

Aprendizado Federado e Deep Q-Network habilitando VANTs como Infraestrutura em Redes 6G

Renan R. de Oliveira^{1,2} Rogério S. e Silva^{1,2},
Leandro A. Freitas², Antonio Oliveira-Jr^{1,3}

¹Instituto de Informática – Universidade Federal de Goiás (UFG), GO, Brasil

²Instituto Federal de Goiás (IFG), GO, Brasil

³Fraunhofer Portugal AICOS, Porto, Portugal

{renan.rodriques, rogerio.sousa, leandro.freitas}@ifg.edu.br,

antoniojr@ufg.br

Abstract. *The deployment of Unmanned Aerial Vehicles (UAVs) as aerial base stations is a key enabler for different emerging use cases of 6G networks. In this context, this article presents a proposition for the positioning of UAVs acting as mobile network infrastructure assisted by Federated Deep Learning (FDL) and Deep Q-Network (DQN). The proposal is based on a decentralized learning paradigm that improves the communication overhead with a focus on preserving privacy and dynamically adapting UAVs to the propagation environment of mobile networks.*

Resumo. *A implantação de Veículos Aéreos Não Tripulados (VANTs) como estações base aéreas é um habilitador chave para diferentes casos de uso emergentes das redes 6G. Neste contexto, este artigo apresenta uma proposição para o posicionamento de VANTs atuando como infraestrutura de redes móveis assistidas por Federated Deep Learning (FDL) e Deep Q-Network (DQN). A proposta é baseada em um paradigma de aprendizado descentralizado que melhora a sobrecarga de comunicação com foco na preservação da privacidade e adaptação dinâmica dos VANTs ao ambiente de propagação das redes móveis.*

1. Introdução

Para garantir a cobertura para todas as áreas não conectadas no mundo, as redes 6G demandam a utilização de novas tecnologias de acesso. O 6G prevê uma arquitetura heterogênea tridimensional (3D) na qual as infraestruturas terrestres são complementadas por estações não terrestres, incluindo Veículos Aéreos Não Tripulados (VANTs), Plataformas de Alta Altitude (*High Altitude Plataformas* - HAPs) e satélites. Os VANTs voam em baixas altitudes (algumas centenas de metros) e podem fornecer conectividade sem fio em larga escala durante desastres ou eventos temporários. [Brasil 6G 2021a].

Portanto, espera-se que os VANTs forneçam serviços de comunicação para novas aplicações inteligentes orientadas por dados [Brik et al. 2020]. Nesse contexto, as abordagens assistidas por Aprendizado de Máquina (*Machine Learning* - ML) tem sido utilizadas extensivamente para fins de otimização e automação [P G and Magarini 2021].

Os VANTs que atuam como infraestrutura de redes móveis podem conter dados que necessitam de segurança e privacidade, como por exemplo, a localização, identidade e consumo de energia, bem como, o conjunto de características da distribuição espacial e temporal do deslocamento dos usuários terrestres [Brik et al. 2020]. Além do mais, as abordagens tradicionais de Aprendizado Profundo (*Deep Learning* - DL) são centradas na nuvem, gerando uma sobrecarga de comunicação da rede e resultando em atrasos de propagação [Mahlool and Abed 2022]. Isto pode comprometer a eficiência energética dos dispositivos e sobrecarregar as redes de acesso e o núcleo das redes móveis, inviabilizando determinadas aplicações em tempo real.

O Aprendizado Federado (*Federated Learning* - FL) é proposto como solução de aprendizado colaborativo com foco na preservação da privacidade, eficiência de comunicação e baixa latência [Lim et al. 2020], abrangendo técnicas de várias áreas de pesquisa, como sistema distribuído, aprendizado de máquina e privacidade. A computação de borda integrada à infraestrutura da rede, conforme proposto na abordagem *Multi-Access Edge Computing* (MEC), contribuiu para a implantação de serviços com menor latência na borda da rede, ou seja, mais próximo de onde os dados são produzidos [Brasil 6G 2021a].

Neste contexto, este artigo apresenta uma proposta para o posicionamento de VANTs como infraestrutura de redes móveis assistidas por Aprendizado Federado Profundo (*Federated Deep Learning* - FDL) e Aprendizado por Reforço Profundo (*Deep Reinforcement Learning* - DRL), visando o melhor ajuste da potência de transmissão, vazão do sistema, mobilidade e *Quality of Service* (QoS) dos equipamentos de usuários. É proposto que a agregação e distribuição dos parâmetros do modelo global seja realizado por um servidor MEC, possibilitando a implantação deste serviço próximo dos VANTs.

Para além desta seção introdutória, a Seção 2 deste artigo introduz os conceitos de ML e FL como habilitadores de VANTs em redes móveis. A Seção 3 apresenta os trabalhos relacionados. A Seção 4 discute uma proposta para a utilização de FL e DRL para o posicionamento de VANTs como infraestrutura em redes 6G. Por fim, na Seção 5, são apresentadas as considerações finais.

2. ML e FL como habilitadores de VANTs em Redes Móveis

No âmbito das Redes 6G, a Internet baseada em VANTs será o novo paradigma no avanço das comunicações móveis [Brasil 6G 2021a]. Neste contexto, o ML é um habilitador que pode ser explorado para a construção de algoritmos inteligentes para orientar a implantação e posicionamento de VANTs com capacidade de aprendizado de maneira autônoma a partir do contato com dados e experiências.

Os paradigmas de ML supervisionado e não-supervisionado utilizam dados de treinamento de forma que o modelo possa generalizar seu aprendizado para novos dados não vistos (que não fizeram parte do treinamento) ou determinar padrões ocultos que possam ser explorados para classificar elementos. O aprendizado supervisionado utiliza conjuntos de dados rotulados, enquanto o não supervisionado emprega conjuntos de dados não rotulados. No aprendizado por reforço (*Reinforcement Learning* - RL), os modelos são treinados para elaborar uma sequência de decisões. Neste paradigma, não existem dados de treinamento, pois os algoritmos se baseiam em um modelo de recompensas e punições à medida que o agente interage com o ambiente [P G and Magarini 2021] .

O DL é um subconjunto de técnicas de ML que utiliza grandes volumes de dados e um grafo profundo com várias camadas de processamento, que pode ser implementado por uma Rede Neural Profunda (*Deep Neural Network* - DNN). Considerando o enorme volume de dados, os algoritmos de DL podem superar os algoritmos clássicos de ML. O DRL é uma combinação de DL e RL. Um dos algoritmos populares de DRL é chamado *Deep Q-Network* (DQN), que lida com espaços de estado de alta dimensionalidade e utiliza uma DNN para aproximar as possíveis ações para um determinado estado. De acordo com [Brik et al. 2020], usar DRL permite que os VANTs que atuam como estações base móveis ajustem sua localização para atender usuários terrestres de acordo com a qualidade do canal prevista e, portanto, adaptem-se dinamicamente ao ambiente de propagação. Além do mais, as técnicas DRL de forma federada permitem a geração de modelos de ML colaborativos.

O FL permite que várias partes treinem em conjunto um modelo de ML sem o compartilhamento dos dados locais. O conceito FDL é composto por duas entidades principais: os clientes (participantes) que são os proprietários dos dados e um servidor agregador. Inicialmente, um modelo global é compartilhado para um conjunto de clientes. Cada participante treina um modelo local usando seu subconjunto de dados locais e, em seguida, envia apenas os parâmetros do modelo local (ou seja, os pesos do modelo) para o servidor agregador. Os modelos locais recebidos são agregados para criar um modelo global que é transmitido para os clientes [Li et al. 2021]. O FL permite que os algoritmos acumulem experiências. Em outros métodos de ML, isso nem sempre pode ser garantido [Mahlool and Abed 2022]. O FDL é baseado essencialmente em uma DNN para treinar modelos de aprendizado colaborativo em dispositivos finais, atenuando as preocupações com a privacidade e reduzindo a sobrecarga de comunicação [Brik et al. 2020].

3. Trabalhos Relacionados

Em [P G and Magarini 2021], os autores apresentam uma abordagem que utiliza RL para otimizar o posicionamento de VANTs como infraestrutura de redes móveis auxiliada por uma estação base terrestre. A técnica de Q-Learning foi usada para otimizar a posição dos VANTs. A recompensa de cada episódio é igual à soma das taxas de dados dos equipamentos de usuários. A abordagem proposta evita a colisão entre múltiplos VANTs e faz uso de um processo de aprendizagem que explora mais nas fases iniciais, sem esperar a recompensa máxima, para depois, nas fases posteriores, tomar ações para maximizá-la. Em [Hu et al. 2020] é proposto um protocolo distribuído para a coordenação de VANTs visando a melhoria da QoS de sensoriamento e comunicação. Em seguida, os autores propuseram um algoritmo Q-learning multi-VANT para resolver problemas de controle de trajetória com diferentes abordagens de RL para o problema de gerenciamento de recursos, incluindo associação de usuários, gerenciamento de energia e alocação de subcanais.

No trabalho de [Brik et al. 2020], são apresentados desafios e casos de usos relacionados do FDL no contexto de VANTs como habilitadores para redes sem fio. Os autores afirmam que soluções de aprendizado centralizado não são adequadas para estes contextos, pois exigem que dados de VANTs sensíveis à privacidade, como dados de altitude, mobilidade e consumo local de energia, sejam transmitidos a uma entidade central. Além do mais, a implantação ideal de VANTs é difícil de ser abordada de maneira centralizada, pois requer dados distintos e de diferentes entidades. Para resolvê-la, o conceito FDL pode ser usado para tratar cada fator separadamente. Por fim, os autores discutem a

implantação de VANTs atuando como estações rádio base móveis e alocação de blocos de recursos (*Resource Block* - RB) para usuários terrestres com espectro de frequência limitado. Este desafio exige que os VANTs se adaptem dinamicamente e em tempo real aos requisitos dos usuários e o aprendizado centralizado pode introduzir uma maior latência para atingir os objetivos esperados. Portanto, as técnicas de RL de forma federada são adequadas para este desafio, pois permite que os VANTs gerem de forma colaborativa um modelo de previsão em relação ao número de RBs a serem atribuídos.

Em [Shahbazi et al. 2022], os autores abordam a utilização de FDL para resolver o problema da localização de usuários terrestres utilizando VANTs como âncoras aéreas e técnicas baseadas na força do sinal recebido (*Received Signal Strength* - RSS). De acordo com os autores, o cenário inclui vários VANTs aprendendo a trajetória em diferentes configurações de ambiente, resultando na convergência mais rápida do modelo. No trabalho de [Liu et al. 2022], os autores propuseram uma abordagem para resolver o problema de otimização conjunta da implantação de estações base aéreas (*Aerial Base Station* - AeBS) em uma rede de computação de borda aérea. A abordagem utiliza um mecanismo de treinamento baseado em FDL, onde AeBSs de baixa altitude treinam suas redes neurais locais individualmente e um HAP desempenha o papel de um nó global para a agregação dos modelos. De acordo com os autores, os resultados da simulação mostraram que a abordagem proposta pode obter melhor desempenho em vários cenários de comunicação em comparação com outros esquemas de referência.

4. Proposta de VANTs como Infraestrutura em Redes 6G

Espera-se que as redes 6G acompanhem a evolução dos principais elementos da arquitetura 5G especificada pelo *3rd Generation Partnership Project* (3GPP). Neste contexto, a atual arquitetura baseada em serviços (*Service-based Architecture* - SBA) do núcleo 5G (5GC) é o ponto de partida para a evolução. O 5GC é composto de várias funções de rede (*Network Functions* - NFs) que executam tarefas específicas através das interações entre as NFs com a rede de acesso (*Radio Access Network* - RAN), com o plano de controle, com o plano do usuário e com os equipamentos de usuários.

A Figura 1 apresenta uma visão geral da proposta deste artigo para o posicionamento de VANTs atuando como infraestrutura de redes móveis assistidas por FDL e DQN. A estação base controladora (terrestre ou não terrestre) de alta potência tem a finalidade de prover tráfego de dados e fornecer links de *backhaul* sem fio para os VANTs. A RAN comunica-se com o núcleo da rede (B5G, isto é, 6G) através das interfaces N2 e N3 (nos planos de controle e usuário, respectivamente). A interface N6 possibilita a conexão com diferentes redes de dados externas ou aplicações de computação de borda.

Considerando uma proposta de arquitetura 6G evolucionária, o caminho para o núcleo 6G deve levar em conta os próximos *releases* das especificações já vislumbradas para o 5G. Portanto, propõe-se a utilização de núcleos identificado por [Brasil 6G 2021b] que podem ser expandidos para o 6G. Nesta proposta, inicialmente como núcleo da rede, propõe-se utilizar o my5G-core¹ que é um *fork* do free5GC². Esta escolha está amparada no fato do seu código ser *open source*, ser aderente ao padrão definido pelo 3GPP e possuir uma comunidade atuante de colaboradores.

¹<https://github.com/my5G/my5G-core>

²<https://www.free5gc.org>

Espera-se que alguns casos de uso das redes 6G tornem-se dependentes dos conceitos do modelo MEC. Dessa forma, propõe-se realizar a agregação e distribuição dos parâmetros do modelo global de FDL por meio de um serviço que integra o modelo de referência MEC e o 6GC. Este serviço pode ser implantado através da arquitetura SBA e uma combinação dos protocolos HTTP, REST e JSON. Neste caso, os VANTs devem enviar apenas os parâmetros dos modelos locais ao servidor MEC durante cada iteração de comunicação. A proposta do MEC como uma solução integrada ao 6GC limita o tráfego dos parâmetros dos modelos na rede de dados. Isto impacta significativamente na latência, na velocidade da rede e na segurança do tráfego dos parâmetros dos modelos.

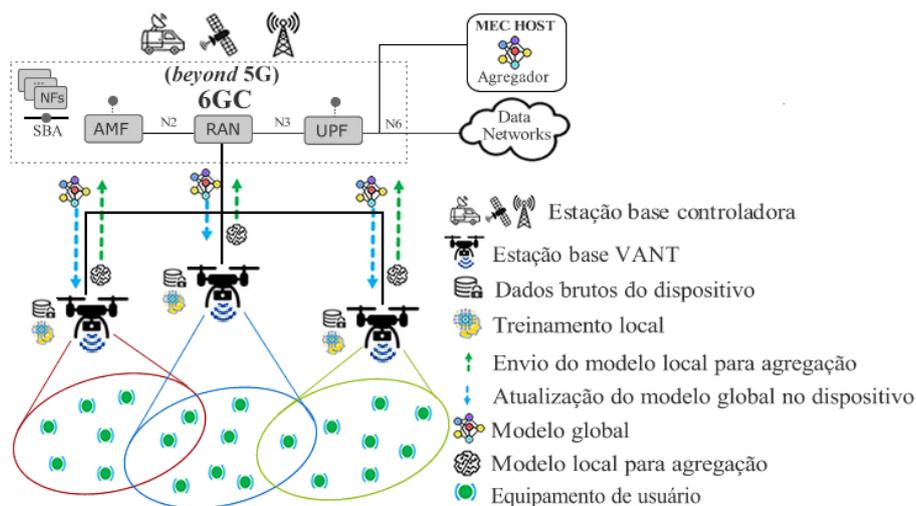


Figura 1. FL e DQN habilitando VANTs como Infraestrutura em Redes 6G

A combinação de FL e DQN visa a proposição de uma solução de aprendizado colaborativo com foco na preservação da privacidade, eficiência de comunicação e adaptação dinâmica ao ambiente de propagação. Além das informações da rede móvel, propõe-se utilizar informações ambientais, ou seja, informações contextuais das interações em tempo real entre VANTs para o enriquecimento dos parâmetros do modelo DQN. Isto inclui dados de altitude, mobilidade, consumo de energia, configuração da área geográfica, comportamentos dos usuários terrestres, características do canal sem fio, etc.

Portanto, a proposta da Figura 1 consiste em um conjunto de tarefas realizadas pelos VANTs para o ajuste da potência de transmissão e vazão do sistema, utilizando um servidor MEC atuando como agregador. Inicialmente, um modelo inicial de DQN é compartilhado para o conjunto de VANTs. O modelo inicial é treinado com base nos dados brutos de cada VANTs no próprio dispositivo, resultando em um modelo local treinado. Depois que um modelo local é treinado, os parâmetros atualizados locais de cada modelo DQN são enviados de volta ao servidor MEC para serem agregados e usados para atualizar os parâmetros do modelo global. Depois que o modelo global é atualizado (por exemplo, utilizando FedAvg), uma rodada de treinamento de FL é concluída e o modelo global atualizado deve ser transmitido para os VANTs.

A abordagem proposta é dinâmica, pois o modelo é continuamente atualizado pelo treinamento local a partir da exploração do ambiente pelos VANTs e do recebimento do modelo colaborativo. A agregação do modelo global pelo servidor MEC melhora o tempo de resposta e o consumo de largura de banda. Além do mais, considerando que o FDL

mantém os dados brutos onde são gerados, o consumo energético para a transmissão, agregação e atualizações dos modelos são minimizados no ambiente federado.

5. Considerações Finais

O escopo do 6G inclui novas estruturas que devem interagir com diferentes arquiteturas e técnicas para atingir os novos requisitos. Neste contexto, este trabalho apresentou uma visão geral de conceitos e técnicas que contribuem com os desafios para habilitar VANTs para 6G. A abordagem proposta é baseada em um paradigma de aprendizado descentralizado que permite a geração colaborativa de um modelo dinâmico com base na exploração do ambiente. Finalmente, destaca-se a necessidade de investigações para utilização de VANTs para 6G, voltadas para as temáticas de computação de borda, tecnologias de comunicação e, principalmente, a utilização de ML como elemento habilitador, considerando as características dinâmicas inerentes à natureza destes dispositivos.

Referências

- Brasil 6G (2021a). Casos de Uso e Requisitos para as Redes 6G. Disponível em: <https://inatel.br/brasil6g>. Acesso em: 07/03/2023.
- Brasil 6G (2021b). Relatório Técnico das Atividades 5.1 e 5.2 - Projeto e Seleção de Componentes, Plataformas, Ferramentas e Especificação. Disponível em: <https://inatel.br/brasil6g>. Acesso em: 07/03/2023.
- Brik, B., Ksentini, A., and Bouaziz, M. (2020). Federated Learning for UAVs-Enabled Wireless Networks: Use Cases, Challenges, and Open Problems. *IEEE Access*, 8:53841–53849.
- Hu, J., Zhang, H., Song, L., Han, Z., and Poor, H. V. (2020). Reinforcement Learning for a Cellular Internet of UAVs: Protocol Design, Trajectory Control, and Resource Management. *IEEE Wireless Communications*, 27(1):116–123.
- Li, Q., Wen, Z., Wu, Z., Hu, S., Wang, N., Li, Y., Liu, X., and He, B. (2021). A Survey on Federated Learning Systems: Vision, Hype and Reality for Data Privacy and Protection. *IEEE Transactions on Knowledge and Data Engineering*.
- Lim, W. Y. B., Luong, N. C., Hoang, D. T., Jiao, Y., Liang, Y.-C., Yang, Q., Niyato, D., and Miao, C. (2020). Federated Learning in Mobile Edge Networks: A Comprehensive Survey. *IEEE Communications Surveys Tutorials*, 22(3):2031–2063.
- Liu, L., Zhao, Y., Qi, F., Zhou, F., Xie, W., He, H., and Zheng, H. (2022). Federated Deep Reinforcement Learning for Joint AeBSs Deployment and Computation Offloading in Aerial Edge Computing Network. *Electronics*, 11:3641.
- Mahlool, D. H. and Abed, M. H. (2022). A Comprehensive Survey on Federated Learning: Concept and Applications. In *Mobile Computing and Sustainable Informatics*, pages 539–553, Singapore. Springer Nature Singapore.
- P G, S. and Magarini, M. (2021). Reinforcement Learning Aided UAV Base Station Location Optimization for Rate Maximization. *Electronics*, 10:2953.
- Shahbazi, A., Donevski, I., Nielsen, J. J., and Di Renzo, M. (2022). Federated Reinforcement Learning UAV Trajectory Design for Fast Localization of Ground Users. In *2022 30th European Signal Processing Conference (EUSIPCO)*, pages 663–666.