

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

Proposta de Tese de Doutorado

Área: Inteligência Computacional

Título: Aprendizado Federado Descentralizado para Enxames de Robôs Leves

Orientador – Bruno José Torres Fernandes (bruno.fernandes@upe.br)

Descrição – O avanço recente da robótica móvel, dos sistemas multiagentes e da inteligência artificial embarcada tem impulsionado o desenvolvimento de enxames de robôs capazes de operar de forma cooperativa em ambientes dinâmicos, parcialmente observáveis e sujeitos a restrições severas de energia, comunicação e processamento [1][2]. Nesse contexto, robôs leves, tais como pequenos veículos terrestres, drones compactos, plataformas educacionais e agentes de inspeção de baixo custo, atuam simultaneamente como unidades físicas autônomas e como nós computacionais distribuídos, coletando dados locais e tomando decisões em tempo real.

Apesar do potencial desses sistemas, o treinamento centralizado de modelos de aprendizado de máquina para enxames robóticos ainda apresenta limitações importantes. A coleta de todos os dados em um servidor central pode gerar gargalos de comunicação, aumentar a latência de decisão, criar pontos únicos de falha e expor informações sensíveis sobre o ambiente, a missão ou o comportamento dos agentes [3][4]. Esses problemas são agravados quando os robôs operam em redes intermitentes, com conectividade variável, baterias limitadas e dados não identicamente distribuídos entre os participantes.

O aprendizado federado (Federated Learning – FL) surgiu como uma alternativa para permitir o treinamento colaborativo de modelos sem compartilhamento direto dos dados brutos [5], adicionando inclusive um importante requisito de privacidade. Entretanto, a maior parte das abordagens clássicas de FL assume a existência de um servidor agregador, responsável por coordenar rodadas de treinamento, selecionar clientes e combinar parâmetros. Em enxames de robôs leves, essa dependência de uma entidade central pode ser incompatível com cenários de missão em campo, nos quais conectividade com a nuvem não é garantida ou nos quais a própria topologia do exame se altera ao longo do tempo.

O aprendizado federado descentralizado (Decentralized Federated Learning – DFL) propõe superar essa limitação ao substituir o servidor central por interações par-a-par entre os nós participantes [6][7]. Em vez de enviar atualizações para um agregador único, cada robô troca conhecimento com vizinhos selecionados, permitindo que o aprendizado coletivo emerge da colaboração local. Trabalhos recentes mostram que a seleção oportunística de pares pode reduzir significativamente o consumo de energia e comunicação, mantendo desempenho similar ou superior ao de abordagens plenamente colaborativas [8]. Além disso, estudos sobre topologias de comunicação indicam que a escolha da estrutura de troca entre nós influencia diretamente a convergência, a robustez e o custo de comunicação do treinamento descentralizado [9].

Paralelamente, a literatura de TinyML e Swarm Learning evidencia que a execução de modelos de aprendizado em dispositivos com recursos limitados abre novas oportunidades para inteligência distribuída, mas também impõe desafios de memória, energia, segurança, sincronização e confiabilidade [10]. Em enxames robóticos, tais desafios são ainda mais críticos, pois o nó de aprendizado não é apenas um sensor estático, mas um agente que se move, interage fisicamente com o ambiente e pode alterar sua posição na rede de comunicação.

Nesse contexto, este projeto propõe desenvolver uma abordagem de Aprendizado

Federado Descentralizado para Enxames de Robôs Leves. A proposta adota o termo “robôs leves” no título por enfatizar o domínio de aplicação e o objeto físico do estudo, enquanto o termo “nós leves” será utilizado no texto para representar a abstração computacional de cada robô como participante do processo federado. Assim, o projeto buscará investigar como modelos compactos, protocolos par-a-par [11], seleção adaptativa de pares e topologias dinâmicas podem viabilizar aprendizado colaborativo em robôs com restrições de processamento, comunicação e energia.

A hipótese central é que enxames de robôs leves podem aprender de forma cooperativa, resiliente e eficiente sem depender de um servidor central, desde que a arquitetura de aprendizado integre mecanismos de seleção de pares, controle de comunicação, adaptação topológica e compressão/compactação de modelos. Espera-se que os resultados contribuam para aplicações em inspeção industrial, monitoramento ambiental, busca e resgate, agricultura de precisão, cidades inteligentes e robótica educacional, promovendo soluções de IA distribuída mais robustas, privadas e autônomas.

Referências Bibliográficas

1. Brambilla, M., Ferrante, E., Birattari, M. et al. Swarm robotics: a review from the swarm engineering perspective. *Swarm Intell* 7, 1–41 (2013). <https://doi.org/10.1007/s11721-012-0075-2>
2. Navarro, I., Matía, F. An introduction to swarm robotics. *ISRN Robotics* 2013, 1–10 (2013). <https://doi.org/10.5402/2013/608164>
3. Yang, Q., Liu, Y., Chen, T. et al. Federated machine learning: Concept and applications. *ACM Trans. Intell. Syst. Technol.* 10, 12 (2019). <https://doi.org/10.1145/3298981>
4. Kairouz, P., McMahan, H.B., Avent, B. et al. Advances and open problems in federated learning. *Found. Trends Mach. Learn.* 14, 1–210 (2021). <https://doi.org/10.1561/22000000083>
5. McMahan, H.B., Moore, E., Ramage, D. et al. Communication-efficient learning of deep networks from decentralized data. In: *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics*, 1273–1282 (2017). <http://proceedings.mlr.press/v54/mcmahan17a.html>
6. Yuan, L., Wang, Z., Sun, L. et al. Decentralized federated learning: A survey and perspective. *IEEE Internet Things J.* 11, 34617–34638 (2024). <https://doi.org/10.1109/JIOT.2024.3407584>
7. Sun, Y., Ochiai, H., Esaki, H. Decentralized deep learning for multi-access edge computing: A survey on communication efficiency and trustworthiness. *IEEE Trans. Artif. Intell.* 3, 963–972 (2022). <https://doi.org/10.1109/TAI.2021.3133819>
8. Masmoudi, N., Jaafar, W. OCD-FL: A novel communication-efficient peer selection-based decentralized federated learning. *IEEE Trans. Veh. Technol.* (2024). <https://doi.org/10.1109/TVT.2024.3518836>
9. Dötzer, M., Mao, Y., Diepold, K. Communication topologies for decentralized federated learning. In: *2023 Eighth International Conference on Fog and Mobile Edge Computing (FMEC)*, 232–238 (2023). <https://doi.org/10.1109/FMEC59375.2023.10306161>
10. Fragkou, E., Katsaros, D. A joint survey in decentralized federated learning and TinyML: A brief introduction to Swarm Learning. *Future Internet* 16, 413 (2024). <https://doi.org/10.3390/fi16110413>
11. Fernandes, B.J.T., Freire, A., de Andrade, J.R., Silva, L.H.S., Navarro-Guerrero, N. FedP2PAvg: A Peer-to-Peer Collaborative Framework for Federated Learning in Non-IID Scenarios. *ICANN 2025*. https://doi.org/10.1007/978-3-032-04558-4_31