

Comparative Study of Predictive Models Based on Moving Averages Applied in Binary Options in the Financial Market

Análise Comparativa de Modelos Preditivos Utilizando Médias Móveis em Opções Binárias no Mercado Financeiro

Luccas R. Hoff¹, Rafael A. Berri¹, Eduardo N. Borges¹, André Riker², Bruno L. Dalmazo^{1*}

Resumo: The technological market has been through significant advances in the last few years, and its application in different markets and business lines was driven by the COVID-19 pandemic. In this context, given the global economic crisis that was generated, some ways of earning money online were popularized, including the Binary Options market, which promises high gains but represents a volatile and risky financial niche. The aim is to evaluate the efficiency and assertiveness of these models applied in operations, in addition to analyzing the risks and possible returns. The aim is to provide a more in-depth understanding of the effectiveness of these models, considering the volatile and unpredictable characteristics of the Binary Options financial market. To achieve the proposed objective, different statistical models based on moving averages will be used to compare individual results and between possible combinations of the best classified. This study is expected to contribute to the understanding of the effectiveness of predictive models based on moving averages applied in Binary Options. The results obtained may offer valuable insights for investors and traders interested in this kind of negotiation, helping them to make informed decisions. Furthermore, this work is expected to stimulate the development of more accurate and efficient investment strategies, increasing the probability of success in financial markets. Finally, this study is expected to advance knowledge in the field of financial market forecasting, highlighting the importance of moving averages as a powerful predictive tool in Binary Options.

Keywords: Binary Options — Moving Average — Predictive Models — Financial Market

Resumo: O mercado tecnológico tem passado por avanços significativos nos últimos anos, e sua aplicação nos diferentes mercados e ramos empresariais foi impulsionada pela pandemia do COVID-19. Nesse contexto, dada a crise econômica mundial que foi gerada, foram popularizadas algumas formas de fazer renda extra online, incluindo o mercado de Opções Binárias (OB), que promete altos ganhos, mas representa um nicho financeiro volátil e arriscado que oculta muitos riscos. O objetivo geral deste trabalho é realizar um estudo comparativo entre modelos preditivos baseados em médias móveis aplicados em Opções Binárias. Busca-se avaliar a eficiência e assertividade desses modelos aplicados nas operações, além de analisar quais os riscos e possíveis retornos. O intuito é fornecer uma compreensão mais aprofundada da eficácia desses modelos, considerando as características voláteis e imprevisíveis do mercado financeiro de Opções Binárias. Para atingir o objetivo proposto, serão utilizados diferentes modelos estatísticos baseados em médias móveis para comparar resultados individuais e entre possíveis combinações das melhores classificadas. Os resultados obtidos poderão oferecer insights valiosos para investidores e traders interessados nesse tipo de negociação, auxiliando-os na tomada de decisões informadas. Além disso, espera-se que este trabalho estimule o desenvolvimento de estratégias de investimento mais precisas e eficientes, aumentando a probabilidade de sucesso nos mercados financeiros. Por fim, espera-se que este estudo avance o conhecimento na área de previsão de mercado financeiro, destacando a importância das médias móveis como uma ferramenta preditiva em Opções Binárias.

Palavras-Chave: Opções Binárias — Médias Móveis — Modelos Preditivos — Mercado Financeiro

¹ Centro de Ciências Computacionais (C3), Universidade Federal do Rio Grande (FURG), Rio Grande, Rio Grande do Sul, Brasil

² Instituto de Ciências Exatas e Naturais (ICEN), Universidade Federal do Pará (UFPA), Belém, Pará, Brasil

*Corresponding author: dalmazo@furg.br

DOI: <https://doi.org/10.22456/2175-2745.139523> • Received: 05/04/2024 • Accepted: 30/06/2024

CC BY-NC-ND 4.0 - This work is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License.

1. Introdução

A tecnologia em torno da ciência de dados é complexa e presente em praticamente todos serviços e ramos existentes, e tem apresentado uma grande evolução nos últimos anos. De acordo com Prof. Salles, a pandemia da Covid-19 acelerou o processo de transformação digital das empresas no Brasil [1], isso se deve ao fato desses negócios sentirem a necessidade de reestruturar a forma de comunicação, compras e vendas, de forma que não deixassem de movimentar seu mercado. Porém, junto à esse marco tecnológico, o Brasil entrou em uma crise econômica [2], e em virtude deste período de dificuldade financeiro e de isolamento social, diversas propagandas divulgaram maneiras de obter renda informal e totalmente online, dando popularidade a áreas como marketing digital, dropshipping, investimentos, apostas e day trade.

Baseado nesse cenário proveniente das consequências da Pandemia do COVID-19, um das promessas mais populares de renda extra foi o de mercado de Opções Binárias (OB). No entanto, Opções Binárias fazem parte de um mercado financeiro baseado em análise gráfica, que para fins de investimento, representam um nicho altamente arriscado, completamente volátil e de complexa previsibilidade [3].

Na literatura, existem artigos no âmbito de estudos e estratégias de predição para prever movimentações do mercado financeiro, focados em análise gráfica, aprendizado de máquina e padrões comportamentais do mercado. Alguns deles, podem ser relacionados com o foco deste artigo, por possuírem objetivos em comum, como é feito no artigo descrito por Singh, Thapliyal e Barthwal [4], que realiza uma análise comparativa entre os modelos lineares e não-lineares, analisando o comportamento gráfico através de indicadores e através da inteligência artificial. No entanto, nenhum destes realiza um comparativo entre modelos estatísticos baseados em médias móveis, aplicados às Opções Binárias.

Dado esse contexto, este trabalho tem por objetivo realizar um estudo comparativo entre modelos preditivos baseados em médias móveis aplicado às Opções Binárias, avaliando quais tipos de médias se destacam, avaliando sua eficiência e a relação entre os riscos e retornos. Reconhecemos que existem diversos fatores micro e macroeconômicos que influenciam o mercado financeiro e que não podem ser capturados por esta classe de modelo preditivo. A inclusão desses fatores em uma análise multivariada certamente aumentaria a precisão dos modelos preditivos; no entanto, tal análise não está no escopo deste trabalho.

O restante deste trabalho está organizado da seguinte forma. A seção 2 apresenta uma revisão sistemática, mapeando artigos no âmbito do projeto e depois apresentados através dos resultados da revisão. A seção 3 apresenta a proposta do atual trabalho, demonstrando o Modelo Conceitual e detalhes de Implementação. Por fim, a seção 4 mostram os cenários avaliados, discutindo os resultados, enquanto a seção 5 fecha o artigo com as considerações finais e direções futuras.

2. Trabalhos Relacionados

Nessa seção foi elaborada uma revisão sistemática com intuito de mapear artigos existentes que abordam o tema sobre formas de predição para os comportamentos do mercado financeiro no âmbito das Opções Binárias. Nesta seção, é apresentada a metodologia adotada nessa revisão, juntamente com uma breve discussão sobre a estratégia utilizada na análise destes trabalhos.

2.1 Metodologia de Seleção

A revisão sistemática tem como principal objetivo realizar a pesquisa de forma estruturada, avaliando de forma crítica e sintetizando estudos de pesquisa sobre determinado assunto, de maneira que facilite outros pesquisadores interessados, para que possam chegar aos mesmos resultados encontrados por este presente trabalho [5]. Esta revisão sistemática foi feita a partir de estratégias de pesquisa, composta por critérios de inclusão, exclusão, métodos de extração de dados e critérios qualitativos. O estudo focou em trabalhos relacionados que abordassem o tema de Predições para o mercado financeiro de Opções Binárias. Para essa pesquisa, foi utilizado o banco de dados IEEE Xplorer que permite realizar busca avançada de termos para encontrar publicações específicas. Nesse caso, foram utilizados os seguintes termos: "Prediction", "Forecast", "Pricing", "Moving Average" e "Stock Market", sendo utilizados os conectivos lógicos que constituem a busca, representada logo abaixo.

((("Abstract":Prediction) OR ("Abstract":Forecast) OR ("Abstract":Pricing)) AND ("Abstract":Moving Average)) AND ("Abstract":Stock Market)))

Foram obtidos 70 resultados a partir da busca realizada em 13 de Maio de 2023, então foram aplicados os critérios de inclusão (IC) e de exclusão (EC), para filtrar os resultados. Na tabela 1, é possível visualizar quais foram os critérios adotados de inclusão e exclusão, sendo um artigo candidato à Inclusão caso sua data de publicação tenha sido entre 2020-2023, enquanto os artigo candidatos à exclusão são representados por aqueles artigos que não fazem parte do contexto de métodos de predição em análises gráficas no mercado financeiro. Ou seja, para ser um artigo candidato à inclusão, deve satisfazer aos critérios de IC e não ser contemplado por nenhum EC, que são representados por artigos fora do contexto do presente artigo. Por fim, foram obtidos 36 artigos, dos quais por critérios de adequação ao tema (EC1), foram por fim selecionados 20 artigos. Pode-se observar esses dados, na Tabela 2.

2.2 Análise da Revisão Sistemática

Como dito anteriormente, foram obtidos 20 artigos como resultado final, que representam a busca por termos realizada com base nos critérios de inclusão e exclusão. Em sua grande maioria, estes artigos apresentam tópicos referentes à padrões e estratégias de predição para as movimentações

Critério de Inclusão	
IC1	Artigos Publicados entre 2020-2024
Critério de Exclusão	
EC1	Artigos fora do contexto de métodos de predição em análises gráficas do mercado financeiro

Tabela 1. Critério de Inclusão e Exclusão

Resultados	Total
Busca no IEE Xplore	70
Não Satisfeitos pelo IC1	34
Artigos Candidatos	36
Excluídas pelo EC1	16
Artigos Finais Selecionados	20

Tabela 2. Resultados Finais

de mercado. Cada trabalho apresenta um diferente estudo ou solução para prever o comportamento gráfico, utilizando diferentes estratégias, indicadores e análises de Trade. Alguns apresentam estudos exclusivos para o mercado de Criptomoe-das, mas que por tratar-se de Trade baseado em análise gráfica, ainda assim é aproveitado para o mercado de Opções Binárias.

Lindsay et al. [6] propõem um estudo sobre a utilização de um modelo de médias móveis autoregressivo não-linear com entradas exógenas (NARMAX) diante do mercado de ações, com intuito de prever movimentações de mercado. Para isso, foram analisados dados do mercado de ações referentes ao período de 2009 a 2019. Os resultados obtidos revelaram que o modelo NARMAX tem forte potencial para prever preços no dia seguinte e pode ser comparado com técnicas existentes para previsão de preços no mercado de ações, pois a avaliação de desempenho demonstra que esse modelo é eficiente na previsão do preço de fechamento do mercado de ações.

Wiiava, Fatichah e Saikhu [7], realizaram em seu artigo um estudo para melhorar as análises técnicas de predição do mercado de ações. Os autores afirmam que geralmente se utiliza indicadores para análise técnica, bem como estocástico, médias móveis, média móvel de convergência e divergência e valores de índice de força relativa, que no entanto na maioria dos casos, sua utilização representa redução na precisão das previsões por serem aplicados diretamente sem transformação, não se tornando indicadores úteis. Com isso, recomenda-se usar os padrões gráficos “cruz de ouro” e a “cruz da morte” em indicadores de análise técnica como gatilhos para melhorar as previsões de preço das ações. Sendo sugerida também a memória de longo prazo no método proposto, que representa um método confiável para prever dados de sequência.

O trabalho de Harish et al [8], consiste em analisar uma forma diferente de métodos de predição que analisam um histórico específico de mercado, como “A Teoria Dow”, “MACD”, “o Índice de Força Relativa (RSI)”, “a Média Móvel Exponencial” e outros. Isso devido ao fato que essas estratégias não apresentaram resultados promissores, enquanto outras não reagiram tão bem na bolsa de valores, devido à estrutura não linear dos sinais do mercado de ações. Com base

nesses problemas, surge o modelo Profeta, que é confiável e gera descobertas com o mínimo de dados. Refere-se ao método de previsão de dados de séries temporais com base em um modelo aditivo com tendências não lineares adequadas aos impactos de feriados, sazonalidade diária, semanal e anual. Este método ainda é considerado resiliente a dados ausentes e hábil para lidar com valores discrepantes. O Facebook foi quem disponibilizou o profeta, um pacote Python de código aberto. As previsões dos preços das ações são mostradas por indicadores como RSI, MACD, Super Trend e outros.

Seguindo a mesma ideia de artigo, Kumar e Chaudhry [9] também realizaram um estudo comparativo entre modelos e métodos preditivos aplicados ao mercado de ações. Nessa oportunidade os autores realizam a comparação entre quatro técnicas de predição de dados, bem como: regressão linear, KNN (k-nearest neighbors), SVM (support vector machine) e ARIMA (Autoregressive Integrated Moving Average). Para isso, foi feita uma análise com base em dados reais do mercado de ações. Os dois parâmetros de desempenho, ou seja, erro e precisão de previsão de todas as quatro técnicas, foram comparados neste trabalho utilizando a linguagem de programação Python.

No estudo feito por Ashok et al. [10], é mostrado que os métodos de aprendizado de máquina podem produzir bons resultados ao realizar análises baseadas em estimativas. Neste artigo em específico, foi utilizada a representação de média móvel integrada auto regressiva (ARIMA), comprovando que esse modelo tem um perfil robusto para predição rápida baseada em período. No entanto, este trabalho também utiliza o modelo de predição de convenção de redes LSTM, que serviu de base para as comparações com modelos de estimação, passando por diversos testes e métricas que julgaram o funcionamento do algoritmo com intuito de encontrar o melhor modelo de previsão. Com isso, os resultados mostraram que o LSTM alcançou o melhor desempenho e projetou o mercado com precisão de 77%. Já o artigo feito por Singh, Thapliyal e Barthwal [4], foi realizado um estudo comparativo entre o modelo não linear, por sua vez baseado em inteligência artificial, RNN (redes neurais de recorrência). Como resultado foi analisado que, quando se trata de previsão de preços de ações, a média móvel exponencial supera o LSTM.

Dinesh et al. [11] propôs um estudo sobre predição das movimentações do mercado financeiro, com base em Médias Móveis utilizando técnicas de Machine Learning neste indicador técnico. O modelo proposto pelos autores surge para aplicar Regressão em médias móveis, visando reduzir a latência do sinal de negociação, fazendo então que supere sua desvantagem. Isso devido ao fato que as Médias Móveis apesar de

representarem um indicador de tendência, também é um indicador de atraso. Portanto, este modelo pode prever a reversão da tendência ao realizar a predição do sinal de negociação dado pelas médias móveis.

No trabalho escrito por Caldera e Lavanya [12], foi feita uma pesquisa sobre o efeito combinatório de vários indicadores técnicos para analisar e prever o mercado de ações. Nesta ocasião foram utilizados onze indicadores técnicos, sendo combinados com diversas formas de prever se o preço de fechamento do dia aumentaria ou diminuiria, ignorando as combinações que dão mais diferença entre o preço de fechamento. Como conclusão desse artigo, foi destacada a seguinte combinação entre as estratégias: “14-days Standard Deviation”, “20-days Chaikin Money Flow Indicator” junto com “14-days Simple Moving Average”, “14-days Bollinger Band”, “14-days Upper Band”, “14-days Lower Band”, “Average Price”, “14-days Exponential Moving Average”. Concluindo que esta combinação foi considerada a melhor, apresentando maior assertividade nas predições.

Partindo para a área de predição com foco em modelos com aprendizado de máquina, Kumar et al. [13] cita vários modelos, como: Support Auto Regressive Integrated Moving Average (ARIMA), Vector Machine (SVM), Artificial Neural Network (ANN), XGBoost e Recurrent Neural Network (RNN), que são amplamente utilizados para estudos preditivos. No entanto, este estudo apresenta o modelo de Deep Learning “Stacked Long Short-Term Memory” (LSTM) com intuito de prever a precisão do mercado de ações e o modelo proposto é comparado com os modelos Moving Average (MA) e XGBoost. Para isso, as comparações de eficiência são realizadas com base no conjunto de dados históricos da Infosys Limited da Bolsa de Valores de Bombaim, Índia (BSE30). Por fim, o modelo também foi avaliado por meio de medidas de desempenho Root Mean Square Error (RMSE) e Mean Absolute Percentage Error (MAPE) e foi possível concluir que o modelo LSTM proposto superou os demais. Enquanto Biswas et al. [14] apresentou um estudo comparativo entre os seguintes algoritmos: Long Short Term Memory, Extreme Gradient Boosting (XGBoost), Linear Regression, Moving Average e Last Value model, aplicados com base em mais de doze meses de dados históricos de ações para construir um modelo de previsão para prever o preço das ações.

O artigo publicado no “Journal of Management Mathematics” escrito por Kouaissah et al. [15], apresenta fundamentos teóricos para o uso de médias móveis no mercado de ações. Ele investiga a probabilidade condicional de aumentos de preço e como essa probabilidade varia ao longo do tempo. Sob certas suposições, é comprovado que a probabilidade de estar em uma tendência de alta é maior do que a probabilidade de estar em uma tendência de baixa. Essa demonstração parcialmente justifica o uso comum das regras de média móvel no mercado de ações. Além disso, é proposta uma análise empírica para avaliar e comparar o desempenho de várias regras de média móvel e outras estratégias de portfólio no mercado de ações dos EUA. Dentro desse contexto, uma meto-

dologia é sugerida para incorporar essas regras de negociação como regras de alarme para prever possíveis falhas no mercado. Os resultados obtidos confirmam as vantagens do uso dessas regras de negociação para prever tendências e crises no mercado de ações.

No trabalho de Agarwal, Rajput e Jena [16], aparecem algumas estruturas de predição como ARIMA (Auto Regressive-Integrated-Moving Average), FLANN (Functional Link Artificial Neural Network), modelos ELM (Extreme Learning Machine) e o otimizador Gray Wolf para previsão de preços de ações. Para fins avaliativos desses métodos, foram considerados os desempenhos das previsões de curto e longo prazo de ambos os modelos, e avaliados com dados de teste e comparativos de erros minimizados das previsões. Os autores desenvolveram um modelo híbrido usando o modelo ELM e o Gray Wolf Optimizer, que pode ser usado para alterar os pesos e o número de camadas do modelo ELM para aumentar sua precisão e fornecer resultados ótimos que são melhores quando comparados aos anteriores modelos.

Com base no artigo escrito por Rajeswari et al. [17], é possível destacar que foram estudados modelos de predição baseados em aprendizado de máquina, bem como Rede Neural Artificial (ANN), Média Móvel Integrada Auto Regressiva (ARIMA), Regressão Linear (LR), Floresta Aleatória (RF). Entre estes modelos, criou-se a tentativa de encontrar um que possa ser usado para previsão de preços de ações de curto prazo. A comparação dos resultados de vários algoritmos revela um algoritmo que ajudará os traders a maximizar seus lucros. Como conclusão os autores ainda mostram uma análise de séries temporais usando ARIMA que fornece resultados mais precisos do que outros modelos para previsão de preços de ações de curto prazo.

De acordo com o artigo publicado por Hossain, Ismail e Karim [18], este estudo apresenta um resultado da busca por métodos de previsão mais eficientes. A pesquisa se concentra no uso eficaz da estratégia de Divisão-e-Conquista por meio da Decomposição do Modo Empírico (EMD, na sigla em inglês). São utilizados dois métodos estatísticos diferentes, ARIMA (Média Móvel Integrada Autoregressiva) e EWMA (Média Móvel Exponencialmente Ponderada), para prever os componentes EMD de alta e baixa frequência. Dois métodos híbridos potenciais são investigados: EMD-ARIMA-EWMA e EMD-EWMA-ARIMA, baseados nos componentes de frequência alta e baixa. Foram realizados experimentos e comparados os resultados desses métodos com outros quatro métodos de previsão, usando os preços diários de fechamento do mercado de ações do índice S&P/TSX 60 da Bolsa de Valores de Toronto. O estudo constatou uma maior precisão de previsão no método EMD-ARIMA-EWMA em comparação com ARIMA, métodos baseados em EWMA e EMD-ARIMA, assim como nos métodos híbridos EMD-EWMA.

No artigo escrito por Mishra et al. [19], é destacada a influência das notícias globais diante das movimentações do mercado financeiro, e a partir daí, iniciado um estudo sobre predições diante de tais circunstâncias. Os autores deste artigo

utilizam o Processamento de Linguagem Natural (NLP) para analisar as notícias e vários modelos de análise preditiva para fazer uso dos dados históricos para fazer previsões sobre os preços das ações. Para facilitar o processo de análise, é utilizado o algoritmo NLP que faz uso do texto como entrada e tokeniza cada frase em palavras. Já para análise das notícias foi utilizado o modelo Bidirectional Encoder Representations from Transformers (BERT) do Google. Para a análise de dados históricos, os dois modelos, ou seja, Auto-regressive Integrated Moving Average (ARIMA) e Long short-term memory (LSTM), foram comparados e, após a avaliação, descobriu-se que LSTM Recurrent Neural Networks (RNN) é um modelo superior. Ambos os modelos usados na análise de notícias e dados históricos foram validados várias vezes, o que rendeu precisão adequada. Enquanto Khanpara et al. [20] apresentou um modelo preditivo para movimentações do mercado financeiro utilizando o modelo de aprendizado profundo, LSTM (Long Short-Term Memory).

Aithal et al. [21] realizaram um estudo comparativo entre modelos de predição das movimentações do mercado financeiro, avaliando a capacidade de previsão de modelos estatísticos e modelos baseados em aprendizado de máquina. Para isso, foram comparados os seguintes modelos: Rede Neural Recorrente (RNN), Rede Neural de Convolução (CNN), Memória de Longo Prazo (LSTM) e Média Móvel Integrada Auto-Regressiva (ARIMA). Como conclusão, observou-se que a CNN supera outros modelos para determinado período de estudo. Também foi possível concluir que os modelos de aprendizado de máquina tiveram os melhores resultados.

Por fim, ainda tem um artigo escrito por Pavel, Muhtasim e Faruk [22], que mostra a implementação de Deep Recurrent Q-Learning (DRQN) e Autoregressive Integrating Moving Average (ARIMA) na negociação de ações com previsão do valor de fechamento de ações que auxiliam na tomada de decisões estratégicas de um mercado de ações, reconhecendo o risco de comprar, manter e vender com cálculo de lucro. Foram utilizados 15 conjuntos de dados de ações da Nasdaq para aplicar o método deste estudo, o qual superou as limitações dos métodos de aprendizado por reforço desenvolvidos recentemente.

A fusão proposta da estratégia, que combina DRQN e ARIMA, apresentou resultados robustos que auxiliam na tomada de melhores decisões para a negociação de ações, com a visualização dos resultados experimentais.

2.3 Discussão sobre os resultados

Os estudos relacionados na área de modelos preditivos para a movimentação do mercado financeiro têm apresentado avanços significativos na assertividade e eficiência nas previsões de tendências e no auxílio à tomada de decisões de negociação de ações. Diversas abordagens foram citadas, como aprendizado de máquina, redes neurais e métodos estatísticos, que são modelos que têm sido explorados para aprimorar a acurácia e a robustez dos modelos preditivos.

No entanto, ao analisar os trabalhos relacionados, é possível identificar uma lacuna: as pesquisas existentes focam em apresentar resultados aplicáveis no mercado de ações e utilizando modelos preditivos baseados em diferentes aspectos, enquanto nenhum foca em aplicar os estudos no mercado de OB, através de modelos baseados em médias móveis. Nesse sentido, este trabalho propõe um estudo comparativo entre os diferentes modelos preditivos baseados em médias móveis.

3. Proposta

Esta seção apresenta a proposta, delineando tanto o modelo conceitual quanto a implementação prática que constituem os pilares desta pesquisa. Ao longo deste, são explorados os fundamentos teóricos que moldam o modelo conceitual, destacando os princípios e estruturas subjacentes.

3.1 Modelo Conceitual

Para alcançar os objetivos propostos no presente projeto, foram seguidas algumas etapas, as quais fazem parte de uma pipeline criada exclusivamente para realização deste trabalho. Com base na Figura 1, é possível verificar este Mecanismo de Predição Estatística, contendo as etapas propostas para realização do mesmo. Com isso, serão mostrados a seguir o significado de cada etapa e dos processos que realizam a intermediação entre elas.




Figura 1. Mecanismo de Predição Estatística

Inicialmente, o *Conjunto de Dados* inicia o processo de coleta e extração de dados relevantes do mercado financeiro. Esses dados poderão incluir informações históricas de ativos financeiros, como preços de abertura, fechamento, máximas, mínimas e cores dos candlesticks. A partir desse ponto, o mecanismo segue para o módulo de construção de séries temporais, como ilustrado na etapa 1 da Figura 1.

A *Construção de Séries Temporais* é realizada a construção de séries temporais. Estas, são estruturas de dados que organizam as observações em uma sequência temporal, permitindo análises com maior precisão. Nesse contexto, as séries temporais são criadas a partir dos dados coletados, organizando-os em intervalos de tempo, como dias, semanas ou meses. Além disso, a duração das velas utilizadas para análise dos dados foi de 60 segundos cada, sendo 43200 velas retroativas analisadas, com uma janela deslizante de 15 velas por vez. Após esse processo de organização dos dados, eles passam pela segunda etapa, onde são selecionados os modelos preditivos.

Na *Seleção dos Preditores* são selecionadas as médias móveis que serão utilizadas nos modelos preditivos, como a média móvel simples (SMA), média móvel ponderada (WMA), média móvel exponencial (EMA), média móvel baseada em processo de Poisson (PMA) e média móvel harmônica (HMA). Esses modelos são aplicados às séries temporais construídas anteriormente, para verificar níveis de desempenho tanto individualmente, quanto se combinados mais de um modelo ao mesmo tempo em uma análise. Após essa etapa, o mecanismo encaminha-se para terceira etapa, que consiste em avaliações.

Após a aplicação dos modelos preditivos, é realizada a *Avaliação das Métricas de Erros*. Essas métricas permitem medir o funcionamento e desempenho dos modelos em relação às previsões realizadas. Pretende-se realizar a implementação de um algoritmo que revise o funcionamento adequado dos modelos preditivos. Por fim, o mecanismo chega em seu quarto e último processo, o relatório.

O *Relatório com Análises e Resultados* é elaborado com base nas métricas de erros obtidas, então é gerado um relatório que apresenta as análises e resultados do estudo comparativo entre os modelos preditivos baseados em médias móveis. Esse relatório inclui discussões sobre a eficácia dos modelos, identificação dos modelos com melhor desempenho e possíveis insights e recomendações para investidores e traders interessados em utilizar esses modelos em suas estratégias de negociação.

3.2 Implementação

A validação dos modelos preditivos através de dados reais de negociação é fundamental para confirmar sua eficácia em um ambiente relevante. Com isso em mente, para esse trabalho, foram desenvolvidos dois scripts que analisam dados reais do mercado financeiro de opções binárias de forma retroativa. Estes scripts facilitam a coleta histórica e contínua de dados, permitindo que os modelos sejam testados e ajustados conforme as condições reais do mercado. O primeiro realiza análises baseadas puramente em médias móveis, enquanto o

segundo, além disso, utiliza a estratégia Martingale.

Para garantir uma replicabilidade facilitada, os artefatos gerados foram disponibilizados na ferramenta GitHub. Isso promove a transparência do trabalho e permite que outros pesquisadores possam replicar e validar os resultados com diferentes conjuntos de dados históricos ou fazer melhorias no script. A implementação dos scripts tem como objetivo demonstrar como as estratégias de negociação baseadas em médias móveis foram programadas para a execução em uma plataforma de negociação financeira, neste caso, a IQ Option. Os códigos podem ser acessados pelo seguinte repositório no GitHub: (<https://github.com/luccashoff/ma-automation>).

3.2.1 Integração com API da Corretora

A integração com a API permitiu uma conexão eficiente com a plataforma de negociação IQ Option. Essa API oferece a capacidade de automatizar estratégias de negociação, além de fornecer acesso a informações de mercado em tempo real e a execução de operações diretamente na plataforma.

Um aspecto fundamental dessa integração foi a habilidade da API em recuperar dados de mercado, incluindo a obtenção de velas retroativas e suas respectivas informações, como cores. Essa funcionalidade possibilitou a análise histórica do mercado, permitindo que um script utilizasse dados históricos para aprimorar as estratégias baseadas em médias móveis. O repositório dessa API está disponível no GitHub, no seguinte link: (<https://github.com/iqoptionapi/iqoptionapi>).

3.2.2 Ambiente de Desenvolvimento

O script foi desenvolvido em Python versão 3.10.4 64-bit, uma linguagem de programação de alto nível amplamente utilizada no desenvolvimento de soluções de automação e análise de dados. A escolha do Python se deu devido à sua simplicidade e facilidade de uso, bem como à disponibilidade de bibliotecas que facilitaram a interação com a API da IQ Option.

Para a conexão com a IQ Option e a execução das estratégias de negociação, foi utilizado o módulo IQ Option, que fornece uma interface programática para a plataforma IQ Option. Além disso, foram utilizadas bibliotecas padrão do Python, como *time* para controlar o tempo de espera e *datetime* para lidar com informações de data e hora.

3.2.3 Configuração Inicial

Em primeiro lugar, é necessário configurar os parâmetros iniciais para garantir uma operação personalizada. As etapas essenciais envolvem:

- **Credenciais de Acesso:** A autenticação na IQ Option é facilitada por meio de um arquivo de configuração (config.txt), que armazena informações como login e senha.
- **Personalização da Média Móvel:** Durante a execução, o script solicita ao usuário o tipo e período da média móvel desejada, proporcionando adaptabilidade ao contexto do mercado.

- Configurações Diretas nos Scripts: Detalhes como o número de velas retroativas e o fator multiplicador Martingale são configuráveis diretamente no script.

A conexão bem-sucedida com a plataforma é essencial para garantir que o catalogador tenha acesso aos dados de mercado necessários para a análise.

3.2.4 Estratégias de Negociação Implementadas

O script incluiu a implementação de várias estratégias de negociação baseadas em médias móveis. Cada estratégia foi desenvolvida como uma função distinta no script. As estratégias implementadas foram:

- SMA (Média Móvel Simples): Utilizou a Média Móvel Simples para determinar a direção das operações com base em uma análise de curto prazo da tendência do preço.
- WMA (Média Móvel Ponderada): Utilizou a Média Móvel Ponderada para realizar operações com base em uma média que dá mais peso aos preços recentes.
- EMA (Média Móvel Exponencial): Implementou a Média Móvel Exponencial, que dá mais importância aos preços mais recentes em relação aos mais antigos.
- PMA (Média Móvel de Poisson): Introduziu a Média Móvel Poisson, que envolveu o cálculo de uma média ponderada com base na distribuição de Poisson.
- HMA (Média Móvel Harmônica): Desenvolveu a Média Móvel Harmônica, que envolveu o cálculo de uma média ponderada de acordo com os preços de cada vela.

3.2.5 Análise em Lotes

A análise em lotes é uma prática eficiente, especialmente ao lidar com grandes conjuntos de dados. O script analisa as velas em lotes, o que não apenas otimiza o desempenho computacional, mas também permite que o catalogador avalie a estratégia em diferentes segmentos temporais. Isso é valioso para identificar como a estratégia se comporta em diferentes condições de mercado.

3.2.6 Resultados e Assertividade

Os resultados proporcionam uma compreensão abrangente do desempenho da estratégia. O acompanhamento das operações bem-sucedidas e malsucedidas é fundamental para avaliar a consistência da estratégia. A assertividade, expressa como uma porcentagem, é uma métrica importante que indica a precisão global da estratégia. Essas estatísticas são valiosas para ajustar e melhorar a estratégia ao longo do tempo.

3.2.7 Pares de Ativos

A iteração sobre diferentes pares de ativos amplia a aplicabilidade da estratégia. Nesse caso são utilizados os pares de moedas, onde cada par pode ter características únicas, e testar a estratégia em uma variedade de ativos ajuda a determinar

sua robustez. A exclusão de ativos OTC é uma consideração prática, concentrando a análise em ativos digitais mais relevantes para o contexto da plataforma IQ Option.

3.2.8 Visualização de Informações

A apresentação dos resultados em um formato tabular, utilizando a biblioteca tabulate, facilita a interpretação dos dados. Cada linha na tabela representa um par de ativos analisado, exibindo estatísticas importantes, como vitórias, derrotas, assertividade e o total de velas analisadas. Essa organização torna os resultados acessíveis e eficientes para análise comparativa entre diferentes pares e estratégias.

4. Avaliação e Discussão dos Resultados

Nesta seção, são apresentados e discutidos os resultados obtidos a partir da execução das estratégias de negociação baseadas em Médias Móveis, abordando dois cenários distintos de operações: baseadas puramente em Médias Móveis e também baseadas em Médias Móveis com utilização de Martingale. As análises foram conduzidas considerando cinco diferentes tipos de médias móveis, incluindo Média Móvel Simples (SMA), Média Móvel Ponderada (WMA), Média Móvel Exponencial (EMA), Média Móvel de Poisson (PMA) e Média Móvel Harmônica (HMA). A avaliação possui cerca de 43200 velas retroativas, dos principais pares de ativos de negociação.

4.1 Descrição dos Cenários de Testes - Estatístico

Nesta seção focou-se na implementação de estratégias de negociação baseadas em Médias Móveis, explorando os cinco diferentes tipos de médias para avaliar seus desempenhos. Cada média móvel foi testada independentemente, proporcionando uma compreensão detalhada de como cada uma delas pode apresentar resultados com diferentes porcentagens de assertividade.

4.1.1 Abordagem Nayve

Antes de apresentar a abordagem com Médias Móveis e Martingale, foi criado um script para fins de verificação adicional do funcionamento dos algoritmos implementados, implementando uma função adicional, chamada de Random. Ela consiste em realizar a análise da mesma forma que as funções das médias fazem, indicando uma tendência a cada vela dentro do período de 43200 velas retroativas, porém desta vez, sem realizar qualquer tipo de análise técnica, somente indicando uma tendência aleatória, podendo ser Call (Operação de Compra) ou Put (Operação de Venda).

Para isso, foi realizada a importação da biblioteca Random do Python, que realiza essa seleção baseada em aleatoriedade. A lógica dessa abordagem seria de obter resultados próximos aos de um usuário que fique clicando aleatoriamente em Comprar ou Vender na corretora, ou seja, esperando resultados próximos aos 50% de assertividade, pois indica duas possibilidades. Caso o algoritmo se aproximasse dessa assertividade, poderia se dizer que a verificação obteve sucesso, e caso fosse um estudo com resultados muito distintos de 50%, surgiria a necessidade de revisar os códigos.

Portanto, a tabela Random 3 apresenta os resultados utilizando essa abordagem simulando um comportamento *Nayve*, ou seja, ingênuo ou aleatório. Na primeira coluna da tabela são mostrados os pares de moedas, em seguida, número de vitórias, erros e taxa de assertividade, respectivamente. E como resultados dessa verificação, pode-se concluir que em todos os pares foram obtidos resultados próximos aos 50% de assertividade, indicando êxito nesse estudo. A média entre as assertividades de todos os pares utilizando essa função randômica foi de 49,79%, o que fortaleceu o resultado, que chegou muito próximo do esperado para o funcionamento adequado dos algoritmos.

PAR	WINS	LOSS	ASSERTIVIDADE
EURUSD	21745	21551	50.22%
EURGBP	21894	21402	50.57%
GBPJPY	21561	21735	49.80%
EURJPY	22354	20942	51.63%
GBPUSD	20680	22616	47.76%
AUDCAD	22132	21164	51.12%
USDCHF	20502	22794	47.35%
AUDUSD	21340	21956	49.29%
USDCAD	21032	22264	48.58%
AUDJPY	22354	20942	51.63%

Tabela 3. Random

4.1.2 Médias Móveis

Foi implementado um script que realiza integração com uma API pré-existente, e possibilita ao usuário, através do terminal do seu computador, escolher o tipo de média móvel desejada (SMA, WMA, EMA, PMA ou HMA) para analisar 43200 velas retroativas dos principais pares de ativos do mercado de Opções Binárias, na corretora IQ Option. Esse número de velas, corresponde a cerca de 30 dias de movimentações do mercado, com cada vela tendo duração de 1 minuto.

Para isso, além do tipo de Média Móvel selecionada pelo usuário, também é necessário informar o período de velas para análise. Isso significa que, se por exemplo, o usuário selecionar SMA para análise e um período de 10 velas, serão analisados lotes de 10 em 10 velas para calcular a Média Móvel Simples (SMA), e com base nesse valor, o algoritmo compara o valor da média, com o preço de mercado atual da vela analisada, e indica uma tendência. Caso o valor da média esteja acima do valor da vela atual, a tendência é que o mercado irá retrair, ou seja, uma tendência de baixa, indicando uma operação de Put (Venda) para próxima vela. Se a próxima vela seguir a tendência, que nesse caso seria finalizar o preço da vela abaixo do fechamento da vela anterior, contabiliza-se uma operação bem sucedida, ou seja, Win. Caso contrário, sendo o fechamento da próxima vela finalizando acima do fechamento da vela anterior, contabiliza-se uma operação perdida, ou seja, Loss. Agora caso o valor da média esteja abaixo do valor da vela atual, a tendência é que o mercado indique uma possível movimentação de alta, portanto é indicado uma operação de Call (Compra) para próxima vela,

seguindo a mesma lógica dita anteriormente, na qual caso o valor do fechamento da vela atual finalize acima da vela anterior, contabiliza-se Win, caso contrário, Loss.

Após verificação do resultado da operação, o algoritmo seleciona as próximas X velas para calcular o novo valor da média e analisar a tendência para a próxima vela em questão, que seguindo o exemplo anterior, então as 10 velas seguintes são analisadas para calcular o valor da SMA, e com base nisso realizar a comparação com o valor de mercado atual e indicar nova tendência para análise. O script realiza essa mesma lógica para todos os tipos de médias disponíveis, e calcula a média para o período indicado ao longo das 43200 velas.

Ainda no script, foi implementada uma função provida da API, que consegue realizar essas análises em diferentes pares de ativos de moedas, filtrando somente os pares que não sejam OTC (Over-the-Counter) tradicionalmente conhecido como Mercado de Balcão, no qual ocorrem nesse caso em finais de semana e feriados, onde são realizadas operações que não são baseadas em movimentações de mercado das cotações dos pares de moedas mundiais, pois nessas datas o mercado oficial não está aberto, sendo responsabilidade das corretoras o funcionamento do mercado e a disponibilidade de ativos. Com base nessas informações, foram analisados dados de 43200 velas retroativas a partir do dia 12/12/2023, e foram obtidos dados dos seguintes pares de ativos:

- AUDCAD - Dólar Australiano / Dólar Canadense
- AUDUSD - Dólar Australiano / Dólar Americano
- AUDJPY - Dólar Australiano / Iene Japonês
- EURUSD - Euro / Dólar Americano
- EURGBP - Euro / Libra Esterlina
- EURJPY - Euro / Iene Japonês
- GBPJPY - Libra Esterlina / Iene Japonês
- GBPUSD - Libra Esterlina / Dólar Americano
- USDCHF - Dólar Americano / Franco Suíço
- USDCAD - Dólar Americano / Dólar Canadense

A seguir serão mostrados os resultados obtidos correspondentes a execução do script no dia 12/12/2023, das 43200 velas retroativas, cerca de 30 dias anteriores. Na Tabela 4 SMA, são apresentados os resultados obtidos para os 10 pares de moedas, mostrando individualmente o número de Wins, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel Simples (SMA), o par com maior assertividade foi GBPUSD com 52,37%, o menos assertivo foi o par USDCAD com 45,83% e a média geral dos resultados obtidos entre todos os dez pares foi de 49,34%.

Seguindo para a Tabela 5 WMA, são apresentados os resultados obtidos para os 10 pares de moedas, mostrando

PAR	WINS	LOSS	ASSERTIVIDADE
EURUSD	21076	22220	48.68%
EURGBP	22239	21057	51.37%
GBPJPY	21883	21413	50.54%
EURJPY	20680	22616	47.76%
GBPUSD	22676	20620	52.37%
AUDCAD	22004	21292	50.82%
USDCHEF	21254	22042	49.09%
AUDUSD	20713	22583	47.84%
USDCAD	19844	23452	45.83%
AUDJPY	21296	22000	49.19%

Tabela 4. SMA

PAR	WINS	LOSS	ASSERTIVIDADE
EURUSD	21171	22125	48.90%
EURGBP	21120	22176	48.78%
GBPJPY	21897	21399	50.58%
EURJPY	20700	22596	47.81%
GBPUSD	22078	21218	50.99%
AUDCAD	22287	21009	51.48%
USDCHEF	21076	22220	48.68%
AUDUSD	20716	22580	47.85%
USDCAD	20328	22968	46.95%
AUDJPY	21144	22152	48,84%

Tabela 6. EMA

PAR	WINS	LOSS	ASSERTIVIDADE
EURUSD	21384	21912	49.39%
EURGBP	21876	21420	50.53%
GBPJPY	22178	21118	51.22%
EURJPY	20911	22385	48.30%
GBPUSD	22082	21214	51.00%
AUDCAD	22528	20768	52.03%
USDCHEF	21206	22090	48.98%
AUDUSD	20996	22300	48.49%
USDCAD	20196	23100	46.65%
AUDJPY	21472	21824	49.59%

Tabela 5. WMA

PAR	WINS	LOSS	ASSERTIVIDADE
EURUSD	21447	21849	49.54%
EURGBP	21856	21440	50.48%
GBPJPY	22076	21220	50.99%
EURJPY	20988	22308	48.48%
GBPUSD	22156	21140	51.17%
AUDCAD	22576	20720	52.14%
USDCHEF	21124	22172	48.79%
AUDUSD	20777	22519	47.99%
USDCAD	20020	23276	46.24%
AUDJPY	21252	22044	49.09%

Tabela 7. PMA

individualmente o número de Wins, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel Ponderada (WMA), o par com maior assertividade foi AUDCAD com 52,03%, o menos assertivo foi o par USDCAD com 46,65% e a média geral dos resultados obtidos entre todos os dez pares foi de 49,61%.

A Tabela 6 EMA, apresenta os resultados obtidos para os 10 pares de moedas, mostrando individualmente o número de Wins, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel Exponencial (EMA), o par com maior assertividade foi AUDCAD com 51,48%, o menos assertivo foi o par USDCAD com 46,95% e a média geral dos resultados obtidos entre todos os dez pares foi de 49,08%.

Na Tabela 7 PMA, são apresentados os resultados obtidos para os 10 pares de moedas, mostrando individualmente o número de Wins, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel de Poisson (PMA), o par com maior assertividade foi AUDCAD com 52,14%, o menos assertivo foi o par USDCAD com 46,24% e a média geral dos resultados obtidos entre todos os dez pares foi de 49,49%.

Por fim, a Tabela 8 HMA, são apresentados os resultados obtidos para os 10 pares de moedas, mostrando individualmente o número de Wins, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel Harmônica

(HMA), o par com maior assertividade foi AUDCAD com 51,60%, o menos assertivo foi o par USDCAD com 45,63% e a média geral dos resultados obtidos entre todos os dez pares foi de 48,88%.

4.1.3 Médias Móveis com Martingale

Além da implementação do script que realiza análise baseada em Médias Móveis, também foi implementado outro script com as mesmas opções de Médias (SMA, WMA, EMA, PMA e HMA) e possibilidade de escolher o período de análise, porém foi acrescentado a lógica Martingale, que consiste em recuperar valores perdidos em operações com resultados negativos. Nessa abordagem, é apresentada somente a parte estatística, seguindo o mesmo modelo, porém dessa vez mos-

PAR	WINS	LOSS	ASSERTIVIDADE
EURUSD	21384	21912	49.39%
EURGBP	21778	21518	50.30%
GBPJPY	21692	21604	50.1%
EURJPY	20339	22957	46.98%
GBPUSD	22176	21120	51.22%
AUDCAD	22341	20955	51.60%
USDCHEF	20856	22440	48.17%
AUDUSD	20889	22407	48.25%
USDCAD	19756	23540	45.63%
AUDJPY	20449	22847	47.23%

Tabela 8. HMA

PAR	WINS	GALE	LOSS	ASSERTIV.
EURUSD	22264	14300	6732	76.78%
EURGBP	20768	14608	7920	72.39%
GBPJPY	22792	13816	6688	77.31%
EURJPY	21032	14520	7744	73.09%
GBPUSD	21868	14344	7084	75.53%
AUDCAD	21560	14388	7348	74.58%
USDCHF	20988	14828	7480	73.72%
AUDUSD	21604	14652	7040	75.42%
USDCAD	20468	15092	7736	72.57%
AUDJPY	22352	14168	6776	76.74%

Tabela 9. SMA com Martingale

trando além dos Wins, Loss e Assertividade, também o número de Gales realizado em cada par de moedas.

Na prática funciona da seguinte forma, supondo que o usuário tenha selecionado o tipo de média SMA e o período das velas de 15, o algoritmo calcula a média com base nas últimas 15 velas, e compara com o valor da vela atual, indicando uma possível tendência para a próxima vela. Até então, repete-se a lógica do algoritmo de análise baseada em Médias Móveis, porém o que se diferencia, é que quando uma vela segue direção oposta à tendência indicada, não é contabilizado Loss direto, realiza-se uma nova entrada para a vela seguinte, acreditando que ela irá seguir a mesma tendência indicada para última vela, buscando então minimizar as operações de perda. Essa estratégia com Martingale tende apresentar resultados mais assertivos, pois não contabiliza as perdas na primeira entrada para cada vela, realiza-se a segunda entrada para a vela seguinte seguindo a mesma tendência, sendo que nessa entrada, caso resulte novamente em uma perda, aí sim é contabilizado o Loss.

Em resumo, o algoritmo está implementado para realizar a primeira entrada para cada vela, caso a vela siga a tendência indicada, contabiliza-se Win, caso contrário inicia-se a segunda entrada para a próxima vela, acreditando seguir a mesma tendência da vela anterior, caso siga a tendência, contabiliza-se Win, caso contrário, contabiliza-se Loss.

Partindo para a análise dos dados, a seguir serão mostrados os resultados obtidos com base na execução do script no dia 29/12/2023, das 43200 velas retroativas, cerca de 30 dias anteriores. Lembrando que o número de velas analisadas nunca é exato pois existe uma margem de erro provida da importação dos dados da IQ Option.

Na Tabela 9 SMA com Martingale, são apresentados os resultados obtidos para os 10 pares de moedas, mostrando individualmente o número de Wins, Gale, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel Simples com Martingale (SMA), o par com maior assertividade foi GBPJPY com 77,31%, o menos assertivo foi o par EURGBP com 72,39% e a média geral dos resultados obtidos entre todos os dez pares foi de 74,81%.

Já na Tabela 10 WMA com Martingale, são apresentados

PAR	WINS	GALE	LOSS	ASSERTIV.
EURUSD	21164	14828	7304	74.34%
EURGBP	20856	14872	7568	73.37%
GBPJPY	22616	13860	6820	76.83%
EURJPY	20988	14476	7832	72.82%
GBPUSD	21648	14564	7084	75.34%
AUDCAD	20944	14652	7700	73.12%
USDCHF	20944	14608	7744	73.01%
AUDUSD	21516	14828	6952	75.58%
USDCAD	20636	14740	7920	72.27%
AUDJPY	22000	14168	7128	75.53%

Tabela 10. WMA com Martingale

PAR	WINS	GALE	LOSS	ASSERTIV.
EURUSD	22264	14120	6952	76.20%
EURGBP	21296	14696	7304	74.46%
GBPJPY	22880	13904	6512	77.84%
EURJPY	20592	14872	7832	72.45%
GBPUSD	22220	14168	6908	76.28%
AUDCAD	21956	14256	7084	75.61%
USDCHF	20856	14740	7700	73.04%
AUDUSD	21516	14828	6952	75.58%
USDCAD	20856	14564	7876	72.59%
AUDJPY	22396	14168	6732	76.89%

Tabela 11. EMA com Martingale

os resultados obtidos para os 10 pares de moedas, mostrando individualmente o número de Wins, Gale, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel Ponderada com Martingale (WMA), o par com maior assertividade foi GBPJPY com 76,83%, o menos assertivo foi o par USDCAD com 72,27% e a média geral dos resultados obtidos entre todos os dez pares foi de 74,22%.

A Tabela 11 EMA com Martingale, apresenta os resultados obtidos para os 10 pares de moedas, mostrando individualmente o número de Wins, Gale, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel Exponencial com Martingale (EMA), o par com maior assertividade foi GBPJPY com 77,84%, o menos assertivo foi o par EURJPY com 72,45% e a média geral dos resultados obtidos entre todos os dez pares foi de 75,09%.

Na Tabela 12 PMA com Martingale, são apresentados os resultados obtidos para os 10 pares de moedas, mostrando individualmente o número de Wins, Gale, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel de Poisson com Martingale (PMA), o par com maior assertividade foi GBPJPY com 76,83%, o menos assertivo foi o par USDCAD com 72,27% e a média geral dos resultados obtidos entre todos os dez pares foi de 74,35%.

Por fim, a Tabela 13 HMA com Martingale, são apresentados os resultados obtidos para os 10 pares de moedas,

PAR	WINS	GALE	LOSS	ASSERTIV.
EURUSD	22088	14145	7084	75.72%
EURGBP	20856	14872	7568	73.37%
GBPJPY	22616	13860	6820	76.83%
EURJPY	20988	14476	7832	72.82%
GBPUSD	21648	14564	7084	75.34%
AUDCAD	20944	14652	7700	73.12%
USDCHF	20944	14608	7744	73.01%
AUDUSD	21516	14828	6952	75.58%
USDCAD	20636	14740	7920	72.27%
AUDJPY	22000	14168	7128	75.53%

Tabela 12. PMA com Martingale

PAR	WINS	GALE	LOSS	ASSERTIV.
EURUSD	22220	14212	6864	76.40%
EURGBP	21296	14344	7656	73.56%
GBPJPY	22528	13948	6820	76.76%
EURJPY	20504	14916	7876	72.25%
GBPUSD	22792	14036	6468	77.89%
AUDCAD	21736	14476	7084	75.42%
USDCHF	21560	14344	7392	74.47%
AUDUSD	21648	14520	7128	75.23%
USDCAD	21340	14652	7304	74.50%
AUDJPY	22352	14344	6600	77.20%

Tabela 13. HMA com Martingale

mostrando individualmente o número de Wins, Gale, Loss e assertividade, marcando a relação de acertos sobre o número total de acertos e erros, em porcentagem. Nessa tabela da Média Móvel Harmônica (HMA), o par com maior assertividade foi GBPUSD com 77,89%, o menos assertivo foi o par EURJPY com 72,25% e a média geral dos resultados obtidos entre todos os dez pares foi de 75,36%.

4.2 Análise de Variância - ANOVA

A fim de verificar a validade dos resultados obtidos, utilizamos a Análise de Variância (ANOVA), uma técnica estatística empregada para comparar as médias de dois ou mais grupos e determinar se existem diferenças estatisticamente significativas entre eles. A ANOVA testa a hipótese nula de que todas as médias dos grupos são iguais contra a hipótese alternativa de que pelo menos uma média é diferente. É uma ferramenta tipicamente usada para avaliar a influência de uma ou mais variáveis categóricas em uma variável contínua.

A aplicação da ANOVA nesse trabalho permite testar a significância das diferenças entre os modelos de médias móveis, algo que não seria possível apenas observando as porcentagens de acerto e erro. Essa análise é crucial para verificar a robustez dos resultados e identificar se as diferenças observadas não são geradas pelo acaso. Para isso, foram realizadas duas Análises de Variância, a primeira contendo os resultados das médias puras e a segunda contendo os resultados das médias com Martingale.

Para realizar esses cálculos e análises, utilizamos a fer-

ramenta de calculadora de ANOVA unidirecional disponível na ferramenta online MathCracker¹. Esta ferramenta nos permitiu calcular as estatísticas F necessárias para testar as hipóteses nula e alternativa. O nível de significância utilizado para todos os cálculos foi de 0,05, garantindo um rigor estatístico adequado para avaliar a significância das diferenças entre os modelos de médias móveis.

4.2.1 Médias Móveis

(1) Hipóteses Nula e Alternativa

As hipóteses que precisam ser testadas são:

- **Hipótese Nula (H_0):** $\mu_1 = \mu_2 = \mu_3 = \mu_4 = \mu_5$
- **Hipótese Alternativa (H_a):** Nem todas as médias são iguais

Estas hipóteses serão testadas usando a razão F para uma ANOVA unidirecional [23].

(2) Região de Rejeição

Com base nas informações fornecidas, o nível de significância $\alpha = 0.05$ e os graus de liberdade são $df_1 = 4$ e $df_2 = 4$. A região de rejeição para este teste F é $F_R = \{F : F > 2.579\}$.

(3) Estatísticas de Teste

A estatística F é calculada da seguinte forma:

$$F = \frac{MS_{\text{between}}}{MS_{\text{within}}} = \frac{0.889}{3.102} = 0.287$$

(4) Decisão sobre a Hipótese Nula

Como a partir das informações da amostra obtemos $F = 0.287 \leq F_R = 2.579$, concluímos que a hipótese nula não é rejeitada.

(5) Conclusão

Conclui-se que a hipótese nula H_0 não é rejeitada. Portanto, não há evidências suficientes para afirmar que nem todas as médias da população são iguais, no nível de significância $\alpha = 0.05$.

4.2.2 Médias Móveis com Martingale

(1) Hipóteses Nula e Alternativa

As seguintes hipóteses nula e alternativa precisam ser testadas:

- **Hipótese Nula (H_0):** $\mu_1 = \mu_2 = \mu_3 = \mu_4 = \mu_5$
- **Hipótese Alternativa (H_a):** Nem todas as médias são iguais

As hipóteses acima serão testadas usando a razão F para uma ANOVA unidirecional.

¹<https://mathcracker.com/pt/calculadora-analise-de-variância>

PAR	Ganho	Perda	Payout	Saldo Final
EURUSD	\$189.684,00	\$222.200,00	90 %	- \$32.516,00
EURGBP	\$200.151,00	\$210.570,00	90 %	- \$10.419,00
GBPJPY	\$196.947,00	\$214.130,00	90 %	- \$17.183,00
EURJPY	\$186.120,00	\$226.160,00	90 %	- \$40.040,00
GBPUSD	\$204.084,00	\$206.200,00	90 %	- \$2.116,00
AUDCAD	\$198.036,00	\$212.920,00	90 %	- \$14.884,00
USDCHF	\$191.286,00	\$220.420,00	90 %	- \$29.134,00
AUDUSD	\$186.417,00	\$225.830,00	90 %	- \$39.413,00
USDCAD	\$178.596,00	\$234.520,00	90 %	- \$55.924,00
AUDJPY	\$191.664,00	\$220.000,00	90 %	- \$28.336,00

Tabela 14. SMA - Simulação com Dinheiro Fictício

(2) Região de Rejeição

Similarmente ao caso das médias móveis, com base nas informações fornecidas, o nível de significância é $\alpha = 0.05$ e os graus de liberdade são $df_1 = 4$ e $df_2 = 4$, portanto, a região de rejeição para este teste F é $F_R = \{F : F > 2.579\}$.

(3) Estatísticas de Teste

A estatística F é calculada da seguinte forma:

$$F = \frac{MS_{\text{between}}}{MS_{\text{within}}} = \frac{2.337}{2.945} = 0.793$$

(4) Decisão sobre a Hipótese Nula

Como a partir das informações da amostra obtemos que $F = 0.793 \leq F_c = 2.579$, conclui-se então que a hipótese nula não é rejeitada.

(5) Conclusão

Conclui-se que a hipótese nula H_0 não é rejeitada. Portanto, não há evidências suficientes para afirmar que nem todas as médias da população são iguais, no nível de significância $\alpha = 0.05$.

4.3 Descrição dos Cenários de Testes - Simulação com Dinheiro Fictício

Nesta seção, serão conduzidas simulações detalhadas para avaliar o desempenho das estratégias de negociação implementadas, tanto para a abordagem pura de Médias Móveis quanto para a variação que incorpora a lógica de Martingale. Valores fictícios serão utilizados para representar investimentos e resultados, observando como as estratégias se comportam em condições simuladas.

Para manter a consistência nos cenários, foi adotado um valor de investimento por operação fixado em \$10. No caso da estratégia com Martingale, será aplicado um fator multiplicador de 2x ao realizar operações subsequentes após uma perda visando recuperar o valor perdido. Além disso, outra informação essencial é o Payout, que indica a porcentagem de retorno sobre o valor investido em cada operação, sendo somente em caso de vitórias. Ou seja, caso a operação seja de \$10 e o Payout 90%, em caso de vitórias, será retornado o valor de entrada da operação, acrescido do Payout multiplicado pelo valor de entrada como lucro, e em caso de derrota

PAR	Ganho	Perda	Payout	Saldo Final
EURUSD	\$192.456,00	\$219.120,00	90 %	- \$26.664,00
EURGBP	\$196.884,00	\$214.200,00	90 %	- \$17.316,00
GBPJPY	\$199.602,00	\$211.180,00	90 %	- \$11.578,00
EURJPY	\$188.199,00	\$223.850,00	90 %	- \$35.651,00
GBPUSD	\$198.738,00	\$212.140,00	90 %	- \$13.402,00
AUDCAD	\$202.752,00	\$207.680,00	90 %	- \$4.928,00
USDCHF	\$190.854,00	\$220.900,00	90 %	- \$30.046,00
AUDUSD	\$188.964,00	\$223.000,00	90 %	- \$34.036,00
USDCAD	\$181.764,00	\$231.000,00	90 %	- \$49.236,00
AUDJPY	\$193.248,00	\$218.240,00	90 %	- \$24.992,00

Tabela 15. WMA - Simulação com Dinheiro Fictício

PAR	Ganho	Perda	Payout	Saldo Final
EURUSD	\$190.539,00	\$221.250,00	90 %	- \$30.711,00
EURGBP	\$190.080,00	\$221.760,00	90 %	- \$31.680,00
GBPJPY	\$197.073,00	\$213.990,00	90 %	- \$16.917,00
EURJPY	\$186.300,00	\$225.960,00	90 %	- \$39.660,00
GBPUSD	\$198.702,00	\$212.180,00	90 %	- \$13.478,00
AUDCAD	\$200.583,00	\$210.090,00	90 %	- \$9.507,00
USDCHF	\$189.684,00	\$222.200,00	90 %	- \$32.516,00
AUDUSD	\$186.444,00	\$225.800,00	90 %	- \$39.356,00
USDCAD	\$182.952,00	\$229.680,00	90 %	- \$46.728,00
AUDJPY	\$190.296,00	\$221.520,00	90 %	- \$31.224,00

Tabela 16. EMA - Simulação com Dinheiro Fictício

se perde o valor total da entrada. Nesse exemplo, em caso de Win seria retornado o valor de entrada inicial e mais \$9 de lucro, e em caso de Loss, seria perdido \$10.

Ao longo das simulações, será examinado o ganho acumulado, a perda acumulada e o saldo final para cada par de moedas considerado. Essas simulações visam proporcionar uma visão mais prática do desempenho das estratégias sob diferentes condições de mercado simuladas.

É importante destacar que essas simulações são baseadas em dados históricos e não garantem resultados reais em ambientes de negociação ao vivo. Elas servem como uma ferramenta de análise para entender como as estratégias poderiam ter se saído em cenários passados e auxiliar na tomada de decisões para possíveis ajustes ou otimizações. Outro fator importante a ser destacado é o fato de que a simulação com dinheiro fictício não apresenta ordem cronológica das operações, é uma análise bruta dos resultados em geral.

4.3.1 Médias Móveis

Em cada tabela, são apresentados os resultados obtidos para os 10 pares de moedas, mostrando individualmente o valor total bruto de ganhos, que seriam o número de Wins multiplicado por nove, que indica o lucro com base no payout para cada entrada, também mostra o valor total bruto de perdas, que seriam o número de Loss multiplicado por dez, que indica prejuízo do valor total da entrada, aparece também o Payout que é padrão em 90% para todos os pares e por fim o Saldo Final, que representa a diferença entre valores ganhos e perdidos, ou seja, o montante final após Wins e Loss.

Na Tabela 14 SMA - Simulação com Dinheiro Fictício, todos os pares obtiveram saldos finais negativos, indicando que a soma das perdas acumuladas foram maiores que os

PAR	Ganho	Perda	Payout	Saldo Final
EURUSD	\$193.023,00	\$218.490,00	90 %	- \$25.467,00
EURGBP	\$196.704,00	\$214.400,00	90 %	- \$17.696,00
GBPJPY	\$198.684,00	\$212.200,00	90 %	- \$13.516,00
EURJPY	\$188.892,00	\$223.080,00	90 %	- \$34.188,00
GBPUSD	\$199.404,00	\$211.400,00	90 %	- \$11.996,00
AUDCAD	\$203.184,00	\$207.200,00	90 %	- \$4.016,00
USDCHE	\$190.116,00	\$221.720,00	90 %	- \$31.604,00
AUDUSD	\$186.993,00	\$225.190,00	90 %	- \$38.197,00
USDCAD	\$180.180,00	\$232.760,00	90 %	- \$52.580,00
AUDJPY	\$191.268,00	\$220.440,00	90 %	- \$29.172,00

Tabela 17. PMA - Simulação com Dinheiro Fictício

ganhos nos diferentes pares. O saldo final com menor prejuízo foi GBPUSD com - \$2.116,00, enquanto o par que mais obteve prejuízo foi USDCAD, com -\$55.924,00. A soma das perdas totalizou um prejuízo total de -\$269.965,00. Concluindo então a primeira simulação para a Média Móvel Simples com apenas resultados negativos.

Seguindo para a Tabela 15 WMA - Simulação com Dinheiro Fictício, novamente todos os pares obtiveram saldos finais negativos, indicando que a soma das perdas acumuladas foram maiores que os ganhos nos diferentes pares. O saldo final com menor prejuízo foi AUDCAD com - \$4.928,00, enquanto o par que mais obteve prejuízo foi USDCAD, com -\$49.236,00. Desta vez, a soma das perdas totalizou um prejuízo total de -\$247.849,00. Concluindo que a simulação para a Média Móvel Ponderada também só obteve resultados negativos.

Já na Tabela 16 EMA - Simulação com Dinheiro Fictício, mais uma vez todos os pares obtiveram saldos finais negativos, indicando que a soma das perdas acumuladas foram maiores que os ganhos nos diferentes pares. Desta vez, o saldo final com menor prejuízo foi AUDCAD com - \$9.507,00, enquanto o par que mais obteve prejuízo foi novamente USDCAD, com -\$46.728,00. Agora a soma das perdas totalizou um prejuízo total de -\$291.777,00. Concluindo que a simulação para a Média Móvel Exponencial obteve resultados negativos.

Próxima Tabela 17 PMA - Simulação com Dinheiro Fictício, outra vez que todos os pares obtiveram saldos finais negativos, indicando que a soma das perdas acumuladas foram maiores que os ganhos nos diferentes pares. Novamente, o saldo final com menor prejuízo foi AUDCAD com - \$4.016,00, enquanto o par que mais obteve prejuízo foi mais uma vez USDCAD, com -\$52.580,00. Somando as perdas foi totalizado um prejuízo total de -\$258.432,00. Nesse caso, pode-se concluir de que está se repetindo um padrão dos pares com maiores e menores prejuízos, e também o fato de que todos os pares estiveram com saldos finais negativos até o momento.

Por fim, é apresentada a Tabela 18 HMA - Simulação com Dinheiro Fictício, concluindo que todos os pares em todos os tipos de médias obtiveram saldos finais negativos, indicando que a soma das perdas acumuladas foram maiores que os ganhos. Segue a tendência do saldo final com menor prejuízo, sendo o AUDCAD, desta vez com - \$8.481,00, enquanto o par com maior prejuízo foi mais uma vez USDCAD, com

PAR	Ganho	Perda	Payout	Saldo Final
EURUSD	\$192.456,00	\$219.120,00	90 %	- \$26.664,00
EURGBP	\$196.002,00	\$215.180,00	90 %	- \$19.178,00
GBPJPY	\$195.228,00	\$216.040,00	90 %	- \$20.812,00
EURJPY	\$183.051,00	\$229.570,00	90 %	- \$46.519,00
GBPUSD	\$199.584,00	\$211.200,00	90 %	- \$11.616,00
AUDCAD	\$201.069,00	\$209.550,00	90 %	- \$8.481,00
USDCHE	\$187.704,00	\$224.400,00	90 %	- \$36.696,00
AUDUSD	\$188.001,00	\$224.070,00	90 %	- \$36.069,00
USDCAD	\$177.804,00	\$235.400,00	90 %	- \$57.596,00
AUDJPY	\$184.041,00	\$228.470,00	90 %	- \$44.429,00

Tabela 18. HMA - Simulação com Dinheiro Fictício

-\$57.596,00. Por fim, as perdas totalizaram um prejuízo total de -\$308.060,00. Nesse caso, pode-se concluir de que o par com maior prejuízo se repetiu em todos os tipos de médias, que no caso foi USDCAD e o par com menor prejuízo nos diferentes tipos de média foi AUDCAD, que liderou nesse quesito em 80% dos tipos de média.

4.3.2 Médias Móveis com Martingale

Nessa segunda abordagem da Simulação com dinheiro fictício, cada tabela apresenta os resultados obtidos para os 10 pares de moedas, mostrando individualmente o valor total bruto de ganhos, que seriam o número de Wins(soma de Wins sem e com Gale), sendo os sem Gale multiplicados por nove, representados pela multiplicação do Payout de 90% pelo valor da entrada que é \$10, enquanto os Wins com Gale são multiplicados por oito, que seriam \$18 de lucro da segunda entrada, menos os \$10 perdidos da primeira entrada. Logo após o fator Gale, que é o fator multiplicador para o valor de entrada em operações de Martingale, aparece a perda acumulada, que é representada pelo valor total de operações perdidas por trinta, que indica o valor da operação normal perdida, ou seja, \$10, acrescidos do valor da operação de martingale perdida, no caso \$20, que juntos totalizam os \$30. Após isso, também são mostradas a quantidade total de Wins sem Martingale e os Wins na operação de Martingale. Aparece também o Payout que é padrão em 90% para todos os pares e por fim o Saldo Final, que representa a diferença entre valores ganhos e perdidos, ou seja, o montante final após Wins e Loss.

Na Tabela 19 SMA com Gale - Simulação com Dinheiro Fictício, desta vez os pares obtiveram novamente saldos finais negativos, indicando que a soma dos ganhos acumulados foram menores que as perdas nos diferentes pares. O saldo final com menor prejuízo foi GBPJPY com - \$2.640,00, enquanto o par que mais obteve prejuízo foi EURGBP, com - \$57.376,00. A soma dos saldos finais totalizou um prejuízo total de -\$305.832,00. Concluindo então a primeira simulação para a Média Móvel Simples com apenas resultados negativos.

Na Tabela 20 seguinte, WMA com Gale - Simulação com Dinheiro Fictício, novamente todos os pares obtiveram saldos finais negativos, indicando que a soma dos ganhos acumulados foram menores que as perdas nos diferentes pares. O saldo final com menor prejuízo foi GBPJPY com -\$8.096,00, enquanto o par que mais obteve prejuízo foi USDCAD, com -

\$58.696,00. Desta vez a soma dos saldos finais totalizou um prejuízo total de - \$373.296,00. Concluindo que novamente todos os pares finalizaram com saldos finais negativos.

Seguindo para a Tabela 21 EMA com Gale - Simulação com Dinheiro Fictício, desta vez obtivemos um par com saldo lucrativo, no entanto, segue sendo a grande maioria negativo. O saldo final com maior lucro foi GBPJPY, com - \$3.168,00, enquanto o par que mais obteve prejuízo foi EURJPY, com - \$56.672,00. Agora a soma dos saldos finais totalizou um prejuízo total de - \$269.844,00. Portanto, agora não foram todos os pares que finalizaram com saldos finais negativos, obtivemos um par com saldo final positivos e outros bem próximos disso também.

Já na Tabela 21 PMA com Gale - Simulação com Dinheiro Fictício, todos os pares obtiveram saldos finais positivos, indicando que a soma dos ganhos acumulados foram maiores que as perdas nos diferentes pares. O saldo final com maior prejuízo foi mais uma vez USDCAD, com - \$58.696,00, e o par que menos obteve prejuízo foi GBPJPY, com - \$8.096,00. Somando os saldos finais totalizou um prejuízo total de - \$357.917,00. Mais uma vez em que todos os pares finalizaram com saldos finais negativos, sendo o par com menor prejuízo GBPJPY e o maior prejuízo causado pelo par USDCAD, percebe-se um padrão sendo seguido nos diferentes tipos de média, restando somente a HMA.

Por fim, a Tabela 23 HMA com Gale - Simulação com Dinheiro Fictício, também teve um par de moedas com saldo final positivo, indicando que a soma dos ganhos acumulados foi maior que as perdas, porém no restante dos pares, o padrão de prejuízos seguiu constante. O saldo final com maior lucro desta vez foi GBPUSD, com \$3.520,00, e o par com maior prejuízo foi EURJPY, com -\$58.784,00. Por fim, a soma dos saldos finais da HMA totalizou um prejuízo total de - \$246.576,00. Mais uma vez em que a grande maioria dos pares finalizaram com saldos finais negativos.

4.4 Discussão dos Resultados

Dando início à seção da análise e discussão dos resultados, é necessário relembrar e destacar que foram abordados dois diferentes cenários com base nos resultados: Estatístico e Simulação com Dinheiro Fictício. Ambos cenários apresentam resultados com base na análise pura em Médias Móveis e também na análise das Médias Móveis com Martingale. No cenário Estatístico ainda é mostrada a abordagem Nayve, servindo de verificação adicional para confirmar o funcionamento adequado dos algoritmos.

Para contextualizar, vale ressaltar a lógica do algoritmo, que ao calcular as Médias Móveis para o período indicado pelo usuário, comparou esses valores com o preço de mercado atual da vela analisada, identificando possíveis tendências. A estratégia sugeriu operações de compra (Call) ou venda (Put) com base nessas comparações, sendo considerada bem-sucedida (Win) se a tendência se concretizasse na próxima vela, e mal-sucedida (Loss) caso contrário. No algoritmo com Martingale, realiza-se uma nova operação em casos de Loss,

indicando a mesma tendência para a próxima vela.

No cenário de testes estatísticos, analisando os resultados das médias móveis puras, a média de resultados mais assertiva foi a Média Móvel Ponderada (WMA) com 49,61%, enquanto a menos assertiva foi a Média Móvel Harmônica (HMA) com 48,88%. E referente aos pares de ativos, o mais assertivo foi AUDCAD com média de 51,61%, enquanto o menos assertivo foi USDCAD com média de 46,26%. Com base nessas informações dos resultados, é possível destacar que no geral não houveram tipos de médias com média geral de assertividade superior a 50%. Um dos fatores contribuintes para esse feito relativamente negativo, pode ter sido o fato de pares como o USDCAD que não foi assertivo, terem auxiliado a diminuir a média geral, pois em todos os tipos de MA, apresentaram números de Loss superiores aos números de Wins. Portanto, pode-se criar a suposição que existem pares de ativos que funcionam melhor com essas estratégias de médias móveis do que outros, e também o fato de que o comportamento do mercado é dinâmico e diante dessas análises com médias móveis podem apresentar resultados distintos, ou seja, é possível coletar dados de um período **X** e obter resultados **Y**, porém, dias após quando coletado novamente, serão obtidos resultados **Z**, distintos dos coletados anteriormente.

Já no cenário de testes estatísticos, analisando os resultados das Médias Móveis com Martingale, foram obtidos resultados bastante distintos da análise com Média Móvel pura, pois a estratégia Martingale subjetivamente reduz o número de perdas, através da utilização de uma segunda entrada após um Loss. Nesse caso, o tipo de Média mais assertivo foi a Média Móvel Harmônica (HMA) com 75,36%, enquanto a menos assertiva foi a Média Móvel Ponderada (WMA). Fica perceptível o aumento da assertividade quando comparada à análise baseada puramente em Médias Móveis, como dito anteriormente, um dos fatores contribuintes para esse feito positivo, foi o fato de não contabilizar o Loss na primeira entrada, pois inicia-se uma segunda entrada buscando recuperar o prejuízo. Portanto, pode-se concluir que pela visão estatística, foi uma grande evolução e aumento de assertividade quando utilizada a estratégia de Martingale, porém existem algumas ressalvas que serão abordadas no próximo parágrafo. Novamente vale ressaltar que o comportamento do mercado é dinâmico e essas análises podem apresentar resultados distintos quando coletados em períodos diferentes.

Com isso, o número de perdas foi relativamente reduzido, no entanto, o valor das perdas podem ser multiplicadas, por conta do fator multiplicador do Martingale, ou seja, perde menos, porém quando perde, o valor é muito maior. Para tratar essa questão de valores, foi realizada uma outra abordagem, com cenário de testes utilizando dinheiro fictício para simular ganhos e perdas. Para isso, foram simuladas entradas fixas de \$10 dólares com Payout de 90%, ou seja, quando operação resultar em Win, retorna \$9 dólares de lucro e em caso de Loss, perde-se o valor total da entrada, ou seja, \$10 dólares. Inicialmente foram feitas simulações para a análise baseada puramente em Médias Móveis, os resultados indica-

PAR	Ganho	Fator Gale	Perda	Wins sem Gale	Wins no Gale	Payout	Saldo Final
EURUSD	\$192.808,00	2x	\$201.960,00	14696	7568	90 %	- \$9.152,00
EURGBP	\$180.224,00	2x	\$237.600,00	14080	6688	90 %	- \$57.376,00
GBPJPY	\$198.000,00	2x	\$200.640,00	15664	7128	90 %	- \$2.640,00
EURJPY	\$182.512,00	2x	\$232.320,00	14256	6776	90 %	- \$49.808,00
GBPUSD	\$189.552,00	2x	\$212.520,00	14608	7260	90 %	- \$22.968,00
AUDCAD	\$187.000,00	2x	\$220.440,00	14520	7040	90 %	- \$33.440,00
USDCHEF	\$181.544,00	2x	\$224.400,00	13640	7348	90 %	- \$42.856,00
AUDUSD	\$186.824,00	2x	\$211.200,00	13992	7612	90 %	- \$24.376,00
USDCAD	\$178.368,00	2x	\$232.080,00	13280	7356	90 %	- \$53.712,00
AUDJPY	\$193.776,00	2x	\$203.280,00	14960	7392	90 %	- \$9.504,00

Tabela 19. SMA com Gale - Simulação com Dinheiro Fictício

PAR	Ganho	Fator Gale	Perda	Wins sem Gale	Wins no Gale	Payout	Saldo Final
EURUSD	\$182.952,00	2x	\$219.120,00	13640	7524	90 %	- \$36.168,00
EURGBP	\$180.400,00	2x	\$227.040,00	13552	7304	90 %	- \$46.640,00
GBPJPY	\$196.504,00	2x	\$204.600,00	15576	7040	90 %	- \$8.096,00
EURJPY	\$182.248,00	2x	\$234.960,00	14344	6644	90 %	- \$52.712,00
GBPUSD	\$187.352,00	2x	\$212.520,00	14168	7480	90 %	- \$25.168,00
AUDCAD	\$181.544,00	2x	\$231.000,00	13992	6952	90 %	- \$49.456,00
USDCHEF	\$181.632,00	2x	\$232.320,00	14080	6864	90 %	- \$50.688,00
AUDUSD	\$185.768,00	2x	\$208.560,00	13640	7876	90 %	- \$22.792,00
USDCAD	\$178.904,00	2x	\$237.600,00	13816	6820	90 %	- \$58.696,00
AUDJPY	\$190.960,00	2x	\$213.840,00	14960	7040	90 %	- \$22.880,00

Tabela 20. WMA com Gale - Simulação com Dinheiro Fictício

PAR	Ganho	Fator Gale	Perda	Wins sem Gale	Wins no Gale	Payout	Saldo Final
EURUSD	\$193.204,00	2x	\$208.560,00	15092	7172	90 %	- \$15.356,00
EURGBP	\$184.272,00	2x	\$219.120,00	13904	7392	90 %	- \$34.848,00
GBPJPY	\$198.528,00	2x	\$195.360,00	15488	7392	90 %	\$3.168,00
EURJPY	\$178.288,00	2x	\$234.960,00	13552	7040	90 %	- \$56.672,00
GBPUSD	\$193.080,00	2x	\$207.240,00	15000	7260	90 %	- \$14.160,00
AUDCAD	\$190.432,00	2x	\$212.520,00	14784	7172	90 %	- \$22.088,00
USDCHEF	\$180.664,00	2x	\$231.000,00	13816	7040	90 %	- \$50.336,00
AUDUSD	\$185.768,00	2x	\$208.560,00	13640	7876	90 %	- \$22.792,00
USDCAD	\$181.016,00	2x	\$236.280,00	14168	6688	90 %	- \$55.264,00
AUDJPY	\$200.464,00	2x	\$201.960,00	15664	7436	90 %	- \$1.496,00

Tabela 21. EMA com Gale - Simulação com Dinheiro Fictício

PAR	Ganho	Fator Gale	Perda	Wins sem Gale	Wins no Gale	Payout	Saldo Final
EURUSD	\$191.731,00	2x	\$212.520,00	15027	7061	90 %	- \$20.789,00
EURGBP	\$180.400,00	2x	\$227.040,00	13552	7304	90 %	- \$46.640,00
GBPJPY	\$196.504,00	2x	\$204.600,00	15576	7040	90 %	- \$8.096,00
EURJPY	\$182.248,00	2x	\$234.960,00	14344	6644	90 %	- \$52.712,00
GBPUSD	\$187.352,00	2x	\$212.520,00	14168	7480	90 %	- \$25.168,00
AUDCAD	\$181.544,00	2x	\$231.000,00	13992	6952	90 %	- \$49.456,00
USDCHEF	\$181.632,00	2x	\$232.320,00	14080	6864	90 %	- \$50.688,00
AUDUSD	\$185.768,00	2x	\$208.560,00	13640	7876	90 %	- \$22.792,00
USDCAD	\$178.904,00	2x	\$237.600,00	13816	6820	90 %	- \$58.696,00
AUDJPY	\$190.960,00	2x	\$213.840,00	14960	7040	90 %	- \$22.880,00

Tabela 22. PMA com Gale - Simulação com Dinheiro Fictício

PAR	Ganho	Fator Gale	Perda	Wins sem Gale	Wins no Gale	Payout	Saldo Final
EURUSD	\$192.632,00	2x	\$205.920,00	14872	7348	90 %	- \$13.288,00
EURGBP	\$184.976,00	2x	\$229.680,00	14608	6688	90 %	- \$44.704,00
GBPJPY	\$195.624,00	2x	\$204.600,00	15400	7128	90 %	- \$8.976,00
EURJPY	\$177.496,00	2x	\$236.280,00	13464	7040	90 %	- \$58.784,00
GBPUSD	\$197.560,00	2x	\$194.040,00	15224	7568	90 %	\$3.520,00
AUDCAD	\$188.232,00	2x	\$212.520,00	14344	7392	90 %	- \$24.288,00
USDCHF	\$187.088,00	2x	\$221.760,00	14608	6952	90 %	- \$34.672,00
AUDUSD	\$187.440,00	2x	\$213.840,00	14256	7392	90 %	- \$26.400,00
USDCAD	\$184.712,00	2x	\$219.120,00	13992	7348	90 %	- \$34.408,00
AUDJPY	\$193.424,00	2x	\$198.000,00	14608	7744	90 %	- \$4.576,00

Tabela 23. HMA com Gale - Simulação com Dinheiro Fictício

ram todos os saldos finais negativos. Lembrando que foram realizados cálculos brutos, números de Wins multiplicados por 9 e números de Loss multiplicados por 10, e para calcular os saldos finais foram calculadas as diferenças entre ganhos e perdas. Nessa análise pura das médias, o tipo de média com maior prejuízo do saldo final, foi a Média Móvel Harmônica (HMA) com saldo negativo de -\$308.060,00. Já que não houveram saldos finais positivos, o tipo de média que obteve o menor prejuízo foi a Média Móvel Ponderada (WMA) com -\$247.849,00. Com base nessas informações dos resultados, é possível destacar que um dos fatores contribuintes para esse feito negativo, foi o fato de as médias terem ficado em torno dos 50%, e a partir do momento em que os ganhos são multiplicados por 9 e as perdas por 10, a lógica indica saldos finais negativos. Portanto, trata-se de uma estratégia com assertividade próxima aos 50%, não podendo ser considerada assertiva ao ponto de utilizar com finalidade de ganhar dinheiro, tendo em vista que as perdas superam o valor dos ganhos.

Ainda, foram feitas as simulações para a análise das médias móveis com Martingale, que na análise estatística obtiveram resultados semelhantes aos das médias puras. Com isso, nessa simulação com dinheiro fictício, todos os tipos de médias, foram predominantes os saldos finais negativos, com exceções de alguns pares que obtiveram lucratividade. Coincidentemente, esses foram pares que se destacaram nas taxas de assertividade, mantendo o padrão da abordagem estatística. Tanto nas análises puras em Médias Móveis, quanto com Martingale, foram obtidos resultados com muito prejuízo, sendo o tipo de média com menor prejuízo a Média Móvel Harmônica (HMA), com - \$246.576,00, enquanto o maior prejuízo foi a Média Móvel Ponderada (WMA) com -\$373.296,00. Isso indica que a utilização de Martingale tem potencial tanto para ser positiva quanto negativa, porém depende justamente da forma a qual vai ser utilizada, precisando de gerenciamento de risco e banca, pois perdas consecutiva podem representar valores exorbitantes negativos. Outra informação são quais pares de moedas mais se destacaram com essa estratégia, que nesse caso foi GBPJPY com o menor prejuízo, de - \$24.640,00, enquanto o par com maior prejuízo geral foi USDCAD, com - \$260.776,00.

Atraente por sua simplicidade, facilidade de implementação,

e potencial de ganhos rápidos, a utilização de Martingale é altamente controversa devido aos riscos significativos que apresenta. A possibilidade de grandes perdas acumuladas em sequências prolongadas, exige um capital inicial elevado e pode causar pressão psicológica significativa nos traders, levando a decisões impulsivas e emocionais. No entanto, assim como existe o impacto negativo, deve-se destacar os potenciais positivos dessa estratégia, que embora seja conhecida por aumentar estatisticamente a probabilidade de recuperação de perdas em comparação com estratégias tradicionais, ela traz consigo riscos significativos. Um dos principais riscos é o potencial de grandes perdas acumuladas durante sequências prolongadas de operações perdidas. Portanto, apesar dos benefícios potenciais de recuperação rápida de perdas e ganhos consistentes a curto prazo, é crucial que os traders compreendam os riscos inerentes e adotem um gerenciamento de risco robusto ao utilizar a estratégia Martingale.

Embora seja possível enriquecer a discussão e fornecer um contexto mais amplo para avaliar a eficácia das médias móveis ao compará-las com outras técnicas de aprendizado de máquina, como redes neurais ou modelos de regressão, o foco deste estudo foi analisar diferentes modelos de médias móveis, permitindo uma análise minuciosa e aprofundada dessas estratégias, sem uma grande dependência histórica e complexidade adicional encontrada em outros modelos disponíveis na literatura[24]. No entanto, é importante considerar a comparação desses resultados com outras técnicas avançadas de aprendizado de máquina em futuras pesquisas. Isto permitirá uma avaliação mais abrangente e precisa das diversas metodologias preditivas existentes, exibindo trade-offs favoráveis, como por exemplo, tempo de resposta vs. precisão.

4.5 Considerações Éticas

O uso de modelos preditivos em Opções Binárias levanta várias considerações éticas importantes que podem ser discutidas. Em primeiro lugar, há o risco de manipulação de mercado, pois fontes de informações não oficiais podem ser usadas para influenciar artificialmente os preços das opções, criando oportunidades de lucro para alguns traders à custa de outros. Essa prática além de ser antiética, é considerada crime

e prejudicial à integridade do mercado.

Além disso, a disseminação de informações falsas é outra preocupação. Redes sociais podem ser utilizadas para criar relatórios ou sinais de negociação enganosos que induzem investidores a tomar decisões financeiras desfavoráveis. Isso pode resultar em perdas significativas para os investidores menos informados ou menos experientes, enquanto beneficia aqueles que têm acesso a informações privilegiadas ou manipuladas.

É essencial que os desenvolvedores e usuários desses modelos atuem com responsabilidade, garantindo que suas estratégias e algoritmos sejam utilizados de forma ética e transparente. Regulamentações adequadas e mecanismos de supervisão devem ser implementados para evitar abusos e proteger todos os participantes do mercado. Promover a educação financeira e a transparência no uso dessas tecnologias é vital para manter a confiança no mercado de Opções Binárias e assegurar que ele funcione de maneira justa e equitativa para todos os investidores.

5. Considerações Finais

Este trabalho realizou um estudo comparativo entre modelos preditivos baseados em médias móveis aplicado ao mercado de Opções Binárias. É importante reiterar que a análise baseada em Médias Móveis obteve resultados divergentes nas análises estatísticas e simulações com dinheiro fictício, quando comparadas com a combinação de Médias Móveis e Martingale. No cenário estatístico a estratégia Martingale se destacou e mostrou um potencial para lucratividade, mas no geral predominou os resultados negativos. Na abordagem de dinheiro fictício com Martingale, fica visível que surgiram alguns pares que lucraram, mas que no entanto necessita-se de um gerenciamento de banca, sendo necessário um controle maior, para converter a redução dos números de perdas na abordagem estatística em lucratividade. Contudo, também foram destacados os riscos associados a essa abordagem, com a possibilidade de grandes perdas acumuladas.

Durante a avaliação e discussão dos resultados foi destacado os perigos inerentes à estratégia Martingale, indicando a necessidade de *traders* do mercado exercerem cautela e considerarem as implicações de longo prazo, utilizando gerenciamento de banca com controle de risco, antes de aplicar essa abordagem. A busca por lucro deve ser equilibrada com a gestão de riscos, e a estratégia Martingale não é isenta de suas próprias vulnerabilidades. A análise de compatibilidade também enfatizou a importância da adaptabilidade da estratégia a diferentes ativos e condições de mercado.

Por fim, sugerimos considerar a análise cronológica das operações, destacando a importância de avaliar a estratégia em um contexto mais próximo do mundo real. Essa abordagem mais realista pode revelar nuances e desafios que podem não ser evidentes de solução apenas através de análises estatísticas, pois o desenvolvimento e teste de estratégias de negociação são tarefas complexas e dinâmicas. O presente estudo contribuiu para o entendimento dessas estratégias específicas,

mas é essencial que os *traders* estejam cientes da necessidade contínua de adaptação, monitoramento e aprendizado no ambiente de negociação financeira. Este trabalho forneceu uma base sólida para futuras investigações e refinamentos nas estratégias, bem como inspiram uma abordagem cautelosa e informada na implementação prática desses modelos em operações reais.

Agradecimentos

Agradecemos à FAPERGS (23/2551-0000773-8) e CNPq (305805/2021-5) por parcialmente suportarem esse trabalho.

Contribuição dos Autores

Conceitualização, B.L.D., L.R.H.; metodologia, B.L.D., A.R., E.N.B., R.A.B.; implementação, L.R.H.; validação, L.R.H.; investigação, B.L.D., L.R.H., E.N.B.; redação - preparação do rascunho original, B.L.D., L.R.H., A.R., R.A.B.; redação - revisão e edição, B.L.D., L.R.H., A.R., E.N.B., R.A.B.; supervisão, B.L.D.; todos os autores leram e aprovaram o manuscrito final.

Referências

- 1 SALLES, M. C. M. S. Transformação digital em tempos de pandemia. *Revista Estudos e Negócios Academics*, v. 1, n. 1, p. 91–100, 2021.
- 2 LIMA, A. V. D.; FREITAS, E. D. A. A pandemia e os impactos na economia brasileira. *Boletim Economia Empírica*, v. 1, n. 4, 2020.
- 3 NETO, W. C. B.; SALVI, A. d. A.; SOUZA, W. P. d. Hybrid neural networks applied to brazilian stock market. *Revista de Informática Teórica e Aplicada*, v. 27, n. 2, p. 42–65, Apr. 2020. Disponível em: https://seer.ufrgs.br/index.php/rita/article/view/RITA_VOL27_NR2_42.
- 4 SINGH, K.; THAPLIYAL, M.; BARTHWAL, V. A comparative analysis of stock price prediction techniques. In: *2022 7th International Conference on Computing, Communication and Security (ICCCS)*. [S.l.: s.n.], 2022. p. 1–4.
- 5 DALMAZO, B. L.; VILELA, J. P.; CURADO, M. Triple-similarity mechanism for alarm management in the cloud. *Computers & Security*, v. 78, p. 33–42, 2018. ISSN 0167-4048. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0167404818306515>.
- 6 LINDSAY, L. et al. Transparent models for stock market price forecasting. In: *2022 IEEE Symposium Series on Computational Intelligence (SSCI)*. [S.l.: s.n.], 2022. p. 860–866.
- 7 WIIAVA, A. Y.; FATICHAH, C.; SAIKHU, A. Stock price prediction with golden cross and death cross on technical analysis indicators using long short term memory.

- In: *2022 5th International Conference on Information and Communications Technology (ICOIAC)*. [S.l.: s.n.], 2022. p. 278–283.
- 8 HARISH, N. et al. Stock index probability prediction using the fb prophet model. In: *2022 International Conference on Futuristic Technologies (INCOFT)*. [S.l.: s.n.], 2022. p. 1–5.
- 9 KUMAR, A.; CHAUDHRY, M. Review and analysis of stock market data prediction using data mining techniques. In: *2021 5th International Conference on Information Systems and Computer Networks (ISCON)*. [S.l.: s.n.], 2021. p. 1–10.
- 10 ASHOK, A.; PRATHIBHAMOL, C. Improved analysis of stock market prediction: (arima-lstm-smp). In: *2021 4th Biennial International Conference on Nascent Technologies in Engineering (ICNTE)*. [S.l.: s.n.], 2021. p. 1–5.
- 11 DINESH, S. et al. Prediction of trends in stock market using moving averages and machine learning. In: *2021 6th International Conference for Convergence in Technology (I2CT)*. [S.l.: s.n.], 2021. p. 1–5.
- 12 CALDERA, H. A.; LAVANYA, W. P. A. Combinatorial impact of technical indicators on price prediction in colombo stock market. In: *2020 20th International Conference on Advances in ICT for Emerging Regions (ICTer)*. [S.l.: s.n.], 2020. p. 256–261.
- 13 KUMAR, R.; KUMAR, P.; KUMAR, Y. Analysis of financial time series forecasting using deep learning model. In: *2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*. [S.l.: s.n.], 2021. p. 877–881.
- 14 BISWAS, M. et al. Predicting stock market price: A logical strategy using deep learning. In: *2021 IEEE 11th IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE)*. [S.l.: s.n.], 2021. p. 218–223.
- 15 KOUAÏSSAH, N. et al. Theoretical and practical motivations for the use of the moving average rule in the stock market. *IMA Journal of Management Mathematics*, v. 31, n. 1, p. 117–138, 2019.
- 16 AGARWAL, S.; RAJPUT, P.; JENA, A. K. A hybrid evolutionary model for stock price prediction using grey wolf optimizer. In: *2022 OITS International Conference on Information Technology (OCIT)*. [S.l.: s.n.], 2022. p. 1–6.
- 17 RAJESWARI, K. et al. Comparative analysis of various machine learning algorithms for stock price prediction. In: *2022 International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON)*. [S.l.: s.n.], 2022. p. 1–6.
- 18 HOSSAIN, M. R.; ISMAIL, M. T.; KARIM, S. A. B. A. Improving stock price prediction using combining forecasts methods. *IEEE Access*, v. 9, p. 132319–132328, 2021.
- 19 MISHRA, P. et al. Analysis of effect of historical prices and news on the stock market. In: *2021 International Conference on Communication information and Computing Technology (ICCICT)*. [S.l.: s.n.], 2021. p. 1–6.
- 20 KHANPARA, P. et al. Stock trend prediction: A comparative study using different approaches. In: *2023 5th International Conference on Smart Systems and Inventive Technology (ICSSIT)*. [S.l.: s.n.], 2023. p. 1697–1701.
- 21 AITHAL, P. K. et al. A comparative study of deep neural network and statistical models for stock price prediction. In: *2022 3rd International Conference for Emerging Technology (INCET)*. [S.l.: s.n.], 2022. p. 1–5.
- 22 PAVEL, M. I.; MUHTASIM, D. A.; FARUK, O. Decision making process of stock trading implementing drqn and arima. In: *2021 IEEE Madras Section Conference (MASCON)*. [S.l.: s.n.], 2021. p. 1–6.
- 23 SAHAI, H.; AGEEL, M. I. *The analysis of variance: fixed, random and mixed models*. [S.l.]: Springer Science & Business Media, 2012.
- 24 CHOLIL, S. R. et al. Predicting startup success using tree-based machine learning algorithms. *Revista de Informática Teórica e Aplicada*, v. 31, n. 1, p. 50–59, Mar. 2024. Disponível em: <https://seer.ufrgs.br/index.php/rita/article/view/133375>.