

ASD 예측을 위한 연합학습 기반 시선 추적 이미지 분류 모델 구축 (Building of a Federated Learning based Eye tracking Image Classification Model for Early Detection of ASD)

신현호*, 이재민*, 전홍우*

(Hyeonho Shin, Jae-Min Lee, Hong-Woo Chun)

요약

자폐 스펙트럼 장애는 아동에게 발현되는 신경 발달 장애로 조기 발견과 치료가 매우 중요하다. 하지만 현재 자폐 스펙트럼 장애의 진단 및 치료는 전문 인력 부족과 제한된 시간으로 인해 어려움이 많다. 최근 많은 연구에서는 시선 움직임 패턴 분석을 통해 아동의 자폐 스펙트럼 장애를 예측하려는 시도가 활발히 이루어지고 있다. ASD 아동 대상 시선 추적 이미지는 의료 데이터이고 현재 대한민국 의료법상 공유 및 분석에 한계가 존재한다. 이에 본 연구에서는 실질적인 해결 방안을 제시하고자 여러 기관에 분산된 데이터를 중앙에서 정보 유출 없이 분석할 수 있는 방법론인 연합학습을 적용한 모델을 제안한다. 연합학습은 클라이언트에서 각 모델을 학습하고 학습된 가중치만 중앙 서버에 공유하는 분산 학습 방법이다. 연구 목표는 분산 학습 모델의 성능이 중앙집중형 학습 모델과 비슷한 결과를 제시하는 것이다. 실험 결과, 연합학습 모델은 정확도 0.85와 F1 스코어 0.84를 달성하여 중앙집중형 학습 모델 대비 각각 약 92.4% 약 94.4%의 성능을 보였다. 이를 통해 자폐 스펙트럼 장애 아동 예측에서 연합학습이 효과적인 접근법임을 입증하였으며, 의료 데이터의 개인정보 보호와 분산 학습의 가능성을 동시에 제시하였다.

■ 중심어 : 자폐 스펙트럼 장애 ; 연합학습 ; 시선 추적 ; 이미지 처리

Abstract

Autism spectrum disorder is a neurodevelopmental disorder that manifests in children, making early detection and treatment critically important. However, the diagnosis and treatment of ASD currently face significant challenges due to a shortage of specialized personnel and limited time. Recent studies have increasingly focused on predicting ASD in children by analyzing gaze movement patterns. However, eye-tracking images of ASD children are classified as medical data, and sharing or analyzing such data is restricted under South Korea's Medical Law. To address these challenges, this study proposes a federated learning approach, which allows distributed data from multiple institutions to be analyzed centrally without risking data leakage. Federated learning is a distributed learning method in which each client trains its model locally and only the learned weights are shared with the central server. This study aims to show that a distributed learning model can perform on par with a centralized learning model. The experimental results indicated that the federated learning model achieved an acc of 0.85 and an F1-score of 0.84, demonstrating approximately 92.4% and 94.4% of the performance level observed in the centralized model, respectively. These findings confirm that federated learning is an effective approach for early ASD prediction while simultaneously preserving the privacy of medical data and demonstrating the potential of distributed learning.

■ keywords : Autism Spectrum Disorder (ASD) ; Federated Learning ; Eye Tracking ; Image Processing

I. 서론

보건복지부가 발표한 ‘2021년 발달장애인 실태조사’에 의하면 등록 발달장애인 수는 2021년 6

* 정회원, 한국과학기술정보연구원 미래기술분석센터

본 연구는 보건복지부의 재원으로 한국보건산업진흥원의 보건의료기술연구개발사업 지원에 의하여 이루어진 것임.(과제고유번호: HR22C1605) 이 논문은 2025년도 한국과학기술정보연구원(KISTI)의 기본사업으로 수행된 연구입니다.(과제번호: K25L4M2C4)

접수일자 : 2025년 01월 15일

게재확정일 : 2025년 02월 27일

수정일자 : 2025년 02월 13일

교신저자 : 전홍우 e-mail : hw.chun@kisti.re.kr

월 기준 25.2만 명이다. 이는 2018년 대비 약 1.8명 증가한 수치이다[1]. 이 중 자폐성 장애인은 약 3.2만 명으로 파악되었다[1]. 2023년 보건복지부가 발표한 등록장애인 현황 통계에서는 자폐성 장애로 등록된 장애인이 약 4.3만 명으로 나타나, 자폐성 장애인 수도 꾸준히 증가하는 추세이다[2]. 이러한 추세는 조기 발견과 치료의 중요성이 날로 증가하고 있음을 시사한다[3].

자폐 스펙트럼 장애(Autism Spectrum Disorder, ASD)는 주로 만 3세 이전에 발현되는 대표적인 신경 발달 장애로 개인마다 증상의 정도와 특성이 다양하게 나타난다[4]. 주로 반복적인 행동과 의사소통 및 사회적 상호작용에 어려움을 보이는 것이 특징이다[3,4]. 이러한 증상은 아동기 초기부터 확인되며 일상생활 전반에 걸쳐 다양한 어려움을 발생시킨다[3]. 자폐 스펙트럼 장애 치료의 주요 목표는 가능한 한 증상을 완화하여 아동의 발달을 돕고 문제행동을 줄여 사회의 구성원으로 지내도록 돕는 데 있다[4]. 특히 만 5세 이전에 조기 진단을 받아 치료를 시작하는 경우 ASD 아동의 인지 및 언어 능력 향상이 이루어져 이후 발달 경과와 사회적 적응에 긍정적인 영향을 미친다는 연구들이 많다[5]. 그러나 임상 현장에서는 여러 진단 도구를 종합적으로 평가하는 과정이 복잡하고, 전문 인력과 시간 부족 등의 이유로 적절한 진단 및 치료 시기가 늦어지는 문제가 발생한다[4].

이에 따라 최근 연구에서는 딥러닝(Deep Learning)을 활용한 자폐 스펙트럼 장애 예측 연구들이 활발하게 이루어지고 있다[4]. 그중에서도 시선 추적 이미지를 활용한 자폐 스펙트럼 장애 아동 예측 연구가 활발히 진행되고 있다[6,7]. ASD 아동 대상 시선 추적 이미지는 시선 추적 장치를 통해 특정 시각 자극을 제시한 후, 아동의 시선 이동 경로를 기록한 데이터이다. 일반적으로 ASD 아동은 정상 아동과 비교했을 때, 눈 맞춤을 회피하거나 특정 시선 자극을 과도하게 집중하는 경향을 보인다[6,7]. 이러한 시선 이동 경로 차이는 ASD 조기 예측에 중요한 특징으로

작용한다[7].

딥러닝 모델을 학습하기 위해서는 일반적으로 대규모 데이터가 필요하다[4]. 하지만 ASD 아동을 대상으로 한 시선 추적 이미지 데이터는 의료 데이터 특성상 민감한 개인정보를 포함하고 있어 수집 및 공유에 제약이 많다. 특히 중앙 서버에 데이터를 모아 일괄적으로 학습하는 기존 학습 방법은 개인정보 보호에 대한 문제와 데이터가 분산되어 있는 경우 협력 연구가 어려워진다는 한계가 존재한다. 이러한 문제를 해결하기 위한 대안으로 최근 연합학습(Federated Learning) 기법을 사용하여 연구를 수행하고 있다. 연합학습은 데이터가 위치한 로컬 기기나 기관(병원, 은행 등)에서 각각 모델을 학습하고, 학습된 파라미터(가중치)만 중앙 서버에 공유함으로써 원본 데이터가 외부로 유출되지 않도록 하는 분산 학습 방법이다[8,9]. 이를 통해 의료 데이터의 개인정보를 보호하면서도 협력하여 딥러닝 모델을 학습할 수 있는 장점을 얻을 수 있다.

본 연구는 의료 데이터 특성상 수집 및 공유에 제약이 많은 한계를 보완하고자 연합학습을 적용한 시선 추적 이미지 데이터 분류 모델을 제안한다. 먼저 ASD 아동과 정상 아동의 시선 추적 결과를 담은 이미지를 기반으로 자폐 스펙트럼 장애 아동 분류 모델을 구축한다. 이후 연합학습을 적용하여 분류 모델을 학습한다. 마지막으로 연합학습 기반 모델이 기존의 중앙집중형 방식 대비 어느 정도의 정확성을 확보하는지 평가함으로써, 분산된 환경에서도 개인정보를 보호하면서 자폐 스펙트럼 장애 예측이 가능함을 입증하고자 한다.

II. 관련 연구

1. 자폐 스펙트럼 장애 조기 예측 연구

전문가들이 기존에 사용하던 자폐 스펙트럼 장애 선별 도구들은 긴 훈련 과정을 요구하며, 전문가의 숙련도에 따라 선별 결과의 일관성이 달

라질 수 있다[3,4]. 또한 전문가들이 도구를 활용해 한 명의 아동에 대해 진단하는 데만 최소 6~7시간이 소요된다[4]. 이러한 한계는 아동들의 ASD 조기 진단 시기를 놓칠 위험을 높이게 하여 조기 치료 및 개입의 효과를 저해하는 주요 요인으로 지적되고 있다[4].

최근에는 많은 연구들이 자폐 스펙트럼 장애 아동을 빠르게 예측할 수 있도록 시선 추적(Eye Tracking) 기술을 활용하고 있다[6,7]. 시선 추적 기술은 다른 측정 기술에 비해 빠르고 비용 효율적이며 모든 연령대 아동에게 적용이 가능하다. 시선 추적 기술을 통해 자폐 스펙트럼 장애 아동과 정상 아동의 시선 이동 패턴을 관찰하였을 때 두 집단 간의 다른 특성을 보인다[7]. 예를 들어 자폐 스펙트럼 장애 아동은 얼굴 인식에서 주의 집중이 낮거나 특정 자극에 과도한 집중을 보이는 경향이 있다[7]. 이러한 특성은 시선 추적 데이터를 활용한 자폐 스펙트럼 예측 모델에 중요한 기반을 제공한다.

딥러닝 모델은 시선 추적 관측 데이터를 활용한 자폐 스펙트럼 장애 예측의 정확도를 높이는 데 중요한 역할을 하고 있다. Carette et al. (2019)는 ASD 아동과 정상 아동을 대상으로 시선 추적 기술을 활용하여 시선 추적 시각화 데이터를 구축하였다. 이를 통해 ASD 아동의 이상 시선 움직임 양상 데이터를 체계적으로 구축할 수 있는 기반을 마련하였다[6]. Ahmed et al. (2022)의 연구는 Carette et al. (2019) 연구에서 구축한 데이터와 GoogLeNet과 ResNet-18과 같은 딥러닝 모델을 활용하여 정확도 90% 이상의 성능을 보여 시선 추적 기반 ASD 예측 모델의 유효성을 입증하였다[7].

2. 연합학습 기반 자폐 스펙트럼 예측 연구

딥러닝 모델로 높은 정확도를 얻기 위해서는 대규모의 고품질 데이터가 필수적이다. 하지만 의료 데이터는 개인정보 보호 및 데이터 보안 문제로 인해 기관 간 공유에 제약이 크다[8]. 개인

정보 비식별화 후 데이터를 공유하는 방법이 있지만, 연구 목적으로 의료 데이터를 제공받기 위해서는 복잡한 법적·윤리적 문제 또한 해결해야 한다[10]. 또한 데이터 공유 과정에서 인적 오류로 인한 정보 유출 위험도 존재한다[11].

이에 따라 최근에는 연합학습(Federated Learning) 기법이 도입되어 연구되고 있다. 연합학습은 데이터를 중앙 서버에 직접 전송하지 않고, 각 로컬 환경(클라이언트)에서 딥러닝 모델을 학습한 뒤 학습된 모델의 파라미터만 중앙 서버로 공유하는 방식이다[8,9]. 분산된 환경에서 모델 학습을 수행하는 경우 의료 데이터 보안 문제를 보완하면서도 딥러닝 모델 성능 향상을 수행할 수 있다는 장점이 있다[9].




그림 1. 중앙집중형 학습 도식도




그림 2. 연합학습 도식도

그림1은 연합학습이 등장하기 이전, 로컬 데이터를 중앙 서버에 모아 학습하는 중앙집중형(Centralized Learning) 구조를 보여준다. 중앙집중형 학습 방법은 각 클라이언트가 보유하고 있는 원본 데이터를 중앙 서버에 업로드 후 통합하여 학습하는 절차이다[9]. 반면 그림 2에서처럼

연합학습은 각 클라이언트가 데이터를 로컬에서 학습하고 학습된 모델의 파라미터(가중치)만 글로벌 모델과 공유함으로써 개인정보 및 데이터 유출을 방지할 수 있게 한다[8,9].

Shamseddine et al. (2022)는 ASD 아동의 행동적 특성과 안면 이미지를 활용하여 연합학습 기반 예측 모델을 제안하였다. 해당 모델은 분산 환경에서 학습을 진행하여 환자 데이터가 직접 외부로 노출되지 않도록 하였다. 실험 결과 제안된 모델은 행동적 특성 데이터에 대해서는 정확도 70%, 안면 이미지 데이터에 대해서는 정확도 62%의 예측 성능을 보였다[12].

또한 Farooq et al. (2023)은 네 가지 종류의 ASD 환자 데이터셋을 바탕으로 연합학습 기반 머신러닝 모델을 개발하였다. 로지스틱 회귀와 서포트 벡터 머신을 각각 로컬에서 학습한 후 중앙 서버에서 메타 분류기를 통해 최적 모델을 선정하는 방식으로, 아동 98%, 성인 81%의 예측 정확도를 기록하였다[13]. 해당 연구는 연합학습이 분산된 환경에서도 자폐 스펙트럼 장애의 조기 예측에서도 유효한 방법임을 입증하였다.

현재 연합학습을 적용한 자폐 스펙트럼 장애 예측 연구에서 시선 추적 데이터를 활용한 연구 사례는 부족한 상황이다. 따라서 본 연구는 시선 추적 데이터를 기반으로 한 자폐 스펙트럼 장애 예측 모델에 연합학습 환경을 구축하여 분산된 의료 데이터 환경에서도 자폐 스펙트럼 장애 예측이 가능함을 입증하고자 한다.

III. 제안 방법

본 연구는 여러 기관에 분산된 의료 데이터 환경에서 자폐 스펙트럼 장애 아동을 효과적으로 예측하는 방법으로 연합학습 기반 시선추적 이미지 분류 모델을 제안한다. 연합학습 워크플로는 그림 3과 같이 “로컬 모델 학습”, “글로벌 모델 업데이트”, “글로벌 모델 배포” 순으로 진행된다.




그림 3. 연합학습 워크플로

우선 각 클라이언트는 ASD 아동 및 TD 아동을 대상으로 구축된 시선 추적 이미지를 활용해 분류 모델을 개별적으로 학습한다. 모델 학습에 앞서, 이미지 내 시선 이동 경로를 강조하기 위해 다음과 같은 단계로 이미지 데이터를 전처리한다. 먼저, 평균 필터를 적용해 노이즈를 제거하고 라플라시안 필터 사용하여 이미지의 엣지를 강조한다. 마지막으로 평균 필터링된 이미지에서 라플라시안 필터링된 결과를 빼는 과정을 통해 시선 이동 경로의 특징을 더욱 선명하게 만든다.

데이터 전처리를 마친 뒤 로컬 CNN 모델 학습을 수행한다. 먼저 합성곱 계층을 통해 입력된 이미지 데이터의 중요한 특징을 추출하고 풀링 계층을 거쳐 맵의 차원을 축소함으로써 계산 효율을 높인다. 이어서 드롭아웃을 활용하여 과적합을 방지하고 완전 연결 계층에서 ASD 아동과 TD 아동을 분류한다. 위와 같은 학습 과정을 통해 로컬 모델 초기 성능을 확보한다.

각 클라이언트는 로컬 모델 학습을 완료한 후, 학습된 로컬 모델의 가중치를 중앙 서버로 전송한다. 서버는 전송받은 가중치를 기반으로 글로벌 모델을 업데이트한다. 글로벌 모델 업데이트는 수식 1과 같이 진행된다.

$$w_{t+1} \leftarrow \sum_{k=1}^K \left(\frac{n_k}{n} w_t^k \right) \quad (1)$$

수식 1에서 w_{t+1} 은 $t+1$ 번째 라운드에서의 글

로벌 모델의 파라미터를 의미한다. w_t^k 는 클라이언트 k의 t번째 라운드 로컬 모델 파라미터를 의미한다. n_k 는 클라이언트 k의 데이터 샘플 수이고 n 은 전체 데이터 샘플 수의 합을 나타낸다. 수식 1을 통해 서버는 클라이언트에서 전달받은 로컬 모델 파라미터를 각 클라이언트의 데이터 샘플 크기에 비례하여 가중 평균을 계산한다. 계산된 파라미터 결과를 통해 글로벌 모델 파라미터를 업데이트한다.

글로벌 모델은 클라이언트의 가중치를 통합한 결과로 생성된다. 이를 다시 클라이언트에 배포하여 다음 라운드 학습의 기반으로 사용한다. 라운드가 반복됨에 따라 글로벌 모델은 점진적으로 안정화되며, 최종 성능에 수렴하게 된다[9].

IV. 실험 환경

본 연구에서는 시선 추적 이미지 데이터를 활용하여 ASD 아동과 TD 아동을 분류하기 위해 Carrette et al.(2019)에서 구축한 데이터를 사용하였다. 이들은 시선 추적 기술을 통해 ASD 아동과 TD 아동을 분류하기 위한 547개 시선 추적 이미지 데이터셋을 구축하였다. ASD 클래스에는 219개, TD 클래스에는 328개 이미지가 포함되어 있다.

자폐 스펙트럼 장애 진단은 CARS(Childhood Autism Rating Scale) 점수를 기반으로 전문가에 의해 평가되었다[6]. 본 연구에서는 자폐 스펙트럼 장애 유무뿐만 아니라 병증의 정도 또한 파악하기 위해 CARS 점수를 기준으로 ASD 클래스를 경증($CARS < 30$), 중등도($30 \leq CARS < 36$), 중증($CARS \geq 36$)의 세 가지 클래스로 세분화하였다. 구분된 데이터 수는 표 1과 같다.

표 1. 시선 추적 이미지 각 Class 별 데이터 수

Class	Train (중강 전)	Train (중강 후)	Test
ASD 경증	88	956	10
ASD 중등도	78	856	9
ASD 중증	30	342	4
TD	295	3,254	33

데이터는 그림 4와 같은 다양한 시각적 요소(예: 풍선, 동물 등)를 포함한 비디오를 시청하는 동안 참가 아동들의 눈 움직임 경로를 시선 추적 기술을 통해 기록하여 구축되었다[6]. 참가 아동은 총 59명(ASD 그룹 29명, TD 그룹 30명)이며 평균 연령은 약 8세 정도이다. 그림 5와 그림 6과 같이 ASD 아동과 TD 아동의 시선 이동 경로의 차이를 분명히 확인할 수 있다[6].



그림 4. 데이터 구축을 위해 사용한 비디오 장면[6]




그림 5. ASD 아동 시선 추적 이미지 샘플[6]




그림 6. TD 아동 시선 추적 이미지 샘플[6]

논문 [6] 연구에서 공개한 데이터 수는 제안하는 연합학습 모델 학습에 충분하지 않아 데이터 증강을 수행하였다. 데이터 증강에 좌우 반전, 회전, 이동 등 기법을 사용하여 약 11배 증강을 수행하였다. 증강된 데이터 수는 표 1과 같다. 증강된 전체 데이터는 동일한 비율로 각 클라이언트에 배정하였으며 배정된 학습 데이터 수는 2,704개이다.

모델 성능 비교 실험은 중앙집중형 학습과 연합학습에 대해 모두 진행하였다. 중앙집중형 학습 실험 환경은 RTX A6000 GPU가 1대 설치된 단일 서버로 구성된다. 모델 학습은 단일 서버에서 모든 데이터를 학습되며, 총 20 epoch 동안 학습이 진행된다. 1 epoch 당 배치 크기는 16으로 설정했으며, Learning rate는 0.001로 설정하였다. 손실함수는 교차 엔트로피 함수를, Optimizer는 Adam을 사용하였다.

연합학습 실험 환경은 서버와 클라이언트 2대로 구성된다. 서버는 TITAN RTX GPU 1대를 장착한 워크스테이션으로 구성된다. 그리고 클라이언트 2대는 각각 RTX 6000 ADA GPU 2대와 RTX A6000 GPU 1대를 사용한다. 모든 클라이언트는 동일한 신경망 구조를 사용한다. 학습 데이터는 각 클라이언트에 전체 데이터를 50:50으로 균등하게 나누어 배정된다.

글로벌 모델 학습은 총 20라운드 진행되며, 각 라운드에서 모든 클라이언트가 학습에 참여한다. 각 클라이언트는 1라운드 당 20 epoch 동안

로컬 학습 데이터를 학습한다. 1 epoch 동안 로컬 모델은 클라이언트가 보유한 전체 데이터를 배치 크기 16으로 나누어 학습을 수행한다. 클라이언트는 1라운드 동안 학습이 완료된 로컬 모델 가중치를 서버로 전송한다. 연합학습은 Flower: A Friendly Federated Learning Framework 라이브러리를 활용하여 수행하였다 [14].

분류 모델 성능 측정은 정확도(Accuracy, ACC), F1 스코어, 재현율(Recall), 정밀도(Precision) 지표를 통해 평가된다. 해당 지표에 대한 수식은 다음과 같다.

$$Accuracy = \frac{(TP + TN)}{Number\ of\ test\ data} \quad (2)$$

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

각 지표를 계산하기 위해서 TP, TN, FP, FN 정보를 활용한다. 여기서 TP(True Positive)는 모델이 양성이라고 예측했을 때 실제로도 양성인 경우를 의미하고, TN(True Negative)은 모델이 음성이라고 예측했을 때 실제로도 음성인 경우를 뜻한다. 반면 FP(False Positive)는 모델이 양성이라고 예측했으나 실제로는 음성인 경우이며, FN(False Negative)은 모델이 음성이라고 예측했으나 실제로는 양성인 경우를 의미한다.

V. 실험 결과

본 연구는 데이터가 분산된 환경에서 연합학습을 적용한 시선 추적 이미지 분류 모델 학습 방법이 얼마나 효과적인지 평가하기 위해 중앙집중형 학습 모델과 연합학습 기반 글로벌 모델 성능을 비교 평가하였다. 표 2는 각 학습 방법에 따

른 성능 결과이다.

표 2. 학습 방법에 따른 분류 모델 성능

학습 방법	ACC	F1	Precision	Recall
중앙집중	0.92	0.89	0.94	0.85
연합학습	0.85	0.84	0.84	0.85

중앙집중형 학습 모델은 전체 데이터를 대상으로 단일 서버에서 학습한 결과이다. 해당 모델은 정확도 0.92, F1 스코어 0.89, 정밀도 0.94, 재현율 0.85의 높은 성능을 기록하였다. 반면 연합학습 기반 글로벌 모델은 정확도 0.85, F1 스코어 0.84, 정밀도 0.84, 재현율 0.85의 성능을 보이며, 중앙집중형 모델 대비 약 94.4%의 성능(F1 스코어 기준)을 보였다. 그러나 연합학습은 데이터를 로컬 환경에 유지하며 학습을 수행하여 개인정보 보호를 유지하는 동시에 일정 수준 이상의 성능을 달성하였다.

연합학습 기반 글로벌 모델은 학습 라운드가

반복됨에 따라 성능이 향상되었다. 모델 성능은 5라운드 이후부터 안정화되기 시작하였다. 그림 7은 라운드별 성능 지표의 수치 변화 그래프이다. 초기 라운드에서는 클라이언트 간 데이터 분산으로 인해 글로벌 모델의 성능이 불안정하였으나, 라운드가 진행됨에 따라 각 클라이언트의 학습 결과가 통합되어 성능이 크게 개선되었다.




그림 8. 클래스별 예측 성능 (혼동행렬)




그림 7. 연합학습 라운드별 분류 모델 성능

분류 클래스별 성능을 파악하기 위해 그림 8과 같이 혼동행렬을 구성하였다. 본 연구에서 제안한 모델은 TD 아동에 대해서 99%의 높은 예측 정확도를 보였다. 하지만 ASD 경증, 중등도, 중증의 세 클래스에서는 각각 77%, 88%, 79%의 비교적 낮은 정확도를 보였다. 이는 TD 클래스 대비 ASD 클래스들의 데이터가 적기 때문에 나타난 결과로 분석된다.

VI. 결 론

자폐 스펙트럼 장애 예측에 활용되는 데이터들은 의료 데이터로 공유 및 분석에 제약이 따른다. 이에 본 연구는 여러 기관에 분산된 데이터를 중앙에서 정보 유출 없이 학습할 수 있는 연합학습을 적용하여 ASD 아동과 TD 아동을 분류하는 시선 추적 이미지 데이터 분류 모델을 구축하였다.

본 연구는 실험을 통해 연합학습을 적용한 시선 추적 이미지 분류 모델 학습 방법의 정확도를 평가하고자 중앙집중형 학습 기반 모델과 비교 실험을 진행하였다. 실험 결과 연합학습을 적용한 모델은 정확도 0.85와 F1 스코어 0.84를 달성하여 중앙집중형 학습 모델 대비 각각 약 92.4% 약 94.4%의 성능을 보였다. 이를 통해 연합학습이 분산 데이터 환경에서도 시선 추적 이미지 분류 모델을 효과적으로 학습할 수 있음을 입증하였다.

향후 연구에서는 연합학습을 적용한 모델의 성능을 개선하기 위해 다양한 심층 신경망 네트워크를 적용한 연구를 수행할 계획이다. 또한 실제 임상 환경에서의 적용 가능성 유무에 관해서도 추가 연구를 수행하여 적용 가능성을 검증할 예정이다.

REFERENCES

- [1] 2021년 발달장애인 실태조사 결과 발표(2022), https://www.mohw.go.kr/board.es?mid=a1050300000&bid=0027&tag=&act=view&list_no=37283
- [2] 2023년 등록장애인 264만 2,000명, 전체 인구 대비 5.1%(2024), https://www.mohw.go.kr/board.es?mid=a1050300000&bid=0027&list_no=1481120&act=view (accessed Jan., 7, 2025).
- [3] 이나림, 홍영은, 김예니, “자폐 스펙트럼 장애 선별 도구에 대한 고찰,” *신경정신의학*, 제58권, 제3호, 192-201쪽, 2019년 8월
- [4] 김정준, 권용섭, 김민규, 김은수, 김경호, 손동섭, “자폐 조기 선별을 위한 리빙랩 구축 방법과 데이터 획득 방안 연구,” *한국컴퓨터정보학회논문지*, 제25권, 제8호, 47-54쪽, 2020년 8월
- [5] 이성춘, 문장원, “자폐스펙트럼장애의 조기 선별에 대한 검토,” *심리운동연구*, 제8권, 제1호, 55-79쪽, 2022년 3월
- [6] R. Carette, M. Elbattah, F. Cilia, G. Dequen, J. L. Guérin, and J. Bosche, “Learning to Predict Autism Spectrum Disorder based on the Visual Patterns of Eye-tracking Scanpaths,” *Proc. of the 12th International Joint Conference on Biomedical Engineering Systems and Technologies (BIOSTEC 2019) - HEALTHINF*, pp. 103-112, Prague, Czech Republic, Feb. 2019.
- [7] I. A. Ahmed, E. M. Senan, T. H. Rassem, M. A. H. Ali, H. S. A. Shatnawi, S. M. Alwazer, and M. Alshahrani, “Eye Tracking-Based Diagnosis and Early Detection of Autism Spectrum Disorder Using Machine Learning and Deep Learning Techniques,” *Electronics*, vol. 11, no. 4, 2022.
- [8] 공희산, 김광수, “연합학습의 의료분야 적용을 위한 자기지도 메타러닝,” *지능정보연구*, 제28권, 제4호, 27-40쪽, 2022년 12월
- [9] 김동균, 임제한, 이현종, 임연섭, “SNN 기반 연합학습의 이미지 분류 성능 및 에너지 효율성 분석,” *한국통신학회논문지*, 제49권, 제7호, 935-946쪽, 2024년 7월
- [10] [기고] 의료데이터 규제와 활용을 위한 국가 정책력 확보 전략(2024), <http://www.docdocdoc.co.kr/news/articleView.html?idxno=3024559> (accessed Feb, 12, 2025).
- [11] 고혜경, “XML 기반 전자 의료 기록 데이터의 개인 정보 보호 기법 연구,” *한국정보기술학회논문지*, 제12권 제5호, 185-191쪽, 2014년 5월
- [12] H. Shamseddine, S. Otoum, and A. Mourad, “On the Feasibility of Federated Learning for Neurodevelopmental Disorders: ASD Detection Use-Case,” *Proc. of GLOBECOM 2022 - 2022 IEEE Global Communications Conference*, Rio de Janeiro, Brazil, pp. 1121 - 1127, Dec. 2022.
- [13] M. S. Farooq, R. Tehseen, M. Sabir, and Z. Atal, “Detection of autism spectrum disorder (ASD) in children and adults using machine learning,” *Scientific Reports*, vol. 13, 2023.

- [14] D. J. Beutel, T. Topal, A. Mathur, X. Qiu, J. Fernandez-Marques, Y. Gao, L. Sani, H. L. Kwing, T. Parcollet, P. P. B. de Gusmão, and N. D. Lane, "Flower: A Friendly Federated Learning Research Framework," arXiv preprint arXiv:2007.14390, 2020.

저 자 소 개



신현호(정회원)

2020년 경기대학교 문헌정보학과 학사 졸업.

2022년 경기대학교 문헌정보학과 석사 졸업.

2025년~현재 경기대학교 문헌정보학과 박사과정 재학.

2023년~현재 한국과학기술정보연구원 재직, 기술원.

<주관심분야 : 사회문제해결 R&SD 분석, 정보추출, 자연어처리, 이미지처리 등>



이재민(정회원)

2001년 서울대학교 물리학과 학사 졸업.

2008년 서울대학교 물리학과 박사 졸업.

2008년~2010년 삼성전자 반도체연구소 책임연구원.

2010년~현재 한국과학기술정보연구원 재직, 책임연구원.

<주관심분야 : 사회문제해결 R&SD 분석, 기술기획발굴 모델, 자연어처리 등>



전홍우(정회원)

2002년 고려대학교 컴퓨터학과 학사 졸업.

2004년 고려대학교 컴퓨터학과 석사 졸업.

2007년 도쿄대학교 컴퓨터과학과 박사 졸업.

2009년~현재 한국과학기술정보연구원 재직, 책임연구원.

<주관심분야 : 치매조기예측시스템, 자연어처리기술기반 사회문제예측, 자연어처리 등>