

Macroeconomia e B3: aplicação de árvores de decisão na seleção dos setores econômicos

Tamires Pimentel Torres^a
José Freitas Alves Neto^a
Luiz Fernando Gonçalves Viana^a

^a Universidade de Fortaleza, UNIFOR. Brasil

Resumo: Este artigo tem como objetivo desenvolver um modelo de *machine learning* que permita a identificação de setores econômicos listados na B3 com maior potencial de retorno a partir da conjuntura econômica do momento. Foi aplicada o algoritmo de árvores de decisão para identificação de padrões macroeconômicos na recomendação de vários analistas CNPI ao longo de 2010 a 2015. Foram utilizadas 14 variáveis macroeconômicas disponíveis nas bases de dados do Bacen e do Ipea. Os resultados demonstram que diante do cenário econômico atual, o algoritmo recomenda a alocação de recursos em instrumentos de renda fixa.

Palavras - chave: Variáveis Macroeconômicas. Árvore de decisão. Machine Learning. Bolsa de Valores. Setores Econômicos.

JEL: G11, C53, E37

1. INTRODUÇÃO

A macroeconomia desempenha um papel crucial ao analisar as principais variáveis econômicas em uma sociedade. Observando o cenário econômico do país, pode-se perceber como essas variáveis interagem diante da conjuntura em constante mudança e como estas impactam os setores produtivos da economia afetando diretamente, positiva ou negativamente, as empresas e os agentes econômicos. Ao analisar as empresas de capital aberto listadas na B3, notam-se impactos significativos que podem representar oportunidades ou riscos para os investidores. Estudos indicam que o mercado de capitais está diretamente ligado ao comportamento das variáveis macroeconômicas (Bernardelli et al., 2020). Jacques, Borges e Miranda (2020) destacam que variáveis como câmbio e PIB demonstram maior associação com os indicadores econômico-financeiros dos segmentos empresariais da B3, evidenciando que diferentes setores respondem de maneira distinta às flutuações econômicas. Antes de analisar os fundamentos da empresa é necessário entender e estudar os dados

econômicos, observando como as empresas absorvem informações dessas variáveis e como isso se reflete no preço das ações, pois alguns negociadores baseiam suas decisões no mercado conforme os indicadores econômicos. A análise setorial permite avaliar como as variáveis macroeconômicas impactam o desempenho das empresas, uma vez que cada setor possui características próprias e responde de forma diferenciada às oscilações da economia.

Dessa forma, a incorporação de indicadores macroeconômicos na avaliação financeira contribui para uma análise mais precisa e fundamentada (MARTINS, 2001; ASSAF NETO, 2015). É necessário estudar tanto os dados da empresa quanto os macroeconômicos. Este artigo tem como objetivo desenvolver um modelo de *machine learning* que permita a identificação de setores econômicos listados na B3 com maior potencial de retorno a partir da conjuntura econômica do momento. Para atingir este objetivo, será necessário analisar e compreender as inter-relações entre variáveis macroeconômicas tais como Produto Interno Bruto (PIB), inflação, taxa de juros, dentre outras para compreender seus impactos nos setores econômicos da B3.

Os dados para desenvolver esta pesquisa foram obtidos no Banco Central do Brasil (BACEN) e no Instituto de Pesquisas Econômicas Aplicadas (Ipea) no período de 2010 a 2015. Por meio da aplicação de técnicas de machine learning, especificamente o modelo de árvore de decisão, busca-se identificar padrões e correlações que permitam a seleção de ativos a partir de indicadores macroeconômicos. A escolha da árvore de decisão justifica-se por sua capacidade de modelar relações não lineares e fornecer interpretações claras, permitindo uma análise robusta e acessível dos efeitos macroeconômicos no desempenho setorial (Gambim et al, 2023; Morettin e Singer, 2025). Este trabalho está estruturado em mais três capítulos, além desta introdução. A próxima seção aborda o referencial teórico onde são apresentados os principais conceitos e usos do critério de análise fundamentalista de ações e das principais variáveis macroeconômicas utilizadas em estudos anteriores, além de expor os conceitos fundamentais e utilização de ciência de dados no mercado financeiro.

2. REFERENCIAL TEÓRICO

2.1 ANÁLISE FUNDAMENTALISTA

A escolha de um ativo para alocação pode, muitas vezes, apresentar um caráter subjetivo, ou intuitivo, mas que segundo Assaf Neto (2023) é imprescindível uma análise mais formal (objetiva) desses ativos para que haja uma racionalidade que dê respaldo à

escolha. Segundo o autor, existem dois modelos de análise para a escolha de ações. A análise técnica utiliza os gráficos com o objetivo de interpretar o mercado para prever os movimentos futuros dos preços com maior probabilidade de acerto. Por outro lado, a análise fundamentalista utiliza uma série de variáveis macro e microeconômicas para projetar o preço-alvo, ou preço justo, de determinada ação (Lemos, 2025). Dentre essas variáveis, o autor cita a taxa de juros, as demonstrações financeiras, o risco-país e as projeções macro e microeconômicas. Para Apimec e CVM (2025) dentre os fins da análise fundamentalista está a obtenção de um valor justo para a empresa, ou seja, para a ação. Os autores esclarecem, ainda, que valor justo e preço são conceitos diferentes. Apesar do preço ser uma referência de uma ação listada em bolsa, ele pode não refletir o valor justo (ou valor real) das ações. A análise fundamentalista representa uma ferramenta para avaliar se o preço da ação reflete o valor justo da empresa.

Segundo Pinheiro (2025) a análise fundamentalista surgiu entre o final do século XIX e começo do século XX. Entretanto, o termo só foi criado de fato após um curso ministrado por Benjamin Graham, em 1929, na Universidade de Colúmbia, em Nova York. A ideia revolucionária de Graham foi propor a identificação de um valor intrínseco para a ação a partir das expectativas dos benefícios que o ativo poderia proporcionar. Para Assaf Neto (2023) o critério fundamentalista está baseado na hipótese de Graham de que existe um valor intrínseco para cada ação que está relacionado com o desempenho econômico e financeiro da empresa, bem como no seu setor de atuação, além do cenário macroeconômico. A análise, portanto, considera tanto aspectos internos quanto externos. Pinheiro (2025) define a análise fundamentalista como importante instrumento para análise das ações que utiliza os fundamentos econômico-financeiros da empresa para determinação do seu valor.

O autor considera ainda que o critério fundamentalista utiliza toda informação disponível no mercado sobre a empresa para identificar seu verdadeiro valor. Barros (2015) cita que a análise fundamentalista é utilizada por investidores com objetivo de avaliar o valor inerente de uma ativo, e assim maximizar seus acertos no mercado acionário. Segundo o autor, a análise é um estudo da situação financeira das empresas e de suas perspectivas futuras de crescimento e que podem se refletir na valorização do papel no futuro. Neste sentido, o critério fundamentalista pode ser utilizado para definir qual ativo deve ser comprado ou vendido pelo investidor.

Assaf Neto (2023) cita que no processo de análise fundamentalista existem dois enfoques. O primeiro é o enfoque *top-down* em que o analista tem como referência inicial o ambiente macroeconômico, ou seja, a análise parte do geral (ambiente macroeconômico) para

entender o específico (empresa). Para tanto, são utilizadas as principais variáveis macroeconômicas tais como PIB, taxa de juros, inflação, dentre outras. O segundo enfoque, chamado *bottom-up*, apresenta uma direção inversa ao primeiro, partindo-se do específico (empresa) para o geral (ambiente macroeconômico). O mais importante para este enfoque são os fundamentos da empresa, seu desempenho histórico e perspectivas de crescimento.

Apimec e CVM (2025) corroboram com a divisão da análise fundamentalista nos dois enfoques. No enfoque *top-down* o analista deve iniciar pela análise da economia de forma geral, tanto local quanto global, para identificar os setores que serão impactados, positiva e negativamente, pelo cenário econômico de momento. Só então, deve-se analisar a empresa que apresenta os melhores fundamentos para enfrentar o cenário vigente. Portanto, este enfoque representa uma análise de fora para dentro. Os autores reforçam que diante de uma economia globalizada é importante levar em consideração o impacto das tendências globais sobre o desempenho da empresa. Por outro lado, no enfoque *bottom-up* os analistas buscam analisar, dentre outras informações, os demonstrativos financeiros, a qualidade da gestão e seus riscos para compará-los com outras empresas listadas. Rudink et al (2013) distinguem o uso dos enfoques a partir do perfil do investidor. Para os autores, o enfoque *top-down* é mais utilizado por gestores profissionais (*asset managements*) enquanto o enfoque *bottom-up* seria mais utilizado por investidores individuais. Para Pinheiro (2025) o processo decisório da análise fundamentalista passa primeiro pela análise do ambiente macroeconômico e seu impacto sobre o setor em que atua e, na sequência, deve-se identificar os principais *drivers* que respondem pelo valor da empresa. Assim, será possível identificar o valor intrínseco, ou valor justo, da empresa. A Figura 1 apresenta um esboço sucinto do enfoque *top-down*:



De acordo com esse enfoque, a decisão de recomendação de compra ou venda vai depender da comparação entre o preço de mercado da ação (P) e o valor intrínseco (VI): caso o preço esteja abaixo do VI, deve-se comprar a ação; caso P esteja acima de VI, deve-se vender. Por fim, caso P esteja igual a VI, não se deve fazer nada (Pinheiro, 2025).

2.2 VARIÁVEIS MACROECONÔMICAS

Conforme descrito acima, no enfoque *top-down* a primeira camada da análise são as variáveis macroeconômicas que impactam a empresa e seu setor de atuação. No âmbito conceitual, Kobori (2025) afirma que tanto as pessoas quanto as empresas estão subordinadas às políticas macroeconômicas globais e nacionais, uma vez que são estas políticas que definem o “preço” do dinheiro na economia e, portanto, impactam todos os custos da economia através de uma cadeia de transmissão. Enquanto a taxa de juros define o custo do dinheiro, a taxa de câmbio define os custos dos importadores e as receitas dos exportadores, a inflação e o desemprego impactam o nível de vendas das empresas. A análise do ambiente macroeconômico deve ser a primeira análise a ser realizada, uma vez que suas operações deverão ser afetadas a partir das mudanças dessa conjuntura. Segundo Apimec e CVM (2025) deve-se levar em conta uma série de variáveis macroeconômicas na análise.

Dentre elas, os autores citam o PIB, a inflação, a carga tributária, taxa de juros, câmbio e o nível de emprego. Para Madaleno et al (2019) as informações necessárias para o investimento em ações são o PIB, a inflação, o déficit público, o déficit comercial, a balança de transações correntes e o desemprego. Bastardo (2015) cita a importância de se estudar os ciclos econômicos para antecipar o comportamento dos mercados financeiros em busca dos ativos mais adequados a cada fase do ciclo. Neste sentido, o autor cita as principais variáveis macroeconômicas que devem compor a análise: PIB, procura, oferta, desemprego, inflação e taxa de juros. Pelo exposto acima pode-se perceber que, no âmbito conceitual, a literatura concorda que o ambiente macroeconômico exerce grande influência sobre os resultados das empresas e devem ser considerados em qualquer tipo de análise fundamentalista, seja pelo enfoque *top-down*, seja pelo enfoque *bottom-up*.

Entretanto, grande parte das pesquisas que tratam sobre análise fundamentalista concentra-se no uso de informações microeconômicas, ou seja, tomam por base informações econômicas e financeiras das empresas (indicadores). Poucos trabalhos foram desenvolvidos

para analisar o impacto das variáveis macroeconômicas sobre o retorno de investimento realizados em ações das empresas listadas em bolsa de valores.

Dentre esses escassos trabalhos, Barbosa e Nogueira (2018) avaliaram a influência de variáveis macroeconômicas sobre o setor de alimentos de 2010 a 2016. Os autores utilizaram uma regressão com dados em painel utilizando o PIB, a taxa Selic, a taxa de câmbio, o Índice de Confiança do Empresário Industrial e o Índice Nacional de Preços ao Consumidor Amplo (IPCA). Os resultados mostraram que a taxa Selic e a taxa de desemprego possuem significância para o ROA (*Return on Assets*) e ML (Margem Líquida), enquanto o IPCA mostrou-se significativo estatisticamente para o ROE (*Return on Equity*). Andrade, Muntaser e Prado (2022) identificaram que a Selic causa impactos negativos sobre os preços das ações das empresas do setor financeiro da B3, enquanto o PIB mostrou-se positivamente correlacionado aos preços.

Os autores aplicaram um modelo de regressão linear com dados em painel entre 2011 e 2020 que incluía como variáveis dependentes, além da Selic e PIB, a taxa de câmbio, inflação e desemprego. Costa e Costa (2028) realizaram uma análise utilizando algoritmos de seleção de modelos autometrics para analisar os impactos de 26 variáveis macroeconômicas domésticas e internacionais sobre o retorno das ações de índices setoriais da B3.

Os resultados demonstraram que em relação às variáveis internacionais as ações brasileiras são impactadas positivamente pelas variações do *Dow Jones Index* e negativamente pelo índice de volatilidade das ações americanas (VIX). Quanto às variáveis nacionais, observou-se uma relação negativa entre a taxa de câmbio e os índices setoriais.

2.3 CIÊNCIA DE DADOS

Para atingir o objetivo deste trabalho de identificação de setores econômicos da B3 que podem beneficiar-se da conjuntura econômica no momento de uma análise serão aplicados métodos relacionados à ciência de dados. A ciência de dados estuda e aplica técnicas para extrair conhecimento novo, relevante e útil de grandes conjuntos de fluxos de dados para apoiar a tomada de decisão (Carvalho, 2025).

Apesar de o termo parecer um conceito novo, Morettin e Singer (2025) provocam a reflexão de que há mais de 200 anos os estatísticos trabalham com a análise de um vasto conjunto de dados provenientes das mais diversas fontes que apresentam como principal característica a análise de grandes conjuntos de dados (megadados).

Para os autores, a ciência de dados serve para “...a formulação de soluções computacionais para transformação, pré-processamento e modelagem de dados que permitam extrair conhecimento de um conjunto de dados”. Dentre os vários temas e conceitos relacionados à ciência de dados, este trabalho irá aplicar técnica de aprendizado de máquina (*machine learning*) que segundo Carvalho (2025) é útil na construção de modelos capazes de extrair conhecimento de um conjunto de dados. O autor subdivide o aprendizado de máquina em quatro grandes abordagens: i) supervisionado; ii) não supervisionado; iii) semi-supervisionado; e iv) por reforço.

O aprendizado supervisionado busca um modelo que seja capaz de realizar corretamente previsões de valores (saída) a partir de um conjunto de dados de entrada, mediante a apresentação da saída esperada (que faz o papel de supervisor). Basicamente, são modelos preditivos muito utilizados na inferência estatística. No caso dos modelos não supervisionados, estes não utilizam uma variável de saída (alvo) e são bastante úteis para organização, descrição de associações e identificação de padrões. Não há distinção entre variáveis preditoras ou variáveis de respostas (alvo ou saída) (Carvalho, 2025; Morettin e Singer, 2025).

A terceira abordagem, semi-supervisionada, é utilizada para conjuntos de dados parcialmente rotulados, ou seja, apenas um subconjunto dos dados possui valor para a variável alvo. Por fim, na quarta abordagem, aprendizado por reforço, o algoritmo aprende por repetição, observando as consequências de decisões tomadas com o fim de maximizar recompensas e penalizando os resultados indesejados (Carvalho, 2025; Morettin e Singer, 2025). Existem vários métodos de aprendizado supervisionado.

Dentre elas, optou-se pelo uso de árvores de decisão para o desenvolvimento deste trabalho que é um dos mais utilizados no âmbito do aprendizado de máquina supervisionado. O modelo é útil tanto para problemas de classificação quanto de previsão (Gambim et al, 2023; Morettin e Singer, 2025) e será melhor detalhado na seção da metodologia. Nesse contexto, o método de árvore de decisão é um modelo preditivo amplamente utilizado em estatística e aprendizagem de máquina para classificar dados e prever resultados.

Sua estrutura hierárquica facilita a interpretação e aplicação em diversas áreas, como finanças, medicina, economia e marketing. Além de lidar bem com dados não lineares, apresenta baixa necessidade de pré-processamento e mostra eficiência quando aplicado a grandes volumes de informações. Segundo Quinlan (1996), “as árvores de decisão são uma ferramenta poderosa para a construção de modelos explicativos e preditivos, permitindo a identificação de padrões e tendências a partir de dados históricos”.

3. METODOLOGIA

Para desenvolver este estudo foi utilizado um modelo de aprendizado de máquina supervisionado, conhecido como árvore de decisão, no qual o algoritmo é treinado a partir de um conjunto de variáveis preditivas, supervisionadas por uma variável *target* (saída). De acordo com o referencial teórico descrito acima, foram escolhidas 14 variáveis macroeconômicas candidatas a preditoras de uma variável *target* binária que indica se a ação teve recomendação de venda ou compra. A Tabela 1 apresenta o conjunto de variáveis utilizadas no modelo, suas respectivas fontes de dados e APIs:

Quadro 1 - Variáveis utilizadas no modelo

API	Variável	Fonte
4380	Produto Interno Bruto - PIB	Banco Central do Brasil - Bacen
433	Índice Nacional de Preços ao Consumidor Amplo - IPCA	Banco Central do Brasil - Bacen
189	Índice Geral de Preços do Mercado - IGP-M	Banco Central do Brasil - Bacen
22701	Conta Corrente	Banco Central do Brasil - Bacen
3697	Taxa de Câmbio Mensal	Banco Central do Brasil - Bacen
22885	Investimento Direto no País	Banco Central do Brasil - Bacen
4649	Resultado Primário	Banco Central do Brasil - Bacen

4006	Resultado Nominal	Banco Central do Brasil - Bacen
4469	Dívida Líquida do Setor Público	Banco Central do Brasil - Bacen
4390	Taxa Selic	Banco Central do Brasil - Bacen
22707	Balança Comercial Saldo	Banco Central do Brasil - Bacen
22708	Balança Comercial Exportação	Banco Central do Brasil - Bacen
22709	Balança Comercial Importação	Banco Central do Brasil - Bacen
-	Taxa de Desemprego	Instituto de Pesquisa Econômica Aplicada - IPEA

Fonte: Elaborado pelos autores.

O mercado financeiro exige análises ágeis e respostas precisas, o que demanda a modernização constante das atividades para acompanhar a volatilidade dos eventos. Conforme aponta Varian (2014), a integração de ferramentas de ciência de dados na economia é essencial para lidar com o volume e a velocidade das informações atuais, tornando a coleta manual de dados macroeconômicos um processo ultrapassado e ineficiente. Para otimizar essa etapa, foi desenvolvido um script em linguagem R utilizando os pacotes ‘GetBCBData’ (PERLIN, 2020) e ‘ipeadatar’ (FERREIRA et al., 2018), que permitem a extração automática de variáveis diretamente de suas fontes oficiais. O código foi estruturado para coletar os dados simultaneamente e compilá-los em um único *dataframe*, utilizando critérios de periodicidade mensal e intervalos temporais específicos, garantindo, assim, uma base de dados organizada.

O ambiente de desenvolvimento utilizado para a manipulação dos dados, aplicação dos tratamentos e desenvolvimento do modelo preditivo foi a linguagem de programação Python, amplamente reconhecida por sua robustez em projetos de ciência de dados e

aprendizado de máquina. A metodologia adotada para desenvolver a inteligência artificial que “decora” o método de investimento de uma carteira recomendada segue uma sequência estruturada de etapas de tratamento e preparação dos dados, visando a adequada aplicação do algoritmo de árvore de decisão.

Por meio de bibliotecas especializadas, como *Pandas*, *NumPy*, *Scikit-Learn* e *Matplotlib*, foi possível realizar desde o pré-processamento dos dados até a análise de desempenho do modelo. Essa etapa envolveu a verificação e correção de anomalias, preparando o *dataset* para os passos subsequentes.

Na sequência, foram realizadas a identificação e o tratamento de dados, garantindo que tais valores não comprometessem a integridade do processamento. Em seguida, todas as colunas foram convertidas para o tipo *float32*, padronizando a precisão dos dados e otimizando o desempenho computacional durante o treinamento.

Dessa forma, avaliou-se a tabela para identificar e remover colunas que não contribuam com a análise ou que poderiam introduzir ruídos ao modelo. A limpeza visou concentrar a informação apenas nos atributos relevantes para a predição. Foi adotado um percentual de 70% dos dados para treinamento e 30% para teste do modelo. Posteriormente, os dados foram estruturados em variáveis de entrada (X) que significa o conjunto contendo os atributos macroeconômicos, que representam os indicadores utilizados, e a variável alvo (y) que é definida como o setor econômico de cada empresa, que será a classe a ser prevista pelo modelo.

Seguidos de um processo de normalização com *MinMaxScaler*, que assegurou que todas as variáveis atuassem em escalas comparáveis, evitando que diferenças de magnitude influenciassem o desempenho do modelo. Para lidar com o desequilíbrio entre classes, foi aplicada uma técnica de *oversampling*, ajustando o número de amostras para 40 por setor econômico, o que garantiu uma base balanceada para o treinamento.

Com o objetivo de aprimorar a precisão preditiva do modelo, os dados de negociação foram organizados segundo o setor econômico a que cada ativo pertence, segundo a classificação da B3. Essa categorização possibilita não somente a análise segmentada do desempenho das estratégias de trading, mas também a identificação do setor com maior potencial de rentabilidade. Adicionalmente, a coluna que representa o setor econômico de cada ativo foi processada por meio do *Label Encoder*, transformando dados categóricos em representações numéricas compatíveis com os algoritmos de aprendizado supervisionado.

Uma inovação metodológica deste estudo reside na inclusão de variáveis que sinalizam momentos em que não se recomenda a realização de operações de trading (compra

ou venda). Essas variáveis são essenciais para que o modelo possa não apenas indicar o setor econômico ideal para a negociação, mas também recomendar períodos de inatividade, quando o cenário não apresenta condições favoráveis para a entrada no mercado de renda variável.

Durante a fase exploratória dos dados, constatou-se um desbalanceamento significativo na distribuição dos *targets* entre os setores econômicos. A associação dos dados macroeconômicos com as recomendações é realizada mediante a padronização da data das operações para o primeiro dia do mês, garantindo, assim, a coerência temporal entre os indicadores econômicos e o momento da recomendação. A fim de capturar a dinâmica dos indicadores macroeconômicos e torná-los mais informativos para o modelo, foram geradas novas variáveis derivadas dos dados originais. Para cada indicador econômico, os seguintes atributos foram calculados:

Quadro 2 - Relação de variáveis criadas a partir das originais

Variável	Descrição
Média dos últimos 12 meses.	Representa a tendência de longo prazo.
Média do último trimestre.	Fornecer uma visão mais imediata das condições econômicas.
Variação absoluta mês a mês.	Mede as mudanças mensais.
Variação percentual em relação aos últimos 12 meses.	Indica a evolução relativa no contexto anual.
Distância em relação à média dos últimos 12 meses.	Evidencia a dispersão dos valores em torno da média.
Desvio padrão dos últimos 12 meses.	Quantifica a volatilidade histórica.

Fonte: Elaborado pelos autores

Dessa maneira, o modelo passa a receber como entrada um conjunto de atributos que condensam informações estatísticas relevantes, facilitando a identificação de padrões e

tendências do cenário macroeconômico. Para possibilitar a integração dos dados provenientes de fontes distintas, os *targets* (datas associadas às recomendações) foram padronizados para o primeiro dia do mês. Este procedimento assegura que os indicadores macroeconômicos, sempre coletados no início do mês, estejam alinhados temporalmente com as operações. Enquanto alguns setores contavam com até 40 registros (recomendações de compra ou venda), outros apresentavam menos de 10 recomendações.

Para mitigar o viés decorrente dessa discrepância, foi adotada uma estratégia de filtragem que eliminou os setores com menos de 5 registros. Essa decisão resultou na exclusão dos setores de energia, indústria e telecomunicações, que, por não atingirem o limiar mínimo de representatividade (5), poderiam comprometer a robustez do modelo. Portanto, o modelo foi treinado a partir de 159 recomendações (linhas) distribuídas entre os seguintes setores: Petróleo (46), Cíclico (44), Construção/Imobiliário (19), Financeiro (13), ETFs/Índices (10), Tecnologia (9), Não Cíclico (7), Mineração (6) e Saúde (5). Após a realização de todas as etapas de tratamento, integração e engenharia dos dados, os registros foram consolidados em uma única tabela. Cada linha da tabela representa uma recomendação de compra ou venda emitida por um profissional certificado (Certificado Nacional do Profissional de Investimento) vinculado a uma instituição financeira, garantindo a qualidade das recomendações de compra e venda.

4. RESULTADOS E DISCUSSÃO

O resultado do trabalho final foi a criação do algoritmo que pode continuar a ser utilizado para realização de novas recomendações ao longo do tempo, utilizando os dados macroeconômicos atualizados para identificação de setores econômicos com maior potencial de retorno para o investidor. Diante do cenário econômico atual, o modelo recomendou a inatividade, ou seja, não alocar recursos em nenhum dos setores econômicos da B3 (renda variável). Portanto, por exclusão dos ativos de renda variável (inatividade), atualmente o modelo recomenda a alocação de recursos em instrumentos financeiros de renda fixa. A relação entre taxa básica de juros e o impacto sobre a renda fixa e a renda variável já foi vastamente pesquisada em outros estudos recentes.

Moraes (2022) analisou os investimentos realizados pelo Banco Modal entre 2017 e 2021 a partir das demonstrações financeiras do banco e identificou que entre 2017 e 2020 não ocorreram grandes variações nas alocações em renda fixa durante a adoção de uma política monetária expansionista. Entretanto, a partir de 2021 houve um aumento significativo nas

posições em renda fixa que autor atribui à política monetária contracionista, quando a taxa Selic chegou à 9,25% no final deste ano. Para avaliar o impacto da taxa Selic sobre os investimentos em renda fixa e renda variável, Casto, Rosa e Pinheiro (2023) analisaram a correlação e variância entre a Selic e a movimentação de investimentos (Ibovespa e CDI). Os autores identificaram que a Selic exerce forte influência sobre a decisão do investidor aplicar em fundos de renda fixa ou variável: i) quando a taxa básica se encontra em patamares elevados, os investidores tendem a direcionar suas alocações para fundos de renda fixa; ii) por outro lado, à medida que a taxa cai e a renda fixa se torna mesmo atrativa, os investidores começam a aceitar maiores riscos e direcional seus recursos para fundos de renda variável.

Utilizando uma ampla revisão bibliográfica e um caso prático, Papandrea e Hess (2023) caracterizaram e compararam retorno de títulos de renda fixa e renda variável. Os autores identificaram que com exceção dos mercados de criptoativos e ouro, há diferença de rentabilidade entre a renda fixa e a variável não foi tão expressiva quanto o usual. Os autores atribuem este achado ao cenário de elevada taxa de juros, o que torna a renda fixa mais atrativa no Brasil. Pode-se perceber que a recomendação do modelo está de acordo com os resultados de outros estudos recentes. A inovação deste artigo está no desenvolvimento de um algoritmo de machine learning que pode ser atualizado periodicamente para recomendar, diante de uma conjuntura econômica, não apenas uma alocação em renda fixa ou variável, mas também indicar quais setores econômicos listados na B3 podem se beneficiar desta conjuntura.

5. CONCLUSÃO

O estudo demonstrou que a aplicação de árvores de decisão, aliada a variáveis macroeconômicas, é uma abordagem eficaz para identificar padrões e prever o desempenho de setores econômicos listados na B3. A metodologia, que combinou coletas manuais e automatizadas, engenharia de dados e categorização setorial, revelou que o modelo é capaz de recomendar setores econômicos (comprar, vender ou manter inatividade) com base em condições macroeconômicas, fornecendo informações relevantes para investidores e gestores. O uso de árvores de decisão não apenas facilita a interpretação de impactos macroeconômicos, mas também contribui para decisões estratégicas no mercado financeiro, reforçando a relevância de ferramentas computacionais no mercado financeiro. O trabalho mostrou-se inovador ao aplicar uma metodologia de machine learning para identificação dos setores econômicos que podem se beneficiar da conjuntura econômica atual. Pesquisas

posteriores podem ser realizadas aplicando o algoritmo a quaisquer outras variáveis macroeconômicas e outros ativos.

6. REFERÊNCIAS

A

Andrade, V. N., Muntaser, J. G. S., & Prado, T. A. R. (2022). Influência de variáveis macroeconômicas no preço das ações do setor financeiro da B3. *Revista de Economia Mackenzie*, 19(1), 170–190. <https://doi.org/10.5935/1808-2785.rem.v19n1p170-190>

Assaf Neto, A. (2015). *Estrutura e análise de balanços: Um enfoque econômico-financeiro* (10ª ed.). Atlas. <https://integrada.minhabiblioteca.com.br/books/9786559775125>

Assaf Neto, A. (2023). *Mercado financeiro* (15ª ed.). Atlas.

Associação de Analistas e Profissionais de Investimentos no Mercado de Capitais. (2025). *Análise de investimentos: Histórico, principais ferramentas e mudanças conceituais para o futuro*. CVM.

B

Barbosa, I. B., & Nogueira, D. R. (2018). Impacto dos indicadores macroeconômicos nos índices de rentabilidade das empresas brasileiras: Uma análise no setor alimentício de 2010 a 2016. *Revista de Administração, Contabilidade e Economia da Fundace*, 9(1).

Barros, T. S. (2015). *Análise técnica e fundamentalista: Ensaio sobre os métodos de análise*. *Revista de Administração e Negócios da Amazônia*, 7(2).

Bastardo, C. (2015). *Gestão de activos financeiros – back to basis*. Escolar Editora.

Bernardelli, L. V., Borges, M. J., Sanches, S. L. R., Araújo, E., & Castro, G. H. L. (2020). A relação entre as variáveis macroeconômicas e o Ibovespa: Novas evidências para o Brasil. *Revista Mineira de Contabilidade*, 21(3), 97–112. <https://doi.org/10.51320/rmc.v21i3.1164>

Bishop, C. M. (2006). Pattern recognition and machine learning. Springer.

https://www.cs.uoi.gr/~arly/courses/ml/tmp/Bishop_book.pdf

C

Carvalho, A. C. P. L. F., Menezes, A. G., & Bonidia, R. P. (2024). Ciência de dados: Fundamentos e aplicações. LTC.

<https://integrada.minhabiblioteca.com.br/reader/books/9788521638766/>

Castro, M. C. C. S., Rosa, E. N., & Pinheiro, J. L. (2023). A influência da taxa de juros na tomada de decisão do investidor: Uma análise da movimentação entre fundos de renda fixa e renda variável. *Revista Gestão & Tecnologia*, 23(4), 76–97.

Costa, L. F. C., & Costa, M. G. (2018). Os impactos de fatores macroeconômicos sobre índices de ações setoriais: Uma análise através do algoritmo de seleção de modelos autometrics. *Revista Evidenciação Contábil & Finanças*, 6(3), 96–109.

F

Ferreira, I. S. et al. (2018). ipeadatar: Ipeadata Data Extraction (Versão 0.1.6) [Pacote de software R]. <https://CRAN.R-project.org/package=ipeadatar>

G

Gambim, M., Camargo, H. A., Lucca, G., Dimuro, G., & Asmus, T. (2023). Uma estratégia para alocação de carteira de ações usando algoritmos de aprendizado de máquina e regras fuzzy. Em *Anais do XX Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)* (pp. 1195–1209). SBC. <https://doi.org/10.5753/eniac.2023.234681>

J

Jacques, K. A. S., Borges, S. R. P., & Miranda, G. J. (2020). Relações entre os indicadores econômico-financeiros e as variáveis macroeconômicas dos segmentos empresariais da B3.

Revista de Administração, Contabilidade e Economia da Fundace, 11(1), 40–59.
<https://doi.org/10.13059/racef.v11i1.642>

K

Kobori, J. (2019). *Análise fundamentalista*. Alta Books.
<https://integrada.minhabiblioteca.com.br/reader/books/9788550808239/>

L

Lemos, F. (2023). *Análise técnica dos mercados financeiros: Um guia completo e definitivo dos métodos de negociação de ativos (3ª ed.)*. Saraiva Uni.
<https://integrada.minhabiblioteca.com.br/reader/books/9786587958002/>

M

Madaleno, M., Vieira, E., Lobão, J., & Armada, M. R. (2019). *Princípios de finanças – Instrumentos financeiros: Teoria e prática*. Edições Sílabo.

Martins, E. (2001). *Contabilidade de custos (9ª ed.)*. Atlas.

Moares, A. Q. (2022). *Impactos da taxa Selic nos investimentos de renda fixa: Um estudo de caso para o Banco Modal S.A.* [Trabalho de Conclusão de Curso, Universidade Federal do Rio de Janeiro].

Morettin, P. A., & Singer, J. M. (2025). *Estatística e ciência de dados (2ª ed.)*. LTC.

P

Papandrea, P. J., & Hess, M. H. S. A. (2025). *Investimentos financeiros: Um estudo comparativo entre renda fixa e renda variável*. *Revista Gestão em Análise*, 14(2), 187–209.
<https://doi.org/10.12662/2359-618xregea.v14i2.p187-209.2025>

Perlin, M. S. (2020). GetBCBData: Reading Data from the Central Bank of Brazil (Versão 0.7.0) [Pacote de software R]. <https://CRAN.R-project.org/package=GetBCBData>

Pinheiro, J. L. (2019). Mercado de capitais (9ª ed.). Atlas.
<https://integrada.minhabiblioteca.com.br/reader/books/9788597021752/>

Q

Quinlan, J. R. (1996). Improved use of continuous attributes in C4.5. *Journal of Artificial Intelligence Research*, 4, 77–90. <https://arxiv.org/pdf/cs/9603103>

R

Rudink, G. C., Oliveira, F., Cota, G. H., Melo, V. A., & Silveira, H. P. (2013). Investimento em ações no mercado brasileiro – um comparativo dos retornos auferidos por carteiras criadas à luz da análise técnica e fundamentalista. *Revista Liceu*, 3(3).

V

Varian, H. R. (2014). Big data: New tricks for econometrics. *Journal of Economic Perspectives*, 28(2), 3–28. <https://doi.org/10.1257/jep.28.2.3>