

데이터 재입력과 퀀텀 합성 곱 신경망에 대한 연구 동향

백한결¹, 윤원준², 김중현³
고려대학교67back@korea.ac.kr¹, ywjoon95@korea.ac.kr², joongheon@korea.ac.kr³

Trends in Data-reuploading and Quantum Convolutinal Neural Network

Hankyul Baek¹, Wonjoon Yun², Joongheon Kim³
Korea University

요 약


퀀텀 컴퓨팅의 발전에 따라 이를 활용한 퀀텀 머신 러닝(QML: Quantum Machine Learning)의 발전 속도가 가속화되고 있다. QML 은 퀀텀 컴퓨팅의 특성으로 인하여 수많은 정보를 빠르게 처리할 수 있다는 점에서 매우 효율적이다. 하지만 사용되는 큐비트 (Qubit: Quantum Bit)의 개수가 증가할수록 전체 시스템의 미분계수가 사라져 학습이 불가능한 현상 (Barren Plateaus) 현상으로 인하여, 학습의 입력 값의 크기가 제한된다는 한계가 존재한다. 본 논문에서는 이를 해결하기 위한 방법인 데이터 재입력 (Data Re-uploading)방법에 대하여 알아본다. 이후, 이를 실제 QML 어플리케이션에 활용하여 그 효용성에 대하여 알아본다.

I. 서 론

퀀텀 컴퓨팅 기술이 비약적으로 발전함에 따라, 이를 활용한 많은 어플리케이션이 연구되고 있다 [1, 2]. 이중 퀀텀 머신러닝 (QML)은 퀀텀 컴퓨팅의 특성을 활용하여 기존 뉴럴 네트워크 (NN: Neural Network)가 해결하지 못하였던 문제점들을 해결할 수 있으면서, 동시에 연산 복잡도에서 우위에 있기에 차세대 인공지능으로써 많은 관심을 받고 있다. 이는 퀀텀 컴퓨팅의 기본 연산 단위가 일반적인 컴퓨터의 비트(Bit)가 아닌 큐비트(Qubit: Quantum Bit)이기 때문이다. Qubit 은 0, 1 의 값을 확정적으로 가지는 Bit와 다르게, 각각의 측정 시마다 0 또는 1 의 값을 가질 수 있다. 이는 컴퓨팅의 메모리 관점에서 연산 가능 량을 선형적 증가가 아닌, 지수적 증가 관점에서 가져올 수 있기에 매우 큰 효용성을 가지고 있다. 이에 따라 매우 방대한 연산과 메모리를 요하는 머신 러닝 (ML: Machine Learning) 분야에서 이를 활용하기 위한 연구들이 진행되고 있다. 하지만 QML 을 저 차원 데이터에서 벗어나 대용량, 고차원의 크기를 가진 입력 데이터를 분석하는 업무에 사용하기 위해서는 해결해야할 문제점이 존재한다. 이는 고차원의 크기를 가진 입력 데이터를 퀀텀 데이터로 인코딩 하기 위하여 Qubit 의 개수를 늘리게 되면 모델의 그라디언트가 사라지는 문제 (Vanishing Gradient)가 발생하게 된다. 이러한 vanishing gradient 문제의 발생으로 인하여, 큐비트의 개수를 확대하지 않고 적은 Qubit 만을 사용하여 QML 을 진행할 수 있도록 하기 위하여 여러 연구들이 진행되었다. 그 중 대표적인 방법으로 데이터 리업로딩(Data Re-uploading), 하이브리드 퀀텀 머신러닝 (HQML: Hybrid Quantum Machine Learning), 퀀텀 합성곱 신경망(Quantum Convolutinal Neural Network)를 들 수 있다. 인코딩 단계에서 동일한 Qubit 에 데이터를 여러 번 입력할 수 있게 하는 data re-uploading 방법과, 퀀텀 회로를 합성곱 신경망(CNN: Convolutional Neural Network)에서의 필터의 역할을 수행하는 학습가능한 필터 (Trainable Filter)로 활용하여 학습을 진행하는 QCNN 방법은 많은 분야에서 연구되었다. 본 논문에서는 이러한 QML 의 발전 방향에 발 맞추어, 실제 Data re-uploading 방법과 QCNN 방법을 통하여 성능향상을

나타낼 수 있는 지 확인하고, QML 을 통하여 고차원의 데이터를 활용하는데 필요한 방법에 대해서 토의한다.

II. Data Re-uploading



[그림 1] Data Re-uploading


Qubit 에 Classical Data 를 Embedding 시킬 수 있는 방법으로, 기저 인코딩(Basis Encoding), 각 인코딩(Angle Encoding), 진폭 인코딩(Amplitude Encoding) 등 여러 인코딩 방법들이 제안되었다. 이러한 인코딩 방법은 기존 Bit 데이터를 Qubit 으로 변환시켜 QML 이 데이터를 입력 받을 수 있도록 하는 역할을 한다. 예를 들어 분석을 원하는 k -bit 로 표현된 데이터세트 가 있다고 가정하자. 이 데이터세트 안의 하나의 데이터를 $x = (d_1, d_2, d_3, \dots, d_k)$ 라고 하자. 여기서 $\forall d \in \{0,1\}$ 을 만족한다. 데이터를 입력 Qubit 의 상태 값 $|\psi\rangle$ 에 인코딩 시키기 위하여 다음과 같은 프로세스를 생각할 수 있다 [3].

$$|\psi\rangle = U(x)|0\rangle^{\otimes n}.$$


여기서, n 은 학습시킬 퀀텀 회로의 Qubit 의 개수, $U(\cdot)$ 은 유니타리 행렬을 나타낸다 [1]. 이번에는 범위를 확장시켜 앞서 살펴본 데이터 x 가 데이터 y 의 부분집합 (Patch)라고 정의한다. 그렇다면 다음과 같이 데이터 y 를 다음과 같이 정의할 수 있다 $y \approx \{x_i | i = 1, 2, \dots, \frac{|y|}{|x|}\}$. 여기서 $|y|$ 와 $|x|$ 는 각각 데이터 y 와 x 의 크기이다. 그렇다면 다음과 같은 Data re-uploading 방법을 고려할 수 있다 [4].

$$|\psi\rangle = \prod_{m=1}^{|y|/|x|} U(\theta_m)U(x_m) |0\rangle^{\otimes n}.$$

III. QCNN




[그림 2] Hybrid QCNN



[그림 3] QCNN

QCNN 은 QML 의 학습을 담당하는 퀀텀 회로를 NN 에서의 학습가능한 필터와 같이 활용하여 데이터 분석을 하는 회로이다. QML 에서 측정 (Measurement)을 통하여 CNN 에서의 Pooling 과 같은 기능을 수행할 수 있다. 그림 2 와 3 은 각각 Hybrid QCNN 과 일반적인 QCNN 을 나타낸다. U 는 유니타리, P 는 Pooling 을 나타낸다. Hybrid QCNN 은 QCNN 의 말미에 NN 중 완전 연결 레이어(FCN: Fully Connected Network)에 연결하여 분류 업무의 클래스를 늘려 다중 클래스 분류를 가능하게 한다 [5]. 이러한 QCNN 은 퀀텀 컴퓨팅의 발전에 맞추어 다양한 성능을 갖추도록 연구되어 왔다. 대표적으로, Barren Plateaus 현상을 피하기 위하여, 동일한 Qubit 개수를 가진 필터를 여러 개 사용하여 필터의 개수를 늘리는 연구가 진행되었다[6]. 또한 입력 차원이 매우 높은 3 차원 데이터를 이러한 QCNN 을 통하여 분석하는 연구가 활발히 진행되었다 [7].

V. 성능평가



[그림 4] QCNN 기반 FMNIST Top-1 Accuracy

그림 4 는 앞서 설명한 Hybrid QCNN 을 활용하여 FMNIST 데이터셋을 분류 작업하였을 때 얻을 수 있는

Top-1 Accuracy 그래프이다. Hybrid QCNN 을 사용하였을 경우 합리적인 Top-1 Accuracy 를 획득하였다.

VI. 결론

본 논문에서는 입력 벡터의 차원이 큰 데이터를 분석할 수 있는 방법으로 Data Re-uploading 과 QCNN 에 대하여 알아보았다. Data Re-uploading 방법을 통하여 우리는 동일한 퀀텀 시스템에 더욱 많은 입력 값을 제시할 수 있고 이는 곧 Barren Plateaus 를 예방할 수 있음을 알아보았다. QCNN 에서는 더불어 퀀텀 회로를 필터로 사용하여 입력할 수 있는 데이터의 양에 제한되지 않고 이미지를 분석할 수 있음을 보였다. 실험을 통하여 대표적으로, QCNN 을 통하여 Fashion MNIST Classification 을 수행하였을 때, 합리적인 성능을 얻을 수 있는 것을 확인하였다. 이를 통하여 다가오는 Beyond NISQ 시대에 맞추어, QML 을 통한 이미지 분류 작업이 활성화될 것을 기대한다.

ACKNOWLEDGMENT

본 연구는 한국연구재단 기초 연구실 지원 사업 (2021R1A4A1030775)의 연구비 지원 및 과학기술 정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터 육성지원사업의 연구결과로 수행되었음 (IITP-2022-2017-0-01637*). 본 논문의 교신저자는 김중현임.

참고 문헌

- [1] W. J. Yun et al., "Cooperative Multiagent Deep Reinforcement Learning for Reliable Surveillance via Autonomous Multi-UAV Control," *IEEE Transactions on Industrial Informatics*, vol. 18, no. 10, pp. 7086-7096, October 2022.
- [2] W. J. Yun, J. Park, and J. Kim, "Quantum multi-agent meta reinforcement learning," *CoRR*, vol. abs/2208.11510, 2022.
- [3] W. J. Yun, Y. Kwak, J. P. Kim, H. Cho, S. Jung, J. Park, and J. Kim, "Quantum multi-agent reinforcement learning via variational quantum circuit design," in *Proc. IEEE International Conference on Distributed Computing Systems (ICDCS)*, Bologna, Italy, July 2022.
- [4] A. P ´erez-Salinas, A. Cervera-Lierta, E. Gil-Fuster, and J. I. Latorre, "Data re-uploading for a universal quantum classifier," *Quantum*, vol. 4, p. 226, February 2020.
- [5] W. J. Yun, J. P. Kim, S. Jung, J. Park, M. Bennis, and J. Kim, "Slimmable quantum federated learning," *Proc. ICML Workshop on Dynamic Neural Networks*, Baltimore, MD, USA, July 2022.
- [6] H. Baek, W. J. Yun, and J. Kim, "Scalable quantum convolutional neural networks," *CoRR*, vol. abs/2209.12372, 2022.
- [7] H. Baek, W. J. Yun, and J. Kim, "3d scalable quantum convolutional neural networks for point cloud data processing in classification applications," *CoRR*, vol. abs/2210.09728, 2022.