

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 utilizando combinação de modelos

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 [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 ARIMA, capturam padrões lineares nas séries, mas 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, essas técnicas podem enfrentar problemas como má especificação de parâmetros, underfitting e overfitting quando aplicadas 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.

Existem na literatura diferentes formas de realizar esse processo de combinação; dois exemplos podem ser chamados de ensembles e sistemas híbridos residuais. Os ensembles combinam diferentes modelos por meio de três passos: geração do grupo de modelos, seleção e agregação de previsões [5]. Os sistemas híbridos residuais, por sua vez, realizam a previsão normalmente por uma estratégia sequencial: aplica-se um modelo linear para prever a série temporal, gerando a série de resíduos; utiliza-se esse resíduo como entrada de um modelo de aprendizagem de máquina não linear, realizando a previsão desse resíduo; por fim, as previsões lineares e não lineares são combinadas por meio de um formalismo de combinação (exemplo: soma) [4].

A literatura indica que técnicas de combinação, que agregam múltiplos e diferentes modelos, oferecem melhores resultados do que modelos individuais [3, 5, 6]. Este projeto propõe aplicar e desenvolver técnicas de combinação em séries temporais, 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)

