

퀀텀 머신 러닝 기반 드론 모빌리티 제어

박찬영, 박수현, 정소이*, 최민석**, 김중헌

고려대학교, *아주대학교, **경희대학교

cosdeneb@korea.ac.kr, soohyun828@korea.ac.kr,

*sjung@ajou.ac.kr, **choims@khu.ac.kr, joongheon@korea.ac.kr

Drone Mobility Control based on Quantum Machine Learning

Chanyoung Park, Soohyun Park, Soyi Jung*, Minseok Choi**, Joongheon Kim

Korea Univ., *Ajou Univ., **Kyung Hee Univ.

요 약

고전 컴퓨터에 비해 많은 양의 정보량을 표현할 수 있는 퀀텀 컴퓨터의 비약적인 발전 속도에 맞추어, 퀀텀 컴퓨팅을 이용하여 많은 연산량 및 메모리를 요구하는 퀀텀 머신 러닝을 발전시키기 위한 연구가 활발히 진행되고 있다. 본 논문에서는 퀀텀 컴퓨팅을 활용한 머신 러닝을 통해 효율적으로 드론 모빌리티를 제어하는 기법에 대해 소개한다.

I. 서 론

우리가 마주하는 일반적인 고전 컴퓨터는 전기를 활용해 트랜지스터를 제어하여 0 또는 1의 이진수 값을 가지도록 함으로써 전기적 신호를 처리한다. 이렇게 제어한 하나의 정보를 비트(Bit)라 하며, 이는 컴퓨터의 기본 연산 단위이다. 따라서, 하나의 비트를 사용하면 총 2가지의 정보를 표현할 수 있기 때문에 n 개의 비트를 사용하면 2^n 개의 정보를 표현할 수 있다. 그러나 일반적인 컴퓨터와 다르게, 양자의 중첩 상태를 이용한 큐비트(Qubit: Quantum Bit)를 사용한다. 큐비트는 0과 1 값이 중첩된 상태로 존재하기 때문에 고전 컴퓨터의 비트보다 훨씬 많은 정보의 양을 표현할 수 있다. 이러한 특징을 가진 퀀텀 컴퓨터는 가벼운 파라미터 수와 연산 속도를 이용하여 많은 연산 및 메모리를 요구하는 분류 모델, 강화학습, 패턴 인식, 등 머신 러닝 분야에서 큰 주목을 받고 있다 [1]. 퀀텀 컴퓨터를 활용한 머신 러닝 기술을 퀀텀 머신 러닝(QML: Quantum Machine Learning)이라고 부르며, 일반적인 인공 신경망을 사용한 머신 러닝과 동일한 파라미터 수를 사용하여 비교하였을 때 퀀텀 머신 러닝을 사용하였을 때 성능이 더 좋다는 사실을 입증하는 많은 연구가 진행되고 있다 [2]-[3]. 이러한 장점은 특히 매우 많은 연산량을 요구하는 심층 강화 학습을 통해 기계를 학습시킬 때 더 유리하다. 심층 강화학습은 비디오 게임, 로봇 제어, 영상 및 이미지 처리 등 다양한 분야에서 활용되는 머신 러닝 기술이기 때문에 심층 강화학습을 이용한 머신 러닝 기술을 발전시키는 것은 큰 의미가 있다 [4].

따라서 본 논문에서는 퀀텀 머신 러닝의 구성 요소에 대해 설명하고, 이를 기존의 인공 신경망을 활용한 머신 러닝과 비교한다. 나아가 퀀텀 머신 러닝을 활용한 양자 심층 강화학습에 대해 설명하고, 이를 통해 자율적인 드론 모빌리티를 제어하는 시스템을 구축하는 기법을 제안한다.

II. 퀀텀 머신 러닝

그림 1을 통해서 인공 신경망의 구조를 대체한 퀀텀 머신 러닝 모델의 양자 회로를 직관적으로 확인할 수

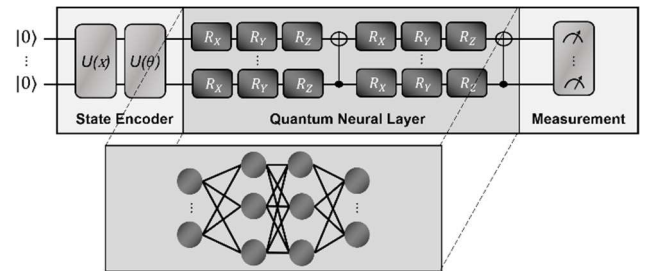


그림 1 퀀텀 머신 러닝 모델 구성

있다. 퀀텀 머신 러닝 모델은 그림 1처럼 총 3가지의 레이어로 구성이 되며, 각각의 레이어에 해당하는 구성 요소는 상태 인코더(State Encoder), 파라미터화 된 양자 회로(PQC: Parameterized Quantum Circuit), 측정 장치(Measurement)이다 [5]. 가장 먼저 맞닥뜨리게 되는 상태 인코더란, 고전적인 비트를 회전 게이트를 통과시켜 퀀텀 컴퓨팅에 사용할 수 있는 큐비트로 전환시켜주는 매개체에 해당한다. 인코딩 과정에 대한 수학적 표현은 다음 식과 같다.

$$|\psi_{enc}\rangle = U(\theta_N)U(x_N) \dots U(\theta_1)U(x_1)|\psi_0\rangle$$

파라미터화 된 양자 회로에는 각 큐비트의 양자 상태를 x, y, z 축으로 회전시킬 수 있는 게이트가 존재하며, 이에 대한 가중치 조절을 통해 큐비트 간의 양자 얽힘을 설계할 수 있다.

$$|\psi_{PQC}\rangle = U(\theta_{PQC})|\psi_{enc}\rangle$$

마지막 구성요소인 측정 장치는 적절히 회전시킨 큐비트에 대해 하나의 축에 대해 사영하여 원하는 벡터를 갖도록 하며, 일반적으로 z 축에 대해 사영한다.

이러한 측정 과정을 통해서 큐비트의 켄텀 상태가 측정이 되면, 비로소 켄텀 상태가 붕괴가 되어 관측 가능한 상태가 된다.

기존의 인공 신경망은 많은 파라미터를 가지고 있기 때문에 비정상성 및 불안정성이라는 특징을 가진다. 이와 비교하였을 때 켄텀 머신 러닝은 큐비트를 활용하여 적은 양의 파라미터 수를 가지지만 빠른 연산 속도를 가지고 있다. 이러한 켄텀 머신 러닝의 장점을 이용한 양자 심층 강화학습에 대한 연구가 활발히 진행이 되고 있으며 [6], 이에 본 논문에서도 켄텀 머신 러닝 기반의 드론 모빌리티 제어 기법을 제안한다.

III. 켄텀 머신 러닝 기반 드론 모빌리티 제어

드론의 민첩성과 이동성을 이용하면, 기존의 모빌리티로 접근하기 어렵거나 비용이 많이 드는 지역에 저렴하고 신속하게 서비스를 제공할 수 있다. 그러나 드론이 존재하는 환경에는 장애물이나 드론의 배터리 상태 등 예측할 수 없는 요소들이 존재한다. 따라서, 이러한 불확실한 요소들에 대해 자율적이고 적응적으로 대처할 수 있는 기술의 필요성이 대두되었으며, 해당 문제를 해결하기 위해 심층 강화학습을 이용하여 자율적인 드론 모빌리티를 제어하여 적응적으로 다양한 서비스를 제공하는 연구가 활발히 진행되고 있다 [7]~[8]. 드론의 크기는 자동차, UAM 등 다른 모빌리티들과 비교하였을 때 매우 작고 가볍기 때문에 외부 자극이나 드론의 현재 상태에 대해 매우 민감하다. 따라서 자율적인 드론 모빌리티 서비스를 구축하기 위해서는 안정적이고 비교적 가벼운 시스템이 필요하다. 본 논문은 이러한 드론의 문제를 해결하기 위해서 켄텀 머신 러닝 기반으로 드론의 위치를 스스로 결정하게 함으로써 효율적으로 모빌리티를 제어하는 기법에 대해 소개한다.

본 논문에서는 드론이 ICT 통신이나 감시 등 다양한 서비스를 제공할 때 여러 드론들이 자신이 현재 관찰하고 있는 환경 정보에 대해서 가능한 많은 사용자에게 좋은 퀄리티의 서비스를 제공하게끔 심층 강화학습의 보상 함수를 설정하였다. 이 때 켄텀 컴퓨터를 드론에 실을 수 없기 때문에 중앙의 클라우드 서버에서 중앙 집중식으로 학습을 진행하고, 분산적으로 각각의 드론을 실행시키는 상황을 고려하였다. 중앙 집중식으로 학습함으로써 각각의 드론이 서로 다른 정보를 관찰함에도 불구하고 클라우드 서버에서 여러 드론의 정보를 학습할 수 있기 때문에 협력적으로 서비스를 제공할 수 있다. 이에 대해 학습을 진행한 결과는 그림 2에서 확인할 수 있다. 기존의 인공 신경망보다 더 적은 수의 파라미터를 가진 켄텀 머신 러닝을 활용해 학습을 진행했을 때 더 안정적이고 빠른 수렴 속도를 보이며, 학습 종료 후 더 높은 보상을 얻는 것을 확인할 수 있다. 이는 더 많은 사용자에게, 더 좋은 퀄리티의 서비스를 제공함을 의미한다.

IV. 결론

본 논문에서는 켄텀 컴퓨터를 활용한 켄텀 머신 러닝에 대해 소개하고, 이를 통해 기존 인공 신경망보다 안정적이고 효율적으로 드론 모빌리티를 제어하는 기법에 대해 제안하고 성능을 확인하였다. 현재까지도 켄텀 컴퓨터 기술을 개발하는 연구가 활발히 진행되고 있으며, 양자 잡음이 무시되는 규모를 벗어나게 되는 시대가 도래하게 될 트렌드에 발맞추어 켄텀 컴퓨터에 대한 지식을 갖추는 것이 중요하다고 판단된다.

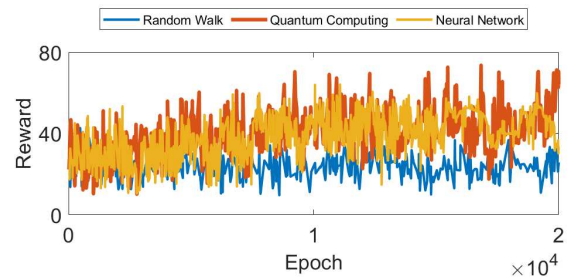


그림 2 켄텀 머신 러닝 기반 심층 강화학습 결과

ACKNOWLEDGMENT

이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. 2022-0-00907, (2 세부) AI Bots 협업 플랫폼 및 자기조직 인공지능 기술 개발). 본 논문의 교신저자는 김중현임.

참 고 문 헌

- [1] F. Arute, K. Arya, R. Babbush, D. Bacon, J. C. Bardin, R. Barends, R. Biswas, S. Boixo, F. G. Brandao, D. A. Buell et al., "Quantum supremacy using a programmable superconducting processor," *Nature*, vol. 574, no. 7779, pp. 505-510, 2019.
- [2] J. Choi, S. Oh, and J. Kim, "A tutorial on quantum graph recurrent neural network (QGRNN)," in *Proc. IEEE International Conference on Information Networking (ICOIN)*, 2021.
- [3] W. J. Yun, J. Park, and J. Kim, "Quantum multi-agent meta reinforcement learning," in *Proc. AAAI*, Washington DC, USA, February 2023.
- [4] K. Arulkumaran, M. P. Deisenroth, M. Brundage, and A. A. Bharath, "Deep reinforcement learning: A brief survey," *IEEE Signal Processing Magazine*, vol. 34, no. 6, pp. 26-38, 2017.
- [5] 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)*, 2022.
- [6] J. R. McClean, S. Boixo, V. N. Smelyanskiy, R. Babbush, and H. Neven, "Barren plateaus in quantum neural network training landscapes," *Nature Communications*, vol. 9, no. 1, pp. 1-6, 2018.
- [7] W. J. Yun, S. Park, J. Kim, M. Shin, S. Jung, D. A. Mohaisen, and J. Kim, "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.
- [8] C. Park, H. Lee, W. J. Yun, S. Jung, C. Cordeiro, and J. Kim, "Cooperative multi-agent deep reinforcement learning for reliable and energy-efficient mobile access via multi-UAV control," *arXiv preprint arXiv:2210.00945*, 2022.