

## 연합학습 환경 내 통신 비용 절감을 위한 블록 단위 모델 집계(BWFL)

박중율, \*조관영, 최민석

경희대학교, 성균관대학교\*

tubduk@khu.ac.kr, chaile9983@gmail.com\*, [choims@khu.ac.kr](mailto:choims@khu.ac.kr)

## Block-wise Federated Learning(BWFL) for Communication-Efficient Model Aggregation in Distributed Environments

Jongyul Park, \*Kwanyoung Cho, Minseok Choi

Kyung Hee Univ., Sung Kyun Kwan Univ.\*

## 요약

연합학습(Federated Learning, FL)은 데이터 프라이버시를 보장하면서 분산 단말에서 모델을 공동 학습하는 기술이다. 그러나 매 라운드마다 전체 모델 파라미터를 업로드·다운로드해야 하므로, 네트워크 지연 및 누적 통신량이 학습 속도의 주요 병목으로 작용한다. 본 연구에서는 이러한 한계를 완화하기 위해 Block-wise Federated Learning (BWFL) 을 새롭게 제안한다. 제안 방식은 모델을 B개의 블록으로 분할하고, 각 라운드에서 선택된 블록만 전송·집계하는 구조로 통신 효율을 극대화한다. 모든 클라이언트는 전 블록을 로컬 데이터로 학습하되, 서버는 선택 블록만을 부분 집계하여 전송량을 절감한다. 실험 결과, BWFL은 기존 FedAvg 대비 동일 정확도 도달 시 누적 통신량을 감소시킴을 확인하였다. 이를 통해 제안 기법은 통신 효율과 학습 성능 간의 균형을 효과적으로 달성함을 확인하였다.

## I. 서론

연합학습은 중앙 서버가 각 단말의 원천 데이터를 수집하지 않고, 분산된 모델 파라미터를 통합하여 전역 모델을 학습하는 기술로 주목받고 있다. 그러나 기존 방식인 FedAvg는 매 라운드마다 전체 모델 파라미터를 업로드·다운로드해야 하므로, 네트워크 지연과 누적 통신량이 학습 효율을 제한하는 핵심 병목으로 작용한다. 특히, 모델 크기가 커질수록 이러한 병목은 더욱 심화되어, 실제 분산 환경에서의 학습 속도 저하와 통신 자원 낭비를 초래한다.

이에 본 연구에서는 이러한 문제를 구조적으로 완화하기 위해 Block-wise Federated Learning (BWFL) 을 새롭게 제안한다. BWFL은 모델을 여러 개의 블록 단위로 분리하고, 각 라운드마다 선택된 블록만을 통신·집계하도록 설계하였다. 모든 클라이언트는 여전히 전체 모델을 로컬 데이터로 학습하므로 표현 일관성을 유지하지만, 서버는 일부 블록만 수집·통합하여 통신량을 크게 줄인다. 이를 통해 전송 비용을 최소화하면서도 기존 방식보다 더 나은 성능을 보일 수 있었다.

본 논문에서는 BWFL의 시스템 구조와 알고리즘을 정식화하고, 기존의 FedAvg 및 진행형 학습(ProgFed)과의 비교를 통해 제안 방식의 효율성을 검증한다. 평가 지표로는 라운드별 정확도 및 누적 통신량 대비 정확도를 함께 분석하여, 제안 기법이 학습 속도와 통신 효율 모두에서 우수함을 보임을 실증한다.

## II. 시스템 모델

본 연구에서는 하나의 중앙 서버와  $M$ 명의 클라이언트로 구성된 연합학습 환경을 고려한다. 각 클라이언트  $k \in \{1, 2, \dots, M\}$  는 고유한 데이터셋

$$D_k = \{(x_i, y_i)\}_{i=1}^{|D_k|}$$

을 보유하며, 서버는 전역 모델 파라미터  $w \in \mathbb{R}^d$  를 관리한다. 모델은  $B$ 개의 연속된 블록으로 구성되어 있으며,

$$w = [w^{(1)}, w^{(2)}, \dots, w^{(B)}]$$

로 표현된다. 각 블록은 네트워크 계층의 기능적 구간(예: Convolution + Batch Normalization + ReLU)을 의미하며, 유사한 파라미터 수를 갖는다.

라운드  $r$ 에서 서버는 전역 모델  $w^r$ 을 모든 클라이언트로 전송하고, 각 클라이언트는 이를 초기값으로 하여 로컬 데이터셋  $D_k$ 를 기반으로 학습을 수행한다. 로컬 목적함수는 다음과 같이 정의된다.

$$F_k(w) = \frac{1}{|D_k|} \sum_{(x,y) \in D_k} \ell(f(x;w), y)$$

여기서  $\ell$ 은 교차 엔트로피 손실 함수,  $f(x;w)$ 는 입력  $x$ 에 대한 모델 예측값이다. 로컬 학습은 확률적 경사하강법(SGD)을 이용하여 다음과 같이 진행된다.

$$w_k^{r,t+1} = w_k^{r,t} - \eta \nabla F_k(w_k^{r,t})$$

모든 클라이언트는 동일한 예폭 수  $E(t=0, 1, \dots, E-1)$ 만큼 학습을 수행하여 로컬 모델  $w_k^r$ 을 완성한다.

로컬 학습 후, 클라이언트는 모든 블록을 학습하지만 서버로는 선택된 블록 집합  $S_r \subseteq \{1, \dots, B\}$ 의 파라미터만 업로드한다. 서버는  $S_r$ 에 포함된 블록에 대해서만 집계를 수행하며, 각 블록  $b \in S_r$ 에 대해 전역 모델은 다음과 같이 갱신된다.

$$w^{r+1}(b) = \sum_{k=1}^M p_k w_k^r(b), \quad p_k = \frac{|D_k|}{\sum_{j=1}^M |D_j|}$$

선택되지 않은 블록은 갱신되지 않고

$$w^{r+1}(b) = w^r(b), \quad b \notin S_r$$

로 유지된다. 이후 서버는  $S_r$ 에 해당하는 블록만 다시 각 클라이언트로 브로드캐스트하여 다음 라운드를 시작한다.

통신량은 라운드  $r$ 에서의 선택 블록 크기에 의해 결정되며,

$$C_r = \sum_{b \in S_r} (|w^{(b)}|_{upload} + |w^{(b)}|_{download}), \quad C(\leq R) = \sum_{r=1}^R C_r$$

로 정의된다. 이를 통해 동일 정확도 달성 시 누적 통신량 절감률을 평가한다.

본 시스템은 (i) 전 블록 학습으로 표현 일관성을 유지하고, (ii) 부분 집계로 통신 효율을 확보하며, (iii) 비집계 블록의 안정성을 보장하는 구조를 갖는다.

### III. 제안 기법: Block-wise Federated Learning(BWFL)

제안하는 Block-wise Federated Learning (BWFL) 은 모델을 블록 단위로 분리하고, 각 라운드에서 선택된 블록만 전송·집계함으로써 통신 효율을 향상시키는 방법이다. 모든 클라이언트는 동일한 전체 모델을 로컬 학습하되, 서버는 블록 선택 규칙에 따라 일부 블록만 수집·통합한다.

이 방식은 전체 모델을 교환하는 전통적 FedAvg 대비 통신량을 크게 절감하면서도, 전 블록 학습을 유지하여 정확도 손실을 최소화한다.

BWFL의 핵심 절차는 다음과 같다.

- (1) 서버는 전역 모델  $w^r$  을 모든 클라이언트에 배포한다.
- (2) 각 클라이언트는 로컬 데이터셋으로 전 블록을 학습하여  $w_k^r$  을 획득한다.
- (3) 서버는 사전에 정의된 선택 집합  $S_r$  에 해당하는 블록의 파라미터만 수신한다.
- (4) 서버는 선택된 블록에 대해서만 가중 평균 집계를 수행하여  $w^{r+1}(b)$  을 갱신한다.
- (5) 갱신된 블록만 브로드캐스트하여 다음 라운드를 진행한다.

이러한 구조는 통신 효율과 모델 일관성의 균형을 달성하도록 설계되었으며, 선택 집합  $S_r$  의 구성에 따라 다양한 트레이드오프 조정이 가능하다. 또한, 클라이언트가 모든 블록을 학습하기 때문에 특정 블록이 집계되지 않더라도 전체 모델의 표현 공간이 안정적으로 유지된다.

### IV. 실험 결과

제안한 BWFL 기술의 성능 평가를 위해 기존 연합학습 방식인 FedAvg와 또 다른 블록 기법을 사용한 연합학습의 종류인 ProgFed와 비교하였다. 모델은 Resnet-18 모델을 사용하였으며, CIFAR-10 데이터 셋을 사용하였다. 평가는 IID, NIID의 경우를 비교하였으며, 라운드 별 정확도와 실제 통신 비용 별 정확도 그래프를 도출하였다. 이를 통해 실제 성능 비교와 통신 비용 절감을 분석하였다..

IID(fig.1 - 2)와 NIID(fig.3 - 4) 환경을 종합적으로 분석한 결과, BWFL은 데이터 분포의 독립성 여부에 관계없이 FedAvg보다 안정적으로 높은 정확도와 우수한 통신 효율을 동시에 달성하였다.

먼저 IID 환경에서는 모든 클라이언트가 균일한 데이터 분포를 가지기 때문에 각 로컬 모델이 비교적 비슷한 방향으로 수렴한다. 이 상황에서 FedAvg는 전체 모델을 매 라운드마다 전송하기 때문에 학습 진행이 완만하게 이루어졌고, 초기 300라운드까지의 상승 구간에서 정확도 개선이 느리게 나타났다. 반면 BWFL은 블록 단위 전송 방식을 통해 보다 빠른 초기 수렴을 달성했으며, 동일한 통신량 기준에서 FedAvg 대비 2~3% 높은 평균 정확도를 보였다. 또한 BWFL은 FedAvg의 최종 정확도(마지막 100라운드 평균)에 도달하기까지 약 30~35%의 누적 통신량만을 사용하였으며, 이후 수렴 구간에서도 정확도의 안정성이 유지되었다. ProgFed는 세 모델 중 가장 높은 최대 정확도를 기록했으나, 학습 과정에서 추가적인 블

록 교환과 연속적 파이프라인 구조로 인해 통신비용 증가가 불가피했다.

반면 NIID 환경에서는 각 클라이언트의 데이터 분포가 상이하여 수렴 과정에서 진동과 불안정성이 나타났지만, BWFL은 여전히 FedAvg보다 빠른 수렴 속도와 더 높은 최종 정확도를 기록했다. 초기 라운드에서는 데이터 편차로 인해 일부 변동이 있었지만, 전체적으로는 점진적이고 안정적인 상승세를 보였다. 반면 FedAvg는 비균등 데이터에 민감하게 반응하여 후반부까지 정확도 향상이 지연되는 경향을 보였다. 특히 통신량 기준 분석(fig.4)에서 BWFL은 동일 정확도 달성까지 필요한 누적 통신량이 FedAvg 대비 약 35~40% 낮았으며, 학습 후반부에서도 통신 효율성이 유지되었다. ProgFed는 최고 정확도를 유지했으나, 클라이언트 간 불균형이 커질수록 오히려 불안정한 진동폭이 확대되어 효율성 면에서는 BWFL보다 낮은 일관성을 보였다.




Fig.1 Round vs Accuracy(IID)




Fig.2 Com-cost vs Accuracy(IID)




Fig.3 Round vs Accuracy(NIID)




Fig.4 Com-cost vs Accuracy(NIID)

### V. 결론

본 연구는 연합학습에서 발생하는 과도한 통신 비용 문제를 해결하기 위해 블록 단위 모델 집계(Block-wise Federated Learning, BWFL)를 제안하였다. 제안한 방식은 모델을 여러 블록으로 분할하고 각 라운드에서 일부 블록만 선택적으로 업로드·집계함으로써 불필요한 데이터 전송을 줄이는 구조를 가진다. 클라이언트는 전체 모델을 로컬 데이터로 학습하되 서버는 선택된 블록만 통합하여 통신 효율을 극대화하며, FedAvg 대비 약 30~40%의 통신량 절감과 동시에 더 높은 정확도 및 빠른 수렴을 달성하였다.

### ACKNOWLEDGMENT

이 논문은 2025년도 정부(과학기술정보통신부)의 재원으로 한국연구재단과 정보통신기획평가원의 지원을 받아 수행된 연구임(RS-2025-00521295, IITP-2025-RS-2024-00434743).

### 참 고 문 헌

- [1] H. B. McMahan, Eider Moore, Daniel Ramage, Seth Hampson, and Blaise A. y Arcas, "Communication-Efficient Learning of Deep Networks from Decentralized Data," Proc. of the 20th International Conference on Artificial Intelligence and Statistics (AISTATS), 2017.
- [2] Hui-Po Wang, Sebastian U. Stich, Yang He, and Mario Fritz, "ProgFed: Effective, Communication, and Computation Efficient Federated Learning by Progressive Training," in Proc. of International Conference on Machine Learning (ICML), 2022, pp. 23034 - 23054.
- [3] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 770 - 778.