

Utilisation des modèles de l'IA dans la prédiction des cours boursiers : Cas du marché boursier marocain

Using AI models in stocks prices prediction: Case of the Moroccan stock market

Mohammed EL MASSAADI, (Doctorant)

*Laboratoire de recherche en Economie et Management des Organisations
Faculté d'Economie et de Gestion,
Université Ibn Tofail, Kénitra, Maroc*

Hajar BOUDRAINE, (Doctorante)

*Laboratoire de Recherches en Management et Sciences des organisations
École Nationale de Commerce et de Gestion
Université Ibn Tofail, Kénitra, Maroc*

Hamid AIT LEMQEDDEM, (Enseignant-Chercheur)

*Laboratoire de Recherches en Management et Sciences des organisations
École Nationale de Commerce et de Gestion
Université Ibn Tofail, Kénitra, Maroc*

Adresse de correspondance :	Faculté d'économie et de gestion École nationale de commerce et de gestion Université Ibn Tofail. BP.1420 Morocco (Kenitra)
Déclaration de divulgation :	Les auteurs n'ont pas connaissance de quelconque financement qui pourrait affecter l'objectivité de cette étude et ils sont responsables de tout plagiat dans cet article.
Conflit d'intérêts :	Les auteurs ne signalent aucun conflit d'intérêts.
Citer cet article	EL MASSAADI, M., BOUDRAINE, H., & AIT LEMQEDDEM, H. (2024). Utilisation des modèles de l'IA dans la prédiction des cours boursiers : Cas du marché boursier marocain. International Journal of Accounting, Finance, Auditing, Management and Economics, 5(11), 568-583. https://doi.org/10.5281/zenodo.14213228
Licence	Cet article est publié en open Access sous licence CC BY-NC-ND

Received: October, 2024

Accepted: November, 2024

Utilisation des modèles de l'IA dans la prédiction des cours boursiers : Cas du marché boursier marocain

Résumé :

Le recours à l'apprentissage automatique (machine Learning) et à l'apprentissage profond (Deep Learning) pour anticiper et capturer l'évolution des marchés boursiers a capté l'attention du secteur financier, offrant la perspective d'une prédiction plus précise et efficace des dynamiques de marché. Face à la complexité croissante et à la nature hautement volatile des marchés financiers, l'adoption de modèles prédictifs avancés s'impose désormais comme une nécessité. Ce papier propose d'étudier la performance de quatre modèles d'apprentissage automatique, pour prédire le marché boursier marocain, à savoir le Perceptron Multicouche (MLP), les Réseaux de Neurones Récurrents (RNN), les Réseaux de Neurones Convolutifs (CNN) et le modèle LSTM, en utilisant les données historiques de cours boursiers journaliers. Les résultats obtenus, appuyés des valeurs de l'erreur moyenne absolue en pourcentage (MAPE) retenus, montrent une alternance entre le MLP et le RNN pour la prédiction et la reconnaissance des schémas dans les séries temporelles étudiées. Cependant, le RNN se distingue comme le modèle offrant, dans la majorité des cas, la meilleure précision pour anticiper les variations des cours boursiers, soulignant son efficacité dans ce contexte.

Mots clés: Prédiction, Réseau de neurone artificiel, CNN, RNN, MLP

Classification JEL : G12

Type de l'article : Recherche appliquée

Abstract:

The use of machine learning and deep learning to anticipate and capture stock market trends has captured the attention of the financial sector, offering the prospect of more accurate and efficient prediction of market dynamics. Faced with the growing complexity and highly volatile nature of financial markets, the adoption of advanced predictive models has become a necessity. This paper investigates the performance of four machine learning models for predicting the Moroccan stock market, namely Multilayer Perceptron (MLP), Recurrent Neural Networks (RNN), Convolutional Neural Networks (CNN) and the LSTM model, using historical daily stock price data. The results obtained, supported by the mean absolute percentage error (MAPE) values retained, show an alternation between MLP and RNN for the prediction and recognition of patterns in the time series studied. However, RNN stands out as a model offering, in the majority of cases, the best accuracy for anticipating stock price variations, underlining its effectiveness in this context.

Keywords: Prediction, Artificial Neural Network, CNN, RNN, MLP.

JEL Classification: G12

Paper type: Empirical research

1. Introduction

La prévision des rendements boursiers et des indices financiers représente un enjeu majeur pour les investisseurs, selon les analystes financiers, ainsi que pour les décideurs politiques. Ces prévisions influencent de manière significative les décisions d'investissement, la gestion des risques et, plus largement, la politique économique d'un pays. L'objectif est de minimiser les incertitudes et d'optimiser les choix d'allocation de capital. En effet, une prévision précise peut permettre de maximiser les rendements financiers tout en réduisant les risques liés aux fluctuations imprévisibles des marchés. Toutefois, cette tâche est loin d'être simple, car les marchés financiers sont caractérisés par une grande complexité et une volatilité élevée, rendant l'analyse et la prévision des rendements boursiers particulièrement difficiles.

Les marchés financiers, en raison de leurs interactions complexes et de la multitude de facteurs influençant leur évolution, sont intrinsèquement dynamiques. Ils sont soumis à des phénomènes tels que les chocs économiques, les crises financières, et les événements géopolitiques imprévus, qui contribuent à rendre les séries temporelles non linéaires et difficiles à modéliser. Traditionnellement, des modèles économétriques tels que les modèles AR (Auto-régressifs), MA (Moyenne mobile), ARMA (Auto-régression à moyenne mobile) ou GARCH (Generalized Autoregressive Conditional Heteroskedasticity) ont été utilisés pour analyser et prévoir l'évolution des rendements financiers. Ces approches ont montré certaines capacités à modéliser les relations linéaires dans les données historiques, mais elles se révèlent rapidement inadéquates lorsque l'on se heurte à la non-linéarité et aux structures complexes des séries temporelles financières. Ces modèles classiques peinent également à intégrer efficacement l'impact des facteurs externes, tels que les événements imprévus ou les ruptures de marché.

C'est dans ce contexte que l'émergence de l'intelligence artificielle (IA), et plus particulièrement des techniques d'apprentissage automatique (machine learning) et d'apprentissage profond (deep learning), a ouvert de nouvelles perspectives pour la prévision des rendements boursiers. Ces méthodes ont permis de dépasser les limitations des modèles traditionnels en offrant une approche plus souple et plus précise pour traiter des données volumineuses, complexes et non linéaires. Parmi ces approches innovantes, les modèles comme les Perceptrons Multicouches (MLP), les Réseaux Neuronaux Récurrents (RNN), et les réseaux à mémoire à long terme (LSTM) se sont révélés particulièrement efficaces. Les réseaux neuronaux profonds, notamment les LSTM, se distinguent par leur capacité à mémoriser les informations passées sur de longues périodes, ce qui est essentiel pour capter les dynamiques complexes des marchés financiers et améliorer la précision des prévisions. Ces modèles, par leur architecture et leurs algorithmes d'apprentissage adaptatif, permettent de modéliser des relations non linéaires et de prendre en compte des variables multiples simultanément, y compris des éléments temporels et des facteurs exogènes.

Néanmoins, bien que ces modèles d'apprentissage profond montrent des résultats prometteurs, leur application à la prévision des rendements boursiers soulève encore plusieurs questions. L'une des principales limites de ces approches réside dans leur capacité à prendre en compte les facteurs économiques externes qui influencent les marchés. Par exemple, des indicateurs macroéconomiques tels que le taux d'inflation, le taux de chômage, la croissance économique ou les politiques monétaires peuvent avoir un impact significatif sur les rendements financiers. Ces variables économiques, souvent interconnectées et influencées par des événements mondiaux, peuvent interagir de manière complexe avec les dynamiques internes des marchés boursiers. Dès lors, la prise en compte de ces indicateurs dans les modèles d'apprentissage profond constitue une piste importante de recherche. Intégrer ces données macroéconomiques dans les réseaux neuronaux pourrait permettre d'affiner les prévisions et d'améliorer la robustesse des modèles face aux fluctuations économiques imprévues.

Dans cette optique, cette étude s'inscrit dans un domaine de recherche en pleine évolution, cherchant à évaluer la performance des modèles d'apprentissage profond, notamment les LSTM, pour la

prévision des rendements boursiers. L'objectif est d'explorer comment ces modèles peuvent non seulement traiter les séries temporelles financières complexes, mais aussi intégrer des facteurs externes tels que les indicateurs macroéconomiques afin d'améliorer la précision des prévisions. En s'appuyant sur des données historiques et des simulations numériques, cette recherche s'efforcera de comprendre comment ces modèles réagissent face à différentes conditions économiques et à l'introduction de variables exogènes. Par ailleurs, l'étude abordera les nouvelles pistes de recherche qui émergent dans ce domaine, notamment l'utilisation combinée de différentes techniques d'intelligence artificielle, comme le renforcement de l'apprentissage ou l'apprentissage en profondeur multi-tâches, pour créer des modèles hybrides capables de mieux appréhender la diversité des facteurs influençant les rendements boursiers.

Les résultats de cette étude pourraient offrir des perspectives nouvelles pour les investisseurs, les économistes et les régulateurs financiers en leur permettant de mieux comprendre les mécanismes sous-jacents aux fluctuations des marchés financiers. De plus, ces approches innovantes pourraient jouer un rôle clé dans la gestion des risques financiers, en fournissant des outils plus performants et plus adaptatifs face à la volatilité croissante des marchés mondiaux. Ainsi, la recherche sur l'application de l'IA et des modèles d'apprentissage profond dans le domaine des marchés financiers apparaît non seulement comme un défi scientifique, mais aussi comme une opportunité pour améliorer la gestion et la stabilité des marchés financiers à l'échelle mondiale.

2. Revue de littérature

De nombreuses études ont exploré les différentes méthodes de prévision des rendements boursiers, en s'appuyant sur des modèles économétriques et des techniques d'intelligence artificielle. Les premiers travaux sur la prédiction des rendements boursiers se sont concentrés sur l'utilisation de modèles à facteurs uniques tels que le modèle d'évaluation des actifs financiers (CAPM). Le CAPM a été largement utilisé pour prédire les rendements des actions, en considérant les informations accessibles au public qui peuvent influencer les rendements anormaux (Mashayekhi et al., 2009). Cependant, des études ont également montré que des anomalies dans les rendements, telles que les erreurs d'évaluation des investisseurs, pouvaient entraîner des rendements anormaux, remettant en question l'efficacité des marchés financiers (Chan et al., 2006).

Parallèlement, des modèles économétriques tels que les ARMA, ARIMA et GARCH ont été largement utilisés pour modéliser les séries temporelles des rendements boursiers. Ces modèles sont particulièrement efficaces pour les données stables et linéaires, mais montrent leurs limites lorsqu'il s'agit de capturer la non-linéarité et la volatilité des marchés financiers, en particulier lors de crises économiques ou d'événements imprévus (Štيفانيć et al., 2020 ; Ronaghi et al., 2022).

L'introduction de l'intelligence artificielle a marqué une avancée significative dans la prévision des rendements boursiers. Les modèles d'apprentissage automatique tels que les arbres de décision (DT), les K-Nearest Neighbors (KNN) et les machines à vecteurs de support (SVR) ont été largement utilisés pour identifier des relations non linéaires dans les données financières (Chen et al., 2017 ; Nayak et al., 2015). Ces techniques permettent de mieux capturer la complexité des données et d'améliorer les prévisions. Cependant, elles présentent encore des limites, notamment en ce qui concerne la gestion des dépendances à long terme et le surajustement sur des ensembles de données volumineux et bruités (Zhang et al., 2023).

Les modèles d'apprentissage profond, en particulier les réseaux neuronaux multicouches (MLP), les réseaux neuronaux récurrents (RNN) et les réseaux à mémoire à long terme (LSTM), ont permis de franchir une étape supplémentaire dans la modélisation des séries temporelles complexes des marchés financiers. Ces modèles sont capables de capter les dépendances à long terme dans les données séquentielles et de traiter des volumes massifs de données avec une grande précision (Sharma et al., 2021 ; Yan, 2023). Les RNN, par exemple, sont particulièrement efficaces pour modéliser les relations séquentielles entre les données passées et futures (Lin et al., 1998). Les LSTM, qui intègrent des mécanismes de mémoire pour retenir et filtrer les informations pertinentes,

ont montré des résultats impressionnants dans la prévision des rendements boursiers, surmontant ainsi les défis liés aux gradients disparus ou explosifs (Yu et al., 2019 ; Huang et al., 2021). Les recherches récentes ont également exploré l'intégration d'indicateurs macroéconomiques dans les modèles de prévision des rendements boursiers. Des études ont montré que des facteurs tels que l'inflation, le taux de chômage et la croissance économique ont un impact significatif sur les rendements des actions, et leur intégration dans les modèles de prévision pourrait améliorer la précision des prévisions (Zhao et al., 2023 ; Bisoï et al., 2019). En particulier, l'intégration de ces variables dans les modèles d'apprentissage profond, tels que les LSTM, permet d'affiner les prédictions et de mieux comprendre les dynamiques du marché en réponse aux évolutions macroéconomiques (Caporale et al., 2022).

Figure 1 : Evolution de l'indice Principal « MASI » et 05 Indices Sectoriels



Source : Auteurs

Ainsi, bien que des progrès significatifs aient été réalisés dans l'utilisation des modèles d'IA pour la prévision des rendements boursiers, il reste de nombreuses pistes de recherche à explorer, notamment l'intégration des indicateurs macroéconomiques dans ces modèles pour améliorer leur robustesse et leur capacité à prédire les rendements dans des contextes économiques variables. Les modèles LSTM, en particulier, ont montré un potentiel remarquable pour la modélisation des séries temporelles complexes et non linéaires des marchés boursiers, offrant ainsi des perspectives prometteuses pour la gestion des risques financiers et la prise de décision en investissement.

Le Maroc, comme tous les pays du monde, a son indice principal, à savoir, le MASI (Moroccan All Shares Index), qui est l'indice principal de la Bourse des valeurs de Casablanca, il regroupe l'ensemble des actions cotées. Aussi le marché marocain a ses propres indices sectoriels. Il permet de mesurer la performance globale de la B.V.C, parlant ici de l'évolution journalière du marché.

À la suite de diverses réformes du marché boursier marocain, mises en œuvre par les autorités, une gamme diversifiée d'indices a été instaurée. Par exemple, l'indice MASI ESG 10, lancé en 2018, est un indice socialement responsable. Ces initiatives contribuent à rendre le marché boursier marocain particulièrement attractif pour les investisseurs, tant au niveau national qu'international. Le graphe suivant nous montre l'évolution quotidienne des cours du marché boursier marocain de la période allant du 1er janvier 2017 au 24 mai 2024, ainsi que son rendement durant la même période.

Afin de concilier le risque inhérent à la complexité du marché boursier et la recherche de rendements modérés de la part des investisseurs, les méthodes de prédiction des cours représentent une solution stratégique. Pour ce faire, un large éventail de techniques et modèles ont été utilisés et appliqués. À ce stade de notre réflexion, il semble pertinent de poser la question suivante : *quel est modèle de l'apprentissage automatique par ceux utilisés dans cette étude à bien capturer les tendances et prédire les valeurs futures des différentes séries étudiées ?*

3. Méthodologie :

3.1 Les Réseaux de Neurones à mémoire longue et courte durée (LSTM) :

Les réseaux LSTM sont des modèles bien adaptés à la modélisation des séries temporelles. Des recherches telles que celles de Fischer et Krauss ont mis en évidence l'utilisation réussie de LSTM dans la prédiction des prix d'actifs financiers en prenant en compte la dépendance temporelle des données. Le réseau est constitué à la base de plusieurs cellules LSTM, chaque cellule LSTM est composée de trois portes principales :

- **Porte d'oubli** : $f_t = (W_f \cdot [h_{t-1}, x_t] + b_t)$ (01)
- **Porte d'entrée** : $i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$ (02) & $C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$ (03)
- **Mise à jour de l'état cellulaire** : $C_t = f_t \cdot C_{t-1} + i_t \cdot C_t$ (04)
- **Porte de sortie** : $o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$ (05) & $h_t = o_t \cdot \tanh(C_t)$ (06)

3.2 Réseau de Neurones Convolutifs (CNN):

Le Réseau de Neurones Convolutifs (CNN), est l'un des types des ANN, qui est très sollicité dans les domaines du traitement des images, il est applicable aussi pour l'étude et l'analyse des séries temporelles, surtout en matière de la prédiction et la classification. Un CNN comprend essentiellement des couches convolutives, de pooling entièrement connectées.

- **Couches convolutives** : $Y = \text{Convolution}(X, W) + b$ (07) & $Z = \text{ReLU}(Y)$ (08)
- **Couches de pooling** : $Z_{\text{pool}} = \text{Max - Pooling}(Z)$ (09)
- **Couches entièrement connectées** : $\hat{y} = W_{fc} \cdot Z_{\text{flattened}} + b_{fc}$ (10)

3.3 Réseau de Neurone Récurrent (RNN) :

Le réseau de neurones récurrents est un modèle de la ANN, conçu pour traiter les données des séries temporelles. Il combine l'entrée actuelle et l'état caché précédent pour produire un nouvel état caché.

$$h_t = \tanh(W_{xh} \cdot x_t + W_{hh} \cdot h_{t-1} + b_h) \quad (11)$$

$$y_t = W_{hy} \cdot h_t + b_y \quad (12)$$

3.4 Le modèle Perceptron Multicouches M.L.P :

Les Multi-Layer Perceptrons (MLP), un type de réseau de neurones artificiels, sont utilisés pour capturer des relations complexes entre différentes variables. Des recherches comme celles de Moody et Wu ont examiné l'utilisation de MLP dans la prédiction des cours boursiers, mettant en avant la capacité de ces modèles à apprendre des motifs non linéaires.

- **Équation de la propagation avant** : $h = f(Wx + b)$ (13)
- **Fonction de coût** : $J(W, b) = \frac{1}{m} \sum_{i=1}^m (y(i) - \hat{y}(i))^2$ (14)

3.5. Métrique:

La Moyenne Absolue des Ecart en Pourcentage ou MAPE, est un moyen de mesure largement utilisé dans l'évaluation de la précision des modèles de prévision. Appliqué à notre thématique de recherche présente, à partir de la fonction ci-dessous, le MAPE est le calcul des écarts détectés entre les valeurs réelles (Données de test, 20% de notre base de données), et valeurs prédites générées par les réseaux appliqués.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| * 100 \quad 15$$

3.6. Données

Cet article a pour but essentiel de modéliser et prédire les valeurs futures des prix de clôture de l'indice principal « MASI » et des prix de clôture de 07 indices sectoriels du marché boursier marocain. Pour ce faire, nous optons pour l'utilisation des prix historiques journaliers des 08 indices (prix d'ouverture, prix plus haut et prix plus bas), durant la période allant du 1^{er} janvier 2017 au 29 mai 2024, soit **1847** observations (1847, 4) pour chaque indice. En plus de l'indice MASI, notre base de données intégrera des indices des secteurs : Bancaire, Télécommunications, Pétrole et Gaz, Loisirs et Hôtels, Matériels Logiciels et Services Informatiques, Participation et Promotion Immobilière, Assurances, et finalement celui des Bâtiments et Matériel de Construction.

4. Résultats et Discussions :

Figure 2 : Valeurs réelles et prédites de l'indice « MASI » par le Réseau RNN



Figure 3 : Valeurs réelles et prédites de l'indice « MASI » par le Réseau MLP




Tableau 1 : MAPE obtenues lors de la prédiction des Valeurs futures de l'indice principal « MASI ».

Indice principal	RNN	LSTM	CNN	MLP
MASI	0.00545	0.00854	0.00717	0.006691

Source : Auteurs

Figure 4 : Valeurs réelles et prédites de l'indice « MASI » par le Réseau LSTM





Figure 5 : Valeurs réelles et prédites de l'indice « MASI » par le Réseau CNN



Source : Auteurs

Dans le cas de l'indice principal « MASI », c'est les réseaux MLP et RNN qui ont réussi à capturer le modèle, cependant, si on compare les M.A.P.E de chaque réseau, on constate que le réseau RNN est plus performant pour le « MASI », en revanche, les deux autres réseaux LSTM et CNN n'arrivent pas de détecter les tendances du modèle. La figure 4 montre la non-cohérence entre les valeurs réelles et celles prédites par le modèle LSTM, le long de 300 observations, alors que le modèle réussit seulement en quelque période de bien capturer la tendance de cet indice, selon la figure 5.

Figure 6 : Valeurs réelles et prédites de l'indice « Loisirs et Hôtels » par le Réseau RNN



Figure 7 : Valeurs réelles et prédites de l'indice « Loisirs et Hôtels » par le Réseau MLP



Figure 8 : Valeurs réelles et prédites de l'indice sectoriel « Loisirs et Hôtels » par le Réseau LSTM



Figure 9 : Valeurs réelles et prédites de l'indice sectoriel « Loisirs et Hôtels » par le Réseau CNN




Tableau 2 : MAPE obtenues lors de la prédiction des Valeurs futures de l'indice sectoriel « Loisirs et Hôtels ».

Indice Sectoriel	RNN	LSTM	CNN	MLP
Loisirs et Hôtels	0.03671	0.02386	0.03736	0.02290

Source : Auteurs

Pour l'indice « Loisirs et Hôtels », le modèle, qui a enregistré un MAPE le plus faible parmi les quatre réseaux, est le réseau MLP, tandis que les réseaux RNN, CNN et LSTM, ne parviennent pas à détecter les tendances du modèle. Le CNN a bien suivi la tendance de cette série, comme il est apparu dans la figure 9, mais il a perdu légèrement entre 150 et 250, après quoi, il n'arrive plus à suivre l'évolution de près. Pour le LSTM, il a enregistré un écart moyen le long de la période (fig 8), aussi le RNN a commencé avec un écart moyen, mais au moment 175 (approximativement), cet écart est devenu très grand (fig.6).

Figure 10: Valeurs réelles et prédites de l'indice « Banques » par le Réseau RNN




Figure 12: Valeurs réelles et prédites de l'indice « Banques » par le Réseau LSTM




Figure 11: Valeurs réelles et prédites de l'indice « Banques » par le Réseau MLP

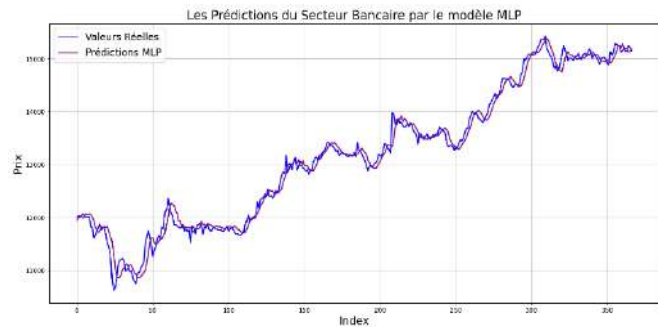


Figure 13: Valeurs réelles et prédites de l'indice « Banques » par le Réseau CNN




Tableau 3 : MAPE obtenues lors de la prédiction des Valeurs futures de l'indice sectoriel « Banques ».

Indice Sectoriel	RNN	LSTM	CNN	MLP
Banques	0.009856	0.010367	0.009581	0.008637

Source : Auteurs

Le cas du secteur « Banquier », le réseau MLP a réussi à capturer le modèle, et a enregistré le MAPE le plus faible. Le réseau RNN a presque réussi à identifier la tendance du modèle, alors que le CNN et le LSTM ne parviennent pas à capturer le changement et la fluctuation, le LSTM le long de la période prédite et le CNN dans quelques périodes (0 et 40 ; 210 et 250, 300 et 350).

Figure 14: Valeurs réelles et prédites de l'indice « Assurances » par le Réseau RNN




Figure 15: Valeurs réelles et prédites de l'indice « Assurances » par le Réseau MLP



Source : Auteurs

Figure 16 : Valeurs réelles et prédites de l'indice « Assurances » par le Réseau LSTM




Figure 17 : Valeurs réelles et prédites de l'indice « Assurances » par le Réseau CNN




Tableau 4 : MAPE obtenues lors de la prédiction des Valeurs futures de l'indice sectoriel « Assurances ».

Indice Sectoriel	RNN	LSTM	CNN	MLP
Assurances	0.024912	0.011428	0.012583	0.010843

Source : Auteurs

Dans le cas de l'indice « Assurances », le réseau MLP est modèle qui capter mieux l'évolution de cette série, en enregistrant la valeur MAPE, la plus faible, ce n'est pas une meilleure prédiction, mais reste la plus pertinente, à cause des mauvaises modélisations des autres algorithmes, ayant montrés que les modèles RNN, LSTM et CNN n'arrivent pas à saisir les tendances le long de la période du test (fig 14, 16 et 17), malgré les valeurs approchées de MAPE de CNN et LSTM.

Figure 18 : Valeurs réelles et prédites de l'indice sectoriel « Pétrole et Gaz » par le Réseau RNN




Figure 19 : Valeurs réelles et prédites de l'indice sectoriel « Pétrole et Gaz » par le Réseau MLP




Figure 20 : Valeurs réelles et prédites de l'indice sectoriel « Pétrole et Gaz » par le Réseau LSTM




Figure 21 : Valeurs réelles et prédites de l'indice sectoriel « Pétrole et Gaz » par le Réseau CNN

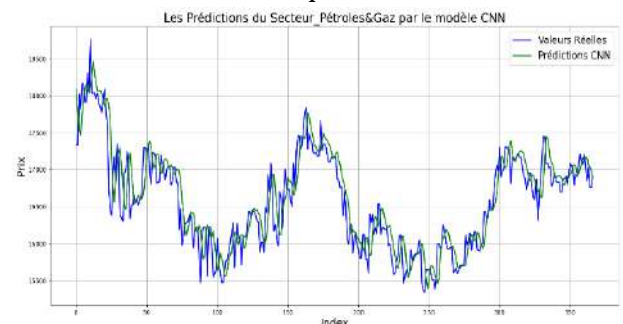


Tableau 5 : MAPE obtenues lors de la prédiction des Valeurs futures de l'indice sectoriel « Pétrole et Gaz ».

Indice Sectoriel	RNN	LSTM	CNN	MLP
Pétrole et Gaz	0.011432	0.014215	0.013622	0.011825

Source : Auteurs

Pour le secteur Pétrole et Gaz, les RNN et MLP sont les réseaux qui ont présenté les meilleures prédictions pour ce secteur, et puisque les valeurs enregistrées du MAPE favorisent le RNN (0.011432 contre 0.011825), on accepte le schéma de ce réseau. Pour les autres réseaux (LSTM et CNN), ils ont échoué à capturer la tendance de modèle le long de la période.

Figure 22 : Valeurs réelles et prédites de l'indice sectoriel « Télécommunications » par le Réseau RNN




Figure 23 : Valeurs réelles et prédites de l'indice sectoriel « Télécommunications » par le Réseau MLP



Figure 24 : Valeurs réelles et prédites de l'indice sectoriel « Télécommunications » par le Réseau LSTM



Figure 25 : Valeurs réelles et prédites de l'indice sectoriel « Télécommunications » par le Réseau CNN



Tableau 6 : MAPE obtenues lors de la prédiction des Valeurs futures de l'indice sectoriel « Télécommunications ».

Indice Sectoriel	RNN	LSTM	CNN	MLP
Télécommunications	0.019737	0.024440	0.023603	0.021978


Source : Auteurs

Dans le cas du secteur des « Télécommunications », d'après les Figures de 22 à 25, les quatre réseaux n'ayant pas capturer efficacement l'évolution de cet indice, il y a des écarts enregistrés par la totalité des modèles, prenant à titre explicatif le modèle RNN, qui est le modèle le plus performant avec sa petite valeur de MAPE, et qui est suivi globalement l'évolution des valeurs réelles. Les trois autres réseaux (CNN, MLP et LSTM) ne parviennent pas à détecter les fluctuations du modèle. Les CNN et MLP ont été largement perdus entre 50 et 130.

Figure 26 : Valeurs réelles et prédites de l'indice sectoriel « Transport » par le Réseau RNN



Figure 27 : Valeurs réelles et prédites de l'indice sectoriel « Transport » par le Réseau MLP



Source : Auteurs

Figure 28 : Valeurs réelles et prédites de l'indice sectoriel « Transport » par le Réseau LSTM




Figure 29 : Valeurs réelles et prédites de l'indice sectoriel « Transport » par le Réseau CNN




Tableau 7 : MAPE obtenues lors de la prédiction des Valeurs futures de l'indice sectoriel « Transport ».

Indice Sectoriel	RNN	LSTM	CNN	MLP
Transport	0.010719	0.015407	0.013248	0.013601

Source : Auteurs

Dans le cas de l'indice sectoriel « Transport », le RNN, comparé aux autres a réussi à capturer les tendances, et a enregistré la plus faible valeur du MAPE. D'après les figures 27, 28 et 29, les LSTM, CNN et MLP ont échoué à bien modéliser le comportement de la série temporelle de ce modèle. Le classement de leur performance se ferait de la sorte : MLP, CNN et LSTM.

Figure 30 : Valeurs réelles et prédites de l'indice sectoriel « Matériel Logiciel et Serv Info » par le Réseau RNN




Figure 31 : Valeurs réelles et prédites de l'indice sectoriel « Matériel Logiciel et Serv Info » par le Réseau MLP




Figure 32 : Valeurs réelles et prédites de l'indice sectoriel « Matériel Logiciel et Serv Info » par le Réseau LSTM



Figure 33 : Valeurs réelles et prédites de l'indice sectoriel « Matériel Logiciel et Serv Info » par le Réseau CNN



Tableau 8 : MAPE obtenues lors de la prédiction des Valeurs futures de l'indice sectoriel « Matériel Logiciel et Serv Info ».

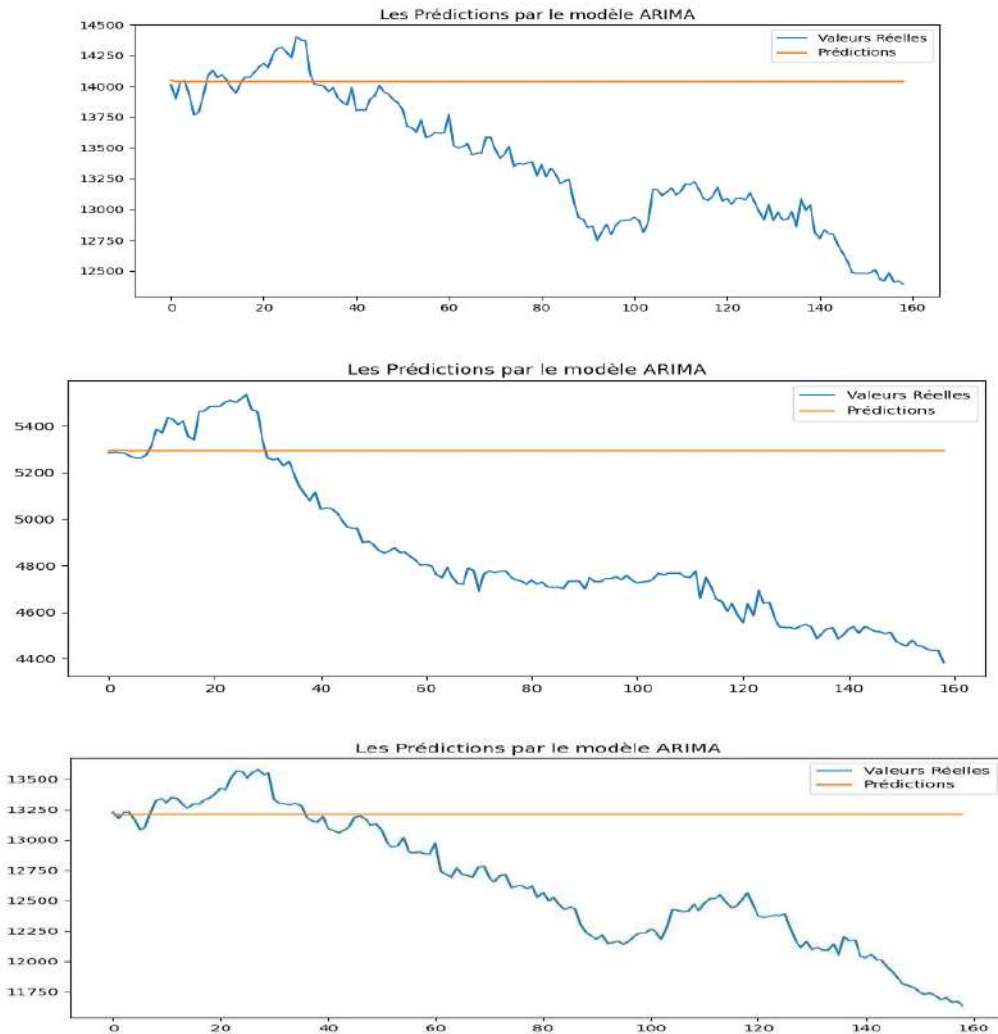
Indice Sectoriel	RNN	LSTM	CNN	MLP
Matériel Logiciel et Services Informatiques	0.009634	0.012906	0.010886	0.010195

Source : Auteurs

Dans le cas du secteur « Matériel Logiciel et Services Informatiques » (fig de 30 à 33), le modèle RNN a obtenu les meilleurs résultats par rapport aux autres réseaux, même si dans certaines périodes, les valeurs prédites par ce modèle restent un peu décalées des valeurs réelles. Ceci peut être constaté également par la faible valeur du MAPE enregistrée. Le MLP se

positionne en deuxième place en matière de performance. Tandis que les CNN et LSTM ont présenté une précision très faible dans les prédictions.

Figure 34 : Valeurs réelles et prédites de l'indice MASI et des indices ASSURANCES et Banques » par le modèle ARIMA



Source : Auteurs

5. Conclusion :

Dans ce travail de recherche, nous avons appliqué quatre modèles d'intelligence artificielle, en particulier ceux issus du Deep Learning, pour prédire les cours du marché boursier marocain. Ces prédictions ont porté sur l'indice principal « MASI » ainsi que sur sept indices sectoriels : les secteurs des banques, des assurances, du pétrole et du gaz, des télécommunications, des transports, des loisirs et hôtels, et enfin, celui du matériel, logiciel et services informatiques. Pour ce faire, nous avons utilisé les modèles de réseaux de neurones multicouches (MLP), de réseaux de neurones récurrents (RNN), de réseaux de neurones Convolutifs (CNN) et de Long Short-Term Memory (LSTM).

Les résultats de notre étude ont montré que les modèles MLP et RNN ont particulièrement bien performé dans la prédiction des tendances des indices boursiers. En effet, sur cinq des huit indices analysés, le modèle RNN a su capter efficacement les tendances du marché, tandis que pour les trois autres indices, c'est le modèle MLP qui a montré une meilleure capacité à prévoir les mouvements des prix. Les différences de performance entre les modèles étaient parfois

minimes, mais la métrique MAPE a permis de trancher en faveur des modèles MLP et RNN dans la majorité des cas. Toutefois, il a été observé que les résultats des modèles classiques, en particulier ARIMA, étaient bien inférieurs, avec des écarts considérables entre les valeurs prédites et réelles. Cela confirme une fois de plus la supériorité des techniques d'intelligence artificielle par rapport aux modèles traditionnels.

Une revue des études antérieures sur la prédiction des marchés financiers indique que le modèle LSTM est souvent cité comme étant particulièrement performant pour la prévision des séries temporelles financières dans différents contextes de marché. Plusieurs recherches ont souligné l'efficacité des LSTM pour capturer les dépendances à long terme dans les données financières, ce qui les rend particulièrement adaptés à la complexité des marchés boursiers. De nombreuses études ont révélé que les LSTM surpassaient d'autres modèles classiques et même d'autres architectures de réseaux neuronaux dans la prédiction des tendances des marchés financiers, en particulier dans les environnements économiques volatils.

Cependant, notre étude ouvre la voie à plusieurs pistes de recherche futures. En premier lieu, l'intégration d'indicateurs financiers externes, tels que l'inflation, le taux de chômage, les taux d'intérêt ou encore les indicateurs macroéconomiques, pourrait permettre d'améliorer les performances des modèles prédictifs en enrichissant les séries temporelles utilisées pour l'entraînement des modèles.

De plus, il serait intéressant d'explorer l'utilisation de techniques d'apprentissage profond combinées à d'autres approches hybrides, telles que les modèles basés sur l'analyse fondamentale et technique, ou encore l'intégration de données alternatives telles que les sentiments des investisseurs extraits des réseaux sociaux et des nouvelles économiques. Ces ajouts pourraient améliorer la robustesse des prédictions et permettre une gestion plus efficace du risque dans les portefeuilles d'investissement.

En somme, bien que les résultats de cette étude montrent que les modèles MLP et RNN sont performants dans la prédiction des cours du marché boursier marocain.

Références

- (1). BOUDRII & EL BOUHADI.A. (2021). Réseau LSTM et méthodologie de Box et Jenkins pour la prévision des séries temporelles : essai sur l'indice MASI de la Bourse de CASABLANCA. *Revue Française d'Economie et de Gestion*, 2(12), pp. 13-36.
- (2). Budhani N., Jha C. K., and Budhani S. K. (2014). "Prediction of stock market using artificial neural network. In *Soft Computing Techniques for Engineering and Technology (ICSCCTET)*, (pp. 1-8).
- (3). H., J. (2016). Investigation into the effectiveness of long short term memory networks for stock price prediction. *arxiv preprint arxiv*, 10389-10397.
- (4). Hiransha Ma, Gopalakrishnan E.Ab, Vijay Krishna Menonab, Soman K.P. (2018). NSE Stock Market Prediction Using Deep-Learning Models. *Elsevier*, 1352-1362.
- (5). Houad Ben Houad, Youssef Oubouali. (2018, Août 23). Prévisions de la liquidité des actions cotées à la bourse des valeurs de Casablanca. Comparaison entre la modélisation ARIMA et les réseaux de neurones NARX. *ScienceDirect*, 83-99.
- (6). HOUAD, B. (2021, juillet). Une approche hybride de transformée en ondelettes, de réseaux de neurones convolutifs et de réseaux de neurones GRU pour la prédiction des prix de Moroccan All Index (MASI). *Alternatives Managériales économiques*(E-ISNN-2665-7511), 102-119.
- (7). Htet Htet Htet, Michael Biehl and Nicolai Petkov. (2023). Survey of feature selection and extraction techniques for stock market prediction. *SpringerOpen*, 9-26.
- (8). Htet, H.H., Biehl, M., Petkov, N. (2024). Forecasting relative returns for S&P 500 stocks using machine learning. *Springer Open*, 1-16. doi:10.1186/s40854-024-00644-

- 0
- (9). Inssafe Bachir, AbdnbiElMarzouki. (2023, May 20). L'Intelligence Artificielle et le marché boursier: Une Analyse théorique appliquée pour traiter le positionnement du Maroc. Hal open science, 4, 359-371. doi:10.5281
 - (10). Kazemi, A., Moddarres, M., Mehregan, M.R. and Foruqi-Asl, A. (2010), "The forecast of transport sector energy demand by the Grey Markov Chain Model", Conference on Energy Efficiency.
 - (11). Khajavi, S., Najafi, Z. and Zinedine Zadeh, S. (2012), "Applying the grey models and the development of a simple way to forecast free cash flow of listed companies in Tehran stock exchange", Journal of Financial and Management Engineering Exchange, Vol. 13, pp. 21-34.
 - (12). Kothari, S.P. and Wasley, C.E. (1989), "Measuring security price performance in size-clustered samples", The Accounting Review, Vol. 64 No. 2, pp. 228-249.
 - (13). Li, Q., Kamaruddin, N., Yuhaniz, S.S., Al-Jaifi, H.A.A. (2024). Forecasting stock prices changes using long-short term memory neural network with symbolic genetic. Elsevier, . doi:10.1038/s41598-023-50783-0
 - (14). Liu, S. and Lin, Y. (2006), Grey Information, Springer, London.
 - (15). Mashayekhi, B., Fadaee Nejad, M. and Kalateh Rahmani, R. (2009), "Explanatory power of accruals (abnormal) stock returns in relation to behavior: Effects of corporate profits and the systematic risk (b)", Journal of Accounting and Auditing, Vol. 4, pp. 1-20.
 - (16). Moghaddam A. H., Moghaddam M. H., and Esfandyari M. (2016). Stock market index prediction using artificial neural network. Journal of Economics, Finance and Administrative Science 21, 89-93.
 - (17). Mohammadi, A. and Zeinodin Zade, S. (2011), "Applying grey forecasting method to forecast the portfolio's rate of return in stock market of Iran", Australian Journal of Business and Management Research, Vol. 1 No. 7, pp. 1-16.
 - (18). Namazi, M. and Kiamehr, M. (2008), "Forecasting daily stock returns of listed companies in Tehran stock exchange using artificial neural networks", Journal of Financial Research, Vol. 6 No. 3, pp. 60-72.
 - (19). Nate Gruver, M. F. (2023, Oct 11). Large Language Models Are Zero-Shot Time Series Forecasters. arXiv:, 1. doi:310.07820
 - (20). Paquet, P. (2019, Aprvil 11). L'utilisation des réseaux de neurones artificiels en finance. Hal open science.
 - (21). Pindyck, R. (1984), "Risk, inflation, and the stock market", American Accounting Review, Vol. 74 No. 3, pp. 335-351.
 - (22). Ping, Y. and Yang, H. (2004), "Using hybrid grey model to achieve revenue assurance of telecommunication companies", Journal of Grey System, Vol. 7, pp. 39-50.
 - (23). Pullets, J.M. and Wilson, M. (2010), "Average correlation and stock market returns", Journal of Financial Economics, Vol. 96 No. 3, pp. 364-380.
 - (24). Raei, R. and Chavoshi, K. (2003), "Forecasting of stock return in Tehran stock exchange: artificial neural networks and multifactors models", J. Financial Study, Vol. 15 No. 5, pp. 97-120.
 - (25). Rui Zhu, Guang-Yan Zhong, Jiang-Cheng Li. (2024). Forecasting price in a new hybrid neural network model with machine learning. Elsevier, 249.
 - (26). Tran Phuoc, Pham Thi Kim Anh, Phan Huy Tam & Chien V. Nguyen. (2023). Applying machine learning algorithms to predict the stock price trend in the stock market – The case of Vietnam. 11(323), . doi:10.1057/s41599-024-02807-x
 - (27). Verchenco, O. (2002), "Determinants of stock market volatility dynamics", Working Paper, HEC University of Lausann.

- (28). Wang, C.-H. and Hsu, L. (2008), "Using genetic algorithms grey theory to forecast high technology industrial output", *Application Mathematics and Computation*, Vol. 195 No.1, pp. 256-263.
- (29). Wang,Z.(2013), "An optimized Nash nonlinear grey Bernoulli model for forecasting the main economic indices of high technology enterprises in China", *Computers & Industrial Engineering*, Vol. 64 No.0, pp. 780-787.
- (30). Zinedine Zadeh, S. (2011), "Predicting stock returns in Tehran Stock Exchange by using the Grey prediction model", MA thesis, Faculty of Economics, Management and Social Sciences, Shiraz University.