

Inteligência computacional no mercado financeiro: uma revisão de técnicas para automação de operações

Computational intelligence in the financial market: a review of techniques for automating operations

Inteligencia computacional en el mercado financiero: una revisión de técnicas para la automatización de operaciones

Recebido: 10/05/2023 | Revisado: 17/05/2023 | Aceitado: 17/05/2023 | Publicado: 21/05/2023

Guilherme Francisco Lima Sobrinho

ORCID: <https://orcid.org/0009-0008-8658-3484>

Universidade Federal de Alagoas, Brasil

E-mail: x.guilima@gmail.com

Rodolfo Carneiro Cavalcante

ORCID: <https://orcid.org/0000-0003-0134-1387>

Universidade Federal de Alagoas, Brasil

E-mail: rodolfo.cavalcante@arapiraca.ufal.br

Resumo

O campo de aplicações financeiras tem se tornado cada vez mais complexo e desafiador, com comportamentos não lineares e incertos que mudam com o tempo. Diante disso, as técnicas de inteligência computacional, incluindo redes neurais, algoritmos genéticos e lógica difusa, têm ganhado destaque como soluções promissoras para a automatização de decisões no mercado financeiro. Este artigo tem como objetivo explorar os estudos recentes que abordam o uso dessas técnicas e discutir suas aplicações, vantagens e limitações. Trata-se de uma revisão de literatura narrativa, de caráter descritivo exploratório. A coleta de literatura foi realizada nas bases de dados Science Direct e Scopus, utilizando palavras-chave relacionadas ao tema. Conclui-se que as técnicas de inteligência computacional têm se mostrado capazes de resolver problemas altamente não lineares e variantes no tempo, tornando-se assim uma abordagem eficaz para automatizar operações no mercado financeiro.

Palavras-chave: Aprendizado de máquina; Redes neurais artificiais; Algoritmos genéticos; Lógica difusa.

Abstract

The field of financial applications has become increasingly complex and challenging, with non-linear and uncertain behaviors that change over time. Therefore, computational intelligence techniques, including neural networks, genetic algorithms and fuzzy logic, have gained prominence as promising solutions for automating decisions in the financial market. This article aims to explore recent studies that address the use of these techniques and discuss their applications, advantages and limitations. This is a narrative literature review, with an exploratory descriptive character. Literature collection was carried out in the Science Direct and Scopus databases, using keywords related to the theme. It is concluded that computational intelligence techniques have been shown to be capable of solving highly non-linear and time-varying problems, thus becoming an effective approach to automate operations in the financial market.

Keywords: Machine learning; Artificial neural networks; Genetic algorithms; Fuzzy logic.

Resumen

El campo de las aplicaciones financieras se ha vuelto cada vez más complejo y desafiante, con comportamientos no lineales e inciertos que cambian con el tiempo. Por lo tanto, las técnicas de inteligencia computacional, incluidas las redes neuronales, los algoritmos genéticos y la lógica difusa, han ganado protagonismo como soluciones prometedoras para la automatización de decisiones en el mercado financiero. Este artículo tiene como objetivo explorar estudios recientes que abordan el uso de estas técnicas y discutir sus aplicaciones, ventajas y limitaciones. Se trata de una revisión de literatura narrativa, de carácter descriptivo exploratorio. La recolección de literatura se realizó en las bases de datos Science Direct y Scopus, utilizando palabras clave relacionadas con el tema. Se concluye que las técnicas de inteligencia computacional han demostrado ser capaces de resolver problemas altamente no lineales y variables en el tiempo, convirtiéndose así en un enfoque efectivo para automatizar operaciones en el mercado financiero.

Palabras clave: Aprendizaje automático; Redes neuronales artificiales; Algoritmos genéticos; Lógica difusa.

1. Introdução

O mercado financeiro é um ambiente extremamente complexo e volátil, caracterizado pela presença de uma vasta quantidade de informações, variáveis e incertezas, além de ser influenciado por diversos fatores econômicos, sociais e políticos (Qiu et al., 2020). Eles englobam uma variedade de mercados, incluindo o mercado de valores mobiliários, mercado de commodities e o emergente mercado de criptomoedas (Bahadur et al. 2019). A negociação nessas áreas requer uma compreensão detalhada da dinâmica de mercado e a capacidade de reagir rapidamente a mudanças nas condições do mercado. Para investidores e operadores financeiros, tomar decisões eficazes pode ser um verdadeiro desafio, considerando a grande quantidade de informações envolvidas.

Os avanços na tecnologia de inteligência artificial (IA) nas últimas décadas têm sido significativos e impactantes em várias áreas. Desde o início dos anos 2010, houve um rápido crescimento no campo de pesquisa em IA, impulsionado pela disponibilidade crescente de dados e pela evolução das técnicas de aprendizado de (Sezer et al., 2020). Através da IA foi permitido a criação de máquinas capazes de analisar dados, prever resultados, recuperar informações e classificar dados com precisão, tornando-se uma ferramenta valiosa para o mercado financeiro (Gupta. Et al., 2023).

Uma compreensão aprofundada desses mercados é crucial para fazer previsões precisas e antecipar possíveis falhas ou recuperações, permitindo que os analistas de mercado alertem os investidores com antecedência. Essas informações podem ajudar os investidores a tomar precauções para possíveis falhas futuras ou aproveitar as oportunidades de lucro durante recuperações subsequentes (Gajamannage et al., 2023a). Portanto, a capacidade de aprender e prever com precisão o comportamento desses mercados é uma habilidade valiosa e altamente desejada na indústria financeira.

Com o avanço da tecnologia, temos visto um progresso significativo no desenvolvimento de métodos baseados em computador para diversas áreas, incluindo a financeira (Vogl et al., 2022). O desenvolvimento de modelos precisos é difícil, pois a previsão do mercado financeiro depende não apenas de um único fator, mas de vários, que incluem, política, oferta e demanda, calamidades naturais, notícias, dados de mídia social, produção da empresa, títulos estatais, preço histórico, bem como a economia do país (Gujral, et al., 2020). Dessa forma, um modelo de previsão que considera apenas uma característica pode não produzir resultados precisos.

O uso de sistemas inteligentes, como redes neurais (Zhang et al., 2021), algoritmos genéticos (Liu & Xiao, 2021) e lógica fuzzy (Tealab et al., 2018), para previsões financeiras tem se mostrado extremamente versátil e aplicável em diversas situações. Esses sistemas são capazes de lidar com grandes quantidades de dados de forma rápida e precisa, e podem ser usados em várias áreas do mercado financeiro, como previsão de preços de ações, detecção de anomalias, previsão de risco de crédito, análise de séries temporais, entre outros.

Entre os diversos métodos disponíveis para prever séries temporais no mercado financeiro, as Redes Neurais Artificiais (RNA) se destacam como uma das mais promissoras, devido à sua capacidade de armazenar memória interna, permitindo que sejam utilizadas para resolver uma grande variedade de problemas (Gajamannage et al., 2023b). A memória interna dessas redes permite que elas se lembrem de entradas anteriores e ajustem suas previsões com base nesses dados, tornando-as ideais para análises de séries temporais financeiras (Ma & Principe, 2018). Essa técnica de aprendizado de máquina é capaz de aprender e identificar padrões complexos e não-lineares nos dados, o que pode ser um desafio para os métodos estatísticos convencionais. Além disso, as redes neurais possuem a vantagem de se adaptarem a novos dados em tempo real, permitindo uma tomada de decisão mais rápida e precisa no mercado financeiro.

O Algoritmo Genético (AG) é uma técnica de otimização heurística adaptativa que se baseia nas ideias de seleção natural e evolução genética. Ele é amplamente utilizado para encontrar soluções ótimas aproximadas para problemas de otimização com grandes espaços de busca. O AG é efetivamente utilizado na seleção de recursos de otimização, pois codifica uma solução potencial em um indivíduo, que possui características de cromossomos. Cada indivíduo é reunido em uma

população, e o processo de otimização do AG é realizado na população (Chen & Zhou, 2021). Esse método é especialmente útil em problemas de previsão financeira, onde o grande espaço de busca pode ser um desafio para métodos tradicionais de previsão, permitindo que o algoritmo encontre soluções mais precisas e eficientes.

A lógica difusa é uma técnica que tem se mostrado altamente eficaz em situações complexas, pois é capaz de imitar o raciocínio humano em condições incertas ou ambíguas. Ao contrário da lógica clássica, que usa apenas valores binários (verdadeiro/falso), a lógica difusa permite que os valores possam variar de 0 a 1, permitindo uma análise mais precisa de situações complexas (Latha et al., 2022). Além disso, a lógica difusa pode lidar com informações imprecisas e incompletas, que são comuns no mundo financeiro. Por essas razões, a lógica difusa é frequentemente utilizada em sistemas de tomada de decisão em finanças e investimentos.

Com a crescente disponibilidade de dados financeiros e a alta complexidade do mercado financeiro, é cada vez mais difícil para os operadores e investidores financeiros tomarem decisões informadas e precisas em tempo hábil. Nesse sentido, as técnicas de inteligência computacional, como redes neurais, algoritmos genéticos e lógica fuzzy, têm se mostrado uma opção promissora para automatizar processos e auxiliar na tomada de decisões no mercado financeiro. O objetivo deste artigo é realizar uma revisão de literatura sobre técnicas de inteligência computacional aplicadas à automatização de operações no mercado financeiro, destacando seus principais conceitos e aplicações, bem como suas vantagens e limitações.

2. Metodologia

Este trabalho é uma revisão de literatura narrativa descritiva e exploratória, que tem como objetivo sistematizar, reunir e organizar os conhecimentos acerca do problema estudado (Pereira et al, 2018). A revisão se baseou em referências já analisadas e publicadas, ou seja, em estudos secundários que têm como fonte os estudos primários (Gerhardt & Silveira, 2009).

As bases de dados Science Direct e Scopus foram utilizadas para coletar artigos científicos e de revisão, e as palavras-chave "Financial market", "forecast", "artificial neural network", "genetic algorithm" e "fuzzy logic", juntamente com suas combinações usando os operadores booleanos and e or, foram utilizadas para buscar os estudos relevantes.

Os critérios de inclusão incluíram artigos internacionais indexados em revistas científicas publicadas entre 2016 e 2023, escritos em inglês e português, que abordavam o uso de técnicas de inteligência computacional no mercado financeiro. Os critérios de exclusão incluíram estudos inferiores a 2016, estudos fora da subárea de ciências da computação, estudos sem livre acesso ou com conteúdo incompleto, e estudos irrelevantes para o tema da pesquisa.

3. Resultados e Discussão

A revisão de literatura identificou diversos estudos que utilizaram técnicas de inteligência computacional para automatizar operações no mercado financeiro. Os resultados mostraram que as técnicas de inteligência computacional podem ser eficazes na automação de operações no mercado financeiro, permitindo aprimorar o desempenho de carteiras de investimentos, identificar oportunidades de negociação e reduzir os riscos de operações financeiras.

3.1 O uso da inteligência artificial no mercado financeiro

A Inteligência Artificial é um ramo da ciência que tem como objetivo utilizar meios tecnológicos para simular a inteligência humana, permitindo que máquinas resolvam problemas, criem soluções e até tomem decisões. Essa capacidade pode ser um grande auxílio em diversas áreas do cotidiano, como na medicina, na indústria, no comércio e nos serviços públicos, entre outros setores, permitindo a produção e otimização do tempo gasto na realização do trabalho (Silva & Mairink, 2019).

Essas ferramentas inovadoras são capazes de organizar informações e automatizar tarefas repetitivas ou que

apresentem determinado padrão, com ou sem o uso da IA tornando o processo mais eficiente e confiável (Coelho, 2019). Além disso, a IA desempenha um papel fundamental no aprimoramento da sociedade em rede, permitindo a identificação ágil de problemas e o potencial aprimoramento da experiência do usuário. A implementação de mecanismos automatizados com fins comerciais pode ter um impacto significativo na economia como um todo, como evidenciado especialmente pela automação do mercado financeiro (Fernandes & Carvalho, 2018).

O desenvolvimento de tecnologias que auxiliem na tomada de decisões tornou-se um fator crucial para a inserção e manutenção de produtos e serviços no mercado moderno. Nesse contexto, a modelagem matemática combinada com simulações de cenários futuros é uma abordagem especialmente relevante, pois pode ser aplicada a uma ampla variedade de finalidades. Para lidar com a complexidade da maioria dos processos industriais, muitas pesquisas têm se concentrado no desenvolvimento de novas ferramentas e tecnologias de controle (Fleck et al., 2016).

Sendo assim, a IA é capaz de realizar tarefas complexas que seriam impossíveis ou muito difíceis de serem feitas por seres humanos. Isso é possível graças a técnicas como redes neurais, algoritmos genéticos e lógica fuzzy, que permitem que as máquinas aprendam com dados e experiências passadas para melhorar continuamente suas decisões e desempenho.

3.2 Técnicas de inteligência computacional que podem ser utilizadas para automatizar operações no mercado financeiro

Os sistemas inteligentes artificiais têm visto uma utilização crescente em campos que exigem previsão de saídas com base na especificação limitada ou incompleta dos parâmetros de entrada. Desenvolvimentos recentes permitem que os sistemas de IA construam modelos causais que podem ser usados para determinar valores de parâmetros ideais para alcançar um resultado específico ou desejado (Lake et al., 2017).

3.2.1 Redes Neurais Artificiais

A Rede Neural Artificial (RNA) é um modelo operacional que tem sido desenvolvido desde o surgimento da tecnologia de inteligência artificial. As RNAs são compostas por muitos neurônios e sua estrutura principal é composta pela camada de entrada, camada oculta e camada de saída. O desempenho da RNA pode ser determinado pelo número de camadas ocultas, sendo que, segundo Zhang et al. (2022), quanto maior o número, melhor o desempenho. As RNAs são algoritmos computacionais que apresentam um modelo matemático inspirado na estrutura de organismos inteligentes. Esses modelos possibilitam a simplificação do funcionamento do cérebro humano em computadores. Dessa forma, as redes neurais artificiais são estatísticas fortes que buscam replicar o modelo lógico do sistema nervoso humano, com neurônios interconectados em uma rede de computação, como destaca Hemmat et al. (2023).

São métodos modernos de aprendizado de máquina utilizados para aplicar o conhecimento adquirido e, conseqüentemente, prever as respostas de saída de sistemas complexos (Hemmat et al., 2023). Nesse sentido, as RNAs têm sido amplamente utilizadas para prever o comportamento dos preços de ações e identificar padrões em séries temporais financeiras. Com essa técnica, é possível analisar um grande volume de dados históricos e, a partir disso, fazer previsões futuras mais precisas, contribuindo para a tomada de decisões mais assertivas em investimentos financeiros.

As RNAs são consideradas aproximadoras na ciência, pois têm a capacidade de encontrar relações em conjuntos de dados específicos. Essas redes são capazes de abordar questões desafiadoras, incluindo modelagem não linear, reconhecimento de padrões, associação e classificação (Fiyadha et al., 2023), permitindo a obtenção da relação empírica entre variáveis independentes e dependentes. Essa técnica é extremamente útil na análise de dados complexos e pode ser aplicada em diversas áreas, como finanças, medicina, engenharia, entre outras, contribuindo para o avanço do conhecimento e tomada de decisões mais assertivas.

A caracterização de uma rede neural depende de suas características estruturais, que incluem as conexões dos nós, a função de ativação e o esquema de ponderação das conexões (Olatunji et al., 2022). Os nós são responsáveis por executar operações matemáticas e calcular as saídas. Dependendo do tipo de operação/função matemática utilizada, diferentes tipos de RNAs são desenvolvidos (Meymand & Sulisz, 2023). A topologia de uma rede neural convencional consiste em um grande número de nós dispostos em um padrão predeterminado. Além disso, as RNAs podem ser categorizadas com base na direção do fluxo de informações durante o processamento, sendo que em uma rede feedforward, os nós são orientados da camada de entrada para a camada de saída (Doray et al., 2020). Essa categorização é importante para entender como a rede processa as informações de entrada e produz as saídas correspondentes, o que pode ser útil em diferentes aplicações, como reconhecimento de imagens, previsão de séries temporais, entre outras.

Várias pesquisas têm explorado o potencial das RNAs como uma ferramenta para computação, representação e mapeamento de entradas para saídas, como discutido em diversas publicações (Fiyadha et al., 2023; Alardhi et al., 2023a; Alardhi et al., 2023b). Na área financeira, há uma vasta gama de estudos envolvendo redes neurais artificiais. Por exemplo, Zhang et al. (2021) utilizaram LSTM para prever os próximos 30 dias do índice de valores da bolsa de Xangai (SSE 50); Nabipour et al. (2020) testaram vários métodos de RNAs (RNN, LSTM e CNN) na bolsa de valores da Índia; e Kamara et al. (2022) propuseram uma rede neural de aprendizado profundo híbrido (EHTS) para prever o fechamento diário da ação Johnson & Johnson (JNJ) na bolsa de valores de Nova York (NYSE). Esses estudos ilustram a crescente importância das RNAs na análise de dados financeiros e a sua capacidade de fornecer informações valiosas para tomadores de decisão no mercado financeiro.

3.2.2 Algoritmos Genéticos (AG)

O algoritmo genético (AG) é uma técnica computacional poderosa que se baseia no processo de evolução natural para otimizar soluções de problemas. É um dos primeiros algoritmos estocásticos com capacidade de combinar seleção, cruzamento e mutação, ele é capaz de encontrar rapidamente soluções para problemas complexos de otimização combinatória em diversas áreas, incluindo finanças (Mirjalili, 2019).

O AG utiliza uma população de soluções, em que cada candidato a solução é representado por um cromossomo que contém genes que representam os parâmetros do problema. No início do processo, é criada uma população aleatória considerando os limites inferior e superior dos parâmetros. Através de uma função de aptidão, é avaliada a adequação de cada indivíduo dessa população inicial com um valor numérico. Para garantir que as soluções mais promissoras tenham uma melhor aptidão, os indivíduos mais bem adaptados são selecionados aleatoriamente com o auxílio de um mecanismo de seleção (Bumin & Ozcalici, 2023). Ainda segundo os autores, duas operações genéticas são então aplicadas aos indivíduos selecionados: cruzamento e mutação. Com essas operações, espera-se que o algoritmo evolua progressivamente em direção a soluções melhores, convergindo eventualmente para a melhor solução possível (Bumin & Ozcalici, 2023).

Os algoritmos genéticos têm sido amplamente utilizados em diversas áreas para resolver problemas complexos do mundo real. No mercado financeiro, a previsão de tendências e movimentos de preços de ações e outros ativos financeiros é um desafio constante para investidores e gestores de fundos. Os GAs apresentam um grande potencial para automatizar e otimizar esse processo (Thakkar & Chaudhari, 2022), pois são capazes de lidar com um grande número de variáveis, que muitas vezes apresentam relações não lineares e interdependências complexas.

Essa técnica pode ser utilizada para encontrar a melhor alocação de recursos em uma carteira de investimentos, considerando diversos fatores, como histórico de preços, indicadores financeiros e tendências do mercado (Mirjalili, 2019). Sua capacidade de otimizar parâmetros em conjuntos de dados amplamente complexos o torna extremamente indicado para ser utilizado no mercado financeiro para aprimorar a estratégia de investimento (Martins & Neves, 2020).

Embora o Algoritmo Genético apresente uma série de vantagens, como a ampla representação de soluções viáveis, características de busca em grupo, independência de informações auxiliares e facilidade de combinação com outras tecnologias, também apresenta algumas desvantagens. Entre elas, destacam-se a falta de padronização na codificação e a representação imprecisa, além de uma única codificação não ser capaz de expressar totalmente as restrições do problema de otimização. Outra desvantagem é que o algoritmo genético é propenso a convergir prematuramente, o que pode prejudicar a busca pela melhor solução (Liu & Xiao, 2021).

O estudo realizado por Liu & Xiao (2021) comparou o desempenho do algoritmo genético com o método de programação quadrática, e constatou que o AG foi a técnica mais eficiente. Segundo os dados experimentais, o risco mínimo de otimização do portfólio pelo algoritmo genético foi reduzido em cerca de 40%, e o retorno máximo foi aumentado em aproximadamente 25%. Esses resultados sugerem que o uso do AG pode melhorar significativamente a eficiência da otimização de portfólio e, conseqüentemente, aumentar os lucros dos investimentos. Em outro estudo recente, Faridi et al. (2023) propuseram um método combinado de aprendizagem de máquina e algoritmo genético, que apresentou o maior rendimento total da carteira de ações de 114,12%, com risco de 0,905%. Além disso, ao examinar a taxa de retorno do capital, observou-se que o método proposto possui a maior taxa média de retorno do investimento de 110,64%. Esses resultados indicam que a combinação de técnicas de aprendizagem de máquina e algoritmo genético pode ser uma abordagem promissora para a otimização de portfólio no mercado financeiro.

3.2.3 Lógica Fuzzy

A Lógica Fuzzy (também conhecida como lógica difusa) tem sido amplamente reconhecida como uma das abordagens inteligentes mais úteis na solução de situações complexas, devido à sua capacidade de imitar o raciocínio humano e lidar com incertezas e ambigüidades (Latha et al., 2022). Ao contrário de outras abordagens que lidam com variáveis binárias (verdadeiro/falso), a Lógica Fuzzy permite a representação de conceitos e valores parciais ou graduais, o que possibilita a manipulação de informações imprecisas e incertas.

Esse método apresenta várias vantagens úteis em relação a outras abordagens, tais como: simplicidade de implementação, interpretabilidade dos modelos e capacidade de apresentar o raciocínio aplicado em cada etapa do processo de tomada de decisão. Essas características tornam a Lógica Fuzzy uma ferramenta valiosa em uma ampla gama de aplicações, incluindo o campo financeiro (Naranjo & Santos, 2019). Na área financeira, a Lógica Fuzzy pode ser utilizada para avaliar o risco de uma operação financeira e ajustar as decisões de investimento em tempo real, levando em consideração uma ampla gama de variáveis e incertezas. Os mercados de ações, por exemplo, são sistemas não lineares de alta complexidade que lidam com a ambigüidade e a incerteza oriundas tanto dos fatos quanto dos significados da linguagem utilizada (Kofi et al., 2020). Com a Lógica Fuzzy, é possível analisar essas variáveis e incertezas de forma mais precisa e eficiente, permitindo uma tomada de decisão mais segura e informada no mercado financeiro.

Ao longo das últimas décadas, a lógica fuzzy e os sistemas fuzzy têm sido amplamente adotados na comunidade científica. Esses modelos são de entrada-saída, onde as variáveis de entrada não possuem valores exatos, mas apresentam probabilidades influentes em relação ao resultado final (Silver et al., 2020). Esse tipo de modelo é especialmente útil em situações em que a precisão dos dados não pode ser garantida, mas onde a probabilidade de um resultado pode ser estimada com certa confiança (Ribeiro, 2022).

A lógica fuzzy tem sido reconhecida como uma contribuição significativa para pesquisas que envolvem dados pouco claros, muitas vezes expressos em termos linguísticos que se assemelham à percepção humana. Sua flexibilidade e capacidade de lidar com informações imprecisas e incertas tornam-na uma ferramenta poderosa em uma ampla gama de aplicações, desde sistemas de controle e automação até tomada de decisões em empresas e organizações governamentais (Ribeiro,

2022).

A lógica fuzzy é amplamente considerada um dos métodos mais eficazes para lidar com problemas de tomada de decisão em situações incertas e complexas (Mondragon et al., 2019). Em um estudo realizado por Tealab et al. (2018), foram comparados três sistemas de decisão: um com estratégia fuzzy clássica, outro com apenas regras fuzzy (R) e um terceiro com regras fuzzy e gerenciamento de capital fuzzy (RC). Os resultados finais mostraram que o sistema Fuzzy RC obteve o melhor desempenho, gerando um lucro líquido total de 145.045,26 € (1450,5%). O sistema Fuzzy R também obteve um resultado positivo, com um lucro líquido total de € 59.119,25 (491,2%), superando os resultados do sistema clássico, que teve um lucro final de € 22.136,3 (221,3%). Esses resultados indicam que o uso da lógica fuzzy, especialmente quando combinada com gerenciamento de capital fuzzy, pode levar a melhores resultados na tomada de decisões financeiras. A Lógica Fuzzy tem sido frequentemente combinada com RNA para melhorar a precisão dos modelos de previsão de preços de ações no mercado de capitais. Em um estudo realizado por Dutta (2018), foi proposta uma combinação entre RNA e Lógica Fuzzy para prever os preços das ações das empresas NIFTY50 e PHARMA no mercado de capitais indiano (NSE). Os resultados experimentais mostraram que o método proposto foi capaz de obter uma precisão média de 88% na previsão dos preços das ações, demonstrando sua eficácia.

4. Considerações Finais

Com base na revisão narrativa de literatura apresentada, é possível concluir que as técnicas de inteligência computacional têm um grande potencial para a automação de operações no mercado financeiro. As abordagens baseadas em redes neurais, algoritmos genéticos e lógica fuzzy têm se mostrado eficazes na previsão de preços e na tomada de decisões de investimento. No entanto, é fundamental destacar que a automação não elimina completamente os riscos associados aos investimentos financeiros. Ainda há desafios a serem superados, como a necessidade de grandes volumes de dados para o treinamento dos modelos, além da complexidade das técnicas. Por fim, é importante mencionar que mesmo com algoritmos sofisticados e modelos de análise preditiva, a decisão final deve sempre ser tomada por um ser humano que leve em consideração fatores como contexto, histórico e análise crítica da informação.

Em suma, a aplicação da inteligência computacional no mercado financeiro tem mostrado resultados promissores na automação de operações. No entanto, ainda há um vasto campo para futuros estudos e pesquisas nessa área. Uma possível linha de pesquisa futura poderia se concentrar no desenvolvimento de técnicas avançadas de aprendizado de máquina e inteligência artificial, para aprimorar ainda mais a eficiência e a precisão dos sistemas de automação financeira. Outro aspecto importante seria explorar como a inteligência computacional pode contribuir para a detecção e prevenção de fraudes financeiras, bem como na gestão de riscos e na tomada de decisões de investimento mais informadas. Com esses estudos futuros, podemos esperar avanços significativos na aplicação da inteligência computacional no mercado financeiro, trazendo benefícios tanto para os investidores como para as instituições financeiras.

Referências

- Alardhi, S. M., Al-Jadir, T., Hasan, A. M., Jaber, A. A., & Al Saedi, L. M. (2023a) Design of Artificial Neural Network for Prediction of Hydrogen Sulfide and Carbon Dioxide Concentrations in a Natural Gas Sweetening Plant. *Ecol. Eng.* 2, 55-66, 10.12912/27197050/157092.
- Alardhi, S. M., Fiyadh, S. S., Salman, A. D., & Adelikhah, M. (2023b) Prediction of methyl orange dye (MO) adsorption using activated carbon with an artificial neural network optimization modeling. *Heliyon*, v.9(1): 1-15, <https://doi.org/10.1016/j.heliyon.2023.e12888>.
- Bahadur, N., Paffenroth, R., & Gajamannage, K. (2019). Dimensional estimation of equity markets. In *2019 IEEE International Conference on Big Data (Big Data)*. pp. 5491-5498, 2019. 10.1109/BigData47090.2019.9006343.
- Bumin, M., & Ozcalici, M. (2023). Predicting the direction of financial dollarization movement with genetic algorithm and machine learning algorithms: The case of Turkey. *Expert Systems with Applications*, 213, 119301. <https://doi.org/10.1016/j.eswa.2022.119301>.

- Chen, S. & Zhou, C. (2021). "Stock Prediction Based on Genetic Algorithm Feature Selection and Long Short-Term Memory Neural Network," *IEEE Access*, 9, 9066-9072, 10.1109/ACCESS.2020.3047109.
- Coêlho, M. V. F. (2019). *O uso da inteligência artificial no meio jurídico*. 2019. <https://www.editorajc.com.br/o-uso-da-inteligencia-artificial-no-meio-juridico>.
- Dobay, A., Ford, J., Decker, S., Ampanozi, G., Franckenberg, S., Affolter, R., ... & Ebert, L. C. (2020). Potential use of deep learning techniques for postmortem imaging. *Forensic Science, Medicine and Pathology*, 16, 671-679. 10.1007/s12024-020-00307-3.
- Dutta, A. K. (2018). A fuzzy based soft computing technique to predict the movement of the price of a stock. *International Journal of Advanced Computer Science and Applications*, 9(2). 10.14569/IJACSA.2018.090245.
- Faridi, S., Madanchi Zaj, M., Daneshvar, A., Shahverdiani, S., & Rahnamay Roodposhti, F. (2023). Portfolio rebalancing based on a combined method of ensemble machine learning and genetic algorithm. *Journal of Financial Reporting and Accounting*, 21(1), 105-125, 10.1108/JFRA-11-2021-0413.
- Fernandes, R. V. C., & Carvalho, A. G. P. (2018). Tecnologia jurídica & direito digital: *II Congresso Internacional de Direito, Governo e Tecnologia – 2018*. Belo Horizonte: Fórum, 2018. 488p. http://adpadvogados.com.br/en/wp-content/uploads/2019/11/Revista_Congresso.pdf.
- Fiyadha, S. S., Alardhi, S. M., Al Omar, M., Aljumaily, M. M., Al Saadic, M. A., Fayaedd, S. S., ... & El-Shafie, A. (2023). A comprehensive review on modelling the adsorption process for heavy metal removal from water using artificial neural network technique. *Heliyon*, 9(4): 1-11, 2023. <https://doi.org/10.1016/j.heliyon.2023.e15455>.
- Fleck, L., Tavares, M. H. F., Eyng, E., Helmann, A. C., & Andrade, M. A. M. (2016). Redes neurais artificiais: princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, 1(13), 47-57, 2016. 10.3895/recit.v7i15.4330.
- Gajamannage, K., Jayathilake, D. I., Park, Y., & Bollt, E. M. (2023a). Recurrent neural networks for dynamical systems: Applications to ordinary differential equations, collective motion, and hydrological modeling. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 33(1), 013109. <https://doi.org/10.1063/5.0088748>.
- Gajamannage, K., Park, Y., & Jayathilake, D. I. (2023b). Real-time forecasting of time series in financial markets using sequentially trained dual-LSTMs. *Expert Systems with Applications*, 223, 119879 <https://doi.org/10.1016/j.eswa.2023.119879>.
- Gerhardt, T. E., & Silveira, D. T. (2009). *Métodos de Pesquisa*. Plageder: UFRGS; 2009;1–31. <https://lume.ufrgs.br/handle/10183/52806>.
- Gujral, H., Kushwaha, A. K., & Khurana, S. (2020). Utilização de ferramentas de séries temporais em ciências da vida e neurociência. *Neurosci Insights*, 15, 1-15, 10.1177/2633105520963045.
- Gupta, S., Modgil, S., Choi, T. M., Kumar, A., & Antony, J. (2023). Influences of artificial intelligence and blockchain technology on financial resilience of supply chains. *International Journal of Production Economics*, 261, 108868. <https://doi.org/10.1016/j.ijpe.2023.108868>.
- Hemmat, M., Toghraie, D., & Amoozad, F. (2023). Prediction of viscosity of MWCNT-AI2O3 (20:80)/ SAE40 nano-lubricant using multi-layer artificial neural network (MLP-ANN) modeling. *Engineering Applications of Artificial Intelligence*, 121: 1-12, 2023. <https://doi.org/10.1016/j.engappai.2023.105948>.
- Kamara, A. F., Chen, E., & Pan, Z. (2022). An ensemble of a boosted hybrid of deep learning models and technical analysis for forecasting stock prices. *Information Sciences*, 594, 1-19. <https://doi.org/10.1016/j.ins.2022.02.015>.
- Kofi, N. I., Adekoya, A. F., & Weyori, B. A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *The Artificial Intelligence Review*, 53(4), 3007-3057. 10.1007/s10462-019-09754-z.
- Lake, B. M., Ullman, T. D., Tenenbaum, J. B., & Gershman, S. J. (2017). Building machines that learn and think like people. *Behavioral and brain sciences*, 40: 1-72, 2017. <https://doi.org/10.1017/S0140525X16001837>.
- Latha, C. M., Bhuvaneswari, S., & Soujanya, K. L. S. (2022). "Stock Price Prediction using HFTSF Algorithm," 2022 *Sixth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, Dharan, Nepal, 1053-1059, 10.1109/I-SMAC55078.2022.9987378.
- Liu, S., & Xiao, C. (2021). Application and Comparative Study of Optimization Algorithms in Financial Investment Portfolio Problems. *Mobile Information Systems*, 1-10. <https://doi.org/10.1155/2021/3462715>.
- Ma, Y., & Principe, J. (2018). "Comparison of Static Neural Network with External Memory and RNNs for Deterministic Context Free Language Learning," 2018 *International Joint Conference on Neural Networks (IJCNN)*, 1-7, 10.1109/IJCNN.2018.8489240.
- Martins, T. M., & Neves, R. F. (2020). Applying genetic algorithms with speciation for optimization of grid template pattern detection in financial markets. *Expert Systems with Applications*, 147, 113191. <https://doi.org/10.1016/j.eswa.2020.113191>.
- Meymand, A. M., & Sulisz, W. (2023). Application of nested artificial neural network for the prediction of significant wave height. *Renewable Energy*, 209: 157-168, 2023. <https://doi.org/10.1016/j.renene.2023.03.118>.
- Mirjalili, S. (2019). Genetic algorithm. *Evolutionary Algorithms and Neural Networks: Theory and Applications*, 43-55. 10.1007/978-3-319-93025-1_4.
- Mondragon, A. E. C., Mastrocinque, E., Tsai, J. F., & Hogg, P. J. (2019). An AHP and fuzzy AHP multifactor decision making approach for technology and supplier selection in the high-functionality textile industry. *IEEE Transactions on Engineering Management*, 68(4), 1112-1125. 10.1109/TEM.2019.2923286.
- Nabipour, M., Nayyeri, P., Jabani, H., Shahab, S., & Mosavi, A. (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis. *IEEE Access*, 8, 150199-150212. 10.1109/ACCESS.2020.3015966.

- Naranjo, R., & Santos, M. (2019). A fuzzy decision system for money investment in stock markets based on fuzzy candlesticks pattern recognition. *Expert Systems with Applications*, 133, 34-48. <https://doi.org/10.1016/j.eswa.2019.05.012>.
- Olatunji, K. O., Ahmed, N.A., Madyira, D.M., Adebayo, A.O., Ogunkunle, O., & Adeleke, O. (2022). Performance evaluation of ANFIS and RSM modeling in predicting biogas and methane yields from *Arachis hypogea* shells pretreated with size reduction. *Renew. Energy*, 189 (2022), 288-303. 10.1016/j.renene.2022.02.088.
- Pereira, A. S., Shitsuka D. M., Parreira, F. J., & Shitsuka, R. (2018). *Metodologia da pesquisa científica*. UFSM. https://www.ufsm.br/app/uploads/sites/358/2019/02/Metodologia-da-Pesquisa-Cientifica_final.pdf.
- Qiu, J., Wang, B., & Zhou, C. (2020). Forecasting stock prices with long-short term memory neural network based on attention mechanism. *PloS one*, 15(1), e0227222. <https://doi.org/10.1371/journal.pone.0227222>.
- Ribeiro, V. S. (2022). Method for the estimation of institutional quality indexes using fuzzy logic. *MethodsX*. 9:101676. 10.1016/j.mex.2022.101676.
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied soft computing*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>.
- Silva, J. A. S., & Mairink, C. H. P. (2019). Inteligência artificial: aliada ou inimiga. *LIBERTAS: Rev. Ciênci. Soc. Apl.*, 9(2), 64-85, <http://famigvirtual.com.br/famig-libertas/index.php/libertas/article/view/247/230>.
- Silver, M., Svoray, T., Karnieli, A., & Fredjc, E. (2020). Improving weather radar precipitation maps: a fuzzy logic approach. *Atmos. Res.* 2020;234 10.1016/j.atmosres.2019.104710.
- Tealab, A., Hefny, H., & Badr, A. (2018). Short-term stock market fuzzy trading system with fuzzy capital management. *International Journal of Intelligent Engineering and Systems*, 11(3). 10.22266/ijies2018.0630.06.
- Thakkar, A., & Chaudhari, K. (2022). Information fusion-based genetic algorithm with long short-term memory for stock price and trend prediction. *Applied Soft Computing*, 128, 109428. <https://doi.org/10.1016/j.asoc.2022.109428>.
- Vogl, M., Rötzel, P. G., & Homes, S. (2022). Forecasting performance of wavelet neural networks and other neural network topologies: A comparative study based on financial market data sets. *Machine Learning with Applications*, 8, 100302, <https://doi.org/10.1016/j.mlwa.2022.100302>.
- Zhang, C., Zhang, F., Chen, N. et al. (2022). Application of artificial intelligence technology in financial data inspection and manufacturing bond default prediction in small and medium-sized enterprises (SMEs). *Oper Manag Res*, 15, 941–952 (2022). <https://doi.org/10.1007/s12063-022-00314-3>.
- Zhang, Y., Chu, G., & Shen, D. (2021). The role of investor attention in predicting stock prices: The long short-term memory networks perspective. *Finance Research Letters*, 38:1-12, 2021. <https://doi.org/10.1016/j.frl.2020.101484>.