

**EXPECTATIVAS ECONÔMICAS DO MERCADO E RETORNO DE AÇÕES: UMA ANÁLISE DO PODER PREDITIVO COM USO DE MACHINE LEARNING.**

**DANIEL COSTA AIRES**  
FUCAPE BUSINESS SCHOOL

**OLAVO VENTURIM CALDAS**  
FUCAPE BUSINESS SCHOOL

**DANILO**  
FUCAPE BUSINESS SCHOOL

**LUIS GUSTAVO DO LAGO QUINTEIRO**  
UNIVERSIDADE ESTADUAL DE GOIÁS (UEG)

# EXPECTATIVAS ECONÔMICAS DO MERCADO E RETORNO DE AÇÕES: UMA ANÁLISE DO PODER PREDITIVO COM USO DE DE MACHINE LEARNING.

## 1. INTRODUÇÃO

Este trabalho estuda o poder das expectativas econômicas divulgadas pelo Banco Central do Brasil na previsão dos retornos das ações no mercado brasileiro. A “previsão de preços de ações” é um dos tópicos de estudo que mais atrai a atenção e desafia pesquisadores da área de finanças, pois o mercado de ações é um sistema complexo, dinâmico, instável e não linear (Chen & Hao, 2017).

Investidores e gestores de portfólio consideram as expectativas econômicas ao decidir onde alocar seus recursos, pois as expectativas desempenham um papel relevante na precificação de ativos (Evans et al., 2022). Os preços dos ativos financeiros são prospectivos, ou seja, o seu preço corrente depende das expectativas dos investidores sobre os benefícios futuros esperados (Adam & Nagel, 2023).

Estudos seminais destacam o comportamento aleatório do mercado (Fama, 1970) e suscitam a impossibilidade de obtenção de lucros anormais, uma vez que em mercados eficientes, todas as informações existentes são automaticamente incorporadas aos preços. No entanto, a busca por uma previsão eficaz de preços ainda é um tema em evidência na área de gerenciamento de Investimentos (Ma & Wang 2020).

Com o avanço da tecnologia da informação e das técnicas econométricas, as pesquisas recentes sobre este tema, são divididas em duas categorias: a primeira baseada em métodos convencionais, composto por modelos econométricos (Atsalakis & Valavanis, 2010) e a segunda baseada em modelos de Machine Learning construídos com diferentes abordagens e tipos de algoritmos (Atsalakis & Valavanis, 2009).

Muitos autores têm obtido retornos anormais com melhoria a acurácia das previsões e a construção de modelos com maior coeficiente de determinação, utilizando-se de algoritmos de Machine Learning (Abraham et al., 2022).

Pesquisas recentes vêm utilizando o algoritmo Extreme Gradient Boosting - XGBoost (Toocheai & Moeini, 2023) para previsão de preços de ações. Zhang (2022) apresentou metodologia com uso do algoritmo XGBoost que utiliza dados históricos de cotações e indicadores financeiros para previsão de preços futuros com resultados promissores, Yang et al. (2021) encontraram que a técnica XGBoost e LightGBM foram eficazes na previsão de preços de ações quando comparada às Redes Neurais Artificiais e Dezhkam & Manzuri (2023) utilizaram a combinação de XGBoost e transformada de Hilbert-Huang para prever as tendências de mudança no próximo preço de fechamento das ações concluindo que tal técnica pode melhorar a previsão do mercado de ações.

Entretanto, pesquisas anteriores indicam lacuna para incorporação de novos modelos, novas variáveis e informações em futuras na previsão de preços de ações visando melhores previsões e retornos anormais (Chen, Zhang, Mehlawat & Jia, 2021). Assim, justifica-se a utilização de expectativas econômicas de mercado e de algoritmo de Machine Learning no presente estudo.

Neste contexto o objetivo desta pesquisa é responder a seguinte questão de pesquisa: Previsões de retorno de ações do mercado brasileiro construídos com algoritmo de Machine Learning XGBoost treinados com dados de expectativas econômicas, contribuem para previsão de retornos?

Portanto, utilizamos dados históricos diários das cotações, dos indicadores técnicos, dos indicadores fundamentalistas das empresas que compuseram o índice IBRX no primeiro quadrimestre de 2023, período de janeiro a abril, bem como das expectativas econômicas do PIB, do câmbio, do IPCA, do IGPM, e da SELIC Anual divulgada pelo Banco Central do Brasil.

A metodologia utilizada seguiu o framework para previsão de preço de ações

apresentado por Kumbure et al. (2022) com utilização de modelo de inteligência artificial denominado XGBoost.

Os resultados encontrados foram condizentes com a literatura e a adição de das variáveis de expectativas econômicas contribuiu para melhoria dos indicadores R2, EVS e MSE de várias empresas da amostra.

A pesquisa contribui ampliando o conhecimento sobre os impactos das expectativas econômicas nos retornos das ações do mercado brasileiro. Aplica a metodologia do framework proposto por Kumbure et al. (2022) e o algoritmo XGBoost no contexto de dados de empresas do Brasil. Viabiliza contribuição prática para os profissionais do mercado financeiro e investidores no desenvolvimento de metodologias para obtenção de maiores retornos financeiros e oportunidades negociais.

## **2. REFERENCIAL TEÓRICO**

### **2.1 EXPECTATIVAS ECONÔMICAS**

Expectativas econômicas são relevantes para a tomada de decisões de investimentos, segundo Muth (1961), pessoas, empresas e governos formam expectativas econômicas com base no conhecimento do passado e informações existentes no presente e a partir delas tomam suas decisões sobre os preços futuros dos ativos.

Lucas Jr. (1972) enfatizou a importância das expectativas racionais na teoria monetária e como elas afetam a relação entre a oferta monetária e a economia real. Os preços dos ativos são inevitavelmente prospectivos, Adam & Nagel (2023), ou seja, seu preço hoje depende das expectativas dos investidores sobre os seus futuros fluxos de caixa bem como o seu provável preço de venda futuro.

Para compreender o comportamento dos preços dos ativos durante o tempo é necessário entender, segundo esses mesmos autores, como tais expectativas se alteram durante o tempo. Adam & Nagel (2023) afirmam também que a abordagem tradicional é presumir expectativas racionais e por consequência grande parte desta literatura trata sobre prêmio de risco dada a formulação matemática que associa incerteza à riscos associados aos pagamentos futuros.

A teoria da racionalidade de Muth (1961) tornou-se um campo vasto de pesquisas em finanças em previsão de preços de ativos (Miah et al., 2016; Farmer, 2018). Farmer (2018) explorou como as expectativas e a dinâmica econômica influenciam em seus preços analisando os ativos, as taxas de juros e os fundamentos econômicos bem como os impactos dos choques e políticas monetárias. Miah et al. (2016) testaram a racionalidade de expectativas de inflação em 18 países por 10 anos e descobriram que as expectativas são imparciais e eficientes para fontes de informações como preço de petróleo e oferta monetária.

Além das expectativas racionais, há outras linhas de pesquisas que abordam o tema a partir de diferentes perspectivas. A primeira, dessas abordagens, trata as expectativas do ponto de vista dos indivíduos como D'acunto et al. (2019) cuja pesquisa demonstrou que indivíduos com maiores coeficientes de inteligência tendem a ter expectativas mais precisas e consistentes em relação aos indicadores econômicos e Dominitz & Manski (2011) que mediram as expectativas de retorno de ativos de indivíduos em períodos diferente es concluíram que eles processam as informações e formam suas expectativas de modos variados.

Uma segunda linha de pesquisa trata as expectativas frente às incertezas. Kunze et al. (2017) encontraram, que mudanças médias de medidas de incerteza coincidem com períodos de crises financeiras levantando questionamento sobre um possível indicador antecipado dada as relações causais entre medidas de incerteza e indicadores econômicos no Reino Unido e Alemanha.

E a terceira linha trata da análise do sentimento frente às expectativas. Nowzohour & Stracca (2020) por exemplo analisam o papel do sentimento econômico como impulsionador do ciclo de negócios e fazem uma revisão teórica sobre componentes do sentimento, a confiança

e a incerteza em um painel de 27 países. Para Zarnowitz & Lambros (1987) há evidências de que as expectativas de inflação mais alta geram maior incerteza sobre a inflação. Os testes também favorecem a hipótese de que um aumento na incerteza da inflação tem efeitos adversos sobre o crescimento real da economia e consequente desempenho no mercado acionário.

Pesquisadores têm se preocupado também como as expectativas respondem a novas informações, por exemplo, Greenwood & Shleifer (2014) investigaram a relação das expectativas de retornos futuros dos investidores em relação aos retornos efetivamente observados, propondo um modelo de expectativas baseadas em informações disponíveis e dados de retornos e preços históricos, mostrando que as expectativas dos investidores são preditores significativo dos retornos futuros.

O impacto das variáveis econômicas no desempenho de bolsa de valores é amplamente estudado na literatura, Verma e Bansal (2021), em revisão sistemática de literatura estudaram 70 artigos que investigam a relação de variáveis como taxa de juros, taxa de câmbio, PIB e inflação e seus resultados mostram que tais variáveis têm impacto significativo no desempenho da bolsa tanto de países desenvolvidos como em desenvolvimento, mas que variam de forma diferentes. Para estes mesmos autores compreender tais impactos é importante para gestores de fundos, formuladores de políticas públicas, tomadores de decisões de investimentos e para políticas econômicas.

A relação entre retorno de ações e a inflação, bem como a volatilidade do mercado e seus impactos sobre os retornos foi pesquisada por Chiang (2023) e seus resultados indicam impacto significativo negativo evidenciando que a inflação reduz a rentabilidade do mercado acionário. Bouri, Nekhili, Kinatader & Choudhury (2023). Estudaram as expectativas de inflação e os índices setoriais americanos e concluíram que a inflação esperada e os índices setoriais são afetados por diferentes fatores em diferentes períodos de crise.

Os indicadores de PIB, Taxa de Juros e Taxa de Câmbio por sua vez, foram pesquisados por de Pontes e Rêgo (2022). Sua pesquisa abordou a relação entre tais variáveis macroeconômicas e a estrutura topológica do mercado de ações brasileiro concluindo que a estrutura de rede estudada é afetada pelas variáveis macroeconômicas.

No Brasil, aproximadamente 140 agentes do mercado, entre bancos, consultorias, corretoras e distribuidoras de títulos e valores mobiliários que possuem equipes especializadas em prever os futuros valores das principais variáveis econômicas, publicam as suas expectativas para o cenário econômico esperado nos próximos meses e anos, no sistema de expectativas de mercado desenvolvido pelo Banco Central do Brasil (BCB). Este sistema permite que a autarquia consolide e divulgue as estatísticas de expectativas ao público em geral.

Um dos principais produtos deste sistema é o FOCUS – Relatório de Mercado que é divulgado toda segunda-feira às 8 horas e 30 minutos, contendo as expectativas médias, medianas e o desvio padrão das variáveis econômicas, bem como o seu comportamento semanal e mensal. (Departamento de Estatísticas (Dstat), [s.d.]). Como os mercados antecipam eventos econômicos é racional pensar que as expectativas econômicas futuras da Selic, do Câmbio, da previsão do PIB e do Índice de Preços impactam os retornos no presente.

## **2.2 PREVISÃO DE RETORNO DE INVESTIMENTO EM AÇÕES COM USO MACHINE LEARNING**

A previsão do preço das ações é um dos problemas mais estudados e desafiadores, atraindo pesquisadores de muitas áreas, incluindo economia, história, finanças, matemática e ciência da computação (Madge, Bhatt, 2015).

A instabilidade, não linearidade dos dados e a mudança dinâmica de um sistema complexo que é afetado por muitos fatores, tais como políticas econômicas, decisões governamentais, mudança de políticas, performance dos setores, psicologia dos investidores, dentre outras, torna a resolução deste problema uma tarefa desafiadora (Chen, & Hao, 2017).

Nos últimos anos, têm sido desenvolvidas técnicas computacionais que utilizam algoritmos de Machine Learning para auxiliar analistas, investidores e acadêmicos na tomada de decisão de investimentos em ações (Kumar et al., 2021).

Essas técnicas têm de modo geral o objetivo de prever características das ações, como preços (Wu et al., 2022), tendência ou direção do movimento (Ma et al., 2023) e retornos (Chen et al., 2021).

A metodologia convencional de previsão aplicada a séries temporais de ações envolve quatro etapas principais: (i) Coleta e preparação dos dados, (ii) Definição do algoritmo, (iii) Treinamento e (iv) Avaliação das previsões (Gandhmal & Kumar, 2019; Kumar et al., 2021; Kumbure et al., 2022).

No que diz respeito a coleta e preparação de dados, como não há consenso sobre quais variáveis são relevantes para prever o comportamento do mercado acionário (Kumbure et al., 2022) muitos estudos abordam seus métodos de previsão com utilização de variáveis diversas como o uso de indicadores técnicos (Abraham et al., 2022), fundamentalistas (Shen & Shafiq 2020; Ma et al., 2023), econômicos (Zhong & Enke 2017), post de blogs e notícias (Dai, Zhang & Li, 2023), comentários de redes sociais (Weng, Wang, Megahed & Martinez, 2018), (Betzer & Harries, 2022) ou mesmo a combinação entre eles (Bhandari et al., 2022) e também indicam para que em pesquisas futuras sejam incorporadas novas variáveis aos modelos (Dai et al., 2023).

A definição do algoritmo é etapa crucial e amplamente pesquisada sendo que os principais algoritmos utilizados são categorizados como Boosting (Bühlmann & Hothorn, 2007), Redes Neurais Artificiais (Chudziak, 2023), Support Vector Machine (Schölkopf et al., 2000), Árvores de Decisão (Sorensen et al., 2000), Clustering (Jain et al., 1999), Aprendizagem por reforço (Salvador et al., 2020).

Um algoritmo de Machine Learning que tem se destacado na área de previsão de ações é o Extreme Gradient Boosting - XGBoost (Tooehaei & Moeini, 2023). Trata-se de um algoritmo de boosting que utiliza árvores de decisão como base para previsões. Funciona por meio do treinamento iterativo de várias árvores de decisão fracas, que são combinadas em uma árvore forte capaz de fazer previsões mais acuradas. É conhecido por sua capacidade de lidar com grandes conjuntos de dados, sua eficiência computacional e sua habilidade em lidar com dados desbalanceados. Além disso, o XGBoost oferece recursos adicionais, como a importância das variáveis para a previsão, permitindo que os investidores entendam quais fatores são os mais relevantes para o movimento das ações. Esses recursos têm feito do XGBoost uma das escolhas preferidas em muitos estudos recentes de previsão de ações (Kumar et al., 2021; Yun et al., 2021, Zhang, 2022).

Hipótese (H0): As expectativas de mercado para indicadores econômicos ajudam a melhorar os resultados das previsões geradas por algoritmos de Machine Learning que buscam prever o retorno das ações de empresas listadas na B3.

### **3. METODOLOGIA DA PESQUISA**

O objetivo deste trabalho foi testar se as previsões de retorno de ações de empresas participantes do IBRX treinados com algoritmo XGBoost proposto por Chen e Guestrin (2016), produzem previsões de retornos cujas métricas de avaliação de desempenhos são melhores caso as variáveis de input do modelo sejam as expectativas de mercado coletadas e divulgadas pelo BCB.

Para realizar tais previsões, utilizou-se como variáveis dados de cotações, indicadores técnicos, indicadores fundamentalistas e expectativas econômicas do crescimento do PIB trimestral, da taxa SELIC Anual, das variações mensais do PIB e do Cambio divulgados pelo Banco Central do Brasil através do Sistema de Gerenciamento de Expectativas.

A geração das previsões objeto de nossa análise seguiu workflow genérico proposto por

Kumbure et al. (2022) cujas etapas são: Coleta de Dados, pré-processamento, divisão em treino e teste, treinamento do modelo, seleção do modelo de melhor desempenho e previsão dos valores futuros. A implementação tecnológica deste trabalho foi executada com a biblioteca Scikit Learning em linguagem de programação Python (Pedregosa et al., 2011).

### **3.1 FRAMEWORK GENÉRICO PARA PREVISÃO DE AÇÕES COM MACHINE LEARNING**

Inicialmente foram coletadas as variáveis de expectativas econômicas, bem como de indicadores técnicos e fundamentalistas das empresas participantes do índice IBRX no quadrimestre compreendido entre janeiro e abril de 2023 (B3, 2023). As variáveis econômicas foram escolhidas de acordo com o trabalho de Verma e Bansal (2021) e as variáveis contábeis seguiram o estudo de Huang et al. (2012). A coleta das variáveis de expectativas econômicas, foi realizada através de API Python BCB (Freitas, 2021) cujo objetivo é disponibilizar dados do Sistema Gerenciador de Expectativas – SGS – BACEN. Foram utilizados os indicadores Câmbio, IPCA e IGPM do conjunto de expectativas de mercado mensais bem como os indicadores PIB Trimestral e taxa SELIC que se referem às expectativas de mercado trimestral e anuais, respectivamente.

Os dados são organizados de forma que para cada dia após a data de início do estudo sejam obtidas a mediana das expectativas dos próximos 24 meses para a taxa de câmbio BRL/USD, a mediana das expectativas para o PIB do trimestre anterior e para os próximos oito trimestres, a mediana das expectativas de inflação do IGP-M e IPCA, contendo as expectativas tanto do mês anterior quanto as dos próximos 17 meses e as expectativas para a taxa SELIC Anual a ser definida nas próximas 16 reuniões do COPOM.

Após a divulgação do indicador econômico e até a data da divulgação da próxima expectativa os dados dos indicadores passam a ser incorporados aos dados de expectativas de tal modo que as variáveis econômicas são compostas em alguns dias pelos indicadores econômicos e para outros as expectativas dos indicadores econômicos.

Os valores das foram séries temporais foram obtidos com código em python em consulta aos dados publicados no Sistema de Gerenciamento de Séries Temporais do Bacen via API SGS disponível em: <https://pypi.org/project/sgs/>. Para as variáveis de indicadores econômicos da categoria taxa de juros obtivemos nos comunicados Bacen 33.761 de 24/6/2019, 35.834 de 22/6/2020, 37.292 de 18/6/2021 e 38.783 de 20/6/2022 as datas de efetiva divulgação deste indicador para incorporar na série de dados os valores efetivamente divulgados.

Os indicadores fundamentalistas, Book To Market (BTM), Lucro por Ação (LPA) e Preço Vendas (PTS) foram calculados conforme trabalho de Nti et al. (2020) e Sloan (1996) com os dados obtidos no portal dados abertos da Comissão de Valores Mobiliários (CVM).

Os dados contábeis utilizados nos indicadores descritos a seguir foram considerados apenas a partir da data de recebimento das informações contábeis pela CVM disponibilizadas no arquivo CIA Abertas, das demonstrações financeiras padronizadas e trimestrais. As informações anuais e trimestrais foram organizadas de tal forma que evidenciassem os valores referentes à cada trimestre no decorrer do período de estudo.

Os dados históricos de preços das ações (Abertura, fechamento, máximo, mínimo e volume) de cada uma das empresas listadas na Bolsa de Valores do Brasil, é realizada através da biblioteca Yahoo Finance (2021) e os indicadores técnicos são calculados utilizando a biblioteca TA-Lib de acordo com o trabalho de o trabalho de Paiva et al. (2019). Desta forma obtemos os indicadores técnicos relacionados na Tabela 1.

Após coleta dos dados iniciais excluimos da amostra quatro empresas novas que não tinham cotações no período para compor a amostra, bem como sete empresas que passaram por combinações de negócios e conseqüentemente tiveram seus códigos de negociação alterados no período do estudo. Além disso excluimos bancos e instituições financeiras devido à diferença

em seu método contábil que não permite a geração de alguns indicadores fundamentalistas utilizados no estudo bem como empresas que operam com duas classes de ações e com algum dado faltante no período. Tal procedimento resultou em uma amostra de 78 empresas para o estudo.

Para essas empresas da extraímos os dados de preços, calculamos os indicadores técnicos e fundamentalistas conforme descrito anteriormente e assim obtivemos 10.000 observações de indicadores técnicos diários, 1.500 de indicadores fundamentalistas, 2.500 de cotações. Esses dados individualizados por empresa foram adicionados à uma base de dados de expectativas de mercado contendo 3.000 expectativas diárias do PIB Trimestral, 12.000 expectativas diárias para a cotação de fechamento mensal do câmbio, 12.000 expectativas do IGPM mensal, 12.000 expectativas diárias para o IPCA mensal e 6.000 expectativas diárias para a taxa Selic Meta Anual.

De tal forma que obtivemos um total de 45.000 observações de expectativas econômicas coletadas no site do banco central do brasil e 14.000 observações de indicadores técnicos, fundamentalistas e de cotações totalizando 1.092.000 observações únicas de informações das empresas e 45.000 observações referente às expectativas de mercado para os indicadores econômicos.

Os dados utilizados foram submetidos a uma técnica de pré-processamento de dados, que envolveu a limpeza e remoção de informações incompletas ou irrelevantes, com o intuito de reduzir a dimensionalidade dos dados, conforme sugerido por Barak e Modarres (2015).

Dessa forma, os dias em que ocorreram feriados e, conseqüentemente, não havia dados de cotações foram excluídos da amostra, mesmo que houvesse expectativas econômicas para aquele dia.

As cotações, os indicadores técnicos e os indicadores fundamentalistas as informações foram transformadas conforme calculado a seguir:

$$Z = \frac{(X-\mu)}{\sigma} \quad (1)$$

Em que  $Z$  é o vetor transformado dos dados a partir da computação da média ( $\mu$ ) e desvio padrão ( $\sigma$ ) da amostra.

**TABELA 1 – VARIÁVEIS RELATIVAS AOS INDICADORES TÉCNICOS**

Categoria do Indicador	Variável	Código	
Momentum	Média móvel simples de 20 dias	SMA_20	
	Média móvel simples de 50 dias	SMA_50	
	Índice de Força Relativa	RSI	
	Change Momentum Oscillator	CMO	
	Money Flow Index	MFI	
	Percentage Price Oscillator	PPO	
	Rate of Change	ROC	
	Stochastic Oscillator		STOCH_K
			STOCH_D
	Ultimate Oscillator	ULTOSC	
	Parabolic SAR	PARABOLIC_SAR	
	Percentage Price Oscillator	PPO	
	Momentum	MOM	
Tendencia	William %R	WILLR	
	On Balance Volume	OBV	
	Moving Average Convergence Divergence	MACD	
	Aroon		AROON_UP
			ARRON_DOWN,
		AROON_OSC	
Volatilidade	Bandas de Bollinger	BBANDS	
		BBANDS_MIDDLE	

		BBANDS_UPPER
		BBANDS_LOWER
	Momentum	MOM
Força do Movimento	Commodity Channel Index	CCI

Para Kumbure, et al. (2022) como no mercado de ações há o uso de muitas variáveis é comum o uso de análise da relevância das variáveis de entrada dos modelos de forma a utilizar apenas as variáveis mais importantes e assim melhorar a precisão dos modelos, reduzir overfitting, reduzir tempo de processamento e melhorar a interpretabilidade dos dados.

As variáveis que alimentaram cada modelo foram filtradas por técnica estatística denominada Informação Mútua computados pela função *Mutual\_Information\_Regression* da biblioteca Scikit Learning.

Baseada na análise empírica realizada por Bergmeir et al. (2014) que demonstrou robustez da validação cruzada bloqueada em séries temporais financeiras voláteis, foi realizado a divisão dos dados em 6 partes. Os dados de teste contaram com as 50 últimas observações diárias para todas as seis partes dos dados. Os dados de treino por sua vez tiveram a primeira divisão de dados, que se refere às informações diárias datadas entre 02/03/2021 e 16/12/2021, com 200 observações diárias de todas as variáveis e as demais divisões tiveram a adição de 50 novas datas, ficando então por exemplo a última divisão com 450 dados de treino.

A Figura 1 a seguir mostra graficamente a divisão dos dados.

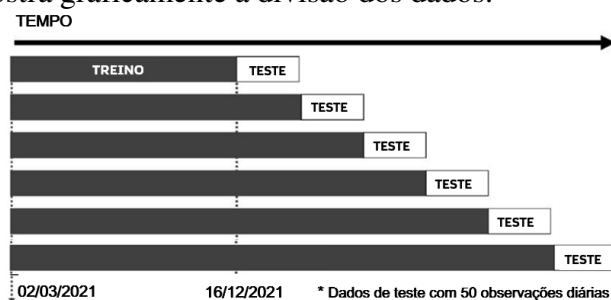


Figura 1 - Representação gráfica da técnica de validação cruzada utilizada.

Para treinamento dos modelos foi desenvolvido código em Python que realiza esta tarefa no intuito de posteriormente prever o retorno diário das ações de cada uma das empresas do estudo.

O retorno diário é calculado pela fórmula:  $\text{Retorno} = (\text{Preço de Fechamento} - \text{Preço de Fechamento}_{-1}) / \text{Preço de Fechamento}$ . O ajuste dos dados ao modelo foi feito pelo algoritmo XGBRegressor da biblioteca XGBoost.

Cada modelo foi treinado então com as variáveis técnicas e fundamentalistas inicialmente e após com a inserção das variáveis de expectativas econômicas do mercado. Resultando em 22 modelos diferentes cujas variáveis de entrada estão descritas na Tabela 2 – Grupos de variáveis utilizadas para construção dos Modelos. Para solucionar este problema de aprendizado supervisionado foi utilizado o XGBoost, onde os múltiplos indicadores técnicos, fundamentalistas e expectativas econômicas, foram utilizados como características de entrada do modelo para prever o retorno das ações.

O código produzido para automatizar a avaliação das 78 empresas objeto deste estudo, lê os dados de um arquivo Excel contendo as informações correspondentes a cada empresa, realiza limpeza e escalonamento dos dados e divide as informações em conjuntos de treinamento e testes conforme descrito na Figura 1. O conjunto de dados de treinamento foi usado para treinar o modelo, e o conjunto de dados de testes usado para avaliar o desempenho do modelo treinado.

O algoritmo de Machine Learning XGBoost, treinou 10.296 bases de dados diferentes compostas cada uma pela combinação de 22 conjunto de variáveis diferentes para cada uma das



seis divisões de dados das empresas selecionadas na amostra. Encontrados os melhores pesos de cada variável após treinamento, é retornado as previsões para os próximos 50 dias úteis. Dados estes que são então utilizadas para a avaliação de métricas de desempenho dos modelos.

**TABELA 2 - GRUPOS DE VARIÁVEIS UTILIZADAS PARA CONSTRUÇÃO DOS MODELOS**

Ord.	Grupo	Variáveis
C1	Padrão	Técnicas
		Fundamentalistas
		Econômicas
C2	Técnicas	Técnicas Cambiais
		Técnicas IGPM
		Técnicas IPCA
		Técnicas Juros
		Técnicas PIB
		Técnicas Econômicas
C3	Fundamentalistas	Fundamentalistas Cambiais
		Fundamentalistas IGPM
		Fundamentalistas IPCA
		Fundamentalistas Juros
		Fundamentalistas PIB
		Fundamentalistas Econômicas
C4	Fundamentalistas e Técnicos	Fundamentalistas Técnicos
		Fundamentalistas Técnicos Cambiais
C5	Fundamentalistas, Técnicos e econômicos	Fundamentalistas Técnicos IGPM
		Fundamentalistas Técnicos IPCA
		Fundamentalistas Técnicos Juros
		Fundamentalistas Técnicos PIB
		Fundamentalistas Técnicos Econômico

### 3.2 AVALIAÇÃO DAS PREVISÕES

A performance dos modelos de previsão propostos foi medida pelo Erro Quadrático Médio (MSE), pelo Erro Absoluto Médio (MAE) pelo Coeficiente de Determinação (R2), pela Taxa de Variação Explicada (EVS) e pelo coeficiente de correlação de Pearson (Correlação) cujas fórmulas estão relacionadas a seguir Yun et al. (2023) e Li et al. (2023).

$$\text{Coeficiente de determinação } R^2 = \mathbf{R}^2(\mathbf{y}, \mathbf{y}') = \mathbf{1} - \frac{\sum_{i=1}^n (\mathbf{y}_i - \mathbf{y}'_i)^2}{\sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})^2} \quad (5)$$

$$\text{Mean Squared Error} = \mathbf{MSE} = \frac{1}{n} \sum_{i=1}^n (\mathbf{y}_i - \mathbf{y}'_i)^2 \quad (6)$$

$$\text{Mae Absolute Error} = \mathbf{MAE} = (1/n) * \sum |\mathbf{y}_i - \mathbf{y}'_i| \quad (7)$$

$$\text{Explained Variation Score} = \mathbf{EVS} = 1 - \text{Var}(\mathbf{y}_i - \mathbf{y}'_i) / \text{Var}(\mathbf{y}_i) \quad (8)$$

$$\text{Coeficiente de Correlação de Pearson} = \mathbf{CORR} = \frac{\sum_{i=1}^n (\mathbf{x}_i - \mathbf{x}'_i)(\mathbf{y}_i - \mathbf{y}'_i)}{\sqrt{\sum_{i=1}^n (\mathbf{x}_i - \mathbf{x}'_i)^2} \sqrt{\sum_{i=1}^n (\mathbf{y}_i - \mathbf{y}'_i)^2}} \quad (9)$$

Em que:  $\mathbf{y}_i$  é o retorno calculado do dia e  $\mathbf{y}'_i$  é o retorno previsto pelo algoritmo XGBoost para o dia  $i$  nas equações 5, 6, 7 e 8 e  $\mathbf{y}'_i$  e  $\mathbf{x}'_i$  são as médias dos valores reais e previstos para a equação 9.

## 4. ANÁLISE DOS DADOS

### 4.1 RESULTADO DAS ESTATÍSTICAS DESCRITIVAS

Na Tabela 3 são apresentadas as estatísticas descritivas do resultado das previsões realizadas para as 78 empresas da amostra classificadas em grupos e subgrupos.

Os resultados mostram que, em média, os modelos técnicos apresentam um R2 mais alto (28,17%) em comparação com os modelos puramente fundamentalistas (12,51%) e puramente econômicos (8,73%). Além disso, os modelos que combinam diferentes abordagens, como fundamentalistas e técnicas, apresentam R2 mais altos em comparação com os modelos que utilizam apenas uma abordagem.

Os modelos que incluem indicadores econômicos, como câmbio, IPCA, juros e PIB, apresentam R2 mais altos em comparação com os modelos que não consideram esses indicadores. No entanto, os modelos que combinam todas as abordagens apresentam um R2 médio de 22,21%, o que sugere que a combinação de diferentes abordagens pode não levar necessariamente a um melhor desempenho do modelo.

A média, o desvio padrão, o mínimo, os quartis, a mediana e os valores máximos dos da variância explicada (EVS) para os diferentes modelos de previsão de retorno de ações nos permite observar que o modelo de análise técnica apresentou os maiores valores médios de EVS, com uma média de 33,15%, seguido pelo grupo de modelos que combinam análise fundamentalista e técnica, com média de 31,37%. Já os modelos baseados apenas em análise fundamentalista apresentaram a menor média de EVS, com 16,85%.

Os modelos com todas as variáveis econômicas têm a menor média, no entanto modelos que combinam variáveis técnicas e indicadores econômicos, em especial PIB e Juros apresentam resultados superiores aos modelos fundamentalistas e técnicos amplamente pesquisados na literatura, sendo que tais médias são estatisticamente diferentes umas das outras.

Os resultados indicam que, em geral, os modelos que utilizam indicadores técnicos apresentam uma maior variância explicada do que os modelos que utilizam indicadores fundamentais e econômicos. Além disso, os modelos que combinam indicadores fundamentais e técnicos apresentam uma variância explicada ainda maior do que os modelos que utilizam apenas um desses tipos de indicadores.

Entre os modelos que utilizam indicadores econômicos, o modelo que utiliza o indicador IPCA apresentou a maior variância explicada, enquanto os modelos que utilizam indicadores de câmbio e PIB apresentaram uma variância explicada menor.

No geral, os modelos que combinam indicadores Técnicos e expectativas econômicas de diferentes tipos (câmbio, juros, PIB, IPCA e IGP-M) apresentam uma variância explicada maior do que os modelos que utilizam apenas um tipo de indicador. Isso sugere que a utilização conjunta de diferentes tipos de indicadores pode melhorar a capacidade de previsão dos modelos.

No que diz respeito à correlação dos valores previstos e os valores reais de retornos podemos abstrair dos dados que além das variáveis técnicas que apresentaram a melhor média de correlação entre os resultados previstos e reais, observamos que o grupo que combinou as variáveis técnicas com as variáveis econômicas obteve os maiores valores máximos. Notavelmente, a combinação de indicadores fundamentalistas com alguns indicadores econômicos, como IGPM, IPCA, Juros e PIB, resultou em previsões com correlações superiores a 90%, o que sugere que esses indicadores podem influenciar diretamente os retornos de diferentes grupos de empresas.

**TABELA 3 - MÉDIAS DAS AVALIAÇÕES DE DESEMPENHO DOS MODELOS**

GRUPO	MODELO	MSE	R2	EVS	MAE	CORRELAÇÃO
<b>Básicas</b>	Fundamentalistas	0,19%	12,51%	16,85%	2,52%	38,25%
	<b>Técnicos</b>	<b>0,13%</b>	<b>28,17%</b>	<b>33,15%</b>	<b>1,90%</b>	<b>62,22%</b>
	Econômicos	0,19%	8,73%	12,21%	2,57%	30,80%
<b>Fundamentalistas e Técnicos (FT)</b>	Fundamentalistas e Técnicos	0,13%	<b>25,92%</b>	31,37%	1,96%	60,89%
<b>Fundamentalistas e Indicadores Econômicos</b>	FT_Cambio	0,13%	25,12%	30,91%	1,98%	60,48%
	FT_Economicos	0,13%	22,30%	28,55%	2,04%	58,55%
	FT_IGPM	0,13%	24,35%	30,84%	1,99%	60,28%
	FT_IPCA	0,14%	23,11%	29,17%	2,03%	59,63%
	FT_JUROS	0,13%	24,90%	30,89%	1,97%	60,49%
	FT_PIB	0,13%	24,37%	30,29%	2,00%	59,99%
<b>Fundamentalistas</b>	FundamentalistasEconomicos*	0,20%	7,39%	11,26%	2,66%	30,70%
	Fundamentalistas_Cambio	0,18%	<b>12,63%</b>	16,84%	2,46%	38,19%
	Fundamentalistas_IGPM*	0,18%	8,95%	13,89%	2,54%	35,77%
	Fundamentalistas_IPCA	0,18%	11,02%	15,54%	2,48%	37,75%
	Fundamentalistas_JUROS*	0,18%	13,30%	17,09%	2,48%	38,54%
	Fundamentalistas_PIB*	0,19%	11,13%	15,85%	2,53%	36,90%
<b>Técnicas</b>	<b>Tecnicas_Cambio</b>	<b>0,13%</b>	<b>26,21%</b>	<b>31,89%</b>	<b>1,94%</b>	<b>61,47%</b>
	Tecnicas_Economicas	0,13%	22,95%	28,90%	2,05%	58,96%
	Tecnicas_IGPM	0,13%	25,18%	30,91%	1,98%	60,74%
	Tecnicas_IPCA	0,13%	24,36%	30,05%	2,00%	60,27%
	<b>Tecnicas_JUROS</b>	<b>0,13%</b>	<b>26,43%</b>	<b>32,49%</b>	<b>1,94%</b>	<b>61,82%</b>
	<b>Tecnicas_PIB</b>	<b>0,13%</b>	<b>26,27%</b>	<b>31,76%</b>	<b>1,95%</b>	<b>61,31%</b>
<b>Fundamentalistas e Técnicas Econômicas</b>	Todos	0,14%	22,21%	28,37%	2,05%	58,57%

#### 4.2 TESTES DE ROBUSTEZ

Foram realizados testes de robustez para garantir a confiabilidade dos resultados. Os testes de diferença de médias (teste t de Student) entre os modelos Fundamentalistas (Modelo A) e modelos com combinações de variáveis técnicas e de expectativas econômicas, baseados no p\_valor ao nível de significância de 0,05 que há evidências estatísticas para rejeitar a hipótese de não existência de diferença de médias para todos os modelos cujo resultado foi “Há diferença de médias”

Os resultados reforçam as evidências encontradas anteriormente indicando que adicionar variáveis técnicas e de expectativas econômicas aos indicadores fundamentalistas aumentam as métricas de desempenho para os indicadores de coeficiente de determinação e variância explicada uma vez que seus valores médios nas demais tabelas são superiores muito embora o melhor indicador seja ainda aquele que utiliza apenas as variáveis técnicas e há evidências de que as médias para estes grupos são diferentes.

O mesmo acontece com os indicadores técnicos e apenas os indicadores fundamentalistas e de expectativas econômicas produzem médias iguais além de piores

resultados quando analisamos as métricas utilizadas neste trabalho.

## **5. CONSIDERAÇÕES FINAIS**

A presente pesquisa buscou avaliar se a inclusão de variáveis de expectativas econômicas melhora a capacidade de previsão de retorno de ações. O estudo combinou variáveis fundamentais, técnicas e de expectativas econômicas para realizar previsões de retornos para 78 empresas da B3, realizou-se uma comparação estatística entre as medidas de avaliação dos modelos com e sem tais variáveis, utilizando o algoritmo de machine learning XGBoost.

O estudo mostrou que, em média, os modelos técnicos apresentam um R2 mais alto em comparação com os modelos puramente fundamentalistas e puramente econômicos, e que a combinação de diferentes abordagens, como fundamentalistas e técnicas, pode levar a resultados melhores do que estes individuais. Os modelos que incluem indicadores econômicos, como câmbio, IPCA, juros e PIB, apresentam R2 mais altos em comparação com os modelos que não consideram esses indicadores.

Os resultados indicam que, em geral, os modelos que utilizam indicadores técnicos apresentam uma maior variância explicada do que os modelos que utilizam indicadores fundamentais e de expectativas econômicos. Os modelos que combinam indicadores fundamentais e técnicos apresentam uma variância explicada ainda maior do que os modelos que utilizam apenas um desses tipos de indicadores. A combinação de indicadores técnicos com indicadores econômicos resultou em previsões com correlações máximas superiores a 90%, sugerindo que esses indicadores podem influenciar diretamente os retornos de diferentes grupos de empresas.

Muito embora para alguns modelos os resultados apresentaram ganhos quando inseridos variáveis de expectativas econômicas, com base nas tabelas apresentadas é possível perceber que os indicadores técnicos constroem modelos cujos indicadores são os melhores. Além disso, é possível verificar que a inclusão de variáveis de expectativas econômicas nos modelos que já utilizam variáveis fundamentais e técnicas não apresentou um impacto significativo nos resultados, como pode ser visto pela comparação entre os valores de correlação obtidos para esses modelos.

Dessa forma, é possível concluir que as variáveis de expectativas econômicas não contribuíram em média para a melhoria dos resultados dos modelos treinados com XGBoost, no entanto para algumas empresas da amostra tal contribuição foi positiva. Essa conclusão pode ser importante para futuros estudos que busquem entender a relação entre variáveis econômicas e a previsão de valores no mercado financeiro.

Foram limitações desta pesquisa os recursos tecnológicos cujo processamento de cada modelo para as 78 empresas foi em média de 178 minutos, o escopo reduzido para as principais variáveis de expectativas divulgadas pelo BCB.

Considerando tais resultados, sugere-se para futuras pesquisas a construção de portfólios de investimentos valendo-se destas previsões como tópico para continuidade desta pesquisa. Também se sugere a comparação com outros algoritmos regressores para verificar efetividade em previsões e a relação entre as variáveis estudadas. Além disso, é importante determinar clusters de empresas baseados em indicadores como endividamento, setor econômico e outras métricas fundamentalistas para melhor ajustar os modelos de modo congruente à sensibilidade de cada empresa aos indicadores.

## **REFERÊNCIAS**

Abraham, R., Samad, M. E., Bakhach, A. M., El-Chaarani, H., Sardouk, A., Nemar, S. E., & Jaber, D. (2022). Forecasting a Stock Trend Using Genetic Algorithm and Random Forest.

- Journal of Risk and Financial Management, 15(5), 188.
- Adam, K., & Nagel, S. (2023). Expectations data in asset pricing. In Handbook of Economic Expectations (pp. 477-506). Academic Press.
- Atsalakis, G. S., & Valavanis, K. P. (2009). Surveying stock market forecasting techniques—Part II: Soft computing methods. *Expert Systems with applications*, 36(3), 5932-5941.
- Atsalakis, G. S., & Valavanis, K. P. (2010). Surveying stock market forecasting techniques—Part I: Conventional methods. *Journal of Computational Optimization in Economics and Finance*, 2(1), 45-92.
- B3 (2023, fevereiro, 6). Índice Brasil 100 (IBrX 100 B3). B3. [https://www.b3.com.br/pt\\_br/market-data-e-indices/indices/indices-amplos/indice-brasil-100-ibrx-100-composicao-da-carteira.htm](https://www.b3.com.br/pt_br/market-data-e-indices/indices/indices-amplos/indice-brasil-100-ibrx-100-composicao-da-carteira.htm)
- Banco Central do Brasil. (s.d.). Perguntas e Respostas sobre Expectativas de Inflação. Banco Central do Brasil - Controle da Inflação. Recuperado em 15 de Outubro de 2022, de <https://www.bcb.gov.br/controleinflacao/faqexpectativa>.
- Barak, S., & Modarres, M. (2015). Developing an approach to evaluate stocks by forecasting effective features with data mining methods. *Expert Systems with Applications*, 42(3), 1325-1339.
- Bergmeir, C., Costantini, M., & Benítez, J. M. (2014). On the usefulness of cross-validation for directional forecast evaluation. *Computational Statistics & Data Analysis*, 76, 132-143.
- Bouri, E., Nekhili, R., Kinatader, H., & Choudhury, T. (2023). Expected inflation and US stock sector indices: A dynamic time-scale tale from inflationary and deflationary crisis periods. *Finance Research Letters*, 103845.
- Bühlmann, P., & Hothorn, T. (2007). Boosting algorithms: Regularization, prediction and model fitting.
- Chang, H. W., Chiang, Y. C., Ke, M. C., Wang, M. H., & Nguyen, T. T. (2023). Market efficiency of Asian stock markets during the financial crisis and non-financial crisis periods. *International Review of Economics & Finance*, 83, 312-329.
- Cheng, C., Xu, W., & Wang, J. (2012, June). A comparison of ensemble methods in financial market prediction. In 2012 Fifth International Joint Conference on Computational Sciences and Optimization (pp. 755-759). IEEE.
- Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining (pp. 785-794).
- Chen, Y., & Hao, Y. (2017). "A feature weighted support vector machine and K-nearest neighbor algorithm for stock market indices prediction." ("A feature weighted support vector machine and K-nearest neighbor ...") *Expert Systems with Applications*, 80, 340-355.
- Chen, W., Zhang, H., Mehlawat, M. K., & Jia, L. (2021). Mean–variance portfolio optimization using machine learning-based stock price prediction. *Applied Soft Computing*, 100, 106943.
- Chiang, W. C., Enke, D., Wu, T., & Wang, R. (2016). An adaptive stock index trading decision support system. *Expert Systems with Applications*, 59, 195-207.
- Chudziak, A. (2023). Predictability of stock returns using neural networks: Elusive in the long term. *Expert Systems with Applications*, 213, 119203.
- Dai, Z., Zhang, X., & Li, T. (2023). Forecasting stock return volatility in data-rich environment: A new powerful predictor. *The North American Journal of Economics and Finance*, 64, 101845.
- D’acunto, F., Hoang, D., Paloviita, M., & Weber, M. (2019). IQ, expectations, and choice (No. w25496). National Bureau of Economic Research.
- Departamento de Estatísticas (Dstat). ([s.d.]). Expectativas de mercado. Recuperado 31 de

- janeiro de 2023, de <https://www.bcb.gov.br/controleinflacao/expectativasmercado>
- de Pontes, L. S., & Rêgo, L. C. (2022). Impact of macroeconomic variables on the topological structure of the Brazilian stock market: A complex network approach. *Physica A: Statistical Mechanics and its Applications*, 604, 127660.
- Dezhkam, A., & Manzuri, M. T. (2023). Forecasting stock market for an efficient portfolio by combining XGBoost and Hilbert–Huang transform. *Engineering Applications of Artificial Intelligence*, 118, 105626
- Dominitz, J., & Manski, C. F. (2011). Measuring and interpreting expectations of equity returns. *Journal of applied econometrics*, 26(3), 352-370.
- Evans, G. W., Hommes, C., McGough, B., & Salle, I. (2022). Are long-horizon expectations (de-) stabilizing? Theory and experiments. *Journal of Monetary Economics*, 132, 44-63.
- Farmer, R. E. (2018). Pricing assets in a perpetual youth model. *Review of Economic Dynamics*, 30, 106-124.
- Freitas, W. (2021). Python-BCB. Retrieved from <https://wilsonfreitas.github.io/python-bcb/>
- Gandhmal, D. P., & Kumar, K. (2019). Systematic analysis and review of stock market prediction techniques. *Computer Science Review*, 34, 100190.
- Greenwood, R., & Shleifer, A. (2014). Expectations of Returns and Expected Returns. *Review of Financial Studies*, 27(3), 714–746. doi:10.1093/rfs/hht082
- Huang, C. F., Chang, B. R., Cheng, D. W., & Chang, C. H. (2012). "Feature Selection and Parameter Optimization of a Fuzzy-based Stock Selection Model Using Genetic Algorithms." ("Feature Selection and Parameter Optimization of a Fuzzy-based Stock ...") *International Journal of Fuzzy Systems*, 14(1).
- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data clustering: a review. *ACM computing surveys (CSUR)*, 31(3), 264-323.
- Kunze, F., Wegener, C., Bizer, K., & Spiwox, M. (2017). Forecasting European interest rates in times of financial crisis—What insights do we get from international survey forecasts?. *Journal of International Financial Markets, Institutions and Money*, 48, 192-205.
- Kumar, G., Jain, S., & Singh, U. P. (2021). Stock market forecasting using computational intelligence: A survey. *Archives of Computational Methods in Engineering*, 28(3), 1069-1101.
- Kumbure, M. M., Lohrmann, C., Luukka, P., & Porras, J. (2022). Machine learning techniques and data for stock market forecasting: a literature review. *Expert Systems with Applications*, 116659.
- Lucas Jr, R. E. (1972). Expectations and the Neutrality of Money. *Journal of economic theory*, 4(2), 103-124.
- Ma, Y., Mao, R., Lin, Q., Wu, P., & Cambria, E. (2023). Multi-source aggregated classification for stock price movement prediction. *Information Fusion*, 91, 515-528.
- Madge, S., & Bhatt, S. (2015). Predicting stock price direction using support vector machines. *Independent work report spring*, 45.
- Miah, F., Rahman, M. S., & Albinali, K. (2016). Rationality of survey based inflation expectations: A study of 18 emerging economies' inflation forecasts. *Research in International Business and Finance*, 36, 158-166.
- Muth, J. F. (1961). Rational expectations and the theory of price movements. *Econometrica: Journal of the Econometric Society*, 315-335.
- Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 53(4), 3007-3057.
- Nowzohour, L., & Stracca, L. (2020). More than a feeling: Confidence, uncertainty, and macroeconomic fluctuations. *Journal of Economic Surveys*, 34(4), 691-726.
- Pedregosa, F., Varoquaux, Ga"el, Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... others.

- (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12(Oct), 2825–2830,
- Salvador, J., Oliveira, J., & Breternitz, M. (2020). Reinforcement learning: A literature review (september 2020). *arXiv*, no. December, 1-36.
- Schölkopf, B., Smola, A. J., Williamson, R. C., & Bartlett, P. L. (2000). New support vector algorithms. *Neural computation*, 12(5), 1207-1245.
- Shen, J., & Shafiq, M. O. (2020). Short-term stock market price trend prediction using a comprehensive deep learning system. *Journal of big Data*, 7(1), 1-33.
- Sloan, R. G. (1996). Do stock prices fully reflect information in accruals and cash flows about future earnings? *Accounting review*, 289-315.
- Sorensen, E. H., Miller, K. L., & Ooi, C. K. (2000). The Decision Tree Approach to Stock Selection. *The Journal of Portfolio Management*, 27(1), 42–52. doi:10.3905/jpm.2000.319781.
- Toochaei, M. R., & Moeini, F. (2023). Evaluating the performance of ensemble classifiers in stock returns prediction using effective features. *Expert Systems with Applications*, 213, 119186.
- Verma, R. K., & Bansal, R. (2021). Impact of macroeconomic variables on the performance of stock exchange: a systematic review. *International Journal of Emerging Markets*.
- Weng, B., Lu, L., Wang, X., Megahed, F. M., & Martinez, W. (2018). Predicting short-term stock prices using ensemble methods and online data sources. *Expert Systems with Applications*, 112, 258-273.
- Yahoo Finance. (2021). Yahoo Finance API. Yahoo! Inc. <https://finance.yahoo.com/>.
- Yang, Y., Wu, Y., Wang, P., & Jiali, X. (2021). Stock price prediction based on xgboost and lightgbm. In *E3S Web of Conferences* (Vol. 275, p. 01040). EDP Sciences.
- Yun, K. K., Yoon, S. W., & Won, D. (2021). Prediction of stock price direction using a hybrid GA-XGBoost algorithm with a three-stage feature engineering process. *Expert Systems with Applications*, 186, 115716.
- Yun, K. K., Yoon, S. W., & Won, D. (2023). Interpretable stock price forecasting model using genetic algorithm-machine learning regressions and best feature subset selection. *Expert Systems with Applications*, 213, 118803.
- Zarnowitz, V., & Lambros, L. A. (1987). Consensus and uncertainty in economic prediction. *Journal of Political economy*, 95(3), 591-621.
- Zhang, Y. (2022, December). Stock Price Prediction Method Based on XGBoost Algorithm. In *2022 International Conference on Bigdata Blockchain and Economy Management (ICBBEM 2022)* (pp. 595-603). Atlantis Press.
- Zhong, X., & Enke, D. (2017). Forecasting daily stock market return using dimensionality reduction. *Expert Systems with Applications*, 67, 126-139.