

AoI-U: Uma Análise do Trade-off entre Fairness Temporal e Utilidade Estatística na Seleção de Clientes em Aprendizado Federado

Andher P. Capanema Santana¹ e Geraldo P. Rocha Filho²

¹Universidade de Brasília – UnB

²Universidade Estadual do Sudoeste da Bahia – UESB

andher.santana@aluno.unb.br, geraldo.rocha@uesb.edu.br

Abstract. *This work examines how client-selection policies affect federated learning (FL) with non-IID data by analyzing the trade-off between temporal fairness (Age of Information, AoI) and statistical utility (prediction entropy). The proposed AoI-U framework combines both criteria through a parameter α . Experiments on CIFAR-10 show that AoI enforces uniform participation, entropy induces concentration, and the mixed policy balances both effects while keeping competitive accuracy. Final accuracies are similar across methods, but convergence trajectories differ. Results suggest that fairness and utility interact in nontrivial ways and shape FL dynamics.*

Resumo. *O trabalho analisa como políticas de seleção de clientes afetam o aprendizado federado (AF) sob dados não-IID, explorando o trade-off entre fairness temporal (via Age of Information, AoI) e utilidade estatística (via entropia das previsões). Propõe-se o framework AoI-U, que combina ambos os critérios com um parâmetro α . Experimentos com CIFAR-10 mostram que AoI gera participação uniforme, entropia concentra atualizações e o método misto reduz desigualdade mantendo desempenho competitivo. Embora as acurácias finais sejam semelhantes, as trajetórias de convergência diferem. Os resultados indicam que fairness e utilidade interagem de forma não trivial e influenciam a dinâmica do AF.*

1. Introdução

O aprendizado federado (*Federated Learning*, FL) tem sido adotado como alternativa à centralização de dados em cenários nos quais privacidade, custos de comunicação e restrições regulatórias inviabilizam a coleta tradicional. Nesse paradigma, múltiplos clientes treinam modelos localmente e enviam atualizações a um servidor de agregação, que compõe um modelo global sem acesso direto aos dados brutos [McMahan et al. 2017, Cavalcante et al. 2022]. Embora conceitualmente atrativo, o FL enfrenta desafios relevantes de eficiência e arquitetura, especialmente em ambientes com grande número de clientes, conectividade intermitente e distribuições de dados não independentes e identicamente distribuídas (non-IID) [de Oliveira et al. 2023, Li et al. 2023].

Entre os componentes de projeto de um sistema federado, a política de seleção de clientes em cada rodada de treinamento tem efeito direto sobre custo de comunicação, tempo de convergência e comportamento sob heterogeneidade [Uddin et al. 2025]. Em

muitos trabalhos, a escolha de clientes segue estratégias simples, como amostragem aleatória uniforme ou seleção por disponibilidade. Essas políticas ignoram tanto o estado de desatualização dos modelos locais quanto a relevância estatística de cada cliente, o que pode levar, por um lado, à participação repetida de subconjuntos privilegiados e, por outro, à negligência de clientes que permanecem longos períodos sem contribuir, exacerbando desigualdades e variância na atualização global.

Age of Information (AoI) é uma métrica introduzida originalmente em teoria de filas e redes para quantificar o frescor da informação disponível em um ponto de observação. Em termos simples, AoI mede há quanto tempo a última atualização recebida foi gerada [Kaul et al. 2012, Sun et al. 2022]. No contexto de FL, AoI pode ser interpretado como o tempo decorrido desde a última participação de um cliente no treinamento global. Políticas de seleção baseadas em AoI tendem a priorizar clientes esquecidos, aproximando-se de um esquema de *fairness* temporal em que todos participam com frequência semelhante ao longo do tempo.

Este trabalho parte de uma avaliação experimental de uma política de seleção de clientes baseada exclusivamente em AoI, comparada à amostragem aleatória tradicional. Os resultados obtidos indicam que o uso isolado de AoI produz efeitos heterogêneos: em alguns cenários acelera a convergência inicial, em outros degrada o desempenho final ou se mostra indistinguível da seleção aleatória. Em particular, sob non-IID severo, a simples imposição de *fairness* temporal não é suficiente para melhorar a qualidade do modelo global e pode intensificar conflitos entre gradientes locais.

Motivado por essas limitações, o artigo propõe uma família de políticas de seleção que combina AoI com uma medida de utilidade local baseada na entropia das predições do modelo nos dados do cliente. A ideia central é explicitar o trade-off entre *fairness* de participação via AoI e utilidade informacional via entropia, por meio de um parâmetro $\alpha \in [0, 1]$ que pondera a contribuição relativa de cada termo. Quando $\alpha = 1$, recupera-se a política de seleção puramente temporal, quando $\alpha = 0$, a seleção passa a ser guiada apenas pela incerteza local, valores intermediários permitem explorar regimes em que nenhum dos dois critérios domina completamente.

Os objetivos deste trabalho são, portanto, dois:

- caracterizar empiricamente as limitações de uma política de seleção baseada apenas em AoI no FL, e
- investigar, em cenários federados, como a combinação de AoI e entropia influencia eficiência de comunicação, convergência e participação dos clientes, à medida que se varia o peso relativo entre *fairness* temporal e utilidade local. O enfoque é deliberadamente exploratório: o objetivo não é apresentar um algoritmo ótimo, mas analisar de forma sistemática o impacto desse trade-off em distintos regimes de heterogeneidade de dados.

O restante deste artigo está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados e formula o gap de pesquisa. A Seção 3 apresenta a solução proposta para a seleção de clientes, detalhando a formulação do trade-off entre *fairness* temporal e utilidade estatística. A Seção 4 apresenta a configuração experimental e discute os resultados obtidos. Por fim, a Seção 5 apresenta as conclusões e as direções para trabalhos futuros.

2. Trabalhos relacionados

O FL tem sido amplamente estudado sob múltiplas perspectivas, incluindo eficiência de comunicação, robustez a heterogeneidade e formas de seleção de clientes. Revisões abrangentes [Kairouz and McMahan 2021, Li et al. 2023] descrevem que o FedAvg [McMahan et al. 2017] permanece o método dominante, mas sua eficácia depende da adequação entre o escalonamento dos participantes e a heterogeneidade estatística e sistêmica da população. Trabalhos focados em heterogeneidade, como FedProx [Li et al. 2020], mostram que desalinhamentos entre distribuições locais levam a gradientes conflitantes e degradação da convergência, o que motiva políticas de seleção mais informadas.

A literatura recente enfatiza a seleção de clientes como mecanismo central para eficiência e robustez. O *survey* de [Uddin et al. 2025] caracteriza seleção de clientes como um conjunto amplo de estratégias voltadas a mitigar efeitos de clientes lentos, não confiáveis ou maliciosos. As abordagens mapeadas incluem métodos baseados em recursos (poder computacional, banda, volume de dados), mecanismos de reputação e filtragem via similaridade de gradientes, detecção de *outliers*, além de algoritmos de *clustering* e técnicas criptográficas para seleção segura. Embora heterogênea, essa linha de pesquisa destaca uma limitação recorrente: pouca investigação sobre seleção em cenários severamente não-IID e forte dependência de parâmetros sensíveis.

Abordagens específicas incluem FedCS [Nishio and Yonetani 2019], que prioriza clientes com maior disponibilidade de recursos, Power-of-Choice [Cho et al. 2020], que utiliza a perda local como proxy de utilidade, e OORT [Lai et al. 2021], que combina exploração e utilidade esperada. Outras linhas exploram seleção por modelos de reforço [Wang et al. 2020]. Em conjunto, esses métodos assumem que a participação mais adequada depende, de alguma forma, da relevância estatística ou sistêmica de cada cliente.

Paralelamente, há literatura consolidada sobre AoI e staleness em redes distribuídas. Pesquisas fundamentais [Kaul et al. 2012, Sun et al. 2022] tratam AoI como métrica de “atualidade” em transmissões, motivando políticas de escalonamento que priorizam entidades com maior defasagem. Esse princípio é aplicado ao FL em redes móveis, como a proposta de um método de seleção baseado em Age-of-Update (AoU) combinado com condições do canal [Yang et al. 2020]. O método prioriza clientes com atualizações mais antigas, modela o problema como otimização e utiliza um algoritmo guloso para decidir transmissões. Os autores mostram ganhos iniciais de convergência, sugerindo que a diversidade de gradientes induzida pelo *staleness* pode ser útil sob certas condições.

Além disso, o uso de medidas de incerteza para guiar alocação de recursos tem precedentes extensos em active learning. *Surveys* [Settles 2009] e trabalhos posteriores [Beluch et al. 2018] mostram que entropia é um critério amplamente empregado para estimar informatividade de amostras. Em FL, esse raciocínio tem sido adaptado de forma limitada, por exemplo, em métodos que utilizam perda local ou variação de gradientes como proxy de incerteza. Entretanto, estratégias baseadas explicitamente na entropia das predições do modelo local ainda são pouco exploradas como critério de seleção de clientes.

Apesar desse conjunto diversificado de estudos, duas lacunas persistem. Primeiro, políticas baseadas exclusivamente em AoI/AoU [Yang et al. 2020], não consideram a uti-

lidade estatística dos clientes, tratando *staleness* como único fator relevante. Segundo, métodos centrados em utilidade, como OORT ou Power-of-Choice, ignoram fairness temporal e podem gerar repetição excessiva dos mesmos clientes, especialmente em cenários não-IID, agravando o viés de participação. Até onde verificamos, não há trabalhos que investiguem explicitamente o trade-off entre fairness temporal (via AoI) e utilidade estatística (via entropia) na seleção de clientes. Essa lacuna motiva a análise do presente estudo, que busca entender empiricamente a interação entre esses dois critérios e seus efeitos sob diferentes formas de heterogeneidade.

3. Solução Proposta

Esta seção apresenta a solução proposta para investigar o impacto conjunto de fairness temporal e utilidade estatística no processo de seleção de clientes em aprendizado federado. Diferentemente de abordagens que buscam diretamente maximizar desempenho, o objetivo aqui é estabelecer uma formulação unificada que permita analisar, de forma sistemática, como diferentes critérios de seleção influenciam a dinâmica de treinamento do FedAvg em cenários com dados não independentes e identicamente distribuídos (non-IID).

A motivação central parte da observação de que políticas de seleção de clientes frequentemente privilegiam apenas um dos dois aspectos relevantes do problema. Estratégias baseadas em amostragem aleatória podem favorecer subconjuntos específicos de clientes ao longo do tempo, enquanto políticas determinísticas focadas exclusivamente em fairness temporal, como aquelas baseadas em Age of Information, promovem participação uniforme, mas ignoram a relevância estatística das atualizações locais. Por outro lado, políticas orientadas apenas por medidas de utilidade tendem a concentrar a seleção em clientes considerados mais informativos, reduzindo a diversidade temporal de participação.

Em cenários federados com heterogeneidade estatística, esses critérios não são naturalmente alinhados. A imposição de equidade temporal pode tanto auxiliar quanto prejudicar a convergência, dependendo da distribuição local de dados, enquanto a maximização de utilidade pode amplificar assimetrias de participação sem ganhos claros de desempenho. Assim, fairness temporal e utilidade estatística configuram objetivos potencialmente conflitantes, e compreender empiricamente sua interação é fundamental para avaliar políticas de seleção de clientes mais gerais.

A solução proposta neste trabalho organiza essa interação por meio de um framework parametrizado, denominado AoI-Utilidade (AoI-U), que integra explicitamente ambos os critérios em uma única política de seleção. Em vez de assumir que um dos aspectos deve dominar o processo, o framework permite explorar um espaço contínuo de políticas, no qual o peso relativo entre fairness temporal e utilidade estatística pode ser controlado de forma direta. Essa formulação serve como base para a análise experimental apresentada posteriormente, possibilitando comparar regimes extremos e intermediários sob uma mesma estrutura conceitual.

3.1. Visão Geral da Solução

A solução proposta parte da ideia de que a seleção de clientes em aprendizado federado pode ser formulada como um problema de balanceamento entre dois critérios distintos: o tempo decorrido desde a última participação de cada cliente no treinamento global e o

potencial informativo de seus dados locais para o estado atual do modelo. Em cenários non-IID, esses critérios não são necessariamente convergentes. Priorizar clientes há muito tempo não selecionados pode aumentar a diversidade temporal de participação, mas não garante que suas atualizações sejam estatisticamente úteis para o modelo global naquele momento. Em sentido oposto, priorizar apenas clientes mais informativos pode concentrar excessivamente a participação em um subconjunto reduzido de clientes. O framework AoI-U foi definido para tornar explícito esse trade-off e permitir sua análise empírica sob uma formulação única.

O primeiro componente do framework corresponde à *fairness* temporal e é modelado por meio da AoI. Para cada cliente i na rodada t , a AoI representa o tempo transcorrido desde sua última participação na atualização do modelo global. No contexto síncrono adotado neste trabalho, essa grandeza é operacionalmente equivalente ao número de rodadas desde a última seleção do cliente, de modo que valores mais altos indicam maior defasagem temporal. Intuitivamente, uma política que favorece clientes com maior AoI tende a reduzir negligência sistemática e a distribuir a participação de forma mais uniforme ao longo do treinamento.

O segundo componente busca capturar a utilidade estatística local. Para isso, utiliza-se a entropia média das previsões produzidas pelo modelo global corrente sobre um subconjunto dos dados do cliente. A entropia é empregada como medida de incerteza: quanto maior a incerteza do modelo sobre as amostras locais, maior o potencial de que aquele cliente forneça atualizações relevantes para o processo de aprendizado. Em cada rodada, essa utilidade é estimada a partir de até 100 amostras do conjunto local de cada cliente. Quando o cliente possui menos de 100 amostras, utiliza-se todo o conjunto disponível. A entropia é calculada para cada amostra individualmente e, em seguida, agregada por média, resultando em um valor que representa a utilidade estatística do cliente na rodada considerada.

Como a utilidade só pode ser atualizada diretamente quando o cliente é observado, cada cliente mantém uma estimativa corrente desse valor ao longo do treinamento. Para clientes ainda não selecionados, adota-se uma inicialização fixa, correspondente à entropia esperada de um modelo inicial aleatório no CIFAR-10. Essa escolha evita introduzir assimetrias artificiais nas rodadas iniciais devido à ausência de histórico de participação.

Para que os dois critérios possam ser combinados posteriormente em uma única política de seleção, tanto a AoI quanto a utilidade estatística são normalizadas a cada rodada por transformação min-max, produzindo valores relativos no intervalo $[0, 1]$. Denotando por $\tilde{a}_i^{(t)}$ a AoI normalizada do cliente i na rodada t e por $\tilde{u}_i^{(t)}$ sua utilidade estatística normalizada, obtém-se duas quantidades diretamente comparáveis, cada uma capturando uma dimensão distinta do problema: a posição temporal relativa do cliente no histórico de participação e o grau de incerteza que seus dados induzem no modelo global.

Essa formulação não pressupõe que *fairness* temporal ou utilidade estatística devam dominar o processo de seleção. Ao contrário, ela estabelece a base conceitual do framework AoI-U como um mecanismo parametrizável, no qual ambas as dimensões podem ser integradas de forma explícita. A subseção seguinte define a política de seleção propriamente dita, mostrando como $\tilde{a}_i^{(t)}$ e $\tilde{u}_i^{(t)}$ são combinadas em um *score* único para selecionar os clientes em cada rodada.

3.2. Política de Seleção AoI-U

Com as métricas de fairness temporal e utilidade estatística definidas de forma independente e normalizadas na mesma escala, a política de seleção de clientes é construída a partir da combinação explícita desses dois critérios. A ideia central é atribuir, a cada cliente, um score que reflita simultaneamente sua defasagem temporal no processo federado e o potencial informativo de seus dados locais em relação ao estado atual do modelo global.

Formalmente, para cada cliente i na rodada t , define-se um score composto como uma combinação linear entre a Age of Information normalizada e a utilidade estatística normalizada:

$$s_i^{(t)} = \alpha \cdot \tilde{a}_i^{(t)} + (1 - \alpha) \cdot \tilde{u}_i^{(t)} \quad (1)$$

em que $\tilde{a}_i^{(t)}$ representa a AoI normalizada do cliente, $\tilde{u}_i^{(t)}$ sua utilidade estatística normalizada e $\alpha \in [0, 1]$ é um parâmetro escalar que controla o peso relativo entre fairness temporal e utilidade estatística.

O parâmetro α desempenha papel central no framework AoI-Utilidade, pois governa explicitamente o regime de seleção adotado. Quando $\alpha = 1, 0$, a política de seleção passa a depender exclusivamente da AoI, privilegiando clientes que estão há mais tempo sem participar do treinamento, o que resulta em um comportamento orientado à equidade temporal. No extremo oposto, quando $\alpha = 0$, a seleção é guiada apenas pela utilidade estatística, favorecendo clientes cujos dados produzem maior incerteza no modelo global, independentemente de sua frequência de participação anterior. Valores intermediários de α definem regimes híbridos, nos quais nenhum dos dois critérios domina completamente o processo de decisão.

Essa formulação induz um espaço contínuo de políticas de seleção de clientes, no qual fairness temporal e utilidade estatística não são tratados como objetivos excludentes, mas como dimensões ajustáveis de um mesmo mecanismo. Em vez de assumir a existência de uma política ótima universal, o framework permite explorar empiricamente como diferentes valores de α alteram padrões de participação dos clientes, diversidade temporal de atualizações e a dinâmica de convergência do aprendizado federado em cenários com heterogeneidade estatística.

Em cada rodada de treinamento, os clientes são ordenados conforme o score composto, e um subconjunto fixo dos clientes com maior pontuação é selecionado para realizar o treinamento local. Em situações de empate, a seleção é resolvida por sorteio, preservando um grau mínimo de aleatoriedade no processo. Essa política de seleção é aplicada de forma consistente ao longo de todo o treinamento, mantendo inalterados os demais componentes do protocolo federado.

Ao formular a seleção de clientes dessa maneira, o framework AoI-Utilidade explicita o trade-off entre diversidade temporal e exploração informacional como um parâmetro controlável do sistema. Essa característica permite analisar, de forma sistemática, como diferentes regimes de seleção influenciam tanto a distribuição de participação quanto o comportamento do modelo global ao longo das rodadas de treinamento, servindo de base para os experimentos comparativos apresentados nas seções

seguintes.

Para explicitar o funcionamento operacional da política de seleção proposta, o Algoritmo 1 descreve o ciclo de seleção e treinamento do método AoI-Utilidade integrado ao FedAvg. Como a utilidade estatística depende exclusivamente dos dados locais, cada cliente mantém uma estimativa corrente desse valor, que é atualizada apenas quando o cliente é selecionado. Para clientes ainda não observados, adota-se um valor inicial fixo $u_i^{(0)}$, correspondente à entropia esperada no início do treinamento.

Algoritmo 1: FedAvg com Seleção de Clientes AoI-Utilidade (AoI-U)

Input: $K, C, T, E, B, \eta, \alpha, S, u_0$
Output: Modelo global $w^{(T)}$

- 1 Inicializar $w^{(0)}$;
- 2 $m \leftarrow \max(C \cdot K, 1)$;
- 3 **for** $i \leftarrow 1$ **to** K **do**
- 4 $\tau_i^{(0)} \leftarrow 0$; $u_i^{(0)} \leftarrow u_0$;
- 5 **end**
- 6 **for** $t \leftarrow 1$ **to** T **do**
- 7 **for** $i \leftarrow 1$ **to** K **do**
- 8 $a_i^{(t)} \leftarrow t - \tau_i^{(t-1)}$;
- 9 **end**
- 10 $\tilde{a}_1^{(t)}, \dots, \tilde{a}_K^{(t)} \leftarrow \text{MinMaxNorm}(a_1^{(t)}, \dots, a_K^{(t)})$;
- 11 $\tilde{u}_1^{(t)}, \dots, \tilde{u}_K^{(t)} \leftarrow \text{MinMaxNorm}(u_1^{(t-1)}, \dots, u_K^{(t-1)})$;
- 12 **for** $i \leftarrow 1$ **to** K **do**
- 13 $s_i^{(t)} \leftarrow \alpha \tilde{a}_i^{(t)} + (1 - \alpha) \tilde{u}_i^{(t)}$;
- 14 **end**
- 15 $S_t \leftarrow$ Top- m clientes segundo s_k (empates por sorteio);
- 16 **foreach** $i \in S_t$ **em paralelo do**
- 17 $u_i^{(t)} \leftarrow \text{ClientUtilityProbe}(i, w^{(t-1)}, S)$;
- 18 $w_i^{(t)} \leftarrow \text{ClientUpdate}(i, w^{(t-1)}, E, B, \eta)$;
- 19 $n_i \leftarrow$ número de exemplos de treino local do cliente i ;
- 20 **end**
- 21 $w^{(t)} \leftarrow \sum_{i \in S_t} \frac{n_i}{\sum_{j \in S_t} n_j} w_i^{(t)}$;
- 22 **foreach** $i \in S_t$ **do**
- 23 $\tau_i^{(t)} \leftarrow t$;
- 24 **end**
- 25 **end**
- 26 **return** $w^{(T)}$;

A cada rodada, a AoI e a utilidade estatística são calculadas e normalizadas por transformação min-max, produzindo valores comparáveis. Em seguida, ambas são combinadas em um score $s_i^{(t)}$, que define a prioridade de seleção dos clientes. Os m clientes com maior pontuação são então escolhidos para treinamento local, mantendo-se um critério de desempate aleatório. Após o treinamento, as atualizações locais são agregadas via média

ponderada, conforme o protocolo FedAvg, e os estados internos dos clientes selecionados são atualizados para a rodada corrente.

3.3. Integração com o Aprendizado Federado

A política AoI-Utilidade é integrada ao aprendizado federado sem modificar o restante do protocolo. O treinamento segue o ciclo padrão do FedAvg, no qual um servidor coordena rodadas síncronas de comunicação: a cada rodada, um subconjunto de clientes é selecionado, realiza treinamento local a partir do modelo global corrente e envia sua atualização ao servidor, que então agrega os modelos locais para produzir um novo modelo global.

Dentro desse ciclo, a única alteração introduzida pelo AoI-U está no mecanismo de seleção de clientes. Em vez de selecionar clientes por amostragem uniforme, cada cliente recebe um score, conforme Equação (1), e a seleção em cada rodada passa a priorizar os clientes com maior pontuação. O restante permanece idêntico entre as políticas comparadas, incluindo:

- o procedimento de treinamento local (mesmo número de épocas e hiperparâmetros), e
- o esquema de agregação do FedAvg, em que os modelos locais são combinados por média ponderada pelo número de exemplos de treino local, produzindo o modelo global atualizado ao final de cada rodada.

Essa integração “modular” é importante porque garante que quaisquer diferenças observadas na dinâmica de convergência ou na distribuição de participações ao longo do tempo possam ser atribuídas diretamente à política de seleção de clientes, e não a mudanças concomitantes no otimizador, no modelo ou na agregação.

3.4. Configuração Experimental

A avaliação é conduzida em um ambiente federado simulado com o framework *Flower* [Beutel et al. 2020], executado localmente. O conjunto de dados utilizado é o CIFAR-10, com 50.000 amostras de treino e 10.000 de teste, distribuídas em 10 classes balanceadas. Foi empregado um particionamento non-IID do tipo Dirichlet por classe, com parâmetro de concentração 0,5, produzindo distribuições locais desbalanceadas e heterogêneas. Em cada cliente, o conjunto local é subdividido em 500 amostras para treino e 100 amostras para teste local.

O modelo é uma CNN pequena inspirada na arquitetura utilizada no trabalho que propôs o FedAvg [McMahan et al. 2017] (baseada no tutorial do TensorFlow), composta por: duas camadas convolucionais ($3 \rightarrow 64$ filtros e $64 \rightarrow 64$ filtros, kernel 5×5), cada uma seguida de max pooling (kernel 3×3 , stride 2), duas camadas totalmente conectadas ($64 \cdot 4 \cdot 4 \rightarrow 384$ e $384 \rightarrow 192$) e uma camada final linear ($192 \rightarrow 10$) gerando *logits*. O *softmax* é aplicado apenas para calcular as probabilidades necessárias ao cálculo da entropia.

Para reprodutibilidade, o particionamento entre clientes e a divisão para testes utilizam *seed* fixa (42). O objetivo do experimento não é otimização absoluta de desempenho, mas a comparação controlada entre políticas de seleção, mantendo constantes as demais escolhas do protocolo. Na Tabela 1, estão listados os outros parâmetros relacionados ao treinamento federado.

Tabela 1. Hiperparâmetros operacionais

Parâmetro	Descrição	Valor
K	Número de clientes	100
C	Fração de clientes selecionados por rodada	0,1 (10 clientes/rodada)
T	Número de rodadas globais	100
E	Épocas locais por rodada	5
μ	Learning rate	0,01
B	Batch size local	50
$ D'_i $	Máximo de amostras locais usadas para entropia	100

Nesta configuração, as políticas comparadas diferem apenas na forma como escolhem o subconjunto de clientes por rodada (aleatória, AoI, entropia ou AoI-U), enquanto o restante do pipeline federado (treinamento local e agregação FedAvg) permanece invariável. Além disso, as métricas observadas incluem a acurácia global no conjunto de teste por rodada, a acurácia final após 100 rodadas e a distribuição de participação dos clientes ao longo do treinamento, como indicador indireto de *fairness*. Por limitações de tempo computacional, cada configuração foi executada apenas duas vezes, caracterizando a análise como descritiva e exploratória.

4. Resultados

Os resultados apresentados nesta seção sintetizam o comportamento das quatro políticas de seleção avaliadas, seleção aleatória, entropia pura ($\alpha = 0$), método misto ($\alpha = 0,5$) e AoI ($\alpha = 1$), considerando duas execuções independentes por cenário. As métricas analisadas refletem tanto o desempenho global do modelo quanto a distribuição de participações entre os clientes ao longo das 100 rodadas de treinamento. As diferenças observadas entre os cenários resultam exclusivamente da política de seleção, uma vez que os demais elementos do protocolo experimental foram mantidos fixos.

A análise da acurácia avaliada por rodada, representada na Figura 1 na forma de curvas monotônicas, indica que os quatro métodos convergem para valores finais semelhantes, em torno de 0,66. Apesar da proximidade no valor final, as trajetórias até esse patamar apresentam diferenças. A política AoI ($\alpha = 1$) produz a maior quantidade de rodadas em que a curva monotônica é dominante entre os métodos avaliados, sugerindo que, ao longo de grande parte do treinamento, ela alcançou o melhor desempenho observado até aquele ponto. Já o método misto ($\alpha = 0,5$) apresenta o maior valor final entre os cenários testados, embora com uma trajetória menos dominante nas fases iniciais. A seleção aleatória apresenta desempenho intermediário ao longo de toda a trajetória, enquanto a entropia pura ($\alpha = 0$) mantém desempenho estável, porém lidera raramente o envelope monotônico.

A Tabela 2 complementa essa análise ao comparar o número de rodadas necessárias para atingir determinados limiares de acurácia. Os resultados mostram diferenças pequenas para o limiar de 0,60, onde os métodos tendem a se aproximar em velocidade de convergência. Entretanto, à medida que o limiar se torna mais exigente, a separação entre os métodos se torna mais evidente. O limiar de 0,65, por exemplo, é atingido primeiro pela política AoI, enquanto o método misto atinge valores elevados na

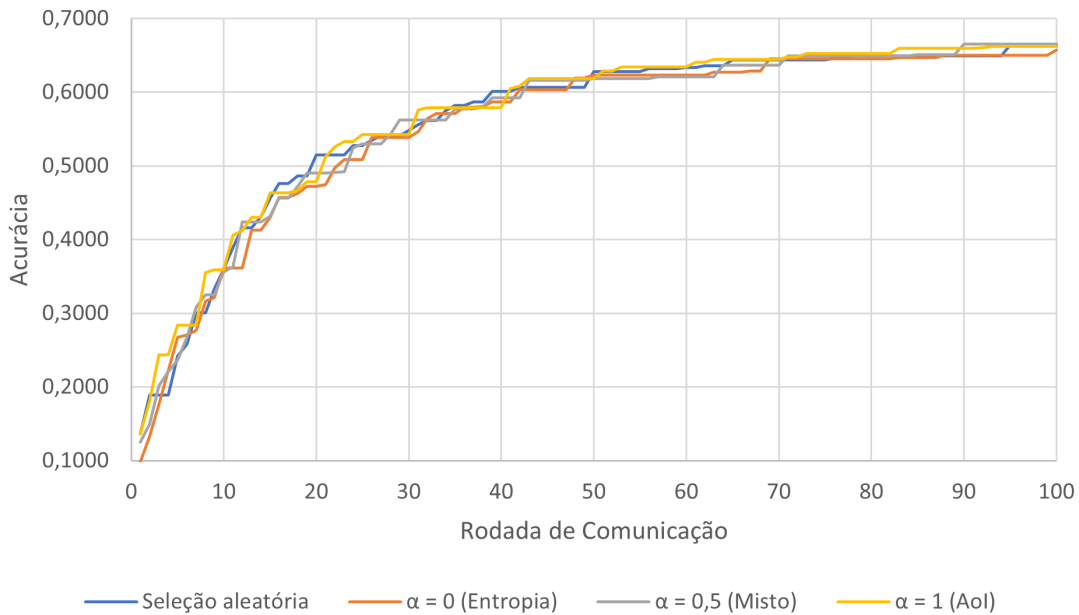


Figura 1. Curva monotônica de acurácia por rodada.

região final de treinamento, produzindo o melhor patamar assintótico. Esses dados sugerem que os diferentes métodos modulam de maneira distinta a relação entre estabilização da acurácia e exploração de clientes ao longo do processo federado.

Tabela 2. Número de rodadas necessárias para atingir limiares de acurácia.

Método	60%	65%
Seleção aleatória	39 (–)	95 (–)
$\alpha = 0$ (Entropia)	42 (0,93 \times)	88 (1,08 \times)
$\alpha = 0,5$ (Misto)	43 (0,91 \times)	85 (1,12 \times)
$\alpha = 1$ (AoI)	41 (0,95 \times)	73 (1,3 \times)

A distribuição de participações por cliente, apresentada na Figura 2 e quantificada na Tabela 3, revela diferenças estruturais mais marcantes entre as políticas. A política AoI resulta em distribuição perfeitamente uniforme: todos os 100 clientes participam exatamente de 10 rodadas, o que produz coeficiente de Gini zero e amplitude nula. O método misto ($\alpha = 0,5$) mantém uma desigualdade reduzida, com a maioria dos clientes participando entre 9 e 12 vezes e apresentando Gini de 0,0874. A seleção aleatória exibe desigualdade moderada, consequência direta da variabilidade estocástica inerente a esse método, seu coeficiente de Gini é 0,1561, com amplitude de 16. A entropia pura ($\alpha = 0$) produz a maior desigualdade entre todos os cenários: Gini de 0,2339 e amplitude de 21,5, incluindo casos extremos de clientes com até 28 participações. Esses padrões empíricos confirmam que o uso exclusivo da utilidade tende a concentrar atualizações em um subconjunto reduzido de clientes, enquanto o uso exclusivo da idade força a participação uniforme, e o método misto amortiza ambos os efeitos.

A comparação integrada entre desempenho e equidade sugere que os métodos

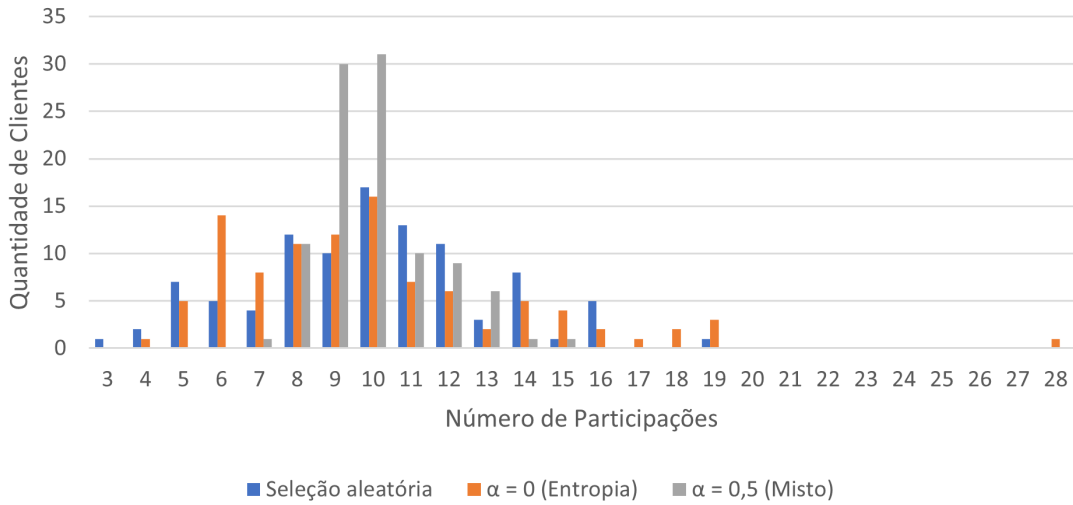


Figura 2. Número de clientes selecionados certo número de vezes ao longo de todo o treinamento. O teste com ($\alpha = 1$) (exclusivamente AoI) não aparece, pois todos os 100 clientes foram selecionados 10 vezes.

Tabela 3. Medidas de dispersão do número de participações por cliente para diferentes políticas de seleção.

Tipo de Seleção	Coeficiente de Gini	Seleção por cliente		
		Mínimo	Máximo	Amplitude
Seleção aleatória	0,1561	2,5	18,5	16,0
$\alpha = 0$ (Entropia)	0,2339	4,0	25,5	21,5
$\alpha = 0,5$ (Misto)	0,0874	7,0	15,5	8,5
$\alpha = 1$ (AoI)	0	10,0	10,0	0,0

operam em regimes distintos do ponto de vista do trade-off fairness-utilidade. A entropia pura prioriza consistentemente clientes considerados mais “incertos”, o que produz forte assimetria na participação, sem oferecer vantagens claras de desempenho em relação ao aleatório. O método AoI, por outro lado, garante equidade perfeita e apresenta trajetória monotônica dominante por longos intervalos do treinamento, mas não obtém o maior valor assintótico. O método misto ($\alpha = 0,5$) ocupa uma posição intermediária, reduzindo substancialmente o desequilíbrio observado no cenário baseado exclusivamente em utilidade, ao mesmo tempo, em que alcança o maior valor final da acurácia entre os métodos testados. Esses resultados ilustram empiricamente que o parâmetro α controla efetivamente o equilíbrio entre diversidade temporal dos clientes selecionados e exploração de clientes considerados mais informativos, produzindo comportamentos diferenciados tanto na dinâmica de convergência quanto na distribuição das participações.

Por fim, é importante reconhecer limitações inerentes ao estudo. Os experimentos foram conduzidos com dois *runs* por cenário, o que não captura completamente a variabilidade estocástica do processo. O *dataset* utilizado representa apenas um tipo de não-IID. Ademais, apenas uma forma de utilidade (entropia do modelo global avaliada sobre subconjuntos locais) e uma forma de AoI foram consideradas. Apesar dessas limitações,

os resultados mostram que diferentes políticas de seleção induzem regimes distintos de participação e apresentam efeitos diferenciados na trajetória de convergência, reforçando a relevância empírica do trade-off entre fairness temporal e utilidade estatística no aprendizado federado.

5. Conclusão

Este trabalho investigou empiricamente o impacto de diferentes políticas de seleção de clientes no aprendizado federado, com ênfase no trade-off entre fairness temporal e utilidade estatística. Para isso, foi proposto o framework AoI-U, que combina idade da informação e uma métrica de utilidade local baseada na entropia do modelo global, parametrizado por um peso α que controla a influência relativa desses componentes. A formulação unificada permitiu analisar, em um mesmo espaço de políticas, comportamentos extremos, equidade perfeita ($\alpha = 1$) e priorização exclusiva de utilidade ($\alpha = 0$), bem como regimes intermediários.

Os resultados mostraram que as políticas geram distribuições de participação estruturalmente distintas. A política AoI produziu equilíbrio perfeito na participação dos clientes, enquanto a utilidade pura levou à concentração extrema de atualizações em um subconjunto reduzido. O método misto reduziu substancialmente essa desigualdade, aproximando-se da equidade do AoI sem a eliminar completamente. Esses padrões de participação influenciaram a dinâmica de convergência: embora todos os métodos tenham alcançado acurácias finais semelhantes, observaram-se diferenças na velocidade com que determinados patamares foram atingidos e no comportamento monotônico ao longo do treinamento. O método misto obteve o melhor valor final em termos de acurácia, enquanto a política AoI apresentou domínio temporal em boa parte da trajetória. A entropia pura, apesar de favorecer clientes considerados mais informativos, não apresentou ganhos concretos em relação aos demais cenários.

Os experimentos foram conduzidos com um único *dataset* não-IID, um modelo relativamente simples e duas execuções por cenário, de modo que as conclusões devem ser interpretadas como indicativas e não definitivas. Ainda assim, os resultados revelam que a escolha da política de seleção tem efeitos mensuráveis tanto sobre a distribuição de contribuições quanto sobre a trajetória de convergência do modelo, e que o parâmetro α atua como mecanismo explícito de controle sobre esse equilíbrio. Em vez de apontar um valor ótimo de α , os achados sugerem que diferentes regimes de *fairness* e utilidade induzem propriedades distintas no treinamento federado, e que essas propriedades podem ser relevantes dependendo dos objetivos do sistema.

Trabalhos futuros podem ampliar a análise considerando mais métricas de utilidade, diferentes definições de idade, modelos maiores, cenários com heterogeneidades mais severas ou métricas de custo adicionais, como latência e energia. Investigações que explorem o comportamento do AoI-U em *tasks* multimodais, em redes móveis reais ou em sistemas com disponibilidade variável também podem aprofundar a compreensão de como fairness temporal e utilidade estatística interagem no aprendizado federado.

Referências

Beluch, W. H., Genewein, T., Nurnberger, A., and Kohler, J. M. (2018). The power of ensembles for active learning in image classification. In *2018 IEEE/CVF Conference*

- on *Computer Vision and Pattern Recognition*, pages 9368–9377.
- Beutel, D. J., Topal, T., Mathur, A., Qiu, X., Fernandez-Marques, J., Gao, Y., Sani, L., Li, K. H., Parcollet, T., De Gusmão, P. P. B., et al. (2020). Flower: A friendly federated learning research framework. *arXiv preprint arXiv:2007.14390*.
- Cavalcante, I. C., Meneguette, R. I., Torres, R. H., Mano, L. Y., Gonçalves, V. P., Ueyama, J., Pessin, G., Amvame Nze, G. D., and Rocha Filho, G. P. (2022). Federated system for transport mode detection. *Energies*, 15(23):9256.
- Cho, Y. J., Wang, J., and Joshi, G. (2020). Client selection in federated learning: Convergence analysis and power-of-choice selection strategies. *arXiv preprint arXiv:2010.01243*.
- de Oliveira, J. A., Gonçalves, V. P., Meneguette, R. I., de Sousa Jr, R. T., Guidoni, D. L., Oliveira, J. C., and Rocha Filho, G. P. (2023). F-nids—a network intrusion detection system based on federated learning. *Computer Networks*, 236:110010.
- Kairouz, P. and McMahan, H. B. (2021). Advances and open problems in federated learning. *Foundations and Trends in Machine Learning*, 14(1-2):1–210.
- Kaul, S., Yates, R., and Gruteser, M. (2012). Real-time status: How often should one update? In *2012 Proceedings IEEE INFOCOM*, pages 2731–2735.
- 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.
- Li, Q., Wen, Z., Wu, Z., Hu, S., Wang, N., Li, Y., Liu, X., and He, B. (2023). A survey on federated learning systems: Vision, hype and reality for data privacy and protection. *IEEE Transactions on Knowledge and Data Engineering*, 35(4):3347–3366.
- Li, T., Sahu, A. K., Zaheer, M., Sanjabi, M., Talwalkar, A., and Smith, V. (2020). Federated optimization in heterogeneous networks. *Proceedings of Machine learning and systems*, 2:429–450.
- McMahan, B., Moore, E., Ramage, D., Hampson, S., and y Arcas, B. A. (2017). Communication-efficient learning of deep networks from decentralized data. In *Artificial intelligence and statistics*, pages 1273–1282. PMLR.
- Nishio, T. and Yonetani, R. (2019). Client selection for federated learning with heterogeneous resources in mobile edge. In *ICC 2019-2019 IEEE international conference on communications (ICC)*, pages 1–7. IEEE.
- Settles, B. (2009). Active learning literature survey. Technical report, University of Wisconsin–Madison.
- Sun, Y., Kadota, I., Talak, R., and Modiano, E. (2022). *Age of information: A new metric for information freshness*. Springer Nature.
- Uddin, M. P., Xiang, Y., Hasan, M., Bai, J., Zhao, Y., and Gao, L. (2025). A systematic literature review of robust federated learning: Issues, solutions, and future research directions. *ACM Comput. Surv.*, 57(10).

- Wang, H., Kaplan, Z., Niu, D., and Li, B. (2020). Optimizing federated learning on non-iid data with reinforcement learning. In *IEEE INFOCOM 2020 - IEEE Conference on Computer Communications*, pages 1698–1707.
- Yang, H. H., Arafa, A., Quek, T. Q. S., and Vincent Poor, H. (2020). Age-based scheduling policy for federated learning in mobile edge networks. In *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 8743–8747.