

Mozaic

Au-delà des modèles traditionnels : Incorporer les pools GMX et l'apprentissage automatique pour une performance supérieure des portefeuilles

Résumé

Cette recherche étudie comment l'apprentissage automatique peut améliorer la diversification des portefeuilles de crypto-monnaies et les rendements ajustés au risque en incorporant les pools de liquidité GMX qui permettent un rendement supplémentaire. Nous explorons des techniques avancées d'optimisation de portefeuille ainsi que des modèles d'apprentissage automatique pour prédire les rendements des pools GMX dans la construction de portefeuilles avec différents profils de risque.

Pour prendre en compte les caractéristiques uniques de ces pools, nous nous appuyons sur la sélection des caractéristiques pour identifier les facteurs les plus importants qui influencent leur rendement et leur prix. Nos modèles d'apprentissage automatique intègrent les prédictions de plusieurs algorithmes, ce qui se traduit par des améliorations significatives de la performance du portefeuille optimisé par rapport à un indice de référence. Cela se traduit par un rendement cumulé plus élevé et un ratio de Sharpe supérieur. Nos simulations démontrent que cette approche fondée sur les données, axée sur des caractéristiques pertinentes, améliore de manière significative la performance du portefeuille par rapport à un indice de référence. Le portefeuille optimisé atteint à la fois un rendement cumulé plus élevé et un ratio de Sharpe supérieur, soulignant les avantages de l'intégration des pools GMX et de l'application de l'apprentissage automatique à la construction de portefeuilles de crypto-monnaies. Dans l'ensemble, cet article propose une nouvelle stratégie pour naviguer sur le marché dynamique des crypto-monnaies. Il démontre la valeur de l'intégration des pools de GMX et de l'apprentissage automatique, en particulier en mettant l'accent sur la sélection de caractéristiques pertinentes, pour construire des portefeuilles de crypto-monnaies robustes.

Mots-clés : Pool GMX ; Cryptocurrency ; Machine Learning ; Gradient Boosting ; Sélection de caractéristiques ; Optimisation de portefeuille ; Ratio de Sharpe.

1. Introduction

Les crypto-monnaies ont bouleversé la finance, attirant les investisseurs avec un potentiel de rendement élevé malgré leurs fluctuations de prix sauvages. Les méthodes traditionnelles d'optimisation de portefeuille ont du mal à s'adapter aux caractéristiques uniques des crypto-monnaies, mais l'apprentissage automatique offre une solution puissante. En analysant de grandes quantités de données, les modèles d'apprentissage automatique peuvent prédire les rendements et la volatilité, ce qui permet aux investisseurs d'améliorer leurs prévisions, d'estimer la volatilité avec plus de précision et de développer des stratégies d'allocation d'actifs dynamiques pour une optimisation risque-rendement en temps réel. Toutefois, l'efficacité de l'apprentissage automatique dépend de la qualité des données et de la sélection des algorithmes. Les protocoles de finance décentralisée (DeFi), tels que les pools GMX, sont encore plus complexes. Ces pools de liquidités offrent des revenus passifs grâce à la culture du rendement, mais leur intégration dans un portefeuille nécessite un examen minutieux de leurs profils risque-rendement et de leurs inconvénients potentiels, tels que les pertes impermanentes.

S'appuyant sur les travaux fondamentaux de Markowitz (1952) sur la théorie moderne du portefeuille (TMP), des études récentes ont exploré l'applicabilité de ces principes dans le contexte des crypto-monnaies. Les travaux de Holovatiuk (2020) démontrent le potentiel des crypto-monnaies à renforcer la diversification des portefeuilles et à améliorer le couple risque-rendement. Sahu et al. (2024) soulignent en outre le rôle des crypto-monnaies dans l'optimisation des portefeuilles, en mettant en évidence leur capacité à améliorer l'efficacité des portefeuilles grâce à la décorrélation avec les actifs traditionnels. Cependant, les caractéristiques uniques des crypto-monnaies nécessitent des approches spécialisées de l'optimisation de portefeuille qui vont au-delà du cadre traditionnel de la TPM. Les études de Lorenzo et Arroyo (2023) explorent ces complexités et proposent des stratégies pour naviguer dans la forte volatilité, la dépendance sérielle et le potentiel d'événements extrêmes inhérents aux marchés des crypto-monnaies. En outre, Letho et al. (2022) examinent les possibilités de diversification sur les marchés émergents des crypto-monnaies.

Dans ce contexte, les techniques d'apprentissage automatique sont de plus en plus explorées pour comprendre les complexités des marchés des crypto-monnaies et prédire à la fois les rendements et la volatilité (Amirzadeh et al. 2022, Tang et al. 2022, Wang et al. 2021). Les études de Poudel et al. (2023) démontrent l'efficacité de divers modèles d'apprentissage automatique tels que LSTM pour la prédiction des prix du Bitcoin et du Dogecoin, ainsi que l'utilisation d'algorithmes de réseaux neuronaux pour prédire la volatilité. De même, Chen et al. (2020) explorent l'utilisation d'algorithmes Random Forest pour prédire la volatilité du bitcoin. Toutefois, une approche unique n'est peut-être pas idéale. Khan et al. (2023) soulignent la nécessité de disposer de modèles spécifiques aux crypto-monnaies. Leurs résultats

suggèrent une performance supérieure avec des techniques de lissage lors de la prédiction de la volatilité du Bitcoin par rapport à un modèle autorégressif de réseau neuronal qui surpasse l'Ethereum. Ces résultats s'inscrivent dans le cadre de l'exploration en cours de diverses techniques de ML, comme l'illustrent Sharifi et al. (2022), qui se concentrent sur les machines à vecteurs de support. Ces études soulignent le potentiel de la ML pour améliorer la prédiction du marché des crypto-monnaies, reconnaissant le besoin de modèles adaptés aux portefeuilles de crypto-monnaies.

Cet article explore la puissance de la ML dans l'optimisation de portefeuille spécifiquement conçue pour le marché des crypto-monnaies. Nous nous concentrons sur la construction de frontières efficaces qui établissent un équilibre optimal entre le risque et le rendement pour les investisseurs. Nous nous penchons sur trois modèles importants : Black-Litterman, la parité des risques hiérarchique (HRP) et l'optimisation de la moyenne-variance. Pour tenir compte des caractéristiques uniques des pools GMX, nous intégrons les prédictions de plusieurs séries temporelles et de modèles d'apprentissage automatique. Cela nous permet de saisir les caractéristiques uniques des pools de liquidité GMX. Nous tirons parti de l'apprentissage automatique pour identifier les facteurs les plus importants qui influencent le rendement et les rendements des pools. Ces informations sont ensuite introduites dans un ensemble varié d'algorithmes d'apprentissage automatique afin de trouver le meilleur modèle pour prédire les rendements et la volatilité. Ces valeurs prédites sont ensuite introduites dans les algorithmes d'optimisation du portefeuille, comme illustré dans la figure 1.

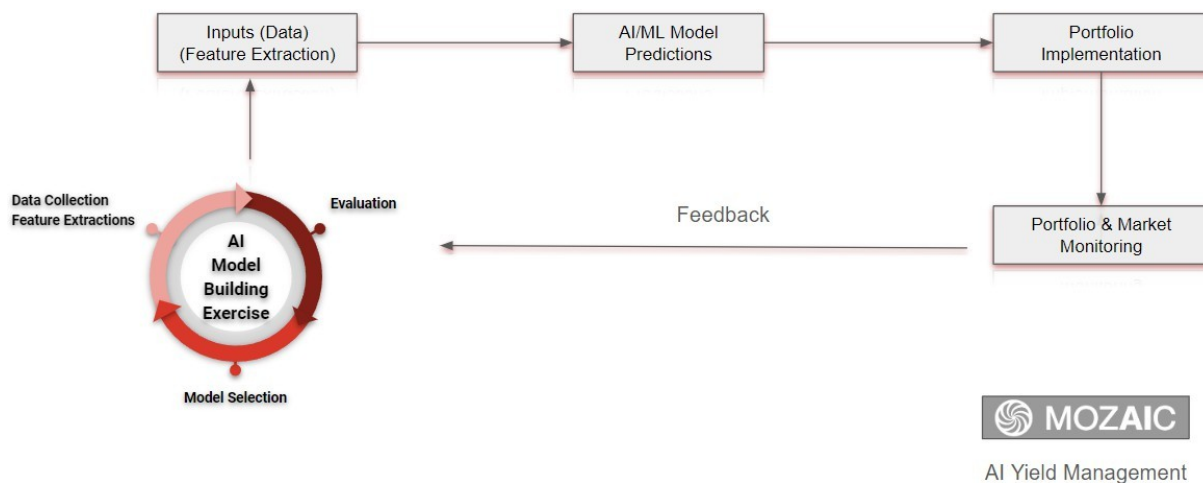


Figure 1 - Gestion du rendement de l'IA

En exploitant la puissance de l'apprentissage automatique à des fins de prédiction et d'optimisation, ces techniques de pointe permettent aux investisseurs de prendre des décisions éclairées. Ils peuvent construire des portefeuilles solides au sein du marché dynamique et évolutif des crypto-monnaies, en s'alignant parfaitement sur leur tolérance au risque et leurs objectifs de rendement individuels.

Les résultats sont probants. Notre portefeuille optimisé, construit en utilisant les rendements et la volatilité prédits par les modèles d'apprentissage automatique, atteint un rendement quotidien de 0,5 %, dépassant le rendement de référence du Bitcoin (BTC) de 0,34 %. En outre, le portefeuille affiche un ratio de Sharpe supérieur, ce qui indique un profil de rendement ajusté au risque plus attrayant que la simple détention de BTC.

2. Optimisation du rendement grâce à l'IA

2.1 Données et caractéristiques

Nos modèles d'apprentissage automatique sont formés sur les données collectées à partir de différentes sources, y compris, mais sans s'y limiter :

- **Prix des crypto-monnaies** : Les prix de clôture quotidiens sont obtenus à partir d'une source fiable pour une période historique significative afin de saisir les tendances et les fluctuations du marché. Nous nous concentrons sur un ensemble défini de crypto-monnaies qui constituent les principaux pools de liquidités sur GMX.
- **Données du pool GMX** : Les données historiques quotidiennes, y compris les prix des pools et les informations sur les taux d'intérêt et les rendements, sont collectées directement à partir de la plateforme GMX.
- **Facteurs supplémentaires** : Les données historiques sur les paramètres pertinents du protocole DeFi (par exemple, la valeur totale bloquée, les frais de négociation) sont recueillies auprès de sources non spécifiées.
- **Les indicateurs techniques** sont calculés sur la base des données historiques des prix du pool GMX afin de saisir les mouvements de prix à court et à long terme.
- **Facteurs macroéconomiques** : Le taux des fonds fédéraux au jour le jour, qui reflète la politique monétaire américaine et l'appétit pour le risque sur les marchés financiers, est pris en compte pour évaluer son impact potentiel sur l'activité des crypto-monnaies et des DeFi. Le pétrole et d'autres matières premières, considérés comme une influence économique mondiale majeure, sont également pris en compte pour comprendre leur effet potentiel sur le sentiment des investisseurs en matière de crypto-monnaies et de DeFi. En outre, nous recueillons des données historiques sur un ensemble plus large de facteurs traditionnels susceptibles d'influencer les rendements, les rendements et les volatilités du pool GMX.

2.2 Algorithmes de prévision ML

Entraînement du modèle pour la prédiction des pools de GMX : Pour prédire le rendement et la volatilité des pools de GMX, qui sont essentiels pour optimiser les portefeuilles d'investissement, des algorithmes d'apprentissage automatique sont utilisés. Ces algorithmes identifient d'abord les facteurs les plus importants qui influencent la performance des pools. Ensuite, ils sont entraînés sur des données historiques séparées en ensembles de formation, de validation et de test. L'ensemble de formation, qui s'étend d'octobre 2023 à janvier 2024, fournit les données permettant aux algorithmes d'apprendre des

modèles. L'ensemble de test, de février à mars 2024, est utilisé pour évaluer la précision du modèle sur des données inédites.

Sélection et évaluation du modèle : Une approche par fenêtre mobile est utilisée, où le modèle est formé sur une période spécifique (semaines ou mois) et prédit ensuite la période suivante. Ce processus est répété en avançant continuellement la fenêtre. Pour garantir la généralisation du modèle et éviter l'ajustement excessif, une technique appelée validation croisée multiple est employée. En outre, plusieurs méthodes d'apprentissage automatique des algorithmes tels que Gradient Boosting, LGBM, Lasso et régression linéaire sont explorés.

La sélection finale du modèle est basée sur ses performances sur l'ensemble de test, mesurées par des paramètres tels que la racine de l'erreur quadratique moyenne (RMSE), l'erreur quadratique moyenne (MSE) et l'erreur absolue moyenne en pourcentage (MAP APE), qui évaluent la différence entre les valeurs prédites et les valeurs réelles.

2.3 Optimisation du portefeuille

Cette recherche explore trois modèles avancés d'optimisation de portefeuille qui vont au-delà de l'approche traditionnelle de la moyenne-variance, à savoir les modèles de Black-Litterman, de parité de risque hiérarchique (HRP) et de moyenne-variance avec GARCH. Le problème du portefeuille est défini comme suit. Si w est le vecteur de poids des actions avec des rendements attendus μ , alors le rendement du portefeuille est égal au poids de chaque action multiplié par son rendement, c'est-à-dire $w^T \mu$. Le risque du portefeuille en termes de matrice de covariance Σ est donné par $w^T \Sigma w$.

L'optimisation du portefeuille peut alors être considérée comme un problème d'optimisation convexe, et une solution peut être trouvée en utilisant la programmation quadratique. Si nous désignons le rendement cible par μ^* , l'énoncé précis du problème d'optimisation du portefeuille à long terme est le suivant :

$$\begin{aligned} & \min (w^T \Sigma w) & (1) \\ \text{s. t. } & w^T \mu \geq \mu^* \\ & w^T \mathbf{1} = 1 \\ & w_i \geq 0 \end{aligned}$$

Si nous modifions le rendement cible, nous obtiendrons un ensemble différent de pondérations (c'est-à-dire un portefeuille différent) - l'ensemble de tous ces portefeuilles optimaux est appelé frontière efficiente.

La performance de chaque modèle d'optimisation de portefeuille est évaluée à l'aide de mesures telles que le ratio de Sharpe, le ratio de Sortino, le Maximum Drawdown, le ratio de Calmar afin de comparer leur efficacité à générer des rendements ajustés au risque pour les portefeuilles avec et sans pools GMX. Les portefeuilles optimisés sont testés à rebours sur des données historiques afin d'évaluer leur performance dans des conditions de marché réelles. Il s'agit de simuler le comportement des portefeuilles sur la base des prix et des rendements passés et d'évaluer les rendements obtenus et les paramètres de risque.

En résumé, nous suivons la procédure décrite dans la figure 1 pour optimiser notre portefeuille. Divers algorithmes d'apprentissage automatique (par exemple, Random Forests, LSTMs) sont utilisés pour prédire les rendements et les volatilités futurs de chaque pool GMX, en exploitant à la fois les données historiques, les valeurs des indicateurs techniques et les données de l'indice de référence.

les facteurs macroéconomiques. Les indicateurs techniques capturent les tendances potentielles et le sentiment sur le marché des crypto-monnaies, tandis que les facteurs macroéconomiques peuvent donner un aperçu des conditions économiques plus larges susceptibles d'influencer le comportement des investisseurs. Les prévisions de rendements et de volatilités des modèles d'apprentissage automatique sont intégrées dans le cadre d'optimisation de portefeuille (Black-Litterman, HRP, moyenne-variance avec GARCH). Cette approche permet aux modèles de saisir les relations non linéaires et d'améliorer potentiellement la précision des estimations de risque et de rendement pour les pools GMX.

3. Résultats

Sélection des caractéristiques et évaluation des modèles : La première étape consiste à identifier les facteurs clés qui influencent le rendement généré par un pool de liquidités sur une période donnée. Nous utilisons ensuite des algorithmes d'apprentissage automatique pour prédire ce rendement. Pour sélectionner les modèles les plus performants, nous évaluons leur performance à l'aide de mesures telles que l'erreur quadratique moyenne (EQM). Par exemple, comme le montre le tableau 1 (non inclus ici mais supposé présenter différents modèles et leur EQM), la régression du Gradient Boosting (GBR) apparaît comme le meilleur modèle avec l'EQM la plus faible.

	Model	MAE	MSE	RMSE	R2	RMSLE	MAPE	TT (Sec)
gbr	Gradient Boosting Regressor	9.0839	163.3279	12.7365	0.2155	0.6719	1.5599	5.3167
lightgbm	Light Gradient Boosting Machine	10.3807	206.7613	14.3408	-0.0817	0.7433	1.6515	0.3867
dt	Decision Tree Regressor	10.4390	201.5329	14.1806	-0.0937	0.7579	2.0252	5.7067
rf	Random Forest Regressor	10.3830	199.6089	14.0564	-0.1035	0.7516	1.9241	7.3933
ada	AdaBoost Regressor	10.8749	219.0463	14.6847	-0.1716	0.7886	1.9467	5.6100
xgboost	Extreme Gradient Boosting	10.7274	211.6512	14.3619	-0.2604	0.7714	2.0471	0.6700
lasso	Lasso Regression	12.8397	5331.6909	50.6127	-18.6038	0.8319	2.6455	0.0600
en	Elastic Net	13.2860	6387.9708	54.8236	-22.4407	0.8345	2.6071	0.0567
lar	Least Angle Regression	22.9211	13101.4262	78.3360	-39.5313	0.9564	2.1775	0.1033
lr	Linear Regression	26.2947	43706.4180	174.2071	-145.2548	1.0008	2.7951	0.1067
ridge	Ridge Regression	33.2523	91807.0704	243.7070	-294.4636	1.0356	3.2227	0.0433

Tableau 1 - Comparaison des modèles

Prévision des rendements et construction de portefeuille : En suivant une approche similaire, nous identifions le meilleur modèle pour prédire les rendements des pools de liquidités. En utilisant ces rendements prédits pour les pools GMX, nous pouvons utiliser des algorithmes d'optimisation de portefeuille pour construire différents portefeuilles ajustés au risque. Ce processus nous permet de créer des portefeuilles avec différents profils de risque et de rendement.

Analyse des performances : Le rendement cumulé de ces portefeuilles, rééquilibrés à la fin de chaque mois, est représenté dans les figures 2 et 3. Les portefeuilles sont optimisés en termes de rendement dans la figure 2, et en termes de rendement et de performance dans la figure 3. Comme vous pouvez le constater, le portefeuille présentant le ratio de Sharpe le plus élevé semble surclasser les autres. Ce ratio, qui mesure le rendement ajusté au risque, indique que ce portefeuille offre un meilleur rendement par rapport à son niveau de risque.

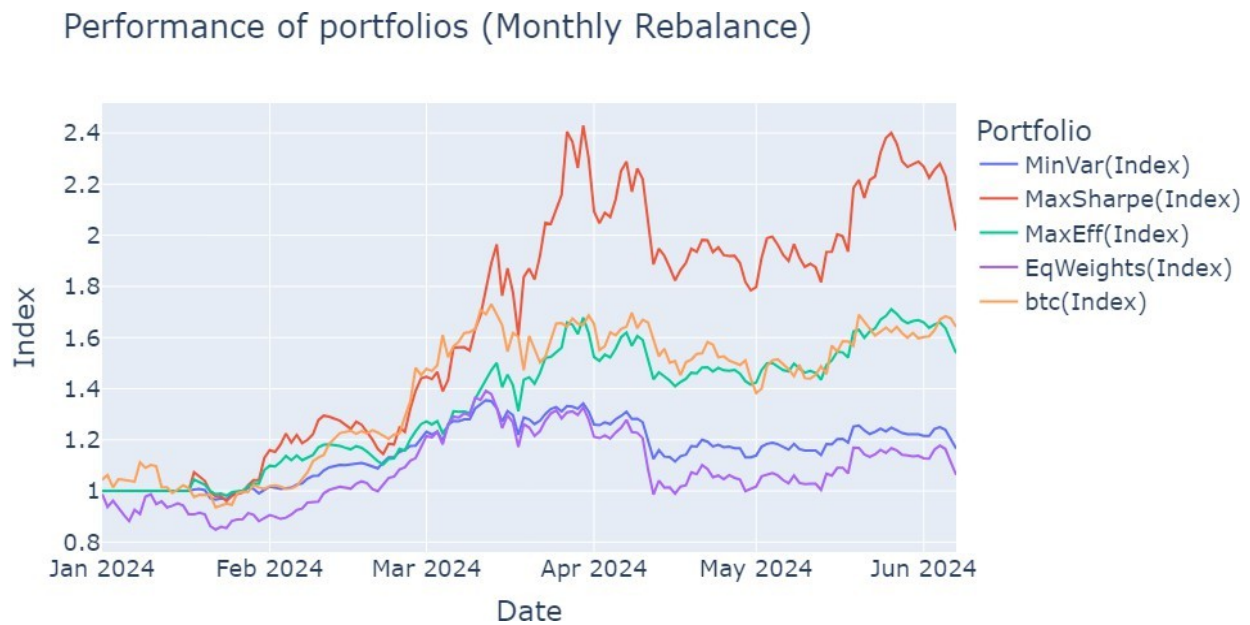


Figure 2 - Performance des portefeuilles (rendement)

Performance of total value (TV) portfolios (Monthly Rebalance)



Figure 3 - Performance de la valeur totale (rendement + prix)

Comparaison avec l'indice de référence : Enfin, pour évaluer l'efficacité de notre portefeuille optimisé, nous comparons sa performance à celle d'un indice de référence, tel que le bitcoin (BTC), comme le montre le tableau 2. Cette comparaison nous aide à comprendre comment notre stratégie se situe par rapport à un investissement couramment utilisé sur le marché des crypto-monnaies.

Mesures de performance	Repère	Stratégie Mozaic
Rendements cumulés	62.36%	101.84%
CAGR%	137.77%	250.85%
Sharpe	2.11	2.29
Smart Sharpe	2.07	2.24
Sortino	3.5	3.89
Abattement maximal	-20.11%	-26.55%
Volatilité (Ann.)	46.06%	63.51%
Pourcentage journalier attendu	0.34%	0.50%
% mensuel attendu	8.41%	12.42%
Critère Kelly	24.39%	-7.31%
Valeur journalière à risque	-4.39%	-6.00%

Tableau 2 - Mesures de performance

Notre analyse révèle des résultats prometteurs pour le portefeuille optimisé par l'apprentissage automatique. Voici un aperçu des principaux résultats :

Rendement quotidien attendu plus élevé : Comparé au rendement quotidien de 0,34 % de l'indice de référence, notre portefeuille affiche un rendement quotidien attendu supérieur de 0,5 %. Cela se traduit par des rendements potentiellement plus élevés au fil du temps.

Des rendements supérieurs ajustés au risque : Le ratio de Sharpe, un indicateur qui prend en compte à la fois les rendements et le risque, est essentiel pour les investisseurs. En atteignant un ratio de Sharpe supérieur à celui de l'indice de référence, notre portefeuille affiche des rendements ajustés au risque supérieurs. Ce résultat implique que pour un niveau de risque donné, notre portefeuille offre une proposition de rendement plus attrayante.

En substance, ces résultats suggèrent que l'optimisation de portefeuille avec des prédictions d'apprentissage automatique a construit un portefeuille avec des rendements potentiellement meilleurs et un profil risque/récompense plus favorable par rapport à l'indice de référence, qui est principalement un pool GMX libellé en bitcoins.

4. Conclusion

Cet article examine l'efficacité des techniques d'apprentissage automatique dans notre cadre d'optimisation de portefeuille. Nous allons au-delà des méthodes traditionnelles telles que l'optimisation de la moyenne-variance en explorant les techniques d'apprentissage automatique qui intègrent les prévisions de rendement dans la construction du portefeuille.

Apprentissage automatique pour la prédiction : Un aspect clé de cette recherche a été l'utilisation de modèles d'apprentissage automatique pour prédire les rendements, les rendements et les volatilités des pools GMX. Ces modèles ont été formés sur des données historiques, englobant des facteurs qui influencent potentiellement le comportement des pools GMX, y compris les prix des crypto-monnaies, les métriques du protocole DeFi et les indicateurs techniques (Li et al., 2019). En capturant des relations complexes dans les données, les modèles d'apprentissage automatique ont généré des prédictions plus précises, s'alignant sur les recherches récentes sur l'efficacité de l'apprentissage automatique pour les prévisions de rendement des crypto-monnaies (Yoon & Baek, 2022).

Intégration de l'apprentissage automatique dans l'optimisation : Les rendements et covariances prédits par les modèles d'apprentissage automatique ont été intégrés de manière transparente dans le cadre d'optimisation du portefeuille. Cela a permis aux modèles de prendre en compte le profil risque-rendement unique des pools GMX, y compris les pertes potentielles impermanentes. En maximisant le

ratio de Sharpe, le processus d'optimisation a identifié le portefeuille offrant le meilleur équilibre entre le risque et le rendement.

Résultats et signification : Nos résultats ont démontré que l'incorporation de pools GMX et l'utilisation de l'apprentissage automatique pour la prédiction du rendement et de la covariance peuvent améliorer de manière significative la performance du portefeuille. Comparé à un portefeuille de référence, le portefeuille optimisé a obtenu un rendement cumulé plus élevé tout en affichant un ratio de Sharpe supérieur. Cela suggère que l'approche basée sur l'apprentissage automatique a capturé efficacement les avantages potentiels des pools GMX, conduisant à une stratégie d'investissement plus robuste et ajustée au risque pour le marché dynamique des crypto-monnaies.

Références

Almeida, J. et Gonçalves, T. (2022). Une revue systématique de la littérature sur la volatilité et la gestion du risque dans l'investissement en crypto-monnaies : Un point de vue méthodologique. *Risques*, 10(5):107.

Chen, Z., Li, C. et Sun, W. (2020). Bitcoin price prediction using machine learning : An approach to sample dimension engineering, *Journal of Computational and Applied Mathematics* 365, 112395.

Holovatiuk, O. (2020). Les crypto-monnaies en tant que classe d'actifs dans l'optimisation de portefeuille. *Central European Economic Journal*, 7(54), 33-55.

Khan, F.U., Khan, F. et Shaikh, P.A. (2023). Forecasting returns volatility of cryptocurrency by applying various deep learning algorithms (Prévision de la volatilité des rendements des crypto-monnaies en appliquant divers algorithmes d'apprentissage profond). *Future Business Journal* 9(25).

Letho, L., Chelwa, G. & Alhassan, A.L. (2022), "Cryptocurrencies and portfolio diversification in an emerging market", *China Finance Review International*, 12(1), 20-50.
<https://www.emerald.com/insight/content/doi/10.1108/CFRI-06-2021-0123/full/html>

Li, F., Li, X. et Wang, S. (2019). Une enquête sur la sécurité des réseaux de crypto-monnaies. *IEEE Communications Surveys & Tutorials*, 21(2), 1289-1313. <https://ieeexplore.ieee.org/document/9996070>

Lorenzo, J. M. et Arroyo, J. M. (2023). Online risk-based portfolio allocation on subsets of crypto assets applying a prototype-based clustering algorithm. *Financial Innovation*, 9(25), 232.

Markowitz, H. M. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77-91.

Poudel, S., Paudyal, R., Cankaya, B., Sterlingsdottir, N., Murphy, M., Pandey, S., Vargas, J. et Poudel, K. (2023). Cryptocurrency price and volatility predictions with machine learning (Prédictions de prix et de volatilité des crypto-monnaies avec l'apprentissage automatique). *Journal of Marketing Analytics*, 11(4), 642-660.

Amirzadeh, R., Nazari, A. et Thiruvady, D. (2022). Application de l'intelligence artificielle aux marchés des crypto-monnaies : A survey. *Algorithms*, 15(11), 428.

Sahu, S., Ochoa Vázquez, J.H., Ramírez, A.F., Kim, J.-M. (2024). Analyse de l'optimisation des portefeuilles sur les marchés des crypto-monnaies : A Comparative Study of Short-Term Investment Strategies Using Hourly Data Approach. *Journal of Risk and Financial Management*, 17(3):125.
<https://doi.org/10.3390/jrfm17030125>

Sharifi, A. M., Khalili Damghani, K., Abdi, F. et Sardar, S. (2022). A hybrid model for predicting bitcoin price using machine learning and metaheuristic algorithms. *Journal of applied research on industrial engineering*, 9(1), 134-150.

Tang, Y., Song, Z., Zhu, Y., Yuan, H., Hou, M., Ji, J., ... & Li, J. (2022). Une étude sur les modèles d'apprentissage automatique pour la prévision des séries temporelles financières. *Neurocomputing*, 512, 363-380.

Wang, X., Zhang, H., Zhang, Y., Wang, M., Song, J., Lai, T. et Khushi, M. (2021). Learning nonstationary time-series with dynamic pattern extractions (Apprentissage de séries temporelles non stationnaires avec des extractions de motifs dynamiques). *IEEE Transactions on Artificial Intelligence*, 3(5), 778-787.

Yoon, S. et Baek, E. C. (2022). A hybrid machine learning model for cryptocurrency return forecasting (Un modèle hybride d'apprentissage automatique pour la prévision des rendements des crypto-monnaies). *Expert Systems with Applications*, 192, 116282.
<https://www.sciencedirect.com/science/article/abs/pii/S2214635022000673>