

멀티모달 연합학습 알고리즘 기술 동향

손석빈, 박수현* 김중헌

고려대학교, *숙명여자대학교

lydiasb@korea.ac.kr, *soohyun.park@sookmyung.ac.kr, joongheon@korea.ac.kr

Trends of the Multimodal Federated Learning Algorithm

Seok Bin Son, Soohyun Park*, Joongheon Kim

Korea Univ., *Sookmyung Womans' Univ.

요약

현재 두 개 이상의 모달리티를 사용하여 다차원의 정보를 활용하는 멀티모달 딥러닝 알고리즘에 대한 연구들이 등장하였다. 다양한 데이터에 접근하고자 하는 멀티모달은 사용자의 개인 정보 보호를 침해할 수 있다는 한계가 있으며, 이러한 한계를 극복하기 위해 모델에서 학습된 파라미터만을 전송하여 개인 정보 보호에 강인한 연합학습 알고리즘을 멀티모달 딥러닝 알고리즘에 결합하려는 연구가 진행 중이다. 본 논문은 멀티모달 딥러닝 알고리즘 및 연합학습 알고리즘의 개념에 대해 소개하였다. 또한 다양한 멀티모달 연합학습 알고리즘을 소개하고 분석하며 멀티모달 연합학습에서 발생하는 고질적인 문제에 대한 해결 방법을 자세히 소개하였다.

I. 서론

멀티모달 딥러닝 알고리즘은 두 개 이상의 서로 다른 형식을 가진 데이터를 통합하여 다차원적인 정보를 활용함으로써 인공지능의 정확도를 향상시킬 수 있는 알고리즘이다 [1]. 이때 멀티모달 접근 방식은 사용자의 원본 데이터에 접근해야 하므로 개인 정보 보호에서 문제가 발생할 수 있다 [2]. 이러한 한계점을 극복하기 위해 최근에는 멀티모달 딥러닝 알고리즘에 개인 정보 보호에서 강점이 있는 연합학습 (FL, Federated Learning) 알고리즘을 결합한 연구들이 진행되고 있다 [2-4]. 연합학습 알고리즘은 각각 로컬모델을 통해서 학습된 파라미터를 서버에 전송함으로써 원본 데이터를 공유할 필요가 없다 [5]. 그러나 멀티모달 딥러닝 알고리즘과 연합학습 알고리즘은 통합하는 과정에서 이질성이 있으며, 여전히 연합학습에서 발생할 수 있는 비독립적 데이터 분포 (Non-IID) 환경으로 인해 성능이 저하되며, 복합적인 데이터를 통합적으로 사용함으로써 통신 부담이 늘어난다는 한계가 있다 [2-4]. 본 논문에서는 멀티모달 딥러닝 알고리즘과 연합학습 알고리즘의 개념에 대해서 자세히 소개하였다. 또한 다양한 멀티모달 연합학습 알고리즘을 소개하며, 각 알고리즘의 특징을 분석하였다.




그림 1 멀티모달 딥러닝 알고리즘 개요도

II. 멀티모달 딥러닝 알고리즘

멀티모달 딥러닝 알고리즘은 그림 1과 같이 다양한 모달리티를 사용함으로써 상호 보완이 가능하여 모델에 다각도의 데이터를 제공해줄 수 있다. 먼저 텍스트, 이미지 등 다양한 유형의 입력을 동시에 처리하고, 각 유형에 대한 중요한 특징을 추출한다. 이후, 추출된 특징을 하나로 통합한 후, 모델에 전송한다. 이때 모델은 각 입력 유형의 중요성을 학습한 후, 이에 따라 가중치를 할당하여 최종 결과를 생성하여 정확도를 산출한다. 이러한 멀티모달 데이터를 생성하기 위해서는 필연적으로 사용자의 데이터를 다양하게 수집해야 하므로, 개인 정보 보호에서의 문제가 발생할 수 있다 [2-4]. 또한 멀티모달 알고리즘은 다중 모달리티를 사용함으로써 오버헤드가 커진다는 한계가 있다 [2-4]. 따라서 해당 문제점을 극복하기 위해 최근에는 학습된 파라미터만을 중앙 서버에 공유하여 개인 정보 보호에 강인한 연합학습 알고리즘을 멀티모달 딥러닝 알고리즘에 적용하려는 연구들이 등장하였다.

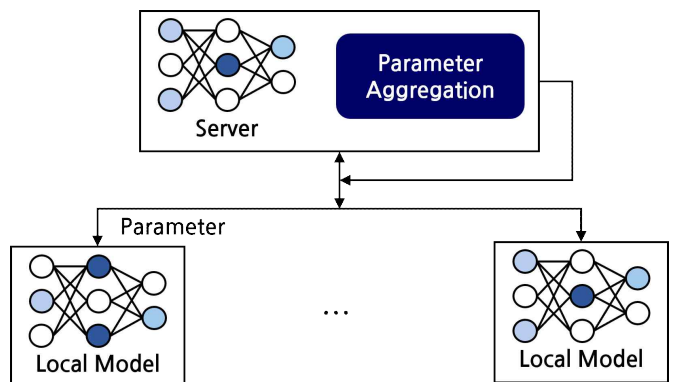


그림 2 연합학습 알고리즘 개요도

III. 연합학습 알고리즘

연합학습 알고리즘은 그림 2와 같이 모델의 학습된 파라미터만을 중앙 서버로 전송함으로써 개인 정보를 보호하면서도 중앙 집중형 학습에 비해 컴퓨팅 자원을 효율적으로 사용할 수 있다는 장점이 있다 [6]. 연합학습 알고리즘은 다음과 같이 동작한다. 먼저, 각 로컬 모델은 로컬 데이터 세트를 사용하여 자체 로컬 모델을 독립적으로 학습하고 학습된 파라미터를 중앙 서버로 전송한다. 그런 다음 서버는 이러한 파라미터를 집계한다. 이후, 각 글로벌 모델 파라미터는 각 로컬 모델로 다시 전송되고, 로컬 모델은 이를 활용하여 로컬 모델을 업데이트하며, 이 과정은 수렴할 때까지 반복된다. 연합학습은 Non-IID의 문제로 데이터 클래스의 불균형에 의해 크게 영향을 받으므로, 해당 한계점을 극복하기 위한 연구들이 진행 중에 있다.

IV. 멀티모달 연합학습 알고리즘의 기술 동향

이제껏 멀티모달 연합학습 알고리즘인 Harmony는 새로운 모달리터별 연합학습과 동적 리소스 최적화 및 모달리터 편향을 활용한 연합 융합 학습을 2단계로 분리하였다 [2]. 먼저 여러 개의 단일 모달 네트워크를 학습시킨 후, 서로 다른 멀티모달 노드의 편향을 활용하여 노드를 클러스터링한다. 그런 다음 연합 융합 학습을 통해 분류기 레이어를 공동으로 학습한다. 이를 통해 Non-IID 데이터 분포에서 모델 정확도를 향상시키고 시스템 융합 속도를 높였다. 또다른 멀티모달 연합학습 알고리즘인 FedDAT (FedDual-Adapter Teacher)은 DAT (Dual-Adapter Teacher)는 기존의 연합학습 알고리즘에 글로벌 어댑터를 통합하였다 [3]. 해당 알고리즘에서의 로컬 어댑터는 로컬 모델의 지식을 캡처함으로써 글로벌 어댑터를 정규화한다. 이를 통해 데이터의 Non-IID로 인한 데이터 이질성 문제를 해결하여 성능 열하를 방지하며, 글로벌 어댑터와 DAT 간의 상호 지식 증류를 통해 DAT가 제한된 로컬 데이터 세트에 과적합 되는 것을 방지하였다. 마지막으로 계층적 그래디언트 블렌딩(HGB) 알고리즘은 과적합 및 일반화 동작을 적응적으로 측정하여 모달리터의 최적 블렌딩과 로컬 모델의 최적 가중치를 동시에 계산하여 멀티모달과 연합학습에서의 불일치를 완화하고자 하였다 [4]. 해당 모델은 빠른 수렴 속도를 보장하면서도 뛰어난 정확도를 달성할 수 있음을 입증하였다. 이처럼 멀티모달 연합학습 알고리즘에서 발생할 수 있는 문제점을 해결하기 위해 다양한 방법이 제시되었으며, 이에 대한 연구가 진행 중에 있다.

V. 결론

본 논문에서는 멀티모달 딥러닝 알고리즘과 연합학습 알고리즘에 대한 기본 개념에 대해 소개하고, 이를 결합한 멀티모달 연합학습 알고리즘의 기술 동향에 대해서 기술하였다. 이를 통해 멀티모달 연합학습 알고리즘에서 주요하게 다루는 문제점에 대해서 파악하였다.

ACKNOWLEDGMENT

본 연구는 2022년 한국연구재단의 지원을 받아 수행됨 (NRF 2022R1A2C2004869). 본 논문의 교신 저자는 김중현임.

참고 문헌

- [1] J. Y. Shim, J. Kim, and J. K. Kim, "Audio-to-Visual Cross-Modal Generation of Birds," *IEEE Access*, Vol. 11, pp. 27719-27729, March 2023.
- [2] X. Ouyang, et al. "Harmony: Heterogeneous Multi-Modal Federated Learning through Disentangled Model Training," in *Proc. Annual International Conference on Mobile Systems, Applications and Services, (MobiSys 2023)*, pp. 530-543, Helsinki, Finland, June 2023.
- [3] H. Chen. et al., "FedDAT: An Approach for Foundation Model Finetuning in Multi-Modal Heterogeneous Federated Learning," in *Proc. AAAI Conference on Artificial Intelligence (AAAI)*, Vol. 38, No. 10, pp. 11285-11293, Vancouver, Canada, February 2024.
- [4] S. Chen, and B. Li, "Towards Optimal Multi-Modal Federated Learning on Non-IID Data with Hierarchical Gradient Blending," in *Proc. IEEE INFOCOM*, pp. 1469-1478, London, United Kingdom, May 2022.
- [5] S. Park, S. Jung, and J. Kim, "Dynamic Quantum Federated Learning for Satellite-Ground Integrated Systems using Slimmable Quantum Neural Network," *IEEE Access*, Vol. 12, pp. 58239-58247, April 2024.
- [6] H. Beak, S. Park, and J. Kim, "Optimization of Parameter Aggregation for Dynamic User Environment Federated Learning," in *Proc. Symposium of the Korean Institute of communications and Information Sciences*, pp. 1535-1536. Jeju Island, Korea, June 2023.