

Universidade de Pernambuco

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

Proposta de Dissertação de Mestrado

Área: Inteligência Computacional

Título: Otimizadores Profundos no Aprendizado Federado Local

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

Descrição – O avanço da tecnologia e a disponibilidade massiva de dados têm impulsionado o desenvolvimento de algoritmos de aprendizado de máquina cada vez mais complexos e eficientes [1]. No entanto, em muitos cenários, os dados estão distribuídos entre diversas fontes, o que torna inviável ou indesejável centralizá-los para o treinamento de um modelo global [2]. Além disso, questões de privacidade, confidencialidade e regulamentação dificultam o compartilhamento direto desses dados [3].

O aprendizado federado (Federated Learning – FL) surgiu como uma abordagem inovadora para enfrentar esses desafios [4]. Essa técnica permite o treinamento colaborativo de modelos de aprendizado de máquina em múltiplos dispositivos ou instituições, sem que os dados locais precisem ser compartilhados. O aprendizado federado viabiliza a criação de modelos globais mais robustos e representativos, preservando a privacidade dos dados e reduzindo custos de comunicação e armazenamento centralizado [5]. Essa abordagem vem sendo amplamente explorada em domínios como cidades inteligentes, segurança urbana, saúde digital e indústria 4.0 [6].

Apesar dos avanços, o aprendizado federado ainda enfrenta desafios relacionados à heterogeneidade dos dados e à estabilidade do processo de otimização. Em ambientes reais, cada nó federado possui diferentes volumes, distribuições e qualidades de dados, o que pode levar a instabilidades no gradiente, lentidão na convergência e modelos locais inconsistentes [7][9]. Nessas condições, a escolha do otimizador local — e da forma como ele ajusta seus parâmetros — torna-se um fator determinante para o desempenho global do sistema.

Os otimizadores tradicionais, como SGD, Adam ou RMSprop, seguem regras fixas de atualização, sem capacidade de se adaptar às mudanças no comportamento dos dados locais. Essa limitação é particularmente relevante em sistemas de detecção de anomalias ou monitoramento contínuo, nos quais as distribuições dos dados podem mudar com o tempo. Nesse contexto, surge a necessidade de otimizadores mais inteligentes e adaptativos, capazes de aprender como aprender em cada nó federado.

Inspirado pelo paradigma de Nested Learning [11], que propõe arquiteturas de aprendizado aninhadas em múltiplos níveis de abstração e tempo, este projeto de mestrado busca investigar o uso de Otimizadores Profundos (Deep Optimizers) em modelos locais de aprendizado federado. A ideia central é tratar o otimizador como uma rede neural adicional que aprende as próprias regras de atualização de pesos, permitindo que cada nó desenvolva uma estratégia de otimização personalizada conforme sua distribuição de dados, ritmo de aprendizado e histórico de gradientes.

Ao contrário do aprendizado federado tradicional, no qual os parâmetros do otimizador são fixos, o uso de Deep Optimizers permite incorporar mecanismos de memória temporal, autoajuste e meta-aprendizado local, tornando cada cliente capaz de evoluir sua dinâmica de aprendizado de forma autônoma. Espera-se que essa abordagem reduza a variabilidade entre os nós, acelere a convergência global e aumente a estabilidade do sistema em contextos de alta heterogeneidade.

Em suma, este projeto propõe desenvolver, implementar e avaliar uma arquitetura de

aprendizado federado que utilize otimizadores profundos nos nós locais, investigando seu impacto sobre a estabilidade, a eficiência e a capacidade de adaptação dos modelos distribuídos. A pesquisa busca contribuir tanto para o avanço científico do campo do aprendizado federado quanto para o desenvolvimento de soluções práticas em ambientes onde o comportamento dos dados é dinâmico e não uniforme.

Referências Bibliográficas

1. NGUYEN, G. T. et al. Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*, v. 52, p. 77–124, 2019.
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.I.: 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. GOSSELIN, R. et al. Privacy and security in federated learning: A survey. *Applied Sciences*, 2022.
7. SHAHID, O. et al. Communication efficiency in federated learning: Achievements and challenges. *ArXiv*, abs/2107.10996, 2021.
8. ABHISHEKV, A. et al. Federated learning: Collaborative machine learning without centralized training data. *international journal of engineering technology and management sciences*, 2022.
9. CUI, S. et al. Collaboration equilibrium in federated learning. *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, 2021.
10. RAMOS, D. B. et al. On the use of scrum for the management of research-oriented projects. *Nuevas Ideas en Informática Educativa*, n. 12, p. 589–594, 2016.
11. BEHROUZ, A. et al. Nested Learning: The Illusion of Deep Learning Architectures. *NeurIPS*, 2025.