

# 연합학습 기반 이미지 분류 시스템 의 IID·Non-IID 성능 분석

Federated Learning Proof of Concept

2019270644\_유재우



# 프로젝트 개요

데이터 프라이버시와 분산 환경에서의 머신러닝은 현대 기업이 직면한 핵심 과제입니다. 개인정보보호 규제 강화와 데이터 이동 제약으로 인해 전통적인 중앙집중식 학습 방식은 한계에 도달했습니다.



## 개인정보보호 강화

GDPR, 개인정보보호법 등 규제 준수를 위한 데이터 로컬 보관 필요성 증가



## 데이터 이동 제약

민감 데이터의 중앙 서버 전송 불가능, 지점별·디바이스별 분산 저장 환경



## 협업 학습 필요성

여러 기관·지점의 데이터를 공유 없이 활용하여 고성능 AI 모델 구축



## 연합학습 기본 개념

연합학습은 데이터를 이동시키지 않고 모델을 학습시키는 혁신적인 접근법입니다. 각 클라이언트는 로컬 데이터로 모델을 훈련하고, 서버는 이를 집계하여 글로벌 모델을 업데이트합니다.



### 글로벌 모델 배포

서버가 초기 모델을 각 클라이언트에게 전송



### 로컬 학습

각 클라이언트가 자신의 데이터로 모델 훈련



### 파라미터 전송

업데이트된 모델 가중치만 서버로 전송



### FedAvg 집계

서버가 모든 클라이언트의 가중치를 평균하여 통합

# IID vs Non-IID가 중요한 이유

실제 기업 환경에서 데이터는 균등하게 분포되지 않습니다. 지역별, 고객층별, 시간대별로 데이터 편향이 발생하며, 이는 연합학습 성능에 직접적인 영향을 미칩니다.

## 금융: 지점별 고객 분포

강남 지점은 고액 자산가 중심, 지방 지점은 일반 고객 중심으로 데이터 편향 발생

## 의료: 병원별 질환 분포

대학병원은 중증 환자, 동네 병원은 경증 환자로 진단 데이터 불균형

## 리테일: 매장별 상품 선호도

도심 매장과 주거지 매장의 구매 패턴 차이로 인한 추천 모델 편향

Non-IID 환경에서는 모델이 특정 클라이언트에 과적합되거나 수렴 속도가 느려지는 문제가 발생합니다. 본 연구는 이러한 현실적 문제를 실험적으로 검증합니다.

# 실험 환경 구성

01

## 데이터셋

MNIST 손글씨 숫자 데이터 (60,000 훈련, 10,000 테스트 이미지)

03

## 학습 라운드

5라운드 반복 학습, 각 라운드마다 FedAvg로 모델 파라미터 집계

05

## 실행 플랫폼

Google Colab 환경에서 PyTorch 프레임워크로 구현 및 실험

02

## 네트워크 구성

5개 클라이언트로 분산 환경 시뮬레이션, 각 클라이언트는 독립적인 로컬 데이터 보유

04

## 모델 아키텍처

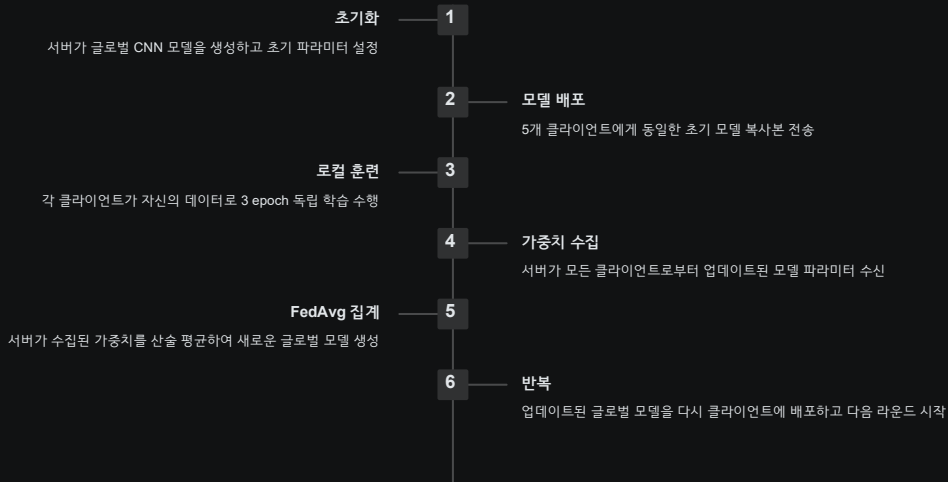
Convolutional Neural Network (CNN) 기반 이미지 분류 모델 사용



❑ 실험 목표: IID와 Non-IID 데이터 분포 조건에서 연합 학습 성능 차이를 정량적으로 비교 분석

# 연합학습 구현 구조

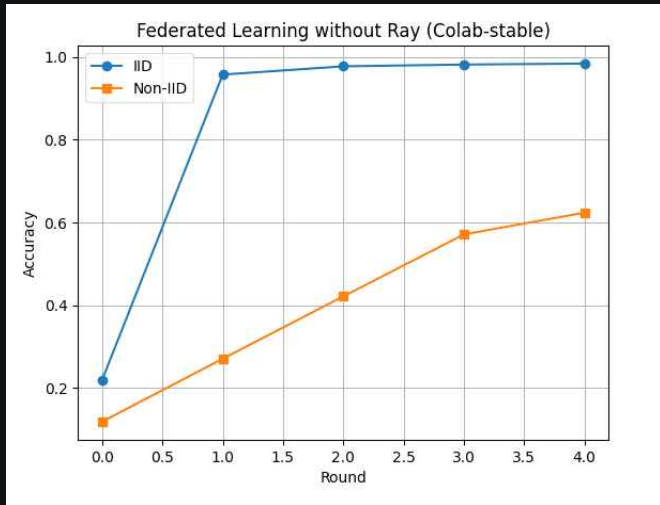
본 프로젝트는 Ray와 같은 복잡한 프레임워크 없이 FedAvg 알고리즘을 경량으로 직접 구현했습니다. 이를 통해 연합학습의 핵심 메커니즘을 명확히 이해하고 제어할 수 있습니다.



□ 구현 특징: PyTorch 기반 순수 Python 코드로 작성되어 교육 및 PoC 목적에 최적화. 프로덕션 환경에서는 통신 최적화 및 보안 계층 추가 필요

## 실험 결과: 정확도 비교

5라운드 동안 IID와 Non-IID 환경에서 측정한 글로벌 모델의 테스트 정확도입니다. 데이터 분포 방식이 학습 성능에 미치는 영향이 명확히 드러납니다.



# 결과 분석

1

## IID: 이상적 조건에서의 강건한 수렴

균등 분포 환경에서는 연합학습이 중앙집중식 학습과 유사한 성능을 보였습니다. 각 클라이언트의 기여도가 균형을 이루며 글로벌 모델의 일반화 능력이 우수했습니다.

2

## Non-IID: 데이터 편향의 치명적 영향

레이블 편향 환경에서는 약 15%p의 성능 저하가 발생했습니다. 특정 클라이언트가 보유하지 않은 클래스에 대한 예측 성능이 현저히 낮아졌습니다.

3

## 데이터 분포가 핵심 성공 요인

연합학습 성능은 알고리즘보다 데이터 분포 전략에 더 크게 의존합니다. 실제 적용 시 클라이언트 간 데이터 균형을 고려한 설계가 필수적입니다.



# 활용방안 및 기대효과

본 연구 결과는 프라이버시 보호가 중요한 다양한 산업 분야에서 실질적인 가치를 제공합니다.

## 금융: 지점별 학습

각 은행 지점의 거래 데이터를 중앙 서버로 전송하지 않고 사기 탐지 모델 학습. 고객 프라이버시 보호와 규제 준수 동시 달성

# 100%

### 데이터 로컬 보관

민감 데이터 외부 전송 불필요

## 의료: 병원 간 협업

여러 병원의 환자 데이터를 공유하지 않고 진단 AI 모델 개발. HIPAA 등 의료정보보호 법 준수하며 모델 정확도 향상

# 15%

### 통신 비용 절감

데이터 대신 모델만 전송

## 모바일: 디바이스 학습

사용자 스마트폰에서 직접 키보드 예측, 음성인식 모델 학습. 개인 데이터가 기기를 떠나지 않아 프라이버시 강화

# 3X

### 규제 준수 용이성

GDPR, 개인정보보호법 대응

# Non-IID 문제 해결 방향

실험에서 확인된 Non-IID 환경의 성능 저하를 개선하기 위한 향후 연구 방향을 제시합니다.

## FedProx 알고리즘

로컬 모델이 글로벌 모델에서 너무 멀어 지지 않도록 제약하는 근접 항(proximal term) 추가. Non-IID 환경에서 수렴 안정성 향상

## 클라이언트 샘플링 전략

매 라운드마다 데이터 분포를 고려하여 클라이언트를 선택적으로 샘플링. 편향된 클라이언트의 영향력 조절

## 개인화 레이어 추가

글로벌 공통 레이어와 클라이언트별 개인화 레이어를 분리. 로컬 데이터 특성을 반영하면서 일반화 능력 유지

---

이러한 기법들을 조합하면 Non-IID 환경에서도 IID 수준의 성능에 근접할 수 있으며, 실제 기업 환경 적용 가능성이 크게 높아집니다.

# 향후 확장 계획

## 복잡한 데이터셋 확장

CIFAR-10, ImageNet 등 컬러 이미지 데이터로 실험 확장. 더 현실적인 비전 태스크에서의 연합학습 성능 검증

## 프라이버시 보장 기술

Differential Privacy, Secure Aggregation 적용. 모델 파라미터 전송 과정에서의 정보 유출 방지

## 고급 집계 알고리즘

FedAdam, FedYogi 등 적응형 옵티마이저 기반 집계 방식 도입. 수렴 속도와 최종 정확도 동시 개선

## 프로덕션 환경 구현

실제 기업 인프라에 배포 가능한 스케일러블 시스템 설계. 통신 최적화 및 장애 복구 메커니즘 구현

# 결론

## 연합학습의 가능성 확인

본 연구는 MNIST 데이터를 활용한 PoC를 통해 연합학습이 프라이버시 보호와 모델 성능을 동시에 달성할 수 있음을 입증했습니다.

IID 환경에서는 중앙집중식 학습에 근접한 96% 정확도를 기록하여, 데이터 분산 환경에서도 고품질 AI 모델 개발이 가능함을 확인했습니다.

## Non-IID 문제와 해결 과제

그러나 현실적인 Non-IID 환경에서는 15%p의 성능 저하가 발생했습니다. 이는 실제 비즈니스 적용을 위해 반드시 해결해야 할 핵심 과제입니다.

FedProx, 개인화 레이어, 클라이언트 샘플링 등의 기법을 통해 Non-IID 문제를 완화하고, 더 복잡한 데이터셋으로 확장하는 것이 다음 단계입니다.



### □ 기대효과

금융, 의료, 모바일 등 프라이버시가 중요한 분야에서 연합학습 기반 AI 시스템 구축 가능성을 제시했습니다. 규제 준수와 혁신을 동시에 달성할 수 있는 실용적 솔루션입니다.