

Intelligence Artificielle, Méga Données et Paradigme de l'efficience des marchés : Feuille de route et guide compréhensif

Artificial Intelligence, Big Data and Market Efficiency Paradigm : Roadmap and comprehensive guide

Oumaima AYI

Faculté d'Économie et de Gestion, Université Ibn Tofail, Kénitra, Maroc

Mounir ELBAKKOUCHI

Faculté d'Économie et de Gestion, Université Ibn Tofail, Kénitra, Maroc

Résumé. La manière dont fonctionne l'industrie financière évolue de manière spectaculaire et rapide grâce à l'intelligence artificielle (IA) et à l'apprentissage automatique (ML). Les banques et les banquiers se tournent de plus en plus vers ces technologies pour améliorer le service client, mieux gérer les risques et rationaliser de nombreux processus internes. Par conséquent, cet article propose une revue exhaustive du degré d'intégration de l'IA et du ML dans le secteur financier à ce jour, en examinant leurs avantages, leurs inconvénients, ainsi que les développements associés au traitement des données à grande échelle (Big Data). L'article met l'accent sur les bénéfices liés à l'adoption de ces technologies guidées par l'innovation, allant d'une efficacité opérationnelle accrue et d'une précision améliorée, à une meilleure gestion des risques, en passant par une expérience client de qualité supérieure. Il aborde également certaines problématiques et risques associés à l'utilisation de l'IA et du ML dans la finance, tels que les considérations éthiques, la confidentialité des données, la cybersécurité, ainsi que le risque de biais algorithmique. Parallèlement, l'étude explore les implications théoriques et empiriques de l'utilisation de l'IA et du Big Data à la lumière de l'hypothèse d'efficience des marchés (EMH). Cette dernière, issue directement de la finance néoclassique, stipule que « le prix d'un actif financier reflète instantanément toute l'information disponible ». En examinant de manière critique et synthétique des articles scientifiques récents, l'étude analyse empiriquement le rôle des modèles d'apprentissage automatique et profond (tels que les réseaux de neurones, les machines à vecteurs de support, les arbres de décision et leurs hybrides) dans la prévisibilité des prix des actifs, des tendances et de la volatilité. Ces avancées sont ainsi évaluées à travers le prisme des postulats classiques de l'efficience des marchés.

Mots-clés : *Apprentissage automatique, Données massives, Intelligence artificielle, Finance, Prédiction boursière, l'efficience des marchés.*

Abstract. The way the financial industry works is changing dramatically and quickly thanks to Artificial Intelligence (AI) and Machine Learning (ML). Banks and bankers are turning to these technologies in greater numbers to improve customer service, better manage risk and to streamline many of their internal processes. Therefore, this paper provides an exhaustive review of the extent to which AI and ML have been incorporated into finance to date, their advantages, disadvantages, and the developments in large-scale data processing (Big Data). The piece focuses on the benefits of adopting these technologies that are technology-driven, ranging from improved efficiency and accuracy of operation, better risk management as well as a superior experience for customers. It also touches on some of the issues and the risks of deploying AI and ML in finance like ethical considerations, data privacy and cybersecurity considerations, and the risk of algorithm bias. Concurrently, the study probes the theoretical and empirical implications of the utilization of AI and Big Data with the EMH. So, this hypothesis which comes right out of neoclassical finance says 'the price of a financial asset instantly reflects all available information'. By critically examining and summarizing recent journal articles, the study empirically investigates the roles played by machine and deep learning models (i.e., neural networks, SVMs, decision trees and their hybrids) on the

predictability of asset prices, trends and volatility. By studying the market from the viewpoint of the classic assumptions of the market efficiency, these advances are reviewed.

Keywords: *Machine learning, Big data, Artificial intelligence, Finance, Stock market prediction, Market Efficiency.*

1. Introduction

“What we're seeing is something unprecedented, which is the arrival of artificial intelligence, which has a big impact ... it creates tremendous uncertainty and impacts different people differently ... and some people could be left out.” Robert Shiller, 2018 Davos Forum.

Les structures d'intelligence artificielle (IA) sont des dispositifs informatiques à différents niveaux d'autonomie qui, pour une totalité d'objectifs à atteindre définis à l'avance par l'utilisateur, produisent pour lui des prédictions, des recommandations ou des décisions, à partir d'une variété de données alternatives et des analyses qui y sont associées, réunies sous le nom de « Big Data ». L'approbation généralisée de l'apprentissage en cours du secteur financier, y compris concernant le risk management, de trading algorithmique, de prêts et de services financiers basés sur des blockchains, intervient alors que des volumes de données massifs sont disponibles et que le calcul est devenu à la fois plus accessible et plus rapide. L'essor rapide des technologies de l'information et des bases de données, couplé aux progrès remarquables réalisés dans les méthodes d'analyse de données et les performances du matériel informatique, a entraîné une augmentation exponentielle du déploiement des méthodes d'apprentissage automatique (ML) dans divers domaines, en particulier le commerce et la finance, Nazareth et Ramana, 2023 ; Chen et al., 2022 ; Hoang et Wiegratz, 2022 ; Xiao et Ke, 2021 Gogas et Papadimitriou, 2021; Ozbayoglu et al., 2020). L'utilisation des techniques d'apprentissage automatique dans des domaines tels que le commerce, le marketing, l'électronique et l'énergie a démontré des résultats particulièrement prometteurs (Athey et Imbens, 2019). En comparaison avec les modèles économétriques traditionnels, les techniques de ML permettent de traiter de manière plus efficace d'immenses quantités de données structurées et chaotiques, facilitant ainsi la prise de décision et la prévision rapide. Ces avantages proviennent essentiellement de la capacité des modèles de ML à fonctionner sans présupposés spécifiques quant à la forme fonctionnelle ou à la distribution des paramètres.

Les deux dernières décennies ont été caractérisées par des avancées significatives en intelligence artificielle (IA) et en robotique. Des progrès futurs, encore plus spectaculaires, sont attendus, et de nombreux observateurs prévoient que ces technologies transformeront profondément le monde du travail à l'échelle globale (McKinsey Global Institute, 2017 ; Brynjolfsson et McAfee 2014; Boston Consulting Group 2015 ; Ford 2016). Des enquêtes récentes révèlent par ailleurs des niveaux élevés d'inquiétude liés à l'automatisation et à d'autres tendances technologiques, soulignant ainsi les préoccupations largement répandues quant à leurs effets potentiels (Pew Research Center, 2017).

La prédiction financière, pilier des décisions d'investissement, est aujourd'hui bouleversée par l'émergence des avancées d'intelligence artificielle et de Big Data. Historiquement cadrée par l'hypothèse d'efficacité des marchés (EMH) d'Eugene Fama, cette discipline est en pleine mutation s'écroule, remettant en en doute la pertinence de cette hypothèse. Cette étude se penche sur la question de l'effet que ces nouvelles technologies exercent sur les marchés financiers, en interrogeant explicitement leur compatibilité avec les fondements théoriques de l'EMH.

Cette recherche se singularise par sa démarche novatrice, multidimensionnelle et intégrative qui articule les apports théoriques de l'efficacité des marchés financiers (EMH) avec les avancées méthodologiques contemporaines en (IA) et en analyse de (Big Data). Elle s'inscrit dans une logique d'interrogation épistémologique et d'exploration empirique à forte valeur ajoutée. D'une part, l'étude propose une revue solide et approfondie de la littérature scientifique tout en examinant plus de 120 publications à travers une double grille de lecture à savoir les techniques d'IA mobilisées (Deep Learning, Reinforcement Learning, Réseaux Neuronaux

Hybrides,...) et les dimensions du marché financier étudiées (types d'actifs, horizons temporels, méthodes d'évaluation). Cette approche permet non seulement de cartographier de manière exhaustive l'état de l'art mais aussi d'identifier les dynamiques émergentes et les lacunes critiques dans les recherches existantes.

D'autre part, l'article se distingue par son positionnement critique vis-à-vis du paradigme classique de l'efficacité des marchés en explorant les tensions entre les postulats néoclassiques tels que la transparence informationnelle, rationalité des agents, ajustement instantané des prix et les capacités prédictives empiriquement démontrées par les modèles d'apprentissage profond. En cela, l'étude contribue à réinterroger la validité et l'actualité de l'EMH à l'ère des marchés algorithmisés en suggérant les contours d'un paradigme alternatif qui est une efficacité computationnelle fondée sur la capacité adaptative des systèmes intelligents à intégrer et prédire l'information.

En outre, la recherche se distingue par ses propositions opérationnelles et théoriques notamment :

- La nécessité de renforcer l'interprétabilité des modèles IA, condition essentielle à leur légitimité réglementaire et à leur adoption institutionnelle ;
- L'intérêt de développer des architectures hybrides intégrant simultanément l'analyse technique et fondamentale en vue d'augmenter la robustesse des modèles de prévision;
- L'importance de concevoir des dispositifs intelligents de détection de crise et de gestion dynamique du risque.

Enfin, l'étude se veut transversale et prospective mobilisant des cadres analytiques issus de la finance quantitative, de la data science, de l'apprentissage automatique et des fondements épistémologiques de la décision dans un environnement incertain et volatil. Elle ambitionne ainsi de contribuer au renouvellement du débat académique sur les formes contemporaines d'efficacité tout en proposant un socle rigoureux pour le développement futur de systèmes de trading autonomes performants.

Pour répondre à cette problématique et mieux appréhender les dynamiques en jeu entre l'intelligence artificielle, le Big Data et l'efficacité des marchés financiers, l'article s'articule autour de six axes complémentaires. Il débute par une définition conceptuelle de l'intelligence artificielle et ses principales typologies posant ainsi les jalons terminologiques nécessaires à la compréhension du propos. Le deuxième axe est consacré à une revue de littérature ciblée et à la contextualisation scientifique de la problématique. Dans un troisième temps, les applications concrètes de l'IA dans le domaine financier sont passées en revue mettant en lumière les usages actuels. Le quatrième axe explore le paradigme de l'efficacité des marchés et c'est en exposant ses limites à la lumière des avancées technologiques. Le cinquième volet s'attarde sur l'émergence du Big Data et son rôle crucial dans l'amélioration des capacités prédictives des modèles boursiers. Et enfin l'article se conclut par une synthèse intégrative soulignant les interactions entre l'IA, le Big Data et le paradigme d'efficacité des marchés en ouvrant ainsi des perspectives théoriques et empiriques pour les recherches futures. Et c'est à travers une revue de littérature exhaustive conduite à partir d'une sélection rigoureuse d'études.

2. Tsunami de Intelligence artificielle

a. C'est quoi l'Intelligence artificielle?

En 1950, Alan Turing posait la célèbre question : « can machine think ? ». Depuis lors, les applications de l'intelligence artificielle (désormais abrégée IA) ont connu des succès divers. Cependant, ces dernières années, on observe un regain d'intérêt significatif pour l'IA qui trouve désormais des applications innovantes à l'échelon mondial des services financiers. La disponibilité du Big Data, les avancées technologiques, l'informatique en nuage (cloud computing), ainsi que le matériel informatique spécialisé de plus en plus performant constituent les moteurs principaux de cette nouvelle vague d'innovation en IA. Les capacités offertes par l'IA et l'apprentissage automatique (Machine Learning, ML) stimulent notamment la

croissance du marché émergent de la Fintech. En termes généraux, la Fintech englobe les nouvelles technologies, services et entreprises qui transforment les services financiers. Cela inclut, sans s'y limiter : les cryptomonnaies, la blockchain, les conseillers automatisés (robo-advisors), les contrats intelligents (smart contracts), le financement participatif, les paiements mobiles et les plateformes d'IA. En 2017, l'IA s'est imposée comme une tendance majeure dans les services financiers et le secteur Fintech (Future Today Institute, 2017).

Comme dans d'autres secteurs de la Fintech, l'IA présente de nombreuses opportunités ainsi que des défis notables. Du point de vue de l'inclusion financière, l'application croissante de l'IA aux marchés financiers devrait réduire les barrières d'entrée pour un grand nombre d'individus qui, auparavant, ne disposaient pas nécessairement d'un accès à ces marchés. Certaines des plus grandes entreprises technologiques mondiales, telles que Apple, Amazon, Tencent et Alibaba, investissent massivement dans la recherche en IA. Toutefois, comme le souligne Robert Shiller lors du Forum de Davos en 2018, l'IA génère également une grande incertitude en tant que technologie potentiellement disruptive.

L'IA continue de devenir plus sophistiquée et complexe, tout comme les marchés financiers, ce qui pose d'importants défis en matière de réglementation et d'élaboration des politiques publiques. Enfin, la présente étude examine comment le ML influence les outils utilisés par les régulateurs pour élaborer des politiques, détecter les fraudes, estimer l'offre et la demande, et assurer la conformité. À l'avenir, les régulateurs devront maintenir des procédures pour déterminer la responsabilité d'une entreprise ou d'une personne. Cette analyse détaille les réponses réglementaires internationales à l'IA dans les services financiers, avec une attention particulière portée au Royaume-Uni, en examinant notamment des agences telles que la Banque d'Angleterre, la Financial Conduct Authority (FCA), le Serious Fraud Office, ainsi que la Competition and Markets Authority.

Le terme « intelligence artificielle » a été introduit en 1956 par John McCarthy. Selon l'Oxford English Dictionary, l'IA est communément défini comme « la théorie et le développement de systèmes informatiques capables d'accomplir des tâches qui nécessitent habituellement l'intelligence humaine, telles que la perception visuelle, la reconnaissance vocale, la prise de décisions et la traduction de langues ». De manière similaire, le Financial Stability Board (FSB, 2017) définit l'IA comme « la théorie et le développement de systèmes informatiques capables d'accomplir des tâches qui traditionnellement exigent une intelligence humaine ».

Le développement historique de l'IA est présenté dans l'annexe. Il ressort clairement de la chronologie que les premières tentatives en IA se concentraient sur des règles intégrant des algorithmes logiques. Turing (1950) propose un test opérationnel (le test de Turing) permettant d'évaluer les comportements intelligents. Dans son travail fondateur, Turing a posé les bases essentielles des futurs travaux en IA dans les domaines du langage, du raisonnement, des connaissances, de l'apprentissage et de la compréhension. Grâce au test de Turing, il a ouvert la voie au ML, aux algorithmes génétiques et à l'apprentissage par renforcement. La tentative de reproduire le processus logique de prise de décision humaine à travers le traitement de symboles fut appelée « l'hypothèse de traitement symbolique » (Gilmartin, Newell et Simon, 1976; Newell et Simon, 1961, Shaw et Simon, 1957).

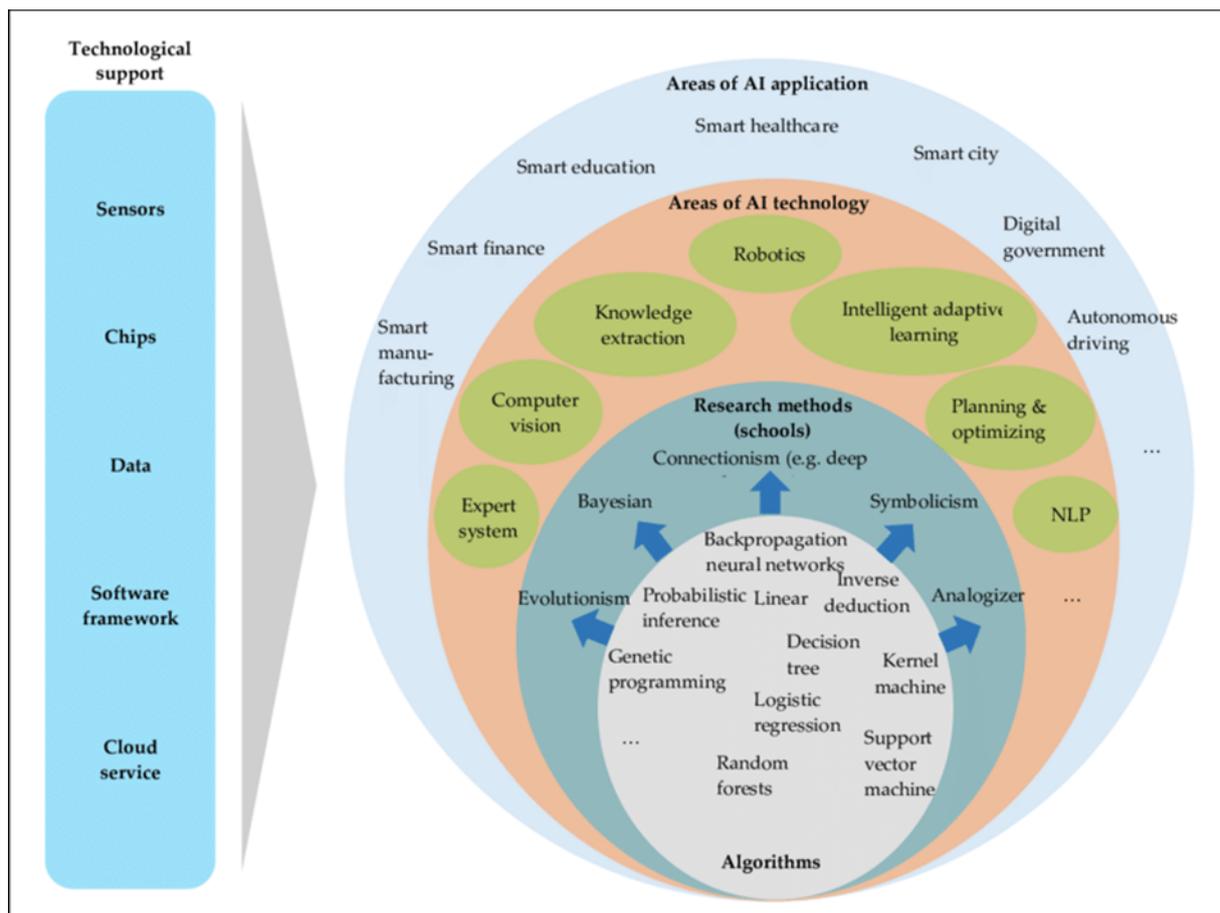
La majorité des travaux en IA des années 1950 et 1960 n'étaient pas axés sur des applications financières. Au cours des années 1960, un corpus important sur la statistique bayésienne fut développé, servant ultérieurement au ML. Les réseaux neuronaux, qui allaient devenir la pierre angulaire de l'apprentissage profond (Deep Learning), apparurent dans les années 1960 et connurent une croissance rapide. Cependant, par manque de données électroniques suffisantes et de puissance informatique, l'IA connut une période de désintérêt appelée « hiver de l'IA » (Kaplan, 2016 ; FSB, 2017), caractérisée par un ralentissement des investissements et de l'intérêt général. En 1973, le rapport Lighthill au Royaume-Uni mit fin au soutien gouvernemental pour la recherche en IA.

L'apprentissage automatique trouve ses origines dans les travaux de McCulloch et Pitts (1943), qui identifièrent le caractère numérique (binaire) des signaux cérébraux. Selon Chakraborty et

Joseph (2017), un système ML comprend cinq composantes : (1) un problème, (2) une source de données, (3) un modèle, (4) un algorithme d'optimisation et (5) une phase de validation et de test.

Le ML est particulièrement adapté aux situations nécessitant d'extraire des motifs à partir de données bruitées ou de perceptions sensorielles, selon une approche ascendante (data-driven). Quatre facteurs principaux expliquent la croissance du ML : la transition vers des données stockées électroniquement, l'amélioration de la mémoire et de la vitesse de calcul, l'accès facilité via Internet, et les capteurs numériques à faible coût et à haute résolution. En 2011, la puissance de calcul et les capacités de stockage augmentaient rapidement, et les superordinateurs ouvraient de nouvelles perspectives en IA. Le Deep Learning (DL) devint alors la nouvelle avancée majeure. Le FSB (2017) définit le DL comme une technique d'apprentissage automatique utilisant des algorithmes structurés en « couches », inspirées du fonctionnement du cerveau humain. Les réseaux neuronaux artificiels, introduits initialement par McCulloch et Pitts (1943), sont conçus pour imiter la structure du cerveau humain. Les avantages principaux du DL sont sa robustesse accrue face au surapprentissage et sa capacité à gérer des événements non-linéaires comme la volatilité du marché, qui nécessitent généralement des ajustements manuels dans les modèles quantitatifs classiques. En 2012, Google gérait deux projets de DL ; en 2017, ce nombre dépassait les mille projets (Makridakis, 2017).

Figure 1: Illustration of all Levels of AI



b. Machine Learning ML

En 1997 Tom Mitchell, a défini le ML: “A computer program is said to learn from experience E with respect to some task T and some performance measure P, if its performance on T, as measured by P, improves with experience E.”

Définir opérationnellement l'apprentissage automatique (Machine Learning, ML) s'avère plus

complexe qu'il n'y paraît initialement. Ce terme désigne non seulement un ensemble de sous-domaines spécifiques de l'informatique, mais également un éventail de sujets développés et employés dans plusieurs disciplines, telles que l'ingénierie, la statistique, et de manière croissante les sciences sociales. L'apprentissage automatique est un champ disciplinaire qui développe des algorithmes conçus pour être appliqués à des ensembles de données, avec pour principaux objectifs la prédiction (régression), la classification et le regroupement (clustering). Ces tâches se divisent en deux grands types : l'apprentissage supervisé et non supervisé. L'apprentissage non supervisé implique l'identification de clusters d'observations similaires en termes de leurs variables explicatives, processus souvent interprété comme une « réduction dimensionnelle ». Cette approche est couramment utilisée pour l'analyse de vidéos, d'images et de textes. Parmi les méthodes populaires en apprentissage non supervisé figurent le clustering k-moyennes, les modèles de sujets (topic modeling), et les méthodes de détection de communautés dans les réseaux. Par exemple, le modèle d'allocation de Dirichlet latente (Blei, Ng et Jordan, 2003) est fréquemment utilisé pour identifier des « sujets » dans des données textuelles. Typiquement, un modèle d'apprentissage non supervisé produit une partition d'observations, dans laquelle chaque groupe contient des observations similaires selon une métrique définie, ou encore un vecteur de probabilités ou de pondérations décrivant une combinaison de sujets ou de groupes auxquels une observation pourrait appartenir. Ces outils sont particulièrement utiles comme étapes intermédiaires dans les travaux empiriques en économie.

Il est crucial de préciser que lorsqu'on parle de « prédiction », le cadre théorique ne porte pas exclusivement sur la prévision au sens temporel, mais plutôt sur des situations où il existe des observations étiquetées pour lesquelles les variables explicatives (X) et les variables cibles (Y) sont connues (données d'entraînement), et où l'objectif est de prédire les résultats (Y) pour un ensemble de test indépendant sur la base des valeurs réalisées de X.

Historiquement, l'approche classique de vision par ordinateur était l'écriture d'un ensemble de règles pour identifier des pixels d'images relativement évidents, tels que la couleur, la luminosité et les contours, en les caractérisant pour prédire des étiquettes. Ce traitement, appelé « featurization » n'avait pas de succès. Les approches modernes fonctionnent directement à partir de pixels bruts sans prédéfinir explicitement des caractéristiques pour être lues par des réseaux multi-couches connus sous le nom de réseau de neurones. Cette approche ne s'est pas uniquement montrée efficace pour la reconnaissance d'images mais aussi pour la détection de voix, la traduction initiale et d'autres tâches qui étaient, jusqu'à il n'y a pas longtemps, des défis d'IA considérables. De nos jours, ces tâches sont exécutées par des systèmes informatiques qui surclasse l'humain dans ce domaine.

Cette approche, appelée Deep Learning, nécessite a) des données étiquetées pour l'entraînement, b) des algorithmes spécifiques pour les réseaux neuronaux, et c) du matériel informatique spécialisé pour exécuter ces algorithmes. Les chercheurs académiques et sociétés de technologie ont distribué massivement gratuitement ces données d'entraînement et ces algorithmes, tandis que les capacités de calcul, y compris pour l'informatique en nuage, continuent d'être bon marché. Une troisième étape concernant une forme importante d'apprentissage automatique concerne l'apprentissage par renforcement. Cette approche est basée sur l'optimisation d'une tâche spécifique, comme celle de gagner aux échecs ou quelques jeux vidéo. En soi, l'apprentissage par renforcement repose essentiellement sur l'expérimentation séquentielle et est donc intrinsèquement lié à la causalité, telle que le choix d'un seul mouvement d'une seule pièce d'échecs.

L'apprentissage automatique et l'intelligence artificielle existent depuis plusieurs années. Cependant, les cinq dernières années ont vu des progrès remarquables grâce aux réseaux neuronaux multicouches dans divers domaines tels que la reconnaissance d'images, la reconnaissance vocale et la traduction automatique. L'intelligence artificielle représente une technologie polyvalente susceptible d'impacter de nombreux secteurs.

L'intelligence artificielle, également les secteurs d'apprentissage automatique et

d'apprentissage profond, évoluent de manière radicalement l'analyse financière des marchés. Conformément, les technologies de l'intelligence artificielle permettent de traiter les volumes de Big Data de données hétérogènes, d'identifier des régularités subtiles, et de fabriquer des modèles prédictifs flexibles et adaptables qui évaluent des formes non-linéaires et des interactions sophistiquées à l'intérieur de marchés financiers.

Plusieurs applications réussies des méthodes prédictives ont déjà été réalisées pour résoudre des problèmes politiques. Kleinberg et al. (2015) affirment que certaines problématiques cruciales en matière de politique et de décision peuvent être efficacement traitées à l'aide de techniques standards d'apprentissage automatique. Ils prennent l'exemple de la décision de procéder ou non à une opération de remplacement de hanche chez un patient âgé : si les caractéristiques individuelles permettent de prédire un décès dans l'année suivante, alors l'opération pourrait être évitée.

D'autres applications incluent le travail de Goel, Rao et Shroff (2016), qui utilisent des techniques d'apprentissage automatique afin d'analyser les lois relatives à la fouille et à la palpation (« stop-and-frisk ») en prédisant, à partir des observations des incidents policiers, la probabilité qu'un suspect détienne une arme. Ils montrent notamment que les personnes noires sont nettement moins susceptibles que les personnes blanches de détenir une arme en conditionnant sur les observables et les fouilles. Glaeser, Hillis et al. (2016) ont aidé des villes à concevoir des concours pour développer des modèles prédictifs identifiant les violations sanitaires dans les restaurants afin d'allouer plus efficacement les ressources d'inspection. Une littérature croissante exploite également l'apprentissage automatique combiné à des images satellites et des cartes de rue pour prédire la pauvreté, la sécurité et les valeurs immobilières (voir par exemple, Naik et al. 2017). Comme le soutiennent Glaeser, Kominers et al. (2015), ce type de méthodologie prédictive a un large éventail d'applications potentielles.

c. De la modélisation linéaire à l'intelligence computationnelle

Les Machine Learning Systems peuvent être catégorisés en se basant sur la quantité ou type de supervision durant le traitement. Quatre catégories se présentent: supervised learning, unsupervised learning, semi-supervised learning, and reinforcement learning (Géron, 2019).

i. Supervised Learning

L'apprentissage supervisé est l'apprentissage automatique où les données d'entraînement fournies à l'algorithme comprennent les solutions attendues, appelées étiquettes. La classification est une tâche typique de l'apprentissage supervisé.

ii. Unsupervised Learning

Dans l'apprentissage non supervisé, les données d'entraînement ne sont pas étiquetées, et le système tente d'apprendre sans supervision. Voici quelques algorithmes essentiels utilisés dans l'apprentissage non supervisé.

iii. Semi-supervised Learning

L'apprentissage semi-supervisé est utilisé dans les cas où l'étiquetage des données est coûteux ou chronophage et où les données sur lesquelles un modèle est entraîné contiennent un petit nombre d'échantillons étiquetés et un grand nombre d'échantillons non étiquetés. Lors de la semi-apprentissage, certains algorithmes sont capables de traiter des données partiellement ou en totalité.

iv. Reinforcement Learning

L'apprentissage par renforcement est un autre type de système d'apprentissage très différent de l'apprentissage supervisé et non supervisé. Cet apprentissage est un design, où le système nommé agent peut observer l'environnement, choisir et exécuter des actions, et puis obtenir des récompenses ou sanctions. L'agent doit apprendre par lui-même quelle est la meilleure stratégie

qu'on appelle politique pour obtenir la récompense maximale au fil du temps. La politique définit ce doit être fait par l'agent si elle se retrouve dans une certaine situation.

d. Deep Learning

L'apprentissage profond (Deep Learning, DL) est une division spécialisée de l'apprentissage automatique qui se concentre sur l'acquisition de représentations des données par des couches successives, chacune apportant une abstraction supplémentaire aux représentations précédentes. Le terme « profond » ne se réfère pas à une compréhension accrue obtenue par cette approche, mais plutôt à la présence de multiples couches successives de représentations qui confèrent sa profondeur au modèle. Contrairement aux méthodes classiques d'apprentissage automatique, qui se limitent généralement à une ou deux couches de représentation des données, l'apprentissage profond exploite des réseaux neuronaux multicouches pour apprendre ces représentations hiérarchiques.

Bien que le terme « réseau neuronal » s'inspire de la neurobiologie, les modèles d'apprentissage profond ne constituent pas des modèles fidèles du cerveau humain, et aucune preuve ne démontre que les mécanismes d'apprentissage cérébraux correspondent aux processus utilisés par ces modèles modernes. En réalité, l'apprentissage profond est davantage un cadre mathématique dédié à l'apprentissage de représentations des données.

L'une des principales forces de l'apprentissage profond réside dans sa capacité à extraire directement des connaissances à partir de données brutes telles que des images, des textes ou des sons, sans recourir à des caractéristiques manuellement définies. Ainsi, les modèles d'apprentissage profond atteignent régulièrement des performances exceptionnelles sur diverses tâches complexes, dépassant souvent les capacités humaines.

Bien que l'apprentissage profond existe depuis plusieurs décennies, c'est au début des années 2010 qu'il a attiré une attention considérable grâce à ses résultats remarquables dans des problèmes perceptuels tels que la reconnaissance des images et la reconnaissance vocale. Depuis, l'apprentissage profond a considérablement influencé le domaine de l'intelligence artificielle et de l'apprentissage automatique (Chollet, 2021 ; Deng et Yu, 2014).

Ding et al. ont élargi cette approche en extrayant des événements de textes d'actualités, représentés sous forme de vecteurs denses, et en entraînant un nouveau type de réseau neuronal tensoriel. En utilisant un réseau neuronal convolutif profond (CNN), ils ont modélisé les effets à court et à long terme sur les mouvements du cours des actions. Cette méthode a permis d'améliorer de 6,6 % la prédiction de l'indice S&P500 par rapport aux données historiques des actions, augmentant ainsi la rentabilité. Constatant que les approches classiques en traitement du langage naturel (NLP) telles que les sacs de mots, les phrases nominales et les entités nommées ne capturaient pas efficacement les relations structurelles, ils ont utilisé l'extraction ouverte d'information (Open IE) pour résoudre ce problème. Sur la base de plus de 10 millions d'événements pour l'entraînement, ils ont conclu que les prédictions quotidiennes étaient plus précises que celles hebdomadaires ou mensuelles. Ils ont également démontré que l'intégration d'événements est plus pertinente que les mots simples pour la prédiction des marchés boursiers, et que les modèles basés sur des CNN surpassent ceux fondés sur des réseaux neuronaux classiques (Ding et al., 2015).

Agrawal et al. ont étudié l'impact des analystes techniques sur le marché boursier en développant un modèle évolutif d'apprentissage profond (EDLM) destiné à prédire les mouvements des prix des actions grâce aux indicateurs techniques à court terme (STIs). L'étude, basée sur les données du marché boursier NSE entre novembre 2008 et novembre 2018, a utilisé un réseau de mémoire à court terme (LSTM) pour introduire le concept de corrélation-tensorielle. Le modèle EDLM a atteint une précision de prédiction de 63,59 % pour HDFC, 56,25 % pour Yes Bank et 57,95 % pour SBI. Ce modèle s'est avéré supérieur à d'autres algorithmes de pointe, permettant ainsi aux traders de prendre des décisions rentables basées sur des prédictions de tendances (Agrawal et al., 2022).

Chen (2018) a employé une combinaison de modèles d'apprentissage profond, incluant un

modèle de prédiction d'indices boursiers basé sur l'apprentissage profond, un auto-encodeur et une machine de Boltzmann restreinte, afin de prédire les mouvements futurs des marchés boursiers. Chen a comparé trois types de réseaux neuronaux artificiels : les réseaux de neurones à rétropropagation du gradient (BP), les machines à apprentissage extrême (ELM), et les réseaux à fonction de base radiale (RBF). Les résultats obtenus indiquent que les méthodes d'apprentissage profond offrent la meilleure précision avec la marge d'erreur la plus faible, malgré un temps d'apprentissage plus important par rapport aux autres modèles (Chen et al., 2018).

i. Convolutional Neural Network

Les (CNN) s'inspirent de la structure du cortex visuel dans le cerveau et sont utilisés dans la reconnaissance d'images depuis les années 1980. En combinant les avancées en puissance de calcul, l'accès à une grande quantité de données d'entraînement et des techniques améliorées pour entraîner des réseaux profonds, les CNN ont atteint des résultats exceptionnels au cours des dernières années dans des tâches visuelles complexes. Ces technologies pour des applications allant de la recherche d'images à des systèmes automatisés, en passant par la classification automatique de vidéos et bien d'autres. En outre, les CNN, pour être traditionnellement associés aux tâches visuelles, ont été trouvés pour être efficaces également lors du travail dans des domaines comme la reconnaissance vocale et le traitement du langage naturel.

À la fin des années 1950 et au début des années 1960, Hubel et ses collaborateurs ont mené plusieurs expériences sur des chats (Hubel, 1959 ; Hubel et Wiesel, 1959) puis sur des singes, fournissant ainsi des éclairages décisifs sur la structure du cortex visuel (Hubel et Wiesel, 1968). Ces recherches ont révélé que de nombreux neurones du cortex visuel possèdent des champs récepteurs locaux réduits, répondant uniquement à des stimuli visuels dans une zone limitée du champ visuel. Les champs récepteurs de différents neurones peuvent se chevaucher pour couvrir tout le champ visuel. De plus, certains neurones répondent uniquement à des lignes horizontales, tandis que d'autres répondent à des lignes ayant différentes orientations. Certains neurones possèdent des champs récepteurs plus vastes et réagissent à des motifs plus complexes combinant des caractéristiques de niveau inférieur. Ces observations indiquent que les neurones de niveau supérieur reçoivent des entrées provenant de neurones voisins de niveaux inférieurs. Cette architecture puissante permet aux CNN de détecter des motifs complexes dans tout champ visuel.

ii. Recurrent Neural Network

Ces dix dernières années, les réseaux neuronaux récurrents (RNN) ont connu un succès remarquable dans divers domaines tels que la reconnaissance vocale, la modélisation du langage, la traduction automatique, ou encore la génération automatique de légendes. Toutefois, pour atteindre ces performances, l'utilisation d'un type spécifique de RNN appelé « mémoire à court et long terme » (Long Short-Term Memory, LSTM) s'avère indispensable. En effet, les LSTM présentent des résultats bien supérieurs à la version originale des RNN dans la plupart des tâches, et presque toutes les avancées notables basées sur des RNN reposent sur les modèles LSTM.

Cependant, les RNN traditionnels présentent une grande limitation dans ce cas : ils ne peuvent associer que des informations passées concernant la tâche actuelle. Par exemple, un RNN ne pourra utiliser les images passées d'un film pour comprendre l'image actuelle. Cependant, on peut imaginer des cas où l'information récente devrait être utilisée pour réaliser des tâches actuelles : même un simple modèle de langue utilisé pour prédire le prochain mot basé sur les mots précédents n'aura pas besoin de plus de contexte si le dernier mot de la phrase est « ciel » dans « les nuages flottent dans le ... ». Par conséquent, les RNN sont impuissants lorsqu'il s'agit d'un écart relativement faible entre l'information pertinente dans les données et l'information réellement nécessaire.

iii. Long Short-Term Memory

Toutefois, pour atteindre ces performances, l'utilisation d'un type spécifique de RNN appelé « mémoire à court et long terme » (Long Short-Term Memory, LSTM) s'avère indispensable. En effet, les LSTM présentent des résultats bien supérieurs à la version originale des RNN dans la plupart des tâches, et presque toutes les avancées notables basées sur des RNN reposent sur les modèles LSTM.

Les LSTM, réseau développé spécifiquement pour résoudre les problèmes de dépendances à long terme. Cependant, contrairement aux RNN classiques, les LSTM sont capables de conserver des informations sur de longues périodes, comme il est essentiel pour de nombreuses applications. La base de leur architecture est une série de modules neuronaux répétés; néanmoins, à l'instar des RNN traditionnels, ces modules ne sont pas limités à la couche de type tanh. En général, les LSTM contiennent quatre couches interconnectées qui ont une structure bien définie, ce qui permet un traitement plus sophistiqué de l'information temporelle. Dans le contexte de la modélisation du langage, les LSTM peuvent être utilisés pour prédire le mot suivant à partir des mots précédents. Par exemple, il peut être nécessaire que l'état de la cellule retienne une information telle que le genre du sujet en cours afin d'utiliser le pronom approprié. Lorsqu'un nouveau sujet est introduit, le LSTM doit alors être capable d'« oublier » l'information de genre associée au sujet précédent, illustrant ainsi la capacité d'adaptation dynamique de ce type de réseau.

e. Transfer Learning

L'apprentissage par transfert fait référence à l'utilisation de connaissances acquises lors de la résolution d'un problème et à leur application dans d'autres situations au sein d'un même domaine. Les modèles d'apprentissage profond possèdent un grand nombre de paramètres en raison de la complexité des couches cachées et des connexions entre les unités, ce qui nécessite des volumes importants de données pour l'entraînement. Toutefois, il arrive fréquemment que les données disponibles soient insuffisantes, ce qui engendre un risque de surapprentissage (). Les modèles d'apprentissage profond sont particulièrement efficaces pour des tâches telles que la reconnaissance d'objets en traitement d'images. Dans ce type de cas, l'apprentissage par transfert permet de tirer parti des caractéristiques générales extraites par un modèle profond pré-entraîné, afin de construire un modèle plus simple, spécifiquement adapté à un problème donné. Les seuls paramètres requis pour le nouveau modèle sont ceux nécessaires à sa conception. Les modèles pré-entraînés sont généralement développés à partir de vastes ensembles de données et possèdent des paramètres robustes et fiables.

L'apprentissage par transfert (Transfer Learning) est un domaine qui exploite les connaissances déjà acquises lors de la résolution d'un problème pour les appliquer à d'autres situations du même domaine. Les modèles d'apprentissage profond ont souvent une grande quantité de paramètres en raison de la grande complexité des couches cachées et des connexions entre les unités, ce qui signifie qu'ils ont un besoin volumineux de données pour être formés. Cependant, il n'est pas toujours évident de trouver suffisamment de données pour entraîner un modèle en profondeur. En outre, cela peut conduire à une formation excessive, overfitting. Les modèles d'apprentissage profond sont très bons pour ce qu'on appelle tasks. par exemple la « reconnaissance d'objets » est une tâche en traitement d'images. Et un exemple d'apprentissage par transfert consiste à reprendre toutes les caractéristiques générales qu'un modèle profond pré-entraîné a trouvées. Je vais expliquer en détail le reusage du modèle d'image à l'apprentissage sans transfert.

f. Residual Neural Network

Dans les réseaux neuronaux convolutifs (CNN) traditionnels, le réseau cherche à apprendre une fonction de mappage structurelle qui permet de classer précisément les données d'entrée au cours des opérations de convolution et des étapes associées. En revanche, les blocs résiduels de

ResNet visent à apprendre une fonction de mappage résiduelle, dans laquelle l'entrée est ajoutée à la sortie de chaque opération Convolution–ReLU–Convolution. Cette méthode consiste à enrichir chaque petit bloc fonctionnel en y réinjectant l'information initiale, afin de produire une sortie finale améliorée. L'idée repose sur le principe que l'apprentissage d'un mappage résiduel à partir de l'entrée initiale vers la sortie est plus simple (Pattanayak, 2017).

g. VGG Network

En 2014, la VGG16 architecture a été introduite en tant que finaliste du ILSVRC competition, et depuis, elle est devenue l'un des modèles standard pour les tâches de reconnaissance d'images. Selon Simonyan & Zisserman, ce modèle est basé sur une architecture simple mais puissante, utilisant des filtres de taille 3×3 et la fonction d'activation ReLU, et une méthode de max-pooling de taille 2×2 plutôt qu'utiliser des noyaux plus grands avec la convolution. Ils ont suggéré que deux couches de 3×3 conv équivalent à une seule couche de 5×5 conv, tout en maintenant une taille de filtre plus petite. Cette pratique diminue le nombre de paramètres tout en augmentant la non-linéarité de la fonction en raison de l'ajout de deux paires conv-ReLU au lieu de une. Une autre caractéristique clé est que, en augmentant la profondeur du modèle, les dimensions spatiales de la taille du volume d'entrée diminuent en raison des opérations de convolution et de max-pooling, mais le nombre de cartes de caractéristique augmente à mesure que de nouveaux filtres sont approvisionnés.

h. Google's InceptionV3

InceptionV3, développé par Google, est l'un des réseaux neuronaux convolutifs les plus avancés. En 2014, cette variante de GoogLeNet a remporté le concours ILSVRC grâce à son architecture de réseau neuronal convolutif innovante (Szegedy et al., 2016). L'innovation majeure de GoogLeNet et de ses versions ultérieures réside dans l'introduction du module Inception pour le pooling et la convolution. Dans les réseaux convolutifs traditionnels, une couche de convolution est généralement suivie soit d'un max-pooling, soit d'une autre opération de convolution.

3. Contexte de la recherche

Dans des recherches récentes en apprentissage automatique, Shen et al. ont utilisé (SVM) ainsi que l'apprentissage par renforcement pour prédire les tendances d'un marché boursier spécifique, en analysant les variations d'autres marchés tels que les bourses internationales, les taux de change, les prix du pétrole, de l'or et de l'argent. En corrélant les variations de ces variables avec celles du marché principal (NASDAQ), ils ont constaté que la précision des prédictions augmentait avec le temps à mesure que davantage de données étaient collectées ; leur étude s'est appuyée sur un volume de données couvrant deux années (Shen et al., 2012).

Chatzis et al. ont pour leur part combiné des techniques d'apprentissage profond avec des méthodes statistiques pour prédire les crises sur les marchés boursiers et étudier les mécanismes de transmission entre marchés. Ils ont utilisé un ensemble diversifié d'algorithmes d'apprentissage automatique, incluant des arbres de classification, des SVM, des forêts aléatoires, des réseaux neuronaux, des algorithmes de gradient boosting (XGBoost), ainsi que des réseaux neuronaux profonds, en se basant sur des données quotidiennes relatives aux actions, obligations et devises provenant de 39 pays.

Leurs résultats ont montré que les réseaux neuronaux profonds amélioraient significativement la précision des prédictions, et constituaient une méthode robuste pour concevoir un système global d'alerte précoce à l'intention des banques centrales, leur permettant d'ajuster leur politique monétaire à temps afin de préserver la stabilité économique (Chatzis et al., 2018).

Par ailleurs, les modèles économétriques classiques tels que ARIMA, GARCH ou VAR ... ont longtemps constitué l'armature de la modélisation financière. Toutefois, ces approches supposent des relations linéaires, la stationnarité des séries et une structure de dépendance temporelle forte. Cependant, avec la volatilité accrue, la non-stationnarité et à la complexité

structurelle de la nature des marchés, ces modèles montrent rapidement leurs défaillances. En revanche, les modèles de Machine Learning n'imposent aucune hypothèse a priori sur la forme fonctionnelle des données. Ils apprennent de manière inductive à partir des observations qui permettant d'extraire automatiquement des figures complexes.

Parmi les modèles fréquemment utilisés en finance prédictive, on peut citer :

- Support Vector Machines (SVM) : très efficaces pour la classification binaire des tendances de marché (hausse/baisse).
- Random Forests et arbres de décision : robustes aux données bruitées, adaptés à la sélection de variables pertinentes.
- Réseaux de neurones artificiels (ANN) : capables de modéliser des dynamiques non linéaires.
- Réseaux neuronaux récurrents (RNN), et en particulier les LSTM (Long Short-Term Memory) : conçus pour gérer les dépendances temporelles longues, très utilisés pour les séries chronologiques financières (Bao et al., 2017).

a. Résultats empiriques et supériorité des modèles IA

La littérature récente témoigne de la performance accrue des approches IA comparées aux méthodes traditionnelles. On peut citer :

- Henrique et al. (2019) comparent plusieurs algorithmes (MLP, SVM, Random Forest) sur des indices boursiers brésiliens et américains et concluent à une nette supériorité des modèles non linéaires avec des erreurs de prédiction significativement réduites à l'aide de RMSE et MAPE
- Najem et al. (2024) montrent que les réseaux LSTM combinés à des techniques de prétraitement (normalisation, fenêtre glissante) améliorent sensiblement la qualité des prévisions à court terme.
- Gandhmal & Kumar (2019), dans une revue exhaustive identifient que la majorité des études rapportent des précisions directionnelles (Direction Accuracy) supérieures à 60–70 % avec des modèles IA qui dépasse les performances attendues sous hypothèse d'efficacité forte.

b. Hybridation et fusion de modèles

Face à la volatilité extrême des marchés et à la multiplicité des sources d'incertitude les chercheurs ont développé des modèles hybrides ou combinés qui fusionnent plusieurs techniques afin d'exploiter la complémentarité de leurs forces. Par exemple :

- L'agrégation de réseaux LSTM avec des indicateurs techniques comme le RSI ou le MACD permet d'intégrer la dynamique comportementale dans les prédictions (Najem et al., 2024).
- La combinaison d'algorithmes d'optimisation (ex : algorithmes génétiques, PSO) avec des réseaux de neurones améliore la sélection d'hyperparamètres et la convergence du modèle.
- La fusion décisionnelle (décision fusion), via l'utilisation d'ensembles (bagging, boosting, stacking), renforce également la robustesse et la stabilité des prédictions, en réduisant les biais spécifiques à chaque modèle de base.

c. Limites et considérations critiques

Malgré leur efficacité apparente, les modèles IA soulève plusieurs défis :

- Sur-apprentissage (overfitting) : la complexité excessive peut conduire à une mémorisation des données d'entraînement au détriment de la généralisation.
- Interprétabilité limitée : les modèles comme les réseaux profonds fonctionnent souvent comme des black box ce qui complique l'interprétabilité économique des prédictions.
- Dépendance aux données : les performances dépendent fortement de la qualité, du volume et de la diversité des données disponibles.

- Validité externe : peu d'études valident leurs résultats sur plusieurs marchés ou dans différents contextes temporels, ce qui limite la généralisable.

4. AI applications dans quelques activités financières

a. AI et la gestion des changes

Le domaine de la prévision des prix boursiers pourrait approfondir l'analyse des prédictifs alternatifs fondés sur l'intelligence artificielle (tels que les algorithmes de clustering et d'autres méthodes d'apprentissage similaires) et concevoir un algorithme de regroupement par régimes afin d'obtenir une vision plus limpide des applications potentielles et des avantages méthodologiques liés aux techniques de clustering (Law et Shawe-Taylor, 2017). À cet égard, Litzenger et al. (2012) ainsi que Booth et al. (2015) recommandent d'élargir l'étude aux cycles de marché et aux politiques de régulation susceptibles d'influencer la performance des modèles d'IA dans la prévision boursière et le trading algorithmique, respectivement. En outre, les modèles de prévision devraient être évalués à l'aide d'informations issues des carnets d'ordres approfondis, ce qui pourrait conduire à une amélioration significative de la précision des prévisions de prix (Tashiro et al., 2019).

Ainsi, l'IA joue également un rôle croissant dans la gestion des devises étrangères. Les activités de couverture ou de trading rentables sur les marchés exigent des prévisions précises des taux de change (Galeshchuk et Mukherjee, 2017). À ce titre, le modèle HONN (Higher Order Neural Network) surpasse de manière significative les réseaux neuronaux traditionnels (tels que les perceptrons multicouches, les réseaux récurrents ou les modèles Psi-sigma) dans la prévision et le trading de la paire de devises EUR/USD, en utilisant les séries quotidiennes de la Banque centrale européenne comme données d'entrée (Dunis et al., 2010).

À l'inverse, Galeshchuk et Mukherjee (2017) considèrent que ces méthodes classiques sont incapables de prédire efficacement la direction des variations des taux de change et, par conséquent, inefficaces pour soutenir un trading rentable. Pour cette raison, ils appliquent un réseau neuronal profond (notamment des réseaux convolutifs) afin de prévoir trois principaux taux de change : EUR/USD, GBP/USD et JPY/USD. Le modèle proposé surpasse nettement les modèles de séries temporelles (tels que ARIMA — Autoregressive Integrated Moving Average) ainsi que les classificateurs d'apprentissage automatique.

En résumé, il parvient de ces travaux de recherche que les modèles fondés sur l'intelligence artificielle, tels que le NARX (Nonlinear Autoregressive Network with Exogenous Inputs) et les techniques susmentionnées, obtiennent de meilleures performances prédictives que les modèles statistiques ou basés sur les séries chronologiques, comme le soulignent Amelot et al. (2021).

b. Chatbots bancaires et services de conseil automatisé (robo-advisors)

Le terme « robo-advisor » était pratiquement inexploré il y a une dizaine d'années, mais il est aujourd'hui relativement courant dans le paysage financier. Toutefois, cette appellation est fallacieuse : il ne s'agit nullement de robots. Les robo-advisors sont en réalité des algorithmes conçus pour calibrer un portefeuille financier en fonction des objectifs et de la tolérance au risque de l'utilisateur. Les chatbots et les robo-conseillers, alimentés par des technologies de traitement automatique du langage naturel (NLP) et des algorithmes d'apprentissage automatique (ML), sont devenus des outils puissants permettant d'offrir aux utilisateurs une expérience personnalisée, conversationnelle et fluide dans divers domaines.

Ces chatbots et robo-advisors rencontrent un fort engouement auprès des consommateurs de la génération millénaire, qui n'ont pas nécessairement besoin d'un conseiller physique pour se sentir à l'aise dans leurs investissements, et qui sont également moins enclins à justifier les frais facturés par des conseillers humains.

L'intelligence artificielle offre plusieurs leviers d'amélioration pour le secteur bancaire, notamment en aidant les utilisateurs à mieux gérer leur argent et leurs économies. Par exemple,

Plum est un chatbot accessible via Facebook Messenger, qui aide les clients à épargner de petites sommes d'argent de manière progressive. Après l'inscription initiale, Plum se connecte au compte bancaire du client ; son moteur d'IA analyse alors les revenus et l'historique de dépenses, puis anticipe combien le client peut raisonnablement mettre de côté. De petites sommes sont ensuite déposées sur le compte d'épargne Plum, avec des rapports périodiques à l'appui.

c. AI et la prévision de la volatilité

L'intelligence artificielle (IA) et la prévision de la volatilité à travers l'indice VIX — issu du Chicago Board Options Exchange (CBOE) — constituent une mesure centrale du sentiment de marché et des attentes des investisseurs. La prévision de la volatilité demeure une tâche complexe en raison de son caractère hautement persistant (Fernandes et al., 2014). Selon Fernandes et ses co-auteurs, le VIX est négativement corrélé au rendement de l'indice S&P500 et positivement corrélé à son volume d'échange. Le modèle autorégressif hétérogène (HAR) fournit les meilleurs résultats prédictifs en comparaison des réseaux neuronaux classiques (Fernandes et al., 2014 ; Vortelinos, 2017). Néanmoins, des réseaux neuronaux modernes tels que le LSTM (Long Short-Term Memory) et le NARX (Nonlinear Autoregressive Network with Exogenous Inputs) apparaissent également comme des alternatives valides (Bucci, 2020). Une autre classe prometteuse de réseaux neuronaux est celle des réseaux neuronaux d'ordre supérieur (HONN), utilisés pour prédire la volatilité réalisée à 21 jours des contrats à terme sur le FTSE100. Grâce à leur capacité à capter des corrélations d'ordre supérieur dans les jeux de données, les HONN affichent des performances remarquables en termes de précision statistique et d'efficacité en matière de stratégie de trading, surpassant les perceptrons multicouches (MLP) ainsi que les réseaux neuronaux récurrents (RNN) (Serpini et al., 2013).

d. L'allocation de portefeuille dans la gestion d'actifs et au sein de la communauté élargie des investisseurs (côté acheteur)

L'affectation de l'intelligence artificielle (IA) et de l'apprentissage automatique (ML) dans la gestion d'actifs présente un fort potentiel pour améliorer l'efficacité et la précision des flux opérationnels, accroître les performances, renforcer la gestion des risques et optimiser l'expérience client (BlackRock, 2019 ; Deloitte, 2019). La génération automatique de langage naturel (Natural Language Generation, NLG), branche spécifique de l'IA, peut être mobilisée par les conseillers financiers afin de « humaniser » et de simplifier l'analyse et la communication des données à destination des clients (Gould, 2016). Les modèles d'apprentissage automatique sont en mesure de surveiller quotidiennement des milliers de facteurs de risque et de tester la performance des portefeuilles sous des milliers de scénarios économiques ou de marché, ce qui en fait un outil puissant pour la gestion du risque chez les gestionnaires d'actifs et autres investisseurs institutionnels de grande envergure.

Afin de réduire les coûts de traitement pour les gestionnaires d'investissement, l'IA les aide à remplacer les processus de rapprochement manuels traditionnels par des solutions automatisées. Cela garantit que les gestionnaires exécutent des ordres plus rapides pour gagner de l'argent. L'IA sera utilisée pour alimenter les modèles ML avec des données big data qui guideront les recommandations pour influencer l'allocation du portefeuille ou la sélection de titres, selon la technique d'IA utilisée. Étant donné que les ensembles de données traditionnels ne conviennent plus aujourd'hui et l'analyse traditionnelle n'est plus compétitive, n'étant plus perçue comme une compétence différentielle parmi les gestionnaires d'actifs, le régime big data constitue vraiment une solution. Pendant de nombreuses années, l'information a été un levier stratégique dans la communauté des investisseurs. De nombreuses approches d'investissement à long terme du vingtième siècle ont été basées sur les données.

Cependant, la participation limitée des petits acteurs devrait persister, du moins jusqu'à ce que ces outils deviennent omniprésents ou accessibles via des prestataires tiers. Par ailleurs, les ensembles de données fournis par des tiers peuvent ne pas répondre à des standards hétérogènes

dans l'industrie, obligeant les utilisateurs à évaluer la fiabilité, la précision et la véracité de ces données avant de les intégrer dans leurs modèles.

Enfin, l'usage généralisé des mêmes modèles d'IA par un grand nombre de gestionnaires d'actifs pourrait générer des comportements mimétiques (herding behavior) et des marchés unidirectionnels, soulevant ainsi des risques potentiels pour la liquidité et la stabilité du système, notamment en période de tension. Une volatilité accrue pourrait en résulter, en raison de ventes ou d'achats massifs effectués simultanément, donnant naissance à de nouvelles sources de vulnérabilité.

e. AI dans l'évaluation de la performance, la gestion des risques et la valorisation du défaut de crédit

Nous analysons les conditions financières des entreprises afin de prédire les situations de détresse financière (Altman et al., 1994). À titre d'illustration, Jones et al. (2017) ainsi que Gepp et al. (2010) évaluent la probabilité de défaut d'entreprise. Sabău Popa et al. (2021), quant à eux, prédisent la performance des entreprises à partir d'un indice financier composite. Les résultats obtenus confirment que les classificateurs fondés sur l'intelligence artificielle sont à la fois extrêmement précis et faciles à interpréter, les rendant ainsi supérieurs aux modèles linéaires classiques. Un article particulièrement original examine la relation entre les traits de masculinité faciale des dirigeants (CEO) et le niveau de risque des entreprises, à travers des techniques de traitement d'image (Kamiya et al., 2018).

f. Le trading algorithmique

L'intelligence artificielle (IA) peut être utilisée dans la sphère du trading à la fois pour proposer des stratégies de négociation et pour alimenter des systèmes de trading automatisés capables de formuler des prédictions, de choisir une ligne d'action et d'exécuter des transactions. Les systèmes de trading basés sur l'IA, opérant sur les marchés, peuvent identifier et exécuter des ordres de manière totalement autonome, sans intervention humaine, en s'appuyant sur des techniques d'IA telles que le calcul évolutionnaire, l'apprentissage profond et la logique probabiliste (Metz, 2016). Ces techniques permettent de systématiser les stratégies à venir selon une logique conditionnelle du type « si/alors », intégrée aux procédures (Bloomberg, 2019).

Compte tenu de l'interconnexion croissante entre les classes d'actifs et les marchés géographiques, l'utilisation de l'IA permet d'atteindre des capacités prédictives qui surpassent désormais celles des algorithmes conventionnels en finance et en trading.

Les systèmes de trading intelligents peuvent également assister les traders dans la gestion du risque et dans la maîtrise du flux de leurs ordres. Par exemple, les applications basées sur l'IA peuvent surveiller l'exposition au risque et ajuster ou clôturer automatiquement une position en fonction des besoins de l'utilisateur, sans nécessiter de reprogrammation, car ces systèmes s'entraînent eux-mêmes et s'adaptent dynamiquement aux conditions changeantes du marché avec peu, voire aucune, intervention humaine. Ils peuvent également aider à gérer le flux d'ordres entre les courtiers, pour des transactions déjà décidées, tout en contrôlant les frais ou en allouant la liquidité de manière optimale (Bloomberg, 2019).

Au final, l'utilisation de l'IA et de l'analyse du sentiment basée sur le big data pour identifier des thèmes, des tendances ou des signaux de trading est technologiquement étendue aux moyens par lesquels le trading a été effectué pendant des décennies. Les traders ont utilisé les dépêches des nouvelles et d'autres annonces ou commentaires de dirigeants à modifier pour des décennies, en les évaluant en fonction de leur conséquence sur le prix d'achat des actions sur leur rang. Aujourd'hui, le text mining et l'analyse des publications sur les réseaux sociaux, des tweets, et même les données satellitaires par les algorithmes de NLP ou le traitement automatique du langage humain (NLP), sont une valeur pour la prise de décision sur le trading. Par l'automatisation de la collecte et de l'analyse des données, ces technologies peuvent identifier les définitions et les comportements avant à une échelle qui précède l'analyse humaine.

Ce qui distingue le trading piloté par IA des stratégies systématiques classiques, c'est l'apprentissage par renforcement et la capacité du modèle d'IA à s'ajuster de manière autonome aux conditions changeantes du marché, là où les stratégies systématiques traditionnelles nécessitent une intervention humaine plus lourde et un temps d'adaptation plus long. Les stratégies classiques de back-testing basées sur les données historiques peuvent échouer à produire des rendements satisfaisants en temps réel, notamment lorsque les tendances identifiées se dégradent ou disparaissent. L'utilisation des modèles d'apprentissage automatique permet de recentrer l'analyse sur la prédiction en temps réel, en recourant par exemple à des tests de type walk forward, qui adaptent les modèles en continu, réduisant ainsi les biais liés au surapprentissage (overfitting) ou à l'ajustement excessif des courbes dans les back-tests fondés sur les données historiques (Liew, 2020).

g. L'intégration de l'IA dans les produits financiers basés sur la technologie blockchain

Il est possible d'utiliser l'intelligence artificielle dans les réseaux blockchain de plusieurs manières pour réduire la vulnérabilité de la sécurité et renforcer la prévention des compromissions du réseau, par exemple, dans le domaine des paiements. Les réseaux blockchain utilisent les données de l'IA pour permettre aux utilisateurs de remarquer immédiatement une activité frauduleuse qui peut éventuellement se produire en cas de vol ou de d'escroquerie. Cela se produit, même si le système exige des clés privées et publiques pour protéger l'utilisateur. En outre, l'IA joue un rôle primordial dans le processus d'intégration des utilisateurs pour les applications reconnaissantes.

Les applications d'IA peuvent également fournir une analyse des adresses de portefeuilles (wallet address analysis), pouvant être utilisée à des fins de conformité réglementaire ou pour une évaluation interne des risques liés aux parties prenantes d'une transaction (Ziqi Chen et al., 2020). Toutefois, lorsque les intermédiaires financiers sont éliminés des transactions, l'efficacité des cadres réglementaires actuels centrés sur des entités régulées peut se retrouver affaiblie (Endo, 2019).

5. Efficience des marchés et limites contemporaines

L'hypothèse d'efficience des marchés, conçue par Eugene Fama, est parmi les piliers les plus influents de la finance théorique moderne. Selon EMH, les prix des actifs financiers incorporeraient instantanément et complètement toute l'information disponible et existant sur les actifs. Ainsi, aucun investisseur ne pourrait réaliser un rendement anormal de manière systématique pour lui ou elle, car une fois qu'une donnée est publique, aucune chance d'arbitrage n'est laissée.

L'EMH est classiquement subdivisée en trois formes :

- Efficience faible : les prix reflètent l'ensemble d'information passée (historical DATA)
- Efficience semi-forte : les prix reflètent à la fois les informations passées et toutes les informations publiquement disponibles (actualités, résultats financiers, ...).
- Efficience forte : les prix reflètent toutes les informations privées ou privilégiées.

Néanmoins, les travaux empiriques récentes remettent en cause la rigidité de ces postulats. De nombreuses anomalies de marché ont été détectées dans la littérature, contredisant les prédictions de l'EMH. On peut citer :

- Les effets de surréaction et de sous-réaction : certains travaux (De Bondt & Thaler, 1985) ont prouvé que les investisseurs réagissent souvent de manière excessive ou insuffisante à de nouvelles informations, ce qui provoque des corrections de prix ultérieures.
- Les anomalies de calendrier : comme Effet janvier, Effet jour de la semaine ou encore Effet fin de mois, qui suggèrent des variations dans les rendements sans justification majeur (Rozeff & Kinney, 1976).
- Les réactions différées aux événements économiques : certains actifs réagissent avec

un temps de latence aux chocs externes ce qui va à l'encontre de l'hypothèse de traitement immédiat de l'information.

- Les bulles spéculatives : telles que la bulle d'Internet des années 2000 ou la bulle immobilière de 2008 qui montrent que les prix peuvent durablement s'écarter des fondamentaux économiques.

L'évidence a alimenté des courants critiques de l'EMH, tels que la finance comportementale, qui a révélé les limites cognitives des agents économiques et les biais psychologiques tels que l'effet de disposition, l'excès de confiance ou l'ancrage qui contredisent l'EMH.

D'autre part, encore, on peut également noter que des développements technologiques en matière de traitement de données ou d'intelligence artificielle ont maintenant permis la mise en lumière de patterns cependant complexes et non linéaires, et que par conséquent impreceptibles par les moyennes statistiques conventionnelles. Un grand nombre de modèles d'apprentissage automatiques, et en particulier des réseaux de neurones profonds, peuvent en fait déduire des relations « cachées » au sein des séries temporelles financières. Ceci implique par conséquent qu'il y a probablement toujours des opportunités d'arbitrage qui omettraient simplement d'intégrer rapidement de l'information exploitable mais paradoxalement facilement dissimulées par le marché.

Timmermann & Granger (2004) mettent en avant que la nature adaptative des marchés influencée par l'apprentissage des investisseurs et les changements structurels, outre les innovations technologiques implique que les opportunités de prédiction apparaissent de façon transitoire avant de s'auto-détruire. Cela supporte l'idée d'une efficacité conditionnelle dans laquelle les marchés peuvent être localement inefficients sur certaines périodes ou types d'informations.

En somme, bien que l'Efficient Market Hypothesis reste un cadre théorique fondamental, son applicabilité stricte est de plus en plus contestée. Les observations empiriques combinées à l'essor des technologies analytiques imposent une reformulation nuancée du concept d'efficacité où la cadence d'apprentissage du marché, la complexité des comportements humains et la montée de l'intelligence artificielle modifient intégralement les conditions d'accès à l'information parfaite et immédiate.

6. Big Data et finance prédictive : apports, enjeux et défis

Un système d'intelligence artificielle (IA), tel que défini par le Groupe d'experts sur l'IA de l'OCDE (AIGO), est un système fondé sur des technologies informatiques capable, pour un ensemble donné d'objectifs définis par l'humain, de produire des prédictions, des recommandations ou des décisions ayant un impact sur des environnements réels ou virtuels (OCDE, 2019). Il utilise des données provenant de sources humaines et/ou machine pour percevoir des environnements réels et ou virtuels, abstraire ces perceptions sous forme de modèles, et exploiter l'inférence sur ces modèles afin de formuler des options informatives ou décisionnelles. Les systèmes d'IA sont destinés pour fonctionner avec des niveaux d'autonomie variables (OCDE, 2019).

L'augmentation exponentielle des capacités d'entreposage, de traitement et de l'analyse des données. Le Big Data ne représente pas un simple changement d'échelle par l'intégration de diverses spécificités mais un véritable changement de nature, simultané des accès ainsi que des modalités d'apparition et d'utilisation de l'information. Au-delà des sources et des caractéristiques de marché citées, l'innovation majeure introduite par le Big Data est de pouvoir abattre ces barrières naturelles, c'est-à-dire des sources de données de marché confirmées parmi lesquelles prix, volumes et croissance des instruments sont intégrés en sources externes alternatives, sur-banalités ou structures, en temps réel et haute fréquence.

a. Conceptualisation

i. Définition et typologies des données massives : Big Data

Le concept de Big Data en finance se caractérise par les « 5V » : Volume, Vitesse, Variété, Véracité et Valeur. Il englobe des données :

- Marché (structured) : historiques de prix (Open,High,Low,Close), volatilité implicite, carnets d'ordres.
- Économiques (semi-structurées) : taux directeurs, données macroéconomiques, résultats financiers.
- Alternatives non structurées : publications sur réseaux sociaux, articles de presse, forums financiers (Reddit, Twitter), images (chart patterns).
- Données transactionnelles : flux de trading à haute fréquence (HFT), logs des ordres.

La combinaison de ces sources ouvre la voie à une compréhension plus riche des dynamiques de marché.

L'apprentissage automatique (Machine Learning, ML) est une section du domaine de l'intelligence artificielle (IA) et désigne la capacité d'un logiciel à apprendre à partir d'ensembles de données pertinents afin de « s'améliorer lui-même » sans être explicitement programmé par un humain (ex. : reconnaissance d'images, prédiction de défaut de paiement, détection de fraude et de blanchiment d'argent) (Samuel, 1959). On distingue différents types de ML :

- L'apprentissage supervisé (ML « classique »), qui repose sur des régressions avancées et la catégorisation de données afin d'améliorer les capacités prédictives ;
- L'apprentissage non-supervisé, qui est conçu à traiter des données en entrée pour en comprendre la distribution et, par exemple, générer automatiquement des segments de clientèle ;
- L'apprentissage profond et l'apprentissage par renforcement, qui s'appuient sur des réseaux neuronaux et peuvent être appliqués à des données non structurées telles que des images ou des signaux vocaux (US Treasury, 2018).

Les modèles de ML exploitent des quantités massives de sources de données alternatives et d'analyses complexes, ce que l'on désigne fréquemment par le terme de big data. Cette expression est apparue au début des années 2000 pour désigner « l'explosion de la quantité et de la qualité des données disponibles et potentiellement pertinentes, principalement due aux avancées récentes et sans précédent dans les technologies d'enregistrement et de stockage des données » (OCDE, 2019). L'écosystème du big data regroupe les sources de données, les logiciels, les outils d'analyse, les langages de programmation, les statistiques, ainsi que les data scientists, qui synthétisent ces données, éliminent le bruit, et produisent des résultats interprétables.

Le big data peut inclure des informations énergétiques, des images satellites, des photos et vidéos numériques, des enregistrements de transactions ou des signaux GPS, ainsi que des données personnelles telles que : nom, adresse e-mail, photo, publications sur les réseaux sociaux, coordonnées bancaires, informations médicales ou adresse IP d'un ordinateur (OCDE, 2019). Ces données posent des défis méthodologiques importants en raison de leur volume, de leur complexité ou de leur rythme de production, et nécessitent des techniques numériques avancées — telles que les modèles d'apprentissage automatique — pour être traitées efficacement. L'utilisation croissante de l'IA dans les applications de l'Internet des objets (IoT) génère également d'importants volumes de données, qui alimentent en retour les systèmes d'IA. La plus grande disponibilité des données permet aux modèles de ML de gagner en performance, grâce à leur capacité à apprendre par itération à partir des exemples qui leur sont fournis — un processus connu sous le nom d'entraînement du modèle (US Treasury, 2018).

ii. Apports du Big Data à la prédiction boursière

La Big Data permettent d'enrichir les modèles prédictifs sur plusieurs plans :

- Capture de l'information non conventionnelle : l'analyse de sentiment (sentiment analysis) permet d'anticiper les réactions du marché aux nouvelles ou aux rumeurs (Li et al., 2014).

- Intégration des comportements collectifs : l'étude des flux sur les plateformes sociales révèle des effets de mimétisme ou d'emballement pouvant précéder des retournements de tendance.
- Analyse en temps réel : la volatilité des données permet d'actualiser continuellement les modèles prédictifs les rendant réactifs aux signaux faibles.

Par exemple, Henrique et al. (2019) démontrent qu'un modèle combinant des données de marché classiques avec des données textuelles traitées par NLP (Natural Language Processing) améliore significativement la précision des prédictions sur l'indice S&P 500.

iii. Méthodes de traitement des données massives

Pour exploiter ces volumes hétérogènes, plusieurs technologies avancées sont mobilisées :

- Traitement du langage naturel (NLP) : analyse lexicale, extraction de sujets, mesure de polarité.
- Apprentissage profond : réseaux LSTM et BERT appliqués aux flux textuels.
- Systèmes distribués : Hadoop, Spark pour le traitement en parallèle de très grands jeux de données.
- Techniques de réduction de dimension : PCA, t-SNE ou auto-encodeurs pour conserver l'essence informative tout en allégeant les modèles.

iv. Enjeux méthodologiques et limites du Big Data

Malgré ses apports considérables, l'usage du Big Data en finance soulève plusieurs défis majeurs:

- Qualité et bruit des données : la véracité des sources en particulier dans les données alternatives peut être douteuse ou biaisée.
- Problèmes d'alignement temporel : les données textuelles ou comportementales peuvent ne pas être synchrones avec les séries financières.
- Complexité computationnelle : le traitement de données massives requiert une infrastructure technologique avancée et coûteuse.
- Questions éthiques : l'usage de données personnelles même indirectement soulève des problématiques de confidentialité et de gouvernance algorithmique.

Enfin, l'interprétabilité des modèles construits sur des layers de données multiples devient un véritable défi. La « boîte noire » de l'IA s'épaissit afin que les couches de traitement se superposent.

En somme, le Big Data ne se limite pas à un apport technique dans la modélisation financière mais il constitue un changement de paradigme qui redéfinit ce qu'est une information financière pertinente. Toutefois, sa valeur dépend fortement de la capacité à transformer la masse brute en signal exploitable de manière rigoureuse éthique et interprétable.

b. Discussion et analyse : vers une redéfinition de l'efficacité des marchés à l'ère de l'intelligence artificielle

En analyse croisée, la littérature contemporaine montre que l'avènement et l'exploitation des technologies de l'intelligence artificielle et du Big Data ont substantiellement transformé les paradigmes régissant la compréhension des marchés et de leurs dynamiques. Ainsi, plus qu'entachée d'une véracité empirique douteuse, son énoncé est lui aussi remis en question. Comment concluons-nous, dans le contexte de cette analyse croisée ? Nous laissons cet article sur trois tensions majeures : entre prédiction et efficacité, entre rationalité limitée et calculabilité avancée et entre signal exploitabilité et bruit informationnel.

i. Un paradigme prédictif : IA performante dans un marché censé être efficient ?

Si l'EMH dans sa version forte stipule qu'aucune information voire même privée ne permet de prédire les mouvements futurs de prix, alors la capacité des modèles d'IA à anticiper des retournements boursiers ou à détecter des motifs récurrents dans les séries temporelles

représente un paradoxe fondamental.

Les résultats empiriques retenus de plusieurs études (Najem et al., 2024 ; Kumbure et al., 2022 ; Gandhmal & Kumar, 2019) montrent que les prédictions générées par des réseaux LSTM, des modèles ensemblistes voire les algorithmes d'optimisation sont non seulement significatifs mais également exploitables à des fins de stratégie d'investissement. Cela remet en question l'idée d'un marché intégrant immédiatement toute information disponible.

Toutefois, cette critique ne conduit pas nécessairement à rejeter l'EMH dans son ensemble. Elle suggère plutôt que l'efficacité peut être :

- Conditionnelle : certains segments de marché ou périodes temporelles sont inefficaces notamment en période de crise ou de forte incertitude.
- Dynamique : l'information n'est pas intégrée instantanément mais progressivement en fonction de la capacité des agents à l'interpréter.
- Hétérogène : l'efficacité peut varier selon les instruments, les zones géographiques ou les horizons temporels.

ii. Rationalité humaine vs rationalité algorithmique

L'EMH repose sur une hypothèse de rationalité économique que la finance comportementale a largement déconstruite. En intégrant les biais cognitifs, les émotions et les erreurs systématiques dans la prise de décision. Cette approche a prouvé que les marchés peuvent s'écarter durablement de leur valeur fondamentale.

En revanche, l'intelligence artificielle instaure la gentillesse présumée de la rationalité computationnelle, pas sur une provocation ou croyance, mais sur l'identification des patterns statistiques. En plus de corriger en effet les erreurs humaines, il inter-agit plaintes à leur endroit. Les modèles de machine prédictive exécutés sur d'énormes montants de faits de temps d'enregistrement sont à même d'anticiper des réponses illogiques collectives, pour donner aux personnels qui ont accès à ces performances un avantage stratégique.

Cela suggère une transformation de l'efficacité non comme propriété globale du marché mais comme résultat émergent d'un écosystème technologique asymétrique dans lequel certains agents possèdent une capacité supérieure d'accès et de traitement de l'information.

iii. Entre signal exploitable et illusion de prédiction :

Une autre ligne critique majeure concerne la robustesse et la stabilité des résultats obtenus par les modèles IA. Si certains travaux rapportent des performances spectaculaires, plusieurs auteurs (Henrique et al., 2019 ; Timmermann & Granger, 2004) mettent en garde contre :

- Le risque de surapprentissage : les modèles apprennent des bruits spécifiques aux données d'entraînement sans capacité de généralisation.
- Le manque de reproductibilité : très peu d'études sont testées sur des données hors échantillon ou sur des marchés non développés.
- Les biais de sélection : les résultats publiés tendent à surreprésenter les succès, et peu d'échecs sont documentés.

Il est donc crucial de distinguer les modèles qui produisent un vrai signal exploitable (avec validation croisée et robustesse hors échantillon, tests économétriques) de ceux qui génèrent une illusion de prédiction due à un ajustement excessif aux données passées.

iv. Vers une nouvelle conceptualisation de l'efficacité :

À la lumière des développements technologiques et des tensions théoriques identifiées, plusieurs chercheurs (Lo, 2004 ; Timmermann & Granger, 2004) proposent des alternatives à l'EMH classique. Parmi les plus notables :

- L'hypothèse des marchés adaptatifs (Adaptive Market Hypothesis) : elle stipule que l'efficacité varie au fil du temps en fonction de l'apprentissage des agents, des régimes économiques et des conditions d'accès à l'information.
- Les modèles basés sur la complexité : inspirés de la théorie des systèmes complexes,

ces modèles considèrent le marché comme un système adaptatif multi-agent dans lequel l'ordre émerge de l'interaction de comportements hétérogènes.

Ces approches offrent un cadre plus flexible et mieux adapté à la réalité des marchés contemporains marqués par une interdépendance systémique, une volatilité structurelle et une capacité de traitement informationnel imperceptible.

v. Discussion critique et perspectives de recherche :

L'adoption de l'intelligence artificielle (IA) dans le secteur financier est stimulée par la disponibilité croissante et massive des données au sein des services financiers ainsi que par l'avantage concurrentiel que l'IA et le machine learning (ML) sont susceptibles d'apporter aux entreprises du secteur. L'explosion du volume de données disponibles et des capacités d'analyse associées (big data) combinée à une capacité de calcul devenue plus accessible notamment via l'informatique en nuage, peut être exploitée par les modèles de ML pour identifier des signaux et capter des relations sous-jacentes dans les données d'une manière qui dépasse les capacités humaines.

Le déploiement de l'IA, du ML et du big data par les entreprises du secteur financier devrait, à terme, devenir un levier majeur d'avantage concurrentiel, à la fois en améliorant l'efficacité opérationnelle par la réduction des coûts, et en renforçant la qualité des produits et services financiers proposés aux clients (US Treasury, 2020).

Rien que dans cette revue de la littérature récente, il semble clair que l'IA et le Big Data défient plusieurs axiomes de base de l'EMH. Dans certains cas, l'amélioration des méthodes de modélisation prédictive, d'analyse des prix et de la vidéo financière, et de la condamnation des figures ennuyeuses qui n'ont pas de sens à identifier des modèles. Aucun modèle économétrique ou autres anciennes idées peuvent fournir plus de précision

vi. Vers une redéfinition de l'efficacité en contexte technologique

L'idée selon laquelle les marchés sont instantanément et parfaitement efficaces devient de moins en moins tenable à mesure que des modèles algorithmiques parviennent à extraire de l'information exploitable. Cependant, ces résultats ne reflètent pas que les marchés sont fondamentalement inefficaces. Ils suggèrent que :

- L'efficacité doit être conçue comme un phénomène évolutif et contingent dépendant des technologies disponibles, de la structure du marché et du niveau de sophistication des participants.
- Il existe une hiérarchie informationnelle technologique : les agents dotés de capacités avancées d'IA disposent d'un avantage informationnel temporaire avant que le marché ne s'ajuste.
- L'efficacité peut être vue comme un équilibre dynamique où la compétition informationnelle entre agents pousse les prix vers une forme d'efficacité endogène.

▪ Contributions de l'étude

Cette revue contribue à la littérature de plusieurs façons :

- Elle systématise les résultats empiriques récents sur la capacité des modèles IA à produire des prédictions robustes.
- Elle met en tension les concepts traditionnels d'efficacité avec les réalités technologiques contemporaines.
- Elle propose une relecture critique de la rationalité en finance à travers le prisme de l'intelligence computationnelle.
- Elle identifie les limites méthodologiques récurrentes dans les travaux actuels, notamment en matière de généralisation, d'explicabilité et d'intégration théorique.

▪ Perspectives de recherche futures

Plusieurs axes de recherche émergent de cette synthèse critique :

- Théorisation hybride : élaborer de nouveaux cadres théoriques combinant efficacité

adaptative, apprentissage algorithmique et rationalité comportementale.

- Finance explicable : renforcer la transparence et l'interprétabilité des modèles IA pour faciliter leur adoption dans les milieux régulés.
- Évaluation rigoureuse de la prédictibilité : développer des standards méthodologiques pour tester la robustesse des modèles sur des marchés variés et des périodes économiques différenciées.
- Études inter-marchés : comparer l'impact de l'IA sur l'efficacité dans les marchés émergents vs. développés, ou dans différents secteurs (technologie, énergie, santé).
- Encadrement éthique et réglementaire : analyser les implications sociétales, concurrentielles et normatives liées à l'utilisation massive d'IA dans la finance.

7. Conclusion

“AI is the ‘new electricity’ ... just as electricity transformed many industries roughly one hundred years ago; AI will also now change every major industry.” Andrew Ng, 2007

L'IA et le Big Data ne sont pas seulement pertinents en tant qu'outils d'optimisation, mais ils sont des vecteurs de changement de champ de paradigme. Ils ont élargi les frontières de l'information disponible, réorganisé le marché de la concurrence de l'information, et fait une ecchymose sur l'hypothèse sous-jacente de l'équilibre en finance classique. Alors qu'une nouvelle science financière qui intègre la complexité, l'adaptabilité, et la technologie est proche, cette revue propose contribuer à cette nouvelle discipline en ouvrant un nouveau champ de la recherche interdisciplinaire.

L'intelligence artificielle (IA) a profondément révolutionné l'ensemble du système financier, grâce aux avancées de l'informatique, à l'analyse des mégadonnées (Big Data Analytics), et à l'afflux croissant de données générées par les consommateurs, les investisseurs, les entreprises et les administrations publiques. Il n'est donc pas surprenant qu'une littérature croissante se soit intéressée aux usages, aux bénéfices et au potentiel des applications de l'IA en finance. Cet article vise à fournir un état des lieux précis de la recherche actuelle sur le sujet, constituant ainsi un guide utile pour les lecteurs intéressés, mais surtout un point de départ pour de futures recherches.

À cette fin, nous sommes parvenus à un grand nombre d'articles publiés dans des revues indexées dans Web of Science et avons réalisé à la fois une analyse bibliométrique et une analyse de contenu. Ainsi, nous avons examiné les caractéristiques des articles étudiés, circonscrit les principales applications de l'IA en finance et mis en évidence dix orientations majeures. Cette revue travail démontre que l'IA s'avère une excellente technologie de la prédiction des marchés, qui favorise la stabilité financière en divisant l'asymétrie de l'information et la volatilité, lequel se traduit par des systèmes d'investissement plus performants et des évaluations de la performance plus exactes.

De plus, dans les risques, un autre domaine est la maintenance peut également être affectée, l'IA peut avertir les gestionnaires de maintenance que certains capteurs machine détectent que des machines particulières ont une probabilité élevée d'échec. Un tel système permet de réduire les coûts de dépannage onéreux, de planification par anticipation. D'autre part, l'IA est également utilisée pour prévoir les risques de faillite et de crédit, à la fois pour les entreprises et les assurés bancaires. Les modèles de détection de fraude surveillent le système financier dans son ensemble et annoncent des perspectives à des régulateurs artificiels sur les marchés. Cela suggère que les crises financières ou les dépressions imprévues du marché mondial pourraient être anticipées et résolues à l'avance.

Dans l'ensemble, compte tenu du rythme rapide de diffusion des applications de l'IA dans la sphère financière, surtout dans de nombreux pays, et au fil du temps, à la lumière de l'évolution rapide de la technologie, il est logique de s'attendre à ce que les outils de l'IA continuent à s'étendre, sur le plan géographique et sectoriel et fonctionnel. Les entreprises qui n'ont pas encore réussi à embrasser le nouveau flux de transformation technologique devraient savoir comment surmonter ces barrières et saisir ces opportunités pour récolter les bénéfices de

l'adoption de l'IA et rester compétitives. De plus, à la lumière de ces conclusions, les responsables politiques devraient encourager les entreprises, surtout celles qui n'ont pas adopté ou intègrent à peine des applications d'IA, à franchir le pas. Cela comprend, par exemple, la création de fonds pour des compétences complexes pour manipuler ces systèmes et ces langages sophistiqués.

L'étude a certaines limites, néanmoins ; étant donné qu'elle couvre un éventail d'aspects, nombreux et interconnectés, et donne une description assez succincte de chacune d'elles. D'autres travaux, ainsi pourraient se concentrer sur certains aspects, par exemple, sur quelques-unes de principales branches de la finance touchée par l'IA, qui, par ailleurs, ont été abordées dans les études antérieures, et offrir une analyse plus détaillée.

8. Références

- Athey, S., & Imbens, G. W. (2019). *Machine learning methods that economists should know about*. *Annual Review of Economics*, 11(1), 685–725. <https://doi.org/10.1146/annurev-economics-080217-053433>
- Brynjolfsson, E., & McAfee, A. (2014). *The Second Machine Age: Work, progress, and prosperity in a time of brilliant technologies*. W. W. Norton & Company.
- Chen, S. (2022). *Stock price prediction using LSTM model*. In Proceedings of the 2nd International Conference on Artificial Intelligence, Big Data and Algorithms (CAIBDA 2022) (pp. 217–220). Nanjing, China.
- Fama, E. (1965-1974). Random Walk Theory.
- Financial Stability Board. (2017, 1er novembre). *Artificial intelligence and machine learning in financial services*. Financial Stability Board. Disponible sur <https://www.fsb.org/2017/11/artificial-intelligence-and-machine-learning-in-financial-service/>
- Ford, M. (2016, mars). *Economic growth isn't over, but it doesn't create jobs like it used to*. *Harvard Business Review*. <https://hbr.org/2016/03/economic-growth-isnt-over-but-it-doesnt-create-jobs-like-it-used-to>
- Gandhmal, D.P., & Kumar, K. (2019). Systematic analysis of stock market prediction techniques.
- Gerbert, P., Hecker, M., Steinhäuser, S., & Ruwolt, P. (2017, 28 septembre). *Putting Artificial Intelligence to Work*. Boston Consulting Group & MIT Sloan Management Review.
- Gilmartin, K. J., Newell, A., & Simon, H. A. (1976). A program modeling short-term memory under strategy control. In C. N. Cofer & F. E. Weaver (Eds.), *The structure of human memory* (pp. 99–122). San Francisco, CA: W. H. Freeman.
- Gogas, P., & Papadimitriou, T. (2021). *Machine Learning in Economics and Finance*. *Computational Economics*, 57(1), 1–4. <https://doi.org/10.1007/s10614-021-10094-w>
- Henrique, B.M. et al. (2019). Big Data and Machine Learning for Stock Market Prediction. <https://doi.org/10.1007/s43546-023-00618-x>
- Hoang, D., & Wiegatz, K. (2023). *Machine learning methods in finance: Recent applications and prospects*. *European Financial Management*, 29(5), 1657–1701. <https://doi.org/10.1111/eufm.12408>
- Kumbure, M.M. et al. (2022). Machine learning techniques for stock market forecasting: A literature review.
- McKinsey Global Institute. (2017, décembre 6). *Jobs lost, jobs gained: Workforce transitions in a time of automation*. McKinsey & Company.
- Najari, O., Ayi, O., & Cheklebire, M. (2025). Resistance to Change and Implementation Challenges of AI in Moroccan Public Administrations. *International Journal of Research in Economics and Finance*, 2(5), 44–53.

<https://doi.org/10.71420/ijref.v2i5.102>

- Najem, R., et al. (2024). Advancements in AI for Stock Market Prediction.
- Nazareth, N., & Ramana Reddy, Y. V. (2023). *Financial applications of machine learning: A literature review*. *Expert Systems with Applications*, 219, 119640.
- Newell, A., & Simon, H. A. (1961). *GPS, a program that simulates human thought*. In E. Feigenbaum & J. Feldman (Éds.), *Computers and Thought* (pp. 279–293). New York, NY : McGraw-Hill.
- Newell, A., Shaw, J. C., & Simon, H. A. (1957). “Elements of a theory of human problem solving.” *Proceedings of the Western Joint Computer Conference*, 218–239.
- Ozbayoglu, A. M., Gudelek, M. U., & Sezer, O. B. (2020). *Deep learning for financial applications: A survey*. *Applied Soft Computing*, 93, 106384. <https://doi.org/10.1016/j.asoc.2020.106384>
- Pew Research Center. (2017, octobre 4). *Automation in everyday life*. <https://www.pewresearch.org/internet/2017/10/04/automation-in-everyday-life/>
- Rihab Najem, Meryem Fakhouri Amr, Ayoub Bahnasse, Mohamed Talea, «Advancements in Artificial Intelligence and Machine Learning for Stock Market Prediction: A Comprehensive Analysis of Techniques and Case Studies, »*Procedia Computer Science*, Volume 231, 2024, Pages 198-204, ISSN 1877-0509,
- Spanos, G., & Angelis, L. (2016). *The impact of information security events on the stock market: A systematic review*. *Journal of Big Data*, 5(1), Article 3. <https://doi.org/10.1186/s40537-016-0041-5>
- Timmermann, A., & Granger, C. (2004). Efficient Market Hypothesis and forecasting.
- Turing, A. M. (1950). *Computing Machinery and Intelligence*. *Mind*, 59(236), 433–460.
- Webb, A. (2016, décembre). *2017 Tech Trends Report*. Future Today Institute.
- Xiao, F., & Ke, J. (2021). *Pricing, management and decision-making of financial markets with artificial intelligence: Introduction to the issue*. *Financial Innovation*, 7(1), Article 85. <https://doi.org/10.1186/s40854-021-00302-9> hub.hku.hk+8