

**UNIVERSIDADE FEDERAL DO MARANHÃO  
DEPARTAMENTO DE INFORMÁTICA /CCET**

**ICARO LUIS MENDES RIBEIRO MOURA**

**Predição de Preços do Mercado Financeiro utilizando Redes Neurais LSTM**

**SÃO LUÍS  
2023**

**ICARO LUIS MENDES RIBEIRO MOURA**

**Predição de Preços do Mercado Financeiro utilizando Redes Neurais LSTM**

Trabalho de conclusão de curso apresentado ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação

Orientador: Prof. Dr. Geraldo Braz Junior

**SÃO LUÍS  
2023**

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).  
Diretoria Integrada de Bibliotecas/UFMA

Mendes Ribeiro Moura, Icaro Luis.

Predição de Preços do Mercado Financeiro utilizando  
Redes Neurais LSTM / Icaro Luis Mendes Ribeiro Moura. -  
2023.

35 f.

Orientador(a): Geraldo Braz Junior.

Monografia (Graduação) - Curso de Ciência da  
Computação, Universidade Federal do Maranhão, São Luís,  
2023.

1. Bolsa de Valores. 2. Day Trading. 3. LSTM. 4.  
Previsão. 5. RNN. I. Braz Junior, Geraldo. II. Título.

**ICARO LUIS MENDES RIBEIRO MOURA**

**Predição de Preços do Mercado Financeiro utilizando Redes Neurais LSTM**

Trabalho de conclusão de curso apresentado ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação

Trabalho aprovado em São Luís, 13 de janeiro de 2023:

Prof. Dr. Geraldo Braz Júnior  
Orientador

Prof. Dra. Simara Vieira da Rocha  
Examinadora

Profa. Dra. Vandecia Rejane Monteiro Fernandes  
Examinadora

**SÃO LUÍS**  
**2023**

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus que permitiu a mim toda esta trajetória incrível de conhecimento e permitiu conhecer pessoas incríveis ao longo do percurso. Agradeço a minha mãe Griziele por ter me dado a luz e ter lutado por meu futuro independente das circunstâncias. Agradeço ao meu pai Luis Claudio que certamente foi meu maior herói e minha maior inspiração de crescimento, nos veremos em breve meu pai. Agradeço a minha irmã Claudia que apesar das nossas birras de irmãos sempre pensou no nosso conforto e harmonia. Agradeço aos meus dois irmãos Micaias e Miqueas por sempre serem leais e firmes, por sempre apoiarem minhas ideias mirabolantes. Agradeço por todos os meus amigos que me apoiaram e agregaram direta ou indiretamente na conclusão deste trabalho, entre eles: Stheffhane, Claudio, Eli e Paulina o eterno grupo dos “Apaixonados”, Luis Carlos, Ivo, Filipe Costa, Jorge, Cassio pelas melhores histórias e aventuras, Leandro Rabelo, Felipe Catarino, João Ferdinand por criarem os fundamentos da minha lealdade. Agradeço a Mayara Lina que sempre teve otimismo nas minhas capacidades e sempre me incentivou na trajetória deste trabalho com muita “qualidade”. Agradeço ao meu orientador professor Geraldo Braz que não desanimou em incentivar a conclusão deste trabalho. Agradeço a professora Vandecia Rejane por criar em mim a vontade de programar. Agradeço a professora Simara Viera por ter sido a melhor coordenadora do curso de Ciência da Computação. Agradeço ao professor Anselmo Paiva pelas lições de humildade e perseverança.

*“Todo aquele que o Pai me der virá a mim,  
e aquele que vem até mim de modo algum o lançarei fora”*

*(João 6:37)*

## RESUMO

O mercado financeiro compões a essência da alocação de bens e recursos escassos no mundo todo. É o termômetro que mede a oferta e a demanda em tempo real dos mais diversos tipos de ativos. Nos últimos anos, uma crescente onda de novos investidores e pesquisadores se dedicaram em desvendar os mistérios do mercado financeiro e seus movimentos, em grande parte motivados por histórias de investidores e grandes corporações que obtiveram sucesso em se posicionar frente as oscilações do mercado. Porém a esmagadora maioria destes novos investidores se deparam com um cenário caótico e nada previsível. Muitos investidores *day-traders* que visam obter lucros com a compra e venda de ativos em um curto período se utilizam de técnicas de análise técnica, tais como médias móveis e osciladores, para tentar prever os movimentos do mercado, no entanto, essas técnicas podem ser limitadas e não são sempre precisas, uma abordagem alternativa é o uso de modelos de aprendizado de máquina para prever os movimentos do mercado financeiro. Neste trabalho, utilizamos o modelo de redes neurais recorrentes Long Short Term Memory (LSTM) para prever o preço de fechamento de algumas ações listadas na Bolsa de Valores de São Paulo. Os resultados demonstram que o modelo LSTM é capaz de prever com precisão os movimentos do mercado financeiro, superando as estratégias de negociação convencionais como o *Buy and Hold*. Além disso, o modelo LSTM é capaz de capturar dependências e padrões em longo prazo, o que é uma vantagem importante na previsão de séries temporais.

**Palavras-chave:** Previsão, LSTM, RNN, Bolsa de Valores , Day Trading , Buy and Hold

## **ABSTRACT**

The financial market makes up the essence of the allocation of goods and scarce resources around the world. It is the thermometer that measures supply and demand in real time for the most diverse types of assets. In recent years, a growing wave of new investors and researchers have dedicated themselves to unraveling the mysteries of the financial market and its movements, largely motivated by stories of investors and large companies that were successful in positioning themselves in the face of market fluctuations. However, the overwhelming majority of these new investors are faced with a chaotic and far from predictable scenario. Many day-trader investors who aim to make profits from buying and selling assets in a short period of time use technical analysis techniques, such as moving averages and oscillators, to try to predict market movements, however, these techniques can be limited and not always accurate, an alternative approach is to use machine learning models to predict financial market movements. In this work, we use the Long Short Term Memory (LSTM) recurrent neural network model to predict the closing price of some stocks listed on the São Paulo Stock Exchange. The results demonstrate that the LSTM model is capable of accurately predicting financial market movements, outperforming conventional trading strategies such as Buy and Hold. Furthermore, the LSTM model can capture long-term dependencies and patterns, which is an important advantage in time series forecasting.

**Keywords:** Forecast, LSTM, RNN, Stock Exchange, Day Trading, Buy and Hold



## SUMÁRIO

1	INTRODUÇÃO .....	9
1.1	Objetivos .....	10
1.1.1	Objetivos Específicos.....	10
2	FUNDAMENTAÇÃO TEÓRICA.....	11
2.1	Mercado de Capitais .....	11
2.1.1	Valores Mobiliários.....	11
2.1.2	Ações.....	12
2.1.3	Book de Ofertas.....	13
2.1.4	Trading.....	15
2.1.5	Buy and Hold.....	16
2.2	Formas de Análises de Investimentos .....	16
2.3	Gerenciamento de Risco .....	17
2.4	Redes Neurais .....	18
2.5	LSTM-RNN .....	19
2.6	Métricas de Avaliação .....	21
3	METODOLOGIA .....	22
3.1	Obtenção e Pré-processamento dos Dados .....	22
3.2	Arquitetura e Hiper-parâmetros .....	24
3.3	Compilação e Treinamento .....	25
3.4	Predição e Avaliações .....	25
3.5	Estratégias de trade e simulação .....	26
4	RESULTADOS e DISCUSSÃO.....	27
4.1	Resultados Pré-pandemia .....	28
4.2	Resultados Durante a Pandemia .....	29
4.3	Resultados Pós-pandemia.....	30
4.4	Resultados Gerais .....	31
5	Conclusão .....	33

## 1 INTRODUÇÃO

Em maio de 2022, o número de investidores pessoas físicas na bolsa de valores brasileira atingiu a marca de 5.129.344 (B3, 2022) um número considerável dado que haviam somente 583.202 investidores cadastrados no final de 2011, revelando um crescente interesse da população brasileira nos mercados de capitais que foi acentuado ainda mais durante o isolamento da pandemia de Covid-19 em 2020. Grande parte deste interesse vem da possibilidade de mudança da qualidade vida e de ganhar dinheiro a partir do conforto de casa num computador. Em contraste com esta informação segundo [Chague e Giovannetti \(2020\)](#) pelo menos 90% dos investidores que operam na modalidade *day-trading* são abatidos com prejuízos financeiros, mostrando a imperícia e inexperiência frente as oscilações do mercado dos novos investidores.

O *day-trading* é a atividade de compra e venda de um mesmo ativo financeiro, no mesmo dia e na mesma quantidade. O *day-trader* lucra quando seu preço médio oscila tornado o preço de médio de venda maior do que seu preço médio de compra, descontando-se os custos de operação.

Os mercados financeiros são movidos por diversas variáveis macroeconômicas e microeconômicas, suas oscilações provem desde pronunciamentos políticos até catástrofes naturais e inclusive por expectativas irracionais dos investidores ([SHILLER, 2005](#)). Nos últimos 3 anos a economia brasileira presenciou um ciclo completo financeiro de ascensão, queda e gradual recuperação ([BRASIL. Banco Central, 2022](#)).

Em 2019 as economias do mundo enfrentavam uma estagnação frente a uma desaceleração global dos mercados ([WORLD BANK, 2022](#)), apesar das projeções otimistas para o fim do ano, o surgimento do novo Coronavírus, Covid-19, derrubou os mercados e iniciou uma nova crise comparável a grande crise da bolsa americana de 1929. A forte expectativa negativa e o pânico generalizado geraram uma oscilação tremenda levando milhares de investidores ao prejuízo, boa parte destes investidores levaram seu capital para os títulos públicos americanos levando a um grande fortalecimento do dólar frente as moedas do mundo ([FED, 2020](#)).

Em 2021 o Brasil foi acometido por uma nova onda da Covid-19 fruto das mutações do Coronavírus ([BRASIL. Ministério da Saúde, 2021](#)), fazendo permanecer as incertezas do mercado. Por fim as expectativas de recuperação da economia voltaram-se para o ano de 2022 que por sua vez presenciou uma guerra inédita entre Rússia e Ucrânia, grandes players respectivamente do mercado de *commodities* petrolífero e de trigo, mais

uma vez as expectativas dos investidores minguaram, apesar do cenário de recuperação na economia brasileira ser real.

Ao longo deste ciclo milhares de investidores tomaram decisões frente aos mais diversos cenários, sendo a análise de *series temporais financeiras* uma das partes mais importantes na tomada de decisões do investidor, dado que o sucesso no mercado de ações está diretamente ligado a acurácia das previsões feitas por esta análise (NOGUEIRA e LIMA, 2021).

Os avanços no campo da inteligência artificial em específico das Redes Neurais têm sido promissores em sua capacidade preditiva numa série de problemas incluindo as *series temporais* (DING e QIN, 2020). Cada vez mais pesquisadores e investidores tem voltado sua atenção para soluções de *machine learning* devido a assertividade de suas previsões, segundo Cavalcante (2016), estudos na literatura para resolver problemas inerentes ao mercado financeiro baseados em metodologias de previsão já têm sido largamente propostos ao longo dos anos por acadêmicos. O grande desafio está em fazer modelos inteligentes que integrem componentes adicionais, tais como estratégias de negociação (*trading strategies*) ao mesmo tempo que realizem alguma avaliação financeira do cenário, para que possa ser possível a validação do método tanto em ambiente simulado quanto real na realização das negociações.

## 1.1 Objetivos

O presente trabalho tem por objetivo desenvolver um modelo de rede neural profunda capaz de prever o preço de fechamento do dia seguinte, de algumas ações da bolsa de valores brasileira (IBOVESPA). Para realizar as previsões, o modelo recebe como entrada séries temporais contendo os preços de fechamento no intervalo dos últimos 3 dias. É proposto uma RNN do tipo Long Short-Term Memory (LSTM), uma arquitetura largamente utilizada para regressões logísticas de séries temporais, para fazer proveito das oscilações das previsões serão testadas duas estratégias de negociação.

### 1.1.1 Objetivos Específicos

- Desenvolver um modelo LSTM para previsão de séries temporais da bolsa
- Avaliar comparativamente o método desenvolvido seguindo as estratégias propostas.

## 2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão apresentados os conceitos que compreendem ser essenciais para o entendimento deste trabalho desde o funcionamento do mercado de ações, bem como o modelo LSTM e algumas métricas de avaliação.

### 2.1 Mercado de Capitais

Na economia, o mercado de capitais ou mercado financeiro é o “ambiente” no qual se é permitido a compra e a venda de bens de valores mobiliários tais como ações, títulos públicos, títulos de dívidas de empresas como debêntures ou mesmo mercadorias agrícolas e câmbio (FRANCO, 2017). Os mercados de capitais em sua maioria são regulamentados por organismos governamentais, no Brasil, pela Comissão de Valores Mobiliários (CVM).

#### 2.1.1 Valores Mobiliários

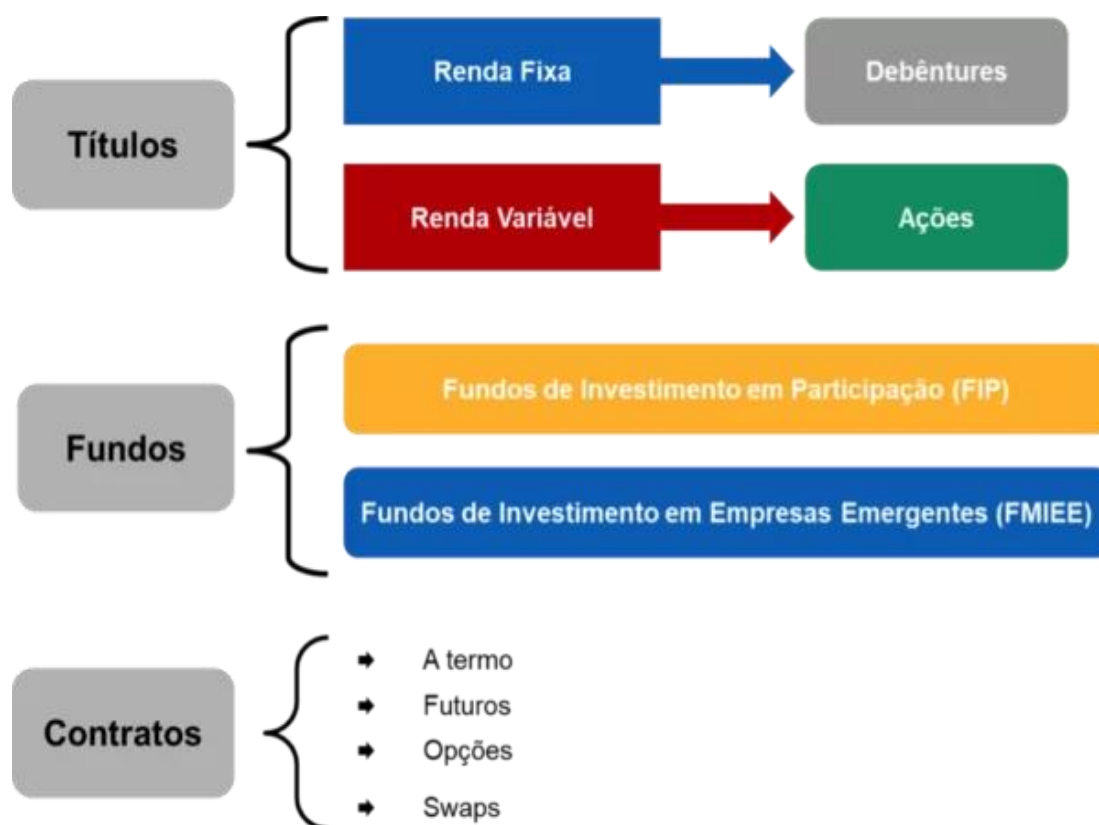
São relacionados como valores mobiliários segundo as Leis 6.385 e 10.303: “Todo investimento em dinheiro ou em bens suscetíveis de avaliação monetária, realizado pelo investidor em razão de uma captação pública de recursos, de modo a fornecer capital de risco a um empreendimento, em que ele, o investidor, não tem ingerência direta, mas do qual espera obter ganho ou benefício futuro” (Constituição Federal, 1988), são objetos da lei:

1. Ações, debêntures e bônus de subscrição;
2. Cupons, direitos, recibos de subscrição e certificados de desdobramento relativos aos valores mobiliários;
3. Certificados de depósito de valores mobiliários;
4. Cédulas de debêntures;
5. Cotas de fundos de investimento em valores mobiliários ou de clubes de investimento em quaisquer ativos;
6. Notas comerciais;
7. Contratos futuros, de opções e outros derivativos, cujos ativos subjacentes sejam valores mobiliários;
8. Outros contratos derivativos, independentemente dos ativos subjacentes;

9. Quando ofertados publicamente, quaisquer outros títulos ou contratos de investimento coletivo, que gerem direito de participação, de parceria ou de remuneração, inclusive resultante de prestação de serviços, cujos rendimentos advêm do esforço do empreendedor ou de terceiros.

A Figura 1 ilustra alguns dos ativos mais comuns do mercado de capitais brasileiro:

Figura 1 – Valores Mobiliários mais comuns



Fonte: PINHEIRO (2019)

O escopo deste trabalho é totalmente dedicado aos valores mobiliários de ações.

### 2.1.2 Ações

Ações são valores mobiliários emitidos por uma empresa (sociedade anônima), elas representam a fração mínima do capital participativo. Ao comprar uma ação, os investidores se tornam sócios e coproprietários do empreendimento, tendo assim direito à participação nos resultados da empresa (B3, 2012). As empresas emitem títulos de ações e as ofertam no mercado aos investidores (pessoas físicas ou instituições financeiras) por meio de ofertas públicas ou privadas. Na oferta pública, a venda dos títulos deve ser antecipada por um registro do processo junto à CVM, garantindo aos investidores de que os requisitos de abertura de informações foram atendidos (folhetos,

publicações, prospectos etc.). Quando esse registro for restritivo a um pequeno grupo de pessoas ou instituições financeiras e suas informações de abertura não forem divulgadas é considerado como oferta privada.

Quando as ações de uma companhia são negociadas na bolsa de valores ela é chamada de empresa de capital aberto. Nos outros casos, diz-se que a empresa é uma sociedade anônima de capital fechado. Os preços das ações são determinados pelas forças de oferta e demanda no mercado. Quando há muitos compradores interessados em comprar ações de uma determinada empresa, o preço dessas ações tende a subir. Por outro lado, quando há muitos vendedores e poucos compradores, o preço tende a cair.

Além das forças de oferta e demanda, os preços das ações também são influenciados por fatores externos, como as condições econômicas gerais, as perspectivas de crescimento de uma empresa e os eventos políticos ou outros acontecimentos que podem afetar o mercado de ações.

Na bolsa de valores, os preços das ações são determinados através de leilões, onde compradores e vendedores oferecem e aceitam preços para comprar e vender ações. Quando um comprador e um vendedor concordam em um preço, a transação é fechada e o preço é considerado o preço de mercado para aquele momento. O preço de mercado é atualizado continuamente à medida que novas transações ocorrem.

### **2.1.3 Book de Ofertas**

O book de ofertas é um registro de todas as ofertas de compra e venda de ações de uma determinada empresa. Ele é mantido pelas bolsas de valores e é um importante mecanismo de transparência que mostra aos investidores as ofertas atuais de compra e venda de ações da empresa. O book de ofertas (Figura 2) é dividido em duas partes: o lado da compra também conhecido como lado de *bid* e o lado da venda também conhecido como lado de *ask*. O lado de compra mostra as ofertas de compra de ações, incluindo o preço que os investidores estão dispostos a pagar e a quantidade de ações que estão dispostos a comprar. O lado de venda mostra as ofertas de venda de ações, incluindo o preço que os investidores estão dispostos a receber e a quantidade de ações que estão dispostos a vender.

Figura 2 – Book de Ofertas

'Book' de Ofertas PETR4

PETR4

Abertura: 23.22 Máximo: 2  
 Último: 22.87 Mínimo: 2  
 Última vez: 6:13:00 PM Spread: 1

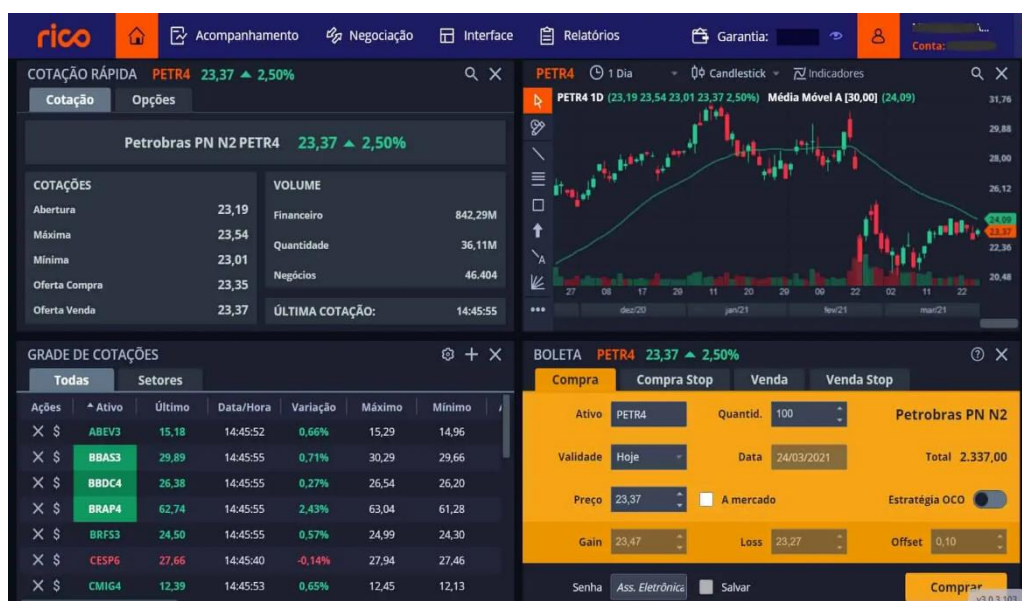
Quantidade: --- Preço médio: --- L/P: ---

Quantidade	Preço	Preço	Quantidade
83,800	22.87	22.88	3,800
7,200	22.86	22.89	5,400
248,900	22.85	22.90	11,800
71,700	22.84	22.91	8,600
1,400	22.83	22.92	4,800
62,500	22.82	22.93	260,900
5,200	22.81	22.94	26,800
26,500	22.80	22.95	258,800
7,000	22.79	22.96	12,400
6,600	22.78	22.97	339,200
28,800	22.77	22.98	76,100
30,200	22.76	22.99	293,700
48,600	22.75	23.00	39,300
16,900	22.74	23.01	272,900

Fonte: REIS (2018)

As ordens de compra e venda no mercado de ações são usadas pelos investidores para especificar como desejam comprar ou vender ações de uma determinada empresa. As ordens podem ser enviadas através de uma plataforma de negociação eletrônica, como um *homebroker* (FIGURA 3). Um *homebroker* é uma plataforma de negociação eletrônica que permite aos investidores comprar e vender ações de forma rápida e eficiente a partir de suas próprias casas, sem a necessidade de se deslocar até uma corretora (HUANG, 2014). Muitas corretoras oferecem *homebrokers* próprios que os seus clientes podem usar para enviar ordens de compra e venda de ações de maneira fácil e conveniente. As ordens podem ser enviadas também diretamente para um corretor, que é uma pessoa ou empresa que atua como intermediário entre os compradores e vendedores de ações. Essas ordens são importantes porque permitem que os investidores comprem e vendam ações de maneira rápida e eficiente, ajudando a garantir que as transações sejam realizadas de maneira justa e eficiente.

Figura 3 – Homebroker



Fonte: NUNES (2022)

### 2.1.4 Trading

Segundo Huang (2014) *trading* é um termo que se refere ao ato de comprar e vender ativos financeiros com o objetivo de obter lucro, isso pode incluir ações, moedas, *commodities* e outros instrumentos financeiros, é um dos principais mecanismos pelos quais os investidores podem ganhar exposição a diferentes ativos financeiros e tentar obter lucro com as flutuações de preços, no entanto, o *trading* envolve riscos, os preços dos ativos podem flutuar rapidamente e de maneira imprevisível, o que pode resultar em perdas significativas para os *traders* que não gerenciam seus riscos de maneira adequada, por isso, é crucial que os *traders* estejam cientes dos riscos envolvidos e adotem medidas para gerenciá-los de maneira eficaz.

O *trading* pode ser realizado por indivíduos ou por instituições financeiras, como bancos e fundos de investimento. Os *traders* geralmente utilizam métodos de análise técnica e análise fundamentalista para tentar prever as flutuações de preço dos ativos e tomar decisões de compra e venda.

O *day trading* é a prática de comprar e vender ativos financeiros no mesmo dia, com o objetivo de obter lucro com as oscilações de preço ao longo do dia. Os *day traders* geralmente mantêm suas posições por um período muito curto, geralmente menos de um dia, e fecham suas posições antes do fim do horário das negociações (CHAGUE e GIOVANNETTI, 2020).



O *day trading* é diferente do *trading* a longo prazo também chamado de *swing trade*, onde os *traders* mantêm suas posições por períodos mais longos, geralmente semanas ou meses, e tentam obter lucro com as tendências de preço ao longo do tempo.

### 2.1.5 Buy and Hold

O *Buy and Hold* (B&H) é uma estratégia de negociação que se popularizou principalmente na década de 1990, durante a qual os mercados de ações experimentaram um crescimento notável, é uma abordagem que se originou como uma reação à técnica de negociação *day trading*, no B&H o investidor compra seus ativos com o objetivo de mantê-los por um longo período de tempo, geralmente por vários anos, isto se baseia na ideia de que ao longo do tempo os mercados tendem a se recuperar de quedas temporárias e a continuar crescendo, logo, se o investidor mantiver seus investimentos por um período suficientemente longo, é provável que veja um retorno positivo. Os defensores da estratégia B&H acreditam que tentar acertar o "timing" do mercado, ou seja, tentar adivinhar quando comprar e vender para obter lucro, é muito arriscado e em contrapartida, é aconselhado aos investidores a se concentrarem em encontrar boas empresas com perspectivas sólidas e mantê-las por um longo período de tempo, isso permitiria que os investidores se beneficiassem do crescimento a longo prazo das empresas e reduzissem o risco de perdas por meio da diversificação (BUFFET e CUNNINGHAM, 1999).

## 2.2 Formas de Análises de Investimentos

Análise fundamentalista é uma abordagem utilizada para avaliar o valor de um ativo financeiro com base em seus fundamentos econômicos e financeiros, isso inclui fatores como: lucro, receita, dívida, crescimento do mercado e perspectivas de crescimento futuro.

A análise fundamentalista se baseia na premissa de que os preços dos ativos tendem a se mover em direção a seu valor intrínseco ao longo do tempo (GRAHAM, 1949), portanto, um ativo que é subavaliado pelo mercado pode ser considerado uma boa oportunidade de compra, enquanto um ativo que é sobreavaliado pode ser visto como uma oportunidade de venda.


Os analistas fundamentalistas tentam avaliar o valor intrínseco de um ativo por meio da análise de seus fundamentos econômicos e financeiros, isso pode incluir a análise

de relatórios financeiros, como balanços e demonstrações de resultados, bem como a análise do mercado e do setor em que o ativo está inserido.

A análise técnica se baseia na premissa de que os padrões observados nos dados de preços e volume podem fornecer informações importantes sobre a força do mercado e a direção futura dos preços.

Os analistas técnicos utilizam gráficos e indicadores (Figura 4) para identificar padrões nos dados de preços e volume. Esses padrões podem incluir tendências de alta ou baixa, suportes e resistências, e divergências entre os preços e os indicadores (MURPHY, 1999). A partir desses padrões, os analistas técnicos podem tentar prever a direção futura dos preços e tomar decisões de compra e venda.

Figura 4 - Gráfico PETR3 com indicadores



Fonte: [Trader View \(2022\)](#)

### 2.3 Gerenciamento de Risco

No contexto do *day trade*, o gerenciamento de risco refere-se às medidas que um *trader* pode tomar para minimizar o risco de perdas em suas negociações, tais como estabelecer limites de perda para cada negociação, diversificar sua carteira de negociação e utilizar técnicas de gerenciamento financeiro para garantir que as perdas não ultrapassem um determinado limite.

O gerenciamento de risco é importante em qualquer tipo de negociação, mas é particularmente crítico no *day trade* devido à sua natureza de curto prazo e à volatilidade do mercado (LOGUE, 2007).

O *stop loss* é uma ordem que um *trader* pode colocar em sua posição para fechá-la automaticamente quando atinge um preço específico, ajudando a garantir que as perdas não ultrapassem um limite predeterminado, por consequência sendo uma importante ferramenta no gerenciamento de risco. Por exemplo, um *trader* pode colocar uma ordem de *stop loss* em uma posição caso o direcionamento do gráfico contrarie sua previsão, para fechá-la automaticamente se o preço continuar o movimento e atingir um determinado nível. Isso pode ajudar a minimizar as perdas e evitar que o *trader* perca mais dinheiro do que o planejado.


O *take profit* é uma ordem usada para aproveitar um movimento de preço favorável e fechar a posição automaticamente quando o preço atinge o nível desejado, sendo útil uma vez que ajuda o *trader* a fixar lucros em uma posição que está tendo sucesso, sem precisar ficar monitorando o mercado a todo tempo. Por exemplo, um *trader* pode colocar uma ordem de *take profit* em uma posição que está lucrando, para fechá-la automaticamente se o preço continuar a subir e atingir um determinado nível. Isso pode ajudar a maximizar os lucros e evitar que o *trader* perca os ganhos se o preço começar a cair.

## 2.4 Redes Neurais

Uma rede neural artificial é um modelo de computação inspirado na forma como o cérebro humano processa informações, ela é composta por várias unidades de processamento interconectadas, chamadas de neurônios (MCCULLOCH e PITTS, 1943) que trabalham em conjunto para realizar tarefas complexas, como reconhecimento de padrões e tomada de decisão.

As redes neurais artificiais são capazes de “aprender” com dados e melhorar sua precisão ao longo do tempo, isso é feito por meio de treinamento, onde a rede é exposta a grandes quantidades de dados e ajusta suas conexões de acordo com o desempenho. A Figura 5 demonstra a representação do modelo de um neurônio proposto por MCCULLOCH & PITTS:

Figura 5 - Rede Neural de MCCULLOCH &amp; PITTS



Fonte: Adaptada de (JAIN; MAO; MOHIUDDIN, 1996)

Cada neurônio possui uma função de ativação ( $u$ ), que determina como os sinais de entrada são processados e como um sinal de saída é produzido, em geral, a função de ativação é uma função matemática que leva em conta os sinais de entrada ( $x$ ), os pesos ( $w$ ) associados a cada sinapse e um limiar de ativação, se o resultado da função de ativação for maior que o limiar, o neurônio é ativado e produz um sinal ( $y$ ) de saída, caso contrário, o neurônio não é ativado e não produz um sinal de saída.

Embora o modelo de McCulloch-Pitts seja considerado bastante simplista em comparação com os modelos de redes neurais atuais, ele ainda é amplamente estudado e é importante como uma base para o entendimento das redes neurais modernas.


As redes neurais artificiais são amplamente utilizadas em várias áreas, como reconhecimento de imagens, processamento de linguagem natural e detecção de fraudes, são consideradas uma das principais tecnologias de inteligência artificial e têm sido utilizadas com sucesso em muitas aplicações práticas. Uma rede neural artificial é caracterizada por sua topologia, ou seja, a forma como os neurônios são conectados entre si, ela também pode ser definida pelas características dos nós, a quantidade de camadas e as regras de treinamento e aprendizado. Existem dois tipos principais de redes neurais: *feedforward networks*, nas quais os grafos não possuem *loops*, e *recurrent networks*, que possuem *loops* (MANDIC e CHAMBERS, 2001).

## 2.5 LSTM-RNN

Uma rede neural recorrente (RNN) é composta por várias camadas recorrentes bidirecionais, seguidas por uma ou mais camadas totalmente conectadas. Esta estrutura permite que a rede acesse estados ocultos de etapas anteriores e posteriores, o que aumenta sua capacidade de entender cada característica dentro de um contexto, isso

significa que a rede é capaz de temporariamente armazenar informações sobre estados anteriores, o que é útil no estudo de séries temporais (CHOW, 2017).

Figura 6 – Uma Rede Neural Recorrente




Fonte: OLAH (2015)

Redes neurais recorrentes tradicionais têm memória curta e podem sofrer com os problemas de *vanish gradient* e *exploding gradient* em casos em que é necessária uma memorização a longo prazo, para resolver essa questão, foi criado o conceito de *long short term memory* (LSTM). Nesse modelo, são inseridas na rede células de memória capazes de aprender dependências a longo prazo (Figura 7), essas células têm a capacidade de adicionar ou remover informações de seus estados através de portas (*gates*), que são entradas opcionais de dados.

Uma diferença estrutural importante entre uma RNN tradicional e o modelo LSTM, é a presença de quatro camadas no módulo de repetição, enquanto uma RNN tradicional tem apenas uma camada, além disso, as camadas de um modelo LSTM interagem de forma específica em cada iteração, enquanto as camadas de uma RNN tradicional apenas passam os sinais de uma para a outra sem qualquer interação adicional.

Figura 7 - Módulo de repetição em uma rede LSTM



Fonte: OLAH (2015)

## 2.6 Métricas de Avaliação

As métricas de avaliação são fundamentais na avaliação do desempenho de modelos RNN, elas permitem comparar o desempenho entre modelos diferentes e verificar se são capazes de generalizar bem para novos conjuntos de dados, além disso, as métricas de avaliação podem ser utilizadas para comparar modelos treinados com diferentes parâmetros e selecionar o modelo que apresenta o melhor desempenho.

O erro quadrático médio (MSE) é uma métrica comumente utilizada para avaliar o desempenho de modelos de predição. Ele é calculado como a média dos erros elevado ao quadrado entre os valores previstos (1) pelo modelo e os valores reais(y). No entanto, o MSE pode ser sensível a *outliers*, ou seja, valores muito distantes da média, o que pode afetar sua precisão.

A Equação 1 descreve o cálculo do Erro quadrático médio.

$$\sum_{i=1}^D (x_i - y_i)^2 \quad (1)$$

Para mitigar esse problema, é comum utilizar a raiz do erro quadrático médio (RMSE) x.2 como uma métrica de avaliação o RMSE fornece uma medida do erro do modelo em unidades do próprio sistema, o que pode ser útil para interpretar os resultados do modelo, quanto mais próximo de zero o valor melhor (GOODFELLOW, BENGIO e COURVILLE, 2016).

$$\sqrt{\sum_{i=1}^D (x_i - y_i)^2} \quad (1.1)$$

O erro absoluto médio (MAE) é uma métrica amplamente utilizada na avaliação do desempenho de modelos de predição, incluindo modelos de redes neurais, ele mede a precisão de um modelo de previsão em unidades absolutas. É calculado como o módulo das médias dos erros absolutos entre os valores previstos pelo modelo e os valores reais

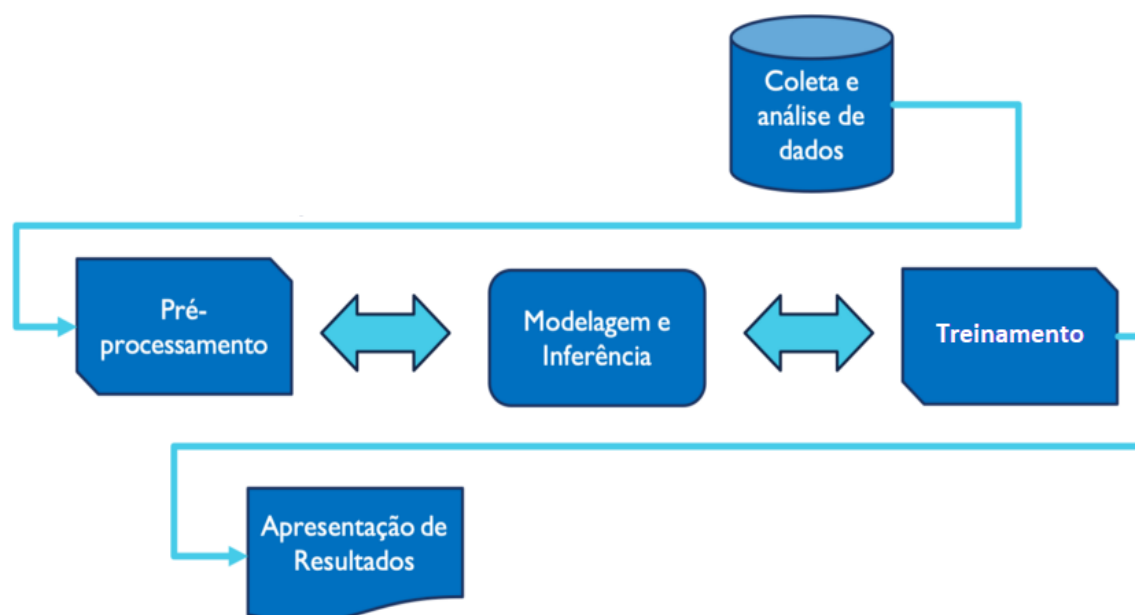
1.2.

$$\sum_{i=1}^D |x_i - y_i| \quad (1.2)$$

### 3 METODOLOGIA

Nesta seção, é descrito o processo utilizado para treinar e avaliar uma RNN do tipo LSTM para prever os preços da bolsa brasileira (Figura 8). Inicialmente, é apresentado o conjunto de dados utilizado, incluindo a origem dos dados e o processo de pré-processamento aplicado, em seguida, a arquitetura da LSTM e os hiper parâmetros escolhidos é detalhada, por fim, o desempenho da LSTM será avaliado com métricas adequadas.

Figura 8 – Fases gerais até o modelo entrar em produção



Fonte: Adaptada de (ESCOVEDO & KOSHIYAMA, 2020)

#### 3.1 Obtenção e Pré-processamento dos Dados

Para treinar e avaliar a LSTM, utilizou-se séries temporais de preços de ações negociadas na B3, os dados foram obtidos a partir do portal Yahoo Finanças e cobrem o período de janeiro de 2010 a setembro de 2022. As séries temporais incluem os preços de fechamento diários de até 11 ações, bem como outras informações financeiras, como volume de negociação e rendimento das ações, no entanto somente o preço de fechamento das ações será utilizado para treinamento. Na Tabela 1 apresenta-se as ações selecionadas

para o treinamento e teste da RNN, o critério utilizado para seleção é que todas tenham mais de 10 anos ou mais na bolsa.

Tabela 1 - Ações selecionadas

<b>Ação</b>	<b>Setor</b>
ITUB4	Financeiro
BBAS3	Financeiro
CYRE3	Construção
TEND3	Construção
DIRR3	Construção
ELET3	Energia
EQTL3	Energia
CMIG4	Energia
PETR3	Petróleo
VALE3	Mineração
BRAP3	Participações

Fonte: B3 (2022)

Antes de utilizar os dados para treinar a LSTM, algumas etapas de pré-processamento foram aplicadas. Primeiramente, verificou-se a existência de valores ausentes nas séries temporais, em casos positivos os valores foram preenchidos utilizando a técnica de interpolação linear. Em seguida, aplicou-se a função `MinMaxScaler` do pacote de bibliotecas em Python *scikit-learn* para normalizar os dados de modo que fiquem dentro do intervalo  $[0,1]$ , essa normalização é feita para evitar que valores extremos enviesem o processo de treinamento da LSTM e para facilitar a comparação entre as séries temporais. Por fim, os dados foram divididos em conjuntos de treinamento, validação e teste, com proporções de 60%, 10% e 30%, respectivamente, de tal modo que o conjunto de treino se inicia em janeiro de 2010 e termina em dezembro de 2017, o conjunto de validação consiste em todo o ano de 2018 e o conjunto de testes se inicia em janeiro de 2019 e termina em setembro de 2022.

Para utilizar as séries temporais de preços de ações como entrada para a LSTM, precisou-se transformá-las em sequências fixas de comprimento, para isso, uma janela de



até 3 dias no passado foi definida para cada dia de previsão, isso significa que, para prever o preço de uma determinada ação em um dia específico, a LSTM receberá como entrada os preços de fechamentos dessa ação nos 3 dias anteriores.

### 3.2 Arquitetura e Hiper-parâmetros

Para treinar e avaliar a LSTM, foi utilizado um modelo sequencial implementado no framework Keras. O modelo (Figura 9) consiste em uma camada de entrada, uma camada LSTM, uma camada de *dropout*, duas camadas densas e uma camada de saída.

Figura 9 - Modelo LSTM

```
#Modelo
model = Sequential()

model.add(InputLayer(( 3 , 1)))

model.add(LSTM(units = 105 , return_sequences = False ))

model.add(Dropout(0.2))

model.add(Dense(7 , 'relu'))

model.add(Dense(1 , 'linear'))

model.summary()
```

Fonte: O Autor

- Camada de entrada: A camada de entrada recebe as sequências de tamanho fixo de 3 dias que está sendo utilizada como *input* para a LSTM.
- Camada LSTM: A camada LSTM é a principal camada do modelo e é responsável por armazenar informações de longo prazo e fazer previsões, nesta camada, utilizou-se 105 unidades LSTM o parâmetro 'return\_sequences' foi definido como 'False', o que significa que a saída da camada será uma única sequência em vez de uma série de sequências.
- Camada de dropout: A camada de *dropout* é utilizada para reduzir o *overfitting* ou sobre ajuste durante o treinamento, a taxa de *dropout* foi definida como 0.2, o que significa que 20% das unidades serão descartadas aleatoriamente na camada LSTM durante cada época de treinamento.

- Camadas densas: As duas camadas densas são camadas totalmente conectadas que utilizam a função de ativação “ReLU”. A primeira camada tem 7 unidades, enquanto a segunda tem 1 unidade, que é a saída do modelo.
- Camada de saída: A camada de saída é uma camada totalmente conectada que utiliza a função de ativação linear, ela produz a previsão final.

### 3.3 Compilação e Treinamento

Para compilar o modelo, utilizou-se o otimizador “Adam” (Figura 10) e a função de perda MSE, o otimizador “Adam” é um otimizador de gradiente estocástico que é uma boa escolha para a maioria dos problemas de aprendizado profundo.

Figura 10 - Parâmetros de Compilação e Treino

```
#Compilação
model.compile(optimizer = 'adam' , loss = 'mean_squared_error')

#Treino
model.fit(x_train , y_train , epochs = 100 , batch_size = 1 , verbose = 1)
```

Fonte: O Autor

Em seguida, depois de algumas experimentações com o número de épocas o modelo foi treinando com 100 épocas por ter o melhor desempenho e o tamanho do lote(batch) como 1. A época corresponde a uma passagem completa pelo conjunto de treinamento, enquanto o tamanho do lote corresponde ao número de amostras processadas antes de atualizar os pesos do modelo. O tamanho do lote foi definido como 1 para que o modelo atualize os pesos após cada amostra de treinamento, também está definido o parâmetro “verbose” como 1 para que o modelo exiba o progresso do treinamento a cada época.

### 3.4 Predição e Avaliações

Após treinar o modelo LSTM, utiliza-se o conjunto de teste para fazer previsões e avaliar o desempenho do modelo (Figura 11). Para fazer as previsões, utiliza-se a função

'predict' do modelo passando o conjunto de teste como entrada, em seguida, calcula-se duas métricas de avaliação: RMSE e o MAE.

Figura 11 - Predição e Métricas de Avaliação

```
#Predição
x_test = model.predict(x_test)

#Métricas de Avaliação
rmse = sqrt(mean_squared_error(x_test ,y_test))

mae = (mean_absolute_error(x_test , y_test))
```

Fonte: O Autor

### 3.5 Estratégias de trade e simulação

Uma vez que foi treinado e avaliado o modelo LSTM com as métricas de erro RMSE e MAE, é necessário avaliar como as previsões do modelo se sairiam em uma simulação de negociação real, para isso, serão utilizadas duas estratégias diferentes que seguem as previsões do modelo: uma estratégia sem *stop loss* e uma estratégia com *stop loss*.

A estratégia sem *stop loss* simplesmente compra ou vende ações de acordo com as previsões do modelo, sem nenhum tipo de proteção contra perdas ou gerenciamento de risco. A estratégia com *stop loss*, por outro lado, inclui uma proteção contra perdas ao fixar um limite máximo de perda em 50% da diferença entre o valor predito pelo modelo e o valor de abertura do mercado. Por fim as previsões do modelo serão divididas e avaliadas em 3 períodos:

- Pré-pandemia: Corresponde a todo ano de 2019
- Durante Pandemia: Corresponde a janeiro de 2020 a agosto de 2021
- Pós-Pandemia: Corresponde a setembro de 2021 a setembro de 2022

## 4 RESULTADOS e DISCUSSÃO

Nesta seção serão apresentados e analisados os resultados obtidos a partir da metodologia utilizada para treinar e avaliar a performance do modelo. Num primeiro momento serão apresentados os gráficos com os valores reais e os valores previstos e depois as tabelas dos resultados dos 3 cenários propostos serão apresentadas.

Figura 12 -Previsões dos setores Financeiro, Elétrico e de Construção

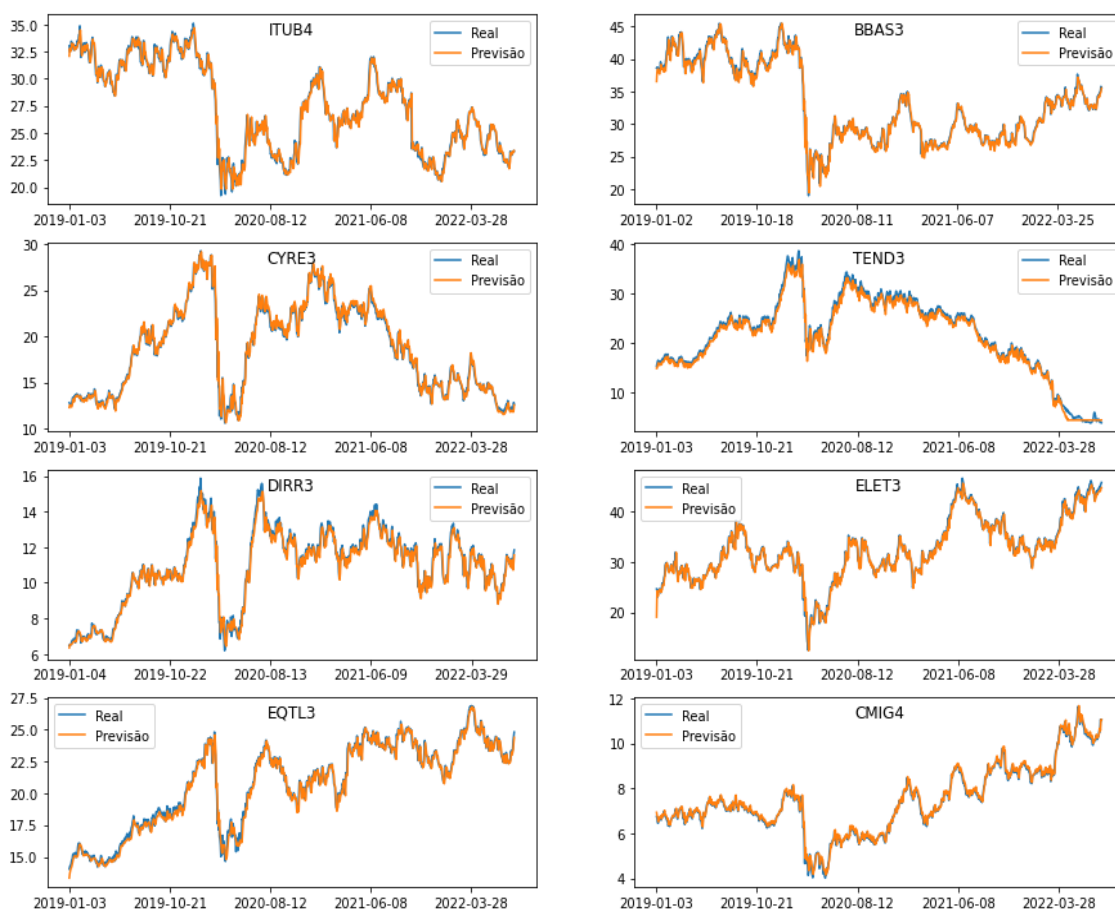
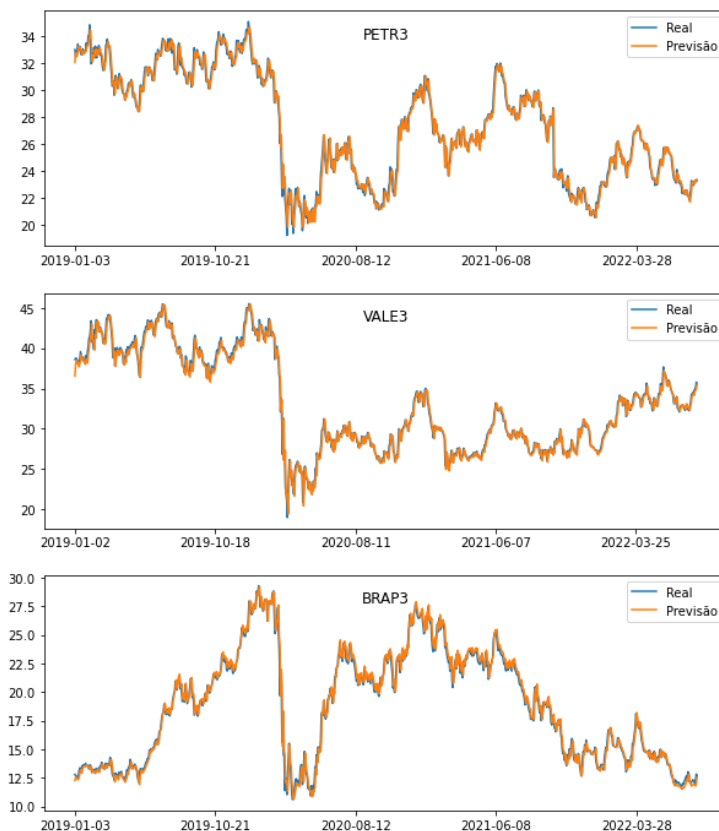


Figura 2 - Previsão das ações PETR3, VAL3 e BRAP3



Fonte: O Autor

#### 4.1 Resultados Pré-pandemia

A estratégia B&H apresenta os resultados mais satisfatórios para o cenário pré-pandemia (Tabela 2). A partir dos resultados apresentados, é possível observar que o desempenho da estratégia “Sem Stop Loss” baseada nas previsões da LSTM foi regular entre as ações analisadas, em alguns casos, como nas ações BBAS3, ELET3 e BRAP3, a estratégia teve um desempenho melhor ou pelo menos empatou tecnicamente com a estratégia B&H, por outro lado a estratégia com “50% Stop Loss” teve um desempenho ruim bem abaixo de suas concorrentes ganhando apenas na ação TEND3 contra a “Sem Stop Loss”. Em relação ao RMSE e MAE, os valores apresentados são bastante variáveis entre as ações, isso pode ser uma indicação de que o modelo teve dificuldades para prever algumas ações com precisão e talvez fosse necessária uma base dados maior ou mais robusta. Não há um padrão exato entre as estratégias baseadas na previsão da LSTM e a acurácia das métricas de avaliação, em ELET3 por exemplo, os valores são próximos de

1, porém a estratégia “Sem Stop Loss” performou até 1% de grandeza melhor que a estratégia B&H, por outro lado na ação DIRR3 os valores das métricas são muito bons próximos do 0,2 e ela fechou o ano com valores negativos. Caso houvesse uma carteira de investimentos baseada nessas ações e nessas estratégias o B&H seria vitorioso com valorização de 72,34% do início ao fim de 2019.

Tabela 2 - Resultados das estratégias em todo ano de 2019

<b>Ações</b>	<b>Sem Stop Loss</b>	<b>50% Stop Loss</b>	<b>Buy and Hold</b>	<b>RMSE</b>	<b>MAE</b>
ITUB4	-2,00%	-3,68%	6,09%	0,51	0,40
BBAS3	7,76%	-8,91%	2,08%	0,83	0,64
CYRE3	2,58%	-4,90%	13,68%	0,41	0,32
TEND3	0,80%	2,67%	15,35%	0,80	0,66
DIRR3	-0,04%	-0,97%	6,89%	0,22	0,17
ELET3	7,14%	-13,30%	6,53%	0,92	0,64
EQTL3	2,85%	-2,33%	7,68%	0,35	0,29
CMIG4	1,17%	-2,80%	0,30%	0,13	0,10
PETR4	2,85%	-4,72%	3,28%	0,29	0,22
VALE3	-1,55%	-14,73%	4,93%	1,05	0,72
BRAP3	5,33%	2,26%	5,53%	0,47	0,32
<b>TOTAL</b>	<b>26,89%</b>	<b>-51,41%</b>	<b>72,34%</b>		

Fonte: O Autor

## 4.2 Resultados Durante a Pandemia

A maior parte das oscilações dos dados se encontra no ano de 2020 devido ao início da pandemia e o derretimento dos mercados globais, na Tabela 3 a estratégia “50% Stop Loss” conseguiu performar positivo somente em uma ação a TEND3 e mesmo assim ficou em segundo lugar, a estratégia B&H teve dificuldades porém é sabido que o ano de 2021 foi um ano de recuperação majoritariamente o que favoreceu estratégias de longo prazo como B&H que performou bem em pelo menos 5 ações das 11 mas foi superada pela estratégia “Sem Stop Loss” fechando com 6 ações positivas com um desempenho muito bom nos setores financeiro, elétrico e de construção, a estratégia “Sem Stop Loss” teve bom desempenho inclusive em mercados lateralizados como o da ação ELET3 no período.

Caso uma carteira de investimentos fosse montada com estas ações e essas estratégias a “Sem Stop Loss” seria a estratégia vencedora com 37,74% de *profit*, performance excelente nas oscilações de uma crise. Quanto as métricas de avaliação a melhor acurácia ficou na ação CMIG4 porem só o B&H teve fechamento positivo na ação no período , a pior acurácia está na ação TEND3 da qual a estratégia “Sem Stop Loss” teve fechamento ótimo frente ao B&H mais uma vez as métricas de avaliação não parecem apontar para um padrão definido.

Tabela 3 - Resultados das estratégias de janeiro de 2020 a agosto de 2021

Ações	Sem Stop Loss	50% Stop Loss	Buy and Hold	RMSE	MAE
ITUB4	18,96%	-6,45%	-4,20%	0,65	0,49
BBAS3	10,93%	-16,02%	-17,31%	0,92	0,60
CYRE3	-21,24%	-25,11%	-8,47%	0,84	0,60
TEND3	21,59%	16,40%	-10,80%	1,19	0,93
DIRR3	2,62%	-2,10%	-1,25%	0,43	0,33
ELET3	24,81%	-15,68%	7,08%	1,05	0,74
EQTL3	20,05%	-5,88%	4,16%	0,52	0,39
CMIG4	-1,44%	-7,77%	1,98%	0,19	0,14
PETR4	-1,40%	-15,37%	-0,80%	0,48	0,32
VALE3	-25,91%	-40,01%	41,94%	1,53	1,18
BRAP3	-11,23%	-1,83%	16,51%	0,77	0,58
<b>TOTAL</b>	<b>37,74%</b>	<b>-119,82%</b>	<b>28,76%</b>		

Fonte: O Autor

#### 4.3 Resultados Pós-pandemia

Este período foi marcado por uma forte alta dos juros americanos o que causou uma migração expressiva dos investidores de ações para a renda fixa em dólares. Como observado na Tabela 4 a estratégia “50% Stop Loss” obteve desempenho muito ruim fechando apenas com duas ações no positivo a TEND3 e BRAP3. A estratégia B&H teve fechamentos majoritariamente negativos o destaque positivo fica para a ação PETR4 que se beneficiou da alta demanda por petróleo durante o início da guerra entre Rússia e Ucrânia, em contrapartida BRAP3 foi o pior destaque com a fuga dos investidores para ativos mais conservadores como os títulos públicos e *commodities*. A estratégia “Sem Stop Loss” teve desempenho positivo em 7 ações das 11 testadas, mesmo com a maioria

das ações em queda a estratégia conseguiu se mostrar consistente superando as outras duas estratégias.

As métricas de avaliação não demonstraram novamente nenhum padrão que se possa traçar entre as previsões do modelo e a acurácia atingida. A ação com a melhor acurácia atingida é a DIRR3 na qual a estratégia “Sem Stop Loss” teve um empate técnico com a B&H. A ação com a pior acurácia é a VALE3 sendo o segundo pior desempenho na estratégia B&H e com fechamento positivo na estratégia “Sem Stop Loss”. Se uma carteira fosse montada com base nessas estratégias e ações a estratégia vencedora seria a “Sem Stop Loss” com fechamento positivo de 18,27% no período.

Tabela 4 - Resultados das estratégias de setembro de 2021 a setembro de 2022

<b>Ações</b>	<b>Sem Stop Loss</b>	<b>50% Stop Loss</b>	<b>Buy and Hold</b>	<b>RMSE</b>	<b>MAE</b>
ITUB4	-2,32%	-6,65%	8,56%	0,53	0,35
BBAS3	6,52%	-5,44%	-5,48%	0,57	0,43
CYRE3	-6,79%	-6,76%	-5,55%	0,47	0,37
TEND3	6,51%	5,75%	-15,47%	0,80	0,64
DIRR3	0,45%	-2,15%	0,40%	0,35	0,28
ELET3	6,72%	-17,44%	9,33%	0,93	0,75
EQTL3	11,90%	-1,73%	-0,20%	0,36	0,29
CMIG4	2,03%	-2,15%	2,21%	0,18	0,13
PETR4	-3,47%	-8,75%	13,77%	0,62	0,47
VALE3	0,35%	-26,01%	-15,47%	1,96	1,55
BRAP3	-3,65%	7,00%	-17,63%	1,47	0,69
<b>TOTAL</b>	<b>18,27%</b>	<b>-64,34%</b>	<b>-25,53%</b>		

Fonte: O Autor

#### 4.4 Resultados Gerais

Avaliando o desempenho geral das estratégias nos 3 períodos na Tabela 5 pode-se inferir que o pior resultado ficou com a estratégia “50% Stop Loss”. Grande parte desse resultado vem da grande volatilidade gerada nos cenários propostos, a estratégia não é flexível a grandes oscilações o que leva a execução precoce das ordens de compra ou venda sem permitir que o ativo negociado corrija ou recupere sua trajetória anterior, isso demonstra a fragilidade da estratégia frente a crises e cenários muito especulativos.

A estratégia B&H possui um resultado sólido e mesmo com um desempenho ruim no auge da pandemia, atingiu um rendimento interessante aos seus utilizadores no



fechamento dos 3 períodos, como a ideia básica da estratégia é o foco no longo prazo em empresas resilientes e bem administradas, as oscilações a curto prazo possuem urgência muito menor o que permite ao ativo negociado mesmo após um *down swing* corrigir sua trajetória.

Por fim a estratégia “Sem Stop Loss” conseguiu apenas seguindo as previsões do modelo superar em até 15,69% a estratégia B&H no fechamento dos 3 períodos. A estratégia “Sem Stop Loss” conseguiu combinar o conservadorismo do B&H permitindo as correções das trajetórias, com a versatilidade da regressão logística da LSTM, realizando um fechamento positivo mesmo no auge da volatilidade dos ativos.

Nas métricas de avaliação o resultado com maior acurácia ficou com a ação CMIG4 e a menor acurácia ficou com a ação VALE3.

Tabela 5 - Resultados das estratégias de janeiro de 2019 a setembro de 2022

<b>Ações</b>	<b>Sem Stop Loss</b>	<b>50% Stop Loss</b>	<b>Buy and Hold</b>	<b>RMSE</b>	<b>MAE</b>
ITUB4	14,78%	-16,93%	-3,05%	0,58	0,57
BBAS3	24,69%	-30,32%	-9,73%	0,82	0,43
CYRE3	-25,15%	-37,12%	-0,18%	0,66	0,47
TEND3	28,61%	24,55%	-11,50%	1,00	0,78
DIRR3	3,75%	-5,36%	5,35%	0,36	0,27
ELET3	36,72%	-46,87%	21,16%	0,99	0,72
EQTL3	34,21%	-10,52%	10,77%	0,44	0,33
CMIG4	1,75%	-12,88%	4,28%	0,17	0,13
PETR4	-1,85%	-28,97%	16,08%	0,48	0,33
VALE3	-24,10%	-81,82%	30,65%	1,54	1,14
BRAP3	-9,23%	6,70%	4,64%	0,94	0,53
<b>TOTAL</b>	<b>84,17%</b>	<b>-239%</b>	<b>68,48%</b>		

Fonte: O Autor

É possível notar que em algumas ações como a PETR4 a estratégia “Sem Stop Loss” possui fechamento negativo enquanto a B&H possui um resultado positivo, em outras ações como a TEND3 o inverso acontece, este comportamento polarizado se deve a natureza das estratégias, a estratégia B&H possui foco total no longo prazo portanto não se beneficia das oscilações do curto prazo, por outro lado, a estratégia “Sem Stop Loss” não só se beneficia das oscilações de curto prazo como tenta manter a trajetória do longo prazo uma característica inerente das células LSTM.

## 5 Conclusão

Este trabalho apresentou previsões dos preços de 11 ações do mercado financeiro brasileiro através de uma rede neural LSTM. Após a obtenção dos dados, pré-processamento e treino do modelo, se pôde testar seu desempenho frente as métricas de avaliação, além de serem testadas 3 estratégias diferentes de negociação.

Ao todo 3 cenários de teste foram escolhidos para a testagem das estratégias. Os resultados para a estratégia proposta baseada nas previsões do modelo LSTM “Sem Stop Loss” foram satisfatórios superando o a estratégia conservadora B&H, o pior desempenho ficou com a estratégia “50% Stop Loss” que não conseguiu bom desempenho nos cenários de alta volatilidade.

A versatilidade e visão de longo prazo das células LSTM foram cruciais para a performance positiva da estratégia “Sem Stop Loss” no auge da pandemia enquanto sua concorrente direta a estratégia B&H não obteve bom desempenho, apesar disso a recuperação da foi solida no período seguinte uma vez que a B&H é uma estratégia que tira proveito máximo dos seus ativos no longo prazo.

Para trabalhos futuros, sugere-se o teste de estratégias voltadas para análise técnica com o uso de osciladores e médias moveis, também se sugere o uso da LSTM para exposição de outros mercados além do mercado de ações como os mercados cambiais ou de *commodities*. É sugerido também um comparativo com outros modelos de regressões linear como o ARIMA ou testes de outros hiper-parâmetros com diferentes redes neurais.

## REFERÊNCIAS

- JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. **Artificial neural networks: A tutorial**. Computer, IEEE, v. 29 1996.
- BUFFET, W.; CUNNINGHAM, L. **The Essays of Warren Buffet**. Wrightbooks; 1ª edição, Melbourne, 1999.
- SHILLER, R. J. **Irrational Exuberance**. Princeton University Press, 2nd ed., New Jersey, 2005.
- B3, **Histórico de pessoas físicas**. 2022. Disponível em: <[http://www.b3.com.br/pt\\_br/market-data-e-indices/servicos-de-dados/market-data/consultas/mercado-a-vista/historico-pessoas-fisicas/](http://www.b3.com.br/pt_br/market-data-e-indices/servicos-de-dados/market-data/consultas/mercado-a-vista/historico-pessoas-fisicas/)>. Acesso em: 23 de ago. 2022.
- WORLD BANK, **Global Economic Prospects 2019**, Disponível em: <<https://www.worldbank.org/en/publication/global-economic-prospects>> Acesso em: 23 de ago. 2022.
- FED, **Statement on Longer-Run Goals and Monetary Policy Strategy Principles for Reducing the Size of the Federal Reserve’s Balance Sheet 2021**, Disponível em: <<https://www.federalreserve.gov/monetarypolicy/fomccalendars.htm>>. Acesso em: 24 de ago. 2022.
- ESCOVEDO, T.; KOSHIYAMA, A. **Introdução a Data Science — Algoritmos de Machine Learning e métodos de análise**. Ed. Casa do Código, São Paulo, 2020.
- NOGUEIRA, G. O. G.; LIMA, M. O. **Previsão dos Preços de abertura, mínima e máxima de índices de mercados financeiros usando a associação de Redes Neurais LSTM**, USP, São Paulo, 2021.
- DING, G., QIN, L. **Study on the prediction of stock price based on the associated network model of LSTM**. Int. J. Mach. Learn. & Cyber, 2020.
- CAVALCANTE, R. C.; BRASILEIRO, R. C.; SOUZA, V. L.; NOBREGA, J. P.; OLIVEIRA, A. L. **Computational intelligence and financial markets: A survey and future directions**. Expert Systems with Applications, Elsevier, 2016.
- BRASIL. [Constituição (1988)]. **Constituição da República Federativa do Brasil**: promulgada em 5 de outubro de 1988.
- FRANCO, F. **Investimento em ações para Iniciantes**, Instituto Municipal Superior de Assis, Assis, 2017
- HUANG, Q.; WANG, T.; TAO, D.; LI, X. **Biclustering learning of trading rules**. IEEE transactions on Cybernetics, IEEE, 2014.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**, MIT Press, MIT, Massachussets, 2016.
- OLAH, C. **Understanding LSTM networks**. 2015. Disponível em: <<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acesso em: 27 ago. 2022.
- PINHEIRO, J. **Mercado de capitais: o que é e como funciona**. Disponível em: <<https://julianopinheiro.com/mercado-de-capitais-como-funciona/>>. Acesse em: 26. ago. 2022.
- GRAHAM, B. **O Investidor Inteligente**. v1, New York: Harper Collins, 1949.
- LOPES, R. **O que você sabe sobre o book de ofertas**. Disponível em: <<https://www.bussoladoinvestidor.com.br/o-que-voce-sabe-sobre-book-de-ofertas/>>
- MURPHY, J. J. **Technical analysis of the financial markets: A comprehensive guide to trading methods and applications**. New York Institute of Finance: Penguin, 1999.
- LOGUE, A. C. **Day Trading for Dummies**. US: For Dummies, 2007.