



# Inteligência Artificial

aplicada ao Mercado Financeiro

Emerson Antonio Freire Pavão



**AYA EDITORA**

**2024**

**Emerson Antonio Freire Pavão**

# **Inteligência Artificial aplicada ao Mercado Financeiro**

**Ponta Grossa  
2024**

## **Direção Editorial**

Prof.º Dr. Adriano Mesquita Soares

## **Autor**

Emerson Antonio Freire Pavão

## **Capa**

AYA Editora©

## **Revisão**

O Autor

## **Executiva de Negócios**

Ana Lucia Ribeiro Soares

## **Produção Editorial**

AYA Editora©

## **Imagens de Capa**

br.freepik.com

## **Área do Conhecimento**

Ciências Sociais Aplicadas

# **Conselho Editorial**

Prof.º Dr. Adilson Tadeu Basquerote Silva

*Universidade para o Desenvolvimento do Alto Vale do Itajaí*

Prof.º Dr. Aknaton Toczec Souza

*Centro Universitário Santa Amélia*

Prof.ª Dr.ª Andréa Haddad Barbosa

*Universidade Estadual de Londrina*

Prof.ª Dr.ª Andreia Antunes da Luz

*Faculdade Sagrada Família*

Prof.º Dr. Argemiro Midonês Bastos

*Instituto Federal do Amapá*

Prof.º Dr. Carlos López Noriega

*Universidade São Judas Tadeu e Lab. Biomecatrônica - Poli - USP*

Prof.º Dr. Clécio Danilo Dias da Silva

*Centro Universitário FACEX*

Prof.ª Dr.ª Daiane Maria de Genaro Chirolí

*Universidade Tecnológica Federal do Paraná*

Prof.ª Dr.ª Danyelle Andrade Mota

*Universidade Federal de Sergipe*

Prof.ª Dr.ª Déborah Aparecida Souza dos Reis

*Universidade do Estado de Minas Gerais*

Prof.ª Ma. Denise Pereira

*Faculdade Sudoeste – FASU*

Prof.ª Dr.ª Eliana Leal Ferreira Hellvig

*Universidade Federal do Paraná*

Prof.º Dr. Emerson Monteiro dos Santos

*Universidade Federal do Amapá*

Prof.º Dr. Fabio José Antonio da Silva

*Universidade Estadual de Londrina*

Prof.º Dr. Gilberto Zammar

*Universidade Tecnológica Federal do Paraná*

Prof.ª Dr.ª Helenadja Santos Mota

*Instituto Federal de Educação, Ciência e Tecnologia Baiano, IF Baiano - Campus Valença*

Prof.ª Dr.ª Heloísa Thaís Rodrigues de Souza

*Universidade Federal de Sergipe*

Prof.ª Dr.ª Ingridi Vargas Bortolaso

*Universidade de Santa Cruz do Sul*

Prof.ª Ma. Jaqueline Fonseca Rodrigues

*Faculdade Sagrada Família*

Prof.ª Dr.ª Jéssyka Maria Nunes Galvão

*Faculdade Santa Helena*

Prof.º Dr. João Luiz Kovaleski

*Universidade Tecnológica Federal do Paraná*

Prof.º Dr. João Paulo Roberti Junior

*Universidade Federal de Roraima*

Prof.º Me. Jorge Soistak

*Faculdade Sagrada Família*

Prof.º Dr. José Enildo Elias Bezerra

*Instituto Federal de Educação Ciência e Tecnologia do Ceará, Campus Ubajara*

Prof.ª Dr.ª Karen Fernanda Bortoloti

*Universidade Federal do Paraná*

Prof.ª Dr.ª Leozenir Mendes Betim

*Faculdade Sagrada Família e Centro de Ensino Superior dos Campos Gerais*

Prof.ª Ma. Lucimara Glap

*Faculdade Santana*

Prof.º Dr. Luiz Flávio Arreguy Maia-Filho

*Universidade Federal Rural de Pernambuco*

**Prof.º Me. Luiz Henrique Domingues**

*Universidade Norte do Paraná*

**Prof.º Dr. Milson dos Santos Barbosa**

*Instituto de Tecnologia e Pesquisa, ITP*

**Prof.º Dr. Myller Augusto Santos Gomes**

*Universidade Estadual do Centro-Oeste*

**Prof.ª Dr.ª Pauline Balabuch**

*Faculdade Sagrada Família*

**Prof.º Dr. Pedro Fauth Manhães Miranda**

*Universidade Estadual de Ponta Grossa*

**Prof.º Dr. Rafael da Silva Fernandes**

*Universidade Federal Rural da Amazônia, Campus  
Pauapebas*

**Prof.ª Dr.ª Regina Negri Pagani**

*Universidade Tecnológica Federal do Paraná*

**Prof.º Dr. Ricardo dos Santos Pereira**

*Instituto Federal do Acre*

**Prof.ª Dr.ª Rosângela de França Bail**

*Centro de Ensino Superior dos Campos Gerais*

**Prof.º Dr. Rudy de Barros Ahrens**

*Faculdade Sagrada Família*

**Prof.º Dr. Saulo Cerqueira de Aguiar Soares**

*Universidade Federal do Piauí*

**Prof.ª Dr.ª Silvia Aparecida Medeiros**

**Rodrigues**

*Faculdade Sagrada Família*

**Prof.ª Dr.ª Silvia Gaia**

*Universidade Tecnológica Federal do Paraná*

**Prof.ª Dr.ª Sueli de Fátima de Oliveira Miranda**

**Santos**

*Universidade Tecnológica Federal do Paraná*

**Prof.ª Dr.ª Thaisa Rodrigues**

*Instituto Federal de Santa Catarina*

© 2024 - **AYA Editora** - O conteúdo deste Livro foi enviado pelo autor para publicação de acesso aberto, sob os termos e condições da Licença de Atribuição *Creative Commons* 4.0 Internacional (**CC BY 4.0**). Este livro, incluindo todas as ilustrações, informações e opiniões nele contidas, é resultado da criação intelectual exclusiva do autor. O autor detém total responsabilidade pelo conteúdo apresentado, o qual reflete única e inteiramente a sua perspectiva e interpretação pessoal. É importante salientar que o conteúdo deste livro não representa, necessariamente, a visão ou opinião da editora. A função da editora foi estritamente técnica, limitando-se ao serviço de diagramação e registro da obra, sem qualquer influência sobre o conteúdo apresentado ou opiniões expressas. Portanto, quaisquer questionamentos, interpretações ou inferências decorrentes do conteúdo deste livro, devem ser direcionados exclusivamente ao autor.

---

P3391 Pavão, Emerson Antonio Freire

Inteligência artificial aplicada ao mercado financeiro [recurso eletrônico]. / Emerson Antonio Freire Pavão. -- Ponta Grossa: Aya, 2024. 75 p.

Inclui biografia

Inclui índice

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

ISBN: 978-65-5379-475-7

DOI: 10.47573/aya.5379.1.249

1. Inteligência artificial. 2. Inovações tecnológicas - Negócios. I. Título

CDD: 006.3

---

Ficha catalográfica elaborada pela bibliotecária Bruna Cristina Bonini - CRB 9/1347

---

**International Scientific Journals Publicações  
de Periódicos e Editora LTDA**

**AYA Editora©**

**CNPJ:** 36.140.631/0001-53

**Fone:** +55 42 3086-3131

**WhatsApp:** +55 42 99906-0630

**E-mail:** contato@ayaeditora.com.br

**Site:** <https://ayaeditora.com.br>

**Endereço:** Rua João Rabello Coutinho, 557  
Ponta Grossa - Paraná - Brasil  
84.071-150

# SUMÁRIO

<b>APRESENTAÇÃO .....</b>	<b>8</b>
<b>INTRODUÇÃO .....</b>	<b>9</b>
<b>METODOLOGIA .....</b>	<b>14</b>
<b>FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>16</b>
Inteligência artificial.....	16
A evolução da inteligência artificial: desafios e perspectivas.....	16
O impacto da inteligência artificial (IA) em nosso cotidiano: explorando seu potencial de aplicações no setor financeiro .....	18
Métodos de investimentos .....	21
Análise fundamentalista.....	21
Análise técnica.....	24
Técnicas de previsão no mercado acionário ...	26
Indicadores técnicos .....	28
Análise temporal e teoria financeira.....	33
<b>ANÁLISE EMPÍRICA DA AÇÃO PETR4: REGRESSÃO LINEAR E TENDÊNCIAS DE MERCADO NO PERÍODO DE 03/01/2023 A 02/01/2024 .....</b>	<b>47</b>
Construção e desenvolvimento de uma base de dados .....	49
Etapas de da Mineração de Dados.....	49
Elaboração de scripts .....	51
Conclusões sobre estratégias e seu impacto na rentabilidade financeira.....	60

<b>CONSIDERAÇÕES FINAIS.....</b>	<b>63</b>
<b>REFERÊNCIAS.....</b>	<b>66</b>
<b>SOBRE O AUTOR .....</b>	<b>70</b>
<b>ÍNDICE REMISSIVO .....</b>	<b>71</b>

# Apresentação

---

Esta pesquisa tem como objetivo aprofundar a compreensão do mercado financeiro e da bolsa de valores, aproveitando o avanço tecnológico exponencial como uma oportunidade para otimizar o investimento neste vasto cenário. Nesse contexto, o estudo concentra-se na aplicação da Mineração de Dados e da Inteligência Artificial para estabelecer conexões entre os dados da bolsa de valores (B3), seus preços de ativos e suas volatilidades. Essa abordagem visa não apenas produzir informações mais compreensíveis sobre o comportamento das ações de empresas, mas também avaliar o risco de investimento, fornecendo uma ferramenta crucial para a tomada de decisões por parte de investidores financeiros. No âmbito deste projeto, destaca-se a implementação do algoritmo Exponential Triple Smoothing (ETS) para a previsão de preços de ações, índices financeiros e outros ativos. A escolha da linguagem Python, além de sua crescente relevância na computação, justifica-se pela simplicidade de uso e acessibilidade em diferentes dispositivos e sistemas operacionais. A eficiência do algoritmo ETS é explorada no contexto da pesquisa, apresentando-se como uma ferramenta significativa para antecipar valorizações ou desvalorizações, sendo particularmente útil para investidores independentes. A pesquisa busca, portanto, integrar o avanço tecnológico com a análise preditiva, oferecendo uma contribuição para a compreensão do mercado financeiro. Ao considerar a previsão de cada ação em relação ao fechamento em alta ou baixa, a eficiência do algoritmo é validada como uma ferramenta confiável para orientar a tomada de decisões de investimento. Essa abordagem interdisciplinar visa não apenas proporcionar informações mais coerentes, mas também gerar resultados que possam ser utilizados como suporte estratégico na complexa dinâmica do mercado financeiro.

Boa leitura!



# Introdução

A análise temporal, desde os tempos antigos, tem sido uma ferramenta intrínseca à natureza humana, permitindo a previsão de eventos futuros por meio da análise de dados passados. Nesse contexto, a incerteza que permeia o futuro se revela desafiadora, levando indivíduos e organizações a buscar minimizar riscos e maximizar lucros. Como destacado por Petropoulos *et al.* (2021), o cenário financeiro apresenta uma série de desafios relacionados a eventos e decisões financeiras, exigindo métodos de previsão diversificados para enfrentar os desafios da vida real.

A evolução da tecnologia trouxe consigo uma revolução na análise de séries temporais no mercado financeiro. A sequência cronológica de observações, dependente do tempo, tornou-se essencial para a compreensão e previsão de tendências financeiras. Lim & Zohren (2021) destacam que, globalmente, a análise de séries temporais abrange previsão, modelagem e detecção de anomalias. Nesse contexto, os algoritmos de aprendizado de máquina e aprendizado profundo têm recebido atenção significativa devido à sua aplicabilidade, possuindo recursos essenciais para enfrentar a complexidade inerente às séries temporais.

No universo do mercado financeiro, a busca por decisões baseadas em critérios objetivos tem impulsionado a pesquisa em Aprendizado de Máquina (AM). Huang, Chai & Cho (2020) exploram diversas técnicas de Aprendizado Profundo alinhadas à Análise Técnica, visando soluções que proporcionem retornos financeiros expressivos nas negociações de ativos financeiros. O crescente volume de operações no mercado financeiro tem elevado a importância do desenvolvimento de sistemas de decisão inteligentes.

A estratégia Buy and Hold (BH) surge como uma escolha preferida por muitos investidores, buscando valorizar ações ao longo do tempo e evitando a preocupação com a volatilidade dos preços. Entretanto, essa abordagem demanda acompanhamento rigoroso de resultados e balanços das empresas, além da análise do comportamento dos preços para decisões fundamentadas de compra e venda. A Teoria do Passeio Aleatório (Fama, 1995) argumenta que o mercado financeiro funciona de maneira irracional, tornando os

movimentos dos preços imprevisíveis. Diante disso, a Análise Técnica, como estratégia de operações de compra e venda, ganha destaque na tentativa de prever tendências futuras.

A automação no mercado de ações, evidenciada pelo aumento significativo das negociações automatizadas, destaca a influência dos algoritmos nas oscilações de preços. Li (2019) revela que aproximadamente 80% das negociações no mercado de ações norte-americano são automatizadas, refletindo a reação do mercado às manchetes e a propensão a oscilações bruscas de preços.

A análise de séries temporais, fundamental para a compreensão dos dados reais, tem se destacado como um campo de pesquisa crucial. McNelis (2005) salienta a importância da previsão na tomada de decisão, proporcionando insights valiosos sobre a relação entre variáveis independentes e dependentes. A complexidade dessa análise é evidenciada por Yang & Wu (2006), que destacam os desafios persistentes na pesquisa de mineração de dados.

A incorporação de Inteligência Artificial (IA) e aprendizagem profunda na previsão de séries temporais, especialmente de preços de ações, representa uma inovação significativa. A complexidade dos problemas mundiais, como as alterações nos preços das ações, impulsiona o uso de redes neurais artificiais (RNA) para modelar pensamento humano considerando variáveis não lineares.

Diante desse cenário, o método Triple Exponential Smoothing surge como uma ferramenta robusta na gestão e otimização de séries temporais. Sua aplicação, disponível no Microsoft Excel, oferece uma abordagem eficiente para lidar com a complexidade intrínseca, contribuindo para a compreensão aprofundada e precisa das tendências e padrões subjacentes. A análise detalhada desse método visa aprimorar a capacidade de previsão e tomada de decisões, integrando conceitos tradicionais com as inovações trazidas pela IA e aprendizado profundo nos mercados financeiros.

A contextualização desta pesquisa surge da crescente relevância da inteligência artificial aplicada ao mercado financeiro, uma área que tem experimentado uma transformação significativa com o avanço tecnológico. A interseção entre a inteligência

artificial e as finanças tem proporcionado oportunidades inovadoras, destacando-se a previsão de preços de ações e ativos financeiros como uma aplicação crucial. Nesse contexto, a busca por algoritmos de previsão de preços torna-se essencial para oferecer aos investidores ferramentas robustas e confiáveis.

A complexidade e a dinâmica do mercado financeiro demandam estratégias avançadas, e a inteligência artificial surge como um catalisador para aprimorar a tomada de decisões. Investir requer não apenas a compreensão das tendências históricas, mas também a capacidade de antecipar movimentos futuros. Assim, a aplicação de algoritmos de previsão de preços impulsionados por inteligência artificial surge como uma abordagem promissora para fornecer insights precisos e oportunos.

A justificativa para esta pesquisa está na necessidade de explorar e validar a eficácia desses algoritmos de previsão de preços, especialmente direcionados a investidores comuns. O impacto potencial dessas ferramentas na otimização de estratégias de investimento e na gestão de riscos é substancial. A relevância da previsão de preços para investidores é incontestável, e a aplicação de inteligência artificial oferece um horizonte de possibilidades para aprimorar a eficiência e a precisão dessas previsões.

Além disso, há uma lacuna significativa que precisa ser abordada: a aplicação da inteligência artificial e algoritmos estatísticos para analisar ativos financeiros sem a necessidade de o investidor comum dispor de ferramentas muito elaboradas para fazer seus relatórios de previsão de preços. Essa lacuna representa uma oportunidade para simplificar e democratizar o acesso a ferramentas de análise, tornando a inteligência artificial mais acessível e compreensível para um público mais amplo de investidores.

A pesquisa visa, assim, preencher lacunas na compreensão atual sobre a aplicação específica da inteligência artificial na previsão de preços de ações e ativos financeiros. Ao analisar algoritmos específicos, pretende-se oferecer uma contribuição prática para a comunidade de investidores, apresentando ferramentas que possam ser incorporadas de maneira eficaz em suas estratégias de tomada de decisão. Essa investigação não apenas aborda a teoria por trás desses algoritmos, mas também busca fornecer insights práticos

sobre sua implementação e aplicabilidade no ambiente dinâmico do mercado financeiro.

A justificativa para este estudo também se fundamenta na necessidade de promover a disseminação do conhecimento e da compreensão das implicações práticas da inteligência artificial no contexto financeiro. A dissecação dos algoritmos de previsão de preços contribui para desmistificar a complexidade percebida dessas tecnologias, tornando-as acessíveis e compreensíveis para um público mais amplo de investidores. A pesquisa, assim, visa empoderar os investidores ao oferecer-lhes ferramentas que podem ser utilizadas de maneira eficaz e informada em seus processos de decisão.

O problema de pesquisa que emerge do contexto apresentado é: “Como a aplicação de inteligência artificial e algoritmos estatísticos pode simplificar e democratizar a análise de ativos financeiros, especialmente na previsão de preços de ações, tornando essas ferramentas mais acessíveis e compreensíveis para investidores comuns, sem a necessidade de ferramentas elaboradas para a produção de relatórios de previsão de preços?”.

O objetivo geral desta pesquisa é investigar como a aplicação de inteligência artificial e algoritmos estatísticos pode simplificar a análise de ativos financeiros, com foco na previsão de preços de ações, visando democratizar o acesso a ferramentas de análise e tornar essas tecnologias mais acessíveis e compreensíveis para investidores comuns, eliminando a necessidade de ferramentas elaboradas para a produção de relatórios de previsão de preços.

Os objetivos específicos são:

- a) Investigar e analisar a eficácia de algoritmos de previsão de preços, com destaque para o Exponential Triple Smoothing (ETS), no contexto da aplicação de inteligência artificial para ativos financeiros, especialmente ações;
- b) Avaliar a aplicabilidade e acessibilidade da linguagem de programação Python na implementação desses algoritmos, considerando sua simplicidade de uso e capacidade de execução em diferentes dispositivos e sistemas operacionais;

- c) Identificar as lacunas e desafios na utilização de inteligência artificial e algoritmos estatísticos para análise de ativos financeiros, especialmente no que diz respeito à democratização do acesso para investidores comuns;
- d) Propor estratégias e abordagens que visem simplificar a interpretação dos resultados gerados por algoritmos de previsão de preços, tornando as informações mais compreensíveis e acessíveis para um público mais amplo; e,
- e) Contribuir para o desenvolvimento de diretrizes e recomendações práticas que permitam a integração eficaz de algoritmos de previsão de preços baseados em inteligência artificial no processo de tomada de decisão de investidores comuns, sem a necessidade de ferramentas complexas para a produção de relatórios de previsão de preços.

# Metodologia

A metodologia desta pesquisa adotará uma abordagem mista, combinando elementos qualitativos, quantitativos e exploratórios para alcançar uma compreensão abrangente e aprofundada da aplicação de inteligência artificial e algoritmos estatísticos na previsão de preços de ativos financeiros.

- 1. Desenho da pesquisa:** inicialmente, será adotado um desenho de pesquisa exploratória, que permitirá a investigação detalhada dos algoritmos de previsão de preços, destacando o Exponential Triple Smoothing (ETS), e sua eficácia no contexto da inteligência artificial aplicada ao mercado financeiro;
- 2. Seleção da amostra:** a seleção da amostra será baseada em critérios específicos, incluindo ações de empresas listadas na bolsa de valores (B3) mais especificamente a ação PETR4;
- 3. Coleta de dados:** a coleta de dados será realizada por meio de análise documental, englobando históricos de preços de ações do Yahoo Finance, dados financeiros relevantes e relatórios. Essa fase exploratória permitirá a identificação de padrões e insights iniciais;
- 4. Implementação dos algoritmos:** a implementação prática dos algoritmos será conduzida utilizando a linguagem de programação Python, com foco na avaliação da simplicidade de uso e acessibilidade dessa ferramenta, proporcionando insights adicionais durante a etapa exploratória;
- 5. Análise estatística:** para a análise quantitativa, serão utilizadas técnicas estatísticas para avaliar a eficácia dos algoritmos na previsão de preços, comparando os resultados previstos com os valores reais. O caráter exploratório permitirá identificar possíveis correlações e tendências iniciais;
- 6. Revisão literária:** uma extensa pesquisa foi conduzida abrangendo literatura acadêmica, livros, artigos científicos, periódicos, sites especializados e outras

fontes pertinentes. O objetivo era entender as teorias, modelos e estratégias de alocação de recursos no mercado de capitais. Esta revisão literária serviu como base sólida para o estudo e permitiu a identificação das práticas e abordagens mais eficazes para maximizar a rentabilidade financeira; e,

- 7. Validade e confiabilidade:** a validade dos resultados será assegurada através da triangulação de dados, considerando a combinação de métodos qualitativos, quantitativos e exploratórios. A confiabilidade será garantida por meio da transparência nos procedimentos metodológicos e da consistência na aplicação dos métodos ao longo da pesquisa, adaptando-se conforme a complexidade exploratória da análise.

# Fundamentação teórica

## Inteligência artificial

A inteligência artificial (IA) se revela como um domínio de inúmeras facetas, desafiando uma definição singular. Na perspectiva linguística, é delineada como “um campo de conhecimento associado à linguagem e inteligência, raciocínio, aprendizagem e resolução de problemas” (Kuaifman, 2016). Sob uma ótica tecnicista, assume a configuração de “um conjunto de tecnologias que integram dados, algoritmos e capacidade de computação” (Comissão Europeia, 2020). De maneira abrangente, é descrita como “sistemas de computador capazes de desempenhar tarefas que tradicionalmente demandavam inteligência humana”. Efetivamente, a contemporaneidade da IA está intrinsecamente vinculada à aptidão dos dispositivos em assimilar informações, estabelecer padrões e formular previsões para alcançar seus objetivos.

## A evolução da inteligência artificial: desafios e perspectivas

A Inteligência Artificial (IA) é um campo fascinante e em constante evolução, dedicado a dotar máquinas da capacidade de realizar tarefas complexas, como lógica, raciocínio, planejamento, aprendizagem e percepção. No entanto, a definição abrangente de IA transcende a mera replicação de processos de pensamento humanos, estendendo-se para abranger conceitos complexos como criatividade, conhecimento emocional e autoconsciência.

A história da IA está intrinsecamente ligada à “IA simbólica”, predominante até os anos 1980, mas superada por abordagens subsimbólicas, como redes neurais e sistemas fuzzy. Essa transição culminou na emergência do termo “Inteligência Computacional”, delineando um subcampo inovador da IA.



Na sua obra, Russell & Norvig (2009) propõem uma definição pragmática de IA como o estudo da inteligência humana replicada artificialmente, incorporando um nível razoável de racionalidade no design. Essa racionalidade pode, em alguns casos, substituir os humanos em tarefas específicas e bem definidas.

A complexidade da definição de IA é agravada pela evolução constante do conhecimento. Negnevitsky (2002) destaca a mudança de foco ao longo do tempo, passando da tentativa de imitar o comportamento humano com programas de computador para a busca por sistemas artificialmente inteligentes. Diversas categorias, como sistemas que pensam ou agem como humanos, e sistemas que pensam ou agem racionalmente, delineiam as tentativas de classificar a IA em suas diversas manifestações.

No entanto, as formas tradicionais de projetar sistemas inteligentes, como os baseados em regras, enfrentaram desafios significativos, especialmente ao tentar alcançar comportamentos verdadeiramente inteligentes. A afirmação de Negnevitsky (2002) de que “os sistemas especialistas sabem tudo sobre quase nada” ressalta a lacuna entre a inteligência artificial e a vastidão do conhecimento humano.

A inserção prática da IA em setores como publicidade, aviação, medicina e reconhecimento de voz demonstra seu impacto crescente. Carros autônomos, equipados com sistemas avançados de direção, e o Alpha-Go, desenvolvido pela Google Deepmind, são exemplos impressionantes dessa revolução tecnológica.

Contudo, as limitações da IA são evidentes. A falta de “senso comum”, a incapacidade de discernir nuances emocionais complexas e a dependência de conhecimento prévio são desafios a serem superados. O episódio do robô Tay da Microsoft, incapaz de distinguir interações positivas de negativas, destaca as fronteiras atuais da inteligência artificial.

A ascensão dos chatbots, embora promissora como canal de comunicação, sublinha a necessidade de avanços na compreensão emocional e na personalização. A verdadeira IA completa, capaz de imitar a cognição humana em sua totalidade, permanece um desafio futuro, exigindo avaliação não apenas sob a perspectiva tecnológica, mas também considerando implicações sociais, éticas e legais.

A abordagem sistemática para agentes inteligentes é uma tendência na IA moderna. Esses agentes, definidos por Hewitt (1977) como entidades autônomas com habilidade social, reatividade e proatividade, são ferramentas avançadas com aplicações em diversos setores.

A definição de agentes inteligentes por Jansen (1997) destaca sua autonomia e capacidade de melhorar o desempenho ao longo do tempo, representando uma evolução além de simples sub-rotinas. Agentes inteligentes encontram aplicações em sistemas de negócios, decisões médicas e ecologia, demonstrando sua versatilidade.

O impacto da IA transcende os aspectos tecnológicos, expandindo-se para considerações jurídicas, éticas e socioeconômicas. A especulação sobre a “singularidade de IA”, onde máquinas constroem máquinas superiores, é abordada com ceticismo, enquanto especialistas como o AI100 direcionam a atenção para tópicos cruciais, destacando a necessidade de abordar questões fundamentais.

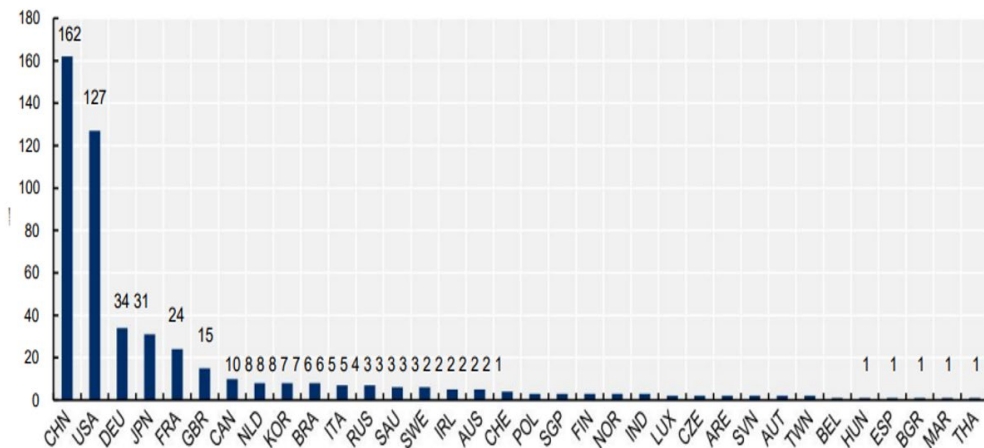
## **O impacto da inteligência artificial (IA) em nosso cotidiano: explorando seu potencial de aplicações no setor financeiro**

O setor financeiro tem se tornado um terreno fértil para a integração crescente de soluções de Inteligência Artificial (IA), permeando diversas dimensões, desde a análise de riscos até a personalização de produtos, e abrangendo a importante esfera de prevenção de fraudes. Em um ambiente já intrinsecamente baseado no processamento de dados, os avanços tecnológicos em IA proporcionam uma significativa redução nos custos de armazenamento e processamento, facilitando a utilização eficiente do vasto volume de informações disponíveis (Noreen, 2023).

A consequente diminuição dos custos operacionais, viabilizada pelo aprimoramento dos processos de tomada de decisão e a automação de procedimentos, entre outros fatores,

associada à melhoria na análise de informações, revela o potencial da IA para impulsionar a inclusão financeira e fomentar o desenvolvimento de produtos e serviços personalizados. Esta perspectiva é corroborada pela Organização para a Cooperação e Desenvolvimento Econômico (OCDE), que sustenta que a utilização da inteligência artificial no âmbito financeiro não apenas proporciona vantagens competitivas às empresas do setor, mediante aprimoramento da eficiência, redução de custos e aumento da produtividade, mas também contribui para a elevação da qualidade dos serviços e produtos oferecidos, cada vez mais alinhados ao perfil de cada cliente (OCDE, 2021). A expectativa é que essas melhorias se traduzam em benefícios palpáveis para o consumidor, possibilitando o acesso a produtos potencialmente aprimorados e mais acessíveis, assim estimulando a inclusão financeira, conforme destacado pela OCDE (2023). A transformação promovida pela Inteligência Artificial transcende as fronteiras do sistema financeiro, impactando tanto o front-office, reconfigurando a interação com o cliente e as operações, quanto o back-office, alterando modelos de pesquisa de mercado, gestão de riscos e aprimorando sistemas de segurança antifraude (Wuermeling, 2018).


**Gráfico 1 – Número dos principais supercomputadores por economia, de acordo com o Top500, novembro de 2022.**



Nota: O Top500 é lançado duas vezes por ano de autoria de Jack Dongarra, Martin Meuer, Horst Simon e Erich Strohmaier. As contribuições para a lista são voluntárias, colocando desafios metodológicos. Esta Figura deve ser vista apenas como ilustrativa e várias advertências devem ser sublinhadas. Não considera a capacidade de diferentes supercomputadores, mas a contagem de supercomputadores por economia (ou seja, trata diferentes supercomputadores como se fossem iguais, embora existam variações significativas na capacidade dos supercomputadores). Não distingue supercomputadores de acordo com a capacidade de carga de trabalho especializada em IA.

**Fonte: Top500, 2022.**

**Gráfico 2 – Os 500 melhores supercomputadores por economia, classificados pelo Rmax total, novembro de 2022**



Nota: Este valor deve ser considerado apenas como uma métrica proxy preliminar e direcional para a capacidade computacional nacional, com as ressalvas descritas na Figura 1. Além disso, como as cargas de trabalho não podem ser executadas em vários supercomputadores, esta medida deve ser vista com limitações (por exemplo, 10 supercomputadores que somam a mesma soma de Rmax que um único supercomputador não seriam equivalentes).

**Fonte: Top500, 2022.**

Na área de investimentos, a Inteligência Artificial (IA), especialmente por meio de modelos de machine learning, desempenha um papel crucial, aprimorando negociações e alocação de portfólio. Essa tecnologia permite uma análise mais precisa de dados, otimizando fluxos e a gestão de riscos. A IA facilita a tomada de decisões na composição de portfólio, aprimora modelos preditivos e de análise de impacto, além de viabilizar transações automatizadas, explorando oportunidades de mercado em tempo real.

No segmento de crédito, a IA apresenta potencial para reduzir custos, promover a inclusão financeira e aprimorar avaliações de crédito, gerenciamento de portfólio e seguros. Na interação com clientes, soluções de IA melhoram a experiência do usuário, personalizam ofertas e proporcionam assistência virtual.

No contexto de conformidade regulatória e cibersegurança, a IA promete fortalecer modelos de segurança, automatizar ferramentas de compliance e aprimorar métodos de KYC, detecção de fraudes e análise de impacto e risco. Bancos centrais também se beneficiam da IA para coleta, armazenamento e processamento eficientes de dados, melhorando a detecção de transações específicas e validação automatizada.

Essas aplicações de IA ampliam sua influência em diversas áreas, proporcionando eficiência, precisão e adaptabilidade no ambiente financeiro (Araújo, 2022).

# Métodos de investimentos

Historicamente, dois métodos têm sido empregados para orientar decisões no mercado acionário: Análise Fundamentalista e Análise Técnica. A primeira concentra-se nos dados pertinentes à empresa subjacente à ação, requerendo perícia na interpretação de informações financeiras, como balanços contábeis, e consideração de fatores econômicos que influenciam a empresa, além do acompanhamento de notícias e eventos relevantes. A estratégia Buy and Hold (BH) adota a Análise Fundamentalista, selecionando empresas por meio dessa análise, presumindo que empresas sólidas continuarão a apresentar desempenho positivo, resultando no incremento gradual do preço de suas ações ao longo do tempo. Dado o caráter dependente da interpretação de dados, uma abordagem de Processamento de Linguagem Natural (PLN) revela-se mais aplicável para esse tipo de estratégia.

Em contrapartida, a Análise Técnica busca lucrar com as oscilações nos preços das ações, geralmente em um curto intervalo de tempo. Pode-se definir a Análise Técnica como o estudo da dinâmica do mercado, principalmente por meio do uso de gráficos, visando antecipar comportamentos ou tendências futuras (Lemos, 2017).

## Análise fundamentalista

A avaliação da viabilidade de investimentos, por meio da análise fundamentalista, assume uma posição central na análise financeira de empresas, direcionando o olhar para a compreensão dos fundamentos do negócio e suas projeções de longo prazo. Este processo, envolve a consideração de três pilares essenciais: análise macroeconômica, análise setorial e análise específica da empresa.

Ao analisar o pilar macroeconômico, é necessário considerar o contexto amplo em que a empresa está inserida. Elementos como PIB, índices de inflação, taxa de câmbio, taxa de juros e nível de renda não apenas influenciam o ambiente econômico geral, mas também moldam as perspectivas de negócios. Nesse sentido, a análise macroeconômica constitui-se como uma etapa crucial para uma avaliação abrangente.

A análise setorial, por sua vez, agrega complexidade ao processo, reconhecendo a disparidade de impactos nos diversos segmentos empresariais. Divergências na resposta setorial a fatores macroeconômicos, como uma taxa de câmbio valorizada, ilustram a necessidade de uma avaliação perspicaz e específica a cada setor. Aspectos como incentivos governamentais, regulamentações e mudanças estruturais adicionam camadas de complexidade a essa abordagem.

No âmbito da análise da empresa, o aprofundamento se dá mediante o estudo minucioso dos dados financeiros. o eixo da análise fundamentalista reside na busca pelo valor real da empresa, moldado pela performance do negócio e o cenário econômico. Esta análise não se limita a meras cotações momentâneas, mas busca antecipar comportamentos futuros dos ativos, considerando o horizonte de longo prazo.

O valor intrínseco de um ativo, conforme Damodaran & Serra (2000), é derivado dos fluxos de caixa esperados e ajustado pelo grau de incerteza associado. O método do Fluxo de Caixa Descontado emerge como uma ferramenta crucial nesse contexto, permitindo uma avaliação criteriosa da riqueza econômica da empresa.

A Hipótese do Mercado Eficiente, conforme Malkiel & Fama (1970), propõe uma perspectiva que supera a análise fundamentalista ao sustentar que os preços de mercado refletem todas as informações disponíveis. Essa teoria, categorizada em eficiência fraca, semi-forte e forte, desafia a ideia de ações baratas ou caras, indicando que o mercado eficiente precifica as ações em seu justo valor.

A teoria do Passeio Aleatório (Random Walk), conforme Fama (1995), reforça a imprevisibilidade dos movimentos de preços, desencorajando análises baseadas em padrões passados. Essa abordagem considera o mercado financeiro como irracional, seguindo um caminho imprevisível, independentemente de padrões históricos.

Os indicadores fundamentalistas e sua análise desempenham um papel crucial na tomada de decisões de investimento. A escolha das ferramentas adequadas depende das necessidades individuais, das condições de mercado e do apetite de risco do investidor. A combinação de vários indicadores é preferível para garantir uma análise consistente, pois

depende de um único indicador pode fornecer uma visão distorcida da realidade.

Dentre os indicadores mais relevantes, destacam-se:

- P/L (Preço / Lucro): Avalia a relação entre o preço da ação e o lucro por ação dos últimos 12 meses. Um P/L elevado pode indicar otimismo do mercado, mas também possível sobrevalorização.
- P/VPA (Preço / Valor Patrimonial por Ação): Relaciona o preço da ação ao valor patrimonial por ação. Um P/VPA alto sugere que as ações estão sendo negociadas acima do valor patrimonial, enquanto um P/VPA baixo pode indicar subvalorização.
- PSR (Price to Sales Ratio): Indica a disposição do mercado em pagar pelas ações com base na receita líquida por ação. Um PSR elevado pode sugerir sobrevalorização.
- EV (Enterprise Value): Representa o valor total de mercado de uma empresa, considerando ativos, passivos e dívida líquida. É útil para avaliações de fusões e aquisições.
- EBITDA (Lucro Antes de Juros, Impostos, Depreciação e Amortização): Mede o lucro operacional da empresa antes de descontos. A Margem EBITDA relaciona o EBITDA à receita operacional.
- CFS (Fluxo de Caixa por Ação): Indica a geração de caixa por ação, considerando o total de ações da empresa. Um CFS mais alto pode indicar maior capacidade de geração de caixa.
- DY (Dividend Yield): Aponta o potencial de pagamento de dividendos em relação ao preço da ação. Um DY elevado sugere uma boa distribuição de dividendos.
- DP (Dividend Payout): Relaciona os proventos pagos por ação ao lucro por ação. Indica a proporção do lucro distribuída como dividendos.

- DB/PL (Dívida Bruta / Patrimônio Líquido): Avalia o nível de endividamento da empresa em relação ao seu patrimônio líquido. Valores mais altos podem indicar situação financeira delicada.
- ROE (Retorno sobre Patrimônio Líquido): Mede a capacidade de geração de resultados em relação ao patrimônio líquido. Um ROE elevado indica eficiência na utilização do patrimônio.

## Análise técnica

Ao longo das décadas, a análise técnica, conforme delineada por Leite & Oliveira (2014), tem como fundamento a observação de um comportamento cíclico no mercado, proporcionando aos especuladores a oportunidade de auferir lucros em períodos de valorização de ativos específicos. A essência dessa abordagem reside na concepção de que os preços seguem uma tendência definida pela média das expectativas de retorno dos ativos. Esta modalidade analítica concentra-se na identificação de padrões de desempenho nos preços dos ativos, empregando informações de índices e indicadores, como preço da cotação atual, máximo, mínimo e volume de negociações.

Conforme apontado por Passos & Pinheiro (2009), na análise técnica, pressupõe-se que os efeitos das informações que emergem no mercado são disseminados e interpretados pelos investidores. As decisões desses investidores, por conseguinte, contribuem automaticamente para o ajuste dos preços dos ativos. Além disso, analistas técnicos têm a flexibilidade de aderir a diferentes modalidades operacionais, como day trade e swing trade, cada uma delineando estratégias diversas de investimento conforme os objetivos específicos do trader.

A evolução ao longo dos anos trouxe à tona ferramentas essenciais para a análise das tendências do mercado, denominadas indicadores técnicos. Esses indicadores visam indicar a operação mais rentável no momento, considerando dados como volume financeiro negociado e preços passados. Colby & Meyers (1988) classificam esses indicadores em categorias distintas, tais como Rastreadores de Tendências, que verificam a tendência



através do histórico de preços, Osciladores, que flutuam entre níveis preestabelecidos, Indicadores de Volatilidade, medidores da dispersão dos preços, e Indicadores de Volume, que evidenciam a força do mercado por meio do volume de negociações. É conhecido que esses indicadores, constituem fórmulas matemáticas que alertam para comportamentos prováveis, validam informações de outros indicadores ou até mesmo preveem o comportamento futuro de uma série histórica do ativo. A prática consolidada é a combinação de padrões gráficos e indicadores técnicos, para embasar decisões de operação mais refinadas. Em diversas abordagens, observa-se a utilização de um conjunto de indicadores técnicos para reconhecer padrões em séries temporais, contribuindo para a classificação da melhor operação de negociação no momento. Essa abordagem integrada representa uma estratégia robusta na dinâmica do mercado financeiro.

Gráfico 3 – Bandas de Bollinger



Fonte: Money Times, 2023.

Gráfico 4 – iShares Ibovespa Fundo de Índice (BOVA11)



Fonte: Trading View, 2024.

## Técnicas de previsão no mercado acionário

Frente à volatilidade do mercado de capitais, os investidores buscam empregar mecanismos de previsão para antecipar os movimentos do mercado e operar de maneira a maximizar seus ganhos. Para superar esse desafio, alguns pesquisadores têm contribuído com estudos que combinam conhecimentos econômicos a procedimentos tecnológicos aplicados a dados históricos do mercado financeiro. Algumas dessas pesquisas serão apresentadas como exemplos.

Wolff *et al.* (2011) focalizou a análise do comportamento da série do Índice Bovespa usando dados mensais de janeiro de 1995 a novembro de 2009. A aplicação da metodologia Box & Jenkins permitiu a formulação de modelos Autoregressive Integrated Moving Average (ARIMA) para prever a curto prazo os valores do índice nos seis meses seguintes. O modelo mais adequado, sob o critério Akaike Information Criterion (AIC), foi identificado como ARIMA (2,1,1). Os resultados indicaram uma ausência de tendência definida no desempenho do Ibovespa, levando os autores a aconselhar cautela nos investimentos em ações até a identificação de uma tendência de alta.

Seguindo essa abordagem, Gaio *et al.* (2007) conduziu um estudo sobre a volatilidade dos retornos do Índice Bovespa, utilizando modelos de série temporal da classe Autoregressive Conditional Heteroskedasticity (ARCH). A análise da volatilidade é crucial para compreender a direção e velocidade do mercado, permitindo um gerenciamento de risco eficaz. Os modelos Generalized Autoregressive Conditional Heteroskedasticity (GARCH), Exponential Generalized AutoRegressive Conditional Heteroskedasticity (EGARCH) e Threshold AutoRegressive Conditional Heteroskedasticity (ARCH) mostraram-se adequados, destacando-se o modelo EGARCH (1,1). Os resultados revelaram uma assimetria na volatilidade das ações, indicando que choques negativos têm maior impacto e duração em comparação a choques positivos.

Nametala *et al.* (2016) apresentou uma estratégia de investimento automatizada por meio de um robô investidor. O estudo incluiu previsões de preços usando uma rede neural artificial e preditores econométricos como Simple Moving Average (SMA), Autoregressive Moving Average (ARMA), ARIMA e GARCH. Os valores previstos foram ajustados por uma segunda rede neural, e os resultados indicaram que a combinação de preditores pelo robô investidor superou as previsões individuais e estratégias aleatórias e buy and hold para a maioria dos ativos avaliados.

Giacomel (2016) desenvolveu um estudo de previsão de comportamento de séries temporais financeiras, utilizando ensembles de redes neurais para diferentes tipos de investimento. Os resultados mostraram que o método foi eficaz em diferentes cenários, superando estratégias como Buy and Hold e Trivial.

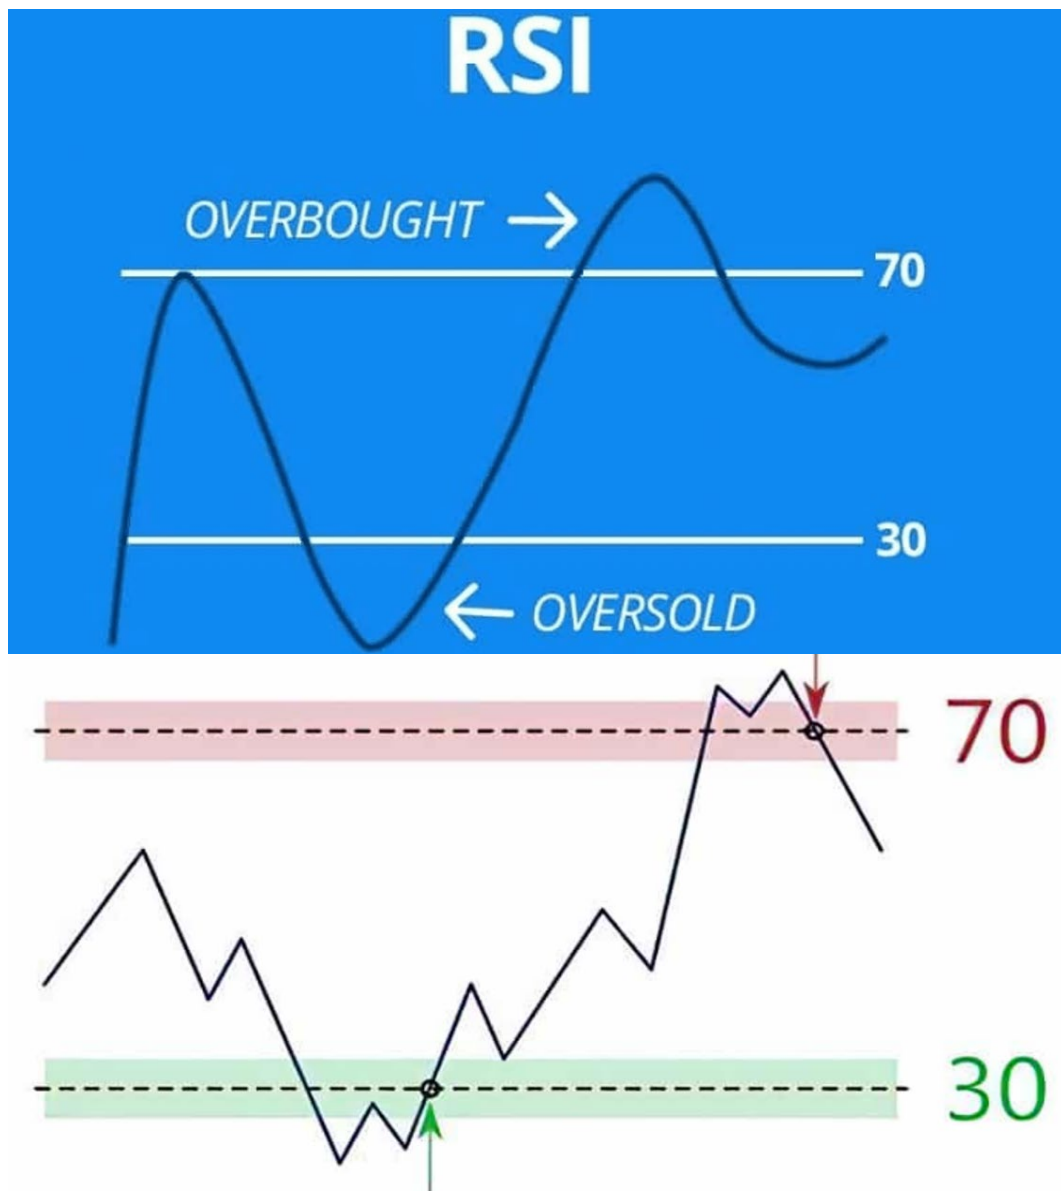
Lucca (2018) avaliou previsões de volatilidade no mercado financeiro brasileiro, utilizando preditores em uma série de variáveis referentes ao BOVA11. A comparação entre o modelo Heterogeneous Autoregressive (HAR) e modelos por regularização indicou que estes últimos foram mais eficientes para as particularidades do estudo.

# Indicadores técnicos

- Índice de Força Relativa (**Relative Strength Index - RSI**)

O Índice de Força Relativa (RSI) é uma ferramenta técnica usada por traders para analisar movimentos de preços. Mede a força comparando ganhos e perdas médias durante 14 dias. Varia de 0 a 100, sendo acima de 70 considerado sobrecomprado e abaixo de 30, sobrevendido. Divergências indicam potenciais reversões. Valores extremos sugerem pontos de entrada ou saída. RSI é uma ferramenta versátil para identificar tendências, condições de mercado e oportunidades de negociação (Wilder, 1978).

Figura 1 – O que é o Índice de Força Relativa (RSI).



Fonte: Akwu, 2023.

O cálculo do RSI ocorre em dois passos distintos. Inicialmente, utiliza-se a seguinte fórmula:

$$RSI_1 = 100 - \frac{100}{1 + \frac{GanhoMédio}{PerdaMédia}}$$

Ganho Médio e Perda Média representam as médias dos dias com fechamento positivo e negativo, respectivamente, ao longo de um período, tipicamente de 14 dias. Isso garante que, se os preços aumentarem exclusivamente na última janela de tempo analisada, o indicador se aproxime de 100, enquanto se apenas diminuïrem, ele se aproxima de 0.

Após acumular dados suficientes no histórico, o segundo passo pode ser calculado da seguinte forma:

$$RSI_2 = 100 - \frac{100}{1 + \frac{GanhoMédioAnterior - GanhoAtual}{PerdaMédiaAnterior - PerdaAtual}}$$

Ganho Médio Anterior e Perda Média Anterior representam as mesmas médias mencionadas anteriormente considerando a partir do instante anterior ao atual.

**Gráfico 5 – Oscilações de compra e venda.**



Fonte: Akwu, 2023.

- Williams %R (WR)

O indicador William %R, frequentemente abreviado como W%R, é um oscilador de inércia que expressa a variação do preço de fechamento em relação ao valor mais elevado para o período determinado. O W%R oscila entre 0 e -100, sendo que leituras de 0 a -20 são consideradas condições de sobrecompra, enquanto aquelas de -80 a -100 são consideradas sobrevendidas. Geralmente, é empregado um período de 14 para a análise (Williams, 1998). A fórmula de cálculo para o W%R é:

$$W\%R = \frac{MáximoPeríodo - FechamentoAtual}{MáximoPeríodo - MínimaPeríodo} * -100$$

As variáveis Máximo Período, Mínima Período e Fechamento Atual representam preço máximo, mínimo e preço de fechamento atual, respectivamente.

**Gráfico 6 – Williams %R como indicador de momento.**



Fonte: Bússola do Investidor, 2013.

- Índice de Fluxo Monetário (Money Flow Index - MFI)

O Índice de Fluxo de Dinheiro (MFI) é uma ferramenta na análise técnica que mede a pressão de compra e venda, utilizando preço e volume. Sua representação gráfica oscila entre 0 e 100, funcionando como um oscilador. Aumentos indicam pressão de compra, enquanto quedas indicam pressão de venda. O MFI fornece sinais de sobrecompra, sobrevenda, divergências e falhas de movimento. A combinação de preço e volume revela valores positivos em ascensão do preço (pressão compradora) e valores negativos em declínio do preço (pressão vendedora), considerando as variações do Preço Típico (TP). Seu cálculo em quatro etapas, frequentemente em períodos de 14, segue a metodologia proposta por Quong & Soudack (1989).

Preço Típico - *Typical Price (TP)*:

$$TP = \frac{Máximo + Mínimo + Fechamento}{3}$$

Fluxo Monetário Bruto - *Raw Money Flow (RMF)*:

$$RMF = TP * Volume$$

Taxa de fluxo monetário - *Money Flow Ratio (MFR)*:

$$MFR = \frac{\sum_{i-t}^i RMF_{Positivo}}{\sum_{i-t}^i RMF_{Negativo}}$$

$$MFI = 100 - \frac{100}{1 + MFR}$$

Gráfico 7 – Comportamento do MFI.



Fonte: Bússola do Investidor, 2013.

- Índice de Canal de Mercadoria (Commodity **Channel Index - CCI**)

O Commodity Channel Index (CCI), desenvolvido por Donald Lambert, é um oscilador de análise técnica amplamente utilizado. Sua introdução ocorreu nos anos 80 através da revista *Commodities*. Este indicador, parte da família de indicadores principais, mede a variação de um ativo em relação à sua média estatística. Calculado como a diferença entre o preço típico de um produto e sua média móvel simples, dividida pelo desvio médio absoluto do preço típico, o CCI é dimensionado por um fator inverso de 0,015.

Sua aplicação vai além das commodities, estendendo-se a moedas estrangeiras e ações da bolsa. O CCI é reconhecido por identificar tendências de ciclos e é utilizado na análise técnica para determinar condições de sobrecompra e sobrevenda. Sua versatilidade o torna uma ferramenta comum em plataformas de negociação, sendo ajustável conforme o período de tempo do mercado escolhido. Além disso, o CCI destaca-se como um indicador de momento, alertando sobre o início de novas tendências ou condições extremas (Lambert, 1983).

$$CCI = \frac{TP * SMA_{20}(TP)}{0.015 * DesvioMédio}$$

A variável TP é calculada com a mesma fórmula utilizada no MFI. SMA, do inglês *Simple Moving Average*, consiste em uma média móvel de preços típicos do período.

Exemplo prático para o cálculo do Índice de Canal de Mercadoria (CCI). Suponha que temos os seguintes dados para uma ação em um determinado dia:

Preço Máximo: \$120 Preço Mínimo: \$100 Preço de Fechamento: \$110

Primeiro, calculamos o Preço Típico (TP):

$$TP = \frac{Máximo + Mínimo + Fechamento}{3} = \frac{120 + 100 + 110}{3} = \$110$$

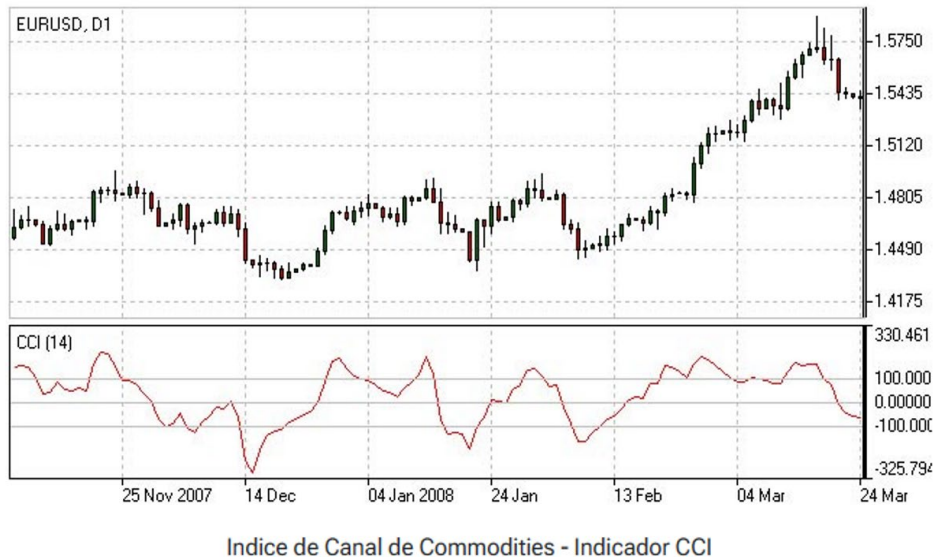
Suponha que a Média Móvel Simples de 20 dias (SMA20) do TP seja \$105 e o Desvio Médio seja \$5. Então, o CCI é calculado como:

$$CCI = \frac{TP - SMA_{20}(TP)}{0.015 * DesvioMédio} = \frac{110 - 105}{0.015 * 5} = 66.67$$



Portanto, o valor do CCI para essa ação nesse dia específico é 66.67. Este valor é usado para identificar condições de sobrecompra e sobrevenda no mercado. Valores de CCI acima de +100 podem indicar uma condição de sobrecompra, enquanto valores abaixo de -100 podem indicar uma condição de sobrevenda.

**Gráfico 8 – Indicador CCI.**



Fonte: IFC Market, 2023.

## Análise temporal e teoria financeira

Os valores das ações, embora altamente voláteis, geralmente seguem uma tendência ascendente ao longo do tempo, refletindo um aumento médio constante. Esta característica faz da estratégia de compra e retenção (BH) a preferida por muitos investidores. Uma série temporal é considerada estacionária quando evolui ao redor de uma média constante, indicando um equilíbrio estável. Nesse contexto, propriedades estatísticas como média ou desvio padrão perdem relevância a longo prazo (Bueno, 2008).

Para analisar padrões em séries temporais, como as de ações, a abordagem de estacionarização dos preços facilita a previsão de comportamento futuro, baseando-se na consistência das propriedades estatísticas ao longo do tempo. Em um estudo de Lee, Lee & Lee (2010), que investigou a estacionariedade nos preços das ações em 32 países desenvolvidos e 26 em desenvolvimento, concluiu-se que os índices reais de preços de ações são processos estacionários, contradizendo a Hipótese de Mercado Eficiente. Isso sugere a presença de oportunidades lucrativas e de arbitragem entre os mercados de ações.

O Preço de Fechamento Estacionário (PFE) é calculado mediante o método da primeira diferença, que envolve subtrair o valor do período anterior do valor atual. Essa diferenciação elimina o efeito acumulado da série, destacando apenas a variação entre os períodos T e T-1 em toda a série temporal. Em adição ao que foi anteriormente elucidado, os mercados financeiros constituem um tópico abrangente e meticulosamente explorado na literatura, destacando-se, dentre os diversos temas, a análise da Hipótese do Mercado Eficiente (EMH) conforme proposta por Fama em 1970.

A referida teoria postula que a concorrência entre os numerosos participantes inteligentes de um mercado garante que os preços efetivos dos ativos individuais reflitam prontamente e de maneira precisa as informações decorrentes de eventos passados e as expectativas futuras do mercado. A eficiência de mercado pode ser caracterizada em três distintos níveis:

- a) EMH de forma robusta: indicando que todas as informações pertinentes acerca do valor de uma ação são prontamente e precisamente incorporadas ao preço de mercado.
- b) EMH de forma parcialmente robusta: uma abordagem ligeiramente menos rígida e mais acessível para testes em comparação com a forma robusta.
- c) EMH de forma frágil: implicando que prever o preço futuro a partir da análise de preços passados é impraticável.

No domínio da análise de sistemas econômicos, a dependência extensiva de dados de séries temporais é inquestionável. Observou-se que diversas categorias de séries temporais financeiras, especialmente os retornos de mercado, manifestam memória de longo prazo e flutuações diárias substanciais que não podem ser devidamente representadas por distribuições de cauda leve, como a distribuição normal. Modelos tradicionais de média móvel autorregressiva (ARMA), utilizados para a análise de dados de séries temporais, revelam incapacidade para acomodar essas propriedades. Adicionalmente, várias extensões de modelos ARMA, como o modelo Heteroscedástico condicional autorregressivo generalizado (GARCH), demonstram ser inadequadas para capturar a genuína natureza dos dados

empíricos (Thompson & Wilson, 2016). A projeção dos valores de ações pode ser equiparada a um problema recorrente de séries temporais, assemelhando-se à previsão de preços de outros ativos, como destacado por Pintelas *et al.* (2020). Ainda não existe um consenso unânime entre os economistas; entretanto, alguns estudos sustentam que a viabilidade de mercados eficientes é questionável, e o grau de eficácia influencia o empenho que as pessoas estão dispostas a investir na coleta e negociação de informações (Lo & Mackinlay, 2011).

## ***Técnicas estatísticas de previsão através de séries temporais***

A análise de séries temporais visa modelos para prever o futuro das variáveis, levando em conta características como média, sazonalidade, ciclo e tendência (Henning, Alves & Konrath, 2010; Makridakis, Wheelwright & Hyndman, 1998; Pellegrini & Fogliatto, 2001). A escolha do método depende do comportamento do fenômeno e do conhecimento prévio sobre sua natureza, utilizando medidas de desempenho, como o erro quadrático médio (MSE), para selecionar o método mais preciso e que melhor se ajusta aos dados existentes (Ragsdale, 2009).

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

Dessa forma, a seleção do método de previsão mais adequado pode ser feita utilizando uma ou mais medidas estatísticas de desempenho em relação aos erros de previsão. Isso é baseado na soma dos erros gerados por cada método, representados por:

$e_t = Z_t - \hat{Z}_t$ , onde  $Z_t$  , onde  $Z_t$  é o valor atual (valor real) para o período  $t$  e  $\hat{Z}_t$  é o valor previsto para o mesmo período.

### ***Método de suavização exponencial simples***

A suavização exponencial simples, proposta por Brown (1959, 1963), é um método

de previsão adequado para séries temporais que flutuam aleatoriamente em torno de um valor fixo, sem tendência. Este método é útil para prever valores futuros da série (Makridakis, Wheelwright & Hyndman, 1998).

$$\hat{Z}_{t+1} = \alpha Z_t + (1 - \alpha)\hat{Z}_t, 0 \leq \alpha < 1$$

Onde,  $\hat{Z}_{t+1}$  é o valor previsto para o período de tempo  $t + 1$ ,  $\alpha$  é o parâmetro constante de suavização do método; que pode assumir qualquer valor entre 0 e 1 ( $0 \leq \alpha < 1$ );  $Z_t$ , é o valor observado atual (valor real) para o período de tempo  $t$  e,  $\hat{Z}_t$  é o valor previsto para o mesmo período de tempo  $t$ . A constante de suavização,  $\alpha$ , é escolhida de forma a minimizar o erro quadrático médio (MSE), que é uma medida do erro de previsão. Isso é feito através de um processo iterativo, onde diferentes valores de  $\alpha$  são testados até encontrar o que produz o menor MSE (Pellegrini & Fogliatto, 2001).

Examinemos a conexão entre dois fatores usando a regressão linear simples. Essa técnica usa uma fórmula para traçar uma linha, facilitando o entendimento dessa relação. Para ilustrar isso, podemos recorrer a um estudo do economista John Keynes. Ele percebeu que, geralmente, as pessoas gastam mais quando ganham mais dinheiro. Basicamente, isso é uma simplificação de como as pessoas decidem gastar com base no aumento da renda (Alura, 2022).

Na tabela abaixo, podemos visualizar as cinco primeiras observações do conjunto de dados:

Tabela 1 – Conjunto de dados.

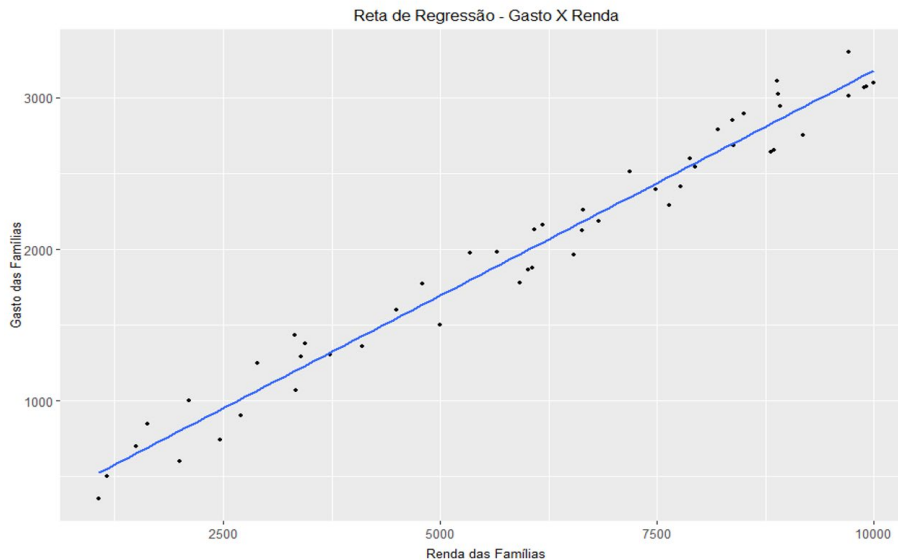
	Gasto	Renda
1	3011	9714
2	1305	3728
3	1879	6062
4	2654	8845
5	2849	8378

Fonte: elaborado pelo autor.

Podemos criar uma relação entre gasto e renda da seguinte forma:

$$Gasto = \beta_0 + \beta_1 Renda$$

**Gráfico 9 – Reta de regressão – gasto x renda.**



Fonte: elaborado pelo autor.

Podemos perceber que quanto menor a renda (X) menor é o gasto das famílias (Y). Ao centro, há uma nuvem de pontos na qual foi ajustada uma reta linear crescente que nos permite entender o comportamento médio dos gastos familiares. Mas, como passamos da função  $Gasto = \beta_0 + \beta_1 Renda + erro$ ?


Independente do seu conjunto de dados, será ajustada uma reta que genericamente podemos representar pela função abaixo:

$$Y = INTERCEPTO\beta_0 + COEFICIENTE\ ANGULAR\beta_1 X_{VARIÁVEL\ EXPLICATIVA} + ERRO$$

O conjunto de valores Y, que está sujeito a uma explicação, é considerado como uma variável dependente, enquanto X é identificada como a variável independente e explicativa. No contexto específico deste exemplo, o gasto da família é contingente à sua renda. O parâmetro  $\beta_0$ , também denominado intercepto, representa o valor de Y quando a variável independente  $X_i$  é igual a zero. Em contrapartida, o coeficiente angular  $\beta_1$ , fornece informações acerca da taxa de variação e da inclinação da reta representativa do modelo. Ambos os parâmetros,  $\beta_0$  e  $\beta_1$ , são desconhecidos e precisam ser estimados,

para estimação desses coeficientes o método dos mínimos quadrados é o mais utilizado (Alura, 2022).

Gráfico 10 – Ângulos dos betas.



Fonte: elaborado pelo autor.


A partir dos nossos dados e desse processo de estimação, podemos calcular os betas com as seguintes fórmulas:

$$\hat{\beta}_1 = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{n \sum X_i^2 - (\sum X_i)^2}$$

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$$

Observa-se que nem todos os pontos exibem alinhamento perfeito com a reta ajustada por nosso modelo. Para abordar essa disparidade, torna-se necessário incorporar o componente de erro em nossa fórmula, representado pela diferença entre o valor observado e o valor predito pela equação conforme o gráfico abaixo:

Gráfico 11 – Incorporação do componente de erro na fórmula.



Fonte: elaborado pelo autor.

## Suavização exponencial dupla

A suavização exponencial dupla, conhecida como método de Holt, é uma ferramenta de previsão desenvolvida por Holt (1957). Ela é uma extensão da suavização exponencial simples, adaptada para dados de série temporal com uma tendência linear. O método incorpora uma constante de suavização para ajustar a tendência da série, proporcionando refinamentos adicionais na modelagem.

$\hat{Z}_{t+n} = L_t + nT_t$ , onde a previsão para o período de tempo  $t+n$  ( $\hat{Z}_{t+n}$ ) é igual estimativa do nível esperado da série temporal no período de tempo  $t$  ( $L_t$ ) mais a influência esperada da tendência (taxa de aumento ou redução) durante os próximos  $n$  períodos ( $nT$ ). A equação de previsão pode ser usada para obter projeções futuras para períodos de tempo  $n$ , onde  $n = 1, 2, 3$ , e assim por diante. O método de Holt utiliza os parâmetros  $\alpha$  e  $\beta$ , conhecidos como constantes de suavização. Além da função de previsão, duas outras funções são empregadas para estimar o nível e a tendência da série temporal, conforme suas respectivas equações.

$$L_t = \alpha Z_t + (1 - \alpha)(L_{t-1} + T_{t-1}), \quad 0 \leq \alpha \leq 1$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, \quad 0 \leq \beta \leq 1$$

Onde  $L_t$  é a estimativa para o nível da série no período  $t$  e  $T_t$  é a estimativa da

inclinação (tendência) da série no mesmo período  $t$ . A equação  $\hat{Z}_{t+n} = L_t + nT_t$ , ajusta  $L_t$  para a tendência do período anterior  $T_{t-1}$ , adicionando o último valor suavizado,  $L_{t-1}$ .

Os parâmetros  $\alpha$  e  $\beta$  são determinados através de testes na série histórica, geralmente selecionando os que minimizam o erro quadrático médio (MSE). Várias pesquisas têm mostrado como otimizar esses parâmetros para melhorar a precisão da previsão. Rasmussen (2004) propôs um método para otimizar tanto os parâmetros  $\alpha$  e  $\beta$  quanto os valores iniciais, usando o MSE como função objetivo a ser minimizada, com a ajuda da ferramenta solver do MS-Excel.

Para ilustrar a aplicação do método de Holt na previsão de preços de ações, considere-se uma ação hipotética de uma empresa. Assuma-se que o preço atual da ação é de R\$100, denotado por  $L_t$ , e que a tendência  $T_t$  é de um aumento de R\$5 por período. A previsão do preço da ação para o próximo período ( $(n=1)$ ) é calculada utilizando a fórmula de previsão do método de Holt:  $\hat{Z}_{t+n} = L_t + nT_t$ , substituindo os valores na fórmula, temos:

$\hat{Z}_{t+1} = R\$100 + 1 * R\$5 = R\$105$ , portanto, com base no método de Holt, a previsão do preço da ação para o próximo período seria de \$105.

Agora utilizando a equação:

$$L_t = \alpha Z_t + (1-\alpha)(L_{t-1} + T_{t-1}), \quad 0 \leq \alpha \leq 1$$

Suponha que temos o preço de uma ação em diferentes períodos de tempo e queremos prever o preço para o próximo período. Aqui,  $L_t$  é a estimativa do nível da série no  $t$ ,  $Z_t$  é o preço da ação no período  $t$ ,  $\alpha$  é uma constante de suavização que pode variar entre 0 e 1,  $T_{t-1}$  é a estimativa da tendência da série no período anterior  $t-1$ , e  $L_{t-1}$  é a estimativa do nível da série no período anterior  $t-1$ .

A equação  $L_t = \alpha * Z_t + (1-\alpha) * (L_{t-1} + T_{t-1})$  é usada para atualizar a estimativa do nível da série com base no preço da ação mais recente e na estimativa do nível e tendência do período anterior.

Por exemplo, se o preço da ação no período atual  $Z_t$  é \$50, a estimativa do nível



no período anterior  $L_{t-1}$  é \$48, a estimativa da tendência no período anterior  $T_{t-1}$  é \$2, e a constante de suavização  $\alpha$  é 0.5, então a estimativa do nível para o próximo período seria:

$$L_t = 0.5 * R\$50 + (1 - 0.5) * (R\$48 + R\$2) = R\$50.$$

Portanto, a estimativa do nível para o próximo período é R\$50. Isso significa que esperamos que o preço da ação seja em torno de \$50 no próximo período, assumindo que a tendência continue a mesma.

A equação:

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, \quad 0 \leq \beta \leq 1$$

Suponha que temos o preço de uma ação em diferentes períodos de tempo e queremos prever o preço para o próximo período. Aqui,  $L_t$  é a estimativa do nível da série no período  $t$ ,  $T_{t-1}$  é a estimativa da tendência da série no período anterior  $t-1$ , e  $L_{t-1}$  é a estimativa do nível da série no período anterior  $t-1$ .

A equação  $T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$  é usada para atualizar a estimativa da tendência da série com base na mudança no nível da série e na estimativa da tendência do período anterior.

Por exemplo, se a estimativa do nível no período atual  $L_t$  é R\$50, a estimativa do nível no período anterior  $L_{t-1}$  é R\$48, a estimativa da tendência no período anterior  $T_{t-1}$  é R\$2, e a constante de suavização  $\beta$  é 0.5, então a estimativa da tendência para o próximo período seria:

$$T_t = 0.5 * (R\$50 - R\$48) + (1 - 0.5) * R\$2 = R\$1 + R\$1 = R\$2$$

Portanto, a estimativa da tendência da série para o próximo período seria R\$2. Isso significa que esperamos que o preço da ação aumente em R\$2 no próximo período, assumindo que a tendência continue a mesma.

## Suavização exponencial tripla

O método Holt-Winters, uma expansão do método Holt, é amplamente utilizado na previsão de curto prazo da demanda em séries temporais com tendência e sazonalidade. Reconhecido por sua simplicidade, baixo custo operacional e rápida capacidade de ajuste, destaca-se pela eficácia na modelagem de séries temporais. Winter (1960) enfatiza sua adequação para captar características repetitivas em intervalos regulares, abordando efeitos sazonais multiplicativos e aditivos.

### Método para efeitos sazonais multiplicativos

A abordagem de Holt-Winter para efeitos sazonais multiplicativos é empregada na modelagem de dados em que a variação da amplitude do ciclo sazonal está diretamente relacionada ao nível da série ao longo do tempo. Imagine um cenário com um modelo de série sazonal, período  $S$ , fator sazonal multiplicativo e uma tendência aditiva, explicado pela equação:

$$Z_t = L_t S_t + T_t + \epsilon_t, \quad t=1,2,\dots$$

Que explica o padrão estrutural da série. As previsões dos valores futuros da série são calculadas usando a função de projeção do método, expressa por,

$$\hat{Z}_{t+n} = (L_t + nT_t) S_{t-s+n}, \quad n=1,2,\dots$$

Onde,  $\hat{Z}_{t+n}$  é a previsão para  $n$  períodos à frente ( $t+n$ ). Além deste método existem mais três equações que explicam o nível, a tendência e os valores para os efeitos sazonais, conforme as respectivas funções:

$$L_t = \alpha \frac{Z_t}{S_{t-s}} + (1-\alpha)(L_{t-1} + T_{t-1}); \quad 0 \leq \alpha \leq 1$$

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1}; \quad 0 \leq \beta \leq 1$$

$$S_t = \gamma \frac{Z_t}{L_t} + (1-\gamma)S_{t-s}, \quad 0 \leq \gamma \leq 1$$

Onde  $\alpha$ ,  $\beta$ , e  $\gamma$  representam as constantes de suavização que influenciam o peso relativo do nível ( $L_t$ ), da tendência ( $T_t$ ), e da sazonalidade ( $S_t$ ), respectivamente,

consideramos que, no instante  $t$ , há uma estimativa do índice sazonal no período  $t-s$  ou um valor  $S_{t-s}$ . Assim, torna-se necessário estimar os valores para  $S_1, S_2, \dots, S_p$ . Uma abordagem simples para essas estimativas sazonais iniciais, essenciais para aplicar as equações de suavização, é permitir que:

$$S_t = \frac{Z_t}{\sum_{n=1}^s \frac{Z_n}{S}}, \quad t=1, 2, \dots, s.$$

Suponha que temos o preço de uma ação da empresa XYZ nos últimos três períodos: R\$50, R\$51 e R\$52. Queremos prever o preço para o próximo período.

- Estimativa do nível da série ( $L_t$ ): Suponha que a estimativa do nível no período anterior ( $L_{t-1}$ ) foi R\$51, a estimativa da tendência ( $T_{t-1}$ ) foi R\$1 e o fator sazonal correspondente ao último período ( $S_{t-s}$ ) foi 1. Usando uma constante de suavização  $\alpha$  de 0.5, a estimativa do nível para o período atual seria  $L_t = \alpha \cdot (Z_t / S_{t-s}) + (1-\alpha) \cdot (L_{t-1} + T_{t-1}) = 0.5 \cdot (R\$52 / 1) + (1-0.5) \cdot (R\$51 + R\$1) = R\$52$ .
- Estimativa da tendência da série ( $T_t$ ): Usando uma constante de suavização  $\beta$  de 0.5, a estimativa da tendência para o próximo período seria  $T_t = \beta \cdot (L_t - L_{t-1}) + (1-\beta) \cdot T_{t-1} = 0.5 \cdot (R\$52 - R\$51) + (1-0.5) \cdot R\$1 = R\$1$ .
- Estimativa do fator sazonal ( $S_t$ ): Usando uma constante de suavização  $\gamma$  de 0.5, a estimativa do fator sazonal para o próximo período seria  $S_t = \gamma \cdot (Z_t / L_t) + (1-\gamma) \cdot S_{t-s} = 0.5 \cdot (R\$52 / R\$52) + (1-0.5) \cdot 1 = 1$ .

Portanto, a previsão do preço da ação para o próximo período seria  $Z_{t+n} = L_t + n \cdot T_t \cdot S_{t-s} = R\$52 + 1 \cdot R\$1 \cdot 1 = R\$53$ . Isso significa que esperamos que o preço da ação seja em torno de R\$53 no próximo período, assumindo que a tendência e o fator sazonal continuem os mesmos.

## Regressão linear múltipla

A análise de dependência entre variáveis é comumente abordada por meio da técnica de regressão linear, uma ferramenta amplamente empregada em pesquisas devido

à sua adaptabilidade (Hair Jr. *et al.*, 2005). Esse método avalia a relação entre uma ou mais variáveis independentes e uma variável dependente determinada pelo pesquisador. Por meio da estimativa de uma equação linear, é possível utilizar os valores conhecidos das variáveis independentes para prever o comportamento da variável dependente.

Conforme destacado por Hair Jr. *et al.* (2005), o modelo de regressão linear oferece versatilidade ao permitir antecipar eventos, como prever as vendas de uma loja ou determinar o preço de aluguel de um apartamento (Levine *et al.*, 2012).

De acordo com Levine *et al.* (2012), o modelo de regressão linear múltipla, incorporando k variáveis independentes, pode ser formulado utilizando a fórmula:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i$$

Onde:

$Y_i$ : variável dependente para a observação i;

$\beta_0$ : intercepto de Y para a população;

$\beta_k$ : inclinação de Y em relação à variável  $X_k$ , mantendo-se constantes as demais variáveis;

$X_{ki}$ : variável independente k para a observação i;

$\varepsilon_i$ : erro aleatório para a observação i;

Para verificar a significância estatística do modelo, recorre-se ao teste F, que avalia a proporção entre a variância atribuída à regressão e a variância proveniente do erro do modelo (Levine *et al.*, 2012). Determina-se o valor crítico de F com base nos graus de liberdade das variâncias e no intervalo de significância desejado. Se o valor F observado no modelo superar o valor crítico, considera-se o modelo relevante. Da mesma forma, se o p-valor, representando a probabilidade de o valor F observado ser inferior ao F crítico, for menor que o nível de significância definido, rejeita-se a hipótese nula (Levine *et al.*, 2012). A aplicação da regressão linear múltipla permite uma análise objetiva da natureza

e intensidade das relações entre variáveis dependentes e independentes. Isso possibilita avaliar quais variáveis independentes exercem maior influência nas variações da variável dependente (Hair Jr. *et al.*, 2005). O sinal do coeficiente de inclinação  $\beta_k$  indica se a variável independente mantém uma relação positiva ou negativa com a variável dependente, ou seja, se uma alteração em  $X_k$  resulta em aumento ou redução em  $Y$ . Além disso, o valor desse coeficiente permite comparar a intensidade das alterações na variável dependente causadas por diferentes variáveis.

Para determinar se existe uma relação estatisticamente significativa entre as variáveis selecionadas para o modelo e o retorno da ação, é necessário testar a hipótese de que o coeficiente é igual a zero. Assim, as hipóteses nulas e alternativas são formuladas da seguinte maneira:

Hipótese 1:  $\beta_k = 0$  (não há relação linear entre as variáveis)

Hipótese 2:  $\beta_k \neq 0$  (existe relação linear entre as variáveis)

O teste de Student é empregado para avaliar se há evidências para rejeitar a hipótese nula. A estatística do teste compara a inclinação da reta ajustada da amostra com o valor citado na hipótese para a inclinação da reta ajustada da população, dividindo pelo erro padrão da inclinação. Se o valor calculado para cada variável ultrapassar o crítico determinado pelo teste t de Student, há evidências suficientes para rejeitar a hipótese nula, indicando uma relação entre a variável dependente e a variável independente.

## ***Exponential triple smoothing***

A exploração de séries temporais desempenha um papel crucial na compreensão e previsão de fenômenos que se desenrolam ao longo do tempo. No cenário financeiro, a precisão ao antecipar variáveis como o valor de ativos torna-se vital para a tomada de decisões estratégicas. Nesse contexto, a Exponential Triple Smoothing (ETS) emerge como uma técnica poderosa, capaz de modelar padrões complexos e oferecer projeções precisas.

O ETS, desenvolvido por Robert Goodell Brown em 1956 e aprimorado por Peter Winters em 1960, proporciona uma abordagem flexível para lidar com elementos como tendência, sazonalidade e erro. “A técnica de suavização exponencial de Brown representou a primeira tentativa significativa de lidar com séries temporais não estacionárias” (Brown, 1956). A teoria subjacente ao ETS foi formalizada por Hyndman, Koehler, Ord e Snyder, oferecendo uma estrutura conceitual sólida para a compreensão e aplicação desse método. “A abordagem de espaço de estado para a suavização exponencial proporciona uma estrutura unificada para modelar e compreender séries temporais” (Hyndman *et al.*, 2008).

# Análise empírica da ação PETR4: regressão linear e tendências de mercado no período de 03/01/2023 a 02/01/2024

Para a validação do presente estudo, foram selecionados os preços de fechamento da ação PETR4, obtidos a partir do site Yahoo Finance, referentes ao período de 03/01/2023 a 02/01/2024. Na análise, foram considerados o volume negociado das ações, as médias móveis dos preços de fechamento e as datas correspondentes. O processo de validação envolveu a aplicação da técnica de regressão linear no Microsoft Excel, visando a verificação dos erros padrão e do erro ajustado.

A análise de regressão linear permitiu examinar os coeficientes, como o  $\beta_k$  cuja significância é avaliada pela sua diferença em relação a zero. A obtenção de um valor não nulo para o  $\beta_k$  valida as duas análises realizadas. A primeira análise consistiu em um comparativo entre os preços de fechamento e as datas correspondentes, enquanto a segunda abordou a relação entre os preços de fechamento e as médias móveis dos preços. Os resultados obtidos proporcionam uma fundamentação sólida para as o estudo, validando as amostras e fornecendo insights relevantes sobre as relações entre os preços de fechamento, datas, médias móveis e volume negociado das ações PETR4 durante o período analisado, abaixo temos os resultados obtidos para a análise de regressão, conforme Tabelas 2 e 3.

Tabela 2 – Comparativo entre preço de fechamento e data.

RESUMO DOS RESULTADOS							
Estatística de regressão							
R múltiplo	0,930263402						
R-Quadrado	0,865389996						
<b>R-quadrado ajustado</b>	<b>0,864291139</b>	<b>Aproximadamente 86% do preço da ação é explicado pelas variáveis independentes, data e volume negociado.</b>					
<b>Erro padrão</b>	<b>1,634914142</b>	<b>Extremamente pequeno considerando que 86% das variáveis dependentes estão explicadas no modelo de regressão linear.</b>					
Observações	248						
ANOVA							
	gl	SQ	MQ	F	F de significação		
Regressão	2	4210,0817	2105,0408	787,5363773	2,051E-107		
Resíduo	245	654,87134	2,6729443				
<b>Total</b>	<b>247</b>	<b>4864,953</b>					

	Coefficientes	Erro padrão	Stat t	valor-P	95% inferiores	95% superiores	Inferior 95,0%	Superior 95,0%
Interseção	-1755,268268	47,57221	-36,896925	<b>4,9987E-102</b>	-1848,970961	-1661,565575	-1848,970961	-1661,565575
Variável Data	0,039568985	0,0010527	37,589244	<b>1,039E-103</b>	0,037495551	0,041642418	0,037495551	0,041642418
Variável Volume	1,86624E-09	4,615E-09	0,4044115	<b>0,686262931</b>	-7,22331E-09	1,09558E-08	-7,22331E-09	1,09558E-08

Fonte: elaborado pelo autor.

Tabela 3 – Comparativo entre preço de fechamento e médias móveis.

RESUMO DOS RESULTADOS							
Estatística de regressão							
R múltiplo	0,950153818						
R-Quadrado	0,902792277						
<b>R-quadrado ajustado</b>	<b>0,901995492</b>	<b>Cerca de 90% das minhas variáveis dependentes no caso o “preço da ação” são explicados através das minhas variáveis independentes: Volume negociado e Média Móvel.</b>					
<b>Erro padrão</b>	<b>1,384270369</b>	<b>Extremamente pequeno considerando que 86% das variáveis dependentes estão explicadas no modelo de regressão linear.</b>					
Observações	247						
ANOVA							
	gl	SQ	MQ	F	F de significação		
Regressão	2	4342,2891	2171,1446	1133,044314	3,1586E-124		
Resíduo	244	467,55389	1,9162045				
<b>Total</b>	<b>246</b>	<b>4809,843</b>					

	Coefficientes	Erro padrão	Stat t	valor-P	95% inferiores	95% superiores	Inferior 95,0%	Superior 95,0%
Interseção	-38,10244313	1,5818128	-24,087834	<b>1,93794E-66</b>	-41,21819354	-34,98669273	-41,21819354	-34,986693
Variável Volume	4,42901E-09	3,926E-09	1,1280891	<b>0,260390284</b>	-3,3044E-09	1,21624E-08	-3,3044E-09	1,216E-08
Variável Média Móvel	2,535346162	0,0559369	45,325116	<b>7,9502E-121</b>	2,425165362	2,645526961	2,425165362	2,645527

Fonte: elaborado pelo autor.



# Construção e desenvolvimento de uma base de dados

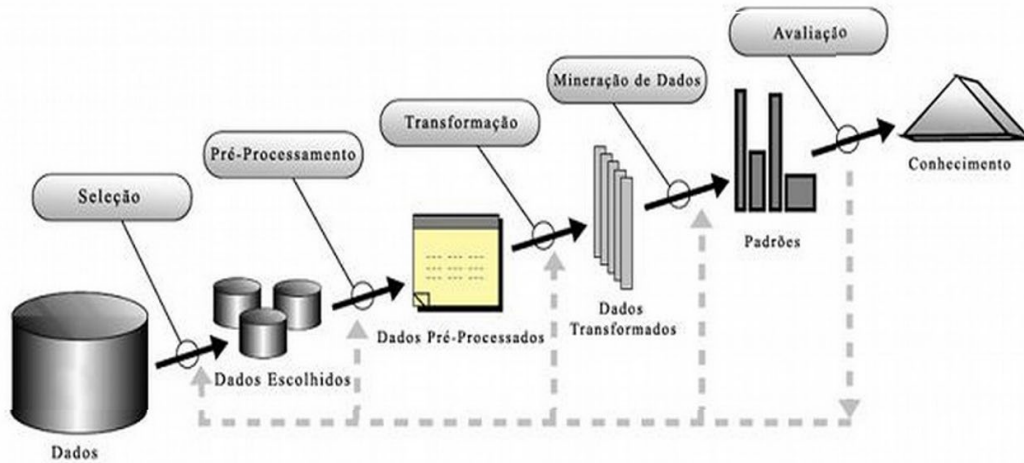
As ações representam as unidades mínimas do capital social de uma empresa, e o mercado de ações, também conhecido como mercado financeiro, refere-se à transação de compra e venda dessas ações com o propósito de investimento. Este mercado engloba uma ampla gama de empresas, resultando em um extenso banco de dados (big data) que contém informações sobre cada empresa e suas ações. A mineração desses dados possibilita a extração de informações com o objetivo de analisar os indicadores econômicos e compreender o potencial de crescimento do negócio.

A base de dados utilizada para a descoberta de conhecimento foi adquirida por meio de websites que disponibilizam o histórico e diversas outras informações sobre as ações das empresas listadas na Bolsa de Valores do Brasil. Em particular, os dados foram coletados do banco de dados do Yahoo Finance. Neste estudo, foi selecionado o histórico da ação PETR4 (uma das ações mais negociadas na B3) no período de janeiro de 2023 até 2 de janeiro de 2024.

## Etapas de da Mineração de Dados

A condução da Mineração de Dados demandou a execução de diversas etapas preliminares, conforme ilustrado na Figura apresentada abaixo. As primeiras fases desse processo, a seleção e o pré-processamento, serão detalhadas nas seções seguintes.

Figura 2 – Etapas da mineração de dados.



Fonte: elaborado pelo autor.

A primeira etapa essencial para a execução da mineração de dados consistiu na disponibilização dos dados para seleção, seguida pelo seu pré-processamento. Este estágio visou aprimorar a qualidade dos dados, tratando-os meticulosamente para evitar possíveis distorções durante a extração de conhecimento. Adicionalmente, foram realizadas transformações na base de dados, adaptando a representação dos dados para facilitar o processo de mineração e eliminar eventuais obstáculos.

A base de dados selecionada para este propósito foi construída a partir de informações coletadas na web e posteriormente importada para o ambiente de desenvolvimento Python e o software Excel. Foram gerados scripts em Python para conduzir a mineração de dados, enquanto o Excel foi utilizado para a implementação da técnica de Regressão Linear Exponential Triple Smoothing (ETS). A linguagem de programação Python desempenhou um papel integral em todas as fases da mineração, possibilitando a detecção de padrões e a criação de conexões significativas entre os dados minerados. Essa abordagem resultou em respostas mais precisas e soluções robustas em relação ao comportamento das ações e suas projeções de preços para a empresa selecionada (PETR4).

Para uma análise comparativa, o Excel também foi empregado na seleção temporal do histórico de ações, permitindo contrastar as previsões de preços obtidas especificamente na linguagem Python, com as projeções do algoritmo ETS geradas pelo Excel. Essa abordagem multifacetada proporcionou uma avaliação abrangente das técnicas utilizadas,

fornecendo insights valiosos sobre a eficácia e consistência dos métodos empregados na análise do mercado financeiro.

## Elaboração de scripts

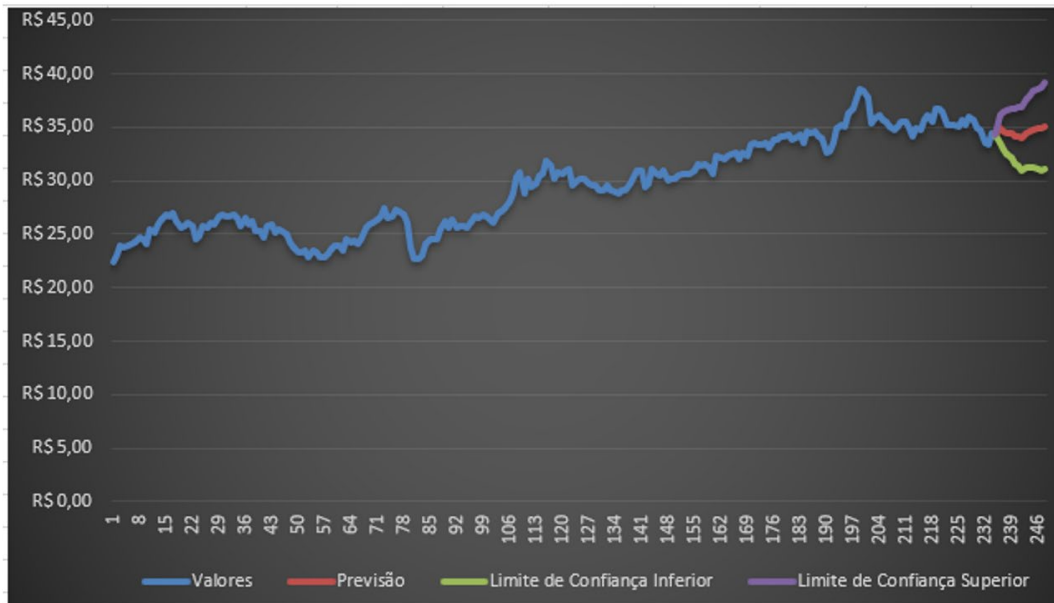
Para a implementação do algoritmo ETS e subsequente previsão de preços, foi constituída uma base de dados contemplando os valores de fechamento da ação PETR4 no período de 03/01/2023 a 02/01/2024. Entretanto, para efeitos de análise e previsão, foram utilizados apenas os dados de fechamento compreendidos entre 03/01/2023 e 11/12/2023. A previsão foi então realizada para um horizonte temporal de 13 dias, cujos resultados foram confrontados com os valores reais de fechamento. Durante este intervalo, destaca-se que as estratégias mais recomendadas são as operações de Swing Trade e Day Trade. Abaixo, apresentam-se os resultados obtidos nas previsões:

**Tabela 4 – Valores de fechamento da ação PETR4.**

DATA	ÍNDICE	R\$ FECHAMENTO	Previsão	Limite Confiança Inferior	Limite Confiança Superior
12/12/2023	236	R\$ 34,08	R\$ 34,84	R\$ 33,52	R\$ 36,15
13/12/2023	237	R\$ 34,57	R\$ 34,64	R\$ 32,93	R\$ 36,36
14/12/2023	238	R\$ 35,32	R\$ 34,48	R\$ 32,45	R\$ 36,51
15/12/2023	239	R\$ 35,40	R\$ 34,49	R\$ 32,18	R\$ 36,80
18/12/2023	240	R\$ 35,84	R\$ 34,18	R\$ 31,62	R\$ 36,74
19/12/2023	241	R\$ 36,25	R\$ 34,16	R\$ 31,37	R\$ 36,94
20/12/2023	242	R\$ 36,38	R\$ 33,94	R\$ 31,37	R\$ 36,94
21/12/2023	243	R\$ 36,39	R\$ 34,44	R\$ 30,94	R\$ 37,64
22/12/2023	244	R\$ 36,74	R\$ 34,61	R\$ 31,25	R\$ 37,99
26/12/2023	245	R\$ 37,33	R\$ 34,79	R\$ 31,23	R\$ 38,34
27/12/2023	246	R\$ 37,36	R\$ 34,85	R\$ 31,12	R\$ 38,57
28/12/2023	247	R\$ 37,24	R\$ 34,85	R\$ 30,96	R\$ 38,74
02/01/2024	248	R\$ 37,78	R\$ 35,11	R\$ 31,07	R\$ 39,16

Fonte: elaborado pelo autor.

Gráfico 12 – Variação dos valores da ação PETR4.



Fonte: elaborado pelo autor.

- Para a execução da implementação em Python, com a importação das bibliotecas relevantes e a subsequente previsão de preços, construiu-se uma base de dados que abrange os valores de fechamento da ação PETR4 no período de 03/01/2023 a 02/01/2024. No entanto, para fins de análise e previsão, foram considerados apenas os dados de fechamento compreendidos entre 03/01/2023 e 11/12/2023. A projeção foi então realizada para um horizonte temporal de 13 dias, e os resultados foram confrontados com os valores reais de fechamento. Neste intervalo, é relevante destacar que as estratégias mais recomendadas são as operações de swing trade e day trade. A seguir, são apresentados os resultados obtidos nas previsões:

Quadro 1 – Resultados obtidos nas previsões.

```
import pandas as pd
from pandas_datareader import data as pdr
import yfinance as yf
from statsmodels.tsa.holtwinters import ExponentialSmoothing
import matplotlib.pyplot as plt

yf.pdr_override()

# Baixar dados históricos
```

```

data = pdr.get_data_yahoo("PETR4.SA", start="2023-01-03", end="2024-01-02")

# Preparar os dados para o modelo
data_train = data['Close'].loc[:'2023-12-11']
data_test = data['Close'].loc['2023-12-12':]

# Calcular a média móvel
data_train_ma = data_train.rolling(window=4).mean()

# Inicializar e ajustar o modelo
model = ExponentialSmoothing(data_train, trend='add', seasonal='add', seasonal_periods=4)
model_fit = model.fit()

# Prever os preços
forecast = model_fit.predict(start=len(data_train), end=len(data_train)+len(data_test)-1)


Quando 1 – continuação...
# Plotar os resultados
plt.plot(data_train.index, data_train.values, label='Preço de Fechamento')
plt.plot(data_train.index, data_train_ma.values, label='Média Móvel')
plt.plot(data_test.index, forecast, label='Previsão')
plt.plot(data_test.index, data_test.values, label='Preço de Fechamento Real')
plt.title('Previsão de Preços de Fechamento')
plt.xlabel('Data')
plt.ylabel('Preço de Fechamento')
plt.legend()
plt.show()

# Mostrar tabela comparativa
forecast_df = pd.DataFrame({'Data': data_test.index, 'Preço Previsto': forecast, 'Preço Real': data_test.values})
for index, row in forecast_df.iterrows():
    print(f'Data: {row['Data']}, Preço Previsto: {row['Preço Previsto']}, Preço Real: {row['Preço Real']}')

```

Fonte: elaborado pelo autor.

**Gráfico 13 – Variação da previsão de preços de fechamento.**



2023-12-12 00:00:00,	Preço Previsto: 34.48502420214288,	Preço Real: 34.080001
2023-12-13 00:00:00,	Preço Previsto: 34.56947283682972,	Preço Real: 34.569999
2023-12-14 00:00:00,	Preço Previsto: 34.46645927841197,	Preço Real: 35.319999
2023-12-15 00:00:00,	Preço Previsto: 34.57439401528195,	Preço Real: 35.400001
2023-12-18 00:00:00,	Preço Previsto: 34.691729417611676,	Preço Real: 35.840000
2023-12-19 00:00:00,	Preço Previsto: 34.77617805229851,	Preço Real: 36.25
2023-12-20 00:00:00,	Preço Previsto: 34.673164493880755,	Preço Real: 36.380000
2023-12-21 00:00:00,	Preço Previsto: 34.78109923075075,	Preço Real: 36.389999
2023-12-22 00:00:00,	Preço Previsto: 34.89843463308047,	Preço Real: 36.740001
2023-12-26 00:00:00,	Preço Previsto: 34.982883267767306,	Preço Real: 37.330000
2023-12-27 00:00:00,	Preço Previsto: 34.87986970934955,	Preço Real: 37.360000
2023-12-28 00:00:00,	Preço Previsto: 34.98780444621954,	Preço Real: 37.240001

**Fonte: elaborado pelo autor.**

- O Random Forest é reconhecido como uma técnica de aprendizado de máquina, inserindo-se no âmbito da inteligência artificial, segundo definições de Hastie, Tibshirani & Friedman (2009). No contexto do código adaptado, o Random Forest atua como modelo de regressão para prever preços de fechamento com base em dados históricos. Essa abordagem, conforme Russel & Norvig (2009), destaca a integração do Random Forest como uma aplicação de inteligência artificial no campo financeiro.

A técnica de *ensemble learning* do Random Forest, destacada por Hastie, Tibshirani & Friedman (2009), combina múltiplas árvores de decisão para aprimorar a precisão do modelo. Cada árvore é treinada em amostras diferentes dos dados, e as previsões são agregadas para formar uma previsão final. Integrar o Random Forest no código significa incorporar técnicas de inteligência artificial para prever dinamicamente os preços no mercado financeiro.

## Quadro 2 – Integração do Random Forest.

```

import pandas as pd
from pandas_datareader import data as pdr
import yfinance as yf
from sklearn.ensemble import RandomForestRegressor
import matplotlib.pyplot as plt

yf.pdr_override()

# Baixar dados históricos
data = pdr.get_data_yahoo("PETR4.SA", start="2023-01-03", end="2024-01-02")

# Preparar os dados para o modelo
data_train = data['Close'].loc[:'2023-12-11']
data_test = data['Close'].loc['2023-12-12':]
# Calcular a média móvel
data_train_ma = data_train.rolling(window=4).mean()

# Inicializar e ajustar o modelo de Aprendizado de Máquina (Random Forest)
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(data_train.index.values.reshape(-1, 1), data_train.values)

# Prever os preços
forecast = model.predict(data_test.index.values.reshape(-1, 1))


Quando 2 – continuação...
# Plotar os resultados
plt.plot(data_train.index, data_train.values, label='Preço de Fechamento')
plt.plot(data_train.index, data_train_ma.values, label='Média Móvel')
plt.plot(data_test.index, forecast, label='Previsão')
plt.plot(data_test.index, data_test.values, label='Preço de Fechamento Real')
plt.title('Previsão de Preços de Fechamento')
plt.xlabel('Data')
plt.ylabel('Preço de Fechamento')
plt.legend()
plt.show()

# Mostrar tabela comparativa
forecast_df = pd.DataFrame({'Data': data_test.index, 'Preço Previsto': forecast, 'Preço Real': data_test.
values})
for index, row in forecast_df.iterrows():
    print(f'Data: {row["Data"]}, Preço Previsto: {row["Preço Previsto"]}, Preço Real: {row["Preço Real"]}')

```

Fonte: elaborado pelo autor.

**Gráfico 14 – Variação da previsão de preços de fechamento utilizando Random Forest.**



Fonte: elaborado pelo autor.

**Quadro 3 – Preços previstos e preços reais por data de mineração utilizando Random Forest.**

Data: 2023-12-12 00:00:00,	Preço Previsto: 34.32390071868897,	Preço Real: 34.08000183105469
Data: 2023-12-13 00:00:00,	Preço Previsto: 34.48390071868897,	Preço Real: 34.56999969482422
Data: 2023-12-14 00:00:00,	Preço Previsto: 35.29390071868897,	Preço Real: 35.31999969482422
Data: 2023-12-15 00:00:00,	Preço Previsto: 35.40390071868897,	Preço Real: 35.400001525878906
Data: 2023-12-18 00:00:00,	Preço Previsto: 35.75390071868897,	Preço Real: 35.84000015258789
Data: 2023-12-19 00:00:00,	Preço Previsto: 36.15390071868897,	Preço Real: 36.25
Data: 2023-12-20 00:00:00,	Preço Previsto: 36.31390071868897,	Preço Real: 36.380001068115234
Data: 2023-12-21 00:00:00,	Preço Previsto: 35.90390071868897,	Preço Real: 36.38999938964844
Data: 2023-12-22 00:00:00,	Preço Previsto: 36.62390071868897,	Preço Real: 36.7400016784668
Data: 2023-12-26 00:00:00,	Preço Previsto: 36.95390071868897,	Preço Real: 37.33000183105469
Data: 2023-12-27 00:00:00,	Preço Previsto: 37.33390071868897,	Preço Real: 37.36000061035156
Data: 2023-12-28 00:00:00,	Preço Previsto: 37.22390071868897,	Preço Real: 37.2400016784668

Fonte: elaborado pelo autor.

- Neste código, empregou-se uma Rede Neural Recorrente (LSTM) para prever preços de fechamento de ações, uma abordagem de aprendizado profundo. A LSTM, introduzida por Hochreiter & Schmidhuber (1997), é eficaz em capturar dependências temporais complexas. Os dados foram normalizados, sequências temporais foram criadas e o modelo foi treinado conforme descrito por Brownlee (2018). A implementação seguiu princípios detalhados por Chollet (2018) em “Deep Learning with Python”.



LSTM (Long Short-Term Memory): LSTM é uma arquitetura de Rede Neural Recorrente (RNN) introduzida por Hochreiter & Schmidhuber (1997). Sua capacidade de capturar dependências temporais de longo prazo a torna eficaz para previsão em séries temporais.

**Quadro 4 – Aplicação de Rede Neural Recorrente para prever preços de fechamento de ações.**

```
import pandas as pd
from pandas_datareader import data as pdr
import yfinance as yf
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from keras.layers import Dense, LSTM
import matplotlib.pyplot as plt
yf.pdr_override()

# Baixar dados históricos
data = pdr.get_data_yahoo("PETR4.SA", start="2023-01-03", end="2024-01-02")

# Usar apenas os preços de fechamento
prices = data['Close'].values.reshape(-1, 1)

# Normalizar os dados entre 0 e 1
scaler = MinMaxScaler(feature_range=(0, 1))
prices_scaled = scaler.fit_transform(prices)

# Criar conjunto de treinamento e teste
train_size = int(len(prices_scaled) * 0.8)
train_data, test_data = prices_scaled[:train_size], prices_scaled[train_size:]

# Função para criar sequências temporais
def create_sequences(data, seq_length):
    x, y = [], []
    for i in range(len(data) - seq_length):
        x.append(data[i:(i + seq_length), 0])
        y.append(data[i + seq_length, 0])
    return np.array(x), np.array(y)

# Configurar sequências temporais
seq_length = 5
X_train, y_train = create_sequences(train_data, seq_length)
X_test, y_test = create_sequences(test_data, seq_length)

# Reshape dos dados para entrada na rede neural
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1], 1))
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
```

```

# Construir o modelo de rede neural
model = Sequential()
model.add(LSTM(50, input_shape=(X_train.shape[1], 1)))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mean_squared_error')

# Treinar o modelo
model.fit(X_train, y_train, epochs=50, batch_size=32)

```

#### Quando 4 – continuação...

```

# Fazer previsões
train_predict = model.predict(X_train)
test_predict = model.predict(X_test)

# Inverter a normalização
train_predict = scaler.inverse_transform(train_predict.reshape(-1, 1))
y_train = scaler.inverse_transform([y_train])
test_predict = scaler.inverse_transform(test_predict.reshape(-1, 1))
y_test = scaler.inverse_transform([y_test])

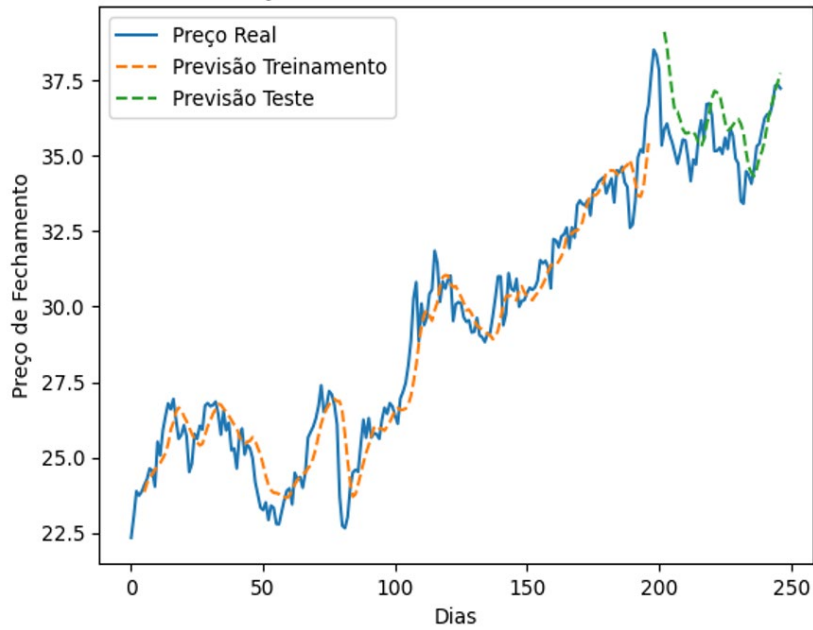
# Plotar os resultados
plt.plot(prices, label='Preço Real')
plt.plot(range(seq_length, len(train_predict) + seq_length), train_predict, label='Previsão Treinamento',
linestyle='dashed')
plt.plot(range(len(train_predict) + (seq_length * 2), len(prices)), test_predict, label='Previsão Teste', line-
style='dashed')
plt.title('Previsão de Preços de Fechamento usando LSTM (Rede Neural)')
plt.xlabel('Dias')
plt.ylabel('Preço de Fechamento')
plt.legend()
plt.show()

# Mostrar tabela comparativa
forecast_df = pd.DataFrame({'Preço Previsto': test_predict.flatten(), 'Preço Real': y_test.flatten()})
print(forecast_df

```

Fonte: elaborado pelo autor.

**Gráfico 15 – Previsão de preços de fechamento usando LSTM.**



Fonte: elaborado pelo autor.

**Quadro 5 – Preços previstos e preços reais por data de mineração utilizando LSTM.**

Data	Preço Previsto	Preço Real
0 2023-10-24	39.133930	35.880001
1 2023-10-25	38.662304	36.070000
2 2023-10-26	37.912991	35.700001
3 2023-10-27	37.190632	35.439999
4 2023-10-30	36.587475	35.080002
5 2023-10-31	36.575836	34.740002
6 2023-11-01	36.320671	35.119999
7 2023-11-03	36.019997	35.540001
8 2023-11-06	35.898777	35.509998
9 2023-11-07	35.901745	34.919998
10 2023-11-08	35.945816	34.169998
11 2023-11-09	35.922050	34.880001
12 2023-11-10	35.788975	34.720001

**Quadro 5 – continuação...**

13 2023-11-13	35.551701	35.689999
14 2023-11-14	35.468777	36.180000
15 2023-11-16	35.711823	35.549999
16 2023-11-17	36.150364	36.709999
17 2023-11-20	36.527676	36.740002
18 2023-11-21	37.033295	36.360001
19 2023-11-22	37.263931	35.160000
20 2023-11-23	37.181984	35.169998
21 2023-11-24	37.126900	35.270000
22 2023-11-27	36.708599	35.070000
23 2023-11-28	36.259838	35.599998

24	2023-11-29	35.989960	35.230000
25	2023-11-30	36.038715	35.910000
26	2023-12-01	36.160137	35.669998
27	2023-12-04	36.279987	34.910000
28	2023-12-05	36.347172	34.750000
29	2023-12-06	36.176952	33.500000
30	2023-12-07	35.878693	33.419998
31	2023-12-08	35.257626	34.490002
32	2023-12-11	34.798885	34.360001
33	2023-12-12	34.613995	34.080002
34	2023-12-13	34.482971	34.570000
35	2023-12-14	34.724613	35.320000
36	2023-12-15	35.107670	35.400002
37	2023-12-18	35.308723	35.840000
38	2023-12-19	35.651501	36.250000
39	2023-12-20	36.173195	36.380001
40	2023-12-21	36.632935	36.389999
41	2023-12-22	36.925663	36.740002
42	2023-12-26	37.250561	37.330002
43	2023-12-27	37.565830	37.360001
44	2023-12-28	37.844719	37.240002

Fonte: elaborado pelo autor.

## Conclusões sobre estratégias e seu impacto na rentabilidade financeira

**a) Introdução Geral:** Na análise abrangente dos resultados financeiros, destaca-se uma observação detalhada dos padrões consistentes e desafios ao longo do período avaliado. Esta análise visa oferecer uma compreensão aprofundada do desempenho do modelo de previsão aplicado ao mercado financeiro.

**b) Precisão das Previsões:** Em diversos cenários, o modelo revelou uma precisão notável, evidenciada pelo alinhamento estreito entre os valores previstos e os preços reais. A proximidade entre os intervalos de confiança e os valores reais reforça a confiabilidade do modelo em diversos momentos.

**c) Desafios em Determinados Períodos:** Contudo, em momentos de variações bruscas no mercado, observou-se que o modelo enfrentou desafios para prever

com precisão os preços reais. Esses períodos críticos sinalizam a importância de ajustes e refinamentos para aprimorar a capacidade do algoritmo em condições voláteis.

**d) Adaptabilidade Temporal:** A análise temporal revela que o modelo demonstrou consistência em sua capacidade de adaptação a diferentes condições de mercado ao longo do período avaliado. Essa adaptabilidade sugere uma robustez geral, destacando, no entanto, a necessidade de ajustes contínuos para otimizar seu desempenho em cenários diversos.

**e) Impacto Potencial nos Investimentos:** Com base na precisão geral das previsões, é evidente que o modelo pode ser uma ferramenta valiosa para os investidores. Suas previsões têm o potencial de influenciar estratégias de investimento, mas é crucial considerar o impacto potencial das variações nas decisões financeiras.

**f) Análise Temporal Detalhada:** Ao se aprofundar na análise diária e nas previsões de longo prazo, é possível identificar padrões diários e tendências mais amplas. A correlação dessas informações proporciona uma compreensão mais completa do desempenho do modelo em diferentes contextos temporais.

**g) Consistência em Cenários Desafiadores:** Em situações desafiadoras, como variações abruptas nos preços, o modelo demonstrou resistência. Essa consistência é crucial para estabelecer a confiança dos investidores nas previsões, mesmo durante períodos de incerteza no mercado.

**h) Potencial de Aprimoramento Contínuo:** A análise global destaca não apenas áreas de sucesso, mas também oportunidades de melhoria. A dinâmica do mercado financeiro demanda uma abordagem adaptativa, com aprimoramentos contínuos no modelo para garantir sua eficácia ao longo do tempo.

**i) Conclusões Finais:** A análise abrangente oferece uma visão equilibrada do desempenho do modelo de previsão, destacando seus pontos fortes e áreas que podem ser refinadas para otimizar seu uso no contexto do mercado financeiro.

Essas conclusões são cruciais para orientar ajustes futuros e melhorias contínuas.

**j) Considerações Futuras:** Para futuras pesquisas, é fundamental explorar ainda mais as nuances do modelo, considerando diferentes parâmetros e ajustes para aprimorar sua robustez em condições desafiadoras. Além disso, a validação do modelo em diferentes períodos e cenários pode proporcionar insights valiosos para sua aplicação prática no mercado financeiro.

# Considerações Finais

Na análise geral dos resultados financeiros, observamos padrões consistentes e desafios significativos ao longo do período avaliado. O modelo demonstrou uma expressiva precisão em muitos casos, com os valores previstos alinhando-se estreitamente aos preços reais. Isso é evidenciado pela proximidade entre os intervalos de confiança e os valores reais em várias instâncias.

Em contrapartida, em alguns momentos, especialmente durante variações bruscas do mercado, o modelo enfrentou desafios para prever com precisão os preços reais. Estes períodos podem indicar a necessidade de ajustes ou refinamentos no algoritmo para melhor lidar com condições de mercado voláteis.

Ao longo do tempo, o modelo mostrou consistência em sua capacidade de adaptação a diferentes condições de mercado. Isso sugere uma robustez geral, mas também destaca a importância contínua de ajustes para garantir um desempenho ótimo em cenários diversos.

A precisão geral das previsões sugere que o modelo pode ser uma ferramenta valiosa para os investidores, fornecendo insights que podem influenciar estratégias de investimento. No entanto, é essencial considerar o impacto potencial das variações em decisões financeiras.

A análise diária complementa a visão geral, destacando padrões diários e tendências mais amplas. A correlação dessas informações oferece uma compreensão mais completa do desempenho do modelo em diferentes contextos temporais.

O modelo mostrou resistência em situações desafiadoras, como variações abruptas nos preços. Essa consistência é crucial para garantir que os investidores possam confiar nas previsões, mesmo durante períodos de incerteza no mercado.

A análise geral destaca áreas de sucesso e oportunidades de melhoria. A natureza dinâmica do mercado financeiro exige uma abordagem adaptativa, com aprimoramentos contínuos no modelo para manter sua eficácia ao longo do tempo.

Essa análise abrangente oferece uma visão equilibrada do desempenho do modelo de previsão, destacando seus pontos fortes e áreas que podem ser refinadas para otimizar seu uso no contexto do mercado financeiro. Para futuras pesquisas, recomenda-se explorar nuances do modelo, considerar diferentes parâmetros e ajustes, e validar sua aplicação em diferentes períodos e cenários para insights valiosos no mercado financeiro.

O algoritmo desenvolvido evidenciou uma eficiência satisfatória na previsão de valorizações ou desvalorizações de ações no contexto do mercado financeiro. Acredita-se que seu potencial pode ser um contribuinte significativo para as decisões de investimento, especialmente direcionado a investidores independentes. A acessibilidade do algoritmo, caracterizada pela simplicidade de uso e pela ausência de requisitos robustos de *hardware* e rede, amplia seu alcance para uma variedade de públicos. A implementação em Python, uma linguagem em ascensão em diversas áreas da computação, confere uma usabilidade ampla, permitindo a execução em diversos dispositivos e sistemas operacionais.

A realização deste projeto não apenas aprofundou o conhecimento em Python, mas também introduziu o Exponential Triple Smoothing (ETS) como uma ferramenta valiosa para a previsão de preços. Além de facilitar a manipulação de dados, a visualização de resultados e o compartilhamento de informações, o ETS revelou-se acessível até mesmo para investidores iniciantes, utilizando o Excel para elaborar planilhas de previsão de preços de ações, índices e cotações de diversos ativos, exigindo apenas uma base de dados robusta.

O projeto abordou conceitos fundamentais de inteligência artificial ao explorar algoritmos de previsão baseados em técnicas estatísticas, destacando a importância da manipulação e processamento de grandes conjuntos de dados como habilidades cruciais para gerar informações úteis na resolução de problemas.

Como perspectiva para trabalhos futuros, sugere-se a exploração de abordagens mais complexas, considerando não apenas o histórico das ações, mas também fatores não financeiros e imprevisíveis, como aspectos políticos, situação social e aceitação do público consumidor. Reconhecendo a volatilidade e complexidade do mercado financeiro,



a aplicação de técnicas aprimoradas pode proporcionar previsões mais abrangentes e precisas.

O desafio proposto para futuros desenvolvimentos envolve a intersecção de algoritmos estatísticos com inteligência artificial aplicada ao mercado financeiro, utilizando técnicas, parâmetros e dados mais abrangentes. Essa abordagem visa enriquecer a compreensão e análise do aspecto financeiro, proporcionando novas simulações e conclusões que contribuam para uma visão mais abrangente do mercado.

# Referências

- Akwu, A. (2023). O que é o Índice de Força Relativa (RSI)? Hantec Markets. Disponível em: <https://hmarkets.com/pt-pt/learn-to-trade/learning-hub/rsi/>. Acessado em: 12 de dezembro de 2023.
- Araújo, D. *et al.* (2022). Machine learning applications in central banking. In: Proceedings of the IFC-Bank of Italy Workshop on “Data Science in Central Banking”, Part 1: Machine learning applications. Rome (virtual event). IFC Bulletin, n. 57, nov.
- Brown, R. G. (1959). Statistical forecasting for inventory control. New York, McGraw-Hill.
- Brown, R. G. (1963). Smoothing, forecasting, and prediction. Englewood Cliffs, Prentice Hall.
- Brownlee, J. (2018). Introduction to time series forecasting with python. Disponível em: <https://machinelearningmastery.com/introduction-to-time-series-forecasting-with-python/>. Acessado em: 17 de janeiro de 2024.
- Bueno, R. L. S. (2008). Econometria de séries temporais. São Paulo, Cengage Learning.
- Bússola do Investidor. (2013, 16 de setembro). Williams %R: um poderoso indicador de momento. Disponível em: <https://www.bussoladoinvestidor.com.br/williams-r-indicador-de-momento/>. Acessado em: 16 de janeiro de 2024.
- Chollet, F. (2018). Deep learning with python. New York, Manning.
- Colby, R. W. & Meyers, T. A. (1988). The encyclopedia of technical market indicators. New Jersey, Dow Jones-Irwin Homewood.
- Damoradann, A. & Serra, A. C. C. (2000). Valuation: como avaliar empresas e escolher as melhores ações. São Paulo, Grupo Gen-LTC.
- Duarte, A. (2022, 07 de fevereiro). Desvendando a regressão linear. Disponível em: <https://www.alura.com.br/artigos/desvendando-a-regressao-linear>. Acessado em: 27 de dezembro de 2023.
- European Commission. (2020). White paper on artificial intelligence - a european approach to excellence and trust. Bruxelas.
- Fama, E. F. (1995). Random walks in stock market prices. Financial Analysts Journal, 51(1):75-80.
- Gaio, L. E. *et al.* (2007). Análise da volatilidade do índice Bovespa: um estudo empírico utilizando modelos da classe ARCH. Revista Contemporânea de Economia e Gestão, 5:7-16.
- Giacomel, F. S. (2016). Um método algorítmico para operações na bolsa de valores, baseado em ensembles de redes neurais para modelar e prever os movimentos dos mercados de ações. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal do Rio Grande do Sul, Porto Alegre.
- Hastie, T., Tibshirani, R. & Friedman, J. (2009). The elements of statistical learning. Berlim, Springer.
- Henning, E., Alves, C. C. & Konrath, A. C. (2010). Previsão de vendas de rodízios para móveis em uma empresa de médio porte. In: Proceedings of 5th Americas International Conference on Production Research, Bogotá.
- Hewitt, C. (1977). Viewing control structures as patterns of passing messages. Artificial Intelligence, 8(3):323-364.

- Hochreiter, S. & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735-1780.
- Huang, J., Chai, J. & Cho, S. (2020). Deep learning in finance and banking: a literature review and classification. *Frontiers of Business Research in China*, 14:1-24.
- Hyndman, R. J., Koehler, A. B., Ord, J. K. & Snyder, R. D. (2008). *Forecasting with exponential smoothing: the state space approach*. New York, Springer.
- IFC Market. (2023, 22 de setembro). Indicador CCI - Donald Lambert CCI. Disponível em: <https://www.ifcmarkets.com.br/ntx-indicators/cci>. Acessado em: 22 de setembro de 2023.
- Indicadores Fundamentalistas (2022, 17 de novembro). Entenda na prática!. Disponível em: <https://blog.genialinvestimentos.com.br/indicadores-fundamentalistas/>. Acessado em: 13 de dezembro de 2023.
- Jansen, J. (1997). Using intelligent agents to enhance search engine performance. Disponível em: <https://firstmonday.org/ojs/index.php/fm/article/view/517>. Acessado em: 06 de dezembro de 2023.
- Kaufman, D. (2016). Inteligência artificial: questões éticas a serem enfrentadas. In: IX Simpósio Nacional ABCiber, São Paulo. Disponível em: [https://abciber.org.br/anaiseletronicos/wp-content/uploads/2016/trabalhos/inteligencia\\_artificial\\_questoes\\_eticas\\_a\\_serem\\_enfrentadas\\_dora\\_kaufman.pdf](https://abciber.org.br/anaiseletronicos/wp-content/uploads/2016/trabalhos/inteligencia_artificial_questoes_eticas_a_serem_enfrentadas_dora_kaufman.pdf). Acessado em: 17 de janeiro de 2024.
- Lambert, D. R. (1983). Commodity channel index: tool for trading cyclic trends. *Technical Analysis of Stocks & Commodities*, 1:47.
- Lee, C.-C., Lee, J.-D. & Lee, C.-C. (2010). Stock prices and the efficient market hypothesis: evidence from a panel stationary test with structural breaks. *Japan and The World Economy*, 22(1):49-58.
- Leite, L. B. & Oliveira, A. S. (2014). Análise técnica de investimentos utilizando o software metastock. *UNOPAR Científica*, 13(1):53-60.
- Lemos, F. A. C. A. (2017). *Análise técnica dos mercados financeiros*. São Paulo, Saraiva Educação SA.
- Levine, D. M. *et al.* (2012). *Estatística: teoria e aplicações*. Rio de Janeiro, LTC.
- Li, Y. (2019, 29 de junho). 80% of the stock market is now on autopilot. Disponível em: <https://www.cnbc.com/2019/06/28/80percent-of-the-stock-market-is-now-on-autopilot.html>. Acessado em: 06 de dezembro de 2023.
- Lim, B. & Zohren, S. (2021). Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society*, 379(2194):202-209.
- Lo, A. W. & Mackinlay, A. C. (2011). *A non-random walk down Wall Street*. Princeton, Princeton University Press.
- Lucca, V. (2018). *Avaliando previsões de volatilidade realizada no Brasil usando um grande conjunto de preditores*. Rio de Janeiro, PUC.
- Makridakis, S., Wheelwright, S. & Hyndman, R. J. (1998). *Forecasting methods and applications*. New York, John Wiley & Sons.
- Malkiel, B. G. & Fama, E. F. (1970). Efficient capital markets: a review of theory and empirical work. *The Journal of Finance*, 25(2):383-417.

- McNelis, P. D. (2005). *Neural networks in finance gaining predictive edge in the market* Amsterdam, Elsevier Academic Press.
- Money Times. (2023, 12 de dezembro). Cotação BOVA11 - ETF ISHARES Ibovespa. Disponível em: <https://www.moneytimes.com.br/cotacao/bova11/>. Acessado em: 12 de dezembro de 2023.
- Nametala, C. A. L. *et al.* (2016). Uma estratégia automatizada de investimento por meio de redes neurais artificiais e preditores econométricos. In: XII Brazilian Symposium on Information Systems, p. 152-159.
- Negnevitsky, M. (2002). *Artificial intelligence: a guide to intelligent systems*. Londres, Pearson.
- Noreen, U., Shafique, A., Zaheer, A. & Ashfaq, M. (2023). Banking 4.0: artificial intelligence (AI) in banking industry & consumer's perspective. *Sustainability*, 15(4): 3682.
- Organisation for Economic Cooperation and Development (2021). *Artificial intelligence, machine learning and big data in finance: opportunities, challenges and implications for policy makers*. Disponível em: <https://www.oecd.org/finance/financial-markets/Artificial-intelligence-machine-learning-big-data-in-finance.pdf>. Acessado em: 17 de janeiro de 2024.
- OECD.AI Expert Group on AI Compute and Climate (2023). *A blueprint for building national compute capacity for artificial intelligence*. OECD Digital Economy Papers, n. 350, feb. Disponível em: <https://www.oecd-ilibrary.org/docserver/876367e3-en.pdf?expires=1705499209&id=id&accname=guest&checksum=9D1EDE02405603D6AB3B516D8D714A73>. Acessado em: 17 de janeiro de 2024.
- Passos, V. C. S. & Pinheiro, J. L. (2009). Estratégias de investimentos em bolsa de valores: uma pesquisa exploratória da visão fundamentalista de Benjamin Graham. *Revista Gestão & Tecnologia*, 9:1-16.
- Pellegrini, F. R. & Foliatto, F. S. (2001). Passos para implantação de sistemas de previsão de demanda -técnicas e estudo de caso. *Revista Produção*, 11(1):43-64.
- Petropoulos, F. *et al.* (2022). *Forecasting: theory and practice*. Arxiv, jan. Disponível em: <https://arxiv.org/abs/2012.03854>. Acessado em: 17 de janeiro de 2024.
- Pintelas, E. *et al.* (2020). Investigating the problem of cryptocurrency price prediction: a deep learning approach. In: IFIP International Conference on Artificial Intelligence Applications and Innovations, Springer, p. 99-110.
- Quong, G. S. & Soudack, A. (1989). Volume-weighted rsi: money flow. *Technical Analysis of Stocks & Commodities*, 7(3):76-77.
- Ragsdale, C. T. (2009). *Modelagem e análise de decisão*. São Paulo, Cengage Learning.
- Rasmussen, R. (2004). On time series data and optimal parameters. *Omega*, 32(2):111-120.
- Russel, S. & Norvig, P. (2009). *Artificial intelligence: a modern approach*. New York, Pearson.
- Thompson, J. R. & Wilson, J. R. (2016). Multifractal detrended fluctuation analysis: practical applications to financial time series. *Mathematics and Computers in Simulation*, 126:63-88.
- Trading View. (2021, 28 de novembro). BOVA11 - Panorama geral e expectativa futura. Disponível em: <https://br.tradingview.com/chart/BOVA11/d19gKxzh/>. Acessado em: 12 de dezembro de 2023.
- Wilder, J. W. (1978). *New concepts in technical trading systems*. Bloomington, Trend Research.

Williams, B. M. (1998). *New trading dimensions: how to profit from chaos in stocks, bonds, and commodities*. New Jersey, Wiley.

Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3):324-342.

Wolff, L. *et al.* (2011). Análise do índice Bovespa sob o enfoque de séries temporais. *Global Manager*, 11.

Wuermeling, J. (2018). Artificial intelligence (AI) in finance: six warnings from a central banker. In: 2nd Annual FinTech Conference, Brussels. Disponível em: <https://www.bis.org/review/r180307d.pdf>. Acessado em: 10 de dezembro de 2023.

Yang, Q. & Wu, X. (2006). 10 challenging problems in data mining research. *International Journal of Information Technology Decision Making*, 5(4):597-604.

---

# Sobre o Autor

## Emerson Antonio Freire Pavão

Formado em licenciatura em matemática pela universidade de Sorocaba, possui MBA em Mercado de Capitais pela Universidade Nove de Julho e Mestre em Administração pela Must University – Florida USA no Curso de Master of Science in Business Administration.

# Índice Remissivo

## A

abordagem 8, 9, 10, 11, 14, 18, 21, 22, 24, 25, 27, 33, 34, 42, 43, 46, 50, 54, 56, 61, 63, 65  
ambiente econômico 21  
análise financeira 21  
análise fundamentalista 21, 22  
análise quantitativa 14  
análise temporal 9, 61  
aprendizagem 10, 16  
ativos financeiros 9, 11, 12, 13, 14  
autoconsciência 16  
avanço tecnológico 8, 10

## B

balanços contábeis 21

## C

conhecimento emocional 16  
criatividade 16

## D

dados financeiros 14, 22  
desenvolvimento 9, 13, 19, 33, 49, 50

## E

estratégia 9, 10, 21, 25, 27, 33, 68  
estratégias 11, 13, 15, 24, 27, 51, 52, 60, 61, 63  
evolução 9, 16, 17, 18, 24

## F

ferramenta 8, 9, 10, 14, 22, 28, 31, 32, 39, 40, 43, 61, 63, 64  
ferramentas 11, 12, 13, 18, 20, 22, 24

## G

gasto 37  
gestão de riscos 11, 19, 20

## I

inclusão financeira 19, 20  
índices financeiros 8  
inflação 21  
informações financeiras 21

inovador 16  
inovadoras 11  
inteligência artificial 10, 11, 12, 13, 14, 16, 17, 18, 19,  
54, 64, 65  
inteligência humana 16, 17  
investidores ferramentas 11  
investidores financeiros 8  
investimento 8, 11, 22, 24, 27, 49, 61, 63, 64, 68

## **J**

jurídicas 18

## **M**

mercado de capitais 15, 26  
mercado financeiro 8, 9, 10, 11, 12, 14, 22, 25, 26, 27,  
49, 51, 54, 60, 61, 62, 63, 64, 65  
mercados financeiros 10, 34, 67  
método 10, 22, 27, 34, 35, 36, 38, 39, 40, 42, 44, 46,  
66  
modalidade analítica 24  
modelagem 9, 39, 42

## **P**

período de tempo 32, 36, 39  
previsão 8, 9, 10, 11, 12, 13, 14, 26, 27, 33, 35, 36, 39,  
40, 42, 43, 45, 51, 52, 54, 56, 57, 60, 61, 64, 68  
procedimentos tecnológicos 26  
processo de estimação 38  
processos estacionários 33

## **R**

raciocínio 16  
redes neurais 10, 16, 27, 66, 68  
renda 21, 36, 37

## **S**

segurança 19, 20  
segurança antifraude 19  
séries temporais 9, 10, 25, 27, 33, 34, 35, 36, 42, 45,  
46, 57, 66, 69  
série temporal 27, 33, 34, 39  
serviços 19  
sistema financeiro 19  
sistemas econômicos 34  
sistemas operacionais 8, 12, 64  
socioeconômicas 18



---

## **T**

taxa de variação 37  
tecnologia 9, 20  
tecnologias 12, 16  
temporais financeiras 27, 34

## **V**

valores das ações 33  
variável 32, 37, 44, 45  
viabilidade de investimentos 21





# DATA



**AYA EDITORA**  
**2024**