ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND

Machine Learning appliqué en Finance : Une lecture théorique des domaines d'application

Machine Learning in Finance: A Theoretical Review of Its Applications

Karima SABBAR, ***(Doctorante)***
Laboratoire de recherche : Économie, Gestion et Développement Durable
Faculté des Sciences Juridiques, Économiques et Sociales de Tanger
Université Abdelmalek Esaadi Tétouan Maroc

Moad EL KHARRIM, *(Enseignant-Chercheur)*
Laboratoire de recherche : Économie, Gestion et Développement Durable
Faculté des Sciences Juridiques Economiques et Sociales de Tanger
Université Abdelmalek Essaâdi Tétouan Maroc

Adresse de correspondance :	Faculté des Sciences Juridiques Économiques et Sociales de Tanger B.P 1373 – Poste principale – Tanger, Maroc Université Abdelmalek Essaâdi, Maroc (Tétouan) Code postal : 93000 0539 39 39 32
Déclaration de divulgation :	Les auteurs n'ont pas connaissance de quelconque financement qui pourrait affecter l'objectivité de cette étude. Ils assument l'entière responsabilité de tout éventuel plagiat, de l'usage de l'intelligence artificielle dans la rédaction, ainsi que des résultats présentés dans cet article.
Conflit d'intérêts :	Les auteurs ne signalent aucun conflit d'intérêts.
Citer cet article	SABBAR, K., & EL KHARRIM, M. (2026). Machine Learning appliqué en Finance : Une lecture théorique des domaines d'application. *International Journal of Accounting, Finance, Auditing, Management and Economics*, *7*(14), 329–349. https://doi.org/10.5281/zenodo.23963096
Licence	**Cet article est publié en open Access sous licence CC BY-NC-ND**

Machine Learning appliqué en Finance : Une lecture théorique des domaines d'application

Résumé :

L'application du Machine Learning en finance a fait l'objet de diverses recherches, mais l'analyse de ses domaines d'application, ses apports économiques ainsi que les limites de sa mise en œuvre méritent d'être approfondies. Cet article propose une synthèse théorique visant à mettre en relation ces différentes dimensions afin de mieux apprécier les possibilités et les contraintes associées à l'intégration de ces technologies dans les activités financières. Il vise à présenter les principales contributions de ce domaine de recherche en plein développement, à examiner la diversité de ses domaines d'application et à identifier les enjeux ainsi que les perspectives susceptibles d'orienter les recherches futures. Ainsi, l'étude aborde les fondements conceptuels de l'intelligence artificielle, de l'apprentissage automatique et de l'apprentissage profond, ainsi que les applications de ces techniques aux activités financières. Le document aborde également les opportunités que ces méthodes offrent pour exploiter des données financières complexes, identifier des relations non linéaires et soutenir les processus de prise de décision, et en même temps les principales limitations de leur utilisation. Sur le plan méthodologique, cet article adopte une lecture conceptuelle et comparative des principales contributions, en vue d'identifier les domaines d'utilisation de ces technologies, leurs apports économiques ainsi que les limites associées à leur intégration dans les activités financières.

Mots clés : Machine Learning ; Intelligence Artificielle ; Deep Learning ; économie ; finance
JEL Classification : O33, G17, C53
Type du papier : Recherche Théorique

Abstract :

The application of machine learning in finance has been the subject of various studies; however, an analysis of its specific areas of application, its economic contributions, and the limitations surrounding its implementation warrants further exploration. This article offers a theoretical synthesis that connects these various dimensions, providing a better understanding of the possibilities and constraints associated with integrating such technologies into financial activities. It aims to present the key contributions from this rapidly evolving field of research, examine the diversity of its applications, and identify the challenges and future prospects that may shape subsequent research. The study addresses the conceptual foundations of artificial intelligence, machine learning, and deep learning, as well as the application of these techniques to financial operations. It also highlights the opportunities these methods provide for leveraging complex financial data, identifying non-linear relationships, and supporting decision-making processes, while simultaneously acknowledging the primary limitations of their use. Methodologically, this article adopts a descriptive theoretical synthesis approach, based on the analysis and contextualization of scholarly work dedicated to the application of machine learning in finance. This approach emphasizes a conceptual and comparative review of major contributions, with the goal of identifying the areas where these technologies are deployed, their economic benefits, and the limitations inherent in their integration into financial activities.

Keywords: Machine Learning; Artificial Intelligence; Deep Learning; economy; finance
Classification JEL: O33, G17, C53
Paper type: Theoretical Research

ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

1. Introduction

L'évolution des marchés financiers caractérisée par la complexité croissante des mécanismes économiques, la diversification des instruments financiers et la disponibilité des données ont conduits à de nouvelles méthodes d'analyse et processus de prise de décision. Les approches quantitatives restent essentielles dans la recherche et la pratique financières mais peuvent présenter certaines limites lorsqu'il s'agit de comprendre des relations complexes, des interactions non linéaires ou des structures de grande dimension. Ces évolutions ont favorisé l'émergence de nouvelles approches analytiques basées sur l'intelligence artificielle parmi lesquelles l'apprentissage automatique (Machine Learning) suscite beaucoup d'intérêt scientifique et professionnel. Selon Dixon, Halperin et Bilokon (2020), ces techniques offrent de nouvelles possibilités de modélisation et d'aide à la décision dans plusieurs domaines de la finance, notamment la gestion des investissements et des risques.

L'apprentissage automatique est ainsi un ensemble de techniques qui permettent aux ordinateurs de découvrir des motifs dans les données et d'améliorer leurs performances sur des tâches spécifiques basées sur l'expérience. En finance, ces techniques ouvrent de nouvelles voies pour exploiter l'information, modéliser les phénomènes financiers et améliorer les outils d'aide à la décision car elles peuvent gérer des données hétérogènes, explorer des relations potentiellement non linéaires et construire des modèles prédictifs.

L'intérêt pour ces méthodes est principalement dû à la transformation numérique du secteur financier et à l'augmentation des volumes d'informations disponibles. Les banques, les sociétés de gestion d'actifs et d'autres institutions financières ont diversifié leurs sources de données (séries temporelles de prix, indicateurs économiques, informations comptables, données transactionnelles et certaines informations non structurées), de sorte que les méthodes d'apprentissage automatique peuvent aider à les exploiter plus efficacement et à développer des outils analytiques adaptés à la complexité des activités financières. En parallèle, les applications de l'intelligence artificielle et du Machine Learning se sont diversifiées dans la recherche financière. Goodell et al. (2021), à travers une analyse bibliométrique, mettent en évidence les principaux thèmes et courants de recherche associés à ces technologies. Différemment, Nazareth et Reddy (2023) ont présenté une revue systématique des applications financières de l'apprentissage automatique, et ils ont accordé une attention particulière aux techniques utilisées, aux données mobilisées et aux modalités d'évaluation des modèles. Dans le présent article, nous avons adopté une orientation différente, nous avons privilégié une synthèse théorique descriptive basée sur les usages du Machine Learning dans les activités financières tout en mettant l'accent sur leurs fonctions économiques et leurs possibilités d'utilisation dans les différents métiers de la finance. Cette démarche vise ainsi à compléter les travaux antérieurs par une présentation transversale des applications, accessible dans une perspective économique et financière, sans chercher à reproduire les analyses bibliométriques ni à comparer systématiquement les performances des algorithmes.

Ainsi, les applications de l'apprentissage automatique aujourd'hui sont très diverses. Sur les marchés financiers, ces techniques sont utilisées pour la prévision des prix et des rendements, l'identification des tendances, la conception de stratégies de trading, le soutien à la décision d'allocation d'actifs, etc. Elles sont aussi utilisées dans la gestion des risques, l'évaluation des instruments financiers, l'analyse de crédit, la détection de fraude et l'automatisation de certains services financiers. Cela montre à quel point l'apprentissage automatique est transversal et comment il peut être exploité pour transformer la pratique financière.

Cette diversité des applications de l'apprentissage automatique dans le secteur financier soulève plusieurs questions sur son utilisation, ses contributions, et les contraintes de son intégration dans les pratiques financières. Ainsi, la question principale que nous avons abordée est donc : **quels sont les principaux domaines d'application de l'apprentissage automatique dans le**

secteur financier et quels sont les avantages potentiels ainsi que les limites de son intégration dans les activités financières ?

Pour répondre à cette question, notre étude s'organise autour de trois axes complémentaires : quels sont les fondements théoriques et les principales approches du Machine Learning ? Section 2) Quelles sont les domaines d'application du Machine Learning en finance ? (Section 3) Et quelles ses principaux apports ainsi que les contraintes pourraient limiter son utilisation ? (Section 4)

2. Fondements conceptuels et principales approches du Machine Learning

L'analyse des applications du *Machine Learning* dans le domaine financier nécessite, au préalable, une compréhension des fondements conceptuels et des principales approches méthodologiques qui caractérisent cette discipline. En effet, le développement des techniques d'intelligence artificielle et l'augmentation de la capacité de traitement des données ont permis de développer de nouvelles méthodes d'analyse et de modélisation qui sont progressivement intégrées dans les activités financières. Mais les notions d'intelligence artificielle, de Machine Learning, de Deep Learning ou de science des données sont souvent utilisées de manière interchangeable bien qu'elles se réfèrent à des concepts différents et complémentaires. Ainsi, avant d'examiner les principales catégories d'apprentissage automatique, nous devons d'abord clarifier ces notions et préciser leurs relations afin de mieux comprendre quels mécanismes les sous-tendent et où elles s'inscrivent en termes de contribution à l'analyse des enjeux financiers.

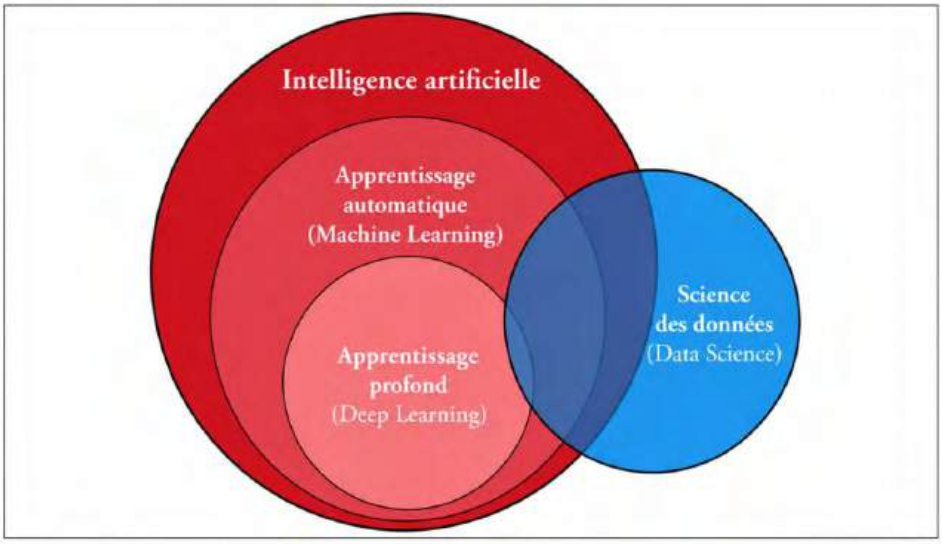
2.1. Intelligence artificielle, Machine Learning, Deep Learning et science des données

Les notions d'apprentissage automatique (Machine Learning), d'apprentissage profond (Deep Learning), d'intelligence artificielle (Artificial Intelligence) et de science des données (Data Science) sont fréquemment sources de confusion, notamment en raison de leurs nombreuses similitudes et de leurs domaines d'application communs. Bien que ces concepts soient étroitement liés, ils sont souvent employés de manière interchangeable, sans distinction précise de leurs caractéristiques et de leurs spécificités respectives.

La figure 1 ci-après illustre les relations conceptuelles entre l'intelligence artificielle (Artificial Intelligence), l'apprentissage automatique (Machine Learning), l'apprentissage profond (Deep Learning) et la science des données (Data Science). Le Machine Learning constitue une branche de l'intelligence artificielle regroupant un ensemble de méthodes permettant aux systèmes informatiques d'identifier des régularités et des structures dans les données afin de développer des applications intelligentes. Le Deep Learning est une autre sous-catégorie de l'apprentissage automatique car il est basé sur des architectures d'apprentissage qui peuvent résoudre des problèmes difficiles et modéliser des relations complexes entre les variables. La science des données n'est pas (à proprement parler) une sous-catégorie de l'apprentissage automatique mais plutôt un domaine interdisciplinaire qui utilise des techniques d'apprentissage automatique, d'apprentissage profond et d'intelligence artificielle pour analyser des données et extraire des informations utiles pour la prise de décision, ainsi que pour combiner ces approches avec d'autres disciplines et technologies (analyse de Big Data, informatique en nuage...) afin de traiter, exploiter et interpréter de grands volumes de données.

ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

Figure 1 : Intelligence artificielle, apprentissage automatique, apprentissage profond et science des données.



Source : Adapté de Tatsat, Puri et Lookabaugh (2020, figure 1-1)

2.1.1. L'intelligence artificielle (Artificial Intelligence – AI)

L'intelligence artificielle (IA) désigne un domaine de recherche consacré à la conception de systèmes capables d'accomplir des tâches mobilisant des capacités telles que le raisonnement, l'apprentissage, la perception et la prise de décision. Russell et Norvig (2021) abordent notamment l'intelligence artificielle à travers la notion d'agent intelligent, capable de percevoir son environnement et d'agir en fonction des informations disponibles.

2.1.2. L'apprentissage automatique (Machine Learning – ML)

L'apprentissage automatique est une branche de l'intelligence artificielle qui permet aux ordinateurs d'apprendre à partir de données et d'expériences afin d'améliorer progressivement leurs capacités d'analyse et de prise de décision, Samuel (1959) et Mitchell (1997). Il existe diverses méthodes algorithmiques utilisées pour identifier des régularités, reconnaître des structures et exploiter des relations dans les données — à travers des processus d'apprentissage répétés, ces techniques aident les modèles à améliorer leurs performances et à guider les prédictions ou les décisions basées sur les informations analysées.

2.1.3. L'apprentissage profond (Deep Learning – DL)

L'apprentissage profond est une sous-catégorie de l'apprentissage automatique où des réseaux de neurones artificiels avec plusieurs couches successives de traitement de l'information sont utilisés. L'architecture de ces modèles est vaguement inspirée (de manière simpliste) par l'organisation des réseaux de neurones biologiques dans le cerveau. L'apprentissage profond cherche ainsi à examiner les données à travers différents niveaux de représentation afin que les caractéristiques et les relations puissent être identifiées progressivement ; une organisation de ce type aide à apprendre des structures élaborées à partir des informations disponibles, Goodfellow et al. (2016), LeCun et al. (2015).

2.1.4. La science des données (Data Science)

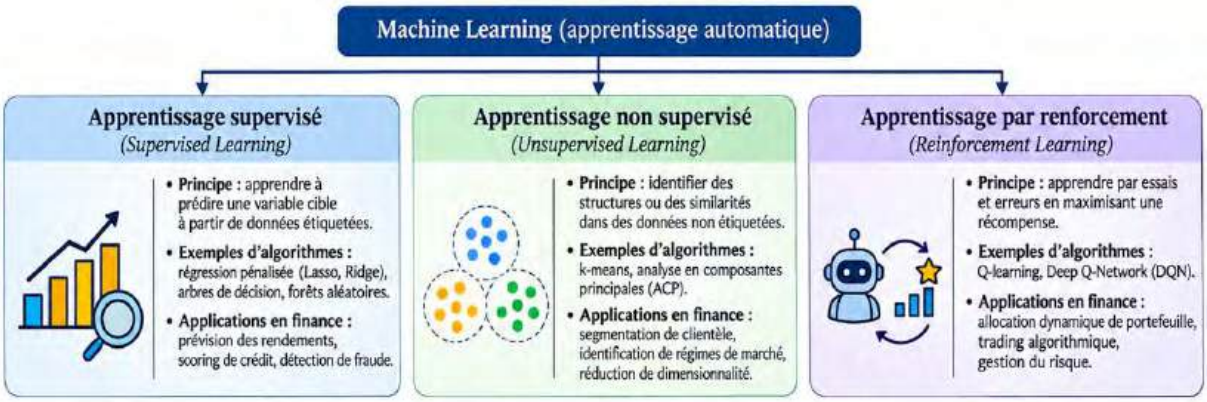
La science des données est un domaine interdisciplinaire où des méthodes scientifiques, statistiques et computationnelles sont utilisées pour extraire des connaissances et des informations à partir de données structurées ou non structurées. L'exploration de données est étroitement liée à la science des données en ce qu'elle cherche principalement à analyser, interpréter et comprendre les informations disponibles afin de produire des connaissances

utilisables pour la prise de décision. Plusieurs outils et techniques sont communs à l'intelligence artificielle (IA) et à l'apprentissage automatique, mais la science des données a un objectif plus large d'exploiter et d'améliorer l'information (approches méthodologiques et analytiques).

2.2. Les principales catégories d'apprentissage automatique (Machine Learning)

L'apprentissage automatique (ML) fait référence à différentes approches méthodologiques utilisées dans de nombreux domaines, y compris le secteur financier. Celles-ci se différencient principalement par leurs mécanismes d'apprentissage et la nature des données utilisées. Comme le montre la figure 2, il existe trois catégories principales : l'apprentissage supervisé (Supervised Learning), l'apprentissage non supervisé (Unsupervised Learning) et l'apprentissage par renforcement (Reinforcement Learning).

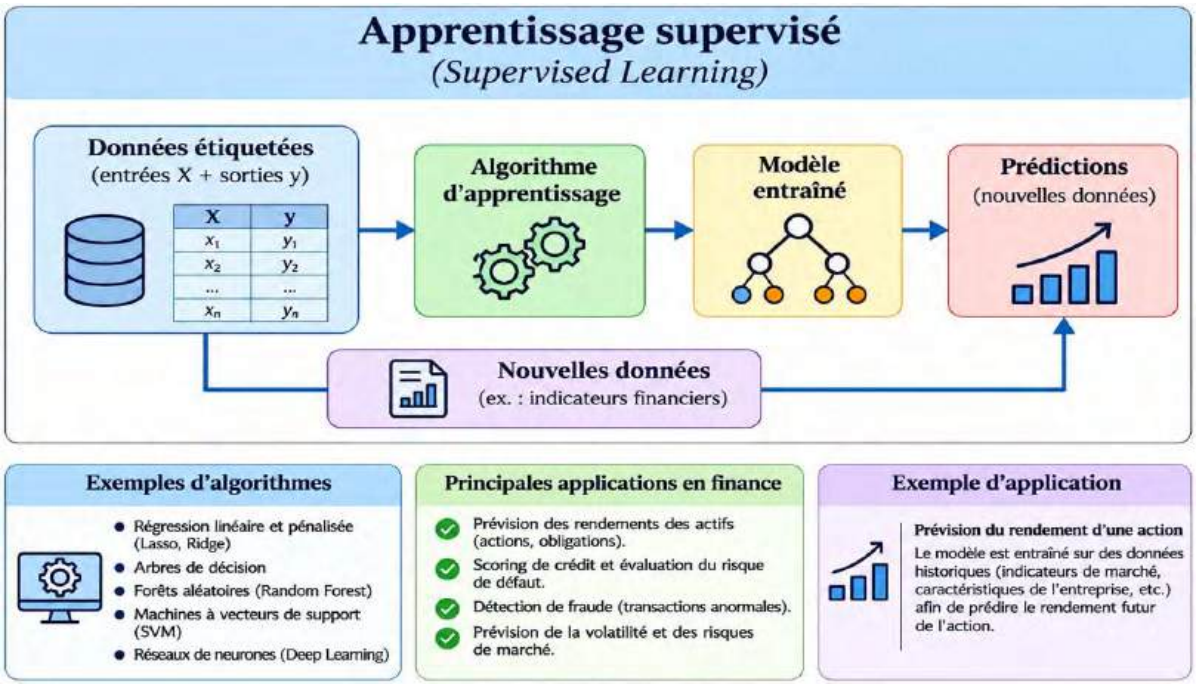
Figure 2 : Les principaux paradigmes du Machine Learning et leurs applications en finance



Source : Les auteurs

2.2.1. L'apprentissage supervisé (Supervised Learning)

Figure 3 : Principe de l'apprentissage supervisé (supervised learning)



Source : Les auteurs

L'apprentissage supervisé (*Supervised Learning*) constitue une approche de l'apprentissage automatique dont l'objectif principal consiste à entraîner un modèle à partir de données

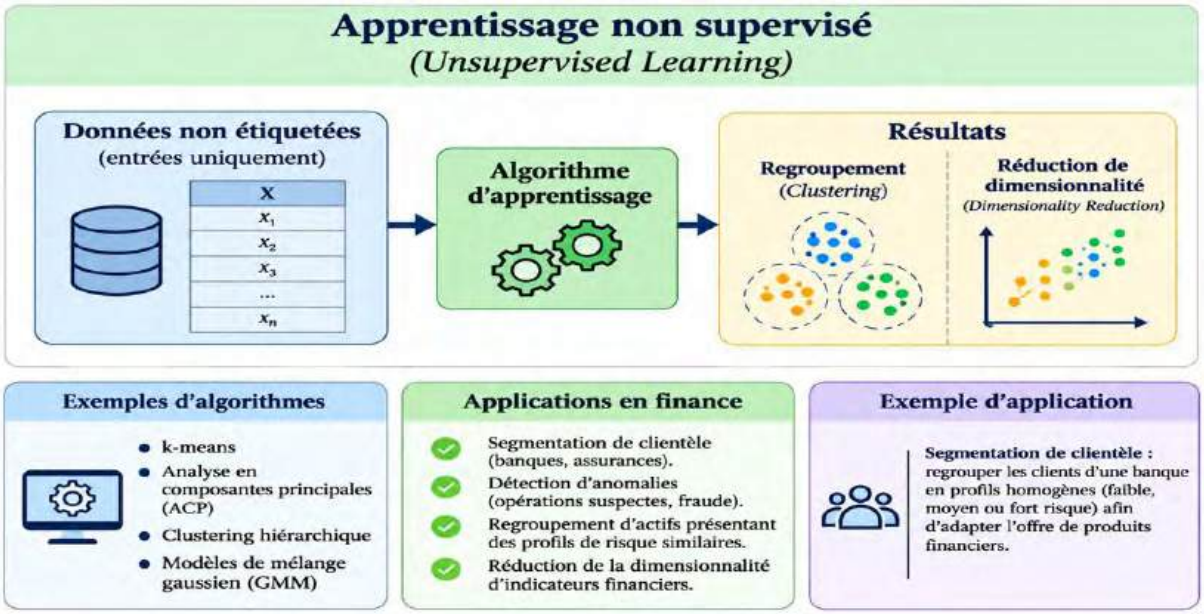
ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

étiquetées, afin de lui permettre de réaliser des prédictions sur de nouvelles observations ou des données futures. Le caractère supervisé de cette méthode repose sur l'utilisation d'un ensemble d'exemples pour lesquels les résultats attendus, appelés étiquettes (*labels*), sont préalablement connus. Les algorithmes d'apprentissage supervisé se répartissent principalement en deux grandes catégories : la classification et la régression. La figure 3 ci-après illustre le principe du supervised learning.

2.2.2. L'apprentissage non supervisé (Unsupervised Learning)

L'apprentissage non supervisé est un type d'apprentissage automatique dans lequel nous examinons des ensembles de données sans étiquettes ni résultats prédéfinis. Les informations provenant des données peuvent ensuite être utilisées pour trouver des structures, des régularités et des relations entre les observations. Les méthodes d'apprentissage non supervisé sont principalement divisées en deux grandes catégories : la réduction de la dimensionnalité et le regroupement des données en classes homogènes. La figure 4 ci-dessous montre le principe de l'apprentissage non supervisé.

Figure 4 : Principe de l'apprentissage non supervisé (unsupervised learning)



Source : Les auteurs

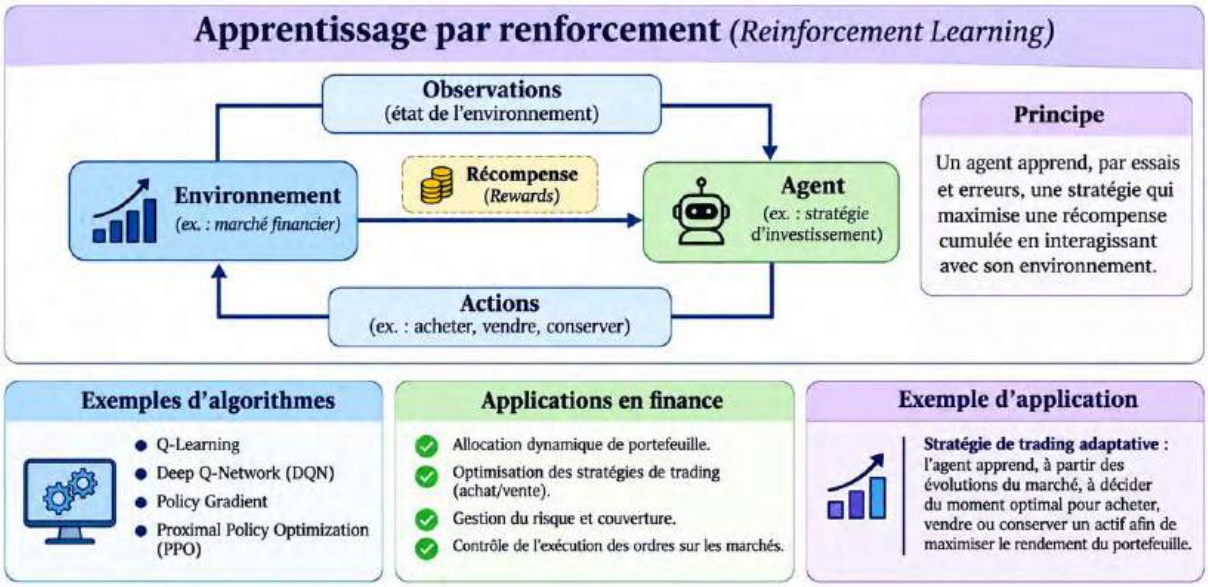
2.2.3. L'apprentissage par renforcement (Reinforcement Learning)

L'apprentissage par renforcement (RL) repose sur l'apprentissage à partir de l'expérience et des mécanismes de récompense ou de pénalité liés aux actions entreprises. Son principal objectif est de trouver les meilleures décisions dans un environnement donné afin que les récompenses cumulées soient maximisées, Sutton et Barto (2018). Dans ce cas, le système d'apprentissage (agent) interagit avec son environnement en observant les situations auxquelles il est confronté, en sélectionnant et exécutant des actions, puis en recevant des récompenses positives ou négatives en fonction des résultats obtenus (voir Figure 5).

La principale différence entre l'apprentissage par renforcement et l'apprentissage supervisé est qu'en RL, il n'y a pas de réponses correctes explicitement données pendant l'entraînement. Dans l'apprentissage supervisé, nous entraînons notre modèle avec des données étiquetées pour lesquelles nous connaissons déjà le résultat attendu. Dans l'apprentissage par renforcement, l'agent doit décider quelles actions il doit entreprendre pour accomplir une tâche et comment elles sont pertinentes en fonction des récompenses reçues. Ainsi, l'algorithme apprend sa

stratégie de prise de décision grâce à l'expérience acquise et aux interactions successives avec son environnement.

Figure 5 : Principe de l'apprentissage par renforcement (Reinforcement Learning)



Source : Les auteurs

Le processus d'apprentissage par renforcement repose sur une succession d'interactions entre l'agent et son environnement. Il peut être présenté selon les trois étapes suivantes :

- **Interaction avec l'environnement :** dans un premier temps, l'agent interagit avec son environnement en sélectionnant et en exécutant une action en fonction de la situation observée.
- **Attribution d'une récompense :** à la suite de cette action, l'environnement fournit à l'agent une récompense, positive ou négative, permettant d'évaluer les conséquences de la décision prise.
- **Évaluation et ajustement du comportement :** sur la base de la récompense obtenue et des nouvelles observations, l'agent évalue la pertinence de son action et ajuste progressivement sa stratégie (si une action aboutit à un résultat favorable, elle peut être préférée dans des situations similaires ; si la récompense n'est pas favorable, elle encourage l'agent à rechercher d'autres possibilités afin d'améliorer les performances futures). Le mécanisme est donc basé sur un processus d'apprentissage par essais et erreurs où l'agent ajuste ses décisions en fonction de l'expérience acquise.

2.3. Machine Learning et économétrie : des approches complémentaires

Les méthodes d'apprentissage automatique sont liées aux approches statistiques et économétriques utilisées dans l'analyse économique et financière, mais elles diffèrent de celles-ci en termes d'objectifs poursuivis. L'analyse économétrique concerne avant tout l'estimation et l'interprétation des relations entre les variables économiques, tandis que les méthodes d'apprentissage automatique visent généralement la précision des prédictions et la capacité des modèles à exploiter des ensembles de données complexes (Varian, 2014 ; Mullainathan et Spiess, 2017).

Cette distinction se réfère en particulier à la différence entre la prédiction et l'inférence causale : la prédiction consiste à anticiper la valeur ou l'évolution d'une variable donnée, tandis que l'inférence causale cherche à déterminer dans quelle mesure un effet d'un facteur sur un phénomène économique est produit. En ce sens, Athey et Imbens (2019) soulignent que les

ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

techniques d'apprentissage automatique peuvent également enrichir les méthodes économétriques (en particulier lors de l'étude des relations causales).
Ainsi, l'apprentissage automatique ne doit pas être considéré comme un remplacement systématique des méthodes économétriques traditionnelles, mais plutôt comme un ensemble d'outils complémentaires. Dans le domaine financier, le choix entre ces deux approches dépend largement de ce que nous voulons comprendre (mécanismes économiques, estimer certaines relations ou améliorer les capacités de prévision). Cette complémentarité nous permet de mieux comprendre les applications financières de l'apprentissage automatique discutées dans le reste de cet article.
La distinction entre le Machine Learning et l'économétrie est présentée simplement dans le tableau 1 ci-dessous.

Tableau 1. Distinction entre Machine Learning et économétrie

Critère	Économétrie	Machine Learning
Objectif principal	Expliquer et estimer des relations économiques ; prévoir également.	Prédire des valeurs ou des catégories ; identifier des régularités dans les données.
Question privilégiée	Quel effet une variable exerce-t-elle sur un phénomène économique, sous quelles hypothèses ?	Avec quelle précision peut-on anticiper une variable à partir des informations disponibles ?
Approche des modèles	Importance des hypothèses, de l'identification et de l'interprétation des paramètres.	Importance de l'apprentissage sur les données, de la généralisation et de la validation hors échantillon.
Interprétation	Souvent centrale pour comprendre les mécanismes économiques.	Variable selon les méthodes ; certains modèles sont moins facilement interprétables.
Évaluation	Validité des hypothèses, qualité de l'identification et, selon l'objectif, précision des prévisions.	Performance prédictive sur des données non utilisées pour l'entraînement.
Exemple en finance	Estimer l'effet d'une variation des taux d'intérêt sur l'investissement.	Prévoir la probabilité de défaut d'un emprunteur ou la direction d'un rendement.

Sources : Élaboration à partir de Varian (2014), Mullainathan et Spiess (2017) et Athey et Imbens (2019).

3. Les applications du Machine Learning dans le domaine de finance

L'apprentissage automatique (Machine Learning) offre de nombreuses perspectives d'application dans le secteur financier, ses méthodes peuvent être mobilisées pour répondre à diverses problématiques liées à l'analyse des marchés, à la gestion des investissements et à l'amélioration des processus décisionnels des institutions financières. Cette section présente les principaux domaines d'application du Machine Learning en finance, en présentant les possibilités offertes par ces approches dans différents contextes financiers.

3.1. Le trading algorithmique

Le trading algorithmique (ou trading automatisé) utilise des algorithmes informatiques pour effectuer des opérations sur les marchés financiers selon des règles et des instructions. Il a été développé et évolué grâce à la technologie informatique et à l'automatisation des systèmes de trading. Des décisions d'achat ou de vente à grande vitesse peuvent être prises et exécutées (intervention humaine limitée), des critères programmés sont utilisés pour que les stratégies de trading puissent être appliquées systématiquement. Les techniques d'apprentissage automatique représentent une avancée importante dans le trading algorithmique. Contrairement aux systèmes basés uniquement sur des règles prédéterminées, les approches d'apprentissage automatique permettent de développer des stratégies basées sur des modèles trouvés dans les données financières ; elles permettent également de mettre à jour certains paramètres du modèle

avec de nouvelles informations (à condition que des mécanismes de réentraînement ou d'adaptation soient disponibles). Elles enrichissent ainsi les outils d'analyse des mouvements de marché et améliorent les processus de formulation des décisions de trading.
Ces approches intéressent particulièrement les fonds d'investissement alternatifs (hedge funds) et les institutions financières qui souhaitent utiliser les informations à leur disposition pour concevoir des stratégies de trading plus réactives. Les méthodes algorithmiques utilisées par ces acteurs sont cependant rarement rendues publiques car elles sont de nature stratégique et concurrentielle. Ainsi, l'apprentissage automatique est un outil qui peut améliorer les capacités d'analyse et d'ajustement des décisions de trading mais soulève également des questions sur la fiabilité des modèles, l'adaptabilité aux conditions du marché et la gestion des risques liés à leur utilisation.

3.2. La gestion de portefeuille et les conseillers financiers automatisés (Robo-Advisors)

La gestion de portefeuille est une application importante de l'apprentissage automatique en finance. Sa base théorique provient de Markowitz (1952) qui a proposé une approche de sélection de portefeuille basée sur le compromis entre le rendement attendu et le risque. Ainsi, les techniques d'apprentissage automatique peuvent compléter les méthodes d'optimisation traditionnelles en estimant les rendements futurs, en modélisant les relations entre les actifs et en identifiant certains développements des conditions de marché. Les prévisions de ces modèles peuvent ensuite être utilisées pour alimenter les procédures d'allocation d'actifs (y compris l'optimisation moyenne-variance) et une complémentarité économiquement intéressante apparaît car les décisions d'investissement sont prises sur des paramètres estimés qui restent incertains. Mais l'apprentissage automatique ne garantit pas une amélioration systématique des performances des portefeuilles car cela dépend avant tout de la qualité des prévisions, de la stabilité des modèles et des coûts de réallocation.
Les sociétés spécialisées dans la gestion d'actifs et de patrimoine accordent un intérêt croissant aux possibilités offertes par l'intelligence artificielle (IA) pour améliorer leurs processus de décision d'investissement et exploiter plus efficacement les données financières historiques dont elles disposent. Ainsi l'intégration des techniques d'apprentissage automatique contribue au développement de nouveaux outils d'aide à la décision, susceptibles de renforcer la personnalisation des stratégies d'investissement et l'automatisation de certains services financiers.
Les exemples les plus évidents de cette évolution sont les conseillers financiers automatisés (robo-conseillers). Ces dispositifs disposent d'algorithmes qui fournissent une allocation d'actifs pour chaque investisseur en fonction de ses objectifs financiers et de son niveau de tolérance au risque. Ils font également des recommandations et donnent des conseils financiers de manière automatisée, de sorte qu'un conseiller humain est rarement nécessaire.
Ces systèmes nécessitent généralement une collecte préalable d'informations sur la situation personnelle et financière de l'investisseur (âge, revenu, actifs financiers, objectifs d'épargne, etc.). L'investisseur saisit des détails (âge, revenu, actifs financiers, objectifs d'épargne et horizon d'investissement). L'algorithme d'allocation essaie ensuite de trouver une répartition des investissements parmi les classes d'actifs et les instruments financiers afin que les objectifs exprimés et les contraintes de risque soient satisfaits.
L'un des plus grands avantages des conseillers financiers automatisés est qu'ils peuvent modifier les recommandations d'investissement lorsque les caractéristiques ou les objectifs de l'utilisateur changent. Les changements dans l'environnement financier peuvent également entraîner une modification de la composition du portefeuille afin que l'allocation aux investisseurs reste cohérente avec le profil de risque et les objectifs de richesse de l'investisseur (mais cela dépendra des règles de fonctionnement, de la fréquence de rééquilibrage et des informations effectivement prises en compte par le système).

ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

Le développement des robo-advisors témoigne ainsi de l'évolution des modalités de fourniture des services de conseil en investissement. Ces solutions suscitent notamment l'intérêt des investisseurs qui privilégient des services numériques et ne considèrent pas l'accompagnement permanent d'un conseiller financier comme indispensable à leurs décisions. Elles illustrent plus largement les possibilités offertes par l'automatisation pour rendre les processus de gestion patrimoniale plus accessibles et davantage adaptés aux caractéristiques individuelles des investisseurs.

3.3. La détection des fraudes financières

La fraude financière est l'un des principaux problèmes auxquels les banques et autres entités financières doivent faire face. Ses coûts économiques et opérationnels justifient l'importance de la mise en place des mécanismes de surveillance et de détection capables de détecter les transactions suspectes. Ainsi, les techniques d'apprentissage automatique constituent une piste prometteuse capable de renforcer la prévention et la lutte contre la fraude financière.

Ainsi, l'application de l'apprentissage automatique à la détection de la fraude financière présente plusieurs défis méthodologiques. Tout d'abord, il existe un déséquilibre des données car les opérations frauduleuses sont généralement très peu nombreuses par rapport à l'ensemble des transactions, de sorte que les modèles peuvent avoir tendance à reconnaître les opérations légitimes au détriment de la détection des comportements frauduleux (des techniques de rééchantillonnage sont utilisées dans certaines approches pour remédier à cette difficulté). Ensuite, les pratiques frauduleuses et les comportements des utilisateurs évoluent au fil du temps (dérive conceptuelle), ce qui modifie les relations observées dans les données (par exemple, Ngai et al., 2011 ; Abdallah et al., 2016 ; Hernandez Aros et al., 2024) et réduit progressivement la fiabilité des modèles : leur évaluation ne peut pas seulement se baser sur le taux global de classification correcte, mais la précision et le rappel doivent également être pris en compte (pour évaluer s'ils détectent la fraude sans trop de fausses alertes). Ces questions sont largement discutées dans la littérature relative à la détection de la fraude financière (Ngai et al., 2011 ; Abdallah et al., 2016 ; Hernandez Aros et al., 2024) et montrent que ces techniques doivent être utilisées avec prudence et régulièrement réévaluées.

La transformation numérique des services financiers (les échanges en ligne augmentent, la puissance de calcul s'accroît et les données stockées dans des environnements numériques augmentent) introduit de nouveaux défis de sécurité : les formes de fraude deviennent plus diverses et l'identification plus difficile. Les systèmes de détection traditionnels fonctionnent avec des ensembles de règles prédéfinies et l'identification de facteurs de risque connus ; ces approches restent utiles mais peuvent présenter certaines limites lorsque le comportement frauduleux change et que de nouvelles formes de menaces émergent.

Les méthodes d'apprentissage automatique permettent d'augmenter ces mécanismes avec des capacités analytiques (données historiques et régularité statistique) au lieu de systèmes de règles fixes. Les modèles d'apprentissage automatique peuvent être entraînés à détecter des comportements inhabituels, des anomalies transactionnelles ou des configurations montrant des opérations frauduleuses (au lieu d'un système basé uniquement sur des règles fixes).

L'un des principaux avantages de ces techniques, c'est le traitement de grands volumes de données transactionnelles et la détection des comportements atypiques en peu de temps. En utilisant différentes méthodes de classification et de détection d'anomalies, les institutions financières peuvent ainsi renforcer leurs systèmes de surveillance et identifier les opérations nécessitant une vérification supplémentaire. Des mécanismes comme celui-ci pourraient aider à accroître la réactivité des systèmes de contrôle ainsi que des équipes gérant les risques opérationnels et la sécurité financière.

Ainsi, la performance des modèles de détection dépend largement de la qualité des données utilisées ; la pertinence des variables sélectionnées et la capacité des modèles à distinguer les

transactions légitimes de la fraude. Les comportements rares ou changeants ainsi que les alertes non justifiées (si elles sont générées) sont des défis sérieux pour leur mise en œuvre. L'apprentissage automatique doit être considéré comme un complément aux procédures de contrôle existantes dont la performance doit être surveillée et mise à jour régulièrement.
Ainsi, lorsque l'apprentissage automatique est utilisé pour la détection de la fraude financière, il nous montre comment il peut améliorer la sécurité des transactions et aider à façonner l'évolution des systèmes de gestion des risques dans les institutions financières.

3.4. L'évaluation des demandes de prêt

Dans le domaine de crédits, les techniques d'apprentissage automatique sont principalement utilisées dans le crédit pour améliorer l'évaluation de la solvabilité des emprunteurs et estimer le risque de défaut. Les modèles de scoring de crédit permettent d'analyser différentes caractéristiques financières et comportementales afin d'évaluer si un emprunteur peut honorer ses engagements (par exemple, revenu, comportement de dépense). Contrairement aux méthodes statistiques, certaines méthodes d'apprentissage automatique peuvent prendre en compte des relations non linéaires et des interactions complexes entre les variables explicatives, ce qui rend leur utilisation intéressante pour l'analyse des risques (classification des demandes de financement), le soutien aux décisions d'octroi de crédit, etc. Mais la performance dépend notamment de la qualité des données disponibles (représentativité), de la stabilité des relations économiques observées. Fuster et al. (2022) montrent également qu'il est nécessaire d'étudier les effets de l'utilisation de l'apprentissage automatique sur les décisions de crédit ainsi que les différences de traitement entre les catégories d'emprunteurs.

3.5. L'automatisation des processus financiers et les agents conversationnels (Chatbots)

L'automatisation des processus est l'un des leviers de l'efficacité opérationnelle dans les services financiers. Elle élimine la charge de travail des tâches répétitives et à faible valeur ajoutée (automatisation de certaines opérations de routine). Les employés ont plus de temps pour effectuer un travail où leur expertise est nécessaire ; les temps de traitement sont réduits et les coûts d'exploitation sont abaissés.
L'apprentissage automatique et l'IA appliqués dans les systèmes d'automatisation donnent aux institutions financières un pouvoir analytique et décisionnel. Ils peuvent analyser les données disponibles plus en profondeur ; faire des recommandations pour soutenir les professionnels dans leurs décisions ; trouver des erreurs et des anomalies afin qu'elles puissent être détectées et corrigées plus rapidement. Ces capacités augmentent la fiabilité des processus, retardent la production des rapports financiers et réduisent les risques d'erreurs opérationnelles.
Les agents conversationnels intelligents (chatbots) sont une autre application de l'intelligence artificielle dans les services bancaires et financiers. Leur développement s'inscrit dans l'expansion des plateformes de support et de communication en ligne — des outils qui automatisent certaines interactions avec les clients et l'accès à l'information et aux services financiers (évolution des modalités de la relation client).

3.6. La gestion des risques

Les techniques d'apprentissage automatique changent la façon dont la gestion des risques traditionnelle est effectuée dans les institutions financières. Les solutions basées sur ces méthodes offrent de nouvelles façons d'identifier, d'évaluer et de contrôler différents types de risques (par exemple, estimer combien de crédit peut être accordé aux emprunteurs ; améliorer les mécanismes de conformité réglementaire ; réduire les risques associés à l'utilisation de modèles financiers). Ces développements montrent la capacité de l'apprentissage automatique à améliorer les processus d'analyse et de contrôle des risques dans les institutions financières.

ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

Ainsi, les techniques d'apprentissage automatique peuvent offrir des possibilités complémentaires aux méthodes statistiques et économétriques dans la gestion des risques financiers (évaluation du risque de crédit, détection de la fraude, configurations des marchés conduisant à une exposition accrue aux risques). En utilisant une variété de données financières, elles permettent de prendre en compte certaines non-linéarités et interactions entre les variables (Khandani et al. 2010 ; Lessmann et al. 2015). Khandani et al. (2010) et Lessmann et al. (2015) montrent leur pertinence pour l'évaluation du risque de crédit, mais l'utilisation des techniques d'apprentissage automatique dans les institutions financières dépend de la qualité des données, de l'interprétabilité des résultats et de la capacité des modèles à rester pertinents dans le temps (les conditions économiques changent).

3.7. La prévision des prix des actifs financiers

La prédiction des prix des actifs financiers est l'un des domaines les plus complexes de la finance. Elle consiste à prévoir les variations des prix en identifiant les facteurs susceptibles d'influencer les mouvements du marché et la performance future des actifs. Traditionnellement, cette approche s'est basée sur les états financiers historiques et les performances passées du marché afin de prendre des décisions d'investissement concernant une valeur mobilière ou une catégorie d'actifs particulière, mais avec la grande quantité de données financières disponibles aujourd'hui, de nouvelles méthodes analytiques ont été introduites qui encouragent leur utilisation. Ainsi, les techniques traditionnelles de prévision et de sélection de titres sont progressivement remplacées par des techniques d'apprentissage automatique (qui offrent de nouvelles possibilités d'exploitation de l'information financière et de modélisation du développement du marché).
Ainsi, la prédiction des prix et des rendements des actifs financiers est devenu l'un des principaux domaines d'application de l'apprentissage automatique en finance. Les méthodes d'apprentissage automatique exploitent les informations historiques et les indicateurs financiers pour trouver des relations complexes qui pourraient aider à prédire les mouvements du marché. Les forêts aléatoires, les méthodes de Gradient Boosting et les réseaux neuronaux (en particulier les architectures LSTM adaptées aux données séquentielles) sont quelques-unes des approches utilisées. Ce sont des techniques intéressantes pour analyser les tendances financières ainsi que pour développer des stratégies d'investissement, mais leur performance prédictive reste sensible aux changements des conditions du marché, à la qualité des données et aux risques de surapprentissage. Krauss et al. (2017), Fischer et Krauss (2018) montrent de l'intérêt pour ces méthodes mais aussi des limites de leur rentabilité au fil du temps (surtout après la prise en compte des coûts de transaction).

3.8. La valorisation des produits dérivés

Les développements du machine learning, associés aux innovations technologiques, apportent de nouvelles perspectives à l'évaluation des dérivés. Leur développement pourrait conduire dans les années à venir à une utilisation accrue (modèle de Black-Scholes, analyse du sourire de volatilité, outils de calcul traditionnels, etc.). La plus grande disponibilité de techniques de modélisation avancées soutient ainsi l'évolution des pratiques d'évaluation des instruments financiers dérivés.
Les modèles classiques d'évaluation des dérivés comportent généralement certaines hypothèses simplificatrices qui peuvent les empêcher de reproduire certaines caractéristiques observées sur les marchés. Les méthodes d'apprentissage automatique nous permettent d'estimer directement les relations entre les variables explicatives (par exemple, le prix d'exercice, le temps restant jusqu'à l'expiration et le type d'option) et les prix des dérivés observés sur le marché (par exemple, les prix des options). Elles apprennent ces relations à partir des données afin que la différence entre les valeurs estimées par le modèle et les prix de référence soit minimisée.

De plus, les outils d'apprentissage automatique de plus en plus efficaces et leur capacité à accélérer le développement et le déploiement des modèles sont des facteurs qui augmenteront probablement leur utilisation dans l'évaluation des dérivés. Ces avancées offrent ainsi de nouvelles façons d'améliorer les processus d'évaluation financière mais appellent également une attention particulière à la fiabilité des estimations et à la robustesse dans différentes conditions de marché.

Ainsi, l'apprentissage automatique est principalement utilisé pour les opérations de valorisation, l'estimation des paramètres de marché et la gestion des stratégies de couverture. Les réseaux neuronaux peuvent être utilisés notamment pour approximer les relations complexes entre les caractéristiques des contrats financiers, les conditions de marché et les prix des instruments dérivés ; ils peuvent également accélérer certaines opérations de valorisation (lorsque les modèles traditionnels nécessitent beaucoup de calculs). Dans la couverture, les techniques d'apprentissage automatique ouvrent des perspectives pour adapter les stratégies aux évolutions du marché et aux coûts de transaction, mais leur utilisation ne nous dispense pas d'évaluer les risques, la stabilité des résultats et la cohérence avec les principes économiques de la valorisation financière (Hutchinson et al., 1994 ; Buehler et al., 2019).

3.9. L'analyse des sentiments des marchés financiers

L'analyse de sentiment est l'une des principales applications de l'apprentissage automatique dans les services financiers. Elle exploite de grandes quantités de données non structurées (vidéos, transcriptions, images, enregistrements audio, publications sur les réseaux sociaux, articles de presse, documents d'entreprise) pour identifier et interpréter les opinions, perceptions et réactions exprimées à travers ces diverses sources d'information afin de mesurer le sentiment général des acteurs envers les marchés financiers.

L'analyse des sentiments dans le secteur financier est l'une des principales applications (pour étudier les informations produites par les médias économiques et financiers) (prédire le comportement des investisseurs et les tendances possibles du marché car les mouvements boursiers sont influencés par de nombreux facteurs liés au comportement humain, aux attentes et aux réactions des participants). De ce point de vue, les techniques d'apprentissage automatique nous permettent d'explorer les informations disponibles pour trouver des tendances émergentes et des signaux qui peuvent éclairer l'évolution des marchés financiers.

Mais ce ne sont pas les seules applications où l'analyse des sentiments peut être appliquée. Elles ne se limitent pas à prédire les prix des actions ou les stratégies de trading non plus — les réseaux sociaux, les tendances médiatiques et d'autres sources d'information qui nous disent ce que les clients pensent des événements du marché sont également des éléments que nous pouvons utiliser pour faire de l'analyse des sentiments. C'est là que l'apprentissage automatique contribue à notre compréhension du comportement économique et financier à partir de données qualitatives et non structurées.

3.10. Le règlement-livraison des transactions financières (Trade Settlement)

Le règlement-livraison des transactions financières est le transfert de titres dans le compte de l'acheteur et de fonds dans le compte du vendeur après une transaction sur les marchés financiers. Cette étape est nécessaire pour finaliser les transactions et aide à exécuter les engagements entre les parties.

La plupart des opérations de règlement-livraison sont automatisées et l'intervention humaine est très limitée (texte source). Cependant, certaines transactions doivent encore être traitées manuellement.

Dans ce sens, l'apprentissage automatique (ML) offre des perspectives intéressantes pour accroître l'efficacité des opérations de règlement-livraison — il peut identifier les raisons pour lesquelles les transactions échouent (et les rejets sont effectués) ; analyser les raisons des rejets ;

ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

proposer des solutions ; prédire les transactions qui pourraient rencontrer des problèmes de règlement. L'automatisation de ces tâches pourrait réduire considérablement les temps de traitement (certaines opérations prennent plusieurs minutes à faire manuellement, mais les algorithmes les effectuent beaucoup plus rapidement).

3.11. La lutte contre le blanchiment de capitaux

Le blanchiment d'argent est un problème majeur pour les institutions financières et les autorités chargés de la surveillance des transactions. Dans une ancienne estimation du Fonds monétaire international (cité dans l'ONUDC, 2011), les montants blanchis pourraient représenter entre 2 % et 5 % du PIB mondial. Les techniques d'apprentissage automatique offrent de nouvelles techniques d'amélioration des systèmes de détection des opérations suspectes : les données internes des institutions financières sont combinées avec des informations disponibles publiquement ainsi que des données transactionnelles sur les relations de réseau des clients afin de détecter des comportements et des configurations inhabituels qui pourraient révéler un blanchiment d'argent.
Ainsi, dans le domaine du blanchiment d'argent, les techniques d'apprentissage automatique peuvent être utilisées pour identifier les transactions atypiques et les comportements financiers qui pourraient être risqués. Les approches de détection d'anomalies vous permettent de détecter des opérations qui sortent de l'ordinaire ; les méthodes d'analyse de réseau et de graphe nous permettent d'étudier les relations entre les comptes, les acteurs et les flux financiers (elles sont particulièrement utiles lorsque des opérations suspectes sont réparties sur plusieurs comptes ou intermédiaires et ne peuvent pas être identifiées en examinant les transactions isolément). Mais ces systèmes sont encore limités en raison de la disponibilité des données, du nombre de cas confirmés, de l'évolution des pratiques de blanchiment et de la difficulté à interpréter les alertes. L'utilisation de ces techniques doit donc être considérée comme un complément aux systèmes de surveillance et de contrôle traditionnels et non comme une alternative à l'expertise humaine.

4. Synthèse des résultats de la lecture et discussion critique

L'examen des différentes applications du Machine Learning dans le domaine financier permet de mettre en évidence la diversité de ses contributions aux activités des institutions financières. Mais au-delà de la présentation de ces applications, il est nécessaire de fournir une comparaison afin de mieux comprendre leurs contributions et leurs limites. Après tout, les avantages de ces techniques varient en fonction de ce qui est réalisé, des caractéristiques des données utilisées et des contraintes spécifiques à chaque activité financière. Dans ce contexte, cette section propose une synthèse des principales leçons tirées de la littérature (Contributions de l'apprentissage automatique aux méthodes financières traditionnelles ; difficultés liées à son utilisation) ainsi que les implications économiques et les perspectives de recherche associées à son développement.

4.1. Synthèse comparative des principales applications du Machine Learning en finance

L'analyse des différents domaines d'application du machine learning montre combien de fonctions ces techniques peuvent remplir dans le système financier : non seulement pour améliorer la prévision des marchés mais aussi l'évaluation des risques, l'automatisation des opérations et le soutien aux décisions financières. Cette diversité révèle le caractère transversal ddu Machine learning, sa contribution dépend du problème étudié (nature des problèmes), des caractéristiques des données disponibles (type de données) et des objectifs poursuivis par les institutions financières (objectifs).

⇒ Un premier type d'applications est celui de l'analyse des marchés financiers et des

décisions d'investissement. Il inclut notamment la prévision des prix des actifs, le trading algorithmique, la gestion de portefeuille et l'évaluation des produits dérivés. Dans ces domaines, l'utilisation de l'apprentissage automatique répond principalement au besoin d'exploiter de nombreuses sources d'information hétérogènes afin de trouver des relations complexes qui peuvent améliorer les estimations et les décisions (Gu, Kelly et Xiu 2020 sur l'évaluation des actifs financiers) par exemple montre l'intérêt de certaines méthodes d'apprentissage automatique pour trouver des relations prédictives entre les caractéristiques des actifs et les rendements.

⇒ Le deuxième type concerne les applications pour la gestion des risques et la sécurité des opérations financières. L'évaluation de la solvabilité des emprunteurs, la détection de la fraude et la lutte contre le blanchiment d'argent reposent sur l'identification de comportements, de profils ou de transactions présentant des caractéristiques précises. Dans ces domaines, l'apprentissage automatique peut améliorer les mécanismes de classification, de surveillance et de détection des anomalies, ainsi que la fiabilité, l'explicabilité et la conformité réglementaire qui sont cruciales.

⇒ Enfin, un troisième type qui est l'automatisation des services et des processus financiers. Les conseillers financiers automatisés, les agents conversationnels et les systèmes d'assistance à la livraison de règlement montrent comment les technologies d'apprentissage automatique peuvent soutenir la transformation numérique des institutions financières : leur contribution vient principalement par la simplification de certaines opérations, la personnalisation des services et la réactivité des systèmes organisationnels.

Cette classification montre que les applications de l'apprentissage automatique ont des objectifs différents : certaines visent des performances prédictives, d'autres la gestion des risques ou l'efficacité opérationnelle. Ainsi, la pertinence de ces applications ne peut être mesurée par un seul critère, mais doit respecter les objectifs économiques et les contraintes spécifiques à chaque domaine financier.

Le tableau 2 ci-dessous constitue une synthèse conceptuelle des applications du Machine Learning en finance.

Tableau 2. Synthèse comparative des applications du Machine Learning en finance

Domaines d'application	Principaux apports potentiels	Limites et enjeux
Prévision financière et trading	Identification de relations complexes et aide à la décision	Instabilité des marchés, surapprentissage, coûts de transaction
Gestion de portefeuille	Exploitation des prévisions et adaptation des allocations	Sensibilité aux estimations et risque de concentration
Risque de crédit et assurance	Classification et évaluation des profils de risque	Biais, explicabilité et conformité
Détection des fraudes et blanchiment	Détection d'anomalies et surveillance des transactions	Faux positifs et évolution des comportements frauduleux
Analyse des sentiments	Exploitation d'informations textuelles non structurées	Bruit informationnel et ambiguïté du langage
Automatisation et robo-advisors	Personnalisation des services et efficacité opérationnelle	Gouvernance, protection des données et contrôle humain

Source : Élaboration des auteurs à partir d'une synthèse conceptuelle des domaines d'application présentés dans l'article.

Ainsi, les applications de l'apprentissage automatique en finance suscitent un intérêt croissant car elles peuvent tirer parti de grands volumes de données et identifier des relations complexes entre les variables financières. Gu, Kelly et Xiu (2020) montrent par exemple qu'il existe un intérêt pour certaines méthodes d'apprentissage automatique pour la prévision des rendements des actifs. Pourtant, ces résultats positifs ne nous permettent pas de conclure que l'apprentissage automatique est systématiquement meilleur dans tous les contextes financiers ; l'amélioration

ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

des performances prédictives ne signifie pas une augmentation de la rentabilité des stratégies d'investissement lorsque les coûts de transaction sont pris en compte, que les conditions du marché changent ou que des contraintes de mise en œuvre sont imposées.
Cette distinction entre performance statistique et performance économique est soulevée par de nombreux travaux critiques. Bailey et al. (2014) mettent en garde contre les stratégies de surapprentissage basées sur des tests historiques répétés : plus les configurations sont testées, plus les stratégies sont sélectionnées qui semblent bien fonctionner sur les données passées mais pas dans des conditions réelles ; Harvey, Liu et Zhu (2016) fournissent un point de vue opposé : la multiplication des facteurs explicatifs proposés dans la littérature financière augmente le risque de découvertes statistiques trompeuses. Ces observations doivent être prises en compte lorsque les résultats de modèles complexes (lorsqu'ils sont évalués sur des données historiques) sont considérés.
De plus, les conclusions de Makridakis et al. (2018) issues de la littérature sur la prévision des séries temporelles nous rappellent que les méthodes les plus complexes ne sont pas nécessairement les meilleures dans tous les cas ; bien qu'elles ne se rapportent pas directement aux stratégies d'investissement financier, ces résultats soulignent ce qui peut mal tourner lorsque l'on généralise la supériorité prédictive de l'apprentissage automatique. Dans le même ordre d'idées, López de Prado (2018) souligne que les procédures de validation et d'évaluation des stratégies financières doivent être rigoureuses pour éviter les biais qui pourraient affecter les résultats. Ainsi, les contributions de l'apprentissage automatique à la finance ne devraient pas seulement être appréciées en termes de pouvoir prédictif mais aussi de robustesse, de stabilité temporelle, d'interprétabilité et de pertinence économique. Ces éléments nous amènent à considérer les méthodes d'apprentissage automatique comme des outils complémentaires aux méthodes traditionnelles plutôt que comme des garanties de performance financière supérieure.

4.2. Les apports du Machine Learning aux méthodes financières traditionnelles

L'adoption de l'apprentissage automatique dans les activités financières fait partie d'une évolution dans les méthodes d'analyse et de prise de décision. Les modèles statistiques et économétriques sont généralement des spécifications relativement structurées qui permettent une interprétation économique des relations étudiées. Les techniques d'apprentissage automatique les complètent en étant plus orientées vers l'identification de motifs dans les données et la recherche de performances prédictives.
L'une des principales contributions de ces méthodes est qu'elles peuvent modéliser simultanément de nombreuses variables et certaines relations non linéaires entre elles. Cela est important dans les applications financières car les phénomènes sont souvent le résultat d'interactions entre des facteurs économiques, institutionnels et comportementaux, de sorte que l'apprentissage automatique ouvre des possibilités d'exploitation des informations disponibles (surtout lorsque les données sont de haute dimension ou complexes).
De plus, ces méthodes permettent également d'utiliser des données non structurées (articles de presse, rapports financiers et publications sur les réseaux sociaux par exemple). Le traitement du langage naturel et l'analyse des sentiments peuvent utiliser ces informations qualitatives comme indicateurs dans les modèles d'analyse financière. Cette évolution permet d'enrichir les modèles classiques utilisées pour étudier les marchés et le comportement des investisseurs.
Cependant, l'intérêt économique de l'apprentissage automatique ne doit pas être interprété comme une supériorité par rapport aux méthodes classiques — une amélioration des performances prédictives ne se traduit pas nécessairement par une meilleure rentabilité des investissements ou une réduction efficace des risques pour les institutions financières ; les résultats dépendent également des conditions d'application (coûts d'utilisation des modèles), des coûts de leur utilisation et de la capacité à maintenir les performances sur de nouvelles données.

Ainsi, les techniques d'apprentissage automatique doivent être considérées comme des outils pour compléter les méthodes financières traditionnelles plutôt que comme des solutions qui les remplacent systématiquement.

4.3. Les limites et les enjeux de l'intégration du Machine Learning en finance

Bien que les techniques d'apprentissage automatique aient de nombreuses perspectives, leur utilisation dans le secteur financier entraîne des difficultés méthodologiques, économiques et organisationnelles.

⇒ La première est la qualité et la représentativité des données utilisées. La performance des modèles dépend directement des informations disponibles pour les apprendre (des données incomplètes, déséquilibrées ou non représentatives peuvent conduire à des estimations peu fiables et à la pertinence des décisions qui en résultent).

⇒ La deuxième limite est le surapprentissage. Lorsqu'un modèle imite de trop près les particularités des données historiques et ne peut pas généraliser ses résultats à de nouvelles observations. Ce problème est aigu en finance où les relations statistiques changent avec la transformation économique, les changements de comportement des investisseurs ou les crises, etc. Ainsi, la performance obtenue sur les données d'entraînement n'est pas en soi une garantie de fiabilité future.

Le problème d'interprétabilité est également un défi majeur. Certains modèles complexes (l'apprentissage profond en particulier) peuvent produire des résultats qui ne sont pas explicables économiquement ; néanmoins, dans les activités bancaires et financières, la justification des décisions reste pertinente (octroi de crédit, évaluation des risques ou conformité réglementaire). La performance prédictive doit donc être équilibrée avec les exigences de transparence, de contrôle et de responsabilité.

En plus de ces difficultés, il y a les coûts de développement, les contraintes de compétences disponibles et l'intégration des modèles dans les systèmes d'information existants. L'adoption de l'apprentissage automatique nécessite des investissements technologiques ainsi qu'organisationnels qui dépendent de la taille et des ressources des institutions financières (par exemple, l'infrastructure technologique).

4.4. Implications économiques et perspectives de recherche

À L'examen des applications et des limites de l'apprentissage automatique, on constate que son développement n'est pas une voie à sens unique pour remplacer les méthodes traditionnelles, mais plutôt un changement progressif dans les pratiques financières. L'adoption de l'apprentissage automatique peut améliorer l'exploitation de l'information, renforcer certains mécanismes de gestion des risques ou accroître l'efficacité des processus de prise de décision, mais seulement si la qualité des données est élevée, les méthodes appropriées aux problèmes étudiés et les conditions organisationnelles pour leur mise en œuvre existent.

Ainsi, une première ligne de recherche consiste à mesurer la véritable valeur économique des modèles d'apprentissage automatique. Au-delà des mesures de précision statistique, les conséquences sur la performance financière (par exemple), les coûts opérationnels, la stabilité des décisions et les effets de contrôle des risques devraient également être pris en compte afin de comprendre comment l'apprentissage automatique contribue aux objectifs économiques des institutions financières.

Un deuxième point de vue est que les modèles ne sont pas sensibles aux changements des conditions économiques et financières. Les crises, les épisodes de forte volatilité ou les changements structurels du marché peuvent déstabiliser les relations basées sur les données historiques. Étudier l'adaptabilité des modèles est donc un défi pour leur utilisation dans des environnements incertains.

ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

Une troisième direction est de développer des approches qui lient la performance prédictive et l'interprétabilité économique. Les connaissances financières pourraient être utilisées dans la conception et l'évaluation des modèles pour renforcer la cohérence des résultats et faciliter leur appropriation par les professionnels.
Enfin, les conditions dans lesquelles l'apprentissage automatique est adopté dans les économies émergentes constituent un angle intéressant. L'accès aux données, la maturité numérique, les ressources technologiques et l'environnement réglementaire influencent tous la possibilité de déployer ces méthodes. Connaître ces spécificités nous aiderait à comprendre les transformations financières qui accompagnent l'apprentissage automatique.
La question n'est pas de savoir si les techniques d'apprentissage automatique peuvent faire des prédictions — c'est de savoir si elles peuvent contribuer de manière durable à des décisions financières pertinentes, explicables et économiquement justifiées.

5. Conclusion

Dans cet article, nous avons montré, à travers une synthèse théorique des principaux domaines d'application de l'apprentissage automatique en finance, comment ces approches peuvent contribuer à enrichir l'analyse des données financières et à soutenir la prise de décision. En particulier, certaines méthodes d'apprentissage automatique (capacité de traitement des big data, identification de relations complexes et non linéaires et intégration d'informations structurées/non structurées) pourraient être ajoutées aux outils d'analyse financière traditionnels ; ces caractéristiques ouvrent de nouvelles perspectives pour améliorer les modèles de prévision, l'évaluation des risques et la conception de stratégies d'investissement pour des environnements financiers de plus en plus complexes.
La comparaison des différentes applications montre également que les contributions de l'apprentissage automatique ne se limitent pas à une meilleure performance prédictive. Elles concernent plus généralement l'efficacité opérationnelle des institutions financières, la personnalisation des services offerts aux clients et le renforcement des mécanismes de suivi/contrôle. Dans le secteur bancaire, ces technologies peuvent notamment automatiser certaines tâches répétitives (traitement des demandes de financement), faciliter l'identification des transactions aux caractéristiques inhabituelles ou améliorer la détection des anomalies sur les marchés financiers. Sur les marchés financiers, elles offrent d'autres possibilités d'exploitation de l'information et de soutien aux décisions d'investissement. L'apprentissage automatique apparaît donc comme un instrument capable de soutenir la transformation des activités financières (analytique et organisationnelle).
Les opportunités que ces méthodes présentent ne doivent pas être prises comme une raison de les utiliser comme une garantie systématique d'amélioration de la performance financière : leur efficacité reste fortement dépendante de la qualité des données mobilisées, de la pertinence des modèles choisis et des résultats produits dans l'environnement économique et financier. Les risques de surapprentissage, l'instabilité des relations statistiques, la difficulté d'interpréter certains algorithmes, les contraintes de protection des données et la conformité réglementaire sont autant de limitations qui peuvent restreindre leur utilisation. Une augmentation de la précision des prévisions ne se traduit pas automatiquement par une rentabilité accrue des investissements ou une réduction efficace des risques (si les coûts de transaction, les contraintes opérationnelles et les changements des conditions de marché ne sont pas également pris en compte).
Ainsi, l'apprentissage automatique doit être intégré dans les activités financières dans une logique de complémentarité avec les méthodes statistiques, économétriques et financières traditionnelles. Les techniques d'apprentissage automatique ouvrent des possibilités de traitement et d'exploitation de l'information, mais les modèles conventionnels conservent un

intérêt essentiel pour l'interprétation économique des phénomènes étudiés ainsi que pour la compréhension des mécanismes sous-jacents aux décisions financières : il s'agit moins de substituer une catégorie de méthodes par une autre que de les articuler pour développer des outils d'analyse efficaces et économiquement interprétables.

Sur le plan scientifique, cette synthèse théorique met en avant plusieurs directions susceptibles de stimuler la recherche future. Il serait particulièrement intéressant d'approfondir la comparaison entre les méthodes traditionnelles et les modèles d'apprentissage automatique (en privilégiant des critères non seulement de précision statistique mais aussi de performance économique, de coût de mise en œuvre et de stabilité des résultats) ; étudier la robustesse des modèles en période de forte volatilité ou de crise financière ; développer des méthodes d'apprentissage automatique explicables et analyser les conditions de leur adoption dans les économies émergentes sont d'autres pistes de recherche qui enrichiront notre compréhension de leurs implications financières et institutionnelles.

Étant donné la question de recherche « Quels sont les principaux domaines d'application de l'apprentissage automatique dans le secteur financier et quels sont les avantages et les limites de son intégration dans les activités financières ? », cette synthèse montre la variété des possibilités offertes par ces technologies. L'apprentissage automatique est principalement utilisé pour la prévision des marchés financiers, la gestion de portefeuille, l'évaluation des risques, les activités de crédit et d'assurance, la détection de fraude, les efforts de lutte contre le blanchiment d'argent et l'automatisation des services financiers. L'avantage de ces possibilités est qu'elles peuvent être exploitées avec diverses sources de données, certaines relations complexes identifiées et soutenues par des processus d'analyse et de prise de décision, mais aussi des limitations (qualité des données, risques de surapprentissage, interprétabilité des modèles, conditions de marché changeantes, exigences réglementaires…). Ainsi, l'apprentissage automatique semble davantage être un instrument pour compléter et enrichir les approches traditionnelles qu'une garantie d'amélioration systématique de la performance économique.

Références :

(1). Abdallah, A., Maarof, M. A., & Zainal, A. (2016). Fraud detection system: A survey. Journal of Network and Computer Applications, 68, 90–113.

(2). Athey, S., & Imbens, G. W. (2019). Machine learning methods that economists should know about. Annual Review of Economics, 11, 685–725.

(3). Bailey, D. H., Borwein, J. M., López de Prado, M., & Zhu, Q. J. (2014). Pseudo-mathematics and financial charlatanism: The effects of backtest overfitting on out-of-sample performance. Notices of the American Mathematical Society, 61(5), 458–471.

(4). Buehler, H., Gonon, L., Teichmann, J., & Wood, B. (2019). Deep hedging. Quantitative Finance, 19(8), 1271–1291.

(5). Bussmann, N., Giudici, P., Marinelli, D., & Papenbrock, J. (2021). Explainable AI in fintech risk management. Frontiers in Artificial Intelligence, 3, Article 26.

(6). D'Acunto, F., Prabhala, N., & Rossi, A. G. (2019). The promises and pitfalls of robo-advising. The Review of Financial Studies, 32(5), 1983–2020.

(7). Dixon, M. F., Halperin, I., & Bilokon, P. (2020). Machine Learning in Finance: From Theory to Practice. Springer.

(8). Financial Stability Board. (2017). Artificial intelligence and machine learning in financial services: Market developments and financial stability implications.

(9). Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. European Journal of Operational Research, 270(2), 654–669.

ISSN: 2658-8455
Volume 7, Issue 14 (2026), pp. 329-349.
© Authors: CC BY-NC-ND
IJAFAME
International Journal of Accounting, Finance, Auditing, Management & Economics

(10). 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.
(11). Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
(12). Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. The Review of Financial Studies, 33(5), 2223–2273.
(13). Harvey, C. R., Liu, Y., & Zhu, H. (2016). … and the cross-section of expected returns. The Review of Financial Studies, 29(1), 5–68.
(14). Hendershott, T., Jones, C. M., & Menkveld, A. J. (2011). Does algorithmic trading improve liquidity? The Journal of Finance, 66(1), 1–33.
(15). Hutchinson, J. M., Lo, A. W., & Poggio, T. (1994). A nonparametric approach to pricing and hedging derivative securities via learning networks. The Journal of Finance, 49(3), 851–889.
(16). Khandani, A. E., Kim, A. J., & Lo, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. Journal of Banking & Finance, 34(11), 2767–2787.
(17). Krauss, C., Do, X. A., & Huck, N. (2017). Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. European Journal of Operational Research, 259(2), 689–702.
(18). Lessmann, S., Baesens, B., Seow, H.-V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. European Journal of Operational Research, 247(1), 124–136.
(19). López de Prado, M. (2018). Advances in Financial Machine Learning. Wiley.
(20). Loughran, T., & McDonald, B. (2011). When is a liability not a liability? Textual analysis, dictionaries, and 10-Ks. The Journal of Finance, 66(1), 35–65.
(21). Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. PLOS ONE, 13(3), e0194889.
(22). Markowitz, H. (1952). Portfolio selection. The Journal of Finance, 7(1), 77–91.
(23). Mitchell, T. M. (1997). Machine Learning. McGraw-Hill.
(24). Mullainathan, S., & Spiess, J. (2017). Machine learning: An applied econometric approach. Journal of Economic Perspectives, 31(2), 87–106.
(25). Ngai, E. W. T., Hu, Y., Wong, Y. H., Chen, Y., & Sun, X. (2011). The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. Decision Support Systems, 50(3), 559–569.
(26). Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. Nature Machine Intelligence, 1, 206–215.
(27). Sutton, R. S., & Barto, A. G. (2018). Reinforcement Learning: An Introduction (2nd ed.). MIT Press.
(28). Tetlock, P. C. (2007). Giving content to investor sentiment: The role of media in the stock market. The Journal of Finance, 62(3), 1139–1168.
(29). Zaimovic, A., Omanovic, A., & Arnaut-Berilo, A. (2021). How many stocks are sufficient for equity portfolio diversification? A review of the literature. Journal of Risk and Financial Management, 14(11), 551.