



REDES COMPLEXAS E APRENDIZADO DE MÁQUINA PARA SÉRIES TEMPORAIS FINANCEIRAS E GERENCIAMENTO DE PORTFÓLIO

Nathan A. Rufino¹; Douglas D. de C. BRAZ²

RESUMO

Redes complexas têm sido uma forma de analisar o mercado financeiro através de uma perspectiva mais ampla e não tão individualizada. Esse tipo de análise, também conhecida como redes financeiras ou redes de ações, tem atraído a atenção de inúmeros pesquisadores das áreas de computação, matemática, estatística e física. Ao invés de analisar cada ação ou série temporal de preços de forma isolada, esse tipo de abordagem permite que sejam extraídas informações sobre o comportamento do mercado de uma forma topológica, onde as ações são representadas pelos vértices de um grafo e as arestas representam os relacionamentos entre eles. Tendo em vista essa estrutura de redes, esse artigo busca analisar a diferença entre dois tipos de redes: uma construída utilizando os preços reais dos ativos e outra, os preços previstos para os ativos, através de um modelo de aprendizagem de máquina.

Palavras-chave:

Redes de Ações; Inteligência Artificial; Computação Financeira; Gestão de Portfólio; Previsão de Mercado.

1. INTRODUÇÃO

As redes complexas são ferramentas poderosas para analisar e compreender a estrutura e o comportamento dos sistemas complexos, incluindo o mercado financeiro (Strogatz, 2001). Sua aplicação tem grande relevância prática, especialmente no desenvolvimento de estratégias de compra e venda de ações. Dentre as principais aplicações da análise de redes financeiras está o gerenciamento de portfólio. O gerenciamento de portfólio de investimentos (carteira) no mercado financeiro é o processo de seleção de um subconjunto de ativos que tem como objetivo manter um controle (trade-off) entre o risco e o retorno do investimento (Markowitz, 1952).

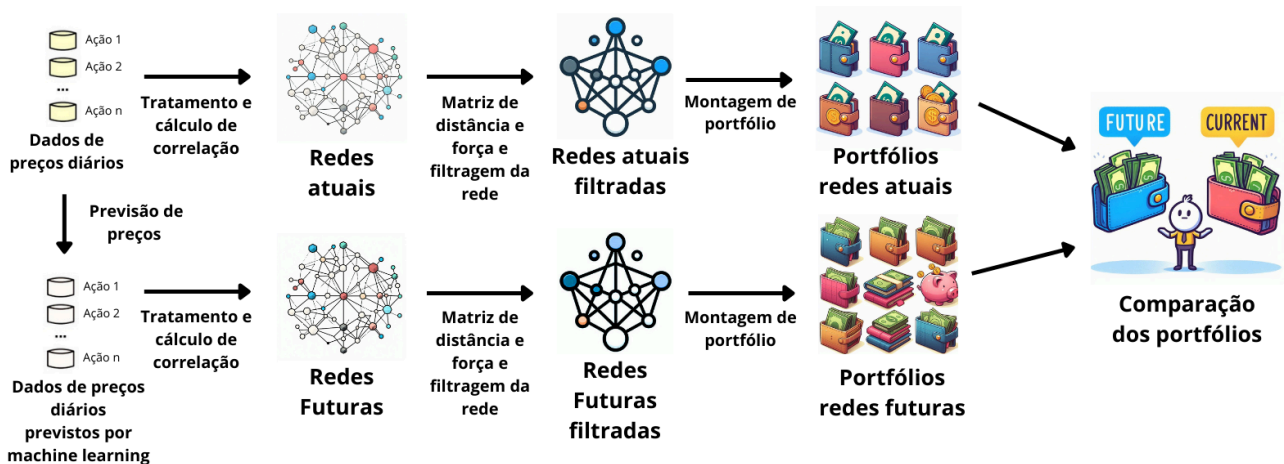
Neste contexto, o objetivo deste trabalho é construir e analisar portfólios utilizando redes complexas. Além disso, será empregado um modelo de aprendizado de máquina para prever os preços das ações e, com base nessas previsões, será criada uma rede complexa. Por fim, será comparado o desempenho entre a rede construída com os preços reais das ações, chamada de rede atual, e a rede construída com os preços previstos, chamada de rede futura, a fim de avaliar qual abordagem resulta em uma melhor seleção de portfólio.

¹Bolsista PIBIC/CNPq, IFSULDEMINAS – *Campus* Poços de Caldas. E-mail: nathan.rufino@alunos.ifsuldeminas.edu.br.

²Orientador, IFSULDEMINAS – *Campus* Poços de Caldas. E-mail: douglas.braz@ifsuldeminas.edu.br.

2. MATERIAL E MÉTODOS

Figura 1 - Metodologia



Fonte: O autor (2024)

- Coleta de Dados
 - Coletar dados históricos de preços de fechamento dos ativos da B3.
- Previsão dos Preços
 - Utilizar um modelo de inteligência artificial para prever os preços futuros dos ativos com base nos dados históricos coletados.
 - Utilizar os preços previstos para construir a rede futura, enquanto os preços reais serão utilizados para construir a rede atual.
- Aplicação da Janela Deslizante e Cálculo dos Retornos Logarítmicos
 - Dividir os dados de preços de fechamento em janelas temporais de tamanho Δt para capturar a evolução das correlações ao longo do tempo.
 - Para cada janela deslizante, calcular os retornos logarítmicos Y_i para cada ativo usando a fórmula: $Y_i = \ln(P_i(t)) - \ln(P_i(t - 1))$

Onde $P_i(t)$ é o preço de fechamento do ativo i no dia t e $P_i(t - 1)$ é o preço de fechamento no dia anterior.
- Cálculo das Matrizes de Correlação
 - Calcular a correlação de Pearson p_{ij} entre os retornos logarítmicos dos ativos i e j para cada janela temporal, utilizando a fórmula:
$$p_{ij} = \frac{\langle Y_i Y_j \rangle - \langle Y_i \rangle \langle Y_j \rangle}{\sqrt{(\langle Y_i^2 \rangle - \langle Y_i \rangle^2)(\langle Y_j^2 \rangle - \langle Y_j \rangle^2)}}$$
- Cálculo das Matrizes de Distância e Força
 - Converter a matriz de correlação em uma matriz de distância usando a fórmula:

$$d_{ij} = \sqrt{2(1 - p_{ij})}$$

- Calcular a matriz de força a partir da matriz de correlação usando a fórmula:

$$f_{ij} = 1 + p_{ij}$$

- Filtragem das Redes

- Gerar redes filtradas a partir das matrizes de distância e força utilizando as técnicas de MST (Minimum Spanning Tree), PMFG (Planar Maximally Filtered Graph), TMFG (Triangulated Maximally Filtered Graph) Massara et al. (2015), DAG (Dynamic Asset Graph) Castilho et al. (2021) e DTN (Dynamic Threshold Networks) Castilho et al. (2021).

- Construção dos Portfólios

- Construção de portfólios com base na centralidade dos ativos:
 - Utilizar as redes filtradas para seguir os passos sugeridos por Pozzi et al. (2013) na seleção de ativos periféricos.
- Construção de portfólios com base em técnicas de Clusterização:
 - Método de Louvain:
 - Utilizar as redes filtradas para identificar comunidades pelo algoritmo de Louvain.
 - Montar um portfólio selecionando dois ativos de cada cluster, os ativos selecionados serão os dois com maior retorno médio.
 - Método de Girvan-Newman:
 - Utilizar as redes filtradas para identificar comunidades pelo algoritmo de Girvan-Newman. O algoritmo divide a rede em n clusters, sendo n um valor definido pelo usuário. Para o valor de n, utilizar a quantidade de clusters gerados pelo algoritmo de Louvain.
 - Montar um portfólio selecionando dois ativos de cada cluster, os ativos selecionados serão os dois com maior retorno médio.

- Comparação dos Resultados

- Comparar o desempenho das redes atual e futura com base nos resultados dos portfólios montados para cada uma delas.

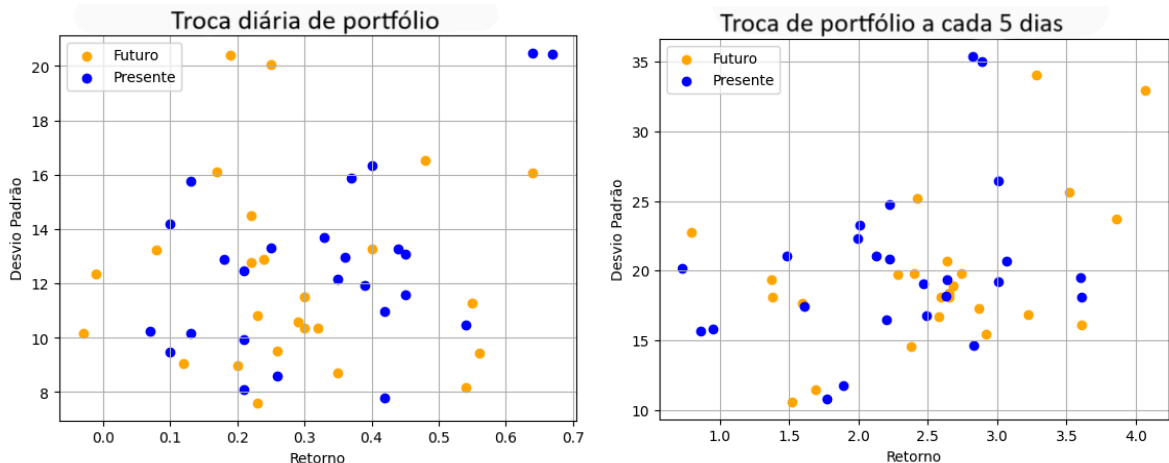
3. RESULTADOS E DISCUSSÃO

Para uma melhor comparação entre os resultados das duas redes (atual e futuro), foram construídos os gráficos abaixo, onde cada ponto corresponde ao retorno de um portfólio. Os pontos

laranja representam os portfólios construídos com as redes futuras, e os pontos azuis representam os portfólios construídos com as redes atuais. O eixo x dos gráficos refere-se ao retorno médio.

As métricas obtidas pelas redes futuras foram levemente melhores se comparadas às métricas geradas pelas redes atuais. Essa observação fica clara ao analisar o primeiro gráfico, onde é possível visualizar um grupo de pontos laranja (que representam as redes futuras) na melhor posição possível do gráfico, na parte inferior à direita, ou seja, um alto retorno para um baixo risco.

Gráfico 1 - Simulação do retorno dos portfólios



Fonte: O autor (2024)

4. CONCLUSÃO

Os resultados até o momento se mostraram satisfatórios. A concentração dos portfólios futuros na melhor região do gráfico reforça a hipótese de que as redes futuras oferecem uma vantagem em termos de risco-retorno, embora a significância estatística desses resultados demande estudos mais detalhados. Tendo em vista esses resultados, a continuidade da pesquisa iniciada neste projeto já está em prática.

REFERÊNCIAS

CASTILHO, D.; SOUZA, T. T. P.; KANG, S. M.; GAMA, J.; CARVALHO, A. C. P. L. F. *Forecasting financial market structure from network features using machine learning*. 2021.

MARKOWITZ, H. *Portfolio selection*. *The Journal of Finance*, [American Finance Association, Wiley], v. 7, n. 1, p. 77–91, 1952. ISSN 00221082, 15406261.

MASSARA, G. P.; DI MATTEO, T.; ASTE, T. *Network filtering for big data: Triangulated maximally filtered graph*. 2015.

POZZI, F. *Filtering financial networks and optimal portfolio selection*. 2013.

STROGATZ, S. H. *Exploring complex networks*. *Nature*, v. 410, n. 6825, p. 268-276, 2001.