

FUCAPE PESQUISA E ENSINO S/A

DANIEL COSTA AIRES

**EXPECTATIVAS ECONÔMICAS DO MERCADO E RETORNO DAS
AÇÕES NO BRASIL: uma análise do poder preditivo com uso de
algoritmo de Machine Learning**

**VITÓRIA-ES
2023**

DANIEL COSTA AIRES

**EXPECTATIVAS ECONÔMICAS DO MERCADO E RETORNO DE
AÇÕES: uma análise do poder preditivo com uso de algoritmo de
Machine Learning**

Dissertação apresentada ao Programa de Pós-graduação em Ciências Contábeis e Administração, da Fucape Pesquisa e Ensino S/A, como requisito parcial para obtenção do título de Mestre em Ciências Contábeis e Administração – Nível Profissionalizante.

Orientador: Prof. Dr. Olavo Venturim Caldas

**VITÓRIA-ES
2023**

DANIEL COSTA AIRES

**EXPECTATIVAS ECONÔMICAS DO MERCADO E RETORNO
DAS AÇÕES NO BRASIL: uma análise do poder preditivo com
uso de algoritmo de Machine Learning**

Dissertação apresentada ao Programa de Pós-Graduação em Administração da Fucape Pesquisa e Ensino S/A, como requisito parcial para obtenção do título de Mestre em Administração.

Aprovada em 18 de maio de 2023.

COMISSÃO EXAMINADORA

Prof. Dr. OLAVO VENTURIM CALDAS
Fucape Pesquisa e Ensino S/A

Prof. Dr. DANILO SOARES MONTE-MOR
Fucape Pesquisa e Ensino S/A

Prof. Dr. LUÍS GUSTAVO DO LAGO QUINTEIRO
Universidade Estadual de Goiás

AGRADECIMENTOS

A Deus, pois, a Ele devemos tudo o que somos e tudo o que temos

Aos meus pais (in memoriam) que sempre me fizeram acreditar que tudo é possível.

Aos colegas e professores do curso de Mestrado da FUCAPE, pelo convívio e crescimento em algumas calorosas discussões. A todos os Professores do curso cujas aulas foram inspiração para este trabalho

E principalmente à minha esposa Renata, parceira de vida e de educação cuja presença me motiva a seguir em frente bem como às minhas filhas Luiza e Letícia, motivos de alegria e orgulho.

E nossa história não estará pelo avesso assim,
sem final feliz. Teremos coisas bonitas para contar,
e até lá, vamos viver. Temos muito ainda por fazer,
não olhe para trás, apenas começamos.
O mundo começa agora,
Apenas começamos.

Renato Russo

RESUMO

Prever retorno de ações é um tema amplamente estudado em finanças. A utilização de variáveis de expectativas econômicas pode ser mais uma ferramenta para melhorar as previsões de retorno das ações. Neste contexto o presente estudo avalia o potencial preditivo das variáveis de expectativas econômicas do mercado divulgadas pelo Banco Central do Brasil para a previsão de retornos. O *workflow* apresentado por Kumbure et al. (2022) e o algoritmo de regressão da biblioteca “XGBoost” foram aplicados em uma amostra de 78 empresas participantes do índice IBRX da Bolsa Balcão Brasil (B3), do período de março de 2021 a março de 2023. As expectativas dos indicadores econômicos (SELIC, Cambio, IPCA, IGP-M e PIB Trimestral) foram obtidas no sistema de gerenciamento de Expectativas do Banco Central do Brasil. O software Python com bibliotecas Sklearn, BCB, XGBoost, Numpy, pandas e statsmodels foram utilizadas para extração, tratamento e análise dos dados. Os resultados encontrados foram consistentes com pesquisas anteriores evidenciando que as variáveis de expectativas econômicas, para algumas empresas, contribuem para melhoria das previsões de retorno das ações na bolsa brasileira.

Palavras-chave: Retorno de Ações; Machine Learning; XGBoost; Expectativas Econômicas; B3; Brasil.

ABSTRACT

Forecasting stock returns is a widely studied topic in finance. The use of economic expectations variables can be another tool to improve stock return forecasts. In this context, the present study evaluates the predictive potential of market economic expectations variables published by the Central Bank of Brazil to forecast stock returns. The workflow presented by Kumbure et al. (2022) and the regression algorithm from the "XGBoost" library were applied to a sample of 78 companies participating in the IBRX index of the Bolsa Balcão Brasil (B3), from March 2021 to March 2023. The expectations of the economic indicators (SELIC, Exchange Rate, IPCA, IGP-M and Quarterly GDP) were obtained from the Expectations Management System of the Brazilian Central Bank. Python software with libraries Sklearn, BCB, XGBoost, Numpy, pandas and statsmodels were used for data extraction, processing and analysis. . The results found were consistent with previous research evidencing that economic expectations variables, for selected companies, contribute to improved forecasts of stock returns on the Brazilian stock market.

Keywords: Stock Returns; Machine Learning; XGBoost; Economic Expectations; B3; Brazil.

LISTA DE ILUSTRAÇÕES

Figura 1 - Representação Gráfica da Técnica de Validação Cruzada Utilizada.....	36
Figura 2 - Variação das Expectativas do IpcA	60
Figura 3 - Variação das Expectativas do IgpM	61
Figura 4 - Variação das Expectativas de Câmbio.....	61
Figura 5 - Variação das Expectativas de Selic Meta Anual	62
Figura 6 - Variação das Expectativas de PIB Trimestral	62
Figura 7 - Coeficiente de Correlação - Modelos Treinados com Indicadores Econômicos.....	91
Figura 8 - Coeficiente de Correlação - Modelos Treinados com Indicadores Técnicos	91
Figura 9 - Coeficiente de Correlação - Modelos Treinados com Indicadores Fundamentalistas	92
Figura 10 - Coeficiente de Correlação - Modelos Treinados com Indicadores Fundamentalistas e Econômicos.....	94
Figura 11 - Coeficiente de Correlação - Modelos Treinados com Indicadores F.....	94

LISTA DE TABELAS

TABELA 1 – VARIÁVEIS COM EXPECTATIVAS COLETADAS PELO SISTEMA EXPECTATIVAS DE MERCADO	20
TABELA 2 – VARIÁVEIS DE INDICADORES FUNDAMENTALISTAS.....	30
TABELA 3 – VARIÁVEIS RELATIVAS AOS INDICADORES TÉCNICOS	31
TABELA 4 – CRITÉRIO DE SELEÇÃO DE EMPRESAS PARTICIPANTES DO ESTUDO	32
TABELA 5 - GRUPOS DE VARIÁVEIS UTILIZADAS PARA CONSTRUÇÃO DOS MODELOS	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 6 - MÉDIAS DAS AVALIAÇÕES DE DESEMPENHO DOS MODELOS	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 7 – VARIÁVEIS DE EXPECTATIVAS DO PIB TRIMESTRAL	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 8 - VARIÁVEIS DE EXPECTATIVAS DO CÂMBIO MENSAL	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 9 – VARIÁVEIS DE EXPECTATIVAS DA SELIC ANUAL	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 10 – VARIÁVEIS DE EXPECTATIVAS DO IPCA MENSAL	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 11 – VARIÁVEIS DE EXPECTATIVAS DO IGPM MENSAL.....	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 12 - LISTA DE INDICADORES TÉCNICOS.....	63
TABELA 13 – RELAÇÃO DE EMPRESAS PARTICIPANTES DO ESTUDO .	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 14 - ESTATÍSTICAS DESCRITIVAS – COEFICIENTE DE DETERMINAÇÃO (R ²)	70
TABELA 15 - ESTATÍSTICAS DESCRITIVAS – VARIÂNCIA EXPLICADA	71
TABELA 16 - ESTATÍSTICAS DESCRITIVAS - CORRELAÇÃO ENTRE VALORES REAIS E PREVISTOS	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 17 - ESTATÍSTICAS DESCRITIVAS - ERRO QUADRÁTICO MÉDIO	ERRO! INDICADOR NÃO DEFINIDO.

TABELA 18 - ESTATÍSTICAS DESCRITIVAS - ERRO ABSOLUTO MÉDIO	
.....	ERRO! INDICADOR NÃO DEFINIDO.
TABELA 19 - TESTE-T – MÉTRICA R2	75
TABELA 20 - TESTE-T – MÉTRICA MAEERRO! INDICADOR NÃO DEFINIDO.
TABELA 21 - TESTE-T – MÉTRICA MSEERRO! INDICADOR NÃO DEFINIDO.
TABELA 22 - TESTE-T – MÉTRICA EVSERRO! INDICADOR NÃO DEFINIDO.
TABELA 23 – TESTE-T – MÉTRICA - CORRELAÇÃO	ERRO! INDICADOR NÃO DEFINIDO.

SUMÁRIO

Capítulo 1	11
1 INTRODUÇÃO	11
Capítulo 2	16
2 REFERENCIAL TEÓRICO	16
2.1 EXPECTATIVAS ECONÔMICAS	16
2.2 PREVISÃO DE RETORNO DE INVESTIMENTO EM AÇÕES COM USO MACHINE LEARNING	22
2.2.1 Funcionamento do algoritmo XGBoost	24
Capítulo 3	27
3 METODOLOGIA	27
3.1 FRAMEWORK GENÉRICO PARA PREVISÃO DE AÇÕES COM MACHINE LEARNING	28
3.1.1 Coleta de dados e variáveis	28
3.1.1.1 Variáveis de Expectativas econômicas	28
3.1.1.2 Variáveis de Indicadores Fundamentalistas	29
3.1.2 Empresas Participantes do Estudo	32
3.1.3 Pré-processamento de Dados	33
3.1.3.1 Padronização dos dados	34
3.1.3.2 Seleção de variáveis	34
3.1.3.3 Informação Mútua	34
3.1.4 Divisão dos dados	35
3.1.5 Treinamento do Modelo	36
3.1.6 Previsão dos Valores	37
3.2 AVALIAÇÃO DAS PREVISÕES	39
Capítulo 4	41
4 ANÁLISE DOS RESULTADOS	41
4.1 RESULTADO DAS ESTATÍSTICAS DESCRITIVAS	41
4.2 RESULTADO DOS TESTES DE DIFERENÇA DE MÉDIAS	45
Capítulo 5	47
5 CONCLUSÃO	47
6 REFERENCIAS	50
7 APÊNDICES	58

APÊNDICE A: Variáveis de Expectativas Econômicas	58
A.1 Tabelas de variáveis utilizadas na pesquisa.	58
A.2 Gráficos com Estatística dos dados de expectativas econômicas.....	60
APÊNDICE B: Fórmula de Cálculo dos Indicadores Técnicos	63
APÊNDICE C: Empresas Participantes do Estudo	68
APÊNDICE E: Tabelas de Testes de Diferença de Média dos Modelos de Machine Learning	75

Capítulo 1

1 INTRODUÇÃO

Este trabalho estuda o potencial das expectativas econômicas de mercado divulgadas pelo Banco Central do Brasil em prever o retorno 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, especialmente a previsão de séries temporais, pois o mercado de ações é um sistema complexo, dinâmico, instável e não linear (Chen & Hao, 2017).

Desde a publicação de estudos seminais sobre a hipótese do comportamento aleatório do mercado (Godfrey et al., 1964) que contrariou a previsibilidade de preços e a teoria da hipótese dos mercados eficientes de Fama (1970) que suscitou a impossibilidade de obtenção de lucros anormais, uma vez que em mercados eficientes, todas as informações existentes são automaticamente incorporadas aos preços, muitos estudos exploraram a previsão de preços no mercado acionário e a eficiência de mercado.

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).

Os preços dos ativos financeiros são sempre prospectivos, sendo o seu preço corrente dependente das expectativas dos investidores sobre os benefícios futuros esperados (Adam & Nagel, 2023).

Investidores e gestores de portfólio consideram as expectativas econômicas ao decidir onde alocar seus recursos pois consideram que as expectativas desempenham um papel central na precificação de ativos (Evans et al., 2022).

As pesquisas 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; Abolmakarem et al., 2022).

Os dados do mercado de ações são dinâmicos, não lineares e não parametrizados e são afetados por fatores, macroeconômicos, políticos empresariais, preferencias dos investidores, psicológicos entre outros (Wang et al., 2011) o que torna os algoritmos de Machine Learning eficazes nesta tarefa de previsão já que são preparados para tratar dados desta natureza Santos (2018).

Yang et al. (2019), por exemplo, utilizaram um modelo de seleção de ações a partir de previsões utilizando Extreme Machine Learning com dados técnicos e fundamentalistas do mercado chinês. Concluíram que o modelo proposto é ferramenta eficiente para gerar portfólios lucrativos e sugerem que futuras pesquisas incorporem outros dados relacionados às ações, aplicação do modelo em outros mercados e uso de outras estratégias de seleção de ações.

No Brasil, estudos publicados com o uso de Machine Learning no Mercado de ações são escassos: Gonçalves (2022) analisou cinco ações de empresas do setor bancário utilizando os algoritmos RF e SVM. Torres (2021) pesquisou 11 ações de 5 setores diferentes da Bovespa no intuito de prever o movimento direcional dos preços das ações utilizando indicadores técnicos nas previsões com LSTM (Long Short Term Memory) e GRU (Gate Recorrent Unit).

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 e 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.

O XGBoost é algoritmo de boosting que utiliza árvores de decisão como base e treinamento iterativo de várias árvores de decisão fracas, que são combinadas em uma árvore forte capaz de fazer previsões mais acuradas, lidando com grandes conjuntos de dados desbalanceados e importância das variáveis para a previsão, recursos esses que o diferenciam dos demais algoritmos (Kumar et al., 2021; Yun et al., 2021; Zhang, 2022).

Assim, considerando que pesquisas anteriores indicam lacuna para incorporação de novas variáveis e informações em futuras pesquisas de previsão de

preços de ações visando melhores previsões e assim obter lucros acima dos normais (Nobre & Neves, 2019; Paiva, Cardoso, Hanaoka, & Duarte, 2019; Saini & Sharma, 2019; Misra & Chaurasia, 2020; Chen, Zhang, Mehlawat, & Jia, 2021; Torres, 2021; Du, 2022; Sharma & Shekhawat, 2022) e considerando que previsões feitas com diferentes métodos de aprendizado de máquina tem produzido resultados favoráveis. Entendemos que se justifica pesquisar a relação entre expectativas econômicas de mercado e retornos do mercado de ações utilizando algoritmo de Machine Learning no mercado brasileiro.

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 realização desta pesquisa é relevante e contribui com a literatura acadêmica, pois amplia 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.

Capítulo 2

2 REFERENCIAL TEÓRICO

Este capítulo tem como objetivo apresentar alguns dos estudos recentes relacionados às expectativas econômicas bem como o uso de Machine Learning aplicado à previsão de preços de ações. Discutiremos sobre como as expectativas econômicas influenciam o mercado acionário e como a metodologia genérica de previsão de preços de ações são comumente utilizadas e avaliadas.

Este arcabouço teórico servirá como base para a definição das hipóteses deste estudo, bem como para a fundamentação dos resultados que serão apresentados.

2.1 EXPECTATIVAS ECONÔMICAS

Expectativas econômicas são importantes para a tomada de decisões de investimentos. Para 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.

Atualmente, Investidores e gestores de portfólio levam em consideração as expectativas econômicas ao decidir onde alocar seus recursos uma vez que as expectativas desempenham um papel central na precificação de ativos. Evans et al. (2022).

Os preços dos ativos são inevitavelmente prospectivos, Adam e 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 e 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 proposta por Muth tornou-se um campo vasto de pesquisas em finanças em previsão de preços de ativos como Farmer (2018) que 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 e Manski (2011) que mediram as expectativas de retorno de

ativos de indivíduos em períodos diferentes e 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 e 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 e 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. 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 (2019), 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, Kinateder e 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, demonstradas na Tabela 1, bem como o seu comportamento semanal e mensal. (Departamento de Estatísticas (Dstat), [s.d.]

As variáveis cujas expectativas do mercado são coletadas pelo SGS- Bacen é apresentada na tabela a seguir:

TABELA 1 – VARIÁVEIS COM EXPECTATIVAS COLETADAS PELO SISTEMA EXPECTATIVAS DE MERCADO

Tipo de variável	Variável projetada	Horizontes temporais para cada variável projetada		Tipo de projeção inserida no Sistema		
		Meses	Trim.	Anos	Mensais	Trimestrais/ Anuais
Índice de preços	IPCA e subconjuntos	25		5 [a]	m/m % [b]	a/a % [b]
	IGP-M	18		5 [a]	m/m % [b]	a/a % [b]
Atividade Econômica	Taxa de desocupação	18		5 [a]	%	%
	PIB Total		8	5 [a]		t/t % [c] a/a %
	PIB Agropecuária, PIB Indústria, PIB Serviços, PIB Despesa de consumo das famílias, PIB Despesa de consumo da administração pública, PIB Formação Bruta de Capital Fixo, PIB Exportação de bens e serviços, PIB Importação de bens e serviços				5	
Taxa de Câmbio	<i>Ptax - média do período (R\$/US\$)</i>	24		5 [d]	[e]	[e]
Taxa Selic	<i>Meta - fim do período</i>	16 [f]		5 [d]	% a.a.	% a.a.
	<i>Exportação</i>			5 [g]		US\$ bilhões
	<i>Importação</i>			5 [g]		US\$ bilhões

Balança Comercial	<i>Saldo Comercial</i>			5 [g]		<i>US\$ bilhões</i>
Balço de Pagamentos	<i>Saldo em Transações Correntes</i>			5		<i>US\$ bilhões</i>
	<i>Investimento Direto no País</i>			5		<i>US\$ bilhões</i>
Fiscal	<i>Resultado Primário do Setor Público Consolidado</i>			10		<i>% do PIB</i>
	<i>Resultado Nominal do Setor Público Consolidado</i>			10		<i>% do PIB</i>
	<i>Dívida Bruta do Governo Geral</i>			10		<i>% do PIB</i>
	<i>Dívida Líquida do Setor Público</i>			10		<i>% do PIB</i>

Fonte: Banco Central do Brasil

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; Pandya & Jaliya, 2022).

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 (Cavalcante et al., 2016; Gandhmal & Kumar, 2019; Bustos & Pomares-Quimbaya, 2020; Kumar et al., 2021; 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) e Ensemble (Ganaie et al., 2022).

Um algoritmo de Machine Learning que tem se destacado na área de previsão de ações é o Extreme Gradient Boosting - XGBoost (Toochemae & 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).

2.2.1 Funcionamento do algoritmo XGBoost

Do tutorial XGBoost. (2022), temos que o objetivo do modelo é encontrar os parâmetros θ que melhor se ajustem às variáveis correspondentes. Isso é feito pela função objetivo que é composta por duas partes, a perda de treinamento (2) e o termo de regularização.

$$\text{obj}(\theta) = L(\theta) + \Omega(\theta)$$

(1)

A função perda determinada pela equação a seguir é uma regressão que mede o erro quadrático médio entre valores previstos para o retorno das ações e os valores reais.

$$L(\theta) = \sum_i (y_i - \hat{y}_i)^2$$

(2)

O termo de regularização por sua vez controla a complexidade do modelo evitando um grande ajuste aos dados (Overfitting) e é medido pela equação (3).

$$\lambda * \sum(w_j)^2$$

(3)

Assim aplica-se o hiper parâmetro de regularização lambda a um peso associado à cada variável (j) penalizando pesos maiores e incentivando pesos menores.

As previsões são realizadas a partir da construção de árvores de decisão construídas por modelos de classificação e regressão.

O processo de construção de uma árvore começa com uma única divisão inicial nos dados de treinamento, que é usada para criar duas folhas iniciais na árvore. Em seguida, a cada iteração, o algoritmo verifica se a adição de um novo nó na árvore pode melhorar o desempenho do modelo em relação ao erro quadrático médio, adicionando um nó à árvore, caso haja melhoria na métrica de avaliação.

O processo de construção é repetido até o alcance do critério de parada (hyperparâmetros definidos para o modelo) ou até que a adição de um nó não melhore mais a métrica.

Cada árvore é treinada em diferentes subconjuntos dos dados de indicadores técnicos, fundamentalistas e expectativas econômicas e a soma ponderada pelo peso de cada árvore é usada para prever o retorno das ações.

Matematicamente, podemos representar a previsão do modelo de árvores de gradiente boosting pela fórmula a seguir:

$$y_i = \sum_{k=1}^K f_k(x_i), f_k \in \mathcal{F}$$

(4)

Onde: K é o número de árvores do modelo, f_k é a função no espaço funcional \mathcal{F} e \mathcal{F} é o conjunto de todas as árvores possíveis.

Assim, tem-se que o algorítmico define uma função objetivo e a otimiza com a seguinte fórmula:

$$\text{obj} = \sum_{i=1}^n l(y_i, y_i^{(t)}) + \sum_{i=1}^t \omega(f_i)$$

Assim, com base nos estudos sobre expectativas, e dos algoritmos de aprendizagem de máquina apresentados foi proposta a seguinte hipótese de pesquisa:

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.

Capítulo 3

3 METODOLOGIA

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.

Seguindo minuciosa coleta de dados em diferentes fontes de informações secundárias podemos aplicar modelos estatísticos, econômico-financeiros e métodos de aprendizagem de máquina para chegar a conclusões sobre previsões com diferentes modelos de Machine Learning de tal modo que esta pesquisa se caracteriza como empírica quantitativa, Creswell e Creswell (2021).

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

3.1.1 Coleta de dados e variáveis

O início se deu com a coleta de 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) relacionadas na Tabela 13 – Relação de empresas participantes do estudo.

3.1.1.1 Variáveis de Expectativas econômicas

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.

Utilizamos 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 conforme detalhado na Tabela 8 – Variáveis de Expectativas de Câmbio Mensal, a mediana das expectativas para o PIB do trimestre anterior e para os próximos oito trimestres detalhadas na Tabela 7 – Variáveis de expectativas do PIB Trimestral, a mediana das expectativas de inflação do IGP-M e IPCA conforme

detalhado nas Tabelas 10 e 11 – variáveis de expectativas do IPCA mensal e do IGPM mensal respectivamente, 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 detalhadas na Tabela 9 – Variáveis de expectativas da SELIC anual.

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 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.

3.1.1.2 Variáveis de Indicadores Fundamentalistas

Os indicadores fundamentalistas, demonstrados na Tabela 2 – Variáveis de Indicadores Fundamentalistas, foram calculados conforme trabalho de Barbee et al. (1996), 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.

O indicador Book To Market (BTM) é a divisão entre a cotação diária e o quociente entre patrimônio líquido e quantidade de ações sendo o primeiro obtido no Balanço Patrimonial Passivo conta Patrimônio Líquido, código 2.03, e o segundo é obtido no arquivo Distribuição de Capital do Formulário de Referência, considerando a quantidade total de ações da companhia a partir da data da última assembleia.

O indicador Lucro por Ação (LPA) é calculado pela divisão entre a cotação no fechamento do pregão e o lucro líquido por ação. O lucro líquido é obtido na conta Lucro/Prejuízo, código 3.11 da Demonstração do Resultado do Exercício (DRE) de cada empresa.

O indicador Preço Vendas (PTS) é o resultado do preço de fechamento dividido pela receita operacional por ação, sendo a receita operacional obtida na DRE conta de código 3.01.

TABELA 2 – VARIÁVEIS DE INDICADORES FUNDAMENTALISTAS

Categoria do Indicador	Variável	Código
Valor de Mercado	Book To Market	BTM
	Preço Venda	PTS
	Preço Lucro	PTE

Fonte: Elaborada pelo autor.

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 Paiva et al. (2019). Desta forma obtemos os indicadores técnicos relacionados na Tabela 3 a seguir:

TABELA 3 – VARIÁVEIS RELATIVAS AOS INDICADORES TÉCNICOS

Categoria do Indicador	Variável ¹	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	

¹ O anexo 3 possui todas as fórmulas de cálculo dos indicadores técnicos utilizados

	Momentum	MOM
Força do Movimento	Commodity Channel Index	CCI

Fonte: Elaborada pelo autor.

3.1.2 Empresas Participantes do Estudo

Após coleta dos dados iniciais excluímos 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 excluímos 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.

TABELA 4 – CRITÉRIO DE SELEÇÃO DE EMPRESAS PARTICIPANTES DO ESTUDO

Empresas participantes da carteira teórica	100
Instituições Financeiras (Setor de atividade “Bancos”	7
Emp. Adm. Part. - Seguradoras e Corretoras	1
Intermediação Financeira	1
Emp. Adm. Part. - Intermediação Financeira	1
Empresas com duas classes de ações, excluída a de menor volume	2
Empresas excluídas por terem data de início de negociação posterior à data do início do estudo: AURE3;	1
Empresas que deixaram de ser negociadas na bolsa: BRMLS (fusão com ALSO3)	1
Empresa com dados faltantes em alguns dias do período estudado	8
Total das empresas estudadas	78

Fonte: Elaborada pelo autor.

Assim obtivemos como resultado a lista de 78 empresas demonstradas na Tabela 13 do apêndice C.

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.

3.1.3 Pré-processamento de Dados

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.

3.1.3.1 Padronização dos dados

Para os modelos de Machine Learning, presumimos que cada variável tem igual importância para previsão dos valores desejados, o que exige transformação de escala para que o resultado não fique sobre influenciado (Niño-Adan et al., 2021) por isso utilizamos técnica de normalização para melhor ajustar os dados fornecidos para treinamento pelo XGBoost (Jain et al., 2005).

Assim 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 (μ) e desvio padrão (σ) da amostra.

3.1.3.2 Seleção de variáveis

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 descrita a seguir.

3.1.3.3 Informação Mútua

A informação mútua (MI) é definida como a quantidade de informação que uma variável aleatória tem sobre outra. É calculada pela diferença entre a entropia da característica e a entropia condicional da característica dado o valor da variável de saída. Vergara e Estévez (2014).

$$MI(X;Y) = H(X) - H(X|Y) \quad (2)$$

onde $H(X)$ é a entropia de X e $H(X|Y)$ é a entropia condicional de X dado Y .

Os mesmos autores esclarecem ainda que a entropia é uma medida de incerteza ou aleatoriedade de uma variável aleatória, que indica a quantidade de informação contida em uma distribuição de probabilidade e que a entropia condicional mede a incerteza de uma variável X dado um valor conhecido de outra variável Y qualquer. Sendo a entropia e a entropia condicional calculada da seguinte forma:

$$H(X) = - \sum p(x) * \log(p(x)) \quad (3)$$

$$H(X|Y) = - \sum p(x, y) * \log(p(x|y)) \quad (4)$$

Os cálculos da informação mútua foram computados pela função `Mutual_Information_Regression` da biblioteca Scikit Learning.

3.1.4 Divisão dos dados

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 01 a seguir mostra graficamente a divisão dos dados.

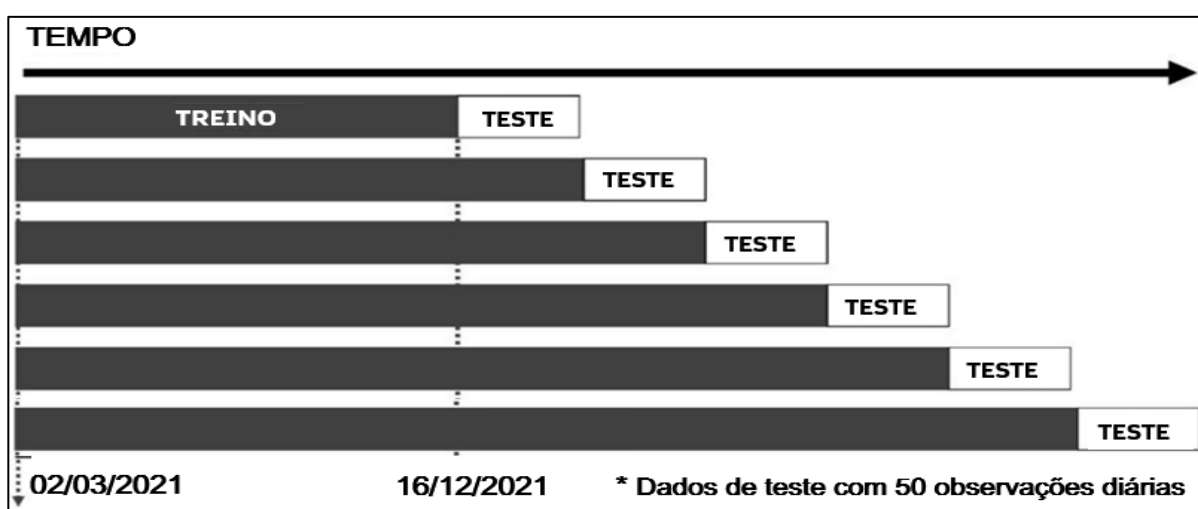


Figura 1 - Representação gráfica da técnica de validação cruzada utilizada.
Fonte: Elaborada pelo autor.

3.1.5 Treinamento do Modelo

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 relacionadas na Tabela 13 do apêndice C.

Para esta pesquisa o retorno diário é calculado pela fórmula a seguir:

$$\text{Retorno} = (\text{Preço de Fechamento}_d - \text{Preço de Fechamento}_{d-1}) / \text{Preço de Fechamento}.$$

Treinar o modelo consiste em encontrar os melhores parâmetros e as melhores variáveis que se ajustem aos dados de treinamento, este procedimento é feito pelo

algoritmo de acordo com metodologia de cálculo descrita no 2.11 – Funcionamento do Algoritmo XGBoost.

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 5 – Grupos de variáveis utilizadas para construção dos Modelos.

3.1.6 Previsão dos Valores

Para solucionar este problema de aprendizado supervisionado foi utilizado o XGBoost, onde os múltiplos indicadores técnicos, fundamentalistas e expectativas econômicas detalhados nas Tabelas 2 (Variáveis de Indicadores Fundamentalistas), 3 (Variáveis de Indicadores técnicos), 7 (Variáveis de Expectativas do PIB Trimestral), 8 (Variáveis de Expectativas do Câmbio Mensal), 9 (Variáveis de Expectativas da SELIC Anual), 10 (Variáveis de Expectativas do IPCA Mensal) e 11 (Variáveis de Expectativas do IGPM – Mensal, 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 seção 3.4.

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.

No que diz respeito à otimização do modelo, foi adotado o uso da função *Mutual_Information_Regression* da biblioteca Scikit Learning que calcula a informação mútua e mantidas apenas as variáveis que têm informação mútua superior à mediana em cada um dos grupos de variáveis.

TABELA 5 - GRUPOS DE VARIÁVEIS UTILIZADAS PARA CONSTRUÇÃO DOS MODELOS

Ord.	Grupo	Variáveis	Tabela Referência
C1	Padrão	Técnicas	3
		Fundamentalistas	2
		Econômicas	7 a 11
C2	Técnicas	Técnicas Cambiais	3 e 8
		Técnicas IGPM	3 e 11
		Técnicas IPCA	3 e 10
		Técnicas Juros	3 e 9
		Técnicas PIB	3 e 7
		Técnicas Econômicas	3 e 7 a 11
C3	Fundamentalistas	Fundamentalistas Cambiais	2 e 8
		Fundamentalistas IGPM	2 e 11
		Fundamentalistas IPCA	2 e 10
		Fundamentalistas Juros	2 e 9
		Fundamentalistas PIB	2 e 7
		Fundamentalistas Econômicas	2 e 7 a 11
C4	Fundamentalistas e Técnicos	Fundamentalistas Técnicos	2 e 3
C5	Fundamentalistas, Técnicos e econômicos	Fundamentalistas Técnicos Cambiais	2,3 e 8
		Fundamentalistas Técnicos IGPM	2,3 e 11
		Fundamentalistas Técnicos IPCA	2,3 e 10
		Fundamentalistas Técnicos Juros	2,3 e 9
		Fundamentalistas Técnicos PIB	2,3 e 7
		Fundamentalistas Técnicos Econômico	2,3 e 7 a 11

Fonte: Elaborada pelo autor.

O algoritmo de Machine Learning XGBoost, treinou então 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 relacionadas na tabela.

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.




Figura 1 – Representação esquemática de exemplo de árvore de decisão
Fonte: Elaborada pelo autor.

3.2 AVALIAÇÃO DAS PREVISÕES

O objetivo deste estudo é avaliar o desempenho dos modelos de previsão de retorno utilizando variáveis técnicas, fundamentalistas e expectativas de mercado de indicadores econômicos, nesta seção discutiremos a eficácia das previsões de cada um dos modelos e compararemos a avaliação do desempenho de algumas métricas comumente usadas em previsões de ações, Jiang (2021).

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).

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

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

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

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

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

Em que: y_i é o retorno calculado do dia e y_i' é o retorno previsto pelo algoritmo XGBoost para o dia i nas equações 5, 6, 7 e 8 e y_i' e x_i' são as médias dos valores reais e previstos para a equação 9.

Capítulo 4

4 ANÁLISE DOS RESULTADOS

4.1 RESULTADO DAS ESTATÍSTICAS DESCRITIVAS

Nesta seção são apresentadas as estatísticas descritivas do resultado das previsões realizadas para as 78 empresas da amostra.

As tabelas numeradas de 13 a 17 apresentam as estatísticas descritivas das métricas R², MAE, MSE, EVS e CORRELAÇÃO, utilizadas na avaliação das previsões realizadas pelo algoritmo XGBoost para as empresas que compunham a amostra desta pesquisa.

Cada uma das tabelas de estatística descritiva apresentam os diferentes grupos de modelos e seus respectivos subgrupos. No grupo básico foram incluídos os modelos que utilizam apenas as variáveis fundamentalistas, ou somente as técnicas, ou somente as econômicas, sem a combinação de qualquer outro indicador.

No grupo Fundamentalistas Técnicos há a combinação das variáveis que representam indicadores fundamentalistas apresentados na Tabela 2 – Variáveis de indicadores fundamentalistas e indicadores técnicos apresentados na Tabela 3 – Variáveis de Indicadores técnicos.

Os demais grupos são a combinação dos indicadores Fundamentalistas, dos Técnicos, bem como a junção desses indicadores com os grupos de variáveis de expectativas econômicas.

Como cada empresa teve seus dados divididos com técnica de divisão de dados em série temporal resultando em 6 partes. Houve 468 observações para cada indicador demonstrado na tabela.

A Tabela 14 apresenta as estatísticas descritivas do coeficiente de determinação (R²) para diferentes grupos de modelos de análise de investimentos. O R² (Equação 2) é uma medida de quão bem o modelo de regressão se ajusta aos dados observados, ou seja, quanto maior o valor do R², melhor é o ajuste do modelo aos dados.

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 Tabela 15 por sua vez, apresenta as estatísticas descritivas da variância explicada pelos diferentes modelos utilizados no estudo. A função `explained_variance_score` mede a proporção da variação dos dados que é explicada pelo modelo independentemente da existência de relação linear entre os dados.

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 apresentados na Tabela 16 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.

As Tabelas 17 e 18 apresentam as estatísticas descritivas da métricas erro quadrático médio e erro absoluto médio respectivamente. Seus dados corroboram com os resultados apresentados nas Tabelas 14 e 15 que apresentam as estatísticas descritivas dos coeficientes de determinação (R2) e a variância explicada, uma vez que são inversamente proporcionais ou sejam, quanto maiores o coeficiente de determinação e a variância explicada menores os erros médios quadráticos e absolutos.

TABELA 6 - MÉDIAS DAS AVALIAÇÕES DE DESEMPENHO DOS MODELOS

GRUPO	MODELO	MSE	R2	EVS	MAE	CORRELAÇÃO
Básicas	Fundamentalistas	0,19%	12,51%	16,85%	2,52%	38,25%
	Técnicos	0,13%	28,17%	33,15%	1,90%	62,22%
	Econômicos	0,19%	8,73%	12,21%	2,57%	30,80%
Fundamentalistas e Técnicos (FT)	Fundamentalistas e Técnicos	0,13%	25,92%	31,37%	1,96%	60,89%
Fundamentalistas e Técnicas e Indicadores Econômicos	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%
Fundamentalistas	FundamentalistasEconomicos*	0,20%	7,39%	11,26%	2,66%	30,70%
	Fundamentalistas_Cambio	0,18%	12,63%	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%
Técnicas	Técnicas_Cambio	0,13%	26,21%	31,89%	1,94%	61,47%
	Técnicas_Economicas	0,13%	22,95%	28,90%	2,05%	58,96%
	Técnicas_IGPM	0,13%	25,18%	30,91%	1,98%	60,74%
	Técnicas_IPCA	0,13%	24,36%	30,05%	2,00%	60,27%
	Técnicas_JUROS	0,13%	26,43%	32,49%	1,94%	61,82%
	Técnicas_PIB	0,13%	26,27%	31,76%	1,95%	61,31%
Fundamentalistas						
Técnicas e Econômicas	Todos	0,14%	22,21%	28,37%	2,05%	58,57%

Fonte: Elaborada pelo autor.

4.2 RESULTADO DOS TESTES DE DIFERENÇA DE MÉDIAS

As Tabelas 18, 19 e 20, mostram os resultados de testes de diferença de médias (teste t de Student) entre os modelos Fundamentalistas (Modelo A) e modelos com combinações de variáveis técnicas e econômicas, em que na coluna resultado é apresentado, baseado 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”

Dos dados apresentados na Tabela 19 – Teste-T para a métrica fortalecemos a ideia apresentada anteriormente que adicionar variáveis técnicas e 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 este grupos são diferentes.

O mesmo acontece com os indicadores técnicos e apenas os indicadores fundamentalistas e econômicos produzem médias iguais além de piores resultados quando analisamos as métricas utilizadas neste trabalho.

Capítulo 5

5 CONCLUSÃO

Em que pese o grande número de pesquisas que se utilizam de algoritmos de Machine Learning para prever preços de ações, está ainda é uma questão em aberto no meio acadêmico e as pesquisas têm produzidos resultados diversos.

A fim de avaliar se a inclusão de variáveis de expectativas econômicas melhora ou piora a capacidade de previsão de retorno de ações estudo avaliou diferentes modelos de análise de investimentos, combinando variáveis fundamentais, técnicas e econômicas para realizar previsões para 78 empresas da B3, realizou-se uma comparação estatística entre as medidas de avaliação dos modelos com e sem tais variáveis.

A amostra de dados de cada empresa foi dividida em seis partes para a técnica de divisão de dados em série temporal, resultando em 468 observações para cada indicador. As tabelas analisadas apresentam as estatísticas descritivas das métricas R2, MAE, MSE, EVS e Correlação para diferentes grupos de modelos e seus subgrupos.

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 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.

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 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.

REFERENCIAS

- 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.
- Abolmakarem, S., Abdi, F., Khalili-Damghani, K., & Didehkhani, H. A Multi-Stage Machine Learning Approach for Stock Price Prediction: Engineered and Derivative Indices.
- 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-amplios/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.
- Barbee Jr, W. C., Mukherji, S., & Raines, G. A. (1996). Do sales—price and debt—equity explain stock returns better than book—market and firm size?. *Financial Analysts Journal*, 52(2), 56-60.
- 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.
- Bruni, R. (2017). Stock market index data and indicators for day trading as a binary classification problem. *Data in brief*, 10, 569-575.

- Bühlmann, P., & Hothorn, T. (2007). Boosting algorithms: Regularization, prediction and model fitting.
- Bustos, O., & Pomares-Quimbaya, A. (2020). Stock market movement forecast: A systematic review. *Expert Systems with Applications*, *156*, 113464.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P., & Oliveira, A. L. (2016). Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, *55*, 194-211.
- 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.
- Chourmouziadis, K., & Chatzoglou, P. D. (2016). An intelligent short term stock trading fuzzy system for assisting investors in portfolio management. *Expert Systems with Applications*, *43*, 298-311.
- Chudziak, A. (2023). Predictability of stock returns using neural networks: Elusive in the long term. *Expert Systems with Applications*, *213*, 119203.
- Creamer, G. (2012). Model calibration and automated trading agent for euro futures. *Quantitative Finance*, *12*(4), 531-545.
- Creswell, J. W., & Creswell, J. D. (2021). *Projeto de pesquisa-: Métodos qualitativo, quantitativo e misto*. Penso Editora.

- 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.
- Dong, X., Li, Y., Rapach, D. E., & Zhou, G. (2022). Anomalies and the expected market return. *The Journal of Finance*, 77(1), 639-681.
- 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.
- Fidelity Digital Asset Services (2023, fevereiro, 16). Chande Momentum Oscillator, Fidelity. <https://www.fidelity.com/learning-center/trading-investing/technical-analysis/technical-indicator-guide/cmo>.
- Fidelity Digital Asset Services (2023, fevereiro, 16). Aroon Indicator, Fidelity. <https://www.fidelity.com/learning-center/trading-investing/technical-analysis/technical-indicator-guide/aroon-indicator>.
- Fidelity Digital Asset Services (2023, fevereiro, 16), Money Flow Index, Fidelity. <https://www.fidelity.com/learning-center/trading-investing/technical-analysis/technical-indicator-guide/MFI>.
- Fidelity Digital Asset Services (2023, fevereiro, 16), On Balance Volume, Fidelity. <https://www.fidelity.com/learning-center/trading-investing/technical-analysis/technical-indicator-guide/OBV>.

- Freitas, W. (2021). Python-BCB. Retrieved from <https://wilsonfreitas.github.io/python-bcb/>
- Ganaie, M. A., Hu, M., Malik, A. K., Tanveer, M., & Suganthan, P. N. (2022). Ensemble deep learning: A review. *Engineering Applications of Artificial Intelligence*, *115*, 105151.
- Gandhmal, D. P., & Kumar, K. (2019). Systematic analysis and review of stock market prediction techniques. *Computer Science Review*, *34*, 100190. <https://doi.org/10.1016/j.cosrev.2019.08.001>.
- Godfrey, M. D., Granger, C. W., & Morgenstern, O. (1964). The Random-Walk Hypothesis of Stock Market Behavior a. *Kyklos*, *17*(1), 1-30. <https://doi.org/10.1111/j.1467-6435.1964.tb02458.x>.
- Gonçalves, G. A. (2022). Comparação de modelos de machine learning para previsão de preço de fechamento de uma ação do setor bancário listada na B3.
- Gorenc Novak, M., & Velušček, D. (2016). Prediction of stock price movement based on daily high prices. *Quantitative Finance*, *16*(5), 793-826.
- Graham, B., Dodd, D. L. F., & Cottle, S. (1934). *Security analysis (Vol. 452)*. New York: McGraw-Hill.
- Greenwood, R., & Shleifer, A. (2014). Expectations of Returns and Expected Returns. *Review of Financial Studies*, *27*(3), 714–746.
- 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.
- Jain, A., Nandakumar, K., & Ross, A. (2005). Score normalization in multimodal biometric systems. *Pattern recognition*, *38*(12), 2270-2285.
- Jiang, W. (2021). Applications of deep learning in stock market prediction: recent progress. *Expert Systems with Applications*, *184*, 115537.
- Kara, Y., Boyacioglu, M. A., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert systems with Applications*, *38*(5), 5311-5319.
- Kunze, F., Wegener, C., Bizer, K., & Spiwoks, 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, R., Kumar, P., & Kumar, Y. (2021, January). Analysis of financial time series forecasting using deep learning model. In 2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence) (pp. 877-881). IEEE.
- 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.
- Misra, P., & Chaurasia, S. (2020). Data-driven trend forecasting in stock market using machine learning techniques. *Journal of Information Technology Research (JITR)*, 13(1), 130-149.
- Morgenstern, G. M. G. C. (1964). The Random Walk Hypothesis of Stock Market Behaviour. *Kyklos*, 17, 1-30.
- Muth, J. F. (1961). Rational expectations and the theory of price movements. *Econometrica: Journal of the Econometric Society*, 315-335.
- Niño-Adan, I., Manjarres, D., Landa-Torres, I., & Portillo, E. (2021). Feature weighting methods: A review. *Expert Systems with Applications*, 184, 115424.
- 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.
- Nobre, J., & Neves, R. F. (2019). "Combining principal component analysis, discrete wavelet transform and XGBoost to trade in the financial markets. *Expert Systems with Applications*, 125, 181-194.

- Nowzohour, L., & Stracca, L. (2020). More than a feeling: Confidence, uncertainty, and macroeconomic fluctuations. *Journal of Economic Surveys*, 34(4), 691-726.
- Pandya, J. B., & Jaliya, U. K. (2022). An empirical study on the various stock market prediction methods. Register: *Jurnal Ilmiah Teknologi Sistem Informasi*, 8(1), 58-80.
- Paiva, F. D., Cardoso, R. T. N., Hanaoka, G. P., & Duarte, W. M. (2019). "Decision-making for financial trading: A fusion approach of machine learning and portfolio selection." ("Decision-making for financial trading: A fusion approach of machine ...") *Expert Systems with Applications*, 115, 635-655.
- Patel, J., Shah, S., Thakkar, P., & Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert systems with applications*, 42(1), 259-268.
- 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
- Saini, A., & Sharma, A. (2019). Predicting the unpredictable: an application of machine learning algorithms in Indian stock market. *Annals of Data Science*, 1-9.
- Salvador, J., Oliveira, J., & Breternitz, M. (2020). Reinforcement learning: A literature review (september 2020). arXiv, no. December, 1-36.
- Santos, H. G. D. (2018). Comparação da performance de algoritmos de machine learning para a análise preditiva em saúde pública e medicina, Tese de Doutorado, Universidade de São Paulo.
- Schölkopf, B., Smola, A. J., Williamson, R. C., & Bartlett, P. L. (2000). New support vector algorithms. *Neural computation*, 12(5), 1207-1245.
- Sharma, M., & Shekhawat, H. S. (2022). Portfolio optimization and return prediction by integrating modified deep belief network and recurrent neural network. *Knowledge-Based Systems*, 109024.
- 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. <https://www.jstor.org/stable/248290>.
- 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.
- Statsmodels. (2021). Statsmodels: Econometric and statistical modeling with Python. Retrieved from <https://www.statsmodels.org/stable/index.html>

- Ticknor, J. L. (2013). A Bayesian regularized artificial neural network for stock market forecasting. *Expert systems with applications*, 40(14), 5501-5506.
- 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.
- Torres, S. (2021). Previsão do preço de ações brasileiras utilizando redes neurais artificiais.
- Vergara, J. R., & Estévez, P. A. (2014). A review of feature selection methods based on mutual information. *Neural computing and applications*, 24, 175-186.
- 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.
- Wu, S., Liu, Y., Zou, Z., & Weng, T. H. (2022). S_I_LSTM: stock price prediction based on multiple data sources and sentiment analysis. *Connection Science*, 34(1), 44-62.
- Yahoo Finance. (2021). Yahoo Finance API. Yahoo! Inc. <https://finance.yahoo.com/>
- Yang, F., Chen, Z., Li, J., & Tang, L. (2019). A novel hybrid stock selection method with stock prediction. *Applied Soft Computing*, 80, 820-831.
- Yang, Y., Wu, Y., Wang, P., & Jiali, X. (2021). Stock price prediction based on xgboost and lightgbm. In *E3S Web of Conferences*, 275, 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..

APÊNDICES

APÊNDICE A: Variáveis de Expectativas Econômicas

A.1 Tabelas de variáveis utilizadas na pesquisa.

TABELA 7 – VARIÁVEIS DE EXPECTATIVAS DO PIB TRIMESTRAL

Categoria Econômica	Variáveis	
Crescimento Econômico	PIB_Trimestre_Anterior	PIB_Trimestre3
	PIB_Trimestre1	PIB_Trimestre4
	PIB_Trimestre2	PIB_Trimestre5

Fonte: Elaborada pelo autor.

TABELA 8 - VARIÁVEIS DE EXPECTATIVAS DO CÂMBIO MENSAL

Categoria Econômica	Variáveis	
Cambial	Câmbio Mês 1	Câmbio Mês 13
	Câmbio Mês 2	Câmbio Mês 14
	Câmbio Mês 3	Câmbio Mês 15
	Câmbio Mês 4	Câmbio Mês 16
	Câmbio Mês 5	Câmbio Mês 17
	Câmbio Mês 6	Câmbio Mês 18
	Câmbio Mês 7	Câmbio Mês 19
	Câmbio Mês 8	Câmbio Mês 20
	Câmbio Mês 9	Câmbio Mês 21
	Câmbio Mês 10	Câmbio Mês 22
	Câmbio Mês 11	Câmbio Mês 23
	Câmbio Mês 12	Câmbio Mês 24

Fonte: Elaborada pelo autor.

TABELA 9 – VARIÁVEIS DE EXPECTATIVAS DA SELIC ANUAL

Categoria Econômica	Variáveis	
Taxa de Juros	R1	R7
	R2	R8
	R3	R9
	R4	R10
	R5	R11
	R6	R12

Fonte: Elaborada pelo autor.

TABELA 10 – VARIÁVEIS DE EXPECTATIVAS DO IPCA MENSAL

Categoria Econômica	Variáveis	
Índices de Preços	IPCA Mês 1	IPCA Mês 13
	IPCA Mês 2	IPCA Mês 14
	IPCA Mês 3	IPCA Mês 15
	IPCA Mês 4	IPCA Mês 16
	IPCA Mês 5	IPCA Mês 17
	IPCA Mês 6	IPCA Mês 18
	IPCA Mês 7	IPCA Mês 19
	IPCA Mês 8	IPCA Mês 20
	IPCA Mês 9	IPCA Mês 21
	IPCA Mês 10	IPCA Mês 22
	IPCA Mês 11	IPCA Mês 23
	IPCA Mês 12	IPCA Mês 24

Fonte: Elaborada pelo autor.

TABELA 11 – VARIÁVEIS DE EXPECTATIVAS DO IGPM MENSAL

Categoria Econômica	Variáveis	
Índices de Preços	IGPM Mês 1	IGPM Mês 13
	IGPM Mês 2	IGPM Mês 14
	IGPM Mês 3	IGPM Mês 15
	IGPM Mês 4	IGPM Mês 16
	IGPM Mês 5	IGPM Mês 17
	IGPM Mês 6	IGPM Mês 18
	IGPM Mês 7	IGPM Mês 19
	IGPM Mês 8	IGPM Mês 20
	IGPM Mês 9	IGPM Mês 21
	IGPM Mês 10	IGPM Mês 22
	IGPM Mês 11	IGPM Mês 23

Fonte: Elaborada pelo autor.

A.2 Gráficos com Estatística dos dados de expectativas econômicas.




Figura 2 - Variação das Expectativas do IPCA

Fonte: Elaborada pelo autor.




Figura 3 - Variação das Expectativas do IGPM
 Fonte: Elaborada pelo autor.




Figura 4 - Variação das Expectativas de Câmbio
 Fonte: Elaborada pelo autor.




Figura 5 - Variação das Expectativas de Selic Meta Anual
Fonte: Elaborada pelo autor.




Figura 6 - Variação das Expectativas de PIB Trimestra
Fonte: Elaborada pelo autor.

APÊNDICE B: Fórmula de Cálculo dos Indicadores Técnicos

Considerando o preço de fechamento para cada dia do estudo os seguintes indicadores técnicos descritos na Tabela 21 foram calculados.

TABELA 12 - LISTA DE INDICADORES TÉCNICOS

INDICADOR	DESCRIÇÃO	FÓRMULA DE CÁLCULO	FONTE
Relative Straigh Index (RSI)	Indicador de momentum que mede a velocidade e a mudança dos movimentos dos preços	$100 - [100 / (1 + RS)]$ onde RS é a proporção média de ganhos em dias positivos para a proporção média de perdas em dias negativos durante o período de cálculo	Ticknor (2013)
Média móvel simples	Média aritmética dos preços de fechamento dos últimos N dias de negociação	$SMA_{20} = (P1 + P2 + \dots + P20) / 20$, onde P1 a P20 são os preços de fechamento dos últimos 20 dias. E; $SMA_{50} = (P1 + P2 + \dots + P50) / 50$ onde P1 a P50 são os preços de fechamento dos últimos 50 dias.	Creamer (2012).
William %R (WILLR)	indicador de momentum que mede o nível atual do preço em relação aos altos e baixos dos últimos períodos	$[(Hn - C) / (Hn - Ln)] * (-100)$ onde C é o preço de fechamento mais recente, Hn é o preço mais alto nos últimos n períodos e Ln é o preço mais baixo nos últimos n períodos	Ticknor (2013)
Moving Average Convergence Divergence (MACD)	indicador de tendência que usa duas médias móveis exponenciais (uma curta e outra	$EMA(12) - EMA(26)$ onde EMA (12) é a média móvel exponencial de 12 dias e	Creamer (2012).

	longa) para indicar uma possível mudança de tendência	EMA (26) é a média móvel exponencial de 26 dias.	
Bandas de Bollinger (BBANDS)	indicador de volatilidade que consiste em três bandas (superior, média e inferior) que são desenhadas em torno da média móvel de um preço	(BBANDS_MIDDLE) = SMA(n); Banda superior (BBANDS_UPPER) = BBANDS_MIDDLE + (k * Desvio padrão(n)); Banda inferior (BBANDS_LOWER) = BBANDS_MIDDLE - (k * Desvio padrão(n)) onde n é o número de períodos usados no cálculo da média móvel e do desvio padrão (20 dias) e k é o número de desvios padrão que determinam a distância das bandas em relação à média móvel (2 desvios padrão).	Creamer (2012).
Aroon (ARON_DOWN, AROON_UP, AROON_OSC)	é um conjunto de três indicadores que medem a força e a direção de uma tendência.	100 x (número de períodos - número de períodos desde o mínimo mais recente) / número de períodos. O Aroon Oscillator é a diferença entre o Aroon Up e o Aroon Down.	Fidelity (2023)
Commodity Channel Index (CCI)	mede a força dos compradores em relação aos vendedores	(Preço típico - SMA(n)) / (0.015 * Desvio padrão(n)) onde Preço típico = (Preço máximo + Preço mínimo + Preço de fechamento) / 3, n é o número de períodos usados no cálculo (geralmente 20 dias).	Patel et al. (2015) Gorenc e Velušček (2016)

Change Momentum Oscillator (CMO)	mede a variação do preço em relação à sua média.	$CMO = ((SM - LM) / (SM + LM)) * 100$ Onde: SM = soma dos últimos n períodos de mudanças positivas de preço LM = soma dos últimos n períodos de mudanças negativas de preço	Fidelity (2023)
Money Flow Index (MFI)	mede o fluxo de dinheiro para um determinado ativo considerando o preço e o volume para calcular o fluxo de dinheiro positivo e negativo e assim calcular um índice de fluxo de dinheiro.	$MF = \text{Fluxo de Dinheiro (Money Flow)} = \frac{[(\text{preço típico} - \text{preço típico anterior}) \times \text{volume}]}{[(\text{preço típico anterior} - \text{preço típico}) \times \text{volume}]}$ Para obter o preço típico, é necessário usar a seguinte fórmula: $\text{Preço Típico} = \frac{(\text{Preço de Fechamento} + \text{Preço Máximo} + \text{Preço Mínimo})}{3}$	Fidelity (2023)
Percentage Price Oscillator (PPO)	Indicador de momentum que compara duas médias móveis exponenciais	$PPO = \frac{(MME12 - MME26)}{MME26} * 100$ Onde: MME12 = Média Móvel Exponencial de 12 períodos MME26 = Média Móvel Exponencial de 26 períodos	Chiang, Enke, & Wang (2016)
Rate of Change (ROC)	indicador de momentum que mede a taxa de mudança percentual no preço de um ativo ao longo do tempo	$ROC = \frac{[(\text{preço atual} - \text{preço } n \text{ períodos atrás}) / \text{preço } n \text{ períodos atrás}] * 100}$	Creamer (2012).

Stochastic Oscillator (STOCH_K, STOCH_D)	indicador de momentum que compara o preço atual de um ativo com sua faixa de preço ao longo de um determinado período	$STOCH_K = [(preço\ atual - menor\ preço\ dos\ últimos\ n\ períodos) / (maior\ preço\ dos\ últimos\ n\ períodos - menor\ preço\ dos\ últimos\ n\ períodos)] * 100$ $STOCH_D = Média\ Móvel\ Simples\ de\ x\ períodos\ de\ STOCH_K$	Ticknor (2013)
Ultimate Oscillator (ULTOSC)	indicador de momentum que usa três diferentes médias móveis ponderadas para calcular o momentum	$ULTOSC = [(4 * SMA7 + 2 * SMA14 + SMA28) / (4 + 2 + 1)] * 100$ Onde: SMA7 = Média Móvel Simples de 7 períodos SMA14 = Média Móvel Simples de 14 períodos SMA28 = Média Móvel Simples de 28 períodos;	Bruni (2017)
Parabolic SAR (PARABOLIC_SAR)	indicador de tendência que usa pontos em um gráfico para indicar a direção da tendência	$SAR_i = SAR_{i-1} + AF * (EP - SAR_{i-1})$ Onde: SAR _i = Valor do Parabolic SAR para o período i SAR _{i-1} = Valor do Parabolic SAR para o período i-1 AF = Fator de Aceleração EP = Ponto Extremo (Máximo ou Mínimo) anterior	Chourmouziadis & Chatzoglou (2016)
On Balance Volume (OBV)	Mede o fluxo de volume positivo e negativo em um determinado ativo ao longo do tempo.	$OBV = OBV_{anterior} + volume_{atual} * sinal$ Onde:	Fidelity (2023)

		OBV_anterior: é o valor do OBV no período anterior volume_atual: é o volume atual da negociação	
Momentum (MMO)			Creamer (2012). Kara et al. (2011).

Fonte: Elaborada pelo autor.

APÊNDICE C: Empresas Participantes do Estudo

TABELA 13 – RELAÇÃO DE EMPRESAS PARTICIPANTES DO ESTUDO

Símbolo	Razão Social	Símbolo	Nome
ABEV3	AMBEV S.A.	KLBN11	KLABIN S.A.
ALPA4	ALPARGATAS SA	LWSA3	LOCAWEB SERVIÇOS DE INTERNET S.A.
AMER3	AMERICANAS S.A.	MDIA3	M DIAS BRANCO SA IND E COM DE ALIMENTOS
ARZZ3	AREZZO INDÚSTRIA E COMERCIO S/A	MGLU3	MAGAZINE LUIZA S.A.
ASAI3	SENDAS DISTRIBUIDORA S.A.	MOVI3	MOVIDA PARTICIPAÇÕES S.A.
AZUL4	AZUL S.A.	MRVE3	MRV ENGENHARIA E PARTICIPAÇÕES S/A
B3SA3	B3 S.A.	MULT3	MULTIPLAN EMP. IMOBILIARIOS S/A
BEEF3	MINERVA S/A	NTCO3	NATURA & CO HOLDING S.A.
BRFS3	BRF S.A.	PCAR3	COMPANHIA BRASILEIRA DE DISTRIBUIÇÃO
BRKM5	BRASKEM S.A.	PETR3	PETRÓLEO BRASILEIRO S.A. – PETROBRAS
CASH3	MÉLIUZ S.A.	PETR4	PETRÓLEO BRASILEIRO S.A. – PETROBRAS
CCRO3	CCR S.A.	PRI03	PETRO RIO S.A.
CMIG4	CIA ENERG MINAS GERAIS – CEMIG	PSSA3	PORTO SEGURO SA
CMIN3	CSN MINERACAO S.A.	QUAL3	QUALICORP S.A.
COGN3	COGNA EDUCAÇÃO	RADL3	RAIA DROGASIL S.A.
CPFE3	CPFL ENERGIA SA	RAIL3	RUMO S.A.
CPLE6	COMPANHIA PARANAENSE DE ENERGIA	RDOR3	REDE D OR SÃO LUIZ S.A.
CRFB3	ATACADÃO S.A.	RENT3	LOCALIZA RENT A CAR SA
CSAN3	COSAN SA INDUSTRIA E COMERCIO	RRRP3	3R PETROLEUM OLEO E GAS S.A.
CSNA3	CIA SIDERURGICA NACIONAL	SLCE3	SLC AGRICOLA SA
CVCB3	CVC BRASIL OPERADORA E AGÊNCIA DE VIAGENS S.A.	SMT03	SÃO MARTINHO SA
CYRE3	CYRELA BRAZIL REALTY SA EMPRS E PARTS	SOMA3	GRUPO DE MODA SOMA S.A.
DXCO3	DURATEX S.A.	STBP3	SANTOS BRASIL PARTICIPAÇÕES S.A.
ECOR3	ECORODOVIAS INFRAESTRUTURA E LOGÍSTICA S.A.	SUZB3	SUZANO PAPEL E CELULOSE S.A.
EGIE3	ENGIE BRASIL ENERGIA S.A.	TAE11	TRANSMISSORA ALIANÇA DE ENERGIA ELÉTRICA S.A.
ELET3	CENTRAIS ELETRICAS BRASILEIRAS SA	TIMS3	TIM S.A.
ELET6	CENTRAIS ELETRICAS BRASILEIRAS SA	TOTS3	TOTVS S.A
EMBR3	EMBRAER S.A.	TRPL4	CTEEP-CIA TRANSM ENERGIA ELÉTR. PAULISTA

ENAT3	ENAUTA PARTICIPAÇÕES S.A.	UGPA3	ULTRAPAR PARTICIPAÇÕES SA
ENBR3	EDP ENERGIAS DO BRASIL S/A	USIM5	USINAS SIDERURGICAS DE MINAS GERAIS SA
ENEV3	ENEVA S.A.	VALE3	VALE S.A.
ENGI11	ENERGISA SA	VAMO3	VAMOS LOCACAO DE CAMINHOS, MÁQUINAS E EQUIPAMENTOS S.A.
EQTL3	EQUATORIAL ENERGIA S/A	VBBR3	VIBRA ENERGIA S.A
EZTC3	EZ TEC EMPREEND. E PARTICIPAÇÕES S/A	VIIA3	VIA VAREJO S.A.
FLRY3	FLEURY SA	VIVT3	TELEFÔNICA BRASIL S.A.
GGBR4	GERDAU SA	WEGE3	WEG SA
GMAT3	GRUPO MATEUS S.A.	KLBN11	KLABIN S.A.
GOAU4	METALURGICA GERDAU SA	LWSA3	LOCAWEB SERVIÇOS DE INTERNET S.A.
GOLL4	GOL LINHAS AEREAS INTELIGENTES SA	MDIA3	M DIAS BRANCO SA IND E COM DE ALIMENTOS
HAPV3	HAPVIDA	MGLU3	MAGAZINE LUIZA S.A.
HYPE3	HYPERA S.A.	MOVI3	MOVIDA PARTICIPAÇÕES S.A.
JBSS3	JBS SA		

Fonte: Elaborada pelo autor.

APENDICE D: TABELAS DESCRITIVAS DAS MÉTRICAS DE AVALIAÇÃO DOS MODELOS

TABELA 14 - ESTATÍSTICAS DESCRITIVAS – COEFICIENTE DE DETERMINAÇÃO (R2)

Grupo	Modelos	Média	Desvio	Mínimo	Quartil1	Mediana	Quartil3	Máximo
Básicos	Fundamentalistas	12,51%	20,25%	0,00%	0,00%	0,00%	20,05%	78,58%
	Técnicos	28,17%	19,85%	0,00%	8,53%	31,86%	44,13%	73,96%
	Econômicos	8,73%	16,32%	0,00%	0,00%	0,00%	10,06%	76,49%
(FT)	Fundamentalistas Técnicas	25,92%	18,94%	0,00%	4,39%	28,35%	41,21%	80,65%
Fundamentalistas e Técnicos (FT) R2 Médio =25,92%	FT_Cambio*	25,12%	19,45%	0,00%	0,00%	27,10%	41,66%	65,40%
	FT_Economicos	22,30%	18,91%	0,00%	0,00%	23,03%	39,66%	74,25%
	FT_IGPM*	24,35%	18,79%	0,00%	3,49%	26,32%	39,66%	68,32%
	FT_IPCA	23,11%	19,08%	0,00%	0,00%	24,78%	38,14%	70,15%
	FT_JUROS*	24,90%	19,09%	0,00%	1,55%	27,50%	40,60%	66,17%
	FT_PIB	24,37%	18,45%	0,00%	3,52%	25,92%	40,61%	62,80%
Fundamentalistas R2 Médio = 12,51%	FundamentalistasEconomicos*	7,39%	14,38%	0,00%	0,00%	0,00%	9,18%	78,38%
	Fundamentalistas_Cambio	12,63%	19,39%	0,00%	0,00%	0,00%	22,13%	81,72%
	Fundamentalistas_IGPM*	8,95%	16,37%	0,00%	0,00%	0,00%	12,05%	84,64%
	Fundamentalistas_IPCA	11,02%	17,98%	0,00%	0,00%	0,00%	18,04%	85,20%
	Fundamentalistas_JUROS*	13,30%	20,34%	0,00%	0,00%	0,00%	25,04%	83,44%
	Fundamentalistas_PIB*	11,13%	18,55%	0,00%	0,00%	0,00%	18,18%	81,11%
Técnicas R2 Médio = 28,17%	Tecnicas_Cambio*	26,21%	19,95%	0,00%	2,84%	29,94%	42,75%	71,52%
	Tecnicas_Economicas	22,95%	19,00%	0,00%	0,00%	24,39%	38,14%	68,84%
	Tecnicas_IGPM	25,18%	19,26%	0,00%	1,65%	27,55%	39,96%	71,50%
	Tecnicas_IPCA	24,36%	19,29%	0,00%	0,00%	27,37%	40,26%	70,09%
	Tecnicas_JUROS	26,43%	19,87%	0,00%	3,50%	28,62%	41,77%	74,49%
	Tecnicas_PIB	26,27%	19,57%	0,00%	2,31%	28,66%	43,22%	68,84%
Todos	Todos	22,21%	19,13%	0,00%	0,00%	22,12%	38,76%	67,94%

Fonte: Elaborada pelo autor.

Nota:*Os modelos marcados com * apresentaram p-valor superior ao nível de significância, evidenciando igualdade de média.

TABELA 15 - ESTATÍSTICAS DESCRITIVAS – VARIÂNCIA EXPLICADA

Grupo	Modelos	Média	Desvio	Mínimo	Quartil1	Mediana	Quartil3	Máximo
Básicos	Fundamentalistas	16,85%	21,83%	0,00%	0,00%	3,64%	30,58%	78,65%
	Técnicos	33,15%	17,93%	0,00%	19,90%	35,67%	47,04%	74,01%
	Econômicos	12,21%	17,87%	0,00%	0,00%	0,00%	21,17%	76,84%
Fundamentalistas e Técnicos (FT)	Fundamentalistas_Tecnicas	31,37%	17,83%	0,00%	18,87%	34,83%	44,38%	81,49%
Fundamentalistas e Técnicos (FT) EVS Médio = 31,37%	FT_Cambio*	30,91%	17,95%	0,00%	18,73%	33,90%	44,54%	67,10%
	FT_Economicos	28,55%	17,71%	0,00%	16,05%	30,41%	42,69%	74,69%
	FT_IGPM*	30,84%	17,57%	0,00%	18,72%	33,64%	43,73%	69,09%
	FT_IPCA	29,17%	18,14%	0,00%	15,38%	31,31%	42,69%	70,63%
	FT_JUROS*	30,89%	17,71%	0,00%	18,42%	33,88%	44,78%	66,30%
	FT_PIB	30,29%	17,63%	0,00%	18,03%	33,52%	43,87%	70,64%
Fundamentalistas EVS Médio = 16,85%	FundamentalistasEconomicos*	11,26%	16,50%	0,00%	0,00%	0,00%	18,83%	78,53%
	Fundamentalistas_Cambio	16,84%	20,53%	0,00%	0,00%	7,01%	31,12%	81,77%
	Fundamentalistas_IGPM*	13,89%	18,69%	0,00%	0,00%	2,82%	25,28%	84,94%
	Fundamentalistas_IPCA	15,54%	19,63%	0,00%	0,00%	5,60%	28,15%	85,27%
	Fundamentalistas_JUROS*	17,09%	21,38%	0,00%	0,00%	5,28%	32,00%	83,70%
	Fundamentalistas_PIB*	15,85%	20,10%	0,00%	0,00%	5,03%	29,78%	81,70%
Técnicas EVS Médio = 33,15%	Tecnicas_Cambio*	31,89%	18,06%	0,00%	18,47%	35,76%	45,06%	71,85%
	Tecnicas_Economicas	28,90%	17,94%	0,00%	16,68%	31,17%	43,22%	70,44%
	Tecnicas_IGPM	30,91%	17,79%	0,00%	19,63%	33,49%	43,65%	71,60%
	Tecnicas_IPCA	30,05%	17,91%	0,00%	15,73%	34,00%	43,36%	70,09%
	Tecnicas_JUROS	32,49%	17,79%	0,00%	22,02%	34,79%	45,23%	74,59%
	Tecnicas_PIB	31,76%	17,92%	0,00%	18,39%	34,14%	45,47%	72,20%
Todos	Todos	28,37%	18,09%	0,00%	14,30%	29,92%	42,29%	68,04%

Fonte: Elaborada pelo autor.

Nota: * Os modelos marcados com * apresentaram p-valor superior ao nível de significância, evidenciando igualdade de médias

TABELA 16 - ESTATÍSTICAS DESCRITIVAS - CORRELAÇÃO ENTRE VALORES REAIS E PREVISTOS

Grupo	Modelos	Média	Desvio	Mínimo	Quartil1	Mediana	Quartil3	Máximo
Básicos	Fundamentalistas	38,25%	25,57%	0,00%	17,63%	37,82%	58,91%	91,00%
	Tecnicos	62,22%	10,93%	16,83%	55,32%	63,58%	70,25%	86,67%
	Economicos	30,80%	24,26%	0,00%	8,71%	28,88%	48,40%	88,17%
Fundamentalistas e Técnicos (FT)	Fundamentalistas_Tecnicas	60,89%	11,06%	21,11%	54,33%	62,09%	69,01%	91,71%
Fundamentalistas e Técnicos (FT) EVS Médio =60,89%	FT_Cambio	60,48%	11,36%	14,29%	54,11%	61,94%	68,56%	82,75%
	FT_Economicos	58,55%	11,63%	1,63%	50,89%	59,89%	66,97%	86,79%
	FT_IGPM	60,28%	11,39%	2,31%	54,46%	61,40%	68,22%	83,48%
	FT_IPCA	59,63%	11,56%	17,21%	52,89%	60,10%	67,83%	85,80%
	FT_JUROS	60,49%	11,09%	8,03%	53,40%	61,11%	68,90%	84,93%
	FT_PIB	59,99%	11,30%	23,83%	53,20%	62,01%	68,05%	85,30%
Fundamentalistas EVS Médio =38,25%	FundamentalistasEconomicos*	30,70%	22,86%	0,00%	11,16%	30,31%	46,09%	88,62%
	Fundamentalistas_Cambio	38,19%	24,86%	0,00%	17,11%	38,12%	57,85%	90,61%
	Fundamentalistas_IGPM*	35,77%	23,63%	0,00%	16,19%	35,72%	54,25%	92,19%
	Fundamentalistas_IPCA	37,75%	23,62%	0,00%	19,65%	38,62%	56,39%	92,55%
	Fundamentalistas_JUROS*	38,54%	25,34%	0,00%	15,81%	39,30%	59,06%	92,51%
	Fundamentalistas_PIB*	36,90%	24,97%	0,00%	14,22%	39,07%	56,64%	92,02%
Técnicas EVS Médio = 62,22%	Tecnicas_Cambio*	61,47%	11,03%	7,16%	55,31%	62,88%	68,87%	86,56%
	Tecnicas_Economicas	58,96%	11,89%	3,28%	52,30%	60,10%	67,26%	84,25%
	Tecnicas_IGPM	60,74%	11,01%	7,95%	53,72%	62,07%	68,41%	84,76%
	Tecnicas_IPCA	60,27%	11,10%	19,36%	53,47%	61,40%	68,02%	86,83%
	Tecnicas_JUROS	61,82%	10,65%	23,01%	55,51%	62,83%	69,57%	86,65%
	Tecnicas_PIB	61,31%	10,96%	25,57%	54,51%	62,35%	69,24%	85,41%
Todos	Todos	58,57%	11,81%	4,47%	50,84%	60,38%	66,89%	83,46%

Fonte: Elaborada pelo autor.

Nota: * Os modelos marcados com * apresentaram p-valor superior ao nível de significância, evidenciando igualdade de médias

TABELA 17 - ESTATÍSTICAS DESCRITIVAS - ERRO QUADRÁTICO MÉDIO

Grupo	Modelos	Média	Desvio	Mínimo	Quartil1	Mediana	Quartil3	Máximo
Básicos	Fundamentalistas	0,19%	1,29%	0,01%	0,04%	0,07%	0,14%	27,83%
	Técnicos	0,13%	1,24%	0,01%	0,03%	0,05%	0,08%	26,87%
	Econômicos	0,19%	1,27%	0,01%	0,04%	0,08%	0,16%	27,45%
(FT)	Fundamentalistas_Tecnicas	0,13%	1,24%	0,00%	0,03%	0,05%	0,09%	26,79%
Fundamentalistas e Técnicos (FT) MSE Médio = 0,13%	FT_Cambio*	0,13%	1,23%	0,01%	0,03%	0,05%	0,08%	26,68%
	FT_Economicos	0,13%	1,23%	0,01%	0,03%	0,05%	0,10%	26,68%
	FT_IGPM*	0,13%	1,23%	0,01%	0,03%	0,05%	0,09%	26,70%
	FT_IPCA	0,14%	1,26%	0,01%	0,03%	0,05%	0,09%	27,21%
	FT_JUROS*	0,13%	1,25%	0,01%	0,03%	0,05%	0,09%	27,14%
	FT_PIB	0,13%	1,26%	0,01%	0,03%	0,05%	0,09%	27,16%
Fundamentalistas MSE Médio =0,19%	FundamentalistasEconomicos*	0,20%	1,32%	0,01%	0,05%	0,08%	0,17%	28,56%
	Fundamentalistas_Cambio	0,18%	1,31%	0,01%	0,04%	0,07%	0,14%	28,37%
	Fundamentalistas_IGPM*	0,18%	1,30%	0,00%	0,04%	0,08%	0,15%	27,96%
	Fundamentalistas_IPCA	0,18%	1,27%	0,00%	0,04%	0,08%	0,15%	27,36%
	Fundamentalistas_JUROS*	0,18%	1,18%	0,00%	0,04%	0,07%	0,14%	25,32%
	Fundamentalistas_PIB	0,19%	1,28%	0,01%	0,04%	0,07%	0,14%	27,60%
Técnicas MSE Médio =0,13%	Tecnicas_Cambio*	0,13%	1,18%	0,01%	0,03%	0,05%	0,08%	25,49%
	Tecnicas_Economicas	0,13%	1,19%	0,01%	0,03%	0,05%	0,09%	25,82%
	Tecnicas_IGPM	0,13%	1,22%	0,01%	0,03%	0,05%	0,09%	26,50%
	Tecnicas_IPCA	0,13%	1,25%	0,01%	0,03%	0,05%	0,09%	27,15%
	Tecnicas_JUROS	0,13%	1,23%	0,01%	0,03%	0,05%	0,09%	26,61%
	Tecnicas_PIB	0,13%	1,24%	0,01%	0,03%	0,05%	0,09%	26,79%
Todos	Todos	0,14%	1,23%	0,01%	0,03%	0,05%	0,10%	26,65%

Fonte: Elaborada pelo autor.

Nota:* Os modelos marcados com * apresentaram p-valor superior ao nível de significância, evidenciando igualdade de médias

TABELA 18 - ESTATÍSTICAS DESCRITIVAS - ERRO ABSOLUTO MÉDIO

Grupo	modelo	Média	Desvio Padrão	Mínimo	Primeiro Quartil	Mediana	Terceiro Quartil	Máximo
Básicos	Fundamentalistas	2,52%	1,67%	0,57%	1,55%	2,12%	2,97%	18,42%
	Tecnicos	1,90%	1,22%	0,58%	1,28%	1,66%	2,20%	20,09%
	Economicos	2,57%	1,50%	0,62%	1,62%	2,20%	3,10%	17,89%
(FT)	Fundamentalistas_Tecnicas	1,96%	1,26%	0,53%	1,30%	1,72%	2,26%	20,06%
Fundamentalistas e Técnicos (FT) MAE Médio = 1,96%	FT_Cambio*	1,98%	1,24%	0,60%	1,30%	1,73%	2,27%	18,69%
	FT_Economicos	2,04%	1,24%	0,60%	1,35%	1,83%	2,38%	18,96%
	FT_IGPM*	1,99%	1,25%	0,64%	1,35%	1,74%	2,33%	19,08%
	FT_IPCA	2,03%	1,27%	0,66%	1,34%	1,78%	2,34%	19,88%
	FT_JUROS*	1,97%	1,27%	0,53%	1,32%	1,73%	2,26%	20,17%
	FT_PIB	2,00%	1,27%	0,56%	1,33%	1,75%	2,32%	20,17%
Fundamentalistas MAE Médio = 2,52%	FundamentalistasEconomicos*	2,66%	1,61%	0,63%	1,66%	2,24%	3,33%	19,12%
	Fundamentalistas_Cambio	2,46%	1,55%	0,52%	1,54%	2,13%	2,99%	19,26%
	Fundamentalistas_IGPM*	2,54%	1,54%	0,53%	1,61%	2,20%	3,13%	18,52%
	Fundamentalistas_IPCA	2,48%	1,55%	0,53%	1,52%	2,14%	3,05%	18,17%
	Fundamentalistas_JUROS*	2,48%	1,70%	0,55%	1,50%	2,10%	2,99%	18,05%
	Fundamentalistas_PIB	2,53%	1,68%	0,56%	1,58%	2,10%	3,00%	18,24%
Técnicas MAE Médio = 1,90%	Tecnicas_Cambio*	1,94%	1,20%	0,60%	1,28%	1,69%	2,28%	19,02%
	Tecnicas_Economicas	2,05%	1,25%	0,60%	1,31%	1,81%	2,40%	18,19%
	Tecnicas_IGPM	1,98%	1,24%	0,57%	1,31%	1,71%	2,34%	19,60%
	Tecnicas_IPCA	2,00%	1,27%	0,58%	1,31%	1,74%	2,28%	20,26%
	Tecnicas_JUROS	1,94%	1,21%	0,61%	1,27%	1,67%	2,27%	18,55%
	Tecnicas_PIB	1,95%	1,24%	0,62%	1,27%	1,70%	2,27%	19,42%
Todos	Todos	2,05%	1,26%	0,62%	1,33%	1,82%	2,38%	19,18%

Fonte: Elaborada pelo autor.

Nota: * Os modelos marcados com * apresentaram p-valor superior ao nível de significância, evidenciando igualdade de médias

APÊNDICE E: Tabelas de Testes de Diferença de Média dos Modelos de Machine Learning

TABELA 19 - TESTE-T – MÉTRICA R2

Modelo A	Modelo B	t_stat	p_valor	resultado
Fundamentalistas	Economicos	0,355599	0,722301	Médias Iguais
Fundamentalistas	FT_Cambio	8,969189	0,000000	Há diferença de médias
Fundamentalistas	FT_Economicos	7,774312	0,000000	Há diferença de médias
Fundamentalistas	FT_IGPM	8,508882	0,000000	Há diferença de médias
Fundamentalistas	FT_IPCA	8,237179	0,000000	Há diferença de médias
Fundamentalistas	FT_JUROS	8,950205	0,000000	Há diferença de médias
Fundamentalistas	FT_PIB	8,528661	0,000000	Há diferença de médias
Fundamentalistas	Fundamentalistas_Cambio	2,020142	0,043939	Há diferença de médias
Fundamentalistas	Fundamentalistas_IGPM	1,534870	0,125493	Médias Iguais
Fundamentalistas	Fundamentalistas_IPCA	2,075730	0,038466	Há diferença de médias
Fundamentalistas	Fundamentalistas_JUROS	1,828976	0,068041	Médias Iguais
Fundamentalistas	Fundamentalistas_PIB	-0,644971	0,519263	Médias Iguais
Fundamentalistas	Fundamentalistas_Tecnicas	-9,113036	0,000000	Há diferença de médias
Fundamentalistas	FundamentalistasEconomicos	-1,102033	0,271015	Médias Iguais
Fundamentalistas	Tecnicas_Cambio	-8,493981	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_Economicas	-7,052464	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_IGPM	-7,894985	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_IPCA	-7,777976	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_JUROS	-8,397584	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_PIB	-8,181343	0,000000	Há diferença de médias
Fundamentalistas	Tecnicos	-8,803676	0,000000	Há diferença de médias
Fundamentalistas	Todos	-7,584680	0,000000	Há diferença de médias
Tecnicos	Todos	6,037878	0,000000	Há diferença de médias
Tecnicos	Tecnicas_PIB	-3,670135	0,000270	Há diferença de médias
Tecnicos	Tecnicas_JUROS	-2,399142	0,016825	Há diferença de médias
Tecnicos	Tecnicas_IPCA	-4,499630	0,000009	Há diferença de médias
Tecnicos	Tecnicas_IGPM	-3,985800	0,000078	Há diferença de médias
Tecnicos	Tecnicas_Economicas	-6,234909	0,000000	Há diferença de médias
Tecnicos	Tecnicas_Cambio	-1,843773	0,065849	Médias Iguais
Tecnicos	FundamentalistasEconomicos	-9,871078	0,000000	Há diferença de médias
Tecnicos	Fundamentalistas_Tecnicas	-2,683170	0,007552	Há diferença de médias
Tecnicos	Fundamentalistas_PIB	-7,668422	0,000000	Há diferença de médias
Tecnicos	Fundamentalistas_JUROS	-7,159335	0,000000	Há diferença de médias
Tecnicos	Fundamentalistas_IPCA	-8,496613	0,000000	Há diferença de médias
Tecnicos	Fundamentalistas_IGPM	-8,949550	0,000000	Há diferença de médias
Tecnicos	Fundamentalistas_Cambio	-8,726731	0,000000	Há diferença de médias

Tecnicos	Fundamentalistas	-8,803676	0,000000	Há diferença de médias
Tecnicos	FT_PIB	-4,277719	0,000023	Há diferença de médias
Tecnicos	FT_JUROS	-3,489197	0,000530	Há diferença de médias
Tecnicos	FT_IPCA	-4,862538	0,000002	Há diferença de médias
Tecnicos	FT_IGPM	-3,701290	0,000240	Há diferença de médias
Tecnicos	FT_Economicos	-5,379127	0,000000	Há diferença de médias
Tecnicos	FT_Cambio	-3,659186	0,000282	Há diferença de médias
		-		
Tecnicos	Economicos	12,152468	0,000000	Há diferença de médias
		-		
Economicos	FT_IGPM	10,411525	0,000000	Há diferença de médias
Economicos	FT_IPCA	-9,921825	0,000000	Há diferença de médias
		-		
Economicos	FT_JUROS	10,814912	0,000000	Há diferença de médias
		-		
Economicos	FT_PIB	10,184450	0,000000	Há diferença de médias
Economicos	Fundamentalistas_Cambio	-0,887492	0,375271	Médias Iguais
Economicos	Fundamentalistas_IGPM	-0,477884	0,632957	Médias Iguais
Economicos	Fundamentalistas_IPCA	-0,930744	0,352467	Médias Iguais
Economicos	Fundamentalistas_JUROS	-0,595756	0,551627	Médias Iguais
Economicos	Fundamentalistas_PIB	-0,163868	0,869906	Médias Iguais
		-		
Economicos	Fundamentalistas_Tecnicas	10,849946	0,000000	Há diferença de médias
Economicos	FundamentalistasEconomicos	1,351950	0,177046	Médias Iguais
		-		
Economicos	Tecnicas_Cambio	11,587926	0,000000	Há diferença de médias
		-		
Economicos	Tecnicas_Economicas	10,041268	0,000000	Há diferença de médias
		-		
Economicos	Tecnicas_IGPM	11,041547	0,000000	Há diferença de médias
		-		
Economicos	Tecnicas_IPCA	10,756449	0,000000	Há diferença de médias
		-		
Economicos	Tecnicas_JUROS	11,783833	0,000000	Há diferença de médias
		-		
Economicos	Tecnicas_PIB	11,357967	0,000000	Há diferença de médias
Economicos	Todos	-9,649824	0,000000	Há diferença de médias

Fonte: Elaborada pelo autor.

TABELA 20 - TESTE-T – MÉTRICA MAE

Modelo A	Modelo B	t_stat	p_valor	resultado
		-		Há diferença de
Economicos	FT_IGPM	10,411525	0,000000	médias
		-		Há diferença de
Economicos	FT_IPCA	9,921825	0,000000	médias
		-		Há diferença de
Economicos	FT_JUROS	10,814912	0,000000	médias

Economicos	FT_PIB	-		Há diferença de médias
Economicos	FundamentalistasEconomicos	10,184450	0,000000	
Economicos	FundamentalistasEconomicos	1,351950	0,177046	Médias Iguais
Economicos	Fundamentalistas_Cambio	-		Há diferença de médias
Economicos	Fundamentalistas_Cambio	0,887492	0,375271	Médias Iguais
Economicos	Fundamentalistas_IGPM	-		Há diferença de médias
Economicos	Fundamentalistas_IGPM	0,477884	0,632957	Médias Iguais
Economicos	Fundamentalistas_IPCA	-		Há diferença de médias
Economicos	Fundamentalistas_IPCA	0,930744	0,352467	Médias Iguais
Economicos	Fundamentalistas_JUROS	-		Há diferença de médias
Economicos	Fundamentalistas_JUROS	0,595756	0,551627	Médias Iguais
Economicos	Fundamentalistas	-		Há diferença de médias
Economicos	Fundamentalistas	0,355599	0,722301	Médias Iguais
Economicos	Fundamentalistas_PIB	-		Há diferença de médias
Economicos	Fundamentalistas_PIB	0,163868	0,869906	Médias Iguais
Economicos	Fundamentalistas_Tecnicas	-		Há diferença de médias
Economicos	Fundamentalistas_Tecnicas	10,849946	0,000000	Médias Iguais
Economicos	Tecnicas_Cambio	-		Há diferença de médias
Economicos	Tecnicas_Cambio	11,587926	0,000000	Médias Iguais
Economicos	Tecnicas_Economicas	-		Há diferença de médias
Economicos	Tecnicas_Economicas	10,041268	0,000000	Médias Iguais
Economicos	Tecnicas_IGPM	-		Há diferença de médias
Economicos	Tecnicas_IGPM	11,041547	0,000000	Médias Iguais
Economicos	Tecnicas_IPCA	-		Há diferença de médias
Economicos	Tecnicas_IPCA	10,756449	0,000000	Médias Iguais
Economicos	Tecnicas_JUROS	-		Há diferença de médias
Economicos	Tecnicas_JUROS	11,783833	0,000000	Médias Iguais
Economicos	Tecnicas_PIB	-		Há diferença de médias
Economicos	Tecnicas_PIB	11,357967	0,000000	Médias Iguais
Economicos	Tecnicos	-		Há diferença de médias
Economicos	Tecnicos	12,152468	0,000000	Médias Iguais
Economicos	Todos	-		Há diferença de médias
Economicos	Todos	9,649824	0,000000	Médias Iguais
Fundamentalistas	Economicos	0,355599	0,722301	Médias Iguais
Fundamentalistas	FT_Cambio	-		Há diferença de médias
Fundamentalistas	FT_Cambio	8,969189	0,000000	Médias Iguais
Fundamentalistas	FT_Economicos	-		Há diferença de médias
Fundamentalistas	FT_Economicos	7,774312	0,000000	Médias Iguais
Fundamentalistas	FT_IGPM	-		Há diferença de médias
Fundamentalistas	FT_IGPM	8,508882	0,000000	Médias Iguais
Fundamentalistas	FT_IPCA	-		Há diferença de médias
Fundamentalistas	FT_IPCA	8,237179	0,000000	Médias Iguais
Fundamentalistas	FT_JUROS	-		Há diferença de médias
Fundamentalistas	FT_JUROS	8,950205	0,000000	Médias Iguais
Fundamentalistas	FT_PIB	-		Há diferença de médias
Fundamentalistas	FT_PIB	8,528661	0,000000	Médias Iguais
Fundamentalistas	FundamentalistasEconomicos	-		Há diferença de médias
Fundamentalistas	FundamentalistasEconomicos	1,102033	0,271015	Médias Iguais

Fundamentalistas	Fundamentalistas_Cambio	2,020142	0,043939	Há diferença de médias
Fundamentalistas	Fundamentalistas_IGPM	1,534870	0,125493	Médias Iguais
Fundamentalistas	Fundamentalistas_IPCA	2,075730	0,038466	Há diferença de médias
Fundamentalistas	Fundamentalistas_JUROS	1,828976	0,068041	Médias Iguais
Fundamentalistas	Fundamentalistas_PIB	0,644971	0,519263	Médias Iguais
Fundamentalistas	Fundamentalistas_Tecnicas	9,113036	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_Cambio	8,493981	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_Economicas	7,052464	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_IGPM	7,894985	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_IPCA	7,777976	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_JUROS	8,397584	0,000000	Há diferença de médias
Fundamentalistas	Tecnicas_PIB	8,181343	0,000000	Há diferença de médias
Fundamentalistas	Tecnicos	8,803676	0,000000	Há diferença de médias
Fundamentalistas	Todos	7,584680	0,000000	Há diferença de médias
Fundamentalistas_Tecnicas	Economicos	10,849946	0,000000	Há diferença de médias
Fundamentalistas_Tecnicas	FT_Cambio	1,201916	0,230005	Médias Iguais
Fundamentalistas_Tecnicas	FT_Economicos	3,463412	0,000582	Há diferença de médias
Fundamentalistas_Tecnicas	FT_IGPM	1,386578	0,166232	Médias Iguais
Fundamentalistas_Tecnicas	FT_IPCA	2,943186	0,003410	Há diferença de médias
Fundamentalistas_Tecnicas	FT_JUROS	0,691689	0,489476	Médias Iguais
Fundamentalistas_Tecnicas	FT_PIB	2,240424	0,025533	Há diferença de médias
Fundamentalistas_Tecnicas	FundamentalistasEconomicos	10,371738	0,000000	Há diferença de médias
Fundamentalistas_Tecnicas	Fundamentalistas_Cambio	8,998474	0,000000	Há diferença de médias
Fundamentalistas_Tecnicas	Fundamentalistas_IGPM	9,512515	0,000000	Há diferença de médias
Fundamentalistas_Tecnicas	Fundamentalistas_IPCA	8,740439	0,000000	Há diferença de médias

Fundamentalistas_Tecnicas	Fundamentalistas_JUROS	-	0,000000	Há diferença de médias
Fundamentalistas_Tecnicas	Fundamentalistas	7,415493	0,000000	Há diferença de médias
Fundamentalistas_Tecnicas	Fundamentalistas_PIB	-	0,000000	Há diferença de médias
Fundamentalistas_Tecnicas	Tecnicas_Cambio	7,836962	0,000000	Médias Iguais
Fundamentalistas_Tecnicas	Tecnicas_Economicas	-	0,176130	Há diferença de médias
Fundamentalistas_Tecnicas	Tecnicas_IGPM	3,120278	0,001919	Médias Iguais
Fundamentalistas_Tecnicas	Tecnicas_IPCA	0,533795	0,593737	Médias Iguais
Fundamentalistas_Tecnicas	Tecnicas_JUROS	1,187728	0,235544	Médias Iguais
Fundamentalistas_Tecnicas	Tecnicas_PIB	-	0,279181	Médias Iguais
Fundamentalistas_Tecnicas	Tecnicos	1,083420	0,279181	Médias Iguais
Fundamentalistas_Tecnicas	Todos	-	0,600828	Há diferença de médias
Tecnicos	Economicos	2,683170	0,007552	Há diferença de médias
Tecnicos	FT_Cambio	4,082807	0,000052	Há diferença de médias
Tecnicos	FT_Economicos	-	0,000000	Há diferença de médias
Tecnicos	FT_IGPM	-	0,000282	Há diferença de médias
Tecnicos	FT_IPCA	3,659186	0,000000	Há diferença de médias
Tecnicos	FT_JUROS	-	0,000240	Há diferença de médias
Tecnicos	FT_PIB	4,862538	0,000002	Há diferença de médias
Tecnicos	FundamentalistasEconomicos	-	0,000530	Há diferença de médias
Tecnicos	Fundamentalistas_Cambio	3,489197	0,000023	Há diferença de médias
Tecnicos	Fundamentalistas_IGPM	-	0,000000	Há diferença de médias
Tecnicos	Fundamentalistas_IPCA	4,277719	0,000000	Há diferença de médias
Tecnicos	Fundamentalistas_JUROS	-	0,000000	Há diferença de médias
Tecnicos	Fundamentalistas	9,871078	0,000000	Há diferença de médias
Tecnicos	Fundamentalistas_PIB	-	0,000000	Há diferença de médias
Tecnicos		8,726731	0,000000	Há diferença de médias
Tecnicos		-	0,000000	Há diferença de médias
Tecnicos		8,949550	0,000000	Há diferença de médias
Tecnicos		-	0,000000	Há diferença de médias
Tecnicos		8,496613	0,000000	Há diferença de médias
Tecnicos		-	0,000000	Há diferença de médias
Tecnicos		7,159335	0,000000	Há diferença de médias
Tecnicos		-	0,000000	Há diferença de médias
Tecnicos		8,803676	0,000000	Há diferença de médias
Tecnicos		-	0,000000	Há diferença de médias
Tecnicos		7,668422	0,000000	Há diferença de médias

Tecnicos	Fundamentalistas_Tecnicas	-		Há diferença de médias
		2,683170	0,007552	
Tecnicos	Tecnicas_Cambio	-		Médias Iguais
		1,843773	0,065849	Há diferença de médias
Tecnicos	Tecnicas_Economicas	-		Há diferença de médias
		6,234909	0,000000	Há diferença de médias
Tecnicos	Tecnicas_IGPM	-		Há diferença de médias
		3,985800	0,000078	Há diferença de médias
Tecnicos	Tecnicas_IPCA	-		Há diferença de médias
		4,499630	0,000009	Há diferença de médias
Tecnicos	Tecnicas_JUROS	-		Há diferença de médias
		2,399142	0,016825	Há diferença de médias
Tecnicos	Tecnicas_PIB	-		Há diferença de médias
		3,670135	0,000270	Há diferença de médias
Tecnicos	Todos	-		Há diferença de médias
		6,037878	0,000000	

Fonte: Elaborada pelo autor.

TABELA 21 - TESTE-T – MÉTRICA MSE

MODELO A	MODELO B	T_STAT	P_VALOR	RESULTADO
		-		Médias
Economicos	FT_IGPM	10,411525	0,000000	diferentes
		-		Médias
Economicos	FT_IPCA	9,921825	0,000000	diferentes
		-		Médias
Economicos	FT_JUROS	10,814912	0,000000	diferentes
		-		Médias
Economicos	FT_PIB	10,184450	0,000000	diferentes
		-		Médias
Economicos	FundamentalistasEconomicos	1,351950	0,177046	Não há diferença
		-		Médias
Economicos	Fundamentalistas_Cambio	0,887492	0,375271	Não há diferença
		-		Médias
Economicos	Fundamentalistas_IGPM	0,477884	0,632957	Não há diferença
		-		Médias
Economicos	Fundamentalistas_IPCA	0,930744	0,352467	Não há diferença
		-		Médias
Economicos	Fundamentalistas_JUROS	0,595756	0,551627	Não há diferença
		-		Médias
Economicos	Fundamentalistas	0,355599	0,722301	Não há diferença
		-		Médias
Economicos	Fundamentalistas_PIB	0,163868	0,869906	Não há diferença
		-		Médias
Economicos	Fundamentalistas_Tecnicas	10,849946	0,000000	diferentes
		-		Médias
Economicos	Tecnicas_Cambio	11,587926	0,000000	diferentes
		-		Médias
Economicos	Tecnicas_Economicas	10,041268	0,000000	diferentes

Economicos	Tecnicas_IGPM	-		Médias diferentes
		11,041547	0,000000	
Economicos	Tecnicas_IPCA	-		Médias diferentes
		10,756449	0,000000	
Economicos	Tecnicas_JUROS	-		Médias diferentes
		11,783833	0,000000	
Economicos	Tecnicas_PIB	-		Médias diferentes
		11,357967	0,000000	
Economicos	Tecnicos	-		Médias diferentes
		12,152468	0,000000	
Economicos	Todos	-		Médias diferentes
		9,649824	0,000000	
Fundamentalistas	Fundamentalistas_PIB	-		Não há diferença
		0,644971	0,519263	
Fundamentalistas	Fundamentalistas_Tecnicas	-		Médias diferentes
		9,113036	0,000000	
Fundamentalistas	Tecnicas_Cambio	-		Médias diferentes
		8,493981	0,000000	
Fundamentalistas	Tecnicas_Economicas	-		Médias diferentes
		7,052464	0,000000	
Fundamentalistas	Tecnicas_IGPM	-		Médias diferentes
		7,894985	0,000000	
Fundamentalistas	Tecnicas_IPCA	-		Médias diferentes
		7,777976	0,000000	
Fundamentalistas	Tecnicas_JUROS	-		Médias diferentes
		8,397584	0,000000	
Fundamentalistas	Tecnicas_PIB	-		Médias diferentes
		8,181343	0,000000	
Fundamentalistas	Tecnicos	-		Médias diferentes
		8,803676	0,000000	
Fundamentalistas	Todos	-		Médias diferentes
		7,584680	0,000000	
Fundamentalistas_Tecnicas	Tecnicas_Cambio	-		Não há diferença
		1,354819	0,176130	
Fundamentalistas_Tecnicas	Tecnicas_Economicas	-		Médias diferentes
		3,120278	0,001919	
Fundamentalistas_Tecnicas	Tecnicas_IGPM	-		Não há diferença
		0,533795	0,593737	
Fundamentalistas_Tecnicas	Tecnicas_IPCA	-		Não há diferença
		1,187728	0,235544	
Fundamentalistas_Tecnicas	Tecnicas_JUROS	-		Não há diferença
		1,083420	0,279181	
Fundamentalistas_Tecnicas	Tecnicas_PIB	-		Não há diferença
		0,600828	0,548246	
Fundamentalistas_Tecnicas	Tecnicos	-		Médias diferentes
		2,683170	0,007552	
Fundamentalistas_Tecnicas	Todos	-		Médias diferentes
		4,082807	0,000052	
Tecnicos	Todos	-		Médias diferentes
		6,037878	0,000000	

Fundamentalistas	Economicos	0,355599	0,722301	Não há diferença
		-		Médias
Fundamentalistas_Tecnicas	Economicos	10,849946	0,000000	diferentes
		-		Médias
Tecnicos	Economicos	12,152468	0,000000	diferentes
				Médias
Fundamentalistas	FT_Cambio	8,969189	0,000000	diferentes
		-		
Fundamentalistas_Tecnicas	FT_Cambio	1,201916	0,230005	Não há diferença
		-		Médias
Tecnicos	FT_Cambio	3,659186	0,000282	diferentes
				Médias
Fundamentalistas	FT_Economicos	7,774312	0,000000	diferentes
		-		Médias
Fundamentalistas_Tecnicas	FT_Economicos	3,463412	0,000582	diferentes
		-		Médias
Tecnicos	FT_Economicos	5,379127	0,000000	diferentes
				Médias
Fundamentalistas	FT_IGPM	8,508882	0,000000	diferentes
		-		
Fundamentalistas_Tecnicas	FT_IGPM	1,386578	0,166232	Não há diferença
		-		Médias
Tecnicos	FT_IGPM	3,701290	0,000240	diferentes
				Médias
Fundamentalistas	FT_IPCA	8,237179	0,000000	diferentes
		-		Médias
Fundamentalistas_Tecnicas	FT_IPCA	2,943186	0,003410	diferentes
		-		Médias
Tecnicos	FT_IPCA	4,862538	0,000002	diferentes
				Médias
Fundamentalistas	FT_JUROS	8,950205	0,000000	diferentes
		-		
Fundamentalistas_Tecnicas	FT_JUROS	0,691689	0,489476	Não há diferença
		-		Médias
Tecnicos	FT_JUROS	3,489197	0,000530	diferentes
				Médias
Fundamentalistas	FT_PIB	8,528661	0,000000	diferentes
		-		Médias
Fundamentalistas_Tecnicas	FT_PIB	2,240424	0,025533	diferentes
		-		Médias
Tecnicos	FT_PIB	4,277719	0,000023	diferentes
		-		
Fundamentalistas	FundamentalistasEconomicos	1,102033	0,271015	Não há diferença
		-		Médias
Fundamentalistas_Tecnicas	FundamentalistasEconomicos	10,371738	0,000000	diferentes
		-		Médias
Tecnicos	FundamentalistasEconomicos	9,871078	0,000000	diferentes
				Médias
Fundamentalistas	Fundamentalistas_Cambio	2,020142	0,043939	diferentes

Fundamentalistas_Tecnicas	Fundamentalistas_Cambio	-		Médias diferentes
Tecnicos	Fundamentalistas_Cambio	8,998474	0,000000	Médias diferentes
Fundamentalistas	Fundamentalistas_IGPM	-		Não há diferença
Fundamentalistas_Tecnicas	Fundamentalistas_IGPM	1,534870	0,125493	Médias diferentes
Tecnicos	Fundamentalistas_IGPM	-		Médias diferentes
Fundamentalistas	Fundamentalistas_IPCA	9,512515	0,000000	Médias diferentes
Fundamentalistas_Tecnicas	Fundamentalistas_IPCA	-		Médias diferentes
Tecnicos	Fundamentalistas_IPCA	8,949550	0,000000	Médias diferentes
Fundamentalistas	Fundamentalistas_JUROS	2,075730	0,038466	Médias diferentes
Fundamentalistas_Tecnicas	Fundamentalistas_IPCA	-		Médias diferentes
Tecnicos	Fundamentalistas_IPCA	8,740439	0,000000	Médias diferentes
Fundamentalistas	Fundamentalistas_JUROS	8,496613	0,000000	Médias diferentes
Fundamentalistas_Tecnicas	Fundamentalistas_JUROS	1,828976	0,068041	Não há diferença
Tecnicos	Fundamentalistas_JUROS	-		Médias diferentes
Fundamentalistas_Tecnicas	Fundamentalistas	7,415493	0,000000	Médias diferentes
Tecnicos	Fundamentalistas	-		Médias diferentes
Fundamentalistas_Tecnicas	Fundamentalistas_PIB	7,159335	0,000000	Médias diferentes
Tecnicos	Fundamentalistas	-		Médias diferentes
Fundamentalistas_Tecnicas	Fundamentalistas_PIB	9,113036	0,000000	Médias diferentes
Tecnicos	Fundamentalistas_PIB	-		Médias diferentes
Fundamentalistas_Tecnicas	Fundamentalistas_Tecnicas	8,803676	0,000000	Médias diferentes
Tecnicos	Tecnicas_Cambio	-		Médias diferentes
Fundamentalistas_Tecnicas	Tecnicas_Economicas	7,836962	0,000000	Médias diferentes
Tecnicos	Tecnicas_IGPM	-		Médias diferentes
Tecnicos	Tecnicas_IPCA	7,668422	0,000000	Médias diferentes
Tecnicos	Tecnicas_JUROS	-		Médias diferentes
Tecnicos	Tecnicas_PIB	2,683170	0,007552	Médias diferentes
Tecnicos	Tecnicas_Cambio	1,843773	0,065849	Não há diferença
Tecnicos	Tecnicas_Economicas	-		Médias diferentes
Tecnicos	Tecnicas_IGPM	6,234909	0,000000	Médias diferentes
Tecnicos	Tecnicas_IPCA	-		Médias diferentes
Tecnicos	Tecnicas_JUROS	3,985800	0,000078	Médias diferentes
Tecnicos	Tecnicas_PIB	-		Médias diferentes
Tecnicos	Tecnicas_PIB	4,499630	0,000009	Médias diferentes
Tecnicos	Tecnicas_PIB	-		Médias diferentes
Tecnicos	Tecnicas_PIB	2,399142	0,016825	Médias diferentes
Tecnicos	Tecnicas_PIB	-		Médias diferentes
Tecnicos	Tecnicas_PIB	3,670135	0,000270	Médias diferentes

Fonte: Elaborada pelo autor.

TABELA 22 - TESTE-T – MÉTRICA EVS

MODELO A	MODELO B	T_STAT	P_VALOR	RESULTADO
----------	----------	--------	---------	-----------

		-		Médias
Economicos	FT_IGPM	10,411525	0,000000	Diferentes
		-		Médias
Economicos	FT_IPCA	9,921825	0,000000	Diferentes
		-		Médias
Economicos	FT_JUROS	10,814912	0,000000	Diferentes
		-		Médias
Economicos	FT_PIB	10,184450	0,000000	Diferentes
Economicos	FundamentalistasEconomicos	1,351950	0,177046	Não há diferença
		-		
Economicos	Fundamentalistas_Cambio	0,887492	0,375271	Não há diferença
		-		
Economicos	Fundamentalistas_IGPM	0,477884	0,632957	Não há diferença
		-		
Economicos	Fundamentalistas_IPCA	0,930744	0,352467	Não há diferença
		-		
Economicos	Fundamentalistas_JUROS	0,595756	0,551627	Não há diferença
Economicos	Fundamentalistas	0,355599	0,722301	Não há diferença
		-		
Economicos	Fundamentalistas_PIB	0,163868	0,869906	Não há diferença
		-		Médias
Economicos	Fundamentalistas_Tecnicas	10,849946	0,000000	Diferentes
		-		Médias
Economicos	Tecnicas_Cambio	11,587926	0,000000	Diferentes
		-		Médias
Economicos	Tecnicas_Economicas	10,041268	0,000000	Diferentes
		-		Médias
Economicos	Tecnicas_IGPM	11,041547	0,000000	Diferentes
		-		Médias
Economicos	Tecnicas_IPCA	10,756449	0,000000	Diferentes
		-		Médias
Economicos	Tecnicas_JUROS	11,783833	0,000000	Diferentes
		-		Médias
Economicos	Tecnicas_PIB	11,357967	0,000000	Diferentes
		-		Médias
Economicos	Tecnicos	12,152468	0,000000	Diferentes
		-		Médias
Economicos	Todos	9,649824	0,000000	Diferentes
		-		
Fundamentalistas	Fundamentalistas_PIB	0,644971	0,519263	Não há diferença
		-		Médias
Fundamentalistas	Fundamentalistas_Tecnicas	9,113036	0,000000	Diferentes
		-		Médias
Fundamentalistas	Tecnicas_Cambio	8,493981	0,000000	Diferentes
		-		Médias
Fundamentalistas	Tecnicas_Economicas	7,052464	0,000000	Diferentes
		-		Médias
Fundamentalistas	Tecnicas_IGPM	7,894985	0,000000	Diferentes

		-		Médias
Fundamentalistas	Tecnicas_IPCA	7,777976	0,000000	Diferentes
		-		Médias
Fundamentalistas	Tecnicas_JUROS	8,397584	0,000000	Diferentes
		-		Médias
Fundamentalistas	Tecnicas_PIB	8,181343	0,000000	Diferentes
		-		Médias
Fundamentalistas	Tecnicos	8,803676	0,000000	Diferentes
		-		Médias
Fundamentalistas	Todos	7,584680	0,000000	Diferentes
Fundamentalistas	Economicos	0,355599	0,722301	Não há diferença
				Médias
Fundamentalistas	FT_Cambio	8,969189	0,000000	Diferentes
				Médias
Fundamentalistas	FT_Economicos	7,774312	0,000000	Diferentes
				Médias
Fundamentalistas	FT_IGPM	8,508882	0,000000	Diferentes
				Médias
Fundamentalistas	FT_IPCA	8,237179	0,000000	Diferentes
				Médias
Fundamentalistas	FT_JUROS	8,950205	0,000000	Diferentes
				Médias
Fundamentalistas	FT_PIB	8,528661	0,000000	Diferentes
				Médias
Fundamentalistas	Fundamentalistas_Cambio	2,020142	0,043939	Diferentes
Fundamentalistas	Fundamentalistas_IGPM	1,534870	0,125493	Não há diferença
				Médias
Fundamentalistas	Fundamentalistas_IPCA	2,075730	0,038466	Diferentes
Fundamentalistas	Fundamentalistas_JUROS	1,828976	0,068041	Não há diferença
		-		
Fundamentalistas	FundamentalistasEconomicos	1,102033	0,271015	Não há diferença
		-		
Fundamentalistas_Tecnicas	Tecnicas_Cambio	1,354819	0,176130	Não há diferença
				Médias
Fundamentalistas_Tecnicas	Tecnicas_Economicas	3,120278	0,001919	Diferentes
Fundamentalistas_Tecnicas	Tecnicas_IGPM	0,533795	0,593737	Não há diferença
Fundamentalistas_Tecnicas	Tecnicas_IPCA	1,187728	0,235544	Não há diferença
		-		
Fundamentalistas_Tecnicas	Tecnicas_JUROS	1,083420	0,279181	Não há diferença
		-		
Fundamentalistas_Tecnicas	Tecnicas_PIB	0,600828	0,548246	Não há diferença
		-		Médias
Fundamentalistas_Tecnicas	Tecnicos	2,683170	0,007552	Diferentes
				Médias
Fundamentalistas_Tecnicas	Todos	4,082807	0,000052	Diferentes

		-		Médias
Fundamentalistas_Tecnicas	Economicos	10,849946	0,000000	Diferentes
		-		
Fundamentalistas_Tecnicas	FT_Cambio	1,201916	0,230005	Não há diferença
		-		Médias
Fundamentalistas_Tecnicas	FT_Economicos	3,463412	0,000582	Diferentes
		-		
Fundamentalistas_Tecnicas	FT_IGPM	1,386578	0,166232	Não há diferença
		-		Médias
Fundamentalistas_Tecnicas	FT_IPCA	2,943186	0,003410	Diferentes
		-		
Fundamentalistas_Tecnicas	FT_JUROS	0,691689	0,489476	Não há diferença
		-		Médias
Fundamentalistas_Tecnicas	FT_PIB	2,240424	0,025533	Diferentes
		-		Médias
Fundamentalistas_Tecnicas	Fundamentalistas	9,113036	0,000000	Diferentes
		-		Médias
Fundamentalistas_Tecnicas	Fundamentalistas_Cambio	8,998474	0,000000	Diferentes
		-		Médias
Fundamentalistas_Tecnicas	Fundamentalistas_IGPM	9,512515	0,000000	Diferentes
		-		Médias
Fundamentalistas_Tecnicas	Fundamentalistas_IPCA	8,740439	0,000000	Diferentes
		-		Médias
Fundamentalistas_Tecnicas	Fundamentalistas_JUROS	7,415493	0,000000	Diferentes
		-		Médias
Fundamentalistas_Tecnicas	Fundamentalistas_PIB	7,836962	0,000000	Diferentes
		-		Médias
Fundamentalistas_Tecnicas	FundamentalistasEconomicos	10,371738	0,000000	Diferentes
				Médias
Tecnicos	Todos	6,037878	0,000000	Diferentes
		-		Médias
Tecnicos	Economicos	12,152468	0,000000	Diferentes
		-		Médias
Tecnicos	FT_Cambio	3,659186	0,000282	Diferentes
		-		Médias
Tecnicos	FT_Economicos	5,379127	0,000000	Diferentes
		-		Médias
Tecnicos	FT_IGPM	3,701290	0,000240	Diferentes
		-		Médias
Tecnicos	FT_IPCA	4,862538	0,000002	Diferentes
		-		Médias
Tecnicos	FT_JUROS	3,489197	0,000530	Diferentes
		-		Médias
Tecnicos	FT_PIB	4,277719	0,000023	Diferentes
		-		Médias
Tecnicos	Fundamentalistas	8,803676	0,000000	Diferentes
		-		Médias
Tecnicos	Fundamentalistas_Cambio	8,726731	0,000000	Diferentes
		-		Médias
Tecnicos	Fundamentalistas_IGPM	8,949550	0,000000	Diferentes

		-		Médias
Tecnicos	Fundamentalistas_IPCA	8,496613	0,000000	Diferentes
		-		Médias
Tecnicos	Fundamentalistas_JUROS	7,159335	0,000000	Diferentes
		-		Médias
Tecnicos	Fundamentalistas_PIB	7,668422	0,000000	Diferentes
		-		Médias
Tecnicos	Fundamentalistas_Tecnicas	2,683170	0,007552	Diferentes
		-		Médias
Tecnicos	FundamentalistasEconomicos	9,871078	0,000000	Diferentes
		-		
Tecnicos	Tecnicas_Cambio	1,843773	0,065849	Não há diferença
		-		Médias
Tecnicos	Tecnicas_Economicas	6,234909	0,000000	Diferentes
		-		Médias
Tecnicos	Tecnicas_IGPM	3,985800	0,000078	Diferentes
		-		Médias
Tecnicos	Tecnicas_IPCA	4,499630	0,000009	Diferentes
		-		Médias
Tecnicos	Tecnicas_JUROS	2,399142	0,016825	Diferentes
		-		Médias
Tecnicos	Tecnicas_PIB	3,670135	0,000270	Diferentes

Fonte: Elaborada pelo autor.

TABELA 23 – TESTE-T – MÉTRICA - CORRELAÇÃO

Modelo A	Modelo B	t_stat	p_valor	resultado
		-		Médias
Economicos	FT_IGPM	10,41152487	5,73025E-23	diferentes
		-		Médias
Economicos	FT_IPCA	9,921825234	3,50859E-21	diferentes
		-		Médias
Economicos	FT_JUROS	10,81491217	1,76698E-24	diferentes
		-		Médias
Economicos	FT_PIB	-10,1844498	3,92115E-22	diferentes
		-		Não há
Economicos	FundamentalistasEconomicos	1,351949651	0,177045813	diferença
		-		Não há
Economicos	Fundamentalistas_Cambio	0,887491611	0,375271117	diferença
		-		Não há
Economicos	Fundamentalistas_IGPM	0,477883691	0,632956596	diferença
		-		Não há
Economicos	Fundamentalistas_IPCA	0,930744324	0,352466718	diferença
		-		Não há
Economicos	Fundamentalistas_JUROS	0,595755747	0,551627025	diferença
		-		Não há
Economicos	Fundamentalistas	0,355599008	0,722301451	diferença
		-		Não há
Economicos	Fundamentalistas_PIB	0,163867555	0,869906304	diferença
		-		Médias
Economicos	Fundamentalistas_Tecnicas	10,84994585	1,30141E-24	diferentes

Economicos	Tecnicas_Cambio	11,58792606	1,82172E-27	-	Médias diferentes
Economicos	Tecnicas_Economicas	10,04126776	1,30082E-21	-	Médias diferentes
Economicos	Tecnicas_IGPM	-11,041547	2,41904E-25	-	Médias diferentes
Economicos	Tecnicas_IPCA	10,75644888	2,93978E-24	-	Médias diferentes
Economicos	Tecnicas_JUROS	11,78383279	3,05962E-28	-	Médias diferentes
Economicos	Tecnicas_PIB	11,35796658	1,44875E-26	-	Médias diferentes
Economicos	Tecnicos	12,15246779	1,02177E-29	-	Médias diferentes
Economicos	Todos	-9,64982387	3,26712E-20	-	Médias diferentes
Fundamentalistas	Fundamentalistas_PIB	0,644970794	0,519262825	-	Não há diferença
Fundamentalistas	Fundamentalistas_Tecnicas	9,113035987	2,36911E-18	-	Médias diferentes
Fundamentalistas	Tecnicas_Cambio	8,493981237	2,68979E-16	-	Médias diferentes
Fundamentalistas	Tecnicas_Economicas	7,052463802	6,36862E-12	-	Médias diferentes
Fundamentalistas	Tecnicas_IGPM	7,894984557	2,08969E-14	-	Médias diferentes
Fundamentalistas	Tecnicas_IPCA	7,777975926	4,75944E-14	-	Médias diferentes
Fundamentalistas	Tecnicas_JUROS	8,397584052	5,50322E-16	-	Médias diferentes
Fundamentalistas	Tecnicas_PIB	8,181343035	2,68412E-15	-	Médias diferentes
Fundamentalistas	Tecnicos	8,803676071	2,59467E-17	-	Médias diferentes
Fundamentalistas	Todos	7,584680463	1,8172E-13	-	Médias diferentes
Fundamentalistas	Economicos	0,355599008	0,722301451	-	Não há diferença
Fundamentalistas	FT_Cambio	8,969189045	7,26078E-18	-	Médias diferentes
Fundamentalistas	FT_Economicos	7,774311737	4,883E-14	-	Médias diferentes
Fundamentalistas	FT_IGPM	8,508881801	2,40678E-16	-	Médias diferentes
Fundamentalistas	FT_IPCA	8,237179243	1,78788E-15	-	Médias diferentes
Fundamentalistas	FT_JUROS	8,950205111	8,40971E-18	-	Médias diferentes
Fundamentalistas	FT_PIB	8,528660587	2,07614E-16	-	Médias diferentes

Fundamentalistas	FundamentalistasEconomicos	1,102033198	0,271014867	-	Não há diferença Médias
Fundamentalistas	Fundamentalistas_Cambio	2,020142452	0,043939045	-	diferentes Médias
Fundamentalistas	Fundamentalistas_IGPM	1,534870135	0,125492914	-	Não há diferença Médias
Fundamentalistas	Fundamentalistas_IPCA	2,075729539	0,038465642	-	diferentes Médias
Fundamentalistas	Fundamentalistas_JUROS	1,828976182	0,068040721	-	Não há diferença Médias
Fundamentalistas_Tecnicas	Tecnicas_Cambio	1,354818516	0,176130418	-	Não há diferença Médias
Fundamentalistas_Tecnicas	Tecnicas_Economicas	3,120277968	0,001918692	-	diferentes Médias
Fundamentalistas_Tecnicas	Tecnicas_IGPM	0,533795068	0,593737305	-	Não há diferença Médias
Fundamentalistas_Tecnicas	Tecnicas_IPCA	1,187728171	0,235544253	-	Não há diferença Médias
Fundamentalistas_Tecnicas	Tecnicas_JUROS	1,083420498	0,279180869	-	Não há diferença Médias
Fundamentalistas_Tecnicas	Tecnicas_PIB	0,600827802	0,548246173	-	diferentes Médias
Fundamentalistas_Tecnicas	Tecnicos	2,683169645	0,007551638	-	diferentes Médias
Fundamentalistas_Tecnicas	Todos	4,082806971	5,2345E-05	-	diferentes Médias
Fundamentalistas_Tecnicas	Economicos	10,84994585	1,30141E-24	-	diferentes Médias
Fundamentalistas_Tecnicas	FT_Cambio	1,201915565	0,230005364	-	Não há diferença Médias
Fundamentalistas_Tecnicas	FT_Economicos	3,463412295	0,000582492	-	diferentes Médias
Fundamentalistas_Tecnicas	FT_IGPM	1,386577841	0,166232078	-	Não há diferença Médias
Fundamentalistas_Tecnicas	FT_IPCA	2,943186295	0,003410316	-	diferentes Médias
Fundamentalistas_Tecnicas	FT_JUROS	0,691689129	0,4894763	-	Não há diferença Médias
Fundamentalistas_Tecnicas	FT_PIB	-2,24042362	0,025532898	-	diferentes Médias
Fundamentalistas_Tecnicas	FundamentalistasEconomicos	10,37173751	8,04144E-23	-	diferentes Médias
Fundamentalistas_Tecnicas	Fundamentalistas_Cambio	8,998473602	5,78614E-18	-	diferentes Médias
Fundamentalistas_Tecnicas	Fundamentalistas_IGPM	9,512514726	9,92488E-20	-	diferentes Médias
Fundamentalistas_Tecnicas	Fundamentalistas_IPCA	8,740439146	4,20266E-17	-	diferentes Médias
Fundamentalistas_Tecnicas	Fundamentalistas_JUROS	7,415493123	5,74995E-13	-	diferentes Médias

		-		Médias
Fundamentalistas_Tecnicas	Fundamentalistas	9,113035987	2,36911E-18	diferentes
		-		Médias
Fundamentalistas_Tecnicas	Fundamentalistas_PIB	7,836961748	3,14659E-14	diferentes
				Médias
Tecnicos	Todos	6,037878017	3,18772E-09	diferentes
		-		Médias
Tecnicos	Economicos	12,15246779	1,02177E-29	diferentes
		-		Médias
Tecnicos	FT_Cambio	3,659185703	0,00028187	diferentes
		-		Médias
Tecnicos	FT_Economicos	5,379127138	1,18582E-07	diferentes
		-		Médias
Tecnicos	FT_IGPM	3,701289943	0,000240089	diferentes
		-		Médias
Tecnicos	FT_IPCA	4,862537828	1,58616E-06	diferentes
		-		Médias
Tecnicos	FT_JUROS	3,489197214	0,000530387	diferentes
		-		Médias
Tecnicos	FT_PIB	4,277719422	2,29141E-05	diferentes
		-		Médias
Tecnicos	FundamentalistasEconomicos	9,871078399	5,33613E-21	diferentes
		-		Médias
Tecnicos	Fundamentalistas_Cambio	8,726730652	4,66433E-17	diferentes
		-		Médias
Tecnicos	Fundamentalistas_IGPM	8,949550318	8,4524E-18	diferentes
		-		Médias
Tecnicos	Fundamentalistas_IPCA	8,496612512	2,63752E-16	diferentes
		-		Médias
Tecnicos	Fundamentalistas_JUROS	7,159335003	3,16781E-12	diferentes
		-		Médias
Tecnicos	Fundamentalistas	8,803676071	2,59467E-17	diferentes
		-		Médias
Tecnicos	Fundamentalistas_PIB	7,668421949	1,02016E-13	diferentes
		-		Médias
Tecnicos	Fundamentalistas_Tecnicas	2,683169645	0,007551638	diferentes
		-		Não há
Tecnicos	Tecnicas_Cambio	1,843773481	0,065849488	diferença
		-		Médias
Tecnicos	Tecnicas_Economicas	6,234908647	1,01235E-09	diferentes
		-		Médias
Tecnicos	Tecnicas_IGPM	-3,98579994	7,80195E-05	diferentes
		-		Médias
Tecnicos	Tecnicas_IPCA	4,499629855	8,6031E-06	diferentes
		-		Médias
Tecnicos	Tecnicas_JUROS	2,399142095	0,016824542	diferentes
		-		Médias
Tecnicos	Tecnicas_PIB	3,670135027	0,000270391	diferentes

Fonte: Elaborada pelo autor.

APENDICE F - Gráficos dos Coeficientes de Determinação R2 – Para Modelos Treinados com os Indicadores Base




Figura 7 - Coeficiente de Correlação - Modelos Treinados com Indicadores Econômicos
Fonte: Elaborada pelo autor.

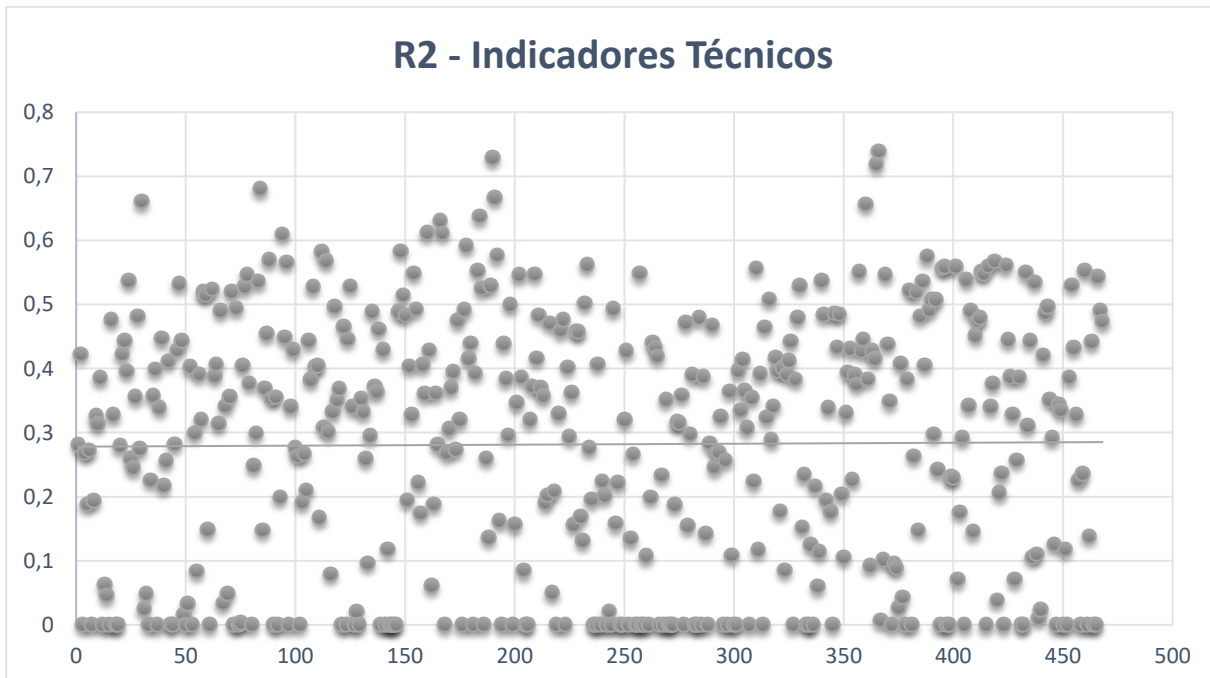


Figura 8 - Coeficiente de Correlação - Modelos Treinados com Indicadores Técnicos
Fonte: Elaborada pelo autor.




Figura 9 - Coeficiente de Correlação - Modelos Treinados com Indicadores Fundamentalistas
Fonte: Elaborada pelo autor.

APENDICE G - Gráficos dos Coeficientes de Determinação R2 – Para Modelos Treinados com Indicadores Base e Indicadores de Expectativas Econômicas




Figura 10 - Coeficiente de Correlação - Modelos Treinados com Indicadores Base e Expectativas Econômicas
Fonte: Elaborada pelo autor.




Figura 10 - Coeficiente de Correlação - Modelos Treinados com Indicadores Fundamentalistas e Econômicos
 Fonte: Elaborada pelo autor.

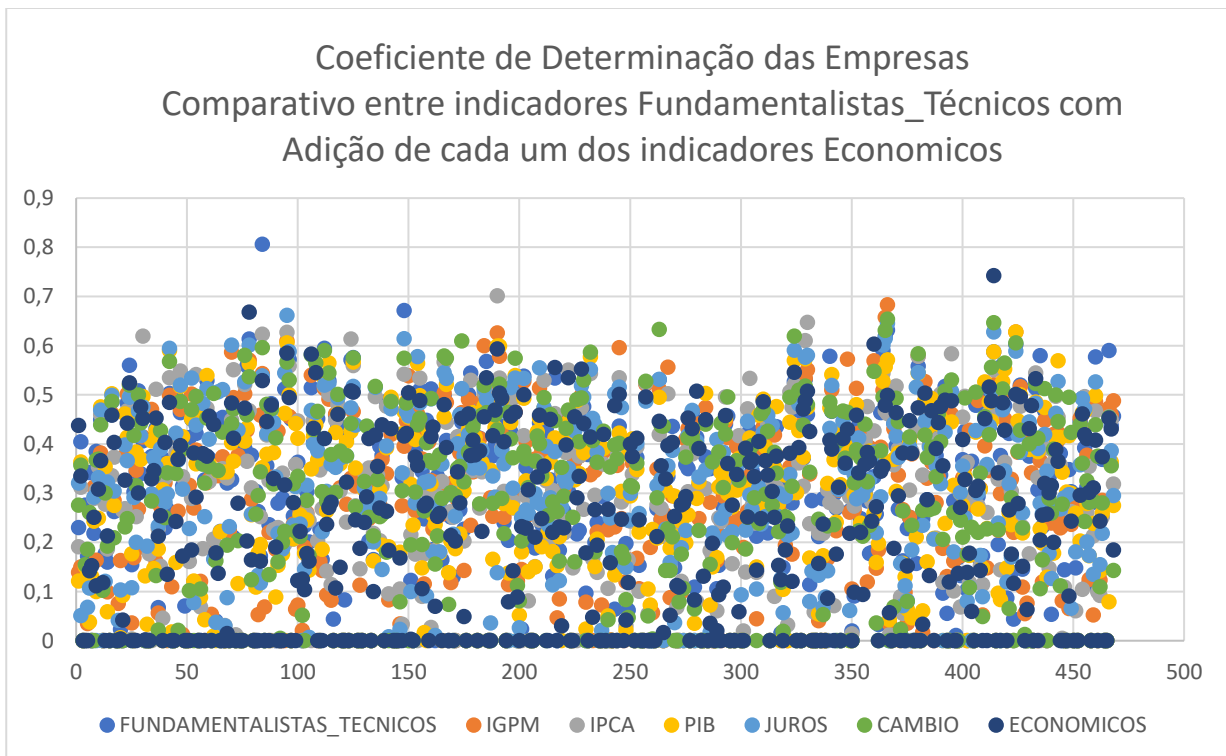


Figura 11 - Coeficiente de Correlação - Modelos Treinados com Indicadores F
 Fonte: Elaborada pelo autor.