

소프트웨어 중심 선박을 위한 연합 학습-선택적 데이터 업로드 하이브리드 전략

김기현, 나영진, 임민중

동국대학교

rlsrlgus123@naver.com, dudwls976@naver.com, minjoong@dongguk.edu

Hybrid Strategy of Federated Learning with Selective Data Upload for Software-Defined Ships

Ki-Hyun Kim, Young-Jin Na, Minjoong Rim

Dongguk University

요약

본 논문은 소프트웨어 중심 선박 환경에서 발생하는 통신 제약과 데이터 불균형 문제를 해결하기 위해 연합 학습을 기반으로, 통신 가능 시점에 선택적으로 데이터를 업로드하는 하이브리드 학습 전략을 제안한다. 데이터 업로드 방식으로는 전체 데이터 랜덤 선택, 희소 클래스 랜덤 선택, 그리고 Cross Entropy 기반 데이터 선택 세 가지 방법을 적용하였다. MNIST 데이터 셋을 활용한 실험 결과, Cross Entropy 기반 데이터 선택 업로드 방식이 전체 클래스 및 희소 클래스 정확도 모두 좋은 성능을 보였다. 이는 통신이 제한된 실험 환경에서도 가치 있는 데이터를 선택적으로 전송하는 방식을 통해 효율적으로 글로벌 모델 성능 향상을 이루어낼 수 있음을 입증한다.

I. 서론

최근 선박과 조선업에서는 디지털 전환을 거치며 기존 아날로그 시스템에서 벗어나 자율운항 등 다양한 분야에서 인공지능 기술의 도입이 본격적으로 추진되고 있다. 특히 자율운항선박은 다양한 센서 데이터와 외부 환경 정보를 반영하여 실시간으로 의사결정을 수행하는 능력이 요구된다. 이러한 자율운항선박은 자율주행 자동차의 발전과 유사한 점을 지니지만, 환경과 기술적 관점에서 다소 차이점을 가지게 된다. 육상 차량은 안정적인 통신 인프라 속에서 동작하여 실시간 데이터 송·수신에 유리한 반면, 선박은 광범위한 해역을 이동하며, 해안에서 조금만 벗어나도 통신이 원활하지 않은 환경에 놓이게 된다. 이러한 해양 특성은 기존의 중앙 집중식 학습 방식과 같이 데이터를 하나의 중앙 서버에 모아 학습하는 접근 방식에 한계를 초래한다. 항해 중 통신 불가로 인해 데이터 전송이 어려우며, 통신이 가능한 지역에서 데이터를 일괄 업로드할 경우에도 대규모 데이터 전송으로 인한 막대한 통신 비용과 시간 지연이 발생할 수 있다.

또한, 선박 운항의 특성상 수집되는 데이터의 양에는 큰 차이가 발생할 수 있다. 예를 들어, 일반적인 날씨 조건에 대한 데이터는 풍부하게 수집되는 반면, 악천후와 같은 특수한 환경에 대한 데이터는 상대적으로 매우 적게 수집되어 희소할 수 있다. 이러한 데이터 불균형 상황에서는 희소한 조건에 대한 학습 성능을 확보하기 위한 전략이 필수적이다. 따라서 본 논문에서는 이러한 선박 간 데이터 편차 및 제한된 통신 환경 문제를 효과적으로 해결하기 위해 연합 학습을 기반으로 한 분산형 인공지능 학습 방식을 제안한다. 연합 학습은 각 선박이 로컬 데이터로 개별적으로 모델을 학습하고, 학습한 모델의 파라미터 만을 중앙 서버로 공유하는 학습 방식으로써 해양 운항 환경과 같이 송·수신이 불안정한 상황에 적합하다. 특히 연합 학습을 기본으로 하되, 통신이 가능한 시점에서 제한된 자원을 고려하여 일부 데이터만을 선택적으로 업로드하는 방식을 통한

하이브리드 전략을 제안한다. 데이터의 희소성, 무작위성, 모델이 잘 예측하지 못하는 샘플을 기준으로 다양한 업로드 방식을 적용하고, 각 방식이 모델의 성능에 미치는 영향을 분석함으로써, 효과적인 학습 방식을 도출하고자 한다.

II. 본론

연합 학습은 여러 클라이언트가 각각 보유한 로컬 데이터를 사용하여 독립적으로 모델을 학습한 뒤, 학습된 모델의 파라미터만 중앙 서버와 공유하여 글로벌 모델을 구축하는 학습 방법이다. 본 논문에서 제안하는 방식은 위와 같은 연합 학습 구조를 기반으로 하되, 통신이 가능한 시점에 각 클라이언트(선박)가 로컬 데이터의 일부만 선택적으로 중앙 서버에 업로드하도록 설계하였다.

어느 기준으로 데이터를 선별하는 것이 모델의 성능 향상에 큰 기여를 하는지를 판단하기 위해 다음과 같이 세 가지 전략을 적용하였다. 첫째, 전체 데이터 중 무작위로 일부를 선택하는 방식, 둘째, 희소 클래스에 속한 데이터 중 무작위로 선택하는 방식, 셋째, 로컬 모델마다 계산된 Cross Entropy Loss 를 기준으로 데이터를 선별하는 방식이다.

Cross Entropy Loss 는 분류 문제에서 예측 확률과 정답 간의 불일치를 측정하는 대표적인 손실 함수이며, 다음과 같이 정의된다:

$$\mathcal{L}_{CE}(y, \hat{y}) = - \sum_{i=1}^C y_i \log(\hat{y}_i) \quad (1)$$

Cross Entropy Loss 가 높은 데이터는 학습이 충분히 이루어지지 않은 어려운 샘플로 판단하고 중요 데이터로 간주한다. 이를 글로벌 학습에 우선적으로 반영하면 모델의 일반화 성능을 향상시킬 수 있다.

해당 방식의 효과를 입증하기 위해, MNIST 데이터 셋을 활용한 성능 비교 실험을 수행하였다. MNIST

데이터 셋은 손글씨 숫자(0 부터 9 까지) 이미지로 구성되어 있는 분류 데이터 셋이며, 구조가 단순하고 정답이 명확해 기초적인 분류 모델의 검증 실험에 널리 사용된다. 실험은 중앙 집중식 학습, 기존 연합 학습, 제안 방식 3 가지 방식에 대하여 전체 클래스 분류 성능 향상, 희소 클래스 분류 성능 향상을 측정하여 제안 방식의 우수성을 평가하고자 한다.

- 데이터 셋 구성

MNIST 데이터 셋을 기반으로 클래스 0~4 는 일반 클래스, 클래스 5~9 는 희소 클래스로 간주한다. 초기 모델 학습을 위한 데이터의 개수는 500 개로 지정, 그 안에서 일반 클래스와 희소 클래스의 개수를 9:1 의 비율로 지정한다.

- 학습 시나리오

본 논문에서는 다음과 같이 3 가지 주요 학습 시나리오를 구성하고 동일한 테스트 데이터 셋을 기준으로 성능을 비교하였다.

1. 중앙 집중식 학습

모든 데이터를 중앙 서버에 수집하여 학습하는 방법이다. 초기 모델에 추가로 500 개의 데이터를 수집하여 모델을 추가 학습하였다.

2. 기존 연합 학습 (FedAvg)

선택은 5 대로 가정하고, 각 선택에 100 개의 로컬 데이터를 분배하여 총 500 개 데이터를 활용한다. 전통적인 FedAvg 알고리즘을 적용하였으며, 5 라운드 진행하였다. 다음은 FedAvg 알고리즘의 가중치 계산 수식이다:

$$w_{t+1} = \sum_{k=1}^K \frac{n_k}{n} w_t^k \quad (2)$$

여기서 w_t^k 는 k 번째 클라이언트의 로컬 모델 파라미터, n_k 는 해당 클라이언트의 데이터 수, n 은 전체 데이터 수를 의미한다.

3. 하이브리드방식

기존 연합 학습 모델을 기반으로 추가 학습을 진행하되, 각 선택은 로컬 학습 과정에서 수집된 데이터를 분석하여 일부만 서버로 업로드하도록 한다. 데이터 업로드 방식은 다음의 세 가지 전략으로 세분화된다:

A. 전체 데이터 중 무작위 샘플링 : 통신 가능 시점에 전체 데이터 중 20 개를 무작위로 선택하여 업로드

B. 희소 클래스에서 무작위 샘플링 : 희소 클래스(클래스 5~9)에 속하는 데이터 중 20 개를 무작위로 선택하여 업로드

C. Cross Entropy 기반 중요도 선별 : 로컬 학습 후 각 샘플의 Cross Entropy 값을 계산하고, 상위 20 개의 샘플을 선택하여 업로드

- 모델 구조

모델은 기본적인 다층 퍼셉트론(MLP) 구조를 사용하였다. 입력층은 784 차원(MNIST 28x28 이미지), 은닉층은 각각 128 개, 64 개의 유닛을 사용하며, ReLU 활성화 함수를 적용하였다. 출력층은 10 개의 클래스를 분류하는 Softmax 구조로 구성되어 있다.

- 실험 결과

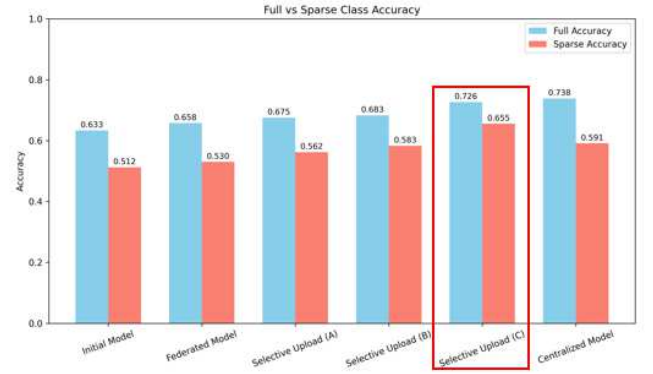


그림 1 각 학습 방식별 성능 비교

성능 평가는 예측 결과와 실제 정답의 일치 비율을 나타내는 Accuracy 지표를 기준으로 산출하였다. 실험 결과, 하이브리드방식은 희소 클래스에 대한 예측 성능을 향상시킴으로써 전체 클래스에 대한 정확도 또한 함께 개선되었다. 특히, 희소 클래스 정확도는 기존 연합 학습 대비 약 12% 향상되어, 제한된 통신 환경에서 데이터 중요도 기반 업로드 방식의 효과성을 입증하였다. 이는 통신 자원이 제한된 실제 환경에서도 적절한 데이터 선택이 글로벌 모델 성능 향상에 기여할 수 있음을 뜻한다.

III. 결론

본 논문에서는 해양 환경에서 발생할 수 있는 데이터 편향 및 통신 제약 문제를 고려하여, 연합 학습과 선택적 데이터 업로드 방식을 제안한다. 특히 Cross Entropy 기반의 중요도 평가를 활용하여, 모델이 판단하기 어려운 샘플을 선별적으로 업로드함으로써 글로벌 모델의 성능을 향상시킬 수 있음을 확인하였다. 실험 결과, 제안한 방식은 희소 클래스에 대한 예측 성능을 향상시킴으로써 전체 클래스에 대해서도 정확도를 효과적으로 개선할 수 있음을 확인하였다.

향후 연구에서는 다음과 같은 내용을 적용해 보고자 한다. 첫째, 실제 해양 상황과 유사한 데이터 셋에 적용해 보고자 한다. 본 논문에서는 MNIST 데이터 셋을 기반으로 실험을 진행하였으나, 향후 소프트웨어 중심 선박 환경에서 사용 가능성이 높은 해양 상황에서의 데이터를 대상으로 실험을 확대할 계획이다. 둘째, 다양한 모델 중요도 평가 기준을 적용해 보고자 한다. 본 실험에서는 Cross Entropy 를 측정하여 데이터를 선별하였으나, 데이터 중요도를 평가할 수 있는 다른 기준들을 적용하여 모델 성능 향상을 이루고자 한다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원 - 학석사연계 ICT 핵심인재양성사업의 지원을 받아 수행된 연구임 (IITP-2024-00436744)

참 고 문 헌

- [1] Shi, H., Radu, V., & Yang, P. (2024). Federated Learning with Workload Reduction through Partial Training of Client Models and Entropy-Based Data Selection. arXiv preprint arXiv:2501.00170.
- [2] Nagalapatti, L., Mittal, R. S., & Narayanam, R. (2022, June). Is your data relevant?: Dynamic selection of relevant data for federated learning. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 36, No. 7, pp. 7859-7867).