

# Otimização da associação entre estações base e equipamentos de usuário com auxílio de Aprendizado Federado para suporte a Realidade Aumentada Móvel

Hudson de P. Romualdo<sup>1</sup>, Luciano de S. Fraga<sup>1</sup>, Paulo F. da Conceição<sup>1</sup>,  
Flávio Geraldo C. Rocha<sup>1</sup> e Kleber V. Cardoso<sup>1</sup>

<sup>1</sup> Universidade Federal de Goiás (UFG), Goiânia, GO – Brasil  
{hudson\_romualdo, lucianosouza, paulofrancisco}@discente.ufg.br  
{flaviogcr, kleber}@ufg.br

**Resumo.** Aplicações imersivas, como Realidade Aumentada Móvel (MAR), dependem de suporte adequado da infraestrutura de comunicação para atender às expectativas dos usuários. Neste trabalho, investigamos o problema de associação de usuários de MAR a estações base que operam em sub-6 GHz e em ondas milimétricas. O objetivo é maximizar a imersão de múltiplos usuários que concorrem pelos recursos de comunicação, minimizando a latência de subida (uplink) e maximizando a vazão de subida e descida (downlink e uplink). Prever a posição e orientação de cada usuário pode contribuir de maneira significativa nesse processo de decisão. Para isso são avaliadas três abordagens baseadas em aprendizado de máquina: Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU) e Echo State Network (ESN). No entanto, as informações dos usuários estão espalhadas nas estações base devido à mobilidade e contêm erros devido à imprecisão dos sensores. O Aprendizado Federado (FL) é então utilizado para receber os modelos locais de cada usuário em um nó central, construir modelos globais com maior exatidão e utilizá-los nas decisões de associação. Por fim, devido à complexidade do problema de otimização de associação dos usuários, propomos uma heurística eficiente para solução. Observamos que a ESN apresenta maior exatidão, no geral, enquanto a GRU converge mais rapidamente no treinamento.

**Abstract.** Immersive applications, such as Mobile Augmented Reality (MAR), depend on adequate communication infrastructure support to meet users' expectations. In this work, we investigate the problem of associating MAR users with base stations that operate in sub-6 GHz and millimeter waves. The objective is to maximize the immersion of multiple users competing for communication resources, minimizing uplink latency, and maximizing uplink and downlink throughput. Forecasting the position and orientation of each user can significantly contribute to this decision process. To this end, three approaches based on machine learning are evaluated: Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and Echo State Network (ESN). However, user information is scattered across base stations due to mobility and contains errors due to sensor inaccuracy. Federated Learning (FL) is then used to receive each user's local models in a central node, build global models with greater accuracy and use them in association decisions. Finally, due to the complexity of the user association optimization problem, we propose an efficient heuristic for the solution. We observed that ESN presents greater accuracy, in general, while GRU converges faster during training.

## 1. Introdução

A Realidade Aumentada Móvel (*Mobile Augmented Reality* – MAR) [Siriwardhana et al. 2021, Bartolomeo et al. 2023] é pioneira entre as aplicações imersivas usadas em redes sem fio móveis, mas ainda vem crescendo de maneira significativa devido a evoluções de hardware, implantação das redes 5G, avanços na computação de borda e novas aplicações. Por outro lado, ainda há necessidade de soluções para oferecer o suporte adequado a múltiplos usuários de MAR através da alocação de recursos que leve em conta características específicas da aplicação.

Assim como em Realidade Virtual (*Virtual Reality* – VR) sem fio [Chung et al. 2010], MAR é sensível a flutuações breves na vazão e na latência que podem levar a problemas como quebra de presença (*Break in Presence* – BIP) e, portanto, impactar sensivelmente a experiência dos usuários [Jain et al. 2023]. O 5G introduziu as ondas milimétricas em redes móveis celulares, passando a oferecer enlaces de alta capacidade adequados para aplicações como MAR. No entanto, a mobilidade e até mesmo a orientação dos usuários podem degradar ou interromper enlaces de ondas milimétricas.

Previsão de mobilidade e orientação dos usuários podem contribuir para antecipar tomadas de decisão sobre a associação de usuários com estações bases de forma a minimizar problemas com os enlaces de ondas milimétricas, reduzindo a quantidade média de quebras de presença e, portanto, melhorando a Qualidade de Experiência (QoE) do usuário de realidade virtual móvel.

O restante do artigo está organizado de seguinte forma. A Seção 2 apresenta os trabalhos relacionados. A Seção 3 apresenta o modelo do sistema e a formulação do problema. Na Seção 4, é descrita a proposta para otimização de associação dos usuários às estações base, considerando a solução do problema de otimização, as estratégias de previsão de mobilidade (localização e orientação) e o aprendizado federado. Na Seção 5, os resultados são mostrados e discutidos, enquanto a Seção 6 apresenta as considerações finais e os próximos passos do trabalho.

## 2. Trabalhos relacionados

Soluções baseadas em aprendizado de máquina, como LSTM, tem mostrado resultados superiores a abordagens tradicionais, sobretudo quando há uma estrutura complexa na série temporal. Por outro lado, esse tipo de técnica não lida bem com dados incompletos e com erros, como pode acontecer se os modelos forem construídos junto às estações base e não no controlador central, para minimizar a sinalização de controle ou a introdução de atrasos. Assim, a construção de modelos locais, sua agregação no controlador central e redistribuição se tornam uma opção para redução de erros de previsão, ou seja, a adoção de FL. A Tabela 1 apresenta outros trabalhos na literatura que têm abordado os problemas descritos, pelo menos em parte.

VR móvel é altamente complexa porque depende de um ambiente preparado para que o usuário possa se deslocar sem riscos severos, uma vez que está completamente imerso. MAR, por outro lado, mantém o usuário ciente do ambiente real à sua volta, apenas inserindo componentes virtuais. No entanto, MAR cria uma demanda adicional na infraestrutura de comunicação porque exige que o vídeo capturado pelo dispositivo de realidade aumentada (AR) seja transmitido para enriquecimento das cenas. Além disso, MAR é mais sensível à latência, uma vez que o usuário está interagindo com o mundo real.

<sup>1</sup> <https://github.com/LABORA-INF-UFG/paper-HLPFK-2024>

**Tabela 1. Comparação com trabalhos relacionados.**

Referência	Aplicação	Solução da associação	Previsão	FL	Replicabilidade
[Picano et al. 2023]	Genérica	–	ESN, LSTM	Não	Difícil
[Yang et al. 2022]	VR móvel	DRL	ESN	Não	Muito difícil
[Chen et al. 2020]	VR móvel	DRL	ESN	Sim	Muito difícil
[Sun et al. 2018]	VR móvel	–	–	–	Difícil
[Yang et al. 2018]	VR móvel	–	–	–	Difícil
[Ge et al. 2017]	Genérica	Algoritmo	–	Não	Muito difícil
<b>Este artigo</b>	<b>MAR</b>	<b>GRASP</b>	<b>ESN, GRU, LSTM</b>	<b>Sim</b>	<b>Muito fácil</b> <sup>1</sup>

Essas diferenças impactam o cálculo de BIP para MAR. Portanto, apesar das semelhanças, nosso trabalho é distinto das investigações realizadas em [Chen et al. 2020]. Em [Picano et al. 2023], os autores abordam um serviço de jogos que pode representar uma aplicação VR ou AR. No entanto, utilizam uma representação genérica da aplicação cujo requisito é basicamente a potência de sinal recebida no dispositivo do usuário. Uma abordagem similar, porém baseada em latência é utilizada em [Ge et al. 2017].

Em [Picano et al. 2023], não é apresentado um modelo de alocação de recursos para o problema de associação porque os autores utilizam apenas a potência do sinal recebido para definir com qual estação base cada usuário deve se associar. Em [Yang et al. 2022, Chen et al. 2020], os autores exploram o potencial de *Deep Reinforcement Learning* (DRL) para resolver problemas de alocação de recursos, enquanto em [Ge et al. 2017], os autores optam por formular um problema que permite obter a solução com um algoritmo ótimo. Em [Sun et al. 2018, Yang et al. 2018], há apenas um usuário e uma estação base, logo o problema de associação não é abordado. Neste trabalho, optamos por uma abordagem inspirada na meta-heurística *Greedy Randomized Adaptive Search Procedure* (GRASP), a qual exibiu resultados satisfatórios tanto em qualidade das soluções quanto em escalabilidade, conforme mostramos na seção de resultados. Embora a solução ótima seja desejável, o problema de associação abordado é  $NP$ -completo e, logo, apresenta limitações em escala e tempo de resposta em um *solver* exato. Apesar dos resultados promissores, a adoção de DRL para alocação de recursos apresenta dificuldades, tais como tempo de (re)treinamento e generalização, que não são abordadas nos trabalhos da Tabela 1. Já havíamos observado em um trabalho anterior [Almeida et al. 2023] que, em determinados problemas, uma meta-heurística pode trazer mais benefícios que DRL.

Ao utilizar estratégias de previsão, é possível tomar decisões melhores em comparação a abordagens reativas, mas parte dos trabalhos listados na Tabela 1 não exploram esse fato. Os demais trabalhos utilizam alguma solução baseada em aprendizado de máquina, com destaque para ESN, mas apenas o nosso trabalho incluiu a GRU na avaliação. Além disso, apenas [Chen et al. 2020] e o nosso trabalho usufruem dos benefícios de usar FL, destacando que essa abordagem não seria justificada em [Sun et al. 2018, Yang et al. 2018] porque há apenas um usuário e uma estação base. Por fim, vale mencionar a dificuldade de replicabilidade de todos os trabalhos anteriores, em especial os mais complexos que envolvem a combinação de diversos elementos e não oferecem nenhuma informação além de seus textos. Todo o material deste trabalho, em especial, código e conjunto de dados, estão disponíveis em repositório público.

### 3. Modelo do sistema e formulação do problema

Neste trabalho, consideramos uma rede móvel celular constituída de um conjunto de  $\mathcal{B} = \{1, 2, \dots, B\}$  estações base que oferecem acesso a um conjunto  $\mathcal{U} = \{1, 2, \dots, U\}$  de usuários de MAR que caminham dentro de uma determinada área. As estações base se interligam a um nó central responsável por tarefas como tomar decisões de associação (usuários – estações) e oferecer conectividade com redes externas. Os usuários utilizam óculos de AR com capacidade de comunicação em sub-6 GHz e em ondas milimétricas (i.e., a partir de 26 GHz), conforme ilustrado na Figura 1.

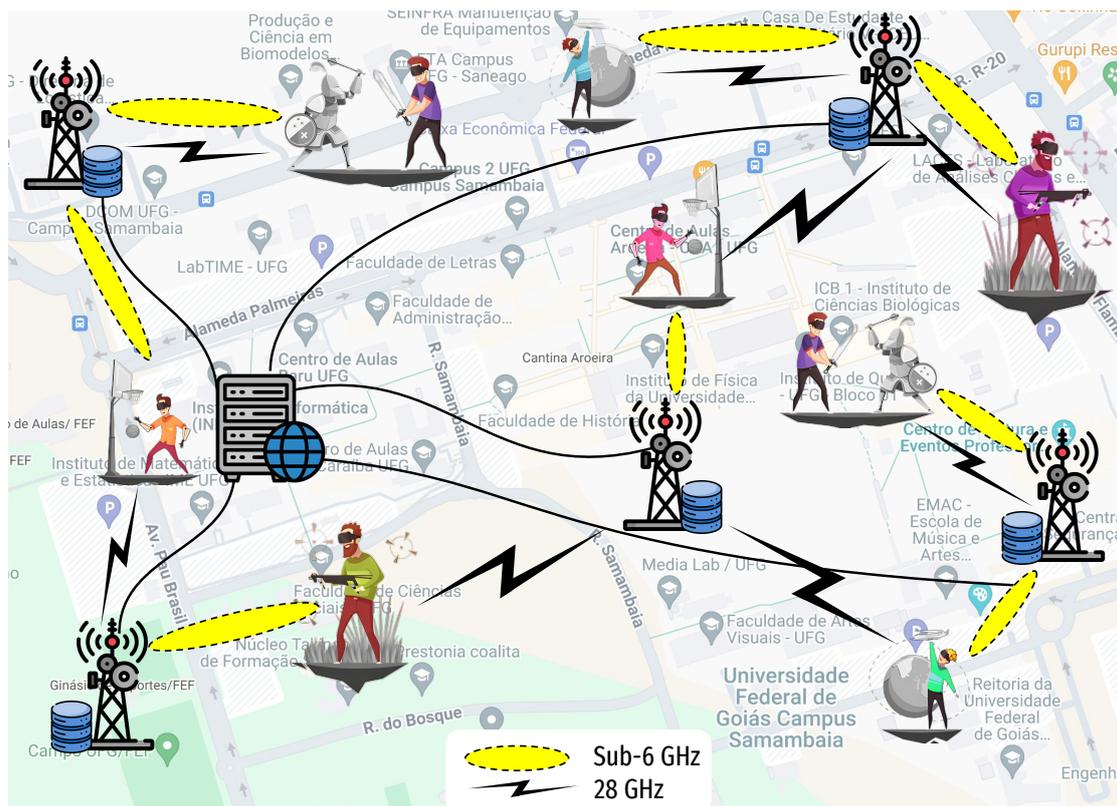


Figura 1. Cenário considerado no modelo de sistema.

Por oferecer uma comunicação mais estável, sub-6 GHz é usada para envio de comandos do usuário ao interagir com o ambiente de AR e também para enviar as informações de sensoriamento do óculos, i.e., localização e orientação do usuário. Essas últimas informações são recebidas regularmente apenas pela estação base com a qual o usuário está associado em sub-6 GHz e usadas para construção de um modelo local de previsão de mobilidade (i.e., localização e orientação) do usuário. O modelo local de cada usuário é enviado para o nó central para agregação, conforme será descrito posteriormente. As estações base também contam com sensores adicionais para monitorar os usuários que não estão associados a elas, mas que se movem em sua vizinhança, permitindo que elas também computem modelos locais de previsão que são enviados para o nó central. Como sub-6 GHz é amplamente usada, não apenas pelos usuários de MAR, as mudanças de associação desse tipo de usuário têm como foco minimizar a latência, i.e., associar os usuários de MAR às estações base com menor carga.

As ondas milimétricas são utilizadas para envio (em *uplink*) do vídeo capturado pelos óculos de AR e (em *downlink*) do conteúdo virtual a ser usado para enriquecer

as cenas. Devido a sua alta vazão, as ondas milimétricas são adequadas para atender esse tráfego de maior demanda, porém, os feixes estreitos desse tipo de tecnologia são sensíveis à mobilidade do usuário. Portanto, as informações de mobilidade obtidas pelo nó central através dos modelos de previsão são muito importantes para a tomada de decisão de associação dos usuários com as estações base em ondas milimétricas.

O cenário descrito leva ao desbalanceamento dos dados de mobilidade do usuários, o que pode afetar as previsões e, por consequência, as decisões de associação, sobretudo em ondas milimétricas. Portanto, é adotado o treinamento no formato federado, no qual as estações base figuram como clientes da federação e o nó central assume o papel de servidor. Enquanto clientes, as estações base realizam o treinamento dos modelos para cada usuário. Ao final de cada ciclo de treinamento local, cada estação base transmite para o servidor somente os modelos e suas respectivas medidas de exatidão. O servidor tem como objetivo a agregação dos modelos fornecidos pelas estações base e, portanto, o provimento de um modelo ótimo de previsão para cada um dos usuários.

### 3.1. Modelo de comunicação

Sejam  $(x_{it}, y_{it})$  as coordenadas cartesianas que representam a localização do usuário  $i$  de MAR no tempo  $t$ . A taxa de dados para transmitir os comandos do usuário  $i$ , assim como suas informações de rastreamento, para a estação base  $j$  é expressa por:

$$c_{ij}^{sub6}(x_{it}, y_{it}) = \frac{F^{sub6}}{\mathcal{U}_j} \log_2 \left( 1 + \frac{P_u g_{ij} d_{ij}^{-\beta}(x_{it}, y_{it})}{\sum_{k \in \mathcal{U}_j} P_u g_{kj} d_{kj}^{-\beta}(x_{kt}, y_{kt}) + \rho^2} \right), \quad (1)$$

onde  $F^{sub6}$  é a largura de banda total do *uplink* de cada estação base  $j$  (assumida igual para todas as estações),  $\mathcal{U}_j$  é o conjunto de usuários de MAR associados à estação base  $j$ ,  $P_u$  é a potência de transmissão do dispositivo de cada usuário de MAR (assumida igual para todos),  $g_{ij}$  é o ganho do canal com desvanecimento *Rayleigh*,  $d_{ij}$  é a distância entre o usuário de MAR  $i$  e a estação base  $j$  no tempo  $t$ , e  $\rho^2$  é a potência do ruído.

Para a comunicação em ondas milimétricas, o ganho de antena da estação é obtido de forma simplificada considerando quatro parâmetros: a largura do feixe de meia potência  $\phi$ , a direção de visada  $\theta$ , o ganho do lóbulo principal  $Q$  e o ganho do lóbulo lateral  $q$ . Seja  $\varphi_{ij}$  a fase da estação base  $j$  até o usuário  $i$ , então temos:

$$G_{ij} = \begin{cases} Q, & \text{caso } |\varphi_{ij} - \theta| \leq \frac{\phi}{2}, \\ q, & \text{caso } |\varphi_{ij} - \theta| > \frac{\phi}{2}. \end{cases} \quad (2)$$

Para representar o efeito de bloqueio  $b_i(\chi_{it})$  causado pelo próprio usuário  $i$ , levamos em conta sua orientação  $\chi_{it}$  no tempo  $t$  e o ângulo máximo  $\vartheta$  na qual a estação base  $j$  pode transmitir em ondas milimétricas diretamente. Dado que  $\Phi_{ij}$  denota a fase do usuário com relação à estação base  $j$ , temos:

$$b_i(\chi_{it}) = \begin{cases} 1, & \text{caso } |\Phi_{ij} - \chi_{it}| \leq \vartheta, \\ 0, & \text{caso } |\Phi_{ij} - \chi_{it}| > \vartheta. \end{cases} \quad (3)$$

A transmissão de vídeo (em *uplink*) e o enriquecimento de cenas (em *downlink*) entre a estação base  $j$  e o usuário de MAR  $i$  pode ocorrer com linha de visada (*Line of*

*Sight* – LoS) ou sem linha de visada (*Non-Line of Sight* – NLoS). A perda de potência no caminho, para cada condição de propagação, é determinada como segue:

$$\begin{aligned} h_{ij}^{LoS}(x_{ij}, y_{ij}) &= L_{FS}(d_0) + 10\mu_{LoS} \log(d_{ij}(x_{ij}, y_{ij})) + \chi_{\sigma_{LoS}}, \\ h_{ij}^{NLoS}(x_{ij}, y_{ij}) &= L_{FS}(d_0) + 10\mu_{NLoS} \log(d_{ij}(x_{ij}, y_{ij})) + \chi_{\sigma_{NLoS}}, \end{aligned} \quad (4)$$

onde  $L_{FS}(d_0)$  representa a perda no caminho do espaço livre para a distância de referência  $d_0$ ,  $\mu_{LoS}$  e  $\mu_{NLoS}$  representam os expoentes de perda de caminho para LoS e NLoS,  $\chi_{\sigma_{LoS}}$  e  $\chi_{\sigma_{NLoS}}$  são variáveis aleatórias Gaussianas com média zero e variância  $\sigma$ .

Também são considerados, por meio da variável  $n_{ij}$ , os bloqueios causados por outros usuários de MAR que estejam posicionados entre o usuário  $i$  e a estação base  $j$ . Considerando que as constantes  $F^{mmW}$  e  $P_B$  representam, respectivamente, a banda alocada para cada usuário de MAR e a potência de transmissão de cada estação base (assumida igual para todas). A taxa de dados para a transmissão de conteúdo é definida da seguinte forma:

$$c_{ij}^{mmW}(x_{it}, y_{it}, b_i(\chi_{it}), n_{ij}) = \begin{cases} F^{mmW} \log_2 \left( 1 + \frac{P_B G_{ij}}{10^{\frac{h_{ij}^{LoS}}{10}} \rho^2} \right), & \text{caso } b_i(\chi_{it}) + n_{ij} = 0 \\ F^{mmW} \log_2 \left( 1 + \frac{P_B G_{ij}}{10^{\frac{h_{ij}^{NLoS}}{10}} \rho^2} \right), & \text{caso } b_i(\chi_{it}) + n_{ij} > 0 \end{cases}. \quad (5)$$

### 3.2. Quebra de presença

Em MAR, a quebra de presença (BIP) é observada quando ocorre inconsistência nas formas dos objetos virtuais adicionados às cenas, afetando a qualidade de experiência do usuário [Jain et al. 2023]. Para identificar os eventos de BIP consideramos conjuntamente o atraso na transmissão dos comandos do usuário e suas informações de mobilidade (em sub-6 GHz), assim como o envio do vídeo e a recepção dos elementos virtuais para as cenas (em ondas milimétricas). Assim, representamos a ocorrência de BIP para o usuário de MAR  $i$  no tempo  $t$  da seguinte forma:

$$\omega_{it}(x_{it}, y_{it}, \mathcal{X}_{it}, \mathbf{a}_{i,t}^{sub6}, \mathbf{a}_{i,t}^{mmW}) = \mathbb{1} \left\{ \frac{S}{a_{ij,t}^{sub6} c_{ij}^{sub6}} + \frac{2 \times D(l_{i,t})}{a_{ik,t}^{mmW} c_{ik}^{mmW}} > \gamma_D \vee l_{i,t} \mathbf{m}_{i,t}(\Psi_S) < \gamma_Q \right\}, \quad (6)$$

onde as variáveis de decisão  $a_{ij,t}^{sub6}$  e  $a_{ik,t}^{mmW}$  dizem respeito, respectivamente, à associação do usuário  $i$  a estações base  $j$  (em sub-6 GHz) e  $k$  (em ondas milimétricas), no instante  $t$ , sendo  $a_{ij,t}^{link} = 1$ , caso exista comunicação, e  $a_{ij,t}^{link} = 0$ , caso contrário.  $S$  representa o tamanho médio dos dados de localização transmitidos no enlace de sub-6 GHz, enquanto  $D(l_{i,t})$  denota o tamanho médio dos dados da aplicação de MAR. O vetor  $l_{i,t} = [l_{i1,t}, l_{i2,t}, \dots, l_{iN_L,t}]$  representa o conteúdo MAR transmitido/recebido, onde  $l_{ik,t} \in \{0, 1\}$  indica se o pixel  $k$  é transmitido/recebido com sucesso. A matriz  $\mathbf{m}_{i,t}(\Psi_S) = [m_{i1,t}, m_{i2,t}, \dots, m_{iN_L,t}]^T$  representa a importância dos pixels, onde  $m_{ik,t} \in [0, 1]$  indica a importância individual e  $\Psi_S$  identifica uma aplicação de MAR. Assim, a função  $\mathbb{1}_{\{x\}} = \{0, 1\}$  define a ocorrência de um evento de BIP caso os requisitos de latência ( $> \gamma_D$ ) ou qualidade de conteúdo ( $< \gamma_Q$ ) não sejam atendidos. A média de BIPs que o usuário  $i$  percebe durante um período de tempo  $T$  é:

$$P_i(x_{it}, y_{it}, \Psi_S, \mathcal{X}_{it}, \mathbf{a}_{i,t}^{sub6}, \mathbf{a}_{i,t}^{mmW}) = \frac{1}{T} \sum_{t=1}^T (\Psi_S + \omega_{it} + \Psi_S \omega_{it} + \epsilon_i + \epsilon_{\Psi_S|i} + \epsilon_B), \quad (7)$$

onde  $\epsilon_i$  representa o nível de consciência imersiva do usuário  $i$ ,  $\epsilon_{\Psi_S|i}$  descreve o efeito conjunto do nível de consciência desse usuário e do tipo da aplicação  $\Psi_S$  que está utilizando, enquanto  $\epsilon_B$  é o equivalente ao ruído aleatório de um modelo de regressão. Esses três parâmetros seguem uma distribuição Gaussiana [Chung et al. 2010] com média zero e variâncias  $\sigma_i^2$ ,  $\sigma_{\Psi_S|i}^2$  e  $\sigma_B^2$ , respectivamente.

### 3.3. Formulação do problema

Considerando as comunicações nos enlaces sub-6 GHz (Equação 1) e de ondas milimétricas (Equação 5), o objetivo é reduzir a quantidade média de BIPs (Equação 7) de todos os usuários do conjunto  $\mathcal{U}$ , controlando a associação dos usuários, ou seja:

$$\underset{\mathbf{a}_{i,t}^{sub6}, \mathbf{a}_{i,t}^{mmW}}{\text{minimizar}} \quad \sum_{i \in \mathcal{U}} P_i(\hat{x}_{it}, \hat{y}_{it}, \Psi_S, \hat{\chi}_{it}, \mathbf{a}_{i,t}^{sub6}, \mathbf{a}_{i,t}^{mmW}) \quad (8)$$

$$\text{sujeito a : } U_j \leq V, \quad \forall j \in \mathcal{B}, \quad (9)$$

$$\mathbf{a}_{i,t}^{sub6}, \mathbf{a}_{i,t}^{mmW} \in \{0, 1\}, \quad \forall i \in \mathcal{U}, \forall j \in \mathcal{B}, \quad (10)$$

$$\sum_{j \in \mathcal{B}} \mathbf{a}_{ij,t}^{sub6} = 1, \quad \sum_{k \in \mathcal{B}} \mathbf{a}_{ik,t}^{mmW} = 1, \quad \forall i \in \mathcal{U}, \quad (11)$$

onde  $(\hat{x}_{it}, \hat{y}_{it})$  e  $\hat{\chi}_{it}$  são a localização e orientação previstas para o usuário  $i$  no tempo  $t$ ,  $U_j$  é o número de usuários associados à estação base  $j$  no enlace de ondas milimétricas e  $V$  é o número máximo de usuários que podem estar associados a cada estação base. A restrição (11) garante que cada dispositivo de usuário sempre mantém uma associação em sub-6 GHz e uma em ondas milimétricas. O problema descrito é  $\mathcal{NP}$ -completo e apresentaremos na próxima seção uma abordagem não exata para sua solução. Apresentaremos também as estratégias baseadas em aprendizado de máquina para obtenção das previsões de localização  $(\hat{x}_{it}, \hat{y}_{it})$  e orientação  $\hat{\chi}_{it}$ .

## 4. Aprendizado federado para auxiliar a associação otimizada

Nesta seção, inicialmente, descrevemos as redes neurais utilizadas para fazer a previsão de mobilidade dos usuários e como os modelos gerados em cada estação base são agregados no nó central utilizando FL. A seguir, apresentamos uma abordagem inspirada na meta-heurística GRASP para solução do problema de otimização descrito na seção anterior.

### 4.1. Redes neurais para previsão e estratégia de agregação

Neste trabalho, utilizamos três tipos de Rede Neural Recorrente (*Recurrent Neural Network* – RNN), a saber: LSTM, GRU e ESN. Essas três redes são variantes adequadas para a modelagem de dependências temporais em dados sequenciais. Tanto GRU quanto LSTM são tipos de células de memória em RNNs, sendo a LSTM mais complexa, incorporando unidades de controle de memória e portões adicionais. A GRU, por sua vez, possui uma estrutura mais simplificada, com menos portões, tornando-a computacionalmente mais eficiente. Em contraste, a ESN é uma classe de RNN com unidades de estado fixas, onde a matriz de pesos da camada recorrente é inicializada aleatoriamente e não é treinada durante o processo de aprendizado, focando na exploração da dinâmica do sistema. ESN é caracterizada por um procedimento de aprendizagem com tempo computacional reduzido [Bianchi et al. 2017]. Para cada usuário  $i \in \mathcal{U}$  é criado um modelo de aprendizado de máquina em cada estação base  $j \in \mathcal{B}$  para previsões de localização  $(\hat{x}_{it}, \hat{y}_{it})$  e orientação  $\hat{\chi}_{it}$ . Avaliamos a criação dos modelos utilizando cada uma das três redes neurais que foram descritas.

Os vários modelos de previsão gerados pelas estações para cada usuário têm exatidões afetadas pela mudança de associação em sub-6 GHz, o que espalha as informações reportadas pelo dispositivo do usuário em múltiplas estações base, e pela mobilidade que afeta o sensoriamento realizado pelas estações com as quais o usuário não está associado. Para lidar com esse problema, foi adotada uma implementação de aprendizado federado canônico como abordagem para agregação dos modelos locais em um modelo global por usuário, utilizando o algoritmo Média Federada (FedAVG) [McMahan et al. 2017]. A cada rodada de treinamento, os pesos atualizados de cada modelo local, treinados nas estações base para cada usuário, são agregados de maneira ponderada, utilizando uma média, com base na exatidão de cada modelo. Assim, o FedAVG permite combinar os pesos dos modelos treinados localmente e criar um modelo global mais robusto e generalizado para cada usuário.

Para evitar que em determinada rodada de treinamento um modelo local com baixa exatidão venha a reduzir a qualidade do modelo global, foi introduzida uma estratégia para permitir ou não a agregação. Ou seja, somente modelos considerados aptos são agregados, enquanto os demais não contribuem com o modelo global. Com base na exatidão  $\xi_{ij}$  do modelo de cada usuário  $i \in \mathcal{U}$ , a qual é verificada em cada estação  $j \in \mathcal{B}$ , são obtidos a média  $\mu(\xi_i)$  e o desvio padrão  $\sigma(\xi_i)$ . A aptidão de um modelo para agregação é definida da seguinte forma:

$$\text{apto} = \begin{cases} \text{sim, se } |\mu(\xi_i) - \xi_{ij}| > \sigma(\xi_i) \\ \text{não, caso contrário.} \end{cases}$$

A interrupção do treinamento é realizada ao alcançar um limiar de exatidão definido empiricamente, o qual se baseou na média das exatidões dos modelos locais participantes da agregação a cada rodada de treinamento. Uma vez que é observado pelo nó central que a exatidão do modelo para determinado usuário já alcançou um valor maior ou igual ao limiar, significa que esse modelo está pronto para ser utilizado para realizar previsões sobre localização e orientação. Portanto, o modelo está disponível para ser usado na tomada de decisão de associação.

## 4.2. Meta-heurística

Levando em consideração os dados de localização e orientação obtidos através de modelos de FL, as posições fixas de estações base, bem como a localização de objetos e construções que possam influenciar nas definições de LoS e NLoS, podemos definir a associação ótima entre usuários e estações base resolvendo o problema de programação linear inteira (*Integer Linear Programming* – ILP) descrito na Seção 3.3. Porém, problemas de otimização combinatória desta natureza apresentam complexidade  $\mathcal{NP}$ -completo. Adotamos então uma abordagem baseada na meta-heurística GRASP, na qual inserimos duas alterações importantes em relação a sua versão canônica [Zäpfel et al. 2010]: **1)** o algoritmo não apresenta lista restritiva de candidatos (*restricted candidate list*) e **2)** não é utilizado outro algoritmo de busca local nas soluções construídas. Assim, nossa abordagem apresenta maior agressividade ao encontrar boas aproximações, em tempo inferior a versão completa de GRASP e, conforme será mostrado posteriormente, obtivemos resultados satisfatórios para o problema de decisão de associação.

O Algoritmo 1 apresenta a abordagem meta-heurística que implementamos. Inicialmente, criamos uma solução vazia  $s$ , ou seja, que não possui nenhuma associação entre usuários e estações base. A variável  $c_m \in C$  representa um componente da solução,

ou seja, uma única associação nos enlaces sub-6 GHz e ondas milimétricas, para um único usuário em um dado instante. Ao criarmos o conjunto  $C$ , consideramos a restrição de número de usuários associados a uma estação base no enlace de ondas milimétricas. Cada elemento  $c_m$  apresenta um custo  $g(c_m)$  a ser inserido na solução. Ao avaliarmos  $c_m$  através de seu custo, estamos priorizando associações com menor quantidade de BIPs. Em seguida, escolhemos o elemento  $c_m$  com menor custo e inserimos em  $s$ . Ao final do laço mais externo, temos uma solução completa gerada para todos os usuários em todos os instantes de tempo.

---

**Algoritmo 1:** Meta-heurística

---

```

 $s \leftarrow \emptyset;$ 
para  $i \in \mathcal{U}$  faça
  para  $t \in T$  faça
     $C \leftarrow u_{i,t}^{ul,dl} \quad \forall ul, dl \in \mathcal{B} : U_{dl} \leq V$ 
    avaliar  $c_m \in C$  conforme  $g(c_m)$ 
    escolher  $c_m \in C : g(c_m) \leq g(c_n) \quad \forall c_n \in C$ 
     $s \leftarrow c_m$ 
  fim
fim

```

---

## 5. Resultados

Nesta seção, descrevemos inicialmente o processo de geração dos dados e o ambiente de simulação utilizados neste artigo. A seguir, apresentamos e discutimos os principais resultados obtidos.

### 5.1. Dados para treinamento e ambiente de simulação

Assim como em [Chen et al. 2020, Yang et al. 2022], neste trabalho, utilizamos modelos de previsão de mobilidade individuais porque o comportamento de uma pessoa enquanto imersa é, geralmente, único devido a fatores como: características físicas, percepção do ambiente e tipo de aplicação de MAR, e.g., jogo, mapa ou informações sobre objetos do ambiente [Chung et al. 2010]. Naturalmente, é importante que os modelos possuam dados que representem o comportamento real dos usuários e em volume suficiente para treinamento, validação e testes. Para isso, utilizamos a ferramenta *Simulation of Urban MOBility* (SUMO) [Lopez et al. 2018], o qual possui um módulo chamado *traci* que permite criar cenários de mobilidade para usuários que estejam caminhando. Além de permitir a obtenção da localização e orientação do usuário a partir de modelos de mobilidade coerentes com a realidade, esse módulo do SUMO permite representar um ambiente real onde as pessoas caminham apenas por calçadas. Similar a [Chen et al. 2020], utilizamos a área de um campus universitário na avaliação, conforme ilustrado na Figura 1.

A área onde os usuários se deslocam é usada como um plano cartesiano, onde a localização (0,0) se refere ao canto inferior esquerdo. A orientação diz respeito ao ângulo no sentido horário entre o norte magnético (orientação magnética) e a direção em que o usuário direciona sua cabeça. É assumido como negligenciável o erro de localização e orientação do dispositivo do usuário e, portanto, a estação base com a qual está associado recebe os valores obtidos diretamente do SUMO. As demais estações base com a qual um determinado usuário não está associado obtêm estimativas de localização e orientação

imprecisas por depender de sensores como câmeras e receptores de sinal sem fio (que utilizam técnicas como detecção de assinatura, ângulo de chegada e tempo de voo). O uso de sensoriamento e comunicações integrados (*Integrated Sensing and Communications* – ISAC) é previsto para Redes 6G e posteriores [Liu et al. 2022]. Para representar as imprecisão nessas estimativas, consideramos um erro Gaussiano com média zero e desvio padrão que cresce com a distância entre o usuário e a estação base. As séries temporais que descrevem a mobilidade dos usuários são formadas por medições (ou estimativas) geradas a cada 5 segundos e cada conjunto de dados (por usuário) tem 720 amostras, i.e., 60 minutos, dentre os quais 50 minutos são utilizados para treinamento e validação e os 10 minutos restantes para testes. É considerada uma infraestrutura com 5 estações base e 20 usuários caminhando. Os valores de outros parâmetros importantes são apresentados na Tabela 2.

**Tabela 2. Valores dos principais parâmetros do sistema.**

<b>Parâmetro</b>	$P_B$	$P_U$	$\sigma_i^2$	$F^{sub6}$	$F^{mmW}$	$\sigma_{\Psi_S I}^2$	$V$
<b>Valor</b>	30 dBm	10 dBm	0,193	5 MHz	50 MHz	0,151	10
<b>Parâmetro</b>	$\beta$	$\Psi_S$	$\sigma_B^2$	$T /  \mathcal{B}  /  \mathcal{U} $	$\gamma_D$	$\gamma_Q$	$S$
<b>Valor</b>	2	11	0,05	100 / 5 / 20	8 ms	0.8	50 kbits
<b>Parâmetro</b>	$\phi$	$d_0$	$f_c$	$\mu_{LoS}$	$\mu_{NLoS}$	$\chi_{\sigma_{LoS}}$	$\chi_{\sigma_{NLoS}}$
<b>Valor</b>	30°	5 m	28 GHz	2	2,4	5,3	5,27

## 5.2. Desempenho dos modelos de previsão

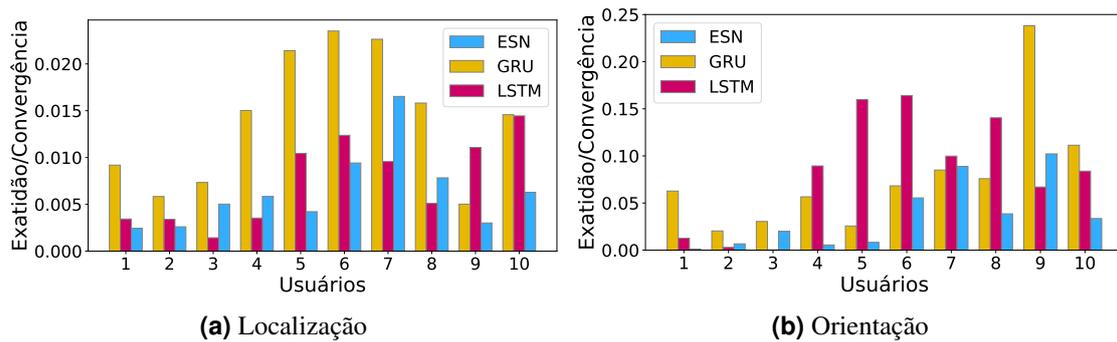
Inicialmente, avaliamos o desempenho das redes neurais ESN, GRU e LSTM com relação a exatidão e convergência. Nessa avaliação inicial, utilizamos o FL com a nossa estratégia de filtragem por aptidão durante a agregação. Para ilustrar o benefício dessa abordagem, a avaliação seguinte mostra o impacto de levar em conta a aptidão versus o impacto de ignorá-la, em cada uma das redes neurais. Por fim, mostramos o erro acumulado de localização e orientação dos usuários, também para as três redes neurais avaliadas. A Tabela 3 apresenta os valores dos hiperparâmetros utilizados nas redes neurais, os quais foram definidos de forma empírica.

**Tabela 3. Hiperparâmetros utilizados nos modelos de previsão.**

Camada de entrada	Camada de escondida	Camada de saída	Taxa de aprendizado	Rodadas (máximo)	Épocas	Limiar de exatidão
3 neurônios	66 neurônios	3 neurônios	0,001	1000	40	99,5%

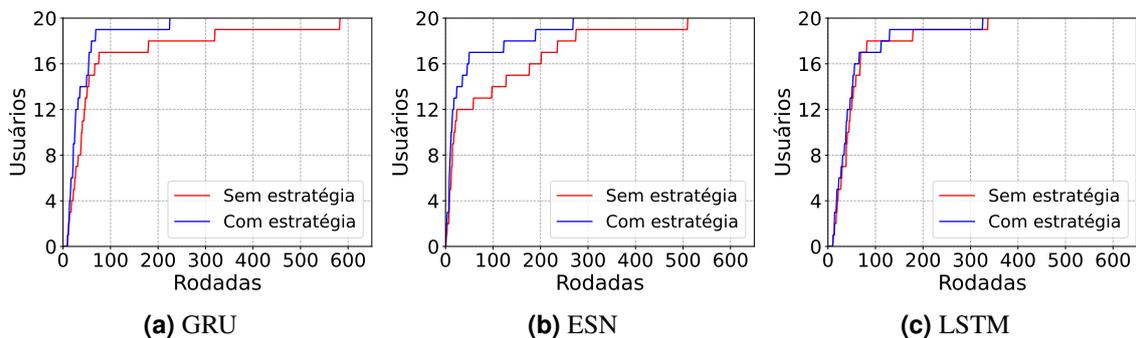
A Figura 2 apresenta o resultado da razão entre a exatidão dos modelos globais individuais e a quantidade de rodadas necessárias para a convergência das três redes neurais para 10 usuários escolhidos aleatoriamente. Os resultados mostram que a GRU apresenta a melhor razão, para a maior parte dos usuários com relação à localização e para metade dos usuários com relação à orientação. A LSTM consegue compensar a maior complexidade apenas na orientação, obtendo a melhor razão para metade dos usuários. A ESN não conseguiu ser competitiva nessa razão entre exatidão e convergência. Entretanto, mostraremos posteriormente que essa rede neural apresenta melhor desempenho quando o critério de quantidade de rodadas necessárias para convergência é desconsiderado.

Na Figura 3, é apresentado o acumulado do número de usuários que alcançaram o limiar de exatidão em função do número de rodadas de treinamento, para cada uma



**Figura 2. Razão entre exatidão e convergência para (a) localização e (b) orientação de 10 usuários selecionados aleatoriamente.**

das redes neurais avaliadas. Tanto GRU quanto ESN tiveram um benefício significativo no uso da estratégia de filtragem por aptidão. Por exemplo, com pouco mais de 200 rodadas, a GRU alcançou o limiar de exatidão para todos os usuários usando a filtragem, enquanto foram necessárias próximo de 600 rodadas para todos os usuários alcançarem o mesmo limiar sem utilizar a filtragem. A LSTM não é impactada de forma sensível pela estratégia de filtragem, em parte devido a estrutura mais complexa desse tipo de rede neural. Ainda assim, vale destacar que o uso da filtragem por aptidão não afeta negativamente o desempenho da LSTM.



**Figura 3. Acumulado do número de usuários que alcançaram o limiar de exatidão em função do número de rodadas de treinamento.**

Para avaliar apenas a exatidão das três redes neurais durante a previsão, consideramos os 10 minutos finais de caminhada dos usuários. A Figura 4 apresenta algumas estatísticas (através de *box plots*) sobre o erro acumulado de localização e orientação dos usuários avaliados. É possível observar que ESN obtém a menor mediana de erro acumulado, aproximadamente metade dos usuários, tanto em localização quanto em orientação. LSTM apresenta o segundo melhor desempenho, enquanto GRU apenas consegue a menor mediana de erro acumulado para dois usuários com relação à orientação. É interessante observar que apenas o usuário 2 possui dados com erros suficientemente altos para afetar as três redes neurais. Todos os demais usuários recebem estimativas com medianas baixas de erro acumulado em pelo menos uma das redes neurais, ilustrando como a agregação e a estratégia de filtragem por aptidão contribuem para a obtenção de modelos satisfatórios. Por fim, vale destacar que as redes neurais não passaram por um processo de ajuste fino que poderia melhorar a exatidão de cada uma delas, mas que dificultaria uma comparação justa.

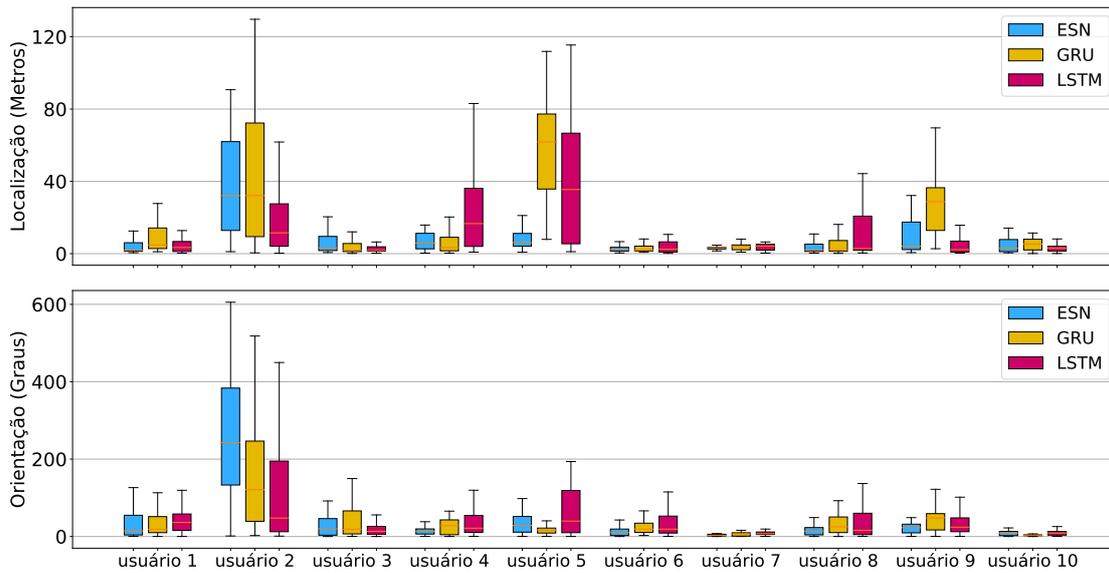


Figura 4. Erro acumulado de localização e orientação.

### 5.3. Desempenho da meta-heurística

Os resultados da meta-heurística proposta na Seção 4.2 foram comparados com os resultados obtidos por um *solver* exato com relação a duas métricas: qualidade das soluções e tempo computacional. A implementação da meta-heurística foi feita em Python, versão 3.8.2. As soluções ótimas foram obtidas pelo IBM CPLEX 20.1, usando docplex 2.25 para realizar a implementação do modelo descrito na Seção 3.3.

A Figura 5a mostra a quantidade de BIPs observados (Equação 8) por todos os usuários de MAR em função do número desses usuários, o qual variou de 30 a 300 nesta avaliação. A diferença percentual entre a abordagem exata (i.e., ótima) e a meta-heurística foi no máximo de 0,12%, alcançando a solução ótima em 7 das instâncias avaliadas. Vale destacar que foi estabelecido um tempo limite de uma hora para obtenção da solução, o qual já seria muito superior ao tempo máximo aceitável para uma tomada de decisão de associação no problema em questão. Para 300 usuários, esse tempo não foi suficiente para encontrar a solução ótima.

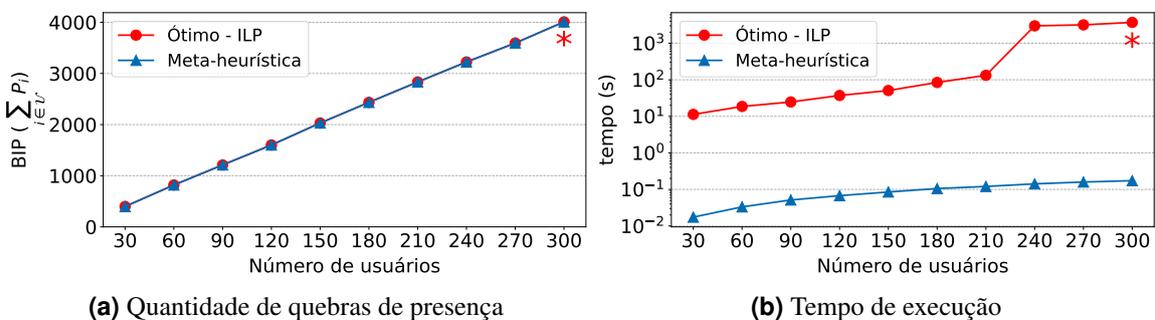


Figura 5. Comparação entre a abordagem de ILP e a meta-heurística.

A Figura 5b apresenta o tempo computacional para execução das duas abordagens, i.e., ILP e meta-heurística. Como pode ser observado, o tempo computacional sobe

sensivelmente a partir de 240 usuários e excede o tempo limite a partir de 300 usuários. A meta-heurística resolve todas as instâncias avaliadas em menos de 1 segundo.

## 6. Conclusão

Este trabalho apresentou uma abordagem de aprendizado federado para agregar em um nó central modelos individuais para previsões de localização e orientação de usuários de MAR geradas a partir de diferentes estações base. A agregação utilizou uma estratégia de filtragem com o objetivo de reduzir os erros de previsão introduzidos por sensores imprecisos. As previsões foram utilizadas para a tomada de decisão no processo de associação entre usuários de MAR com as estações base, tanto em sub-6GHz quanto em ondas milimétricas. As decisões de associações tinham como objetivo minimizar a ocorrência dos eventos de quebra de presença (BIP) dos usuários de MAR. Foram avaliadas três redes neurais recorrentes para previsão de mobilidade, sendo a ESN com melhor desempenho geral em exatidão, enquanto a GRU apresentou convergência em menor número de rodadas de treinamento. Além disso, foi desenvolvida uma meta-heurística, baseada em GRASP, que demonstrou resultados promissores na resolução do problema de associação entre usuários e estações base, tanto em termos de qualidade das soluções quanto em tempo computacional. Por fim, vale destacar a replicabilidade do trabalho, dada a disponibilidade de um repositório com códigos e dados utilizados neste trabalho.

Como trabalhos futuros, pretendemos evoluir o trabalho através de melhorias no aprendizado federado e nas redes neurais. Por exemplo, planejamos avaliar estratégias de agregação mais sofisticadas e considerar alguns ajustes finos promissores introduzidos recentemente na literatura para a ESN. Além disso, pretendemos investigar o potencial de utilizar a abordagem geral deste trabalho em outras aplicações imersivas, como realidade estendida e metaverso, assim como realizar experimentos em outros cenários de comunicações móveis, e.g., redes veiculares.

## Reconhecimentos

Este trabalho foi apoiado pela CAPES; pela RNP/MCTIC, através do projeto No. 01245.010604/2020-14 – Sistemas de Comunicações Móveis 6G; pela FAPESP, por meio do Projeto “SAMURAI: núcleo 5G inteligente e integração de múltiplas redes de acesso” sob concessão 2020/05127-2; pela Anatel e FAPEG, através do projeto “Avaliação de Impacto da Web 3.0: Descentralizada, Imersiva, Semântica, Centrada no Usuário e Conectada com o Mundo Ciberfísico”.

## Referências

- Almeida, G. M., Camilo-Junior, C., Correa, S., and Cardoso, K. (2023). A Genetic Algorithm for Efficiently Solving the Virtualized Radio Access Network Placement Problem. In *ICC 2023 - IEEE International Conference on Communications*, pages 1874–1879.
- Bartolomeo, G., Cao, J., Su, X., and Mohan, N. (2023). Characterizing Distributed Mobile Augmented Reality Applications at the Edge. In *Companion of the 19th International Conference on Emerging Networking EXperiments and Technologies, CoNEXT 2023*, pages 9–18, New York, NY, USA. Association for Computing Machinery.
- Bianchi, F. M., Maiorino, E., Kampffmeyer, M. C., Rizzi, A., and Jenssen, R. (2017). *Recurrent Neural Networks for Short-Term Load Forecasting: An Overview and Comparative Analysis*. Springer International Publishing.

- Chen, M., Semiari, O., Saad, W., Liu, X., and Yin, C. (2020). Federated Echo State Learning for Minimizing Breaks in Presence in Wireless Virtual Reality Networks. *IEEE Transactions on Wireless Communications*, 19(1):177–191.
- Chung, J., Yoon, H.-J., and Gardner, H. J. (2010). Analysis of Break in Presence During Game Play Using a Linear Mixed Model. *ETRI Journal*, 32(5):687–694.
- Ge, X., Pan, L., Li, Q., Mao, G., and Tu, S. (2017). Multipath Cooperative Communications Networks for Augmented and Virtual Reality Transmission. *IEEE Transactions on Multimedia*, 19(10):2345–2358.
- Jain, R., Shi, J., Duan, R., Zhu, Z., Qian, X., and Ramani, K. (2023). Ubi-TOUCH: Ubiquitous Tangible Object Utilization through Consistent Hand-object interaction in Augmented Reality. In *Proceedings of the 36th Annual ACM Symposium on User Interface Software and Technology, UIST '23*, New York, NY, USA. Association for Computing Machinery.
- Liu, F., Cui, Y., Masouros, C., Xu, J., Han, T. X., Eldar, Y. C., and Buzzi, S. (2022). Integrated Sensing and Communications: Toward Dual-Functional Wireless Networks for 6G and Beyond. *IEEE Journal on Selected Areas in Communications*, 40(6):1728–1767.
- Lopez, P. A., Behrisch, M., Bieker-Walz, L., Erdmann, J., Flötteröd, Y.-P., Hilbrich, R., Lücken, L., Rummel, J., Wagner, P., and Wiessner, E. (2018). Microscopic Traffic Simulation using SUMO. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pages 2575–2582.
- McMahan, B., Moore, E., Ramage, D., Hampson, S., and Arcas, B. A. y. (2017). Communication-Efficient Learning of Deep Networks from Decentralized Data. In Singh, A. and Zhu, J., editors, *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics*, volume 54 of *Proceedings of Machine Learning Research*, pages 1273–1282. PMLR.
- Picano, B., Scommegna, L., Vicario, E., and Fantacci, R. (2023). Echo State Learning for User Trajectory Prediction to Minimize Online Game Breaks in 6G Terahertz Networks. *Journal of Sensor and Actuator Networks*, 12(4).
- Siriwardhana, Y., Porambage, P., Liyanage, M., and Ylianttila, M. (2021). A Survey on Mobile Augmented Reality With 5G Mobile Edge Computing: Architectures, Applications, and Technical Aspects. *IEEE Communications Surveys & Tutorials*, 23(2):1160–1192.
- Sun, Y., Chen, Z., Tao, M., and Liu, H. (2018). Communication, Computing and Caching for Mobile VR Delivery: Modeling and Trade-Off. In *2018 IEEE International Conference on Communications (ICC)*, pages 1–6.
- Yang, P., Quek, T. Q. S., Chen, J., You, C., and Cao, X. (2022). Feeling of Presence Maximization: mmWave-Enabled Virtual Reality Meets Deep Reinforcement Learning. *IEEE Transactions on Wireless Communications*, 21(11):10005–10019.
- Yang, X., Chen, Z., Li, K., Sun, Y., Liu, N., Xie, W., and Zhao, Y. (2018). Communication-Constrained Mobile Edge Computing Systems for Wireless Virtual Reality: Scheduling and Tradeoff. *IEEE Access*, 6:16665–16677.
- Zäpfel, G., Braune, R., and Bögl, M. (2010). *Metaheuristic Search Concepts*. Springer.