

위성-지상 기지국 간 슬림형 양자 인공 신경망을 활용한 동적 양자 연합학습 프레임워크

윤원준, 김재평, *정소이, † 박지홍, 김중현

고려대학교, *아주대학교, † Deakin 대학

ywjoon95@korea.ac.kr, paulkim436@korea.ac.kr *sjung@ajou.ac.kr,

† jihong.park@deakin.edu.au, joongheon@korea.ac.kr

Dynamic Quantum Federated Learning Framework at Satellites and Ground Stations using Slimmable Quantum Neural Networks

Won Joon Yun, JaePyoung Kim, Soyi Jung, Jihong Park, Joongheon Kim*


Korea Univ., Ajou Univ., Deakin Univ.

요약

최근 LEO(Low Earth Orbit) 위성의 발전으로 통신 볼모지를 없애는 것이 가능해졌다. 특히, 양자 장치와 위성 간의 링크를 실용적인 가능성이 있다. 본 논문에서는 위성-지상 통신에서 최초의 양자 연합 학습 애플리케이션을 제안한다. 통신 및 컴퓨팅 성능을 개선하기 위해 양자 신경망에서 두 가지 다른 구성인 각도 및 극 구성을 허용하는 슬림형 양자 연합 학습 및 양자 신경망을 사용한다. 또한 중첩 코딩 및 연속 디코딩을 사용하여 통신 기회를 늘린다. 실험을 통해 우리는 프레임워크가 작동하고 고전적인 연합 학습 및 표준 양자 연합학습에 비해 계산 및 통신 측면에서 모두 효율적임을 실험을 통해 확인하였다.

1. 서론

시장조사보고서[1]에 의하면 전세계적 위성 통신 시장은 2027년 안에 453억원의 가치를 가질 것이고, 2020년부터 2027년까지 8.1%의 누적 연간 성장률을 기록할 것이라고 추정되고 있다. 이런 폭발적인 성장의 배경에는 위성 기반 브로드밴드 서비스와 고처리량 저궤도 (LEO) 위성 같이 고도화된 위성 기술이 있다. LEO 위성들은 최근에 전쟁으로 인해 접근이 어려워진 우크라이나 같은 지역 혹은 외진 지역에 통신망을 제공하기 위해 사용된다. LEO 위성을 통해 다양한 사이트를 가지고 있는 연합학습 (FL)도 위성 기술의 적용 방법으로 제시되었고, 특히 다수의 양자 컴퓨터를 사용한 양자 심층 학습(QDL)을 기반으로 한 적용 사례가 강조되었다 [2]. LEO 위성들을 로컬 QDL 기기들의 연합학습을 사용한다면 통신 효율과 컴퓨팅 자원 측면에서 많은 이득을 가져올 수 있다. LEO 위성은 특히 학습 가능한 파라미터를 백홀 (backhaul) 연결을 통해 송수신 할 때 발생하는 고정 통신 비용을 위성의 궤도이동으로 인해 크게 감소시킬 수 있다. 이 논문에서는 양자 컴퓨터와 양자 연합학습(QFL)에서 지상-위성간 통신이 가져오는 통신과 컴퓨팅 자원 효율을 최대한 사용하기 위해 이 기술들을 도입하고자 한다. 양자 컴퓨터들은 고전 컴퓨터들에 비해 더 효율적으로 연산을 할뿐만 아니라 양자 통신은 더 확장될 가능성을 가지고 있다. 이런 접근법은 로컬 기기들의 자원을 운용할 수 있게끔 해준다. 양자 비트(큐비트)는 양자 컴퓨터에서 사용되는 기본적인 연산 단위이고, 중첩 상태로 존재한다. 또한, 특정 작업들을 고전 컴퓨팅에 비해 훨씬 효율적으로 수행하는 것이 가능하다. 큐비트가 증가는 곧 양자 노이즈의 증가를 의미하지만, 동시에 더 큰 양자 상태 공간을 제공하기도 한다. 이는 곧 양자 우월성으로 이어질 수 있다. 양자 상태 공간을 최대한 활용하기 위한 하나의 접근법은 각 (angle) 영역이라고 불리는 파라미터화 된 회로 영역과 축 (pole)영역이라고 불리는 학습 가능한 측정 여역을 동시에 사용하는 것이다. 이 접근법은 논문에서 사용되는 *slimmable quantum federated learning* (SQFL)이라는 모델이다. 이 모델은 로컬 기기에서 각과 축 파라미터를 학습하고, superposition coding (SC)를 통해 인코딩하여 서버로 송신한다. 신호는 수신 후, successive decoding(SD)를 통해 신호 디코딩을 진행한다. 이 과정을 통해 다른 QFL 기법에 비해 더 좋은 통신 효율과 성능을 보인다. 해당 논문은 최초로 QFL을 위한 지상-위성간 통신에 .



주요 연산 프로세스

- ① 지상 QDL 디바이스에서 로컬 학습
- ② 중첩 코딩을 활용한 위성 업링크 통신
- ③ 연속 디코딩을 이용한 서버단 sQNN 취합
- ④ 위성 다운링크 통신 및 로컬 모델 업데이트

위성 서버 구성 요소



지상 QDL 장치 구성 요소



그림 1 위성-지상간 SQFL 통신 framework

기반한 새로운 접근법을 제시한다. 이 방법은 SQFL로 양자 컴퓨팅의 강점을 사용하고 SC와 SD를 통해 고전 컴퓨팅에 비해 더 원활한 통신을 달성한다.

II. LEO 위성-지상간 통신에서의 동적 양자 연합학습 프레임워크

II-1) 시스템 개요

이 논문에서는 N개의 로컬 QDL 기기가 분류 작업을 위해 사용되는 시나리오를 가정한다. 위성과 지상 QDL 기기들이 모두 단일 안테나를 가지고 있다는 가정 하에, [5]에서 나오는 채널 모델을 사용한다. 또한, 기기의 업링크 통신만 고려되고, 각 기기에서 두 개의 다른 폭 구성에 상응하는 두 개의 신호를 송신한다. 신호의 밴드 대역폭은 기기들 사이에서 동일하게 배분되기 때문에 유저간 간섭은 무시할 수 있지만, 위성과 지상 기기 간의 통신 간섭은 노이즈로 고려한다. 가우시안 코드북을 통해 정의되는 Shannon's capacity 식을 사용하여 통신 성능을 이상적인 소스와 채널 코딩의 가정 하에 분석한다 [6].

II-2) Pole-to-Angle 로컬 학습

여기서는 pole-to-angle 로컬 학습에 관해 설명한다. 각과 축 파라미터는

Model\ t	0	20	40	60	80	100
Proposed	0	57.5	62.5	63.33	63.31	63.32
Quantum FL	0	58	61.67	62.6	62.64	62.64
Classical SlimFL	0	50	56.43	58.71	58.99	59.4

표 1 평균 SNR vs Top-1 Accuracy

Model\ SNR	10	12.5	15.0	17.5	20
SQFL	53.97	59.34	59.41	60.01	62.03
QFL	51.97	56.95	57.76	58.94	61.62
Classical	35.23	44.71	52.29	52.89	59.55

표 2 학습 곡선 (α, γ)=(100,20)

Model\ α	0.1	0.5	1	10
SQFL	58.83	59.6	62.78	63.43
QFL	58.32	57.99	58.94	62.95
Classical	44.44	44.93	45.97	59.44
Standalone	24.66	25.19	42.95	58.33

표 3 Non-IIDness vs Top-1 Accuracy

각각 Θ_n, Φ_n 로 나타낼 수 있다. Θ_n 는 D개의 학습 가능한 파라미터를 가지고 Φ_n 는 2개의 학습 가능한 파라미터를 가지게 된다. Φ_n 의 파라미터가 Θ_n 의 파라미터보다 작기 때문에 축이 더 빠른 수렴 달성을 할 것이라 예상하고 축 학습을 먼저 진행하고 각 학습을 한다. 각 파라미터 수가 축 파라미터보다 $\frac{D}{2}x$ 배 많기 때문에 각 영역의 공변량 변화(covariance shift)에 대해 견고성을 가진다. [7]. Pole-to-angle 로컬 학습은 데이터 분포로 인해 공변성 변화가 있는 FL 모델에 이득을 가져올 수 있다고 주장한다. 각 기기는 축 파라미터를 L번 동안 기기의 로컬 데이터에서 샘플링하여 학습하고 각 파라미터를 학습한다. 최적화를 위해서는 cross entropy loss를 이용한다.

II-3) 위성-지상간 채널에서의 superposition coding

기기와 위성이 통신이 일어날 때마다 n 번째 기기는 quantum slimmable neural network (QSNN) 구조를 사용하여 통신 채널의 상태, 주어진 전력 및 다른 시변 환경 요소들에 따라 축 파라미터만 송신하거나, 각 파라미터까지 둘 다 송신한다. 지상에 있는 로컬 QDL 기기는 같은 라디오 자원 블록을 사용하여 신호를 서버에게 송신한다. 각 기기는 신호를 이루는 원본 데이터를 코드율 (code rate) u 로 인코딩한다. 유저의 위치가 고정되어 있을 때, small-scale 및 large-scale fading으로 고려하여 QDL 로컬 기기와 LEO 위성 간의 채널 모델을 정의한다.

II-4) Successive decoding을 사용한 model aggregation

서버가 송신 신호를 수신할 때, 신호에는 가산성 백색 가우시안 노이즈 (AWGN)이 첨가된다. n 번째 신호를 통해 신호 대비 간섭 비율 (SINR)을 정의한다. Shannon's capacity 식과 가우시안 코드북 [8]을 사용하여 해당 신호가 통신 채널의 주파수에서 가지는 처리율을 알 수 있다. 만약 송신기가 u 의 코드율로 신호를 인코딩한다면, 모든 기기에서 송신한 신호를 모두 수신해야지만 인코딩된 신호를 확정적으로 디코딩한다. 각각 기기에서 온 디코딩된 신호를 모두 종합하여 글로벌 QSNN을 설계한다. 이 글로벌 모델은 다시 각 로컬 기기들에게 송신되고, 기기들은 최신판 모델 을 사용하여 다시 데이터 수집 및 로컬 모델 학습을 진행하여 다음 학습 회차로 넘어가게 된다. 이 과정은 수렴이 달성될 때까지 반복된다.

III. 실험 결과

III-1) 실험 설정

본 논문에서 제시된 모델과 비교를 위해 벤치마크 모델이 설계되었다. 사용된 프레임워크들은 모두 동일하게 다양한 평균 SNR 실험을 진행하였다. 또한, non-identically distributed data (non-IID) 데이터가 SQFL 모델에 끼치는 영향을 분석하기 위해 *Dirichlet* 계수 α [9]에 기반한 데이터

분할 방법을 사용한다. sQNN에서 학습할 수 있는 파라미터 수는 82로, 80개의 각 파라미터와 2개의 축 파라미터로 이뤄져있다. 초기 학습률 계수는 0.01이고, Adam optimizer을 통해서 sQNN의 학습을 진행한다.

III-2) 정량적 결과

일단 SNR의 영향을 알기 위해 표 1의 실험으로 평균 SNR과 top-1 accuracy 간의 관계를 알아낼 수 있었다. SNR이 낮을 때, top-1 accuracy는 비교적 낮은 수치를 보이고 그 반대로 높은 SNR에서는 수렴 한계에 가까운 값을 보인다. SQFL 모델은 QFL 모델에 비해 SC와 SD를 사용하여 통신율을 증가시켰기 때문에 낮은 SNR임에도 불구하고 더 좋은 성능을 보인다. 따라서, 논문에서 제시된 SQFL 모델이 QFL 모델에 비해서 낮은 SNR에 견고하다. 표 2는 양자 컴퓨팅을 사용했을 때 얻을 수 있는 이득에 대한 실험으로 완벽한 통신 조건과 IID한 데이터를 가진 SQFL, QFL, 고전 FL의 top-1 accuracy를 보인다. SQFL과 QFL은 고전 FL에 비해서 각각 약 3.65%, 3.22% 높은 성능을 가지고 있다. 이 결과는 동일한 수의 파라미터를 가진 양자 컴퓨팅의 모델이 고전 컴퓨팅 모델보다 좋은 성능을 보인다는 [3]의 결과와 상응한다. 마지막으로, 4개의 *Dirichlet* 계수 집합을 가지고 non-IID한 데이터가 어떻게 성능 저하에 기여하는지 알아보는 실험을 진행하였다. α 의 값이 높을 때는 데이터가 IID에 가깝고, 낮은 α 는 데이터가 non-IID에 가깝다는 의미이다. 표 3은 α 와 top-1 accuracy의 관계를 보여준다. α 가 작아질수록 모든 모델의 성능이 저하되고 α 가 가장 높은 값이 10일 때 성능이 가장 높다. 결정적으로, 이 논문에서 사용한 SQFL이 데이터가 non-iid에 가까워지더라도 다른 모델에 비해 가장 작은 폭의 성능 저하를 겪는다. 따라서, 본 논문의 모델은 non-IID 데이터에 대한 견고함을 보인다.

IV. 결론

이 논문은 위성-지상 간 통신을 위한 sQNN을 사용하는 동적 할당 가능한 양자 연합학습 프레임워크를 제시하였다. Pole-to-angle 학습과 SC, SD와 결합시킴으로써, 제시된 SQFL 모델은 다른 기존 모델들의 통신과 컴퓨팅 자원 측면의 높은 성능을 증명하였다. 또한, SQFL 모델이 낮은 SNR과 non-IID 데이터 견고성을 증명할 수 있었다.

ACKNOWLEDGMENT

본 연구는 한국연구재단 기초연구실지원사업(2021R1A4A1030775)의 연구비 지원으로 수행됨. 본 논문의 교신저자는 정소이, 박지홍, 김중현 임.

참고 문헌

- [1] The Business Research, Low earth orbit (LEO) satellites global market report 2020-30: COVID-19 growth and change (2021).
- [2] Y. Kwak, W. J. Yun, J. P. Kim, H. Cho, J. Park, M. Choi, S. Jung, J. Kim, Quantum distributed deep learning architectures: Models, discussions, and applications, *ICT Express* (2022) 1 - 7.
- [3] W. J. Yun, J. Park, J. Kim, Quantum multi-agent meta reinforcement learning, in: *Proc. AAAI Conference on Artificial Intelligence*, Washington DC, USA, 2023.
- [4] W. J. Yun, J. P. Kim, S. Jung, J. Park, M. Bennis, J. Kim, Slimmable quantum federated learning, in: *Proc. of ICML Workshop on Dynamic Neural Networks*, Baltimore, Maryland, USA, 2022.
- [5] L. You, X. Qiang, C. G. Tsinos, F. Liu, W. Wang, X. Gao, B. Ottersten, Beam squint-aware integrated sensing and communications for hybrid massive MIMO LEO satellite systems, *CoRR* abs/2203.00235.
- [6] W. J. Yun, Y. Kwak, H. Baek, S. Jung, M. Ji, M. Bennis, J. Park, J. Kim, SlimFL: Federated learning with superposition coding over slimmable neural networks, *IEEE Transactions on Networking*.
- [7] N. Tripuraneni, B. Adlam, J. Pennington, Overparameterization improves robustness to covariate shift in high dimensions, *Advances in Neural Information Processing Systems* 34 (2021) 13883 - 13897.
- [8] C. E. Shannon, A mathematical theory of communication, *The Bell System Technical Journal* 27 (3) (1948) 379 - 423.
- [9] T. H. Hsu, H. Qi, M. Brown, Measuring the effects of nonidentical data distribution for federated visual classification, in: *Proc. NeurIPS Federated Learning for Data Privacy and Confidentiality Workshop*, Vancouver, Canada, 2019.