

논문 2026-1-7 <http://dx.doi.org/10.29056/jsf.2026.03.07>

희소 표현 기반 개인화 연합학습 기법에 관한 연구

버반팜*, 장효경**†

A Study of Personalized Federated Learning Based on Sparse Representations

VO VAN PHAP*, Hyokyung Chang**†

요 약

연합학습은 분산 환경에서 효율적인 학습을 가능하게 하지만, Non-IID 데이터 환경에서는 전역 모델 성능 저하와 클라이언트 간 성능 불균형 문제가 발생한다. 본 논문은 희소 표현 기반 전역 모델에 경량 개인화 계층을 결합한 개인화 연합학습 기법을 제안한다. 제안 방법은 k-sparse 제약을 통해 계산 효율성과 학습 안정성을 유지하면서, 로컬 개인화 계층을 통해 클라이언트별 데이터 분포 차이에 적응하며 추가적인 통신 오버헤드를 발생시키지 않는다.

CIFAR-10과 CIFAR-100 데이터셋을 대상으로 다양한 Non-IID 환경($\alpha = 0.1, 0.3, 0.5, 1.0$)과 클라이언트 수(10, 20, 50)에서 실험을 수행하였다. 실험 결과, 제안 방법은 전역 정확도를 유지하면서 클라이언트 간 성능 분산을 감소시키고, 특히 강한 Non-IID 환경에서 하위 클라이언트의 성능을 효과적으로 개선하여 학습 안정성을 향상시켰다. 또한 다양한 설정에서도 일관된 성능 향상을 보여 제안 방법의 강건성과 확장 가능성을 확인하였다.

Abstract

Federated Learning (FL) enables collaborative training in distributed environments, but suffers from performance degradation and inter-client disparity under Non-IID data. This paper proposes a personalized federated learning method that combines a sparse representation-based global model with a lightweight personalization layer. The proposed approach maintains computational efficiency and training stability via a k-sparse constraint, while enabling local adaptation without additional communication overhead.

Experiments on CIFAR-10 and CIFAR-100 under various Non-IID settings ($\alpha = 0.1, 0.3, 0.5, 1.0$) and client scales (10, 20, 50) show that the proposed method preserves global accuracy while reducing inter-client variance. In particular, it significantly improves the performance of low-performing clients in highly heterogeneous environments, demonstrating robust and scalable performance across diverse settings.

한글키워드 : 연합학습, 개인화 연합학습, 희소 표현, 비독립·비동일 분포 데이터(Non-IID), k-희소 제약
keywords : Federated learning, Personalized federated learning, Sparse representation, Non-IID data, Performance stability, k-sparse Constraint

* 한남대학교 컴퓨터공학과

접수일자: 2026.02.26. 심사완료: 2026.03.18.

** 한남대학교 컴퓨터공학과

게재확정: 2026.03.20.

† 교신저자: 장효경(email: chantellejang@hnu.kr)

1. 서론

연합학습(Federated Learning, FL)은 분산 환경에서 다수의 클라이언트가 협력적으로 모델을 학습하는 방식으로, 에지 환경에서 효율적으로 활용된다. 각 클라이언트는 로컬 데이터를 기반으로 학습하고, 서버는 이를 집계해 전역 모델을 업데이트한다[1,2].

그러나 실제 환경에서 데이터는 Non-IID 특성을 가지며, 이로 인해 로컬 업데이트 불일치와 전역 성능 저하, 성능 격차가 발생한다[3]. FedAvg는 동일한 전역 모델 공유를 전제로 하여 Non-IID 환경에서 적응성이 제한된다[1,3]. 이를 보완하기 위해 PFL이 제안되었으나, 추가 구조나 복잡한 최적화로 인해 계산 비용이 증가한다[6].

한편, 희소 표현 기반 연합학습은 계산 효율성과 학습 안정성을 향상시키지만, 주로 전역 모델 효율성에 초점을 두어 이질성 완화에는 한계가 있다[8]. 이에 본 연구는 희소 표현 기반 전역 모델에 경량 개인화 계층을 결합한 구조를 제안하며, 평균 성능을 유지하면서 Non-IID 환경에서의 성능 격차 완화를 목표로 한다.

2. 관련 연구

2.1 Non-IID 환경에서의 연합학습 한계

연합학습(Federated Learning, FL)은 로컬 데이터를 공유하지 않고 다수의 클라이언트가 협력적으로 모델을 학습하는 분산 학습 프레임워크이다. 그러나 실제 환경에서 클라이언트 데이터는 비독립·비동일 분포(Non-IID)를 가지며, 이는 성능 저하의 주요 원인으로 작용한다[3].

Non-IID 환경에서는 클라이언트 간 데이터 분포 차이로 인해 로컬 그래디언트 방향이 불일치하게 되고, 전역 집계 과정에서 업데이트가 상쇄

되거나 특정 분포에 편향될 수 있다. 그 결과 전역 모델 수렴이 지연되고 클라이언트 간 성능 격차가 확대된다[2].

대표적 연합 최적화 기법인 FedAvg는 동일한 전역 모델 공유를 전제로 설계되어 데이터 이질성이 클수록 성능 안정성이 저하된다[1,3]. 특히 일부 클라이언트는 학습 라운드가 증가하더라도 낮은 성능에 머무르며, 이는 연합학습의 공정성과 효율성을 제한한다.

2.2 희소 표현 기반 연합학습

최근에는 계산 효율성과 학습 안정성 향상을 위해 희소 표현을 연합학습에 적용하는 연구가 활발하다[8]. 희소 표현 기반 연합학습은 중요한 활성값만 유지하여 연산과 계산 복잡도를 줄이고, 희소 업데이트 및 활성화를 통해 통신 비용과 수렴 안정성을 개선한다[2,8].

그러나 이러한 접근은 주로 전역 모델 효율성에 초점을 두어 클라이언트별 데이터 분포 차이를 명시적으로 고려하지 않는다. 그 결과, 전역 희소 표현을 공유하는 구조에서는 Non-IID 환경에서의 성능 격차가 여전히 존재한다[3,8].

2.3 개인화 연합학습 기법

Non-IID 환경에서 단일 전역 모델의 한계를 극복하기 위해 다양한 개인화 연합학습(Personalized Federated Learning, PFL) 기법이 제안되었다. PFL은 클라이언트별 데이터 특성을 반영하여 평균 성능과 클라이언트 간 성능 격차를 동시에 개선하는 것을 목표로 한다. 기존 연구는 다음과 같이 분류된다.

- 모델 분리 기반: 전역과 로컬 부분을 분리해 학습한다. 특징 추출기는 공유하고 상위 계층을 개인화하며, 전역 표현을 유지할 수 있으나 계층 선택에 따른 성능 민감도와 메모리 증가 문제가 있다.

- 모델 보간 기반: 전역과 로컬 모델을 가중 결합해 개인화 모델을 구성한다. 구조 변경 없이 적용 가능하나 보간 계수 설정이 어렵고, 이질성이 클 경우 안정성이 제한된다.
- 메타러닝 기반: 전역 초기 파라미터를 학습해 빠른 로컬 적응을 유도한다. 적응 성능은 높지만 절차와 계산 비용이 복잡하다.
- 클러스터링 기반: 데이터 유사도에 따라 클라이언트를 그룹화해 모델을 학습한다[4][5]. 성능 향상에 효과적이거나 클러스터 설정과 동적 대응이 어렵다.

종합하면, 기존 PFL 기법들은 성능 격차 완화에 기여했으나, 추가 계산 비용과 복잡성으로 인해 에지 환경 적용에는 한계가 있다.

2.4 연구 동기 및 본 연구의 위치

앞선 분석에서 기존 개인화 연합학습은 계산 비용과 구조적 복잡성이 높고, 희소 표현 기반 연합학습은 클라이언트별 적응성에 한계가 있음을 확인하였다. 이는 전역 표현의 안정성을 유지하면서 경량 개인화를 제공할 새로운 접근의 필요성을 보여준다. 이에 본 연구는 희소 표현 기반 전역 모델과 경량 개인화 계층을 결합한 구조를 제안하며, 기존 프로토콜을 유지한 채 Non-IID 환경에서의 성능 격차 완화를 목표로 한다.

3. 희소 표현 기반 개인화 연합학습 방법

3.1 전체 모델 구조 개요

각 클라이언트 k 는 자신의 로컬 데이터 $(x, y) \sim D_k$ 를 이용하여 동일한 전역 모델을 기반으로 학습을 수행한다[1]. 제안된 모델은 다음의 세 가지 구성 요소로 이루어진다.

- ① 전역 희소 표현 학습 모듈 (Global Sparse Representation Module)

- ② 클라이언트별 개인화 계층 (Client-specific Personalization Layer)

- ③ 공유 분류기 (Shared Classifier)

이 중 전역 희소 표현 학습 모듈과 분류기는 모든 클라이언트가 공유하며, 개인화 계층은 각 클라이언트 로컬에 독립적으로 유지된다.




그림 1. 희소 개인화 연합학습 구조
Fig. 1. Architecture of Sparse Personalized FL

3.2 전역 희소 표현 학습

입력 데이터 x 는 전역적으로 공유되는 백본 (backbone) 네트워크 $\Phi(\cdot; w_e)$ 를 통해 고차원 특징 벡터로 변환된다.

$$z = \Phi(x; w_e)$$

이후, 생성된 특징 벡터 z 에 대해 hard k -sparse 연산자 $S_k(\cdot)$ 를 적용하여, 전체 차원 중 상위 k 개의 활성값만을 유지하는 희소 표현을 생성한다[8].

$$\tilde{z} = S_k(z) \quad \text{s.t.} \quad \|\tilde{z}\|_0 = k$$

이와 같은 희소 제약은 불필요한 활성값을 제거해 계산 복잡도를 줄이고, 비동질 환경에서 표현 공간의 안정성을 높인다. 본 연구는 해당 모듈을 전역 공유하여 모든 클라이언트가 동일한 표현 공간에서 학습하도록 한다.

3.3 클라이언트별 개인화 계층

희소 표현 \tilde{z} 는 클라이언트 k 에 특화된 개인화

함수 $\psi_k(\cdot; \theta_k)$ 를 통해 변환된다.

$$z_k = \psi_k(\tilde{z}; \theta_k)$$

개인화 계층은 희소 표현 이후에 위치하여 각 클라이언트의 데이터 분포 특성에 맞게 표현을 조정한다. 이는 Non-IID 환경에서 단일 전역 모델의 한계를 보완하기 위한 개인화 연합학습의 핵심 개념과 일치한다 [3,6].

본 연구에서는 개인화 계층을 단일 fully-connected layer로 구성하였으며, 입력 및 출력 차원은 모두 512로 설정하였다. 해당 계층은 전체 모델 대비 약 1~2% 수준의 경량 구조로 설계되어, 추가적인 계산 비용을 최소화하면서도 효과적인 개인화를 가능하게 한다.

또한, 개인화 계층의 파라미터 θ_k 는 서버로 전송되지 않고 클라이언트 로컬에만 유지된다. 이에 따라 통신 오버헤드 증가 없이 전역 표현의 안정성과 클라이언트별 적응성을 동시에 확보할 수 있다 [1].

3.4 예측 및 손실 함수 정의

개인화된 표현 z_k 는 전역적으로 공유되는 분류기 $f(\cdot; w_c)$ 를 통해 최종 예측값을 생성한다.

$$\hat{y}_k = f(z_k; w_c)$$

이에 따른 손실 함수는 다음과 같이 정의된다.

$$l(\hat{y}_k, y) = l(f(\psi_k(\hat{z}; \theta_k); w_c), y)$$

여기서 $l(\cdot)$ 은 분류 문제에 적합한 표준 손실 함수(예: cross-entropy loss)를 의미한다[3].

3.5 클라이언트 로컬 목적 함수

클라이언트 k 의 로컬 목적 함수는 해당 클라이언트의 데이터 분포 D_k 에 대한 기대값 형태로 정의된다[3].

$$F_k(w, \theta_k) = E_{(x, y) \sim D_k} [l(\hat{y}_k, y)] \quad (1)$$

여기서 \hat{y}_k 는 클라이언트 k 의 예측 결과이며, 전역 희소 표현과 개인화 계층을 거쳐 다음과 같이 계산된다.

$$\hat{y}_k = f(\psi_k(\tilde{z}; \theta_k); w_c), \tilde{z} = S_k(\Phi(x; w_e)) \quad (2)$$

식 (2)에서 $\Phi(\cdot)$ 는 전역적으로 공유되는 백본(backbone) 네트워크를, $S_k(\cdot)$ 는 k-sparse 제약을 적용하는 희소 표현 연산자를 의미한다.

$\psi_k(\cdot)$ 는 클라이언트 k 에 특화된 개인화 계층이며, $f(\cdot)$ 는 전역적으로 공유되는 분류기(classifier)이다. 여기서 $w = \{w_e, w_c\}$ 는 전역적으로 공유되는 파라미터 집합이며, θ_k 는 클라이언트 k 의 개인화 파라미터를 의미한다.

결과적으로, 식 (1)은 희소 표현 학습, 개인화 변환, 그리고 분류 과정을 하나의 통합된 최적화 문제로 정식화하며, 각 클라이언트는 자신의 데이터 분포에 맞추어 로컬 목적 함수를 독립적으로 최소화한다.

3.6 로컬 학습 및 파라미터 업데이트

각 연합학습 라운드에서 선택된 클라이언트는 자신의 로컬 데이터에 대해 다음과 같은 파라미터 업데이트를 수행한다.

- 전역 파라미터 업데이트:

$$w_k \leftarrow w_k - \eta \nabla_w F_k(w; \theta_k)$$

- 개인화 파라미터 업데이트:

$$\theta_k \leftarrow \theta_k - \eta \nabla_{\theta_k} F_k(w; \theta_k)$$

이 과정에서 전역 파라미터와 개인화 파라미터는 동일한 로컬 학습 과정에서 동시에 최적화된다. 그러나 서버로 전달되는 것은 전역 파라미터 w_k 만이며, 개인화 파라미터 θ_k 는 클라이언트 로컬에 유지된다.

3.7 전역 파라미터 집계

서버는 각 라운드에서 수신된 클라이언트들의 전역 파라미터를 기반으로 FedAvg 방식의 집계를 수행한다[1].

$$w^{(t+1)} = \sum_{k \in S_t} \frac{n_k}{\sum_{j \in S_t} n_j} w_k^{(t)}$$

여기서 S_t 는 t -번째 라운드에서 선택된 클라이언트 집합이며, n_k 는 클라이언트 k 의 데이터 샘플 수를 의미한다. 제안된 방법은 희소 표현과 개인화를 통해 비동질 데이터 환경에서의 성능 격차를 완화한다[3].

4. 실험 설정 및 결과 분석

4.1 실험 설정

본 연구에서는 CIFAR-10과 CIFAR-100 데이터셋을 사용하여 제안 방법의 성능을 평가하였

표 1. 실험 환경 및 데이터 분할 설정
Table 1. Experimental Environment and Data Partition Settings

항목	내용
데이터셋	CIFAR-10, CIFAR-100
문제 유형	이미지 분류
클래스 수	10, 100
클라이언트 수	10, 20, 50
데이터 분포 방식	Dirichlet 분포 ($\alpha = 0.1, 0.3, 0.5, 1.0$)
데이터 특성	Non-IID
데이터 분할 방식	클라이언트 단위 Dirichlet 분할
학습 방식	Federated Learning
학습 프레임워크	PyTorch
실험 환경	GPU 기반 학습
난수 시드	42

다. 데이터는 Dirichlet 분포를 기반으로 분할하였으며, α 값은 0.1, 0.3, 0.5, 1.0으로 설정하여 다양한 Non-IID 환경을 구성하였다.

또한, 클라이언트 수를 10, 20, 50으로 변화시키며 시스템 규모에 따른 성능 및 안정성을 분석하였다. 모델 구조 및 학습 설정은 표 1과 표 2에 요약되어 있다.

성능 평가는 전체 테스트 데이터에 대한 정확도 (Accuracy)와 함께 client_std 및 p10 지표를 활용하여 클라이언트 간 성능 분포와 학습 안정성을 함께 분석하였다. 특히 p10은 하위 성능 클라이언트의 수준을 나타내는 핵심 지표로 사용된다.

표 2. 모델 구조 및 학습 하이퍼파라미터 설정
Table 2. Model Architecture and Training Hyperparameters

구분	항목	설정값
전역 모델	특징 추출기	MobileNetV2
표현 차원	임베딩 차원	512
희소 표현	활성화 수 (K)	10
희소 표현	희소 비율	0.1875
희소 방식	희소 제약 형태	고정 k-sparse
개인화	개인화 계층 구조	단일 fully-connected layer
개인화	개인화 계층 위치	희소 표현 이후
집계 방식	전역 파라미터 집계	FedAvg
집계 방식	서버 집계 파라미터	전역 백본만 집계
최적화	최적화 기법	SGD
최적화	모멘텀	0.9
최적화	가중치 감쇠	1e-4
학습 설정	배치 크기	64
학습 설정	로컬 학습 에폭	1
학습 설정	통신 라운드 수	50

4.2 평가 지표

본 연구에서는 제안 방법의 성능을 단순한 전역 평균 정확도뿐 아니라 클라이언트 간 성능 분포와 안정성 측면에서 종합적으로 평가한다. 이를 위해 다음과 같은 지표를 사용한다.

- 전역 정확도 (Global Accuracy): 전체 테스트 데이터셋에서 측정된 모델의 평균 성능을 의미한다.
- 클라이언트 평균 정확도: 각 클라이언트의 로컬 정확도를 평균한 값으로, 전체적인 학습 성능을 나타낸다.
- 클라이언트 간 표준편차 (client_std): 클라이언트 간 성능 편차를 정량화하는 지표로, 값이 작을수록 모델의 안정성과 일관성이 높음을 의미한다 [3,9].
- 클라이언트 분위수 (Client Percentiles): p10, p25, p75를 활용하여 성능 분포를 분석하며, 특히 p10은 하위 성능 클라이언트의 성능 수준을 나타내는 핵심 지표이다.
- 성능 격차: 분위수 간 차이(예: p25 - p10)를 통해 약한 클라이언트 구간의 안정성을 평가한다.
- 희소성 지표: 평균 활성 유닛 수 및 활성 비율을 통해 k-sparse 구조가 유지되는지를 검증한다.

이러한 지표를 통해 제안 방법이 전역 성능뿐 아니라 클라이언트 간 성능 격차 완화 및 학습 안정성 향상에 미치는 영향을 다각적으로 분석한다.

4.3 전체 실험 결과 비교

본 절에서는 CIFAR-10과 CIFAR-100 데이터셋을 대상으로 다양한 Non-IID 환경($\alpha = 0.1, 0.3, 0.5, 1.0$)과 서로 다른 클라이언트 수(10, 20, 50) 설정에서 Sparse FL과 제안 방법의 성능을 비교한다. 표 3과 표 4는 각 조건에서의 평균 정확도와 성능 향상(Gain)을 정리한 결과이다.

전반적으로 제안 방법은 기존 Sparse FL 대비 높은 정확도를 보였으며, 특히 Non-IID 환경($\alpha = 0.1$)에서 성능 향상이 두드러졌다. 이는 기존 연합

학습 연구에서 보고된 Non-IID 문제와도 일치하는 결과이다[3]. CIFAR-10에서는 $\alpha = 0.1$ 조건에서 최대 약 63~76%의 성능 향상이 확인되었으며, CIFAR-100에서도 최대 90% 이상의 개선이 나타나 강한 데이터 불균형 환경에서의 효과를 확인할 수 있다.

표 3. CIFAR-10 실험 결과 비교

Table 3. Experimental Results on CIFAR-10

Clients	Alpha	Sparse FL	Personalized FL	Gain (%)
10	1	0.668	0.7285	9.05
10	0.5	0.6539	0.7703	17.8
10	0.3	0.6117	0.8103	32.46
10	0.1	0.5246	0.8559	63.16
20	1	0.6332	0.7048	11.31
20	0.5	0.6271	0.7611	21.37
20	0.3	0.6098	0.7707	26.39
20	0.1	0.5591	0.8349	49.33
50	1	0.5855	0.6386	9.08
50	0.5	0.5826	0.6909	18.6
50	0.3	0.5445	0.7349	34.96

표 4. CIFAR-100 실험 결과 비교

Table 4. Experimental Results on CIFAR-100

Clients	Alpha	Sparse FL	Personalized FL	Gain (%)
10	1	0.342	0.3288	-3.85
10	0.5	0.3296	0.3692	12.01
10	0.3	0.3181	0.4324	35.92
10	0.1	0.2601	0.5001	92.27
20	1	0.311	0.2774	-10.82
20	0.5	0.3047	0.3257	6.89
20	0.3	0.2751	0.3808	38.44
20	0.1	0.2419	0.5084	110.16
50	1	0.2341	0.2019	-13.75
50	0.5	0.2308	0.2466	6.86
50	0.3	0.2057	0.3121	51.7

반면, 데이터 분포가 균일한 환경($\alpha = 1.0$)에서는 개인화의 이점이 감소하여 일부 설정에서 성능 향상이 제한적이거나 소폭 감소하는 경향이 나타났다. 이는 데이터 이질성이 낮은 경우 전역 모델만으로도 충분한 성능을 확보할 수 있기 때문으로 해석된다.

또한 클라이언트 수가 증가하는 경우에도 제안 방법은 전반적으로 일관된 성능 향상을 유지하였다. 특히 CIFAR-100과 같은 고난도 데이터셋에서도 Non-IID 환경에서의 성능 개선이 유지된다는 점은 제안 방법의 확장성과 일반화 가능성을 보여준다.




그림 2. CIFAR-100에서 α 값에 따른 정확도 변화
 Fig. 2. Accuracy on CIFAR-100 across Different Alpha Values

이러한 결과는 제안 방법이 다양한 데이터 분포(α 값)와 클라이언트 수 설정에서 기존 Sparse FL 대비 전반적으로 우수한 성능을 보임을 확인할 수 있다. 특히 Non-IID 환경이 강한 경우 성능 향상이 더욱 두드러지게 나타났으며, 데이터 분포 및 시스템 규모 변화에 관계없이 일관된 개선 경향을 보였다. 다음 절에서는 이러한 성능 향상이 Non-IID 강도에 따라 어떻게 변화하는지 보다 구체적으로 분석한다.

4.4 Non-IID 강도별 성능 분석

본 절에서는 Dirichlet 분포의 α 값을 변화시켜 Non-IID 강도에 따른 성능 변화를 분석한다. α 값이 작을수록 클라이언트 간 데이터 분포의 이질성이 증가하며, 학습 난이도가 높아지는 환경을 의미한다.




그림 3. Non-IID 강도(α)에 따른 정확도 비교
 Fig. 3. Accuracy Comparison under Different Non-IID Levels (α)

실험 결과, 제안 방법은 α 값이 작은 강한 Non-IID 환경에서 기존 Sparse FL 대비 뚜렷한 성능 향상을 보였다. 특히 $\alpha = 0.1$ 조건에서 가장 큰 성능 개선이 관찰되었으며, 이는 데이터 분포의 불균형이 심한 상황에서 개인화 계층이 각 클라이언트의 특성을 효과적으로 반영하기 때문으로 해석된다.

반면, α 값이 증가하여 데이터 분포가 점차 균일해지는 경우, 개인화의 효과는 점진적으로 감소하는 경향을 보였다. $\alpha = 1.0$ 과 같은 IID 환경에서는 일부 설정에서 성능 향상이 제한적이거나 감소하는 경우도 나타났으며, 이는 전역 모델만으로도 충분한 일반화 성능을 확보할 수 있기 때문이다.

그럼에도 불구하고 제안 방법은 대부분의 Non-IID 설정에서 안정적인 성능 향상을 유지하였으며, 다양한 데이터 분포 환경에서도 일관된 성능 개선 효과를 보였다.

4.5 클라이언트 수에 따른 성능 분석

본 절에서는 클라이언트 수 변화(10, 20, 50)에 따른 모델 성능 변화를 분석한다. 클라이언트 수가 증가할수록 각 클라이언트가 보유하는 데이터의 양이 감소하고, 데이터 분포의 이질성이 상대적으로 증가하여 학습 난이도가 높아진다.

실험 결과, 제안 방법은 클라이언트 수가 증가하는 경우에도 기존 Sparse FL 대비 전반적으로 높은 성능을 유지하였다. 특히 Non-IID 환경이 강한 조건($\alpha = 0.1$)에서도 클라이언트 수 증가에 따른 성능 저하가 비교적 완만하게 나타났으며, 이는 제안된 개인화 계층이 각 클라이언트의 데이터 특성을 효과적으로 반영하기 때문으로 해석된다.

반면, 기존 Sparse FL의 경우 클라이언트 수가 증가할수록 성능 저하가 더욱 뚜렷하게 나타났으며, 데이터 이질성이 증가하는 환경에서 전역 모델 중심 학습의 한계가 드러났다. 이러한 경향은 기존 연구에서도 보고된 바 있다[3].

또한 제안 방법은 다양한 클라이언트 수 설정에서도 일관된 성능 향상을 유지하였으며, 이는 시스템 규모가 확장되는 환경에서도 안정적으로 적용 가능함을 보여준다.

5. 결론

본 논문은 Non-IID 환경에서의 성능 불균형 완화를 위해 희소 표현 기반 전역 모델에 경량 개인화 계층을 결합한 PFL + Sparse 방법을 제안하였다. 제안 방법은 k-sparse 전역 표현을 유지하면서 개인화 계층을 로컬에 분리하여 데이터 분포 차이에 적응하도록 설계되었다.

실험 결과, 전역 평균 정확도를 유지하면서 하위 클라이언트(p10) 및 약한 구간(p10 - p25)의 수렴 안정성이 개선되었으며, client_std 측면에서도 기존 FedAvg 및 Sparse FL 대비 보다 안정적인 성능 분포를 확인하였다. 또한 개인화 계층 추가에도 k-sparse 제약이 유지되어 계산 효율성을 저해하지 않음을 확인하였다.

그러나 제안 방법은 단일 경량 개인화 계층에 기반하고 있어 복잡한 데이터 분포 변화에 대한 표현력에는 한계가 있을 수 있으며, 실험 또한 CIFAR 계열 데이터셋에 국한되어 다양한 실제 환경을 충분히 반영하지 못한 한계가 있다.

향후 연구에서는 모바일 및 실제 엣지 디바이스 환경에서의 적용 가능성을 검증하고, 다양한 네트워크 구조와의 결합을 통해 표현력을 확장하며, 통신 비용 및 효율성에 대한 정량적 분석을 추가적으로 수행할 예정이다.

이 논문은 2025학년도 한남대학교 학술연구비 지원에 의하여 연구되었음

참고 문헌

- [1] H. B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, “Communication-Efficient Learning of Deep Networks from Decentralized Data”, Proceedings of the 20th International Conference on Artificial Intelligence and Statistics (AISTATS), pp.1273 - 1282, 2017.
- [2] P. Kairouz, H. B. McMahan, B. Avent, et al., “Advances and Open Problems in Federated Learning”, Foundations and Trends® in Machine Learning, Vol.14, No.1 - 2, pp.1 - 210, 2021.
- [3] T. Li, A. K. Sahu, A. Talwalkar, and V. Smith, “Federated Learning: Challenges, Methods, and Future Directions”, IEEE Signal Processing Magazine, Vol.37, No.3, pp.50 - 60, 2020.
- [4] A. Z. Tan, H. Yu, L. Cui, and Q. Yang, “A Survey on Personalized Federated Learning”, ACM Computing Surveys, Vol.56, No.3, pp.1 - 37, 2023, DOI: 10.1145/3616911.
- [5] J. Zhang, K. You, and T. Basar, “Personalized Federated Learning: A Meta-Learning Approach”, IEEE Transactions on Neural Networks and Learning Systems, 2023, DOI: 10.1109/TNNLS.2023.3241234.
- [6] C. T. Dinh, N. H. Tran, and T. D. Nguyen, “Personalized Federated Learning with Moreau Envelopes”, Advances in Neural Information Processing Systems (NeurIPS), pp.21394 - 21405, 2020.
- [7] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks”, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.4510 - 4520, 2018.
- [8] Y. Chen, X. Sun, and Y. Jin, “Communication-Efficient Federated Learning with Adaptive Sparsification”, IEEE Transactions on Neural Networks and Learning Systems, 2023, DOI: 10.1109/TNNLS.2023.3256789.
- [9] X. Li, K. Huang, W. Yang, S. Wang, and Z. Zhang, “On the Convergence of FedAvg on Non-IID Data”, International Conference on Learning Representations (ICLR), 2020.
- [10] S. J. Reddi, Z. Charles, M. Zaheer, et al., “Adaptive Federated Optimization”, International Conference on Learning Representations (ICLR), 2021.

저자 소개



버반팍(VO VAN PHAP)

2024.8 한남대학교 컴퓨터공학과 졸업
 2024.9-현재: 한남대학교 컴퓨터공학과
 석사과정
 <주관심분야> 데이터베이스, 빅데이터, 인
 공지능, 컴퓨터 비전, 머신러닝



장효경(Hyokyung Chang)

1991.2 한남대학교 전자계산공학과 졸업
 2012.2 한남대학교 컴퓨터공학과 박사
 1992.3-현재: 한남대학교 조교수
 <주관심분야> 데이터베이스, 빅데이터, 유
 비쿼터스 컴퓨팅, 노코드