

# 서버 집계 방식에 따른 양자 연합학습 알고리즘 분석

손석빈, 김중헌  
고려대학교

lydiasb@korea.ac.kr, joongheon@korea.ac.kr

## Analyzing quantum federated learning algorithms with server aggregation

Seok Bin Son, Joongheon Kim  
Korea Univ.

### 요약

본 논문은 양자 연합학습(Quantum Federated Learning, QFL)에서의 서버 집계 방식이 모델 성능에 미치는 영향을 분석한다. 세 가지 대표적인 집계 방식인 FedAvg, Weighted FedAvg, Server Momentum 을 비교 대상으로 하였으며, MedMNIST 데이터셋 기반 실험을 통해 각 방식의 정확도를 평가하였다. 실험 결과, FedAvg 와 Weighted FedAvg 가 높은 정확도를 기록한 반면, Server Momentum 은 수렴 안정성 측면에서 기대와 달리 낮은 성능을 보였다. 본 연구는 QFL 환경에서 상황에 따라 적절한 집계 전략 선택의 필요성을 강조한다.

### I. 서론

양자 컴퓨팅(Quantum Computing)의 발전과 함께, 양자 신경망(Quantum Neural Networks, QNN)의 분산 학습에 대한 관심이 높아지고 있다 [1]. 특히, 데이터가 여러 지점에 분산되어 있는 환경에서는 중앙 서버가 각 클라이언트의 데이터를 직접 수집하지 않고 모델 파라미터만을 공유하는 연합학습(Federated Learning) 기법이 적합하다 [2]. 이러한 연합학습을 양자 컴퓨팅 환경에 적용한 양자 연합학습(Quantum Federated Learning)은 양자 모델의 학습 가능성과 통신 효율성, 그리고 개인정보 보호 측면에서 주목받고 있다 [3]. 기존의 양자 연합학습 연구는 대부분 FedAvg 와 같은 단순 평균 기반의 집계 방식을 사용하였다. 하지만 클라이언트 간 데이터 분포가 상이하거나 학습이 불안정한 경우, 단순 평균 방식은 모델 수렴에 한계를 보인다 [4]. 따라서 본 논문에서는 서버에서의 집계(aggregation) 전략을 중심으로 다양한 방식이 양자 연합학습에 미치는 영향을 분석하고자 한다. 이를 위해 대표적인 세 가지 집계 방식(FedAvg, Weighted FedAvg, Server Momentum)을 비교하고, 그에 따른 양자 모델 성능 차이를 실험적으로 검증한다.

### II. One-shot Quantum NAS 알고리즘

양자 연합학습은 중앙 서버와 여러 클라이언트가 협력하여 양자 신경망을 학습하는 구조로, 다음과 같은 절차로 진행된다. 먼저 서버는 글로벌 모델을 초기화하여 각 클라이언트에게 전달한다. 이후 각 클라이언트는 로컬 데이터를 기반으로 자체적으로 양자 모델을 학습하며, 학습이 완료되면 각자의 모델 파라미터를 서버로 전송한다. 서버는 이 파라미터들을 집계하여 글로벌 모델을 갱신하며, 이 과정을 여러 차례 반복함으로써 전체 모델의 성능을 향상시킨다. 이때, 서버가 각 클라이언트의 모델을 어떻게 집계하느냐에 따라 전체 학습의 효율성과 성능이 달라질 수 있다.

본 논문에서는 대표적인 세 가지 집계 방식을 분석한다. 첫 번째는 가장 기본적인 방식인 Federated Averaging (FedAvg)이다 [4]. 이 방식은 모든 클라이언트의 모델 파라미터를 단순 평균하여 글로벌 모델을 업데이트하는 방식이다. 수식으로는  $w_{global} = \frac{1}{K} \sum_{k=1}^K W_k$  로 표현되며, 구현이 간단하고 대부분의 기본적인 연합학습 상황에서 효과적인 것으로 알려져 있다. 하지만 클라이언트 간의 데이터 양이 상이할 경우에는 모든 클라이언트의 기여도를 동일하게 보는 이 방식이 적절하지 않을 수 있다는 단점이 존재한다. 이러한 한계를 보완하기 위해 제안된 방식이 Weighted FedAvg (WFedAvg)이다 [4]. 이 방식은 각 클라이언트가 보유한 데이터의 양을 고려하여 모델 파라미터에 가중치를 부여하는 방식으로, 수식은  $w_{global} = \sum_{k=1}^K \frac{n_k}{n_{total}} W_k$  로 나타낼 수 있다. 여기서  $n_k$  는 클라이언트  $k$ 의 데이터 수를 의미하며, 전체 데이터의 합인  $n_{total}$  로 나누어 가중치를 부여한다. 이 방식은 데이터가 불균형하게 분포된 상황에서도 보다 안정적인 학습 성능을 기대할 수 있어, 클라이언트 간 데이터 크기 차이가 큰 경우에 적합하다. 마지막으로 살펴볼 방식은 Server Momentum (SM)이다 [5]. 이 방식은 글로벌 모델의 업데이트 과정에 모멘텀(momentum)을 도입함으로써, 과거 업데이트 방향을 일정 비율 반영하여 진동을 줄이고 수렴을 안정화시키는 데 목적이 있다. 수식으로는  $m_t = \mu m_{t-1} + (1 - \mu) \Delta_t, w_t = w_{t-1} - \eta m_t$  로 표현되며, 여기서  $\mu$ 는 모멘텀 계수,  $\eta$ 는 학습률,  $\Delta_t$ 는 현재 클라이언트로부터의 평균 업데이트를 의미한다. 이 방식은 특히 고비선형성 모델 또는 non-IID 데이터 환경에서 학습이 불안정하게 진행되거나 소수의 epoch 만을 사용할 수 있는 환경에서 유용하다. 이와 같이 각 집계 방식은 데이터 분포, 클라이언트 수, 연산 환경 등에 따라 상이한 장단점을 가지므로, QFL 환경에서는 상황에 맞는 집계 전략 선택이 성능 향상의 핵심 요소가 된다.

MedMNIST 데이터셋을 사용하여 50 epoch 동안 세




그림 1 서버 집계 방식별 양자 연합학습 정확도 비교

가지 서버 집계 방식을 비교한 결과, 그림 1 과 같이 FedAvg 와 WFedAvg 가 각각 65.63%와 65.7%의 정확도를 보여 가장 우수한 성능을 기록하였다. 반면, SM 은 42.89%로 상대적으로 낮은 정확도를 나타냈다. 이는 간단한 의료 영상 분류 문제에서는 단순 평균 기반의 FedAvg가 가장 효과적인 집계 전략일 수 있음을 시사하며, SM 방식은 오히려 과도한 누적 효과로 인해 수렴을 방해할 수 있음을 보여준다. WFedAvg 는 데이터 불균형이 클 경우에 더욱 유리할 수 있으나, 본 실험에서는 그 차이가 제한적이었다.

### III. 결론

본 연구에서는 양자 연합학습에서 사용되는 세 가지 대표적 서버 집계 방식을 비교 분석하였다. MedMNIST 기반 실험 결과, FedAvg 와 WFedAvg 는 높은 정확도를 보였으며, 특히 FedAvg 는 가장 간단하면서도 효과적인 방식으로 확인되었다. 반면, SM 은 본 실험 환경에서 수렴을 방해하며 성능이 저하되는 결과를 보였다. 이러한 결과는 데이터 특성과 환경에 따라 집계 전략을 적절히 선택하는 것이 QFL 성능 향상의 핵심임을 시사한다.

### ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2025-00561377).

### 참 고 문 헌

- [1] E. J. Roh, H. Baek, D. Kim and J. Kim, "Fast Quantum Convolutional Neural Networks for Low-Complexity Object Detection in Autonomous Driving Applications," *IEEE Transactions on Mobile Computing*, vol. 24, no. 2, pp. 1031-1042, February 2025.
- [2] D. Kwon, J. Jeon, S. Park, J. Kim, and S. Cho, "Multiagent DDPG-Based Deep Learning for Smart Ocean Federated Learning IoT Networks," *IEEE Internet of Things Journal*, vol. 7, no. 10, pp. 9895-9903, October 2020.
- [3] S. B. Son and S. Park, "Toward Uniform Quantum Federated Aggregation: Heterogeneity Exclusion Using

Entropy and Fidelity," *IEEE Internet of Things Journal*, vol. 12, no. 5, pp. 5732-5741, 1 March 2025.

- [4] B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, "Communication-efficient Learning of Deep Networks from Decentralized Data," In *Proc. of the Artificial intelligence and statistics*, Lauderdale, FL, USA, April 2017, pp. 1273-1282.
- [5] J. Sun, X. Wu, H. Huang, and A. Zhang, "On the Role of Server Momentum in Federated Learning," In *Proc. of the AAAI Conference on Artificial Intelligence*, Vancouver, Canada, Vol. 38, No. 13, March 2024, pp. 15164-15172.