

FedAttnPSO: Non-IID 환경에서 연합학습 정확도 향상을 위한 개선된 알고리즘 제안

장 선 영*, 김 중 욱*, 최 미 정[°]

FedAttnPSO: A Novel Algorithm for Improving Federated Learning Accuracy in Non-IID Environments

Sun-young Jang*, Jong-Wouk Kim*, Mi-Jung Choi[°]

요 약

연합학습은 데이터를 공유하지 않고 분산된 환경에서 학습을 수행할 수 있도록 설계된 방법으로, 개인정보보호가 중요한 현대사회에서 실용성을 높이 평가받고 있다. 하지만 각 클라이언트가 보유한 데이터의 양과 분포 및 특성이 모두 상이한 Non-IID 환경에서 모델 성능이 저하되는 한계가 존재한다. 이 문제를 해결하기 위해 알맞은 클라이언트 선택과 가중치 집계 문제를 해결해야 한다. 본 논문에서는 이 문제들을 해결하기 위해 FedAttnPSO를 제안한다. FedAttnPSO는 각 클라이언트의 손실값을 기준으로 성능이 우수한 상위 N개의 클라이언트를 선택한다. 선택된 클라이언트들 중 Attention Mechanism을 통해 성능이 높은 클라이언트의 기여도를 높이고 성능이 낮은 클라이언트의 영향력을 제한하여 동적으로 집계 가중치를 부여한다. 또한 클라이언트 및 서버 측에서 PSO (Particle Swarm Optimization) 알고리즘을 활용한 학습 최적화를 통해 전체적인 모델의 성능을 향상시킨다. FedAttnPSO와 다른 연합학습 알고리즘을 비교하기 위해 표준 이미지 데이터셋인 CIFAR-10, CIFAR-100을 사용하여 비교하였으며, Non-IID 환경에서의 실험을 위해 FEMNIST를 사용하여 FedAttnPSO를 평가 및 비교했다. 실험 결과, 모든 데이터셋에서 기존 알고리즘 대비 성능이 향상됨을 확인하였다.

Key Words : Federated Learning, Particle Swarm Optimization, Attention Mechanism, Non-IID

ABSTRACT

Federated learning is a distributed training approach designed to operate without sharing raw data, making it particularly valuable in modern society where data privacy is paramount. However, in non-IID environments—where the amount, distribution, and characteristics of data vary significantly across clients—the performance of federated models tends to degrade. To address this issue, it is essential to carefully select clients and effectively aggregate their model updates. In this paper, we propose FedAttnPSO, a novel aggregation algorithm designed to tackle these challenges. FedAttnPSO first selects the top-N performing clients based on their local loss values. Among the selected clients, it dynamically assigns aggregation weights using an attention mechanism, enhancing the contributions of high-performing clients while limiting the influence of low-performing ones. To evaluate the performance of FedAttnPSO, we conducted experiments using the standard image datasets CIFAR-10 and CIFAR-100, as well as FEMNIST to simulate non-IID conditions. The results demonstrate that FedAttnPSO consistently outperforms existing federated learning algorithms across all datasets.

※ 이 논문은 보건복지부의 재원으로 한국보건산업진흥원의 보건의료기술연구개발사업지원에 의하여 이루어진 것임(과제 번호: HI23C0733).

* First Author : Kangwon National University Department of Data Science, jsy0708@kangwon.ac.kr

[°] Corresponding Author : Kangwon National University Department of Computer Science and Kangwon National University IGP. in Medical Bigdata Convergence, mjchoi@kangwon.ac.kr

* Kangwon National University Department of Computer Science, jw.kim@kangwon.ac.kr

논문번호 : KNOM2025-01-04, Received July 14, 2025; Revised August 08, 2025; Accepted August 25, 2025

I. 서 론

최근 스마트폰, 웨어러블 기기와 같은 엣지 디바이스의 발전과 함께 병원, 금융 기관 등에서 생성되는 데이터 양 또한 기하급수적으로 늘어나고 있다. 이러한 데이터는 개인 정보 보호 관점에서 민감한 정보를 포함하고 있는 경우가 많아 외부로 직접 공유하거나 중앙 서버에 집중시키는 것이 어렵다. 이러한 배경 속에서 연합학습(Federated Learning, FL)은 원시 데이터를 중앙 서버로 전송하지 않고 분산된 환경에서 협력적으로 머신러닝 모델을 훈련하는 새로운 패러다임으로 주목받고 있다. 연합학습은 각 클라이언트가 자신의 로컬 데이터로 모델을 개별 훈련한 뒤, 학습된 모델의 파라미터만을 중앙 서버로 전송한다. 서버는 수집된 파라미터를 종합하여 하나의 전역 모델을 구축하기 때문에 데이터 프라이버시를 효과적으로 보호할 수 있다. 연합학습에서 가장 널리 사용되는 알고리즘은 FedAvg (Federated Averaging)으로, 매 라운드마다 무작위로 선택된 클라이언트들의 로컬 모델의 파라미터를 데이터 크기에 비례하여 단순 평균하는 방식으로 동작한다.

하지만 실제 연합학습 환경은 각 클라이언트가 보유한 데이터의 양, 분포, 특성이 다른 Non-IID (Non-Independent and Identically Distributed) 라는 본질적인 한계를 가진다. 각 클라이언트의 데이터는 고유한 사용 패턴에 따라 생성되므로 편향된 특성을 가지며, 이는 전역 모델의 일반화 성능을 저해하는 핵심 원인이 된다. FedAvg 알고리즘은 이러한 Non-IID 환경에서 명확한 문제를 드러낸다. FedAvg의 무작위 클라이언트 선택 방식은 데이터의 품질이나 대표성과 무관하게 클라이언트를 선택하므로 편향되거나 노이즈가 많은 데이터를 가진 클라이언트가 학습에 참여하여 전역 모델의 성능을 저하시킬 수 있다[2],[3]. 또한 데이터의 양에만 비례하여 가중치를 부여하는 단순 가중치 집계 방식은 데이터의 품질이나 학습 기여도를 전혀 고려하지 못하며, 이로 인해 편향된 대용량 데이터가 모델에 과도한 영향을 미치는 결과를 초래할 수 있다[4]. 이러한 문제를 해결하기 위한 연구가 진행되었지만 실제 연합학습 환경에서는 아직 많은 어려움을 겪고 있다[5]. 따라서 Non-IID 환경에서 연합학습의 성능을 높이기 위해서는 클라이언트 선택과 가중치 집계의 고도화를 넘어, 다양한 클라이언트

트 모델로부터 최적의 전역 모델을 탐색하는 고도화된 최적화 관점의 접근이 필요하다.

이에 본 논문에서 제안하는 FedAttnPSO는 두 가지 문제를 다음과 같이 해결한다. 클라이언트 선택 문제에 대응하기 위해 FedAvg의 무작위 방식 대신 모델의 손실값(loss)을 기반으로 학습에 기여할 가능성이 높은 클라이언트를 선별하여 학습의 효율성과 안정성을 높인다. 가중치 집계 문제를 해결하기 위해 기존의 데이터 크기 기반 단순 평균 방식을 어텐션 기반 가중치 계산과 PSO 기반 점진적 업데이트라는 2단계의 정교한 방식으로 대체한다. 어텐션 메커니즘을 활용하여 각 클라이언트 모델이 전역 모델에 기여하는 중요도를 계산한다. 이렇게 계산된 중요도와 입자 군집 최적화(Particle Swarm Optimization, PSO) 알고리즘을 통해 기존 전역 모델을 새로운 전역 모델로 안정적이고 점진적으로 이동시킨다. 이러한 방식은 특정 라운드의 편향된 집계 결과가 전역 모델을 한 번에 오염시키는 것을 방지하는 역할을 할 수 있다. 더 나아가, 클라이언트 측에서도 PSO를 활용한 로컬 학습을 수행하여 로컬 모델 자체의 품질을 높이고 전체 학습 과정의 안정성을 더한다. 결론적으로 FedAttnPSO는 명확한 기준의 클라이언트 선택, 정교한 가중치 집계 방식, 그리고 모델 학습 최적화를 통해 Non-IID 환경의 한계를 극복하고 안정적으로 전역 모델을 구축 및 배포하는 것을 목표로 한다.

본 논문의 구성은 다음과 같다. 2장에서는 제안하는 알고리즘에 적용된 핵심 기술들과, Non-IID 환경에서 연합학습 성능 향상을 위해 수행된 관련 연구들을 소개한다. 3장에서는 제안 알고리즘의 구체적인 구조와 동작 원리를 설명하고, 4장에서는 실험 설정 및 결과 분석을 다룬다. 마지막으로 5장에서는 본 연구의 결론을 제시하고, 향후 연구 방향에 대해 논의한다.

II. 배경 지식 및 관련 연구

이 장에서는 본 논문에서 제안한 FedAttnPSO의 이해를 돕기 위한 관련 핵심 기술들의 배경 지식과 연합학습 성능 향상을 위한 기존 연구들을 소개한다. 나아가 본 논문이 기존 연구와 구별되는 차별점을 설명한다.

2.1 배경 지식

2.1.1 Particle Swarm Optimization

Particle Swarm Optimization (PSO)[6]는 Kernedy와 Eberhart가 제안한 전역 최적화 알고리즘이며, Swarm Intelligence 개념에 기반을 두고 있다. 군집 지능은 단순한 개체 간의 지역적인 상호작용을 통해서 복잡하고 지능적인 집단 행동이 자발적으로 일어나는 자연 현상을 인공지능에 적용한 분야이다. 특히 PSO 알고리즘은 새 떼의 이동, 물고기 무리의 행동 등에서 영감을 얻은 방식이며, PSO 알고리즘에서는 최적해를 찾기 위해 입자(Particle)를 가지고 있다. 각 입자는 자신의 위치와 속도를 가지며, 이를 사용하여 집단적으로 최적해를 찾아간다. 입자는 매 반복마다 자신의 최적 경험과 전체 입자 중 가장 우수한 위치를 참조하여 새로운 위치를 결정하며, PSO의 핵심 수식은 다음 수식 (1) - (2)와 같다:

$$v_i^{t+1} = w \cdot v_i^t + c_1 \cdot r_1 \cdot (p_i - x_i^t) + c_2 \cdot r_2 \cdot (g - x_i^t) \quad (1)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (2)$$

- v_i : 입자 i 의 속도
- x_i : 입자 i 의 위치
- p_i : 입자 i 의 개인 최적 위치
- g : 전역 최적 위치
- w : 관성 계수
- c_1, c_2 : 가속 계수(인지 계수, 사회적 계수)
- r_1, r_2 : [0,1] 범위의 난수

관성 계수(w)는 이전 속도를 얼마나 유지할지 결정하는 계수로서, 관성 계수가 클수록 더욱 멀리 이동하여 탐색이 강화되고, 작을수록 수렴이 강화된다. 가속 계수(c_1, c_2)는 목표 지점으로 얼마나 빠르게 끌려갈지 조절한다. 인지 계수(c_1)는 개인적 요인으로, 자신의 최적 경험으로 되돌아가려는 정도이다. 사회적 계수(c_2)는 사회적 요인으로써 전역 최적 위치로 끌려가는 정도이다. r_1 과 r_2 는 무작위 난수로서 매 반복마다 새로 생성된다. 입자마다 다른 방향성과 크기로 이동하도록 해줌으로써 무작위성을 부여하여 탐색 공간을 넓히고 지역 최적점에 갇히지 않도록 한다. 이러한 PSO 알고리즘은 탐색과 수렴의 균형을 유지하면서 점진적으로 최적해에 접근하는 능력이 뛰어나기 때문에 연합학습의 집계를 넘어 각 클라이언트의

로컬 모델 최적화와 중앙 서버에서 글로벌 모델 최적화 단계에 적용하여 전체적인 학습 성능을 높이는 데 효과적이다.

2.1.2 Attention Mechanism

어텐션 메커니즘(Attention Mechanism)은 입력 정보 중 중요한 부분에 집중하여 더 큰 비중을 두고 처리하는 방식으로, 자연어처리 분야에서 시작되어 이후 컴퓨터 비전 등 다양한 분야로 확장되었다. 특히 입력 데이터의 각 요소가 서로에게 어떤 영향을 미치는지 학습하고, 이 상호작용의 중요도를 동적으로 조절하는 데 유용하다. 기존의 단순한 평균 방식에서는 모든 입력 요소가 동일한 중요도로 처리되지만 Attention Mechanism은 각 요소의 상대적 중요도를 학습하여 이를 기반으로 출력에 반영한다. 예를 들어 문장을 번역할 때 특정 단어가 문장의 의미에 더욱 큰 영향을 미친다면 그 단어에 더욱 높은 가중치를 부여하여 번역 품질을 높일 수 있다.

기존에는 클라이언트마다 상이한 데이터의 양, 품질, 분포를 가지고 있음에도 불구하고 단순 평균 방식으로 글로벌 모델로 집계를 진행하였기 때문에 전체 모델의 성능이 저하될 수 있다는 문제가 존재한다. 이때 어텐션 메커니즘을 연합학습에 적용하여 각 클라이언트가 글로벌 모델 업데이트에 얼마나 영향을 미쳤는지 파악할 수 있다. 이에 따라 각 클라이언트에 대한 중요도를 파악하고, 중요도에 따라 글로벌 모델 업데이트를 위해 집계할 때 집계 가중치를 다르게 부여함으로써 보다 효과적이고 유연한 집계가 가능하다.

2.2 관련 연구

2.2.1 클라이언트 선택 개선 연구

Chen 외[7]는 FedAvg의 무작위 클라이언트 선택 방식이 Non-IID 데이터와 클라이언트 간 자원 이질성으로 인해 학습 효율을 크게 저하한다고 지적하며, 이를 개선하기 위한 새로운 방법으로 FedGRA(Federated Grey Relational Analysis)를 제안하였다. FedGRA는 무작위 선택 대신 그레이 관계 분석(GRA) 이론을 기반으로 클라이언트를 선택한다. 장치 이질성(CPU 및 RAM의 사용량), 데이터 이질성(훈련 손실 및 가중치 발산), 그리고 모든 클라이언트가 특정 라운드 수 내에서 최소 한 번은 훈련에 참여하도록 보장하는 공

정성 보장이라는 세 가지 주요 지표를 고려하여 각 클라이언트의 그레이 관계 등급(GRG)을 계산하고 이 등급이 높은 클라이언트를 선택하는 방식이다. 하지만 선택된 클라이언트를 글로벌 모델로 집계하는 과정에는 FedAvg의 기본적인 집계 방식인 가중 평균 방식을 사용하였다. FedGRA는 MNIST 2NN 실험에서 80% 정확도 달성에 FedAvg보다 69%의 라운드 감소로, 수렴 속도의 향상을 보였다.

Nguyen 외[8]는 데이터 프라이버시를 침해하지 않으면서 클라이언트 데이터를 기반으로 클라이언트를 선택하는 FedDSS (Federated Data Similarity Selection) 프레임워크를 제안한다. 데이터 통계 유사성과 왜도 유사성을 측정하여 각 클라이언트의 데이터 분포의 모양이 얼마나 유사한지 측정한다. 이를 바탕으로 각 클라이언트마다 자신과 가장 유사한 N개의 이웃 클라이언트를 찾아 N-SNN을 구성하고, N-SNN을 기반으로 공정성을 고려한 K-단계 random walk 알고리즘을 사용하여 높은 유사성을 가진 클라이언트를 선택한다. 선택된 클라이언트를 연합 평균(FedAvg) 방식으로 집계하여 전역 모델을 업데이트한다. 실험 결과 IID 및 Non-IID 환경에서 FedAvg 대비 더욱 빠른 수렴을 달성하였다.

Marfo 외[9]는 효율적인 클라이언트 선택과 견고한 개인 정보 보호 메커니즘이 핵심 과제를 언급하며 FedAvg의 무작위 클라이언트 선택 방식의 한계를 개선하는 새로운 방법을 제안한다. 먼저, 각 라운드에서 사용 가능한 클라이언트들을 데이터 품질 및 계산 용량과 같은 요소를 사용하여 계산된 유틸리티 점수(utility scores)를 기반으로 평가한다. 유틸리티 점수가 높은 K개의 클라이언트를 모델 훈련에 선택하고, 이 과정은 성능과 시스템 제약 조건에 따라 동적으로 조절한다. 그리고 개인 정보 보호를 위해 차등 프라이버시 및 Fault Tolerance를 통합하여 데이터 추론 방지와 실패로부터의 복구 가능성을 높인다. 선택된 클라이언트들을 집계하는 과정에 구체적인 집계 방식은 언급되지 않았지만, Aggregate updates라는 용어를 통해 표준적인 연합 학습 집계 절차가 사용되었음을 유추할 수 있다. 비교 대상으로는 ACFL 및 FedL2P가 사용되었으며, 기존 베이스라인 대비 정확도가 7% 향상되었으며, 훈련 시간 또한 25% 가량 감소되어, 제안하는 방법이 정확도와 훈련 시간을 크게 개선하고 시스템의 견고성을 높였음을 입증하였다.

2.2.2 가중치 집계 개선 연구

Shi 외[10]는 FedAvg의 데이터 크기 기반 집계 의 모델 성능 저하 및 불안정한 수렴 문제를 해결하기 위해 FedAWA (Federated learning with Adaptive Weight Aggregation)라는 새로운 방법을 제안한다. FedAWA는 클라이언트 벡터라는 개념을 도입하여 집계 가중치를 적응적으로 최적화한다. 클라이언트 벡터는 로컬 데이터의 변화와 모델 업데이트의 방향을 반영하고, 글로벌 벡터는 클라이언트 벡터들을 집계 가중치로 가중 평균한 값이다. 클라이언트 벡터와 병합된 글로벌 벡터 간의 정렬 정도를 사용하여 전역 최적화 방향과 밀접하게 정렬되는 로컬 모델에 높은 집계 가중치를 할당하여 전역 모델의 안정성과 일반화 성능을 향상시킨다. 제안하는 방법은 Non-IID 환경에서 전반적으로 높은 성능을 달성하였다.

Ye 외[11]는 로컬 및 전역 카테고리 분포 간의 불일치가 유익한 보완 지표가 될 수 있다는 분석을 기반으로 새로운 방법인 FedDisco (Federated Learning with Discrepancy-Aware Collaboration)를 제안한다. 각 클라이언트는 자신의 로컬 카테고리 분포와 전역 카테고리 분포 간의 불일치 수준을 계산한다. 이 계산은 클라이언트 측에서 이루어지므로 추가적인 데이터 공유 없이 프라이버시를 보존할 수 있으며, 서버는 클라이언트로부터 수집한 불일치 수준 값을 바탕으로 각 클라이언트의 데이터셋 크기와 로컬 불일치 수준을 활용하여 집계 가중치를 결정한다. 새로 결정된 불일치 인자 집계 가중치를 사용하여 로컬 모델을 집계하여 전역 모델을 업데이트한다. 하지만 클라이언트 선택에 대해서는 FedAvg에서 사용되는 무작위 클라이언트 샘플링 방법을 사용한다. FedDisco는 다양한 데이터셋과 Non-IID 환경에서 기존 알고리즘 대비 높은 성능 향상을 보였다.

Bang 외[12]는 딥 강화학습(DRL)을 활용해 배치 크기와 가중치 집계를 조정하는 BWA (Batch size and Weighted aggregation Adjustment) 메커니즘을 제안하였다. 전역 모델 정확도를 최대화하기 위한 최적화 문제는 여러 개의 국소 최적해를 가질 수 있는 복잡한 구조로, 기존의 볼록 최적화 기법으로는 해결이 어려워 이를 해결하기 위해 DRL을 적용하였다. DRL의 PPO (Proximal Policy Optimization) 방법을 기반으로 최적의 클라이언트 집계 가중치를 계산한다.

서버는 이 값을 사용하여 로컬 모델을 집계하여 전역 모델을 업데이트한다. 클라이언트 선택 시에는 클라이언트 집계 가중치가 특정 임계값 이하인 경우는 제외하는 방식으로 동작한다. BWA는 MNIST, FashionMNIST, CIFAR10 데이터셋의 Non-IID 환경에서 FedAvg 대비 목표 정확도 달성까지 57.78%의 라운드 감소를 달성하였다.

2.2.3 FedPSO

Park 외[13]는 연합학습에서 기존의 FedAvg가 모델 가중치 전체를 서버에 전송하고 데이터 크기만을 기반하는 집계하는 방식에서 발생하는 문제를 해결하기 위해 FedPSO (Federated Particle Swarm Optimization) 알고리즘을 제안한다. 기존 FedAvg는 학습된 로컬 모델의 모든 가중치를 서버로 전송하는데, 이는 네트워크 통신 비용을 증가시키고, 불안정한 네트워크 환경에서 정확도 감소를 유발할 수 있다. 따라서 FedPSO는 클라이언트가 학습된 로컬 모델의 모든 가중치 대신 손실값(loss)만을 서버로 전송한다. 그 다음 분산 환경에서 최적의 해를 찾는 데 적합한 PSO 알고리즘을 사용하는데, 각 클라이언트 모델을 입자로 간주하여 자신의 최고 성능과 전체 군집의 최고 성능을 공유하며 반복적으로 최적값을 찾아가는 방식으로 동작한다. 그리고 모든 클라이언트를 평균내어 집계하는 것이 아닌, loss가 가장 낮은 클라이언트만 식별하여 전역 모델로 업데이트한다. 실험 결과, CIFAR-10 데이터셋에서 FedAvg 대비 9.47% 더 높은 정확도를 달성하였다. 하지만 FedPSO는 통신 효율성을 높이기 위해 집계 과정을 loss가 가장 낮은 클라이언트만을 선택하는 방식을 사용하였다. 이는 Non-IID 환경에서 클라이언트 다양성 반영이 미흡하다는 분명한 한계가 존재한다. 클라이언트 간 데이터 분포의 편차가 존재하는 상황에서 단일 클라이언트의 weight로 글로벌 모델을 대체하는 방식은 전체 모델의 일반화를 저해할 수 있다.

대다수의 기존 연구는 클라이언트 선택 연구와 가중치 집계 연구 중 하나에 집중하는 경향이 있었으며, 클라이언트 선택 및 가중치 집계에 집중하여 클라이언트 모델과 전역 모델을 학습하는 과정에서의 최적화를 고려하지 않았다. 따라서 본 논문에서는 이 세 가지 요소를 모두 고려하는 FedAttnPSO (Federated Learning Attention Particle Swarm Optimization) 알고리즘을 제안한다. 기존 연구와의 차이점 비교를 위해 표 1과 같이 정리

표 1. 기존 연구와 차이점

Table 1. Differences with related works

연구	클라이언트 선택	집계 가중치	최적화
[7, 8, 9]	○	×	×
[10, 11]	×	○	×
[12]	○	○	×
[13]	×	○	○
Ours	○	○	○

하였다. 제안하는 알고리즘은 연합학습 매 라운드마다, loss가 가장 낮은 상위 N개의 선별한 뒤, 각 클라이언트의 로컬 모델을 어텐션 메커니즘을 사용하여 전역 모델에 끼치는 중요도를 계산한다. 이러한 어텐션 중요도를 기반으로 집계 가중치를 부여하여 전역 모델을 업데이트한다. 즉, 전역 모델 업데이트에 중요한 영향을 끼치는 클라이언트에는 높은 가중치를 부여하고, 그렇지 않은 클라이언트에는 낮은 가중치를 부여하여 Non-IID 환경에서도 보다 안정적이고 정밀한 학습이 가능하다. 또한 PSO 알고리즘을 통하여 클라이언트 로컬 모델과 서버 전역 모델 모두 안정적이고 점진적인 모델 학습을 통해 지역 최적해에 빠질 위험을 줄여 전체적인 수렴 안정성과 성능을 동시에 향상시키는 것을 목표로 한다.

III. FedAttnPSO

이 장에서는 본 연구에서 제안하는 FedAttnPSO 알고리즘의 세부적인 동작 방식을 설명한다. FedAttnPSO는 클라이언트와 서버 간의 상호작용을 통해 전역 모델을 점진적으로 최적화하는 연합학습 알고리즘이다. 전체 과정은 클라이언트 측 로컬 최적화와 서버 측 글로벌 최적화라는 두 개의 큰 축으로 구성되며, 이 과정이 여러 라운드에




그림 1. 시스템 개요

Fig. 1. System overview

걸쳐 반복된다. 전체적인 개요는 그림 1과 같으며, 각 요소마다 세부적인 동작 절차를 설명한다.

3.1 클라이언트 측 연산

연합학습의 각 라운드가 시작되면 각 클라이언트는 중앙 서버가 가지고 있는 현재의 전역 모델 파라미터를 수신받는다. 각 클라이언트는 수신받은 전역 모델을 기반으로 자신의 로컬 데이터를 사용하여 로컬 모델 학습을 수행한다. FedAttnPSO 알고리즘에서 클라이언트는 모델을 학습할 때 PSO 알고리즘을 통한 최적화 단계를 결합하여 로컬 모델을 업데이트한다. 여기서 각 클라이언트 모델의 가중치는 PSO의 입자(Particle)로 간주되며, 자신의 과거 최고 성능과 서버로부터 받은 전역 모델을 모두 고려하여 최적의 방향으로 이동한다. 클라이언트 모델은 수식 (3) - (4)을 통해 업데이트되며, 알고리즘 1과 같다:

$$v_i^{t+1} = w \cdot v_i^t + c_1 \cdot r_1 \cdot (p_i^{best} - x_i^t) + c_2 \cdot r_2 \cdot (g^{best} - x_i^t) \quad (3)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (4)$$

- x_i^t : 클라이언트 i 의 현재 모델
- v_i^t : 클라이언트 i 의 모델 변화 방향
- p_i^{best} : 클라이언트 i 의 로컬 최적 모델
- g^{best} : 전역 최적 모델
- w : 관성 계수
- c_1, c_2 : 가속 계수
- r_1, r_2 : $[0, 1]$ 범위의 난수

사전에 정의된 로컬 에폭만큼 학습을 마친 클라이언트는 최종적으로 업데이트된 로컬 모델의 손실값을 중앙 서버로 전송한다.

3.2 서버 측 연산

3.2.1 성능 기반 클라이언트 선택

서버는 수신된 손실값을 기준으로 성능이 가장 우수한 상위 N 개의 클라이언트를 선택한다. 손실값이 가장 낮을수록 성능이 좋은 모델이라고 판단하며, 손실값이 가장 낮은 N 개의 클라이언트만을 식별한다. 식별된 클라이언트들에게 파라미터 정보를 요청하고 다음 집계 과정에 포함시킨다. 이 과정을 통해 성능이 낮거나, 학습에 부정적인 영향을 줄 수 있는 클라이언트를 사전에 필터링하여 전역 모델의 품질을 높인다.

Algorithm 1 Client-Side PSO Model Update

Input from Server:

g^{best} : The current global best model received from the server.

Persistent State (for each client i):

p_i^{best} : The personal best model found by client i across all rounds.

v_i : The current velocity of the client's model.

Parameters:

E : Number of local epochs.

w, c_1, c_2 : PSO hyperparameters

$\mathcal{D}_i$: The client's local dataset.

```

1: Begin
2:  $x_i \leftarrow g^{best}$ 
3: for each local epoch  $j = 1, \dots, E$  do
4:    $r_1, r_2 \sim U(0, 1)$ 
5:    $v_i \leftarrow w \cdot v_i + c_1 \cdot r_1 \cdot (p_i^{best} - x_i) + c_2 \cdot r_2 \cdot (g^{best} - x_i)$ 
6:    $x_i \leftarrow x_i + v_i$ 
7:   Evaluate the loss  $L(x_i)$  on the local dataset  $\mathcal{D}_i$ 
8:   if  $L(x_i) < L(p_i^{best})$  then
9:      $p_i^{best} \leftarrow x_i$ 
10:  end if
11: end for
12: End

```

알고리즘 1. 클라이언트 측 PSO 알고리즘
Algorithm 1. Client-side PSO algorithm

3.2.2 어텐션 기반 가중치 집계

선택된 상위 N 개의 클라이언트 모델들을 전역 모델로 집계하는 과정에 어텐션 메커니즘을 사용한다. 이는 단순히 평균을 내는 것이 아니라, 각 클라이언트의 성능, 즉 손실값에 기반하여 차등적인 가중치를 부여하는 방식이다. 손실값이 낮은 클라이언트가 더 높은 어텐션 점수를 할당받고, 이에 따라 가중치가 부여된다. 각 클라이언트의 어텐션 점수는 수식 (5)와 같이 해당 클라이언트의 손실값의 역수를 취하여 계산된다. 이때 분모에 더해지는 작은 상수를 손실값이 0에 가까워질 때 발생할 수 있는 수치적 불안정성을 방지하는 역할을 한다. 수식 (6)을 통해 소프트맥스 함수를 통해 모든 클라이언트의 가중치 합이 1이 되도록 정규화한다:

$$s_i = \frac{1}{loss_i + \epsilon}, \quad \epsilon = 1 \times 10^{-8} \quad (5)$$

$$a_i = \frac{e^{s_i}}{\sum_{j=1}^N e^{s_j}} \quad (6)$$

이렇게 계산된 어텐션 가중치를 사용하여 새로운 전역 모델을 생성하는데, 선택된 클라이언트 모델들의 각 파라미터에 해당 가중치를 곱하여 가중합을 구하는 방식으로 이루어진다.-

3.2.3 PSO 기반 전역 모델 업데이트

서버는 수식 (5) - (6)으로 계산된 전역 모델을

Algorithm 2 Server-Side PSO Model Update

Input:
 g_{new}^{best} : The new global model aggregated/selected from clients in the current round.

Persistent Server State:
 x_s : The server's current global model state (position).
 v_s : The current velocity of the server's model.

Parameters:
 S : Number of server-side stabilization steps.
 w : Inertia weight.
 c : Acceleration coefficient.

```

1: Begin
2:   Let the target model  $g^{best} \leftarrow g_{new}^{best}$ 
3:   for each stabilization step  $k = 1, \dots, S$  do
4:      $r \sim U(0, 1)$ 
5:      $v_s \leftarrow w \cdot v_s + c \cdot r \cdot (g^{best} - x_s)$ 
6:      $x_s \leftarrow x_s + v_s$ 
7:   end for
8:   return  $x_s$ 
9: End

```

알고리즘 2. 서버 측 PSO 알고리즘
 Algorithm 2. Server-side PSO algorithm

즉시 다음 라운드의 모델로 채택하는 것이 아니라, 서버 측 PSO 알고리즘을 통해 현재의 전역 모델을 안정적이고 점진적으로 이동시킨다. 서버는 개인 최적해 없이 전역 최적해만을 참조하여 자신의 위치를 업데이트한다. 이는 특정 라운드의 결과가 전역 모델에 급격한 변화를 주는 것을 막고, 전체 학습 과정의 안정성을 확보하는 역할을 할 수 있다. 서버 측 업데이트는 수식 (7) - (8) 및 알고리즘 2와 같다:

$$v_i^{t+1} = w \cdot v_i^t + c \cdot r \cdot (g^{best} - x_i^t) \quad (7)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (8)$$

- x_i^t : 서버 모델의 현재 상태
- v_i^t : 서버 모델의 변화 방향(속도)
- g : 서버가 기억하는 가장 좋은 모델
- w : 관성 계수
- c : 가속 계수
- r : $[0, 1]$ 범위의 난수

3.3 전체 시스템 요약

지금까지 설명한 클라이언트와 서버의 동작을 통합한 FedAttnPSO의 전체 흐름은 알고리즘 3과 같다. 이처럼 FedAttnPSO는 성능 기반의 클라이언트 선택, 어텐션 메커니즘을 이용한 가중치 집계,

Algorithm 3 FedAttnPSO

Input:
 C : The set of all clients.
 R : The number of total communication rounds.
 E : The number of local epochs for client training.
 N : The number of top clients to select for aggregation.

Output:
 g_{best} (the final trained global model)

```

1: begin
2:   for each round  $i = 1, \dots, R$  do
3:     for each  $C_k \in C$  do
4:        $w_{C_k} \leftarrow g_{best}$ 
5:       for each epoch  $e = 1, \dots, E$  do
6:          $w_{C_k} \leftarrow$  Update model using Client-Side PSO Algorithm
7:       end for
8:        $loss_{C_k} \leftarrow$  Calculate loss for  $w_{C_k}$ 
9:       local  $p_{best} \leftarrow loss_{C_k}$ 
10:      Send  $w_{C_k}$  and  $loss_{C_k}$  to Server
11:    end for
12:     $C_{target} \leftarrow$  Select top N clients
13:     $\alpha \leftarrow$  Calculate attention weights( $C_{target}$ )
14:     $w_{attention} \leftarrow \alpha \cdot C_{target}$ 
15:     $w_{global} \leftarrow$  Update model using Server-Side PSO Algorithm
16:    Update global best( $g_{best}$ ) if  $w_{global}$  is better
17:  end for
18:  return  $g_{best}$ 
19: end

```

알고리즘 3. FedAttnPSO 알고리즘
 Algorithm 3. FedAttnPSO algorithm

클라이언트 및 서버에서의 PSO 기반 점진적 업데이트를 결합하여 Non-IID 환경에서도 강건하고 효율적인 학습을 가능하게 한다.

IV. 실험 및 결과

4.1 데이터셋

본 논문에서 제안하는 FedAttnPSO의 성능을 평가하기 위해 CIFAR-10, CIFAR-100, 그리고 FEMNIST 데이터셋을 사용하였다. 표준 이미지 데이터셋인 CIFAR-10과 CIFAR-100에서는 IID 환경과 Non-IID 환경에서의 성능 차이를 보기 위해 두 환경으로 구분하여 실험을 진행하였다. FEMNIST는 연합학습의 실제 환경을 구현하기 위한 데이터셋으로, Non-IID하게 구분되어 있기에 본 논문에서 제안하는 알고리즘의 성능을 입증하기 위해 사용하였다.

CIFAR-10 및 CIFAR-100은 32x32 컬러 이미지 데이터셋이다. CIFAR-10은 10개의 클래스를 포함하며, CIFAR-100은 100개의 세분화된 클래스를 가져 분류 문제의 복잡도를 높인 데이터셋이다. IID 환경 구성을 한 경우, 전체 학습 데이터를 클라이언트 수에 따라 중복 없이 균등하게 분할하였으며, 이를 통해 각 클라이언트는 모든 클래스에 대해 동일한 분포의 데이터를 보유하도록 설계되었다.




그림 2. IID 환경에서 상위 N 비율 비교
Fig. 2. Top N comparison in IID




그림 3. Non-IID 환경에서 상위 N 비율 비교
Fig. 3. Top N comparison in Non-IID

반면에 Non-IID 환경을 구성한 경우, 현실 세계의 데이터 불균형을 묘사하기 위해 디리클레 분포 기반의 데이터 분할 방법을 사용하였다. 이 방식은 각 클라이언트가 특정 클래스에 편향되게 데이터를 갖도록 유도하기 때문에 데이터 이질성을 구현할 수 있다.

FEMNIST[14]는 62개의 클래스(숫자 0-9, 영어 대소문자 a-z, A-Z)로 구성된 28x28 흑백 손글씨 이미지 데이터셋이다. 이 데이터셋은 실제 연합학습 환경에서의 실험을 목적으로 구성된 것으로, 실제 작성자별로 데이터가 그룹화되어 있다. 사용자별로 각 클래스가 가지고 있는 데이터가 매우 상이하며, 클래스가 없는 경우도 존재하여 본질적으로 Non-IID 환경을 구성하고 있다. 본 실험에서는 사전처리된 3,500명의 사용자 데이터 중 일부를 클라이언트로 지정하여 사용하였으며, FEMNIST 데이터셋의 특성 상 각 클라이언트는 작성자에 따라 고유한 데이터 양과 클래스 분포를 가지고 있다.

4.2 실험 시나리오

논문에서는 2개의 실험 시나리오(최적 N 선정

표 2. 최적 N 선정 실험을 위한 파라미터

Table 2. Parameters for the optimal N selection experiment

Parameters	Value	
Number of clients	20	
Ratio for selecting clients	0.1, 0.3, 0.5	
Environment	IID	Non-IID
Dataset	CIFAR 10	CIFAR 10
	CIFAR 100	CIFAR 100
		FEMNSIT

표 3. 성능 비교 실험을 위한 파라미터

Table 3. Parameters for the accuracy comparison experiment

Parameter	Value	
Algorithm	FedAvg, FedPSO, FedAttnPSO	
Rounds	10, 30, 50	
Environment	IID	Non-IID
Dataset	CIFAR 10	CIFAR 10
	CIFAR 100	CIFAR 100
		FEMNSIT

실험, 성능 비교 실험)를 통해 FedAttnPSO를 검증하였다. 최적 N 선정 실험에서는 글로벌 모델 통합 과정에 사용하는 상위 N개의 클라이언트를 선택할 때, 가장 최적의 비율을 도출하는 실험을 진행하

였다. 이때, IID 환경과 Non-IID 환경에서의 최적의 N의 비율을 찾기 위해 각각 실험을 진행하였다. 성능 비교 실험에서는 FedAttnPSO 알고리즘과 기존에 널리 사용되는 FedAvg 알고리즘[1], 그리고 PSO를 사용한 선행연구인 FedPSO 알고리즘[13]과의 성능을 비교 및 분석한다. 최적 N 선정 실험을 위한 파라미터는 표 2와 같고, 성능 비교 실험을 위한 파라미터는 표 3과 같다.

4.3 실험 결과

4.3.1 최적 N 선정 실험

최적의 상위 N의 비율을 찾기 위한 첫 번째 실험의 결과는 그림 2 및 그림 3과 같다. 표 2와 같이, 최적 N 선정 실험에서 사용한 클라이언트의 수는 20개이며, 비율을 각각 0.1, 0.3, 0.5로 진행하였다. IID 환경과 Non-IID 환경을 구분하여 실험을 진행했다. IID 환경에서는 CIFAR-10과 CIFAR-100 데이터셋을 사용하였으며, Non-IID 환경에서는 CIFAR-10, CIFAR-100, 그리고 FEMNIST 데이터셋 모두를 사용하여 진행하였다. 그림 2와 같이 IID 환경에서의 실험 결과는 N의 비율을 0.1로 했을 때, CIFAR-10에서 65%, CIFAR-100에서 30%로 가장 높은 성능을 달성하였다. 이는 데이터가 모두 균일하게 분포된 환경에서는 소수의 클라이언트만으로도 전체 데이터의 대표성을 확보할 수 있기 때문에 가장 낮은 클라이언트 비율을 선택할 때 성능이 높은 것으로 해석된다.

Non-IID 환경에서 최적의 N의 비율은 그림 3에서 볼 수 있듯이 0.5이다. CIFAR-10은 53%, CIFAR-100은 24%, FEMNIST는 73% 성능을 달성하였다. 본 실험 결과에서 CIFAR-100 데이터셋의 경우, 100개의 클래스로 세분화되어 분류의 복잡성이 증가되었을 때 클라이언트 선택 비율이 낮은 경우 이에 수렴하지 못하는 것을 볼 수 있다. 이를 바탕으로 IID 환경과 다르게 Non-IID 환경에서는 개별 클라이언트가 가지는 데이터 편향성이 크기 때문에 보다 다양한 클라이언트를 글로벌 모델에 통합시켜야 전체 데이터 분포의 다양성을 반영할 수 있기에 가장 높은 비율인 0.5를 선택한 경우 성능이 높은 것으로 해석된다.

4.3.2 성능 비교 실험 결과

최적 N 선정 실험 결과를 바탕으로, 성능 비교 실험에서 상위 N의 비율을 IID 환경과 Non-IID

표 4. CIFAR10 실험 결과

Table 4. CIFAR10 test accuracy by epoch

Environment	Algorithm	Accuracy (%)		
		10 Rounds	30 Rounds	50 Rounds
IID	FedAvg	38.9	57.3	57.9
	FedPSO	53.1	56.1	54.8
	FedAttnPSO	<u>54.5</u>	<u>63.4</u>	<u>64.9</u>
Non-IID	FedAvg	33.4	52.1	53.2
	FedPSO	29.2	32.2	32.7
	FedAttnPSO	<u>45.4</u>	<u>56.5</u>	<u>58.0</u>

표 5. CIFAR100 실험 결과

Table 5. CIFAR100 test accuracy by epoch

Environment	Algorithm	Accuracy (%)		
		10 Rounds	30 Rounds	50 Rounds
IID	FedAvg	18.0	23.6	24.3
	FedPSO	16.3	22.5	20.7
	FedAttnPSO	<u>21.4</u>	<u>27</u>	<u>29.8</u>
Non-IID	FedAvg	14.2	22.9	24.1
	FedPSO	Nan	Nan	Nan
	FedAttnPSO	<u>14.7</u>	<u>24.3</u>	<u>27.4</u>

표 6. FEMNIST 실험 결과

Table 6. FEMNIST test accuracy by round

Environment	Algorithm	Accuracy (%)		
		20 clients	30 clients	50 clients
Non-IID	FedAvg	66.1	65.4	65.1
	FedPSO	30.7	38.4	35.3
	FedAttnPSO	<u>72.6</u>	<u>71.3</u>	<u>69.7</u>

환경에서 각각 0.1, 0.5로 선택하였다. 먼저 CIFAR-10 및 CIFAR-100 데이터셋의 경우, 전체 데이터의 양이 많지 않아 클라이언트의 개수를 20으로 고정하고, 전체 라운드의 수를 증가시키며 실험을 진행하였다. 라운드별 자세한 수치는 표 4, 5과 같다. CIFAR-10의 경우, IID 환경에서는 제안한 알고리즘이 FedAvg 대비 최대 15.6%, FedPSO 대비 최대 10.1% 높은 정확도를 달성하였고, Non-IID 환경에서는 FedAvg 대비 최대 12%, FedPSO 대비 최대 25.3% 향상되어 제안하는 알고리즘의 타당성을 입증하였다. 다음으로 CIFAR-100의 경우, IID 환경에서 제안하는 알고리즘이 FedAvg 대비 최대 5.5%, FedPSO 대비 최대 9.1% 높은 정확도를 달성하였으며, Non-IID 환경에서는 FedAvg 대비 최대 3.3% 정확도 향상을 달성하였다. FedPSO의 경우는 분류의 복잡성이 높은 CIFAR-100 데이터셋의 경우 Non-IID 환경에서는 수렴하지 못하는 것에 비해 제안하는 알고리즘은 최대 27.4%까지 달성하는 것을 보였다.

앞선 두 데이터셋과 다르게 FEMNIST의 경우, 실제 연합학습 환경 실험을 위한 데이터셋으로 작성

자별로 데이터가 Non-IID 분포를 따라 구성되어 있다. 전체 데이터는 작성자 3,500명으로 구성되어 있어, 본 실험에서는 전체 라운드 수를 고정하고 클라이언트의 개수를 20, 30, 50으로 증가시켜 실험을 진행하였다. 클라이언트 수 별 자세한 수치는 표 6와 같으며, 제안하는 알고리즘이 FedAvg 대비 최대 6.5%, FedPSO 대비 최대 41.9% 향상되었다.

세 가지 데이터셋의 실험 결과, 특히 FedPSO의 경우 Non-IID 환경에서의 성능 저하가 크게 나타났는데, 이는 통신비용 감소를 위해 매 라운드마다 단일 클라이언트의 모델만을 글로벌 모델에 반영하기 때문에 PSO 알고리즘을 사용하여 모델 최적화를 진행함에도 불구하고 Non-IID 환경에서는 제대로 학습하지 못하는 것을 알 수 있다. 반면 본 연구에서 제안하는 FedAttnPSO 알고리즘의 경우, 상위 N개의 클라이언트 모델을 어텐션 매커니즘을 통해 중요도 기반으로 가중 집계하고, 서버 측 PSO 최적화까지 결합하여 기존 연구인 FedPSO의 한계를 해결하며, FedAvg보다도 빠르고 안정적인 수렴을 보여 제안하는 알고리즘의 견고성을 입증하였다.

V. 결 론

본 논문에서는 연합학습의 한계인 Non-IID 환경에서의 성능 저하를 극복하기 위해 성능 기반 클라이언트 선택, 어텐션 메커니즘 기반 가중치 집계, PSO 최적화를 결합한 새로운 알고리즘인 FedAttnPSO를 제안하였다. 기존에 널리 사용되는 FedAvg 알고리즘의 무작위 클라이언트 선택과 단순 평균 집계를 개선하기 위해 각 클라이언트의 손실값을 기준으로 상위 N개를 선택하는 방식과, 어텐션 메커니즘을 사용하여 가중치를 차등 부여하는 방식, 더 나아가 학습 과정에 PSO 알고리즘을 결합하여 보다 안정적이고 점진적인 모델 업데이트를 통해 견고한 알고리즘을 제안하였다.

세 가지 데이터셋(CIFAR-10, CIFAR-100, FEMNIST)을 사용한 성능 비교 실험을 통해 제안하는 알고리즘의 우수성을 정량적으로 입증하였다. 특히 현실적인 Non-IID 환경을 구현한 FEMNIST 데이터셋을 사용한 실험에서 FedAttnPSO는 FedAvg 대비 최대 6.5%, FedPSO 대비 최대 41.9%의 정확도 향상을 달성했다. 또한 분류 복잡성이 높은 CIFAR-100 Non-IID 환경에서 FedPSO가 수렴에 실패한 반면, 제안하는 FedAttnPSO 알고리즘은 안정적인

로 학습을 진행하며 최대 27.4%의 정확도를 달성하였다. 이는 다양한 클라이언트를 고려하고, 안정적으로 통합하는 방식의 견고성을 증명하여 충분한 실험 가능성을 입증하였다.

본 연구에서는 이미지 데이터셋을 중심으로 실험을 진행하였으나 향후 연구에서는 보다 다양한 유형의 데이터셋을 활용하여 여러 환경에서의 적용 가능성을 검토하고, 제안하는 알고리즘의 일반성과 타당성을 입증하고자 한다. 아울러, 현재의 손실값 기반 클라이언트 선택 방식에서 나아가 강화학습 기반의 선택 정책을 도입함으로써 클라이언트의 신뢰도, 데이터 품질, 이전 라운드에서의 기여도 등을 종합적으로 고려하는 방향으로 확장하고자 한다. 이를 통해 보다 지능적이고 동적인 클라이언트 관리를 실현하고, 연합학습의 성능을 더욱 향상시키고자 한다. 또한 클라이언트 모델의 집계 과정에 PSO 알고리즘과 어텐션 메커니즘을 적용함에 따라 기존 FedAvg 알고리즘 대비 계산 복잡도가 증가할 수 있으므로, 정량적 분석을 통해 성능 향상과 복잡도 증가 간의 균형을 평가하고 실제 적용 가능성을 검토할 계획이다. 마지막으로, 모델 성능의 다각적 평가를 위해 정확도 뿐만 아니라 정밀도, 재현율, F1 Score 등의 지표를 활용한 실험을 추가로 수행함으로써 제안 기법의 전반적인 효과성을 검증할 것이다.

References

- [1] H. B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. Aguerre y Arcas, "Communication-efficient learning of deep networks from decentralized data," *Proceedings of 20th International Conference on Artificial Intelligence and Statistics (AISTATS)*, pp. 1273 - 1282, Florida, USA, April 2017.
- [2] Y. J. Cho, J. Wang, and G. Joshi, "Towards understanding biased client selection in federated learning," *Proceedings of the 25th International Conference on Artificial Intelligence and Statistics (AISTATS)*, pp. 10351 - 10375, Valencia, Spain, March 2022.
- [3] D. Zeng, Z. Xu, S. Liu, Y. Pan, Q. Wang, and X. Tang, "On the power of adaptive weighted aggregation in heterogeneous federated learning and beyond," *Proceedings of the 28th International*

- Conference on Artificial Intelligence and Statistics (AISTATS)*, pp. 1 - 22, Phuket, Thailand, May 2025.
- [4] Z. Li, T. Lin, X. Shang, and C. Wu, "Revisiting weighted aggregation in federated learning with neural networks," *Proceedings of the 40th International Conference on Machine Learning*, pp. 19767 - 19788, Honolulu, Hawaii, USA, July 2023.
- [5] N. Kang, Y. Lim, and J. Im, "Optimizing federated learning: addressing key challenges in real-world applications," *IEEE Internet of Things Journal*, vol. 12, no. 12, pp. 19065 - 19089, April 2025.
- [6] J. Kennedy, and R. Eberhart, "Particle Swarm Optimization," *Proceedings of IEEE International Conference on Neural Networks*, WA, Australia, pp. 1942 - 1948, December 1995.
- [7] S. Chen, O. Tavalai, M. H. Hambali, S. M. Zandavi, H. Haddadi, N. Lane, S. Guo, and A. Y. Zomaya, "Optimization of federated learning's client selection for non-iid data based on grey relational analysis," *arXiv preprint arXiv:2310.08147*, October 2023.
- [8] T. M. Nguyen, K. L. Poh, S. L. Chong, and J. H. Lee, "FedDSS: a data-similarity approach for client selection in horizontal federated learning," *International Journal of Medical Informatics*, vol. 192, pp. 1 - 9, October 2024.
- [9] W. Marfo, D. K. Tosh, and S. V. Moore, "Efficient client selection in federated learning," *arXiv preprint arXiv:2502.00036*, January 2025.
- [10] C. Shi, H. Zhao, B. Zhang, M. Zhou, D. Guo, and Y. Chang, "FedAWA: adaptive optimization of aggregation weights in federated learning using client vectors," *Proceedings of the Computer Vision and Pattern Recognition Conference*, pp. 30651 - 30660, Nashville, Tennessee, USA, June 2025.
- [11] R. Ye, M. Xu, J. Wang, C. Xu, S. Chen, and Y. Wang, "FedDisco: federated learning with discrepancy-aware collaboration," *Proceedings of the 40th International Conference on Machine Learning*, pp. 39879 - 39902, Honolulu, Hawaii, USA, July 2023.
- [12] J. S. Bang, S. P. Woo, and J. H. Lee, "DRL-empowered joint batch size and weighted aggregation adjustment mechanism for federated learning on non-iid data," *ICT Express*, vol. 10,

no. 4, pp. 863 - 780, August 2024.

- [13] S. H. Park, Y. R. Suh, and J. W. Lee, "FedPSO: federated learning using particle swarm optimization to reduce communication costs," *Sensors*, vol. 21, no. 2, pp. 1 - 13, January 2021.
- [14] S. Caldas, S. M. K. Duddu, P. Wu, T. Li, J. Konecny, H. B. McMahan, V. Smith, and A. Talwalkar, "Leaf: a benchmark for federated settings," *arXiv preprint arXiv:1812.01097*, December 2018.

장 선 영 (Sun-young Jang)



2024년 2월 : 강원대학교 컴퓨터공학과 졸업
2024년 2월 - 현재 : 강원대학교 데이터사이언스학과 석사 과정
<관심분야> 연합학습, 네트워크 보안

김 종 욱 (Jong-Wouk Kim)



2019년 2월 : 강원대학교 컴퓨터과학 졸업
2021년 2월 : 강원대학교 컴퓨터과학 석사
2021년 3월 - 현재 : 강원대학교 컴퓨터과학 박사과정
<관심분야> 네트워크 보안, 악성코드 분석, 딥러닝

최 미 정 (Mi-Jung Choi)



1998년 2월 : 이화여자대학교 공학사 졸업
2000년 2월 : 포항공과대학교 공학석사
2004년 2월 : 포항공과대학교 공학박사
2004년 - 2005년 : 프랑스 INRIA 연구소 박사 후 연구원
2005년 - 2006년 : 캐나다 워터루대학 박사 후 연구원
2008년 - 현재 : 강원대학교 컴퓨터학부 컴퓨터공학 전공 교수
<관심분야> 네트워크 관리, 정보보안, 네트워크 보안