

Análise de algoritmos de negociação para recomendação de investimentos na bolsa de valores brasileira

Diana Braatz¹, Edimar Manica¹

¹Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul - *Campus* Ibirubá
Rua Nelsi Ribas Fritsch, 1111 – CEP: 98200-000 – Ibirubá – RS – Brasil

{diana.braatz, edimar.manica}@ibiruba.ifrs.edu.br

Abstract. *With a 17.5% increase of investors in the Brazilian stock exchange in 2022 compared to 2021, the need for financial guidance for these people arises, either through an investment system or by a professional in the area. Following this line, the problem raised by this work is the lack of a safe and free system that indicates the right moment to buy or sell shares. Thinking about minimizing this gap, the present work selects, analyzes and evaluates different trading algorithms through different indicators focusing on the Brazilian stock exchange. Five trading algorithms were tested using 9 performance indicators for 30 shares of the Brazilian stock exchange, divided into 9 sectors and 15 segments. The algorithm with the best performance was the Buy and Hold obtaining an average Sharpe ratio of 0.830 that analyzes the risk-adjusted return.*

Resumo. *Com um aumento em 2022 de 17,5% de investidores na bolsa de valores brasileira em comparação a 2021, surge a necessidade de orientação financeira para essas pessoas, seja através de um sistema de investimentos ou por um profissional da área. Seguindo essa linha, o problema levantado por este trabalho é a falta de um sistema seguro e gratuito que indique o momento ideal de compra ou venda de ações. Pensando em minimizar essa lacuna, o presente trabalho seleciona, analisa e avalia diferentes algoritmos de negociação por meio de diversos indicadores com foco nas ações da bolsa brasileira. Foram testados 5 algoritmos de negociação por meio de 9 indicadores de desempenho para 30 ações da bolsa de valores brasileira, divididas em 9 setores e 15 segmentos. O algoritmo com maior desempenho foi o Buy and Hold obtendo um índice Sharpe médio de 0,830 que analisa o retorno ajustado ao risco.*

1. Introdução

Segundo Ferrari (2023), a bolsa de valores brasileira (B3) chegou no final de 2022 com aproximadamente 5,8 milhões de investidores, um aumento de 17,5% em comparação com 2021 que indica o quanto fazer a gestão das finanças pessoais vem se popularizando. A indústria de tecnologia financeira busca aproveitar amplamente a tecnologia para inovar e melhorar as atividades financeiras. Basicamente, muitos problemas na tomada de decisões relacionadas ao setor financeiro podem ser solucionados com estratégias aplicadas em algoritmos, a fim de prever tendências de preços de ações, identificar padrões no comportamento de ativos e administrar carteiras de investimentos (THÉATE; ERNST, 2021).

Conforme Souza (2022), para realizar uma aplicação deve-se primeiramente entender o mercado de ações, dominar alguns termos, conhecer o seu perfil de investidor,

definir metas de lucro e nível de risco. Todos esses passos demandam dedicação de tempo e acompanhamento diário, que devido às tarefas cotidianas, resultam em perda do momento ideal de compra ou venda das ações e consequentemente, perda financeira. Agentes autônomos ou algoritmos de negociação podem servir como guia para os investidores, lhes fornecendo previsões do mercado (ZAP, 2022), contudo podem existir custos na sua aquisição ou contratação que nem sempre o investidor está disposto a gastar (G1, 2022).

Nesse contexto, o problema abordado por este trabalho é a falta de um sistema eficaz que indique o momento certo de compra ou venda de ações. Para minimizar essa lacuna, o objetivo do presente trabalho é selecionar, analisar e avaliar diferentes algoritmos de negociação por meio de diversos indicadores. A contribuição deste trabalho é fazer a análise com foco nas ações da bolsa de valores brasileira. Foram testados 5 algoritmos de negociação que utilizam inteligência artificial, ou estratégias clássicas como seguimento de tendência ou compra e mantenha, isso por meio de 9 indicadores de desempenho que analisam o lucro, o retorno sobre o risco ou a volatilidade para 30 ações da bolsa de valores brasileira, divididas em 9 setores e 15 segmentos. O algoritmo com maior desempenho foi o *Buy and Hold* obtendo um índice Sharpe médio de 0,830 que analisa o retorno ajustado ao risco.

O restante deste artigo está organizado da seguinte forma. Na Seção 2, são definidos os conceitos necessários para a compreensão deste trabalho. Na seção 3, são analisados os trabalhos relacionados à área de inteligência artificial e negociação de ações. A Seção 4 descreve a metodologia adotada. Os resultados dos experimentos são apresentados e discutidos na Seção 5. A Seção 6, apresenta a conclusão do trabalho e sugere trabalhos futuros.

2. Fundamentação Teórica

Esta seção trata a respeito da fundamentação teórica que tem como objetivo apresentar os conceitos necessários para compreensão deste trabalho. Inicialmente é explicado a evolução do mercado financeiro e como ele se adaptou a negociação algorítmica. Em seguida é apresentado os algoritmos de negociação e por fim os indicadores de desempenho.

2.1. Mercado Financeiro e Negociação algorítmica

O ato de negociar ocorre quando investidores que possuem ativos procuram comprar e vender ações e outros títulos com os demais investidores no mercado financeiro. Para facilitar a negociação desses títulos no mercado, foram criadas instituições que têm por objetivo administrar sistemas centralizados, regulados e seguros para a negociação desses títulos. São exemplos destas instituições as bolsas de valores e as entidades administradoras do mercado (INVESTIDORA, 2022)

Para Théate e Ernst (2021), a negociação algorítmica é a metodologia para negociar usando computadores e um conjunto específico de regras matemáticas. Pode ser vista também como a abordagem de tomar decisões de negociação automaticamente com base em um conjunto de regras matemáticas computadas por uma máquina. Conforme Géron (2019), um algoritmo de negociação pode ser utilizado pelo software para determinar as ações a serem realizadas. É através do algoritmo que o sistema realiza as ações necessárias utilizando os dados armazenados e retornando com observações e recompensas.

2.2. Algoritmos de Negociação

Os algoritmos assumem uma importância cada vez mais relevante no contexto da negociação por facilitarem a execução de ordens conforme parâmetros previamente determinados, tornarem o processo mais ágil e permitirem uma negociação com maior controle (ALMEIDA, 2016). Conforme Carvalho, Barboza e Fiorucci (2020), utilizando algoritmos de negociação, o investidor tem a liberdade de desenvolver métodos automatizados para realizar suas aplicações sem ter a necessidade de dedicar tempo para acompanhamento diário.

Os algoritmos atuais são cada vez mais complexos, sendo capazes de interpretar diferentes sinais no mercado quase em tempo real, além de serem capazes de assimilar informação em diferentes plataformas. Ao identificar uma oportunidade de negociação, os algoritmos realizam ordens de compra e venda diárias buscando a melhor oferta. Nas próximas subseções são descritos os algoritmos de negociação identificados na literatura. Por fim, a subseção 3.1.6 apresenta um resumo dos algoritmos.

2.2.1. *Buy and Hold* (B&H)

Conforme Silva (2022), uma das estratégias de investimento mais comuns entre os investidores brasileiros para a negociação denomina-se *Buy and Hold* (Compra e mantém). Destaca-se por ser um algoritmo que utiliza uma técnica antiga de investimento, onde o investidor compra a ação e não vende por um longo período visando a valorização ao longo do tempo e o acúmulo dos dividendos (juros). Apesar dos valores de cotação variarem diariamente, no longo prazo, a cotação sempre acompanha os lucros históricos das empresas.

A estratégia *Buy and Hold* é indicada para investidores que não possuem muito tempo para acompanhar e monitorar diariamente o mercado financeiro, assim possibilitando um número menor de negociação, minimizando os custos de transações, aumentando o retorno líquido financeiro da carteira de ações (NEVES, 2019). Basicamente a estrutura que mantém o algoritmo *Buy and Hold* tecnicamente efetivo é constituída pelos seguintes itens: escolher boas empresas; investimento constante; tempo de investimento; e, diversificação das ações. Por exemplo, se um investidor comprou 100 ações ao preço de fechamento de R\$18,00 por ação em janeiro de 2008 e manteve o estoque até janeiro de 2019 e o estoque subiu para R\$157,00 por ação, o retorno do investimento será de 772,22% em 11 anos sem contabilizar os dividendos.

2.2.2. *Sell and Hold* (S&H)

Conforme Théate e Ernst (2021) o algoritmo *Buy and Hold* sempre faz *long trading position decision* (decisão de posição de negociação longa) e o algoritmo *Sell and Hold* sempre faz *short trading position decision* (decisão de posição de negociação curta), devido a isso, o investidor que utiliza o algoritmo *Sell and Hold* (Vende e mantém) sempre vende as ações de sua carteira na intenção de compra-las de volta posteriormente por um preço menor, visando a queda de preço ao longo do tempo. Isso significa que é possível lucrar mesmo quando os mercados estão em baixa.

Por exemplo, se um investidor vendeu 100 ações ao preço de fechamento de R\$155,00 por ação em março de 2012 e manteve até março de 2022, quando comprou as 100 ações ao preço de fechamento de R\$20,00 por ação, o lucro obtido será de R\$13.500,00, igual a 675% em 10 anos. A diferença entre o valor que o investidor vendeu as ações e as comprou de volta é o lucro obtido (WRITERS, 2022).

2.2.3. *Trend following* (TF)

O algoritmo *Trend following* (acompanhamento de tendência) se diferencia dos algoritmos anteriores por não se preocupar com o preço das ações, se está caro ou barato, tendo uma tendência definida, o investidor pode fazer a operação (ISMAR, 2021). *Trend following* é uma estratégia de investimento que se fundamenta na tendência dos preços, na observação de crescimento ou decréscimo deles. Segundo Silva (2018), os investidores estabelecem uma estratégia de acompanhamento de tendências e nelas se baseiam para tomar decisões de compra ou venda de determinada ação apostando na continuidade do movimento.

Para compreender, os investidores que seguem a tendência não tentam prever o preço ou “adivinhar” como o mercado pode se comportar, apenas são guiados por conceitos estatísticos baseados em uma única informação: o preço. Se o preço sobe, a tendência é de alta. Se o preço desce, a tendência é de baixa. Se o preço permanece em uma faixa lateral, o mercado fica sem tendência. Por fim, observando a direção geral do preço, sabe-se a direção da tendência para então tomar uma decisão de comprar ou vender uma ação.

2.2.4. *Mean reversion* (MR)

Algoritmos com técnica de *Mean reversion* (reversão à média) tentam capturar lucros à medida que o preço de uma ação retorna a níveis mais normais ou à média. Entende-se que os movimentos extremos de preços são difíceis de se sustentar por períodos prolongados (MARKETS, 2023). A estratégia de *Mean reversion* acredita que ações com bom desempenho tendem a apresentar desempenho ruim comparado a outras ações em período subsequente, e que ações com desempenho baixo, tendem a performar melhor.

Em outros termos, quando a ação sofre uma valorização acima de seu preço médio, o algoritmo de negociação venderá essa ação apostando na volta do preço para a média. Caso a ação se desvalorize abaixo da média, o algoritmo de negociação comprará. Basicamente um algoritmo de reversão à média sempre vai contra as tendências enquanto um algoritmo de seguimento de tendência segue os movimentos.

2.2.5. TDQN

O algoritmo *Trading Deep Q-Network* (TDQN), criado por Théate e Ernst (2021), trata-se de uma aplicação de aprendizado por reforço profundo que deve indicar um momento de compra e venda ideal durante uma atividade de negociação algorítmica no mercado de ações. O algoritmo TDQN foi adaptado e baseado no algoritmo *Deep Q-Network* (DQN), que refere-se a uma técnica de aprendizado de máquina que une rede neural con-

volucional (algoritmo de aprendizado profundo) com aprendizado por reforço para ensinar uma inteligência artificial a obter sucesso em um ambiente recebendo apenas dados dele como entrada.

2.2.6. Resumo dos algoritmos

Na Tabela 1, é possível observar uma explicação breve de cada um dos algoritmos de negociação utilizados nesse trabalho.

Tabela 1. Algoritmos de negociação

Algoritmo	Descrição
<i>Buy and Hold</i>	Compra a ação e mantém ela na carteira por um longo período, visando a valorização da ação.
<i>Sell and Hold</i>	Vende as ações e monitora até a ação valorizar ao longo do tempo
<i>Trend following</i>	Segue uma tendência, apostando na continuidade do movimento.
<i>Mean reversion</i>	Vai contra a tendência, preferindo atentar-se ao preço na medida que retorna à média histórica.
TDQN	Estratégia que monitora o mercado, a fim de não perder o momento ideal de compra e venda.

2.3. Indicadores de Desempenho

Indicadores de desempenho são utilizados em diversas áreas para auxiliar na tomada de decisão. Hoje as empresas utilizam para avaliar a produtividade de seus empregados, a participação de mercado de um produto, o tempo de término de estoque da empresa, entre outras. No mercado financeiro, os indicadores possuem o mesmo objetivo, a partir de uma análise retornar alguma informação que possa auxiliar na tomada de decisão (REIS, 2019).

Conforme Théate e Ernst (2021) e Reis (2018) é a partir da análise de indicadores que os investidores podem obter uma “fotografia” clara da situação financeira de uma empresa, onde é possível avaliar de forma mais técnica a performance dos investimentos e assim ter uma assertividade maior e um risco consciente no momento de investir. Vale ressaltar a importância de ter mais de um indicador para avaliar os ativos devido às diferenças entre indicadores.

Os seguintes indicadores foram selecionados: Índice Sharpe, Índice Sortino, Lucros e Perdas, Relação de Lucros e Perdas, Retorno Anualizado, Volatilidade Anualizada, Índice de Lucratividade, Rebaixamento Máximo e Duração de Rebaixamento Máximo. Nas próximas subseções são descritos os indicadores de desempenho encontrados nas pesquisas de demais autores. Posteriormente, a subseção 2.2.10 apresenta um resumo dos indicadores de desempenho.

2.3.1. Principais conceitos

Visando a compreensão dos cálculos dos diversos indicadores de desempenho, esta subseção explica alguns conceitos utilizados conforme Théate e Ernst (2021).

- *Cash* - Valor que o agente tem em conta (em moeda) para investir novamente, por exemplo o agente inicia com R\$100.000,00 de *cash* para investir;

- *Holdings* - Valor que o agente tem em ações, por exemplo se o agente tem 10 ações, cujo o valor é R\$2,00 reais em um determinado dia, então nesse dia ele tem R\$20,00 reais de *holdings*;
- *Money* - Valor resultante da soma de *cash* e *holdings* (*cash* + *holdings*);
- *Returns* - Valor resultante da diferença entre o *cash* obtido no dia atual e o *cash* obtido no dia anterior, dividido pelo *cash* obtido no dia anterior ($((\textit{cash} \textit{ dia atual} - \textit{cash} \textit{ do dia anterior}) / \textit{cash} \textit{ do dia anterior})$);
- *Expected Returns* - É a média dos *returns* de determinada ação durante todo o período de teste;
- *Volatility* - É o desvio padrão dos *returns* de determinada ação no período todo de teste;
- *Risk Free Ratio* - É o retorno de uma renda fixa, de um investimento seguro, no período, por exemplo Selic ou CDI;
- Retorno acumulado - Valor acumulado dos *returns* diários;
- *Time Elapsed* - quantidade de dias entre o início e o fim do período observado;
- Raiz quadrada de 252 - É a quantidade de dias úteis para investimento na bolsa.

2.3.2. Índice Sharpe

Hoje, o índice Sharpe é o mais utilizado no mundo financeiro por considerar simultaneamente os benefícios e os riscos (PACTUAL, 2022; LEI et al., 2020). Ele mostra quanto de volatilidade foi necessário assumir para ter em troca a rentabilidade mais robusta. Quanto mais alto o índice Sharpe, maior tende a ser o retorno ajustado ao risco, ou seja, o retorno financeiro gerado com o investimento em determinada ação vale o risco que essa oferece. A Equação 1 especifica como o índice Sharpe é calculado.

$$\textit{Sharpe} = \sqrt{252} * \frac{\textit{ER} - \textit{RFR}}{V} \quad (1)$$

Onde ER é o *Expected Returns*, ou seja, a rentabilidade obtida em determinado período pelo investimento analisado; RFR, *Risk Free Ratio*, indica a rentabilidade de uma aplicação conservadora que pode ser Selic ou CDI, e V é a *Volatility*, que mede a quantidade e a intensidade das oscilações de preços de um investimento. Logo, se preço dos investimentos com cada um dos algoritmos passa por constantes ou profundas altas e baixas, é considerado mais volátil, com maior risco.

A variável RFR, pode utilizar a taxa Selic ou o CDI, contudo para os experimentos deste trabalho foi utilizada a taxa livre de risco padrão que o Théate e Ernst (2021) utilizou. Destaca-se que o retorno de um investimento com um índice Sharpe igual ou acima de 0,5 é considerada um ótimo investimento, que entregará bons retornos, por outro lado, caso o índice seja igual a 0 ou negativo, indica não ser vantajoso assumir aquele risco, sendo mais interessante investir em uma aplicação livre de risco conforme (THÉATE; ERNST, 2021; ISMAR, 2022; PACTUAL, 2022).

2.3.3. Índice Sortino

O índice Sortino é uma adaptação do índice Sharpe, mudando basicamente a medida de risco que ele considera, passando a ser o desvio padrão negativo ou a volatilidade

negativa. Segundo Maverick (2021), o índice Sharpe é mais utilizado por investidores para avaliar carteiras de investimento de baixa volatilidade, e a variação Sortino é mais utilizada para avaliar carteiras de alta volatilidade. O índice Sortino utiliza apenas os retornos abaixo de um certo valor de referência, ou seja, apenas considera as ações que possuem a volatilidade negativa. É um indicador que busca avaliar até que ponto a rentabilidade oferecida compensa o risco (KENTON, 2020). A Equação 2 especifica como o índice Sortino é calculado.

$$Sortino = \sqrt{252} * \frac{ER - RFR}{VN} \quad (2)$$

Onde ER é o *Expected Returns*, ou seja, a rentabilidade obtida em determinado período pelo investimento analisado; RFR, *Risk Free Ratio*, indica a rentabilidade de uma aplicação conservadora que pode ser a Selic ou o CDI, e VN é a *Volatility* negativa, indica o desvio padrão dos retornos negativos dos investimentos feitos pelos algoritmos, ou seja, deve-se considerar apenas a volatilidade do investimento quando o retorno ficou negativo. O índice Sortino é uma maneira útil para investidores avaliarem o retorno de um investimento para um determinado nível de risco ruim, quanto mais instável é um investimento, melhor deve ser a sua rentabilidade. Não faz nenhum sentido assumir um nível de risco para um ganho pequeno (MAVERICK, 2021; GIRÃO, 2018).

2.3.4. Lucros e Perdas

O indicador de Lucros e Perdas tem como objetivo demonstrar a saúde financeira de uma empresa. Consiste basicamente em indicar se o negócio está tendo lucro ou prejuízo. O demonstrativo de Lucros e Perdas resume as receitas, custos e despesas de uma empresa durante um período específico, e fornece informações sobre a capacidade ou incapacidade de uma empresa de gerar lucro aumentando a receita, reduzindo custos ou ambos (FERNANDO, 2022).

Ainda segundo Fernando (2022), investidores e analistas utilizam essas informações para avaliar a lucratividade da empresa, muitas vezes combinando essas informações com *insights* das outras demonstrações financeiras. Neste caso, o indicador foi ajustado para avaliar se o retorno gerado a partir da negociação dos algoritmos gerou lucro ou perda financeira. A Equação 3 especifica como o indicador de Lucros e Perdas é calculado.

$$Lucros\&Perdas = Money(-1) - Money(0) \quad (3)$$

Onde *Money(-1)* se refere ao valor total acumulado até o momento e *Money(0)* se refere ao valor em que o agente tinha antes de investir, o valor inicial. Vale ressaltar que o retorno é em reais, portanto onde o valor for positivo significa um ganho financeiro e onde o valor for negativo significa uma perda financeira. Por exemplo, o resultado de R\$182.278,00 representa um ganho de determinado investimento, contudo R\$-41.512,00 representa uma perda.

2.3.5. Razão de Lucros e Perdas

A relação lucro/perda assim como os demais indicadores, mede o desempenho de um algoritmo, estratégia ou sistema de negociação. Uma relação lucro/perda consistentemente sólida pode encorajar um *trader* (investidor no mercado financeiro) a alavancar apostas na mesma estratégia na tentativa de gerar maiores lucros absolutos. Talvez o investidor decida abandonar completamente um algoritmo ou sistema se a relação não estiver produzindo ganhos suficientes ou mesmo causando perdas de capital (KENTON, 2021; FXPRO, 2023). A Equação 4 representa como a razão de lucros e perdas é calculada.

$$RazaoLP = \frac{\left(\frac{GT}{NV}\right)}{\left(\frac{PT}{NP}\right)} \quad (4)$$

Onde GT é o ganho financeiro total, NV é o número de negociações vencedoras, ou seja, que tiveram o ganho financeiro, PT é a perda financeira total e NP é o número de negociações perdedoras, ou seja, que tiveram a perda financeira. É, basicamente, o lucro médio das negociações vencedoras dividido pela perda média das negociações perdedoras durante um período de tempo especificado. Segundo Kenton (2021), o ideal é que a proporção seja 2/1, por exemplo, se um sistema tivesse uma média de ganhos de R\$750,00 por negociação e uma perda média ao mesmo tempo de R\$250,00 por negociação, a relação lucro/perda seria de 3/1.

2.3.6. Retorno Anualizado

Um retorno anualizado é o resultado da diferença entre o valor dos gastos e dos lucros adquiridos em uma negociação a cada ano e é útil quando deseja-se ver o desempenho de um investimento ao longo do tempo ou comparar dois investimentos com períodos de tempo diferentes conforme Team (2022). A fórmula para calcular a taxa de retorno anualizada precisa de apenas duas variáveis: os retornos para um determinado período de tempo e o tempo em que o investimento foi realizado. A Equação 5 representa como o retorno anualizado é calculado.

$$RetornoAnualizado = 100 \times \left((1 + RAc)^{\frac{365}{timeElapsed}} - 1 \right) \quad (5)$$

Onde RAc é o retorno total acumulado, e *timeElapsed* é o número em dias entre o início e o fim do período. Se o retorno for positivo, considera-se ganho, se for negativo, considera-se perda sobre o investimento inicial. Chen (2021) e Team (2023) colocam que a taxa de retorno varia de acordo com o nível de risco envolvido.

2.3.7. Volatilidade Anualizada

A volatilidade anualizada calcula a volatilidade obtida em um investimento a cada ano, em um período de tempo. Quanto mais o preço de um investimento varia em um período curto de tempo, maior o risco de se ganhar ou perder dinheiro negociando segundo Srivastav (2023). A Equação 6 representa como a volatilidade anualizada é calculada.

$$VolatilidadeAnualizada = 100 \times \sqrt{252} \times \sigma \quad (6)$$

Onde σ (desvio padrão dos *returns*), indica quanto o retorno varia em um determinado período de tempo, podendo ser para cima ou para baixo. Uma volatilidade mais alta indica que o valor do investimento pode mover-se em qualquer direção em um curto período. Por outro lado, uma menor volatilidade indica que o valor do retorno não oscilaria muito e continuará estável ao longo do período (ALIDA, 2021).

2.3.8. Lucratividade

A lucratividade se refere ao quanto uma empresa consegue gerar lucro com sua atividade, o quanto obtém receita, considerando suas despesas. Analistas e investidores utilizam a métrica de lucratividade para entender melhor como a empresa consegue ganhar o dinheiro necessário para cobrir suas despesas e outros custos relacionados à empresa (SMARTER, 2023; HORTON, 2021). A avaliação das ações funciona como mencionado, contudo para avaliar os algoritmos, o indicador foi adaptado e a Equação 7 representa como a lucratividade é calculada.

$$Lucratividade = \frac{NV}{NV + NP} \times 100 \quad (7)$$

Onde NV é o número de negociações vencedoras, ou seja, que tiveram o ganho financeiro, e NP é o número de negociações perdedoras, ou seja, que tiveram a perda financeira. Trata-se de um percentual que indica quantas negociações resultaram em lucro.

2.3.9. Rebaixamento Máximo

O rebaixamento máximo é um indicador de risco de queda de preço durante um período de tempo especificado. É uma medida da maior queda de preço de um ativo. A Equação 8 representa como o rebaixamento máximo é calculado.

$$RebaixamentoMaximo = \frac{V_{max} - V_{min}}{V_{max}} \times 100 \quad (8)$$

Onde V_{min} é o *Money* mínimo, ou seja, o ponto mais baixo em uma série histórica e V_{max} é *Money* máximo, ou seja, o valor mais alto da série histórica antes de alcançar o mínimo. Suponha que uma carteira de investimentos tenha um valor inicial de R\$500.000,00. A carteira aumenta para R\$750.000,00 ao longo de um período de tempo, antes de cair para R\$400.000,00 em um agressivo mercado de baixa. Em seguida, ele se recupera para R\$600.000,00, antes de cair novamente para R\$350.000,00. Posteriormente, mais do que dobra para R\$800.000,00. O *Money* mínimo nesse exemplo é R\$350.000,00 e o *Money* máximo é R\$750.000,00. Neste exemplo a maior queda (R\$350.000,00) ocorreu antes do valor de R\$800.000,00 e devido a isso, este não foi utilizado como *Money* máximo. O exemplo gera um rebaixamento máximo de 53,33%.

É preferível um rebaixamento máximo baixo, pois indica que as perdas do investimento foram pequenas. Se um investimento nunca perdesse um centavo, o rebaixamento máximo seria zero. O pior rebaixamento máximo possível seria 100%, o que significa que o investimento é completamente inútil de acordo com Hayes (2022).

2.3.10. Duração do Rebaixamento Máximo

Seguindo a mesma linha do indicador de rebaixamento máximo citado anteriormente, o indicador de duração de rebaixamento máximo irá retornar a duração em dias em que o investimento leva do ponto mais alto até a maior queda (HAYES, 2022). A Equação 9 representa como o rebaixamento máximo é calculado.

$$RMdias = DMax - DMin \quad (9)$$

Onde DMax é o dia de alta do investimento antes da maior queda e o DMin é o dia da maior queda do investimento.

2.3.11. Resumo dos indicadores

Conforme dito nas subseções anteriores, cada métrica avalia uma característica dos algoritmos, mas se utilizado e olhada em conjunto é possível ter uma análise completa dos investimentos realizados. Na Tabela 2 pode ser observado as definições de forma sucinta de cada indicador de desempenho utilizado no presente trabalho.

Tabela 2. Indicadores de desempenho

Indicador de desempenho	Descrição
Índice Sharpe	Índice de retorno do investimento em relação ao risco que este oferece
Índice Sortino	Avalia o retorno do investimento em relação ao risco, considerando apenas o desvio padrão negativo
Lucros e Perdas	Demonstrativo de lucro ou perda após um investimento em determinada ação
Razão de Lucros e Perdas	Retorna o lucro médio das negociações vencedoras pelas negociação perdedoras
Retorno Anualizado	Retorna o desempenho médio anual de um investimento
Volatilidade Anualizada	Retorna a variação média anual de um investimento
Lucratividade	Indica quantas negociações resultaram em lucro
Rebaixamento Máximo	Representa o risco de queda de preço em determinado ativo durante um período
Duração de Rebaixamento Máximo	Representa em dias o risco de queda de preço em determinado ativo durante um período

3. Trabalhos Relacionados

Nesta seção são apresentados os trabalhos relacionados à recomendação de investimentos. Esses trabalhos foram encontrados na plataforma *Google Scholar* (SCHOLAR, 2022), a partir da busca pelas seguintes palavras-chave: *deep learning e algorithmic trading*. Após analisar o título e o resumo dos artigos que a pesquisa retornou, utilizou-se como critério para escolha dos trabalhos o ano de publicação mais recente, a quantidade de citações e a avaliação do Qualis Periódicos (CAPES, 2023) que os mesmos obtiveram.

3.1. DQN e A3C

O trabalho de Li, Zheng e Zheng (2019) propõe a criação de uma estrutura de aprendizado de reforço robusto e profundo para tomar decisões de negociação de ações e obter lucro nos mercados financeiros. O modelo consiste de dois elementos, o ambiente que gerencia os dados históricos do mercado e recebe dados atuais da bolsa de valores e o agente que contém um módulo de pré-processamento de dados e um algoritmo de negociação.

Foram testados dois algoritmos de negociação: o *DQN-EXTENDED* (*Value-based algorithm* - Aprendizagem por reforço baseado em valores) e o *A3C-EXTENDED* (*Actor-critic algorithm* - Aprendizagem por reforço ator-crítico). O trabalho utilizou como métrica para medir desempenho os indicadores: Índice Sharpe (IS) e Retorno Anualizado

(RA). Ao final do estudo o algoritmo *A3C-EXTENDED* apresentou um desempenho maior em relação ao algoritmo *DQN-EXTENDED*, pois obteve 3,44 de Índice Sharpe, para 2,76 do *DQN-EXTENDED*.

3.2. TFJ-DRL

O trabalho de Lei et al. (2020) propõe um modelo de aprendizado de reforço em conjunto com o reconhecimento de recursos o qual integra os modelos de aprendizado profundo supervisionado e aprendizado por reforço com o objetivo de solucionar o problema da negociação algorítmica que requer percepção contínua de sinais financeiros dados pelo ambiente e tomada de decisões corretas de forma online.

Os autores realizaram a seleção de ações com diferentes padrões e utilizaram dados históricos reais para comparar o desempenho do modelo proposto *Time-driven feature-aware jointly deep reinforcement learning* (TFJ-DRL) com os demais do mercado e também verificar a capacidade de generalização e confiabilidade do mesmo. O trabalho utilizou como métrica para medir desempenho os indicadores: Índice Sharpe (IS), Retorno Anualizado (RA), Lucratividade (L) e Tempos de Transação (TT). Com isso, os resultados demonstraram a eficácia do modelo, superando os outros modelos com lucros maiores, mais confiáveis e índices mais precisos. O algoritmo TFJ-DRL alcançou um Índice Sharpe médio de 0,75.

3.3. TDQN

O trabalho de Théate e Ernst (2021) trata a respeito de uma aplicação de aprendizado por reforço profundo que deve indicar um ponto de compra e venda ideal durante uma atividade de negociação algorítmica no mercado de ações. Para avaliar o desempenho deste algoritmo, faz-se uso de um conjunto limitado de dados históricos financeiros para treinamento do agente por meio de aprendizado profundo.

O trabalho utilizou como métrica para medir desempenho os indicadores: Índice Sharpe (IS), Índice Sortino (ISOR), Lucros e Perdas (LP), Razão de Lucros e Perdas (RLP), Retorno Anualizado (RA), Volatilidade Anualizada (VA), Lucratividade (L), Rebaixamento Máximo (RM) e Duração de Rebaixamento Máximo (DRM). O algoritmo *Deep Q-Network* (DQN) foi adaptado ao problema mencionado acima, resultando no algoritmo *Trading Deep Q-Network* (TDQN). Esse passou por uma avaliação de performance, e mostrou resultados superiores em comparação com outros algoritmos, obtendo 0,404 de Índice Sharpe médio.

3.4. Análise Comparativa

A tabela 3 demonstra uma análise comparativa entre os trabalhos relacionados e o trabalho proposto. Todos os três autores utilizam o algoritmo DQN como base, porém realizam algumas modificações e tornam o algoritmo adaptado para atender as suas necessidades. Importante ressaltar que o autor Théate e Ernst (2021) disponibiliza o código Theate (2022) do algoritmo TDQN, e que o mesmo foi utilizado para o trabalho proposto. Referente ao item comparativo de período de dados, quantidade de ações e algoritmos de negociação, assim como Théate e Ernst (2021), foram coletados neste trabalho 8 anos de dados para treinamento e teste, 30 ações e os seguintes algoritmos B&H, S&H, TF, MR, TDQN.

Outro ponto relevante é em relação aos indicadores de desempenho utilizados, onde o índice Sharpe é o único que aparece em todos os trabalhos, tal qual os algoritmos de negociação, em que a estratégia *Buy and Hold* (B&H) se repete. Vale pontuar o diferencial do trabalho proposto que executou todos os seus experimentos com ações da bolsa brasileira, enquanto que os demais trabalhos realizaram seus experimentos com dados das bolsas estrangeiras como bolsas da Europa, da Ásia, da China e dos Estados Unidos da América.

Tabela 3. Análise comparativa dos trabalhos correlatos

Itens comparativos	Li et al. 2019	Lei et al. 2020	Théate and Ernst 2021	Trabalho proposto
Algoritmo	Base: DQN Adaptado: DQN estendido e A3C estendido	Base: DQN Adaptado: TFJ-DRL	Base: DQN Adaptado: TDQN	Base: TDQN
Disponibilidade de código do algoritmo	Ambos não disponíveis	Ambos não disponíveis	DQN não disponível TDQN disponível	DQN não disponível TDQN disponível
Período dos dados	10 anos	20 anos	8 anos	8 anos
Quantidade de ações	5 ações	55 ações	30 ações	30 ações
País/Continente das ações	EUA, China	EUA	EUA, Europa e Ásia	Brasil
Algoritmos de negociação	B&H, DQN, A3C, DQN EXTEND, A3C EXTEND	B&H, SFM, RRL, DDR, GRU BASED DRL, TFJ-DRL	B&H, S&H, TF, MR, TDQN	B&H, S&H, TF, MR, TDQN
Indicadores de desempenho	IS e RA	IS, RA, L, TT	IS, ISOR, LP, RLP, RA, VA, L, RM, DRM	IS, ISOR, LP, RLP, RA, VA, L, RM, DRM

4. Metodologia

A Figura 1 traz o fluxograma das etapas da metodologia adotada. Esse processo é constituído por cinco fases. A primeira fase, identificação de algoritmos de negociação, tem como objetivo selecionar diferentes estratégias algorítmicas de negociação para análise das ações das bolsas de valores. A próxima fase, seleção de indicadores de desempenho, visa identificar as métricas que devem ser utilizadas para avaliar os algoritmos. Em seguida, a fase de obtenção dos dados busca coletar os dados de um determinado período da bolsa de valores e armazená-los. Posteriormente, a fase de treinamento e teste, visa treinar e testar os algoritmos de negociação com os dados coletados, gerando assim os resultados. Por fim, a fase de análise tem como objetivo avaliar os resultados obtidos nos experimentos realizados com os indicadores e algoritmos de negociação. Destaca-se que houve uma interação entre as etapas de treinamento e teste e a etapa de análise, onde a partir da análise dos resultados, um novo treinamento e teste era realizado com ajustes em alguns parâmetros. A seguir cada etapa é explicada nas próximas subseções, exceto a fase de análise, que é descrita na Seção 5.

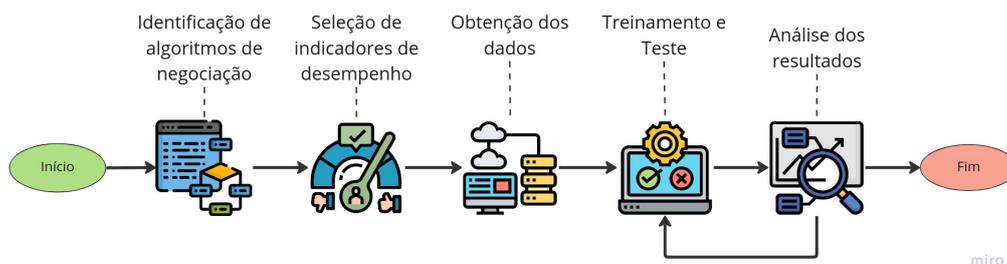


Figura 1. Fluxo da metodologia

Fonte: Autora

4.1. Identificação de algoritmos de negociação

A fase de identificação de algoritmos de negociação tinha como objetivo selecionar e avaliar os algoritmos aos executar as ações, a fim de, encontrar aquele que possuísse a melhor relação de retorno sobre o risco. Os algoritmos de negociação que foram utilizados neste trabalho foram: *Buy and Hold*, *Sell and Hold*, *Trend Following*, *Mean Reversion* e TDQN, os quais são o estado da arte dentre as pesquisas realizadas e também foram utilizados por Théate e Ernst (2021).

4.2. Seleção de indicadores de desempenho

O objetivo dessa etapa foi selecionar as métricas que seriam utilizadas para avaliar e comparar os algoritmos de negociação. No contexto deste trabalho, os indicadores foram adaptados para avaliar os algoritmos, analisando os retornos das negociações realizadas na bolsa de valores brasileira pelos diferentes algoritmos. Os seguintes indicadores de desempenho foram selecionados e empregados neste trabalho: Índice Sharpe, Índice Sortino, Lucros e Perdas, Relação de Lucros e Perdas, Retorno Anualizado, Volatilidade Anualizada, Índice de Lucratividade, Rebaixamento Máximo e Duração de Rebaixamento Máximo, que são os mesmos utilizados por Théate e Ernst (2021).

4.3. Obtenção dos dados

Esta subseção tem como finalidade explicar como os dados foram coletados. A metodologia adotada neste trabalho é genérica para qualquer bolsa de valores, porém os experimentos foram realizados na bolsa de valores brasileira (B3), onde foram capturados e utilizados dados históricos diários de um período de oito anos, de 30 ações de empresas listadas na B3. Esse período de tempo, a quantidade de ações e a forma aleatória de escolha dessas ações, seguiu a metodologia de Théate e Ernst (2021).

Através da API *Google Finance* (FINANCE, 2022), conseguiu-se coletar os dados históricos do período de treino e teste, utilizando os comandos mostrados na Figura 2. Foi utilizada a função *GOOGLEFINANCE* composta pelos seguintes parâmetros:

1. código da bolsa de valores e código da ação;
2. atributos, onde nesse caso *ALL* inclui os seguintes atributos:
 - (a) *open* - O preço de abertura nas datas especificadas;
 - (b) *close* - O preço de fechamento nas datas especificadas;
 - (c) *high* - O preço da alta nas datas especificadas;
 - (d) *low* - O preço da baixa nas datas especificadas;
 - (e) *volume* - O volume nas datas especificadas;
3. data inicial e data final para busca dos dados históricos.

Com o propósito de produzir conclusões confiáveis, os treinamentos e os testes deste trabalho foram realizados com uma base de dados composta por 30 ações com características diversas (volatilidade, liquidez), de 9 setores e 15 segmentos diferentes, como pode ser observado na Tabela 4. Essa tabela apresenta o setor, o segmento, o nome e o código das ações.

Treinamento

```
fx | =GOOGLEFINANCE("BVMF:ENGI11";"ALL"; "01/01/2012"; "31/12/2017")
```

Teste

```
fx | =GOOGLEFINANCE("BVMF:ENGI11";"ALL"; "01/01/2018"; "31/12/2019")
```

Figura 2. Comandos para extração de dados

Fonte: Autora

Tabela 4. Características das ações utilizadas

Setor	Segmento	Nome	Código
Bens Industriais	Material de Transporte	MARCOPOLO	POMO3
Bens Industriais	Transporte	AZUL	AZUL4
Bens Industriais	Transporte	GOL	GOLL4
Consumo Cíclico	Automóveis e Motocicletas	IOCHP-MAXION	MYPK
Consumo Cíclico	Automóveis e Motocicletas	METAL LEVE	LEVE
Consumo Cíclico	Comércio	AMERICANAS	AMER3
Consumo Cíclico	Comércio	AREZZO	ARZZ3
Consumo Cíclico	Comércio	LOJAS RENNER	LREN3
Consumo Cíclico	Comércio	MAGAZLUIZA	MGLU3
Consumo Cíclico	Tecidos. Vestuário e Calçados	TECHNOS	TECN3
Consumo Cíclico	Viagens e Lazer	CVC BRASIL	CVCB3
Consumo não Cíclico	Agropecuária	SLCAGRICOLA	SLCE3
Consumo não Cíclico	Alimentos Processados	CAMIL	CAML
Consumo não Cíclico	Alimentos Processados	JBS	JBSS3
Consumo não Cíclico	Alimentos Processados	M.DIASBRANCO	MDIA
Consumo não Cíclico	Alimentos Processados	MINERVA	BEEF
Consumo não Cíclico	Comércio e Distribuição	CARREFEUR	CRFB3
Financeiro	Intermediários Financeiros	BRASIL	BBAS
Financeiro	Intermediários Financeiros	BTGP BANCO	BPAC
Materiais Básicos	Siderurgia e Metalurgia	GERDAU	GGBR3
Materiais Básicos	Siderurgia e Metalurgia	USIMINAS	USIM3
Petróleo, Gás e Biocombustíveis	Petróleo, Gás e Biocombustíveis	COSAN	CSAN
Petróleo, Gás e Biocombustíveis	Petróleo, Gás e Biocombustíveis	PETROBRAS	PETR
Saúde	Comércio e Distribuição	RAIADROGASIL	RADL
Saúde	Medicamentos e Outros Produtos	OUROFINO	OFSA3
Tecnologia da Informação	Programas e Serviços	TOTVS	TOTS
Tecnologia da Informação	Programas e Serviços	SINQIA	SQIA
Utilidade Pública	Energia Elétrica	CPFL	CPFE3
Utilidade Pública	Energia Elétrica	ELETROBRAS	ELET
Utilidade Pública	Energia Elétrica	ENERGISA	ENGI11

4.4. Treinamento e teste

O objetivo dessa etapa é realizar o treinamento dos algoritmos bem como o teste, a fim de criar um modelo capaz de recomendar negociações na bolsa de valores. Para treinar e testar todos os algoritmos selecionados foi utilizado o código disponível em Theate

(2022) e também o período de oito anos de dados históricos. O horizonte de negociação de oito anos é dividido em conjuntos de treinamento e teste como é especificado abaixo e indicado na Figura 3 onde, 75% dos dados históricos coletados foram utilizados para treinamento dos algoritmos de negociação e 25% dos dados foram utilizados para teste dos algoritmos:

- Conjunto de treinamento: 01/01/2012 → 31/12/2017.
- Conjunto de teste: 01/01/2018 → 31/12/2019

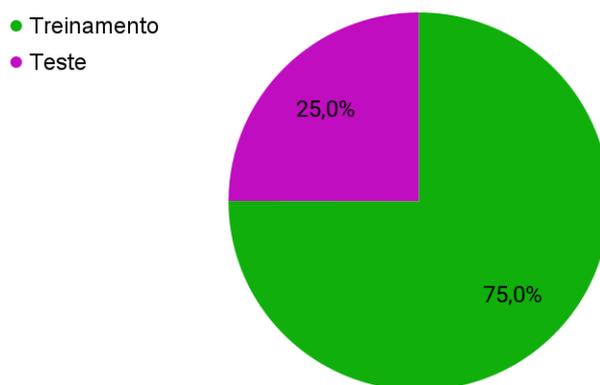


Figura 3. Conjunto de dados de treinamento e teste

Fonte: Autora

Além disso, fez-se uso dos seguintes parâmetros: o valor inicial para investimento de R\$ 100.000,00 para todos os algoritmos, um total de 50 episódios para o algoritmo TDQN, e custo de transação de 0,1% para todos os algoritmos. Foi utilizada a mesma taxa livre de risco de Théate e Ernst (2021) que foi a taxa padrão igual a 0.

Para utilizar os algoritmos foi necessário uma organização dos dados que incluía baixar as planilhas geradas em formato CSV a partir dos comandos do *Google Finance*, modificar o nome da coluna *Date* para *Timestamp*, devido ao padrão adotado no algoritmo e substituir em todas as colunas a vírgula (,) por ponto (.), pois o delimitador entre as colunas é a vírgula. Os algoritmos fazem a leitura dos dados dos arquivos salvos na pasta *Data*, portanto as planilhas transformadas necessitam estar armazenadas nessa pasta. Outra pasta importante é a *Figures* que deve ser criada para que os algoritmos consigam salvar as figuras geradas.

É necessário incluir no código do algoritmo as ações selecionadas, contendo o nome e o respectivo código da ação, na lista *stocks* e *companies* do arquivo *tradingSimulator.py*, além disso, na lista *indices* também do arquivo *tradingSimulator.py* deve ser incluído o mercado financeiro utilizado, nesse caso a bolsa de valores brasileira (B3). Após os ajustes necessários os dados estão adequados ao formato utilizado pelos algoritmos, não necessitando mais nenhum processamento adicional.

A Figura 4 demonstra a linha de comando utilizada para realizar o treinamento e teste dos algoritmos. É necessário informar na linha de comando o código do algoritmo (BuyandHold, SellandHold, TFMA, MRMA ou TDQN) e o nome da ação (conforme Tabela 4) para a execução. Por exemplo, o código da Figura 4 treina e testa o algoritmo TDQN para a ação Energisa.

```
dianabraatz@dianabraatz-Vostro-14-5480:~/Drible$ python3
main.py -strategy TDQN -stock energisa
```

Figura 4. Comando para execução do treinamento e teste dos algoritmos

Fonte: Autora

5. Resultados e discussão

A finalidade desta seção é apresentar e discutir os resultados obtidos a partir da análise dos algoritmos de negociação. O primeiro experimento demonstra uma análise global dos algoritmos por meio do indicador de desempenho índice Sharpe. Em seguida, foram selecionadas ações com o maior e menor índice Sharpe para o algoritmo TDQN a fim de analisar os resultados desse algoritmo. Possibilitou-se também comparar os resultados entre a bolsa brasileira e as bolsas estrangeiras. O algoritmo TDQN foi escolhido e mais utilizado nos experimentos por ser o estado da arte, resultado das pesquisas realizadas.

5.1. Resultados Globais

Este experimento teve como propósito analisar qual o algoritmo de negociação obteve o melhor desempenho de uma forma global para as trinta ações selecionadas. O indicador escolhido para essa análise foi o índice Sharpe, uma vez que esse é o indicador mais utilizado no campo da negociação por combinar lucratividade e risco, além de ser também utilizado por Théate e Ernst (2021).

A Tabela 5 apresenta os resultados do índice Sharpe nas ações escolhidas para os cinco algoritmos de negociação testados. Observa-se que o algoritmo que teve o maior índice Sharpe médio foi *Buy and Hold* com 0,830. Isso representa um ganho de 705,83% com relação ao segundo maior que foi o *Trend following*. Ressalta-se ainda que o TDQN alcançou um índice Sharpe médio negativo de -0,479, assim como o *Sell and Hold* com -0,463 e *Mean Reversion* com -0,233. Conforme Pactual (2022) e Morooka (2022), um fundo é considerado bom quando possui índice Sharpe acima de 0,5, pois o mercado entende que é uma ótima opção e que entregará resultados, ou seja, quanto maior o índice Sharpe, mais interessante será o retorno ajustado ao risco.

Analisando os resultados do algoritmo TDQN para cada ação, verifica-se que em 9 ações ele teve um índice Sharpe positivo, enquanto que em 21 ações ele teve um resultado negativo. Isso mostra que o algoritmo TDQN não obteve uma performance adequada devido aos casos de índice Sharpe negativo, que podem ser chamados de fundos "pobres", que geram perdas complementa Pactual (2022). Destaca-se que a ação Energisa obteve o maior índice Sharpe no algoritmo TDQN com 1,313 enquanto que a ação da Americanas teve o menor valor, com -2,201.

5.2. Maior resultado - Energisa

O objetivo deste experimento é analisar detalhadamente a performance da ação que alcançou o maior índice Sharpe para o algoritmo TDQN, a Energisa. Essa análise inclui todos os indicadores selecionados. Na Tabela 6, é demonstrado o desempenho alcançado pelos algoritmos para a ação Energisa.

Tabela 5. Performance dos algoritmos em relação ao índice Sharpe

Ação	<i>Buy and Hold</i>	<i>Sell and Hold</i>	<i>Trend following</i>	<i>Mean Reversion</i>	TDQN
Americanas	1,289	-0,856	-0,281	0,097	-2,201
Arezzo	0,428	-0,247	0,007	0,222	-1,969
Azul	1,078	-0,657	0,670	-1,011	0,535
Brasil	0,567	-0,280	0,627	-0,347	-1,410
BTGP Banco	1,823	-0,945	-0,336	-1,362	-1,250
Camil	0,421	-0,228	-1,450	-0,511	-0,913
Carrefour	0,980	-0,608	-0,574	-0,010	-0,972
Cosan	0,907	-1,099	-0,904	0,444	-1,720
CPFL	1,322	-1,046	-1,147	-0,994	-0,838
CVC Brasil	-0,113	0,452	-0,265	0,129	-0,147
Eletrobras	0,783	0,149	0,405	-0,949	-0,121
Energisa	1,306	-1,077	0,028	-0,697	1,313
Gerdau	0,591	-0,492	-0,154	-0,360	0,622
Gol	0,974	-0,915	0,565	-0,404	0,235
JBS	1,437	-1,148	0,402	0,451	-0,902
Lojas Renner	1,132	-0,970	0,524	0,901	-1,067
Magazine Luiza	2,081	-1,227	0,194	-0,153	-1,744
Marcopolo	0,707	-0,629	0,787	-0,061	1,021
Maxion	0,144	0,130	0,701	-0,547	-0,594
M Dias Branco	-0,497	0,893	-0,787	-0,163	-1,438
Metal Leve	0,456	-0,234	0,176	-0,377	-0,092
Minerva	0,598	-0,254	1,115	0,557	0,728
Ourofino	1,283	-0,471	0,237	-0,739	0,552
Petrobras	0,768	-0,150	-0,376	0,493	-0,208
Raia Drogasil	0,669	-0,651	-0,322	-0,009	-0,635
Sinqia	1,896	-1,282	1,983	-0,147	0,945
SLC Agricola	0,691	0,094	0,797	-0,444	-0,621
Technos	0,293	0,136	0,994	-0,664	0,827
Totvs	1,432	-1,106	-0,391	-0,504	-0,865
Usiminas	-0,550	0,817	-0,145	0,165	-1,440
Média	0,830	-0,463	0,103	-0,233	-0,479

Tabela 6. Desempenho dos algoritmos de negociação para a ação Energisa

Indicador de desempenho	<i>Buy and Hold</i>	<i>Sell and Hold</i>	<i>Trend following</i>	<i>Mean Reversion</i>	TDQN
Índice Sharpe	1,306	-1,077	0,028	-0,697	1,313
Índice Sortino	2,171	-1,508	0,046	-1,081	2,246
Lucros e Perdas \$	69.221	-69.421	-3.691	-30.570	69.823
Índice de Lucros e Perdas	inf	0,000	1,724	0,830	10,284
Retorno Anualizado %	25,66	-83,97	0,61	-17,18	25,80
Volatilidade Anualizada %	22,64	46,42	22,64	23,04	22,67
Lucratividade %	100,00	0,00	35,29	46,08	40,00
Rebaixamento Máximo %	20,26	72,97	28,39	41,67	20,35
Duração de Rebaixamento Máximo (dias)	99	331	116	284	94

O algoritmo TDQN teve um Retorno Anualizado que indica que em média cada ano teve 25,80% de ganho sobre o capital investido, e sua volatilidade anual chegou a

22,67% mostrando que o valor seguirá estável, sem oscilar muito para cima ou para baixo. Seu percentual máximo de queda (Rebaixamento Máximo) foi de 20,35% , ficando próximo ao percentual do algoritmo *Trend following* com 28,39% apontando que o preço seguirá constante, sem altas quedas. Contudo através do índice Sharpe, é possível observar que o risco oferecido pelo algoritmo *Trend following* é maior comparado ao algoritmo TDQN, com 0,028 e 1,313, respectivamente. Ou seja, apesar de não haver grandes quedas de preço, há um risco alto em relação ao retorno.

O algoritmo TDQN, alcançou o maior Índice Sortino com 2,246, por ser, assim como o índice Sharpe, um indicador que trata a respeito do risco em relação ao retorno, isso mostra que vale correr-se o risco, pois haverá retorno financeiro. Além disso, analisando o indicador de Lucratividade, percebe-se que o algoritmo TDQN obteve lucro em 40,00% das negociações, enquanto o *Buy and Hold* obteve lucro em todas as negociações. Porém, o lucro total obtido pelo TDQN foi maior, igual a R\$ 69.823,00 que é observado através do indicador de Lucros e Perdas, ficando na frente do algoritmo *Buy and Hold* com um lucro de R\$69.221,00. A estratégia TDQN atinge melhores resultados em comparação as demais estratégias, quando se trata dos indicadores de lucratividade versus risco e perdas.

5.3. Menor resultado - Americanas

O objetivo deste experimento é analisar detalhadamente a performance da ação que alcançou o menor índice Sharpe para o algoritmo TDQN, a Americanas. Essa análise inclui todos os indicadores selecionados. Na Tabela 7, é demonstrado o desempenho alcançado pelos algoritmos de negociação para a ação Americanas.

Tabela 7. Desempenho dos algoritmos de negociação para a ação Americanas

Indicador de desempenho	<i>Buy and Hold</i>	<i>Sell and Hold</i>	<i>Trend following</i>	<i>Mean Reversion</i>	TDQN
Índice Sharpe	1,289	-0,856	-0,281	0,097	-2,201
Índice Sortino	2,173	-1,081	-0,420	0,160	-3,239
Lucros e Perdas \$	182.278	-99.964	-41.512	-21.682	-91.578
Índice de Lucros e Perdas	inf	0,000	0,571	0,781	0,449
Retorno Anualizado %	51,75	-100,00	-15,22	5,60	-100,00
Volatilidade Anualizada %	51,45	205,16	51,00	60,82	51,38
Lucratividade %	100,00	0,00	52,17	52,54	29,23
Rebaixamento Máximo %	40,59	99,98	63,24	57,17	92,24
Duração de Rebaixamento Máximo (dias)	60	483	352	136	359

O desempenho médio anual (Retorno Anualizado) foi negativo 100%, o que indica perda sobre o investimento inicial, e sua volatilidade anual ficou maior se comparada com a ação Energisa, chegando a 51,38%, mostrando que o valor pode oscilar muito, movendo-se para cima e para baixo. Em relação a Energisa, o percentual máximo de queda também ficou elevado, atingindo 92,24% apontando que as perdas do investimento são altas. O algoritmo TDQN, alcançou o menor Índice Sharpe com -2,201 e o menor Índice Sortino com -3,239, por serem dois indicadores que tratam a respeito do risco em relação ao retorno, isso aponta que não faz sentido assumir esse nível de risco, para um ganho financeiro pequeno.

Analisando o indicador de Lucratividade, percebe-se que o algoritmo TDQN obteve prejuízo em 70,77% das negociações, enquanto o *Buy and Hold* obteve lucro em

todas as negociações. Com isso, o TDQN adquiriu uma perda de R\$ -91.578,00 que é observada através do indicador de Lucros e Perdas. Além do índice de Lucratividade estar baixo em relação aos demais algoritmos, segue sendo um percentual baixo de 29,23%, comparando o índice de lucratividade com os resultados da ação Energisa. Vale ressaltar que para a Americanas o algoritmo *Buy and Hold* conseguiu resultados mais promissores nos indicadores apresentados, de acordo com a definição individual de cada métrica, revelando que naquele período, o ideal era comprar e manter, aguardando a valorização dos preços.

5.4. Bolsa Brasileira X Bolsas Estrangeiras

Este experimento busca comparar o desempenho dos algoritmos de negociação entre as bolsas de valores estrangeiras e a bolsa de valores brasileira. Essa comparação analisa o índice Sharpe de todos os algoritmos de negociação selecionados. Os resultados para a bolsa brasileira foram obtidos por meio dos experimentos realizados neste trabalho. Os resultados das bolsas estrangeiras, foram extraídos do trabalho de Théate e Ernst (2021) que inclui ações de bolsas dos Estados Unidos, Europa e Ásia. Em ambos os casos, foram utilizadas 30 ações de diferentes setores e segmentos, sendo utilizado o período de 01/01/2012 a 31/12/2017 para treinamento e de 01/01/2018 a 31/12/2019 para teste.

Na tabela 8, é demonstrado o valor de índice Sharpe médio nos conjuntos de ações das bolsas de valores estrangeiras e na bolsa brasileira para todos os algoritmos de negociação. Pode-se observar que a bolsa brasileira alcançou resultado maior no algoritmo *Buy and Hold* com 0,830 de índice Sharpe, enquanto para as bolsas estrangeiras o algoritmo TDQN foi melhor, com índice Sharpe de 0,404. É importante frisar que os algoritmos *Buy and Hold* e *Trend Following* tiveram índice Sharpe positivo ao se tratar das ações brasileiras, enquanto que nas ações estrangeiras, os algoritmos com índice Sharpe positivo foram *Buy and Hold* e TDQN. Isso indica que para as ações brasileiras no período selecionado, era mais seguro comprar e manter, acompanhando a tendência dos preços e assim acumulando a valorização das ações. Vale ressaltar ainda que assim como as ações brasileiras, as ações dos Estados Unidos, Europa e Ásia tiveram resultados negativos para os algoritmos de negociação *Sell and Hold* e *Mean Reversion*.

Conforme mostra Oliveira e Máximo (2018), o dólar e a Bolsa de Valores Brasileira sofreram oscilações, motivadas por fatores internos e externos, como as eleições de outubro de 2018 e a guerra comercial entre Estados Unidos e China. Com isso, é possível compreender as diferenças entre os resultados obtidos para o índice Sharpe entre as bolsas de valores, pois essas oscilações retratam um risco para investir no período de treinamento e teste selecionado.

Tabela 8. Resultados dos algoritmos de negociação para as diferentes bolsas de valores usando o índice Sharpe

Bolsa de valores	<i>Buy and Hold</i>	<i>Sell and Hold</i>	<i>Trend following</i>	<i>Mean Reversion</i>	TDQN
EUA/Europa/Ásia	0,369	-0,202	-0,331	-0,056	0,404
Brasil	0,830	-0,463	0,103	-0,233	-0,479

6. Conclusão

Este trabalho teve a proposta de analisar diferentes algoritmos buscando a melhor estratégia que atenda ao problema de realizar uma negociação de compra ou venda de ações no mercado financeiro, sem que haja perda de tempo e dinheiro. Para tal finalidade foram testados e comparados 5 algoritmos de negociação, sendo eles: *Buy and Hold*, *Sell and Hold*, *Trend following*, *Mean Reversion* e TDQN. Os algoritmos foram analisados por meio de 9 indicadores de desempenho: Índice Sharpe, Índice Sortino, Lucros e Perdas, Relação de Lucros e Perdas, Retorno Anualizado, Volatilidade Anualizada, Índice de Lucratividade, Rebaixamento Máximo e Duração de Rebaixamento Máximo. Foram coletados dados de 8 anos para treinamento e teste, de 30 ações, divididas em 9 setores e 15 segmentos da Bolsa de Valores Brasileira (B3).

Com a análise global dos algoritmos para todas as ações sob o indicador índice Sharpe, o algoritmo *Buy and Hold* obteve o maior índice Sharpe médio, de 0,830, indicando a maior relação de retorno ajustado ao risco. É possível analisar que no período selecionado, as ações da bolsa de valores brasileira geraram maior resultado utilizando a estratégia de comprar e manter (B&H), a fim de obter o maior retorno do investimento.

Além disso, dentre as 30 ações para o algoritmo TDQN, foi possível selecionar a ação Energisa, com maior índice Sharpe igual a 1,313 e a ação Americanas, com menor índice Sharpe igual a -2,201. Outro experimento realizado foi a comparação dos resultados médios das bolsas de valores estrangeiras e brasileira para o índice Sharpe. Nesse experimento foi possível verificar que o algoritmo TDQN gerou um resultado maior para as ações das bolsas estrangeiras igual a 0,404, enquanto que para a bolsa brasileira a médias dos resultados ficou maior para o algoritmo *Buy and Hold* igual a 0,830.

Como indicação para trabalhos futuros, sugere-se a possibilidade de realização de mais experimentos com um período maior para treinamento e teste dos algoritmos. Alinhado a isso, pode-se também aumentar a quantidade de execução de cada ação para cada algoritmo, e ao final calcular a média dos resultados gerados, para um assertividade maior. Outra sugestão é analisar de forma individual todo o grupo de ações selecionado, da mesma forma que foi realizado com as ações Energisa e Americanas. Criar um sistema que utilize os algoritmos de negociação e faça a recomendação de compra ou venda para o usuário. Além disso, testar as ações com diferentes *episodes* para treinamento do TDQN. E por fim, analisar os resultados obtidos ao utilizar a taxa livre de risco Selic ou CDI.

Referências

- ALIDA. *Annualized Volatility: Definition Formula*. 2021. Disponível em: <<https://study.com/academy/lesson/annualized-volatility-definition-formula.html>>. Último acesso em: 27/01/2023.
- ALMEIDA, M. S. Introdução à negociação de alta frequência. *Cadernos do Mercado de Valores Mobiliários*, 2016.
- CAPES. *Metodologia do Qualis Referência - Quadriênio 2017-2020*. 2023. Disponível em: <<https://www.gov.br/capes/pt-br/aceso-a-informacao/acoes-e-programas/avaliacao/avaliacao-quadrienal/metodologia-do-qualis-referencia-quadriennio-2017-2020>>. Último acesso em: 10/02/2023.

CARVALHO, A. M.; BARBOZA, F.; FIORUCCI, J. A. Um algoritmo de negociação automatizado baseado em uma análise gráfica, pode apresentar um bom resultado? *REVISTA ENIAC PESQUISA*, v. 9, n. 1, p. 129–150, 2020.

CHEN, J. *Annualized Total Return Formula and Calculation*. 2021. Disponível em: <<https://investopedia.com/terms/a/annualized-total-return.asp>>. Último acesso em: 27/01/2023.

FERNANDO, J. *Profit and Loss Statement Meaning, Importance, Types, and Examples*. 2022. Disponível em: <<https://www.investopedia.com/terms/p/plstatement.asp>>. Último acesso em: 26/01/2023.

FERRARI, H. *Número de investidores na B3 sobe para 5,8 milhões em 2022*. 2023. Disponível em: <<https://www.poder360.com.br/economia/numero-de-investidores-na-b3-sobe-para-58-milhoes-em-2022/>>. Último acesso em: 15/01/2023.

FINANCE, G. *Google Finance*. 2022. Disponível em: <<https://www.google.com/finance/>>. Último acesso em: 17/03/2022.

FXPRO. *Profit and Loss Ratio*. 2023. Disponível em: <<https://www.fxpro.com/help-section/traders-glossary/profit-and-loss-p-l>>. Último acesso em: 26/01/2023.

G1. *Empresa incubada na UFU usa a inteligência artificial para fazer previsões financeiras*. 2022. Disponível em: <<https://g1.globo.com/mg/triangulo-mineiro/noticia/2022/02/13/empresa-incubada-na-ufu-usa-a-inteligencia-artificial-para-fazer-previsoes-financeiras.ghtml>>. Último acesso em: 13/02/2022.

GIRÃO, L. F. de A. P. *Índice de Sortino em Billions: volatilidade é ruim?* 2018. Disponível em: <<https://www.contabilidadeemq.com.br/2018/06/indice-de-sortino-ratio-billions.html>>. Último acesso em: 16/01/2023.

GÉRON, A. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow - Conceito, Ferramentas e Técnicas para a Construção de Sistemas Inteligentes*. Rio de Janeiro: Alta Books Editora, 2019.

HAYES, A. *Maximum Drawdown (MDD) Defined, With Formula for Calculation*. 2022. Disponível em: <<https://www.investopedia.com/terms/m/maximum-drawdown-mdd.asp>>. Último acesso em: 27/01/2023.

HORTON, M. *What difference between profitability and profit*. 2021. Disponível em: <<https://www.investopedia.com/ask/answers/012715/what-difference-between-profitability-and-profit.asp>>. Último acesso em: 18/02/2023.

INVESTIDORA. *Entendendo o mercado de valores*. 2022. Disponível em: <https://www.investidor.gov.br/menu/primeiros_passos/Entendendo_mercado_valores.html>. Último acesso em: 17/03/2022.

ISMAR, B. *Trend following: conheça essa estratégia*. 2021. Disponível em: <<https://renovainvest.com.br/blog/trend-following-conheca-a-estrategia-baseada-em-seguir-uma-tendencia/>>. Último acesso em: 19/02/2023.

ISMAR, B. *Índice Sharpe: o que é e como funciona esse índice?* 2022. Disponível em: <<https://renovainvest.com.br/blog/indice-sharpe-o-que-e-e-como-funciona-esse-indice/>>. Último acesso em: 26/01/2023.

- KENTON, W. *Sortino Ratio: Definition, Formula, Calculation, and Example*. 2020. Disponível em: <<https://www.investopedia.com/terms/s/sortinoratio.asp>>. Último acesso em: 26/01/2023.
- KENTON, W. *Profit/Loss Ratio Definition, Formula, How It Works*. 2021. Disponível em: <https://www.investopedia.com/terms/p/profit_loss_ratio.asp>. Último acesso em: 26/01/2023.
- LEI, K. et al. Time-driven feature-aware jointly deep reinforcement learning for financial signal representation and algorithmic trading. *Expert Systems with Applications*, v. 140, p. 112872, 2020. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417419305822>>.
- LI, Y.; ZHENG, W.; ZHENG, Z. Deep robust reinforcement learning for practical algorithmic trading. *IEEE Access*, v. 7, p. 108014–108022, 2019.
- MARKETS, C. *Mean reversion*. 2023. Disponível em: <<https://www.cmcmarkets.com/en-gb/trading-guides/mean-reversion>>. Último acesso em: 19/02/2023.
- MAVERICK, J. *The Difference Between the Sharpe Ratio and the Sortino Ratio*. 2021. Disponível em: <<https://www.investopedia.com/ask/answers/010815/what-difference-between-sharpe-ratio-and-sortino-ratio.asp>>. Último acesso em: 20/01/2023.
- MOROOKA, T. *Conheça os fundos de ações com índice de Sharpe elevado e que remuneram bem seus cotistas*. 2022. Disponível em: <<https://maisretorno.com/portal/conheca-os-fundos-de-acoes-com-mais-risco-pelo-indice-de-sharpe-mas-que-remuneram-bem-seus-cotistas-de-10-a-20-em-marco>>. Último acesso em: 25/01/2023.
- NEVES, R. J. T. Análise técnica ou buy and hold. *ISCAC - Dissertações de Mestrado*, 2019.
- OLIVEIRA, K.; MÁXIMO, W. *Retrospectiva 2018: veja fatos que marcaram a economia*. 2018. Disponível em: <<https://agenciabrasil.ebc.com.br/economia/noticia/2018-12/retrospectiva-2018-veja-fatos-que-marcaram-economia>>. Último acesso em: 20/02/2023.
- PACTUAL, B. *Índice de Sharpe: O que é e como impacta os seus investimentos?* 2022. Disponível em: <<https://www.btgpactualdigital.com/blog/coluna-gustavo-cerbasi/indice-de-sharpe-o-que-e-e-como-impacta-os-seus-investimentos/amp>>. Último acesso em: 25/01/2023.
- REIS, T. *Análise de indicadores: conheça a importância de levá-los em conta*. 2018. Disponível em: <<https://www.suno.com.br/artigos/analise-indicadores/>>. Último acesso em: 16/01/2023.
- REIS, T. *Conheça os fundos de ações com índice de Sharpe elevado e que remuneram bem seus cotistas*. 2019. Disponível em: <<https://www.suno.com.br/artigos/kpi/>>. Último acesso em: 16/01/2023.
- SCHOLAR, G. *Pesquisa de "deep learning" e "algorithmic trading"*. 2022. Disponível em: <https://scholar.google.com.br/scholar?hl=pt-BR&as_sdt=0%2C5&q=deep+learning+algorithmic+trading&btnG=>>. Último acesso em: 10/01/2022.
- SILVA, D. F. S. da. Investimento em ações com foco no longo prazo: buy and hold. jun. 2022.

SILVA, M. S. A. da. *Filtros de tendência em estratégias trend-following: uma aplicação a séries financeiras de mercados emergentes*. 2018.

SMARTER, S. *Profitability Ratio*. 2023. Disponível em: <<https://www.studysmarter.co.uk/explanations/business-studies/financial-performance/profitability-ratio/>>. Último acesso em: 27/01/2023.

SOUZA, S. *Brasil está próximo de 5 milhões de investidores na Bolsa; confira dicas para começar*. 2022. Disponível em: <<https://fdr.com.br/2022/01/13/brasil-esta-proximo-de-5-milhoes-de-investidores-na-bolsa-confira-dicas-para-comecar/>>. Último acesso em: 22/02/2022.

SRIVASTAV, A. K. *Volatility Formula*. 2023. Disponível em: <<https://www.wallstreetmojo.com/volatility-formula/>>. Último acesso em: 27/01/2023.

TEAM, C. *Annual Return*. 2022. Disponível em: <<https://corporatefinanceinstitute.com/resources/wealth-management/annual-return/>>. Último acesso em: 27/01/2023.

TEAM, C. *Annualized Total Return*. 2023. Disponível em: <<https://corporatefinanceinstitute.com/resources/wealth-management/annualized-total-return/>>. Último acesso em: 27/01/2023.

THEATE, T. *An-Application-of-Deep-Reinforcement-Learning-to-Algorithmic-Trading*. 2022. Disponível em: <<https://github.com/ThibautTheate/An-Application-of-Deep-Reinforcement-Learning-to-Algorithmic-Trading>>. Último acesso em: 17/03/2022.

THÉATE, T.; ERNST, D. An application of deep reinforcement learning to algorithmic trading. *Expert Systems with Applications*, v. 173, p. 114632, 2021. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417421000737>>.

WRITERS, S. *What's the difference between Long and Short Positions?* 2022. Disponível em: <<https://skilling.com/row/en/blog/trading-articles/what-is-the-difference-between-long-and-short-positions/>>. Último acesso em: 07/03/2023.

ZAP. *Humanos vs. Inteligência Artificial: Quem é melhor a ganhar dinheiro nos mercados financeiros?* 2022. Disponível em: <<https://zap.aeiou.pt/humanos-vs-ia-ganhar-dinheiro-460690>>. Último acesso em: 05/02/2022.