



Título: **Soluções em detecção de anomalias em séries temporais multivariadas utilizando modelos preditivos** Data: **30/04/2021** Horário: **09:00** Local: **Videoconferência** Resumo:

Detecção de anomalias em séries temporais é uma área de estudo em rápido crescimento atualmente, devido ao aumento exponencial da criação de novos dados temporais produzidos por sensores de diversos contextos, como, por exemplo, a Internet das Coisas (IOT). Muitos modelos preditivos foram propostos ao longo dos anos, e muitos trazem resultados promissores na diferenciação de pontos normais e anômalos nas séries temporais. Neste trabalho, serão propostas três contribuições. Em uma delas, buscamos encontrar e combinar os melhores modelos preditivos em detecção de anomalias em séries temporais, para que as diferentes estratégias e diferentes parâmetros na criação dos modelos possam contribuir para a análise das séries, propondo um ensemble baseado em modelos chamado TSPME-AD (Time Series Prediction Model Ensemble for Anomaly Detection, ou Ensemble de Modelos Preditivos em Séries Temporais para a Detecção de Anomalias). O TSPME-AD utiliza os modelos preditivos do estado-da-arte, e combina seus scores de anomalias com uma função ponderada. As outras duas contribuições desse trabalho são, uma técnica dinâmica de quebra de janelas, que utiliza a periodicidade e o formato da série para criar janelas que ajudem no treinamento dos modelos, e na descoberta dos padrões das séries com mais facilidade, e um novo modelo de auto-encoder que modifica a estrutura de um dos modelos do estado-da-arte. A efetividade das propostas do trabalho são analisadas utilizando-se dois conjuntos de dados reais, dados de um ano de demanda de energia elétrica, e o banco de dados de eletrocardiogramas do MIT. Com os experimentos, demonstramos que a técnica de ensemble proposta, melhora o score  $F_1$  em até 22% comparado com o melhor score dentre os modelos individuais que a compõem, com nossa função de combinação específica apresentando uma melhora de até 13% com relação a outras funções de combinação mais simples. Também demonstramos que nossa nova arquitetura de auto-encoder, combinada com a nova estratégia de quebra dinâmica de janelas consegue melhorias de até 25% no score  $F_1$  comparado com uma das técnicas de auto-encoder do estado-da-arte, e uma melhoria de até 64% comparado com um modelo de LSTM empilhada.

Banca examinadora:

- Prof. Dr. José Antonio Fernandes de Macêdo (Orientador - MDCC/UFC)
- Prof<sup>a</sup>. Dr<sup>a</sup>. Ticiania Linhares Coelho da Silva (Coorientadora - UFC)
- Prof. Dr. Leopoldo Melo Junior (BNB)
- Prof. Dr. César Lincoln Cavalcante Mattos (MDCC/UFC)

## **Defesa de Dissertação: Erick Lima Trentini**

Escrito por Secretaria MDCC

Ter, 27 de Abril de 2021 00:00 - Última atualização Ter, 27 de Abril de 2021 12:24

---