

# Previsão das movimentações de ativos financeiros usando ensemble learning para implementação de um portfólio descorrelacionado

Gabriel Costa Baptista<sup>1</sup>, Carlos Alberto Rodrigues<sup>1</sup>

<sup>1</sup>Universidade Estadual de Feira de Santana (UEFS)  
Caixa Postal 44036-900 – Feira de Santana, Bahia, Brasil

`gabriel.costa.baptista1@gmail.com, carod@uefs.br`

**Abstract.** *This article explores the application of ensemble learning techniques, including bagging, boosting, stacking, and voting, in trading algorithms designed for a portfolio of uncorrelated assets in the Brazilian futures market. Based on Modern Portfolio Theory (MPT) principles, the research aims to mitigate risks and improve prediction accuracy by applying the walk-forward method to adjust the models to the data continuously. The effectiveness of the predictions is evaluated using traditional metrics, while the performance of the trading strategies is analyzed by considering the integration of the forecasts.*

**Resumo.** *Este artigo explora a aplicação das técnicas de ensemble learning bagging, boosting, stacking e voting, em algoritmos de negociação voltados para um portfólio de ativos descorrelacionados no mercado de futuros brasileiro. Com base nos princípios da Teoria Moderna do Portfólio (TMP), a pesquisa busca mitigar riscos e melhorar a precisão das previsões, aplicando o método walk-forward para ajustar continuamente os modelos aos dados. A eficácia das previsões é avaliada com métricas tradicionais, enquanto o desempenho das estratégias de negociação é analisado considerando a integração das previsões.*

## 1. Introdução

Estudos indicam que investidores que operam por conta própria no mercado de ações tendem a obter resultados inferiores ao índice do mercado, levando muitos a abandonar essa modalidade de investimento [Barber and Odean 2000]. Estratégias de investimentos, sejam elas automáticas ou manuais, estão sujeitas a períodos prolongados de perdas, conhecidos como drawdown ou redução de capital. A diversificação de ativos em um portfólio geralmente contribui para mitigar essas sequências de perdas [Chekhlov et al. 2005].

Na teoria de gestão de risco, a diversificação é uma das principais estratégias para lidar com essa situação. Harry Markowitz, ganhador do Prêmio Nobel de Economia em 1990 por seu trabalho na Teoria Moderna do Portfólio (TMP), propôs a construção de carteiras compostas por diferentes ativos com baixa correlação, de modo que o risco individual seja atenuado pela diversificação. Markowitz também introduziu o conceito de fronteira eficiente, que define a alocação ideal de cada ativo no portfólio [Markowitz 1952]. Essa teoria continua a ser amplamente utilizada pela indústria de fundos para maximizar lucros e minimizar riscos, junto com suas variantes [Golosnoy et al. 2022][Santos and Tessari 2012].

Nos últimos anos, diversos modelos de aprendizado de máquina têm sido empregados para prever os movimentos do mercado [Cavalcante et al. 2016]. Em vez de confiar em um único modelo, a combinação de diferentes modelos, conhecida como ensemble learning, tem se mostrado uma estratégia eficaz. O uso de ensembles permite explorar informações adicionais e alcançar um consenso entre os modelos que compõem o ensemble, resultando em um desempenho geral superior.

Várias técnicas de ensemble têm sido aplicadas para resolver problemas no mercado financeiro. Para entender como essa estratégia vem sendo utilizada, diversos trabalhos foram analisados. Haykin [Haykin 1999] apresenta os fundamentos matemáticos do ensemble, essenciais para a compreensão da teoria. Hastie, Tibshirani e Friedman [Hastie et al. 2009] fornecem uma abordagem teórica detalhada sobre métodos como bagging, random forest e boosting. Por outro lado, Kyriakides e Margaritis [Kyriakides and Margaritis 2019] e Liu [Liu 2019] oferecem uma visão prática do ensemble learning utilizando Python, com exemplos e aplicações no mercado financeiro, além do método walk forward. Sarkar e Natarajan [Sarkar and Natarajan 2019] e Kumar [Kumar 2019] também fornecem guias de implementação do ensemble e aplicação do walk forward em vários algoritmos, embora sem foco específico no mercado financeiro.

Asad [Asad 2015] utiliza Support Vector Machine (SVM), Random Forest e Multiple Layer Perceptron (MLP) para selecionar os índices de ações que comporão um portfólio, tomando a decisão final com base no voto da maioria e, em seguida, utilizando o modelo de aprendizado para definir a alocação do portfólio. Pinsky [Pinsky 2018] desenvolveu um ensemble de vetores, onde o peso do voto de cada portfólio depende da probabilidade de estar correto, demonstrando que o aumento do número de vetores melhora a precisão. Shen et al. [Shen et al. 2019] aplicaram o ensemble bagging para otimizar o portfólio de Kelly, sendo uma abordagem ideal para conjuntos de treino pequenos. Nti et al. [Nti et al. 2020] realizaram uma comparação de métodos de ensemble, concluindo que stacking e blending atingem altas taxas de precisão nas previsões, variando de 90–100% e 85.7–100%, respectivamente, e recomendam o uso dessas técnicas para inovações em previsões no mercado de ações.

Este artigo explora a implementação de técnicas de ensemble learning com o objetivo de realizar negociações baseadas em previsões, em um portfólio composto por ativos desconcorrelacionados. Com base nos princípios da Teoria Moderna do Portfólio (TMP), as correlações entre diversos ativos do mercado de futuros brasileiro foram analisadas, buscando-se aqueles com baixa correlação entre si. O objetivo dessa seleção foi mitigar os riscos associados às estratégias de negociação.

Foram aplicados os algoritmos de ensemble learning bagging, stacking, voting e boosting aos dados históricos dos ativos, utilizando a biblioteca Scikit-learn em Python para prever suas movimentações. Para aumentar a robustez das previsões, adotou-se o método *walk-forward*, que permite que os modelos sejam continuamente atualizados com novos dados, adaptando-se às mudanças do mercado.

A estratégia de negociação foi desenvolvida em duas abordagens: a primeira utiliza apenas indicadores técnicos, sem considerar as previsões geradas pelos modelos de ensemble; a segunda incorpora os indicadores de médias móveis e as previsões geradas pelos modelos de ensemble. A análise dos resultados busca determinar se a inclusão des-

As previsões melhora o desempenho das estratégias em comparação com a abordagem puramente técnica, avaliando a viabilidade da metodologia proposta.

## **2. Descrição dos Dados**

As séries históricas usadas neste estudo foram obtidas através da corretora XP Investimentos, utilizando o sinal disponibilizado para a plataforma Metatrader 5. Assim, extraíram-se séries históricas dos seguintes ativos do mercado de futuros brasileiro: milho (CCM\$N), a taxa média de depósitos interfinanceiros de um dia e que influencia o mercado de juros (DI1\$N), mini-dólar (WDO\$N) e o mini-índice (WIN\$N). O mercado de futuros brasileiro foi escolhido por possuir alta liquidez em seus produtos e baixa corretagem, fazendo com que a entrada e a saída de participantes no mercado necessite ser mais massiva para afetar o valor das cotações. O mercado de futuros também se mostrou interessante na diversidade de ativos ofertados, facilitando obter ativos com baixa correlação e também alavancagem.

Estas séries foram coletadas e utilizadas no time-frame de 15 minutos, cobrindo um período de 40 dias corridos, de 19/09/2023 até 28/10/2023, resultando em 840 candles para o CCM\$N e 1008 candles nos demais ativos. Esta disparidade na quantidade de candles dentro de um mesmo período ocorre devido ao funcionamento do mercado. Assim, alguns ativos são negociados enquanto outros não estão disponíveis, gerando essa diferença.

Para contornar a diferença na quantidade de dados e viabilizar a utilização dos ativos, os registros foram tratados de duas maneiras diferentes: para calcular a correlação entre as séries históricas, os dados que estavam presentes em um ativo, mas ausentes nos outros, foram removidos. E para a realização de backtestes e treinamento dos ensembles, os dados que não estavam presentes em um ativo, mas estavam presentes em outro, foram preenchidos repetindo o dado anterior. Para o ensemble, foram utilizados dados de 40 dias, devido ao custo computacional. Para o cálculo da correlação, que não apresentava essa restrição, foram utilizados dados de 5 anos, de 02/08/2019 a 02/08/2024.

## **3. Métodos de Ensemble Learning e walk-forward**

Ensemble learning é uma técnica de aprendizado de máquina que combina vários modelos de base para formar um modelo mais robusto. O princípio subjacente é que, ao reunir modelos diferentes, suas previsões combinadas podem superar o desempenho de um único modelo, melhorando a precisão e a generalização das previsões. Essa abordagem ajuda a reduzir a variância (overfitting), o viés (underfitting), e a aumentar a estabilidade do modelo.

Neste trabalho, utilizaram-se os métodos stacking, voting, bagging e boosting para a previsão dos retornos. Stacking e voting usam individualmente classificadores treinados (base learners) para o aprendizado, enquanto o bagging faz uso de amostragem (bootstrapping) para o treinamento dos base learners e combina suas previsões usando o voting. A motivação por trás do bagging é produzir diversos base learners através da diversificação dos conjuntos de treinamento. O boosting, por outro lado, constroi sequencialmente os base learners, corrigindo os erros dos modelos anteriores ao dar mais peso aos exemplos mal classificados em cada iteração.

Para validar os modelos de forma eficaz, foi utilizado o método de *walk-forward* (WF), que divide o conjunto de dados em múltiplas janelas temporais. A cada iteração, o modelo é treinado em uma janela de dados passados e, em seguida, testado em uma janela subsequente que contém dados recentes ainda não vistos. Posteriormente, a janela de treinamento é movida para incluir novos dados, e o modelo é ajustado novamente. Esse processo se repete por todo o conjunto de dados, com o modelo sendo continuamente reavaliado e ajustado para refletir as mudanças no comportamento dos ativos financeiros. Dessa forma, foi adotado neste trabalho uma janela móvel de 30 candles em todos os ensembles, com cada candle representando um intervalo de 15 minutos.

No ensemble boosting, foi utilizado o XGBRegressor do pacote XGBoost, configurado com profundidade máxima de 2 (`max_depth=2`), 10 estimadores (`n_estimators=10`) e regularização L1 (`reg_alpha=0.5`). O modelo foi treinado em paralelo com 5 núcleos (`n_jobs=5`), aproveitando a capacidade de processamento simultâneo para otimizar o desempenho.

Em contraste, no ensemble bagging, foi utilizado o BaggingRegressor do scikit-learn. Este ensemble emprega o DecisionTreeRegressor como estimador base, configurado com profundidade máxima de 1 (`max_depth=1`). A combinação dos modelos base é feita por meio de reamostragem (bootstrapping), formando um conjunto de árvores de decisão que melhora a robustez e a generalização.

Enquanto o bagging se baseia em reamostragem, o ensemble stacking adota uma abordagem diferente com o StackingRegressor. Este método combina múltiplos modelos base, incluindo Support Vector Regressor (SVR) e K-Nearest Neighbors (KNN), e utiliza um modelo de Regressão Linear como meta-modelo para aprimorar a precisão das previsões.

Por outro lado, no ensemble voting, foi empregado o VotingRegressor, que também combina múltiplos modelos base, mas com uma estratégia de votação para agregar as previsões. Os modelos base incluídos são Support Vector Regressor (SVR), K-Nearest Neighbors (KNN) e Regressão Linear, promovendo um consenso entre diferentes abordagens para alcançar uma previsão mais precisa.

#### **4. Estratégia de Negociação**

Para analisar os impactos das previsões nas negociações de um ativo, implementou-se uma estratégia de negociação baseada em médias móveis e previsões de preços, com o objetivo de otimizar as operações de compra e venda de ativos financeiros. Utilizaram-se duas médias móveis com períodos de 20 e 200 candles para guiar as decisões de negociação de acordo com as tendências dos preços. A estratégia consiste em abrir uma posição de compra quando o preço do ativo supera tanto a média móvel longa (200 candles) quanto a média móvel média (20 candles), e em abrir uma posição de venda quando o preço fica abaixo dessas médias.

A simulação foi conduzida de duas formas distintas: uma utilizando apenas dados históricos e outra incorporando previsões dos movimentos futuros dos preços. Na primeira abordagem, as decisões de entrada e saída são tomadas exclusivamente com base nas médias móveis calculadas a partir dos dados históricos, permitindo que a estratégia capture tendências estabelecidas. Na segunda abordagem, aplicamos as previsões percentuais do preço futuro, geradas pelo modelo de ensemble em questão, diretamente ao preço

atual. Isso significa que, em vez de usar o preço de fechamento atual para tomar decisões, ajustamos esse preço com a previsão percentual, simulando o valor que o preço poderia alcançar no próximo candle. As decisões de compra e venda são então baseadas nesse preço ajustado, permitindo que a estratégia antecipe movimentos futuros com base nas previsões.

Para gerenciar o risco, foram implementados em ambas as estratégias parâmetros de take profit e stop loss, ambos fixados em 5% em relação ao preço de entrada. Isso significa que uma posição é automaticamente encerrada quando o preço alcança um nível de lucro ou de perda de 5% a partir do preço de entrada. No código, ao abrir uma posição de compra ou venda, o gerenciamento de risco é aplicado continuamente, monitorando o preço atual em comparação com o preço de entrada. Se o preço atinge o nível de take profit, o saldo é ajustado para refletir o lucro e a posição é fechada. Se o preço atinge o nível de stop loss, o saldo é ajustado para refletir a perda e a posição também é fechada.

## 5. Métricas de Avaliação

Nesta seção serão descritas as métricas de avaliação que serão utilizadas para comparar os métodos que utilizam ou não os algoritmos de predição.

### 5.1. Avaliação do ensemble

Para mensurar a performance das predições, foram selecionadas 4 métricas comumente utilizadas para este propósito: erro percentual absoluto médio (MAPE), erro médio absoluto (MAE), erro quadrático médio (MSE) e raiz do erro quadrático médio (RMSE). As notações destas medidas de avaliação são mostradas nas equações 1-4.

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left( \frac{|A_i - P_i|}{|A_i|} \right) \times 100 \quad (1)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n (|A_i - P_i|) \quad (2)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (A_i - P_i)^2 \quad (3)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (A_i - P_i)^2} \quad (4)$$

Onde  $A_i$  e  $P_i$  são os valores reais e previstos para o  $i^{\circ}$  intervalo de 15 minutos e  $n$  é o número total de intervalos de 15 minutos para os quais a previsão é feita.

### 5.2. Avaliação dos algoritmos de negociação

Para mensurar o desempenho ajustado ao risco das estratégias de negociação, foi selecionada a métrica Sharpe Ratio. Essa métrica é comumente utilizada para avaliar a relação

entre o retorno e o risco de um portfólio ou estratégia de investimento. O Sharpe Ratio mede o excesso de retorno obtido em relação a um ativo livre de risco, dividido pela volatilidade do portfólio. A equação para o cálculo é mostrada abaixo:

$$\text{Sharpe Ratio} = \frac{\bar{R}_p - R_f}{\sigma_p} \quad (5)$$

Onde  $\bar{R}_p$  é o retorno médio do portfólio,  $R_f$  é uma taxa de baixo risco como títulos do governo, e  $\sigma_p$  é o desvio padrão (volatilidade) dos retornos do portfólio.

## 6. Validação e Testes

Para avaliar a eficácia das estratégias de negociação, com e sem o uso de previsões, foi realizado um backtest nos dados históricos de todos os ativos do portfólio. Cada ativo foi simulado de forma independente, somando-se os resultados de cada negociação para calcular o rendimento total do portfólio. Além disso, cada simulação foi avaliada utilizando as métricas mencionadas anteriormente, a fim de medir a precisão das previsões e o desempenho dos modelos. O processo foi repetido para cada uma das abordagens de ensemble testadas, permitindo uma comparação clara entre as diferentes estratégias aplicadas.

## 7. Resultados


Nesta seção serão apresentadas informações relativas aos dados obtidos. A subseção 7.1 apresenta a matriz de correlação, utilizada para filtrar quais ativos farão parte do portfólio. Em seguida, a subseção 7.2 traz o desempenho dos modelos de ensemble baseado nas métricas de avaliação. Por fim, a subseção 7.3 apresenta os resultados das estratégias de negociação utilizando ou não os modelos de predição.

### 7.1. Descorrelação entre Ativos

A correlação entre dois ativos, representados por  $x$  e  $y$ , é obtida por meio do cálculo do coeficiente de correlação de Pearson, representado na equação 6. Nesta fórmula,  $r$  representa o coeficiente de correlação, enquanto  $\bar{x}$  e  $\bar{y}$  são as médias aritméticas de cada variável  $x$  e  $y$ , respectivamente. Os valores  $x_i$  e  $y_i$  correspondem aos dados individuais das duas variáveis. Juntos, esses elementos permitem calcular a correlação, indicando a intensidade e a direção da relação linear entre as variáveis.

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (6)$$

A matriz de correlação apresentada (Figura 1) oferece uma visão detalhada das relações lineares entre os ativos selecionados. A correlação varia de -1 a 1, onde valores próximos de 1 representam uma correlação positiva forte, valores próximos de -1 indicam uma correlação negativa forte e por fim, valores próximos de 0 sugerem pouca ou nenhuma correlação entre os ativos.



**Figura 1. Matriz de Correlação Entre Ativos**

Esses resultados demonstram que os ativos escolhidos para o portfólio apresentam graus variados de correlação, buscando sempre se manter próximo de 0. Essa desconexão é benéfica no contexto da TMP de Harry Markowitz, uma vez que a inclusão de ativos menos correlacionados tende a reduzir a volatilidade total do portfólio e a maximizar o retorno ajustado ao risco. Portanto, a seleção dos ativos WIN\$N, WDO\$N, CCM\$N e DI1\$N atende ao objetivo de compor um portfólio diversificado, com potencial para mitigar os riscos de mercado em estratégias de negociação.

## 7.2. Desempenho dos Modelos de Ensemble

O desempenho dos modelos de ensemble foi avaliado com base em métricas citadas anteriormente. Essas métricas foram calculadas para os quatro ativos (CCM\$N, DI1\$N, WDO\$N e WIN\$N) utilizando as quatro técnicas de ensemble learning: boosting, bagging, stacking e voting. As Tabelas 1, 2, 3, 4 resumem os resultados obtidos.

**Tabela 1. Resultados obtidos com o Boosting**

Ativo	MSE	rMSE	MAE	MAPE
CCM\$N	0.01	0.10	0.07	0.11
DI1\$N	0.00	0.02	0.01	0.12
WDO\$N	36.12	6.01	4.37	0.09
WIN\$N	39651.33	199.13	141.58	0.12

**Tabela 2. Resultados obtidos com o Bagging**

Ativo	MSE	rMSE	MAE	MAPE
CCM\$N	0.01	0.12	0.08	0.13
DI1\$N	0.00	0.02	0.01	0.12
WDO\$N	41.57	6.45	4.68	0.09
WIN\$N	48840.19	221.00	151.54	0.13

**Tabela 3. Resultados obtidos com o Stacking**

Ativo	MSE	rMSE	MAE	MAPE
CCM\$N	0.01	0.11	0.07	0.12
DI1\$N	0.00	0.02	0.01	0.12
WDO\$N	40.74	6.38	4.64	0.09
WIN\$N	42903.04	207.13	145.97	0.13

**Tabela 4. Resultados obtidos com o Voting**

Ativo	MSE	rMSE	MAE	MAPE
CCM\$N	0.01	0.12	0.08	0.14
DI1\$N	0.00	0.02	0.01	0.13
WDO\$N	46.72	6.84	5.05	0.10
WIN\$N	47335.21	217.57	160.57	0.14

A análise dos resultados com as técnicas de ensemble mostra desempenho similar entre os modelos, com pequenas variações nas métricas de erro. Embora o boosting tenha se destacado em alguns casos, as diferenças não foram estatisticamente significativas. Isso está de acordo com a literatura, que sugere que modelos de ensemble costumam ter resultados comparáveis em séries temporais financeiras. Os ativos analisados apresentaram variações nas métricas devido a características próprias, como volatilidade e liquidez.

### 7.3. Desempenho das Estratégias de Negociação

A tabela a seguir compara o desempenho das estratégias de trading sem e com os métodos de ensemble para os ativos. A análise dos dados revela que o uso das predições varia pouco os resultados do Sharpe obtido. Sem predição, os métodos de ensemble mostram diferenças de desempenho menores. A construção de uma estratégia que integre predições de maneira eficiente representa um desafio significativo, dado que implica não apenas a seleção do modelo adequado, mas também a interpretação e a incorporação apropriada das predições no processo decisório. A eficácia de tais estratégias pode ser amplamente influenciada pela natureza dos dados coletados, os quais podem apresentar variações que favoreçam o algoritmo utilizado, causando um overfitting.

**Tabela 5. Sharpe Ratio das negociações**

Ativo	Boosting		Bagging		Stacking		Voting	
	Sem Pred.	Com Pred.	Sem Pred.	Com Pred.	Sem Pred.	Com Pred.	Sem Pred.	Com Pred.
CCM\$N	0.17	0.17	-0.55	-0.55	0.17	0.19	0.15	0.13
DI1\$N	0.20	0.14	-2.02	-2.08	0.20	0.17	0.14	0.12
WDO\$N	-0.06	-0.06	-1.51	-1.49	-0.06	-0.06	-0.04	-0.04
WIN\$N	0.01	0.01	-2.30	-2.30	0.01	0.01	-0.16	-0.15

## 8. Conclusão

Este artigo buscou realizar uma análise comparativa de métodos de ensemble bagging, boosting, stacking e voting para previsão dos preços de ativos do mercado de futuros brasileiro. Essas previsões foram utilizadas para implementar um sistema de negociação e comparar seus resultados com mesmo sistema sem a utilização do ensemble.



Os resultados obtidos demonstraram a eficácia dos métodos de ensemble, com alguma vantagem para o boosting. Por outro lado, a comparação dos resultados das negociações demonstra que não houveram vantagens significativas da estratégia que fez uso das previsões do ensemble em relação ao método que utilizou unicamente a análise técnica.

Portanto, em trabalhos futuros, outras estratégias de negociação deverão ser testadas. Estas incluirão a testagem de diferentes timeframes, a inclusão de mais indicadores técnicos tais como RSI (Relative Strength Index), volume das negociações, horários específicos para entrada e saída e o MACD (Moving Average Convergence Divergence) para a captura das divergências nos preços.

## Referências

- Asad, M. (2015). Optimized stock market prediction using ensemble learning. In *9th International Conference on Application of Information and Communication Technologies (AICT)*, Rostov on Don, Russia.
- Barber, B. and Odean, T. (2000). Trading is hazardous to your wealth: the common stock investment performance of individual investors. *SSRN*. <https://ssrn.com/abstract=219228>.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., Nobrega, J. P., and Oliveira, A. L. I. (2016). Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, 55:194–211.
- Chekhlov, A., Uryasev, S., and Zabarankin, M. (2005). Drawdown measure in portfolio optimization. *International Journal of Theoretical and Applied Finance*, 8(1):13–58.
- Golosnoy, V., Gribisch, B., and Seifert, M. (2022). Sample and realized minimum variance portfolios: Estimation, statistical inference, and tests. *Wiley Interdisciplinary Reviews: Computational Statistics*, 14(5):1–18.
- Hastie, T., Tibshirani, R., and Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer.
- Haykin, S. S. (1999). *Neural networks: a comprehensive foundation*. Pearson, 2nd edition.
- Kumar, R. (2019). *Machine learning quick reference: Quick and essential machine learning hacks for training smart data models*. Packt Publishing.
- Kyriakides, G. and Margaritis, K. (2019). *Hands-On Ensemble Learning with Python: Build highly optimized ensemble machine learning models using scikit-learn and Keras*. Packt Publishing.
- Liu, Y. (2019). *Python Machine Learning By Example*. Packt Publishing.
- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1):77–91.
- Nti, I., Adekoya, A., and Weyori, B. (2020). A comprehensive evaluation of ensemble learning for stock-market prediction. *Journal of Big Data*, 7(20):1–40.
- Pinsky, E. (2018). Mathematical foundation for ensemble machine learning and ensemble portfolio analysis. *SSRN*, pages 1–48.

- Santos, A. A. P. and Tessari, C. (2012). Técnicas quantitativas de otimização de carteiras aplicadas ao mercado de ações brasileiro. *Revista Brasileira de Finanças*, 10(3):369–363.
- Sarkar, D. and Natarajan, V. (2019). *Ensemble Machine Learning Cookbook: Over 35 practical recipes to explore ensemble machine learning techniques using Python*. Packt Publishing.
- Shen, W., Wang, B., Pu, J., and Wang, J. (2019). The kelly growth optimal portfolio with ensemble learning. In *The Thirty-Third AAAI Conference on Artificial Intelligence*, pages 1134–1141.