

Fairness em Aprendizado Federado Multi-Modelo sob Heterogeneidade de Dados e Sistemas

Cláudio G. S. Capanema¹, Fabrício A. Silva²,
Leandro A. Villas³, Antonio A. F. Loureiro¹

¹ Universidade Federal de Minas Gerais (UFMG), Brasil

² Universidade Federal de Viçosa (UFV), Brasil

³ Universidade Estadual de Campinas (UNICAMP), Brasil

{claudio.capanema, loureiro}@dcc.ufmg.br, fabricio.asilva@ufv.br
lvillas@unicamp.br

Abstract. *This work analyzes the problem of fairness in Multi-model Federated Learning (MEFL) under data and system heterogeneity. Unlike traditional approaches based on equality, we propose a notion of fairness grounded in contribution proportionality, jointly considering data volume, computational capacity, and model cost. To this end, we define two metrics: Fairness Proportional to Inter-Client Contribution (FPC-Inter), which evaluates proportionality across clients, and Fairness Proportional to Intra-Client Contribution (FPC-Intra), which analyzes contribution by comparing models within each client. The results show that existing methods exhibit different client and model selection patterns, but fail to simultaneously balance performance and fairness, highlighting the need for new approaches better aligned with reference contribution.*

Resumo. *Este trabalho analisa o problema de fairness em Multi-model Federated Learning (MEFL) sob heterogeneidade de dados e sistemas. Diferentemente de abordagens tradicionais baseadas em igualdade, propõe-se uma visão de fairness fundamentada na proporcionalidade da contribuição, considerando simultaneamente volume de dados, capacidade computacional e custos dos modelos. Para isso, são definidas duas métricas: Fairness Proporcional à Contribuição Inter-Clientes (FPC-Inter), que avalia a proporcionalidade entre clientes, e Fairness Proporcional à Contribuição Intra-Cliente (FPC-Intra), que analisa a contribuição comparando modelos dentro de cada cliente. Os resultados mostram que os métodos existentes apresentam diferentes padrões de seleção de clientes e modelos, mas não conseguem equilibrar simultaneamente desempenho e fairness, evidenciando a necessidade de novas abordagens mais alinhadas à contribuição de referência.*

1. Introdução

O *Federated Learning (FL)* tem se consolidado como uma abordagem promissora para treinamento distribuído de modelos preservando a privacidade dos dados e reduzindo custos de comunicação [Capanema et al. 2024]. Tradicionalmente, o *FL* considera o treinamento de um único modelo global a partir da colaboração de múltiplos clientes [Capanema et al. 2023, Capanema et al. 2025a]. No entanto, a crescente capacidade dos

dispositivos de borda e a diversidade de aplicações têm impulsionado a necessidade de suportar múltiplas tarefas simultaneamente.

Nesse contexto, o *Multi-model Federated Learning (MEFL)* surge como uma extensão natural, permitindo o treinamento simultâneo de múltiplos modelos sobre um mesmo conjunto de clientes [Capanema et al. 2025c]. Embora essa abordagem possibilite maior eficiência no uso de recursos e melhor aproveitamento da infraestrutura distribuída, ela introduz desafios adicionais relacionados à alocação de recursos entre clientes e tarefas.

Um dos principais desafios do *MEFL* é a definição de *fairness* em um cenário onde múltiplos modelos competem por recursos limitados e os clientes apresentam heterogeneidade significativa. Na literatura de *FL*, a *fairness* é frequentemente associada à igualdade de participação, desempenho ou representação dos dados [Shi et al. 2023]. No entanto, tais definições tornam-se inadequadas em ambientes multi-modelo, pois ignoram aspectos fundamentais como a capacidade computacional dos clientes e o custo dos diferentes modelos. A busca por equidade em ambientes de elevada heterogeneidade está frequentemente associada ao *trade-off* entre *fairness* e acurácia [Mukhtiar et al. 2025], tornando esse problema ainda mais desafiador em cenários de *MEFL*.

Diante disso, torna-se necessário repensar a noção de *fairness* considerando as limitações reais do sistema, uma vez que alocações uniformes podem ser ineficientes em cenários heterogêneos. Nesse contexto, a distribuição de recursos deve refletir o potencial de contribuição dos participantes, incorporando dados, capacidade computacional e custo dos modelos.

Em cenários de *MEFL*, essa perspectiva implica considerar não apenas a distribuição de recursos entre clientes, mas também como esses recursos são alocados entre diferentes modelos dentro de cada cliente. Essas duas dimensões, inter-clientes e intra-cliente, são complementares e essenciais para uma compreensão completa do uso de recursos no sistema.

Apesar de avanços na literatura, a maioria das abordagens existentes não considera explicitamente essa visão integrada de *fairness*. Em geral, as soluções atuais focam em desempenho ou participação, sem modelar adequadamente o impacto conjunto da heterogeneidade de dados, da capacidade dos clientes e do custo computacional dos modelos. Como consequência, ainda há uma lacuna na compreensão de como diferentes estratégias de aprendizado federado se comportam sob uma perspectiva de alocação de recursos em ambientes multi-modelo.

Neste trabalho, realizamos uma avaliação sistemática de diferentes estratégias de aprendizado federado no contexto de *MEFL*, sob a ótica de *fairness* de contribuição. Para isso, propomos duas métricas baseadas em Fairness Proporcional à Contribuição (FPC): *FPC-Inter*, que avalia se a participação de cada cliente é proporcional à sua contribuição de referência no sistema, e *FPC-Intra*, que avalia se a quantidade de vezes que cada modelo foi treinado dentro de um mesmo cliente é proporcional à sua contribuição de referência dentre os modelos existentes. Essas métricas permitem analisar se a participação de clientes segue um princípio de proporcionalidade em cenários multi-modelo sob heterogeneidade de dados e de sistemas.

As principais contribuições deste trabalho são:

- A proposição de duas métricas de *fairness* baseadas em alinhamento com contribuição de referência, capturando as dimensões inter-clientes e intra-cliente.
- Uma reformulação da noção de *fairness* em *MEFL* como proximidade entre contribuição observada e contribuição de referência baseada em taxa de processamento e volume de dados.
- Uma avaliação comparativa de diferentes estratégias de aprendizado federado sob essa nova perspectiva.
- Uma análise dos trade-offs entre desempenho e *fairness*, evidenciando que alocação uniforme nem sempre é desejável em ambientes heterogêneos.

O restante deste artigo está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados. A Seção 3 define formalmente o paradigma de *MEFL*. A Seção 4 introduz as métricas propostas de *fairness*. A Seção 5 descreve a configuração experimental, enquanto a Seção 6 apresenta e discute os resultados. Por fim, a Seção 7 conclui o trabalho e aponta direções futuras.

2. Trabalhos Relacionados

Nesta seção, revisamos trabalhos relevantes em aprendizado federado tradicional e multi-modelo, com foco em estratégias de seleção de clientes, eficiência de treinamento e *fairness*. Diferentemente da literatura existente, este trabalho analisa *fairness* sob a perspectiva de proporcionalidade entre a participação do cliente no treinamento e a sua respectiva contribuição de referência, considerando explicitamente as dimensões inter-clientes e intra-cliente.

2.1. Trabalhos em *MEFL*

O aprendizado federado multi-modelo (*MEFL*) estende o *FL* tradicional ao permitir o treinamento simultâneo de múltiplas tarefas em ambientes distribuídos, introduzindo competição por recursos entre modelos e novos desafios de alocação.

O *MultiFedAvg* [Bhuyan and Moharir 2022] generaliza o *FedAvg* para múltiplos modelos, utilizando seleção de clientes aleatória ou baseada em *UCB*. Embora eficiente, não impõe qualquer critério de proporcionalidade entre participação e capacidade dos clientes.

O *FedFairMMFL* [Siew et al. 2025] introduz α -*fairness* para balancear o desempenho entre tarefas, mas define *fairness* em termos de *loss*, e não em termos de alocação de recursos ou contribuição. Assim, esta solução não modela a relação entre frequência de treinamento e a contribuição para o sistema.

Outras abordagens, como [Lobato et al. 2024], realizam atribuição dinâmica de modelos com base em entropia dos dados, latência e mobilidade dos clientes. Apesar de incorporarem fatores de sistema, essas soluções focam em eficiência operacional, sem avaliar se a taxa de uso dos recursos é proporcional à contribuição efetiva.

De forma geral, os trabalhos em *MEFL* tratam da alocação de clientes entre modelos, mas não analisam se essa alocação respeita uma relação de proporcionalidade entre uso, taxa de processamento e volume de dados, nem distinguem explicitamente as dimensões inter-clientes e intra-cliente.

2.2. Trabalhos em FL Tradicional

No contexto de FL tradicional, diversas abordagens exploram a eficiência e, em alguns casos, *fairness*, principalmente por meio de estratégias de seleção de clientes.

O *Oort* [Lai et al. 2021] seleciona clientes com base em utilidade, combinando ganho esperado de aprendizado e eficiência de execução. Essa estratégia favorece clientes com maior contribuição por unidade de tempo, induzindo implicitamente uma alocação proporcional à eficiência. No entanto, essa relação não é explicitamente modelada nem avaliada como critério de *fairness*.

O *FedBalancer* [Shin et al. 2022] busca equilibrar o treinamento considerando o tamanho dos dados e a dificuldade das amostras, promovendo eficiência no uso dos recursos. Ainda assim, não estabelece uma relação explícita entre taxa de participação e eficiência computacional.

O *FairHetero* [Talukder et al. 2025] ajusta a participação dos clientes com base em suas capacidades, introduzindo uma forma de *fairness* entre clientes. Entretanto, essa abordagem foca no equilíbrio entre grupos e não na proporcionalidade entre uso e contribuição efetiva.

De forma geral, essas abordagens consideram eficiência ou equilíbrio, mas não modelam *fairness* como alinhamento entre a taxa de uso dos clientes e sua eficiência no sistema.

2.3. Comparação entre as abordagens

As abordagens existentes tratam diferentes aspectos do problema. Métodos como *Oort* e *FedBalancer* priorizam eficiência, enquanto *FairHetero* considera *fairness* entre clientes e *FedFairMMFL* aborda *fairness* de desempenho entre tarefas.

No entanto, nenhuma dessas soluções avalia explicitamente se: (i) a taxa de participação dos clientes é proporcional à sua contribuição de referência no sistema, e (ii) a taxa de treinamento dos modelos dentro de cada cliente é proporcional à sua contribuição de referência.

Essa ausência de uma definição baseada em proporcionalidade limita a análise da alocação de recursos, especialmente em cenários multi-modelo.

Tabela 1. Comparação entre abordagens sob *fairness* de recursos

Método	Seleção	Critério de Fairness	Multi-modelo	Inter-clientes	Intra-cliente
<i>MultiFedAvg</i>	Aleatória / UCB	Não trata	Sim	Não	Não
<i>Oort</i>	Utilidade + sistema	Implícito (eficiência)	Não	Parcial	Não
<i>FairHetero</i>	Ponderada por grupos	Equilíbrio entre clientes	Não	Parcial	Não
<i>FedBalancer</i>	Baseada em dados	Não trata	Não	Não	Não
<i>FedFairMMFL</i>	Baseada em loss (α -fairness)	Desempenho (tarefas)	Sim	Não	Parcial
<i>MELRO</i>	Entropia + sistema	Não trata	Sim	Não	Não

2.4. Síntese e Limitações

Os trabalhos analisados exploram eficiência, desempenho e, em alguns casos, *fairness*, mas não definem *fairness* como uma relação de proporcionalidade entre uso e contribuição de referência.

Em particular, nenhuma abordagem existente modela simultaneamente: (i) a proporcionalidade entre a taxa de participação dos clientes e sua contribuição de referência (dimensão inter-clientes), e (ii) a proporcionalidade entre a taxa de treinamento dos modelos e sua contribuição de referência dentro de cada cliente (dimensão intra-cliente).

Essa lacuna motiva a necessidade de métricas que permitam avaliar explicitamente essas relações, fornecendo uma visão mais precisa da alocação de recursos em cenários de *MEFL*.

3. Definição Formal de *MEFL*

No contexto de *MEFL*, consideramos um conjunto de K clientes que colaboram para o treinamento simultâneo de ME modelos independentes. Cada cliente $k \in \{1, \dots, K\}$ possui, para cada modelo $me \in \{1, \dots, ME\}$, um conjunto de dados local $D^{k,me}$ e é capaz de realizar atualizações locais sobre os parâmetros do modelo correspondente [Capanema et al. 2025c, Capanema et al. 2025b].

O treinamento ocorre de forma iterativa ao longo de T rodadas. Em cada rodada $t \in \{1, \dots, T\}$, o servidor seleciona um subconjunto de clientes para participar do treinamento. Seja $C \leq K$ o número máximo de clientes ativos por rodada. Para cada modelo me , define-se um subconjunto $S_t^{me} \subseteq \{1, \dots, K\}$ de clientes selecionados, tal que $|S_t^{me}| = C_t^{me}$.

Devido a restrições de recursos computacionais, cada cliente selecionado participa do treinamento de no máximo um modelo por rodada. Após receber os parâmetros globais do modelo atribuído, cada cliente realiza treinamento local utilizando seus dados $D^{k,me}$, produzindo uma atualização $w_{t+1}^{k,me}$.

O servidor, então, agrega as atualizações recebidas para cada modelo de forma ponderada, considerando o tamanho relativo dos conjuntos de dados locais. A atualização do modelo global me é dada por [Capanema et al. 2025b]:

$$w_{t+1}^{me} \leftarrow \sum_{k \in S_t^{me}} \frac{|D^{k,me}|}{|D^{me}|} w_{t+1}^{k,me}, \quad (1)$$

onde $|D^{me}| = \sum_{k=1}^K |D^{k,me}|$ representa o total de amostras disponíveis para o modelo me .

O objetivo global do *MEFL* consiste em otimizar simultaneamente todos os modelos treinados. Na formulação padrão baseada em MultiFedAvg, busca-se minimizar a soma das funções de perda associadas a cada modelo:

$$\min_{w^1, \dots, w^{ME}} \sum_{me=1}^{ME} f^{me}(w^{me}), \quad (2)$$

onde a função de perda global de cada modelo me é definida como a média ponderada das perdas locais dos clientes:

$$f^{me}(w^{me}) = \sum_{k=1}^K \frac{|D^{k,me}|}{|D^{me}|} \mathcal{L}^{k,me}(x^{k,me}, y^{k,me}; w^{me}), \quad (3)$$

em que $\mathcal{L}^{k,me}$ representa a função de perda local do cliente k para o modelo me , aplicada sobre seus dados de entrada $x^{k,me}$ e respectivos rótulos $y^{k,me}$.

Essa formulação estende diretamente o paradigma clássico de *FL* para múltiplas tarefas independentes, introduzindo novos desafios relacionados à alocação de clientes, competição por recursos e equilíbrio no progresso dos diferentes modelos ao longo do treinamento.

4. Métricas Propostas de *Fairness* de Contribuição

No contexto de *MEFL*, a alocação de recursos ocorre sob heterogeneidade significativa de dados, capacidade computacional e custo dos modelos. Nesse cenário, abordagens baseadas em igualdade de participação tornam-se inadequadas, pois ignoram diferenças estruturais entre clientes e tarefas.

A nova noção proposta de *fairness* baseada em proporcionalidade busca reduzir o *trade-off* entre acurácia e *fairness* o que é especialmente importante em cenários de elevada heterogeneidade como em *MEFL*.

Neste sentido, esta seção apresenta duas métricas de *fairness* para *MEFL*: *FPC-Inter*, que avalia o quão alinhada está a participação dos clientes com sua contribuição de referência; e *FPC-Intra*, que avalia o quão alinhada está a distribuição da participação de cada cliente entre os modelos com suas respectivas contribuições de referência.

4.1. Da Taxa de Processamento à Contribuição do Cliente

A taxa de processamento do cliente k no modelo me é definida como:

$$R_k^{me} = \frac{v_k}{\text{Custo}_{me}}, \quad (4)$$

onde v_k (FLOPs/s) representa a capacidade computacional do cliente e Custo_{me} (FLOPs/amostra) representa o custo do modelo. Assim, R_k^{me} possui unidade de amostras/s, indicando quantas amostras o cliente consegue processar por segundo.

No entanto, esta taxa não captura diretamente a contribuição total do cliente, pois não considera o volume de dados disponível.

Para obter a medida de contribuição (γ_k^{me}) do cliente k no modelo *ME*, calcula-se a taxa de processamento ponderada pelo volume de dados $|D^{k,me}|$, como:

$$\gamma_k^{me} = |D^{k,me}| \cdot R_k^{me} = |D^{k,me}| \cdot \frac{v_k}{\text{Custo}_{me}} = \frac{v_k \cdot |D^{k,me}|}{\text{Custo}_{me}}. \quad (5)$$

Interpretação. O valor de γ_k^{me} pode ser interpretado como a capacidade efetiva do cliente de transformar dados em atualizações de modelo por unidade de tempo. Clientes mais rápidos, com mais dados ou operando sobre modelos mais leves apresentam maior contribuição no sistema de aprendizado. Além disso, ao combinar explicitamente taxa de processamento e disponibilidade de dados, a métrica evita vieses extremos: não privilegia clientes que são apenas rápidos, mas que possuem poucos dados (e, portanto, contribuição

limitada), nem clientes com grande volume de dados, porém baixa capacidade de processamento. Dessa forma, estabelece-se uma referência mais equilibrada de contribuição, alinhada ao impacto real de cada cliente no processo de treinamento.

Por fim, a contribuição total γ_k do cliente k no sistema é calculada como o somatório das suas contribuições em cada um dos modelos, definida como:

$$\gamma_k = \sum_{me=1}^{ME} \gamma_k^{me}. \quad (6)$$

4.2. FPC-Inter: *Fairness* entre Clientes

A métrica Fairness Proporcional à Contribuição Inter-Clientes (FPC-Inter) avalia se a participação dos clientes está proporcional à sua contribuição no sistema.

4.2.1. Contribuição de Referência Inter-Clientes

A contribuição de referência \hat{u}_k do cliente k é calculada a partir da sua contribuição γ_k normalizada pela contribuição total dos clientes do sistema, sendo definida como:

$$\hat{u}_k = \frac{\gamma_k}{\sum_{j=1}^K \gamma_j}. \quad (7)$$

Em termos práticos, o valor de \hat{u}_k representa a taxa de participação de referência do cliente no sistema.

4.2.2. Contribuição Observada Inter-Clientes

A contribuição observada de um cliente k no modelo me até a rodada t é definida como:

$$u_k^{me}(t) = \sum_{\tau=1}^t \mathbb{I}[k \in S_{\tau}^{me}], \quad (8)$$

onde $\mathbb{I}[k \in S_{\tau}^{me}]$ é uma função indicadora que assume valor 1 quando o cliente k é selecionado para treinar o modelo me na rodada τ , e 0 caso contrário.

A contribuição observada total $u_k(t)$, isto é, envolvendo todos os modelos do cliente k até a rodada t é definida como:

$$u_k(t) = \sum_{me=1}^{ME} u_k^{me}(t). \quad (9)$$

Dessa forma, ao somar essa quantidade sobre todas as rodadas ($\tau = 1, \dots, t$) e todos os modelos ($me = 1, \dots, ME$), obtém-se o número total de vezes que o cliente participou do treinamento no sistema.

Por fim, calcula-se a contribuição observada normalizada $\tilde{u}_k(t)$ do cliente k até a rodada t é definida como:

$$\tilde{u}_k(t) = \frac{u_k(t)}{\sum_{j=1}^K u_j(t)}. \quad (10)$$

4.2.3. Métrica de Fairness

O desvio relativo δ_k entre as contribuições observada e de referência é definido como:

$$\delta_k = \frac{|\tilde{u}_k - \hat{u}_k|}{\max(\tilde{u}_k, \hat{u}_k) + \epsilon}, \quad (11)$$

onde o valor de δ_k cresce a medida que aumenta a diferença absoluta entre as contribuições e ϵ é um valor próximo de 0.

O valor de FPC-Inter é então calculado com base no desvio relativo δ_k ponderado pela contribuição de referência \hat{u}_k , sendo definido como:

$$F^{\text{inter}}(t) = 1 - \sum_k \hat{u}_k \cdot \delta_k. \quad (12)$$

Dessa forma, quanto maior o desvio e maior a contribuição de referência (i.e., importância do cliente), menor o valor de *fairness*.

4.3. FPC-Intra: Fairness entre Modelos por Cliente

A métrica Fairness Proporcional à Contribuição Intra-Cliente (FPC-Intra) avalia se, dentro de cada cliente, a alocação entre modelos segue a contribuição referência de cada modelo.

4.3.1. Contribuição de Referência Intra-Cliente

A contribuição referência \hat{u}_k^{me} do cliente k no modelo me é definida como a sua contribuição γ_k^{me} no respectivo modelo normalizada pela contribuição total de todos os clientes, sendo definida como:

$$\hat{u}_k^{me} = \frac{\gamma_k^{me}}{\sum_{j=1}^{ME} \gamma_k^j}. \quad (13)$$

4.3.2. Contribuição Observada Intra-Cliente

A contribuição observada normalizada $\tilde{u}_k^{me}(t)$ do cliente k no modelo me até a rodada t é definida como:

$$\tilde{u}_k^{me}(t) = \frac{u_k^{me}(t)}{\sum_j u_k^j(t)}. \quad (14)$$

Em termos gerais, esta contribuição representa a fração de treinamento foi aplicado pelo cliente k no modelo me em relação a quantidade total de treinamento que este cliente realizou considerando todos os modelos.

4.3.3. Métrica de Fairness

O desvio relativo δ_k^{me} entre as contribuições observada e de referência é definido como:

$$\delta_k^{me} = \frac{|\tilde{u}_k^{me} - \hat{u}_k^{me}|}{\max(\tilde{u}_k^{me}, \hat{u}_k^{me}) + \epsilon}, \quad (15)$$

onde δ_k^{me} tem um comportamento análogo ao de δ_k , ou seja, crescendo a medida que aumenta o a diferença absoluta entre as contribuições.

O valor de FPC-Intra do cliente k é então calculado com base no desvio relativo δ_k^{me} ponderado pela contribuição de referência \hat{u}_k^{me} , sendo definido como:

$$F_k^{\text{intra}}(t) = 1 - \sum_{me} \hat{u}_k^{me} \cdot \delta_k^{me}. \quad (16)$$

Finalmente, o valor global de FPC-Intra é calculado a partir da média dos F_k^{intra} dos clientes ponderada pelos tamanhos dos seus *datasets*:

$$F^{\text{intra}}(t) = \frac{\sum_k ((\sum_{me} |D^{k,me}|) \cdot F_k^{\text{intra}}(t))}{\sum_k \sum_{me} |D^{k,me}|}. \quad (17)$$

4.4. Discussão

As métricas propostas definem *fairness* como o alinhamento entre a contribuição observada e uma contribuição de referência baseada três aspectos: volume de dados, velocidade de processamento, e custo de modelo.

A métrica *FPC-Inter* captura a proporcionalidade entre clientes, enquanto *FPC-Intra* captura a proporcionalidade entre modelos dentro de cada cliente.

Essa separação permite analisar explicitamente duas dimensões fundamentais da alocação de recursos em *MEFL*, oferecendo uma visão mais precisa do comportamento dos algoritmos sob heterogeneidade de dados, sistemas e modelos.

5. Configuração Experimental

Nesta seção descrevemos o ambiente experimental utilizado para avaliar as diferentes abordagens de aprendizado federado no contexto de *MEFL*. Todas as soluções analisadas, incluindo métodos originalmente propostos para *FL* de modelo único, são executadas sob o mesmo protocolo experimental, garantindo uma comparação justa.

5.1. Configuração Geral

Os experimentos consideram um cenário com $K = 40$ clientes e $T = 100$ rodadas de treinamento federado. Em cada rodada, apenas uma fração dos clientes participa do treinamento, definida por $C = 0.3 \cdot K$, resultando em até 12 clientes ativos por rodada.

Cada cliente executa treinamento local por uma época, utilizando batch size de 64 e taxa de aprendizado de 0.01. Além disso, as soluções analisadas são: *FedBalancer* [Shin et al. 2022], *Oort* [Lai et al. 2021], *FairHetero* [Talukder et al. 2025], *FedFairMMFL* [Siew et al. 2025] e *MultiFedAvg* [Bhuyan and Moharir 2022].

5.2. Datasets e Cenário Multi-Modelo

O cenário de *MEFL* considerado envolve o treinamento simultâneo de dois modelos distintos, associados aos datasets CIFAR-10 e GTSRB. Esses datasets apresentam características diferentes em termos de complexidade e dimensionalidade, permitindo avaliar o comportamento das abordagens sob diferentes demandas computacionais e padrões de aprendizado. Cada cliente possui dados locais para ambos os modelos, respeitando o cenário multitarefa típico de *MEFL*.

5.3. Heterogeneidade de Dados

A heterogeneidade estatística entre clientes é simulada por meio de uma distribuição de Dirichlet, amplamente utilizada na literatura de *FL* para gerar partições não-iid. São considerados dois níveis de heterogeneidade:

- $\alpha = 0.1$: cenário altamente não-iid, com forte concentração de classes por cliente;
- $\alpha = 1.0$: cenário mais próximo de distribuição uniforme.

Essa configuração permite avaliar o impacto da heterogeneidade de dados no comportamento das abordagens, especialmente sob a perspectiva de *fairness*.

5.4. Heterogeneidade de Sistema

A heterogeneidade de sistema é modelada considerando diferenças tanto na capacidade computacional dos clientes quanto no custo dos modelos.

Cada cliente k possui uma velocidade de processamento v_k (FLOPs/s), que representa sua capacidade de executar operações computacionais. No ambiente experimental, v_k é simulado por meio de uma distribuição log-normal, refletindo a heterogeneidade típica de dispositivos, e limitado a um intervalo finito para evitar valores extremos.

Cada modelo me possui um custo computacional por amostra, denotado por FLOPs_{me} .

No cenário considerado, simulamos custos distintos entre os modelos, assumindo que o modelo associado ao dataset GTSRB possui custo computacional quatro vezes maior que o modelo associado ao CIFAR-10, ou seja:

$$\text{FLOPs}_{\text{GTSRB}} = 4 \cdot \text{FLOPs}_{\text{CIFAR}}. \quad (18)$$

Essa configuração introduz competição assimétrica por recursos, permitindo avaliar como as abordagens lidam com tarefas de diferentes custos computacionais.

5.5. Métricas de Avaliação

A avaliação considera três perspectivas: desempenho dos modelos, *fairness* inter-clientes e intra-cliente.

5.5.1. Desempenho (Acurácia)

Para cada modelo me , a acurácia global é definida como:

$$\text{Acc}^{me} = \sum_{k=1}^K \frac{|D^{k,me}|}{|D^{me}|} \text{acc}_k^{me}. \quad (19)$$

Também reportamos a acurácia média entre modelos:

$$\text{Acc}_{\text{média}} = \frac{1}{ME} \sum_{me=1}^{ME} \text{Acc}^{me}. \quad (20)$$

5.5.2. Fairness

A *fairness* é avaliada pelas métricas propostas *FPC-Inter* e *FPC-Intra* (Seção 4), que medem o alinhamento entre a alocação real de recursos e uma alocação de referência proporcional à contribuição efetiva:

- *FPC-Inter*: proporção de contribuição entre clientes;
- *FPC-Intra*: proporção de contribuição entre modelos dentro de cada cliente.

Valores próximos de 1 indicam maior alinhamento com a proporcionalidade.

Também reportamos a *fairness* média:

$$F_{\text{médio}} = \frac{F_{\text{inter}} + F_{\text{intra}}}{2}. \quad (21)$$

6. Resultados

Nesta seção, são analisados os resultados de acurácia e *fairness* para diferentes níveis de heterogeneidade (α), considerando intervalos de confiança de 95%.

6.1. Acurácia

Na Tabela 2, para $\alpha = 0,1$, todos os métodos apresentam baixa acurácia devido à alta heterogeneidade. Com exceção do *FedBalancer* todas as soluções são estatisticamente similares em termos da acurácia média. Para $\alpha = 1,0$, há melhora geral de acurácia, porém é mantida a forte sobreposição entre os principais métodos, indicando que nenhum método consegue se destacar neste cenário.

6.2. Fairness

Na Tabela 3, para $\alpha = 0,1$, MultiFedAvg e FairHetero apresentam maior *fairness* médio. O FedFairMMFL se destaca em F_{inter} , indicando melhor alinhamento entre a participação e a contribuição de referência dos clientes. Para $\alpha = 1,0$, todos os métodos melhoram em *fairness*. Note que o *MultiFedAvg*, um método que seleciona clientes e modelos com igual probabilidade, tende a ter um bom desempenho em ambos os cenários avaliados.

Algoritmo	Acurácia Média (%)	CIFAR	GTSRB
$\alpha = 0, 1$			
FedFairMMFL	23.76 ± 2.93	20.38 ± 4.26	27.14 ± 4.04
FedBalancer	13.42 ± 3.91	17.13 ± 7.75	9.70 ± 1.07
MultiFedAvg	22.94 ± 5.97	18.27 ± 11.23	27.61 ± 4.07
Oort	25.12 ± 7.18	22.96 ± 12.07	27.28 ± 7.77
FairHetero	26.32 ± 3.84	27.02 ± 3.55	25.62 ± 6.81
$\alpha = 1, 0$			
FedFairMMFL	42.27 ± 3.13	38.47 ± 3.07	46.07 ± 5.46
FedBalancer	24.90 ± 3.70	29.38 ± 3.25	20.41 ± 6.64
MultiFedAvg	43.57 ± 3.38	41.46 ± 4.77	45.68 ± 4.79
Oort	42.45 ± 3.28	40.96 ± 4.92	43.95 ± 4.34
FairHetero	41.84 ± 2.69	39.63 ± 3.54	44.06 ± 4.05

Tabela 2. Comparação de acurácia (%) com IC (95%) e destaque por sobreposição.

O *FedFairMMFL* permanece entre os melhores em F_{inter} , mas com menor F_{intra} , refletindo um trade-off entre proporcionalidade global e balanceamento entre modelos.

Além disso, outro ponto a se notar é que, quando os dados se tornam menos heterogêneos (i.e., quando $\alpha = 1, 0$), apenas F_{inter} melhora, enquanto F_{intra} não sofre variação significativa. Isto ocorre porque a métrica F_{inter} compara clientes, e com α maior, a quantidade de dados que eles possuem se torna mais similar.

6.3. Discussão

Os resultados mostram que diferentes estratégias de seleção induzem comportamentos distintos na alocação de recursos, refletindo diretamente no trade-off entre acurácia e *fairness*. Métodos como Oort, FairHetero e MultiFedAvg alcançam alta acurácia, especialmente em cenários menos heterogêneos ($\alpha = 1, 0$). Por outro lado, métodos como FedBalancer apresentam desempenho inferior, indicando menor capacidade de adaptação à heterogeneidade. De forma geral, observa-se que os métodos analisados conseguem manter desempenho competitivo entre si nos melhores casos, ainda que adotem critérios distintos de seleção de clientes.

Sob a perspectiva de *fairness*, observa-se que MultiFedAvg e FairHetero tendem a apresentar valores maiores tanto em F_{inter} quanto em F_{intra} , caracterizando uma distribuição mais uniforme de participação. Em contraste, Oort e FedFairMMFL apresentam maior alinhamento com F_{inter} em alguns cenários, indicando uma alocação mais próxima da contribuição de referência dos clientes, porém com redução em F_{intra} . Esses resultados evidenciam que diferentes critérios de seleção favorecem distintas noções de *fairness*: enquanto alguns métodos promovem uniformidade, outros se aproximam de uma alocação proporcional à contribuição. No entanto, nenhuma das soluções atuais da literatura se destacam tanto em acurácia quanto em *fairness*, indicando a necessidade de se desenvolver métodos de *fairness* que considerem a heterogeneidades de dados, sistemas

Algoritmo	<i>fairness</i> Médio	F_{inter}	F_{intra}
$\alpha = 0, 1$			
FedFairMMFL	0.49 ± 0.02	0.54 ± 0.03	0.44 ± 0.01
FedBalancer	0.41 ± 0.02	0.42 ± 0.03	0.40 ± 0.01
MultiFedAvg	0.55 ± 0.01	0.55 ± 0.02	0.55 ± 0.01
Oort	0.47 ± 0.02	0.44 ± 0.04	0.49 ± 0.01
FairHetero	0.55 ± 0.02	0.54 ± 0.02	0.56 ± 0.01
$\alpha = 1, 0$			
FedFairMMFL	0.52 ± 0.01	0.64 ± 0.01	0.40 ± 0.01
FedBalancer	0.55 ± 0.01	0.63 ± 0.01	0.47 ± 0.01
MultiFedAvg	0.60 ± 0.01	0.66 ± 0.02	0.54 ± 0.00
Oort	0.54 ± 0.02	0.62 ± 0.03	0.47 ± 0.01
FairHetero	0.59 ± 0.00	0.64 ± 0.01	0.54 ± 0.00

Tabela 3. Comparação de *fairness* com IC (95%) e destaque por sobreposição.

e modelos.

7. Conclusão

Este trabalho analisou o problema de *fairness* em Multi-model Federated Learning (MEFL) sob heterogeneidade de dados e sistemas, adotando uma perspectiva baseada em proporcionalidade de contribuição. Foram utilizadas as métricas FPC-Inter e FPC-Intra para avaliar o alinhamento entre participação observada e contribuição de referência, tanto entre clientes quanto entre modelos dentro de cada cliente. Os resultados mostraram que diferentes estratégias de seleção levam a padrões distintos de contribuição, variando entre distribuições mais uniformes e mais alinhadas à contribuição de referência.

De modo geral, observou-se a que as soluções atuais não se destacaram em termos de *fairness* de proporcionalidade. Além disso, os resultados reforçam que igualdade de participação não é suficiente em cenários heterogêneos, sendo necessário considerar eficiência e disponibilidade de dados. Como trabalho futuro, destaca-se o desenvolvimento de estratégias que incorporem diretamente essas métricas no processo de seleção.

Agradecimentos

Este projeto foi apoiado pelo Ministério da Ciência, Tecnologia e Inovações, com recursos da Lei nº 8.248, de 23 de outubro de 1991, no âmbito do PPI-SOFTEX, coordenado pela Softex e publicado Arquitetura Cognitiva (Fase 3), DOU 01245.003479/2024-10. Os autores agradecem às agências de pesquisa CAPES, CNPq, FAPEMIG e bolsas 15/24494-8 & 18/23064-8, Fundação de Amparo à Pesquisa de São Paulo (FAPESP).

Referências

Bhuyan, N. and Moharir, S. (2022). Multi-model federated learning. In *2022 14th International Conference on COMMunication Systems & NETWORKS (COMSNETS)*, pages 779–783. IEEE.

- Capanema, C., Costa, J., Silva, F., Villas, L., and Loureiro, A. (2024). Treine menos, preveja mais: plugin de aprendizado federado habilita alta eficiência em dados heterogêneos. In *Anais do VIII Workshop de Computação Urbana*, pages 85–98, Porto Alegre, RS, Brasil. SBC.
- Capanema, C. G., de Souza, A. M., Silva, F. A., Villas, L. A., and Loureiro, A. A. (2023). Fedpredict: Combining global and local parameters in the prediction step of federated learning. In *2023 19th International Conference on Distributed Computing in Smart Systems and the Internet of Things (DCOSS-IoT)*, pages 17–24. IEEE.
- Capanema, C. G. S., de Souza, A. M., da Costa, J. B. D., Silva, F. A., Villas, L. A., and Loureiro, A. A. F. (2025a). A novel prediction technique for federated learning. *IEEE Transactions on Emerging Topics in Computing*, 13(1):5–21.
- Capanema, C. G. S., Silva, F. A., Villas, L. A., and Loureiro, A. A. F. (2025b). Data shift under delayed labeling in multi-model federated learning. In *2025 21st International Conference on Distributed Computing in Smart Systems and the Internet of Things (DCOSS-IoT)*, pages 570–577.
- Capanema, C. G. S., Silva, F. A., Villas, L. A., and Loureiro, A. A. F. (2025c). Non-iid-aware multi-model federated learning. In *2025 International Conference on Modeling, Analysis and Simulation of Wireless and Mobile Systems (MSWiM)*, pages 10–14.
- 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.
- Lobato, W., Da Costa, J. B. D., Gonzalez, L. F. G., Cerqueira, E., Rosário, D., Sommer, C., and Villas, L. A. (2024). Entropy and mobility-based model assignment for multi-model vehicular federated learning. In *2024 2nd International Conference on Federated Learning Technologies and Applications (FLTA)*, pages 8–15.
- Mukhtiar, N., Mahmood, A., and Sheng, Q. Z. (2025). Fairness in federated learning: Trends, challenges, and opportunities. *Advanced Intelligent Systems*, 7(6):2400836.
- Shi, Y., Yu, H., and Leung, C. (2023). Towards fairness-aware federated learning. *IEEE Trans. on Neural Netw. and Learning Systems*.
- Shin, J., Li, Y., Liu, Y., and Lee, S.-J. (2022). Fedbalancer: Data and pace control for efficient federated learning on heterogeneous clients. In *Proceedings of the 20th Annual International Conference on Mobile Systems, Applications and Services*, pages 436–449.
- Siew, M., Zhang, H., Park, J.-I., Liu, Y., Ruan, Y., Su, L., Ioannidis, S., Yeh, E., and Joe-Wong, C. (2025). Fair concurrent training of multiple models in federated learning. *IEEE Transactions on Networking*.
- Talukder, Z., Lu, B., Ren, S., and Islam, M. A. (2025). Hardware-sensitive fairness in heterogeneous federated learning. *ACM Transactions on Modeling and Performance Evaluation of Computing Systems*, 10(1):1–31.