

컴퓨팅 자원의 동적인 상황에 대한 유연한 Federated Learning 방식

정준표, 고영배
아주대학교 소프트웨어학과

forjune@ajou.ac.kr, youngko@ajou.ac.kr

Flexible Federated Learning Method for dynamic computing resource

June-Pyo Jung, Young-Bae Ko
Dept. of Software and Computer Engineering, Ajou University

요 약

논문[1]에서는 Federated Learning(FL) 방식에 Client Selection(CS) 단계를 추가함으로 기존의 모든 고객으로부터 글로벌 모델 변수를 받아오는 방식에 따른 Client 별로 다른 컴퓨팅 자원의 차이에서 생기는 비효율적 방식에 대해 deadline 을 설정하면서 기간내에 작업을 처리할 수 있는 Client 만 선택하여 글로벌 모델을 업데이트 시키는 방법을 제시했다. 하지만 CS 단계에서 deadline 을 설정하는데 있어서 동적인 컴퓨팅 자원 상황을 고려하지 않고 고정적인 deadline 을 설정하였다. 따라서 본 논문에서는 CS 단계에서 동적인 상황에 대한 FL 방식에 유연한 deadline 설정을 기존 CS 방식에 추가하여 실 상황에 더 적합한 FL 방식을 제시한다.

I. 서 론

FL 방식은 기하급수적으로 증가하는 IoT 디바이스에서 효율적이고 정보 보호적인 방법으로 현재 주목받고 있는 분산 학습 방식이다. 엣지 디바이스에서 생성되는 데이터를 서버에 직접 전송하지 않아 개인 정보가 담긴 데이터에 대한 정보 보호가 보장되고 모든 데이터를 전송하지 않고 글로벌 모델에 대한 새롭게 업데이트된 변수만을 서버에 전송함으로 네트워크 자원의 사용을 절약시킬 수 있다.[3] FL 이 효율적인 분산 학습 방식임에는 틀림없지만 실사용 측면에서는 아직 실질적인 문제점이 있다.

FL 은 서버에서 엣지 디바이스로부터 받은 글로벌 모델 변수를 취합(agggregation) 단계를 통해 새로운 글로벌 모델을 만들어 낸다. 하지만 실세계에서는 엣지 디바이스의 컴퓨팅 능력과 네트워크의 상황은 상이 하여 변수를 생성하는 시간과 서버로의 전송시간이 서로 다를 것이다. 그 결과, 서버는 글로벌 모델 변수를 취합하는데 있어서 기다리는 상황에 놓여지게 되고 먼저 모델 변수를 보낸 엣지 디바이스도 새로운 글로벌 모델에 대한 자체 데이터 학습을 위한 컴퓨팅 자원의 낭비가 이어진다. [4]

이를 해결하기 위해 논문[1]에서 client selection 이란 단계를 추가하였다. CS 란 서버가 사용자로부터 네트워크와 컴퓨팅 자원에 대한 상태정보를 받아와 임의로 설정한 deadline 내에 모델 변수를 추출하고 전송할 수 있는 사용자만 선택하는 학습 방식이다. [1]

하지만 [1]에서 제안한 CS 의 문제점은 deadline 을 고정하여 설정하였다. 고정된 deadline 은 일정수준의 정확도를 요구하는 모델을 학습하기 위해 필요한 사용자들의 수가, 설정한 deadline 내에 처리 가능하여

선택될지 예측할 수 없다. 또한 실사용적 측면에서 엣지 디바이스의 동적인 자원 상황은 예측 불가능하며 그 시점마다 유연성 있게 자원의 상황을 고려하여 조정 가능한 deadline 을 설정하여야 한다.

따라서 본 논문에서는 CS 단계의 deadline 설정에 있어 동적인 자원 상황에 맞게 유연하게 처리 가능한 deadline 기반 client selection 알고리즘을 제시한다.

II. 본론

본 논문에서는 동적인 상황에서의 유연한 FL 설정을 위한 필요 조건으로 다음과 같이 제시한다. 이종(heterogeneous)의 사용자 디바이스는 다른 서비스를 필요로 한다. 실시간성을 요구하는 학습(ex. 자율 주행 시스템, 재난상황 등)에서는 상황에 좀 더 민감하게 반응하는 모델을 만들기 위해 업데이트의 빈도를 증가시켜야 한다. 반대의 경우는 최소로 요구되어지는 업데이트 빈도에 맞춰 컴퓨팅 자원의 소모를 최소화한다.

모든 사용자의 네트워크 속도가 일정한 수준 유지를 가정하여도 사용자마다 서로 다른 컴퓨팅 능력에 의해 모델 업데이트에 필요한 변수들을 추출하는데 시간의 차가 생길 것이고 이로 인해 변수를 취합하기 위해 대기하는 서버의 컴퓨팅 자원들 또한 낭비가 생길 것이다.

위의 조건들에 따른 유동적 deadline 설정과 합리적 사용자 선택을 위한 알고리즘을 제시한다.

알고리즘 1 사용자의 수를 K , 선택되어지는 사용자의 비율을 $C \in (0,1]$ 로 설정한 FL.

1: Initialization: 서버는 기존의 사용자들의 디바이스로부터 모델을 초기화 한다.

2: Resource Request: 서버는 무작위로 선택된 $[K \times C]$ 만큼의 사용자들에게 자원 정보와 사전의 로컬 업데이트에 소비된 시간 정보를 보낸다.

3: Client Selection: 받은 정보를 활용하여 선택되는 사용자에게 count 를 부여한 후 횟수를 증가시키고 count 의 횟수가 많을수록 우선순위를 둔다. Deadline 설정은 파레토 법칙을 따라 count 횟수가 많은 사용자들의 평균 로컬 컴퓨팅시간의 80% 비율과 나머지 사용자들의 평균 시간의 20% 비율을 계산하여 정한다. 정해진 deadline 을 기준으로 처리 가능한 사용자들만 선택한다.

4. Distribution: 서버는 우선순위와 CS 단계에서 선택된 사용자에게 글로벌 모델의 변수를 전송한다.

5: Update and Upload: 사용자들은 로컬 글로벌 모델을 활용하여 서버로부터 받은 변수들을 이용해 업데이트하고 갱신된 모델 변수를 서버에 업로드 한다.

6: Aggregation: 전송된 모델변수를 취합하여 평균값을 구하고 기존 서버에 있던 글로벌 모델을 교체한다.

[4] Shiqiang W, Tiffany T, Theodoros S, Kin K L, Christian M, Ting H, and Kevin C, "Adaptive Federate Learning in Resource Constrained Edge Computing Systems" vol. 37, No.6, JUNE 2019.

III. 결론

본 논문에서 기존 [1]에서 제시한 CS 기반의 FL 에 새로운 deadline 설정 방식과 사용자들의 모델 업데이트 빈도수에 기반한 사용자 선택 알고리즘 제시하여 동적인 상황에서의 유연한 FL 방식을 제안하였다. 추후 실질적인 환경에서 적용을 위해 좀더 세밀한 non-iid(non-independent and identically distributed) 데이터의 효율적 처리 방식에 대한 연구가 필요하다.[2]

참 고 문 헌

- [1] T.Nishio and R.Yonetani, "Client selection for federated learning with heterogeneous resources in mobile edge" in *Proc. IEEE Int. Conf. Commun. (ICC)*, Shanghai, China, May 2019, pp. 1-7[online]. Available: <https://arxiv.org/abs/1804.08333>
- [2] Y. Zhao, M. Li, L. Lai, N. Suda, D. Civin, and V. Chandra, "Federated learning with non-iid data," *CaRR*, vol. abs/1806.00582, 2018.
- [3] H. B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. Y. Arcas, "Communication-efficient learning of deep networks from decentralized data," in *Proc. Int. Conf. Artif. Intell. Statist. (AISTATS)*, in Proceedings of Machine Learning Research, vol. 54, pp. 1273- 1282, Apr. 2017.