



Escalonamento de Recursos de Rádio para Suporte ao Aprendizado Federado em Redes 5G

Renan R. de Oliveira^{1,2}, Luan Gabriel S. Oliveira¹, Carlos Eduardo da S. Santos³,
Kleber V. Cardoso¹ e Antonio Oliveira-Jr^{1,4}

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

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

³Instituto Federal do Tocantins (IFTO), Palmas, Brasil

⁴Fraunhofer Portugal AICOS, Porto, Portugal

renan.rodriques@ifg.edu.br, luangabriel@egresso.ufg.br,
carlostedu@ifto.edu.br, {kleber,antoniojr}@ufg.br

Abstract. *This article proposes a scheduling algorithm for Federated Learning tasks in 5G networks under non-priority concurrent background traffic and constraints on communication resources. The algorithm selects devices with more representative data and better channel conditions, employs a scheduling heuristic that prioritizes model-update flows while ensuring coexistence with background traffic, and applies an aggregation strategy that reinforces the contributions that promote convergence of the global model. The implementation is integrated into the 5G-LENA module of ns-3 and demonstrates improvements in convergence and in key performance indicators of the 5G network, surpassing traditional scheduling algorithms.*

Resumo. *Este artigo propõe um algoritmo de escalonamento para tarefas de Aprendizado Federado em redes 5G considerando tráfego de fundo concorrente não prioritário e limitações dos recursos de comunicação. O algoritmo seleciona dispositivos com dados mais representativos e com melhores condições de canal, emprega uma heurística de agendamento que prioriza os fluxos de atualizações de modelos com coexistência de tráfego de fundo e aplica uma estratégia de agregação que reforça as contribuições que favorecem a convergência do modelo global. A implementação é integrada ao módulo 5G-LENA do ns-3 e demonstra melhorias na convergência e nos indicadores de desempenho da rede 5G, superando os algoritmos tradicionais de escalonamento.*

1. Introdução

As redes 5G introduzem avanços significativos nas comunicações móveis, proporcionando maior capacidade, menor latência e maior eficiência espectral [3GPP 2020a]. Neste contexto, o 5G *New Radio* (NR) define a interface de rádio, introduzindo numerologias escaláveis e configurações flexíveis. Os UEs (*User Equipment*) representam os dispositivos finais conectados à rede, enquanto a gNB atua como estação rádio-base responsável pela coordenação do acesso e pela alocação dos recursos de rádio [3GPP 2020b].

Adicionalmente, as redes B5G/6G indicam um cenário caracterizado por aplicações inteligentes emergentes, possibilitando que modelos de Aprendizado de

Máquina (*Machine Learning* – ML) sejam executados em UEs heterogêneos e com recursos limitados [Cao et al. 2023]. No entanto, em redes sem fio, o treinamento centralizado é limitado devido ao alto volume de dados transmitidos, ao risco de exposição de informações sensíveis e à sobrecarga imposta à infraestrutura de comunicação. Neste contexto, o Aprendizado Federado (*Federated Learning* – FL) [McMahan et al. 2016] surge como uma abordagem descentralizada que permite o treinamento colaborativo de um modelo global, preservando os dados nos próprios dispositivos. Em cada rodada de comunicação, os UEs selecionados recebem o estado do modelo global (w_{global}) e realizam o treinamento local utilizando um algoritmo de otimização baseado na Descida do Gradiente Estocástico (*Stochastic Gradient Descent* – SGD) com seus próprios dados. Em seguida, os UEs utilizam o canal de subida (*uplink*) para enviar os parâmetros do modelo atualizado para a gNB conectada a um servidor agregador de parâmetros, que combina as atualizações para gerar o novo estado w_{global}^{t+1} do modelo global [Chen et al. 2022].

O desempenho do FL depende da entrega completa das atualizações de modelo e da representatividade dos dados locais [Li et al. 2020]. Esses requisitos são especialmente críticos em redes 5G com múltiplos serviços e perfis de tráfego. No contexto do mMTC (*massive Machine Type Communication*), típico de cenários da Internet das Coisas (*Internet of Things* – IoT), a conexão massiva de dispositivos acentua as limitações dos recursos de comunicação. Em contraste, o eMBB (*enhanced Mobile Broadband*) prioriza altas taxas de transmissão, enquanto o URLLC (*Ultra Reliable Low Latency Communications*) impõe requisitos rigorosos de latência e confiabilidade. Dessa forma, em tais cenários, as limitações dos recursos podem impactar negativamente a convergência do treinamento federado, caso os recursos de rádio não sejam devidamente priorizados [Cao et al. 2023].

Portanto, torna-se necessária a proposição de políticas de agendamento de recursos capazes de atender aos requisitos específicos do FL, uma vez que os algoritmos tradicionais de escalonamento não contemplam essas demandas. Por exemplo, o RR (*Round Robin*) distribui os recursos de forma igualitária, sem considerar as condições do enlace ou a relevância estatística dos dados dos UEs. O MR (*Max Rate*) prioriza UEs com maior eficiência espectral, podendo excluir participantes relevantes para a convergência de w_{global} . O PF (*Proportional Fair*) tende a favorecer UEs com a melhor relação entre taxa instantânea e média histórica, o que também pode resultar na exclusão de UEs relevantes para a convergência do treinamento federado.

Neste contexto, este artigo propõe um novo algoritmo de escalonamento, denominado Fed-Sched (*Federated Learning-Aware Resource Scheduler*)¹, voltado para tarefas de FL em redes 5G, onde os fluxos de atualizações de modelos competem com tráfego de fundo concorrente não prioritário. Os fluxos concorrentes correspondem a tráfegos sem garantias de taxa, atraso ou confiabilidade, sendo utilizados para avaliar a capacidade do escalonador em priorizar os fluxos de atualizações de modelos sob saturação do *uplink*. Fed-Sched opera em três fases: primeiro, seleciona os UEs com melhores condições de canal e dados mais representativos; em seguida, aplica uma heurística de agendamento de recursos que prioriza o tráfego de atualizações de modelo e ajusta a coexistência com o tráfego de fundo; por fim, realiza a agregação ponderada, atribuindo maior peso às atualizações de UEs com dados menos heterogêneos para mitigar o desvio no processo de agregação e favorecer a convergência de w_{global} .

¹Disponível em: <https://github.com/LABORA-INF-UFG/FedSched-5G>

As principais contribuições deste artigo são: (i) **Algoritmo de escalonamento com suporte ao FL:** Fed-Sched é proposto como um algoritmo de escalonamento que prioriza os fluxos de atualizações de modelos no agendamento dos recursos de rádio em redes 5G. (ii) **Método sensível à qualidade dos dados e do canal:** Fed-Sched combina a seleção de UEs com melhores condições de canal e dados mais representativos com um esquema de agregação consciente da qualidade dos dados. (iii) **Integração com Módulo 5G-LENA do ns-3:** Fed-Sched estende o escalonador OFDMA do módulo 5G-LENA do ns-3 sem alterar sua arquitetura. (iv) **Novo Mecanismo de Coleta de Métricas:** Fed-Sched introduz a classe `GlobalMetrics`, uma instância única que registra as decisões do escalonador e possibilita a estruturação das métricas do FlowMonitor por rodada de comunicação. (v) **Disponibilização da Implementação:** O código de Fed-Sched é disponibilizado, permitindo a reprodução dos experimentos, a validação dos resultados e o uso como base para estudos e extensões futuras.

O restante deste artigo está organizado nas seções descritas a seguir. A Seção 2 discute os trabalhos relacionados. A Seção 3 apresenta uma visão geral sobre a alocação de recursos no 5G NR e a implementação do Fed-Sched. A Seção 4 descreve as etapas do algoritmo Fed-Sched. A Seção 5 detalha o cenário de simulação e apresenta a análise dos resultados. A Seção 6 apresenta as considerações finais e os trabalhos futuros.

2. Trabalhos Relacionados

O FL foi inicialmente formulado por [McMahan et al. 2016], introduzindo os princípios fundamentais e a avaliação do desempenho do algoritmo FedAvg sob diferentes modelos, conjuntos de dados e configurações experimentais. Métodos posteriores, como FedProx [Li et al. 2020] e Scaffold [Karimireddy et al. 2020], incorporam técnicas que ajustam a agregação e a atualização do modelo local, restringindo desvios excessivos e promovendo o alinhamento das representações aprendidas pelos modelos locais com o modelo global para estabilizar a convergência. No entanto, essas abordagens não consideram as limitações impostas pelas redes de comunicação.

O trabalho de [Cao et al. 2023] apresenta uma visão geral do FL sob a perspectiva da comunicação, evidenciando os desafios impostos pelas restrições e pela dinâmica das redes sem fio. Os estudos de [Chen et al. 2021] e [Chen et al. 2022] incorporam a alocação e o escalonamento de recursos de comunicação no FL por meio de técnicas de otimização, incluindo seleção de dispositivos e estratégias para redução do custo de comunicação. Em [de Oliveira et al. 2025], a seleção de dispositivos considera a qualidade dos dados, as condições do canal e a otimização da potência para reduzir o consumo energético. No entanto, esses estudos baseiam-se apenas em simulações analíticas, limitando a representação realista dos efeitos dos enlaces de comunicação sem fio.

Em [Eris et al. 2021], o FedAvg é integrado ao ns-3 [NS-3 2025] via ns3-ai [Yin et al. 2020] para analisar o impacto do tráfego de fundo na convergência de w_{global} . Utilizando uma topologia *dumbbell* com enlaces ponto-a-ponto para induzir congestionamento, o estudo demonstra que o tráfego concorrente pode degradar o desempenho do FL em cenários de alta carga. Entretanto, a abordagem não incorpora técnicas de FL conscientes do canal, restringindo-se à análise dos efeitos do tráfego. No trabalho de [Ekaireb et al. 2022], é apresentado um *framework* que integra o simulador *flsim* ao ns-3 com o objetivo de avaliar conjuntamente os efeitos de dados, algoritmos e condições

de rede no FL. A ferramenta é validada por meio de experimentos comparativos com uma implantação real baseada em Raspberry Pi. No entanto, o estudo limita-se a redes Wi-Fi e Ethernet sem a proposição de estratégias de agendamento de recursos.

No trabalho de [Villegas et al. 2024], os autores apresentaram uma extensão do módulo 5G-LENA do ns-3, implementando um escalonador baseado em teoria de Lyapunov, projetado para garantir requisitos de QoS e otimizar o uso dos recursos de rádio em cenários com tráfego XR (*eXtended Reality*). A proposta demonstra ganhos na priorização de fluxos sensíveis a taxa e atraso em comparação com os escalonadores clássicos. Entretanto, o estudo não aborda o padrão de tráfego próprio do FL no *uplink*, que é esporádico, dependente do tempo da rodada e da representatividade dos dados locais.

Motivado pelas lacunas dos trabalhos relacionados, este artigo propõe o Fed-Sched, um escalonador consciente de FL implementado no módulo 5G-LENA do ns-3, que melhora os indicadores de desempenho da rede e a convergência de w_{global} .

3. 5G NR e Modelagem do Fed-Sched no 5G-LENA

3.1. Alocação de Recursos em Redes 5G

A alocação dos recursos de rádio no 5G NR baseada em OFDMA (*Orthogonal Frequency-Division Multiple Access*) distribui o espectro simultaneamente no tempo e na frequência [3GPP 2020a]. O canal é particionado em Blocos de Recursos (*Resource Blocks – RBs*), cada um contendo 12 subportadoras durante um *slot* de tempo [Patriciello et al. 2019]. A numerologia define o espaçamento entre subportadoras (*Subcarrier Spacing – SCS*), variando entre 15 kHz e 240 kHz, estabelecendo os parâmetros físicos que organizam a ocupação do espectro e a quantidade de recursos disponíveis. Essa configuração determina a duração dos símbolos e, por consequência, a largura de banda efetiva e a quantidade de *slots* de cada TTI (*Transmission Time Interval*), influenciando diretamente a latência, a eficiência espectral e a capacidade do canal [Villegas et al. 2024].

Os *slots* são compostos por 14 símbolos OFDM [3GPP 2020a] e constituem a unidade básica de multiplexação temporal, permitindo que múltiplos UEs transmitam simultaneamente no mesmo TTI. No domínio da frequência, os recursos são distribuídos em Grupos de Blocos de Recursos (*Resource Block Groups – RBGs*) [Patriciello et al. 2019], formados pela agregação de RBs adjacentes para reduzir a sobrecarga de sinalização. O BWP (*Bandwidth Part*) especifica o intervalo espectral no qual o UE opera sob uma numerologia, sendo uma subdivisão configurável da largura de banda disponível [3GPP 2020b]. A quantidade de recursos alocáveis, incluindo o tamanho efetivo dos RBGs, é estabelecido em função da largura de banda atribuída ao BWP e de sua configuração. Essa organização habilita a multiplexação de numerologias em frequência, permitindo que diferentes BWPs coexistam na mesma largura de banda e atendam simultaneamente serviços com requisitos distintos [Villegas et al. 2024].

A gNB utiliza o CQI (*Channel Quality Indicator*) para selecionar o MCS (*Modulation and Coding Scheme*) de cada UE, definindo a ordem de modulação e a taxa de codificação, determinando a eficiência espectral e a quantidade de RBGs que são necessários para transmitir um determinado volume de tráfego [Patriciello et al. 2019]. A alocação dos recursos é efetivada por meio do DCI (*Downlink Control Information*), que especifica recursos, modulação, codificação e parâmetros de retransmissão. Essa

operação segue as definições de canais físicos, estrutura de recursos e procedimentos de camada física descritos em [3GPP 2020a] e [3GPP 2020b].

3.2. Implementação do Fed-Sched no 5G-LENA

O módulo 5G-LENA [5G-LENA 2025] do ns-3 provê uma abstração do 5G NR, permitindo a proposição de diferentes políticas de escalonamento. A implementação do Fed-Sched mantém essa estrutura, integrando-se ao fluxo padrão das decisões de agendamento sem modificar o funcionamento das classes existentes. De forma análoga aos escalonadores tradicionais, Fed-Sched pode ser selecionado diretamente nos *scripts* de simulação do ns-3. Adicionalmente, Fed-Sched integra-se ao módulo ns3-ai, o qual coordena o controle das rodadas de FL entre o ambiente Python e a simulação em C++.

A Figura 1 apresenta o diagrama UML do módulo 5G-LENA do ns-3, com destaque para as novas classes implementadas para o Fed-Sched. Em `nr-mac-scheduler-ofdma`, a implementação incorpora a lógica de coexistência adaptativa responsável por identificar os UEs elegíveis e encaminhá-los ao escalonador especializado `NrMacSchedulerOfdmaFL`, que adiciona o mecanismo de comparação que prioriza os fluxos de atualizações de modelos. A representação desses UEs é ampliada por `NrMacSchedulerUeInfoFL`, que ajusta as rotinas de ordenação das filas de escalonamento, e por `NrMacSchedulerUeExtInfo`, que introduz o atributo `isFL`. A identificação dos UEs é definida por `NrMacSchedulerLoadInfo`, que carrega o conjunto de RNTIs (*Radio Network Temporary Identifier*) dos UEs da tarefa de FL.

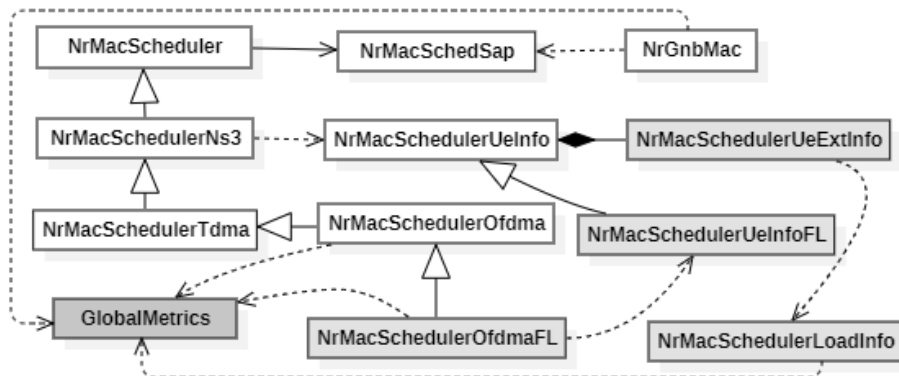


Figura 1. Diagrama UML do 5G-LENA, com novas classes do Fed-Sched.

A classe `GlobalMetrics` desempenha um papel central na simulação. Implementada como um padrão de projeto do tipo *singleton*, esta classe mantém uma única instância ativa ao longo de toda a simulação e pode ser acessada por qualquer componente do ns-3 para o registro de métricas. Esse mecanismo organiza as métricas por rodada de comunicação, utilizando o controle interno do tempo de início, término e do número da rodada para a coleta de valores como MCS, RBGs, TBSize, HARQ, `ymbPerSlot` e contagem de modelos completos transmitidos com sucesso. Dessa forma, `GlobalMetrics` registra as decisões do escalonador com precisão em cada rodada e ainda permite que as métricas de fluxo capturadas pelo `FlowMonitor` sejam agregadas e segmentadas de acordo com a janela temporal da rodada, algo que não seria trivial de calcular utilizando apenas as interfaces padrões de coletas de métricas do ns-3.

4. Projeto do Fed-Sched em Redes 5G

4.1. Seleção de UEs

Fed-Sched seleciona UEs combinando a métrica EMD (*Earth Mover's Distance*) com o SINR (*Signal-to-Interference-plus-Noise Ratio*) estimado, identificando dispositivos com dados mais representativos e melhores condições de enlace para favorecer a estabilidade e a convergência de w_{global} . O EMD é calculado por cada UE comparando sua distribuição local com uma distribuição uniforme, quantificando a heterogeneidade sem expor os rótulos dos dados. O SINR é estimado a partir do modelo de propagação em espaço livre e indica a qualidade do enlace no início de cada rodada de comunicação.

Seja \mathcal{S}_{FL} o conjunto de N UEs FL, \mathcal{S}_t um subconjunto de n_p UEs FL e b um vetor binário que representa a seleção de n_f dispositivos. Dessa forma, a determinação dos UEs participantes de cada rodada é definido como

$$\min \sum_{u \in \mathcal{S}_t} \left(\varphi \widehat{\text{EMD}}_u + \beta \frac{1}{\widehat{\text{SINR}}_u} \right) b_u, \quad (1)$$

onde EMD_u é o valor da métrica EMD e SINR_u é o valor de SINR estimado do UE u . Além disso, $n_f \leq n_p$, onde n_f define o número final de UEs selecionados para a etapa de agendamento dos recursos de comunicação. Os termos $\widehat{\text{EMD}}_u$ e $\widehat{\text{SINR}}_u$ são normalizados utilizando a normalização Min-Max, a fim de equalizar seus intervalos numéricos e garantir contribuições equilibradas na função objetivo. O coeficiente φ reforça a seleção de dispositivos com menores valores de $\widehat{\text{EMD}}_u$, enquanto β privilegia aqueles com maiores valores de $\widehat{\text{SINR}}_u$. A restrição $\sum_{u \in \mathcal{S}_t} b_u = n_f$ assegura que exatamente n_f dispositivos sejam escolhidos e a restrição $b_u \in \{0, 1\}$ estabelece que b é um vetor binário, onde $b_u = 1$ indica seleção do UE u a partir de \mathcal{S}_t e $b_u = 0$ indica o contrário.

4.2. Heurística para o Agendamento dos Recursos de Comunicação

4.2.1. Controle Adaptativo de Coexistência

Nesta fase, Fed-Sched define o conjunto de UEs para a etapa de agendamento dos recursos. Sejam \mathcal{A}_{FL} o conjunto de UEs FL com fila de *uplink* ativa e \mathcal{A}_{NFL} o conjunto de UEs com tráfego de fundo concorrente não prioritário. Dessa forma, o problema de decisão pode ser formulado como

$$\max \sum_{u \in \mathcal{A}_{FL}} s_u^{\text{FL}} + \eta \sum_{u \in \mathcal{A}_{NFL}} s_u^{\text{NFL}}, \quad (2)$$

onde s_u^{FL} e s_u^{NFL} são variáveis binárias que indicam se o UE u é mantido ou removido do escalonamento. O limite de UEs com tráfego de fundo é determinado em função da quantidade N_{FL} de UEs FL ativos, onde η atua como fator de tolerância dinâmico, ajustado conforme a função de coexistência $\Gamma(N_{FL})$. A restrição $s_u^{\text{FL}} = 1, \forall u \in \mathcal{A}_{FL}$ estabelece que todos os UEs FL com dados pendentes para transmissão devem ser mantidos no escalonamento. A restrição $\sum_{u \in \mathcal{A}_{NFL}} s_u^{\text{NFL}} \leq \Gamma(N_{FL})$ limita a quantidade de UEs com tráfego de fundo que podem coexistir no mesmo *slot* de transmissão e a restrição $s_u^{\text{FL}}, s_u^{\text{NFL}} \in \{0, 1\}$ define a natureza binária das variáveis de decisão, indicando quais UEs são mantidos no escalonamento. Assim, o relacionamento de η e $\Gamma(N_{FL})$ é dado por

$$\eta = \frac{\Gamma(N_{FL})}{N_{NFL}}, \quad (3) \quad \Gamma(N_{FL}) = \left[N_{NFL} \times \left(1 - \frac{N_{FL}}{n_f} \right)^\phi \right], \quad (4)$$

onde N_{NFL} é o número de UEs com tráfego de fundo em *uplink* ativo, n_f é o limite máximo de UEs FL por rodada e ϕ controla o decaimento. Assim, η ajusta dinamicamente a prioridade do tráfego de fundo, pois quando poucos UEs FL possuem dados pendentes $\eta \approx 1$ e, conforme N_{FL} aumenta, tanto $\Gamma(N_{FL})$ quanto η diminuem, reduzindo progressivamente a influência do tráfego de fundo.

4.2.2. Priorização dos UEs na Fila de Agendamento de Recursos

Após a etapa de coexistência, Fed-Sched organiza o conjunto resultante de UEs $\mathcal{A} = \mathcal{A}_{FL} \cup \mathcal{A}'_{NFL}$ da fila de escalonamento \mathcal{Q} para alocação dos RBGs conforme o tipo de fluxo e as condições do canal. O subconjunto \mathcal{A}'_{NFL} corresponde aos UEs com tráfego de fundo que permaneceram elegíveis para o escalonamento. Conforme descrito por [Koutlia et al. 2023], no *uplink* o 5G-LENA não distingue os LCs (*Logical Channels*) de um UE na camada MAC. Diante dessa limitação, Fed-Sched emprega a modelagem dos fluxos de atualizações de modelos agregados por UE. Dessa forma, a prioridade de cada UE u é definida como $p(u) = \text{isFL}(u) + \text{MCS}_u$, onde $\text{isFL}(u)$ é uma função indicadora que retorna 1 quando u é um UE ativo com tráfego de atualização de modelo e 0 caso contrário. O termo MCS_u define o nível de eficiência espectral alcançável em função das condições do canal. Assim, a fila de escalonamento resultante é expressa por

$$\mathcal{Q} = \{u_1, u_2, \dots, u_{|\mathcal{A}|}\}, \quad (5)$$

onde $p(u_1) \geq p(u_2) \geq \dots \geq p(u_{|\mathcal{A}|})$ indica que os UEs FL com maiores valores de MCS são alocados primeiro, seguidos pelos UEs com tráfego de fundo em ordem decrescente de MCS. Em casos de empate, os recursos são distribuídos de forma equitativa entre os UEs. Portanto, os UEs FL recebem mais RBGs no mesmo *slot* para priorizar o envio das atualizações, enquanto os UEs com tráfego de fundo podem transmitir dentro da cota de coexistência. Nos *slots* seguintes, quando os UEs FL interrompem a transmissão para o treinamento local ou na etapa de agregação, os demais fluxos passam a utilizar integralmente os recursos disponíveis, garantindo a continuidade do tráfego da rede.

4.3. Agregação Consciente da Qualidade dos Dados

Seja $f(w_{global})$ a função de perda global, que representa o objetivo de otimização sobre todos os UEs. No FedAvg, a agregação é dada por $w_{t+1} = \sum_{i \in \mathcal{S}_t} \frac{n_i}{m_t} w_{t+1}^i$, onde \mathcal{S}_t é o conjunto de UEs participantes da rodada, n_i o número de amostras locais e $m_t = \sum_{i \in \mathcal{S}_t} n_i$. No Fed-Sched, essa etapa é ajustada pela introdução de um fator de ponderação, onde o peso atribuído a cada UE é definido como $\bar{n}_i = n_i \times \frac{1}{\text{EMD}_i}$, favorecendo aqueles com dados mais representativos. Assim, a atualização global passa a ser expressa por

$$w_{t+1} = \sum_{i \in \mathcal{S}_t} \frac{\bar{n}_i}{\bar{m}_t} w_{t+1}^i, \quad (6)$$

onde $\bar{m}_t = \sum_{i \in \mathcal{S}_t} \bar{n}_i$. Portanto, ao reforçar as contribuições da etapa de agregação utilizando os valores de EMD_i , Fed-Sched reduz a divergência entre gradientes locais e globais, promovendo uma convergência mais estável e que minimiza o valor de $f(w_{global})$.

4.4. Algoritmo Fed-Sched em Redes 5G

O Algoritmo 1 descreve o fluxo de execução do Fed-Sched em uma rede 5G no módulo 5G-LENA do ns-3. Inicialmente, obtém-se o EMD_u de cada UE. No início de cada rodada, a gNB estima o $SINR_u$ do subconjunto \mathcal{S}_t e combina essa informação com EMD_u . Em seguida, Fed-Sched seleciona n_f UEs com dados mais representativos e condições de canal mais favoráveis para participar da rodada t . Após a gNB enviar w_t aos UEs selecionados, inicia-se o treinamento local e a posterior transmissão das atualizações no *uplink*. Durante essa fase, o Fed-Sched aplica o controle adaptativo de coexistência dos fluxos de transmissão, que define o conjunto \mathcal{A} de UEs elegíveis para o agendamento de recursos com base no fator de tolerância Γ , ajustado conforme o número de UEs FL ativos.

Algoritmo 1: Fed-Sched em Redes 5G

```

1 Inicializar  $w_0, \mathcal{S}_{FL}, T, n_p, n_f, \varphi, \beta, \phi, \gamma_T$ 
2 Obter  $EMD_u, \forall u \in \mathcal{S}_{FL}$ 
3  $srvSock \leftarrow \text{CreateTCPSocket}() \triangleright \text{Create, Bind e Listen}$ 
4 para cada rodada  $t = 1, 2, \dots, T$  faça
5   Determinar  $\mathcal{S}_t \leftarrow \text{rand}(\mathcal{S}_{FL}, n_p)$  e estimar  $SINR_u, \forall u \in \mathcal{S}_t$ 
6   Calcular  $\Psi_u \leftarrow \varphi \widehat{EMD}_u + \beta / \widehat{SINR}_u, \forall u \in \mathcal{S}_t$ 
7   Determinar  $\mathcal{A}_{FL}$  com  $n_f$  UEs:
8      $\mathcal{A}_{FL} \leftarrow n_f$  UEs com menor  $\Psi_u \triangleright \text{Eq. (1)}$ 
9    $\text{OpenTCP}(srvSock, u)$  e  $\text{SendDL}(srvSock, u, w_t), \forall u \in \mathcal{A}_{FL} \triangleright DL$ 
10   $\text{TrainingOnDevice}(u, w_t^u)$ 
11  para cada slot de uplink na rodada  $t$  faça  $\triangleright UL$ 
12    Determinar  $\mathcal{A}$  com até  $\Gamma$  UEs com tráfego de fundo:
13     $\mathcal{A} \leftarrow \mathcal{A}_{FL} \cup \mathcal{A}'_{NFL} \triangleright \text{Eq. (2)}$ 
14    Calcular  $p(u), \forall u \in \mathcal{A}$ :
15     $p(u) \leftarrow \text{isFL}(u) + \text{MCS}_u$ 
16    Ordenar  $\mathcal{A}$  por  $p(u)$  decrescente, definindo a fila  $\mathcal{Q}$ :
17     $\mathcal{Q} \leftarrow \text{sort}(\mathcal{A}, p(u), \text{desc}) \triangleright \text{Eq. (5)}$ 
18    Alocar RBGs em  $\text{AssignULRBG}()$ , conforme  $\mathcal{Q}$ 
19    Enviar payload UL de  $u \in \mathcal{Q}$ 
20    se  $\text{AllRecv}(w_t^u: \forall u \in \mathcal{A}_{FL})$  ou  $\text{TimeOut}(\gamma_T)$  faça
21       $\text{FinishRound}(t)$ 
22     $\text{CloseTCP}(srvSock, u), \forall u \in \mathcal{A}_{FL}$ 
23    para cada  $u \in \mathcal{A}_{FL}^{\text{succ}}$  faça
24       $w_{t+1}^u \leftarrow \text{DeviceUpdate}(u, w_t^u)$ 
25       $\bar{n}_u \leftarrow n_u \times \frac{1}{EMD_u}$ 
26       $\bar{m}_t \leftarrow \sum_{u \in \mathcal{A}_{FL}^{\text{succ}}} \bar{n}_u$ 
27       $w_{t+1} \leftarrow \sum_{u \in \mathcal{A}_{FL}^{\text{succ}}} \frac{\bar{n}_u}{\bar{m}_t} w_{t+1}^u \triangleright \text{Eq. (6)}$ 
28     $\text{Close}(srvSock)$ 
29 Retorne  $w_{global}$ 

```

A partir do conjunto \mathcal{A} , Fed-Sched calcula a prioridade $p(u)$ e organiza os UEs na fila \mathcal{Q} , utilizada na alocação dos RBGs. Em cada *slot* de UL, os UEs ordenados transmitem seu *payload* conforme os recursos atribuídos. A rodada é encerrada quando os

modelos w_{t+1}^u dos UEs FL são completamente transmitidos ou quando o limite de tempo γ_T da rodada é atingido. Apenas os modelos transmitidos com sucesso são considerados na etapa de agregação, a qual utiliza uma ponderação por EMD_u para compor o modelo global. O resultado da agregação atualiza w_t e produz w_{t+1} , repetindo esse processo até que todas as T rodadas previstas sejam finalizadas.

5. Avaliação e Análise dos Resultados

Considere uma rede 5G com topologia de célula única composta por uma gNB e $N = 150$ UEs para uma tarefa de FL. Conforme mostrado na Figura 2, os UEs são distribuídos de maneira uniforme e aleatória na área de cobertura, com distâncias variando entre 50 e 160 metros da gNB. Em cada rodada, até $n_f = 6$ UEs são selecionados a partir de $n_p = 4 \times n_f$ candidatos, os quais recebem e enviam suas atualizações de modelo via TCP. No Fed-Sched, foram utilizados $\varphi = 8$ e $\beta = 1$ na função de seleção dos UEs, atribuindo maior peso à métrica EMD do que ao SINR, com o objetivo de maximizar a seleção de UEs com dados locais mais representativos. Simultaneamente, n_f UEs entre 50 e 80 metros da gNB geram tráfego de fundo concorrente não prioritário utilizando uma aplicação `OnOff` sobre UDP, com taxas entre 256 kbps e 512 kbps. A gNB é posicionada a 50 metros de altura, enquanto os UEs operam a 1,5 metros. A Tabela 1 apresenta outros parâmetros da simulação.

Tabela 1. Parâmetros da Simulação

Parâmetro	Valor	Parâmetro	Valor
channelModel	3GPP UMa	roundWindow	5 s
gnbTxPower	41 dBm	ueTxPower	23 dBm
numerology	1	bandwidth	10 MHz
carrierFrequency	4 GHz	numCcPerBand	1
payload	407.088 bytes	seed	[1-15]

O canal segue o modelo 3GPP UMa, que representa cenários urbanos de macrocélulas, combinando condições LoS e NLoS. A simulação utiliza uma única portadora (*Component Carriers – CC*) e um único BWP, garantindo que todos os UEs operem na mesma faixa espectral e concorram pelos mesmos recursos. Dois servidores são conectados ao núcleo da rede por meio de um *gateway*, onde o primeiro recebe o tráfego federado e o segundo processa o tráfego de fundo. Além disso, cada rodada tem duração de $\gamma_T = 5$ s, totalizando $T = 100$ rodadas em cada execução da simulação.

5.1. Conjuntos de Dados e Modelos de ML

As tarefas de FL correspondem a problemas de classificação de imagens baseados nos conjuntos MNIST e Fashion-MNIST, como em [Chen et al. 2021, Eris et al. 2021, Chen et al. 2022, Ekairab et al. 2022, de Oliveira et al. 2025]. A simulação considera diferentes distribuições de dados entre UEs, variando de casos altamente enviesados com classe única a distribuições Dirichlet parametrizadas por valores de α , que controlam o grau de heterogeneidade. Valores baixos de α reforçam o viés das classes, enquanto valores altos aproximam a distribuição para um cenário balanceado. Cada UE possui entre 200 e 1.000 amostras, rotacionadas aleatoriamente em até 15° nos dois sentidos.

O conjunto de dados foi distribuído entre cinco grupos de 30 UEs, totalizando 150 dispositivos. O primeiro grupo contém dados de rótulo único, caracterizando heterogeneidade extrema. Os demais seguem distribuições Dirichlet com $\alpha = \{0,1; 0,5; 1; 10\}$ que representam diferentes graus de desbalanceamento. Neste trabalho, as partições dos conjuntos de dados MNIST e Fashion-MNIST foram denominadas R-MNIST e R-FMNIST, respectivamente. A Figura 2 apresenta a distribuição dos UEs e o grau de heterogeneidade estatística dos dados. A Figura 2a mostra o histograma das distâncias dos UEs em relação à gNB. As Figuras 2b e 2c ilustram o posicionamento dos UEs, onde o tamanho dos círculos representam a quantidade de dados locais e as cores distinguem os grupos de UEs com características similares de distribuição de dados.

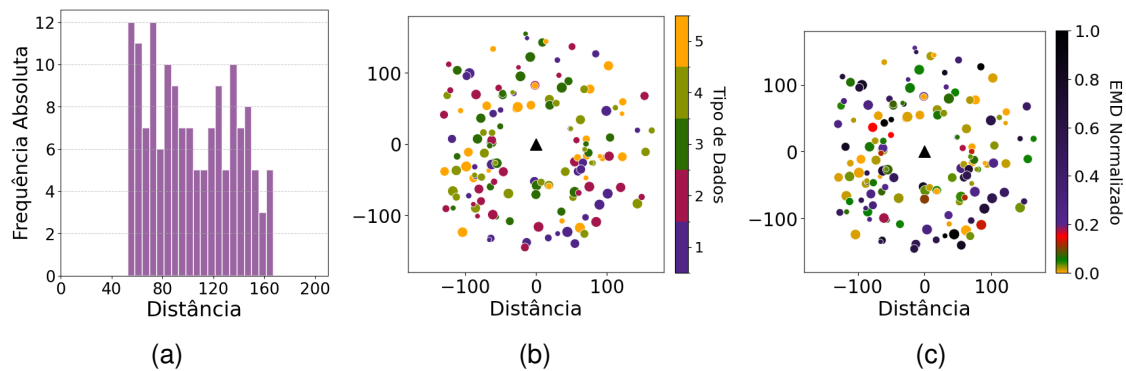


Figura 2. Distribuição e heterogeneidade dos dados dos UEs FL.

Para a tarefa de classificação do R-MNIST, utiliza-se um MLP (*Multi-Layer Perceptron*) com camadas de 192 e 96 neurônios, ativação ReLU e saída *softmax*, totalizando 170.218 parâmetros treináveis. Para o R-FMNIST, emprega-se uma CNN (*Convolutional Neural Network*) composta por três blocos convolucionais com 96 e 48 filtros, normalização e ativação ReLU, incluindo camadas *MaxPooling* e *GlobalAveragePooling*. A arquitetura é finalizada por uma camada densa com 96 neurônios, seguida de uma saída *softmax*, totalizando 178.186 parâmetros treináveis. Ambos os modelos utilizam o otimizador ADAM e a função de perda *Sparse Categorical Cross-Entropy*.

Neste trabalho, cada UE é configurado com o mesmo padrão de dados para R-MNIST e R-FMNIST, conforme a Figura 2. Como os modelos MLP e CNN apresentam quantidades semelhantes de parâmetros treináveis e, portanto, *payloads* equivalentes em torno de 407.088 bytes, ambos podem ser avaliados na mesma simulação de rede, utilizando o mesmo mapa de transmissões. Dessa forma, após a execução no ns-3 é possível comparar o desempenho do treinamento federado em modelos de ML com tamanhos equivalentes, considerando diferentes conjuntos de dados e estratégias de agregação.

5.2. Resultados da Simulação

Esta seção apresenta os resultados do Fed-Sched em comparação com RR, MR e PF. Para mitigar os efeitos da heterogeneidade estatística dos dados dos UEs, a etapa de agregação destes métodos tradicionais adota o FedProx [Li et al. 2020], cujo termo proximal estabiliza o treinamento ao restringir o afastamento entre os modelos locais e w_{global} . A Figura 3 apresenta a acurácia e $f(w_{global})$ dos algoritmos considerando o número de transmissões com êxito. As curvas contínuas mostram o desempenho médio e as regiões sombreadas representam o desvio padrão ao longo de 15 execuções independentes.

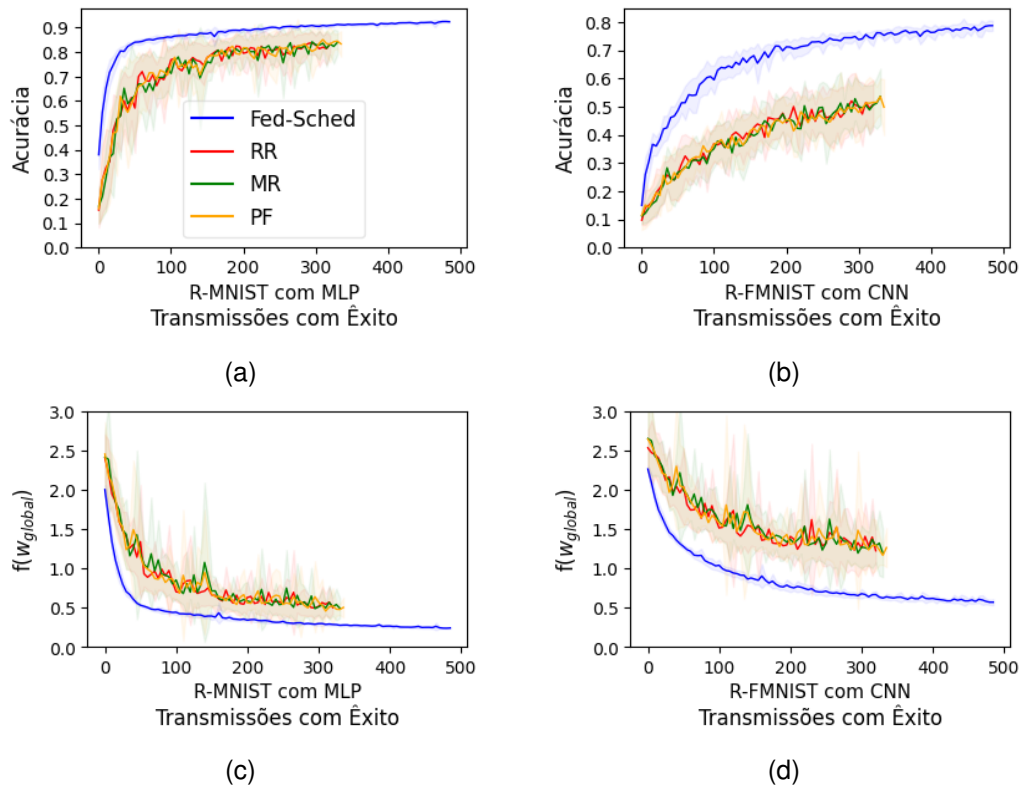


Figura 3. Evolução da acurácia e $f(w_{global})$.

De acordo com a Figura 3, Fed-Sched alcança convergência mais rápida e acurácia superior em comparação com RR, MR e PF. Isto é devido ao algoritmo de Fed-Sched que seleciona UEs com melhores condições de enlace e dados mais representativos e prioriza o tráfego de atualizações de modelo no agendamento dos recursos. Em contraste, os escalonadores tradicionais não implementam uma etapa de seleção de UEs e não controlam o tráfego não prioritário, o que resulta em transmissões incompletas, maior variabilidade estatística no treinamento dos modelos locais e convergência inferior de w_{global} , mesmo quando o FedProx é utilizado para mitigar os desvios das atualizações locais. Como consequência, Fed-Sched apresenta maior estabilidade e promove uma melhor redução de $f(w_{global})$, tanto no MLP quanto na CNN.

A Figura 4 mostra que o Fed-Sched apresenta maior confiabilidade na transmissão dos modelos, mantendo taxa de entrega elevada e perda de pacotes reduzida para os fluxos de atualizações de modelos. Em contraste, RR, MR e PF exibem menor taxa de entrega e maiores perdas, pois não implementam o controle de coexistência, e portanto, não distinguem o tráfego de FL nem limitam o tráfego de fundo concorrente não prioritário.

Na Figura 5, são apresentadas métricas de latência dos escalonadores considerando os fluxos de atualizações de modelos. Neste caso, Fed-Sched alcança menores níveis de atraso e *jitter*, pois reserva uma fração ampliada de RBGs aos UEs FL com atualizações de modelo pendentes e prioriza os fluxos federados na fila de transmissão, mitigando a concorrência com o tráfego de fundo. Em contraste, os escalonadores tradicionais apresentam maior instabilidade e degradação das métricas de latência para os fluxos federados de atualizações de modelos.

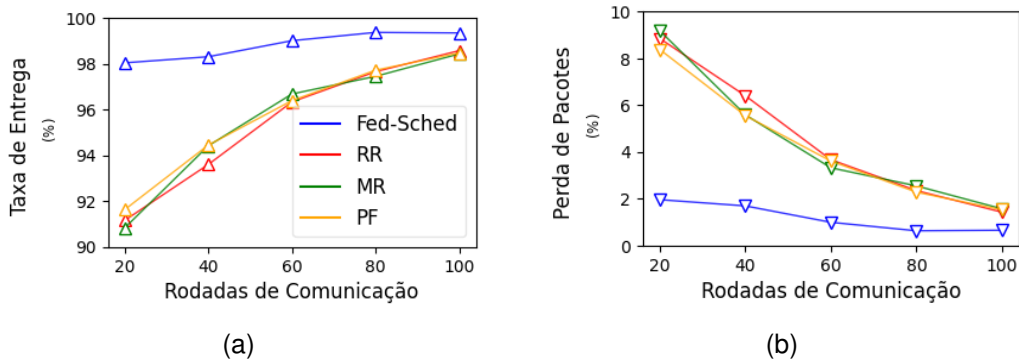


Figura 4. Taxa de entrega e perda de pacotes.

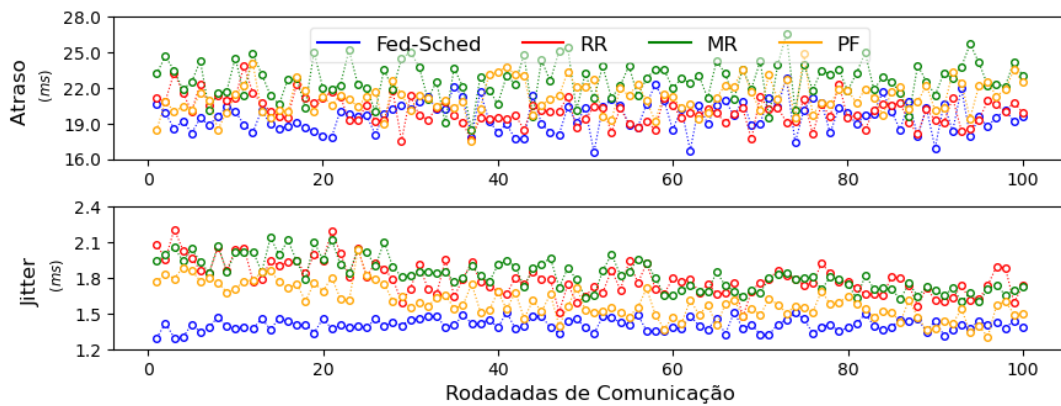


Figura 5. Atraso médio no *uplink* e variação de *jitter* dos pacotes.

A Figura 6 avalia o desempenho das transmissões na rede 5G para os fluxos de atualizações de modelos. A Figura 6a indica que Fed-Sched acumula valores menores de TBSize e mantém um número mais estável de símbolos OFDM por TTI, reduzindo oscilações causadas pela competição com o tráfego de fundo. Essa estabilidade indica menor fragmentação das unidades de transporte e maior consistência na alocação dos recursos para os fluxos federados. Na Figura 6b, Fed-Sched apresenta eficiência na redução das ativações HARQ para novos blocos de transporte e no menor número de retransmissões, indicando melhor estabilidade do processo de transmissão. Por outro lado, RR, MR e PF apresentam maior variabilidade tanto em TBSize quanto nas estatísticas HARQ, o que aumenta a fragmentação das transmissões e a probabilidade de retransmissões.

A Figura 7 apresenta a influência dos escalonadores considerando a alocação de RBGs e as transmissões completas de modelos. Na Figura 7a, observa-se que Fed-Sched acumula maior quantidade de RBGs por rodada, devido a aplicação da heurística de agendamento de recursos que prioriza os fluxos de atualizações de modelos. Por fim, a Figura 7b evidencia que o Fed-Sched apresenta mais transmissões de modelos com êxito e um menor número de falhas de transmissão. Em contraste, RR, MR e PF apresentam maior número de falhas por *timeout*, pois tratam os fluxos de atualizações de modelos e os fluxos concorrentes de forma indistinta, não garantindo condições adequadas para que o envio completo dos modelos seja concluído no tempo estabelecido para cada rodada de comunicação do treinamento federado.

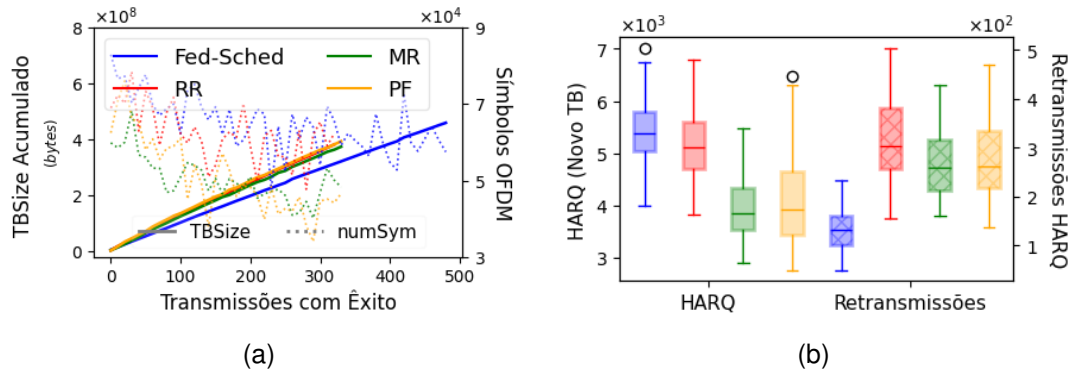


Figura 6. Desempenho das transmissões na rede 5G.

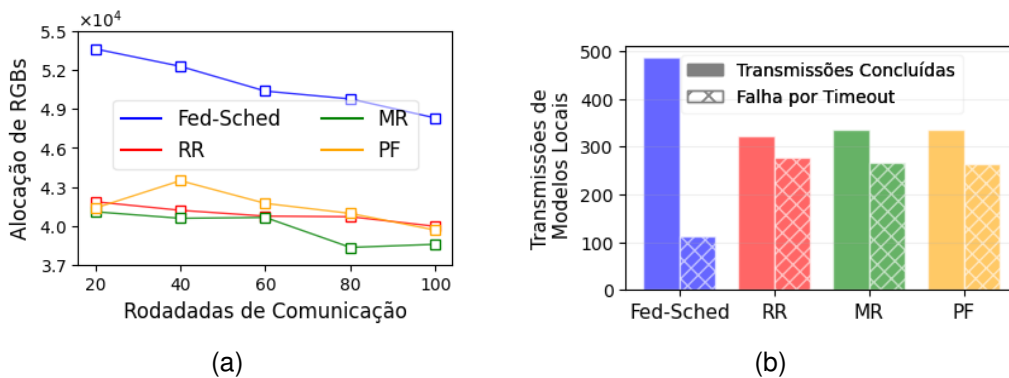


Figura 7. Alocação de RGBs e totalização das transmissões de modelos.

6. Considerações Finais

Este artigo apresentou o Fed-Sched, um escalonador para aplicações de FL em redes 5G que integra um mecanismo consciente do tráfego federado. Os resultados demonstram que Fed-Sched supera os escalonadores tradicionais, proporcionando melhorias na convergência de w_{global} e dos indicadores de desempenho da rede 5G. Como trabalhos futuros, pretende-se investigar soluções de escalonamento baseadas em Aprendizado por Reforço, considerando a coexistência dos fluxos de atualizações de modelos com tráfego útil em cenários simulados no módulo 5G-LENA do ns-3. Além disso, pretende-se avaliar o desempenho do Fed-Sched em diferentes topologias de rede com múltiplas células, diferentes perfis de tráfego e cenários com elevada densidade e mobilidade de UEs.

Disponibilidade de Artefatos

Repositório público do projeto: <https://github.com/LABORA-INF-UFG/FedSched-5G>

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Referências

3GPP (2020a). NR – Physical channels and modulation. Technical Report 3GPP TS 38.211, 3GPP, Sophia Antipolis, France. Release 16.

- 3GPP (2020b). NR – Physical layer procedures for data. Technical Report 3GPP TS 38.214, 3GPP, Sophia Antipolis, France. Release 16.
- 5G-LENA (2025). 5G NR module for ns-3. <https://5g-lena.cttc.es/>.
- Cao, X., Başar, T., Diggavi, S., Eldar, Y. C., Letaief, K. B., Poor, H. V., and Zhang, J. (2023). Communication-Efficient Distributed Learning: An Overview. *IEEE Journal on Selected Areas in Communications*, 41(4).
- Chen, H., Huang, S., Zhang, D., Xiao, M., Skoglund, M., and Poor, H. V. (2022). Federated Learning Over Wireless IoT Networks With Optimized Communication and Resources. *IEEE Internet of Things Journal*, 9(17).
- Chen, M., Yang, Z., Saad, W., Yin, C., Poor, H. V., and Cui, S. (2021). A Joint Learning and Communications Framework for Federated Learning Over Wireless Networks. *IEEE Transactions on Wireless Communications*, 20(1).
- de Oliveira, R. R., e Silva, R. S., Freitas, L. A., and Oliveira, A. (2025). Power Allocation and Communication Resource Scheduling for Federated Learning in Wireless IoT Networks. *Annals of Telecommunications*, 80(9).
- Ekaireb, E., Yu, X., Ergun, K., Zhao, Q., Lee, K., Huzaifa, M., and Rosing, T. (2022). ns3-fl: Simulating Federated Learning with ns-3. In *Proceedings of the 2022 Workshop on Ns-3*, WNS3'22, New York, NY, USA. ACM.
- Eris, M. C., Kantarci, B., and Oktug, S. (2021). Unveiling the Wireless Network Limitations in Federated Learning. In *2021 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*.
- Karimireddy, S. P., Kale, S., Mohri, M., Reddi, S. J., Stich, S. U., and Suresh, A. T. (2020). SCAFFOLD: Stochastic Controlled Averaging for On-Device Federated Learning. In *International Conference on Machine Learning (ICML)*.
- Koutlia, K., Lagen, S., and Bojovic, B. (2023). Enabling QoS Provisioning Support for Delay-Critical Traffic and Multi-Flow Handling in ns-3 5G-LENA. In *Proceedings of the 2023 Workshop on Ns-3*, WNS3'23, New York, NY, USA. ACM.
- Li, T., Sahu, A. K., Zaheer, M., Sanjabi, M., Talwalkar, A., and Smith, V. (2020). Federated Optimization in Heterogeneous Networks. In *Conference on MLSys*.
- McMahan, H. B., Moore, E., Ramage, D., Hampson, S., and y Arcas, B. A. (2016). Federated Learning of Deep Networks using Model Averaging. *CoRR*, abs/1602.05629.
- NS-3 (2025). Network Simulator. <https://www.nsnam.org/>.
- Patriciello, N., Lagen, S., Giupponi, L., and Bojovic, B. (2019). An Improved MAC Layer for the 5G NR ns-3 Module. In *Proceedings of the 2019 Workshop on Ns-3*, WNS3'19, page 41–48, New York, NY, USA. ACM.
- Villegas, N., Larrañaga, A., Diez, L., Koutlia, K., Lagén, S., and Agüero, R. (2024). Extending QoS-aware scheduling in ns-3 5G-LENA: A Lyapunov based solution. In *Proceedings of the 2024 Workshop on Ns-3*, WNS3'24, New York, NY, USA. ACM.
- Yin, H., Liu, P., Liu, K., Cao, L., Zhang, L., Gao, Y., and Hei, X. (2020). ns3-ai: Fostering Artificial Intelligence Algorithms for Networking Research. In *Proceedings of the 2020 Workshop on Ns-3*, WNS3'20, New York, NY, USA. ACM.