

Universidade de Pernambuco Programa de Pós-Graduação em Engenharia da Computação (PPGEC)

Proposta de Dissertação de Mestrado

Área: Inteligência Computacional

Título: Previsão de Séries Temporais Hierárquicas utilizando Ensemble

Orientador: Domingos Sávio de Oliveira Santos Júnior (email:domingos.santos@upe.br)

Resumo

Séries temporais são conjuntos de dados coletados ao longo do tempo e ordenados cronologicamente. Entre elas, existem as que podem ser desagregadas ou agrupadas em sub-séries, dependendo de critérios como localização geográfica, fontes de informação ou regras de negócio, resultando em séries hierárquicas que podem ser analisadas em vários níveis de detalhe [1].

A previsão de séries temporais visa descrever a estrutura da série e modelar as observações passadas para prever futuros valores. Métodos tradicionais como o framework do ARIMA capturam padrões lineares nas séries possuem limitações ao lidar com padrões não-lineares [2].

Para modelar padrões não-lineares, técnicas de aprendizagem de máquina, como Redes Neurais Artificiais Perceptron de Multicamadas e Máquinas de Vetores de Suporte para Regressão, são frequentemente utilizadas. Por outro lado, podem enfrentar problemas como má especificação de parâmetros, underfitting e overfitting quando aplicados a dados reais [3].

A seleção do modelo adequado para uma série temporal pode ser desafiadora, especialmente na identificação se a série possui padrões lineares e/ou não-lineares [4]. Para melhorar a previsão e lidar com essas incertezas, utiliza-se a combinação de diferentes modelos, conhecida como ensemble. Essa abordagem combina diferentes modelos por meio de três passos: geração do grupo de modelos, seleção e agregação de previsões [5].

A literatura indica que técnicas de ensemble, que agregam múltiplos modelos, oferecem melhores resultados do que modelos sozinhos [3, 5, 6]. Este projeto propõe aplicar técnicas de ensemble a séries temporais hierárquicas, com a hipótese de que a abordagem combinada será mais eficaz na captura das dinâmicas e complexidades das séries temporais quando comparada com modelos aplicados separadamente.

Referências Bibliográficas

- [1] Hyndman, RJ (2018). Forecasting: principles and practice, OTexts.
- [2] Box, George EP et al., (2015). Time series analysis: forecasting and control, John Wiley & Sons.
- [3] Santos Júnior, Domingos S de O et al., (2023). “A hybrid system based on ensemble learning to model residuals for time series forecasting”, Information Sciences, Vol. 649, p. 119614.
- [4] Santos Júnior, Domingos S de O Santos, Oliveira, João FL de, and Mattos Neto, Paulo SG de (2019). “An intelligent hybridization of ARIMA with machine learning models for time series forecasting”,
- [5] Rostami-Tabar, Bahman and Hyndman, Rob J (2024). “Hierarchical time series forecasting in emergency medical services”, Journal of Service Research, p. 10946705241232169.
- [6] Knowledge-Based Systems, Vol. 175, pp. 72–86. Wang, Lin et al., (2018). “Optimal forecast combination based on neural networks for time series forecasting”, Applied soft computing, Vol. 66, pp. 1–17.



Programa de Pós-Graduação em
Engenharia da
Computação (PPGEC/UPE)

