



CLASSIFICAÇÃO DE SÉRIES TEMPORAIS DO MERCADO FINANCEIRO UTILIZANDO IMAGENS SINTÉTICAS E APRENDIZADO PROFUNDO

Vinicius M. MARRAFON¹; Douglas CASTILHO²; Thiago C. TAVARES³

RESUMO

Imagens são uma excelente forma de se visualizar informações, ainda mais se os dados não apresentarem nenhum padrão aparente. Séries Temporais podem muitas vezes parecerem caóticas sem nenhum indício claro de sazonalidade, tendência ou ciclos, o que torna a sua representação por imagens uma alternativa plausível para sua interpretação e análise. Dado que estes valores podem apresentar certos comportamentos, como troca de regimes, podemos capturá-los através de uma representação mais robusta. Os Campos Angulares Gramianos (Gramian Angular Field - GAF) são largamente utilizados na literatura. Com padrões de comportamento tão aparentes, surge a ideia de se utilizar técnicas de aprendizado de máquina para automatizar o processo de classificação de Séries Temporais.

Palavras-chave: Campos Angulares Gramianos; Aprendizado de Máquina; Visão Computacional;

1. INTRODUÇÃO

Séries temporais podem ser entendidas como dados amostrados de forma cronológica, o que o torna uma ferramenta com um domínio amplo de aplicações. Dado uma Série Temporal de qualquer natureza, um dos principais problemas abordados acerca deste tipo de conjunto de dados é a previsão de seu comportamento em um tempo futuro, ou seja, com base em dados temporais entre um período t_0 até t_n , queremos descobrir o valor de t_{n+1} . Este tipo de problema é comumente abordado na literatura e aplicado em diversas áreas, tais como dados climáticos, séries históricas de temperatura, preços de commodities, dentre outros.

O uso de modelos de aprendizado de máquinas (Machine Learning - ML) tem sido largamente utilizados para automatizar o processo de classificação ou regressão de um dado conjunto de dados. Um dos princípios básicos de seu funcionamento é a tentativa de extrair padrões dentro dessas bases de dados. Neste contexto, o objetivo desta pesquisa é desenvolver abordagens utilizando aprendizado de máquinas para prever o comportamento de séries temporais, aplicado ao mercado financeiro. O principal intuito desta pesquisa é investigar métodos para convertermos séries temporais em imagens e, através dessas imagens, realizar a previsão futura do comportamento dessas séries utilizando ML.

2. FUNDAMENTAÇÃO TEÓRICA

Proposta por Wang & Oates (2015), a utilização de GAFs tem sido largamente utilizadas em problemas de previsão de séries temporais financeiras. Bello & Kasapbaşı (2023) fizeram a utilização de GAF junto com *ensemble* de Redes Neurais Convolucionais (CNN) para a previsão de séries temporais financeiras, usando a base de dados da Historical International Business Machines (IBM) Stock Price Data, obtendo como resultado uma acurácia de 97.4% na previsão do mercado no dia seguinte.

Sako, Mpinda & Rodrigues (2022), em seu artigo, utilizaram Redes Neurais Recorrentes (Recurrent Neural Network - RNN), Memória de curto prazo longa (Long Short-Term Memory - LSTM) e Unidade recorrente com portão (Gated Recurrent Unit - GRU) para previsão de séries temporais financeiras, utilizando os dados históricos de índices do mercado financeiro, em um problema de regressão e obtiveram resultados satisfatórios com Erro quadrático médio (Root Mean Squared Error - RMSE) e erro absoluto médio (Mean Absolute Error - MAE) inferiores a 0.5 no treino, validação e teste, nos três modelos utilizados. Imagens, em vários contextos, têm sido extremamente eficazes na captura de padrões complexos e suas transformações atenuam ruídos indesejados, que podem dificultar o aprendizado dos modelos. Séries temporais financeiras tendem a possuir essas características, então a sua representação por imagens, junto com arquiteturas de CNNs, podem nos ajudar a atingir um melhor poder preditivo acerca do futuro.

3. MATERIAL E MÉTODOS

A metodologia utilizada seguirá o seguinte esquema, apresentado na Figura 1 abaixo

Figura 1: *Framework* utilizado para desenvolvimento da pesquisa



Fonte: Autor (2024)

As etapas da metodologia, apresentadas na Figura 1, compreendem os seguintes métodos: ● Coleta e Pré-processamentos das Séries Temporais Financeiras - Ao invés de usarmos o preço de fechamento puro, é comum na literatura olhar para o log do retorno, isto é: $Y_i = \ln(P_i(t)) - \ln(P_i(t-1))$,

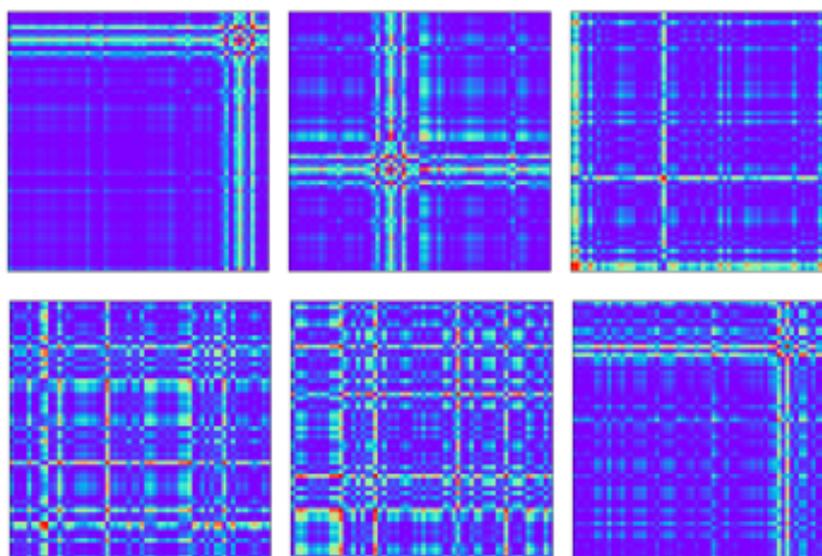
● Y_i é a diferença do log dos preços, P_i é o preço de fechamento i da Série Temporal ● Estratificação das Séries Temporais - Aplica-se uma janela deslizante nas Séries Temporais

obtidas para aumentar o conjunto de dados. Várias bases foram criadas para comparar qual tamanho de janela e salto trouxeram uma melhor compreensão para os modelos preditivos. • Criação da Base de Imagens - Para cada janela extraída, aplicamos o algoritmo de GAF para convertê-lo em imagem. Este pode ser através de dois métodos. Soma e Subtração. Para cada imagem, atribuir o seu respectivo rótulo quanto a tendência e troca de regime. • Aplicação de Modelos de Aprendizado de Máquina nas imagens obtidas - Usaremos um modelo de aprendizado de máquina para tentar aprender os padrões derivados da granularidade do algoritmo de GAF. Na literatura é comum utilizarem as chamadas Tiled Convolutional Neural Network (CNN), porém há artigos que citam outras, como VGG, ResNet, dentre outras.

4. RESULTADOS PRELIMINARES E DISCUSSÃO

Esta seção apresenta os resultados preliminares obtidos através da metodologia apresentada na Figura 1. Foram coletadas séries temporais de 93 ações brasileiras, obtidas pelo Google Finance. Foram coletados dados diários da cotação das ações entre um período de maio de 2006 a maio de 2024. Após a coleta, calculamos o retorno dos preços de fechamento de cada ação e obtivemos séries temporais estacionárias, que serão utilizadas em todos os experimentos deste trabalho. Dadas as séries temporais dos retornos, calculamos o seu respectivo GAF utilizando o método da soma, pois este possui uma interpretação mais simples a primeiro momento. A Figura 2 apresenta um conjunto de imagens em sequência cronológica das imagens obtidas através da aplicação do GAF para ações das empresas Eletrobras (ELET3) e Petrobras (PETR4).

Figura 2: **GAF**, método da soma - Janela de 60 dias (2 meses) com intersecção de 30 dias



Fonte: Autor (2024)

Na primeira linha, ações da Eletrobras, da Figura 2, podemos observar que o maior volume da imagem é composto por azul, o que indica que a série temporal na janela selecionada possui uma alta estabilidade, isto é, sem oscilações abruptas. Conforme o tempo avança para as duas janelas

seguintes, surgem tons mais quentes, isto é amarelados, alaranjados e avermelhados, o que indicam que o mercado nestes períodos começa a se tornar mais turbulento. Já na segunda linha, ações da Petrobras, temos um comportamento caótico e de bastante risco pela grande presença de *pixels* quentes, o que indicam picos ou vales em escala global, em outras palavras, regiões distantes da média dentro da janela de tempo selecionada.

5. CONCLUSÕES PRELIMINARES

Gramian Angular Field (GAF) pode nos trazer indicadores valiosos quando se trata de troca de regime e previsão de valores, além de manter características fundamentais das séries temporais, como a dependência temporal e granularidade, o que a torna uma excelente escolha quando falamos de representar séries temporais. Além disso, a própria transformação da série temporal em imagens segue uma distribuição esparsa, o que pode ser um fator primordial para o aprendizado dos modelos. Trabalhos na literatura que aplicaram CNNs apresentaram resultados satisfatórios, o que eleva o potencial do documento apresentado.

REFERÊNCIAS

S. Barra, S. M. Carta, A. Corrigan, A. S. Podda and D. R. Recupero, "Deep learning and time series-to-image encoding for financial forecasting," in *IEEE/CAA Journal of Automatica Sinica*, vol. 7, no. 3, pp. 683-692, May 2020, doi: 10.1109/JAS.2020.1003132. keywords: {Time series analysis; Forecasting; Market research; Indexes; Encoding; Imaging; Predictive models},

Wang, Z. & Oates, T. Spatially Encoding Temporal Correlations to Classify Temporal Data Using Convolutional Neural Networks. Computer Science and Electrical Engineering Department, University of Maryland Baltimore County, 2015

KASAPBAŞI, M. C. & Bello, S. A. Encoding Time-Series Data Into Images for Financial Forecasting Using Convolutional Neural Network (CNN), Istanbul Ticaret Universitesi & Doç. Dr., Istanbul Ticaret Universitesi, (2023)

Ghasemieh, A., Kashef, R. An enhanced Wasserstein generative adversarial network with Gramian Angular Fields for efficient stock market prediction during market crash periods. *Appl Intell* **53**, 28479–28500 (2023).

J. Ngiam, Z. Chen, D. Chia, P. W. Koh, Q. V. Le, A. Y. Ng, Tiled convolutional neural networks, in: *Advances in Neural Information Processing Systems*, Computer Science Department, Stanford University, 2010

Y. Zheng, Q. Liu, E. Chen, Y. Ge, J. L. Zhao, Time series classification using multi-channels deep convolutional neural networks, in: *Web-Age Information Management*, Springer, 2014, pp. 298–310.

Sako K, Mpinda BN, Rodrigues PC. Neural Networks for Financial Time Series Forecasting. *Entropy*. 2022; 24(5):657. <https://doi.org/10.3390/e24050657>