

## Machine Learning dans l'évaluation du risque crédit : revue systématique


Machine learning in credit risk assessment: A systematic review.

- **AUTEUR 1** : Mousaab Elkhair GHOUJDAM,
- **AUTEUR 2** : Rachid CHAABITA,
- **AUTEUR 3** : Salwa IDAMIA,

**(1)**: Docteur en sciences économiques, Faculté des Sciences Juridiques Économiques et Sociales d'Ain Chock ,Université Hassan II de Casablanca, Maroc.

**(2)**: Professeur d'enseignement supérieur à la Faculté des sciences juridiques, économiques et sociales, Université Hassan II et Directeur du Laboratoire de Gouvernance de l'Intelligence d'Affaires des Organisations, de la Finance et de la Criminalité Financière. Université Hassan II Casablanca, Maroc

**(3)**: Doctorante, ESTC, Université Hassan II Casablanca, Maroc.



**Conflit d'intérêts** : L'auteur ne signale aucun conflit d'intérêts.

**Pour citer cet article** : GHOUJDAM .M, CHAABITA .R & IDAMIA .S (2024) « Machine learning dans l'évaluation du risque crédit :revue systématique.»,

**IJAME** : Volume 02, N° 08 | Pp: 255 – 274.

Date de soumission : Mai 2024

Date de publication : Juin 2024



DOI : 10.5281/zenodo.12528088

Copyright © 2024 – IJAME

**Résumé :**

L'article entreprend une revue systématique des diverses approches de l'apprentissage automatique dans l'analyse du risque de crédit, basée sur l'examen de 20 articles spécifiquement sélectionnés. Les résultats mettent en évidence une diversité d'approches de machine learning, telles que les arbres de décision, les réseaux de neurones et la classification K-plus proche voisin (KPV). Une analyse approfondie révèle que certaines méthodes, notamment les réseaux de neurones et les arbres de décision, affichent une précision supérieure et des performances remarquables comparées aux approches classiques telles que la régression logistique et l'analyse discriminante. Cependant, ces méthodes présentent également des limitations, comme la sensibilité au bruit des données et la complexité des modèles. Cette étude souligne un intérêt crucial pour les praticiens et les décideurs financiers dans le but d'améliorer les pratiques de gestion du risque de crédit. Elle met en exergue l'importance croissante de l'apprentissage automatique dans ce domaine, tout en soulignant la nécessité de futures recherches empiriques pour valider ces résultats et surmonter les défis inhérents à ces approches. Cela permettrait d'optimiser encore davantage les performances et l'applicabilité de ces méthodes innovantes.

**Mots clés :** MACHINE LEARNING , ANALYSE CREDIT , ARBRE DE DECISION , RESEAU NEURONE ARTIFICIEL, K-PLUS PROCHE VOISIN (KPV)

## Abstract

The article undertakes a systematic review of various machine learning approaches in credit risk analysis, based on the examination of 20 specifically selected articles. The results highlight a diversity of machine learning approaches, such as decision trees, neural networks, and K-nearest neighbor (KNN) classification. An in-depth analysis reveals that some methods, particularly neural networks and decision trees, demonstrate superior accuracy and remarkable performance compared to classical approaches such as logistic regression and discriminant analysis. However, these methods also exhibit limitations, such as sensitivity to data noise and model complexity. This study emphasizes a crucial interest for practitioners and financial decision-makers aiming to enhance credit risk management practices. It underscores the increasing importance of machine learning in this domain while emphasizing the need for future empirical research to validate these findings and overcome the inherent challenges of these approaches. This would further optimize the performance and applicability of these innovative methods.

**Keywords:** Machine learning, credit analysis, decision tree, artificial neural network, and K-nearest neighbor (KNN) classification

## 1. INTRODUCTION

L'analyse du risque de crédit constitue un pilier fondamental dans le domaine de la finance, offrant aux institutions financières et aux prêteurs une compréhension approfondie des risques associés à l'octroi de crédit à différents emprunteurs. Cette discipline revêt une importance cruciale dans la prise de décision financière, influençant directement la rentabilité et la stabilité des institutions financières, ainsi que la confiance des investisseurs. Dans ce contexte, les modèles de scoring de crédit émergent comme des outils essentiels pour évaluer le risque de défaut d'un emprunteur potentiel. Ces modèles, en se basant sur diverses variables financières et non financières, visent à prédire la probabilité de défaut d'un emprunteur, fournissant ainsi aux prêteurs des indications précieuses pour prendre des décisions éclairées en matière de crédit. L'intérêt de la recherche dans ce domaine réside dans la capacité des approches de machine learning à améliorer la précision des prévisions de risque de crédit, à réduire les pertes liées au défaut de paiement et à optimiser la gestion des portefeuilles de prêts. En outre, dans un environnement financier en constante évolution, caractérisé par des fluctuations économiques et des changements dans les comportements des emprunteurs, la recherche continue dans le domaine du scoring de crédit est essentielle pour répondre aux nouveaux défis et aux demandes croissantes des marchés. La problématique centrale de cette recherche réside dans l'exploration et l'évaluation des approches de machine learning appliquées au scoring de crédit pour identifier les modèles les plus robustes et adaptés aux besoins spécifiques des institutions financières dans un environnement économique en mutation, cette étude cherchera à répondre à des questions cruciales telles que : En quoi l'intégration des approches basées sur le machine learning améliore-t-elle la performance de l'analyse du risque de crédit, et quelles implications cela a-t-il pour la prise de décision ?

L'objectif de cette recherche est de se focaliser sur les approches de machine learning dans la prédiction du risque de crédit, en utilisant une revue systématique de la littérature pour examiner de manière critique les différents modèles de scoring de crédit. Cette étude mettra en lumière :

- Exploration des approches du machine learning application a l'analyse du risque crédit
- Analyse comparative des différentes approches du machine learning

- Évaluer l'impact des approches basées sur la machine learning sur la précision et l'efficacité de l'analyse du risque de crédit

Pour atteindre l'objectif de cette recherche et permettre une meilleure compréhension des approches de machine learning appliquées à la prédiction du risque de crédit, ainsi que de leurs applications, défis et perspectives, nous procéderons. Tout d'abord, par expliquer la méthodologie utilisée dans cette revue systématique en fournissant une analyse approfondie résumant les recherches existantes sur le sujet. Pour réaliser cette revue systématique, nous avons utilisé les bases de données Scopus et Google Scholar pour identifier les articles pertinents publiés dans les revues scientifiques et les conférences académiques. Nous avons choisi des mots-clés tels que "machine learning", "analyse crédit" et "apprentissage automatique" pour identifier les articles pertinents. En appliquant des critères stricts d'inclusion et d'exclusion, nous avons retenu 20 articles pour une analyse approfondie.

Ensuite, nous procéderons à l'analyse des articles sélectionnés à la lumière de notre étude. Cette analyse visera à identifier les différentes approches du machine learning et leurs implications dans le contexte de la prédiction du risque de crédit dans ce contexte particulier. Nous évaluerons et comparerons les différentes approches de machine learning pour déterminer lesquelles sont les plus performantes dans la prévision du risque de crédit.

## **2. MÉTHODOLOGIE**

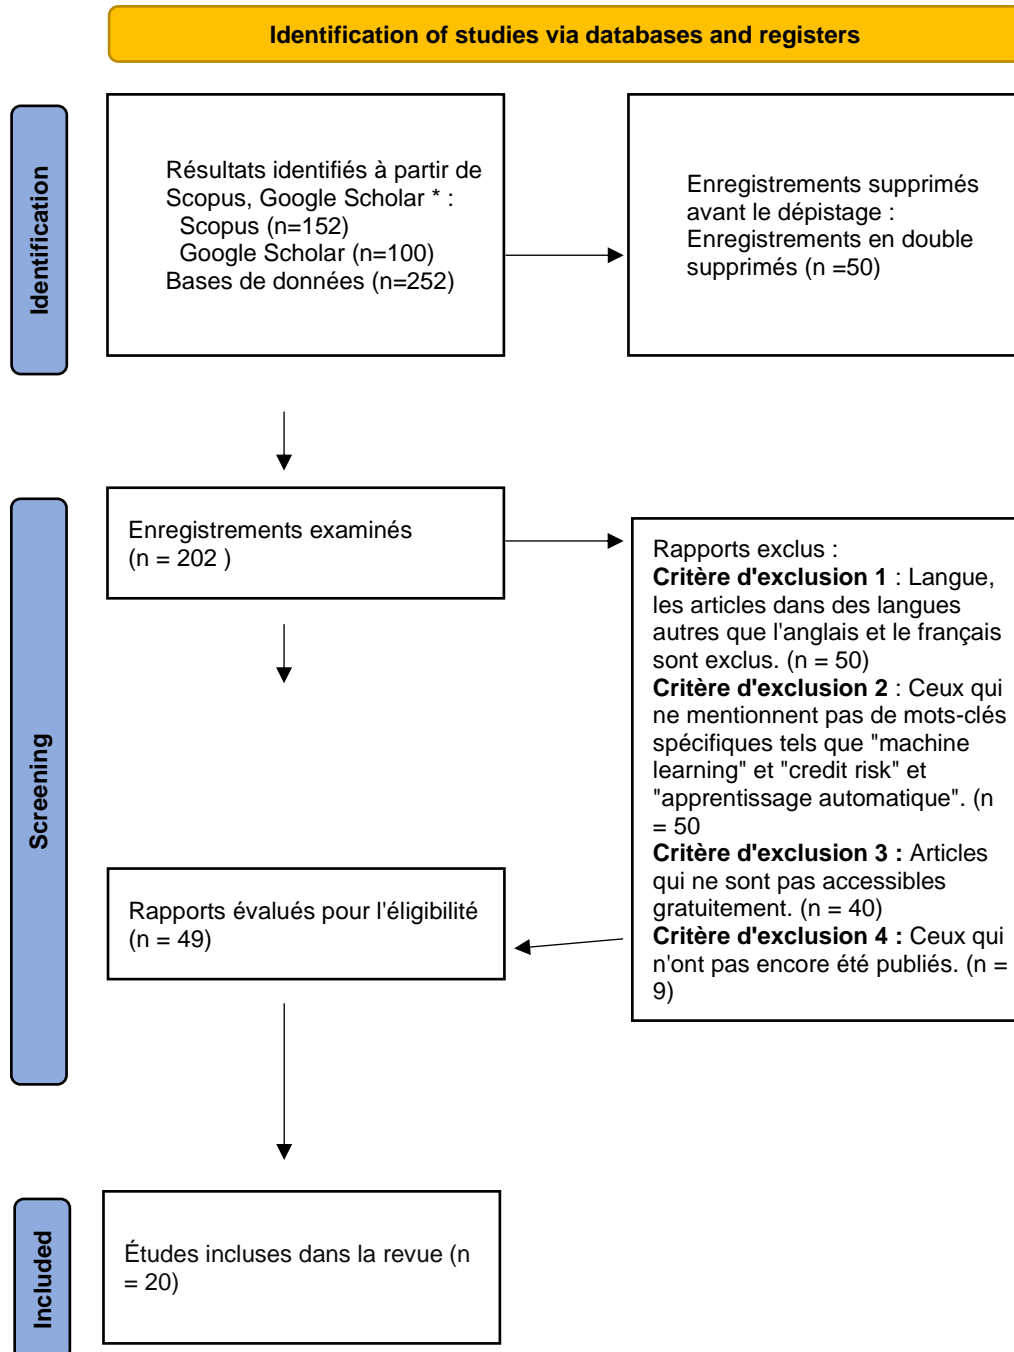
Cette recherche s'appuie sur une revue systématique, une méthode permettant d'identifier, d'évaluer, d'analyser et d'interpréter des études avec des données primaires afin de répondre à des questions de recherche spécifiques dans un domaine particulier (Staples & Niazi, 2007). Une revue systématique est définie comme une analyse systématique de la littérature visant à trouver les preuves disponibles pertinentes concernant une question de recherche donnée, dans le but de fournir des réponses informatives et fondées sur des preuves (Boland et al., 2014). Dans cette section, nous détaillerons les méthodologies adoptées pour cette revue systématique, en présentant les principales étapes du protocole.

Pour mener à bien cette revue systématique sur les approches de machine learning appliquées à la prédiction du risque de crédit, nous avons formulé notre question de recherche : Quelles sont les implications des approches du machine learning dans l'analyse du risque de crédit ?

Cette question a guidé nos critères de sélection des articles. Nous avons effectué une recherche ciblée dans les bases de données Scopus et Google Scholar pour identifier des articles pertinents sur ce sujet. Le choix des bases de données Scopus et Google Scholar pour les recherches académiques se justifie par leurs caractéristiques complémentaires et leurs atouts respectifs. Scopus, grâce à sa couverture étendue et diversifiée, offre une vue d'ensemble exhaustive des publications scientifiques de haute qualité dans de nombreuses disciplines. La rigueur de sa sélection de sources garantit la fiabilité et la pertinence des données. Google Scholar, quant à lui, permet un accès gratuit et étendu à une multitude de documents académiques, incluant articles, thèses, livres et rapports techniques. Il excelle par sa capacité à indexer une grande variété de contenus, enrichissant ainsi la recherche et la rendant plus complète et accessible. Ensemble, ces deux bases de données fournissent une combinaison optimale de profondeur, de qualité et d'accessibilité, indispensable pour des recherches académiques rigoureuses et exhaustives. Notre stratégie de recherche était basée sur des mots-clés tels que "machine learning" OR "analyse crédit" AND "apprentissage automatique". La recherche initiale a révélé 152 articles sur Scopus et 100 articles sur Google Scholar, totalisant 252 articles. Nous avons ensuite déterminé des critères d'inclusion et d'exclusion pour sélectionner les articles appropriés. Les critères d'inclusion se limitaient aux articles publiés en français ou en anglais et traitant des mots-clés "machine learning" et "analyse crédit". Les articles non librement accessibles et ceux non encore publiés ont également été exclus. Ces critères ont conduit à l'élimination de 149 articles de la base de données Scopus et de Google Scholar, ainsi que de 50 articles en double, réduisant la liste à 49 articles. Le modèle PRISMA, présenté dans la Figure 2, détaille la procédure adoptée.

Les critères d'inclusion étaient liés à la pertinence du contenu par rapport à nos questions de recherche et à la qualité méthodologique des articles. Après application de ces critères, chaque article a été analysé pour déterminer sa pertinence vis-à-vis de notre question de recherche. Les articles ont été évalués en fonction de leur qualité méthodologique, de leur pertinence et de leur contribution à notre problématique de recherche. Finalement, 20 articles répondant à nos critères d'inclusion ont été retenus pour notre revue systématique. Par la suite, nous avons interprété et synthétisé les informations des articles étudiés pour répondre à la question de recherche et tirer les conclusions appropriées.

*Fig. 1. Figure 1 . Modèle PRISMA, méthodologie sélective pour la revue systématique des articles*



### 3. RÉSULTAT

La compilation présentée dans cet article couvre vingt études, dont les références sont listées dans le Tableau 1. Cette synthèse examine des articles publiés entre 2018 et 2023, qui offrent différents points de vue sur le développement et l'application de l'apprentissage automatique dans l'analyse du risque de crédit.

Tableau 1 . Articles sélectionnés, dates de publication et nombres de citations

<b>L'auteur</b>	<b>Date de publication</b>	<b>titre</b>	<b>Citation</b>
<b>Rita tan chin and al</b>	2022	Machine learning-driven credit risk: a systemic review	26
<b><u>Mohammad Shamsu Uddin</u></b>	2022	Modeling credit risk with a multi-stage hybrid model: An alternative statistical approach	1
<b>Yu Xiang Xia and al</b>	2023	Predicting Chain's Manufacturing SME Credit Risk in Supply Chain Finance Based on Machine Learning Methods	8
<b><u>Guansan Du &amp; Frank Elston</u></b>	2022	RETRACTED ARTICLE: Financial risk assessment to improve the accuracy of financial prediction in the internet financial industry using data analytics models	2
<b>Andrés Alonso Robisco &amp; José Manuel Carbó Martínez</b>	2022	Measuring the model risk-adjusted performance of machine learning algorithms in credit default prediction	11
<b>Qian Ma &amp; Yue Wang</b>	2021	Default Risk Prediction Based on Machine Learning Under Big Data Analysis Technology	1
<b>John Donovan &amp; al</b>	2021	Measuring credit risk using qualitative disclosure	41
<b>Mirko Moscatelli &amp; al</b>	2021	Corporate default forecasting with machine learning	81



<b>Michel Alexandre &amp; al</b>	2021	The drivers of systemic risk in financial networks: a data-driven machine learning analysis	17
<b>Mohammad Mahbobi</b>	2021	Credit risk classification: an integrated predictive accuracy algorithm using artificial and deep neural networks	18
<b>Qiang Liu &amp; al</b>	2021	Mining Cross Features for Financial Credit Risk Assessment	12
<b>Nikolaos Sariannidis &amp; al</b>	2019	Default avoidance on credit card portfolios using accounting, demographical and exploratory factors: decision making based on machine learning (ML) techniques	21
<b>Vincenzo Moscato &amp; al</b>	2021	A benchmark of machine learning approaches for credit score prediction	144
<b>Jiaming Liu &amp; al</b>	20222	A two-stage hybrid credit risk prediction model based on XGBoost and graph-based deep neural network	49
<b>Andreas Fuster &amp; al</b>	2021	<u>Predictably Unequal? The Effects of Machine Learning on Credit Markets</u>	70
<b>Germannno Teles &amp; al</b>	2020	Artificial neural network and Bayesian network models for credit risk prediction	22
<b>Wei Wang &amp; al</b>	2020	Using Small Business Banking Data for Explainable Credit Risk Scoring	10
<b>Christophe Hurlin &amp; Christophe Pérignon</b>	2019	Machine learning et nouvelles sources de données pour le scoring de crédit	11
<b>Peter Martey Addo &amp; al</b>	2018	Credit Risk Analysis Using Machine and Deep Learning Models	341
<b>Sayjadah, Y. &amp; al</b>	2018	Credit Card Default Prediction using Machine Learning Techniques	34

Source: auteurs

L'étude de (Rita Tan Sim Tse et al .2020). examine les modèles de risque de crédit basés sur l'apprentissage automatique, en comparant les performances des modèles d'apprentissage en profondeur avec les méthodes traditionnelles de machine learning et statistiques. Les résultats montrent que les modèles d'apprentissage en profondeur surpassent ces méthodes traditionnelles dans l'estimation du risque de crédit, et que les méthodes d'ensemble sont plus précises que les modèles individuels. De même, (Mohammad Shamsu Uddin et al. 2022) modélisent le risque de crédit avec un modèle hybride multi-étapes, offrant une précision supérieure en tenant compte de la dimensionnalité des données. Les performances varient selon les dimensions des données, mais le modèle hybride s'avère efficace. (Yu Xiang Xia et al.2023) se concentrent sur les PME manufacturières, utilisant des méthodes d'apprentissage automatique pour évaluer le risque de crédit, avec une efficacité notable de l'algorithme de forêt aléatoire. (Guansan Du et al. 2022) utilisent l'apprentissage en profondeur pour améliorer l'exactitude des prédictions financières en ligne, optimisant l'algorithme standard pour résoudre les problèmes de données déséquilibrées. (Andrés Alonso Robisco et al. 2022)proposent un cadre pour quantifier les ajustements de risque, montrant l'efficacité des modèles d'apprentissage automatique comme XGBoost et la forêt aléatoire dans la prédiction du défaut de crédit. (Qian Ma et al. 2021) comparent les performances des algorithmes SVM et KNN, soulignant que SVM offre la meilleure mesure de risque dans l'analyse de crédit. (John Donovan et al. 2021) améliorent la prédiction des événements de crédit en utilisant des informations qualitatives, développant une mesure complète du risque de crédit. (Mirko Moscatelli et al. 2021) montrent que les modèles d'apprentissage automatique offrent des gains substantiels en termes de puissance discriminatoire par rapport aux modèles statistiques traditionnels. (Michel Alexandre et al. 2021) identifient les déterminants du risque systémique dans les réseaux financiers à l'aide de l'apprentissage automatique, montrant l'importance des caractéristiques topologiques du réseau pour les banques. (Mohammad Mahbobi and al.2021) présentent un algorithme de précision prédictive utilisant des techniques de suréchantillonnage et de sous-échantillonnage pour améliorer les prédictions. (Qiang Liu et al.2021) proposent une méthode d'extraction de caractéristiques croisées appelée DNN2LR, surpassant les modèles conventionnels en termes de précision et d'interprétabilité. (Nikolaos Sariannidis et al. 2019) utilisent des techniques d'apprentissage automatique pour analyser les défauts de paiement dans les portefeuilles de cartes de crédit, tandis que (Vincenzo Moscato et al. 2021) proposent une étude de benchmarking des modèles de scoring de risque de crédit pour les plateformes de prêt P2P. (Jiaming Liu et al. 2022) proposent un modèle hybride pour la prédiction du risque de

crédit, atteignant des résultats supérieurs en termes de précision et de F1-score. (Andreas Fuster et al. 2021) examinent l'impact de l'apprentissage automatique sur les disparités de crédit, soulevant des préoccupations sur l'équité des résultats de crédit. Wei Wang et al. 2020 comparent le modèle traditionnel de score de crédit à des modèles d'apprentissage automatique, démontrant la supériorité de XGBoost avec des contraintes monotones. Peter Martey Addo se concentre sur l'analyse du risque de crédit en utilisant des modèles de machine learning et d'apprentissage en profondeur, soulignant l'importance de la qualité des données et de la sélection des caractéristiques. Et finalement (Christophe Hurlin et Christophe Pérignon .2019) montrent que les modèles de machine learning peuvent améliorer les scores de crédit en exploitant de nouvelles sources de données, bien que des préoccupations éthiques subsistent quant à l'utilisation des données.

#### **4. DISCUSSION**

Il existe un large éventail de méthodes basées sur l'intelligence artificielle pour évaluer le risque de crédit, parmi lesquelles les plus couramment utilisées incluent les arbres de décision, le clustering k-means et les réseaux neuronaux. Les techniques d'intelligence artificielle ont démontré une performance solide dans la modélisation du risque de crédit

**Quelles sont les diverses approches de l'apprentissage automatique employées pour analyser le risque de crédit ?**

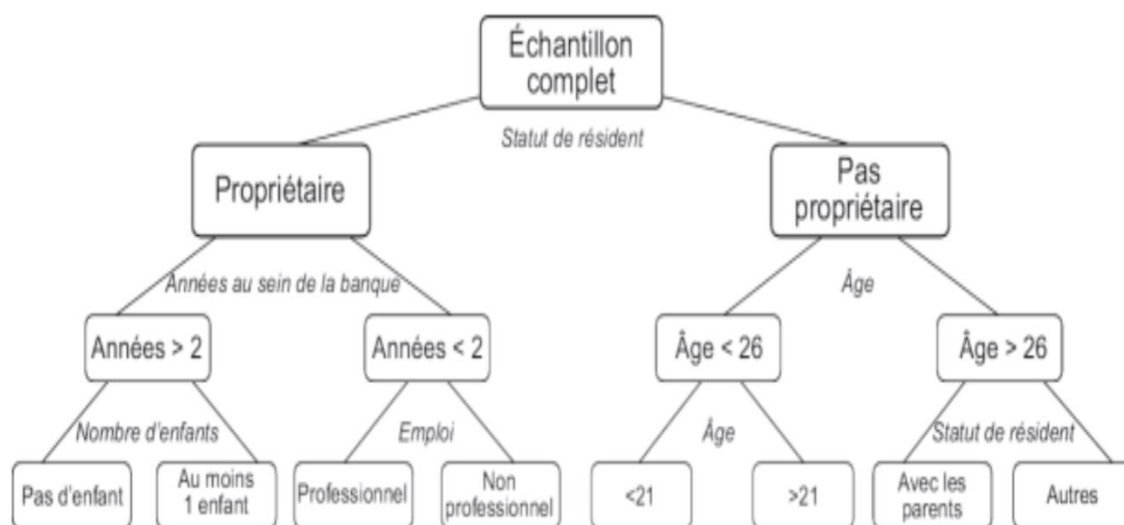
- **Arbre de décision**

Un arbre de décision est une structure permettant de déduire un résultat à partir de décisions successives. Pour traverser un arbre de décision et trouver une solution, on commence par la racine. Chaque nœud représente soit une feuille dénotant une décision, soit une branche spécifiant un test sur une valeur d'un attribut. Le nombre de descendants de chaque nœud dépend des résultats du test effectué à ce niveau (Hurlin, C. & Pérignon, C. 2019). Un arbre de décision adopte une structure hiérarchique similaire à un organigramme qui démarre à partir d'un nœud racine, progresse vers les nœuds inférieurs à travers des états ou des décisions possibles (représentés comme une branche), et se termine au nœud terminal qui montre la conséquence de toute la branche. Les arbres de décision ont l'avantage d'être utilisés à la fois pour des modèles de régression et de classification (Bazarbash, M. 2019).

Il est plus facile de comprendre le fonctionnement d'un modèle d'arbre de décision avec un schéma(FIGURE 2). Dans le domaine de l'apprentissage automatique, un arbre de décision est un modèle utilisé pour la prédiction ou la classification, principalement dans l'apprentissage supervisé. Il offre une représentation visuelle des données sous forme d'un graphe arborescent ou par une version textuelle. Des algorithmes tels que Classification And Regression Tree (CART) ou Iterative Dichotomiser (ID3) sont à la base de la création d'arbres. Leur utilisation est répandue en apprentissage automatique et en fouille de données en raison de leur facilité de compréhension et d'explication.

L'élaboration d'arbres de décision à partir de données remonte à une époque antérieure. Morgan et Sonquist (1963) ont été parmi les premiers à utiliser des arbres de régression pour la prédiction et l'explication. La méthode CART (Classification and Regression Tree) de Breiman et al. (1984) est généralement considérée comme un point culminant de cette approche, décrite en détail dans une monographie qui est encore aujourd'hui une référence. Thomas (2000) propose la première synthèse littéraire englobant les modèles de scoring incluant des techniques de machine learning. Il examine le taux de classification correcte (PCC) de six méthodes issues de cinq études différentes, concluant qu'aucune méthode ne l'emporte sur les autres et soulignant les infimes disparités entre les PCC de ces diverses méthodes, ce qui démontre la fiabilité et la performance de cette approche.

**Fig. 2. Figure 2 . exemple d'un arbre de décision pour l'évaluation du risque crédit**



Source : (Thomas L. C. 2000)

Les modèles d'arbres de décision offrent une approche intuitive et transparente pour évaluer le risque de crédit, ce qui en fait des outils attrayants pour les institutions financières. Leur capacité à fournir des directives claires dans la prise de décision est particulièrement précieuse lors de la formation des évaluateurs de crédit, où la clarté des lignes directrices peut être essentielle. De plus, les arbres de décision peuvent gérer efficacement les problèmes à sortie multiple, ce qui les rend polyvalents dans divers contextes de gestion des risques. Cependant, malgré ces avantages, les arbres de décision présentent également des inconvénients pratiques importants, en particulier lorsqu'ils sont confrontés à de grandes quantités de données telles que celles rencontrées dans le domaine du prêt FinTech. Les arbres complexes générés peuvent devenir difficiles à interpréter, et leur tendance au surajustement peut entraîner des prédictions peu robustes. De plus, leur sensibilité au bruit et leur instabilité potentielle en raison de l'utilisation d'algorithmes localement optimaux soulèvent des préoccupations quant à leur fiabilité dans des environnements dynamiques. Enfin, le biais inhérent des arbres de décision lorsque certaines classes dominent dans l'échantillon souligne la nécessité de prendre en compte les caractéristiques spécifiques de la population étudiée lors de l'évaluation du risque de crédit.

- **La méthode de classification KPV**

La méthode de classification KPV, également connue sous le nom de K-plus proche Voisin (KNN), est un algorithme d'apprentissage automatique largement utilisé dans le domaine de l'intelligence artificielle. Malgré sa désignation comme un "apprenant paresseux" selon Cunningham et Delany (2021), les KNN ont prouvé leur efficacité dans la résolution de nombreux problèmes commerciaux, comme le soulignent Jiang et al. (2012) et Mccord et al. (2011). L'algorithme se base sur l'ensemble des données existantes pour prédire la valeur d'une observation externe en recherchant les observations les plus similaires dans le jeu de données. Cette méthode de classification a été classée parmi les dix principales méthodes utilisées en raison de sa simplicité et de sa performance, et a été appliquée avec succès dans divers domaines de Data Mining, y compris la classification, la régression et le comblement des valeurs manquantes. L'approche repose sur le principe du vote parmi les k individus les plus similaires dans les données d'entraînement pour anticiper l'étiquette de l'individu testé. Les expérimentations menées par Zhang et al. (2017) ont confirmé la précision et l'efficacité de la méthode KPV, laquelle peut également être utilisée pour la régression et l'imputation des données manquantes.


- **Les réseaux de neurones**

également connus sous le nom de réseaux de neurones artificiels (RNA) ou de réseaux neuronaux simulés (SNN), constituent une composante essentielle de l'apprentissage automatique, en particulier des algorithmes d'apprentissage en profondeur. Leur conception et leur fonctionnement sont inspirés des réseaux neuronaux biologiques, reproduisant ainsi la façon dont les neurones biologiques communiquent entre eux. Les premières recherches sur les réseaux de neurones remontent aux années 1940, lorsque Warren McCulloch et Walter Pitts ont envisagé la possibilité de réaliser des calculs arithmétiques ou logiques à l'aide de ces réseaux.

L'apprentissage des réseaux de neurones repose sur l'utilisation de données d'entraînement afin d'améliorer leur précision au fil du temps. Une fois ces algorithmes d'apprentissage suffisamment développés, ils deviennent des outils puissants en informatique et en intelligence artificielle, capables de classer et de regrouper rapidement de grandes quantités de données. L'application pratique des réseaux de neurones a réellement émergé à la fin des années 1950 avec les travaux de Frank Rosenblatt sur le perceptron. Depuis lors, les réseaux de neurones, en tant que composante de l'intelligence artificielle, se sont largement répandus dans divers domaines appliqués, tels que la biologie et la physique, et ont été particulièrement adoptés par le secteur financier dans les années 1990. Ils ont été reconnus comme une méthode prévisionnelle quantitative complémentaire aux méthodes statistiques traditionnelles.

Les réseaux de neurones fonctionnent en apprenant par eux-mêmes les relations entre les variables à partir d'un échantillon de données, imitant ainsi la logique humaine. Ils établissent des liens entre les données d'entrée et les résultats de sortie en supposant une relation non linéaire, comme c'est le cas dans la détection des risques de crédit. La construction d'un réseau de neurones capable de simuler un raisonnement biologique comprend trois étapes principales : la phase d'entrée, la phase de fonction de transfert et la phase d'apprentissage. Un réseau de neurones se compose d'une couche d'entrée avec des neurones correspondant aux variables d'entrée, d'une couche de sortie reflétant les variables de sortie, et éventuellement d'une ou plusieurs couches cachées avec des nœuds intermédiaires (figure 3).

**Figure 3. Réseaux neuronaux artificiels récurrents**



**Source :** (Krenker & al , 2011)

L'avantage principal des réseaux de neurones réside dans leur flexibilité et leur capacité à reconnaître des motifs complexes dans les données, ce qui est particulièrement utile lorsque la taille des données est importante. Alors que les modèles traditionnels peinent à obtenir des gains de performance avec des échantillons de données plus importants, les réseaux de neurones sont capables de saisir des connexions plus profondes entre les caractéristiques et les résultats. Cependant, ces modèles produisent des motifs difficiles à interpréter par les humains, les rendant ainsi des modèles "boîte noire". En effet, les réseaux de neurones apprennent en mémorisant des motifs dans les données grâce à l'estimation d'un grand ensemble de paramètres, et utilisent une structure non linéaire via la fonction d'activation, ce qui accroît la flexibilité du modèle.

### **Quel est l'implication des approches du machine learning dans l'analyse risque credit par rapport aux approches classiques ?**

L'ensemble des articles examinés souligne l'évolution et l'amélioration des modèles de risque de crédit grâce à l'apprentissage automatique et en profondeur. Les études montrent que les modèles d'apprentissage en profondeur surpassent souvent les méthodes traditionnelles de machine learning et les algorithmes statistiques, notamment grâce à une meilleure capacité à traiter les données complexes et volumineuses. Les méthodes d'ensemble se révèlent également plus précises que les modèles individuels, augmentant ainsi la fiabilité des évaluations de risque

de crédit. Cependant, plusieurs défis persistent, notamment le déséquilibre des données, la transparence des modèles et l'incohérence des ensembles de données.

Tam et Kiam (1992) ont également évalué les réseaux de neurones par rapport à d'autres méthodes comme l'analyse discriminante ou la régression logistique. Leurs résultats ont démontré que les réseaux de neurones surpassent les autres approches en termes de performance.

Tableau 2. Comparaison analytique entre la régression logistique, l'analyse discriminante et les réseaux neuronaux.

<b>Erreur de classement</b>						
<b>Pourcentage%</b>						
	<b>Une année avant défaillance</b>			<b>Deux ans avant la défaillance</b>		
<b>Méthode</b>	<b>Erreur type1</b>	<b>Erreur type 2</b>	<b>Erreur total</b>	<b>Erreur type 1</b>	<b>Erreur type 2</b>	<b>Erreur total</b>
<b>Analyse discriminante</b>	17.3	11.1	14.2	17.3	13.9	15.6
<b>Régression logistique</b>	12.3	17.3	14.8	15.2	20.9	17.7
<b>Réseau sans couche</b>	8.6	13.5	11.11	8.9	25.3	17.1
<b>Réseau avec 10 neurones dans la couche intermédiaire</b>	8.6	12.3	10.5	8.9	12.7	10.8

Source : (Tam et Kiam .1992)

De même, Roy et Cosset (1989) ont comparé les réseaux de neurones avec des méthodes statistiques pour évaluer le risque pays. Ces méthodes visent à estimer le risque de non-remboursement des dettes d'un pays. Leurs recherches ont affiché des résultats prometteurs. En effet, la performance de chaque technique a été évaluée en se basant sur les erreurs absolues lors de la détermination des cotes de risque pays. Les réseaux de neurones ont manifesté une erreur absolue moyenne inférieure à celle de la régression logistique.(tableau 2)



**Tableau 3. Comparaison analytique entre la régression logistique et les réseaux neuronaux.**

		$R^2$		Erreur moyenne absolue	
		RNA	Régression logistique	RNA	Regression logistique
Modèles variables	8	0.815	0.788	8.78	9.59
Modèles variables	10	0.945	0.903	4.70	6.78

**Source : (Roy et Cosset .1989)**

Les études antérieures que nous avons analysées ont présenté des résultats intéressants. Il ressort clairement de ces travaux que les méthodes d'IA, telles que les réseaux neuronaux, les arbres de décision et la classification k plus proches voisins (kppv), ont montré une capacité significative à améliorer la performance de la prédiction du risque de crédit par rapport aux méthodes classiques telles que l'analyse discriminante et la régression logistique. En outre, l'intégration de nouvelles sources de données et les implications éthiques de leur utilisation nécessitent une attention particulière pour garantir une évaluation équitable et réglementée du risque de crédit. Ces recherches mettent en évidence la nécessité d'améliorer continuellement les modèles et les pratiques pour mieux prédire et gérer le risque de crédit dans divers contextes financiers.

## CONCLUSION

Dans cette revue systématique, nous avons entrepris une exploration approfondie des différentes approches de l'apprentissage automatique dans l'analyse du risque de crédit en analysant 20 articles sélectionnés. Notre investigation a permis de mettre en lumière une diversité d'approches, du machine learning telles que les arbres de décision, les réseaux de neurones et la classification K-plus proche Voisin (KPV). En comparant ces différentes approches, nous avons pu mettre en évidence leurs forces respectives, ainsi que leur efficacité dans la prédiction du risque de crédit. Nos résultats ont révélé que certaines méthodes, notamment les réseaux de neurones et les arbres de décision, se distinguent par leur efficacité accrue dans la modélisation du risque de crédit. Ces approches offrent une précision supérieure par rapport aux méthodes traditionnelles et peuvent être particulièrement utiles dans des contextes où la complexité des données est élevée. Cependant, nous avons également constaté des limitations, telles que la sensibilité au bruit des données et la difficulté d'interprétation des modèles complexes, qui peuvent restreindre leur applicabilité dans certains scénarios.

En conclusion, notre analyse comparative met en évidence l'importance croissante de l'apprentissage automatique dans le domaine de l'analyse du risque de crédit. Les avancées technologiques dans ce domaine ouvrent de nouvelles perspectives passionnantes pour les praticiens et les chercheurs, offrant des outils plus puissants et sophistiqués pour évaluer et gérer le risque de crédit. Nos travaux ont également souligné l'importance de la recherche future dans ce domaine, en mettant en évidence plusieurs avenues prometteuses pour l'amélioration des modèles d'analyse du risque de crédit. Des études empiriques approfondies sont nécessaires pour valider les résultats rapportés dans la littérature et pour mieux comprendre les facteurs qui influent sur la performance des différentes approches. De plus, des efforts continus sont nécessaires pour développer des méthodologies robustes et des cadres analytiques pour guider l'application pratique de l'apprentissage automatique dans l'industrie financière.

Enfin, bien que notre revue systématique ait permis d'identifier plusieurs tendances et perspectives intéressantes, elle présente également certaines limitations. Notre analyse s'est concentrée sur un nombre limité d'articles et pourrait avoir omis des recherches pertinentes publiées dans d'autres sources. De plus, notre évaluation des approches d'apprentissage automatique peut être influencée par des biais de publication, car les articles sélectionnés peuvent être ceux qui rapportent des résultats positifs. En conséquence, une approche plus exhaustive et rigoureuse pourrait être nécessaire pour obtenir une image plus complète et précise de l'état actuel de la recherche dans ce domaine.

## Références

Addo, P. M., Guegan, D., & Hassani, B. (2018). Credit risk analysis using machine and deep learning models. *Risks*, 6(2), 38.

Alexandre, M., Silva, T. C., Connaughton, C., & Rodrigues, F. A. (2021). The drivers of systemic risk in financial networks: a data-driven machine learning analysis. *Chaos, Solitons & Fractals*, 153, 111588.

Alonso Robisco, A., & Carbo Martinez, J. M. (2022). Measuring the model risk-adjusted performance of machine learning algorithms in credit default prediction. *Financial Innovation*, 8(1), 70.

Bazarbash, M. (2019). *Fintech in financial inclusion: machine learning applications in assessing credit risk*. International Monetary Fund.

Breiman, L., J. H. Friedman, R. A. Olshen, et C. J. Stone (1984). *Classification And Regression Trees*. New York: Chapman and Hall

Cunningham, P., & Delany, S. J. (2021). K-nearest neighbour classifiers-a tutorial. *ACM computing surveys (CSUR)*, 54(6), 1-25.

Donovan, J., Jennings, J., Koharki, K., & Lee, J. (2021). Measuring credit risk using qualitative disclosure. *Review of Accounting Studies*, 26, 815-863.

Du, G., & Elston, F. (2022). Financial risk assessment to improve the accuracy of financial prediction in the internet financial industry using data analytics models. *Operations Management Research*, 15(3-4), 925-940.

Fuster, A., Goldsmith-Pinkham, P., Ramadorai, T., & Walther, A. (2022). Predictably unequal? The effects of machine learning on credit markets. *The Journal of Finance*, 77(1), 5-47.

Hurlin, C., & Pérignon, C. (2019). Machine learning et nouvelles sources de données pour le scoring de crédit. *Revue d'économie financière*, (3), 21-50.

Krenker, A., Bešter, J., & Kos, A. (2011). Introduction to the artificial neural networks. *Artificial Neural Networks: Methodological Advances and Biomedical Applications*. InTech, 1-18.

Liu, J., Zhang, S., & Fan, H. (2022). A two-stage hybrid credit risk prediction model based on XGBoost and graph-based deep neural network. *Expert Systems with Applications*, 195, 116624.

Liu, Q., Liu, Z., Zhang, H., Chen, Y., & Zhu, J. (2021, October). Mining cross features for financial credit risk assessment. In *Proceedings of the 30th ACM international conference on information & knowledge management* (pp. 1069-1078).

Ma, Q., & Wang, Y. (2022). Default Risk Prediction Based on Machine Learning Under Big Data Analysis Technology. In *The 2021 International Conference on Machine Learning and Big Data Analytics for IoT Security and Privacy: SPIoT-2021 Volume 1* (pp. 73-78). Springer International Publishing.

Mahbobi, M., Kimiagari, S., & Vasudevan, M. (2023). Credit risk classification: an integrated predictive accuracy algorithm using artificial and deep neural networks. *Annals of Operations Research*, 330(1), 609-637.

Matoussi, H., & Abdelmoula, A. K. (2010, May). LA PREVENTION DU RISQUE DE DEFAUT DANS LES BANQUES TUNISIENNES. Analyse comparative entre les méthodes linéaires classiques et les méthodes de l'intelligence artificielle: les réseaux de neurones artificiels. In *Crises et nouvelles problématiques de la Valeur* (pp. CD-ROM).

Mccord, M., & Chuah, M. (2011). Spam detection on twitter using traditional classifiers. In *Autonomic and Trusted Computing: 8th International Conference, ATC 2011, Banff, Canada, September 2-4, 2011. Proceedings 8* (pp. 175-186). Springer Berlin Heidelberg.

Morgan, J. et J. A. Sonquist (1963). Problems in the analysis of survey data, and a proposal. *Journal of the American Statistical Association* 58, 415–435

Moscatelli, M., Parlapiano, F., Narizzano, S., & Viggiano, G. (2020). Corporate default forecasting with machine learning. *Expert Systems with Applications*, 161, 113567.

Moscato, V., Picariello, A., & Sperlí, G. (2021). A benchmark of machine learning approaches for credit score prediction. *Expert Systems with Applications*, 165, 113986.

ROY, J., & COSSET, J.1989. Forecasting country risk ratings using a neural network. La prévision des cotes de risque-pays à l'aide des réseaux de neurones.

Sariannidis, N., Papadakis, S., Garefalakis, A., Lemonakis, C., & Kyriaki-Argyro, T. (2020). Default avoidance on credit card portfolios using accounting, demographical and exploratory factors: decision making based on machine learning (ML) techniques. *Annals of Operations Research*, 294(1), 715-739.

Sayjadah, Y., Hashem, I. A. T., Alotaibi, F., & Kasmiran, K. A. (2018, October). Credit card default prediction using machine learning techniques. In *2018 Fourth International Conference on Advances in Computing, Communication & Automation (ICACCA)* (pp. 1-4). IEEE.

Shi, S., Tse, R., Luo, W., D'Addona, S., & Pau, G. (2022). Machine learning-driven credit risk: a systemic review. *Neural Computing and Applications*, 34(17), 14327-14339.

Teles, G., Rodrigues, J. J. P. C., Rabê, R. A., & Kozlov, S. A. (2020). Artificial neural network and Bayesian network models for credit risk prediction. *Journal of Artificial Intelligence and Systems*, 2(1), 118-132.

THOMAS L. C. (2000), « A Survey of Credit and Behavioural Scoring: Forecasting Financial Risk of Lending to Customers », *International Journal of Forecasting*, vol. 16, pp. 149-172.

Uddin, M. S., Chi, G., Al Janabi, M. A., Habib, T., & Yuan, K. (2022). Modeling credit risk with a multi-stage hybrid model: An alternative statistical approach. *Journal of Forecasting*, 41(7), 1386-1415.

Wang, W., Lesner, C., Ran, A., Rukonic, M., Xue, J., & Shiu, E. (2020, April). Using small business banking data for explainable credit risk scoring. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 34, No. 08, pp. 13396-13401).

Xia, Y., Xu, T., Wei, M. X., Wei, Z. K., & Tang, L. J. (2023). Predicting chain's manufacturing SME credit risk in supply chain finance based on machine learning methods. *Sustainability*, 15(2), 1087.

Zhang, S., Li, X., Zong, M., Zhu, X., & Cheng, D. (2017). Learning k for knn classification. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 8(3), 1-19.