

MRI 영상을 활용한 경량 CNN-Transformer 기반 알츠하이머병 분류

윤태현*¹, 김상욱*², 류지열**³, 하지환***⁴

Alzheimer's Disease Classification using MRI-based Lightweight CNN - Transformer

Taehyeon Yun*¹, Sanguk Kim*², Jee-Youl Ryu**³, and Jihwan Ha***⁴

본 과제(결과물)는 2025년도 교육부 및 부산시의 재원으로 부산RISE혁신원의 지원을 받아 수행된 지역혁신중심 대학지원체계(RISE)의 결과입니다(2025-RISE-02-001-002)

요 약

알츠하이머병(AD)은 개인과 사회에 막대한 부담을 주며, 이를 줄이기 위해서는 증상 발현 이전 단계에서의 조기 진단이 필수적이다. 멀티모달 접근은 성능상 이점이 있으나 비용, 복잡성, 데이터 가용성의 제약으로 임상적 도입이 제한된다. 본 연구는 MRI 단일 모달리티만으로 AD와 정상군(CN)을 구분하는 경량 CNN-Transformer 모델을 제안한다. 전체 MRI 볼륨에서 관심 영역(ROI)의 대표 2D 슬라이스를 추출해 저비용 입력을 구성하였고, 공유 가중치 CNN과 Transformer로 ROI 표현과 상호작용을 학습한다. 이어 ROI attention pooling으로 전역 표현을 구성해 핵심 ROI를 정량화한다. 마지막으로, 제안 모델은 Accuracy 0.88, AUC 0.93을 달성하였으며, ROI 수준의 분석으로 높은 해석 가능성을 보였음을 확인하였다.

Abstract

Alzheimer's Disease (AD) imposes a substantial burden on individuals and society, and early diagnosis before symptom onset is essential to mitigate this burden. Although multimodal approaches offer performance advantages, their cost, complexity, and data availability constraints limit clinical adoption. This study proposes a lightweight CNN-Transformer model that distinguishes AD from Cognitively Normal (CN) subjects using MRI alone. From whole-brain MRI volumes, we extract representative 2D slices from Regions of Interest (ROIs) to construct a low-cost input, and use a shared-weight CNN and a Transformer to learn ROI representations and their interactions. We then employ ROI attention pooling to compose a global representation and quantitatively identify key ROIs. Finally, we confirmed that the proposed model exhibits competitive discriminative performance and high interpretability compared to existing methods.

Keywords

Alzheimer's disease, MRI, deep learning, bioinformatics, CNN-Transformer, ROI-based classification

* 부경대학교 데이터공학과

- ORCID¹: <https://orcid.org/0009-0009-3548-7430>

- ORCID²: <https://orcid.org/0009-0007-3765-2212>

** 부경대학교 정보통신학과 교수

- ORCID: <https://orcid.org/0000-0003-2343-7056>

*** 부경대학교 빅데이터융합전공 교수(교신저자)

- ORCID: <https://orcid.org/0000-0002-6086-5693>

• Received: Aug. 28, 2025, Revised: Oct. 14, 2025, Accepted: Oct. 17, 2025

• Corresponding Author: Jihwan Ha

Major of Big Data Convergence, Division of Data Information Science,

Pukyong National University, Busan 48513, Korea

Tel.: +82-51-629-4614, Email: jhha@pknu.ac.kr

I. 서 론

알츠하이머병(AD, Alzheimer's Disease)은 전 세계적으로 가장 흔한 퇴행성 뇌질환으로, 기억력 감퇴, 언어 장애, 판단력 저하 등 다양한 인지 기능의 손상을 유발하는 치매의 주요 원인이다[1]. 특히 고령화 사회로 진입한 현대 사회에서 AD로 인한 사회적·경제적 부담은 급격히 증가하고 있으며, 세계보건기구(WHO)에 따르면 2050년에는 전 세계 치매 환자 수가 1억 3,900만명에 이를 것으로 예측된다[2]. 그러나 현재까지는 AD는 완치가 불가능하며, 증상 발현 이후에는 질환의 진행을 지연시키는 치료만 가능하기 때문에, 증상이 나타나기 전에 조기 진단과 예방적 개입이 무엇보다 중요하다[3]. 한편 경도인지장애(MCI, Mild Cognitive Impairment)는 AD의 전구 단계로, 초기에는 정상군과의 차이가 미세해 조기 변별이 어렵다[4].

AD의 진단에는 자기공명영상(MRI, Magnetic Resonance Imaging), 양전자 방출 단층 촬영(PET, Positron Emission Tomography), 전자의무기록(EHR, Electronic Health Records) 등 다양한 모달리티의 데이터가 활용되고 있다[5]. 이러한 멀티 모달 접근은 진단 정확도를 높이는 데 효과적이지만, 각 데이터의 획득에 필요한 비용과 시간, 환자에게 가해지는 부담, 데이터의 불균형 및 통합의 복잡성 등의 문제가 여전히 존재한다[6]. 이 중 MRI는 비침습적이며 반복 촬영이 가능하고, 뇌의 해부학적 변화를 고해상도로 제공할 수 있어 실용성과 접근성 측면에서 유리한 단일 모달리티로 평가된다[7].

최근에는 딥러닝(DL, Deep Learning)을 비롯한 다양한 인공지능 기술이 AD 진단뿐만 아니라 의료 영상 분석 및 생물정보학 분야 전반에서 높은 성능을 보이며 주목받고 있다[8]-[18]. 특히 합성곱 신경망(CNN, Convolutional Neural Network)은 원시 영상으로부터 특징을 자동으로 학습할 수 있어, 기존 머신러닝 기반 접근보다 우수한 성능을 달성해왔다[19][20]. 그러나 대부분의 딥러닝 기반 모델은 다양한 모달리티를 활용하거나 높은 성능을 보이더라도, 해석 가능성이 낮고 실제 임상 환경에서의 적용을 위한 비용 및 데이터 확보의 제약 문제를 완전히

해결하지 못하고 있다[21]. 이에 따라 MRI 단일 모달리티 기반의 경량화되고 해석 가능한 딥러닝 모델의 개발이 여전히 중요한 과제로 남아 있다.

본 연구는 MRI 단일 모달리티만을 활용하여 정상군(CN, Cognitively Normal)과 알츠하이머병(AD)을 구분하는 경량 딥러닝 모델을 제안한다. 본 모델은 복잡한 멀티모달 융합 없이도 AD 조기 진단을 위한 실용적인 성능을 달성하였으며, 계산 효율성과 해석 가능성을 동시에 고려한 구조를 설계하였다. 특히 모델이 주목한 뇌 영역을 시각화함으로써 단순한 분류 정확도를 넘어 임상적으로 신뢰 가능한 진단 근거를 함께 제시하고자 하였다.

II. 관련 연구

AD의 조기 진단을 위한 딥러닝 기반 연구는 의료영상 분석, 특히 MRI 데이터를 중심으로 활발히 이루어져 왔다. 초기에는 해마(Hippocampus)나 측두엽(Temporal lobe)처럼 퇴행이 먼저 시작되는 영역의 부피 감소 또는 형태학적 변화를 분석하는 데 초점을 맞추었으며, 이를 기반으로 한 전통적 머신러닝 접근법이 주로 활용되었다. 하지만 이러한 방식은 복잡한 전처리 및 수작업 기반의 특징(Feature) 설계가 필요하다는 한계가 있었다[22]-[27]. 이러한 문제를 해결하고자, 최근에는 딥러닝 기반의 자동 특징 학습 기술이 주목받고 있다. 특히 CNN은 원시 영상에서 의미 있는 패턴을 자동으로 추출할 수 있어 전처리 과정을 단순화하고 분류 성능을 크게 향상시켰다[20][28]. CNN 기반 모델들은 전체 뇌 영상 혹은 특정 관심 영역(ROI, Region of Interest)을 입력으로 하여 인지 저하의 단서를 탐지하는 데 활용되었으며, 다양한 구조 개선을 통해 성능을 점차 향상시켜 왔다[28].

최근 연구들은 단일 MRI 정보뿐 아니라 PET, 유전자 정보(SNP), 뇌척수액(CSF), EHR 등 이질적인 데이터를 통합하는 멀티모달 학습 기법으로 확장되고 있다. 예를 들어, Suk et al.[29]은 MRI와 PET 데이터를 병렬로 입력받아 딥러닝 기반의 AD 분류 모델을 제안하였고, Zhang, Daoqiang, et al.[30]은 MRI, PET, CSF 정보를 함께 통합하여 분류 정

확도를 높이는 데 성공하였다. 또한 Qiu, Shangran, et al.[31]은 MRI 기반의 구조적 정보와 MMSE(Mini-Mental State Examination) 및 LM(Logical Memory) 검사 등 EHR 기반의 인지 평가 정보를 통합하여, MCI 진단을 위한 임상적 기능과 뇌 구조 변화 간의 연관성을 정량적으로 모델링한 바 있다. 하지만 이러한 멀티모달 접근법은 PET 촬영에서의 방사선 노출, 유전체 데이터 수집에 따른 윤리적 이슈, 그리고 EHR의 불완전성과 병원 간 데이터 호환성 문제 등으로 인해 실제 임상 현장에서의 적용에는 여러 제약이 따른다[17]. 특히 AD의 조기 진단을 위해서는 비침습적이고 환자 친화적인, 저비용·저위험 진단 방법이 요구되며, 이러한 요구는 MRI와 같은 단일 모달리티 기반 접근의 활용 가능성을 다시금 부각시키고 있다.

더불어 최근 연구들은 모델의 해석 가능성(Interpretability) 확보에도 주목하고 있다. AD는 특정 뇌 영역의 위축이나 병리적 변화를 기반으로 진단되는 질환이므로, 모델이 어떤 뇌 부위에 주목했는지 설명 가능한 구조가 필수적이다. 이를 위해 attention 매커니즘을 활용하거나[32], 모델의 feature activation map을 시각화하는 Grad-CAM 기반 기법이 도입되고 있으며, 모델의 판단 근거를 뇌 해부학적 구조와 연관짓는 시도들이 이어지고 있다[33]-[35]. 따라서 최근에는 MRI 단일 모달리티 기반으로도 충분한 진단 성능을 확보할 수 있는 모델 개발, 모델이 주목하는 뇌 영역을 직관적으로 해석할 수 있는 구조 설계, 임상 적용을 고려한 경량화 모델에 대한 관심이 점차 증가하고 있다[35][36]. 이러한 연구 흐름은 향후 실제 임상에서의 적용 가능성을 높이기 위한 중요한 기반이 되고 있으며, 본 연구는 이러한 요구를 충족시키기 위한 경량화 및 해석 가능한 단일 모달 CNN 기반 모델을 제안하고자 한다.

III. 딥러닝 기반 AD 진단 모델링

3.1 데이터셋

본 연구에서는 ADNI(Alzheimer's Disease Neuroimaging Initiative) 데이터베이스(adni.loni.usc.edu)

에서 제공하는 T1-weighted MRI 영상을 사용하였다. ADNI는 2003년에 시작된 공공-민간 협력 프로젝트로, MRI, PET, 생물학적 지표, 임상 및 신경심리학적 평가자료를 통해 알츠하이머병(AD)과 경도인지장애(MCI)의 진행 과정을 분석하는 것을 목적으로 한다. 분석에는 ADNI1, ADNI-GO, ADNI2, ADNI3에 해당하는 데이터를 포함하였으며, 본 연구에서는 AD와 CN만을 대상으로 하는 이진 분류(AD vs CN) 실험에 한정하였으며, 한 피험자의 여러 시점에서 촬영된 MRI를 각각 독립적인 샘플로 활용하여 데이터셋의 규모를 확장하였다. 이러한 접근은 모델이 시기별 변화를 포함한 다양한 패턴을 학습할 수 있도록 하여, 일반화 성능 향상에 기여한다. 각 진단군의 피험자 수와 샘플 수는 표 1에 제시하였다.

표 1. 실험 데이터 세트

Table 1. Experimental dataset

Class	Subject	Sample
CN	298	802
AD	355	616

3.2 데이터 전처리

본 연구에서는 ADNI에서 제공하는 T1-weighted MRI 데이터를 대상으로, 모델 입력의 일관성과 분석 신뢰성을 확보하기 위해 일련의 전처리 과정을 수행하였다.

첫 단계에서는, MRI 영상에서 발생하는 RF(Radio Frequency) 필드 불균일성(RF inhomogeneity)으로 인한 신호 강도 왜곡을 보정하기 위해 ANTs(Advanced Normalization Tools)의 N4ITK 알고리즘을 기반으로 한 bias-field correction을 적용하였다. 이 단계는 특히 고해상도 MRI에서 발생하는 중심부/주변부 강도 차이를 보정하여, 후속 분석의 정밀도를 향상시킨다[37].

이후, FSL(FMRIB Software Library)의 BET(Brain Extraction Tool)을 이용하여 두개골, 연부조직, 피부 등 뇌 외부 구조를 제거하는 skull stripping을 수행하였다[38].

정합 단계에서는 모든 영상을 MNI152 표준공간(1mm isotropic resolution)에 맞추기 위해, 먼저

FLIRT(FMRIB's Linear Image Registration Tool)를 사용한 12자유도 아핀 정합(Affine registration)을 수행한 뒤, ANTs SyN(Symmetric Normalization) 알고리즘을 활용하여 비선형 정합(non-linear registration)을 진행하였다[39]-[42]. 이를 통해 피험자 간 구조적 차이를 표준 좌표계로 정렬하여 공간적 일관성을 확보하였다.

다음으로, 스캐너, 세션, 사이트 간 강도 차이를 줄이기 위해 z-score 기반 강도 정규화(Intensity normalization)를 적용하여 각 영상의 평균 강도를 0, 표준편차를 1로 조정하였다[43].

마지막으로, AAL(Automated Anatomical Labeling) atlas를 기반으로 알츠하이머병과 연관성이 보고된 19개의 관심영역(ROI)을 분할(Parcellation)하였다. 선택된 ROI에는 양측 편도체(Amygdala), 해마(Hippocampus), 시상(Thalamus), 소뇌(Cerebellum) 등이 포함된다[29][44]. 각 ROI는 3차원 볼륨으로 추출된 뒤, 모델 입력 차원을 줄이고 주요 구조적 특징을 보존하기 위해 ROI의 bounding box 좌표계에서 축 방향(axial·coronal·sagittal) 25%, 50%, 75% 위치의 2D 슬라이스를 선택하였다. 이는 알츠하이머병변이 특정 축의 중앙 단면에서만 나타나는 것이 아니라, ROI의 주변부까지 다양한 위치에서 발생할 수 있다는 점을 고려한 것이다. 따라서 ROI 내부의 서로 다른 위치를 반영함으로써 병변 분포의 다양성을 포착할 수 있으며, 단일 중앙 슬라이스만 사용하는 경우보다 더 풍부한 구조적 정보를 제공한다.

최종적으로 ROI당 9장의 2차원 슬라이스(128×128 해상도)를 스택(Stack)하여 모델 입력으로 구성하였다(그림 1 참조). 이러한 방식은 3D 볼륨 전체를 직접 처리하지 않고도 ROI별 주요 해부학적 특징을 효과적으로 보존할 수 있으며, 연산 효율성 또한 확보할 수 있다. 더 나아가, 이와 같은 3D에서 2D 슬라이스 기반 접근은 기존 선행 연구들에서도 알츠하이머병 진단 과제에서 타당성과 성능이 입증된 바 있다[45]-[49].

3.3 모델 구조

본 절에서는 제안하는 CNN-Transformer 기반 모델의 전체 구조를 설명한다. 모델은 CNN 인코더, Transformer 인코더, ROI attention pooling, Classification head로 구성된다.

3.3.1 CNN 인코더

먼저, CNN 인코더의 개요는 그림 2와 같다. CNN 인코더는 입력된 MRI 슬라이스에서 국소적 특징(local feature)을 추출하는 역할을 수행한다. 각 ROI는 9장의 슬라이스(128×128 해상도)를 채널 축으로 쌓아 입력으로 사용된다. CNN 인코더는 총 5개의 Residual Block으로 구성되어 있다. 각 블록은 첫 번째 3×3 Conv 뒤 배치정규화(BN)와 ReLU를 적용하고, 이어서 두 번째 3×3 Conv와 BN을 수행한다.




그림 1. ROI 기반 입력 데이터 전처리 과정

Fig. 1. ROI-based input data preprocessing pipeline




그림 2. ROI별 CNN 인코더 구조
Fig. 2. Per-ROI CNN encoder architecture




그림 3. 전체 모델 구조
Fig. 3. Overall model architecture

해상도를 줄여야 할 때는 첫 번째 Conv에 stride=2를 두며, 입력·출력 채널 수가 달라지는 경우에는 1x1 Conv를 사용해 차원을 정합한다. 이러한 설계를 통해 블록이 진행될수록 공간 해상도는 단계적으로 감소하고, ReLU가 비선형성을 강화한다. 마지막 단계에서는 Adaptive Average Pooling을 통해 공간 정보를 1x1로 축약하고, Fully-Connected 층을 거쳐 64차원의 임베딩 벡터를 생성한다. 본 연구에서는 CNN 인코더를 19개 ROI에 대해 가중치 공유(Shared weights) 방식으로 적용한다. 이 설계는 ROI마다 별도 백본을 둘 때와 대비하여 파라미터 수를 줄여 과적합 위험을 낮추고, 모든 ROI 표현을 동일한 64차원 공간에 정렬해 Transformer가 ROI 간 상호작용과 상대적 중요도를 일관되게 비교할 수

있게 하며, 연산 및 메모리 효율을 높인다. 이에 따라 각 ROI는 동일 인코더를 통과해 64차원 임베딩 $e_i \in R^{64}$ 로 표현된다.

3.3.2 Transformer 인코더

ROI 인코더를 거쳐 산출된 19개의 임베딩을 모아 토큰 시퀀스 $X \in R^{B \times 19 \times 64}$ 를 구성하고, 이를 Transformer 인코더(층 수 L=2)에 입력한다. 본 연구에서는 명시적 positional embedding을 사용하지 않으며, ROI 순서를 고정함으로써 set encoder처럼 동작하도록 설계하였다. 인코더의 자세한 구조는 그림 3에 제시하였다. 두 개의 인코더 층을 통과한 뒤 추가 LayerNorm을 적용하며, 출력 형상은 [B, 19, 64]

로 유지된다. Transformer 인코더를 통과한 임베딩은 $h_i \in R^{64}$ 로 표기한다. 이러한 구조는 ROI 간 전역적 상호작용을 학습하여, 모델이 영역 간 상관 및 의존 관계를 포착하고 이를 통합한 전역 표현을 형성하도록 한다.

3.3.3 ROI attention pooling

본 연구에서는 ROI별 중요도를 소프트맥스 가중치로 평균하여 전역 표현을 얻는 ROI attention pooling을 사용한다.

Transformer 인코더의 ROI 토큰 출력 $H = [h_1, \dots, h_N] \in R^{N \times d}$ ($N=19, d=64$)에 대해, 각 ROI의 임베딩 h_i 의 중요도를 선형 점수로 계산하고, ROI 축에서 softmax로 정규화한 가중치를 사용하여 전역 표현 z 를 얻는다.

우선 각 ROI의 스코어 s_i 는 식 (1)과 같이 정의한다. 이어 스코어 벡터 s 를 ROI 차원에서 소프트맥스 정규화하여 가중치 α_i 를 구한다(식 (2)). 마지막으로, α_i 를 가중치로 하여 가중 평균을 통해 전역 표현 z 를 얻는다(식 (3)).

$$s_i = w^T h_i + b, w \in R^d, b \in R, s \in R^N \quad (1)$$

$$\alpha_i = \frac{\exp(s_i)}{\sum_{j=1}^N \exp(s_j)}, \quad \sum_{i=1}^N \alpha_i = 1 \quad (2)$$

$$z = \sum_{i=1}^N \alpha_i h_i \in R^d \quad (3)$$

3.3.4 Classification head

Classification head에서는 앞 절(3.3.3)에서 얻은 전역 표현을 입력으로 받아 두 개의 fully-connected 층을 거쳐 최종적으로 AD와 CN에 대한 예측 확률을 출력한다. 이 구조는 각 ROI의 기여도를 반영하면서 동시에 뇌 전체 수준의 통합 표현을 제공하므로, 모델 해석 가능성과 분류 성능을 동시에 확보할 수 있다. 전체 모델 구조는 그림 3에 제시하였다.

3.4 학습 설정

본 연구에서는 ADNI 데이터베이스에서 제공되는 T1-weighted MRI 영상을 사용하여 알츠하이머병 환자군(AD)과 정상 대조군(CN)의 이진 분류를 수행하였다. 데이터셋의 규모가 제한적임을 고려하여, 단일 분할 방식 대신 10-fold 교차검증을 수행하였다. 전체 데이터를 10개의 fold로 분할한 후, 각 fold를 검증용으로 번갈아 사용하고 나머지 9개 fold로 학습을 진행하였다. 최종 성능은 10개 fold 결과의 평균값으로 산출하였다.

본 실험의 교차검증은 샘플 단위 분할로 수행되어 동일 피험자의 상이한 시점이 서로 다른 fold에 배치될 가능성이 있으며, 이 경우 데이터 누수(Leakage)로 성능이 과대추정될 수 있음을 명시한다. 향후에는 누수 발생 여지를 배제하도록 피험자 단위(Subject-wise) 분할을 도입할 예정이다.

모델의 일반화 성능을 향상시키기 위해 훈련 세트에 한해 데이터 증강(Data augmentation)을 적용하였다. 구체적으로, 슬라이스에 대해 확률 0.5의 수평 반전, $\pm 15^\circ$ 범위의 무작위 회전, 0.9-1.0 배율의 무작위 크롭(RandomResizedCrop), 그리고 표준편차 약 0.01의 가우시안 노이즈를 추가하였다. 증강은 데이터셋의 크기를 늘리지 않고, 기존 샘플을 무작위로 변형하여 사용하였다. 검증 및 시험 세트에는 원본 데이터를 그대로 사용하였다.

최적화에는 Adam 옵티마이저를 사용하였으며, 학습률은 7×10^{-5} 가중치 감쇠는 4.7×10^{-4} 로 설정하였다. 손실 함수는 label smoothing($\alpha=0.1$)을 적용한 교차 엔트로피 손실을 사용하여 모델이 특정 클래스에 과도한 확신을 완화하였다. 학습률은 검증 손실(Validation loss)을 기준으로 조정되는 ReduceLROnPlateau 스케줄러를 사용하였으며, factor는 0.5, patience는 2로 설정하였다. 또한, 검증 손실이 10 epoch 동안 개선되지 않을 경우 학습을 조기 종료하도록 설정하였다.

학습은 배치 크기 32, 최대 100 epoch으로 수행하였다. 모든 실험은 난수 시드를 고정하여 재현성을 확보하였으며, 각 fold에서 검증 손실이 최소화되는 시점의 가중치를 기준으로 모델을 선택하였다.

3.5 평가 지표

본 연구에서는 모델의 분류 성능을 다각도로 평가하기 위하여 여러 지표를 사용하였다. 기본적으로는 정확도를 측정하였으며, 클래스 불균형의 영향을 고려하기 위해 정밀도, 재현율, F1-score를 함께 보고하였다. 이러한 지표는 fold별로 산출한 후, 10-fold 교차검증 결과를 평균하여 최종 성능으로 제시하였다. 또한, 모델의 분류 신뢰도를 보다 정밀하게 분석하기 위하여 ROC(Receiver Operating Characteristic) 곡선과 AUC(Area Under the Curve) 값을 산출하였다. ROC-AUC는 이진 분류 문제에서 모델의 판별 능력을 종합적으로 평가할 수 있는 지표로, 임계값에 관계없이 전반적인 분류 성능을 비교하는 데 적합하다. 더불어 Precision-Recall 곡선도 함께 제시하여, 불균형 데이터 상황에서의 모델 성능을 보완적으로 검토하였다.

추가적으로, 모델의 해석 가능성을 확보하기 위해 ROI attention pooling에서 산출된 ROI별 가중치(Attention weight)를 저장하고 분석하였다. 이를 통해 예측 과정에서 상대적으로 중요한 ROI를 식별하고, 알츠하이머병과 연관된 뇌 영역의 해부학적·임상적 의미를 논의하였다.

IV. 실험 결과

4.1 10-fold 교차검증 성능

본 연구에서 제안한 CNN-Transformer 모델에 대해 AD vs CN 10-fold 교차검증을 수행하였다. 평가 지표로는 Accuracy, Precision, Sensitivity(=Recall), F1-score, ROC-AUC를 사용하였으며, 표 2는 각 fold 결과의 평균±표준편차를 요약한 것이다. 전반적으로 모델은 교차검증 각 fold에서 안정적인 성능을 보였으며, 평균 ROC-AUC가 0.93(±0.02)로 높은 판별 능력을 확인할 수 있었다. 그림 4는 10-fold 교차검증의 평균 ROC 곡선을 제시하였다. 이를 통해

제안 모델의 전반적인 판별 성능을 확인할 수 있다.

본 연구의 성능을 선행 연구들과 비교하여 표 3에 정리하였다. 비교 대상은 동일하게 ADNI MRI 데이터를 활용하여 AD vs CN 이진 분류를 수행한 기존 연구들을 포함하였다.




그림 4. 10-fold 교차검증 ROC 곡선(평균 AUC = 0.931)
Fig. 4. ROC curves over 10-fold CV (mean AUC = 0.931)

4.2 선행 연구와의 비교

선행 연구로서, S. Liu et al.[50]은 83개 ROI의 희색질 용적을 입력으로 한 스택드 오토인코더(SAE) 기반 MRI 단일 모달리티 분류 실험에서 정확도 0.8259, 민감도 0.8683을 보고하였다. S. Korolev et al.[51]은 전뇌 3D VoxCNN으로 정확도 0.79, AUC 0.88을, K. Oh et al.[35]은 전이학습을 결합한 3D volumetric CNN으로 정확도 0.8660, AUC 0.9102를 각각 제시하였다. 최근에는 G. Lozupone et al.[52]이 3D MRI 볼륨에서 2D 슬라이스를 추출하여 2D CNN과 어텐션을 결합, 전뇌 수준의 주목 영역을 시각화하는 방법을 제안하였고, 정확도 0.856을 보고하였다. 이에 비해 본 연구에서 제안된 경량 CNN-Transformer은 AUC 0.9305로 가장 높은 판별력을 보였고, 정확도 0.8773을 달성하여 3D 볼륨 기반 방법뿐 아니라 최근 2D-어텐션 계열과 비교해도 경쟁력 있는 성능을 확인하였다.

표 2. 10-fold 교차검증 성능(평균 ± 표준편차)

Table 2. 10-fold cross-validation performance (mean ± STD)

Task	Accuracy	Precision	Sensitivity	F1-score	AUC
AD vs CN	0.877 ± 0.019	0.883 ± 0.036	0.829 ± 0.038	0.854 ± 0.022	0.931 ± 0.023

이러한 성능은 ROI 공유 백본, Transformer 기반 ROI 간 상호작용 학습, ROI attention pooling을 통한 전역 표현 학습의 효과로 해석된다. 연구 간 성능 지표의 정량적 비교는 표 3에 제시하였다. 다만 민감도는 상대적으로 낮아 재현을 개선의 여지가 있다. 아울러 연구별 데이터 분할, 전처리, 학습 설정이 상이하므로 직접적인 수치 비교에는 한계가 있음을 명시한다.

표 3. 선행 연구와의 성능 비교(AD vs CN, MRI 기반)
Table 3. Performance comparison with prior studies (AD vs CN, MRI-based)

Study	Accuracy	Sensitivity	AUC
S. Liu et al. [50]	0.8259	0.8683	Not reported
S. Korolev et al.[51]	0.79	Not reported	0.88
K. Oh et al. [35]	0.8660	0.8855	0.9102
G. Lozupone et al.[52]	0.856	0.792	Not reported
Proposed (Ours)	0.8773	0.8294	0.9305

4.3 ROI Attention 가중치 분석

그림 5와 표 4는 10-fold 교차검증에서 얻은 ROI별 attention 가중치를 요약한다. 가중치는 각 샘플에서 ROI 축으로 softmax로 정규화되어 합이 1이 되며, 값이 클수록 해당 ROI가 최종 예측에 더 크게 기여했음을 의미한다.

가장 높은 가중치를 보인 영역은 좌측 시상(Left thalamus)이었고, 그 다음은 우측 편도체(Right amygdala), 우측 꼬리핵(Right caudate), 좌측 해마(Left hippocampus), 우측 상측두회(Right superior temporal) 순이었다. 이 상위 5개 ROI가 전체 가중치의 약 62%를 차지하여 소수의 영역에 중요도가 집중되는 경향을 보였다. 반면 후대상피질(Posterior cingulate)은 0.013 ± 0.003 으로 가장 낮은 가중치를 보였다.

또한 상위 ROI들에서 뚜렷한 좌우 비대칭이 관찰되었다. 시상과 해마는 좌측 > 우측, 편도체는 우측 > 좌측 경향을 보였다. 이러한 패턴은 질병 진

행의 비대칭성 가능성을 시사할 수 있으나, 동시에 ROI 경계 정의, 슬라이스 선택(25/50/75%) 등 방법론적 요인의 영향도 배제할 수 없다. 따라서 비대칭 자체의 해석은 추가 검증이 필요하다.

마지막으로, attention 가중치는 모델이 어떤 ROI 정보를 더 많이 참조했는가를 반영할 뿐, 병리의 인과적 중요도를 직접 의미하지는 않는다. 그럼에도 상위에 위치한 시상·편도체·꼬리핵(기저핵/변연계), 해마(내측 측두계열), 상측두회(측두엽 피질)는 AD에서 구조적/기능적 변화가 빈번히 보고되는 영역으로, 본 모델의 주목 패턴이 임상적 지식과 정합 가능성을 보인다[21][53]-[57]. 향후 ROI 제거나 occlusion/Grad-CAM 기반 시각화 등 추가 검증을 통해 해석의 신뢰도를 높일 예정이다.




그림 5. ROI별 어텐션 가중치(10-fold 평균)
Fig. 5. ROI-wise attention weights (mean across 10 folds)

표 4. ROI 어텐션 가중치 상위 5개 영역(평균 ± 표준편차)

Table 4. Top-5 ROIs by attention weight (mean ± STD)

ROI	Attention weight (mean ± std)
Left thalamus	0.208 ± 0.032
Right amygdala	0.185 ± 0.022
Right caudate	0.080 ± 0.017
Left hippocampus	0.074 ± 0.016
Right superior temporal	0.070 ± 0.009

V. 결론 및 향후 과제

본 연구는 MRI 단일 모달리티만으로 AD vs CN 이진 분류를 수행하는 경량 CNN-Transformer 모델을 제안하였다. 19개 ROI를 대상으로 9장의 슬라이스를 채널 축으로 스택한 뒤, CNN 인코더로 각 ROI의 국소 특징을 64차원 임베딩으로 추출하고, 2개의 Transformer 인코더 층을 통해 ROI 간 전역 상호작용을 학습하였다. 이어서 ROI에 대한 ROI attention pooling으로 전역 표현을 구성하고, MLP 분류기를 통해 최종 예측을 산출하였다. 10-fold 교차검증 결과, 본 모델은 Accuracy 0.88 ± 0.02 , AUC 0.93 ± 0.02 의 안정적인 판별 성능을 보였다. 효율 측면에서, 제안 모델은 3.05M parameters (≈ 12.2 MB, FP32)의 경량 구성이며, ROI 공유 백본(shared-weight CNN) 설계를 통해 파라미터 규모를 최소화하였다. ROI별 가중치 해석에서는 시상, 편도체, 꼬리핵, 해마, 상측두회 등 AD 관련 영역이 상대적으로 높은 중요도를 갖는 경향을 나타냈다. 이는 2D 기반의 연산 효율성을 유지하면서도 ROI 단위의 해석 가능성을 확보할 수 있음을 시사한다.

그럼에도 몇 가지 한계가 남는다. 첫째, AAL 기반의 고정 ROI 집합과 25/50/75% 슬라이스 전략에 의존하여 해부학적 다양성과 병변 위치 변이를 충분히 포착하지 못했을 수 있다. 둘째, 외부 코호트 검증이 부재하여 스캐너·사이트 차이에 대한 일반화 성능이 확인되지 않았다. 셋째, 이진 분류에 한정되어 MCI 관련 과제로의 확장 가능성이 아직 검증되지 않았다.

향후 연구에서는 외부 코호트를 활용한 일반화 검증을 수행하고, 스캐너·사이트 간 편차를 줄이기 위한 도메인 보정을 병행한다. 입력 표현은 2D의 효율성을 유지하되 3D 정보를 보완하는 방향으로 확장하고, 모델은 임상 운영 환경에 맞춘 민감도·특이도 균형과 예측 신뢰도 향상에 초점을 둔다. 해석 가능성은 occlusion map과 Grad-CAM 등 설명 기반 기법으로 보강한다. 또한 MCI 피험자 데이터를 추가하여 AD/CN/MCI 3-클래스 및 pMCI(progressive MCI)/sMCI(stable MCI) 이진 과제를 모두 구성하되, 데이터 누수 방지를 위해 피험자 단위로 분석하고

사용 시점은 첫 방문(Baseline)으로 고정, 추적 정보는 레이블링에만 활용한다. 이 확장은 pMCI 고위험군의 조기 식별을 통해 초기 선별과 예방적 개입(예: 추적 간격 조정, 생활 중재·인지 훈련, 약물 평가) 의사결정을 직접 지원한다. 아울러 EHR·SNP 등 추가 정보와의 경량 멀티모달 결합을 모색하고, 모델 경량화를 통해 실제 배포·적용 가능성을 높이는 방향으로 발전시킬 계획이다.

References

- [1] Z. S. Khachaturian, "Diagnosis of Alzheimer's Disease", Arch Neurol, Vol. 2, No. 11, pp. 1097-1105, Nov. 1985. <https://doi.org/10.1001/archneur.1985.04060100083029>.
- [2] Alzheimer's Disease International, "World Alzheimer Report 2024: Global Changes in Attitudes to Dementia", Alzheimer's Disease International, London, Sep. 2024.
- [3] B. Dubois, et al., "Preclinical Alzheimer's disease: Definition, natural history, and diagnostic criteria", Alzheimer's & Dementia, Vol. 12, No. 3, pp. 292-323, Mar. 2016. <https://doi.org/10.1016/j.jalz.2016.02.002>.
- [4] S. Gauthier, et al., "Mild cognitive impairment", The Lancet, Vol. 367, No. 9518, pp. 1262-1270, Apr. 2006. [https://doi.org/10.1016/S0140-6736\(06\)68542-5](https://doi.org/10.1016/S0140-6736(06)68542-5).
- [5] S. G. Mueller, et al., "Ways toward an early diagnosis in Alzheimer's disease: The Alzheimer's Disease Neuroimaging Initiative (ADNI)", Alzheimer's & Dementia, Vol. 1, No. 1, pp. 55-66, Jul. 2005. <https://doi.org/10.1016/j.jalz.2005.06.003>.
- [6] C. R. Jack, et al., "The Alzheimer's disease neuroimaging initiative (ADNI): MRI methods", Journal of Magnetic Resonance Imaging, Vol. 27, No. 4, pp. 685-691, Apr. 2008. <https://doi.org/10.1002/jmri.21049>.
- [7] A. Payan and G. Montana, "Predicting Alzheimer's disease: a neuroimaging study with 3D

- convolutional neural networks", arXiv preprint arXiv:1502.02506, Feb. 2015. <https://doi.org/10.48550/arXiv.1502.02506>.
- [8] J. Ha and K. Kim, "Neighborhood-Regularized Matrix Factorization for lncRNA-Disease Association Identification", *International Journal of Molecular Sciences*, Vol. 26, No. 9, pp. 4283, Jan. 2025. <https://doi.org/10.3390/ijms26094283>.
- [9] K. Kim and J. Ha, "GMFLDA: improved prediction of lncRNA-disease association via graph convolutional network", *IEEE Access*, Vol. 13, pp. 85330-85341, May 2025. <https://doi.org/10.1109/ACCESS.2025.3568461>.
- [10] J. Ha, "DeepWalk-based graph embeddings for miRNA-disease association prediction using deep neural network", *Biomedicines*, Vol. 13, No. 3, pp. 536, Feb. 2025. <https://doi.org/10.3390/biomedicines13030536>.
- [11] J. Ha, "Graph Convolutional Network with Neural Collaborative Filtering for Predicting miRNA-Disease Association", *Biomedicines*, Vol. 13, No. 1, pp. 136, Jan. 2025. <https://doi.org/10.3390/biomedicines13010136>.
- [12] J. Ha, "MDMF: Predicting miRNA-Disease Association Based on Matrix Factorization with Disease Similarity Constraint", *Journal of Personalized Medicine*, Vol. 12, No. 6, pp. 885, Jun. 2022. <https://doi.org/10.3390/jpm12060885>.
- [13] J. Ha and S. Park, "NCMD: Node2vec-Based Neural Collaborative Filtering for Predicting MiRNA-Disease Association", *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, Vol. 20, No. 2, pp. 1257-1268, Mar. 2023. <https://doi.org/10.1109/TCBB.2022.3191972>.
- [14] J. Ha, "SMAP: Similarity-based matrix factorization framework for inferring miRNA-disease association", *Knowledge-Based Systems*, Vol. 263, pp. 110295, Mar. 2023. <https://doi.org/10.1016/j.knosys.2023.110295>.
- [15] J. Ha, "LncRNA Expression Profile-Based Matrix Factorization for Predicting lncRNA-Disease Association", *IEEE Access*, Vol. 12, pp. 70297-70304, May 2024. <https://doi.org/10.1109/ACCESS.2024.3401005>.
- [16] B. Kim, S. Kim, and J. Ha, "An Ensemble Machine Learning Framework for Identifying lncRNA-Disease Association", *The Journal of Korean Institute of Information Technology*, Vol. 23, No. 6, pp. 41-53, Jun. 2025. <https://doi.org/10.14801/jkiit.2025.23.6.41>.
- [17] S. Kim and J. Ha, "Development of lncRNA-Disease Associations Prediction Model using CNN-RNN Feature Extraction based on lncRNA Sequence Data", *The Journal of Korean Institute of Information Technology*, Vol. 22, No. 10, pp. 1-11, Oct. 2024. <https://doi.org/10.14801/jkiit.2024.22.10.1>.
- [18] J.-H. Ha, "Autoencoder-based Disease-related miRNA Prediction Research using Deep Learning", *The Journal of Korean Institute of Information Technology*, Vol. 20, No. 6, pp. 33-40, Jun. 2022. <https://doi.org/10.14801/jkiit.2022.20.6.33>.
- [19] S. Vieira, W. H. L. Pinaya, and A. Mechelli, "Using deep learning to investigate the neuroimaging correlates of psychiatric and neurological disorders: Methods and applications", *Neuroscience & Biobehavioral Reviews*, Vol. 74, pp. 58-75, Mar. 2017. <https://doi.org/10.1016/j.neubiorev.2017.01.002>.
- [20] V. Viswan, N. Shaffi, M. Mahmud, K. Subramanian, and F. Hajamohideen, "Explainable Artificial Intelligence in Alzheimer's Disease Classification: A Systematic Review", *Cogn Comput*, Vol. 16, No. 1, pp. 1-44, Jan. 2024. <https://doi.org/10.1007/s12559-023-10192-x>.
- [21] G. B. Frisoni, et al., "The clinical use of structural MRI in Alzheimer disease", *Nature Reviews Neurology*, Vol. 6, No. 2, pp. 67-77, Feb. 2010. <https://doi.org/10.1038/nrneurol.2009.215>.

- [22] S. Klöppel, et al., "Automatic classification of MR scans in Alzheimer's disease", *Brain*, Vol. 131, No. 3, pp. 681-689, Mar. 2008. <https://doi.org/10.1093/brain/awm319>.
- [23] E. Moradi, A. Pepe, C. Gaser, H. Huttunen, and J. Tohka, "Machine learning framework for early MRI-based Alzheimer's conversion prediction in MCI subjects", *NeuroImage*, Vol. 104, pp. 398-412, Jan. 2015. <https://doi.org/10.1016/j.neuroimage.2014.10.002>.
- [24] E. Pellegrini, et al., "Machine learning of neuroimaging for assisted diagnosis of cognitive impairment and dementia: A systematic review", *Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring*, Vol. 10, pp. 519-535, Jan. 2018. <https://doi.org/10.1016/j.dadm.2018.07.004>.
- [25] M. Liu, D. Zhang, and D. Shen, "Ensemble sparse classification of Alzheimer's disease", *NeuroImage*, Vol. 60, No. 2, pp. 1106-1116, Apr. 2012. <https://doi.org/10.1016/j.neuroimage.2012.01.055>.
- [26] C. Plant, et al., "Automated detection of brain atrophy patterns based on MRI for the prediction of Alzheimer's disease", *NeuroImage*, Vol. 50, No. 1, pp. 162-174, Mar. 2010. <https://doi.org/10.1016/j.neuroimage.2009.11.046>.
- [27] A. Ebrahimi, S. Luo, and R. Chiong, "Deep sequence modelling for Alzheimer's disease detection using MRI", *Computers in Biology and Medicine*, Vol. 134, pp. 104537, Jul. 2021. <https://doi.org/10.1016/j.compbiomed.2021.104537>.
- [28] J. Venugopalan, et al., "Multimodal deep learning models for early detection of Alzheimer's disease stage", *Scientific Reports*, Vol. 11, No. 1, pp. 3254, Feb. 2021. <https://doi.org/10.1038/s41598-020-74399-w>.
- [29] H.-I. Suk, S.-W. Lee, and D. Shen, "Hierarchical feature representation and multimodal fusion with deep learning for AD/MCI diagnosis", *NeuroImage*, Vol. 101, pp. 569-582, Nov. 2014. <https://doi.org/10.1016/j.neuroimage.2014.06.077>.
- [30] D. Zhang, Y. Wang, L. Zhou, H. Yuan, and D. Shen, "Multimodal classification of Alzheimer's disease and mild cognitive impairment", *NeuroImage*, Vol. 55, No. 3, pp. 856-867, Apr. 2011. <https://doi.org/10.1016/j.neuroimage.2011.01.008>.
- [31] S. Qiu, G. H. Chang, M. Panagia, D. M. Gopal, R. Au, and V. B. Kolachalama, "Fusion of deep learning models of MRI scans, Mini-Mental State Examination, and logical memory test enhances diagnosis of mild cognitive impairment", *Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring*, Vol. 10, pp. 737-749, Jan. 2018. <https://doi.org/10.1016/j.dadm.2018.08.013>.
- [32] W. Zhu, et al., "Dual attention multi-instance deep learning for Alzheimer's disease diagnosis with structural MRI", *IEEE Transactions on Medical Imaging*, Vol. 40, No. 9, pp. 2354-2366, Sep. 2021. <https://doi.org/10.1109/TMI.2021.3077079>.
- [33] C. Yang, A. Rangarajan, and S. Ranka, "Visual Explanations From Deep 3D Convolutional Neural Networks for Alzheimer's Disease Classification", *AMIA Annu Symp Proc*, Vol. 2018, pp. 1571-1580, Dec. 2018.
- [34] J. Rieke, et al., "Visualizing convolutional networks for MRI-based diagnosis of Alzheimer's disease", *Proc. International Workshop on Machine Learning in Clinical Neuroimaging (MLCN)*, Springer, Granada, Spain, pp. 24-31, Sep. 2018. https://doi.org/10.1007/978-3-030-02628-8_3.
- [35] K. Oh et al., "Classification and visualization of Alzheimer's disease using volumetric convolutional neural network and transfer learning", *Scientific Reports*, Vol. 9, No. 1, pp. 18150, Oct. 2019. <https://doi.org/10.1038/s41598-019-54548-6>.
- [36] S. Katabathula, Q. Wang, and R. Xu, "Predict Alzheimer's disease using hippocampus MRI data: A lightweight 3D deep convolutional network model with visual and global shape representations", *Alzheimer's Research & Therapy*, Vol. 13, No. 1, pp. 104, May 2021.

- <https://doi.org/10.1186/s13195-021-00837-0>.
- [37] N. J. Tustison, et al., "N4ITK: Improved N3 Bias Correction", *IEEE Transactions on Medical Imaging*, Vol. 29, No. 6, pp. 1310-1320, Jun. 2010. <https://doi.org/10.1109/TMI.2010.2046908>.
- [38] S. M. Smith, "Fast robust automated brain extraction", *Human Brain Mapping*, Vol. 17, No. 3, pp. 143-155, Nov. 2002. <https://doi.org/10.1002/hbm.10062>.
- [39] M. Jenkinson and S. Smith, "A global optimisation method for robust affine registration of brain images", *Medical Image Analysis*, Vol. 5, No. 2, pp. 143-156, Jun. 2001. [https://doi.org/10.1016/S1361-8415\(01\)00036-6](https://doi.org/10.1016/S1361-8415(01)00036-6).
- [40] B. B. Avants, C. L. Epstein, M. Grossman, and J. C. Gee, "Symmetric diffeomorphic image registration with cross-correlation: Evaluating automated labeling of elderly and neurodegenerative brain", *Medical Image Analysis*, Vol. 12, No. 1, pp. 26-41, Feb. 2008. <https://doi.org/10.1016/j.media.2007.06.004>.
- [41] B. B. Avants, N. J. Tustison, G. Song, P. A. Cook, A. Klein, and J. C. Gee, "A reproducible evaluation of ANTs similarity metric performance in brain image registration", *NeuroImage*, Vol. 54, No. 3, pp. 2033-2044, Feb. 2011. <https://doi.org/10.1016/j.neuroimage.2010.09.025>.
- [42] V. Fonov, A. C. Evans, K. Botteron, C. R. Almli, R. C. McKinsty, and D. L. Collins, "Unbiased average age-appropriate atlases for pediatric studies", *NeuroImage*, Vol. 54, No. 1, pp. 313-327, Jan. 2011. <https://doi.org/10.1016/j.neuroimage.2010.07.033>.
- [43] F. Isensee, et al., "nnU-Net: A self-configuring method for deep learning-based biomedical image segmentation", *Nature Methods*, Vol. 18, No. 2, pp. 203-211, Dec. 2021. <https://doi.org/10.1038/s41592-020-01008-z>.
- [44] N. Tzourio-Mazoyer, et al., "Automated Anatomical Labeling of Activations in SPM Using a Macroscopic Anatomical Parcellation of the MNI MRI Single-Subject Brain", *NeuroImage*, Vol. 15, No. 1, pp. 273-289, Jan. 2002. <https://doi.org/10.1006/nimg.2001.0978>.
- [45] J. B. Bae, et al., "Identification of Alzheimer's disease using a convolutional neural network model based on T1-weighted magnetic resonance imaging", *Scientific Reports*, Vol. 10, No. 1, pp. 22252, Dec. 2020. <https://doi.org/10.1038/s41598-020-79243-9>.
- [46] D. Pan, et al., "Early detection of Alzheimer's disease using magnetic resonance imaging: A novel approach combining convolutional neural networks and ensemble learning", *Frontiers in Neuroscience*, Vol. 14, pp. 259, May 2020. <https://doi.org/10.3389/fnins.2020.00259>.
- [47] W. Kang, L. Lin, B. Zhang, X. Shen, and S. Wu, "Multi-model and multi-slice ensemble learning architecture based on 2D convolutional neural networks for Alzheimer's disease diagnosis", *Computers in Biology and Medicine*, Vol. 136, pp. 104678, Sep. 2021. <https://doi.org/10.1016/j.combiomed.2021.104678>.
- [48] J. S. Kim, et al., "Deep learning-based diagnosis of Alzheimer's disease using brain magnetic resonance images: An empirical study", *Scientific Reports*, Vol. 12, No. 1, pp. 18007, Oct. 2022. <https://doi.org/10.1038/s41598-022-22917-3>.
- [49] T. Chattopadhyay, et al., "Comparison of deep learning architectures for predicting amyloid positivity in Alzheimer's disease, mild cognitive impairment, and healthy aging, from T1-weighted brain structural MRI", *Front. Neurosci.*, Vol. 18, Jul. 2024. <https://doi.org/10.3389/fnins.2024.1387196>.
- [50] S. Liu, et al., "Multimodal neuroimaging feature learning for multiclass diagnosis of Alzheimer's disease", *IEEE Transactions on Biomedical Engineering*, Vol. 62, No. 4, pp. 1132-1400, Apr. 2014. <https://doi.org/10.1109/TBME.2014.2372011>.
- [51] S. Korolev, A. Safiullin, A. Belyaev, and Y.

Chernigin, "Residual and plain convolutional neural networks for 3D brain MRI classification", Proc. 2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI), Melbourne, VIC, Australia, pp. 835-838, Apr. 2017. <https://doi.org/10.1109/ISBI.2017.7950647>.

- [52] G. Lozupone, A. Bria, F. Fontanella, F. J. A. Meijer, and C. D. Stefano, "AXIAL: Attention-based eXplainability for Interpretable Alzheimer's Localized Diagnosis using 2D CNNs on 3D MRI brain scans", arXiv preprint arXiv:2407.02418, Jul. 2024. <https://doi.org/10.48550/arXiv.2407.02418>.
- [53] B. C. Dickerson, et al., "The cortical signature of Alzheimer's disease: Regionally specific cortical thinning relates to symptom severity in very mild to mild AD dementia and is detectable in asymptomatic amyloid-positive individuals", Cerebral Cortex, Vol. 19, No. 3, pp. 497-510, Mar. 2009. <https://doi.org/10.1093/cercor/bhn113>.
- [54] S. K. Madsen, et al., "3D maps localize caudate nucleus atrophy in 400 Alzheimer's disease, mild cognitive impairment, and healthy elderly subjects", Neurobiology of Aging, Vol. 31, No. 8, pp. 1312-1325, Aug. 2010. <https://doi.org/10.1016/j.neurobiolaging.2010.05.002>.
- [55] Y. Xiao, et al., "Progressive structural and covariance connectivity abnormalities in patients with Alzheimer's disease", Frontiers in Aging Neuroscience, Vol. 14, pp. 1064667, Jan. 2023. <https://doi.org/10.3389/fnagi.2022.1064667>.
- [56] K. M. Stouffer, et al., "Amidst an amygdala renaissance in Alzheimer's disease", Brain, Vol. 147, No. 3, pp. 816-29, Mar. 2024. <https://doi.org/10.1093/brain/awad411>
- [57] S. N. Shah, et al., "Dementia risk and thalamic nuclei volumetry in healthy midlife adults: The PREVENT Dementia study", Brain Communications, Vol. 6, No. 2, pp. fcae046, Feb. 2024. <https://doi.org/10.1093/braincomms/fcae046>.

저자소개

윤 태 현 (Taehyeon Yun)



2025년 2월 : 국립부경대학교
해양바이오신소재학과(이학사)
2025년 2월 : 국립부경대학교
빅데이터융합전공(공학사)
2025년 3월 ~ 현재 : 국립부경대학교
데이터공학과 석사과정
관심분야 : 기계학습, 생물정보학,
데이터마이닝, 딥러닝, 의료인공지능

김 상 욱 (Sanguk Kim)




2024년 8월 : 부경대학교
냉동공조공학과(공학사)
2024년 8월 : 부경대학교
빅데이터융합전공(공학사)
2024년 9월 ~ 현재 : 부경대학교
데이터공학과 석사과정
관심분야 : 기계학습, 생물정보학,
데이터마이닝, 딥러닝, 추천시스템

류 지 열 (Jee-Youl Ryu)



1993년 2월 : 부경대학교
전자공학과(공학사)
1997년 2월 : 부경대학교
전자공학과(공학석사)
2004년 12월 : 애리조나
주립대학교 전기공학과(공학박사)
2009년 3월 ~ 현재 : 부경대학교
정보통신공학과 교수
관심분야 : 시스템-온-칩 설계, 고주파 회로 설계,
임베디드 시스템 설계

하 지 환 (Jihwan Ha)



2015년 8월 : 연세대학교

컴퓨터과학과(공학석사)

2020년 8월 : 연세대학교

컴퓨터과학과(공학박사)

2020년 9월 ~ 2021년 8월 :

하와이 암센터 포스닥 연구원

2021년 9월 ~ 2025년 8월 :

부경대학교 데이터정보과학부 빅데이터융합전공
조교수

2025년 9월 ~ 현재 : 부경대학교 데이터정보과학부
빅데이터융합전공 부교수

관심분야 : 기계학습, 생물정보학, 데이터마이닝, 딥러닝,
추천시스템