

Comparaison des approches classiques et des modèles d'intelligence artificielle dans la prévision de la défaillance des petites entreprises : Revue de littérature

Comparison of Classical Approaches and Artificial Intelligence Models in Small Business Failure Prediction: A Literature Review

Salma BOUKAIRA

Laboratoire Business Intelligence, Gouvernance des organisations, Finance et Criminalité financière (BIGOFC), Faculté des Sciences Juridiques Économiques et Sociales Ain Chock, Université Hassan II, Casablanca, Maroc.

Mohamed DAAMOUCHE

Laboratoire Business Intelligence, Gouvernance des organisations, Finance et Criminalité financière (BIGOFC), Faculté des Sciences Juridiques Économiques et Sociales Ain Chock, Université Hassan II, Casablanca, Maroc.

Résumé. Les très petites entreprises, essentielles à l'économie mondiale, font face à des risques de défaillance importants en raison de leur vulnérabilité structurelle et de leurs ressources limitées. Dans un environnement économique de plus en plus complexe et incertain, les méthodes traditionnelles de gestion des risques montrent leurs limites, ce qui a conduit à l'exploration de solutions innovantes comme l'intelligence artificielle. Cet article examine comment des technologies avancées telles que les réseaux neuronaux et les forêts aléatoires peuvent aider les TPE à identifier de manière plus précise et proactive les signes avant-coureurs de défaillance. La méthodologie repose sur une revue approfondie de la littérature, avec une collecte de données issues de bases de données académiques. Après avoir filtré les sources pertinentes, une analyse détaillée des méthodologies et résultats a permis de comparer les modèles d'IA et les modèles classiques, en mettant en évidence les avantages et les limites de chaque approche. L'étude a révélé que l'IA offre de nouvelles opportunités pour anticiper les risques en analysant des données complexes que les méthodes traditionnelles ne sauraient exploiter. Cependant, des défis demeurent, notamment en matière de qualité des données, d'interprétabilité des modèles et d'accès aux technologies, limitant ainsi l'intégration pleine et entière de ces outils dans les processus décisionnels des TPE. Néanmoins, l'IA représente un levier potentiellement transformateur pour renforcer la résilience et la compétitivité des TPE face aux incertitudes économiques.

Mots-clés: Très Petites Entreprises ; Défaillance ; Intelligence artificielle ; Prévision ; Modèles d'IA.

Abstract. Microenterprises, which are essential to the global economy, face significant failure risks due to their structural vulnerability and limited resources. In an increasingly complex and uncertain economic environment, traditional risk management methods have shown their limitations, leading to the exploration of innovative solutions such as artificial intelligence. This paper examines how advanced technologies like neural networks and random forests can help microenterprises more accurately and proactively identify early warning signs of failure. The methodology is based on an in-depth literature review, with data collected from academic databases. After filtering relevant sources, a detailed analysis of methodologies and results allowed for a comparison of AI models and classical models, highlighting the advantages and limitations of each approach. The study revealed that AI offers new opportunities to anticipate

risks by analyzing complex data that traditional methods cannot exploit. However, challenges remain, particularly regarding data quality, model interpretability, and access to technologies, thus limiting the full integration of these tools into decision-making processes for microenterprises. Nevertheless, AI represents a potentially transformative lever to enhance the resilience and competitiveness of microenterprises in the face of economic uncertainties.

Keywords: Microenterprises, Failure, Artificial intelligence, Forecasting, AI models.

1. Introduction

Les très petites entreprises jouent un rôle fondamental dans l'économie mondiale, représentant une part significative du tissu entrepreneurial dans de nombreux secteurs. Bien qu'elles soient essentielles à la création d'emplois, à l'innovation et à la diversification des économies, elles sont également confrontées à des défis importants qui menacent leur pérennité. Leur structure de gestion souvent réduite, leurs ressources limitées et leur faible capacité d'adaptation aux évolutions économiques les rendent particulièrement vulnérables. Les causes de défaillance des TPE sont variées et multifactorielles, incluant des problèmes internes tels que la mauvaise gestion, un manque de stratégie d'innovation ou une planification financière défaillante, ainsi que des facteurs externes comme les crises économiques ou les changements réglementaires. Comme le souligne Picory et Geffroy (1995), l'incapacité d'adaptation aux évolutions du marché est une des causes majeures de l'échec des TPE. De plus, des travaux tels que ceux de Porter (1980) et Van Caillie et al. (2006) mettent en évidence que des facteurs externes comme l'intensification de la concurrence ou des perturbations économiques peuvent également mettre en péril la viabilité des entreprises.

Dans ce contexte, la gestion proactive des risques est essentielle pour la survie des TPE. La prévision des risques de défaillance est un enjeu majeur pour anticiper et minimiser ces menaces. Traditionnellement, les modèles de prévision des défaillances, tels que le Z-score d'Altman (1968), la régression logistique ou la méthode discriminante, ont été largement utilisés pour évaluer la solidité financière des entreprises. Ces modèles reposent principalement sur des ratios financiers bien établis (comme la rentabilité, la solvabilité et la structure financière) et ont montré une certaine efficacité dans des environnements économiques relativement stables. Cependant, dans des contextes économiques plus complexes et dynamiques, ces approches traditionnelles présentent plusieurs limites. Les critiques formulées par Ohlson (1980) et Beaver (1966) soulignent que ces modèles peinent à saisir la complexité des relations non linéaires entre les différentes variables économiques. En outre, ces modèles classiques sont souvent incapables d'intégrer des facteurs exogènes, comme les crises économiques ou les changements réglementaires, qui peuvent avoir un impact majeur sur la défaillance des entreprises.

L'intelligence artificielle, avec ses capacités avancées de traitement des données massives et de modélisation des comportements complexes, constitue une réponse prometteuse à ces limitations. Les modèles basés sur l'IA, tels que les réseaux neuronaux et les forêts aléatoires offrent une approche plus flexible et robuste pour la prévision des défaillances des entreprises. Zhang et al. (1999) ont démontré que les réseaux neuronaux, en raison de leur capacité à modéliser des relations non linéaires, peuvent fournir des prévisions plus précises que les approches traditionnelles telles que le Z-score.

Ces techniques d'IA présentent l'avantage supplémentaire d'être capables de s'adapter aux évolutions économiques et sectorielles, et de traiter des variables complexes et interconnectées, offrant ainsi une meilleure visibilité sur les risques de défaillance que les modèles traditionnels. Toutefois, malgré ces avantages indéniables, l'adoption de l'IA dans les TPE pose plusieurs défis. Ceci nous mène à poser la question : *Dans quelle mesure les modèles basés sur l'intelligence artificielle peuvent-ils améliorer la prévision de défaillance des très petites entreprises, comparativement aux modèles traditionnels, tout en surmontant les défis liés à l'adaptation de ces technologies aux contraintes spécifiques des TPE ?*

Cette revue de littérature examine l'impact de l'intelligence artificielle dans la gestion des risques de défaillance d'entreprise, en comparant les performances des modèles traditionnels de prévision à celles des modèles basés sur l'IA. L'objectif de l'étude est d'analyser dans quelle mesure ces approches innovantes, telles que les réseaux neuronaux, les forêts aléatoires, ou les réseaux neuronaux récurrents (RNN) offrent une meilleure capacité de détection précoce des signes de défaillance, grâce à leur aptitude à traiter des données complexes, massives et en évolution constante. Si cette comparaison s'appuie sur des études portant majoritairement sur des entreprises de tailles diverses, une attention particulière est portée aux très petites entreprises, pour lesquelles l'adoption de ces technologies pose des enjeux spécifiques.

L'originalité de cette étude réside précisément dans cette mise en perspective : elle ne se limite pas à évaluer les performances techniques des modèles, mais s'attache à discuter les opportunités et les limites de leur adoption dans le contexte particulier des TPE. Ces dernières, souvent limitées en ressources humaines, financières et technologiques, rencontrent des obstacles significatifs dans l'appropriation de l'IA, notamment en ce qui concerne la qualité des données disponibles, l'interprétabilité des algorithmes et l'accessibilité des outils. La valeur ajoutée de cette revue tient ainsi à sa capacité à articuler les apports des avancées technologiques à une réflexion pragmatique sur les conditions d'une intégration effective et utile de l'IA dans les pratiques de gestion des risques propres aux TPE, contribuant ainsi à leur résilience dans un environnement économique incertain.

Cette étude repose, dans un premier temps, sur une revue approfondie de la littérature existante relative à l'impact de l'intelligence artificielle sur la prévision de la défaillance des entreprises, en mettant l'accent sur les très petites entreprises. La méthodologie adoptée comprend une phase de collecte et de sélection des sources à partir de bases de données académiques précises, à savoir Cairn, ScienceDirect, ResearchGate et Google Scholar. Ces plateformes ont permis d'accéder à une diversité de publications scientifiques et d'études de cas pertinentes, en français et en anglais, afin d'assurer une couverture thématique et géographique étendue. La sélection des articles s'est effectuée en deux étapes : un premier filtrage basé sur les titres et résumés, en retenant ceux portant directement sur la prévision des défaillances d'entreprise par l'intelligence artificielle ; puis une lecture approfondie des publications retenues, avec un examen attentif de leur méthodologie, de leurs résultats et de leur contribution au sujet. Dans un second temps, l'étude s'est articulée autour d'une synthèse structurée des résultats, en identifiant les facteurs influençant spécifiquement la défaillance des TPE, puis en comparant les modèles traditionnels et ceux fondés sur l'intelligence artificielle. Une section centrale est dédiée à l'analyse comparative des performances issues de différentes recherches empiriques. Enfin, une discussion critique met en lumière les bénéfices potentiels, les limites techniques et organisationnelles, ainsi que les conditions concrètes d'intégration de l'IA dans les pratiques de gestion des risques au sein des TPE.

2. Méthodologie

Cette étude s'appuie sur une revue de la littérature existante relative à l'impact de l'intelligence artificielle sur les très petites entreprises. Les sources consultées comprennent des articles académiques ainsi que des études de cas.

a. Collecte et repérage des articles

Les données de cette étude ont été collectées à partir de plusieurs bases de données électroniques, à savoir : Cairn, ScienceDirect, ResearchGate et Google Scholar, qui offrent un accès à des articles scientifiques et à des publications académiques pertinentes. Afin d'assurer une couverture étendue et représentative, des articles rédigés en français et en anglais ont été inclus, permettant ainsi de prendre en compte les contextes spécifiques ainsi que les perspectives locales concernant

l'intégration de l'intelligence artificielle dans la prévision de la défaillance des très petites entreprises.

b. Analyse des données collectées

Pour la sélection des articles, nous avons adopté une approche en deux étapes. Dans un premier temps, nous avons filtré les titres et résumés des articles, en privilégiant ceux qui traitaient directement de la prévision des défaillances des très petites entreprises et de l'utilisation de l'intelligence artificielle dans ce domaine spécifique. Dans un second temps, nous avons analysé l'intégralité des articles retenus, en nous concentrant particulièrement sur leur méthodologie et leurs résultats. Nous avons priorisé les articles se concentrant directement sur la prévision des défaillances des TPE, puis ceux qui examinaient cet aspect dans des entreprises de différentes tailles. Cette approche nous a permis de sélectionner des sources à la fois pertinentes et récentes, spécifiquement axées sur l'impact de l'IA dans la prévision des défaillances des TPE.

3. Synthèse des résultats

Les risques de défaillance d'une entreprise sont définis comme la probabilité que celle-ci ne soit plus en mesure d'honorer ses dettes à court ou moyen terme, en raison d'une gestion financière inappropriée, d'une baisse de rentabilité, ou de l'incapacité à générer des flux de trésorerie positifs (Altman, 1968). Les TPE, en raison de leurs ressources limitées, sont particulièrement vulnérables à ces risques, et la prévision de la défaillance devient un élément stratégique crucial pour leur pérennité.

a. Facteurs influençant la défaillance des TPE

Les défaillances des très petites entreprises sont souvent le résultat d'une combinaison de facteurs internes et externes, qui influencent leur stabilité et leur pérennité. Parmi ces facteurs, les dimensions stratégiques, organisationnelles et managériales jouent un rôle crucial dans la réussite ou l'échec des entreprises. En effet, l'absence de stratégie d'innovation est fréquemment citée comme une cause de défaillance, les TPE peinant à s'adapter aux évolutions du marché (Picory et Geffroy, 1995 ; Van Caillie et al., 2006). Selon le modèle des 5 (+1) forces de Porter (1980), des facteurs externes comme la concurrence accrue ou les changements dans l'environnement économique peuvent également avoir un impact direct sur la viabilité des entreprises. Cette analyse est soutenue par Guilhot (2000) et Ooghe & Waeyaert (2004), qui soulignent l'importance des forces du marché dans l'échec des TPE. En parallèle, les problèmes organisationnels et managériaux, tels que l'inadaptation des structures internes, la mauvaise gestion ou des erreurs stratégiques, sont des causes de défaillance souvent évoquées. Coulibaly (2004) met également en évidence l'influence de la personnalité du dirigeant et de l'environnement socioculturel sur la prise de décision. D'autres recherches montrent que la qualité de gestion, un manque d'expérience et une mauvaise anticipation des évolutions concurrentielles peuvent accroître la vulnérabilité des entreprises (Pompe & Bilderbeek, 2005 ; Thornhill & Amit, 2003). Ces différents éléments soulignent la complexité des facteurs contribuant à la défaillance des TPE et l'importance d'une gestion agile et d'une stratégie d'adaptation pour minimiser les risques.

b. Les modèles traditionnels de prévision de la défaillance

Les modèles traditionnels de prévision de la défaillance des entreprises, tels que le Z-score d'Altman (1968), la régression logistique et la méthode discriminante, ont longtemps dominé les analyses financières en raison de leur simplicité et de leur efficacité dans des contextes relativement stables. Ces outils, basés sur des ratios financiers bien établis, ont permis d'évaluer la solidité financière des entreprises en se concentrant sur des indicateurs classiques tels que la rentabilité, la solvabilité et la structure financière. Toutefois, dans le cadre des environnements économiques contemporains, particulièrement pour les très petites entreprises, ces modèles

traditionnels présentent des limites importantes, tant en termes de leur capacité à intégrer des données complexes que de leur adaptabilité face à des dynamiques de marché toujours plus volatiles et imprévisibles.

L'une des principales critiques formulées à l'encontre de ces approches réside dans leur incapacité à capturer des relations non linéaires et interconnectées entre les différentes variables économiques. Ohlson (1980) a souligné que la régression logistique, bien que robuste dans de nombreux cas, échoue à prendre en compte la complexité des interactions économiques, en particulier dans des environnements dynamiques. Ce modèle repose sur des relations linéaires qui, par nature, ne peuvent pas refléter la réalité d'un marché où les phénomènes sont souvent interconnectés de manière non triviale. Ainsi, la régression logistique s'avère insuffisante pour saisir l'ensemble des nuances influençant la défaillance des entreprises, en particulier dans des périodes de turbulence économique ou de changements rapides.

Par ailleurs, le Z-score d'Altman, qui combine plusieurs ratios financiers pour fournir un indice de solvabilité, n'échappe pas aux mêmes limitations. Ce modèle, bien qu'ayant prouvé son efficacité dans les années 1960, ne parvient pas à s'adapter aux contextes économiques contemporains, où la structure financière des entreprises devient de plus en plus complexe et variée. Beaver (1966) a ainsi critiqué la capacité du Z-score à ignorer l'interdépendance des variables, ce qui peut conduire à des erreurs d'appréciation dans les périodes de récession ou d'instabilité financière. De même, Altman (1984) lui-même a reconnu que son modèle, conçu pour un environnement économique spécifique, n'était plus aussi pertinent face à des évolutions économiques imprévisibles et des structures d'entreprises de plus en plus diversifiées.

Une autre critique récurrente concerne la difficulté de ces modèles à intégrer des facteurs exogènes qui peuvent influencer de manière décisive la défaillance des entreprises. Les événements extérieurs tels que les crises économiques, les changements politiques ou les catastrophes naturelles, souvent ignorés par ces modèles financiers classiques, peuvent avoir un impact majeur sur la survie des entreprises.

Bien que les modèles traditionnels comme le Z-score, la régression logistique et la méthode discriminante aient fourni des résultats satisfaisants dans des contextes économiques plus simples et stables, ils présentent désormais des limites notables dans la prévision des défaillances des entreprises, en particulier dans des environnements économiques complexes et dynamiques. Ces modèles peinent à saisir la diversité des facteurs influençant la santé financière des TPE et ne parviennent pas à anticiper les crises ni à intégrer les interactions complexes entre variables. Dès lors, il devient impératif de se tourner vers des approches plus modernes et plus flexibles, capables de traiter des données complexes et d'adopter une vision plus holistique des facteurs de défaillance.

c. L'impact de l'intelligence artificielle dans la prévision de la défaillance

Les modèles de prévision des défaillances basés sur l'intelligence artificielle, tels que les réseaux neuronaux représentent une avancée significative par rapport aux modèles traditionnels. Ces approches sont capables de traiter des volumes de données massifs et d'intégrer des informations non structurées, comme des textes ou des données comportementales, ce qui les rend particulièrement efficaces pour les petites et moyennes entreprises, souvent caractérisées par des données complexes et peu structurées. Selon Zhang et al. (1999), les réseaux neuronaux sont capables de modéliser des relations complexes et non linéaires entre les différentes variables, ce qui leur permet de fournir des prévisions plus précises que les modèles classiques comme le Z-score d'Altman. En outre, les SVM, en raison de leur capacité à maximiser les marges entre les classes de données, permettent une meilleure généralisation, ce qui améliore la robustesse du modèle dans des contextes économiques variés (Cortes et Vapnik, 1995). Ces modèles d'IA sont également capables d'adapter leurs performances en fonction des évolutions économiques et

sectorielles, rendant ainsi les prévisions plus dynamiques et adaptées à l'environnement changeant des entreprises.

i. Comparaison des modèles d'intelligence artificielle et modèles classiques pour la prédiction de défaillance : Arbre de décision, AdaBoost, Gradient Boosting, SVM, Régression logistique et Naive Bayes (Máté et al., 2023)

Dans cette étude, plusieurs modèles d'apprentissage automatique ont été utilisés pour prédire la faillite des entreprises pakistanaises en se basant sur des ratios financiers tels que le ROA, le ROA opérationnel, le ratio de couverture de la dette, etc. Parmi les modèles testés, les arbres de décision, AdaBoost et Gradient Boosting ont montré les meilleures performances, atteignant une précision parfaite (100%) pour tous les ensembles de caractéristiques. Les modèles Support Vector Machine (SVM) et Régression Logistique (LR) ont également bien performé, avec une précision variant de 89 % à 99 %, s'améliorant à mesure que le nombre de caractéristiques augmentait. En revanche, le modèle Naive Bayes (NB) a présenté la plus faible précision (58 % à 70 %), bien que son taux de rappel élevé ait indiqué sa force pour détecter les entreprises en faillite. L'échantillon utilisé dans l'étude comprend des entreprises non financières du Pakistan, ce qui permet de mieux comprendre les dynamiques financières locales. Cette étude montre que les modèles d'apprentissage automatique, notamment les méthodes d'ensemble, surpassent les modèles traditionnels comme le Z-Score d'Altman en termes d'adaptabilité et de précision, offrant ainsi des prédictions de faillite plus fiables. Ces résultats suggèrent que l'apprentissage automatique peut améliorer considérablement l'évaluation des risques financiers pour les entreprises pakistanaises, bien que des études futures devraient affiner le choix des modèles et traiter les biais des données pour garantir une plus grande applicabilité.

ii. Comparaison des modèles d'intelligence artificielle et modèles classiques pour la prédiction de défaillance : Forêt Aléatoire, SVM, Réseaux de Neurones, Régression Logistique Linéaire, Régression Logistique Non Linéaire, et Régression Logistique Pénalisée (Dumitrescu et al., 2022)

Dans cette étude, la performance de la méthode de régression logistique arborescente pénalisée (Penalized Logistic Tree Regression) est comparée à celle de plusieurs modèles traditionnels et modernes utilisés pour la prédiction de la défaillance. Ces modèles incluent la régression logistique linéaire et non linéaire (avec des termes quadratiques et d'interaction), la régression logistique pénalisée, le random forest, le support vector machine (SVM) et le réseau de neurones (NN). L'évaluation est réalisée sur quatre ensembles de données réels issus du domaine du scoring de crédit, à savoir Kaggle, Australian, Housing et Taiwan, en utilisant la validation croisée 5 × 2 pour mesurer la performance sur des statistiques comme l'AUC, le PGI, le KS, et la BS. Les résultats montrent que la régression logistique arborescente pénalisée (PLTR) surpasse la régression logistique classique sur la plupart des métriques, avec des performances proches de celles du random forest, tout en offrant une meilleure interprétabilité grâce à l'utilisation de règles basées sur des arbres de décision peu profonds. Enfin, l'analyse économique met en évidence que PLTR génère des réductions de coûts de mauvaise classification importantes par rapport aux autres modèles, ce qui le rend attractif d'un point de vue pratique tout en restant compréhensible pour les parties prenantes.

iii. Comparaison entre le modèle d'apprentissage profond (IA) et le modèle de risque discret (Alam et al, 2021)

Dans cette étude, deux modèles de prédiction des défaillances d'entreprises sont comparés : un modèle d'apprentissage profond (IA) et un modèle de risque discret traditionnel, tous deux appliqués aux données financières et de marché d'entreprises cotées en Amérique du Nord. Le modèle de risque discret traditionnel repose sur des méthodes statistiques classiques, souvent

utilisées dans le domaine financier pour évaluer la probabilité de défaut d'une entreprise en fonction de divers indicateurs économiques et financiers. Ce modèle, tout en étant efficace, peut être limité par sa capacité à capturer des relations complexes et non linéaires dans les données, ce qui peut nuire à sa précision.

En revanche, le modèle d'apprentissage profond est capable de traiter de grandes quantités de données et de détecter des relations complexes et non linéaires, ce qui en fait un outil particulièrement puissant pour des tâches de prédiction dans des ensembles de données complexes comme ceux des entreprises cotées. L'étude montre que ce modèle a atteint une précision de 93,71 % pour prédire les défaillances, contre 86,95 % pour le modèle traditionnel. Cela illustre non seulement la supériorité de l'apprentissage profond en termes de performance, mais aussi sa capacité à mieux s'adapter aux complexités des données financières et de marché sur de grandes périodes et échantillons.

Ainsi, bien que les deux modèles puissent être utiles, le modèle d'apprentissage profond semble offrir des résultats significativement meilleurs dans le contexte de la prédiction des défaillances d'entreprises dans des ensembles de données de panel.

iv. Comparaison des modèles d'intelligence artificielle et modèles classiques pour la prédiction de défaillance : Réseau de Neurones Profonds – DNN, Forêt Aléatoire – RF, Analyse Discriminante Linéaire - LDA, Régression Logistique - LR, Arbres de Décision - DT, Machine à Vecteurs de Support - SVM (Hamdi et al., 2024)

Cet article compare plusieurs modèles de prévision de la défaillance des entreprises en utilisant des techniques d'intelligence artificielle et des modèles traditionnels de statistiques et d'apprentissage automatique. Les modèles évalués incluent la Machine à Vecteurs de Support (SVM), le Réseau de Neurones Profonds (DNN), qui fait partie des approches d'apprentissage profond, ainsi que des méthodes classiques telles que l'Analyse Discriminante Linéaire (LDA), la Régression Logistique (LR), les Arbres de Décision (DT), et la Forêt Aléatoire (RF).

L'étude se concentre sur la prévision des défaillances des entreprises tunisiennes à partir de 25 ratios financiers, en utilisant un échantillon de 732 entreprises sur la période 2011-2017. Trois mesures de performance ont été choisies pour évaluer l'efficacité prédictive de ces modèles : le taux de précision (accuracy), le score F1 (qui combine précision et rappel) et l'Aire Sous la Courbe (AUC), qui mesure la capacité de chaque modèle à distinguer les entreprises défaillantes de celles non défaillantes.

Les résultats montrent que le modèle de Réseau de Neurones Profonds (DNN) surpasse les autres techniques classiques en termes de précision prédictive, offrant ainsi une solution plus fiable pour prévoir les défaillances des entreprises. Cependant, la Forêt Aléatoire (RF), bien qu'elle soit une méthode d'apprentissage automatique, a également montré une excellente performance, surpassant les autres approches statistiques et d'apprentissage automatique comme l'Analyse Discriminante Linéaire (LDA), la Régression Logistique (LR), les Arbres de Décision (DT) et la Machine à Vecteurs de Support (SVM).

v. Comparaison des modèles d'intelligence artificielle et modèles classiques pour la prédiction de défaillance : Réseaux de Neurones Profonds – DNN, Régression Logistique, Arbres de Décision, et Machine à Vecteurs de Support (Chen and Mao, 2024)

Cette étude se concentre sur la comparaison de cinq modèles de prédiction des défaillances d'entreprises, répartis entre deux grandes catégories : les modèles traditionnels d'apprentissage automatique et les modèles d'apprentissage profond (intelligence artificielle). Les modèles traditionnels incluent la Régression Logistique (LR), les Arbres de Décision (DT) et la Machine à Vecteurs de Support (SVM), tandis que les modèles d'apprentissage profond sont représentés par les Réseaux de Neurones Profonds (DNN).

Les caractéristiques utilisées pour la prédiction des défaillances ont été extraites des états financiers publics des entreprises, couvrant ainsi des informations pertinentes telles que les ratios financiers, la rentabilité, la solvabilité, et la liquidité. L'entraînement des modèles ainsi que les tests ont été réalisés à partir de ces données financières, permettant d'évaluer leur performance dans des conditions réalistes.

Les résultats expérimentaux ont révélé que les modèles d'apprentissage profond (notamment les Réseaux de Neurones Profonds (DNN)) ont surpassé les modèles traditionnels en termes de précision, de rappel et de score F1, offrant ainsi une meilleure capacité à prédire la défaillance des entreprises, notamment dans des situations où des relations complexes et non linéaires sont présentes dans les données.

Cependant, bien que les modèles d'apprentissage profond aient montré des performances supérieures de manière générale, certains modèles traditionnels d'apprentissage automatique, comme les Arbres de Décision (DT) et la Machine à Vecteurs de Support (SVM), ont également montré de bons résultats dans des contextes spécifiques, comme la gestion de petites quantités de données ou des scénarios où des modèles simples sont préférés pour leur interprétabilité.

vi. Comparaison entre le modèle C5.0, CART et les Réseaux de Neurones Artificiels - ANN pour la prédiction du succès ou de l'échec financier des entreprises (Aksoy and Boztosun, 2018)

Cette étude compare trois modèles différents de prédiction du succès ou de l'échec financier d'entreprises, en se concentrant sur des entreprises opérant dans le secteur de la fabrication de la Bourse d'Istanbul (BIST) entre 2006 et 2009. L'échantillon comprend 126 entreprises, avec un ensemble de 25 variables quantitatives et 4 variables qualitatives extraites des états financiers et d'autres sources pertinentes.

Les modèles analysés sont les Réseaux de Neurones Artificiels (ANN), un modèle d'apprentissage profond, l'Algorithme de Classification C5.0, qui fait partie des modèles traditionnels d'apprentissage automatique, et les Arbres de Classification et de Régression (CART), un modèle classique également utilisé en apprentissage supervisé.

Les résultats expérimentaux ont montré l'efficacité de chaque modèle dans la prédiction de l'échec ou du succès financier des entreprises sur trois périodes (2006, 2007, 2008). Les Arbres de Classification et de Régression (CART) ont obtenu la meilleure précision globale de classification pour les trois années étudiées. En 2006 (trois ans avant l'événement), la précision était de 84,21 % pour CART, suivie de 81,58 % pour les Réseaux de Neurones Artificiels (ANN) et 76,32 % pour C5.0. En 2007 (deux ans avant), CART a atteint 86,84 %, suivi de 84,21 % pour ANN et 78,95 % pour C5.0. En 2008 (un an avant), les ANN et CART ont obtenu la même précision de 92,11 %, tandis que C5.0 a atteint 86,84 %.

Ce qui distingue particulièrement les modèles ANN et CART, c'est leur capacité à prédire l'échec financier imminent des entreprises avec une précision de 100 % un an avant l'événement, ce qui met en évidence leur potentiel pour une intégration dans les outils utilisés par les parties prenantes, comme les investisseurs ou les gestionnaires, pour une gestion proactive des risques financiers.

Bien que CART ait légèrement surpassé les autres modèles en termes de précision générale, les ANN et CART se révèlent être des modèles robustes pour la détection précoce des échecs financiers, avec une précision particulièrement élevée à l'approche de l'échec.

vii. Comparaison entre les réseaux neuronaux artificiels (ANN) et la régression logistique (Logit) pour la prédiction de la détresse financière des entreprises du secteur industriel indonésien (Kristanti et al., 2023)

Cette étude se concentre sur l'analyse de la prédiction de la détresse financière des entreprises du secteur industriel en Indonésie, en se basant sur des ratios financiers spécifiques. Dans un

contexte économique mondial incertain, où les crises peuvent exacerber le risque de faillite, il devient essentiel pour les investisseurs, les dirigeants d'entreprise et les régulateurs de disposer d'outils précis pour évaluer la santé financière des entreprises et prendre des décisions stratégiques éclairées. L'étude compare deux modèles de prédiction de la détresse financière : les réseaux neuronaux artificiels (ANN), un modèle d'intelligence artificielle, et la régression logistique (Logit), un modèle traditionnel d'apprentissage statistique.

L'échantillon étudié comprend des entreprises inscrites à la Bourse indonésienne (IDX) dans le secteur industriel, sur la période 2017-2021. Pour les prédictions, l'étude utilise une série de ratios financiers, qui sont des indicateurs cruciaux pour évaluer la solvabilité et la liquidité des entreprises. Les variables incluent le ratio de liquidité (CR), le retour sur actifs (ROA), le ratio dette sur actifs, le turnover des actifs totaux et le ratio de flux de trésorerie sur la dette.

Les résultats expérimentaux montrent que le modèle Logit surpasse nettement le modèle ANN en termes de précision. En effet, la précision du modèle Logit est de 98%, avec une sensibilité de 94,20% et une spécificité de 99,30%, ce qui indique qu'il est très performant pour prédire les entreprises en détresse financière et éviter les faux positifs. En revanche, le modèle ANN, bien qu'il soit un modèle d'IA puissant capable de détecter des relations non linéaires complexes dans les données, a montré une précision de seulement 82,50%, avec une sensibilité de 84% et une spécificité de 82%. Ces résultats suggèrent que, bien que les réseaux neuronaux artificiels aient des capacités impressionnantes, le modèle Logit, plus simple et plus interprétable, offre des performances supérieures pour ce type de prédiction spécifique dans le secteur industriel indonésien.

L'étude montre que, dans ce contexte précis, le modèle Logit peut être une option plus fiable pour prédire la détresse financière, permettant ainsi aux investisseurs, entrepreneurs et régulateurs de prendre des décisions plus précises pour prévenir la faillite des entreprises. Ce modèle peut ainsi jouer un rôle clé dans la gestion des risques financiers dans le secteur industriel en Indonésie, surtout en période de crise économique.

Ce tableau qui suit synthétise donc les principales études présentées, comparant les performances des modèles traditionnels et des modèles basés sur l'intelligence artificielle dans la prédiction de la défaillance des entreprises. Il met en évidence la diversité des approches utilisées dans la littérature, en distinguant clairement les modèles classiques — tels que la régression logistique (LR), l'analyse discriminante linéaire (LDA), le modèle Logit, ou encore le Naive Bayes — des modèles d'IA, qui incluent notamment les arbres de décision (DT), les forêts aléatoires (RF), les réseaux de neurones artificiels (ANN), les réseaux de neurones profonds (DNN), ainsi que les algorithmes d'ensemble comme AdaBoost et Gradient Boosting.

Tableau 1 : Comparaison des modèles traditionnels et des modèles basés sur l'intelligence artificielle dans la prédiction de la défaillance des entreprises : synthèse des études empiriques

Étude	Modèles traditionnels	Modèles basés sur l'IA	Résultats principaux
Maté et al. (2023)	Régression Logistique (LR), Naive Bayes (NB), Z-Score d'Altman, Machine à Vecteurs de Support (SVM)	Arbre de Décision, AdaBoost, Gradient Boosting,	Arbres de décision et méthodes d'ensemble (AdaBoost, Gradient Boosting) ont atteint 100 % de précision. NB a obtenu de faibles résultats.
Dumitrescu et al. (2022)	Régression Logistique (linéaire, non linéaire, pénalisée), Machine à Vecteurs de Support (SVM)	Forêt Aléatoire (RF), Réseaux de Neurons (NN)	La méthode PLTR surpasse les modèles traditionnels et approche les performances du RF, avec une meilleure interprétabilité.
Alam et al. (2021)	Modèle de risque discret	Apprentissage profond	L'IA atteint une précision de 93,71 % contre 86,95 % pour le modèle traditionnel. L'IA gère mieux les données complexes.
Hamdi et al. (2024)	Régression logistique, Analyse discriminante linéaire, Machine à Vecteurs de Support (SVM)	Réseau de neurones profonds (DNN), Forêt aléatoire (RF), Arbre de décision (DT)	DNN surpasse tous les autres. RF performe aussi très bien, mieux que les modèles statistiques.
Chen and Mao (2024)	Régression logistique, Machine à Vecteurs de Support (SVM)	Arbres de décision (DT), Réseau de neurones profonds (DNN)	DNN offre de meilleures performances globales (précision, rappel, F1). Toutefois, DT et SVM restent utiles dans certains contextes.
Aksoy and Boztosun (2018)	C5.0, CART	Réseaux de neurones artificiels (ANN)	CART obtient les meilleurs résultats globaux, mais ANN atteint 100 % de précision un an avant l'échec.
Kristanti et al. (2023)	Régression Logistique (Logit)	Réseaux de neurones artificiels (ANN)	Le modèle Logit surpasse ANN en précision et en fiabilité. ANN montre des limites dans ce contexte spécifique.

Source : Auteur.

On constate que les modèles d'IA, en particulier ceux utilisant l'apprentissage profond, tendent à surpasser les modèles traditionnels en termes de précision, de capacité à modéliser des relations non linéaires, et d'adaptabilité à des données complexes. Cependant, certaines études montrent que dans des contextes spécifiques, des modèles plus simples comme la régression logistique ou les arbres de décision classiques peuvent encore offrir de très bonnes

performances, notamment en matière d'interprétabilité ou lorsqu'on dispose de peu de données. Cette récapitulation permet ainsi de mieux cerner les atouts et limites de chaque catégorie de modèles, tout en soulignant la montée en puissance des techniques d'IA dans la gestion prédictive des risques de défaillance.

4. Discussion

La comparaison des modèles d'intelligence artificielle et des modèles traditionnels dans la prédiction des défaillances financières des entreprises révèle des différences marquées en termes de performances, d'adaptabilité et de capacité à traiter des relations complexes entre variables économiques. Le présent article, à travers l'examen de plusieurs cas pratiques, met en lumière les avantages distincts des modèles d'IA par rapport aux approches traditionnelles telles que la régression logistique et les arbres de décision classiques. Les résultats des études de Máté et al. (2023), Kristanti et al. (2023), ainsi que de Hamdi et al. (2024), montrent que les modèles d'IA, en particulier les réseaux neuronaux profonds (DNN), et les forêts aléatoires (RF) surpassent souvent les modèles traditionnels comme la régression logistique, les arbres de décision et l'analyse discriminante linéaire (LDA) en termes de précision et de capacité à capturer des relations non linéaires complexes entre les variables financières. Les réseaux neuronaux, en particulier, ont démontré leur efficacité dans des contextes où les données sont riches et complexes, permettant de mieux gérer les non-linéarités et d'améliorer la précision des prédictions de défaillance des entreprises, comme l'indiquent les travaux de Zhang et al. (1999) et Nanni et Lumini (2009). Cependant, bien que les modèles d'IA offrent une supériorité en termes de précision, certains modèles traditionnels, tels que le Z-score d'Altman ou la régression logistique, restent compétitifs pour des jeux de données plus simples ou dans des contextes où l'interprétabilité est cruciale. Ces modèles permettent une interprétation plus claire des résultats, ce qui est un avantage pour les parties prenantes qui privilégient la transparence et la compréhension des facteurs sous-jacents à la prédiction (Ohlson, 1980). Par exemple, l'étude de Kristanti et Dhaniswara (2023) dans le secteur industriel indonésien a montré que le modèle Logit, bien que plus simple que les réseaux neuronaux, a obtenu des performances supérieures en termes de précision, de sensibilité et de spécificité, particulièrement dans un environnement où la clarté du modèle est essentielle pour les décideurs.

Les systèmes hybrides, qui combinent plusieurs modèles d'IA pour en exploiter les forces complémentaires, ont également montré des performances supérieures par rapport aux modèles individuels. Par exemple, dans l'étude de Nanni et Lumini (2009), l'utilisation d'ensembles de classificateurs, combinant SVM et réseaux neuronaux, a permis de réduire les taux d'erreur tout en offrant des résultats robustes. Cette approche hybride semble être une stratégie efficace pour traiter des ensembles de données financiers complexes, où des modèles simples peuvent ne pas suffire à capturer toute la richesse des relations entre les variables. Il convient de noter que la performance des modèles d'IA dépend fortement de la qualité et de la quantité des données disponibles. Les modèles comme le DNN qui ont montré des performances exceptionnelles dans des études sur des jeux de données plus vastes et riches (Hamdi et al., 2024), peuvent ne pas être aussi efficaces avec des jeux de données plus petits ou avec des informations limitées. Dans de tels cas, des modèles plus simples, comme la régression logistique ou les arbres de décision, pourraient offrir un meilleur compromis entre précision et interprétabilité, comme l'illustre l'étude de Kristanti et Dhaniswara (2023) dans le contexte indonésien. L'analyse économique présentée par Dumitrescu et al. (2022) montre que des modèles comme la régression logistique pénalisée (PLTR) peuvent offrir un bon équilibre entre performance prédictive et interprétabilité. Ce modèle, bien que performant, s'appuie sur des règles basées sur des arbres de décision peu profonds, offrant ainsi une meilleure transparence et une réduction significative des coûts de mauvaise classification. Dans ce contexte, il devient essentiel de prendre en compte les coûts associés aux faux positifs et aux faux négatifs dans les

décisions pratiques.

Bien que les modèles d'IA, en particulier les DNN, aient montré une grande promesse dans la prédiction des faillites, la question de leur adoption à grande échelle reste influencée par plusieurs facteurs pratiques. En particulier, l'interprétabilité des modèles et leur capacité à s'adapter à des environnements économiques dynamiques sont des critères cruciaux pour les institutions financières et les régulateurs. À cet égard, des études futures pourraient se concentrer sur l'optimisation de l'interprétabilité des modèles d'IA ou sur le développement de modèles hybrides, combinant à la fois des approches traditionnelles et des techniques modernes d'IA pour répondre à ces défis.

Malgré les avantages considérables que présente l'utilisation de l'intelligence artificielle, plusieurs limites et défis demeurent. Les modèles d'IA sont fortement dépendants de la qualité des données utilisées pour l'entraînement et la validation. Les erreurs, les valeurs manquantes, ou même la présence de biais dans les données peuvent altérer significativement les résultats. Par exemple, si un modèle est formé avec des données historiques biaisées ou non représentatives, il risque de produire des prédictions erronées ou injustes, surtout lorsqu'il est appliqué à de nouveaux ensembles de données. De plus, les entreprises évoluent dans des environnements économiques variés, et la collecte de données pertinentes et actualisées reste un défi constant. Les modèles d'IA, particulièrement les réseaux neuronaux profonds et les techniques de machine learning complexes, sont souvent considérés comme des "boîtes noires". Cela signifie qu'il peut être difficile pour les experts humains de comprendre comment le modèle est parvenu à une conclusion spécifique. Cette absence d'interprétabilité limite l'acceptation des résultats dans des domaines comme la finance, où la transparence est cruciale pour les décideurs, les régulateurs et les parties prenantes. Les parties prenantes peuvent hésiter à prendre des décisions basées sur des résultats qu'elles ne comprennent pas pleinement, en particulier dans des contextes réglementés. Par ailleurs, les modèles d'IA avancés, en particulier les réseaux neuronaux et les méthodes d'apprentissage profond, nécessitent des ressources computationnelles importantes pour l'entraînement et la mise en œuvre. Cela peut entraîner des coûts élevés en termes de puissance de calcul, de stockage des données, et de temps d'entraînement, rendant ces solutions potentiellement inaccessibles pour les petites et moyennes entreprises. De plus, la gestion de grands ensembles de données, notamment dans le cadre de données financières en temps réel ou de données non structurées, peut devenir complexe. L'un des défis majeurs lors de l'utilisation des modèles d'IA est le surapprentissage (overfitting), où un modèle devient trop ajusté aux données d'entraînement et perd sa capacité à généraliser sur de nouvelles données. Cela peut entraîner des performances dégradées lorsqu'il est appliqué à des données réelles ou non vues. Les modèles d'IA, en particulier les modèles complexes, sont susceptibles de capter des bruitages et des variations mineures dans les données d'entraînement, ce qui les rend moins efficaces dans la pratique. Les modèles d'IA qui réussissent dans un environnement de marché donné peuvent devenir obsolètes ou moins performants face à des évolutions économiques rapides, des changements dans les réglementations ou des crises financières imprévues. L'adaptabilité des modèles est donc cruciale, mais elle nécessite un suivi constant et un réajustement des modèles pour tenir compte des nouvelles tendances économiques. Ce processus d'adaptation peut être coûteux et chronophage. Les modèles d'IA peuvent reproduire ou même exacerber des biais existants dans les données. Par exemple, si les données historiques reflètent des inégalités structurelles (comme des biais en fonction du sexe, de l'âge ou de l'origine ethnique), ces biais peuvent être captés par le modèle et se traduire par des prévisions injustes ou discriminatoires. La gestion des biais algorithmique devient un défi majeur pour garantir que les décisions prises à partir des prédictions des modèles soient éthiques, impartiales et conformes aux réglementations sur la non-discrimination. Une autre limitation est la dépendance accrue aux systèmes automatisés pour la prise de décisions financières importantes. Si ces systèmes sont mal calibrés, mal

interprétés ou mal surveillés, les entreprises risquent de faire des choix erronés qui pourraient nuire à leur performance. La confiance excessive dans les modèles d'IA pourrait éroder la capacité humaine à faire des jugements éclairés, notamment dans des situations complexes ou imprévues où l'expérience et l'intuition humaine jouent un rôle crucial.

5. Conclusion

En conclusion, l'intégration de l'intelligence artificielle dans la prévision de la défaillance des TPE constitue une avancée majeure par rapport aux modèles traditionnels, notamment en termes de précision, de capacité à gérer des ensembles de données complexes et de flexibilité face aux dynamiques économiques changeantes. Les approches modernes telles que les réseaux neuronaux, et les forêts d'arbres décisionnels (Random Forests) ont démontré leur efficacité à détecter des relations non linéaires et à modéliser des interactions complexes entre variables qui échappent aux modèles classiques. Ces techniques permettent une prise en compte plus complète des facteurs internes et externes qui influencent la défaillance des entreprises, tout en s'adaptant aux environnements économiques instables.

Cependant, bien que les avantages de l'IA soient indéniables, plusieurs défis demeurent. La qualité des données est un facteur crucial, car des données incomplètes ou biaisées peuvent altérer la performance des modèles d'IA. De plus, l'interprétabilité des modèles reste une préoccupation majeure, notamment pour les gestionnaires d'entreprise qui doivent comprendre et justifier les décisions prises par des systèmes algorithmiques souvent perçus comme des "boîtes noires". Il est également essentiel de prendre en compte la formation des gestionnaires et des équipes afin qu'ils soient capables de comprendre et d'exploiter pleinement ces outils avancés dans leurs processus décisionnels.

L'avenir de la prévision des défaillances des TPE réside probablement dans une approche hybride combinant les méthodes classiques et modernes. En intégrant les atouts des modèles traditionnels, qui restent précieux pour leur simplicité et leur interprétabilité, avec les capacités des modèles basés sur l'IA, il est possible d'obtenir des outils d'aide à la décision plus robustes et plus fiables. Une telle combinaison permettrait de minimiser les risques liés à l'utilisation exclusive d'une seule approche et d'offrir une réponse plus complète et plus nuancée aux défis complexes auxquels font face les petites entreprises. En fin de compte, l'IA pourrait devenir un levier stratégique indispensable pour la gestion des risques et la pérennité des TPE, tout en renforçant la capacité des entreprises à anticiper et à s'adapter aux évolutions économiques futures.

6. Références

- Aksoy, B., & Boztosun, D. (2018). Financial Failure Prediction Using Discriminant and Logistic Regression Methods: BIST Manufacturing Sector Example. *Journal of Financial, Political and Economic Comments*, 55, 9-32.
- Alam, N., Gao, J., & Jones, S. (2021). Corporate failure prediction : An evaluation of deep learning vs discrete hazard models. *Journal of International Financial Markets, Institutions and Money*, 75, 101455. <https://doi.org/10.1016/j.intfin.2021.101455>
- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589–609. <https://doi.org/10.2307/2978933>
- Altman, E. I. (1984). "The success of business failure prediction models : An international survey," *Journal of Banking & Finance*, Elsevier, vol. 8(2), pages 171-198, June.
- Beaver, W. H. (1966). Financial Ratios As Predictors of Failure. *Journal of Accounting Research*, 4, 71–111. <https://doi.org/10.2307/2490171>
- Chen, L and Mao, S. (2024). From Traditional to Deep: A multi-model approach in predicting business failure. In *Proceedings of the 2023 4th International Conference on*

- Computer Science and Management Technology (ICCSMT '23). Association for Computing Machinery, New York, NY, USA, 885–890. <https://doi.org/10.1145/3644523.3644682>
- Cortes, C. and Vapnik, V. (1995) Support-Vector Networks. *Machine Learning*, 20, 273-297. <http://dx.doi.org/10.1007/BF00994018>
 - Coulibaly, A. D. (2004). La défaillance des PME belges : Analyse des déterminants et modélisation statistique. UCL - ESPO/IAG - Département d'administration et de gestion.
 - Dumitrescu, E., Hué, S., Hurlin, C., & Tokpavi, S. (2022). Machine learning for credit scoring : Improving logistic regression with non-linear decision-tree effects. *European Journal of Operational Research*, 297(3), 1178-1192. <https://doi.org/10.1016/j.ejor.2021.06.053>
 - Guilhot, B. (2000). Défaillances d'entreprise : Soixante-dix ans d'analyse théoriques et empiriques. *Revue Française de Gestion*, 52-67.
 - Hamdi, M., Mestiri, S., & Arbi, A. (2024). Artificial Intelligence Techniques for Bankruptcy Prediction of Tunisian Companies: An Application of Machine Learning and Deep Learning-Based Models. **JRFM**, 17(4), 1-14. <https://doi.org/10.3390/jrfm17040114>.
 - Kristanti, T. F., & Dhaniswara, V. (2023). The Accuracy of Artificial Neural Networks and Logit Models in Predicting the Companies' Financial Distress. *Journal of Technology Management & Innovation*, 18(3), 42–50. <https://doi.org/10.4067/S0718-27242023000300042>
 - Máté, D., Raza, H., & Ahmad, I. (2023). Comparative Analysis of Machine Learning Models for Bankruptcy Prediction in the Context of Pakistani Companies. *Risks*, 11(10), 1-17.
 - Nanni, L., & Lumini, A. (2009). An experimental comparison of ensemble of classifiers for bankruptcy prediction and credit scoring. *Expert Systems with Applications*, 36(2, Part 2), 3028-3033. <https://doi.org/10.1016/j.eswa.2008.01.018>
 - Ohlson, J. A. (1980). Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, 18(1), 109–131. <https://doi.org/10.2307/2490395>
 - Ooghe, H., & Waeyaert, N. (2004). Causes of company failure and failure paths : The rise and fall of Fardis. *European Case Study*, 1-8.
 - Picory, C., & Geffroy, B. (1995). Degré d'intégration bancaire des PME : Une approche par l'organisation industrielle. *Revue économique*, 46(2), 365-392. <https://doi.org/10.3406/reco.1995.409648>
 - Pompe, P. P. M., & Bilderbeek, J. (2005). The prediction of bankruptcy of small- and medium-sized industrial firms. *Journal of Business Venturing*, 20(6), 847-868. <https://doi.org/10.1016/j.jbusvent.2004.07.003>
 - Porter, M. (1980) *Competitive Advantage: Creating and Sustaining Superior Performance; and Competitive Strategy: Techniques for Analyzing Industries and Competitors*. Free Press, New York.
 - Thornhill, S., & Amit, R. (2003). Learning about Failure : Bankruptcy, Firm Age, and the Resource-Based View. *Organization Science*, 14(5), 497-509.
 - Van Caillie, D., Santin, S., Crutzen, N., & Kambwigiri, C. (2006). L'analyse équilibrée des symptômes de déséquilibre de la PME à reprendre, facteur-clé du succès du processus de reprise : Légitimation théorique et première validation empirique. 1 ères Journées George Doriot, Deauville. <http://journesdoriot.free.fr/fichiers/Communications%20en%20ateliers/R%E9sum%E9s/>

DORIOT%202006%20RESUME%20VAN%20CAILLIE%20SANTIN%20CRUTZEN%
20KABWIGIRI.pdf

- Zhang, G., Y. Hu, M., Eddy Patuwo, B., & C. Indro, D. (1999). Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis. *European Journal of Operational Research*, 116(1), 16-32. [https://doi.org/10.1016/S0377-2217\(98\)00051-4](https://doi.org/10.1016/S0377-2217(98)00051-4)