



# QFL-Adaptive: Uma Abordagem Híbrida de Aprendizado Federado Quântico Personalizado e Resiliente

Rómulo W. C. Bustincio<sup>1</sup>, Edgar C. Pozo<sup>2</sup>, Ricardo J. Hanco-Ancori<sup>3</sup>,  
Francisco Airton Silva<sup>4</sup>, Allan M. de Souza<sup>1</sup>, Luiz F. Bittencourt<sup>1</sup>

<sup>1</sup> Instituto de Computação, Universidade Estadual de Campinas, Brasil

<sup>2</sup> Departamento de Física, Universidad de Guanajuato, México

<sup>3</sup> Universidad Nacional de San Agustín de Arequipa, Perú

<sup>4</sup> Universidade Federal do Piauí, Picos-PI, Brasil

{romulo.bustincio, allanms, bit}@ic.unicamp.br

e.condori@ugto.mx, rhancohan@unsa.edu.pe, faps@ufpi.edu.br

**Abstract.** *Quantum Federated Learning (QFL) emerges as a paradigm for distributed training with privacy preservation. However, its practical implementation in the Noisy Intermediate-Scale Quantum (NISQ) era faces critical barriers: communication overhead and model drift caused by Non-Independent and Identically Distributed (Non-IID) data. This work proposes QFL-Adaptive, a framework that integrates a slimmable VQC-inspired architecture with personalized aggregation via Weighted Personalized QFL (wp-QFL). The architecture follows a Variational Quantum Circuit (VQC)-inspired pole-angle segmentation into Angle ( $\phi$ ) and Pole ( $\theta$ ) parameters, allowing for dynamic adjustment of the transmission load through conditional uplink based on channel telemetry. Results across four datasets show 77.81% bandwidth saving and over 97.9% accuracy retention under 80% communication failure. Real hardware validation remains essential to confirm efficacy against systemic decoherence.*

**Resumo.** *O Aprendizado Federado Quântico (QFL) surge como um paradigma para o treinamento distribuído com preservação de privacidade. No entanto, sua implementação prática na era Noisy Intermediate-Scale Quantum (NISQ) enfrenta barreiras críticas: a sobrecarga de comunicação e a deriva do modelo causada por dados Non-Independent and Identically Distributed (Non-IID). Este trabalho propõe o QFL-Adaptive, um framework que integra uma arquitetura segmentada inspirada em VQC com agregação personalizada via Weighted Personalized QFL (wp-QFL). A arquitetura segue uma segmentação pole-angle inspirada em Circuitos Quânticos Variacionais (VQC), separando parâmetros de Ângulo ( $\phi$ ) e Polo ( $\theta$ ), permitindo o ajuste dinâmico da carga de transmissão via uplink condicional baseado na telemetria do canal. Resultados em quatro datasets demonstram economia de banda de 77,81% e retenção de acurácia superior a 97,9% sob 80% de falha comunicacional. Validações em hardware quântico real são fundamentais para confirmar a eficácia sob ruído de decoerência.*

## 1. Introdução

O Aprendizado Federado (FL) consolidou-se como a abordagem padrão para o treinamento colaborativo de modelos de inteligência artificial, permitindo que múltiplos clientes treinem modelos locais sem a necessidade de centralizar dados sensíveis [McMahan et al. 2017, Nguyen et al. 2025]. No entanto, à medida que a complexidade dos padrões aumenta, os modelos clássicos de aprendizado profundo enfrentam limitações intrínsecas de custo computacional ao processar dados de altíssima dimensão [Thompson et al. 2020, Havlíček et al. 2019].

Neste cenário, a convergência entre Computação Quântica (QC) e Aprendizado Federado (FL), conhecida como Aprendizado Federado Quântico (QFL), tem sido investigada como uma alternativa para inteligência artificial distribuída ao explorar espaços de Hilbert de alta dimensão com preservação de privacidade [Ballester et al. 2025, Nguyen et al. 2025]. Fundamentalmente, este espaço vetorial permite mapear dados para dimensões exponencialmente superiores, onde o emaranhamento quântico captura correlações não-lineares complexas que seriam computacionalmente intratáveis para modelos clássicos [Cerezo et al. 2022, Chehimi and Saad 2022].

No entanto, a implementação prática de QFL em redes distribuídas reais colide com barreiras físicas e estatísticas severas impostas pela era NISQ. Primeiramente, a escassez de qubits e o ruído intrínseco associado às portas quânticas limitam a profundidade dos circuitos variacionais; circuitos muito profundos sofrem de decoerência e do problema dos *Barren Plateaus*, tornando o treinamento ineficaz [Preskill 2018, Cerezo et al. 2022]. Em segundo lugar, a instabilidade dos canais de comunicação é crítica: em redes quânticas, a latência de transmissão causa a degradação dos estados emaranhados, enquanto em redes clássicas, a flutuação de banda leva ao descarte de atualizações vitais (*dropout*) [Chehimi et al. 2024, Park et al. 2025]. Por fim, a heterogeneidade estatística dos dados (Non-IID) entre clientes provoca a *deriva do modelo* (*client drift*), onde a otimização local diverge do objetivo global, dificultando a convergência do algoritmo federado [Gurung and Pokhrel 2025, Zhao 2023].

Trabalhos recentes tentaram mitigar esses problemas isoladamente. O *Slimmable QFL* (SlimQFL) [Park et al. 2025] propôs ajustar a largura das redes neurais quânticas para se adaptar a canais instáveis. Paralelamente, abordagens de personalização como o *wp-QFL* [Gurung and Pokhrel 2025] focaram em combater a deriva do modelo (model drift) causada por dados não independentes e identicamente distribuídos (Non-IID). Contudo, falta uma arquitetura unificada que trate simultaneamente da eficiência de comunicação e da personalização do modelo sob restrições de hardware quântico. Neste trabalho, propomos o QFL-Adaptive, um framework resiliente que integra a adaptação dinâmica de modelos quânticos com agregação personalizada. A arquitetura utiliza uma lógica de decisão baseada na qualidade do canal para mitigar o impacto de falhas de transmissão e instabilidade de rede. Em condições de conectividade degradada, o sistema comuta para um modo de operação reduzido, transmitindo apenas parâmetros essenciais para evitar o descarte das atualizações locais. Esta abordagem busca equilibrar a economia de recursos de comunicação com a convergência do modelo em cenários NISQ.

O restante deste trabalho está organizado da seguinte forma: a Seção 2 aborda os trabalhos relacionados, focando nos limites do aprendizado profundo e em espaços de características quânticos. A Seção 3 apresenta a fundamentação teórica necessária. A

Seção 4 detalha a proposta desenvolvida. A Seção 5 analisa os resultados obtidos e a Seção 6 apresenta as conclusões finais.

## 2. Trabalhos Relacionados

O QFL não constitui um mero amálgama de tecnologias, mas a resposta necessária da razão perante o limite onde a computação clássica perde a sua capacidade de representar espaços de alta dimensão [Chen and Yoo 2021, Chehimi et al. 2024]. Esta seção apresenta soluções para desafios no QFL.

### 2.1. Eficiência de Comunicação e Adaptação Dinâmica

Um dos principais obstáculos para a descentralização do QFL é o *overhead* de comunicação. Em redes reais, a largura de banda flutua e a transmissão de VQC densos torna-se inviável. Por estas razões, é necessário o desenvolvimento de modelos que não sejam estáticos, mas sim elásticos.

Neste contexto, Yun et al. e, mais recentemente, Park et al. introduziram e aperfeiçoaram o conceito de *Slimmable Quantum Federated Learning* (SlimQFL) [Yun et al. 2022, Park et al. 2025]. A inovação central destes trabalhos reside na estruturação do VQC em componentes de “Polo” (parâmetros de medição) e “Ângulo” (parâmetros de emaranhamento). A justificativa para esta divisão é crítica: sob condições de canal severas, a transmissão completa falha. O SlimQFL permite que os clientes transmitam apenas os parâmetros de Polo (que são dimensionalmente menores), garantindo a continuidade do aprendizado onde abordagens clássicas sofreriam *timeout*.

Simultaneamente, para resolver a escassez de qubits em dispositivos de borda, Liu e Chen propuseram o *Quantum-Train* (QT) [Liu and Chen 2024]. Diferente das abordagens híbridas convencionais que tentam codificar dados clássicos massivos em estados quânticos (o que exige muitos qubits e profundidade de circuito proibitiva), o QT inverte o paradigma: utiliza uma pequena rede quântica para *gerar* os pesos de uma rede neural clássica. Isso demonstra que é possível alcançar alta acurácia (ex: em CIFAR-10) utilizando apenas 8 qubits, desacoplando a complexidade dos dados das limitações do hardware.

### 2.2. Heterogeneidade Estatística e Personalização

Enquanto o SlimQFL resolve a heterogeneidade de sistemas, a diversidade dos dados (*Non-IID*) impõe outro desafio: a deriva do modelo (*model drift*). O algoritmo *Federated Averaging* (*FedAvg*) padrão falha em convergir quando as distribuições locais dos clientes divergem significativamente.

Para mitigar este problema, Gurung e Pokhrel desenvolveram o *Weighted Personalized QFL* (wp-QFL) [Gurung and Pokhrel 2025]. A importância deste trabalho reside na introdução de uma métrica de divergência baseada na distância Euclidiana entre os modelos locais e o global. Ao ponderar a agregação com base nesta deriva, o wp-QFL estabiliza o treinamento de circuitos quânticos sensíveis, oferecendo uma convergência superior em cenários descentralizados e estatisticamente heterogêneos.

Complementarmente, Zhao abordou o problema sob a ótica da teoria da informação, decompondo canais quânticos globais em estimadores de densidade local

[Zhao 2023]. Esta abordagem é fundamental para cenários de comunicação restrita, pois viabiliza a inferência federada em “one-shot” (uma única rodada), eliminando a latência de múltiplas sincronizações.

### 2.3. Otimização em Paisagens Ruidosas

Por fim, o treinamento de QNNs enfrenta o problema dos *Barren Plateaus* (desaparecimento de gradientes), exacerbado pelo ruído NISQ. Qi et al. demonstraram que otimizadores clássicos como *Stochastic Gradient Descent* (SGD) são ineficientes na geometria complexa do espaço de Hilbert [Qi et al. 2023, Qi and Hsieh 2024]. Eles propuseram o *Federated Quantum Natural Gradient Descent* (FQNGD), que utiliza o tensor métrico de Fubini-Study para corrigir a curvatura do espaço de parâmetros. A adoção do FQNGD é crucial para reduzir o número de rodadas de comunicação necessárias para a convergência, minimizando assim o tempo de exposição dos qubits à decoerência ambiental.

## 3. Fundamentação Teórica

Esta seção estabelece os fundamentos teóricos necessários para a compreensão da arquitetura proposta no QFL-Adaptive. Abordamos a integração entre Computação Quântica e Aprendizado Federado, com ênfase nas arquiteturas variacionais híbridas e nas estratégias de adaptação dinâmica e personalização que fundamentam nossa implementação.

### 3.1. Fundamentos da Computação Quântica

A computação quântica opera sob paradigmas que transcendem a lógica booleana, fundamentando-se nos postulados da mecânica quântica para processar informações em espaços vetoriais complexos.

**Qubits e a Vantagem Exponencial.** O *qubit*, é a unidade básica de informação; se distingue do bit clássico por poder estar em uma superposição linear de estados, descrita como  $|\psi\rangle = \alpha|0\rangle + \beta|1\rangle$ , com  $\alpha, \beta \in \mathbb{C}$  e a normalização  $|\alpha|^2 + |\beta|^2 = 1$  [Nielsen and Chuang 2010]. Um registro clássico de  $N$  bits representa apenas um estado entre  $2^N$  possibilidades, enquanto um sistema de  $N$  qubits pode manter uma superposição de todos os  $2^N$  estados ao mesmo tempo. Essa característica possibilita que algoritmos quânticos naveguem em um vasto espaço de Hilbert com recursos polinomiais, proporcionando uma vantagem teórica em tarefas de alta dimensionalidade, como classificação de padrões em redes neurais.

**Emaranhamento e Correlações Não-Locais.** Ao contrário dos algoritmos quânticos teóricos que precisam de precisão exata como o de Shor, a principal abordagem de aprendizado de máquina hoje é o uso de VQC ou Parametrizados (PQC). Funcionam como redes neurais, com uma sequência de portas lógicas fixas e portas de rotação ajustáveis ( $R_x(\theta)$ ,  $R_y(\phi)$ ), cujos parâmetros são otimizados por um coprocessador clássico [Chehimi et al. 2024, Illiano et al. 2022].

**Circuitos Quânticos Variacionais.** Diferente dos algoritmos quânticos teóricos que exigem precisão perfeita como o algoritmo de Shor, a abordagem predominante para

aprendizado de máquina na atualidade é o uso de VQC ou Parametrizados (PQC). Estes funcionam de maneira análoga às redes neurais: consistem em uma sequência de portas lógicas fixas e portas de rotação ajustáveis ( $R_x(\theta)$ ,  $R_y(\phi)$ ), cujos parâmetros são otimizados iterativamente por um coprocessador clássico [Cerezo et al. 2022].

**O Cenário NISQ e a Medição.** Atualmente, operamos na era NISQ, caracterizada por processadores com número limitado de qubits (50-1000) e suscetíveis a erros de decoerência, onde a profundidade do circuito é severamente limitada pelo tempo de vida da informação quântica [Preskill 2018, Broughton et al. 2021]. A extração da informação desses sistemas ocorre através da medição. O principal desafio do QFL na era NISQ é criar algoritmos que suportem o ruído do hardware e sejam eficientes na comunicação, para que a vantagem quântica não seja perdida por erros de porta ou latência, guiando a arquitetura adaptativa desenvolvida.

### 3.2. Aprendizado de Máquina Quântico Híbrido (Hybrid QML)

Na era atual de dispositivos NISQ, os modelos predominantes são os *Variational Quantum Algorithms* (VQA) [Cerezo et al. 2022]. Nestes modelos, um Circuito Quântico Parametrizado (PQC), ou *Ansatz*, atua como uma rede neural, onde as portas lógicas possuem parâmetros treináveis  $\theta$  (ângulos de rotação).

O treinamento ocorre em um loop híbrido: o dispositivo quântico prepara o estado e realiza medidas, enquanto um otimizador clássico como Adam ou SGD atualiza os parâmetros para minimizar uma função de custo [Broughton et al. 2021]. Em nossa abordagem, utilizamos uma arquitetura onde o VQC é composto por duas partes funcionais distintas, conforme proposto por Park et al. [Park et al. 2025]:

- **Parâmetros de Ângulo ( $\phi$ ):** Responsáveis pelo emaranhamento e extração de características no corpo do circuito.
- **Parâmetros de Polo ( $\theta$ ):** Responsáveis pelo ajuste da base de medição (camada final), atuando como um classificador linear no espaço de Hilbert.

### 3.3. Aprendizado Federado Quântico

O QFL estende o paradigma federado clássico, permitindo que múltiplos clientes (nós quânticos ou simuladores) treinem modelos VQC locais sem compartilhar seus dados brutos [Chen and Yoo 2021, Chehimi et al. 2024]. O servidor central agrega os parâmetros dos circuitos locais para formar um modelo global. No entanto, o QFL enfrenta desafios severos de heterogeneidade de sistemas (largura de banda variável) e heterogeneidade de dados (distribuições Non-IID), que degradam a convergência do algoritmo padrão *FedAvg* [Nguyen et al. 2025].

### 3.4. SlimQFL e Adaptação Dinâmica

Para mitigar a instabilidade das redes de comunicação, a técnica de *Slimmable QFL* introduz a adaptação dinâmica da largura do modelo [Yun et al. 2022, Park et al. 2025]. A premissa fundamental é que nem todos os parâmetros do circuito quântico precisam ser transmitidos em todas as rodadas.

O protocolo define dois modos de operação baseados na qualidade do canal ( $R_n$ ):

$$\text{Update}_k = \begin{cases} (\phi_k, \theta_k) & \text{se } R_n \geq \tau_{\text{full}} \quad (\text{Modelo Completo}) \\ (\theta_k) & \text{se } \tau_{\text{pole}} \leq R_n < \tau_{\text{full}} \quad (\text{Apenas Polos}) \end{cases} \quad (1)$$

Esta estratégia garante que clientes em condições adversas ainda preservem sua contribuição para a camada de decisão. Ao evitar o descarte completo das atualizações locais, o modelo incorpora informação parcial mesmo quando o canal é precário, mantendo a participação dos clientes em rodadas de comunicação degradada.

### 3.5. Personalização via wp-QFL

Em cenários onde os dados dos clientes são estatisticamente divergentes (Non-IID), o modelo global tende a não se especializar corretamente para nenhum cliente. O *Weighted Personalized QFL* (wp-QFL) propõe mitigar a “deriva do modelo” (*model drift*) através de uma agregação ponderada [Gurung and Pokhrel 2025].

Diferente da substituição direta dos pesos locais pelos globais, o cliente  $k$  atualiza seu modelo interpolando o conhecimento global com seu estado local anterior:

$$\Theta_k^{t+1} = \alpha \cdot \Theta_{\text{global}}^{t+1} + (1 - \alpha) \cdot \Theta_k^t \quad (2)$$

Onde  $\alpha$  é um fator de personalização. Esta técnica permite que o modelo retenha conhecimentos específicos do dataset local do cliente, aumentando a acurácia em distribuições de dados heterogêneas, como demonstrado nos experimentos com MNIST e dados médicos [Gurung and Pokhrel 2024].

## 4. QFL-Adaptive

A arquitetura do QFL-Adaptive (Figura 1) é projetada para operar em cenários de QFL caracterizados por dispositivos heterogêneos e canais de comunicação instáveis (comuns em redes 5G/IoT) [Park et al. 2025, Nguyen et al. 2025]. A proposta integra dois mecanismos principais: (i) uma arquitetura segmentada inspirada em VQC para adaptação dinâmica da transmissão de parâmetros e (ii) agregação personalizada via wp-QFL para mitigação da divergência estatística em cenários Non-IID [Gurung and Pokhrel 2025].

### 4.1. Modelo Local: VQC Híbrido e Segmentado

Cada cliente  $k$  possui um modelo local baseado em um VQC. Seguindo a implementação de Park et al. [Park et al. 2025], os parâmetros do circuito são segmentados funcionalmente em dois conjuntos:

- **Parâmetros de Ângulo ( $\phi$ ):** Correspondem às portas de rotação no “corpo” do circuito (e.g., camadas de *ansatz* profundo), responsáveis pela extração de características complexas e emaranhamento. Este conjunto possui maior dimensionalidade.
- **Parâmetros de Polo ( $\theta$ ):** Correspondem à “cabeça” de medição ou classificação final. Este conjunto é significativamente menor (baixo custo de transmissão) e crucial para a definição das fronteiras de decisão lineares no espaço de Hilbert.

Durante o treinamento local, o cliente executa a otimização sequencial (Pole-Angle Training), garantindo que ambas as partes do modelo sejam refinadas.

## 4.2. Protocolo de Comunicação Adaptativa

Para mitigar falhas de comunicação e reduzir a latência, o QFL-Adaptive implementa um mecanismo de *uplink* condicional. Seja  $Q_{ch}$  a métrica de qualidade do canal de comunicação do cliente  $k$  na rodada  $t$  e  $\tau$  um limiar de qualidade pré-definido:

$$\Delta_k^{(t)} = \begin{cases} \{\phi_k^{(t)}, \theta_k^{(t)}\} & \text{se } Q_{ch} \geq \tau \quad (\text{Modo Full}) \\ \{\theta_k^{(t)}\} & \text{se } Q_{ch} < \tau \quad (\text{Modo Slim/Pole}) \end{cases} \quad (3)$$

No modo “Slim”, o cliente transmite apenas os parâmetros de polo. Isso assegura que, mesmo sob severa restrição de banda, o cliente contribua para a atualização da camada de decisão global, evitando o descarte total da rodada [Yun et al. 2022].


## 4.3. Personalização e Agregação Híbrida

Para lidar com a heterogeneidade dos dados (Non-IID), o QFL-Adaptive utiliza uma estratégia de personalização baseada em interpolação. Ao receber o modelo global  $\mathcal{M}_{global}$ , o cliente não o sobrescreve diretamente. Em vez disso, calcula uma atualização ponderada:

$$\mathcal{M}_{local}^{(t+1)} \leftarrow \alpha \cdot \mathcal{M}_{global}^{(t)} + (1 - \alpha) \cdot \mathcal{M}_{local}^{(t)} \quad (4)$$

Onde  $\alpha$  é o fator de personalização. Esta técnica permite reter conhecimento específico do domínio local, estabilizando a convergência em distribuições de dados divergentes [Gurung and Pokhrel 2025].

No lado do servidor, a agregação deve lidar com atualizações parciais. Utilizamos uma média ponderada seletiva: para os parâmetros de ângulo ( $\phi$ ), a média é calculada apenas sobre o subconjunto de clientes que conseguiram transmitir no modo “Full”. Para os parâmetros de polo ( $\theta$ ), a média incorpora todos os clientes participantes.



**Figura 1. Arquitetura sistêmica do QFL-Adaptive: Detalhamento do fluxo de parâmetros entre a unidade VQC do cliente, o seletor de uplink baseado em telemetria de canal e os buffers de agregação seletiva no servidor.**

## 4.4. Algoritmo QFL-Adaptive

O fluxo de execução completo do sistema proposto é detalhado no Algoritmo 1. A lógica operacional, que ilustra a interação entre o servidor central e os clientes heterogêneos sob condições de canal variáveis, é visualmente representada na Figura 1.

---

**Algoritmo 1:** Fluxo de Treinamento do QFL-Adaptive

---

**Entrada:**  $K$  clientes, Taxa de aprendizado  $\eta$ , Limiar de canal  $\tau$ , Fator de personalização  $\alpha$

- 1 **Servidor:** Inicializa parâmetros globais  $\Theta_0 = \{\phi_0, \theta_0\}$
- 2 **para rodada**  $t = 1, \dots, T$  **faça**
- 3     **Servidor:** Seleciona subconjunto de clientes  $S_t$  e envia  $\Theta_{t-1}$
- 4     **para cada cliente**  $k \in S_t$  **em paralelo faça**
  - 5         // Etapa de Personalização (wp-QFL)
  - 5         Recuperar modelo local anterior  $\mathcal{M}_{loc}^{prev}$
  - 6          $\mathcal{M}_k \leftarrow \alpha \Theta_{t-1} + (1 - \alpha) \mathcal{M}_{loc}^{prev}$
  - 6         // Treinamento Local
  - 7          $\mathcal{M}_k \leftarrow \text{LocalTrain}(\mathcal{M}_k, \text{Dados}_k, \eta)$
  - 7         // Decisão Adaptativa (SlimQFL)
  - 8         Medir qualidade do canal  $Q_{ch}$
  - 9         **se**  $Q_{ch} < \tau$  **então**
    - 10             Pacote  $\Delta_k \leftarrow \{\text{apenas } \theta_k\}$                      // Transmissão Leve
  - 11         **senão**
    - 12             Pacote  $\Delta_k \leftarrow \{\phi_k, \theta_k\}$                      // Transmissão Completa
  - 13         Enviar  $\Delta_k$  para o servidor
- 14     **Servidor:** Agregação Híbrida
- 15      $\theta_t \leftarrow \frac{1}{|S_t|} \sum_{k \in S_t} \theta_k$
- 16      $S_{full} \leftarrow \{k \in S_t \mid \text{modo Full}\}$
- 17     **se**  $S_{full} \neq \emptyset$  **então**
  - 18          $\phi_t \leftarrow \frac{1}{|S_{full}|} \sum_{k \in S_{full}} \phi_k$
- 19     **senão**
- 20      $\phi_t \leftarrow \phi_{t-1}$                      // Mantém estado anterior

---

## 5. Resultados

Nesta seção, avaliamos o framework QFL-Adaptive para responder à necessidade de resiliência em cenários QFL com conectividade instável. O foco reside na capacidade de manter a aprendizagem global enquanto se otimiza o uso de banda através da política adaptativa de transmissão.

### 5.1. Configuração do Experimento e Protocolo

Avaliamos a proposta em quatro cenários de classificação binária representativos: *breast* (saúde), *fashion* (objetos), *mnist* (dígitos) e *pneumonia* (imagens médicas).

**Arquitetura e Particionamento:** A configuração experimental adota uma implementação emulada da arquitetura de circuitos variacionais elásticos (*Slimmable VQC*), seguindo a segmentação *pole-angle* utilizada em QFL. O modelo local é decomposto em um bloco  $\phi$ , associado ao corpo parametrizável do modelo, e uma cabeça  $\theta$ , associada à etapa de decisão e transmissão reduzida. No protótipo computacional, esses blocos são implementados como camadas diferenciáveis clássicas, permitindo isolar e avaliar a política federada de comunicação adaptativa, a agregação parcial e a personalização sob falhas de canal. Assim, os experimentos avaliam a dinâmica sistêmica do QFL-Adaptive em ambiente simulado, enquanto a validação em hardware quântico real permanece como etapa futura.

**Protocolo de Comunicação:** Foram executadas 25 rodadas de comunicação por experimento. Em cada rodada, a qualidade do canal de comunicação ( $Q_{ch}$ ) é simulada

estocasticamente. Se  $Q_{ch} < \tau$ , o framework comuta para o modo de transmissão de parâmetros de polo ( $\theta$ ), caso contrário, envia o modelo completo.

**Tabela 1. Detalhamento dos Hiperparâmetros e Configuração do Sistema**

Categoria	Parâmetro	Especificação Técnica
<b>Arquitetura Segmentada</b>	Modelo	SlimmableVQC emulado (híbrido)
	Bloco $\phi$	Corpo parametrizável: 2 Linear + ReLU (784 $\rightarrow$ 64 $\rightarrow$ 64)
	Bloco $\theta$	Cabeça de decisão/transmissão reduzida: 1 Linear (64 $\rightarrow$ 2)
	Dimensão de Entrada	784 (imagem 28 $\times$ 28 vetorizada)
<b>Treinamento Local</b>	Otimizador	Adam
	Taxa de Aprendizado ( $\eta$ )	0.005
	Épocas Locais	1 por rodada
	Função de Perda	CrossEntropyLoss
<b>Federação</b>	Agregação	Híbrida, seletiva por tipo de parâmetro
	Personalização	wp-QFL ( $\alpha = 0.8$ )
	Escala	$K = 10$ clientes / $T = 25$ rodadas
<b>Dados</b>	Particionamento	Subconjuntos locais por cliente
	MNIST	Classes 3 vs 5 (alta ambiguidade)
	Fashion	Pullover vs Coat
<b>Rede e Resiliência</b>	Modelo de Canal	Bernoulli, $p \in \{0.0, 0.2, 0.5, 0.8\}$
	Limiar ( $\tau$ )	$\tau \in \{0.3, 0.7\}$

A Tabela 1 sintetiza a configuração experimental e os hiperparâmetros do framework QFL-Adaptive. A implementação segue uma representação segmentada inspirada em VQC, separando o bloco  $\phi$ , associado ao corpo parametrizável do modelo, e a cabeça  $\theta$ , associada à decisão e ao modo de transmissão reduzida. Essa formulação permite avaliar a robustez da política de comunicação adaptativa, da agregação seletiva e da personalização sob diferentes probabilidades de falha de canal, sem depender da execução em hardware quântico real.

## 5.2. Definição das Métricas e Rigor Estatístico

Para garantir a validade científica, cada configuração foi executada com 5 sementes aleatórias (*seeds*). Os resultados são reportados como média  $\pm$  desvio padrão. A métrica  $N$  nas tabelas indica o número de execuções válidas; casos onde  $N < 5$  representam descartes preventivos por instabilidade numérica. As métricas fundamentais são definidas como:

1. **Acurácia Global ( $Acc$ ):** Percentual de predições corretas sobre o conjunto de teste consolidado.
2. **Economia de Banda ( $S$ ):** Redução percentual do custo de uplink:

$$S = \left( 1 - \frac{\sum Bytes_{sent}}{\sum Bytes_{full}} \right) \times 100\% \quad (5)$$

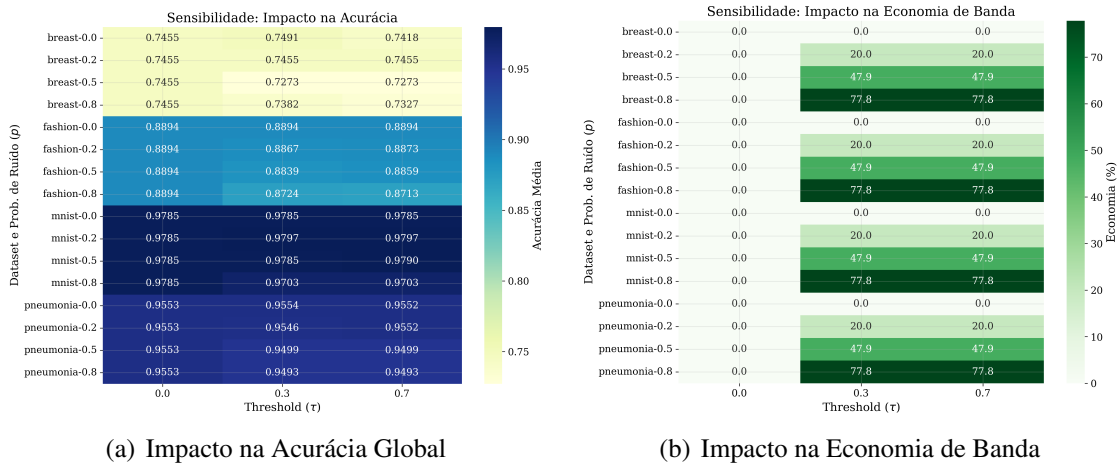
3. **Índice de Retenção ( $R$ ):** Razão de preservação da performance sob ruído ( $p$ ) em

relação ao canal ideal ( $p = 0$ ):

$$R = \frac{Acc(p)}{Acc(0)} \times 100\% \quad (6)$$

### 5.3. Análise de Sensibilidade e Seleção de Limiar ( $\tau$ )

A Figura 2 apresenta a comparação entre os limiares  $\tau \in \{0.3, 0.7\}$  e a configuração de referência ( $\tau = 0.0$ ).



**Figura 2. Análise de sensibilidade comparativa. A estabilidade dos resultados de acurácia entre os limiares avaliados sustenta o uso de  $\tau = 0.7$  como configuração de referência para os experimentos de resiliência.**

Observa-se que o uso do limiar  $\tau = 0.7$  mantém a acurácia estável em relação aos demais limiares avaliados, permitindo analisar a resiliência do framework sob diferentes probabilidades de falha de canal.

### 5.4. Resultados de Resiliência para $\tau = 0.7$

Com o limiar fixado em 0.7, a Tabela 2 detalha a robustez do QFL-Adaptive comparando o cenário ideal com o estresse máximo ( $p = 0.8$ ).

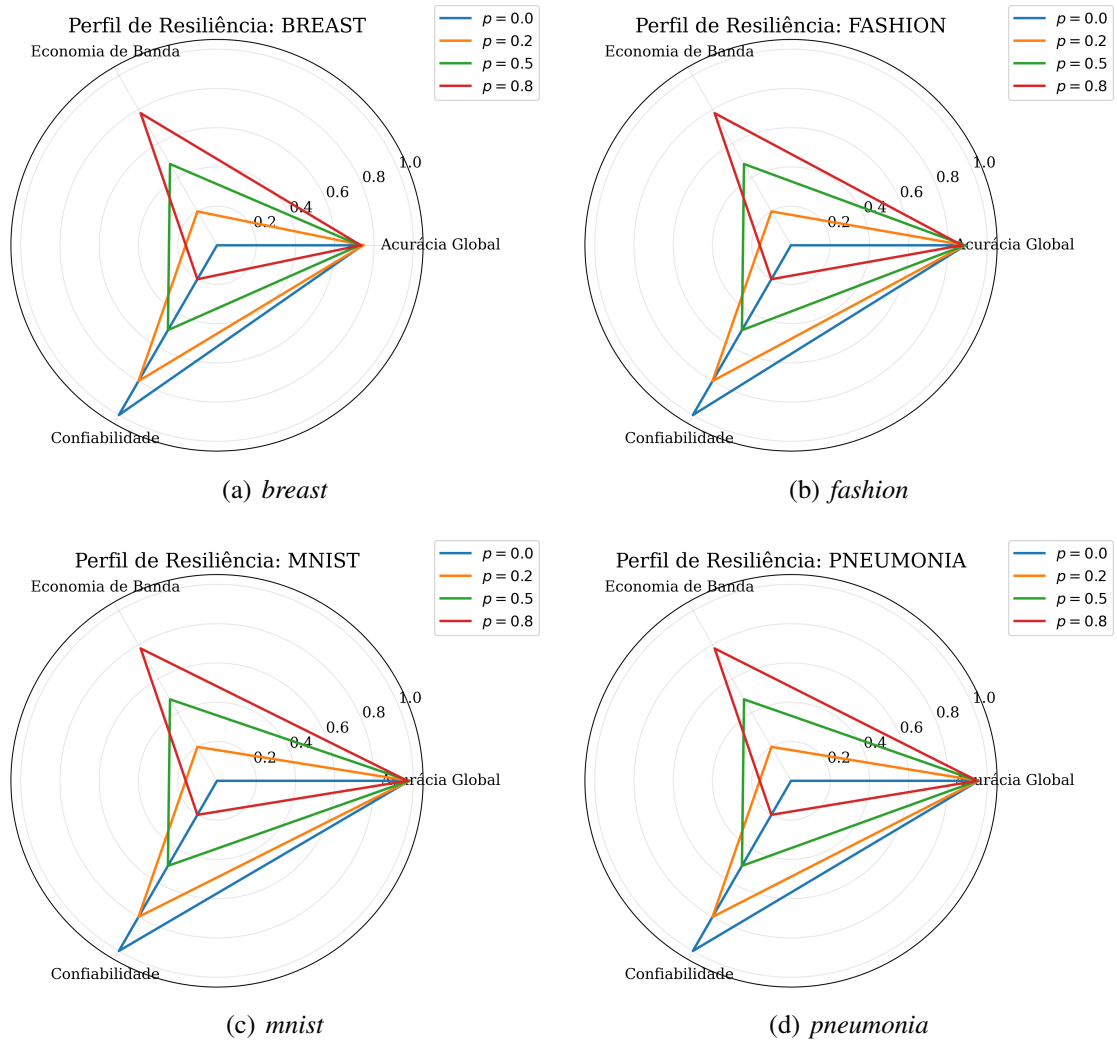
**Tabela 2. Resumo de Desempenho e Resiliência ( $\tau = 0.7$ ) para  $N = 5$  sementes.**

Dataset	Acc ( $p = 0.0$ )	Acc ( $p = 0.8$ )	Retenção ( $R$ )	Economia ( $S$ )
<i>breast</i>	0,7418 $\pm$ 0,046	0,7327 $\pm$ 0,056	98,77%	77,81%
<i>fashion</i>	0,8894 $\pm$ 0,003	0,8713 $\pm$ 0,011	97,97%	77,81%
<i>mnist</i>	0,9785 $\pm$ 0,004	0,9703 $\pm$ 0,004	99,16%	77,81%
<i>pneumonia</i>	0,9552 $\pm$ 0,009	0,9493 $\pm$ 0,015	99,38%	77,81%

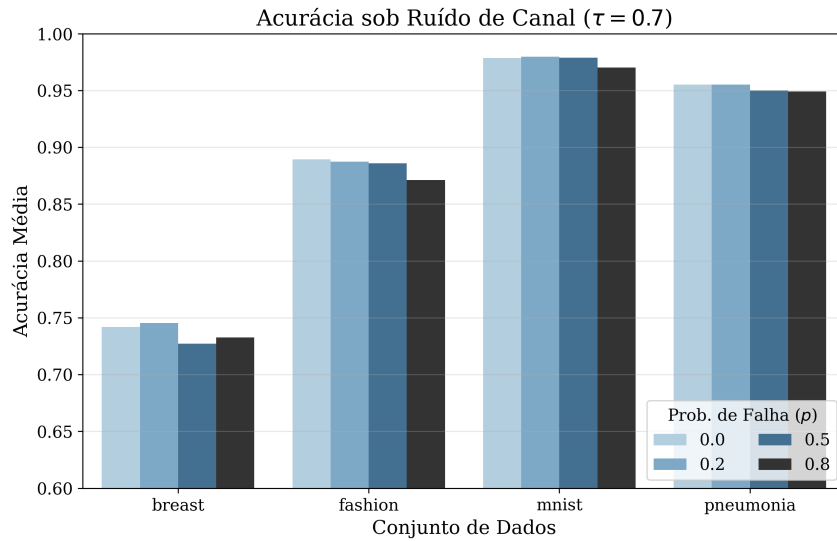
A Figura 3 ilustra a natureza adaptativa do framework através de gráficos de radar para todos os domínios.

### 5.5. Acurácia e Estabilidade

A Figura 4 apresenta o resumo consolidado do desempenho do QFL-Adaptive em todos os domínios avaliados.



**Figura 3. Perfis de Resiliência Multidimensionais ( $\tau = 0.7$ ). Nota-se que à medida que a confiabilidade do canal diminui, o polígono de performance se desloca para o eixo de economia sem reduzir significativamente o eixo de acurácia.**



**Figura 4. Consolidação de resultados: estabilidade da acurácia média por conjunto de dados e nível de falha de canal para o limiar selecionado ( $\tau = 0.7$ ).**

Observa-se que, para todos os quatro conjuntos de dados (*breast*, *fashion*, *mnist* e *pneumonia*), a altura das barras (acurácia) permanece praticamente invariável, mesmo quando o sistema opera sob regime de 80% de falha comunicacional ( $p = 0.8$ ). Esse resultado constitui um indicativo de resiliência do framework: a estratégia adaptativa consegue preservar a contribuição dos parâmetros essenciais ( $\theta$ ) de forma tão eficiente que a ausência dos parâmetros completos ( $\phi, \theta$ ) não impede a convergência para um modelo global de alta performance.

## 6. Conclusões

Este trabalho apresentou o QFL-Adaptive, um mecanismo de aprendizado federado quântico com comunicação adaptativa para cenários de conectividade variável. A proposta ajusta dinamicamente o volume de atualização transmitida pelos clientes com base na condição do canal: em situações favoráveis, envia-se a atualização completa; sob canal degradado, prioriza-se uma atualização parcial, reduzindo tráfego sem interromper o processo de treinamento. Essa estratégia torna o método particularmente adequado para ambientes reais com oscilações de qualidade de rede e restrições de largura de banda.

Os resultados experimentais em quatro benchmarks binários (*breast*, *fashion*, *mnist* e *pneumonia*) evidenciam um padrão consistente: o aumento da probabilidade de falha do canal leva a maior economia de comunicação, confirmando a efetividade da política adaptativa. Em contrapartida, observamos um *trade-off* controlável entre economia e desempenho, no qual regimes de economia elevada podem introduzir pequena degradação de acurácia em alguns conjuntos de dados. Ainda assim, configurações intermediárias, por exemplo com probabilidade de falha entre 0.2 e 0.5, frequentemente oferecem um ponto operacional atrativo, combinando redução significativa de tráfego com perda limitada de desempenho, muitas vezes compatível com a variabilidade entre sementes.

## Disponibilidade de Artefatos

Os artefatos experimentais deste trabalho, incluindo scripts de simulação, configurações, sementes aleatórias e resultados agregados, estão disponíveis em: [https://github.com/romulobustincio/FL\\_adaptive](https://github.com/romulobustincio/FL_adaptive).

## Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico – Brasil (CNPq), processo nº 405940/2022-0. Além disso, 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.

## Referências

- Ballester, R., Cerquides, J., and Artiles, L. (2025). Quantum federated learning: a comprehensive literature review of foundations, challenges, and future directions. *Quantum Machine Intelligence*, 7(73).
- Broughton, M. et al. (2021). Tensorflow quantum: A software framework for quantum machine learning. *arXiv preprint arXiv:2003.02989*.
- Cerezo, M. et al. (2022). Challenges and opportunities in quantum machine learning. *Nature Computational Science*, 2:567–576.
- Cehimi, M., Chen, S. Y.-C., Saad, W., Towsley, D., and Debbah, M. (2024). Foundations of quantum federated learning over classical and quantum networks. *IEEE Network*, 38(1):124–130.
- Cehimi, M. and Saad, W. (2022). Quantum federated learning with quantum data. *ICASSP 2022*, pages 8617–8621.
- Chen, S. Y.-C. and Yoo, S. (2021). Federated quantum machine learning. *Entropy*, 23(4):460.
- Gurung, D. and Pokhrel, S. R. (2024). A personalized quantum federated learning. In *Proceedings of the 8th Asia-Pacific Workshop on Networking, APNet '24*, page 175–176, New York, NY, USA. Association for Computing Machinery.
- Gurung, D. and Pokhrel, S. R. (2025). Performance analysis and design of a weighted personalized quantum federated learning. *IEEE Transactions on Artificial Intelligence*. DOI: 10.1109/TAI.2025.3545393.
- Havlíček, V., Córcoles, A. D., Temme, K., Harrow, A. W., Kandala, A., Chow, J. M., and Gambetta, J. M. (2019). Supervised learning with quantum-enhanced feature spaces. *Nature*, 567(7747):209–212.
- Illiano, J., Caleffi, M., Manzalini, A., and Cacciapuoti, A. S. (2022). Quantum internet protocol stack: A comprehensive survey. *Comput. Netw.*, 213(C).
- Liu, C.-Y. and Chen, S. Y.-C. (2024). Federated quantum-train with batched parameter generation. *arXiv preprint arXiv:2409.02763*.

- McMahan, H. B., Moore, E., Ramage, D., Hampson, S., and Agüera y Arcas, B. (2017). Communication-efficient learning of deep networks from decentralized data. In *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics, AISTATS*, pages 1273–1282.
- Nguyen, D. C. et al. (2025). Quantum federated learning: A comprehensive survey. *IEEE Communications Surveys and Tutorials*.
- Nielsen, M. A. and Chuang, I. L. (2010). *Quantum Computation and Quantum Information*. Cambridge University Press, 10th anniversary edition.
- Park, S., Lee, H., Son, S. B., Jung, S., and Kim, J. (2025). Quantum federated learning with pole-angle quantum local training and trainable measurement. *Neural Networks*, 187:107301.
- Preskill, J. (2018). Quantum computing in the nisq era and beyond. *Quantum*, 2:79.
- Qi, J. and Hsieh, M.-H. (2024). Federated quantum natural gradient descent for quantum federated learning. In *Federated Learning*, pages 329–341. Elsevier.
- Qi, J., Zhang, X.-L., and Tejedor, J. (2023). Optimizing quantum federated learning based on federated quantum natural gradient descent. In *ICASSP 2023*.
- Thompson, N. C., Greenewald, K., Lee, K., and Manso, G. F. (2020). The computational limits of deep learning. *arXiv preprint arXiv:2007.05558*.
- Yun, W. J. et al. (2022). Slimmable quantum federated learning. *arXiv preprint arXiv:2207.10221*.
- Zhao, H. (2023). Non-iid quantum federated learning with one-shot communication complexity. *Quantum Machine Intelligence*, 5(1):3.