبية بين التعثر المالي وخبرة أعضاء لجان المراجعة ومضاعف الربحية والعائد على الأصول والتعثر المالي.

وهدفت (Yusra & Bathtera (2021) دراسة تأثير آليات حوكمة الشركات في التعثر المالي في إندونيسيا. ولتحقيق هدف الدراسة حصل الباحثان على عينة من 35 شركة صناعية مقيمة في البورصة خلال الفترة من 2017-2019، واستخدمت الدراسة تحليل الانحدار المتعدد، وتوصلت إلى أن هيكل الملكية واستقلالية مجلس الإدارة لا تؤثر في التعثر المالي في الشركات، غير أن الدراسة توصلت إلى وجود علاقة ذات تأثير جوهري لحجم مجلس الإدارة ولجان المراجعة في التعثر المالي في الشركات.

وفي غانا استهدفت دراسة (Abugri (2022) تحديد أثر آليات حوكمة الشركات، مثل: هيكل الملكية ومجلس الإدارة (حجم مجلس الإدارة، التنوع والمديرين المستقلين) في التعثر المالي في الشركات، وذلك على 15 شركة خلال الفترة 2015-2019. أوضح تحليل الانحدار الخطي أن نسبة التباين في التعثر المالي في الشركات المقيمة كانت بسبب آليات الحوكمة، وأن كل من تنوع وحجم مجلس الإدارة يؤثر في التعثر المالي، وذلك على عكس هيكل الملكية والأعضاء المستقلين في المجلس، وأوصت الدراسة بضرورة تطبيق حوكمة جيدة في الشركات، وذلك لاتخاذ القرارات السليمة التي تحقق أهداف الشركات واستقلاليتها.

وفي إندونيسيا استخدمت دراسة (Nawang et al. (2022) الانحدار الخطي لدراسة تأثير ربحية الشركات وآليات الحوكمة (مجلس الإدارة) في التعثر المالي للشركات خلال الفترة من 2017-2021. وتوصلت نتيجة الدراسة إلى وجود علاقة عكسية ذات دلالة إحصائية بين ربحية الشركات والتعثر المالي، وتدعم هذه النتيجة نظرية الإشارة، واستنتجت الدراسة وجود علاقة موجبة ذات دلالة إحصائية بين حجم مجلس الإدارة والتعثر المالي، وأشار الباحثون إلى أن هذه النتيجة تدعم نظرية الوكالة، غير أن تمثيل المرأة في مجلس الإدارة لا يرتبط بحدوث التعثر المالي للشركات.

واستهدفت دراسة النجار وبسيوني (2022) تحديد أثر خصائص مجلس الإدارة وجودة الأرباح في التعثر المالي في الشركات المصرية المقيدة في البورصة خلال الفترة من 2016-2018، وتم تجميع بيانات عن خصائص مجلس الإدارة، متمثلة في التنوع في الجنس Gender Diversity وحجم مجلس الإدارة والوظيفة المزدوجة للمدير التنفيذي ووجود أعضاء مستقلين في مجلس الإدارة، وجودة الأرباح متمثلة في القدرة على التنبؤ بالأرباح والاستمرارية في تحقيق الأرباح. بالمثل استخدمت الدراسة تحليل الانحدار الخطي المتعدد لتحقيق هدفها، واستخلصت إلى وجود تأثير سلبي جوهري لخصائص مجلس الإدارة في التعثر المالي، وكذلك وجود علاقة عكسية ذات دلالة إحصائية بين جودة الأرباح والتعثر المالي للشركات.

كما استهدفت دراسة Li et al. (2021) تحديد تأثير آليات حوكمة الشركات في 2824 شركة في الصين خلال الفترة من 2003 حتى 2019. واتخذت الدراسة كل من خصائص مجلس الإدارة (حجم مجلس الإدارة والمديرين المستقلين) وهياكل الملكية (ملكية الدولة وملكية أعضاء مجلس الإدارة ومكافآت المديرين، إلى جانب الصفات الشخصية لمجلس الإدارة، مثل عمر رئيس مجلس الإدارة والعضو التنفيذي) للتنبؤ بالتعثر المالي. واستخدمت الدراسة تحليل الانحدار اللوجستي الذي أسفرت نتائجه على أن ملكية الدولة تؤثر في التعثر المالي للشركات. وأشارت الدراسة إلى أنه على الرغم من أهمية الحوكمة في تحقيق الرقابة والإشراف والمسئولية إلا أنه ينبغي دمج المعلومات الاقتصادية والمعلومات المالية لتحديد التعثر المالي.

وفي إندونيسيا استهدفت دراسة Rahmasari (2018) تحديد أثر حوكمة الشركات في التنبؤ بالتعثر المالي وذلك خلال الفترة من 2012-2016 بعدد مشاهدات 605 مشاهدات، حيث عرف الباحث الشركات المتعثرة بأنها تلك الشركات التي تحقق خسائر من العمليات التشغيلية لمدة ثلاث سنوات، وتحقيق صافي تدفقات من العمليات التشغيلية بالسالب لمدة 3 سنوات، ومعدل تغطية الفائدة أقل من واحد لمدة 3 سنوات متتالية، ورمز لها بمتغير وهي (1) وشركات غير المتعثرة رمز لها بصفر؛ وبناء على التعريف السابق وجد أن هناك 220 شركة غير متعثرة و385 متعثرة، واستخدمت الدراسة آليات الحوكمة، مثل: حجم مجلس الإدارة وملكية المديرين واستقلالية أعضاء مجلس الإدارة، واستنتجت الدراسة أن حجم مجلس الإدارة وعدد أعضاء المجلس المستقلين يخفض من احتمال حدوث التعثر المالي، غير أن ملكية المديرين للأسهم في الشركة لا تعد من العوامل المؤثرة في التعثر المالي.

واختبرت دراسة Werner et al. (2018) العلاقة بين آليات الحوكمة وخصائص الشركات (الحجم) والتعثر المالي في الشركات وعددها 337 بواقع 1685 مشاهدة خلال الفترة 2011-2015 تعمل في إندونيسيا، واستخدم الباحثون الانحدار اللوجستي لتحليل البيانات، وتوصلت الدراسة إلى أن كل من المديرين المستقلين وتقرير المراجع الخارجي ودرجة الرفع المالي للشركة تؤثر بعلاقة موجبة في التعثر المالي، في حين أثبتت الدراسة وجود علاقة عكسية ذات دلالة جوهريّة بين حجم الشركة والتعثر المالي.

واستخدم Hamid & Rohani (2018) المؤشرات المالية المتمثلة في الربحية والمديونية ومعدلات التغطية والسيولة والمؤشرات الخاصة بالتدفقات النقدية وخصائص المنشأة، في تحديد العوامل المؤثرة في التعثر المالي في باكستان وعددها 290 شركة خلال الفترة من 2007-2016، واعتمدت هذه الدراسة على تحليل الانحدار اللوجستي التي أوضحت نتائجها تأثير نسب معدلات التغطية (صافي الربح قبل الفائدة/إجمالي الفائدة) ونسب السيولة والملاءمة (الأصول المتداولة/الخصوم المتداولة، الأرباح المحتجزة/إجمالي الأصول) ونسب الديون (إجمالي حقوق

الملكية/إجمالي الالتزامات) ونسب التدفقات النقدية (التدفقات النقدية/إجمالي المبيعات) في التعثر المالي للشركات. وأثبتت الدراسة عدم وجود تأثير جوهري لكل من نسبة التدفقات النقدية/إجمالي الالتزامات، التدفقات النقدية من العمليات التشغيلية/إجمالي الأصول في التعثر المالي للشركات، وأشارت الدراسة إلى أن حجم الشركات من العوامل الهامة في تحديد التعثر المالي.

وفي كينيا اختبر (Atosh & Iraya (2018) أثر كل من حجم مجلس الإدارة واختلاف أعضاء مجلس الإدارة من حيث النوع وملكية المديرين للأسهم في الشركة في التعثر المالي، وذلك على 66 شركة مقيدة في بورصة كينيا. واستخدمت الدراسة تحليل الانحدار المتعدد، وتوصلت إلى حجم مجلس الإدارة يرتبط بعلاقة موجبة ذات دلالة إحصائية والتعثر المالي، وأن التنوع في مجلس الإدارة لا يؤثر فيه، وتعتمد الدراسة الحالية على متغيرات الحوكمة وهي التنوع في الجنس Gender Diversity.

وفي سرى لانكا استخدمت دراسة (Balagobei & Keerthana (2023) تحليل الانحدار الخطي لتحديد تأثير آليات الحوكمة (حجم مجلس الإدارة، الوظيفة المزدوجة للعضو التنفيذي، حجم لجان المراجعة، عدد مرات انعقاد مجلس الإدارة) في التعثر المالي للشركات، وأوضحت الدراسة أن الوظيفة المزدوجة للعضو التنفيذي تزيد من فرص تعرض الشركات إلى التعثر المالي، وذلك بخلاف حجم مجلس الإدارة الذي يخفض من فرص تعرض الشركات للتعثر المالي، وانتهت الدراسة إلى عدم وجود علاقة بين كل من عدد مرات انعقاد مجلس الإدارة وحجم لجان المراجعة وملكية المديرين للأسهم في الشركات، وبين التعثر المالي للشركات.

واستهدفت دراسة (Nour et al. (2023) تحديد العلاقة بين آليات حوكمة الشركات (استقلالية أعضاء مجلس الإدارة وملكية المؤسسات وجودة المراجع الخارجي وحجم مجلس الإدارة وعدد مرات انعقاد مجلس الإدارة ووجود لجان المراجعة) وبين التعثر المالي، وذلك على 35 شركة مقيدة في بورصة فلسطين. واستخدمت الدراسة تحليل الانحدار اللوجستي؛ وبناء عليه توصلت الدراسة إلى وجود علاقة ذات دلالة إحصائية بين استقلالية أعضاء مجلس الإدارة وملكية المؤسسات وجودة المراجع الخارجي وبين التعثر المالي للشركات، في حين إلى أن كل من حجم مجلس الإدارة وعدد مرات انعقاد مجلس الإدارة ووجود لجان للمراجعة لا تؤثر في التعثر المالي للشركات.

وفي مصر استهدفت دراسة (Ragab & Saleh (2022) تحديد تأثير آليات حوكمة الشركات في التنبؤ بالتعثر المالي للشركات، وذلك على 120 من شركات صغيرة ومتوسطة الحجم المقيدة في بورصة النيل خلال الفترة من 2014-2018، ولتحقيق هدف الدراسة جمع الباحثان بيانات عن حوكمة الشركات متمثلة في مجلس الإدارة (حجم مجلس الإدارة، وجود أعضاء مستقلين، عدد مرات مجلس الإدارة، الوظيفة المزدوجة لرئيس العضو التنفيذي وعدد مرات مجلس الإدارة)، لجان مراجعة (وجود لجان مراجعة، عدد مرات انعقاد مجلس الإدارة) هيكل الملكية (ملكية المؤسسات، ملكية المديرين وأعضاء مجلس الإدارة). كما استخدمت الدراسة عددًا من مؤشرات المالية وهي نسبة النقدية/إجمالي الأصول، الالتزامات المتداولة/حقوق الملكية، الربح قبل الفائدة والضريبة/الفائدة، الربح قبل الفائدة والضريبة/إجمالي الأصول، الأرباح المحتجزة/إجمالي الأصول. واستخدمت الدراسة تحليل الانحدار اللوجستي الإحصائي؛ وبناء عليه أثبتت الدراسة عدم تأثير آليات الحوكمة في التعثر المالي للشركات، كما استخلصت الدراسة عدم وجود علاقة ذات دلالة إحصائية بين التعثر المالي للشركات والنسب المالية المستخدمة.

وتناول (2022) Humairod & Nurilita العلاقة بين آليات الحوكمة، مثل: هيكل الملكية ولجان المراجعة ومجلس الإدارة؛ في التعثر المالي على 13 شركة صناعية بواقع 78 مشاهدة في إندونيسيا وذلك خلال الفترة من 2015-2020. واستخلصت نتائج تحليل الانحدار المتعدد إلى أن ملكية المؤسسات تؤثر في التعثر المالي للشركات، في حين لا توجد علاقة بين لجان المراجعة وملكية المديرين وعدد الأعضاء المستقلين في مجلس الإدارة وبين التعثر المالي للشركات.

- تأثير المؤشرات المالية في التعثر المالي

واعتمد بعض الدراسات على المؤشرات المالية: نسب السيولة، الرفع المالي والمديونية، الربحية، الكفاءة (عدلات الدوران)، كما استهدف بعض الباحثين في تحديد مؤشرات السوق مثل مضاعف الربحية، سعر السهم، القيمة السوقية لحقوق الملكية/ القيمة الدفترية لحقوق الملكية على التعثر المالي للشركات، حيث واستهدفت دراسة (2024) Savery & Riswan تحديد تأثير الأداء المالي في التنبؤ بالتعثر المالي على شركات التعدين الخاصة في إندونيسيا خلال الفترة من 2018 - 2022. ولتحقيق هدف الدراسة تم تجميع بيانات عن الأداء المالي متمثلة في الربحية (العائد على الأصول) والسيولة (نسبة التداول) والرفع المالي (إجمالي الالتزامات/إجمالي الأصول)، واستخدمت الدراسة تحليل الانحدار اللوجستي، حيث توصلت الدراسة إلى وجود علاقة عكسية ذات دلالة إحصائية بين معدلات الربحية والسيولة وبين التعثر المالي. كما يوجد تأثير إيجابي معنوي بين نسب الرفع المالي والتعثر المالي.

في ماليزيا استخدمت دراس (2024) Siti et al. الأداء المالي للشركات للتنبؤ بالتعثر المالي، واستخدمت رأس المال العامل/إجمالي الأصول، الأرباح المحتجزة/إجمالي الأصول، الربح قبل الضريبة/إجمالي الأصول، القيمة السوقية لحقوق الملكية/القيمة الدفترية لحقوق الملكية، معدل دوران الأصول، صافي الربح قبل الفائدة والضريبة/الالتزامات المتداولة، العائد على الأصول، الالتزامات طويلة الأجل/إجمالي الأصول ونسبة التداول. ولتحقيق هدف الدراسة ركزت على 290 شركة في قطاع التشييد والتكنولوجيا والعقارات خلال الفترة من 2017-2021. وتوصلت إلى أن كل من نسبة رأس المال العامل/إجمالي الأصول، الأرباح المحتجزة/إجمالي الأصول، القيمة السوقية لحقوق الملكية/القيمة الدفترية لحقوق الملكية، العائد على الأصول، معدل دوران الأصول، نسبة الالتزامات/إجمالي الأصول؛ لها تأثير جوهري في التنبؤ بالتعثر المالي.

واستخلصت دراسة (2024) Jessie & Tannira أن كل من الربحية والسيولة والرفع المالي لها تأثير جوهري في التعثر المالي للشركات، حيث إنه يوجد علاقة طردية ذات دلالة إحصائية بين الرفع المالي والتعثر المالي، كما يوجد علاقة عكسية ذات دلالة إحصائية بين الربحية والسيولة وبين التعثر المالي، كما أظهرت الدراسة عدم تأثير مؤشرات النشاط (دوران الأصول) في التعثر المالي في الشركات العقارية المقيدة في بورصة إندونيسيا.

واستخدم (2023) Tran et al. النماذج الاحتمالية الإحصائية في التنبؤ بالتعثر المالي، واعتمد على النسب المالية في تحديد العوامل المؤثرة في التعثر المالي لشركات التشييد والقطاع العقاري في فيتنام خلال الفترة من 2012-2021. وتوصلت نتيجة الدراسة إلى أن كل من مؤشرات صافي الربح قبل الفائدة والضرائب/إجمالي الأصول، صافي الربح/إجمالي الأصول، إجمالي الالتزامات/إجمالي الأصول، إجمالي حقوق الملكية/إجمالي الالتزامات؛ تؤثر في التعثر المالي للشركات.

كما استهدف Veromica & Muhyarsyah (2023) تحديد أثر النسب المالية في التنبؤ بالتعثر المالي في الشركات العقارية الإندونيسية خلال الفترة من 78 شركة خلال الفترة من 2016 حتى 2020، واستخدمت الدراسة z-score لقياس المتغير التابع، واعتمدت على تحليل الانحدار الخطي الذي أظهرت نتائجه أن كل من نسب رأس المال العامل/إجمالي الأصول، الأرباح المحتجزة/إجمالي الأصول، صافي الربح قبل الضريبة/إجمالي الأصول ونسبة الالتزامات/حقوق الملكية؛ تؤثر في التعثر المالي للشركات العقارية، وتدعم هذه الدراسة نظرية الإشارة.

استهدفت دراسة Andika (2022) تحديد العوامل المؤثرة في التعثر المالي، وذلك على شركات النقل خلال الفترة من 2016-2020. واستخدمت الدراسة مؤشر الرفع المالي (إجمالي الديون/إجمالي حقوق الملكية) والربحية (العائد قبل الفائدة/إجمالي الأصول) وخصائص الشركات (حجم المنشأة)، باستخدام أسلوب الانحدار المتعدد، وأوضحت الدراسة وجود علاقة طردية قوية بين نسبة الرفع المالي والتعثر المالي، وعلاقة عكسية ذات دلالة إحصائية بين الربحية والتعثر المالي.

علاوة على ذلك استهدفت دراسة Mashudi et al. (2021) تحديد العوامل المؤثرة في التعثر المالي في إندونيسيا، وذلك في قطاعات البنية التحتية والمرافق والنقل خلال الفترة من 2015-2020. ولتحقيق هدف الدراسة استخدم الباحثون الانحدار الخطي. واعتمدت الدراسة على العوامل الاقتصادية مثل التضخم، وذلك علاوة من استخدام المؤشرات المالية، وتوصلت الدراسة إلى أن كل من التضخم ونسبة التداول ونسبة سعر السهم/القيمة الدفترية ومعدل دوران إجمالي الأصول، تعد من محددات التعثر المالي في الشركات محل الدراسة، كما أثبتت الدراسة عدم تأثير التعثر المالي بنسب الديون/حقوق الملكية والعائد على حقوق الملكية في قطاعات البنية التحتية والمرافق والنقل محل الدراسة.

كما أثبتت الدراسة عدم تأثير التعثر المالي بنسب الديون/حقوق الملكية والعائد على حقوق الملكية في قطاعات البنية التحتية والمرافق والنقل محل الدراسة.

واختبرت دراسة Utami et al. (2021) العلاقة بين النسب المالية والتنبؤ بالتعثر المالي في ثلاث قطاعات (الزراعة والكيمائيات والصناعات الأساسية) في إندونيسيا، وذلك على 76 شركة بواقع 380 مشاهدة خلال الفترة من 2015-2019. ولتحقيق هدف الدراسة استخدمت مؤشرات الربحية (العائد على الأصول) ونسبة الرفع المالي (إجمالي الديون/حقوق الملكية) ونسبة السيولة (صافي رأس المال العامل/إجمالي الأصول). واستخدمت الدراسة تحليل الانحدار اللوجستي، وتوصلت إلى اختلاف تأثير النسب المالية في التنبؤ بالتعثر المالي، حيث أوضحت الدراسة تأثير معدلات الربحية والسيولة في التنبؤ بالتعثر المالي في قطاعي الزراعة والصناعات الأساسية، أما في قطاع الكيمائيات، أظهرت الدراسة أنه يوجد علاقة ذات دلالة إحصائية بين معدلات الرفع المالي والتنبؤ بالتعثر المالي.

واستخدم Ogachi et al. (2020) عددًا من النسب المالية الخاصة بكفاءة الاستخدام (معدل دوران المخزون، معدل دوران العملاء، معدل دوران الأصول) والسيولة (الأصول المتداولة/الخصوم المتداولة، الأصول المتداولة - المخزون/الخصوم المتداولة، رأس المال العامل/الخصوم المتداولة، ونسب المديونية (القروض/حقوق الملكية، إجمالي الالتزامات/حقوق الملكية) بهدف تحديد العوامل المؤثرة في التعثر المالي في كينيا، حيث تم تجميع بيانات عدد 64 شركة مقيدة في البورصة، واعتمدت الدراسة على تحليل الانحدار اللوجستي، وتوصلت الدراسة إلى وجود علاقة

طردية بين التعثر المالي ومعدل دوران الأصول ونسبة رأس المال العامل/إجمالي الالتزامات، وعلاقة عكسية بين معدل دوران المخزون ومعدل دوران العملاء وإجمالي القروض/حقوق الملكية/إجمالي الالتزامات/حقوق الملكية وبين التعثر المالي.

كما توصلت دراسة (Evangelos & Ian (2019) على 31000 شركة خاصة في اليونان مستخدمة تحليل الانحدار اللوجستي والنسب المالية، إلى أن كل من مؤشرات الربحية والرفع المالي ونسبة الأرباح المحتجزة/إجمالي الأصول، الحجم والسيولة والقدرة على سداد توزيعات نقدية ومعدل النمو في الناتج القومي الإجمالي؛ من العوامل المؤثرة في التعثر المالي للشركات اليونانية الخاصة.

وبالمثل استخدمت (Charalambakis et al. (2019 بيانات 31000 شركة خاصة صغيرة ومتوسطة الحجم في اليونان لإيجاد محددات التعثر المالي في هذه الشركات، حيث استخدمت نماذج الاحتمالية في تحليل البيانات، وتوصلت الدراسة إلى أن كل من الربحية والرفع المالي ونسبة الأرباح المحتجزة/إجمالي الأصول ونسبة السيولة والمتغير الخاص بالصادرات وحجم الشركة؛ يؤثر تأثيرًا جوهريًا في التعثر المالي للشركات اليونانية.

وعلى النقيض توصلت بعض الدراسات إلى عدم وجود علاقة بين نسب الرفع المالي مثل دراسة (Wira et al. (2024 التي استخلصت أنه لا يوجد تأثير في نسبة الرفع المالي على التعثر المالي، في حين أن الربحية تؤثر تأثيرًا سلبيًا جوهريًا في التعثر المالي للشركات، أما نسب السيولة ومعدل دوران الأصول لا تؤثر في التعثر المالي للشركات. وذلك في دراسة قاموا بها على الشركات الصناعية في إندونيسيا بواقع 46 مشاهدة خلال الفترة من 2020-2022 بغرض تحديد العوامل المؤثرة في التعثر المالي للشركات، معتمدين في ذلك على تحليل الانحدار اللوجستي.

واستهدفت دراسة (Haris (2023 تحديد تأثير بعض المؤشرات المالية (السيولة - الأصول المتداولة/الخصوم المتداولة، ونسبة الرفع المالي، إجمالي الالتزامات/حقوق الملكية) في التعثر المالي، واستخدمت الدراسة تحليل الانحدار المتعدد على 22 شركة مقيدة في إندونيسيا قبل 2018، واستخلصت الدراسة أنه يوجد علاقة ذات دلالة إحصائية بين نسب السيولة والتعثر المالي، في حين أثبتت الدراسة عدم تأثير نسبة إجمالي الالتزامات/حقوق الملكية في تعثر الشركات محل الدراسة.

واستهدفت العديد من الدراسات في تحديد العلاقة بين مؤشرات الربحية و السيولة والكفاءة (معدلات دوران الأصول) وجاءت متباينة من حيث النتائج فاستخدمت دراسة (Yusuf (2024 تحليل الانحدار الخطي لتحديد العوامل المؤثرة في التعثر المالي في 29 شركة لتجارة الجملة والتجزئة. واختبرت الدراسة مدى تأثير نسب الربحية (العائد على الأصول) والسيولة (نسبة التداول) ومعدل دوران الأصول ونسبة الالتزامات/إجمالي الأصول، وأثبتت الدراسة وجود علاقة ذات دلالة إحصائية بين معدل دوران الأصول ونسبة (إجمالي الالتزامات/إجمالي الأصول) وبين التعثر المالي، كما تؤثر الربحية تأثيرًا سلبيًا في التعثر المالي، وأخيرًا لم تثبت الدراسة تأثير معدلات السيولة في التعثر المالي للشركات.

واستهدفت دراسة (Nurchayono et al. (2023 تحديد العوامل المؤثرة في التعثر المالي في شركات التعدين في إندونيسيا وعددها 18 شركة، واعتمدت الدراسة على النسب المالية مستخدمة تحليل الانحدار المتعدد. واستخلصت نتيجة الدراسة أن الشركات ذات الربحية العالية ولديها فائض في السيولة يصعب تعرضها للتعثر

المالي، وأن ارتفاع نسب الديون تؤدي إلى زيادة احتمال وقوع الشركات محل الدراسة في التعثر المالي، غير أن الدراسة لم تثبت وجود تأثير جوهري في كفاءة استخدام الموارد (معدل دوران إجمالي الأصول) على تعرض شركات التعدين للتعثر المالي.

وفي إندونيسيا استهدفت دراسة (Mahardini & Bandi, 2023) إيجاد نموذج ملائم للتنبؤ بالتعثر المالي على قطاعات الأسمنت والسيراميك والمعادن والكيماويات والبلاستيك وأعلاف الحيوانات واللبن والخشب، وقسمت هذه الشركات إلى شركات متعثرة، وهي تلك الشركات التي تعاني من خسائر في حقوق الملكية، وفي الربح من العمليات التشغيلية، وخسائر في صافي الربح لمدة عامين متتاليين قبل حدوث التعثر المالي، واعتمدت الدراسة على النسب المالية فقط، كما استخدمت الشركة أسلوب تحليل التمايز المتعدد. وأوضحت الدراسة أن مؤشرات الربحية (صافي الربح قبل الضريبة/صافي المبيعات) والسيولة (رأس المال العامل/إجمالي الأصول) والكفاءة (المبيعات/إجمالي الأصول) تعد من محددات التعثر المالي.

واعتمدت الدراسة على النسب المالية فقط، كما استخدمت الشركة أسلوب تحليل التمايز المتعدد، وأوضحت الدراسة أن مؤشرات الربحية (في الربح قبل الضريبة/ صافي المبيعات) والسيولة (رأس المال العام/إجمالي الأصول) والكفاءة (المبيعات/إجمالي الأصول)؛ تعد من محددات التعثر المالي. كما استخدمت (Dewin et al., 2023) الانحدار اللوجستي في إندونيسيا، حيث استهدف تحديد أثر النسب المالية والعوامل الاقتصادية وأدوات الحوكمة في التعثر المالي للشركات. ولتحقيق هدف الدراسة صنف الشركات إلى شركات متعثرة وغير متعثرة، وعرف الشركات المتعثرة بأنها الشركات التي ينخفض فيها أو تحقق صافي خسارة لمدة عامين متتاليين أو أكثر. واستخدم مؤشر الملائمة المالية (الأرباح المحتجزة/إجمالي الأصول)، ومع معدل دوران الأصول وحجم مجلس الإدارة واستقلالية مجلس الإدارة وهيكل الملكية كمقاييس للحوكمة، وسعر الصرف ومعدل التضخم كمقاييس للعوامل الاقتصادية. وأوضحت نتيجة الدراسة أن المؤشرات المالية (معدل الملائمة ودوران الأصول) وحجم مجلس الإدارة والتضخم، تؤثر في التعثر المالي للشركات.

وكذلك استخلصت دراسة (Bukhori et al., 2022) وجود علاقة ذات دلالة إحصائية بين نسب السيولة (الأصول المتداولة/الخصوم المتداولة) ومعدلات النشاط (إجمالي المبيعات/إجمالي الأصول) ونسب الرفع المالي و(إجمالي الالتزامات/حقوق الملكية)، ومعدل نمو المبيعات في التنبؤ بالتعثر المالي في قطاع الصناعات بإندونيسيا، غير أنه يوجد علاقة طردية بين نسب الرفع المالي والتنبؤ بالتعثر المالي وعكسية بينه وبين كل من معدلات السيولة والنشاط ومعدلات نمو المبيعات، وذلك باستخدام الانحدار اللوجستي خلال الفترة من 2016-2019.

واستخدمت دراسة (Sugianto et al., 2022) تحليل الانحدار اللوجستي لتحديد تأثير المؤشرات المالية، مثل: (الربحية العائد على الأصول)، والملائمة (إجمالي الالتزامات/إجمالي الأصول)، والسيولة (الأصول المتداولة/الخصوم المتداولة)، وذلك على 16 مؤسسة مالية مقيمة في إندونيسيا خلال الفترة من 2015-2019. وتوصلت نتيجة الدراسة إلى أن كل من الربحية والسيولة والملائمة تؤثر في التنبؤ بالتعثر المالي.

واستهدف أبو السعود وآخرون (2022) تحديد أثر نسب المال في التعثر المالي في الشركات القابضة بوزارة قطاع الأعمال العام، حيث تم تجميع بيانات ربع سنوية للشركات محل الدراسة خلال الفترة من 2017 حتى 2019.

واستخدم أبو السعود مؤشرات مالية (نسب التداول، نسبة التداول السريع، النقدية/الخصوم المتداولة، صافي رأس المال/إجمالي الأصول، معدل دوران إجمالي الأصول، معدل دوران الأصول الثابتة، العائد على حقوق الملكية، العائد على رأس المال المستثمر، العائد على المبيعات، إجمالي حقوق الملكية/إجمالي الأصول، صافي التدفقات من العمليات التشغيلية/إجمالي الالتزامات، صافي التدفقات النقدية من العمليات التشغيلية/إجمالي الأصول، إجمالي الالتزامات/إجمالي الأصول، هامش الربح الإجمالي والعائد على الأصول). وباستخدام النماذج الاحتمالية استخلصت الدراسة أن أهم المؤشرات التي تؤثر في تحديد احتمالية تعثر الشركات المصرية هي نسبة التداول السريع، معدل دوران الأصول، معدل دوران الأصول الثابتة، العائد على المبيعات والعائد على الأصول.

كما استنتج خالد (2021) في دراسة أجراها على الشركات الفلسطينية خلال الفترة من 2010-2017 لتحديد العوامل المؤثرة في التعثر المالي للشركات معتمداً على 26 مؤشراً مالياً (متضمناً نسبة النقدية والعائد على الأصول ومعدل دوران رأس المال العامل ومضاعف الربحية ومعدل دوران المخزون ومتوسط فترة التحصيل والعائد على السهم)؛ وجود علاقة ذات دلالة إحصائية بين كل من نسبة النقدية والعائد على الأصول ومعدل دوران رأس المال العامل ومضاعف الربحية والتعثر المالي.

وفي إندونيسيا، استخدم (Tawfic & Sugianto (2021) النسب المالية، مثل: رأس المال العامل/إجمالي الأصول، الأرباح المحتجزة/إجمالي الأصول، صافي الربح قبل الفائدة والضرائب/إجمالي الأصول، سعر السهم؛ والمؤشرات الاقتصادية (التضخم، أذون الخزانة) على عدد من الشركات الإندونيسية خلال الفترة من 2016-2020 بواقع 1710 مشاهدة. بلغت نسبة الشركات المتعثرة في العينة 31.3%، والشركات غير المتعثرة 68.70%، حيث حدد الباحثان التعثر المالي بمعدل تغطية الفائدة، فإذا كان معدل أقل من 1 تكون الشركة متعثرة، ويرمز لها بواحد.

وبناء على تحليل الانحدار اللوجستي، توصلت الدراسة إلى وجود علاقة عكسية ذات دلالة إحصائية بين التعثر المالي ونسب الأرباح المحتجزة/إجمالي الأصول، صافي الربح قبل الفائدة والضرائب/إجمالي الأصول. في حين لا يؤثر سعر السهم والتضخم في التعثر المالي. وأشارت الدراسة إلى أن الكساد يؤدي إلى حدوث تعثر مالي، حيث إن الدولة تعرضت إلى الكساد في فترات الدراسة.

واعتمدت دراسة (Laksmiwati et al. (2021) على نموذج الانحدار الخطي المتعدد في تحديد العلاقة بين عدد من المؤشرات المالية (نسبة التداول، الرفع المالي ومعدل دوران الأصول والعائد على الأصول) وبين التنبؤ بالتعثر المالي بالشركات العقارية الإندونيسية. وأسفرت نتيجة الدراسة عن وجود علاقة موجبة ذات دلالة إحصائية بين العائد على الأصول ومعدل دوران الأصول وبين التعثر المالي للشركات، كما أوضحت الدراسة وجود علاقة عكسية ذات دلالة إحصائية بين نسبة التداول والتعثر المالي، وأشارت الدراسة إلى عدم وجود علاقة بين التعثر المالي ونسبة الرفع المالي.

وفي فيتنام اتخذ (Vam et al. (2019) كل من العائد على الأصول والعائد على حقوق الملكية ومعدل دوران الأصول، وذلك على عدد 44 شركة لتحديد العوامل المؤثرة بالتنبؤ بالتعثر المالي، وتوصلت نتيجة تحليل الانحدار المتعدد إلى وجود علاقة ذات دلالة إحصائية بين العائد على الأصول والعائد على حقوق الملكية ومعدل دوران الأصول، وبين التنبؤ بالتعثر المالي.

وفي ماليزيا استهدفت دراسة (Alifia & Tahir (2018) تحديد أثر المعلومات الاقتصادية والنسب المالية في التعثر المالي قبل حدوثه بسنة إلى خمس سنوات، ولتحقيق هدف الدراسة تم الحصول على بيانات لشركات صناعية وغير صناعية خلال الفترة من 2001 إلى 2015، واستخدمت الدراسة مؤشرات الاقتصادية وهي معدل الفائدة على الإقراض والنتائج القومي الإجمالي والتضخم وأداء مؤشر البورصة، واختارت النسب المالية وهي نسبة التداول ونسبة رأس المال العامل/إجمالي الخصوم ونسبة الديون ونسبة صافي الربح/إجمالي الأصول ونسبة الرفع المالي ومعدل دوران الأصول. واستخدمت الدراسة أسلوب الاحتمال الإحصائي (Logit Model)، وأوضحت أن نسبة السيولة وصافي الربح/الأصول والطلب على النقود تؤثر في التنبؤ بالتعثر المالي في الشركات الصناعية، أما نسبة الديون ورأس المال العامل/الخصوم المتداولة وصافي الدخل/إجمالي الأصول والطلب على النقود تؤثر في التعثر المالي في الشركات غير الصناعية.

وفي الجزائر استهدفت دراسة بوضياف (2018) تحديد تأثير النسب المالية في التنبؤ بالتعثر المالي، مستخدمة تحليل الانحدار الخطي وذلك في قطاع صناعة الألبان في الجزائر؛ وبناء عليه تم تجميع بيانات 60 شركة تعمل في هذا القطاع خلال الفترة من 2010 حتى 2013، واستخدمت الدراسة نسب الربحية مثل العائد على الأصول، ونسبة هامش الربح/إجمالي المبيعات، ومعدلات السيولة (نسبة التداول، نسبة التداول السريع) ومعدلات التغطية ونسب المديونية (إجمالي الالتزامات/إجمالي الأصول، إجمالي الالتزامات/حقوق الملكية). وأثبتت الدراسة عدم وجود علاقة ذات دلالة إحصائية بين مؤشرات السيولة ومعدل تغطية الفائدة، غير أن الدراسة أثبتت وجود علاقة ذات دلالة إحصائية بين نسب الربحية والمديونية وبين التعثر المالي للشركات.

واعتمد عدد من الباحثين على دراسة نسب التدفقات النقدية المختلفة (نسبة التدفقات النقدية من العمليات التشغيلية / إجمالي الالتزامات المتداولة، ونسبة التدفقات النقدية من العمليات التشغيلية/ إجمالي الالتزامات) على التعثر المالي للشركات

واستخدم عرفة وفانوس (2020) أسلوب الانحدار الخطي المتعدد في تحديد العوامل التي تؤثر في التعثر المالي للشركات المصرية، واعتمدت الدراسة على النسب المالية الخاصة السيولة والربحية وكفاءة هيكل المديونية، وذلك على 23 شركة مقيدة في مؤشر EGX 30 خلال الفترة من 2012 إلى 2017، وتوصلت الدراسة إلى تأثير نسب التداول والسيولة السريعة في التعثر المالي للشركات وعدم تأثير مؤشرات الربحية والكفاءة وهيكل المديونية في التعثر المالي في الشركات المصرية. وتختلف الدراسة الحالية عن هذه الدراسة من حيث عينة ومجتمع الدراسة، حيث تستخدم الدراسة التقارير المالية للشركات العقارية ومواد البناء وشركات التشيد المسجلة في EGX 100، غير أن الدراسة الحالية تعتمد على بعض النسب المستخدمة في هذه الدراسة، مثل: رأس المال العامل/إجمالي الأصول، العائد على الأصول، نسبة التداول، إجمالي الالتزامات/إجمالي الأصول، صافي التدفقات النقدية من عمليات التشغيل/إجمالي الخصوم المتداولة، إجمالي الالتزامات/حقوق الملكية، هامش الربح/المبيعات، وتختلف عن الدراسة الحالية في دمجها للعوامل الاقتصادية الكلي وآليات الحوكمة وخصائص الشركات.

واستخدم Hamid & Rohani (2018) المؤشرات المالية المتمثلة في الربحية والمديونية ومعدلات التغطية والسيولة والمؤشرات الخاصة بالتدفقات النقدية المنشأة، في تحديد العوامل المؤثرة في التعثر المالي في باكستان وعددها 290 شركة خلال الفترة من 2007-2016، واعتمدت هذه الدراسة على تحليل الانحدار اللوجستي التي أوضحت نتائجها

تأثير نسب معدلات التغطية (صافي الربح قبل الفائدة/إجمالي الفائدة) ونسب السيولة والملاءمة (الأصول المتداولة/الخصوم المتداولة، الأرباح المحتجزة/إجمالي الأصول) ونسب الديون (إجمالي حقوق الملكية/إجمالي الالتزامات) ونسب التدفقات النقدية (التدفقات النقدية/إجمالي المبيعات) في التعثر المالي للشركات. وأثبتت الدراسة عدم وجود تأثير جوهري لكل من نسبة التدفقات النقدية/إجمالي الالتزامات، التدفقات النقدية من العمليات التشغيلية/إجمالي الأصول في التعثر المالي للشركات، وأشارت الدراسة إلى أن حجم الشركات من العوامل الهامة في تحديد التعثر المالي.

غير أن عدد من الدراسات استندت إلى مؤشرات السوق (مثل مضاعف الربحية، القيمة السوقية لحقوق الملكية/القيمة الدفترية لحقوق الملكية، وسعر السهم. وستخدمت دراسة (Mohamed (2022) معلومات عن السوق وعوامل الاقتصاد، مثل: التضخم بخلاف المعلومات المالية للتنبؤ بالتعثر المالي للشركات. كما استخدم الباحث أسلوب تحليل الانحدار اللوجستي لدراسة محددات التعثر المالي والتنبؤ بالتعثر المالي، وذلك على 15 شركة تعمل في مجال المواد الأساسية والكيمائيات خلال الفترة من 2000 إلى 2017.

وعرفت الدراسة أن الشركات تكون متعثرة عندما يكون معدل تغطية الفائدة أقل من أو يساوي صفر معتمدة في ذلك على المعلومات المالية. واستخلصت الدراسة أنه يجب الأخذ في الاعتبار النسب المالية التالية عند التنبؤ بالتعثر المالي: إجمالي الديون/إجمالي الأصول، صافي الربح/المبيعات، الفائدة/إجمالي الأصول، أصول المتداولة/إجمالي الأصول، المبيعات/رأس المال العامل. كما يجب الأخذ في الاعتبار نسب المالية الخاصة بالسوق مثل القيمة السوقية/القيمة الدفترية، سعر السهم، وذلك مع الأخذ في الاعتبار عوامل الاقتصاد الكلي مثل التضخم (تم تحديد العوامل الاقتصادية بناء على الدراسة السابقة وهي التضخم، وكذلك المؤشرات السوق كسعر السهم).

وبالمثل استخدم (Mochammad et al. (2019) الانحدار اللوجستي في تحديد تأثير متغيرات نموذج - Altman Z Score في التنبؤ بالتعثر المالي، حيث جمع الباحثون بيانات مالية لعدد 40 شركة صناعية في إندونيسيا، واستخلصت نتيجة الدراسة إلى أن القيمة السوقية لحقوق الملكية/إجمالي الأصول، المبيعات/إجمالي الأصول، لها تأثير سلبي جوهري في التعثر المالي، غير أن الدراسة أثبتت عدم تأثير كل من نسب رأس المال العامل/إجمالي الأصول، والأرباح المحتجزة/إجمالي الأصول، في التعثر المالي في الشركات الإندونيسية.

واستخدمت دراسة (Toly et al. (2019) نموذج Z- Score لتحديد العوامل المؤثرة في التعثر المالي للشركات، وذلك على 139 شركة صناعية في إندونيسيا خلال الفترة من 2016-2018، واستخدمت الدراسة تحليل الانحدار اللوجستي، حيث أثبتت وجود علاقة موجبة ذات دلالة إحصائية بين نسبة الأرباح المحتجزة/إجمالي الأصول، صافي الربح قبل الفائدة والضريبة/إجمالي الأصول، وبين التعثر المالي للشركات محل الدراسة.

وفي فيتنام استهدفت دراسة (Binh et al. (2018) بناء نموذج شامل دقيق يتضمن معلومات مالية جانباً إلى جنب مع مؤشرات السوق والعوامل الاقتصادية؛ وبناء عليه تم تجميع بيانات 800 شركة خلال الفترة من 2003-2016 بواقع 6736 مشاهدة، واستعانت الدراسة بمتغيرات نموذج Altan 1968 وذلك للنسب المالية، أما مؤشرات السوق فاختلفت القيمة السوقية للسهم، أما العوامل الاقتصادية فتمثلت في التضخم ومعدل سعر الفائدة. واتبعت الدراسة Olson في استخدام الانحدار اللوجستي، وأوضحت نتيجة التحليل الإحصائي أن كل من النسب المالية

المتثلة في الربحية والملائمة والسيولة تؤثر في التعثر المالي للشركات، غير أن التأثير في اتجاهات مختلفة، حيث استخلصت الدراسة وجود علاقة موجبة بين التضخم وسعر الفائدة والمؤشرات المالية التعثر المالي، ووجود علاقة عكسية بين التعثر المالي والقيمة السوقية للسهم. وأشارت الدراسة إلى ضرورة دمج المعلومات الاقتصادية عند التنبؤ بالتعثر المالي بجانب المؤشرات المالية ومؤشرات السوق.

واستخدم أحمد وعبد الحليم (2015) متغيرات نموذج Altman 1968 للتنبؤ بالتعثر المالي على قطاعات الزراعة والصناعات الغذائية وقطاع الفنادق وقطاع الاتصالات وتنقية المعلومات على 18 شركة سعودية خلال الفترة من 2008-2012. واستخدمت الدراسة تحليل الانحدار الخطي التي أسفرت نتائجها على وجود علاقة ذات دلالة إحصائية بين التنبؤ بالتعثر المالي ومؤشرات السيولة (رأس المال العامل/إجمالي الأصول)، والملاءمة (الأرباح المحتجزة/إجمالي الأصول)، والربحية (الربح قبل الفائدة والضرائب/إجمالي الأصول)، والرفع المالي (القيمة السوقية للحقوق الملكية/إجمالي الالتزامات)، وأخيرًا نسب الكفاءة (المبيعات/إجمالي الأصول).

كما صنف العديد من الباحثين الشركات إلى شركات متعثرة وغير متعثرة؛ فالشركات المتعثرة هي تلك الشركات التي تحقق صافي ربح للشركات سالب لعامين متتاليين أو تحقق صافي التدفقات النقدية العمليات التشغيلية بالسالب لمدة عامين أو أنها تشطب من البورصة.

واقترحت دراسة Mahfuzur et al. (2021) تحديد إمكانية استخدام نموذج F-Score ومكوناته في التنبؤ بالتعثر المالي في الشركات الأمريكية، حيث تم تجميع البيانات من البورصة وبيانات 81 شركة من قاعدة البيانات UCLA-LoPucki Bankruptcy Research خلال الفترة من 2009 حتى 2017، وتوصلت نتيجة الدراسة إلى وجود علاقة قوية بين F-Score واحتمال تعرض الشركات للتعثر المالي، وأشارت الدراسة إلى أن الشركات التي تتعرض للإفلاس تسجل في دفاترها تدفقًا نقديًا من العمليات التشغيلية بالسالب، وانخفاضًا في العائد على الأصول في العام السابق للتخلف عن السداد ووقوعها في التعثر المالي. ويعتمد هذا البحث على بعض النسب الواردة في هذه الدراسة من رأس المال العامل/إجمالي الأصول، إجمالي الالتزامات/حقوق الملكية ومعدل دوران الأصول، وتختلف الدراسة الحالية عن هذا البحث، حيث إن الأولى تستخدم حجم الشركة كأحد محددات التعثر المالي.

واستخدم Dunakhir (2023) تحليل التمايز المتعدد في تصنيف عشرة شركات تعمل في إنتاج الفحم في إندونيسيا إلى ثلاث شركات غير متعثرة وأربع شركات متعثرة وثلاث شركات تقع في المنطقة المحايدة وذلك خلال جائحة كورونا. وأشارت الدراسة إلى أن الشركات المتعثرة غالبًا ما تعاني من مشاكل في التدفقات النقدية نتيجة وجود خسائر في مرحلة تفاقم في الديون وانخفاض صافي ربح قبل الفائدة والضرائب (خسائر من عمليات التشغيل).

Ensemble (2-3-2) الدراسات الخاصة باستخدام وتقييم أداء نموذجي للتعلم الجماعي

Learning ونموذج خوارزميات التجميع Clustering Algorithm

- اقترح عدد من الدراسات استخدام نماذج التعلم الجماعي المختلفة في التنبؤ بالتعثر المالي

حيث استخدمت دراسة Wu et al. (2024) نموذج Staking في التنبؤ بالتعثر المالي في الشركات الصينية، واتخذت الدراسة نموذج Light GBM، CatBoost، كمتعلم أساسي، واستخدمت DT، XGBOOST، SVM، LR، المتعلم الفوقي META-LEARNING، واستخدمت الدراسة XGBOOST - RF لتحديد العوامل المؤثرة في التعثر المالي، واختبرت

الدراسة أداء نموذج Staking في التنبؤ بالتعثر المالي، حيث توصلت الدراسة إلى أن دقة النموذج بلغت 86.40، ومن حيث الاستدعاء 85%، ومن حيث القيمة التنبؤية الإيجابية 0.879، ومن حيث المنطقة الواقعة تحت الخط 0.889. كما استهدفت دراسة Papikova and Papik (2024) تحديد تأثير التنوع بين الجنسين في مجلس الإدارة في التنبؤ بالتعثر المالي للشركات، مستخدمين نموذجي LR, XGBOOST في سلوفاكيا على عينة مكونة من 173 شركة كبيرة و351 متوسطة و827 صغيرة الحجم خلال الفترة من 2019-2020. واستخدمت اختبار AUC لتقييم أداء نماذج تعلم الآلة في التنبؤ بالتعثر المالي. واستخلصت الدراسة أن التنوع بين الجنسين يؤثر في التنبؤ بالتعثر المالي، وأن زيادة تمثيل المرأة في مجلس الإدارة بمقدار يزيد عن 50% يؤدي إلى تخفيض احتمال تعرض الشركات للتعثر المالي. كما أظهر اختبار AUC تفوق أداء XGBOOST على LR بمقدار يفوق 25%، حيث بلغت المنطقة الواقعة تحت المنحى لـ XGBOOST نسبة 98%، وهذا يدل على كفاءة تصنيف XGBOOST للشركات محل الدراسة إلى شركات متعثرة وغير متعثرة باستخدام السمات الهامة وهي التنوع بين الجنسين.

وظورت دراسة Anong & Kamsami (2023) نموذجًا لتحديد مدى تعرض خمس وكالات حكومية صغيرة ومتوسطة الحجم للتعثر المالي على المدى القريب في سنغافورة، واقترحت الدراسة استخدام RF, Adapboost XGBOOST، معًا، واستخدمت الدراسة أسلوب SMOTE لمعالجة مشكلة عدم التوازن في البيانات. وأشارت الدراسة إلى أن إجمالي الأصول غير المتداولة وصافي الربح بعد الضرائب وإجمالي الالتزامات من محددات التعثر المالي، وبصفة عامة تُعد الشركات محل الدراسة جيدة وغير معرضة للتعثر المالي فيما عدا قطاعات التغذية وتجارة الجملة.

وأظهرت دراسة Almamis et al. (2023) دقة أداء نموذج Gradient Boosting Models في التنبؤ بالتعثر المالي قبل حدوثه بعام، وذلك على 2585 شركة أمريكية خلال الفترة من 1990 إلى 2019.

وفي الصين اقترحت دراسة Liu et al. (2022) تحسين نموذج Extreme Gradient Boost للتنبؤ بالتعثر المالي، وذلك في حالة عدم التوازن الطبقي بين الفئات Imbalanced Data، حيث اتبع نهج المتوسط الحساس للتكلفة weight Cost Sensitive، وذلك لتقليل أخطاء التصنيف للشركات المتعثرة، وذلك بإعادة أخذ عينة من البيانات ثم اتخاذ القرار لإعادة بناء شجرة جديدة كتقريب لنموذج المجموعة الحساس للتكلفة مما يجعل الشجرة الجديدة المقترحة المستندة إلى Extreme Gradient Boost المعدل بنهج منهج المتوسط الحساس للتكلفة. واختبرت الدراسة النموذج المعدل الذي أثبت كفاءته بعد معالجة مشكلة عدم التوازن الطبقي في التصنيف.

اقترح Hadi et al. (2022) استخدام نموذج Stacking Models في التنبؤ بالتعثر المالي. واعتمد الباحثون على المتغيرات المستخدمة في نموذج Altman وهي النسب المالية، واستخدموا Beneish M- Score للكشف على التلاعب في التقارير المالية، واستخدموا LR, K – Nearest كمعلم أساسي في النموذج المقترح، وحصل الباحثون على بيانات 324 شركة في تايلون تم تقسيمها إلى 162 تعاني من تعثر مالي و162 شركة غير متعثرة، وتم تقييم أداء النموذج المقترح ومقارنته بالتقنيات المستخدمة في الدراسة باستخدام اختبار Wilcoxon Test، حيث أشارت نتائجه بتفوق أداء نموذج Stacking Models على نماذج LR, K- Nearest.

كما اقترح Aly et al. (2022) استخدام Catboost مع معالجة البيانات غير المتوازنة SMOTE على عينة من الشركات البولندية. وأوضحت الدراسة أن النموذج المقترح يخفض من أبعاد مجموعة البيانات لزيادة الأداء التنبؤي

باستخدام ثلاث تقنيات لاختيار العوامل المؤثرة في التعثر المالي للشركات. كما أوضحت الدراسة دقة النموذج المقترح في التنبؤ بحالات التعثر المالي في الشركات البولندية.

وطور (Jabeur et al., 2021) نموذجًا للتنبؤ بالتعثر المالي، مستخدمًا نموذج Catboost، وهو أحد نماذج Gradient Boosting التي تندرج ضمن نماذج التعلم الجماعي Ensemble Learning للتنبؤ بالتعثر المالي قبل حدوثه على الأقل بثلاث سنوات، وذلك باستخدام 18 مؤشرًا ماليًا يدل على الربحية والسيولة والمديونية. وقارن الباحثون بين النموذج المطور وعدد من نماذج الذكاء الاصطناعي والنماذج الإحصائية، وهي: الشبكات العصبية الاصطناعية، Random Forest، Support Vector Machine، Extreme Gradient Boosting، واستخلصت الدراسة تفوق أداء Catboost عن النماذج الأخرى، وخاصة في حالة انخفاض حجم العينات.

في سلوفينيا استخدمت (Durica et al., 2021) نموذج Cart للتنبؤ بالتعثر المالي في الشركات في النسب المالية فقط، واستخدمت الدراسة اختبار الدقة الذي أوضح دقة النموذج في التنبؤ بالتعثر المالي بدرجة 91%. وأشارت الدراسة إلى تفوق أداء نموذج Cart عن أساليب التنبؤ بالتعثر المالي، وخاصة أسلوب تحليل التمايز المتعدد والانحدار اللوجستي.

اقترحت دراسة (Muslim & Daszil 2021) نموذج STACKING للتنبؤ بالتعثر المالي في الشركات البولندية خلال الفترة من 2000-2012، حيث استخدم Extreme Gradient Boost لتحديد المزايا الأساسية في التعثر المالي، أما على المستوى الأساسي STACKING، اعتمدت فيه على نتائج أعمال نماذج K-Nearest, SVM, RF, DT، وفي المستوى الفوق اعتمدت على Light Gradient Boosting، وأشارت الدراسة إلى تحقيق نموذج STACKING دقة في التنبؤ بالتعثر المالي بنسبة 97%.

واختبرت دراسة (Liang et al., 2020) تأثير آليات الحوكمة في التنبؤ بالتعثر المالي. ولتحقيق هدف الدراسة استعانت بعناصر آليات الحوكمة والبالغ عددها 41 آلية تتضمن مجلس الإدارة وهيكل الملكية، وعدد 21 مؤشرًا ماليًا للتنبؤ بالتعثر المالي على شركات أمريكية، واستخدموا Staking Models والنماذج الاحتمالية التقليدية، وأجروا تجربتين: الأولى تمثلت في المقارنة بين استخدام آليات الحوكمة مع المعلومات المالية، واستخدام الباحثون نموذج Staking Models بدلاً عن التحليل الإحصائي، وأسفرت نتيجة التجربة الأولى بعدم قدرة النموذج المستخدمة في التنبؤ بالتعثر المالي بدقة عالية. أما التجربة الثانية استخدم الباحثون التحليل التمييزي التدريجي لتحديد الميزات المهمة التي تؤثر في التعثر المالي، وأجريت التحليل بواسطة Staking models الذي أظهر قدرته في التنبؤ بالتعثر المالي بدقة عالية؛ وبناء عليه أشارت الدراسة إلى إمكانية دمج معلومات الحوكمة والمعلومات المالية سوياً بعد تحضير البيانات باستخدام خاصية اختيار المميزات.

وفي أمريكا استخدم (Kim 2018) نموذج Stacking في تحديد العوامل المؤثرة في التعثر المالي في قطاعات الفنادق والمطاعم وأماكن الترفيه والتسلية. واتخذت الدراسة نماذج SVM, NN, DT في المستوى الأساسي BASE LEARNING، أما المستوى الفوق META LEARNING اعتمد على SVM، واستخلصت الدراسة أن نسبة الالتزامات/حقوق الملكية تؤثر تأثيرًا جوهريًا في التعثر المالي للشركات في الثلاث قطاعات.

وتختلف هذه الدراسة مع الدراسة الحالية في تكوين نموذج Stacking، حيث إن الدراسة الحالية تعتمد على نماذج Random Forest و AdaBoost و Gradient Boosting و XGBoost و CatBoost في المستوى الأساسي BASE LEARNING، أما التصنيف الفوقي (META LEARNING) فهو الانحدار اللوجستي.

- استخدام نماذج الذكاء الاصطناعي غير الخاضع للإشراف خاصة نماذج Clustering Algorithm في التنبؤ بالتعثر المالي

فاستخدمت استخدم Serkan et al. (2023) في دراستهم k-means Algorithm في تصنيف الشركات إلى شركات متعثرة وشركات غير متعثرة، معتمدين في ذلك على تشابه المؤشرات للشركات التركية محل الدراسة، وذلك خلال الفترة 2011 إلى 2021 في قطاع الصناعة، وأشارت الدراسة إلى دقة k-means algorithm وتفوقه على نمودي النماذج الاحتمالية ونموذج تحليل التمايز المتعدد من حيث الدقة.

كما استخدمت دراسة Justin et al. (2020) نموذج التعلم الآلي غير الخاضع للإشراف k-Means Clustering في تصنيف الشركات الخاصة بالرعاية الصحية في الولايات المتحدة الأمريكية إلى متعثرة، معرضة للتعثر وغير معرضة للتعثر، وذلك على 255269 مستشفى خلال الفترة من 2000 حتى 2015. واعتمدت على متغيرات نموذج Altman المعدل 1993 والخاص بالشركات الصناعية والشركات غير الصناعية في تحديد العوامل الخاصة بالتعثر المالي، كما استخدمت منحنى تحليل التمايز لتحديد السمات التي تؤثر في تصنيف الشركات الثلاثي. وأوضحت الدراسة أن معدلات الربحية والسيولة له تأثير جوهري في التعثر المالي للشركات، واختبرت الدراسة دقة النموذج المستخدم، حيث أثبتت الدراسة قدرة k-Means Clustering على تصنيف الشركات إلى متعثرة ومعرضة للتعثر وغير معرضة للتعثر بنسبة 44%، بل حدوث التعثر بسنة، و41% قبل حدوث التعثر بسنتين، و39% قبل حدوثه بثلاث سنوات. وتقرن الدراسة الحالية k-Means Clustering النماذج غير الخاضعة للإشراف والنماذج الخاضعة للإشراف التعلم الجماعي.

واقترحت دراسة Arian et al. (2020) استخدام خوارزمية الخليط الغوسي Gaussian Mixture Models في التنبؤ بالفشل المقترضين في سداد ديونهم، وقارن النموذج المقترح كأحد نماذج تعلم الآلة غير الخاضع للإشراف بعدد من نماذج الخاضعة للإشراف، مثل الانحدار اللوجستي و SVM، وأوضحت الدراسة تفوق نموذج Gaussian Mixture Models على نمودي تعلم الآلة الخاضع للإشراف.

- دراسات استهدفت تقييم أداء نمودي التعلم الجماعي وخوارزميات التجميع

ومع زيادة عدد الدراسات التي استهدفت استخدام نماذج الذكاء الاصطناعي المختلفة بنوعها الخاضعة للإشراف وغير الخاضع للإشراف، تناولت العديد من الدراسة تقييم أداء نماذج الذكاء الاصطناعي (Ensemble Learning, Clustering Algorithm)، ومقارنة أدائها في التنبؤ بالتعثر المالي، وكذلك مقارنة أدائها مع الأساليب الإحصائية التقليدية باستخدام العديد من الاختبارات المختلفة في هذا الشأن،

فاستهدفت دراسة Drogovoz & Nevredinov (2024) تقييم أداء بعض النماذج الفردية ANN، ونماذج التعلم الجماعي (Ensemble Learning) مثل STAKING، RF، في التنبؤ بالتعثر المالي، مستخدمين معلومات غير مالية مثل الناتج القومي الإجمالي ومعلومات مالية. وتوصلت الدراسة إلى دقة أداء ANN بمقدار 0.9727، في حين بلغت دقة

أداء RF 0.9746، وأخيرًا STAKING التي بلغت دقته 0.97836، أما اختبار AUC فحققت كل من النماذج السابقة أداء 0.92813 لـ ANN و 0.93277 لـ RF، وأخيرًا 0.9355 لـ STAKING؛ مما يشير إلى تفوق أداء STAKING على باقي النماذج الأخرى المستخدمة في الدراسة، غير أن الباحثين أشاروا إلى مدى تعقد بناء هذا النموذج وخاصة في المستوى الأساسي BASE LEVEL. وأخيرًا أكد الباحثون ضرورة إدراج المعلومات غير المالية مثل معلومات عن عوامل اقتصاد الدولة التي تعمل فيها الشركات، مثل: الناتج القومي الإجمالي، وعدم الاعتماد على المعلومات المالية فقط.

واستهدفت دراسة (Rahman & Zhu (2024) تقييم أداء عدد من نماذج التعلم الجماعي Ensemble Learning، وهي Cart, Adaboost, CUSBOOST في التنبؤ بالتعثر المالي في الشركات التشيد في الصين خلال الفترة من 2012 حتى 2021، واستخدمت الدراسة اختبار المنطقة الواقعة تحت المنحنى وAUC. حيث أوضحت نتيجة هذا الاختبار تفوق أداء CUSBOOST على Cart, Adaboost، حيث بلغ أداء كل منهم 0.78، 0.722، 0.68 على التوالي.

وتتماشى الدراسة الحالية مع هذه المقارنة بين CART وADABOOST، كما تتشابه الدراسة الحالية من حيث قطاع الصناعة حيث تعتمد كلا منهما على قطاع التشيد.

وقارنت دراسة (Soydas & Handan (2024) بين أداء عدد من نماذج تعلم الآلة الخاضع للإشراف (نماذج الفردية مثل SVM وDT، ونماذج التعلم الجماعي Ensemble Learning وهي RF في التنبؤ بالتعثر المالي، وذلك قبل حدوثه بفترات من سنة إلى خمس سنوات، وذلك على 178 شركة صناعية مقيدة في تركيا. واستخلصت نتيجة الدراسة أن كل من ANN وRF تفوق أداءها على باقي النماذج الأخرى المستخدمة في الدراسة، غير أن الباحثين توصلوا إلى استخدام RF للتنبؤ بالتعثر المالي قبل حدوثه بسنة أو ثلاث أو خمس سنوات، أما ANN يستخدم في التنبؤ بالتعثر المالي قبل حدوثه بستين أو أربع أو خمس سنوات.

وقارنت دراسة (Liashenko et al, (2023) بين نماذج التصنيف الأحادي SVM والشبكات العصبية وشجرة القرارات، والانحدار اللوجستي ونماذج التعلم الجماعي (Ensemble Learning) مثل Random Forest, Boosting، وذلك في ثلاث حالات: حالة استخدام بيانات متوازنة وحالة استخدام بيانات غير متوازنة وبيانات ضخمة، وذلك على بيانات لشركات أمريكية تم الحصول عليها من منصة Kaggle خلال الفترة من 1980 حتى 2017. واعتمدت الدراسة على تقنية Smote لعلاج مشكلة عدم التوازن، وأوضحت الدراسة تفوق نموذج Random Forest في حالات البيانات الصغيرة وحالات عدم توازن البيانات، أما في حالة البيانات الضخمة تتفوق الشبكات العصبية على باقي النماذج الأخرى محل الدراسة، كما لاحظت الدراسة تفوق RF على Boosting في التنبؤ بالتعثر المالي للشركات.

وبالمثل قارنت دراسة (Chaves et al., (2023) بين نماذج تعلم الآلة الخاضعة للإشراف، وهي نماذج التعلم الجماعي Ensemble Learning Models وهي Catboost, RF والنماذج LR, DT، وذلك على عدد 84 شركة برازيلية خلال الفترة من 2011-2020، وأوضحت الدراسة تفوق أداء نموذجي Ensemble Learning وهي Catboost, RF، غير أن الدراسة أثبتت تفوق نموذج Catboost على RF.

كما اختبرت دراسة (Aker & karavadar (2023) نماذج التعلم الآلي وخاصة بالتعلم الآلي الخاضع للإشراف وهي LR, DT, RF, SVM, Naïve Bays، وذلك على شركات صغيرة ومتوسطة الحجم وعددها 392 شركة، وذلك قبل حدوث التعثر المالي بسنة وستين أو أكثر. وأوضحت الدراسة أن دقة أداء DT قبل حدوثه بسنة أو اثنين بلغت بنسبة 90%

و97% على التوالي، بينما بلغت دقة نموذج Naïve Bays في توقع التعثر المالي قبل حدوثه بسنتين على الأقل بنسبة 90%، وأشارت الدراسة إلى أن الشركات المتعثرة تكون غير قادرة على سداد ديونها وخاصة المصرفية منها؛ مما يؤدي إلى تراكم الديون وزيادة أعباء الدين مما يقود إلى التعثر المالي والإفلاس.

واستهدفت دراسة (Tron et al. (2023) تحديد العلاقة بين حوكمة الشركات والتعثر المالي في إيطاليا، وذلك باستخدام نموذجي تعلم الآلة الخاضعة للإشراف وهي RF والنماذج الاحتمالية LOGIT، واستخدمت الدراسة خصائص مجلس الإدارة لتحقيق هدف الدراسة، والتي أسفرت على أن كل من التجديد للعضو التنفيذي واستقلالية مجلس الإدارة تؤثر في التعثر المالي، كما اختبرت الدراسة أداء النموذجين السابقين باستخدام أسلوب ROC الذي أوضح نتائج تفوق أداء RF على النماذج الاحتمالية المستخدمة في الدراسة.

وبالمثل اختبرت دراسة (Seyfullah (2023) أداء نماذج التعلم الآلي الخاضع للإشراف وهي RF, SVM, LR, K- NEAREST METHOD في التنبؤ بالتعثر المالي خلال الفترة من 2012 حتى 2021، واستخدمت الدراسة الاختبارات الدقة والقيمة التنبؤية الإيجابية والاستدعاء، حيث أسفرت نتيجة الاختبارات تفوق أداء نموذج RF عن غيره من النماذج المستخدمة في التنبؤ بالتعثر المالي. كما أشارت الدراسة إلى أن النسب المالية (الأصول المتداولة/الخصوم المتداولة، رأس المال العامل/إجمالي الأصول، مجمل الربح/الإيرادات، الأرباح المحتجزة/إجمالي الأصول، معدل نمو المبيعات) ذات تأثير جوهري في التعثر المالي للشركات.

واختبرت دراسة (Umut and Salih (2023) أداء XGBOOST في تركيا على 223 شركة خلال الفترة من 2010-2020 في التنبؤ بالتعثر المالي. ولتحقيق هدف الدراسة تم الحصول على عدد 25 نسب مالية قُسموا إلى 4 أقسام تخص الربحية والسيولة والهيكلة التمويلية والفاعلية. ولمعالجة مشكلة عدم التوازن الطبقي في البيانات استخدمت الدراسة أسلوب Smote، واستخدمت اختبارات الاستدعاء والدقة والقيمة التنبؤية الموجبة وF-Score. كما سجلت نتائج الاختبارات النسب التالية على التوالي (84.5%، 91.6%، 85.7%، 85.5%)، وأوصت الدراسة بضرورة تطبيق XGBOOST في التنبؤ بالتعثر المالي في تركيا.

وفي باكستان استهدفت دراسة (Domician et al. (2023) تقييم أداء نماذج تعلم الآلة الخاضع للإشراف وهي Ensemble Models مثل Adaboost, Gradient Boost، بجانب بعض النماذج الأخرى، مثل Naives, SVM, LR, Byes، وذلك على عينة من 385 شركة خلال الفترة من 2016-2021، واعتمدت الدراسة على النسب المالية، كما عرفت الدراسة الشركات المتعثرة بأنها التي تحقق صافي خسائر من العمليات التشغيلية وصافي تدفقات نقدية من عملياتها التشغيلية بالسالب لمدة ثلاث سنوات متتالية. وتوصلت الدراسة إلى أن نماذج تعلم المجموعات Ensemble Models تتفوق على النماذج الأخرى المستخدمة في الدراسة من حيث دقة التنبؤ بالتعثر المالي، حيث حقق Adaboost, Gradient Boost نسبة 100% من الدقة، وبلغت دقة نموذج SVM وLR نسبة 89% - 99%، أما نموذج Naives Byes بلغت دقته 70%.

واستهدفت دراسة (Wiena et al. (2023) إيجاد نموذج دقيق للتنبؤ بالتعثر المالي في تايلوان. ولتحقيق هذا الهدف استخدمت الدراسة أسلوب SMOTE لمعالجة مشكلة الاختلال الطبقي بين الفئات وعدد من النماذج تعلم الآلة الخاضع للإشراف الفردية وهي: K- NEAREST, CART, GRADIENT BOOSTING, NAIVES BAYS, LIGHT

GRADIENT BOOSTING و STACKING ، والذي يتضمن مستويين ، هما المستوى الأساسي ، وشمل النماذج سالفة الذكر ، أما المستوى الفوقى فاستخدم الباحثون فيه Extreme Gradient Boosting ؛ وبناء على اختبار الدقة حقق نموذج STACKING دقة فائقة في التنبؤ بالتعثر المالي وصلت نسبته 99.2% ، وقد تفوق النموذج المقترح في دقته على النماذج الأخرى المستخدمة .

استهدفت دراسة (Ramzan (2023) تقييم أداء النماذج الإحصائية التقليدية وخوارزميات التعلم الآلي خاصة التعلم الجماعي (Ensemble Learning) ، وذلك للتنبؤ بالتعثر المالي في الشركات المدرجة في بورصة نيويورك وناسداك . ومن خلال الاستفادة من النهج الكمي استخدمت الدراسة بيانات 1577 شركة لعام 2021 ، واستخلصت الدراسة أن (RF) و (XGBOOST) تفوقا في أدائهما في التنبؤ بالتعثر المالي بدقة 92.79% و 95.17% على الترتيب ، كما أشارت الدراسة إلى تفوق أداء نموذجي (XGBOOST) و (RF) على النماذج الأخرى من حيث الاستدعاء والقيمة التنبؤية الإيجابية .

قارنت دراسة (Malakauskas et al. (2023) عدداً من نماذج الخاصة بـ Ensemble Learning مثل RF, XGBOOST, CATBOOST ونموذج LR ، وذلك على عدد من الشركات الصغيرة ومتوسطة الحجم ، وأظهرت الدراسة تفوق نموذج CATBOOST على باقي النماذج تعلم الآلة المستخدمة ، كما أكدت الدراسة أن الشركات الصغيرة ومتوسطة الحجم ذات عمر أقل من 10 سنوات والتي تقل نسب السيولة النقدية عن 20%؛ أكثر الشركات عرضة للتعثر المالي ، وأن أهم السمات المؤثرة في التعثر المالي هي عمر الشركات والعملاء والمدنيين ونسب النقدية ، والمتمثلة في النقدية/إجمالي الخصوم المتداولة .

قارنت دراسة (jiaming et al. (2023) بين أداء عدد من نماذج Ensemble Learning وهي Gradient Boosting ، XGBOOST ، LIGHT GRADIENT BOOSTING ، Categorical Boosting ، والشركات المقيدة في البورصة خلال الفترة من 1998 حتى 2014 ، واستخلصت الدراسة أن أداء نموذج Gradient Boosting في التنبؤ بالتعثر المالي يفضل عن باقي النماذج الأخرى المستخدمة في الدراسة .

وباستخدام Shapley Regression حددت الدراسة أهم العوامل المؤثرة في التعثر المالي ، مثل صافي الربح التشغيلي/الخصوم المتداولة ، وأشارت الدراسة إلى أن العلاقة بين النسب المالية والتعثر المالي غير خطية .

قارنت دراسة (Liu et al. (2022) النماذج المختلفة وهي LR, SVM, RF, ADABOOST, GRADIENT BOOSTING ، وذلك في حالة معالجة البيانات وقبل معالجة البيانات باستخدام تقنية SMOTE في الشركات عالية التكنولوجيا الناشئة في دول الاتحاد الأوروبي . واستخلصت الدراسة تفوق أداء ADABOOST و EXTREEME GRADIENT BOOSTING على النماذج الأخرى المستخدمة في الدراسة ، ولم يختلف أداء RF على أدائه في حالتي قبل معالجة البيانات وبعدها ، وتفوق أداء EXTREEME GRADIENT BOOSTING على باقي النماذج الأخرى بعد معالجة SMOTE ؛ وبناء عليه تشير الدراسة إلى الدور الذي يمكن أن تؤديه SMOTE في تحسين أداء نماذج الذكاء الاصطناعي عند التنبؤ بالتعثر المالي .

كما استهدفت دراسة (Begum (2022) إيجاد نموذج دقيق للتنبؤ بالتعثر المالي في تاوان ، ولتحقيق هدف الدراسة أجريت مقارنة بين عدد من نماذج تعلم الآلة وهي Random Forest ، وهو نموذج Extreme Boosting Gradient

وANN، والنموذج الإحصائي الانحدار اللوجستي، وذلك على عدد من الشركات خلال الفترة من 1999-2009، واستخدمت الدراسة أسلوب Gini index لتحديد دقة النماذج المستخدمة في التنبؤ بالتعثر المالي، واعتمدت كذلك على المؤشرات المالية في تحديد العوامل المؤثرة في التعثر المالي، مثل: معدل تغطية الفائدة، معدل دوران الأصول الثابتة، متوسط فترة تحصيل، التدفقات النقدية/إجمالي الأصول، رأس المال العامل/إجمالي الأصول. واستخلصت الدراسة إلى تفوق أداء Random Forest على غيره من النماذج المستخدمة.

وقارنت دراسة (Zhong & Wang (2022) بين النماذج المختلفة Ensemble Models وهي CatBOOST Gradient Boosting، Random Forest، Extreme Gradient Boosting، boosting، للتنبؤ بالتعثر المالي قبل حدوثه من سنة إلى ثلاث سنوات، وذلك على 1668 شركة صناعية في الصين خلال الفترة من 2016-2021. واعتمدت الدراسة على 26 مؤشراً مالياً تم تقسيمهم إلى 6 مجموعات، وهي: الربحية، والملاءمة المالية، والقدرة على النمو، والمؤشرات الخاصة بهيكل رأس المال، ومؤشرات خاصة بالقدرة على النمو، ومعدلات النشاط لتحديد العوامل المؤثرة في التعثر المالي. ونظراً لصعوبة الحصول على البيانات الشركات المتعثرة عرفت الدراسة الشركات المتعثرة بأنها تلك الشركات التي يتم شطبها من البورصة، وتوصلت الدراسة إلى تفوق أداء نموذج Random Forest على باقي نماذج Ensemble Learning models الأخرى المستخدمة عند التنبؤ بالتعثر المالي أكثر من سنة وأقل من ثلاث سنوات، وأشارت الدراسة إلى أن مؤشرات الربحية وخاصة العائد على حقوق الملكية من أهم محددات التعثر المالي في الشركات الصناعية الصينية.

كما استهدفت دراسة (Tran et al. (2022) إجراء مقارنة بين بعض من نماذج الذكاء الاصطناعي، مثل: الانحدار اللوجستي، وشجرة القرارات، وRandom Forest وSVM وExtreme Gradient Boosting، على 90 شركة مقيدة في بورصة فيتنام خلال الفترة من 2010 حتى 2011، وذلك بإجراء عدد من الاختبارات، مثل: الدقة والحساسية و-F Score. وأوضحت نتيجة المقارنة إلى أن كل من Random Forest وExtreme Gradient Boosting، تتفوق في أدائها على باقي نماذج التنبؤ بالتعثر المالي، وأوضحت الدراسة أن نسبة القروض طويلة الأجل/إجمالي حقوق الملكية وقيمة المنشأة/إجمالي الإيرادات، نسبة الدائنين/إجمالي حقوق الملكية والعائد على السهم المنخفض diluted EPS؛ تؤثر في التنبؤ بالتعثر المالي.

واستهدفت دراسة (Tarun et al. (2022) تقييم أداء نماذج تعلم الآلة للتنبؤ بالتعثر المالي من حيث الدقة، وتم تجميع عدد من بيانات الشركات في تاوان، كما استخدمت الدراسة أسلوب SMOTE لتفادي مشكلة عدم توازن البيانات، واختارت الدراسة نموذج الانحدار اللوجستي وRF، Extreme Gradient Boosting، Cat boost ANN، كما استخدمت أسلوب الدقة لتقييم أداء نماذج تعلم الآلة، والتي أسفرت عن دقة أداء نموذجي RF، Extreme Gradient Boosting في التنبؤ بالتعثر المالي على نموذج الشبكات العصبية المستخدم في الدراسة.

استهدفت دراسة (Lenka & Mario (2022) تقييم عدد من نماذج تعلم الآلة، وهي: Catboost، Adaboost، Cart، C5- algorithm، LR، Naives Bayes، وذلك على عينة من 89851 شركة صغيرة ومتوسطة الحجم في سلوفيكيا. واستخدمت الدراسة عددًا من اختبارات التقييم مثل AUC- والدقة والحساسية والاستدعاء. وتوصلت نتيجة الدراسة إلى تفوق أداء Catboost على باقي النماذج الأخرى في كافة الاختبارات، فقد حقق على سبيل المثال نسبة 99.95% في اختبار AUC.

وفي إسبانيا اقترحت دراسة (Smith et al. (2022) استخدام Extreme Gradient Boost في التنبؤ بالتعثر المالي قبل حدوثه بأربع سنوات خلال الفترة من 1992-2016، واعتمدت الدراسة على عدد من النسب المالية، كما حددت الدراسة الميزات الخاصة بها باستخدام شجرة القرارات، وأشارت إلى أن أهم العوامل المؤثرة في التعثر المالي هي: نسبة إجمالي الالتزامات/إجمالي الأصول، معدل تغطية الفائدة وحجم الشركات. وقارنت الدراسة بين Extreme Gradient Boost وعدد من نماذج تعلم الآلة الخاضع للإشراف، مثل RF, SVM, NN, Light Gradient Boosting. وأوضحت نتيجة الاختبارات وخاصة ROC تفوق نموذج Extreme Gradient Boost على باقي النماذج الأخرى، وأشارت الدراسة إلى قدرة Extreme Gradient Boost على التنبؤ بالتعثر المالي في حالات العلاقات غير الخطية والظروف غير العادية مثل حالات الكساد التي مرت بها إسبانيا خلال فترة عينة الدراسة.

في بلجيكا استخدمت دراسة (Shetty et al. (2022) نماذج تعلم الآلة الخاضع للإشراف وهي: Support Vector Machine, Extreme Gradient Boosting، وتعلم الآلة غير الخاضع للإشراف، وهي التعلم العميق للآلة، ويتمثل هذا النموذج في نموذج الشبكة الاصطناعية العميقة Deep Neural Network، وذلك على 3728 شركة صغيرة ومتوسطة الحجم خلال الفترة من 2002-2012. واعتمدت الدراسة على عدد من النسب المالية لتحديد الميزات المؤثرة في التعثر المالي. وأوضحت نتيجة الدراسة الحالية أن كل من العائد على الأصول ونسبة التداول تؤثر في التعثر المالي، كما أوضحت نتيجة اختبار الدقة في نماذج التعلم الآلي تتراوح ما بين 82-83 من الدقة. ولا توجد فروق جوهرية من حيث دقة النماذج المستخدمة، ويرجع ذلك إلى زيادة التداخل بين السمات المؤثرة في التعثر المالي.

وتختلف الدراسة الحالية عن دراسة (Shetty et al. (2022) بحجم العينة المستخدمة، حيث إن الدراسة الأخيرة اعتمدت على الشركات الصغيرة ومتوسطة الحجم ولم تحدد قطاع الصناعة، وتطبق الدراسة الحالية على الشركات العقارية والتشييد ومواد البناء المقيدة في البورصة المصرية، وتختبر حجم الشركة كإحدى السمات المؤثرة في التنبؤ بالتعثر المالي، كما أنها تعتمد على المعلومات غير المالية إضافة إلى المعلومات المالية.

استهدفت دراسة (Quian et al. (2022) تقييم أداء بعض نماذج تعلم الآلة وهي: LR, ANN, SVM, DT، وذلك على الشركات الصينية المقيدة في البورصة خلال الفترة من 2001-2019 وذلك على بيانات متوازنة. واستخدمت الدراسة RF للاختيار السمات المهمة، كما استخدمت تقنية Permutation Importance لتفادي تأثير المتغيرات في بعضها. واستخلصت الدراسة تفوق أداء نموذج XGBOOST، على باقي النماذج الأخرى المستخدمة في الدراسة، وذلك من حيث الدقة والاستدعاء والقيمة التنبؤية الايجابية H- MEASURE، AUC، F- Score.

قارنت دراسة (Catalin et al. (2022) بين عدد من نماذج الآلة الخاضع للإشراف (LR, RF, XGBOOST) لعدد من الشركات التي تعمل في الأسواق الناشئة خلال الفترة من 2000 إلى 2012، وأوضحت الدراسة تفوق أداء XGBOOST على باقي النماذج الأخرى وذلك على بيانات غير متوازنة، ثم أجريت تجربة باستخدام XGBOOST على بيانات متوازنة (أي بعد استخدام تقنية SMOTE)، وأطلق على هذا التعديل XGBOOST WITH SMOTE، وتم تقييم أداء النموذج المعدل باستخدام SMOTE، حيث أثبتت الدراسة تحسين أداء نموذج 6% بعد استخدام (SMOTE).

قارنت دراسة (Abdulla (2021) بين عدد من نماذج تعلم الآلة (CART, K-NEAREST NEAREST NEIGHBOR, NAIVES BAYES, NN, SVM) في التنبؤ بالتعثر المالي، وذلك على عدد 244 شركة في بنجلاديش خلال الفترة من 2015-2019. واعتمدت الدراسة على النسب المالية فقط. واستخلصت الدراسة تفوق أداء نموذج CART في التنبؤ بالتعثر المالي على باقي النماذج المستخدمة في الدراسة، حيث بلغت دقته 96%، في حين بلغت دقة NN, KNN, SVM, NAIVES BAYES على التوالي: 74%، 80%، 85%، 88%.

واستخدم (Fan et al. (2021) عددًا من النسب المالية، مثل: إجمالي الالتزامات/إجمالي الأصول، الأصول المتداولة/الخصوم المتداولة، نسبة التداول - إجمالي الالتزامات/إجمالي حقوق الملكية، صافي التدفقات النقدية من العمليات التشغيلية/الالتزامات المتداولة، وعوامل الحوكمة مثل عدد الأسهم المملوكة لمديرين في تقييم أداء نماذج التعلم الآلي في التنبؤ بالتعثر المالي وهي: NN, SVM, LR, DT, RF, Adapboost, Extreme Gradient Boost. كما استخدمت الدراسة SMOTE لمواجهة مشكلة عدم التوازن في البيانات، وأجريت اختبارات الدقة والاستدعاء لنماذج سألقة الذكر، حيث أوضحت النتائج تفوق XGBOOST و RF عن غيره من النماذج.

واستخدمت دراسة (Phan & Ho (2021) نماذج التعزيز Boosting وهي XGBOOST و Adapboost و Gadient Boosting، وذلك على تقارير ربع سنوية لعدد 180 بنكًا أمريكيًا خلال الفترة من 2009 حتى 2019. واستخدمت الدراسة عددًا من اختبارات تقييم أداء النماذج التنبؤية باستخدام التعلم الآلي، مثل: الدقة والاستدعاء والقيمة التنبؤية الإيجابية.

وأظهرت نتيجة XGBOOST تفوق أدائه عن غيره من نماذج التعزيز من حيث الدقة، فبلغت دقته 96.3%، ولبه Gradient Boosting بدرجة 94.44%، وأخيرًا Adapboost فبلغت دقته 92.59%. أما من حيث الاستدعاء فوصلت درجة أدائه إلى 100%، كما اقترحت الدراسة استخدام التقارير ربع السنوية بديلًا عن التقارير المالية السنوية، وأنه يمكن التنبؤ بالتعثر المالي قبل حدوثه بفترة من أربعة إلى خمسة فصول ربع سنوية.

واستخدمت دراسة (Malakuskas & Lakstutiene (2021) نماذج LR, NN, RF لتصنيف 12000 شركة صغيرة ومتوسطة الحجم إلى شركات متعثرة وشركات غير متعثرة في دول البلطيق. كما استخدموا المؤشرات المالية وعمر المنشأة والسجل الائتماني للشركات. وصنّف الباحثون أداء النماذج المستخدمة باستخدام أساليب تقييم البرامج مثل الدقة والحساسية، حيث أسفرت نتائج تقييم النماذج عن دقة RF وتفوقه على غيره من نماذج الدراسة.

واستهدفت دراسة (Fayaz et al. (2021) تقييم أداء نماذج التعلم الآلي في التنبؤ بالتعثر المالي في باكستان. ولتحقيق هدف الدراسة استخدم الباحثون عددًا من المؤشرات المالية التي تؤثر في التعثر المالي، واستخدم ROC لتقييم أداء نماذج تعلم الآلة وهي NN, SVM, DT, LR, Adaboost. وأوضحت الدراسة أن صافي الربح قبل الضريبة/إجمالي الأصول، الأصول المتداولة/إجمالي الأصول، صافي الربح/الالتزامات، صافي الربح/المبيعات، رأس المال العامل/إجمالي الأصول؛ من محددات التعثر المالي ودقة أداء Adaboost في التنبؤ بالتعثر المالي في باكستان عن غيره من نماذج تعلم الآلة.

استهدفت دراسة (Yousaf et al. (2021) تنوع أعضاء مجلس الإدارة من حيث العمر والنوع والخلفية العلمية على التعثر المالي للشركات الصينية خلال الفترة من 2007-2016. ولتحقيق هدف الدراسة استخدمت عددًا من نماذج

تعلم الآلة الخاضع للإشراف مثل LR, Boosting, RF. واستخلصت نتائج الدراسة أن تنوع أعضاء مجلس الإدارة يرتبط ارتباطاً قوياً بالتعثر المالي للشركات، وأن RF يتفوق على باقي النماذج الأخرى المستخدمة في الدراسة.

استهدفت دراسة (Manthoulis et al. (2021) تقييم أداء عدد من نماذج التعلم الآلي الخاضع للإشراف، مثل الانحدار اللوجستي RF, SVM, ANN, EXTREEME GRADIENT BOOSTING, LR في التنبؤ بالتعثر المالي في البنوك الأمريكية قبل حدوثه بسنة أو أكثر، وذلك بواقع 60000 مشاهدة خلال الفترة من 2005-2014. ولتحقيق هدف الدراسة استخدمت عددًا من الاختبارات تقييم الأداء (المنطقة الواقعة تحت الخط H-MEASURE – ROC – AUC ANN, LR, KOLMOGOROV – SMIRNOV- DISTANCE)، وتوصلت نتيجة الاختبارات السابقة إلى تفوق أداء ANN, LR, ETREEME GRADIENT BOOSTING RF، وذلك عند التنبؤ بالتعثر المالي قبل حدوثه بعام، في حين تفوقت نماذج ANN, LR, ETREEME GRADIENT BOOSTING RF، على نماذج الإشراف الفردية LR, ANN عند التنبؤ بالتعثر المالي قبل بثلاث سنوات.

استهدفت دراسة (Bragoli et al. (2021) تقييم أداء بعض نماذج تعلم الآلة الخاضع للإشراف وهي RF, XGBOOST, NN, LR في التنبؤ بالتعثر المالي في الشركات الصناعية في إيطاليا خلال الفترة من 2007-2015. واعتمدت الدراسة على النسب المالية فقط وذلك قبل سنة من حدوثه، واستخدمت الدراسة اختبار الدقة لتحديد هذا الهدف، حيث أسفرت على تفوق أداء XGBOOST على غيره من النماذج المستخدمة في الدراسة.

استهدفت دراسة (Narvekar & Guha (2021) تقييم أداء نماذج RF, SVM, XGBOOST في التنبؤ بالتعثر المالي قبل حدوثه بـ 30 يومًا أو 90 يومًا أو 180 يومًا، وذلك على 21114 شركة أمريكية خلال الفترة من 1970 حتى 2020، مستخدمين 57 مؤشرًا ماليًا و ROC-AUC لتقييم أداء النماذج. واستخلصت الدراسة تفوق XGBOOST على RF, SVM، حيث حقق ROC-AUC نسبة 99% والتي تدل على قدرة XGBOOST في التنبؤ بالتعثر المالي بدقة عالية.

واستخدمت دراسة (Viswanathan et al. (2020) التعلم الآلي غير الخاضع للإشراف Unsupervised machine وهي K-means، كما تم استخدام عدد من نماذج التعلم الآلي الخاضع للدراسة، وخاصة نموذج RF والنموذج الإحصائي والتحليل التمييزي الخطي من النماذج الإحصائية، وذلك لتصنيف البنوك إلى بنوك جيدة وغير جيدة، وذلك على 44 بنوكًا هنديًا، وباستخدام نموذج (K-means)، وأوضحت الدراسة أن العائد على الأصول من العوامل التي تحدد البنوك الجيدة أو غير الجيدة، كما استخلصت الدراسة تفوق النموذج الإحصائي التحليل التمييزي الخطي على RF في تصنيف البنوك إلى بنوك جيدة وغير جيدة.

واستخدم (Chenand Shen (2020) المؤشرات المالية وعوامل الحوكمة (هيكل الملكية وجودة المراجع الخارجي) وأسلوب RF و CART في تايوان للتنبؤ بالتعثر المالي، وأسلوب LASSO لمعالجة مشكلة عدم الاستقلالية بين المتغيرات، وذلك على شركات في تايوان خلال الفترة من 2012-2018. وتوصلت الدراسة إلى أن نموذج CART يستطيع التنبؤ بالتعثر المالي بدقة تبلغ 89.74%، أما RF فتبلغ دقة أدائه في التنبؤ بالتعثر المالي 86.30%.

واستهدفت دراسة (Sreedharan et al. (2020) تقييم ومقارنة أداء نماذج تعلم الآلة وهي: NN, DT, SVM, RF, ADABOOST في دولة الإمارات المتحدة، وذلك على 38 شركة خلال الفترة من 2010-2017. واستخدمت الدراسة في تقييم أداء نماذج تعلم الآلة اختبارات الدقة والقيمة التنبؤية الإيجابية والاستدعاء، وتوصلت نتيجة الاختبارات السابقة إلى تفوق أداء الشبكات العصبية على باقي النماذج الأخرى.

واستهدفت دراسة Faris et al. (2020) تقييم أداء بعض من نماذج تعلم الآلة وهي KNN- ANN- DT- RF وADABOOST في التنبؤ بالتعثر المالي في الشركات الإسبانية، وكما استخدمت الدراسة تقنية SMOTE لمعالجة الاختلال الطبقي بين الفئات، كما استخدمت الدراسة نهج السمات المميزة لتحديد العوامل المؤثرة في التعثر المالي. وأجريت الدراسة اختبار دقة أداء النماذج، حيث استخلصت الدراسة تفوق أداء ADBOOST على غيره من النماذج الأخرى والتي بلغت 98.3%.

وقارنت دراسة Shrivasta et al. (2020) بين أداء نماذج تعلم الآلة RF, ADABOOST, LR في التنبؤ بالتعثر المالي في البنوك الخاصة والبنوك الحكومية في الهند، واعتمدت الدراسة على SMOTE في معالجة مشكلة عدم التوازن الطبقي بين الفئات وLasso لتحديد السمات المميزة، واستخلصت الدراسة تفوق أداء ADABOOST, على نموذجي RF وLR.

واستخدمت دراسة Francisco et al. (2019) نموذج (XGBOOST) للتنبؤ بالتعثر المالي في البنوك بأوروبا، وهي تلك البنوك التي تتلقى منحًا من الحكومات وذلك خلال الفترة من 2006-2016، واستخدمت الدراسة المؤشرات المالية كسمات أساسية للنموذج التنبؤي، كما استخدمت ROC- AUC لتقييم أداء نموذج (XGBOOST) وحقق أداء نموذج (XGBOOST) نسبة 81.7%، وأشار الباحثون إلى أن البنوك كبيرة الحجم أكثر عرضة للتعثر المالي، وأن (XGBOOST) يمكنه التعامل مع مشكلة تعدد العلاقات الخطية بين السمات وبعضها وهي مشكلة متأصلة في نماذج الانحدار الخطي.

واستخدم Halteh et al. (2018) نماذج (RF, GRADIENT BOOSTING, CART) ENSEMBLE LEARNING لتحديد العوامل المؤثرة في التنبؤ بالتعثر المالي في البنوك الإسلامية العالمية، حيث تم تجميع بيانات من 101 بنك إسلامي من قاعدة APITAL IQ. واعتمدت الدراسة على متغيرات النسب المالية المستخدمة في نماذج ALTMAN, Z-SCORE, ALTAMAN FOR SERVICE, ومعايير الربحية الخاصة بالبنوك، واستخلصت الدراسة أن كل من نسبة رأس المال العامل/إجمالي الأصول والعائد على الإيرادات من محددات التعثر المالي.

قارنت دراسة Wyrobeck & Krzytof (2018) بين دقة النماذج المستخدمة النماذج الاحتمالية الإحصائية ونموذج التمايز الخطي (LDA) ونماذج التعلم الجماعي (Ensemble learning) وهي نموذج GRADIENT BOOSTING وRF في التنبؤ بالتعثر المالي، وذلك على الشركات البولندية خلال الفترة من 2008 – 2017. واستخلصت الدراسة تفوق أداء نموذج GRADIENT BOOSTING على باقي النماذج الأخرى المستخدمة في الدراسة بدقة 99.9%، تبعه في ذلك RF بدقة 98.91%، والنماذج الاحتمالية بدقة 87.10%، ونموذج التمايز الأحادي بلغت دقته 86.31%.

وأجرى Bard (2017) دراسة على شركات صناعة السلمون وتربية الأسماك النرويجية وذلك في تجربتين منفصلين. واستخدم الباحث عددًا من النسب المالية، مثل: نسبة التداول وحقوق الملكية/إجمالي الأصول ومعدل دوران الأصول الثابتة والعائد على المبيعات ومعدل تغطية الفائدة. واستخدمت الدراسة نموذجي LR, Cart، وبناء على التجريبتين أثبتت الدراسة تأثير معدل تغطية الفائدة في التعثر المالي للشركات الخاصة بصناعة السلمون وشركات تربية الأسماك، ومن حيث أداء النموذجين المستخدمين في الدراسة استخلصت الدراسة تفوق أداء نموذج Cart على LR بنسبة 86.7% في الشركات الخاصة بصناعة السلمون، وذلك على عكس الشركات الخاصة بتربية الأسماك،

حيث تفوق LR على Cart بنسبة 75.2%، وعلل الباحث هذه النتيجة باختلاف حجم العينة المستخدم في التجريبتين والفترة الزمنية لهما.

-الفجوة البحثية

بناء على العرض السابق للدراسات السابقة نجد أن معظم الدراسات استهدفت تقييم أداء نماذج تعلم الآلة الخاضع للإشراف وإجراء مقارنة مع بعضهم البعض مثل دراسة (Seyfullah (2023). كما قارنت عددًا من الدراسات بين نماذج التعلم الجماعي Ensemble Learning بعضها مثل (Phan & Ho. (2021)، و قارنت العديد من الدراسات نماذج التعلم الجماعي والنماذج الفردية مثل (Soydas and Drogovoz & Nevredinov (2024) دراسة SVM, DT, كما قارن العديد من الباحثين نماذج التعلم الجماعي ونماذج الإحصاء التقليدية مثل دراسة (Handan (2024) كما قارن العديد من الباحثين نماذج التعلم الجماعي ونماذج الإحصاء التقليدية مثل دراسة (Papikova and Papik (2024); Durica et al. (2021); Chaves et al. (2023)، واختلفت نتائج هذه الدراسة فعلى سبيل المثال اسفرت دراسة (Malakuskas & Lakstutiene (2021) تفوق نماذج التعلم الجماعي RF على الانحدار اللوجستي، بينما أسفرت دراسة (Viswanathan et al. (2020) عن تفوق أداء النموذج الإحصائي (تحليل التمايز الخطي) على نماذج التعلم الجماعي . RF

وعلى الجانب الآخر قارن بعض الباحثين أداء نماذج Clustering Algorithm و بين النماذج الإحصائية ونماذج الإشراف الفردية (Serkan et al. (2023); Arian et al. (2020) عند التنبؤ بالتعثر المالي، حيث اسفرت تلك الدراسات على تفوق أداء نماذج Clustering Algorithm على كل من النماذج الفردية و النماذج الاحصائية في التنبؤ بالتعثر المالي . غير أنه لم يتطرق الباحثين إلى إجراء مقارنة بين Clustering Algorithm و Ensemble Learning، وذلك على حد علم الباحث وفي ضوء المسح الشامل لدراسات التي قام بها الباحث؛ وبناء عليه تستهدف الدراسة الحالية تقييم أداء نماذج الخاصة Clustering algorithm ونماذج Ensemble Learning.

ومن ناحية أخرى ركزت أغلب الدول في دراساتها على بلدان أوروبا وأمريكا والصين والهند وباكستان وخاصة المعتمدة على التعلم الآلي، ولم تتناول منها هذه الدراسات تقييم أداء النماذج السالفة الذكر في دول الاقتصاديات الناشئة أو تلك التي تعاني من مشاكل اقتصادية مثل مصر. كما تختلف هذه الدراسة في تحديد التعثر المالي باستخدام نموذج EM-ZSCORE الخاص بالدول النامية، حيث إن أغلب هذه الدراسات تصنف هذه الشركات بأنها تلك الشركات التي تحقق صافي تدفقات بالسالب خلال عامين متتاليين، أو تحقيق خسائر من عملياتها التشغيلية لمدة عامين متتاليين أو الشطب من البورصة. وتختلف هذه الدراسة عن الدراسات المعروضة في معالجتنا لمشاكل البيانات التي تواجه الباحثين في مجال التنبؤ مثل مشكلة القيم المتطرفة، حيث إن الدراسات المعروضة لم تتطرق إلى هذه المشكلة، وأخيرًا تدمج هذه الدراسة العوامل الاقتصادية وخصائص الشركات مثل حجم الشركات وعمرها، وهي تلك العوامل التي لم تأخذها الدراسات الخاصة بالتعلم الآلي Machine Learning في الحسبان.

ومن العرض السابق للدراسات نجد أن هناك عددًا من المشكلات التي واجهت العديد من الباحثين منها مشكلة اختلال التوازن الطبقي، والذي يحدث عندما يكون عدد الحالات في فئة واحدة كثيرة وأكبر من الآخر وهو أمر واقعي، وخاصة في تصنيف الشركات إلى شركات متعثرة وغير متعثرة، وتحدث هذه الحالات نتيجة إلى: نقص بيانات الأقليات (حيث لا يمكن العثور على أنماط مبررات وبسبب محدودية وكمية أمثلة فئات الأقليات، تداخل أو فصل

الطبقة، ومن الأمثلة الشائعة في هذا الشأن (الفئة مختلطة وبعضها البعض في حيز تمييز الانفصالات الصغيرة وتدخلات ومجموعات صغيرة من فئة الأقليات بالمساحة)؛ مما دعى العديد من الباحثين إلى استخدام أساليب معالجة هذه المشكلة مثل SMOTE - (Dovile et al. 2022). Synthetic Minority Over-sampling Technique. واستخدمت عددًا من الدراسات هذه التقنية منها (Liashenko et al. 2023); An`Ong & kamsami (2023) وغيرها من الدراسات، وتقارن الدراسة الحالية بين نماذج التعلم الآلي المدربة على بيانات غير متوازنة (حالة عدم استخدام تقنية Smote). وحالة استخدام بيانات متوازنة (بعد استخدام تقنية Smote). كما أننا نجد أن معظم الدراسات تطرقت إلى مشكلة ظهور قيم متطرفة في البيانات مثل Smith et al. 2022. وهناك العديد من الطرق التي تكشف عن هذه المشكلة مثل الرسوم البيانية أو IQR ويتم معالجة هذه الطرق بعدد من الطرق، فإذا كانت هذه المشكلة ناتجة عن أخطاء في البيانات يتم تصحيح الخطأ أو حذفها، وإذا كانت ناتجة عن أخطاء غير ذلك يتم معالجتها بعدد من الطرق، إما بالإبقاء عليها أو الحذف أو التسجيل والملاحظة أو إعادة الترميز (Dash et al. 2023). وتستخدم الدراسة الحالية QR الالكتشاف القيم المتطرفة وذلك على نحو ما يلي في الفصل التالي.

(3) مشكلة الدراسة

نجد أن هناك العديد من الدراسات استهدفت تقييم أداء مجموعة Ensemble Learning ومقارنة أداء بعضها البعض في التنبؤ بالتعثر المالي في الشركات، مثل دراسة (Rahman & Zhu (2024)، أو مقارنة أدائها بنماذج أخرى من نماذج الذكاء الاصطناعي الخاضعة للإشراف، مثل: النماذج الفردية مثل الشبكات العصبية و SVM وغيرها من النماذج، وذلك مثل دراسة (Drogovoz & Nevredinov (2024); Shetty et al. 2022; Soydas & Handan 2024) وعلى الرغم من استخدام عدد من الدراسات مثل (Serkan et al. (2023); Justin et al. (2020) نماذج Clustering Algorithm خاصة K- MEANS، والذي أثبت تفوقه في التنبؤ بالتعثر المالي للشركات على الأساليب الإحصائية التقليدية، مثل: الانحدار اللوجستي.

كما تناولت بعض الدراسات (Arian et al. (2020) تقييم أداء Clustering Algorithm ومقارنته بنماذج الخاضعة للإشراف الفردي مثل SVM، إلا أن الدراسات السابقة لم تتناول إجراء مقارنة بين Clustering Algorithm و Ensemble Learning، وذلك على حد علم الباحث وفي حدود المسح الشامل للدراسات التي حصل عليه؛ وبناء عليه تدرس الدراسة الحالية الفروق الجوهرية في أداء Clustering Algorithm و Ensemble Learning، وذلك لإيجاد الفروق ذات الدلالة الإحصائية في أدائها باستخدام الاختبارات المتعلقة في هذا الشأن؛ وبناء عليه يمكن طرح تساؤل التالي:

- هل توجد فروق ذات دلالة إحصائية بين نموذج الذكاء الاصطناعي الخاضع للإشراف (Learning Ensemble) ونموذج الذكاء الاصطناعي غير الخاضع للإشراف (Clustering Algorithm)؟

قارنت العديد من الدراسات بين نماذج الإشراف الخاضع للإشراف (Ensemble Learning) ونماذج الإحصاء التقليدية خاصة نموذج التمايز الخطي مثل دراسة (Chaves et al. 2023; Durica et al. 2021; Malakauskas et al. 2023; Wyrobeck & Krzytof, 2018) حيث استخلصت معظم الدراسات المذكورة بتفوق أداء نماذج الذكاء

الاصطناعي (Clustering Algorithm) & (Ensemble Learning)؛ وبناء عليه يمكن وضع الفرض التي؛ ولذا يمكن طرح التساؤل التالي:

- هل توجد فروق ذات دلالة إحصائية بين نموذج الذكاء الاصطناعي الخاضع للإشراف (Ensemble Learning) ونموذج الذكاء الاصطناعي غير الخاضع للإشراف (Clustering Algorithm) ونماذج الإحصاء التقليدية؟

(4) منهجية الدراسة

تستعرض الدراسة في جزء منها المنهجية المتبعة لتحقيق هدفها، وهو إيجاد نموذج للتنبؤ بالذكاء الاصطناعي مناسب للتنبؤ بالتعثر المالي بداية من تحديد المتغير التابع التنبؤي و (Labels)، وتحديد العوامل المؤثرة في القيمة التنبؤية - المتغير المستقل Feature، ثم اختيار الذكاء الاصطناعي (الخاضع وغير الخاضع للإشراف)، والتدريب على النموذج التنبؤي، وتقييم أداء هذه النماذج من خلال عدد من الاختبارات، مثل: الدقة والضبط والاستدعاء و F-Score والمنطقة الواقعة أسفل المنحنى.

(5) فروض الدراسة

- توجد فروق ذات دلالة إحصائية بين نموذج الذكاء الاصطناعي الخاضع للإشراف (Ensemble Learning) ونموذج الذكاء الاصطناعي غير الخاضع للإشراف (Clustering).

- توجد فروق ذات دلالة إحصائية بين نماذج الذكاء الاصطناعي (Ensemble Learning) و (Clustering) وبين النماذج التقليدية في الإحصاء.

(6) مجتمع وعينة الدراسة

تم تطبيق الدراسة على 44 شركة مقيدة في البورصة المصرية خلال الفترة من 2007-2022، موزعة على ثلاث قطاعات كالتالي: 7 قطاعات من التشيد والمقاولات، 25 قطاعًا عقاريًا، 12 شركة تخص مواد البناء.

خطوات اختيار نموذج الذكاء الاصطناعي للتنبؤ بالتعثر المالي

اتبعت الدراسة عددًا من الخطوات التي سنعرضها في هذا الجزء.

(1-6) تحديد المتغير التابع

احتسبت الدراسة (EM- Z SCORE) للشركات محل الدراسة، وذلك طبقًا لمعادلة التالية:

$$Z=3.25+ 6.56X_1+3.26X_2+6.72X_3+1.05X_4$$

وتمثل X_1, X_2, X_3, X_4 على الترتيب: رأس المال العامل/إجمالي الأصول، الأرباح المحتجزة/إجمالي الأصول، الربح قبل الفائدة والضريبة/إجمالي الأصول، حقوق الملكية/إجمالي الالتزامات، حيث تم احتساب كل من هذه النسب من التقارير المالية السنوية للشركات محل الدراسة خلال الفترة من 2007-2022، واحتساب Z SCORE عن كل سنة، واحتساب متوسط Z SCORE لتصنيف الشركات، وذلك على النحو الموضح بالمحلقة رقم (1). وتم استخدام تصنيف الشركات إلى شركات متعثرة وغير متعثرة وشركات تقع في المنطقة الرمادية، وذلك لاستخراج Z SCORE

التنبؤية والتي اعتمدت على تكويد وترميز متعثر – غير متعثر ومنطقة رمادية إلى 1 للتعثر، صفر غير متعثر، وتم اختيار رقم عشوائي لمنطقة الرمادية وهو 2، وذلك طبقاً لما يلي:

```
label_map = {
'Not Distress': 0,
'Distress': 1,
'Grey Area': 2,
if z < 1.1:
return 'Distress'
elif z > 2.60:
return 'Not Distress'
else:
return 'Grey Area'
```

- Apply Categorization and Map Labels:

```
df['Label'] = df['z score'].apply(categorize_z_score)
df['Label'] = df['Label'].map(label_map)
```

وبناء على ما سبق تم اشتقاق Z1 ، والتي تمثل التنبؤ بالتعثر المالي، غير أن هذه القيم غير متوازنة؛ ولذا تم استخدام تقنية SMOTE لتوازن Z1؛ وبناء عليه أصبح لدينا نوعين من Z1 التنبؤية قبل التوازن وبعد التوازن، والتي سيتم تدريب واختبار مصدقية النماذج المختارة.

(2-6) تحديد المتغير المستقل FEATURE

تم تحديد 26 عنصرًا لتحديد العوامل المؤثرة في التعثر المالي، تمثلت في مجموعة النسب المالية وعوامل الاقتصاد وعوامل الحوكمة وخصائص الشركات (العمر، الحجم)، وذلك كما في الجدول التالي:

جدول 2: العوامل المؤثرة في التعثر المالي

المتغيرات	النسب والمتغيرات	التصنيف ومقياس	الدراسات السابقة
المؤشرات المالية			
X ₁	رأس المال العامل/إجمالي الأصول	السيولة	siti et al 2024,halteh et al 2018
X ₂	الأرباح المحتجزة/إجمالي الأصول	الملاءمة	Siti et al 2024, Justin et al 2020 ,
X ₃	صافي الربح قبل الضريبة/إجمالي الأصول	الربحية	Siti et al 2024
X ₄	إجمالي المبيعات/إجمالي الأصول	نسب نشاط (كفاءة)	Wira et al 2024
X ₅	الأصول المتداولة/الخصوم المتداولة	سيولة	Bukhori et al 2022
X ₆	إجمالي الالتزامات/إجمالي الأصول	ديون	Yusuf 2024, Zhong et al (2022

الدراسات السابقة	التصنيف ومقياس	النسب والمتغيرات	المتغيرات
الطوليل & مهننا 2020	سيولة	صافي التدفقات النقدية من عمليات التشغيلية/ إجمالي الالتزامات المتداولة	X ₇
ابوالسعود وآخرون 2022	السيولة	صافي التدفقات النقدية من العمليات التشغيلية/ إجمالي الالتزامات	X ₈
Mohamed 2022	السيولة	أصول المتداولة/ إجمالي الأصول	X ₉
Hidayat & Yuniati (2024)--	ديون	الخصوم المتداولة/ إجمالي الأصول المتداولة.	X ₁₀
Haris 2023, kimsoon young 2018,	رفع مالي	إجمالي الالتزامات/ حقوق الملكية	X ₁₁
بوضياف 2018	ربحية	نسبة هامش الربح/ المبيعات	X ₁₂
Hamid & rohani 2018, bard 2017	تغطية	معدل الربح قبل الفائدة والضرائب/ معدل الفائدة	X ₁₃
Mohamed 2022	مؤشر مالي سوقي	سعر السهم	X ₁₉
عوامل الحوكمة			
Ragab & salah 2022,	حوكمة	نسبة ملكية أعضاء مجلس الإدارة	X ₁₄
Aburgri 2022,	حوكمة	نوع (الجنس) عدد تمثيل المرأة في مجلس الإدارة	X ₁₅
Rasheed et al 2023	حوكمة	عدد مرات اجتماع لجان المراجعة	X ₁₆
Rasheed et al 2023	حوكمة	عدد مرات مجلس الإدارة	X ₁₇
Nour et al 2023	حوكمة	جودة المراجع الخارجي - إذا ما كان مكتب المراجع أحد المكاتب الكبرى أم لا؟	X ₁₈
عوامل الاقتصاد			
Evi & indra 2022	عوامل الاقتصاد	سعر الصرف	X ₂₀
Valentine et al 2023,	عوامل الاقتصاد	سعر الفائدة	X ₂₁
Dewin et al 2023,	عوامل الاقتصاد	معدل التضخم	X ₂₂
Ece & guven 2020	عوامل الاقتصاد	معدلات البطالة	X ₂₃
Rinofah et al 2022	عوامل الاقتصاد	معدل النمو	X ₂₄
Sakulpolphaisan & hensawang 2022	تاريخ القيد للبورصة	عمر المنشأة	X ₂₅
Hidayat & yuniati (2024), kebedee et al 2024, trisandi & syifa 2024	رأس مال الشركة	حجم المنشأة	X ₂₆

المصدر: من إعداد الباحثة

ولاختيار أهم العوامل الرئيسية المؤثرة في التعثر المالي تم إجراء اختبارات استكشافية، تركزت في التوزيع الطبيعي للبيانات واختبارات الترابط بين المتغيرات المستقلة وتحليل الترابط، وأخيراً استخدام مجموعة ENSEMBLE LEARNING لتحديد العوامل المؤثرة في التعثر المالي، وسوف نستعرض في الفصل التالي من الدراسة أهم نتائج هذه الاختبارات، وفيما يلي شرح موجز لهذه الخطوات.

- الاختبارات تقييم أداء نماذج الذكاء الاصطناعي في التنبؤ بالتعثر المالي

يتضمن هذا الجزء من الرسالة استعراض الاختبارات التي أجريت.

○ التوزيع الطبيعي للبيانات Normalization: هذه الخطوة ضرورية للخوارزميات الحساسة لحجم البيانات، مثل الانحدار اللوجستي، و SVMs، والشبكات العصبية. يضبط التوزيع الطبيعي حجم البيانات بحيث لا تهيمن

الميزات ذات القيم الكبيرة على النموذج. الطريقة الشائعة هي: Min-Max scaling

$$x^i = \frac{x - \min(x)}{\max(x) - \min(x)}$$

التعامل مع القيم المفقودة: يمكن للبيانات المفقودة أن تحرف التحليل أو تحيزه إذا لم يتم التعامل معه بشكل صحيح. يمكن تطبيق العديد من التقنيات، مثل الإسناد وهو استبدال القيم المفقودة بالتقديرات الإحصائية، مثل المتوسط أو الطرق القائمة على النماذج، حيث يتم استخدام الأنماط في البيانات لتقدير القيم المفقودة.

ترميز المتغيرات الفئوية: تتطلب العديد من نماذج التعلم الآلي مدخلات عددية، مما يستلزم تحويل المتغيرات الفئوية إلى تنسيق عددي. إحدى التقنيات الشائعة هي الترميز الساخن الواحد one-hot encoding، والذي يخلق عمودًا ثنائيًا لكل مستوى فئة.

التوازن الطبقي مع SMOTE Synthetic Minority Oversampling Technique: من الاعتبارات المهمة خلال مرحلة ما قبل معالجة البيانات، خاصة في سياق التنبؤ بالتعثر المالي، توازن الفئات، وعادة ما تكون شركات المتعثرة قليلة مقارنة بالشركات غير المتعثرة؛ مما يؤدي إلى مشكلة اختلال التوازن الطبقي. ويمكن لمجموعة البيانات غير المتوازنة أن تحيز النموذج التنبؤي تجاه فئة الأغلبية، وتضعف قدرتها على اكتشاف طبقة الأقلية، والتي غالبًا ما تكون ذات أهمية أكبر (He & Garcia, 2009).

لمعالجة هذه المشكلة، سيتم استخدام تقنية أخذ العينات المفرطة للأقلية الاصطناعية Synthetic Minority Oversampling Technique (SMOTE) هو نهج أخذ عينات مفرطة يولد عينات اصطناعية من فئة الأقلية (Chawla وآخرون، 2002). يتم ذلك عن طريق اختيار نقطة عشوائية من فئة الأقلية وحساب أقرب الجيران k لهذه النقطة. تتم إضافة النقاط الاصطناعية بين النقطة المختارة وجيرانها.

يمكن تلخيص خوارزمية SMOTE في الخطوات التالية:

- لكل عينة في فئة الأقلية، احسب المسافة الإقليدية، وابحث عن أقرب جيرانها في مساحة الميزة.
- اضرب الفرق بين متجه الميزة للعينة قيد النظر، وأقرب جار لها برقم عشوائي بين 0 و1.
- أضف هذه النقطة الجديدة إلى مساحة الميزة (Chawla وآخرون، 2002).

$$X_{new} = X_i + \lambda \times (X_{z_i} - X_i)$$

X_i : يمثل عينة فئة الأقلية.

X_{z_i} : هو واحد من أقرب الجيران لـ x_i ، is one of the k-nearest neighbors of x_i .

λ = متغير عشوائي بين (0، 1).

تؤدي هذه الطريقة إلى منطقة قرار أكثر عمومية لطبقة الأقلية، حيث تجبر الخوارزمية المصنف على إنشاء حدود قرار أكبر وربما أكثر تعقيداً.

بعد تطبيق SMOTE، ستحتوي مجموعة البيانات على عدد متساوٍ من الحالات لكلا الفئتين، مما يسمح للخوارزميات بأداء أفضل أثناء اجراءات التدريب.

من المهم تطبيق SMOTE فقط على بيانات التدريب وليس على بيانات التحقق أو الاختبار؛ لتجنب تسرب البيانات والتأكد من أن مقاييس التقييم تعكس أداء النموذج على بيانات غير مرئية حقاً. (Brownlee, 2020)

- وصف البيانات وأنواعها (أنواع البيانات): في البداية سيتم إجراء تحليل وصفي للتأكد من المقاييس الإحصائية الأساسية، مثل: المتوسط والوسيط والانحراف المعياري والرباعي والنطاقات لكل متغير في مجموعة البيانات. وسيتم تحديد أنواع البيانات لكل خاصية لضمان إلقائها بشكل مناسب، لمزيد من التحليل سيتم فحص المتغيرات الرقمية بحثاً عن بيانات مستمرة أو منفصلة، بينما سيتم فحص المتغيرات الفئوية بحثاً عن البيانات الاسمية أو الترتيبية. تضمن هذه الخطوة استخدام أنواع البيانات الصحيحة في التحليلات اللاحقة.

- تحليل القيم المتطرفة مع IQR: يمكن أن يكون للقيم المتطرفة تأثير غير متناسب على التحليلات الإحصائية، ويمكن أن تؤدي إلى نتائج منحرفة. سيتم استخدام طريقة IQR لاكتشاف القيم المتطرفة. وهذا ينطوي على حساب معدل الجودة على أنه الفرق بين 25 و75% من توزيع البيانات. سيتم تعريف القيم المتطرفة على أنها ملاحظات أقل من الربع الأول $IQR * 1.5$ أو أعلى من الربع الثالث $IQR * 1.5$

تحديد السمات المميزة (العوامل المؤثرة على التنبؤ بالتعثر المالي $z1$) باستخدام التعلم الجماعي ENSEMBLE LEARNING والأساليب الإحصائية.

تم تدريب نماذج ENSEMBLE LEARNING لتحديد أهمية الميزات المختلفة في التنبؤ بالتعثر المالي، تم استخدام نماذج ENSEMBLE LEARNING، وتتضمن هذه المنهجية تدريب نماذج التعلم الجماعي لتوفير تقييم شامل لأهمية عامل المتغير، وتتضمن نماذج RF, GRADIENT BOOSTING, EXTREEME GRADIENT BOOSTING, ATBOOSTING. ADABOOSTING. ويوفر كل نموذج بطبيعته درجة أهمية الميزة والتي تشير إلى الأهمية النسبية لكل ميزة في عمل تنبؤات دقيقة.

تبدأ العملية بتدريب كل نموذج على مجموعة البيانات واستخراج درجات العوامل الخاصة بها، ويتم بعد ذلك استخدام هذه الدرجات لتصنيف الميزات لكل نموذج على حدة.

- تحليل الارتباط: سيتم إجراء تحليل الارتباط لفحص العلاقات بين المتغيرات، ويتضمن ذلك حساب معامل ارتباط بيرسون للمتغيرات المستمرة والمقاييس المناسبة للمتغيرات الفئوية، مثل Cramer's V. سيتم تصور مصفوفة الارتباط باستخدام خريطة حرارة لتحديد المتغيرات المرتبطة ارتباطاً وثيقاً بسهولة، والتي قد تشير إلى مشاكل التكرار والتواصلية التي يمكن أن تؤثر في أداء بعض خوارزميات التعلم الآلي.

○ وظيفة التوزيع التراكمي التجريبية Empirical Cumulative Distribution Function ECDF

وستستخدم مخططات دالة التوزيع التراكمي التجريبية كل متغير لفهم توزيع البيانات وانتشارها على عكس الرسوم البيانية، وتوفر ECFDs صورة كاملة لتوزيع القيم، وتسهل ملاحظة نسبة الملاحظات التي تقل عن قيمة معينة،

ويمكن أن يكون هذا مفيدًا بشكل خاص لفهم انحراف التوزيع وذيولها، والتي تُعد حاسمة عند النظر في تأثير القيم المتطرفة في التنبؤ بالتعثر المالي.

وسيتم استخدام الأفكار المكتسبة من EDA لإرشاد خطوات المعالجة المسبقة واختيار النماذج في المراحل اللاحقة من الدراسة، وسيتم توثيق نتائج EDA بدقة لتوفير الشفافية والفهم الشامل لخصائص مجموعة البيانات قبل الانتقال إلى تحليلات أكثر تعقيدًا. وتضع هذه المرحلة الاستكشافية الأساس للنمذجة القوية من خلال ضمان تلبية الافتراضات الكامنة وراء مختلف نماذج التعلم الإحصائي والآلي، ومن خلال تسليط الضوء على مجالات التركيز المحتملة للنمذجة التنبؤية، بالإضافة إلى ذلك ستساعد EDA في تحديد أي أنماط أو هياكل متأصلة في البيانات التي يمكن أن تفيد في تطوير الفرضيات لإجراء اختبارات إحصائية أكثر تفصيلاً.

وعلى سبيل المثال، إذا تبين أن بعض النسب المالية هي مؤشرات قوية على التعثر المالي في مرحلة EDA، فقد تتطلب تحليلاً أكثر تعمقاً في مرحلة النمذجة، وبالمثل إذا كانت بعض عوامل الحوكمة مثل تكوين مجلس الإدارة أو جودة المراجع الخارجي مرتبطة ارتباطاً وثيقاً بالنتائج المالية، فقد تشكل هذه العوامل أساساً لتوصيات محددة لإدارة الشركات.

علاوة على ذلك، ستساعد EDA في ضمان توازن مجموعة البيانات وتمثيلها للعينة في سياق التنبؤ بالتعثر المالي، وهذا مهم بشكل خاص لأن الشركات المتعثرة عادة ما تكون ممثلة تمثيلاً ناقصاً في العينة، ويمكن النظر في تقنيات مثل SMOTE المذكورة سابقاً بعد EDA إذا تم اكتشاف اختلال كبير في الطبقة.

ولن يؤدي النهج الشامل تجاه EDA إلى تحسين موثوقية النمذجة التنبؤية فحسب، بل سيساهم أيضاً في شفافية البحث وقابليته للتكرار، وهما أمران مهمان للصلاحيات العلمية والفائدة العملية لنتائج الدراسة.

(3-6) اختيار نماذج الذكاء الاصطناعي

استخدمت الدراسة نماذج Ensemble learning التالية:

- Extreme Gradient Boosting –XGBOOST
- Adapboost
- Cat boost
- Gradient boosting
- Cart
- Staking

خوارزميات التجميع clustering algorithm

- k- means
- Agglomerative
- DBSCAN
- Gaussian Mixed Models (GMM)

- مقاييس الإحصاء التقليدية لتحقيق السؤال البحثي الثاني: تحليل التمييزي الخطي (LDA) LINEAR (DISCRININANT ANALYSIS)

(4-6) الاختبارات المستخدمة في تقييم النماذج المختلفة

- الدقة - F- Score
- الاستدعاء - المنطقة الواقعة تحت الخط ROC -AUC
- الضبط أو (القيمة التنبؤية الإيجابية) - مصفوفة الارتباك: CONFUSION MATRIX

(7) نتائج اختبارات الدراسة

- التحليل المسبق للبيانات DATA PRE- PROCESSING

تتناول الدراسة في هذا الجزء اختبارات المسبقة للبيانات، مثل اختبارات الإحصاء الوصفي والقيم المتطرفة واختبارات التوزيع الطبيعي وتحليل الارتباط، وذلك على النحو الموضح أدناه.

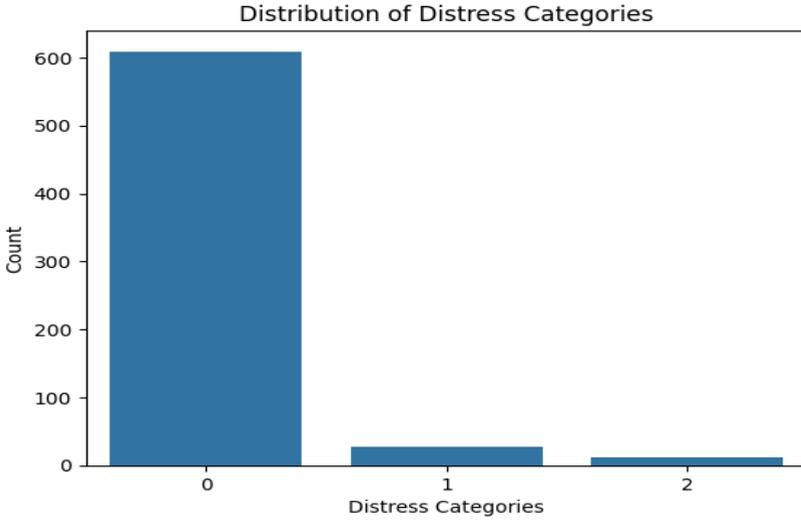
(1-7) المتغير التابع (تصنيف الشركات) بناء على نموذج EM-ZSCORE

تظهر متغير التابع -وهو محور تحليلنا- توزيعاً للفئات (تصنيف الشركات محل الدراسة إلى متعثرة وغير متعثرة وشركات في المنطقة الرمادية كما في الشكل التالي)، حيث يعبر رقم (0) أو صفر وهو تصنيف الشركات غير متعثرة، (1) شركات متعثرة، و(2) (في المنطقة الرمادية).

ومن الملاحظ أن أغلب الشركات محل الدراسة تقع في منطقة عدم التعثر (0) وهي الفئة الغالبة. ويشير التوزيع إلى خلل كبير في التوازن، لا سيما وأن فئة "عدم التعثر" تفوق بشكل كبير الفئتين الأخريين. لمعالجة هذا الخلل الطبقي وتعزيز القدرة التنبؤية لنماذجنا، وخاصة في التعلم من فئات الأقليات ("التعثر" و"المنطقة الرمادية"). تم تطبيق تقنية الإفراط في أخذ العينات للأقليات الاصطناعية (SMOTE) على مجموعة التدريب، ويساعد SMOTE في إنشاء مجموعة بيانات متوازنة عن طريق إنشاء عينات تركيبية لفئات الأقليات، وبالتالي تزويد النماذج ببيانات أكثر تمثيلاً أثناء التدريب.

من المهم ملاحظة أنه تم تطبيق SMOTE فقط على مجموعة بيانات التدريب لتجنب تسرب البيانات. تعكس الإحصائيات الوصفية وتحليل البيانات الاستكشافية (EDA) أن مجموعة البيانات الأصلية غير المتوازنة، حيث لم تُجر الموازنة إلا في وقت لاحق خلال مرحلة التدريب النموذجي.

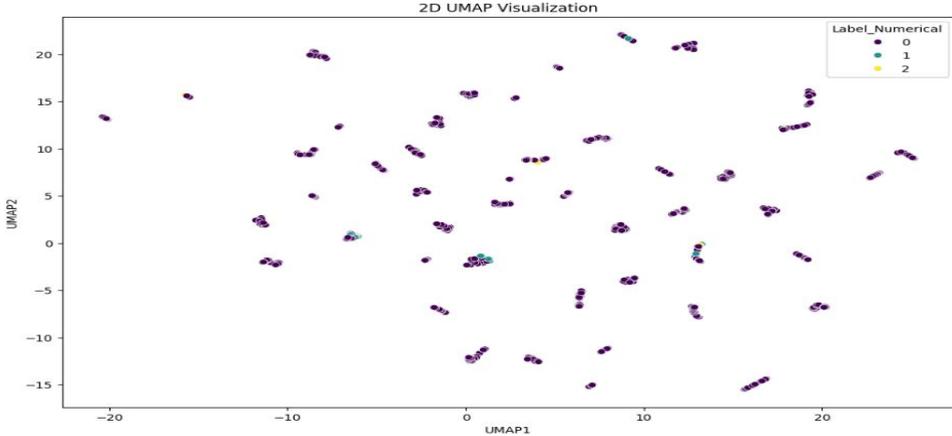
من خلال معالجة اختلال التوازن الطبقي من خلال SMOTE، من المتوقع أن تتحسن قوة النماذج التنبؤية ودقتها، مما يضمن تعميمًا وأداء أفضل عبر جميع فئات الضائقة المالية.



شكل 3: تصنيف الشركات محل الدراسة إلى متعثرة وغير متعثرة وشركات في المنطقة الرمادية المصدر: من إعداد الباحثة

(2-7) نتائج اختبار التوزيع الطبيعي

استخدمت الدراسة UMAP لتصوير مجموعة البيانات عالية الأبعاد في بعدين، وخلافاً للتوقعات لم يكشف مخطط UMAP عن مجموعات متميزة. تم توزيع نقاط البيانات دون أنماط واضحة للفصل بين فئات التعثر وعدم التعثر والمنطقة الرمادية؛ مما يشير إلى بنية بيانات معقدة ومتشابكة، وذلك كما في الشكل التالي:



شكل 4: توزيع نقاط البيانات دون أنماط واضحة للفصل بين فئات التعثر وعدم التعثر والمنطقة الرمادية المصدر: من إعداد الباحثة

ويعني الافتقار إلى مجموعات متميزة أن التعثر المالي لا يمكن فصله بسهولة استناداً إلى الخصائص المحددة وحدها؛ مما يسلط الضوء على التحديات التي تواجه التمييز بين الشركات المتعثرة والشركات غير المتعثرة والشركات في

المنطقة الرمادية استناداً إلى الخصائص المحددة وحدها، ومما يسلط الضوء أيضاً على التحديات التي تواجه تصنيف الشركات المتعثرة وغير متعثرة استناداً إلى عوامل المؤشرات المالية والحوكمة والاقتصادية المتاحة. وتشير المجموعات المختلطة الملاحظة إلى أن العلاقة بين المحددات والتعثر المالي غير واضحة، وأن النماذج التنبؤية قد تحتاج إلى مراعاة التفاعلات المعقدة بين المتغيرات. ويشير أيضاً إلى عدم إمكانية الفصل الخطي؛ ومن ثمّ قد تكون النماذج غير الخطية والأكثر تطوراً ضرورية لالتقاط الفروق الدقيقة. وتؤكد هذه الرؤية المستمدة من تحليل UMAP الحاجة إلى تقنيات النمذجة المتقدمة التي يمكنها مع هذا التعقيد، وتركيز جهود النمذجة اللاتحقة على الاستفادة من الخوارزميات التعلم الآلي القادرة على اكتشاف الأنماط الدقيقة في البيانات.

- التحليل الوصفي للبيانات (المتغير المستقل)

أظهرت نتيجة التحليل الإحصائي الذي تضمن المتوسط الحسابي والانحراف المعياري والتشتت، تعرض نسب السيولة والملاءة المالية لنطاق واسع من القيم؛ مما يشير إلى درجات متفاوتة من الاستقرار المالي. وتشير بعض النسب المالية ذات المتوسطات المنخفضة إلى تحديات مالية ضمن مجموعة البيانات. وعلى الرغم من أن مؤشرات الحوكمة تغطي قدرًا أقل من التقلب إلا أنها ضرورية لفهم تأثير ممارسات الشركة في الاستقرار المالي ويتم تمثيل عوامل الاقتصاد الكلي بشكل ثابت عبر مجموعة البيانات؛ مما يسلط الضوء على تأثير البيئة الاقتصادية الأوسع في أداء الشركة. ويساعد النطاق الربيعي في تحديد القيم المتطرفة ومعالجتها، مما يضمن قوة النماذج التنبؤية.

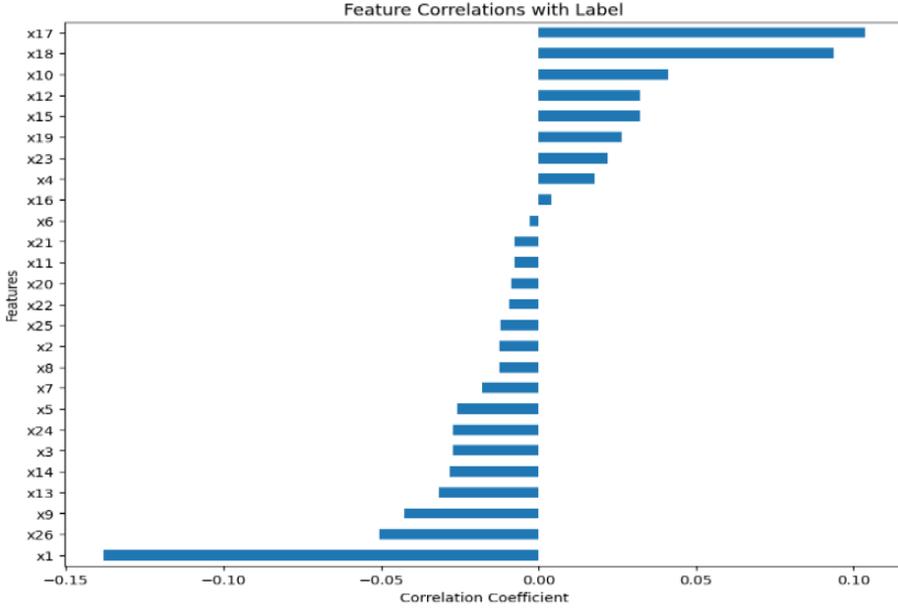
ويوضح ملحق رقم (2) الإحصاء الوصفي، مثل: المتوسط الحسابي والانحراف المعياري.

(3-7) نتيجة الترتيب النسبي للبيانات باستخدام نماذج التعلم الجماعي ENSEMBLE LEARNING

ما يلي:

- قد ظهر عامل عدد مرات اجتماع لجان المراجعة من العوامل الأكثر تأثيراً في التعثر المالي؛ مما يشير إلى أن عدد مرات لجان المراجعة يعد مؤشراً قوياً على عدم تعثر الشركات.
- بالنسبة للملكية أعضاء مجلس الإدارة والمراجع الخارجي (مكاتب كبرى أم لا) والتنوع بين الجنسين مهمة للغاية؛ مما يشير إلى أن الحوكمة تؤدي دوراً حاسماً في الاستقرار المالي. وبالمثل يؤدي سعر الصرف ضمن المؤشرات الاقتصادية دوراً هاماً في تحديد التعثر المالي للشركات، أما عوامل التضخم والنسب المالية (إجمالي الالتزامات المتداولة/إجمالي الأصول المتداولة).
- تؤكد هذه العوامل تأثير ظروف الاقتصاد الكلي والسيولة في التعثر المالي وصافي التدفقات النقدية من العمليات التشغيلية/ إجمالي الالتزامات، وإجمالي الالتزامات/ حقوق الملكية، حيث إدارة التدفقات النقدية ونسب الرفع المالي حاسمة أيضاً في تقييم مخاطر تعرض الشركة للتعثر المالي.
- كما ساهمت عوامل أخرى مثل النسب المالية (صافي التدفقات النقدية من العمليات التشغيلية / إجمالي الالتزامات المتداولة) واجتماعات مجلس الإدارة والنمو الاقتصادي وحجم الشركة في النموذج مما يشير إلى وجود مزيج من عوامل السيولة والحوكمة والاقتصاد الكلي وخصائص الشركة ذات صلة بالتنبؤ التعثر المالي.

وتؤكد هذه النتائج الطبيعة متعددة الأوجه للتعثر المالي، حيث تتفاعل عوامل الحوكمة والسيولة والربحية وعوامل الاقتصاد الكلي في تحديد الاستقرار المالي للشركة، وتؤثر قدرة نماذج التعلم الجماعي Ensemble Learning في تحديد أهمية كل ميزة وإرشادات قيمة لتركيز الجهود التحليلية على العوامل الأكثر تنبؤًا.



شكل 5: نتيجة الترتيب النسبي للبيانات باستخدام نماذج التعلم الجماعي ENSEMBLE LEARNING

تقييم أداء النماذج المختارة على z1 التنبؤية والعوامل المؤثرة في التعثر المالي (من الخطوة السابقة) والتدريب على القيمة التنبؤية المتوازنة وغير المتوازنة لإيجاد الفروق الإحصائية بين نماذج الذكاء الاصطناعي المختارة نماذج الذكاء الاصطناعي غير الخاضع للإشراف (Clustering)

جدول 3: نتائج اختبارات Clustering

Model	الدقة – Accuracy	القيمة الإيجابية التنبؤية – precision	الاستدعاء – recall	F1 Score	ROC AUC
KMeans	0.938776	0.881299	0.938776	0.90913	0.5
Agglomerative Clustering	0.938776	0.881299	0.938776	0.90913	0.5
DBSCAN	0.938776	0.881299	0.938776	0.90913	0.5
GaussianMixture	0.938776	0.881299	0.938776	0.90913	0.5

المصدر: من إعداد الباحثة.

من الجدول السابق يمكن القول: KMeans حقق النموذج دقة بلغت 93.8776؛ مما يوحي ظاهريًا بمستوى عالٍ من التنبؤ من التنبؤات الصحيحة، ومع ذلك يشير الفحص الأعمق من خلال القيمة التنبؤية الإيجابية (الضبط) والاستدعاء و F1 Score و ROC AUC، والتي سجلت جميعها عند حوالي 0.88 إلى 0.94 إلى أن أداءه جيدًا في التنبؤ

بفئة الأغلبية، ولكنه فشل في تحديد التعثر المالي بدقة، وتكشف درجة ROC AUC البالغة 0.50 أن النموذج لم يتمكن من التمييز بشكل هادف بين الفئات، مما يشير إلى أن الأداء يعادل الصدفة العشوائية.

ومن الجدول السابق يتضح لنا أن كل من GaussianMixture وDBSCAN وAgglomerativeClustering على غرار 93.886 KMeans من حيث الدقة، و0.88 درجة التنبؤية الإيجابية وF1 Score وROC AUC، فإن الاتساق في أداء النماذج المختلفة وهي عدم قدرة مجموعة CLUSTERING على التنبؤ بالتعثر المالي، وذلك في حالة عدم التوازن للبيانات.

(1-3-7) النماذج الذكاء الاصطناعي الخاضع للإشراف Ensemble learning فتم تدريبه على

مجموعة البيانات غير المتوازنة والمتوازنة كما في الجدول التالية

تسعرض الدراسة فيما يلي نتائج اختبار Ensemble learning على بيانات غير متوازنة، وذلك كما في الجدول التالي:

جدول 4: نتائج اختبار Ensemble learning على بيانات غير متوازنة

Model	الدقة = accuracy	القيمة التنبؤية الإيجابية (الضبط) precision	الاستدعاء recall	F1 Score	ROC AUC
RandomForest	0.969388	0.949946	0.969388	0.958700	0.750000
AdaBoost	0.928571	0.971839	0.928571	0.947004	0.885417
GradientBoosting	0.969388	0.949946	0.969388	0.958700	0.750000
XGBoost	0.979592	0.980026	0.979592	0.977272	0.833333
CatBoost	0.989796	0.989906	0.989796	0.989095	0.916667
CART	0.969388	0.949946	0.969388	0.958700	0.750000
StackingClassifier	0.969388	0.949946	0.969388	0.958700	0.750000

المصدر: تدريب مجموعة ensemble learning على البيانات غير المتوازنة، من إعداد الباحثة.

جدول 5: نتائج تدريب نماذج التعلم الجماعي على البيانات المتوازنة

النموذج model	الدقة accuracy	الضبط (القيمة التنبؤية الإيجابية) precision	الاستدعاء recall	F1 Score	ROC AUC
RandomForest Balanced	0.989796	0.989906	0.989796	0.989095	0.916667
AdaBoost Balanced	0.979592	0.982993	0.979592	0.979883	0.911458
GradientBoosting Balanced	0.979592	0.979592	0.979592	0.979592	0.911348
XGBoost Balanced	0.969388	0.972677	0.969388	0.970325	0.906139
CatBoost Balanced	0.989796	0.989906	0.989796	0.989095	0.916667
CART Balanced	0.959184	0.965874	0.959184	0.962161	0.900931
StackingClassifier Balanced	0.989796	0.989906	0.989796	0.989095	0.916667

ومن الجدولين يمكن ملاحظة الآتي:

- حقق RandomForest نسبة دقة 0.969388 على البيانات غير المتوازنة و0.989796 على بيانات متوازنة، وضبط قبل التوازن وبعد التوازن (0.9499466، 0.9899)، أما الاستدعاء (0.96، 0.986) و (F- Score) 0.95700، 0.985، أما (ROC-AUC) فبلغت 0.75، 0.915، مما يشير إلى الموازنة بين الدقة والضبط والاستدعاء على قدرته في تصنيف حالات التعثر المالي.
- أما AdaBoost البالغ دقته 92.8571، 0.979 ودرجة ضبط 97.18، 0.982 ومعدل استدعاء بنسبة 92.85، و0.979، إلى جانب بلغت F1 Score 94.7 و0.978، وأخيراً ROC AUC بلغ 0.885 و0.911348 يدل على دقة هذا النموذج وحساسيته في التنبؤ بالتعثر المالي.
- كما حافظت Catboost على دقة 0.989796، 0.989796 وقيمة تنبؤية إيجابية ومعدل استدعاء و F-Score و ROC-AUC على البيانات المتوازنة وغير المتوازنة، وبدل ذلك على قدرته على التعامل بكفاءة في حالات التنبؤ بالتعثر المالي وتصنيفها في جميع الحالات.
- أما XGBoost تتميز بأعلى دقة تبلغ 97.98%، وضبط 98.0026، ومعدل استدعاء شبه مثالي 97.95%؛ مما أدى إلى الحصول على F1 Score بنسبة 97.97%، و ROC AUC 0.83، ويشير هذا إلى قدرتها الفائقة على تحديد الشركات المتعثرة دون أي خطأ كبير في التصنيف.
- أما CatBoost حقق أعلى أداء عبر كافة المقاييس، مما يشير إلى قدرته الفائقة على التعامل مع مجموعة البيانات غير المتوازنة بفعالية. ولقد لوحظت دقة واستدعاء مثاليين للشركات في المنطقة الرمادية ودرجات شبه مثالية لفئة عدم التعثر؛ مما يشير إلى موثوقيتها وفعاليتها كنموذج تنبؤي للتعثر المالي، وكان متوسط الدقة المرجح والاستدعاء ودرجة 0.99؛ مما يدل على أدائها الاستثنائي.
- و CART حقق دقة قدرها 96.93%، مع ضبط 94.99%، واستدعاء 96.93%، و F1 Score البالغة 95.87%، و ROC AUC 0.75 قوتها كأداة تنبؤية لا سيما قدرتها على تصنيف الشركات المتعثرة بشكل صحيح.

- وحقق StackingClassifier أداءً قويًا من حيث الدقة والضبط والاستدعاء و96.93F1 Score، ودرجة ROC 0.75 AUC، ويستفيد هذا النموذج بشكل فعال من نقاط القوة في النماذج الفردية؛ مما يؤكد فعالية تقنيات المجموعة في مهام التنبؤ المعقدة.

- أظهر XGBoost أداءً فائقًا مع درجات مثالية تقريبًا لفئة (0) والفئة (1)، ودقة واستدعاء متتالين للفئة (2)، وتسلط الدقة العالية والاستدعاء لجميع الفئات الضوء على قوتها وقدرتها على تحديد المتعثرين دون خطأ كبير في التصنيف. وحقق XGBoost متوسط دقة مرجح 0.98، واستدعاء 0.98، ودرجة 0.98؛ مما يجعله واحدًا من النماذج الأفضل أداءً.

أما CART فأوضح الدقة العالية لفئة الأغلبية تشير إلى دقة استثنائية في التنبؤ بالتعثر المالي دون نتائج إيجابية كاذبة، ومع ذلك فإن سحب فئات الأقليات يكون مصدرًا قلقًا عند تحديد جميع الشركات المتعثرة. وعلى الرغم من ذلك أظهر CART أداءً عامًا قويًا بمتوسط دقة 0.95، واستدعاء 0.97، و0.96 F1 Score.

أما Adaboost فيقدم قدرة تنبؤية قوية ولا سيما في توازنه بين الدقة والاستدعاء لفئة الأغلبية، في حين أن الدقة بالنسبة لفئات الأقلية عالية، إلا أن الاستدعاء منخفض؛ مما يشير إلى أنها تفوت بعض حالات التعثر. ويعد هذا التوازن أمرًا حيويًا في السيناريوهات التي يحمل فيها كلا من النوعين من الأخطاء والإيجابيات الكاذبة والسلبيات الكاذبة؛ تكاليف كبيرة، وحقق Adaboost متوسط دقة 0.97، واستدعاء 0.93، و0.95 F1 Score.

وبدل ذلك على قوة نماذج ENSEMBLE LEARNING في حالات التوازن وعدم التوازن، حيث أظهرت النماذج أداءً عاليًا مثل XGBoost Balanced وCART Balanced واستقرارًا ملحوظًا في مقاييسها. وأظهرت اختلافات ضئيلة بين مجموعات البيانات المتوازنة وغير المتوازنة، وتؤكد هذه على القوة على قدراتها المتأصلة على إدارة اختلال التوازن الطبقي بكفاءة. كما أن الأداء العالي المتسق لنماذج المجموعة ENSEMBLE LEARNING في جميع الحالات أدى تغييرًا أمرًا هامًا، حيث أظهرت نماذج ENSEMBLE LEARNING أداءً عاليًا في مجموعة البيانات المتوازنة وغير المتوازنة، ويشير الاتساق عبر الدقة والضبط والاستدعاء وF1 core ومقاييس ROC AUC إلى موثوقية هذه النماذج وقابليتها للتعميم في سيناريوهات التنبؤ بالتعثر المالي.

وبناء على ما سبق يمكن القول بتفوق نماذج Ensemble Learning وخاصة نموذج Catboost الذي لديه القدرة الفائقة في التنبؤ بالتعثر المالي في كافة الأحوال على نماذج Clustering Algorithm.

- نتائج اختبار النموذج الإحصائي لتحليل التمييزي الخطي

ولتحقيق الهدف الثاني من الدراسة والإجابة على السؤال البحثي تم تدريب تحليل التمييزي الخطي على البيانات المتوازنة، حيث أوضحت الدراسة أن دقة تحليل التمييزي الخطي بلغت 0.591837، والقيمة الإيجابية 0.945، والاستدعاء 0.5912، و IF- Score 0.698573، و AUC- ROC 0.789340. كما أشارت الدراسة إلى أن النموذج الإحصائي لتحليل التمييزي الخطي أوضح الأداء الجيد للفئة الأغلبية (الشركات غير المتعثرة)، ومن ناحية أخرى فإن انخفاض ROC AUC إلى الصفر يشير إلى تحديات كبيرة في التمييز بين الشركات المتعثرة وغير المتعثرة. كما أشارت الدراسة إلى أن هذا النموذج قد لا يكون مناسبًا تمامًا لمهمة التصنيف للبيانات غير المتوازنة، حيث بلغ متوسط دقة مرجح 0.88، واستدعاء 0.93، ودرجة F1 0.90.

(8) النتائج والتوصيات

(1-8) مناقشة النتائج

استهدفت الدراسة تقييم أداء نماذج التعلم الجماعي وخوارزميات التجميع على عدد 44 شركة تعمل في قطاعات مواد البناء والتشييد والمقاولات خلال الفترة من 2007 – 2022، ولتحقيق هدف الدراسة اتبعت عددًا من الخطوات، وهي: إيجاد المتغير المستقل وهو التعثر المالي، واستخدمت الدراسة نموذج EM- Z-SCORE؛ وبناء عليه استخلصت الدراسة أن معظم الشركات محل الدراسة غير متعثرة، وذلك كما في ملحق الدراسة رقم (1). وتحديد تأثير عوامل الحوكمة ومعلومات الاقتصاد الكلي والمؤشرات المالية وخصائص الشركات، وذلك باستخدام تحليل الارتباط وتحليل الأهمية للعناصر باستخدام بعض نماذج التعلم الجماعي، حيث توصلت الدراسة بعض الخصائص بالنسبة للشركات، وأظهرت الدراسة بأن حجم الشركات يرتبط بعلاقة عكسية بالتعثر المالي، واتفقت نتائج هذه الدراسة مع Wang & Guedes, (2024)، غير أن نتائج هذه الدراسة اختلفت مع دراسة Trisandi and Syifa (2024).

أما بالنسبة لعوامل الاقتصاد الكلي، استخلصت الدراسة أن سعر التضخم يؤثر في التعثر المالي للشركات، واتفقت نتائج هذه الدراسة مع Kebede et al. (2024)، في حين اختلفت نتائج هذه الدراسة مع Evi & Indra (2022). استخلصت الدراسة أن سعر الصرف يؤثر في التعثر المالي، واتفقت نتائج هذه الدراسة مع دراسة Zizi et al. (2022)، على الرغم من المنهجية المستخدمة في تحليل البيانات، حيث اعتمدت الأخيرة على أسلوب تحليل الانحدار الخطي، واختلفت نتائج هذه الدراسة مع Rinofah et al. (2022).

كما توصلت إلى أن معدل النمو الاقتصادي يؤثر في التعثر المالي للشركات، واتفقت نتائج هذه الدراسة مع دراسة Rinofah et al. (2020)، واختلفت نتائج هذه الدراسة مع Ece & Guven (2020).

أما بالنسبة لعوامل الحوكمة، فقد استخلصت الدراسة أن لجان المراجعة تؤثر طرديًا مع التعثر المالي للشركات، واتفقت نتيجة هذه الدراسة مع دراسة Sakulpolphaisan & Hensawang (2022).

استخلصت الدراسة أن التنوع في مجلس الإدارة يؤثر في التعثر المالي للشركات، واتفقت هذه الدراسة مع دراسة Abugri (2022)، وذلك على عكس دراسة (Atosh & Iraya 2018).

كما استخلصت الدراسة وجود علاقة طردية بين عدد مرات انعقاد مجلس الإدارة والتعثر المالي، وذلك على خلاف مع دراسة (Balagobei and Keerthana, 2023).

بالنسبة للمراجع الخارجي، أظهرت الدراسة أن جودة المراجع الخارجي تعد أحد محددات التعثر المالي واتفقت الدراسة مع دراسة (Nour et al., 2023; Werner et al., 2018).

بالنسبة للمؤشرات المالية فهي النسب الخاصة بالتدفقات النقدية (نسبة التدفقات النقدية من العمليات التشغيلية/إجمالي الالتزامات، واتفقت هذه الدراسة مع (Hamid & Rohani, 2018).

تؤثر نسب الرفع المالي (إجمالي الالتزامات/إجمالي الأصول) في التعثر المالي، واتفقت هذه النتيجة مع Savery & Riswan (2024).

كما أسفرت الدراسة على تأثير جوهري بالنسبة رأس المال العامل/إجمالي الأصول في التعثر المالي للشركات، واتفقت هذه النتيجة مع دراسة (Siti et al., 2024).

أما بالنسبة لنسبة الخصوم المتدولة/الأصول المتدولة ترتبط بعلاقة طرية مع التعثر المالي للشركات، واتفقت هذه الدراسة مع دراسة (Mashudi et al. 2021).

اختبرت الدراسة نماذج التعلم الجماعي، وهي RF, XGBOOST, STACKING, CART- GREDIENT BOOST – CAT و DBSCAN و k- means. Agglomerative Clustering و BOOST – ADAPBOOST ، وخوارزميات التعلم وهي: Gaussian Mixture و DBSCAN، وتوصلت نتيجة الدراسة إلى عدم قدرة نماذج خوارزميات التعلم على التنبؤ بالتعثر المالي، واختلفت نتيجة هذه الدراسة مع دراس (Justin et al., 2020).

في حين أثبتت الدراسة دقة وضبط واستدعاء كافة أنواع نماذج التعلم الجماعي في التنبؤ بالتعثر المالي، واتفقت هذه الدراسة مع دراسات (Liang et al., 2020); Liu et al., 2022;

وللتحقق من مصداقية النتيجة validation أجرت الدراسة تدريب نماذج التعلم الجماعي ونموذج تحليل التمايز الخطي الإحصائي على مجموعة بيانات متوازنة؛ وبناء عليه استخلصت الدراسة تفوق كافة أنواع نموذج التعلم الجماعي، وخاصة CAT- BOOST الذي حافظ على توازنه ودقته ودرجة استدعاء مثالية، وجاءت هذه النتيجة متفقة مع دراسة (Chaves et al., 2023; Malakauskas et al., 2023)، وتفوقت كافة أنواع نموذج التعلم الجماعي على أسلوب تحليل التمايز الخطي، واتفقت هذه الدراسة مع دراسة (Wyrobeck & Krzytof, 2018)، وخالفت هذه الدراسة دراسة (Viswanathan et al., 2020).

وفي النهاية أظهرت نتائج الدراسة التفوق الملاحظ لنماذج التعلم الجماعي على خوارزميات التجميع وتحليل التمايز، ويُعد هذا التفوق مؤشراً على فعالية التقنيات الحديثة في تحسين دقة التنبؤ والاستدعاء في جميع المجالات وخاصة مجال التنبؤ بالتعثر المالي.

وظهر نموذج cat – boost من أبرز نماذج التعلم الجماعي وحافظ على مستوى عالٍ من الدقة والاستدعاء وتفوق على باقي النماذج الأخرى يعود ذلك على عدد من العوامل، أبرزها قدرته على التعامل بكفاءة مع البيانات غير المتجانسة والمتباينة دون الحاجة إلى المعالجة المسبقة للبيانات، وهذا يتيح للنموذج التعلم بشكل أفضل من البيانات المعقدة والمتنوعة.

ومن ثم يمكن القول بأن استخدام نموذج CAT- BOOST عبر مختلف السيناريوهات، حيث يوفر أساساً قوية لمعالجة البيانات المعقدة والمتنوعة؛ مما يعزز قدرة الشركات على اتخاذ قرارات مستنيرة مبنية على تحليل شامل.

(2-8) التوصيات وأبحاث مستقبلية

(1-2-8) التوصيات

- توصي بتبني نماذج التعلم الجماعي كجزء أساسي من أدوات التحليل المالي في الشركات؛ فهو مثال قوي على فعالية هذه النماذج في تحسين دقة التنبؤ , Cat boost.
- توصي بتوفير برامج تدريبية متخصصة لموظفي التحليل المالي لتحسين مهاراتهم في استخدام التعلم الجماعي وخوارزميات التجميع، ويشمل ذلك على أدوات التعلم الآلي وتحليل البيانات المتقدمة.
- توصي بتعزيز دور لجان المراجعة ومجالس الإدارة في مراقبة الأداء المالي من خلال تطبيق نماذج التعلم الجماعي لتحليل البيانات المالية، واتخاذ القرارات المستنيرة بناء على نتائج التنبؤ بالتعثر المالي.
- توصي الدارسة بتحسين جودة البيانات المستخدمة في نماذج التعلم الجماعي من خلال تبني تقنيات المعالجة المسبقة، مثل: التنظيف والتصفية والتطبيع لضمان دقة النتائج.

(2-2-8) مقترحات للأبحاث المستقبلية

- إجراء دراسات إضافية تشمل مناطق جغرافية وصناعية مختلفة لفهم تأثير العوامل المحلية والقطاعية في دقة نماذج التنبؤ بالتعثر المالي باستخدام التعلم الجماعي.
- إجراء أبحاث تحليلية تدرس تأثير التغييرات الاقتصادية والزمنية على أداء نماذج التعلم الجماعي، مثل: تأثير الأزمات الاقتصادية والتقلبات السياسية.
- دمج البيانات غير المالية، مثل العوامل الاجتماعية والبيئية في نماذج التنبؤ للتوصل إلى نتائج أكثر شمولية ودقة في تحليل مخاطر التعثر المالي.
- إجراء دراسات لتقييم أداء نماذج التعلم الجماعي في ظل ظروف اقتصادية مختلفة، مثل: الأزمات المالية وفترات الركود والنمو الاقتصادي، لفهم كيفية تكيف النماذج مع التغييرات الاقتصادية.

المراجع

أولاً: المراجع باللغة العربية

- ابوالسعود، نهال، عبد العال، مدحت، زين الدين طلبية (2022). استخدام نموذج بروبت في التنبؤ بالتعثر المالي للشركات قطاع الاعمال العام مصر، *المجلة العلمية للاقتصاد والتجارة - جامعة عين شمس، كلية تجارة*، 875-892:1.
- احمد، نبيل ياسين، عبد الحليم، احمد حامد (2015). تطوير نموذج محاسبي للتنبؤ بالتعثر المالي للشركات - دراسة تطبيقية في بيئة الاعمال السعودية، *مجلة البحوث المحاسبية، جامعة طنطا، كلية تجارة، قسم المحاسبة*، 2، 417-495.
- بوجلخة، ابراهيم (2021). قياس الاستقرار المالي للبنوك الاسلامية والتقليدية في ماليزا خلال الفترة من 2008 حتى 2015، *مجلة المنهل الاقتصادي*، 4، (1)، 422-405.
- بوضياف، صفاء (2018). مساهمة مؤشرات تقييم الاداء المالي في تحديد عوامل الفشل المالي - دراسة تطبيقية على عينة مؤسسات قطاع الحليب ومشتقاته، *مجلة ابعاد الاقتصادية، جامعة امحمد بوقرة بومرداس، كلية العلوم الاقتصادية والتجارية وعلوم التيسير*، (8)، 122-109.
- الحسناوي، سالم صلال، يحيى نوفل (2023). اختبار التعثر المالي لشركات الاستثمار باستعمال التحليل التمييزي نموذج (sherro) دراسة تطبيقية في سوق العراق للاوراق المالية، *مجلة مركز دراسات الكوفة*، 1، (69)، <https://journal.uokufa.edu.iq/index.php/ksc/article/view/11926>
- خالد، زبدة (2021). التنبؤ بالفشل المالي باستخدام المؤشرات المالية، *دراسة تطبيقية على شركات قطاع الخدمات المدرجة في بورصة فلسطين مجلة الجامعة العربية الامريكية للبحوث*، 7، (1)، 4-67.
- رحماني، ربحانة مختار، مقدم، يمينية (2022) استخدام نموذج Zmijewski للتنبؤ بالإفلاس: دراسة تطبيقية على عينة من المؤسسات الانتاجية الصغيرة والمتوسطة خلال الفترة (2016-2020)، *المجلة الجزائرية للعلوم الاجتماعية* 10 (2) 289-306. <https://www.asjp.cerist.dz/en/article/209848>
- طالب، محمد الامير وليد، قلادة، نظيرة (2021). استخدام نموذجي Springate و Altman في التنبؤ بالتعثر المالي للمؤسسات الصناعية المدرجة في بورصة الجزائر، *مجلة الدراسات المالية والمحاسبية والادارية*، 8، (3)، 281-297.
- الطويل، ليلى، مهنا، بلال (2020). التنبؤ بالعسر المالي للشركة - مقارنة اداء النماذج المحاسبية والسوقية "ادلة من سوق الكويت ومسقط للاوراق المالية، *مجلة جامعة تشرين للبحوث والدراسات العلمية، سلسلة العلوم الاقتصادية*، 42، (2)، 69-92.
- عبد المنعم، ريم (2018). مدى ملائمة المعلومات المحاسبية التاريخية والمعلومات المحاسبية المعدلة بالتضخم في التنبؤ بالتعثر المالي للشركات، *مجلة الدراسات والبحوث، جامعة بنها*، 38، (4)، 105-176.

- عرفة، عمرو محمد، فانوس، نادر البير (2020). نموذج مقترح للتنبؤ بالفشل المالي للشركات المسجلة في البورصة المصرية، *المجلة العلمية للاقتصاد والتجارة*، جامعة عين شمس، كلية تجارة، 3، 231-256 .
- كموش، عبد المجيد (2020). اثر ممارسات حوكمة الشركات على التعثر المالي للشركات – دراسة حالة عينة من الشركات بولاية سطيف، *مجلة العلوم الاقتصادية والتيسير والعلوم التجارية*، 13(1)، 124-137 .
- النجار، سامح محمد، امين، بسيوني مروة (2022). اثر العلاقة بين خصائص مجلس الادارة وجودة مجلس الادارة وجودة الارباح على خطر التعثر المالي للشركات – ادلة عملية من بيئة الاعمال المصرية، *مجلة الاسكندرية للبحوث المحاسبية*، 6(3): 259-336 .
- الشوادفي، محمد غمري، شهوان، تامر محمد حسن، فاضل، ميسرة (2019). التنبؤ بالتعثر المالي للشركات المساهمة الصغيرة والمتوسطة المصرية باستخدام المؤشرات المالية وغير المالية والاقتصادية، *مجلة الدراسات والبحوث التجارية*، كلية تجارة، جامعة بنها، 39(4)، 309-333.
- عيد، أحمد عبد الوهاب أحمد (2015). استخدام الشبكات العصبية الاحتمالية في الدمج بين اليات الحوكمة والتنبؤ بالتعثر المالي في سوق راس المال المصري: دراسة نظرية تطبيقية، *مجلة الدراسات والبحوث التجارية*، كلية تجارة، جامعة بنها، 35(4)، 39-124.
- ادم، حسابو احمد حسابو (2016). مدى استخدام ادوات التحليل المالي في التنبؤ بالتعثر المالي المصرفي بالتطبيق على فروع البنك الزراعي قطاع ولاية النيل الابيض، *المجلة العلمية لجامعة الامام المهدي*، 7، 203-230.
- عبد الغنى، سميرة (2014). استخدام اساليب التعلم الالى لتطوير اداء المكتبات: دراسة استكشافية، *المجلة العلمية للمكتبات والوثائق والمعلومات*، كلية الاداب، جامعة القاهرة، 6(19)، 245-281.

ثانيا: المراجع باللغة الاجنبية

- Abdelghani, S., (2024). Using Automated Learning Methods to Develop Library Performance: An Exploratory Study, *Scientific Journal of Libraries, Documents and Information*, 6(19), 245-281. (in Arabic).
- Abdul Moneim, R. (2018). Suitability of Historical Accounting Information and Accounting Information Adjusted for Inflation in Corporate Financial Distress Forecast, *Journal of Studies and Research*, 38(4), 105-176. (in Arabic)
- AbuAl-Saud, N., Abdelal, M., Zinedine, T. (2022). "using the Probet Model to Predict the Financial Distress of Companies General Business Sector Egypt", *Scientific Journal of Economics and Commerce*, 1, 875-892. (in Arabic)
- Abugri, A. (2022). "Effect of Corporate Governance on Financial Distress, Evidence from Listed Firms at Ghana Stock Exchange, *International Journal of Multidisciplinary Research and Analysis*, 5(2), 319-327.
- Adam, H. (2016). The Extent to Which Financial Analysis Tools Are Used to Predict Banking Financial Distress by Applying to Branches of the Agricultural Bank of the White Nile State Sector, *the Scientific Journal of Imam Mahdi University*, 7, 203-230.
- Ahmad, N.Y. & Abdul Halim .A. H. (2015). Develop an Accounting Model for Forecasting Financial Faltering of Companies - Applied Study in Saudi Business Environment, *Journal of Accounting Research*, 2, 417-495. (in Arabic)
- Aker Yusuf, A. K. V. (2023). Using Machine Learning Methods in Financial Distress Prediction, Sample of Small and Medium Sized Enterprise in Turkey, *EGE Academic Review*, 23(2), 145-162.
- Alamis, E., & Chava S., A. (2023). Benchmarking Machine Learning Models to Predict Corporate Bankruptcy, *Journal of Credit Risk*, 19(2),77-110.
- Al-Hasnawi, S. & Yahya. N. (2023). Investment Companies Financial Distress Test Using Discriminatory Analysis Sherro Model, *Applied Study in Iraq's Stock Market Journal* 1(69). (in Arabic)
- Alifia, M. & Tahir, M. (2018). Predicting Financial Distress Companies in the Manufacturing and non-Manufacturing Sectors in Malaysia Using Macro-Economic Variable, *Management Sciences Letters*, 8, 593-604
- Al-Najjar, S. M. A. & Bassiouni, M. (2022). The Impact of the Relationship Between the Characteristics of the Board of Directors and the Quality of the Board of Directors and the Quality of Profits on the Risk of Financial

- Distress of Companies - Practical Evidence from the Egyptian Business Environment, *Alexandria Journal of Accounting Research*, 6(3),259-336, (in Arabic).
- Al-Shawadfi, M. G., Shahwan, T. H. & Fadhil, M. (2019). Predicting the Financial Distress of Egyptian SMEs Using Financial, Non-Financial and Economic Indicators, *Journal of Business Studies and Research*, 39(4), 309-333, (in Arabic).
- Altman, E. (2005). An Emerging Market Credit Scoring System for Corporate Bonds, *Emerging Market Review* 6, 311-323
- Aly, S., Alfonse, M., salem, M. & Abdel- B. (2022). Intelligent Model for Enhancing the Bankruptcy Prediction with Imbalanced Data using Oversampling and Cat boost, *International Journal of Intelligent Computing and Information Science*, 22(3), 92-108.
- Andika, L. (2022). Effect of Leverage, Profitability and Firm Size on Financial Distress, Empirical Study on Transportation Companies Listed on the Indonesia Stock Exchange (2016-2020) , *Budapest International Research and Critics Institute Journal*, 5(3), 25237-25247
- Anong, C. & Kamsani, R. (2023). Monitoring Corporate Health in Singapore using Machine Learning Modeling Approach, *Economic Survey of Singapore*, 42-50
- Appah, E., Gods, P. & Emmanuel (2024). Firm Attribute and Corporate Financial Distress of Listed Manufacturing Firm at the Nigeria Exchange Group, *British Journal of Multidisciplinary and Advanced Studies, Bsinness and Management* ,5(1), 16-40
- Arfa. A. M. & Vanos, N. A. (2020). Proposed Model for Predicting Financial Failure for Companies Listed on the Egyptian Stock Exchange, *Scientific Journal of Economics and Commerce*, 3, 231-256
- Arian, H., Seyfi, S. & Sharifi, A. (2020). Forecasting Probability of Default for Consumer Loan Management with Gaussian Mixture Models, www.researchgate.net/publication/345970967.
- Atosh, M.A. & Iraya, C. (2018). Effect of Corporate Governance Practices on Financial Distress Among Listed Firms at Nairobi Exchange Securities, *Journal of International , Business , Innovation and Strategic Management*, 1(6), 70-90
- Balagobei, s., Keerthana, g. (2023). Corporate Governance Practices and Financial Distress, Empirical Evidence from Listed Companies in Sri- Lanka, *Kelaniya Journal of Management*, 12(1), 76-89.

- Balasubrsmanian, S., & Radhakrishna, N. (2019). Modeling Corporate Financial Distress Using Financial and Non – Financial Variable, *International Journal of Law and Management*, 61, 457-484
- Bao, W. Lian, J.N. & Yuem, K. (2019). Intergration of Unsupervised and Supervised Machine Learning Algorithm for Credit Assessment, *Expert System With Application*, 128, 301-315.
- Bard, M. (2017). Financial Ratios and Prediction on Corporate Bankruptcy in the Atlantic Salmon, *Aquaculture Economics & Management*, 27(3), 441-467
- Begum, S. (2022). A Detailed Study for Bankruptcy Prediction by Machine Learning, *Intelligent Sustainable Systems*, 201-213.
- Benabdella, A.C. Benghabrit, A. & Bouhaddou. I (2019). A Survey of Clustering Algorithms for An Industrial Context, *Procedia, Computer Science*, 148, 291-302.
- Binh, P.V. N., Trung, D.T.& Duc .V. H. (2018). *Financial Distress and Bankruptcy Prediction, an Appropriate Model for Listed Frm in Vietman*, *Economic System*, 42: 616-624.
- Bougelkha. I. (2021). Measuring the Financial Stability of Islamic and Traditional Banks in Malaysia from 2008 to 2015, *Al-Manhal Economic Journal*, 1(4), 405-422.
- Bousiaf, S. (2018). Financial Performance Assessment Indicators Contribution to Determining Factors of Financial Failure - Applied Study on the Sample of Milk Sector Institutions and Derivatives, *Journal of Economic Dimensions*, (8), 109-122.
- Bragoli, D. Ferretti, C., Ganugi, P. Mezzofori, D. & Zammori, F. (2021). Machine Learning Models for Bankruptcy Prediction: Do Industrial Variable Matter, *Spatial Economic Analysis*, 17(2), 1-22.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32.
- Buhkori, I. & kusumawati, R. (2022). Prediction of Financial Distress in Manufacturing Companies, Evidence from Indonesia, *Journal of Accounting & Investment*, 23(3), 588-605.
- Catalin, E. C.& Tureatca, M. V.(2022) Prediction of Business Bankruptcy With the help of Extreme Gradient Increase, *Economic and Applied Information*, 3, 178-185
- Charalambakis, E.C.&Garrets (2019). *On Corporate Financial Distress Prediction: What Can We Learn from Private Firms in a Development Economy? Evidence from Greek*, *Rew Quant Finan ACC*, 52, 467-49.

- Chaves, R., Rossi, A. & Garcia, L. (2023). A Financial Distress Prediction Using a Non-Stationary Dataset, Brazilian Computer Society, <https://www.researchgate.net/publication/375012270>
- Chen, S. & Shen, Z. (2020). Financial Distress Prediction using Hybrid Machine Learning Technique, *Asian Journal of Economics, Business and Accounting*, 16(2), 1-12.
- Dash, S. Behera, Ajit & Dehuri, G. (2023). *An Outliers Detection and Elimination Framework in Classification Task of Data Mining*, *Decision Analysis Journal*, 6.
- Dewin, N. D., Murhadi, W. & Sutejo, B. (2023). Financial Ratios, Corporate Governance and Macro- Economics Indicators in Predicting Financial Distress, *Journal of Law and Sustainable Development*, 1(4), 1-18
- Dhaliwal, S., A. N. & Abbas, R. (2018) Effective Intrusion Detection System Using XG BOOST, *Information*, 9(149)
- Dirman, A. (2020). Financial Distress, The Impact of Profitability Liquidity, Leverage, Firm Size, and Free Cash flow, *International Journal of Business, Economic and Law*, 22(1), 17-25.
- Domician, M., Hassan, R., & Ishtiap, A. (2023). *Comparative Analysis of Machine Learning Models for Bankruptcy Prediction in the Context of Pakistani Companies*, *Risks*, 11, 176.
- Dovile, K., Tomas, K., Roberttas, D. & Rytis, M. (2022). Systematic Review of Financial Distress Using Artificial Intelligence Methods, *Applied Artificial Intelligence*, 36, 1.
- Drogovoz, P. & Nevredinov, A. (2024). Application Text Analysis and Ensemble Algorithm in Forecasting Companies Bankruptcy, Ecological Footprint of the Modern Economy and the Ways to Reduce it, *Advance in Science, Technology & Innovation*.
- Dunakhir, S. (2023). Predicting Firm's Financial Distress: A Case Study, *Pinisi Discretion Review*, 6(2), 321-326.
- Durica, M., Frnda, J. & Svabova, L. (2021). Financial Distress Prediction in Slovakia, An Application of the cart algorithm, *Journal of Internal Studies*, 14(1), 201-215.
- Ece, A. & Guven, S. (2020). Determinants of Financial Distress in Turkey, an Econometric Analysis, *Australian Accounting Business and Finance Journal*, 14(5), 86-107.
- Eid, A. A. (2015). Using Potential Neural Networks to Combine Governance Mechanisms and Predicting Financial Faltering in the Egyptian Capital

- Market: Applied Theoretical Study, *Journal of Business Studies and Research*, 35(4), 39-124. (In Arabic)
- El Ansary, O. & Bassam, L. (2019). Predicting Financial Distress for Listed Mena Firms, *International Journal of Accounting and Financial Reporting*, 9(2), 51-75.
- Ester, M., Kriegel, H.P., Sander, J. & Xu, X., (1996) *A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases With Noise*. In *kdd*, 96, (34), 226-231.
- Evangelos, C. & Ian, G. (2019). On Corporate Financial Distress Prediction: What Can We Learn from Private Firms in a Developing Economy? Evidence from Greece, *Review of Quantitative Finance and Accounting*, 52, 467-491.
- Evi, M.S. & Indra, S. (2022). Analysis of the Effect of Macro-Economic Factors on Financial Distress in Property & Real Estate Sub-Sector Companies Listed on the Indonesia Stock Exchange in 2010-2019, *International Journal of Management Studies and Social Science Research*, 4(4), 243-254
- Faisal, S. A. & Mubarrok, U. (2024). Financial Distress Analysis Using the Altman Z-Score and Ohlson Method on Companies Listed on the Indonesian Sharia Stock Index for 2020-2023, *the 3rd International Conference on the Islamic Economics and Business*.
- Fan, J. Z., Lu, J. Z., Mi, Z. & Feng, P. (2021). Financial Distress Prediction, a Novel Data Segmentation, Research on Chinese Listed Companies, *Technological and Economic Development of Economy* 27(6), 1413-1446
- Faris, H., Aabukhurma, R., Almanaseer, W., Saadeh, M., Mora, A., Castillo, P. & Al Jarrah, I. (2020). Improving Financial Bankruptcy Prediction in a Highly Imbalanced Class Distribution Using Oversampling and Ensemble Learning: A Case from Spanish Market, *Progress in Artificial Intelligence*, 9, 31-53
- Fayaz, H.T., Amad, N., & Kinza, A. (2021). Financial Distress Prediction Using Adaboost and Bagging in Pakistan Stock Exchange, *Journal of Assian Finance, Economics, and Business*, 8(1), 665-673
- Francisco, C., Alexander, M. & Pedro, C. (2019). *Anticipating Bank Distress in the Eurozone: An Extreme Gradient Boosting*, *Journal of Business*, 101, 885-896.
- Freund, Y. & Schapire, R.E., (1997). *A Decision-Theoretic Generalization of on-Line Learning and an Application to Boosting*. *Journal of Computer and System Sciences*, 55(1), 119-139.
- Friedman, J.H. (2001). *Greedy Function Approximation: A Gradient Boosting Machine*. *Annals of statistics*, 1189-1232.

- Ghosal, A., Nandy, A., & Dasak, G. (2020). A Short Review on Different Clustering Technique and Their Application, *Emerging Technology in Modeling and Graph*, 69-83.
- Gyarteng. K.A. (2021). Corporate Financial Distress, the Impact of Profitability, Liquidity, Assets Productivity, Activity and Solvency, *Journal of Accounting, Business and Management*, 28(2), 104-115.
- Hadi, M., Fadhill, L.D. & Priyambodo, A. (2022). *Financial Distress Prediction with Stacking Ensemble learning*, *Indonesian Journal of Computing and Cybernetics System*, 16(3), 281-290
- Halteh, K., Kumar, K. & Geep, A. (2018) Financial Distress of Islamic Banks Using Tree-Based Stochastic Techniques, *Managerial Finance*, 44(6), 759-773.
- Hamid, J., Masoud, M., Eric, G. & Fariba, M. (2021) Bagging and Boosting Ensemble Classifiers for Classification of Multispectral, Hyperspectral and Polarsar Data, a Comparative Evaluation, *Remote Sensing*, 133,1-22.
- Hamid, W. & Rohani, M.D. (2018). *Predicting Financial Distress Importance of Accounting and Firm Specific Market Variable for Pakistan's Listed Firms*, *Cogent Economic & Finance*, 6.
- Haris, .A.S. (2023). Determinants of Company Bankruptcy Before and During the Covid- 19 Pandemic, *Jurnal Ekonomi Perusahaan*, 30(1), 1560-2830.
- Hidayat, W. & Yuniati, T. (2024). Determinants of Financial Distress in Transportation Equipment Industry, Evidence from Indonesia, *Quality*, .25.(199), 262-271
- Humairoh, F. N. (2022). The Effect of Corporate Governance of Financial Distress, *Jurnal Riset Akuntansi Konlemporer*, 14, (2), 237-242.
- Isayas, M. N. (2021). Financial Distress and its Determinants: Evidence from Insurance Companies in Ethiopia, *Cogent Business & Management*, 8,1-16
- Isil, E.C. (2021). The Impact of Firm-Specific and Macro-Economic Factors on Financial Distress Risk, *Universal Journal of Accounting and Finance*, 9 (3), 506-517.
- Ja, H.(1979). *A k-Means Clustering Algorithm*. *JR Stat. Soc. Ser. C-Appl. Stat.*, 28, 100-108.
- Jabeur, S. Gharib, C., Wali, S. & Arfi, W., (2021) Cat Boost Model and Artificial Intelligence Techniques for Corporate Failure Prediction, *Technological Forecasting & Social Change*, 166.
- Jessie, J., Tannia, T. (2024). The Effect of Liquidity, Activity, Profitability and Leverage on the Financial Distress of Properties and Real Estate

Companies, *Dinasti International Journal of Management Science*, 5(3), 420-429

- Jiaming, L., Chengzhang, L., Pen, O. & Jajia, L. (2023). Intrpreting the Prediction Results of the Tree – Based Boosting for Financial Distress Prediction with an Explainable Machine Learning Approach, *Journal of Forecasting*, 42(5), 1112-1137.
- Justin, L., Army, L., Grant, T. S. & Robert, W. (2020). Predicting Nursing Home fFinancial Distress Using Altman Z Score, *Inquiry: The Journal of Health Care Organization, Provision and Financing*, 57.
- Kebede, N., Tesfaye, G. & Erana, O. (2024). Determinants of Financial Distress of Financial Distress: Evidence from Insurance Companies in Ethiopia, *Journal of Innovation and Entrepreneurship*, 13,17.
- Khaled, Z. (2021). Financial Failure Prediction Using Financial Indicators, Applied Study on Services Sector Companies Listed on the Palestine Stock Exchange, *Journal of the Arab American University of Research*, 7(1),4-67. (in Arabic).
- Kim, S. Y. (2018). Predicting Hospitality Financial Distress with Ensemble Models, The Case of US Hotels, Resetaurants and Amusement and Recreation, *Sevice Business*, 12,483-503
- Kmush, .A. M.(2020). The Impact of Corporate Governance Practices on Corporate Financial Distress - Case Study of a Sample of Companies in the State of Setif, *Journal of Economics, Facilitation and Commercial Sciences*, 13 (1), 124-137.
- Kommareddy, M., Manideep, S., Vasudeva, R.&Sreelatha, K. (2022). Bankruptcy Detection on the Unbalanced Data with Various Machine Learning Models, *International Journal for Research in Applied Science& Engineering Technology*.10(6), 1435-1439
- Laksmiwati .M., Mappadang, A.,Indrabudiman, A.&Riza, V.(2021). Determination of Financial Distress on the Prediction of Fnancial Distress, *Asian Journal of Economic Business and Accounting*, 21(22),46-57.
- Lenka, P. & Mario, P. (2022). Effect of Classification, Feature Selection and Resampling Methods on Bankruptcy Prediction of Small and Medium Sized Enterprise, *Interlligent System in Accounting, Finance and Management, An International Journal*, 29(4), 254-281.
- Li, T., Gang. K., Peng, Y. & Philip, Y. (2022). An Integrated Cluster Detection, Optimization and Interpretation Approach for Financial Data, *IEEE Transactions on Cybernetics*. 52(2),1348-1361.

- Li, Zh., Grook, G., A. & Tang, Y. (2021). Predicting the Risk of Financial Distress Using Corporate Governance Measure, *Pacific Basin Finance Journal*, 68, 1-12
- Liang, D., Tsai, C.F. & Lu. H. Y. (2020). Combining Corporate Governance Indicators With Staking Ensemble for Financial Distress Prediction, *Journal of Business Research*, 120,137-146
- Liashenko, O., Tetyana, K. & Koslovelskyri, Y (2023). Machine Learning and Data Balancing Methods for Bankruptcy Prediction, *Ekonomika*, 102(2), 28-46
- Liu,W., Fan, H., X. & Pang, C. (2022). Predicting and Interpreting Financial Distress Using Weight Boost – Tree Based Tree, *Engineering Application of Artificial Intelligence*,116.
- Liu, Y. , Zeng, Q., Lili, B., M. & Mere, J.O. (2022). Anticipating Financial Distress of High- Tech Startups in the European Union, a Machine Learning Approach for Imbalanced Sample, *Journal of Forecasting*, 41(6),1131-1155
- Lombardo, G., Pellgrino, M., Adosoglou, G., Cagnomi, P. & Poggi, A. (2022). Machine Learning for Bankruptcy Prediction the American Stock Market: Dataset and Benchmarks, *Future Internet*, 14(8), 244-267
- Long, L. & Muhanna, B. (2020). Predicting the Financial Hardship of the Company - Comparison of the Performance of Accounting and Market Models "Evidence from Kuwait Market and Location of Securities, *Journal of Research and Scientific Studies, Economics Series*, 42(2), 69-92.(in Arabic).
- Mahardini, N. &Yustina, B.(2023). Choosing Ratio in the Financial Distress Prediction, *Journal of Namibian Studies*, 34,1213-1232.
- Mahfuzur, R., Cheong, Li, S. & MD, A.M. (2021). Prediting Firms Financial Distress, an Empirical Analysis Using the F-score Model, *Journal of Risk and Financial Management*,14(199),1-16.
- Malakauskas, A. & Laksatutiene, A. (2021). Financial distress prediction for Small and Medium Enterprise Using Machine Learning, *Inzineine Ekonomika – Enginnerring Economics*, 32(1),4-14.
- Malakauskas, L., Y. (2023). Interpretable MachineLearning for SMEs Financial Distress Prediction, In: Laouar, M.R., Balas, V.E., Lejdel, B., Eom, S., Boudia, M.A. (eds) *12th International Conference on Information Systems and Advanced Technologies “ICISAT*
- Manthoulis, G., Dowmpos, Z., Galariotis & Baouraks (2021). Bank Failure Prediction, a Comparison of Machine Learning Approaches , *Financial Risk Management and Decision*, Springer, Cham, https://doi.org/10.1007/978-3-030-66691-0_10

- Mashudi, R. H., Azdilla, F.& Citira, S. (2021). Financial Distress Prediction in Infrastructure, Utilities, and Transportation Sector Companies, *Jurnal Kewangandan Perbankan*, 25(3), 656-670.
- Maya, I., Indri, K., & Naila, N.(2021). Financial Distress Prediction, The Ownership Structure and Managerial Agency Cost, *The Indonesian Journal of Accounting Research*, 24(2),243-258.
- Mochammad, M., Renny, H. & Kusmanieim, H. (2019). *Financial Distress Prediction in Indonesia*, *Wseas Transaction on Business and Economics Journal*,161, 251-260.
- Mohamed, S. S. (2020). Suggested Model for Explaining Financial Distress in Egypt, Toward a Comprehensive Model, Biswas, and Michaelides (ED), *Financial Issue in Economics: Special Issue Including* 36, 99-122,
- Müllner, D. (2011). *Modern Hierarchical, Agglomerative Clustering Algorithms*. ArXiv 1109.2378.
- Muslim, A. & Dasril, Y. (2021). *Company Bankruptcy Prediction Framework Based on the Most Influential Prediction Framework Based on the Most Influential Prediction Feature Using XGBOOST and Stacking Ensemble Learning*, *International Journal of Electrical and Computer Engineering*, 11(6), 5549-5557
- Narvekar & Guha (2021). Bankruptcy Prediction Using Machine Learning and Application to the Case of the Covid- 19 Recession, *Data Science in Finance and Economics*, 1(2),180-195
- Nawang, K.B., Muhammad, T., Lia, U. & Dadan (2022). *The Effect of Profitability, Board Size, Woman on Board and Political Connection on Financial Distress Conditions*, *Cogent Business & Management*,9,1-22.
- Nour. A. I., Najjar, M., Saed al, K., Abullateef, A., Mahmoud, I., N. & Rani S. (2023). The Impact of Corporate Governance Failure, an Empirical Evidence from Palestine Exchange, *Journal of Accounting in Emerging Economies*.
- Noviantoro,T., Huang, J. P. (2021). Comparing Machine Learning Algorithms to Investigate Financial Distress, *Review of Business, Accounting, Finance*,1: 454-479.
- Nurcahyono, N., Adelia, P., Christanty, I., Nugroho, S. (2023). The Effect of Financial Ratio on Financial Distress in Mining Companies, *Value Added: Majalah Ekonomi Dan Bisnis*, 19 (2), 80-88.
- Ogachi, D., Ndege, R. & Graturu (2020). Corporate Bankruptcy Prediction Model, a Special Focus on Listed Companies in Kenya, *Journal of Risk and Financial Management*, 13, 47.

- Oyewole, J., & Thopil (2023). Data Clustering: Application and Trends, *Artificial Intelligence Review*, 56:6439-6475.
- Papikova, L. & Papik (2024). Gender Diversity of Board of Directors and Shareholders Machine Learning Exploration During Covid- 19, *Gender in Management*, 39(3), 345-369.
- Phan, X. & Ho, T. (2021). Using Boosting Algorithm to Predict Bank Failure: an Untold Story, *International Review of Economic and Finance*, 76, 40-54.
- Quian, H., Wang, B., Yuan, M.Y. & Gao, S. (2022). Financial Distress Prediction Using a Corrected Feature Selection Measure and Gradient Boosted of Decision Tree, *Expert System with Application*, 190.
- Ragab, Y. & Saleh, M. (2022). Non- Financial Variable Related to Governance and Financial Distress in SMEs, Evidence from Egypt, *Journal of Applied Accounting Research*, 23(3), 604-627.
- Rahman, J., Z.H. (2024). Predicting Financial Distress Using Machine Learning Approaches: Evidence China, *Journal of Contemporary Accounting & Economics*, 20(1).
- Rahmani, R.M. & Right, W.P. (2022). Using the Zmijewski Model to Predict Bankruptcy: An Applied Study on a Sample of Small and Medium Productive Enterprises During the Period (2016-2020), *Algerian Journal of Social Sciences* 10(2), 289-306. (in Arabic)
- Rahmasari, I. (2018). Corporate Governance Effect on Financial Distress, Evidence from Indonesian Public Llisted Companies, *Journal of Economics, Business, Accounting Ventura*, 31(3), 415-422.
- Ramzan, S. (2023). Comparison of Financial Ddistress Prediction Models Using Financial Variable, *International Conference on Electric, Computer and South Africa*, 1-7.
- Rasheed, D. (2023). Corporate Governance , Intellectual Capital and Bankruptcy Risk, Evidence from Egypt, *Journal of Commerce and Finance*, 43(3), 1-48.
- Rashid, F., khan, A.R. & Quereshi, H. (2021). Assessing the Financial Distress of Indian Banks, a Comparative Study Using Emerging Market ZScore Model, *Elementary Education*,. 20(6), 6065-6081.
- Refiana, D. M., Nadia, A. & Ulil, H. (2023). Moderation Analysis of Good Corporate Governance on the Effect of Financial Ratio and Market on Financial Distress, *International Journal of Professional Business Review*, 8(7), 1-26.

- Reynolds, D.A. (2009). *Gaussian Mixture Models. Encyclopedia of biometrics*, 741 (659-663).
- Rinofah, R. k., Virginia, A. & Maha, P. (2022). Factors Affecting Potential Company Bankruptcy During the COVID-19, *Journal Keuangan Danperbankan*, 26(1), 208-228.
- Sairin, N.H., Bujang, U. & Shalls, M. (2019). Determing Macro-Economic Factor of Financial Distress in Malaysia, *MJBE, Malaysian Journal of Business and Economics*, 29-36.
- Sakulpolphaisan, E., Hensawang, S. (2022). Impact of Audit Committee and Financial Performance on Financial Distress Prediction, An Empirical Study of the Listed Companies in the Market for Altenative Investment, *Cuadernos De Eeconomia*, 45, 127, 128-139.
- Savery, Y.I. & Riswan, H. (2024). Financial Performance to Determine Financial Distress Conditions, *Journal of Management, Accounting, General Finance and International Economic*, 3(2), 598-611.
- Serkan, G. S. & Eda, K. (2023). Predicting Financial Distress in the BIST Industrials Index, Evaluating Traditional Models and Clustering Technique, *Journal of Research in Economic Politics & Finance*, 8(4), 660-680.
- Seyfullah, S. (2023). *Prediction Financial Distress Using Supervised Machine – Learning Algorithm: An Application on Borso Istanbul*, *Journal of Economics, Finance, and Accounting*, 10(4), 217-223.
- Shegal, S., Mishra, R. & Jaisaul, A. (2021). A Search for Macroeconomic Determinants of Corporate Financial Distress, *Indian Economic Review*, 56, 435-461.
- Shetty, S., Musa, M. & Xavier, B. (2022) Bankruptcy Prediction Using Machine Learning Technique, *Journal of Risk and Financial Management*, 15(35), 1-10.
- Shrivasta, S., Jeyanthi, M., Singh, S. (2020). failure prediction of indian bank using smote, lasso regression, bagging and boosting, *Cogent Econominc & Finance*, 8(1),1-17.
- Siti, S. I., Mod, R., Al Amahami, A. & Berlian, N. M. (2024). Logistic Regression Model for Evaluating Performance of Construction, Technology, and Property- Based Companies in Malaysia, *Journal of Advanced Research in Applied Science and Engineering Technology*, 39(2), 72-85.
- Smith, M. & Alvarez, F. (2022). *Predicting Frm Level Bankruptcy in The Spanish Economy Using Extreme Gradient Boosting*, *Computational Economics*, 59, 263-295.

- Souse, A. B. & Jorje, C. (2022). Impact of Macro- Economic Indicators on Bankrupt Prediction Models, Case of the Portuguese Construction Sector, *Quantitative Finance and Economic* 6(3), 405-432
- Soydas, S. & Handan (2024). Predicting Financial Failure in Companies by Employing Machine Learning Methods, *International Journal of Social Science Research and Review*,7(2),111-125.
- Sponerova, S. & Svoboda (2021). Dependence of Company Size on Factors Influencing Bankruptcy, *SHS Web of Conference, the 20th International Scientific Conference Globalization and Its Socio-Economic Consequence*, 92.
- Sreedharan, M., Khedr, A. & El Bannany, M. (2020). A Comparative Analysis of Machine Learning Classifiers and Ensemble Technique in Financial Distress, *The International Multi- Conference on Systems, Signals & Device, SSD, Tunisia*.
- Sugianto, N., Lestari, S .D., Soekoljo, S. & Selamet, R.A. (2022). The Role of the Board of Commissioners: Determinants in Predicting Bankruptcy Financing Company, *International Journal of Business and Management Invention*, 11(7), 33-38.
- Tanya,T.,Taniy, T. & Sanjay, T. (2018). How Artificial Intelligence, Machine Learning and Deep Learning are Radically Different? *International Journal of Advanced Research in Computer Science and Software Engineering*, 8(2), 1-9
- Tawific, M. & Sugianto, C. (2021). Do Accounting, Market and Macro-Economic Factors Affect Financial Distress? Evidence in Indonesia, *International Journal of Applied Business*, 5(2), 166-182.
- Toly, A.A., Permanata, R. & Wiranata, E. (2019). The Effect of Financial Ratio (altman z- score) on Financial Prediction in Manufacturing Sector in Indonesia 2016-2018, *Advances in economics, Business and Management Research*,144, 47-53.
- Tran, K.L., Le Hoang, Nguyen,T. & Nguyen, D.T. (2022). Explainable Machine Learning for Financial Distress Prediction: Evidence from Vietnam, *Data*, 7(11), 160.
- Tran,T., Nguyen Nit, Thanbvun (2023). Examining Financial Distress of the Vietnamese Listed Firm Using Accounting Based – Models, *Plos One*, 18(2).
- Trisandi, E., Putri, S., Ariella, P. (2024). Determinant of Financial Distress in Construction Sub-Sector Companies in Indonesia and Malaysia, *Proceeding of International Conference on Accounting and Finance*,2, 319-334.

- Tron, A., Dallochio, M., Ferri, S., & Colantoni, F. (2023). Corporate Governance and Financial Distress: Lesson Learned from an Unconventional Approach, *Journal of Management*, 27, 425-456.
- Umut Engin & Salih Durer (2023). Financial Distress Prediction from Tmes Series Using XGBOOST: BIST 100of Borsa Istanbul, *Docus University Journal* 24(2), 589-604.
- Utami, D., Atmaja, H., Hirawati, H. (2021). the Role of Financial Distress Prediction, *Kinerja*, 25(2), 287-307.
- Valentine, B., Roy, S., Edison, H. & Gracia, U. (2023). Early Warning Signs of Financial Distress Using Random Forest and Logit model, *Corporate and Business Strategy Review*, 4(4), 69-88.
- Van, C., Nguyen, T. N. & Tuooanh, L. (2019). Determining The Impact of Financial Performance Factors on Bankruptcy Risk, An Empirical Study of Listed Real Estate Companies , *Investment Management and Fncial Innovation*. 16(3), 308-318.
- Veromica, S., & Kinanti, M. (2023). *Financial Ratio Analysis for Predicting Financial Distress*, *Eduvest, Journal of Universal Studies*, 3(10),1841-1856.
- Viswanathan, S. & Suresh, H. (2020). Predicting Financial Health of Banks for Investors Guidance Using MachineL learning Algorithm, *Journal of Emerging Market Finance*, (19), 226-261.
- Walid, M.Q. (2021). Demanded the Use of the Models Altman and Springate in predicting the Financial Distress of the Industrial Enterprises Listed on the Algiers Stock Exchange, *Journal of Financial, Accounting and Management Studies*, 8(3), 281-297. (in Arabic).
- Wang, W. & Guedes .M.J. (2024). Firm Failure Prediction for Small and Medium – Sized Enterprises and New venture *Rev Manag Sci*, <https://doi.org/10.1007/s11846-024-00742-4>.
- Werner, R., Murhadi, F.T. & Bertha, S. S. (2018). The Influence of Good Corporate Governance on Financial Distress, *Advance in Social Education and Humanities Research*, 186, 76-79.
- Wiena, F. Abror, A. & Muhammad, A. (2023). *Bankruptcy Prediction Using Genetic – Algorithm Support Vector Machine (Ga- SVM), Feature Selection and Stacking*, *Journal of Information System, Exploration & Research*, 1(2),103-108.
- Wira, A.M., Sr, A. & Luch, G. (2024). The Effect of Leverage, Profitability, Liquidity and Sale/Total assets on Financial Distress of Non- cyclical Companies Listed on the Indonesia Stock Exchange for the Period of 2020-

- 2022, *Russian Journal of Agricultural and Socio- economic Science*, 3(147), 117-125.
- Wolpert, D.H. (1992). *Stacked Generalization. Neural Networks*, 5(2), 241-259.
- Wu, C., Chen, X. & Jiang, Y. (2024). Financial Distress Prediction Based on Ensemble Feature Selection and Improved Stacking Algorithm, *Kybernetes*.
- Wyrobeck, J., Krzystof, k. (2018). Efficiency of Gradient Boosting Decision Trees Technique in Polish, Willimowska, Borzemski Swiatek, *Advances in Intelligent Systems and Computing*, 854, Springer.
- Younas, N., Uddin, S., Awan,T. & Yrthan, M. (2021). Corporate Governance and Financial Distress: Assian Emerging Market Perspective, *Corporate Governance*,1(4), 702-715.
- Yousaf, U., Khalil, J. & Man,W. (2022). *A Comparison of Static, Dynamic and Machine Learning Models in Predicting the Financial Distress of Chinese Firms, Romanian Journal of Economics Forecasting*, xxv(1),122-138.
- Yusra & Bathtera (2021). *Prediction Modelling the Financial Distress Using Corporate Governance Indicators in Indonesia, Jurnal Kajian Manajermen Bisnis*,10(1),18-32.
- Yusuf, D., C.U. (2024). Determinants of Financial Distress, Review of the Aspects of Profitability, Liquidity, Leverage and Activity, *International Journal Multidisciplinary Science*, 3(1), 36-44.
- Zhao, Qi., Xuwijun & Ji .Y. (2023). Prediction Financial Distress of Chinese Listed Companies Using Machine Learning: to What Extent Does Textual Disclosure Matter? *International Review of Financial Analysis*, 89, 1-14.
- Zhong, J. & Wang, Z. (2022). Artificial Intelligence Technique for Financial Distress Prediction, *AIMS Mathematics*,7(12), 20891-20908.
- Zizi, Y., Mohamed, O. & Abdedelam (2022) The Macro- economic Determinants of Moroccan Corporate Bankruptcy, *International Journal of Applied Economics , Finance and Accounting*, 14(1).

الملاحق

ملحق 1: الشركات التي تمت الدراسة عليها

أولاً: قطاع التشيد والمقاولات

Company	Company Name	Time	Z Score	التصنيف
1	أكرو مصر للشدات	2022	6.286699	غير متعثرة
1	أكرو مصر للشدات	2021	7.047112	غير متعثرة
1	أكرو مصر للشدات	2020	8.04721	غير متعثرة
1	أكرو مصر للشدات	2019	3.230272	غير متعثرة
1	أكرو مصر للشدات	2018	7.744018	غير متعثرة
1	أكرو مصر للشدات	2017	6.227397	غير متعثرة
1	أكرو مصر للشدات	2016	6.348896	غير متعثرة
1	أكرو مصر للشدات	2015	6.184743	غير متعثرة
1	أكرو مصر للشدات	2014	7.547815	غير متعثرة
1	أكرو مصر للشدات	2013	8.294697	غير متعثرة
1	أكرو مصر للشدات	2012	10.07215	غير متعثرة
1	أكرو مصر للشدات	2011	32.32128	غير متعثرة
1	أكرو مصر للشدات	2010	8.103659	غير متعثرة
1	أكرو مصر للشدات	2009	10.25502	غير متعثرة
1	أكرو مصر للشدات	2008	6.746307	غير متعثرة
	average z score		8.963818	غير متعثرة
2	شركة النصر للأعمال المعدنية	2022	6.741	غير متعثرة
2	شركة النصر للأعمال المعدنية	2021	8.114066	غير متعثرة
2	شركة النصر للأعمال المعدنية	2020	7.344516	غير متعثرة
2	شركة النصر للأعمال المعدنية	2019	7.814154	غير متعثرة
2	شركة النصر للأعمال المعدنية	2018	6.804969	غير متعثرة
2	شركة النصر للأعمال المعدنية	2017	6.470905	غير متعثرة
2	شركة النصر للأعمال المعدنية	2016	3.25	غير متعثرة
2	شركة النصر للأعمال المعدنية	2015	7.099897	غير متعثرة
2	شركة النصر للأعمال المعدنية	2014	65.47705	غير متعثرة
2	شركة النصر للأعمال المعدنية	2013	6.288544	غير متعثرة
2	شركة النصر للأعمال المعدنية	2012	6.581143	غير متعثرة
2	شركة النصر للأعمال المعدنية	2011	6.413057	غير متعثرة
2	شركة النصر للأعمال المعدنية	2010	25.84141	غير متعثرة
2	شركة النصر للأعمال المعدنية	2009	5.360531	غير متعثرة
2	شركة النصر للأعمال المعدنية	2008	13.4071	غير متعثرة
2	شركة النصر للأعمال المعدنية	2007	30.86911	غير متعثرة
	متوسط zscore		13.8091	غير متعثرة
3	المصرية لتطوير صناعة السفن	2022	12.21232	غير متعثرة

تقييم أداء نماذج الذكاء الاصطناعي في التنبؤ بالتعثر المالي

3	المصرية لتطوير صناعة السفن	2021	6.464052	غير متعثرة
3	المصرية لتطوير صناعة السفن	2020	5.949754	غير متعثرة
3	المصرية لتطوير صناعة السفن	2019	6.109736	غير متعثرة
3	المصرية لتطوير صناعة السفن	2018	4.439987	غير متعثرة
3	المصرية لتطوير صناعة السفن	2017	-5.93119	متعثرة
3	المصرية لتطوير صناعة السفن	2016	-10.679	متعثرة
3	المصرية لتطوير صناعة السفن	2015	-59.1258	متعثرة
3	المصرية لتطوير صناعة السفن	2014	-5.01749	متعثرة
3	المصرية لتطوير صناعة السفن	2013	2.223477	رمادية
3	المصرية لتطوير صناعة السفن	2012	-9.00157	متعثرة
3	المصرية لتطوير صناعة السفن	2011	2.573545	رمادية
3	المصرية لتطوير صناعة السفن	2010	4.248678	غير متعثرة
3	المصرية لتطوير صناعة السفن	2009	4.477432	غير متعثرة
3	المصرية لتطوير صناعة السفن	2008	34.63763	غير متعثرة
3	المصرية لتطوير صناعة السفن	2007	6.64691	غير متعثرة
			0.014274	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2022	6.063889	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2021	4.320796	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2020	8.540593	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2019	10.33955	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2018	29.56088	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2017	7.493557	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2016	6.536364	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2015	6.254229	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2014	12.84784	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2013	9.366486	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2012	2010.368	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2011	4.538869	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2010	6.161086	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2009	36.64145	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2008	61.87777	غير متعثرة
4	المصريين للاستثمار والتنمية العمرية	2007	3.25	غير متعثرة
	average		139.0101	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2022	-9.78974	متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2021	5.8913	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2020	6.154096	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2019	6.333758	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2018	6.99688	غير متعثرة

5	الصناعات الهندسية المعمارية للإنشاء	2017	5.224325	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2016	3.25	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2015	3.25	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2014	3.25	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2013	3.25	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2012	3.25	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2011	3.25	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2010	3.25	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2009	3.25	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2008	3.25	غير متعثرة
5	الصناعات الهندسية المعمارية للإنشاء	2007	3.25	غير متعثرة
	average		3.331914	غير متعثرة
7	الصعيد العامة للمقاولات	2022	6.958519	غير متعثرة
7	الصعيد العامة للمقاولات	2021	8.826465	غير متعثرة
7	الصعيد العامة للمقاولات	2020	9.553568	غير متعثرة
8	الصعيد العامة للمقاولات	2019	8.410144	غير متعثرة
7	الصعيد العامة للمقاولات	2018	12.31332	غير متعثرة
7	الصعيد العامة للمقاولات	2017	10.21335	غير متعثرة
7	الصعيد العامة للمقاولات	2016	3.25	غير متعثرة
7	الصعيد العامة للمقاولات	2015	3.25	غير متعثرة
7	الصعيد العامة للمقاولات	2014	3.25	غير متعثرة
7	الصعيد العامة للمقاولات	2013	3.25	غير متعثرة
7	الصعيد العامة للمقاولات	2012	4.663489	غير متعثرة
7	الصعيد العامة للمقاولات	2011	4.450421	غير متعثرة
7	الصعيد العامة للمقاولات	2010	40.27015	غير متعثرة
7	الصعيد العامة للمقاولات	2009	40.37968	غير متعثرة
7	الصعيد العامة للمقاولات	2008	6.955981	غير متعثرة
7	الصعيد العامة للمقاولات	2007	6.024253	غير متعثرة

ومن التحليل السابق لقطاع المقاولات والتشييد نجد أنه تتضمن 7 شركات، وبناء على متوسط z score يمكن القول بأنه عدد الشركات غير المتعثرة بلغ 5 شركات، في حين بلغ عدد الشركات غير المتعثرة 2، وهي المصرية لتطوير صناعة السفن والجيزة العامة للمقاولات.

ثانيًا: القطاع العقاري

1	الخليجة الكندية للاستثمار العقاري	2022	3.191090641	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2021	8.466776621	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2020	9.528796223	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2019	9.534063763	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2018	9.663102152	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2017	9.820443498	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2016	14.49569237	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2015	11.10932644	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2014	5.75707759	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2013	6.622287271	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2012	17.62419359	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2011	4.743071896	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2010	4.981462449	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2009	1.301457477	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2008	6.217766632	غير متعثر
1	الخليجة الكندية للاستثمار العقاري	2007	289.3954794	غير متعثر
1			25.7782555	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2022	3.272351075	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2021	3.388633277	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2020	3.310318196	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2019	3.246618887	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2018	3.62596451	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2017	3.778032992	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2016	3.25	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2015	3.25	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2014	3.25	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2013	3.25	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2012	3.25	غير متعثر
2	موسليا المصرية الخليجية للاستثمار العقاري	2011	3.25	غير متعثر
			3.343493245	غير متعثر

3	القاهرة للإسكان و التعمير	2022	5.883934184	غير متعارة
3	القاهرة للإسكان و التعمير	2021	6.230859979	غير متعارة
3	القاهرة للإسكان و التعمير	2020	7.697065618	غير متعارة
3	القاهرة للإسكان و التعمير	2019	11.65976554	غير متعارة
3	القاهرة للإسكان و التعمير	2018	7.315375715	غير متعارة
3	القاهرة للإسكان و التعمير	2017	5.925576018	غير متعارة
3	القاهرة للإسكان و التعمير	2016	4.292381043	غير متعارة
3	القاهرة للإسكان و التعمير	2015	3.25	غير متعارة
3	القاهرة للإسكان و التعمير	2014	9.516797296	غير متعارة
3	القاهرة للإسكان و التعمير	2013	6.793085097	غير متعارة
3	القاهرة للإسكان و التعمير	2011	3.25	غير متعارة
3	القاهرة للإسكان و التعمير	2010	7.753731339	غير متعارة
3	القاهرة للإسكان و التعمير	2009	8.877430261	غير متعارة
3	القاهرة للإسكان و التعمير	2008	10.5332856	غير متعارة
3	القاهرة للإسكان و التعمير	2007	10.63099633	غير متعارة
			7.307352267	غير متعارة
5	التعمير للاستشارات الهندسية	2022	6.520133473	غير متعارة
5	التعمير للاستشارات الهندسية	2021	11.60394062	غير متعارة
5	التعمير للاستشارات الهندسية	2020	12.11416058	غير متعارة
5	التعمير للاستشارات الهندسية	2019	10.00681614	غير متعارة
5	التعمير للاستشارات الهندسية	2018	8.464825069	غير متعارة
5	التعمير للاستشارات الهندسية	2017	7.425054304	غير متعارة
5	التعمير للاستشارات الهندسية	2016	3.25	غير متعارة
5	التعمير للاستشارات الهندسية	2015	3.25	غير متعارة
5	التعمير للاستشارات الهندسية	2014	8.130580388	غير متعارة
5	التعمير للاستشارات الهندسية	2013	7.056596807	غير متعارة
5	التعمير للاستشارات الهندسية	2012	6.355604569	غير متعارة
5	التعمير للاستشارات الهندسية	2011	73.77160578	غير متعارة
5	التعمير للاستشارات الهندسية	2010	3.541332735	غير متعارة
5	التعمير للاستشارات الهندسية	2009	5.821445039	غير متعارة
5	التعمير للاستشارات الهندسية	2008	6.809316351	غير متعارة
5	التعمير للاستشارات الهندسية	2007	0.362044373	غير متعارة
			10.90521601	غير متعارة
6	المتحدة للتعمير و الإسكان	2022	13.52124588	غير متعارة
6	المتحدة للتعمير و الإسكان	2021	13.71587772	غير متعارة
6	المتحدة للتعمير و الإسكان	2020	10.98845012	غير متعارة
6	المتحدة للتعمير و الإسكان	2019	8.685674554	غير متعارة
6	المتحدة للتعمير و الإسكان	2018	9.593301557	غير متعارة
6	المتحدة للتعمير و الإسكان	2017	9.149518795	غير متعارة
6	المتحدة للتعمير و الإسكان	2016	9.541003468	غير متعارة
6	المتحدة للتعمير و الإسكان	2015	10.08157842	غير متعارة
6	المتحدة للتعمير و الإسكان	2014	6.724914033	غير متعارة
6	المتحدة للتعمير و الإسكان	2013	8.330483772	غير متعارة
6	المتحدة للتعمير و الإسكان	2012	9.231097281	غير متعارة
6	المتحدة للتعمير و الإسكان	2011	10.29401585	غير متعارة
6	المتحدة للتعمير و الإسكان	2010	9.593776941	غير متعارة
6	المتحدة للتعمير و الإسكان	2009	8.732193788	غير متعارة
6	المتحدة للتعمير و الإسكان	2008	4.085655636	غير متعارة
6	المتحدة للتعمير و الإسكان	2007	4.342041736	غير متعارة
			9.163176846	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2022	-26.04521061	متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2021	-18.4642236	متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2020	6.044345845	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2019	6.435098496	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2018	6.722550164	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2017	7.907743556	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2016	3.25	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2015	3.25	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2014	3.25	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2013	3.25	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2012	8.355044147	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2011	7.645360672	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2010	7.524807084	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2009	8.585457807	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2008	6.648057799	غير متعارة
7	كوبير للاستثمار لعقارى (العقارية للبنوك)	2007	9.760152887	غير متعارة
			2.757449016	غير متعارة

تقييم أداء نماذج الذكاء الاصطناعي في التنبؤ بالتعثر المالي

8	العبور للاستثمار العقاري	2022	-0.216009093	متعثرة
8	العبور للاستثمار العقاري	2021	4.883160203	غير متعثرة
8	العبور للاستثمار العقاري	2020	5.383727355	غير متعثرة
8	العبور للاستثمار العقاري	2019	5.761716139	غير متعثرة
8	العبور للاستثمار العقاري	2018	5.535086747	غير متعثرة
8	العبور للاستثمار العقاري	2017	5.637628891	غير متعثرة
8	العبور للاستثمار العقاري	2016	3.25	غير متعثرة
8	العبور للاستثمار العقاري	2015	3.25	غير متعثرة
8	العبور للاستثمار العقاري	2014	3.25	غير متعثرة
8	العبور للاستثمار العقاري	2013	3.25	غير متعثرة
8	العبور للاستثمار العقاري	2012	5.779376485	غير متعثرة
8	العبور للاستثمار العقاري	2011	5.046251952	غير متعثرة
8	العبور للاستثمار العقاري	2010	61.93239092	غير متعثرة
8	العبور للاستثمار العقاري	2009	4.152230131	غير متعثرة
8	العبور للاستثمار العقاري	2008	3.25	غير متعثرة
			8.009703982	غير متعثرة

9	مدينة مصر (مدينة نصر)	2022	7.382901785	غير متعثرة
9	مدينة مصر (مدينة نصر)	2021	8.913131348	غير متعثرة
9	مدينة مصر (مدينة نصر)	2020	9.570532211	غير متعثرة
9	مدينة مصر (مدينة نصر)	2019	9.450067214	غير متعثرة
9	مدينة مصر (مدينة نصر)	2018	7.687149733	غير متعثرة
9	مدينة مصر (مدينة نصر)	2017	6.540121663	غير متعثرة
9	مدينة مصر (مدينة نصر)	2016	4.331277595	غير متعثرة
9	مدينة مصر (مدينة نصر)	2015	9.814753937	غير متعثرة
9	مدينة مصر (مدينة نصر)	2014	8.487306542	غير متعثرة
9	مدينة مصر (مدينة نصر)	2013	8.850374675	غير متعثرة
9	مدينة مصر (مدينة نصر)	2012	7.844973544	غير متعثرة
9	مدينة مصر (مدينة نصر)	2011	6.972849141	غير متعثرة
9	مدينة مصر (مدينة نصر)	2010	5.809005214	غير متعثرة
9	مدينة مصر (مدينة نصر)	2009	5.921609626	غير متعثرة
9	مدينة مصر (مدينة نصر)	2008	3.890404182	غير متعثرة
9	مدينة مصر (مدينة نصر)	2007	5.294146593	غير متعثرة
	مدينة مصر (مدينة نصر)		7.297537813	غير متعثرة
10	الدلتا للإسكان والتعمير	2022	3.191090641	غير متعثرة
10	الدلتا للإسكان والتعمير	2021	8.466776621	غير متعثرة
10	الدلتا للإسكان والتعمير	2020	9.528796223	غير متعثرة
10	الدلتا للإسكان والتعمير	2019	9.534063763	غير متعثرة
10	الدلتا للإسكان والتعمير	2018	9.663102152	غير متعثرة
10	الدلتا للإسكان والتعمير	2017	9.820443498	غير متعثرة
10	الدلتا للإسكان والتعمير	2016	14.49569237	غير متعثرة
10	الدلتا للإسكان والتعمير	2015	11.10932644	غير متعثرة
10	الدلتا للإسكان والتعمير	2014	5.75707759	غير متعثرة
10	الدلتا للإسكان والتعمير	2013	6.622287271	غير متعثرة
10	الدلتا للإسكان والتعمير	2012	17.62419359	غير متعثرة
10	الدلتا للإسكان والتعمير	2011	4.743071896	غير متعثرة
10	الدلتا للإسكان والتعمير	2010	4.981462449	غير متعثرة
10	الدلتا للإسكان والتعمير	2009	1.301457477	غير متعثرة
10	الدلتا للإسكان والتعمير	2008	6.217766632	غير متعثرة
10	الدلتا للإسكان والتعمير	2007	289.3954794	غير متعثرة
			25.7782555	غير متعثرة

تقييم أداء نماذج الذكاء الاصطناعي في التنبؤ بالتعثر المالي

11	الشركة العربية للإدارة الأصول	2022	17.94905004	غير متعثرة
11	الشركة العربية للإدارة الأصول	2021	6.374226011	غير متعثرة
11	الشركة العربية للإدارة الأصول	2020	51.50790828	غير متعثرة
11	الشركة العربية للإدارة الأصول	2019	9.655849703	غير متعثرة
			21.37175851	غير متعثرة

12	زهراء المعادي للتعمير	2022	13.19971609	
12	زهراء المعادي للتعمير	2021	18.703163	
12	زهراء المعادي للتعمير	2020	8.971696809	
12	زهراء المعادي للتعمير	2019	18.99429382	
12	زهراء المعادي للتعمير	2018	22.69834508	
12	زهراء المعادي للتعمير	2017	24.9474615	
12	زهراء المعادي للتعمير	2016	10.08482798	
12	زهراء المعادي للتعمير	2015	14.11223792	
12	زهراء المعادي للتعمير	2014	13.95911991	
12	زهراء المعادي للتعمير	2013	13.38876777	
12	زهراء المعادي للتعمير	2012	12.29402845	
12	زهراء المعادي للتعمير	2011	8.097091227	
12	زهراء المعادي للتعمير	2010	9.804073736	
12	زهراء المعادي للتعمير	2009	6.83549597	
12	زهراء المعادي للتعمير	2008	7.361376037	
12	زهراء المعادي للتعمير	2007	6.922958998	
			<u>13.14841589</u>	

زهراء المعادي غير متعثرة

13	بالم هليز	2022	5.800343583	غير متعثرة
13	بالم هليز	2021	5.543486164	غير متعثرة
13	بالم هليز	2020	4.838516422	غير متعثرة
13	بالم هليز	2019	5.002170758	غير متعثرة
13	بالم هليز	2018	4.189320003	غير متعثرة

13	بالم هليز	2017	3.957623769	غير متعثرة
13	بالم هليز	2016	4.021993247	غير متعثرة
13	بالم هليز	2015	4.650780459	غير متعثرة
13	بالم هليز	2014	13.29940134	غير متعثرة
13	بالم هليز	2013	3.966045867	غير متعثرة
13	بالم هليز	2012	6.583363185	غير متعثرة
13	بالم هليز	2011	8.876953461	غير متعثرة
13	بالم هليز	2010	10.8030748	غير متعثرة
13	بالم هليز	2009	3.25	غير متعثرة
13	بالم هليز	2008	3.25	غير متعثرة
			5.868871537	غير متعثرة
14	الإسماعلية الجديدة للتطوير والتنمية العمرانية	2021	-52.21972559	متعثرة
14	الإسماعلية الجديدة للتطوير والتنمية العمرانية	2022	4.269937967	غير متعثرة
14	الإسماعلية الجديدة للتطوير والتنمية العمرانية	2020	9.278627758	غير متعثرة
14	الإسماعلية الجديدة للتطوير والتنمية العمرانية	2019	59.33187709	غير متعثرة
14	الإسماعلية الجديدة للتطوير والتنمية العمرانية	2018	9.338746859	غير متعثرة
14	الإسماعلية الجديدة للتطوير والتنمية العمرانية	2017	9.404176631	غير متعثرة
14	الإسماعلية الجديدة للتطوير والتنمية العمرانية	2016	3.25	غير متعثرة
14	الإسماعلية الجديدة للتطوير والتنمية العمرانية	2015	3.25	غير متعثرة
	الإسماعلية الجديدة للتطوير والتنمية العمرانية			
	الإسماعلية الجديدة للتطوير والتنمية العمرانية		5.737955089	غير متعثرة
15	المطورون العرب - بورتو جروب سابقاً	2022	5.333672	غير متعثرة
15	المطورون العرب - بورتو جروب سابقاً	2021	7.22653	غير متعثرة
15	المطورون العرب - بورتو جروب سابقاً	2020	4.955369	غير متعثرة
15	المطورون العرب - بورتو جروب سابقاً	2019	4.389237	غير متعثرة
15	المطورون العرب - بورتو جروب سابقاً	2018	4.623388	غير متعثرة
15	المطورون العرب - بورتو جروب سابقاً	2017	4.456209	غير متعثرة
15	المطورون العرب - بورتو جروب سابقاً	2016	6.869253	غير متعثرة
15	المطورون العرب - بورتو جروب سابقاً	2015	7.320202	
			5.646733	غير متعثرة

تقييم أداء نماذج الذكاء الاصطناعي في التنبؤ بالتعثر المالي

16	إعمار مصر	2022	5.333672	غير متعثرة
16	إعمار مصر	2021	7.22653	غير متعثرة
16	إعمار مصر	2020	4.955369	غير متعثرة
16	إعمار مصر	2019	4.389237	غير متعثرة
16	إعمار مصر	2018	4.623388	غير متعثرة
16	إعمار مصر	2017	4.456209	غير متعثرة
16	إعمار مصر	2016	6.869253	غير متعثرة
16	إعمار مصر	2015	7.320202	غير متعثرة

5.646733 غير متعثرة

17	السادس من أكتوبر	2022	7.526996	غير متعثرة
17	السادس من أكتوبر	2021	7.317651	غير متعثرة
17	السادس من أكتوبر	2020	7.755437	غير متعثرة
17	السادس من أكتوبر	2019	8.03499	غير متعثرة
17	السادس من أكتوبر	2018	7.188523	غير متعثرة
17	السادس من أكتوبر	2017	9.337902	غير متعثرة
17	السادس من أكتوبر	2016	4.249974	غير متعثرة
17	السادس من أكتوبر	2015	3.964978	غير متعثرة
17	السادس من أكتوبر	2014	16.25911	غير متعثرة
17	السادس من أكتوبر	2013	4.121084	غير متعثرة
17	السادس من أكتوبر	2012	4.19621	غير متعثرة
17	السادس من أكتوبر	2011	5.979071	غير متعثرة
17	السادس من أكتوبر	2010	47.41962	غير متعثرة
17	السادس من أكتوبر	2009	2.687666	غير متعثرة
17	السادس من أكتوبر	2008	10.33804	غير متعثرة
17	السادس من أكتوبر	2007	19.7196	غير متعثرة
			10.38105	غير متعثرة

18	ميناء للاستثمار السياحي	2022	-74.0386	متعثرة
18	ميناء للاستثمار السياحي	2021	-78.2342	متعثرة
18	ميناء للاستثمار السياحي	2020	-73.7208	متعثرة
18	ميناء للاستثمار السياحي	2019	0.809127	متعثرة
18	ميناء للاستثمار السياحي	2018	2.178423	منطقة رمادية
18	ميناء للاستثمار السياحي	2017	-0.49537	متعثرة
18	ميناء للاستثمار السياحي	2016	7.392191	غير متعثرة
18	ميناء للاستثمار السياحي	2015	-9.14449	متعثرة
18	ميناء للاستثمار السياحي	2014	0.354975	متعثرة
18	ميناء للاستثمار السياحي	2013	-10.0674	متعثرة
18	ميناء للاستثمار السياحي	2012	-6.74224	متعثرة
18	ميناء للاستثمار السياحي	2011	4.4996	غير متعثرة

غير متعثرة	6.263051	2010	مينا للاستثمار السياحي	18
غير متعثرة	6.827379	2009	مينا للاستثمار السياحي	18
غير متعثرة	7.414315	2008	مينا للاستثمار السياحي	18
غير متعثرة	19.0832	2007	مينا للاستثمار السياحي	18
متعثرة	-14.4469			

20	الاستثمار العقاري العربي	2022	10.8159	غير متعثرة
20	الاستثمار العقاري العربي	2021	14.10378	غير متعثرة
20	الاستثمار العقاري العربي	2020	11.97426	غير متعثرة
20	الاستثمار العقاري العربي	2019	12.08599	غير متعثرة
20	الاستثمار العقاري العربي	2018	10.92954	غير متعثرة
20	الاستثمار العقاري العربي	2017	11.60791	غير متعثرة
20	الاستثمار العقاري العربي	2016	7.980242	غير متعثرة
20	الاستثمار العقاري العربي	2015	9.112513	غير متعثرة
20	الاستثمار العقاري العربي	2014	20.20681	غير متعثرة
20	الاستثمار العقاري العربي	2013	8.46391	غير متعثرة
20	الاستثمار العقاري العربي	2012	17.02343	غير متعثرة
			12.20948	غير متعثرة

19	المصريين للإسكان والتنمية والتعمير	2022	11.96517	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2021	4.592627	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2020	7.861141	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2019	12.02643	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2018	6.912682	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2017	6.826913	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2016	5.348774	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2015	5.884057	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2014	12.87989	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2013	9.394331	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2012	2.026	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2011	4.574873	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2010	6.242884	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2009	7.507231	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2008	62.34335	غير متعثرة
19	المصريين للإسكان والتنمية والتعمير	2007	6.602419	غير متعثرة
			10.8118	غير متعثرة

تقييم أداء نماذج الذكاء الاصطناعي في التنبؤ بالتعثر المالي

20	الاستثمار العقاري العربي	2022	10.8159	غير متعثر
20	الاستثمار العقاري العربي	2021	14.10378	غير متعثر
20	الاستثمار العقاري العربي	2020	11.97426	غير متعثر
20	الاستثمار العقاري العربي	2019	12.08599	غير متعثر
20	الاستثمار العقاري العربي	2018	10.92954	غير متعثر
20	الاستثمار العقاري العربي	2017	11.60791	غير متعثر
20	الاستثمار العقاري العربي	2016	7.980242	غير متعثر
20	الاستثمار العقاري العربي	2015	9.112513	غير متعثر
20	الاستثمار العقاري العربي	2014	20.20681	غير متعثر
20	الاستثمار العقاري العربي	2013	8.46391	غير متعثر
20	الاستثمار العقاري العربي	2012	17.02343	غير متعثر
			12.20948	غير متعثر
21	مجموعة شركات طلعت مصطفى	2022	7.637455	غير متعثر
21	مجموعة شركات طلعت مصطفى	2021	8.406883	غير متعثر
21	مجموعة شركات طلعت مصطفى	2020	13.5086	غير متعثر
21	مجموعة شركات طلعت مصطفى	2019	11.52628	غير متعثر
21	مجموعة شركات طلعت مصطفى	2018	9.814903	غير متعثر
21	مجموعة شركات طلعت مصطفى	2017	10.79076	غير متعثر
21	مجموعة شركات طلعت مصطفى	2016	7.325884	غير متعثر
21	مجموعة شركات طلعت مصطفى	2015	7.184894	غير متعثر
21	مجموعة شركات طلعت مصطفى	2014	33.83903	غير متعثر
21	مجموعة شركات طلعت مصطفى	2013	7.541773	غير متعثر
21	مجموعة شركات طلعت مصطفى	2012	7.462454	غير متعثر
21	مجموعة شركات طلعت مصطفى	2011	6.957981	غير متعثر
21	مجموعة شركات طلعت مصطفى	2010	6.583256	غير متعثر
21	مجموعة شركات طلعت مصطفى	2009	8.415401	غير متعثر
21	مجموعة شركات طلعت مصطفى	2008	4.646971	غير متعثر
21	مجموعة شركات طلعت مصطفى	2007	4.416659	غير متعثر
			156.0592	
			9.753699	غير متعثر

22	الشركة الوطنية للإسكان نقابات المهنية	2022	50.554	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2021	3.25	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2020	-295.703	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2019	3.542018	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2018	3.25	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2017	261.6772	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2016	5.858419	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2017	5.593813	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2016	3.795612	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2015	8.574485	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2014	5.774251	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2013	6.184605	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2012	6.506915	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2011	7.498366	غير متعثرة
22	الشركة الوطنية للإسكان نقابات المهنية	2010	6.631906	غير متعثرة
			5.532587	غير متعثرة

23	العالمية للاستثمار والتنمية	2022	0.125303	متعثرة
23	العالمية للاستثمار والتنمية	2021	0.282152	متعثرة
23	العالمية للاستثمار والتنمية	2020	0.260942	متعثرة
23	العالمية للاستثمار والتنمية	2019	0.229602	متعثرة
23	العالمية للاستثمار والتنمية	2018	0.190234	متعثرة
23	العالمية للاستثمار والتنمية	2017	0.212048	متعثرة
23	العالمية للاستثمار والتنمية	2016	0.205094	متعثرة
23	العالمية للاستثمار والتنمية	2015	0.12368	متعثرة
23	العالمية للاستثمار والتنمية	2014	0.11932	متعثرة
23	العالمية للاستثمار والتنمية	2013	0.336912	متعثرة
23	العالمية للاستثمار والتنمية	2012	0.188773	متعثرة
23	العالمية للاستثمار والتنمية	2011	0.102067	متعثرة
23	العالمية للاستثمار والتنمية	2010	0.349126	متعثرة
23	العالمية للاستثمار والتنمية	2009	0.552955	متعثرة
23	العالمية للاستثمار والتنمية	2008	0.149215	متعثرة
23	العالمية للاستثمار والتنمية	2007	0.135728	متعثرة
			0.222697	متعثرة

تقييم أداء نماذج الذكاء الاصطناعي في التنبؤ بالتعثر المالي

غير متعثر	31.56439554	2022	الغربية الإسلامية للتنمية العمرانية	24
متعثر	-14.06076639	2021	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	15.29934493	2020	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	12.42125783	2019	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	9.559612428	2018	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	14.61	2017	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	11.98461741	2016	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	10.30759347	2015	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	9.773840979	2014	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	9.884260578	2013	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	60.98718301	2012	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	9.937346576	2011	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	9.186915124	2010	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	8.995496735	2009	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	8.470147303	2008	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	8.343144547	2007	الغربية الإسلامية للتنمية العمرانية	24
غير متعثر	13.57892352			
غير متعثر	8.281780595	2022	مصر الجديدة للإسكان والتعمير	25
غير متعثر	8.133683964	2021	مصر الجديدة للإسكان والتعمير	25
غير متعثر	8.246698645	2020	مصر الجديدة للإسكان والتعمير	25
غير متعثر	8.330413825	2019	مصر الجديدة للإسكان والتعمير	25
غير متعثر	5.791789573	2018	مصر الجديدة للإسكان والتعمير	25
غير متعثر	8.696464829	2017	مصر الجديدة للإسكان والتعمير	25
غير متعثر	7.431451271	2016	مصر الجديدة للإسكان والتعمير	25
غير متعثر	5.346177435	2015	مصر الجديدة للإسكان والتعمير	25
غير متعثر	4.023388145	2014	مصر الجديدة للإسكان والتعمير	25
غير متعثر	4.366907307	2013	مصر الجديدة للإسكان والتعمير	25
غير متعثر	63.51405487	2012	مصر الجديدة للإسكان والتعمير	25
غير متعثر	5.088355023	2011	مصر الجديدة للإسكان والتعمير	25
غير متعثر	6.246529497	2010	مصر الجديدة للإسكان والتعمير	25
غير متعثر	6.209148956	2009	مصر الجديدة للإسكان والتعمير	25
غير متعثر	6.825510711	2008	مصر الجديدة للإسكان والتعمير	25
غير متعثر	6.393901653	2007	مصر الجديدة للإسكان والتعمير	25
غير متعثر	10.18289102			

ملحق 2: الاحصاء الوصفي لتغيرات المستقلة الدراسة

وهي بالترتيب: المؤشرات المالية من (1-13) و مؤشرات الحوكمة من (14-18) وعوامل الاقتصاد (20-24)، خصائص الشركات (25-26)

	x1	x2	x3	x4	x5	x6													
count	6.550000e+02	655.000000	655.000000	655.000000	655.000000	655.000000	655.000000												
mean	-6.188617e+05	25.869901	6.233811	0.525290	2.968480	0.706101													
std	4.531530e+07	606.766604	63.381807	1.270820	13.740723	2.043213													
min	-8.318177e+08	-92.060859	-41.207373	0.000000	0.000000	0.000000													
25%	6.570932e-02	0.010152	0.009712	0.075461	0.000000	0.184287													
50%	2.394326e-01	0.105538	0.053162	0.205021	1.301907	0.439398													
75%	4.498928e-01	0.397568	0.117692	0.578435	1.927771	0.641937													
	x7	x8	x9	x10	x11	x12	x13	x14	x15	x16									
count	655.000000	655.000000	655.000000	655.000000	655.000000	6.550000e+02	655.000000	652.000000	653.000000	654.000000									
	x20	x21	x22	x23	x24	x25	x26												
count	655.000000	655.000000	655.000000	655.000000	655.000000	655.000000	6.550000e+02												
mean	11.419746	12.376473	11.619695	10.308397	4.389618	1998.149618	1.121464e+09												
std	6.173057	2.438665	4.970539	2.154465	1.644735	7.799018	2.944123e+09												
min	5.485400	8.750000	4.500000	7.300000	1.800000	1982.000000	2.310604e+05												
25%	6.030900	11.095000	8.600000	8.800000	3.100000	1994.000000	7.500000e+07												
50%	7.730500	11.920000	10.900000	9.600000	4.300000	1997.000000	2.667126e+08												
75%	16.884600	12.390000	12.800000	12.650000	5.300000	2000.000000	6.590849e+08												
max	24.743400	17.250000	23.300000	13.200000	7.200000	2018.000000	1.815204e+10												

المصدر: اعداد الباحثين

Evaluation of The Artificial Intelligence Models in Financial Distress Prediction in Egyptian Listed Companies during 2007-2022

Marwa Mohamad Abdel Razek

prof. Iman Moheb Zaki

Dr. Wael Mustafa Hassan

Abstract

This paper aims to evaluate artificial intelligence in financial distress prediction, to reach our purpose, we collect data from 44 Egyptian listed companies during the period of 2007-2022, ensemble learning machine and clustering algorithm were trained and tested, based on their validation test, we conclude that ensemble learning outperform clustering algorithm in prediction financial distress.

Keyword

Artificial Intelligence, Ensemble Learning Models, Clustering Algorithm, Financial Distress Prediction.

التوثيق المقترح للدراسة وفقا لنظام APA

عبد الرازق، مروة محمد، زكي، إيمان محب، حسن، وائل مصطفى (2024). تقييم أداء نماذج الذكاء الاصطناعي في التنبؤ بالتعثر المالي: دراسة تطبيقية على الشركات المقيدة في البورصة خلال الفترة من 2007-2022. مجلة جامعة الإسكندرية للعلوم الإدارية، 61(6)، 407-498.