

논문 2026-2-10 <http://dx.doi.org/10.29056/jsf.2026.06.10>

비정형 데이터 환경에서 CCTV 감시 시스템 향상을 위한 PSR-FL 기반 학습 기법

버반팜*, 장효경**†

PSR-FL-based Learning Method for Enhancing CCTV Surveillance System Performance in Non-IID Data

VO VAN PHAP*, Hyokyung Chang**†

요 약

Non-IID 데이터 환경에서 발생하는 전역 모델의 성능 저하 및 클라이언트 간 성능 편차 문제를 해결하기 위해, 본 논문에서는 희소 표현 기반 특징 학습과 경량 개인화 계층을 결합한 PSR-FL 기법을 제안한다. 특히 k -sparse 제약을 도입해 내부 활성 차원을 제한함으로써 불필요한 연산량을 줄이고 학습 안정성을 확보하였다. 아울러 개인화 계층이 로컬 데이터 특성에 자체적으로 적응하기 때문에, 추가적인 통신 오버헤드 없이 클라이언트 간 성능 불균형 문제를 완화한다. RAPv2 및 PETA 데이터셋을 활용한 실험 결과, 제안 아키텍처는 기존 연합학습 방식에 비해 전역 정확도와 안정성을 대폭 향상시켰다. 결론적으로 심각한 데이터 불균형 조건하에서도 우수한 수렴성과 개인화 성능을 입증하였으며, 분산형 CCTV 감시 시스템에서의 높은 실용성과 확장성을 확인하였다.

Abstract

To tackle global model degradation and inter-client disparities under Non-IID data environments, we introduce PSR-FL, a novel federated learning method integrating a sparse representation-based feature learning structure with a lightweight personalization layer. By incorporating a k -sparse constraint to cap internal feature activations, our approach eliminates redundant computational loads while maintaining training stability. Furthermore, the personalization layer adapts directly to unique local data characteristics, minimizing performance variance without incurring additional communication overhead. Benchmarked on the RAPv2 and PETA datasets across diverse non-uniform settings, PSR-FL consistently outperforms conventional federated learning frameworks in both global accuracy and client stability. These empirical results prove its robust convergence and scalability, validating its readiness for distributed CCTV surveillance infrastructures.

한글키워드 : CCTV 감시 시스템, 연합학습, 개인화 연합학습, 희소 표현, Non-IID 데이터

keywords : CCTV surveillance system, Federated learning, Personalized federated learning, Sparse representation, Non-IID data

* 한남대학교 컴퓨터공학과

** 한남대학교 컴퓨터공학과

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

접수일자: 2026.06.01. 심사완료: 2026.06.14.

게재확정: 2026.06.20.

1. 서론

최근 CCTV 기반 감시 시스템은 단순 영상 저장 기능을 넘어 객체 인식, 이상 행동 탐지 및 보행자 속성 인식과 같은 지능형 분석 기능으로 확장되고 있다. 특히 엣지 컴퓨팅 환경에서는 다수의 카메라 장치가 분산된 형태로 운영되며, 데이터 프라이버시 보호와 효율적인 학습 구조의 필요성이 증가하고 있다. 이러한 환경에서 연합학습(Federated Learning)은 로컬 데이터를 외부로 전송하지 않으면서 협력 방식을 통해 글로벌 모델을 구축할 수 있어 효율적인 대안으로 평가받는다 [1].

하지만 실제 감시 구역은 카메라 배치나 조명 조건에 따라 Non-IID 특성을 나타낸다. 이는 전역 모델의 성능 저하를 초래하고 클라이언트 간 불균형을 야기하는 요인이 된다[2, 10]. 또한 엣지 디바이스의 제한된 자원 한계를 고려할 때 모델 경량화는 필수적이다. 이에 본 논문은 해당 자원 장벽을 해소하는 대안으로 경량형 개인화 계층을 희소 표현 전역 모델에 결합한 PSR-FL(Personalized Sparse Representation Federated Learning) 아키텍처를 제시한다. 제안 기법은 k-sparse 활성화를 적용하여 연산 효율과 학습 안정성을 확보하였으며, personalization layer를 통해 각 클라이언트 데이터 특성에 최적화되도록 유도하였다. 마지막으로 RAPv2 와 PETA 데이터셋을 활용한 실험을 통해 다양한 Non-IID 조건에서도 해당 기법의 성능을 검증하였다.

2. 관련 연구 및 PSR-FL 구조

2.1 기존 연구 한계

연합학습의 기본 프레임워크인 FedAvg는 간결성과 효율성을 갖추었으나, Non-IID 조건에서는 글로벌 모델의 역량이 열화되거나 클라이언트 디바이스 사이의 불균형 현상이 나타난다. 이를 보완하고자 Ditto, FedBABU 같은 개인화 연합

학습(PFL) 기법이 제안되어 로컬 개인화 구조로 적응력을 높였으나, 추가적인 최적화나 복잡한 학습 구조를 요구한다는 제약이 있다[3-5, 11].

한편, 희소 표현 기반 학습은 활성화 특징 수를 제한해 연산 부하를 줄이고 효율적으로 특징을 추출한다. 그러나 기존 희소 표현형 연합학습은 각 클라이언트의 고유 데이터 특성을 반영하기에 적응성 측면에서 한계가 있다. 결과적으로 계산 효율성과 개인화 성능 고도화를 동시에 충족할 새로운 연합학습 아키텍처 설계가 요구된다.

2.2 PSR-FL 구조

본 연구에서는 희소 표현 기반 전역 모델과 personalization layer를 결합한 PSR-FL(Personalized Sparse Representation Federated Learning) 구조를 제안한다. 제안된 구조는 shared backbone, sparse representation layer 및 local personalization layer로 구성되며, 전체 구조는 그림 1과 같다.




그림 1. PSR-FL 전체 시스템 구조
Fig. 1. Overall Architecture of the PSR-FL System

Backbone에서 추출된 특징 벡터는 k-sparse 기반 활성화를 통해 상위 K개의 특징만 유지하며, 나머지 값은 0으로 설정된다. 본 연구에서는 임베딩 차원을 512로 설정하고 K=96을 사용하였다. k-spa

rse 활성화 함수는 식(1)과 같이 정의된다.

$$S_k(z_i) = \begin{cases} z_i & \text{if } z_i \in \text{top } K(z) \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

이로써 불필요한 연산 부하를 줄이고 학습 안정성을 도모한다. 아울러 personalization layer는 개별 클라이언트에 로컬로 유지하며 서버와 공유되지 않아 추가적인 통신 오버헤드를 유발하지 않는다. 중앙 서버는 shared backbone 파라미터만을 취합하며, 전역 모델 업데이트는 FedAvg 기반의 식(2)를 바탕으로 전개된다.

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

식 (1)의 k -sparse 활성화를 거쳐 추출된 512 차원의 희소 특징 벡터는 이후 각 클라이언트 내부에 독립적으로 배치된 로컬 개인화 계층(Local Personalization Layer)의 입력으로 전달된다. 해당 계층은 보행자의 다양한 속성을 분류하기 위해 경량 선형 계층(Linear Layer) 구조로 설계되었다. 특히, 본 계층은 중앙 서버와의 전역 가중치 취합 과정에 참여하지 않고, 오직 개별 클라이언트의 로컬 데이터만을 사용하여 독립적인 역전과 방식으로 가중치를 업데이트한다. 이를 통해 추가적인 통신 오버헤드를 유발하지 않으면서도, 분산된 CCTV 카메라별 고유한 환경적 특성에 맞춤형으로 적용할 수 있도록 지원한다.

제안하는 PSR-FL 아키텍처는 희소 표현으로 계산 효율성을 고도화하는 한편, personalization layer를 활용해 Non-IID 환경 속 클라이언트별 적응력을 동시에 확보한다.

3. 실험 설정 및 결과 분석

3.1 실험 전체 흐름

본 연구의 실험은 중앙집중식 학습 성능 측정을 시작으로, 연합학습 환경 속 희소 표현과 개인화

구조가 나타내는 효과를 단계별로 검증하도록 구성하였으며 전체 실험 흐름은 그림 2와 같다.




그림 2. PSR-FL 실험 검증 흐름

Fig. 2. Experimental Validation Flow of PSR-FL

우선 데이터가 균등한 IID 조건에서 기본 성능을 확인한 후, Non-IID 환경에 희소 표현을 주입하여 계산 효율성과 학습 안정성을 도모하였다. 이어서 로컬 개인화 계층을 도입하여 클라이언트 장치 간 성능 불균형이 완화되는 효과를 판별하였다. 또한 클라이언트 수 증가에 따른 확장성과 RAPv2 데이터셋 기반의 일반화 성능까지 다각적으로 검증하였다.

3.2 실험 설정

본 연구에서는 분산 CCTV 감시 환경에서의 성능 평가를 위해 보행자 속성 인식 데이터셋인 RAPv2와 PETA를 사용하여 실험을 수행하였다. RAPv2는 다양한 감시 카메라 환경과 보행자 속성 정보를 포함하는 대규모 데이터셋이며[8], PETA는 다양한 시점과 환경 조건에서 수집된 보행자 속성 기반 데이터셋으로 구성된다[9]. 두 데이터는 실제 CCTV 감시 환경과 유사하여, Non-IID 환경 속 개인화 연합학습 성능 검증에 적절하며 상세한 실험 설정은 표 1과 같다.

데이터는 클라이언트별 데이터 이질성을 반영하기 위해 Dirichlet 분포 기반으로 분할하였으며, α 값은 0.1, 0.3, 0.5 및 1.0으로 설정하였다. α 값이 작을수록 클라이언트 간 데이터 분포 격차가

벌어지는 강한 Non-IID 조건을 뜻한다.

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

항목	내용
데이터셋	RAPv2, PETA
문제 유형	보행자 속성 인식
클라이언트 수	10, 20, 50
데이터 특성	Non-IID
데이터 분할 방식	Dirichlet 분포 ($\alpha=0.1, 0.3, 0.5, 1.0$)
Backbone	MobileNetV2
Embedding Dimension	512
k-sparse	K=96
학습 방식	Federated Learning
난수 시드	42

아울러 다각적인 분산 환경 검증을 위해 클라이언트 수는 10, 20, 50으로 설정하였다. Backbone 모델은 경량 CNN 구조인 MobileNetV2를 사용하였으며, 임베딩 차원은 512로 설정하였다[7]. 희소 표현을 위해 k-sparse 기반 활성화를 적용하였으며, 상위 K개의 특징만 유지하도록 K=96

으로 설정하였다. 아울러 실험 결과의 재현성을 보장하기 위해 난수 시드(Random Seed)는 42로 고정하였다.

3.3 평가 지표

본 연구에서는 제안한 PSR-FL 구조의 성능을 평가하기 위해 Accuracy, Worst-10%, 그리고 활성 뉴런 비율(Active Neuron Ratio)을 사용하였다. Accuracy는 전체 분류 성능을 평가하기 위해 사용하였으며, Worst-10%는 Non-IID 환경에서 성능이 낮은 클라이언트의 안정성을 분석하기 위해 활용하였다. 또한 sparse representation의 계산 효율성을 분석하기 위해 전체 feature 중 실제 활성화된 뉴런의 비율을 함께 측정하였다.

3.4 실험 결과 및 분석

먼저 희소 표현 메커니즘이 계산 효율 및 모델 성능 유지에 미치는 기여도를 분석하였다. 그림 3은 IID 조건의 연합학습과 Non-IID 환경에서의 희소 표현을 탑재한 PSR-FL의 수렴 성능을 대조한 지표를 보여준다. 도출된 수치상, 제안 기법은 전체 뉴런 중 약 18.75%만 활성화했음에도 77.07%의 정확도를 달성하며 IID 조건 연합학습의 77.41%와 대등한 성능을 달성하였다. 학습 초기 시점에는 다소 완만한 수렴 속도가 관측되었




그림 3. Sparse Representation 기반 성능 비교
Fig. 3. Sparse Performance Comparison

으나, 에포크가 진행될수록 안정적인 수렴 곡선을 그리는 흐름을 확인하였다.

이러한 결과는 희소 표현 구조가 불필요한 특성 활성화를 효율적으로 차단하는 한편 주요 특징 정보는 온전히 유지함을 뜻하며, 나아가 엡지 디바이스 환경의 연산 부하 경감에도 탁월함을 입증한다.

이어서, Non-IID 환경에서 클라이언트 수 증가에 따른 성능 추이와 PSR-FL 내 개인화 계층이 발휘하는 효용성을 검증하였다. 그림 4에서 확인할 수 있듯이, 클라이언트 수가 10개에서 50개로 늘어날수록 데이터 분포의 이질성이 극대화되어 기존 연합학습 환경 내 클라이언트 장치 간 성능 불균형 현상이 심화되었다. 특히 개인화 기법을 적용하지 않은 경우, 평균 성능은 75.88%에서 68.87%로 하락하였으며 성능이 저조한 클라이언트의 정확도 또한 그림 4의 중앙 그래프(Without Personalization)의 최저 성능 지표와 같이 75.55%에서 74.31% 수준까지 대폭 감소하는 현상이 나타났다. 반면 PSR-FL 구조에 개인화 계층을 적용한 경우에는, Non-IID 환경에서도 전체 클라이언트의 평균 성능이 98.9% 이상의 매우 높고 안정적인 성능을 지속적으로 유지하였고, 기존에 낮은 성능을 보이던 클라이언트 역

시 그림 4의 우측 성능 향상 그래프(Client Improvement)에서와 같이 96.72% 수준에서 99% 이상으로 크게 향상되는 우수한 결과를 직접 확인하였다. 이러한 실험 결과는 개인화 계층이 개별 클라이언트의 로컬 데이터 특성에 효과적으로 적응하면서도 전역 모델의 공통 지식을 안정적으로 유지할 수 있음을 의미하여, 결과적으로 대규모 연합학습 환경에서도 제안하는 PSR-FL 구조가 높은 안정성과 탁월한 확장성을 가질 수 있음을 보여준다.

다양한 non-IID 환경에서 PSR-FL의 안정성을 추가적으로 검증하기 위해 RAPv2 데이터셋 기반 실험을 수행하였다. 그림 5와 표 2는 클라이언트 수 및 Dirichlet α 값 변화에 따른 클라이언트 간 성능 표준편차(Client Std) 변화를 나타낸다. 실험 결과, α 값이 감소할수록 데이터 분포의 이질성이 증가하면서 기존 FL에서는 클라이언트 간 성능 편차가 크게 증가하는 경향을 보였다.

반면 PSR-FL을 도입한 이후에는 대부분의 환경에서 성능 표준편차가 감소하는 경향을 보였다. 다만, 데이터 분포의 이질성이 극대화된 강한 Non-IID 환경($\alpha=0.1$) 및 일부 설정에서는 개인화 적용 후 표준편차가 일부 상승하는 현상이 관찰되었다.




그림. 4. PSR-FL의 확장성 및 Non-IID 성능 분석
Fig. 4. PSR-FL Scalability and Performance




그림. 5. RAPv2 기반 성능 편차 분석

Fig. 5. Client Performance Variance on RAPv2

이는 개별 클라이언트가 고유한 로컬 데이터 특성에 맞춰 독립적으로 최적화되는 과정에서 발생하는 개인화 연합학습의 자연스러운 특성으로 해석되며, 특히 클라이언트 수가 대폭 증가한 환경에서도 상대적으로 안정적인 지표를 유지하는 흐름을 확인하였다.

이러한 결과는 제안하는 개인화 메커니즘이 개별 클라이언트의 로컬 데이터 특성에 효율적으로 반영되면서도 전체 모델의 안정성을 유지할 수 있음을 시사한다. 아울러 해당 지표는 PSR-FL 아키텍처가 특정 데이터셋에 종속되지 않고 다각적인 CCTV 환경에서도 견고하게 동작할 수 있음을 입증한다.

결론적으로, 앞서 수행한 PETA 데이터셋 기반의 시뮬레이션 실험에 이어 실제 CCTV 환경의 복잡한 데이터 분포와 높은 난이도를 반영한 RAPv2 데이터셋에서도 PSR-FL 아키텍처의 안정적인 수렴 성능을 다시 한번 확인하였다. 이러한 실험 결과는 제안 기법이 클라이언트 수 증가에 따라 필연적으로 발생하는 장치 간 성능 불균형 문제를 효과적으로 완화할 수 있음을 증명할 뿐만 아니라, 특정 데이터셋의 고유한 특성에 의존하지

않고 독립적인 알고리즘 효율성을 확보할 수 있음을 검증한다.

표 2. RAPv2 클라이언트 성능 비교

Table 2. Client Performance Variance on RAPv2

Alpha	Client 수	개인화 적용 전 표준편차 (%)	개인화 적용 후 표준편차 (%)
1.0	10	4.8	7.4
1.0	20	2.6	2.8
1.0	50	4.5	3.9
0.5	10	7.7	5.1
0.5	20	4.2	4.3
0.5	50	4.9	4.0
0.3	10	8.1	7.9
0.3	20	5.1	5.0
0.3	50	8.1	5.3
0.1	10	8.6	10.6
0.1	20	9.8	11.0
0.1	50	9.5	7.3

이처럼 오픈 벤치마크 데이터셋을 통한 다각적인 검증의 성공은 알고리즘의 유연성을 입증하는 것이며, 궁극적으로 향후 실제 환경을 대상으로 한 시스템 배포 및 실용적 응용 연구를 전개하기 위한 강인한 기술적 선행 기반과 신뢰성 있는 이론적 토대를 마련하였음을 시사한다

4. 결론

본 연구에서는 Non-IID 데이터 환경 기반의 분산형 CCTV 감시 시스템에서 학습 성능을 극대화하기 위해, PSR-FL(Personalized Sparse Representation-Federated Learning) 아키텍처를 제안한다. 본 아키텍처는 희소 표현 메커니즘과 개인화 계층을 유기적으로 결합함으로써, 연산 효율성 확보와 클라이언트별 데이터 적응성 제고를 동시에 달성하고자 하였다. 이를 위해 k -희소(k -sparse) 기반 활성화 알고리즘을 도입하여 활성 특징의 수를 제한함으로써 연산 부하를 대폭 경감하고 학습 안정성을 향상시켰다. 아울러, 개별 클라이언트의 로컬 영역에 개인화 계층을 유지하는 것은 각 카메라 고유의 데이터 특성에 유연하게 적응하여 전체 시스템의 성능 평형을 도모하며, 결과적으로 데이터 비독립적(Non-IID) 특성으로 인해 발생하는 단말 장치 간 정확도 편차를 추가적인 통신 오버헤드 없이 최소화한다.

RAPv2 및 PETA 데이터셋을 활용한 다각적인 실험적 검증을 통해, 제안 기법이 극심한 Non-IID 조건 하에서도 안정적인 수렴 성능을 유지하며 클라이언트 장치 간 성능 편차를 유의미하게 완화함을 실증하였다. 본 실험적 지표는 PSR-FL 아키텍처가 자원 제약적인 엣지(Edge) 기반 CCTV 감시 환경에 실용적으로 적용될 수 있음을 시사하며, 향후 실제 엣지 환경에서의 실시간 성능 검증 및 통신·에너지 효율성을 고려한 심화 연구를 전개할 계획이다.

이 논문은 2025학년도 한남대학교 학술연구비 지원에 의하여 연구되었음

참 고 문 헌

- [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 International Conference on Artificial Intelligence and Statistics (Proc. AISTATS), pp.1273 - 1282, 2017.
- [2] T. Li, A. K. Sahu, M. Zaheer, M. Sanjabi, A. Talwalkar, and V. Smith, "Federated Optimization in Heterogeneous Networks," Proceedings of Machine Learning and Systems (Proc. MLSys), 2, pp.429-450, 2020, URL : mlsys.org
- [3] J. Oh, S. Kim, and S.-Y. Yun, "FedBABU: Toward Enhanced Representation for Federated Image Classification," Proceedings of International Conference on Learning Representations (Proc. ICLR), 2022, URL : <https://openreview.net/forum?id=HuaYQfggn5u>
- [4] Y. Li, K. Huang, W. Yang, S. Wang, and Z. Zhang, "Ditto: Fair and Robust Federated Learning Through Personalization," Proceedings of International Conference on Machine Learning (Proc. ICML), pp.6357-6368, 2021.
- [5] M. Arivazhagan, V. Aggarwal, A. K. Singh, and S. Choudhary, "Federated Learning with Personalization Layers," arXiv preprint arXiv:1912.00818, 2019, DOI : 10.48550/arXiv.1912.00818
- [6] A. Makhzani and B. Frey, "K-Sparse Autoencoders," Proceedings of International Conference on Learning Representations (Proc. ICLR), 2014, DOI : 10.48550/arXiv.1312.5663
- [7] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," Proceedings of IEEE Conference on Computer Vision and Patte

- rn Recognition (Proc. CVPR), pp.4510 - 4520, 2018, DOI : 10.1109/CVPR.2018.00474
- [8] D. Li, X. Chen, Z. Zhang, and K. Huang, "RAP: Richly Annotated Pedestrian Dataset for Person Attribute Recognition," Proceedings of IEEE International Conference on Image Processing (Proc. ICIP), pp.3096-3100, 2016, DOI : 10.1109/ICIP.2016.7532929
- [9] Y. Deng, P. Luo, C. C. Loy, and X. Tang, "Pedestrian Attribute Recognition at Far Distance," Proceedings of the ACM International Conference on Multimedia (Proc. ACM MM), pp.789 - 792, 2014, DOI : 10.1145/2647868.2654966
- [10] P. Kairouz et al., "Advances and Open Problems in Federated Learning," Foundations and Trends in Machine Learning, 14(1 - 2), pp.1 - 210, 2021, DOI : 10.1561/22000000083
- [11] V. V. Phap and H. Chang, "A Study of Personalized Federated Learning Based on Sparse Representations," Journal of Software Forensics, 22(1), pp.67 - 75, 2026, URL : kci.go.kr.

저 자 소 개



버반팜(VO VAN PHAP)

2024.8 한남대학교 컴퓨터공학과 졸업
2024.9-현재: 한남대학교 컴퓨터공학과
석사과정

<주관심분야> 데이터베이스, 빅데이터, 인공지능, 컴퓨터 비전, 머신러닝



장효경(Hyokyung Chang)

1991.2 한남대학교 전자계산공학과 졸업
2012.2 한남대학교 컴퓨터공학과 박사

1992.3-현재: 한남대학교 조교수
<주관심분야> 데이터베이스, 빅데이터, 유비쿼터스 컴퓨팅, 노코드