
A INFLUÊNCIA DA TECNOLOGIA NAS TÉCNICAS TRADICIONAIS DE ANÁLISE DE INVESTIMENTOS

THE INFLUENCE OF TECHNOLOGY ON TRADITIONAL INVESTMENT ANALYSIS TECHNIQUES

Joseph Alfredo Abdayem de Lima
Simone Sawasaki Tanaka

RESUMO

A pesquisa aborda três principais metodologias de avaliação de investimentos. A Análise Fundamentalista enfoca o valor intrínseco de um ativo, analisando a saúde financeira e projeções de empresas. Já a Análise Quantitativa integra estatísticas com tecnologias emergentes, como inteligência artificial, para prever movimentos de preços de ações em um mercado volátil. A Análise ESG considera critérios ambientais, sociais e de governança na seleção de ativos, reforçados por avanços tecnológicos e respaldados por órgãos reguladores. Conclui-se que estas abordagens, em conjunto, oferecem ferramentas robustas para investidores no mercado de ações.

288

Palavras-chave: análise fundamentalista; análise quantitativa; análise ESG; mercado de ações; investimentos; aprendizado de máquina.

ABSTRACT

This research addresses three primary investment evaluation methodologies. Fundamental Analysis focuses on an asset's intrinsic value by assessing companies' financial health and future projections. Quantitative Analysis integrates statistical techniques with emerging technologies, such as artificial intelligence, to predict stock price movements in a volatile market. ESG Analysis incorporates environmental, social, and governance criteria in asset selection, reinforced by technological advancements and backed by regulatory bodies. It is concluded that, collectively, these approaches offer robust tools for investors in the stock market.

Keywords: fundamental analysis; quantitative analysis; ESG analysis; stock market; investments, machine learning.

1 INTRODUÇÃO

Desde os primórdios do mercado financeiro, a capacidade de realizar uma análise acurada dos investimentos sempre foi fundamental para orientar decisões

econômicas. Originalmente, essa capacidade estava ancorada em metodologias tradicionais, as quais se baseavam majoritariamente em avaliações manuais e no discernimento de padrões a partir de conjuntos de dados financeiros. Contudo, o panorama mudou com a evolução da sociedade e o surgimento de avanços tecnológicos que permearam diversos segmentos, incluindo o financeiro.

A entrada da tecnologia nesse cenário trouxe consigo uma série de ferramentas sofisticadas, tais como *machine learning* e *big data*. Essas ferramentas transformaram radicalmente a análise de investimentos, permitindo aos investidores processar e analisar volumes massivos de dados em tempo quase real. A resultante é uma tomada de decisão mais informada, respaldada por insights que antes eram inalcançáveis. Além disso, uma nova vertente de análise surgiu: a análise de sentimentos. Utilizando plataformas de mídia social como fonte, esta técnica emergente tem provado ser eficaz na previsão de tendências e movimentações de mercado.

Entretanto, a inovação traz consigo desafios intrínsecos. No âmbito da análise financeira potencializada pela tecnologia, os profissionais agora enfrentam o desafio de filtrar informações espúrias e assegurar a integridade e precisão dos dados com os quais trabalham.

Neste contexto, este trabalho propõe-se a entrar na interseção entre tecnologia e análise de investimentos tradicionais. Com uma abordagem criteriosa, busca-se elucidar as principais vantagens, obstáculos e possibilidades geradas por essa simbiose. O objetivo final é fornecer uma perspectiva holística sobre como a inovação tecnológica está delineando os contornos futuros da análise de investimentos.

2 METODOLOGIA

Neste estudo, adotou-se a pesquisa bibliográfica como principal abordagem metodológica, uma etapa fundamental no processo científico e acadêmico. A pesquisa bibliográfica visa reunir informações e dados que formam a base para a investigação de um tema específico. Após a definição do tema central deste trabalho, que se concentra nas análises de ações do mercado financeiro com foco nas abordagens fundamentalista, quantitativa e ESG, a pesquisa bibliográfica foi delimitada a esse escopo.

Através desta metodologia, foi possível traçar um histórico sobre o objeto de estudo, identificando contradições, respostas previamente encontradas e trabalhos semelhantes já realizados. Esse levantamento permitiu discernir a relevância da investigação proposta e a metodologia mais adequada para sua execução.

O levantamento bibliográfico foi conduzido analisando fontes que abordam o tema em questão de diferentes perspectivas. Estas fontes incluíram não apenas artigos do meio acadêmico com alta confiabilidade, mas também revistas especializadas e livros de autores renomados na área. Cada material selecionado foi cuidadosamente lido, analisado e interpretado. Durante esse processo, foram feitas anotações e fichamentos dos conteúdos mais relevantes, que posteriormente serviram como base para a fundamentação teórica deste trabalho.

A inclusão de revistas e livros no levantamento enriqueceu a pesquisa, proporcionando uma visão mais ampla e diversificada sobre o tema. Livros, em particular, ofereceram insights aprofundados e contextuais, enquanto revistas apresentaram estudos e análises mais recentes e atualizadas.

A pesquisa bibliográfica, sendo uma das abordagens de pesquisa mais comuns, proporcionou uma compreensão aprofundada das abordagens de análise de ações e sua relação com a tecnologia, permitindo uma discussão crítica e informada sobre o tema.

290

3 DESENVOLVIMENTO

3.1 REVISÃO DA LITERATURA

A era digital desencadeou transformações em diversos setores, sendo o mercado financeiro um dos mais influenciados. Esta revolução tem impulsionado uma profunda fusão da tecnologia com as técnicas convencionais de análise de investimentos, dando origem a métodos mais precisos e robustos.

A análise fundamentalista, tradicionalmente centrada na avaliação aprofundada de fatores financeiros e econômicos, como balanços e indicadores macroeconômicos, têm evoluído. Agora, ela se beneficia da incorporação de modelos avançados e da análise de dados não convencionais. Segundo Bustos e Pomares-quimbaya (2020),

informações provenientes de notícias estão sendo usadas para refinar previsões e determinar o valor intrínseco de uma ação com maior acurácia.

Por outro lado, a análise quantitativa, com sua base em modelos matemáticos e estatísticos, tem passado por uma transformação radical graças ao machine learning. Xing *et al.* (2013) indicam que essas tecnologias, ao processar enormes volumes de dados financeiros, estão elevando a precisão das previsões. Isso oferece aos investidores insights mais detalhados e estratégias de investimento mais sólidas no mercado atual.

O critério ESG no investimento se destacou recentemente, com a tecnologia desempenhando um papel central. A análise de dados que retratam as práticas sustentáveis das empresas é agora mais acessível e precisa. De acordo com D'amato, D'ecclesia e Levantesi (2021), as ferramentas atuais proporcionam uma avaliação em tempo real do desempenho ESG das corporações, moldando assim as decisões de investimento.

Além disso, a mineração de texto, especialmente em mídias sociais e notícias online, está emergindo como uma ferramenta chave na antecipação de tendências de mercado. khadjeh Nassirtoussi *et al.* (2014) apontam que a análise precisa do sentimento nas plataformas digitais pode ser decisiva para prever movimentos financeiros. A união da economia comportamental com técnicas de inteligência artificial oferece uma perspectiva mais completa na previsão de tendências a partir de dados textuais.

Em resumo, a literatura recente evidencia uma integração profunda da tecnologia com as técnicas de análise de investimento. Esta integração não só aprimora a precisão das análises, mas também abre portas para estratégias de investimento inovadoras.

3.2 ANÁLISE FUNDAMENTALISTA

A técnica de Análise Fundamentalista serve como ferramenta essencial para avaliar a viabilidade de investimentos em ações. Ela busca fornecer insights sobre o valor intrínseco de um ativo. Conforme Villaschi, Galdi e Nossa (2011), essa metodologia facilita aos investidores a comparação entre o valor de mercado atual de

um ativo com seu valor intrínseco, permitindo-lhes inferir se o ativo está subvalorizado, sobrevalorizado ou adequadamente precificado.

De acordo com Penman (2004), o "valor fundamental" refere-se ao valor subjacente de um ativo, e a técnica que explora esse conceito é denominada análise fundamental. Ela engloba a avaliação aprofundada da posição financeira de uma empresa e suas projeções de futuro, com foco em compreender o potencial de crescimento dos lucros, que pode, conseqüentemente, afetar o valor de suas ações.

Seguindo a perspectiva de Galdi (2008), o objetivo da Análise Fundamentalista é discernir divergências entre o preço de mercado de um ativo e seu valor intrínseco. Para isso, utiliza-se uma variedade de métricas financeiras e projeções corporativas. Além disso, conforme ressaltado por Bustos e Pomares-quimbaya (2020), avanços tecnológicos têm possibilitado a incorporação de dados não convencionais, como informações de notícias e análises de sentimentos, visando refinamento na precisão dessa análise.

Em suma, a abordagem fundamentalista orienta os investidores na identificação de ativos com maior probabilidade de proporcionar retornos satisfatórios a longo prazo. Essa metodologia avalia, em essência, a solidez financeira e econômica de empresas, possibilitando comparações entre empresas de um mesmo segmento. Adicionalmente, considera-se o cenário econômico e político vigente na análise, conforme indicado por Lagioia (2009) e Damodaran (2002).

292

3.3 ANÁLISE QUANTITATIVA

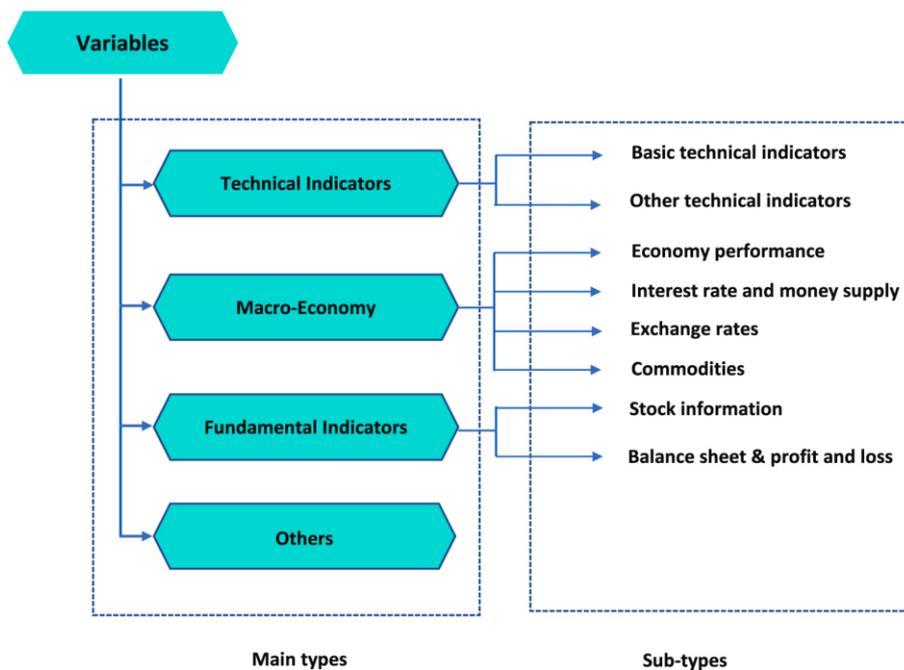
A avaliação quantitativa do mercado de investimentos, tradicionalmente apoiada em métodos estatísticos convencionais, vem sendo transformada significativamente com os avanços das tecnologias de informação. A integração de algoritmos sofisticados e técnicas de machine learning está redefinindo o cenário do mercado financeiro Xing *et al.* (2013).

A ascensão da inteligência artificial e do aprendizado profundo nesse domínio ilustra o potencial dessas tecnologias em otimizar lucros e minimizar riscos. Utilizando a lógica de negociação humana em modelos computacionais, os investidores podem validar a eficácia desses modelos em vastos conjuntos de dados antes de aplicá-los

em contextos reais Yetis, Kaplan e Jamshidi (2014).

A literatura recente enfatiza a relevância de variáveis como indicadores técnicos, métricas financeiras e dados macroeconômicos na previsão de movimentos de preços de ações Tsai *et al.* (2011). Indicadores técnicos, por exemplo, têm sido frequentemente utilizados em estudos de previsão devido à sua capacidade de sinalizar oportunidades de compra e venda (Sedighi *et al.* 2019; Chun; Park 2005; Hadavandi; Shavandi; Ghanbari 2010). Por outro lado, variáveis macroeconômicas, como taxas de câmbio e performance econômica, são consistentemente analisadas em estudos relacionados ao mercado de ações (Enke; Grauer; Mehdiyev 2011; Zhong; Enke 2017). A Figura 1 mostra uma classificação hierárquica de variáveis utilizadas na análise de investimentos. As variáveis são divididas em "Principais tipos"(Técnicas, Macroeconomia, Fundamentais e Outros) e cada tipo principal tem "Subtipos"específicos, como indicadores técnicos básicos, desempenho econômico, taxas de câmbio e informações sobre ações.

Figura 1 – Categorias de variáveis para previsões de preço de ações e retornos



Fonte: Kumbure et al. (2022)

No entanto, é essencial reconhecer a volatilidade e complexidade inerentes ao mercado financeiro. Estratégias eficazes em um momento podem não ser igualmente

bem-sucedidas posteriormente devido às constantes mudanças dos mercados globais. A capacidade da inteligência artificial de adaptar-se e atualizar-se frente a novas informações é um diferencial crucial nesse cenário dinâmico (Mahajan *et al.*, 2016).

Em estudos contemporâneos exploram métodos de projeção de valores de ações, avaliando desde técnicas tradicionais até as baseadas em aprendizado profundo. O questionamento predominante é como as novas técnicas quantitativas, potencializadas pela tecnologia, se comparam aos métodos antigos Milosevic (2016).

Em suma, as atuais inovações tecnológicas estão moldando a avaliação e a estratégia no mercado financeiro. Ainda, alguns desses avanços, é imperativo que investidores reconheçam e adaptem-se às novas ferramentas, garantindo assim decisões mais informadas (Kumar; Bala, 2016).

3.4 ANÁLISE ESG

O investimento socialmente responsável (SRI) tem emergido como uma abordagem que alia retornos financeiros a um impacto sócio ambiental positivo. Brzeszczyński e McIntosh (2014) definem o SRI como uma estratégia que visa retornos tanto morais quanto financeiros, incorporando fatores ambientais, sociais e de governança (ESG) na seleção de ativos. Estes fatores ESG tornaram-se cruciais na seleção de ativos, conforme reiterado por Vives e Wadhwa (2012) e Jain, Sharma e Srivastava (2019).

Os avanços em tecnologia, especialmente em inteligência artificial e machine learning, têm aprimorado a análise de investimentos ESG. Algoritmos, como o *random forest*, têm sido usados para aumentar a precisão na análise e previsão de *scores* ESG, graças à sua capacidade de identificar padrões complexos nos dados (Breiman, 2001).

Segundo Giese *et al.* (2019), os investimentos ESG podem ser categorizados em três tipos: integração ESG, alinhamento com normas e crenças, e investimento de impacto. Tais investimentos têm conquistado uma diversidade de investidores, como destacado por Sandberg *et al.* (2009), e demonstrado solidez em períodos adversos, como apontam estudos recentes, incluindo Arif *et al.* (2022) e Mousa, Saleem e Sági

(2022).

A tecnologia e as ferramentas analíticas têm desempenhado papel fundamental na avaliação das práticas ESG das empresas. No estudo de D'amato, D'ecclesia e Levantesi (2021), foi utilizado o *Bloomberg ESG Data Service*, que abrange dados de 11.500 empresas em 83 países. Usando o algoritmo *random forest*, o estudo evidenciou a influência de variáveis financeiras na definição do score ESG.

Por fim, órgãos reguladores e instituições financeiras têm crescentemente reconhecido a relevância dos fatores ESG. Adotar práticas ESG não beneficia apenas a sociedade e o meio ambiente, mas também proporciona vantagens competitivas às empresas. A combinação da análise fundamentalista com critérios ESG pode resultar em uma avaliação mais acurada do valor real de uma empresa, conforme indicam estudos como os de Penman (2004) e Galdi (2008).

3.5 COMPARAÇÃO ENTRE AS ANÁLISES

No domínio da análise de investimentos, diferentes técnicas oferecem múltiplas perspectivas sobre a avaliação e previsão de ativos. A análise fundamentalista, tradicionalmente, aprofunda-se em fatores financeiros e econômicos para determinar o valor intrínseco de um ativo. Esta abordagem é conhecida por fornecer insights a longo prazo, sendo especialmente valorizada por investidores com uma perspectiva de longo alcance Villaschi, Galdi e Nossa (2011). Em contraste, a análise quantitativa, apoiada em modelos matemáticos e estatísticos, oferece uma reatividade às rápidas mudanças do mercado, tornando-se uma ferramenta inestimável para traders de alta frequência (Xing *et al.*, 2013).

O critério ESG, por outro lado, introduz uma abordagem holística que vai além do desempenho financeiro puro. Empresas que priorizam práticas ESG demonstram um compromisso não apenas com a sustentabilidade, mas também com a responsabilidade social e uma governança corporativa robusta Brzeszczyński e Mcintosh (2014). Estas práticas podem atrair investidores conscientes, melhorar a reputação corporativa e, potencialmente, mitigar riscos associados a práticas insustentáveis ou antiéticas.

Com o contínuo avanço da tecnologia, cada uma dessas técnicas tem

experimentado uma evolução e integração profunda com ferramentas tecnológicas modernas. Esta convergência está capitalizando as forças individuais de cada técnica, promovendo análises mais precisas e abrangentes para o cenário financeiro contemporâneo.

3.6 MACHINE LEARNING NO MERCADO FINANCEIRO

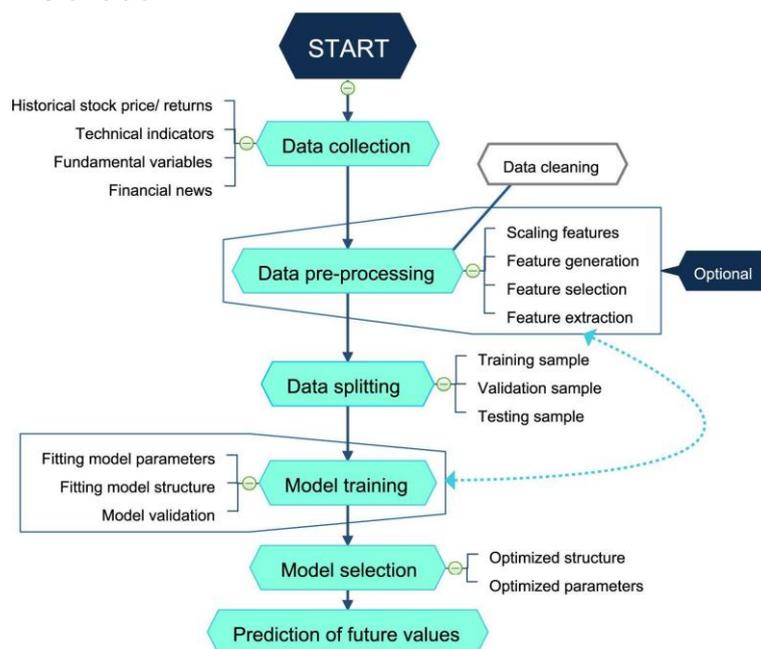
O campo do *machine learning*, destacando-se por sua capacidade inigualável de descobrir padrões e oferecer insights de grandes volumes de dados, tem impulsionado inovações em diversas áreas. De maneira especial, o domínio financeiro tem se beneficiado grandemente destas avançadas técnicas Kubat (2017). Dentre as abordagens, o aprendizado supervisionado se destaca, recebendo notoriedade por sua eficácia na previsão das flutuações do mercado de ações. Para demonstrar isso, a Figura 2 oferece uma representação visual sobre como o aprendizado supervisionado pode ser implementado para prever tendências no mercado financeiro.

Este processo rigoroso começa pela seleção criteriosa de dados de séries temporais. Estes dados, obtidos de períodos específicos, são muitas vezes complementados com informações adicionais que enriquecem o contexto Kubat (2017). Após a coleta, eles são submetidos a uma etapa rigorosa de limpeza e refinamento, onde indicadores técnicos são derivados. Uma vez estabelecida essa base de dados robusta, diversos algoritmos avançados de *machine learning* são postos em prática. Uma estratégia nesse estágio é dividir os dados em conjuntos distintos: treinamento, validação e teste. Esta divisão estratégica visa otimizar a precisão e a confiabilidade do modelo final.

Historicamente, diversas técnicas têm sido exploradas para a previsão do mercado de ações. Por exemplo, as Redes Neurais Artificiais (ANNs) ganharam destaque e são amplamente estudadas por sua capacidade de lidar com problemáticas intrincadas Rajhy, Nermend e Alsakaa (2017). De forma semelhante, às Máquinas de Vetores de Suporte (SVMs) têm se mostrado eficazes, particularmente em cenários desafiadores como Tay e Cao (2001). Em uma tentativa de decifrar as incertezas do mercado, Zadeh (1965) introduziu a lógica fuzzy, que visa entender a natureza volátil do mercado financeiro. Avançando para técnicas mais

contemporâneas, o aprendizado profundo, que é uma extensão do *machine learning*, tem se revelado promissor. Com abordagens como redes neurais profundas e LSTM, a precisão das previsões do mercado de ações tem alcançado patamares sem precedentes (Minh *et al.* 2018; Fischer e Krauss 2018).

Figura 2 – Fluxo de um modelo de previsão do mercado de ações com aprendizado supervisionado.



Fonte: Kumbure *et al.* (2022)

3.7 RANDOM FOREST

A metodologia *random forest* é uma personificação da sabedoria coletiva. Originada da combinação de múltiplas árvores de decisão, esta técnica busca obter uma previsão mais acurada através do consenso dessas árvores, ao invés de depender da decisão de uma única árvore D'amato, D'ecclesia e Levantesi (2021).

A força da *random forest* está entrelaçada à diversidade de suas árvores de decisão. Essa diversidade é alcançada construindo-se cada árvore com uma variação aleatória dos dados. Isso assegura que os erros de uma árvore não são replicados pelas demais, fortalecendo a robustez do modelo coletivo Breiman (1996).

Trilhando os caminhos da história, a origem da floresta aleatória é influenciada pelo conceito de "bagging", uma inovação proposta por Breiman (1996). "Baggingé

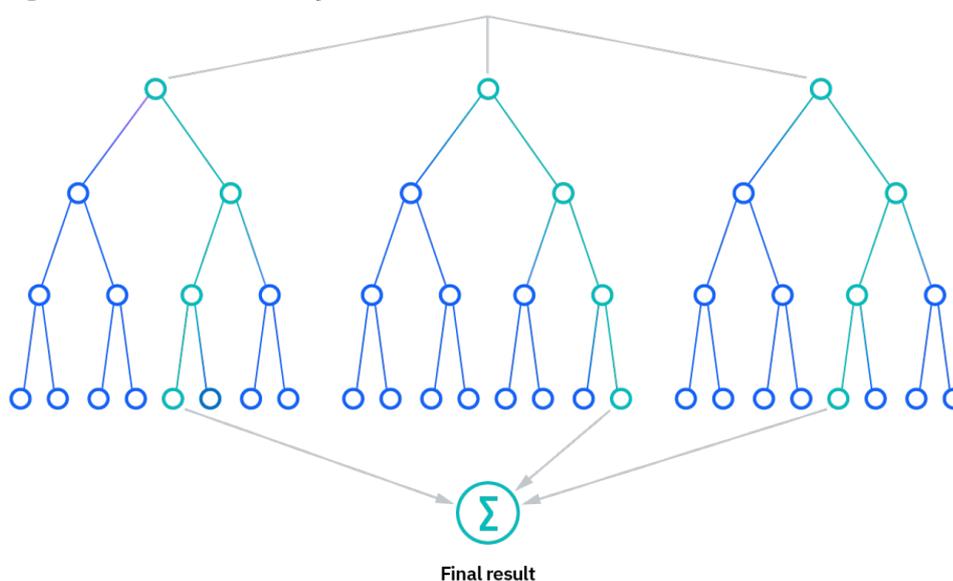
uma técnica que utiliza subconjuntos aleatórios dos dados para criar árvores de decisão independentes. Apenas alguns anos depois, Breiman, em 2001, aperfeiçoou essa técnica. Ele introduziu a ideia de seleção aleatória de características para as divisões dos nós das árvores. Esse refinamento culminou na metodologia que hoje conhecemos como floresta aleatória.

Ao se aprofundar na mecânica, percebe-se que a floresta aleatória constrói suas árvores levando em consideração um conjunto específico e aleatório de características. Esta abordagem promove uma variedade intrínseca entre as árvores. Assim, ao consolidar as decisões de todas elas, a predição final emerge mais robusta e confiável.

No entanto, um aspecto importante ao aplicar esta metodologia é determinar o número adequado de árvores que irão compor a floresta. Um número grande pode acarretar em redundâncias desnecessárias, ao passo que um número muito pequeno pode limitar a precisão das previsões. Assim, a tarefa se torna uma busca constante por equilíbrio, onde o objetivo é otimizar a variação explicativa do modelo enquanto se minimizam os possíveis resíduos. Assim, ao consolidar as decisões de todas elas, a predição final emerge mais robusta e confiável. A Figura 3 ilustra um exemplo de como uma *random forest* funciona, mostrando várias árvores de decisão contribuindo para uma previsão final.

298

Figura 3 – Demonstração do funcionamento de uma *Random Forest*.



Fonte: IBM (2023)

4 CONCLUSÃO

A atual paisagem do mercado financeiro e de investimentos está sendo profundamente influenciada por técnicas de análise e tecnologias avançadas. A Análise Fundamentalista oferece uma visão abrangente do valor intrínseco de ativos, facilitando a compreensão sobre o posicionamento de empresas no mercado. Em paralelo, a Análise Quantitativa, revitalizada pelos avanços da inteligência artificial, está redefinindo como os investidores percebem oportunidades e riscos no cenário financeiro.

Ademais, a abordagem de investimento ESG, que integra considerações ambientais, sociais e de governança, está ganhando relevância, demonstrando a necessidade crescente de alinhar retorno financeiro com impacto socioambiental. As ferramentas de *Machine Learning*, como o aprendizado supervisionado, têm mostrado eficácia na previsão das flutuações do mercado de ações, atestando a necessidade de incorporar tecnologias de ponta no campo financeiro.

Especificamente, o *random forest*, com sua estrutura baseada em múltiplas árvores de decisão, exemplifica como técnicas avançadas podem ser empregadas para tornar as previsões mais acuradas e confiáveis. A difusão randômica das árvores na Floresta Aleatória serve como uma metáfora perfeita para os mercados: da mesma forma que uma floresta saudável é composta de diversas árvores, cada uma adaptada às suas próprias condições e respondendo a diferentes estímulos, o mercado financeiro é repleto de nuances e variáveis. A abordagem do *random forest* permite abraçar essa diversidade, filtrando eficazmente o ruído macroeconômico e revelando padrões subjacentes com maior precisão.

No entanto, é importante reconhecer a ausência de profundidade em alguns tópicos abordados neste trabalho. Em particular, a análise fundamentalista, embora mencionada, carece de uma exploração técnica mais aprofundada. Em futuras investigações, seria válido explorar aplicações avançadas e inovadoras nesta área, potencialmente revelando novas perspectivas e estratégias para os investidores.

Além disso, enquanto o *machine learning* e a inteligência artificial prometem revolucionar o mercado financeiro, é importante considerar as implicações potenciais dessas tecnologias. À medida que essas ferramentas se tornam mais sofisticadas,

existe o risco de que elas possam levar a um posicionamento uniforme entre os investidores ou, em cenários extremos, controlar o mercado de maneira massiva. Estas são questões que merecem uma reflexão cuidadosa e uma investigação mais aprofundada.

Em vista disso, os investidores contemporâneos devem estar equipados com uma combinação de conhecimentos tradicionais e tecnológicos para navegar com eficácia neste mercado em constante evolução. Esta síntese de metodologias antigas e novas promete uma abordagem de investimento mais informada, responsável e lucrativa, mas também exige uma consciência crítica das potenciais ramificações dessas inovações.

REFERÊNCIAS

- ARIF, M. et al. Diversifier or more? hedge and safe haven properties of green bonds during covid-19. **Energy Policy**, v. 168, p. 113102, 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0301421522003275>. Acesso em: 24 out. 2023.
- BREIMAN, L. Bagging Predictors. **Machine Learning**, v. 24, p. 123-140, ago. 1996.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, p. 5-32, out. 2001.
- BUSTOS, O.; POMARES-QUIMBAYA, A. Stock market movement forecast: A systematic review. **Expert Systems with Applications**, v. 156, p. 113464, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417420302888>. Acesso em: 24 out. 2023.
- CHUN, S. hak; PARK, Y. joo. Dynamic adaptive ensemble case-based reasoning: application to stock market prediction. **Expert Systems with Applications**, v. 28, n. 3, p. 435–443, 2005. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417404001484>. Acesso em: 24 out. 2023.
- DAMODARAN, A. **Investment Valuation**: tools and techniques for determining the value of any asset. [S.l.: s.n], 2002.
- IBM. **O que é floresta aleatória?** 2023. Disponível em: <https://www.ibm.com/br-pt/topics/random-forest>. Acesso em: 24 out. 2023.

JAIN, M.; SHARMA, G. D.; SRIVASTAVA, M. **Can sustainable investment yield better financial returns: A comparative study of ESG indices and MSCI indices.** [S.l.]: MDPI AG, 2019.

KHADJEH NASSIRTOUSSI, A. *et al.* Text mining for market prediction: A systematic review. **Expert Systems with Applications**, v. 41, n. 16, p. 7653–7670, 2014. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417414003455>. Acesso em: 24 out. 2023.

KUBAT, M. **An Introduction to Machine Learning.** 2nd. ed. [S.l.]: Springer Publishing Company, Incorporated, 2017.

KUMAR, P.; BALA, A. Intelligent stock data prediction using predictive data mining techniques. *In: INTERNATIONAL CONFERENCE ON INVENTIVE COMPUTATION TECHNOLOGIES*, 2016. **Anais [...]**. [S.l.]: ICICT, 2016. v. 3, p. 1–5.

KUMBURE, M. M. *et al.* **Machine learning techniques and data for stock market forecasting: A literature review.** 2022.

LAGIOIA, U. C. T. **Fundamentos do Mercado de Capitais.** [S.l.: s.n.], 2009.

MAHAJAN, S. D. *et al.* Stock market prediction and analysis using naïve bayes. **International Journal on Recent and Innovation Trends in Computing and Communication**, v. 4, n. 11, p. 121–124, 2016. Disponível em: <https://ijritcc.org/index.php/ijritcc/article/view/2614>. Acesso em: 24 out. 2023.

MILOSEVIC, N. **Equity forecast: Predicting long term stock price movement using machine learning.** 2016. Disponível em: <https://arxiv.org/abs/1603.00751>. Acesso em: 24 out. 2023.

MINH, D. L. *et al.* Deep learning approach for short-term stock trends prediction based on two-stream gated recurrent unit network. **IEEE Access**, v. 6, p. 55392–55404, 2018.

MOUSA, M.; SALEEM, A.; SÁGI, J. Are esg shares a safe haven during covid-19? evidence from the arab region. **Sustainability (Switzerland)**, v. 14, n. 1, 2022.

PENMAN, S. H. **Financial Statement Analysis and Security Valuation.** 2nd. ed. Boston: Irwin Mc Graw Hill, 2004.

RAJIHY, Y.; NERMEND, K.; ALSAKAA, A. Back-propagation artificial neural networks in stock market forecasting. an application to the warsaw stock exchange wig20. **The IEB International Journal of Finance**, v. 15, p. 88–99, 01 2017.

SANDBERG, J. *et al.* The heterogeneity of socially responsible investment. **Journal of Business Ethics**, v. 87, n. 4, p. 519–533, 2009. Disponível em: <https://doi.org/10.1007/s10551-008-9956-0>. Acesso em: 24 out. 2023.

SEDIGHI, M. *et al.* A novel hybrid model for stock price forecasting based on metaheuristics and support vector machine. **Data**, v. 4, n.75, 2019.

TAY, F. E.; CAO, L. Application of support vector machines in financial time series forecasting. **Omega**, v. 29, n. 4, p. 309–317, 2001. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0305048301000263>. Acesso em: 24 out. 2023.

TSAI, C. F. *et al.* Predicting stock returns by classifier ensembles. **Applied Soft Computing**, v. 11, n. 2, p. 2452–2459, mar. 2011. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1568494610002516>. Acesso em: 24 out. 2023.

VILLASCHI, A.; GALDI, F.; NOSSA, S. Análise fundamentalista para seleção de uma carteira de investimento em ações com baixa razão book-to-market. **BASE - Revista de Administração e Contabilidade da Unisinos**, v. 8, n. 12, p. 325–337, 2011.

VIVES, A.; WADHWA, B. Sustainability indices in emerging markets: impact on responsible practices and financial market development. **Journal of Sustainable Finance and Investment**, v. 2, n. 10, 2012.

XING, T. *et al.* **The analysis and prediction of stock price**. [S.l.: s.n.], 2013.

YETIS, Y.; KAPLAN, H.; JAMSHIDI, M. Stock market prediction by using artificial neural network. *In*: WORLD AUTOMATION CONGRESS, 2014. **Anais [...]**. [S.l.]: WAC, 2014. p. 718–722.

ZHONG, X.; ENKE, D. A comprehensive cluster and classification mining procedure for daily stock market return forecasting. **Neurocomputing**, v. 267, p. 152–168, 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0925231217310652>. Acesso em: 24 out. 2023.