

Redução da Subjetividade na Identificação da Variação do Nível de Valores de Ativos Financeiros

José Jeovane R. Cordeiro¹, Arlino Henrique M. de Araújo¹,
Victor Gabriel C. Rodrigues¹, Guilherme A. Avelino¹

¹Universidade Federal do Piauí (UFPI)
Campus Universitário Ministro Petrônio Portella – Bairro Ininga
CEP: 64.049-550 – Teresina – PI

jose.cordeiro@ifma.edu.br, {arlino, victor.gabriel, gaa}@ufpi.edu.br

Abstract. *Support and resistance represent price levels at which buyers and sellers have shown significant interest in an asset. As such, they can help traders and investors make decisions. However, identifying support and resistance can be subjective due to factors such as analyst interpretation, inference, and market psychology. This article proposes an approach to identify support and resistance levels automatically and objectively by applying Machine Learning techniques with minimal human intervention. The results obtained indicate a generalizable solution capable of adapting to different markets, time granularities, and analytical configurations.*

Resumo. *Suporte e resistência representam níveis de preço pelos quais os compradores e vendedores demonstraram interesse significativo em um ativo. Assim, eles podem auxiliar traders e investidores nas tomadas de decisões. Contudo, identificar suporte e resistência pode ser uma tarefa subjetiva devido a fatores como interpretação do analista, inferências e psicologia do mercado. Este artigo propõe uma abordagem para identificar níveis de suporte e resistência de forma automática e objetiva por meio da aplicação de técnicas de Aprendizado de Máquina com o mínimo de intervenção humana. Os resultados obtidos indicam uma solução generalizável capaz de se adaptar a diferentes mercados, granularidades de tempo e configurações analíticas.*

1. Introdução

Suporte e resistência (S/R) são conceitos fundamentais da Análise Técnica (AT) no mercado financeiro, utilizados para identificar níveis de preço nos quais um ativo tende a encontrar obstáculos para continuar subindo (resistência) ou caindo (suporte). Esses níveis representam zonas de intensa disputa entre compradores (*bulls*) e vendedores (*bears*). A força e a duração dessa disputa determinam a relevância e a probabilidade de o preço romper ou ser repellido por esses níveis. Adicionalmente, eles representam zonas de provável reversão ou desaceleração no movimento dos preços de ativos financeiros (*tickers*). Tradicionalmente, esses níveis têm sido representados graficamente por meio de linhas horizontais e diagonais [Yıldırım et al. 2019], conforme ilustrado na Figura 1.

Identificar níveis de preços por meio de S/R pode se tornar uma tarefa subjetiva. Analistas podem traçar níveis de preços de maneiras bastante distintas devido a fatores, como a interpretação utilizada e a representação do tempo adotada no gráfico

[Osler 2000]. Osler destaca essa subjetividade ao afirmar que muitos analistas técnicos utilizam avaliações visuais do desempenho recente dos preços, bem como inferências baseadas no conhecimento do fluxo de ordens e na psicologia do mercado para identificar níveis de preços.

Yıldırım *et al.* destacam que avanços recentes no campo da Inteligência Artificial (IA) e do Aprendizado de Máquina (ML) têm permitido a automação e o aprimoramento da identificação de zonas S/R, possibilitando um mapeamento mais robusto e adaptativo às dinâmicas do mercado. Apesar de os profissionais do mercado financeiro utilizarem com frequência os níveis de S/R, ainda há poucos estudos acadêmicos voltados à sua geração automática. Neste contexto, o presente trabalho propõe um sistema que incorpora múltiplas *features* como entrada para um modelo de ML, voltado à identificação automatizada desses níveis, sendo aplicável a diferentes tipos de ativos financeiros. O código-fonte do sistema proposto está disponível para acesso público no repositório do GitHub¹.

O principal diferencial da abordagem proposta reside na redução da subjetividade que, historicamente, caracteriza a AT tradicional. Chan *et al.* [Chan et al. 2022] ressaltam que tal subjetividade decorre da ausência de uma definição quantitativa formal para os níveis de S/R. Por essa razão, nos métodos convencionais, a identificação desses níveis depende da interpretação do analista, a qual pode variar conforme sua experiência [Yıldırım et al. 2019]. Diante disso, este trabalho propõe uma abordagem para a identificação automatizada de níveis de S/R de forma automatizada e objetiva, com o mínimo de intervenção humana, com base em critérios estatísticos e algoritmos bem definidos. Dessa forma, o sistema proposto provê objetividade, consistência e replicabilidade no processo de análise.

Nesse trabalho, a abordagem é organizada em seções para detalhar o problema e as soluções. A Seção 2 elucida a fundamentação teórica necessária para o entendimento do trabalho. A Seção 3 discute os principais trabalhos relacionados. A Seção 4 apresenta detalhes do sistema proposto. A Seção 5 mostra alguns experimentos feitos para avaliar a solução proposta. Finalmente, na Seção 6, são apresentadas as conclusões, destacando as contribuições do estudo e apontando trabalhos futuros.

2. Referencial Teórico

Essa seção aborda os fundamentos conceituais e tecnológicos que embasam o sistema desenvolvido neste trabalho.

2.1. Suporte e Resistência

A avaliação de um ativo no contexto do mercado financeiro pode ser categorizada, de forma geral, em duas abordagens: análise fundamentalista e análise técnica. A análise fundamentalista dedica-se à exploração minuciosa da situação financeira e econômica de uma empresa ou país. Já a análise técnica concentra-se na investigação retrospectiva de dados históricos, incluindo a variação dos preços do ativo ao longo do tempo e o volume de transações associado [Patel et al. 2015].

Suporte e resistência são conceitos da AT que indicam níveis de preços onde o mercado pode ter dificuldade de subir ou descer. São ferramentas usadas para identificar

¹Repositório: <https://github.com/jeovanereges/SRSBBD2025>

zonas de provável reversão ou desaceleração no movimento dos preços de ativos financeiros. O suporte é um ponto em que a demanda tende a impedir que os preços caiam ainda mais, ou seja, é quando se espera que a pressão compradora seja suficientemente forte para superar a pressão de venda. A resistência representa um patamar no qual a oferta é suficiente para conter os avanços de preço [Edwards et al. 2018, Osler 2000].

Segundo Evens [Evens 1999], quando um nível atuou como S/R no passado, há uma grande probabilidade de que volte a desempenhar esse papel no futuro. A significância e a confiabilidade futura de uma linha de S/R estão diretamente relacionadas ao número de vezes em que os preços tocam essa linha e, em seguida, reverterem. Esses níveis podem ser horizontais ou diagonais, conforme representado na Figura 1.



Figura 1. Ilustração de Níveis de S/R – TradingView.

A imagem apresentada na Figura 1 ilustra um gráfico de velas (*candlestick*) do par BTC/USD (Bitcoin *versus* Dólar Americano), com periodicidade diária, capturado na plataforma *online* TradingView² [TradingView 2025]. O gráfico abrange o período de março a julho de 2024, permitindo a observação da evolução do preço do ativo ao longo do tempo. As velas em azul representam *candlesticks* de alta, indicando que o preço de fechamento foi superior ao de abertura. Por outro lado, as velas em vermelho indicam *candlesticks* de baixa, ou seja, o preço de fechamento foi inferior ao valor de abertura. Por exemplo, a primeira vela do gráfico abriu em aproximadamente 57.000 dólares, enquanto seu fechamento ocorreu em torno de 62.000 dólares, caracterizando-se, portanto, como um *candlestick* de alta. Já a segunda vela corresponde a um *candlestick* de baixa, uma vez que o preço de abertura foi de cerca de 62.000 dólares e o fechamento, de aproximadamente 61.000 dólares.

Os níveis S/R da Figura 1 são estabelecidos em relação à cotação atual do ativo cujo valor está em 64.233 dólares (no quadro branco à direita). A resistência está destacada por uma linha horizontal em tom vermelho, posicionada no nível de preço de 72.000 dólares. Em três ocasiões, quando o preço atingiu essa zona – cujas máximas foram de

²Ferramenta amplamente utilizada para acesso a dados históricos de mercado, como preços de ações e gráficos de índices, sendo especialmente útil para fins de estudo e análise técnica.

aproximadamente 72.750, 71.500 e 71.750 dólares – observou-se uma reversão do movimento de alta, evidenciando a presença de uma pressão vendedora significativa, capaz de conter o avanço dos preços. Já o suporte está destacado por uma linha horizontal em tom azul, posicionada no nível de preço de 61.000 dólares. Em três situações, quando o preço invadiu essa região – com mínimas em aproximadamente 59.670, 59.630 e 60.170 dólares – ocorreram interrupções nos movimentos de baixa, o que revela a presença de uma pressão compradora significativa, responsável por conter a queda dos preços e favorecer possíveis reversões de tendência.

Na prática convencional da análise técnica, a identificação dos níveis de S/R é frequentemente realizada de forma empírica, com base na observação visual de gráficos de *candlestick*. Essa prática está sujeita a elevada subjetividade, tanto na escolha dos pontos considerados relevantes quanto na contagem ou agrupamento das ocorrências. Fatores como o intervalo de tempo do gráfico, a granularidade dos dados e a própria experiência – ou viés – do analista influenciam diretamente a determinação desses níveis. Tais limitações motivam o desenvolvimento de abordagens automatizadas capazes de reduzir a influência de julgamentos subjetivos no mapeamento das zonas críticas de negociação.

2.2. Aprendizagem de Máquina

Machine Learning é um ramo da Inteligência Artificial, cujo aspecto central reside na capacidade dos algoritmos de aprender padrões e relações complexas a partir dos dados, sem a necessidade de serem explicitamente programados para tal [Li et al. 2022, Ju and Chen 2022]. Essa técnica tem ganhado destaque em diversas áreas do conhecimento, tais como: reconhecimento de imagens, análise de vídeo, detecção de objetos, previsão de séries temporais financeiras, previsão do tempo e *marketing*.

No campo do *trading* (negociação), o ML também tem ganhado notoriedade, uma vez que oferece ferramentas poderosas para análise, previsão e desenvolvimento de estratégias de negociação algorítmica [Rahimpour et al. 2024, Teja and Liu 2023]. Nesse contexto, modelos de IA como Redes Neurais Artificiais (ANN), Aprendizado por Reforço Profundo (DRL), Redes Neurais Recorrentes (RNN), Redes Neurais Convolucionais (CNN), *Transformers*, Modelos Baseados em Regressão, Modelos Baseados em Detecção de Anomalias, Clusterização, dentre outros, são frequentemente empregados para identificar padrões e desenvolver estratégias de negociação automatizadas.

2.2.1. Isolation Forest

O *Isolation Forest* é um algoritmo de aprendizado de máquina não supervisionado, amplamente utilizado para a detecção de anomalias [Deepika et al. 2024]. Diferentemente dos métodos tradicionais, como o Intervalo Interquartil (IQR), que buscam modelar o comportamento normal dos dados, o *Isolation Forest* atua isolando diretamente as anomalias, o que o torna eficiente na identificação de pontos atípicos. Seu funcionamento baseia-se na construção de uma floresta de isolamento composta por múltiplas árvores de isolamento (*iTrees*), nas quais as anomalias tendem a apresentar caminhos mais curtos desde o nó raiz até as folhas, por serem mais facilmente isoladas [Zhang et al. 2024].

De acordo com Zhang et al., o *Isolation Forest* é particularmente eficiente para dados de alta dimensão e faz poucas suposições sobre a distribuição dos dados, sendo também computacionalmente eficiente e rápido na detecção de anomalias. Além disso,

o algoritmo pode ser empregado para a remoção de *outliers* em conjuntos de dados, mostrando-se especialmente útil no contexto do mercado financeiro, onde dados rotulados como “anormais” são raros ou inexistentes. Nesses casos, algoritmos não supervisionados são particularmente eficazes para identificar padrões incomuns sem a necessidade de conhecimento prévio sobre o que caracteriza uma anomalia [Zhang et al. 2024].

2.2.2. K-Means

O algoritmo *K-Means* é uma técnica de agrupamento por similaridade, não supervisionada, amplamente utilizada em diversas áreas, devido à sua simplicidade, eficiência e aplicabilidade a diferentes tipos de dados [Silva and Razente 2024]. Seu objetivo principal é particionar um conjunto de dados em um número predefinido k de grupos, denominados *clusters*, de modo que os pontos de dados dentro de cada *cluster* sejam mais semelhantes entre si do que em relação aos pontos pertencentes a outros *clusters* [Kumari et al. 2020]. A escolha do número ideal de *clusters* (k) é uma etapa crucial no processo de agrupamento, sendo comumente auxiliada por métodos como o método do cotovelo (*Elbow Method*) e o método da silhueta (*Silhouette Method*), amplamente utilizados para essa finalidade [Kedia et al. 2018]. Em razão dessas características, Aqsari et al. [Aqsari et al. 2022] defendem que essa abordagem é adequada para dados de séries temporais de preços, devido à sua capacidade de alinhar sequências não lineares.

3. Trabalhos Relacionados

Yıldırım et al. desenvolveram um modelo para gerar automaticamente linhas de S/R através de um algoritmo de otimização evolutiva. Os autores reconhecem que os resultados preliminares indicaram que o uso isolado dessas linhas não apresentou melhorias significativas. Embora os autores pudessem utilizar a ferramenta *irace*³ para automatizar o processo de seleção dos parâmetros, esta não foi adotada. Assim, uma limitação deste estudo reside na necessidade de definir manualmente os parâmetros do algoritmo *Particle Swarm Optimization* (PSO), o que introduz um grau de subjetividade no processo, uma vez que essas escolhas impactam diretamente os resultados da otimização e, consequentemente, a construção das linhas de S/R [Yıldırım et al. 2019].

Osler realizou um estudo sobre níveis de suporte e resistência fornecidos por grandes instituições de negociação cambial, comparando-os com níveis artificiais gerados por um método mecânico. O estudo constatou que os níveis de S/R apresentavam poder preditivo sobre os movimentos de preços *intraday*⁴. No entanto, verificou-se que os níveis com maior concordância entre as instituições não eram, necessariamente, os mais fortes. Uma limitação relevante do estudo reside no fato de que a identificação dos níveis de S/R baseia-se nas práticas adotadas por analistas técnicos e nas informações por eles utilizadas, o que introduz um grau de subjetividade ao processo e compromete a replicabilidade e a consistência dos resultados [Osler 2000].

Chan et al. propuseram uma abordagem determinística baseada na identificação de *swing highs* e *swing lows*, caracterizados como pontos extremos identificados em um gráfico de preços. O estudo propõe um algoritmo inspirado no indicador ZigZag para

³Ferramenta *irace*: <https://mlopez-ibanez.github.io/irace/>

⁴Variações ocorridas dentro do horário de funcionamento do mercado em um único dia.

identificar esses pontos de forma sistemática e automatizada, seguido da aplicação de engenharia de *features* derivadas da distância entre o preço atual e os níveis de S/R mais próximos. A inclusão dessas *features* em modelos de Aprendizado Profundo (DL) demonstrou ganhos expressivos em precisão e lucratividade, destacando a importância dos níveis de S/R como variáveis preditoras no contexto do *trading* algorítmico. No entanto, uma limitação da abordagem reside na subjetividade associada à configuração dos parâmetros do indicador ZigZag, os quais podem variar de acordo com as características específicas de preço e volatilidade de cada ativo, impactando negativamente a capacidade de generalização e a replicabilidade do modelo [Chan et al. 2022].

Os trabalhos apresentados nessa seção exploraram a aplicação isolada de otimização evolutiva, a análise de níveis publicados ou o uso de indicadores em modelos preditivos. O presente trabalho propõe um sistema unificado, adaptável e fundamentado em dados, com a expectativa de superar as limitações individuais das abordagens anteriores. A metodologia proposta não apenas promove maior objetividade, como também amplia sua aplicabilidade a diferentes ativos financeiros e contextos operacionais, contribuindo de forma significativa para o avanço dos sistemas de apoio à decisão no mercado financeiro.

4. Uma Proposta para Redução da Subjetividade de S/R

Nessa seção são apresentadas as etapas utilizadas na implementação do sistema proposto: coleta de dados, configuração do sistema, pré-processamento e identificação de S/R.

4.1. Coleta de Dados

O sistema proposto permite coletar automaticamente dados históricos de diversos ativos financeiros em *timeframes* definidos. Para cada ativo, são coletadas as informações de data/hora, preço de abertura, preço máximo, preço mínimo, preço de fechamento e volume de negociação. Para isso, o sistema utiliza a biblioteca *yfinance*, que permite o acesso a dados históricos do mercado financeiro por meio da API da plataforma *Yahoo Finance*. Essa plataforma é *online* e bastante popular entre investidores e entusiastas de finanças [Bagul et al. 2022]. Além disso, ela fornece informações sobre cotações de ações, notícias de mercado, relatórios financeiros, entre outros, e também ferramentas para gestão de finanças. A biblioteca *yfinance* permite o acesso a ativos como Apple Inc. (AAPL), Microsoft Corporation (MSFT), Alphabet Inc. (GOOG), Amazon.com Inc. (AMZN) e Meta Platforms Inc. (FB). Ela contém um grande número de *tickers*, incluindo ações (106.332), ETFs (21.196), futuros (9.294), índices (80.017), fundos mútuos (24.926) e pares de moedas (4.019) [Bagul et al. 2022].

4.2. Features Utilizadas

A escolha adequada das variáveis preditivas pode influenciar significativamente na capacidade do modelo de identificar padrões relevantes e gerar *insights* valiosos [Chinprasatsak et al. 2020]. Para o desenvolvimento do sistema proposto, além dos dados históricos de movimentação financeira mencionados na Seção 4.1, foram consideradas as seguintes *features*: (i) o indicador *Relative Strength Index* (RSI), (ii) padrões de *candlestick* e (iii) variações diárias nos preços e volumes.

Desenvolvido por J. Welles Wilder Jr., o indicador RSI mede a magnitude das recentes mudanças de preço para avaliar condições de sobrecompra ou sobrevenda de

um determinado ativo. O indicador RSI também apresenta as seguintes capacidades: (a) identificar potenciais pontos de reversão de tendência, (b) medir a força do *momentum*, (c) adaptar-se a diferentes períodos e (d) ser amplamente utilizado e estudado [Chen et al. 2021]. Essas características foram determinantes para sua escolha definitiva como uma das *features* do modelo. Além do RSI, outros indicadores amplamente utilizados na análise técnica também foram testados, tais como o CCI, as Médias Móveis, o MACD e o Oscilador Estocástico. Esses indicadores foram avaliados tanto de forma isolada quanto combinada. Porém, eles não atingiram os resultados esperados, uma vez que reduziram a frequência com que os níveis de S/R eram respeitados, ou seja, os preços deixaram de reagir conforme o esperado ao se aproximarem dessas regiões, ultrapassando-as sem apresentar sinais de reversão ou consolidação. A fórmula geral para o cálculo do RSI está ilustrada na Equação 1. A variável *RS* (*Relative Strength*) representa a razão entre a média dos ganhos e a média das perdas ao longo de um determinado período *n* [Cocco et al. 2019]. Nesse contexto, *n* corresponde ao número de unidades temporais consideradas (por exemplo, dias, caso o *timeframe* seja diário).

$$RSI(n) = 100 - \left[\frac{100}{1 + RS(n)} \right] \quad (1)$$

A inclusão de padrões de *candlestick* como *features* permite que o modelo capture informações visuais relevantes sobre a dinâmica do mercado [Noertjahyana et al. 2019]. O padrão escolhido como *feature* para o modelo foi o Marubozu, que é calculado a partir dos dados de cada *candlestick* da amostra. Esse padrão é identificado como um Marubozu de alta quando o preço mínimo é igual ou próximo do preço de abertura e o preço máximo é igual ou próximo ao preço de fechamento. Por outro lado, um Marubozu de baixa é identificado quando o preço máximo é igual ou próximo do preço de abertura e o preço mínimo é igual ou próximo ao preço de fechamento. Este padrão apresenta ainda as seguintes características: (a) indica forte pressão compradora ou vendedora, (b) representa um potencial sinal de continuação de tendência e (c) trata-se de um padrão visual claro e facilmente identificável. Portanto, a sua escolha não apenas se justifica por suas propriedades técnicas, mas também pela sua robustez e facilidade de identificação. Outros padrões de *candlestick* amplamente reconhecidos na literatura de análise técnica também foram investigados, como Estrela Cadente, Engolfo e Martelo. Contudo, testes empíricos, utilizando esses padrões, mostraram uma deterioração nos resultados.

4.3. Pré-processamento

A detecção de *outliers* em séries temporais de preço e volume é fundamental para garantir a qualidade dos dados e a robustez do modelo, uma vez que *outliers* – que representam observações atípicas ou anormais – podem distorcer a análise e levar a conclusões equivocadas [Öner et al. 2024]. Segundo Mao et al. [Mao et al. 2024], as vantagens de incorporar a detecção de *outliers* como uma etapa de pré-processamento incluem: (a) melhorar a precisão do modelo, (b) aumentar a confiabilidade dos dados e (c) identificar potenciais anomalias.

A etapa de pré-processamento dos dados é fundamental para garantir a qualidade das entradas utilizadas pelos algoritmos de ML. Segundo Temur et al., a análise do padrão das variações diárias de preço e volume, quando livre de distorções, fornece informações

diretas sobre a atividade e o sentimento do mercado em cada sessão de negociação [Temür et al. 2024]. No sistema proposto, o algoritmo *Isolation Forest* (Seção 2.2.1) foi empregado com o objetivo de identificar e tratar *outliers* presentes nos retornos de preço e volume.

Inicialmente, os dados de entrada correspondem às séries temporais dos preços de fechamento e dos volumes de negociação do ativo selecionado. Esses dados são utilizados para calcular os retornos percentuais diários, que, então, são submetidos ao algoritmo *Isolation Forest*. O modelo é treinado de forma não supervisionada para isolar observações atípicas – retornos ou volumes que se desviam significativamente do comportamento padrão da série.

A saída do *Isolation Forest* é um conjunto de rótulos binários atribuídos a cada observação, indicando se ela foi classificada como normal ou como *outlier*. A Figura 2 apresenta os resultados de sua aplicação aos dados de retornos do Bitcoin (BTC/USD), no período de junho de 2024 a abril de 2025, considerando o tempo gráfico de uma hora. As linhas azuis representam os retornos percentuais, enquanto os pontos vermelhos indicam as observações identificadas como *outliers*. O maior *outlier*, que resultou em lucros, foi detectado em abril de 2025 quando o preço atingido por um dos *candles* gerou um lucro 100% superior ao do anterior. Já o *outlier* que resultou na maior perda ocorreu em março de 2025 quando um dos *candles* apresentou uma perda 100% maior do que a do *candle* anterior.




Figura 2. Detecção de Outliers.

A saída do *Isolation Forest* pode ser incorporada ao sistema de duas maneiras: (i) como uma *feature* adicional no modelo de identificação de níveis de suporte e resistência, possibilitando que o algoritmo considere a ocorrência de eventos anômalos; e (ii) como critério de filtragem para análises específicas em que se opta por utilizar apenas dados “limpos”, mediante a exclusão dos *outliers*.

Dessa forma, o pré-processamento não apenas aprimora a robustez do sistema, mas também confere maior flexibilidade analítica, possibilitando testes e comparações entre resultados obtidos com e sem a presença de anomalias. Além disso, a identificação de *outliers* contribui para mitigar o impacto de eventos extremos, assegurando que a geração dos níveis de S/R seja mais representativa do comportamento típico do mercado.

4.4. Identificação de S/R

Após a etapa de pré-processamento, o sistema emprega as *features* selecionadas – histórico da movimentação financeira, RSI, padrões de *candlestick* (Marubozu), informações das variações diárias de preço e volume – como insumos para a identificação automatizada dos níveis de S/R de um ativo.

O processo é realizado em duas etapas principais: a clusterização dos dados e a extração dos níveis de S/R. Inicialmente, o algoritmo *K-Means* (Seção 2.2.2) é aplicado para agrupar observações semelhantes com base nas *features* selecionadas. O número de clusters (k) é determinado por meio do método do coeficiente de silhueta, visando alcançar um equilíbrio entre a segmentação detalhada dos dados e a generalização dos padrões de comportamento. Cada *cluster* resultante representa uma região caracterizada por comportamentos estatisticamente similares, em que o valor mais representativo (a moda) contido em cada *cluster* é interpretado como um potencial nível de S/R.

A utilização de múltiplas *features* para a definição dos *clusters* permite ao sistema captar nuances do comportamento do mercado que vão além da simples análise gráfica. Por exemplo, a combinação de um RSI indicando sobrecompra, a presença de um padrão Marubozu de baixa e um aumento anômalo no volume pode reforçar a identificação de uma resistência robusta. Essa metodologia assegura que os níveis de S/R identificados sejam embasados em evidências quantitativas extraídas diretamente dos dados históricos, conferindo ao processo analítico maior objetividade, precisão e capacidade de generalização.

5. Experimentos

Para validar a viabilidade e a eficácia do sistema proposto, foram conduzidos experimentos com dados de dois ativos distintos e amplamente conhecidos: Bitcoin (BTC/USD) e o Índice Bovespa (B3).

5.1. Configurações dos Testes

Para o par BTC/USD, foram coletados dados históricos entre junho de 2024 e abril de 2025, considerando um *timeframe* de 1 hora. Para o índice Bovespa, os dados cobriram o período de janeiro de 2020 a abril de 2025, com *timeframe* diário. Em ambos os experimentos, optou-se por testá-los em dois cenários distintos: (a) com a aplicação dos padrões de *candlestick*, a consideração dos níveis de RSI e a remoção dos *outliers*; e (b) desconsiderando a aplicação dos padrões de *candlestick*, os níveis de RSI e a remoção dos *outliers*.

5.2. Resultados Obtidos

A Figura 3 ilustra os níveis de S/R identificados no experimento do ativo BTC/USD, utilizando o cenário (a) descrito na Seção 5.1. A Figura 2 representa os *outliers* encontrados na etapa de pré-processamento do experimento. Esse experimento identificou 14 níveis, sendo 9 de suporte e 5 de resistência, cada um associado a um valor específico de preço e à frequência com que foi detectado durante o período analisado. Por exemplo, o nível mais frequente foi detectado no valor de 60.938,00 com 237 ocorrências. Os S/R foram calculados em relação ao valor 94.201,05, que era o preço atual do ativo. Esse resultado

sugere que esse ponto se trata de uma zona de congestão de preços, caracterizada por significativa atuação de compradores e vendedores.



Figura 3. Plotagem de S/R do BTC com Filtros.

A Figura 4 apresenta os níveis de S/R identificados no experimento com o ativo BTC/USD, obtidos a partir do cenário (b), descrito na Seção 5.1. Nesse experimento, foram identificados seis níveis – cinco de suporte e um de resistência –, o que permite observar como a ausência desses tratamentos influencia a definição dos níveis críticos do mercado. Os S/R foram calculados em relação ao valor 94.201,05, que era o preço atual do ativo. Como observado, o experimento da Figura 3 revelou uma quantidade maior de níveis distintos, permitindo uma segmentação mais refinada e informativa da estrutura de preços.



Figura 4. S/R do BTC sem Filtros.

As Figuras 5a e 5b apresentam a plotagem dos níveis de S/R para o índice Bovespa cujo valor do ativo era de 135.067,00. A Figura 5a apresenta a plotagem dos níveis de S/R considerando todos os filtros aplicados no experimento. Observa-se uma distribuição mais rica de níveis – oito no total – ao longo da série, inclusive em regiões mais próximas

da cotação atual do ativo, o que sugere uma análise mais sensível e refinada das zonas de negociação. Na Figura 5b, todos os dados foram utilizados sem a aplicação de qualquer filtro. Nesse teste, observou-se uma redução no número total de níveis detectados – apenas sete –, com concentrações em pontos intermediários e omissão de níveis relevantes que foram identificados no experimento da Figura 5a. Em ambas as abordagens, o nível com maior número de ocorrências foi em 127.359,00 pontos, totalizando 47 registros.

S/R	Pontos	S/R	Pontos
Suporte	79063.0 (8)	Suporte	79063.0 (8)
Suporte	100457.0 (21)	Suporte	100457.0 (21)
Suporte	110785.0 (28)	Suporte	110048.0 (36)
Suporte	115950.0 (35)	Suporte	110785.0 (28)
Suporte	118901.0 (39)	Suporte	118163.0 (35)
Suporte	126278.0 (36)	Suporte	118901.0 (39)
Suporte	127016.0 (33)	Suporte	127753.0 (47)
Suporte	127753.0 (47)		

(a) Plotagem de S/R da B3 com Filtros. (b) Plotagem de S/R da B3 sem Filtros.

Figura 5. Resultado dos Experimentos para o ativo B3.

A ausência de níveis explícitos de resistência nas Figuras 5a e 5b pode ser compreendida à luz da metodologia adotada para a identificação dos pontos críticos do mercado. Embora possam ter existido regiões com comportamento compatível com zonas de resistência, os valores associados a essas regiões não corresponderam à moda dos respectivos *clusters* formados pelo algoritmo K-Means. Como consequência, tais valores foram considerados estatisticamente menos representativos dentro do conjunto de observações agrupadas, não sendo, portanto, selecionados. Esse resultado evidencia uma das vantagens da abordagem proposta: a priorização de evidências quantitativas extraídas diretamente dos dados históricos, em detrimento de interpretações visuais subjetivas, o que contribui para maior objetividade na definição dos níveis mais relevantes para a tomada de decisão.

Para reforçar a aplicabilidade do sistema proposto, foram realizados outros experimentos. A Figura 6 apresenta os níveis de S/R, no período diário e sem a aplicação de qualquer filtro, para os seguintes ativos: Vale, Petrobras, S&P 500 e Ethereum. Os valores entre parênteses, apresentados abaixo de cada tabela na Figura 6, correspondem ao *ticker* de cada ativo analisado. Para o ativo da Vale, foi considerado o período de janeiro de 2022 até o final de junho de 2025. Para os demais ativos, adotou-se o período de janeiro de 2024 até o final de junho de 2025. Esse recorte temporal foi escolhido por representar uma faixa em que os preços estavam mais próximos dos valores atuais, sendo: Vale cotada a R\$ 52,87; Petrobras a R\$ 31,21; S&P 500 a 6.173,07 pontos; e Ethereum a US\$ 2.500,96.

S/R	Preço	S/R	Preço	S/R	Preço	S/R	Preço
Suporte	49.20	Suporte	29.17	Suporte	4739.15	Suporte	1793.68
Suporte	50.48	Suporte	29.32	Suporte	4742.86	Suporte	1799.12
Suporte	51.52	Suporte	29.36	Suporte	5187.73	Suporte	2267.84
Suporte	51.85	Suporte	29.40	Suporte	5303.22	Suporte	2268.62
Suporte	52.56	Suporte	29.89	Suporte	5396.59	Resistência	2536.31
Resistência	54.86	Resistência	34.46	Suporte	5528.70	Resistência	3505.13
Vale S.A. (VALE3.SA)		Petrobras (PETR4.SA)		S&P 500 (^GSPC)		Ethereum (ETH-USD)	

Figura 6. Outros Resultados de S/R.

5.3. Ambiente dos Experimentos

A máquina usada nos experimentos rodava Ubuntu 22.04 com kernel 6.2.0-37-generic, processador Intel i7-10700K (3.80GHz, 16 núcleos) e 128 GB de RAM (2133 MT/s). Embora essa informação seja relevante, vale salientar que o protótipo não demanda alto poder computacional e que os testes realizados não envolvem avaliação de desempenho.

5.4. Ameaças à Validade

A principal ameaça à validade dos experimentos está relacionada à dependência da escolha das variáveis preditivas (*features*) e dos parâmetros adotados no modelo. Especificamente, a definição do número de *clusters* no algoritmo K-Means, embora orientada pelo coeficiente de silhueta, pode não refletir, de forma ideal, a complexidade dos dados em determinados contextos, o que pode impactar a generalização dos resultados.

6. Conclusão e Trabalhos Futuros

Este trabalho apresentou uma abordagem para identificação automatizada de níveis de S/R em ativos financeiros, utilizando técnicas de ML com o objetivo de reduzir a subjetividade inerente à análise técnica tradicional. Ao integrar múltiplas *features*, bem como algoritmos avançados, o sistema proposto demonstrou elevada capacidade de generalização e robustez diante de diferentes ativos, períodos e configurações operacionais.

Com base nos testes realizados, observa-se que a aplicação de filtros técnicos exerce impacto direto na qualidade da identificação dos níveis de S/R, tanto no mercado de criptomoedas quanto no mercado tradicional. Além disso, é possível concluir que o sistema proposto é capaz de identificar com precisão os níveis de S/R, independentemente do ativo analisado, dos filtros aplicados ou do período gráfico considerado.

A principal contribuição desta pesquisa reside na proposta de um sistema unificado, adaptativo e parametrizável, que torna o processo de mapeamento de níveis de S/R mais objetivo, transparente e replicável. Os resultados obtidos evidenciam a aplicabilidade da solução em contextos distintos, reforçando seu potencial como ferramenta de apoio à tomada de decisão em ambientes de negociação automatizada.

Como proposta de trabalho futuro, destaca-se a possibilidade de incorporar métodos de aprendizado supervisionado para validar os níveis de S/R gerados, com base em dados históricos de reversões confirmadas. Recomenda-se, ainda, a exploração de visualizações interativas e de técnicas de explicabilidade de modelos, com o objetivo de aumentar a confiança dos usuários quanto aos níveis de suporte e resistência identificados.

Referências

- [Aqsari et al. 2022] Aqsari, H. W., Prastyo, D. D., and Puteri Rahayu, S. (2022). Clustering stock prices of financial sector using k-means clustering with dynamic time warping. In *2022 6th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*.
- [Bagul et al. 2022] Bagul, J., Warkhade, P., Gangwal, T., and Mangaonkar, N. (2022). Arima vs lstm algorithm – a comparative study based on stock market prediction. In *2022 5th International Conference on Advances in Science and Technology (ICAST)*.
- [Chan et al. 2022] Chan, J. Y.-L., Phoong, S. W., Cheng, W. K., and Chen, Y.-L. (2022). Support resistance levels towards profitability in intelligent algorithmic trading models. *Mathematics*, 10(20).
- [Chen et al. 2021] Chen, Y., Huang, L.-E., Wang, P.-H., Tang, J.-H., Hsu, K.-N., Chou, Y.-H., and Kuo, S.-Y. (2021). A dynamic stock trading system using gnqts and rsi in the u.s. stock market. In *2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*.
- [Chinprasatsak et al. 2020] Chinprasatsak, K., Niparnan, N., and Sudsang, A. (2020). Neural network for forecasting high price and low price on foreign exchange market. In *2020 17th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*.
- [Cocco et al. 2019] Cocco, L., Tonelli, R., and Marchesi, M. (2019). An agent-based artificial market model for studying the bitcoin trading. *IEEE Access*.
- [Deepika et al. 2024] Deepika, D., Pogiri, D., Pandravisham, L. R., Prudvi, Y. K., and Ramannagari, S. R. (2024). Anomaly network traffic detection of wireless network system. In *2024 5th International Conference on Electronics and Sustainable Communication Systems (ICESC)*.
- [Edwards et al. 2018] Edwards, R. D., Magee, J., and Bassetti, W. C. (2018). *Technical analysis of stock trends*. CRC press.
- [Evens 1999] Evens, S. (1999). Support and resistance. *TECHNICAL ANALYSIS OF STOCKS AND COMMODITIES-MAGAZINE EDITION-*.
- [Ju and Chen 2022] Ju, C.-B. and Chen, A.-P. (2022). Identifying financial market trend reversal behavior with structures of price activities based on deep learning methods. *IEEE Access*.
- [Kedia et al. 2018] Kedia, V., Khalid, Z., Goswami, S., Sharma, N., and Suryawanshi, K. (2018). Portfolio generation for indian stock markets using unsupervised machine learning. In *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*.
- [Kumari et al. 2020] Kumari, S., Patil, N., Nankar, P., and Kulkarni, M. (2020). Cuda parallel computing framework for stock market prediction using k-means clustering. In *2020 International Conference on Smart Electronics and Communication (ICOSEC)*.
- [Li et al. 2022] Li, Y., Liu, P., and Wang, Z. (2022). Stock trading strategies based on deep reinforcement learning. *Scientific Programming*, 2022.
- [Mao et al. 2024] Mao, B., Cao, Y., and Li, B. (2024). Grain price prediction model based on timef-iforest-transformer. In *2024 Twelfth International Conference on Advanced Cloud and Big Data (CBD)*.
- [Noertjahyana et al. 2019] Noertjahyana, A., Noertjahyana, A., Abas, Z. A., and Yusoh, Z. I. M. (2019). Combination of candlestick pattern and stochastic to detect trend rever-

- sal in forex market. In *2019 4th Technology Innovation Management and Engineering Science International Conference (TIMES-iCON)*.
- [Osler 2000] Osler, C. L. (2000). Support for resistance: technical analysis and intraday exchange rates. *Economic Policy Review*.
- [Patel et al. 2015] Patel, J., Shah, S., Thakkar, P., and Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert systems with applications*.
- [Rahimpour et al. 2024] Rahimpour, S. M., Goudarzi, R., Shahparifard, V., and Mirpoorian, S. N. (2024). Algorithmic trading using technical indicators and extreme gradient boosting. In *2024 11th IEEE Swiss Conference on Data Science (SDS)*.
- [Silva and Razente 2024] Silva, A. P. and Razente, H. (2024). Desempenho de operações distribuídas de agrupamento por similaridade em dados de alta dimensionalidade por meio da vp-tree. In *Anais do XXXIX Simpósio Brasileiro de Bancos de Dados*.
- [Teja and Liu 2023] Teja, K. R. and Liu, C.-M. (2023). Trade ease with machine learning and aws. *IEEE Access*.
- [Temür et al. 2024] Temür, G., Birogul, S., and Kose, U. (2024). Comparison of stock “trading” decision support systems based on object recognition algorithms on candlestick charts. *IEEE Access*.
- [TradingView 2025] TradingView (2025). Tradingview – gráficos de ações, cripto e forex. Acessado em: 24 abr. 2025.
- [Yıldırım et al. 2019] Yıldırım, E. O., Uçar, M., and Özbayoğlu, A. M. (2019). Evolutionary optimized stock support-resistance line detection for algorithmic trading systems. In *2019 1st International Informatics and Software Engineering Conference (UBMYK)*.
- [Zhang et al. 2024] Zhang, Y., Li, Z., Su, Y., Li, J., and Chen, S. (2024). A novel method for bitcoin price manipulation identification based on graph representation learning. *IEEE Transactions on Computational Social Systems*.
- [Öner et al. 2024] Öner, S. C., Şahan, H., Demirdağ, M., and Bayrak, A. T. (2024). Anomaly detection in stock market transactions: A comparison of deep learning methods. In *2024 32nd Signal Processing and Communications Applications Conference (SIU)*.