Seleção de Clientes Federados usando Aprendizado por Reforço Multiagente

Marcelo P. Zwetsch, Guilherme A. Thomaz e Miguel Elias M. Campista

[1]GTA/PEE-COPPE/DEL-Poli – Universidade Federal do Rio de Janeiro (UFRJ)

{marcelo, guiaraujo, miguel}@gta.ufrj.br

Abstract. *In federated learning, the central server decides which clients should participate in each training round. However, traditional strategies that do not estimate each client's contribution may be vulnerable to low-quality data and malicious clients. This work investigates a client selection approach based on multi-agent reinforcement learning (MARL). The proposed architecture models each client as an agent, in which decisions are made in a decentralized and cooperative manner. Each agent evaluates characteristics such as data diversity, processing capacity, and participation history, learning to contribute to a more strategic selection of training participants in dynamic and non-IID scenarios. The experiments simulate different degrees of heterogeneity among clients, reflecting non-IID data distributions, and also consider scenarios with label-flipping attacks. The performance, compared with FedAvg and single-agent RL (SARL), shows improvements in the final model accuracy and in balancing client participation.*

Resumo. *No aprendizado federado, o servidor central decide quais clientes devem participar de cada rodada de treinamento. Entretanto, estratégias tradicionais que não estimam a contribuição de cada cliente podem ser vulneráveis a dados de baixa qualidade e a clientes maliciosos. Este trabalho investiga uma abordagem de seleção de clientes baseada no aprendizado por reforço multiagente (MARL). A arquitetura proposta modela cada cliente como um agente, no qual as decisões são tomadas de forma descentralizada e cooperativa. Cada agente avalia características como diversidade de dados, capacidade de processamento e histórico de participação, aprendendo a contribuir para uma seleção mais estratégica dos participantes do treinamento em cenários dinâmicos e não-IID. Os experimentos simulam diferentes graus de heterogeneidade entre os clientes, refletindo distribuições não-IID, além de considerar cenários com inversão de rótulos como estratégia de ataque ao aprendizado. O desempenho, em comparação ao FedAvg e ao single-agent RL (SARL), demonstra melhoria na acurácia final do modelo e no equilíbrio na participação dos clientes.*

1. Introdução

O uso crescente de dispositivos conectados, especialmente em IoT e computação de borda, leva à geração de grandes volumes de dados de forma distribuída. Em muitos

Este trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001 e 88887.954253/2024-00, do CNPq (310234/2025-5, 407304/2025-8, 408255/2023-4 e 405940/2022-0), da FAPERJ (E-26/200.380/2023 e E-26/210.778/2025), da FAPESP (2023/00673-7 e 2023/00811-0) e da Fundação de Desenvolvimento da Pesquisa - Fundep - Rota 2030 em conjunto dos nossos parceiros Stellantis e Mobway.

cenários, restrições de privacidade e de comunicação dificultam a centralização dessas informações. Nesse contexto, o Aprendizado Federado (*Federated Learning* – FL) permite treinar modelos de aprendizado de máquina mantendo os dados nos clientes. O servidor coordena o processo em rodadas, selecionando um subconjunto de clientes para realizar o treinamento local e enviar atualizações do modelo para agregação, produzindo um novo modelo global a cada rodada [de Souza et al. 2024]. Em cenários reais, os conjuntos locais são não independentes e identicamente distribuídos (não-IIDs) e a qualidade pode variar entre participantes, incluindo inversão de rótulos, o que torna a seleção por rodada um fator crítico para a qualidade do modelo [Jiang et al. 2025, Zhao et al. 2018].

Estratégias simples de seleção, como amostragem aleatória, podem ser insuficientes nesses casos, pois o servidor pode acabar selecionando clientes cujas atualizações trazem pouco ganho ao modelo global ou até degradam o desempenho. Além disso, a relevância de um cliente tende a mudar ao longo das rodadas conforme o modelo evolui, o que sugere tratar a seleção como um problema dinâmico de decisão sequencial no lugar do uso de um critério fixo. Ainda assim, é comum que a literatura recente adote políticas de participação baseadas em heurísticas ou em funções de utilidade avaliadas a cada rodada [Lai et al. 2021, Jee Cho et al. 2022].

Diante desse caráter dinâmico, este trabalho propõe o uso do Aprendizado por Reforço (*Reinforcement Learning* – RL) para guiar a seleção de clientes ao longo das rodadas, com enfoque em cenários heterogêneos e adversariais. Uma formulação possível consiste em considerar um único agente que aprende a pontuar individualmente cada cliente com base em sinais observáveis durante o treinamento e, a cada rodada, seleciona os K clientes com as maiores pontuações. Outra alternativa seria definir a ação do agente para que, em vez de atribuir pontuações individuais aos clientes, atribua pontuações a subconjuntos de K clientes. Nesse caso, o espaço de ações cresce de forma combinatória, com $\binom{N}{K}$ possibilidades para um conjunto de N clientes. Essa formulação torna-se um problema de alta dimensionalidade e dificulta o aprendizado à medida que N aumenta. Para contornar essa limitação, este trabalho adota uma abordagem baseada em Aprendizado por Reforço Multiagente (*Multi-Agent RL* – MARL), na qual cada cliente é modelado como um agente cooperativo. Essa abordagem permite combinar a seleção dos melhores K clientes, eliminando o problema combinatorial, sem perder o caráter coletivo da seleção a cada rodada.

Foram conduzidos experimentos em cenários não-IID, incluindo a inversão de rótulos (*label flipping*) em uma fração dos clientes, como forma de ação maliciosa. Para comparação, a seleção aleatória e uma formulação com SARL são utilizadas como *baseline*. Os resultados revelam um aumento na acurácia em comparação com o FedAvg e com uma estratégia baseada em SARL, indicando que a proposta evita a seleção de participantes prejudiciais para o treinamento. Ademais, os resultados revelam como o aumento da acurácia depende de forma direta da fração de clientes atacantes, da heterogeneidade dos dados e da fração de rótulos comprometidos.

O restante deste trabalho está organizado como se segue: A Seção 2 revisa a literatura em seleção de clientes federados em presença de ataques. A Seção 3 apresenta a fundamentação teórica sobre FL e MARL. Já a Seção 4 introduz a proposta para seleção de clientes do FL usando MARL. Os experimentos e os resultados são discutidos na Seção 5. Por fim, a Seção 6 conclui este trabalho e estabelece os próximos passos. A

Tabela 1 apresenta as variáveis utilizadas ao longo de todo o trabalho.

2. Trabalhos Relacionados

Ataques ao aprendizado federado (FL) têm sido amplamente estudados devido à impossibilidade do servidor observar diretamente os dados e o processo de treinamento local. A literatura sistematiza essas ameaças, classificando-as como envenenamento de dados (*data poisoning*) e envenenamento de modelos (*model poisoning*) e diferencia os ataques como direcionados (*targeted*) e não direcionados (*untargeted*) [Sagar et al. 2023]. Entre os ataques por envenenamento de dados, a inversão de rótulos (*label flipping*) destaca-se por sua simplicidade de execução e dificuldade de detecção, podendo degradar significativamente o desempenho do modelo global, especialmente quando uma fração dos clientes é maliciosa [Jebreel et al. 2022]. Esses trabalhos evidenciam a necessidade de mecanismos que reduzam a influência de clientes maliciosos durante o treinamento.

Diante deste cenário, diversas defesas foram propostas, atuando majoritariamente no estágio de agregação ou na filtragem de atualizações anômalas. Estratégias clássicas incluem agregadores tolerantes a falhas bizantinas [Blanchard et al. 2017] e métodos baseados em mediana coordenada [Yin et al. 2018], que buscam reduzir a influência de atualizações adversariais no modelo global. Contudo, tais abordagens mostram-se reativas, uma vez que se limitam a mitigar o impacto de clientes maliciosos somente após o envio das atualizações, sem mecanismos para orientar a seleção de participantes ou limitar sua recorrência ao longo das rodadas. Nessa direção, Lai et al. propõem uma estratégia de seleção de clientes baseada em utilidade dos dados e restrições de sistema, sem abordar explicitamente o cenário adversarial [Lai et al. 2021]. Mais recentemente, abordagens baseadas em aprendizado por reforço multiagente (MARL) têm sido exploradas para melhorar a eficiência e a coordenação do aprendizado federado. Zhang *et al.* e Tian *et al.* empregam múltiplos agentes para aprender políticas de seleção de clientes, priorizando participantes mais promissores a cada rodada. Tais trabalhos buscam ganhos tanto em desempenho quanto em custo de comunicação, mesmo considerando dados não-IID e restrições de recursos [Zhang et al. 2022, Tian et al. 2024].

Embora haja ampla literatura sobre defesas contra ataques em FL, principalmente no estágio de agregação e na filtragem de atualizações, abordagens que exploram explicitamente a seleção de participantes como mecanismo de mitigação ainda são menos

Tabela 1. Principais notações.

Símbolo	Significado	Símbolo	Significado.
N / K	Núm. de clientes total/selec.	i / t	Índice de cliente/rodada
α	Param. da dist. de Dirichlet	w_t	Pesos do modelo FL
$o_{i,t} \in \mathbb{R}^4$	Observação local	$\mathcal{S}_t$	Clientes selecionados
$a_{i,t} \in \{0, 1\}$	Ação de seleção do cliente	γ	Fator de desconto
r_t	Recompensa global	π	Política
l_t^{val}	Perda de validação	Q_{tot}	Função valor-ação
y_t	Alvo do RL (eq. de Bellman)	$\mathcal{L}$	Perda do modelo FL
$\mathcal{D}$ / $\mathcal{D}_{val}$	*Dataset* de treino/val.	ϵ	Constante pequena
$\mathbf{X}_{i,t}^{(j)}$ / $\mathbf{y}_{i,t}^{(j)}$	Entrada/saída j do modelo FL	$\hat{\mathbf{y}}_{i,t}^{(j)}$	Rótulo da amostra j
Θ_T	Pesos da rede-alvo do DQN	Θ_Q	Pesos da rede-Q do DQN

comuns, sobretudo quando formulado como um problema de decisão sequencial. O presente trabalho formula a seleção de clientes como um problema de MARL em ambiente adversarial, no qual agentes aprendem uma política que reduz a prioridade de participantes associados a padrões consistentes com ataques. Assim, este trabalho visa mitigar dinamicamente a degradação do modelo global, preenchendo uma lacuna da literatura.

3. Fundamentação Teórica

Esta seção introduz conceitos fundamentais em aprendizado federado (FL) e aprendizado por reforço multiagente (MARL).

3.1. Aprendizado Federado

No aprendizado federado, em cada rodada t, o servidor seleciona um subconjunto de K cliente, a partir de um conjunto de N clientes, e os envia uma cópia do modelo global w_t. Os clientes selecionados realizam algumas épocas de treinamento local utilizando seus próprios dados, que permanecem no dispositivo, mantendo a privacidade. Em seguida, eles transmitem de volta as atualizações do modelo. O servidor atua como agregador dos parâmetros recebidos, tipicamente usando uma média ponderada pelo tamanho do conjunto de dados de cada cliente (FedAvg [McMahan et al. 2017]). Esse novo modelo global é usado na próxima rodada. Esse processo se repete até um critério de convergência do modelo. Em cenários idealizados, com dados IID, o método de referência, o FedAvg apresenta bom desempenho. Entretanto, em cenários realistas, a heterogeneidade entre os dados dos clientes (cenários não-IID) tende a degradar significativamente o desempenho [Zhao et al. 2018]. Para lidar com esses desafios, a seleção de clientes torna-se um componente crucial. Trabalhos anteriores têm seguido duas linhas principais: estratégias heurísticas [Lai et al. 2021] e estratégias baseadas em aprendizado [Wang et al. 2020]. Este trabalho adota a segunda abordagem.

3.2. Aprendizado por Reforço Multiagente

O MARL é um método cooperativo no qual um conjunto de N agentes interage em um mesmo ambiente, frequentemente adotado em problemas nos quais um único agente não é suficiente para resolver a tarefa. Nesse contexto, o aprendizado é mais complexo, uma vez que os múltiplos agentes devem tomar decisões simultaneamente, e a dinâmica do ambiente passa a depender das ações de todos. O objetivo é aprender políticas que maximizem o retorno esperado. Os agentes são modelados em um jogo estocástico (*stochastic game*), definido por $(\mathcal{S}, \mathcal{A}_1, \ldots, \mathcal{A}_N, P(s' \mid s, a_1, \ldots, a_N), r_1, \ldots, r_N)$. Em cada passo, os agentes escolhem ações $a_i \in A_i$, formando a ação conjunta $\mathbf{a} = (a_1, \ldots, a_N)$. A dinâmica do sistema evolui segundo a probabilidade de transição de estados $P(s' \mid s, a)$, onde $s \in \mathcal{S}$ é o estado global atual e $s' \in \mathcal{S}$ é o estado global seguinte. Cada agente i decide a ação acessando apenas uma observação local $o_i = O_i(s)$, dependente apenas do seu estado. Em geral, assume-se que P não é conhecida explicitamente, de modo que o agente observa a dinâmica por amostragem via interação com o ambiente.

As políticas são definidas como $\pi_i(a_i \mid o_i)$, mapeando uma observação local para uma ação de cada agente. No caso cooperativo, assume-se recompensa compartilhada $r_1, \ldots, r_N = r$. Define-se então a função valor-ação sob a política conjunta $\boldsymbol{\pi}$ como

$$Q^{\boldsymbol{\pi}}(s_t, a_t) = \mathbb{E}_{\boldsymbol{\pi}, P}\left[\sum_{k=0}^{\infty} \gamma^k \, r(s_{t+k}, a_{t+k}) \;\middle|\; s_t = s, a_t = a\right],$$

onde t indica a iteração atual e $Q^{\boldsymbol{\pi}}(s, \mathbf{a})$ quantifica o retorno esperado ao executar a ação conjunta $\mathbf{a}$ no estado s e, em seguida, seguir a política conjunta π. γ é um fator de desconto que penaliza recompensas de longo prazo.

O *Value Decomposition Network* (VDN) [Sunehag et al. 2017] é uma das abordagens de agregação para treinamento cooperativo de agentes em MARL. No VDN, cada agente utiliza uma rede neural profunda (*Deep Nerual Network* – DNN) para inferir sua ação. Essa rede aproxima a função valor-ação $Q_{\theta_n}(s, a)$, onde θ_n são os parâmetros da DNN do agente. Para treinar o VDN, utiliza-se um *replay buffer* para armazenar transições na forma $(\mathcal{S}_t, \mathcal{A}_t, r_t, \mathcal{S}_{t+1})$. A função valor-ação conjunta é então representada como a soma das funções individuais:

$$Q_{\text{tot}}(s_t, a_t) = \sum_{n=1}^{N} Q_{\theta_n}(s_{i,t}, a_{i,t}),$$

onde $s_t = \{s_{i,t}\}_{i=1}^{N}$ e $a_t = \{a_{i,t}\}_{i=1}^{N}$ denotam o estado global e a ação conjunta. As DNNs dos agentes são treinadas com o objetivo de minimizar a perda (*loss*):

$$\mathbb{E}_{s_t, a_t, r_t, s_{t+1}}[(y_t - Q_{tot}(s_t, a_t))^2],$$

onde o valor alvo y_t é definido pela equação de Bellman:

$$y_t = r_t + \gamma \max_{a_{t+1}} Q_{tot}(s_{t+1}, a_{t+1}).$$

4. Modelagem do Problema de Seleção de Clientes usando MARL

Esta seção descreve o arcabouço proposto para seleção de clientes em aprendizado federado (FL), fundamentado em aprendizado por reforço multiagente (MARL). O objetivo é aprender uma política de seleção que melhore o desempenho do modelo global em cenários heterogêneos (não-IID) e sob inversão de rótulos (*label flipping*), utilizando sinais observáveis ao longo do treinamento federado.

A seleção de clientes é tratada como um problema de decisão sequencial ao longo de T rodadas federadas. Considera-se um conjunto fixo com N clientes, onde cada cliente i é modelado como um agente cooperativo. Na rodada t, dado o modelo global w_t, o servidor coleta d sinais observáveis do treinamento e constrói uma observação local $\mathbf{o}_{i,t} \in \mathbb{R}^d$ para cada cliente. Em seguida, o servidor seleciona o conjunto de participantes $\mathcal{S}_t \subseteq \{1, \ldots, N\}$, com $|\mathcal{S}_t| = K$, e executa algumas épocas de treinamento local nos clientes selecionados, seguida de agregação via FedAvg, produzindo o modelo w_{t+1}.

Variáveis de decisão (seleção Top-K). Seja $a_{i,t} \in \{0, 1\}$ uma variável binária que indica se o cliente i é selecionado na rodada t. A cada rodada, impõe-se a restrição de selecionar exatamente K clientes:

$$\sum_{i=1}^{N} a_{i,t} = K, \quad \forall t \in \{1, \ldots, T\}. \tag{1}$$

Função objetivo. Busca-se aprender uma política de seleção π que, em cada rodada t, define quais clientes participam do treinamento, representada por um vetor binário $a_t = (a_{1,t}, \ldots, a_{N,t})$. A função objetivo, portanto, visa maximizar o retorno esperado associado à recompensa global r_t. Sendo assim, a função objetivo é definida como:

$$\max_{\pi} \mathbb{E}\left[\sum_{t=1}^{T} \gamma^{t-1} r_t\right], \tag{2}$$

onde $\gamma \in [0, 1)$ é o fator de desconto. A recompensa r_t é calculada no servidor a partir da perda (*loss*) de validação após a agregação. Considerando ℓ_t^{val} como a perda de validação do modelo global ao final da rodada t e $\bar{\ell}_t^{\text{val}}$ como a média das perdas de validação nas τ rodadas anteriores, define-se:

$$r_t = \frac{\bar{\ell}_t^{\text{val}} - \ell_t^{\text{val}}}{\bar{\ell}_t^{\text{val}} + \varepsilon}. \tag{3}$$

A recompensa r_t é escalar e compartilhada entre todos os agentes. A variável ε no denominador é um valor positivo pequeno (e.g. 10^{-6}) que garante estabilidade numérica quando $\bar{\ell}_t^{\text{val}}$ tende a zero.

4.1. Espaço de observação

Para viabilizar a tomada de decisão sob heterogeneidade e possíveis contribuições adversariais, cada agente (cliente) i é associado a um vetor de observação $o_{i,t} \in \mathbb{R}^4$, calculado no servidor a partir de $d = 4$ sinais observáveis do treinamento na rodada t. Utiliza-se

$$o_{i,t} = \left[\text{proj}_{i,t},\ \text{gener}_{i,t},\ \text{estag}^*_{i,t},\ \text{serie}^*_{i,t}\right], \tag{4}$$

onde os termos são definidos a seguir.

Projeção de gradiente. O termo $\text{proj}_{i,t}$ mede o alinhamento entre a atualização local do cliente i e um gradiente de referência do servidor no início de uma rodada. Antes de iniciar o treinamento na rodada $t+$, calcula-se a atualização local do cliente i a partir do modelo global agregado ao final da rodada t (w_t) em poucos *mini-batches* dos seus dados locais e o gradiente de referência do servidor em poucos *mini-batches* de um conjunto de validação do servidor $\mathcal{D}_{\text{val}}$. Na prática, o conjunto de validação do servidor pode ser formado de dados públicos utilizados para testar o desempenho do modelo sem depender dos dados privados locais dos clientes. Denotando por $\nabla_{w_t}\mathcal{L}(\cdot)$ o gradiente da perda em relação aos parâmetros, define-se:

$$\text{proj}_{i,t} = \frac{\Delta w_{i,t}{}^{\top}(-\nabla_{w_t}\mathcal{L}(w_t; \mathcal{D}_{\text{val}}))}{\|\nabla_{w_t}\mathcal{L}(w_t; \mathcal{D}_{\text{val}})\|}. \tag{5}$$

onde $\Delta w_{i,t}$ denota a diferença entre os parâmetros do modelo local obtido pelo cliente i após a atualização local e os parâmetros do modelo global w_t, com $\nabla_{w_t}\mathcal{L}(\cdot)$ suavizado por uma média móvel.

Esta equação é proporcional à similaridade de cosseno. Valores positivos indicam que o cliente tende a atualizar o modelo na mesma direção do servidor, enquanto valores negativos indicam o oposto.

Perda de generalização A perda de generalização, denotada como $\mathrm{gener}_{i,t}$, é calculada avaliando o modelo global w_t em poucos *mini-batches* do conjunto local do cliente i, antes da atualização de pesos. Valores elevados de $\mathrm{gener}_{i,t}$ indicam que o modelo global generaliza mal para aquele cliente, o que pode refletir heterogeneidade dos dados e comportamento adversarial. O conjunto de dados do cliente i na rodada t é representado por $\left\{\left(\mathbf{X}_{i,t}^{(j)}, \mathbf{y}_{i,t}^{(j)}\right)\right\}_{j=1}^{|\mathcal{D}|}$, onde cada uma das $|\mathcal{D}|$ amostras é formada por atributos (entrada) $\mathbf{X}_{i,t}^{(j)}$ e rótulo (saída esperada, ou *ground-truth*) $\mathbf{y}_{i,t}^{(j)}$. A passagem pelo modelo w_t é representada por $\hat{\mathbf{y}}_{i,t}^{(j)} = f\left(\mathbf{X}_{i,t}^{(j)}, w_t\right)$, onde a saída $\hat{\mathbf{y}}_{i,t}^{(j)}$ é o valor predito. Define-se:

$$\mathrm{gener}_{i,t} = \frac{1}{|\mathcal{D}|} \sum_{j=1}^{|\mathcal{D}|} \mathcal{L}\left(\hat{\mathbf{y}}_{i,t}^{(j)}, \mathbf{y}_{i,t}^{(j)}\right), \tag{6}$$

onde a função de perda $\mathcal{L}(\cdot)$ usada é a entropia cruzada.

Estagnação. A variável $\mathrm{estag}_{i,t}$ contabiliza quantas rodadas se passaram desde a última seleção do cliente i. Para obter um sinal comparável entre clientes na rodada t, aplica-se uma normalização pelo maior valor observado na rodada:

$$\mathrm{estag}_{i,t}^{*} = \frac{\mathrm{estag}_{i,t}}{\max_{j \neq i} \mathrm{estag}_{i,t} + \varepsilon}. \tag{7}$$

Série de seleções. A $\mathrm{serie}_{i,t}$ é a contagem de seleções consecutivas do cliente i até a rodada t. Define-se a versão normalizada como:

$$\mathrm{serie}_{i,t}^{*} = \min\left(\frac{\mathrm{serie}_{i,t}}{\mathrm{serie}_{i,t}^{(\max)}},\, 1\right), \tag{8}$$

onde $\mathrm{serie}_{i,t}^{(\max)}$ é um hiperparâmetro constante global, aplicado igualmente a todos os clientes e em todas as rodadas. Este hiperparâmetro define a quantidade de rodadas consecutivas que um mesmo cliente precisa ser selecionada para que $\mathrm{serie}_{i,t}^{*}$ atinja seu valor máximo, igual a um.

4.2. Processo de Aprendizagem

Cada cliente i estima $Q_i(o_{i,t}, a)$, sendo a_i a variável binária indicadora de seleção (eq 9). Esses valores são calculados por uma rede neural treinada a partir do algoritmo *Deep Q-Network* (DQN), que recebe $o_{i,t}$ como entrada e retorna $Q_i(o_{i,t}, 0)$ e $Q_i(o_{i,t}, 1)$. O servidor seleciona os K clientes com maior diferença entre saídas:

$$S_t = \mathrm{TopK}\left(\{Q(o_{i,t}, 1) - Q(o_{i,t}, 0)\}_{i=1}^{N},\, K\right). \tag{9}$$

4.3. Treinamento centralizado com execução descentralizada

Adota-se o paradigma de treinamento centralizado com execução descentralizada. Na execução, cada cliente é avaliado de forma independente a partir de sua observação

local $o_{i,t}$, produzindo um escore utilizado pelo servidor na seleção Top-K (Eq. 9). Essa restrição de decisão local implica que cada agente observa apenas sinais do próprio cliente e não tem acesso direto às observações dos demais, de modo que a coordenação entre os agentes é estabelecida no treinamento a partir de uma função objetivo compartilhada. Para viabilizar esse aprendizado cooperativo sob observações parciais e uma recompensa global compartilhada r_t (Eq. 3), emprega-se a abordagem *Value Decomposition Networks* (VDN) para agregar as estimativas de ação-valor dos agentes. Em particular, define-se uma função $Q_{\text{tot}}(o_t, a_t)$ associada à decisão conjunta, decomposta como soma das estimativas individuais $Q_i(o_{i,t}, a_{i,t})$:

$$Q_{\text{tot}}(o_t, a_t) = \sum_{i=1}^{N} Q_i(o_{i,t}, a_{i,t}), \tag{10}$$

permitindo que múltiplos agentes aprendam de forma cooperativa a partir de um único sinal de recompensa. O treinamento minimiza o erro médio quadrático sobre a função agregada Q_{tot}, estimada pela rede neural com parâmetros Θ_Q (*Q-Network*):

$$\mathcal{L}(\theta) = \big(y_t - Q_{\text{tot}}(o_t, a_t; \Theta_Q)\big)^2, \tag{11}$$

utilizando como variável alvo a diferença temporal, calculada por uma rede-alvo (*target network*) com parâmetros Θ_T:

$$y_t = r_t + \gamma \max_{a'} Q_{\text{tot}}(o_{t+1}, a'; \Theta_T). \tag{12}$$

Ao final de cada rodada federada t, forma-se a transição $\tau_t = (o_t, a_t, r_t, o_{t+1})$, em que $o_t = (o_{1,t}, \ldots, o_{N,t})$ agrega as observações locais de todos os clientes, $a_t = (a_{1,t}, \ldots, a_{N,t})$ representa as ações binárias executadas na rodada, r_t é a recompensa global computada no servidor, e o_{t+1} é construído a partir dos sinais observáveis da rodada seguinte. Essas transições são armazenadas em um *replay buffer* e amostradas aleatoriamente para treinamento *off-policy*, isto é, o estimador Q é atualizado com experiências coletadas por políticas anteriores (não necessariamente a política atual). Isso reduz a correlação temporal entre amostras consecutivas e permite reutilizar experiências de rodadas passadas.

Entretanto, nem todas as transições do *replay buffer* são igualmente informativas. Rodadas em que a seleção causa maior variação na perda de validação tendem a gerar atualizações mais relevantes do estimador Q. Para enfatizar essas experiências, utiliza-se *Prioritized Experience Replay* (PER), substituindo a amostragem uniforme por uma estratégia que atribui a cada transição uma prioridade proporcional ao erro de diferença temporal. Dessa forma, transições em que o estimador Q erra mais são revisitadas com maior frequência, acelerando a correção dos casos mais informativos.

Para estabilizar o aprendizado, adota-se a abordagem *Double DQN*, utilizando a rede-Q com parâmetros Θ_Q, além da rede-alvo com parâmetros Θ_T, citadas anteriormente na descrição do DQN. A rede-Q estima o retorno esperado $Q_{\text{tot}}(o_{t+1}, a'; \Theta_Q)$ para cada ação a' a partir da observação o_{t+1} amostrada do *replay buffer*. Em seguida, é escolhida, de forma gulosa, a ação que maximiza esse retorno:

$$a^* = \arg\max_{a'} Q_{\text{tot}}(o_{t+1}, a'; \Theta_Q). \tag{13}$$

A diferença temporal é calculada pela rede-alvo usando essa ação:

$$y_t = r_t + \gamma\, Q_{\text{tot}}(o_{t+1}, a^*\,; \Theta_T). \tag{14}$$

A cada passo, a rede-alvo (Θ_T) é mantida fixa, enquanto que os pesos da rede-Q (Θ_Q) são atualizados por retropropagação, usando a perda definida na eq. 11. Apenas a cada C passos a rede-alvo é atualizada.

5. Experimentos

O objetivo dos experimentos é avaliar como a proposta de seleção de clientes no aprendizado federado (FL) por MARL desempenha em comparação com estratégias mais simples (FedAvg e SARL). São utilizados 50 clientes, e são selecionados 30% do número total de clientes disponíveis para treinamento ($K = 15$ clientes), exceto quando dito o contrário. Enquanto o FedAvg escolhe 30% dos clientes aleatoriamente a cada rodada, as alternativas com RL selecionam os 30% melhores para a rodada. A máquina utilizada para os experimentos possui uma GPU NVIDIA GeForce RTX 5090, 21.760 núcleos CUDA e memória VRAM GDDR7 de 32GB e 1,79TB/s. Ademais, todos os resultados foram obtidos ao longo de 500 rodadas de treinamento. Este valor foi escolhido empiricamente, tendo em vista a convergência observada em todos os cenários de avaliação. A implementação do arcabouço proposto, bem como o código-fonte utilizado nos experimentos, está disponível em `https://github.com/GTA-UFRJ/FEDMARL`.

O ambiente de aprendizado federado é implementado em PyTorch e utiliza uma Rede Neural Convolucional (CNN) para classificação com 5 camadas. Assume-se a seguinte notação: `Conv(f,`c_{in}`,`c_{out}`)` representa uma camada convolucional com *kernel* de tamanho f, c_{in} canais de entrada e c_{out} canais de saída, seguida de uma unidade retificadora linear, `Pool(a,b)` representa uma camada de *pooling* de dimensões $a \times b$, `FC(`c_{in}`,`c_{out}`)` representa uma camada completamente conectada, e `Relu(`c_{in}`,`c_{out}`)` representa uma camada completamente conectada seguida de uma função retificadora linear. No ambiente MARL, a rede Q é uma rede totalmente conectada (MLP) de três camadas, treinada a partir de *mini-batches* amostrados do *replay buffer*, com uma rede-alvo sincronizada periodicamente (*target update*). Em cada rodada, a exploração é realizada por uma perturbação do Top-K, com probabilidade ϵ, trocam-se m clientes selecionados por não selecionados. Além disso, há uma fase inicial de *warm-up* com seleções aleatórias até que o *buffer* contenha transições suficientes. A Tabela 2 apresenta os principais parâmetros das redes e do treinamento. Como a rede do treinamento federado é uma CNN simples e customizada, os resultados não superam o estado da arte mas permitem uma comparação entre as estratégias.

O conjunto de dados é o CIFAR10, utilizado como *benchmarking* em trabalhos na área. Ele contém 50 mil imagens coloridas 32x32 para treino, e outras 10 mil para teste. Para simular um cenário com distribuição de rótulos não-IID, a quantidade de amostras de cada classe em cada cliente segue a distribuição de Dirichlet, com parâmetro α. Valores maiores de α aproximam a distribuição do caso uniforme, enquanto valores menores simulam cenários mais heterogêneos. A validação é realizada ao final de cada rodada, após a agregação do modelo global, como no FedAvg.

Para avaliar a influência dos principais parâmetros relevantes na proposta, esta seção é organizada em seis experimentos. O primeiro avalia o impacto da proporção

entre clientes atacantes (aqueles que praticam inversão de rótulos) e o total de clientes. O segundo avalia o impacto da proposta na seleção de clientes, evidenciando a menor participação dos clientes atacantes no processo de treinamento. O terceiro avalia o impacto da distribuição dos dados por meio da manipulação do parâmetro α da distribuição de Dirichlet. A ideia é mostrar que a acurácia do modelo é negativamente afetada sob o ponto de vista dos atacantes, servindo como um desestímulo ao ataque. A porcentagem de inversão de rótulos executada por cada atacante é verificada no quarto experimento, enquanto o quinto experimento o impacto do número K de clientes selecionados. Por fim, o desempenho da proposta é comparado ao SARL.

5.1. Impacto da proporção de clientes atacantes

Esta subseção avalia o impacto da proporção de clientes atacantes no total de clientes do aprendizado federado. Para isso, adota-se o parâmetro de Dirichlet igual a 0,3, considera-se ainda que os atacantes invertem o rótulo de todas as suas amostras, que o número total de clientes é 50 e que o número k de clientes selecionados é sempre 15 (30% do total). A Figura 1(a) apresenta o resultado de acurácia sem atacantes ao longo das rodadas de treinamento. Observa-se que o desempenho do FedAvg e do MARL é idêntico, chegando a valores próximos a 70% ao final do treinamento. Já a Figura 1(b) mostra o impacto da proposta ao preservar a acurácia do modelo próximo a do cenário sem atacantes. A acurácia do FedAvg, ao final das rodadas, é reduzida até aproximadamente 50%, como consequência da inclusão de clientes maliciosos no treinamento. A Figura 1(c) apresenta a mesma tendência, acentuando mais ainda a diferença entre a acurácia do modelo com o MARL e a acurácia do modelo usando o FedAvg, como consequência da proporção ainda maior de atacantes. Nos casos com atacante, a curva de acurácia do MARL não é superior à do FedAvg nas primeiras rodadas, pois os agentes ainda não tiveram tempo de explorar o espaço de estado. Após essa etapa inicial, os agentes aprendem uma política para definir a ações de seleção de cada cliente que supera o desempenho do FedAvg.

5.2. Impacto na seleção de clientes

A Tabela 3 apresenta o número médio de vezes que cada um dos clientes foi selecionado ao longo das rodadas de treinamento nos experimentos executados na Seção 5.1. Note que, sem atacantes, o número médio de vezes que cada cliente é selecionado é igual

Tabela 2. Parâmetros do treinamento da tarefa federada.

Parâmetros do treinamento federado.

Nome do parâmetro	Valor do parâmetro
Camada de entrada	Conv(3,3,32) + Pool(2×2)
Camada 2	Conv(3,32,64) + Pool(2×2)
Camada 3	Conv(3,64,128) + Pool(2×2)
Camada 4	ReLU(2048,256)
Camada de saída	FC(256,10)
Função de perda	Entropia cruzada
Otimizador	SGD ($mom. = 0.9$)
Learning rate	$\eta = 0.01$
Batch size	64

Parâmetros do DQN.

Nome do parâmetro	Valor do parâmetro
Camada de entrada	ReLU(4,128)
Camada 2	ReLU(128,128)
Camada de saída	FC(128,2)
Função de perda	Huber
Otimizador	Adam ($\lambda = 10^{-4}$)
Learning rate	$\eta = 10^{-3}$
Batch size (base $\rightarrow$ máx.)	$32 \rightarrow 256$
Target update	C = 20
Warm-up	50 rodadas
Exploração	$\epsilon = 0.15$, $m = 3$
Fator de de desconto	$\gamma = 0.90$

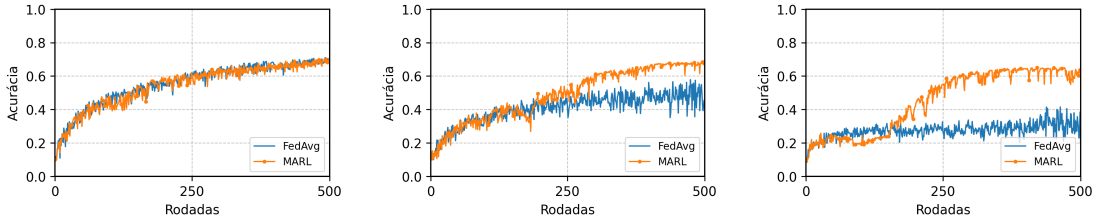

(a) Sem atacantes. (b) 40% de clientes atacantes. (c) 60% de clientes atacantes.

Figura 1. Impacto da proporção de clientes atacantes sobre o número total.

ao número de rodadas vezes a proporção de clientes selecionados, ou seja, $500 \times 0,3 = 150$, demonstrando que a probabilidade de escolha de cada cliente é aproximadamente a mesma. Com 40% de atacantes, o número de vezes que os clientes honestos e atacantes no FedAvg permanece próximo de 150, enquanto, para o MARL, observa-se o efeito da seleção em que os clientes honestos são priorizados. Com 60% de atacantes, o efeito da seleção de clientes no MARL é ainda acentuado. Esses resultados confirmam que a proposta, de fato, seleciona os clientes que mais contribuem para o treinamento do modelo, além de justificar os resultados da Seção 5.1.

Tabela 3. Número médio de vezes que os clientes honestos e os atacantes são selecionados para participar de rodadas de treinamento.

Cenário	FedAVG		MARL	
	Honestos	Atacantes	Honestos	Atacantes
Sem atacantes	150 ± 10.61	Não há	150 ± 38.27	Não há
40% de atacantes	149.13 ± 11.00	151.30 ± 12.37	204.17 ± 73.25	68.75 ± 11.93
60% de atacantes	151.20 ± 12.28	$149.20 \pm \pm 10.00$	257.95 ± 115.93	78.03 ± 36.87

5.3. Impacto da distribuição dos dados

A mesma configuração anterior é reutilizada nesta seção. Dessa forma, os atacantes invertem o rótulo de todas as suas amostras, o número total de clientes é 50 e o número K de clientes selecionados é 15. Porém, a porcentagem de atacantes é fixa em 40% e, diferentemente dos resultados anteriores, o foco deste experimento é verificar o impacto da distribuição dos dados na acurácia do modelo. Para isso, reduz-se o parâmetro α de Dirichlet para simular distribuições mais heterogêneas, com valores de 0,3, 0,2 e 0,1.

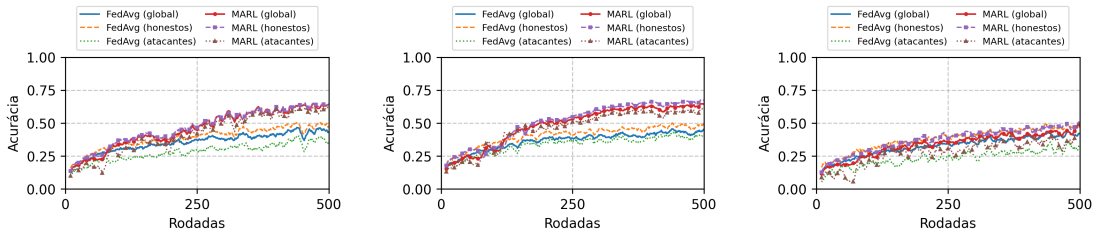

(a) Dirichlet $\alpha = 0,3$ (b) Dirichlet $\alpha = 0,2$ (c) Dirichlet $\alpha = 0,1$

Figura 2. Impacto da distribuição dos dados com a variação do α de Dirichlet.

Um resultado adicional que esta subseção apresenta é a acurácia do modelo treinado sob o ponto de vista dos clientes honestos e atacantes. Este resultado é importante, já

que não participar de uma rodada de treinamento pode ser entendido como um estímulo ao ataque devido à economia de recursos computacionais e de rede. Nesse sentido, a Figura 2(a) mostra, no entanto, que os clientes honestos possuem sempre desempenho superior aos atacantes. Assume-se que o atacante adota uma postura egoísta em que os rótulos são invertidos apenas no treinamento, de forma que os testes são realizados sem a inversão de rótulos. No caso do MARL, os clientes atacantes contribuem menos com amostras, fazendo com que o modelo fique mais ajustado aos clientes honestos. No FedAvg, a diferença é ainda mais evidente e o desempenho do modelo global é ainda pior para os desonestos. Esse mesmo comportamento se mantêm com a redução do parâmetro de Dirichlet, Figuras 2(b) e 2(c), sendo que para 0,1, há um decréscimo mais evidente da acurácia devido a heterogeneidade dos dados.

5.4. Impacto da porcentagem de inversão de rótulos

Este experimento avalia a convergência do modelo quando nem todas as amostras de um atacante têm seus rótulos comprometidos. Para isso, é utilizada a mesma distribuição de Dirichlet e valor de K da Seção 5.1 ($\alpha = 0,3$ e 15, respectivamente), e a mesma proporção de atacantes da Seção 5.3 (40%). A porcentagem de rótulos invertidos pelos atacantes é reduzida de 100% para 60%, e, em seguida, para 40%, para simular diferentes níveis de força do ataque. A Figura 3 revela um aumento na acurácia no FedAvg a medida que menos amostras são comprometidas. Já o MARL permanece estável, com acurácia próxima dos 64% em todos os cenários, superando o FedAvg. Esse desempenho é decorrente da seleção de clientes que tende a excluir os atacantes do treinamento.

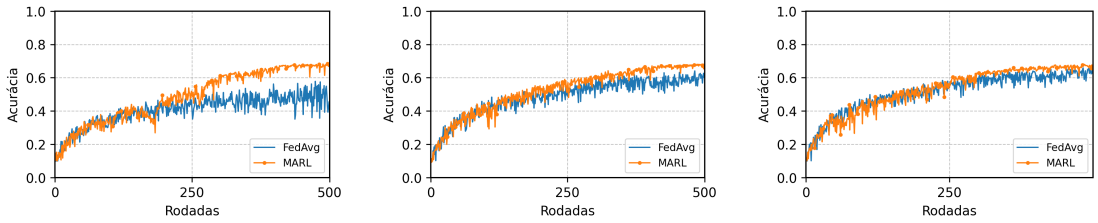

(a) 100% de inversão de rótulos. (b) 60% de inversão de rótulos. (c) 40% de inversão de rótulos.

Figura 3. Impacto da porcentagem de inversão de rótulos.

5.5. Impacto da variação do número de clientes selecionados (parâmetro K)

Este experimento avalia a fração de clientes selecionados, parâmetro K, em 10, 15 e 35, utilizando os valores padrões de α (0,3), fração de atacantes (40%) e porcentagem de inversão de rótulos (100%). A Figura 4 revela que os resultados do MARL e do FedAvg são similares para K=10 e 15, com o MARL apresentando melhor desempenho devido à seleção dos melhores clientes. Também é avaliado um cenário mais extremo para K=35, ou seja para um K que seleciona 70% dos clientes, no qual, dada a presença de 40% de atacantes, torna-se inviável selecionar apenas clientes honestos. Nesse cenário, o FedAvg degrada mais, enquanto o MARL mantém maior acurácia, sugerindo que a política aprendida prioriza, entre os atacantes inevitáveis, aqueles que menos degradam o modelo global.

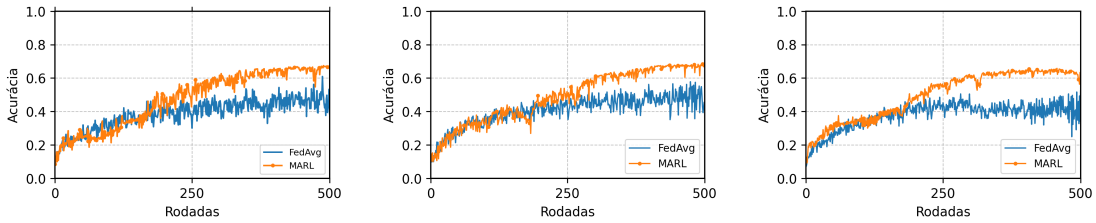

(a) $K = 10$. (b) $K = 15$. (c) $K = 35$.

Figura 4. Impacto da variação do parâmetro K.

5.6. Comparação com o *single-agent* RL

Esta seção compara a proposta com MARL com a abordagem de agente único (SARL), onde ambos selecionam K clientes a cada rodada (Top-K), usando as mesmas configurações da Seção 5.1. Enquanto no SARL cada cliente é recompensado conforme sua contribuição para o treinamento na rodada, no MARL, a recompensa é conjunta entre os clientes. Consequentemente, o SARL possui uma visão local avaliada por cliente, enquanto o MARL coordena agentes sob uma mesma meta global. Na Figura 5, é possível observar que o MARL ainda obtém um desempenho melhor, destacando o benefício da tomada de decisões coletivas.

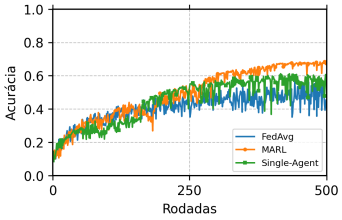

Figura 5. Comparação com o SARL.

6. Conclusão e Trabalhos Futuros

Este trabalho propõe o uso de aprendizado por reforço multiagente (MARL) na seleção de clientes do aprendizado federado (FL) com dados não independentes e identicamente distribuídos (não-IID) e inversão de rótulos. O trabalho contribui para a literatura ao demonstrar que o MARL evita a seleção de clientes que efetuam ataques adversariais durante o treinamento do modelo. Os resultados revelam um aumento na acurácia em relação ao FedAvg e ao uso de agente único (SARL) em todos os cenários, com destaque para cenários com maior proporção de atacantes, dados muito heterogêneos e com mais rótulos invertidos por atacante. Como trabalhos futuros, é prevista a implementação da proposta em um ambiente real, com modelos mais complexos, como modelos fundacionais de visão computacional e modelos grandes de linguagem (LLMs), assumindo também ataques mais complexos, além de comparações com um conjunto mais amplo de *baselines*.

Referências

Blanchard, P., Mhamdi, E. M. E., Guerraoui, R., and Stainer, J. (2017). Byzantine-Tolerant Machine Learning. *CoRR*, abs/1703.02757.

de Souza, L. A. C., Camilo, G. F., Rebello, G. A. F., Sammarco, M., Campista, M. E. M., and Costa, L. H. M. K. (2024). ATHENA-FL: Avoiding Statistical Heterogeneity with One-versus-All in Federated Learning. *Journal of Internet Services and Applications*, 15(1):273–288.

Jebreel, N. M., Domingo-Ferrer, J., Sánchez, D., and Blanco-Justicia, A. (2022). Defending against the Label-flipping Attack in Federated Learning. *CoRR*, abs/2207.01982.

Jee Cho, Y., Wang, J., and Joshi, G. (2022). Towards Understanding Biased Client Selection in Federated Learning. In *25th International Conference on Artificial Intelligence and Statistics*, pages 10351–10375.

Jiang, X., Li, J., Wu, N., Wu, Z., Li, X., Sun, S., Xu, G., Wang, Y., Li, Q., and Liu, M. (2025). FNBench: Benchmarking Robust Federated Learning against Noisy Labels. *CoRR*, abs/2505.06684.

Lai, F., Zhu, X., Madhyastha, H. V., and Chowdhury, M. (2021). Oort: Efficient Federated Learning via Guided Participant Selection. In *15th USENIX Symposium on Operating Systems Design and Implementation (OSDI 21)*, pages 19–35.

McMahan, B., Moore, E., Ramage, D., Hampson, S., and Aguera y Arcas, B. (2017). Communication-Efficient Learning of Deep Networks from Decentralized Data. In *20th International Conference on Artificial Intelligence and Statistics (AISTATS)*, pages 1273–1282.

Sagar, S., Li, C.-S., Loke, S. W., and Choi, J. (2023). Poisoning Attacks and Defenses in Federated Learning: A Survey. *CoRR*, abs/10.48550.

Sunehag, P., Lever, G., Gruslys, A., Czarnecki, W. M., Zambaldi, V., Jaderberg, M., Lanctot, M., Sonnerat, N., Leibo, J. Z., Tuyls, K., and Graepel, T. (2017). Value-Decomposition Networks For Cooperative Multi-Agent Learning. *CoRR*, abs/1706.05296.

Tian, C., Shi, Z., Qin, X., Li, L., and Xu, C.-Z. (2024). Ranking-based Client Imitation Selection for Efficient Federated Learning. In *Proceedings of the 41st International Conference on Machine Learning*, pages 48211–48225.

Wang, H., Kaplan, Z., Niu, D., and Li, B. (2020). Optimizing Federated Learning on Non-IID Data with Reinforcement Learning. In *IEEE Conference on Computer Communications (INFOCOM)*, pages 1698–1707.

Yin, D., Chen, Y., Ramchandran, K., and Bartlett, P. (2018). Byzantine-Robust Distributed Learning: Towards Optimal Statistical Rates. In *35th International Conference on Machine Learning*, pages 5650–5659.

Zhang, S. Q., Lin, J., and Zhang, Q. (2022). A Multi-Agent Reinforcement Learning Approach for Efficient Client Selection in Federated Learning. In *Proceedings of the AAAI Conference on Artificial Intelligence*, pages 9091–9099.

Zhao, Y., Li, M., Lai, L., Suda, N., Civin, D., and Chandra, V. (2018). Federated Learning with Non-IID Data. *CoRR*, abs/1806.00582.