

# Framework Federado para Redes Neurais Quânticas sem Pesos Distribuídas

Nicolas M. de Oliveira<sup>1</sup>, Adenilton J. da Silva<sup>1</sup>

<sup>1</sup>Centro de Informática – Universidade Federal de Pernambuco (UFPE)  
Recife – PE – Brazil

{nmo, ajsilva}@cin.ufpe.br

**Abstract.** *This work proposes a distributed Quantum Federated Learning framework grounded in the Quantum Weightless Neural Network paradigm. By integrating federated learning with a weightless quantum architecture, the model ensures privacy preservation across decentralized quantum nodes without the need to share raw data. The weightless structure effectively reduces communication overhead and streamlines the optimization process. Simulation results demonstrate the model's viability and highlight its potential as a foundation for future research in quantum federated learning.*

**Resumo.** *Este trabalho propõe um framework de Aprendizado Federado Quântico distribuído, fundamentado no paradigma das Redes Neurais Quânticas sem Pesos. Ao integrar o aprendizado federado à arquitetura quântica sem pesos, o modelo viabiliza a preservação da privacidade entre nós quânticos descentralizados sem o compartilhamento de dados brutos. A estrutura sem pesos reduz a sobrecarga de comunicação e simplifica o processo de otimização. Resultados de simulações indicam a viabilidade do modelo e evidenciam seu potencial como base para pesquisas futuras em aprendizado federado quântico.*

## 1. Introdução

A Computação Quântica Distribuída (*Distributed Quantum Computing* - DQC) [Barral et al. 2025] é considerada um dos caminhos mais promissores para superar as limitações dos atuais dispositivos NISQ (*Noisy Intermediate-Scale Quantum*) [Preskill 2018]. No lugar de um único processador monolítico de larga escala, a DQC propõe a interconexão de múltiplas Unidades de Processamento Quântico (*Quantum Processing Units* - QPUs) por meio de redes quânticas. Por sua vez, o Aprendizado Federado (*Federated Learning* - FL) [McMahan et al. 2017] é uma abordagem da computação distribuída que permite o treinamento com preservação de privacidade em conjuntos de dados descentralizados e sensíveis. Nos últimos anos, alguns trabalhos consolidaram os fundamentos do Aprendizado Federado Quântico (*Quantum Federated Learning* - QFL), com ênfase particular em propostas que empregam o teletransporte de estados ou de pesos [Liu et al. 2025]. Além disso, a literatura sobre Computação Quântica Distribuída formalizou primitivas como o *Telegate*, que implementa operadores quânticos não-locais [Peckham et al. 2024].

Paralelamente, pesquisas demonstram que Redes Neurais Quânticas (*Quantum Neural Networks* — QNNs) possuem o potencial de serem treinadas mais rapidamente

e de expressarem uma gama maior de funções do que modelos clássicos equivalentes [Abbas et al. 2021]. Entre os modelos de QNN, as Redes Neurais Quânticas sem Pesos (*Quantum Weightless Neural Networks* — QWNNs) [Ludermir 2022] constituem uma classe de redes neurais artificiais baseadas em uma rede de nós de Memória de Acesso Aleatório (RAM). Essas redes podem obter desempenhos semelhantes a outros métodos de aprendizado de máquina em tarefas de classificação [De Gregorio and Giordano 2018].

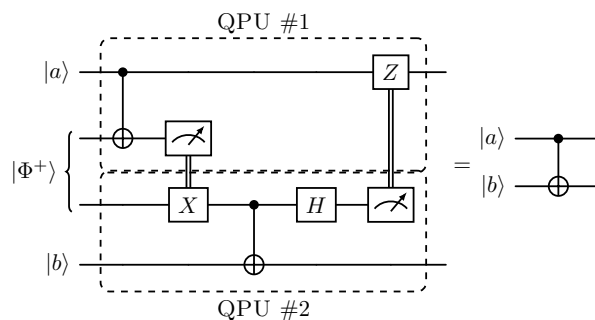
Este trabalho apresenta uma arquitetura distribuída para QWNNs que integra o aprendizado federado a circuitos quânticos variacionais com o uso do protocolo *telegate*, preenchendo uma lacuna existente na literatura. O modelo viabiliza a colaboração entre múltiplos participantes sem a necessidade de permuta de dados brutos ou parâmetros clássicos intermediários. Resultados de simulações validam a viabilidade da arquitetura, demonstrando sua eficácia. Diferenciando-se de abordagens híbridas convencionais, este modelo estabelece uma rede federada puramente quântica, que prescinde da comunicação clássica para o compartilhamento de pesos e assegura uma separação rigorosa entre os dados locais dos clientes e os parâmetros globais do servidor.

## 2. Aprendizado Federado Quântico

O Aprendizado Federado Quântico estende o aprendizado federado clássico para ambientes quânticos e híbridos quântico-clássicos, viabilizando o treinamento colaborativo entre clientes quânticos distribuídos ao mesmo tempo em que preserva a privacidade dos dados. Contudo, o QFL explora adicionalmente propriedades quânticas, como superposição, emaranhamento e interferência, para ampliar o poder representacional e, potencialmente, obter vantagens computacionais. No cenário quântico, os parâmetros do modelo estão nos Circuitos Quânticos Variacionais [Benedetti et al. 2019], não correspondendo mais exclusivamente a pesos clássicos.

### 2.1. Telegate


Uma abordagem para a realização da computação quântica distribuída é o uso do protocolo *telegate*, que transmite operações de portas quânticas ao invés de estados quânticos completos entre qubits fisicamente separados, utilizando recursos auxiliares como pares de Bell compartilhados (ver a Fig. 1). Em [Eisert et al. 2000] foi demonstrado que a implementação ótima de uma porta CNOT entre qubits distantes requer exatamente um par de qubits emaranhados e dois bits de comunicação clássica (ver a Fig. 1).



**Figura 1. Circuito quântico que implementa o protocolo *telegate* para o operador não-local CNOT entre  $|a\rangle$  e  $|b\rangle$ . O estado  $|\Phi^+\rangle$  representa o par emaranhado que produz o estado de Bell  $|\Phi^+\rangle$ . Esse esquema é diretamente generalizado para um operador controlado parametrizado  $R_y$ .**

### 3. Redes Neurais Quânticas sem Pesos

Redes Neurais Quânticas utilizam circuitos compostos por mapas de características e camadas variacionais parametrizadas [Abbas et al. 2021], operando usualmente em esquemas híbridos quântico-clássicos [Benedetti et al. 2019]. Por sua vez, as Redes Neurais Sem Pesos (*Weightless Neural Networks* — WNNs) baseiam-se em unidades sem pesos treináveis [Ludermir 2022]. No domínio quântico, essa arquitetura utiliza operadores  $U$  parametrizados que podem corresponder a uma porta de rotação  $R_y$  [Oliveira et al. 2008] (ver Fig. 3).




**Figura 2.** Diagrama de uma QWNN. Diferentes valores para os qubits de entrada  $|a\rangle, |b\rangle$  resultam na aplicação de operadores distintos ao qubit de saída.

### 4. Aprendizado Federado Quântico Através de Redes Neurais Quânticas sem Pesos

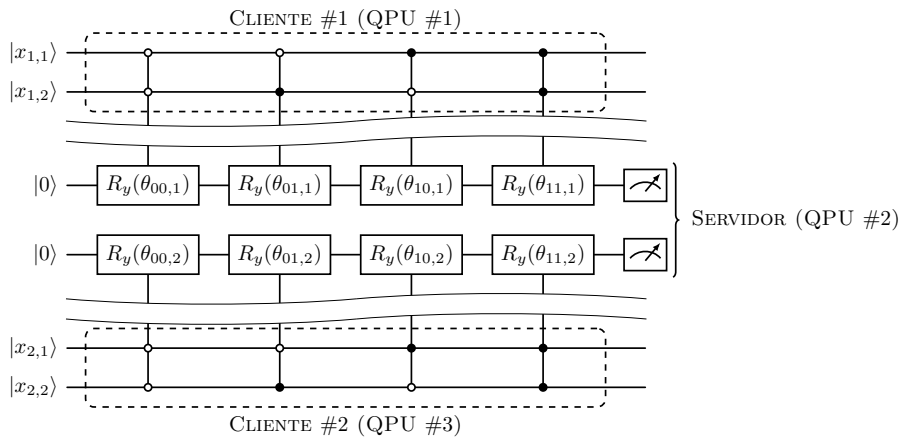
Embora QWNNs explorem a superposição quântica para o processamento paralelo de informações, a representação de um neurônio com múltiplas entradas exige um número de operadores controlados que cresce exponencialmente, tornando a implementação direta impraticável em dispositivos da era NISQ. Além disso, conjuntos de dados do mundo real são tipicamente volumosos, sensíveis e distribuídos entre diferentes entidades, de forma que sua centralização viola requisitos de privacidade.

Como se pode observar na arquitetura QWNN ilustrada na Fig. 3, os qubits de dados não são modificados diretamente por portas quânticas, mas, em vez disso, controlam operações parametrizadas. Essa estrutura suporta naturalmente uma configuração distribuída na qual os dados dos clientes residem em nós quânticos locais, enquanto os parâmetros do modelo são mantidos em um servidor central. Assim, cada cliente pode contribuir para o processo de treinamento sem expor seus dados brutos. Contudo, essa configuração distribuída introduz o desafio de realizar operações entre qubits em processadores distintos, o que exige inerentemente portas quânticas não-locais, aqui endereçadas por meio do protocolo *telegate*.



**Figura 3.**  $|x_1\rangle$  e  $|x_2\rangle$  são os qubits de entrada após a codificação dos estados clássicos nos registradores quânticos. O qubit de saída é denotado por “o” no final do circuito. Medimos o operador  $I \otimes I \otimes Z$ , onde  $Z$  é medido no qubit de saída.

Visando mitigar as limitações do hardware quântico, garantir a privacidade dos dados e explorar o paralelismo quântico, propomos um modelo de aprendizado quântico distribuído que integra as QWNNs aos princípios do aprendizado federado, constituindo a primeira combinação entre redes neurais quânticas sem pesos, computação distribuída e o uso do *telegate*. O modelo proposto, apresentado na Fig. 4, utiliza uma camada quântica variacional (servidor) composta por portas  $R_y$  controladas, acionadas por qubits remotos de clientes. Para que um cliente ative uma operação controlada em um qubit remoto do servidor, um par emaranhado  $|\phi^+\rangle$  deve ser previamente compartilhado entre ambos, viabilizando o treinamento distribuído por meio do *telegate*.



**Figura 4. Exemplo de uma QWNN implementada em um *framework* de aprendizado federado com dois clientes. As conexões entre cada cliente e o servidor central são estabelecidas por meio do protocolo *telegate*.**

O servidor gerencia a aplicação de portas, a medição e as atualizações de parâmetros com base nos gradientes computados. Cada cliente retém seu conjunto de dados local, e a acurácia global é avaliada pelas saídas de todos os clientes durante o processo de otimização. A saída de classificação de cada cliente é obtida a partir do valor esperado do operador de Pauli-Z no qubit correspondente,  $y_i = \langle \psi(\mathbf{x}, \boldsymbol{\theta}) | Z_i | \psi(\mathbf{x}, \boldsymbol{\theta}) \rangle$ , resultando em um vetor de predição  $\mathbf{y} = (y_1, \dots, y_N)$  com valores no intervalo  $[-1, 1]$ .

## 5. Simulações e discussão

Para as nossas simulações, realizamos classificação binária utilizando a base de dados *Iris*. Para a codificação dos modelo e otimização dos parâmetros, usamos o *Qiskit*. O treinamento foi conduzido utilizando validação cruzada *k-fold*, com  $k = 10$  e 2 clientes. Para cada *fold*, os parâmetros variacionais do circuito quântico federado são inicializados aleatoriamente e otimizados de forma independente por meio do algoritmo SPSA, com taxa de aprendizado 0.05 e perturbação de 0.05. A agregação é realizada implicitamente, uma vez que as saídas individuais de cada cliente são consideradas na otimização dos parâmetros do servidor. Os resultados obtidos com as simulações podem ser vistos na Tabela 1.

Os resultados demonstram a viabilidade do modelo, cuja combinação entre QWNNs e QFL reduz a complexidade de otimização, adequando-o a dispositivos NISQ

**Tabela 1. Média das acurácias de treinamento e teste obtidas a partir da simulação do modelo por meio de validação cruzada do tipo  $k$ -fold.**

Classes	Treinamento	Teste
1 & 2	1.0	1.0
1 & 3	0.988	0.97
2 & 3	0.995	1.0

devido à eficiência de seus circuitos de baixa profundidade. Contudo, as limitações incluem o uso de simulações e a necessidade de avaliar a escalabilidade e o impacto do ruído em hardware real. Apesar disso, o *framework* estabelece uma base sólida para futuras investigações em aprendizado federado quântico com arquiteturas mais expressivas e cenários de maior escala.

A implementação de portas de rotação controladas via *telegate* exige o consumo de recursos de rede quântica e clássica. Para um sistema com  $K$  clientes e  $G$  operadores de rotação controlados por nó, a demanda total de emaranhamento é de  $KG$  pares de Bell ( $N_{\text{EPR}}$ ), utilizando  $2KG$  qubits auxiliares. No domínio clássico, o protocolo requer a transmissão de  $2KG$  bits clássicos ( $N_{\text{cbits}}$ ). O principal limitador do sistema é a latência de comunicação e o tempo de geração de pares de Bell: se a latência exceder o tempo de coerência dos qubits, a fidelidade é comprometida pela decoerência antes da aplicação das portas de correção de Pauli. O custo total  $C_{\text{total}}$  é modelado pela Equação 1, onde  $\alpha$  e  $\beta$  são os custos de emaranhamento e comunicação clássica,  $\gamma$  é a penalidade de latência da rede, e  $\delta$  o custo computacional das operações locais  $N_{\text{op\_locais}}$ .

$$C_{\text{total}} = \alpha N_{\text{EPR}} + \beta N_{\text{cbits}} + \gamma + \delta N_{\text{op\_locais}} \quad (1)$$

É importante notar que nosso modelo requer canais de comunicação quânticos e clássicos entre cliente e servidor. O canal quântico estabelece e mantém o emaranhamento entre os nós, enquanto o canal clássico é responsável pela transmissão dos rótulos de classe (fase de treinamento) e dos resultados de classificação (fase de teste). Por fim, a adoção do protocolo *telegate* permite que os qubits locais do cliente controlem diretamente portas unitárias no servidor, preservando a natureza puramente quântica da interação. Diferente das abordagens federadas convencionais, que dependem da transmissão de parâmetros clássicos e são vulneráveis a gargalos ou ataques de inferência, esta estratégia mantém a informação sensível codificada em estados locais enquanto executa transformações não-locais. Tal abordagem é fundamental para a fidelidade dos estados na rede e fundamenta-se nos princípios de computação quântica distribuída [Eisert et al. 2000], que otimizam a implementação de portas remotas sem a necessidade de transferir estados ou parâmetros sensíveis.

## 6. Conclusão

Este trabalho apresentou um *framework* federado para Redes Neurais Quânticas sem Pesos (QWNN), estendendo o paradigma clássico para o domínio quântico distribuído. A arquitetura proposta preserva a privacidade dos dados ao evitar a troca direta de informações entre clientes. Resultados de simulações com o conjunto de dados Iris serviram como

prova de conceito, demonstrando a viabilidade do modelo em cenários controlados e sua capacidade de realizar aprendizado colaborativo.

Como perspectivas, trabalhos futuros focarão na escalabilidade do modelo e em sua avaliação em bases de dados mais desafiadoras e de maior dimensionalidade. Pretende-se investigar o impacto da quantização na expressividade do classificador e realizar experimentos em hardware quântico real para mensurar os efeitos de ruído e limitações físicas da era NISQ. Adicionalmente, serão exploradas novas estratégias de codificação quântica e a simulação de parâmetros inter-chip — como latência e restrições de comunicação —, visando consolidar este *framework* como uma base promissora para o aprendizado quântico escalável na era pós-NISQ.

### Agradecimentos

Os autores agradecem ao CNPq pelo apoio financeiro por meio do processo 156131/2025-0 de pós-doutorado e do INCT em Computação Quântica Aplicada (408884/2024-0).

### Referências

- Abbas, A., Sutter, D., Zoufal, C., Lucchi, A., Figalli, A., and Woerner, S. (2021). The power of quantum neural networks. *Nature Computational Science*, 1(6):403–409.
- Barral, D., Cardama, F. J., Diaz-Camacho, G., Faílde, D., Llovo, I. F., Mussa-Juane, M., Vázquez-Pérez, J., Villasuso, J., Piñeiro, C., Costas, N., et al. (2025). Review of distributed quantum computing: from single qpu to high performance quantum computing. *Computer Science Review*, 57:100747.
- Benedetti, M., Lloyd, E., Sack, S., and Fiorentini, M. (2019). Parameterized quantum circuits as machine learning models. *Quantum science and technology*, 4(4):043001.
- De Gregorio, M. and Giordano, M. (2018). An experimental evaluation of weightless neural networks for multi-class classification. *Applied Soft Computing*, 72:338–354.
- Eisert, J., Jacobs, K., Papadopoulos, P., and Plenio, M. B. (2000). Optimal local implementation of nonlocal quantum gates. *Physical Review A*, 62(5):052317.
- Liu, Z.-P., Cao, X.-Y., Liu, H.-W., Sun, X.-R., Bao, Y., Lu, Y.-S., Yin, H.-L., and Chen, Z.-B. (2025). Practical quantum federated learning and its experimental demonstration. *arXiv preprint arXiv:2501.12709*.
- Ludermir, T. B. (2022). *Weightless Neural Models: An Overview*, pages 335–349. Springer International Publishing, Cham.
- 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.
- Oliveira, W. R. d., Silva, A. J., Ludermir, T. B., Leonel, A., Galindo, W. R., and Pereira, J. C. (2008). Quantum logical neural networks. In *2008 10th Brazilian Symposium on Neural Networks*, pages 147–152.
- Peckham, J., Makaroff, D., and Rayan, S. (2024). Asynchronous telegate and teledata protocols for distributed quantum computing. In *2024 IEEE 10th World Forum on Internet of Things (WF-IoT)*, pages 1–6. IEEE.
- Preskill, J. (2018). Quantum computing in the nisy era and beyond. *Quantum*, 2:79.