

Universidade de Pernambuco

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

Proposta de Tese de Doutorado

Área: Inteligência Computacional

Título: Aprendizado Federado para Previsão de Demanda e Otimização de Recursos em Ambientes Distribuídos

Orientador – Bruno José Torres Fernandes (bjtf@ecomp.poli.br)

Descrição – A análise de séries temporais é fundamental em muitos campos, como economia, meteorologia, e saúde, onde padrões temporais precisam ser analisados para previsão e tomada de decisões. Com o aumento dos dados gerados em tempo real e distribuídos geograficamente, surge a necessidade de desenvolver modelos que possam aprender de forma eficiente sem comprometer a privacidade dos dados ou incorrer em altos custos de comunicação.

O aprendizado federado [4], um paradigma emergente na aprendizagem de máquina, oferece uma solução promissora para o treinamento de modelos em dados descentralizados, mantendo a privacidade dos dados [3] e minimizando os custos associados à comunicação e armazenamento centralizado. Este projeto visa explorar o potencial do aprendizado federado na análise de séries temporais, particularmente para previsão de demanda e otimização de recursos em ambientes distribuídos [2,6], como redes de sensores, cidades inteligentes e sistemas de saúde [5].

Os principais objetivos deste projeto são:

1. Desenvolver um modelo de aprendizado federado que suporte a análise eficiente de séries temporais em um ambiente distribuído;
2. Investigar técnicas para lidar com desafios específicos de séries temporais em aprendizado federado, como a heterogeneidade dos dados e a distribuição não uniforme dos conjuntos de dados entre os participantes;
3. Avaliar a aplicabilidade do modelo em casos reais, como previsão de consumo energético em cidades inteligentes e monitoramento da saúde em tempo real.

Espera-se que o projeto resulte em um modelo de aprendizado federado robusto para séries temporais que possa ser aplicado em uma variedade de domínios, proporcionando insights valiosos para a previsão e a otimização de recursos em ambientes distribuídos, ao mesmo tempo que garante a privacidade dos dados.

Referências Bibliográficas

1. BENIDIS, K. et al. Deep Learning for Time Series Forecasting: Tutorial and Literature Survey. ACM Comput. Surv. 55, 6, 2023.
2. TULADHAR, A. et al. Building machine learning models without sharing patient data: A simulation-based analysis of distributed learning by ensembling. Journal of biomedical informatics, p. 103424, 2020.
3. ZHANG, T.; HE, Z.; LEE, R. B. Privacy-preserving machine learning through data obfuscation. ArXiv, abs/1807.01860, 2018.
4. MCMAHAN, H. B. et al. Communication-efficient learning of deep networks from decentralized data. In: International Conference on Artificial Intelligence and Statistics. [S.l.: s.n.], 2016.
5. ALEDHARI, M. et al. Federated learning: A survey on enabling technologies,

- protocols, and applications. IEEE Access, v. 8, p. 140699–140725, 2020.
6. SHAHID, O. et al. Communication efficiency in federated learning: Achievements and challenges. ArXiv, abs/2107.10996, 2021.