

3D CNN 모델을 활용한 뇌 MRI 기반 산소추출률 예측 방법

김원태*, 이해연**

Oxygen Extraction Fraction Prediction Method on Brain MRI using 3D CNN Model

Won-Tae Kim*, Hae-Yeoun Lee**

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. RS-2023-00242116)

요 약

뇌 질환은 주요한 건강 문제로 자기공명영상을 진단에 활용해 뇌 조직에서 혈액의 산소추출률을 계산하여 뇌의 활성화 수준을 분석할 수 있다. 본 논문에서는 QQ 모델을 기반으로 3D CNN 모델을 활용하여 산소추출률을 예측하는 방법을 제안한다. 이 모델은 1개 입력 계층과 LeakyReLU 활성화와 BatchNormalization을 포함한 5개 Conv3D 은닉 계층, 1개 Conv3D 출력 계층으로 구성된다. 은닉 계층 중 4개 Conv3D 계층 뒤에는 과적합 방지를 위해 Dropout을 포함한다. 전체 모델 구조는 4차원 데이터의 안정적 학습과 성능 최적화를 통해 설계되었다. 제안한 방법의 실험에서는 자기공명영상 신호 감쇄 및 자화율 데이터를 이용하여 모델을 훈련 및 검증하였고, 테스트 결과 평균 RMSE 값이 5.19로 산소추출률을 안정적으로 예측하는 것을 확인하였다.

Abstract

Brain diseases are major health issues, and magnetic resonance imaging can be applied to diagnose by calculating the OEF of blood in brain tissue, which helps access brain activation levels. This paper proposes a OEF prediction method using a 3D CNN model based on the QQ model. The model consists of 1 input layer, 5 Conv3D hidden layers with LeakyReLU activation and BatchNormalization, and 1 Conv3D output layer. To prevent overfitting, Dropout is added after 4 of the Conv3D hidden layers. The overall model architecture is designed for stable learning and performance optimization of 4 dimensional data. In the experiment, the proposed model was trained and validated using magnetic resonance imaging signal decay and susceptibility data. The test results showed that the model could reliably predict OEF, achieving an average RMSE value of 5.19.

Keywords

oxygen extraction fraction, brain MRI, QQ model, 3D CNN model

* 국립금오공과대학교 컴퓨터소프트웨어공학과
- ORCID: <https://orcid.org/0009-0002-1568-3820>

** 국립금오공과대학교 컴퓨터소프트웨어공학과 교수(교신저자)
- ORCID: <http://orcid.org/0000-0002-6081-1492>

· Received: Mar. 25, 2025, Revised: Apr. 24, 2025, Accepted: Apr. 27, 2025

· Corresponding Author: Hae-Yeoun Lee

Dept. of Computer Software Engineering, Kumoh National Institute of Technology, Korea

Tel.: +82-54-458-7548, Email: haeyeoun.lee@kumoh.ac.kr

I. 서 론

전 세계적으로 뇌 질환은 주요한 문제로, 국내에서 암, 심장 질환 및 폐렴 다음으로 흔한 사망의 원인이다[1][2]. 뇌 조직의 활성화 상태에 대해서 올바르게 분석하는 것은 뇌 질환을 진단하고 치료하는 과정에서 중요하며, 특히 조기 진단과 효과적인 관리를 통해 환자의 생존 가능성을 높이고 후유증을 줄여서 전반적인 삶의 질을 향상할 수 있다.

뇌 조직 내의 혈액에서 산소추출률(OEF, Oxygen Extraction Fraction)은 뇌의 질환을 진단하는 중요한 지표로서 대사 상태와 활성화 정도를 파악할 수 있는 정보를 제공한다. 기존에 OEF 예측을 위해 연구들이 수행되었고, Quantitative imaging of extraction of oxygen and tissue consumption 방법[3], Calibrated fMRI 방법[4], qBOLD(quantitative Blood Oxygenation Level Dependent) 방법[5], 그리고 qBOLD 방법과 QSM(Quantitative Susceptibility Mapping) 방법을 결합한 QQ 모델[6][7] 등이 있다. 특히, 특정 가정을 두지 않고 OEF를 추정할 수 있는 QQ 모델을 기반으로 클러스터 분석 혹은 2D 딥러닝 기술을 적용하는 연구가 많이 진행되고 있다[8]-[11].

본 논문에서는 뇌의 자기공명영상(MRI, Magnetic Resonance Imaging)을 기반으로 OEF 예측의 정확도와 안정성을 높이기 위한 효과적 예측 방법을 제안한다. 제안하는 방법에서는 QQ 모델을 기반으로 1개 입력 계층과 5개 3D 컨볼루션 은닉 계층, 1개 3D 컨볼루션 출력 계층으로 구성하여 3D CNN (3-Dimensional Convolutional Neural Network) 모델을 설계하였다. 특히, 컨볼루션 은닉 계층 뒤에는 LeakyReLU 활성화 함수와 배치 정규화, 그리고 드롭아웃을 적용하였다. 3차원 필터($5 \times 5 \times 5$, $4 \times 4 \times 4$, $3 \times 3 \times 3$)를 단계적으로 사용해 공간적·시간적 특징을 보다 풍부하게 학습하고, 마지막에는 $1 \times 1 \times 1$ 컨볼루션을 통해 최종 채널 수에 맞게 출력을 만든다. 이렇게 설계한 구조는 3차원 데이터 처리에 특화된 강점을 발휘하며, 학습 안정성을 높이고 과적합을 방지하기 위한 정규화를 적절히 활용한다. 제안한 모델은 총 17명 환자의 MRI 데이터로 학습 및 검증하였고, 성능을 극대화하기 위해 다양한 최적화 과정을 거쳐 OEF 예측 정확도를 향상하였다.

기존에 연구된 2D 기반 모델들과 달리, 본 연구에서는 원본 3D 데이터를 2D 형태로 전처리할 필요 없이 그대로 활용할 수 있도록 3D CNN 모델을 적용하였다. 이를 통해 3차원 컨볼루션 필터가 데이터의 깊이 축까지 함께 처리함으로써 패턴을 효과적으로 학습하였고, GPU 기반의 실험 환경을 구축하여 대규모 3D 연산을 수행함과 동시에, Leaky ReLU 활성화 함수를 활용하여 학습 안정성과 성능 향상을 동시에 추구하였다. 마지막으로, 최종 결과 산출 단계에서는 $1 \times 1 \times 1$ 컨볼루션 계층을 통해 출력 채널을 조정함으로써 예측 정확도를 높였다.

본 논문의 구성은 다음과 같다. 먼저, 관련 연구를 2장에 요약하고, 3장에서는 제안하는 3D CNN 모델을 활용해 OEF를 예측하는 방법을 설명한다. 실험 결과 및 분석 결과는 4장에서 제시하고, 5장에서 본 연구에서 얻은 결론을 정리한다.

II. 관련 연구

뇌가 전체 산소 소비량 중 약 20%를 차지하는 사실은 뇌와 산소가 얼마나 밀접한 관련성을 지니는지를 보여준다[12]. 뇌에서 산소 사용률은 혈류 및 OEF로 파악할 수 있고, 다양한 뇌 질환의 주요한 바이오마커로 활용된다. 특히, 진단에 활용되는 MRI 기술의 진보는 OEF 예측에 새로운 가능성을 제시하고 있다. 전통적으로 ^{15}O -PET(Oxygen-15 Positron Emission Tomography)의 경우 OEF 예측에 표준으로 알려졌지만, MRI 기반 OEF 예측 방법들은 비침습적이고 방사선 노출이 없으므로 보다 넓은 영역에서 활용될 수 있는 이점이 있다[13].

2.1 QQ 모델

정맥 내에서 디옥시헤모글로빈의 영향과 비혈액 조직 자화율을 분리하여 QSM 모델은 측정할 수 있고, mGRE(multi-echo GRAdient Echo) 시퀀스의 MRI 신호 세기를 활용해 qBOLD 모델은 OEF의 영향을 모델링한다. QSM 및 qBOLD 모델에서 독립적으로 요구되던 매개변수의 한계를 QQ 모델은 상호 보완하는 구조로 설계되어, 특정 조건을 전제하지 않고 더욱 폭넓은 상황에서 적용 가능한 것이 특징이다.

QQ 모델은 이론상 mGRE 시퀀스의 MRI 신호에서 크기 및 위상을 활용해 계산할 수 있지만, 실제 상황에서는 정맥 혈액량과 산소포화도 간의 상호관계, qBOLD 역변환의 잡음에 대한 민감도 등 여러 요인으로 인해 계산 과정이 복잡하다[7][8]. 이러한 문제를 완화하고자 CAT(Cluster Analysis of Time evolution) 기법[7]과 CCM(Cluster-based Classification and Matching) 기법[8] 등이 연구되었다.

2.2 CCM

CCM 기법은 클러스터링 이후 정합의 과정을 통해 QQ 모델이나 CAT 기법이 갖는 문제점을 개선하고, 더욱 안정적인 OEF 계산이 가능하다[8].

이 기법에서는 먼저 QQ 모델에 실제 값을 입력하여 계산된 출력값을 바탕으로 클러스터 기반 분류를 수행하여 클러스터 데이터베이스를 생성한다. 이후 미지의 샘플을 정합할 때는 에코 시간에서 측정된 MRI 신호값을 활용하여 입력값을 추정하는 과정을 거치며, 미지의 출력값을 토대로 데이터베이스에서 정합과 보간을 수행함으로써 입력값을 추론하고, 결과적으로 OEF를 계산한다.

그러나 클러스터 개수 의존성이나 잡음에 의한 영향으로 OEF 계산 정확도 향상에 어려움이 있다.

2.3 2D LSTM 기반 딥러닝 모델

MRI 기반 OEF 계산에 신경망 기술을 적용하는 연구가 활발히 이루어지고 있으며[9]-[11], 최근 QQ 모델을 바탕으로 딥러닝 모델들을 설계하여 OEF를 예측하려는 연구들이 활발히 진행되고 있다.

기본적인 DNN 모델보다는 최근에는 LSTM(Long Short-Term Memory) 네트워크를 비롯하여 시계열 특화 모델[14]을 QQ 모델과 결합하여 과거 신호 정보와 현재 입력 사이의 상관관계를 안정적으로 유지하며 OEF 예측 성능을 높이하고자 하는 방법이 연구되었다[15]. 이를 통해 기존의 클러스터 분석 기반 CAT, CCM 기법 및 DNN 기반 딥러닝 모델 대비 향상된 OEF 계산 성능을 보여주었다.

그러나 2D LSTM 모델의 경우도 공간적 연속성

을 온전히 보존하지 못하고, 깊이 축에 대한 정보 손실이 발생할 수 있다는 한계를 갖는다.

III. QQ 모델 기반의 3D CNN 모델을 활용한 OEF 예측 방법

본 절에서는 기존 CCM 기법이나 2D LSTM 모델이 갖는 정확도 성능 한계, 구조적 한계 등 문제를 해결하기 위하여 새로운 방법을 제안한다.

제안하는 방법은 3D CNN 모델을 수립하여 공간적, 구조적 특징을 보다 효과적으로 학습하여 할 수 있으며, 뇌 MRI 데이터에 직접적으로 적용해 빠르고 정확하게 OEF 계산을 수행한다.

3.1 3D CNN

3D CNN은 주로 3차원 데이터에 적용하기 위해 설계된 딥러닝 모델 아키텍처로서 그림 1과 같이 3차원 컨볼루션 필터(커널)를 사용하여 3차원 인접 데이터들 사이의 공간적·구조적 특징을 효과적으로 추출한다. 3D CNN은 2D CNN이 1개 축에서 가로·세로 인접한 데이터만 고려하는 것과 달리, 인접한 축(깊이 축)까지 함께 처리함으로써 슬라이스 간 연관성과 전체 입체 구조를 인식할 수 있는 이점이 있다. 이를 통해 인접 단면 간의 공간적 연속성과 지역적 패턴을 함께 학습할 수 있으며, 저수준 특징부터 고수준 특징까지 단계적으로 추출한다. 특히 3차원 합성곱과 풀링(Pooling) 과정을 반복함으로써, 볼륨 전체의 복잡한 형태학적 정보와 다차원적 상관관계를 효율적으로 파악하고 예측하는데 활용할 수 있다.




그림 1. 3D CNN 모델 구조
Fig. 1. 3D CNN model structure

3.2 딥러닝 모델의 입력 및 출력과 OEF

QQ 모델은 OEF 예측을 위하여 QSM 및 qBOLD를 다음 식 (1)과 같이 결합하였다[7]-[9].

$$QQ(Y, v, R_2, S_0, \chi_{nb}) = \underset{Y, v, R_2, S_0, \chi_{nb}}{\operatorname{argmin}} \left\{ \begin{aligned} & w \| F_{QSM}(Y, v, \chi_{nb}) - \chi \|_2^2 + \\ & \| S(t) - S_{qBOLD}(S_0, Y, v, R_2, \chi_{nb}, t) \|_2^2 + \\ & + \lambda (OEF(\bar{Y}) - OEF_{wb})^2 \end{aligned} \right\} \quad (1)$$

식 (1)에서 Y 는 정맥 산소포화도, v 는 정맥 혈액량, R_2 는 BOLD(Blood Oxygenation Level Dependent) 효과가 제외된 조직에서 가로 방향 이완이다. 또한 S_0 는 에코 타임(TE, Echo Time) 0에서 신호 강도, χ_{nb} 는 비혈류 물질 자화율(Non-blood susceptibility)이다. 추가적으로 w 는 QSM의 가중치, λ 는 정규화 가중치를 의미한다. F_{QSM} 모델 및 S_{qBOLD} 모델은 Lee와 Cho et al에서 제시된 것과 같다[7][8].

식 (2)와 같이 OEF는 정맥의 산소포화도(Y)를 이용해 계산할 수 있으며, 일반적으로 Y_a 는 0.98로 가정하는 동맥 산소화 값이다. 이 값은 동맥의 산소화 상태를 실험적으로 측정하여 얻는다[7].

$$OEF = 1 - Y/Y_a \quad (2)$$

본 연구에서는 미국 코넬 의과대학의 CAT 방법에 사용된 데이터셋을 제안하는 딥러닝 모델의 입력 및 출력 데이터로 사용하였다[7]. 이 데이터셋에는 QQ 모델에서 5개 입력 변수의 값과 출력에 대한 8개 에코 타임에서 측정한 MRI 신호값 및 자화율이 포함되어 있다[8].

제안하는 3D CNN 모델은 관심 영역(ROI, Region of Interest)의 데이터를 최대한 활용하고 안정적이고 빠른 학습을 위해 MRI 촬영으로 얻은 3차원 구조 데이터의 중심을 기준으로 크롭하여 활용하였다. 또한 이 모델은 QQ 모델에서 5개 입력 파라미터에 해당하는 정맥 산소포화도 및 정맥 혈액량, 조직에서의 가로 이완, TE 0에서 신호 강도, 비혈류 물질에서 자화율을 3차원 데이터 출력으로 구성하였다.

3.3 3D CNN 모델의 구조 설계

제안하는 3D CNN 기반 딥러닝 모델의 전반적인 구조를 그림 2에 도시하였다.




그림 2. OEF 예측을 위한 3D CNN 모델 구조
Fig. 2. Structure of 3D CNN model to predict OEF

제안하는 모델은 1개 입력 계층, 5개 Conv3D 은닉 계층, 1개 Conv3D 출력 계층으로 구성되었다.

각 TE에서 측정한 8개 MRI 신호값과 1개 자화율을 포함한 총 9개 입력에 대한 데이터를 사용하는 입력 계층으로 시작한다.

일반적인 2D CNN은 가로·세로 방향의 특징만 추출하지만, 3D CNN은 깊이까지 고려하여 합성곱을 수행하기 때문에 3차원(볼륨) 또는 시·공간 데이터를 다루는 데 적합하여 학습 과정에서의 계산에 대한 부담을 줄이면서 모델의 성능을 향상할 수 있다. Conv3D 레이어는 배치, 깊이, 높이, 너비, 채널의 5차원 입력을 받는데, 보통은 여기서 깊이, 높이, 너비에 해당하는 3차원 데이터를 다룬다. 본 연구에서의 4차원 입력 데이터(공간 3차원 + 시간 차원)를 사용하기 위해 커널은 공간 3차원으로 사용하고 TE에 대한 시간 차원은 채널 부분으로 독립적으로 처리함으로써 차원이 4개인 해당 데이터를 3D CNN 모델에 활용이 가능하다. 이를 통해 3D Conv 구조에 쉽게 맞춰 모델 구현 및 코드 구성을 단순화하고 연산량 및 메모리 절약 이점을 얻는다.

또한 시점별 가중치 결합을 통해 채널 차원에서 필터가 여러 시점을 동시에 받을 수 있게 한다.

제안하는 모델의 은닉 계층은 총 5개 블록으로 구성되었고, 필터 수를 점차 변화시키면서 다수의 Conv3D 계층을 쌓는 방식으로 설계되었다. 이와 같은 네트워크 구조는 복잡성을 점진적으로 제어하면서도 필요한 정보의 효과적인 전달이 가능하게 한다. 또한, 마지막 블록을 제외한 각각의 블록들은 Conv3D, LeakyReLU, BatchNormalization, Dropout 순서로 구성되고 다음 블록으로 진행될 때마다 필터 수는 증가하고 커널의 크기는 감소하는 형태이다. 여기서, LeakyReLU는 음수 입력에 대해서도 일정한 기울기를 갖도록 하며, BatchNormalization은 정규화 기법으로 신경망의 학습 속도를 향상시키고 학습을 안정시키기 위해 사용하였다. 또한 신경망의 학습 과정에서 일부 뉴런들을 확률적으로 비활성화하여 과적합을 방지하고 일반화 성능을 향상시키기 위하여, Dropout 정규화 기법을 적용하였고, 이를 통하여 과적합을 방지한다.

최종적으로 커널 크기가 1인 출력 계층을 통해 모델의 최종 출력을 결정한다.

해당 구조를 통해 3D CNN 모델은 MRI 데이터를 기반으로 QQ 모델의 입력 변수들을 효율적으로 예측함으로써 OEF 계산을 정확하게 수행할 수 있도록 설계되었다.

IV. 실험 결과 및 분석

제안한 방법은 Intel i9-11900, nVidia RTX 3090, 64GB RAM 하드웨어와 Windows 10 Pro 운영체제 환경에서 TensorFlow로 구현하였다.

4.1 학습 정확도

미국 코넬 의과대학의 데이터셋을 활용해 제안하는 3D CNN 모델을 학습하였다. 이 데이터셋은 17명 환자에게서 수집된 3차원 뇌 MRI 신호값과 자화율 데이터를 포함하며, QQ 모델에 대응하는 정맥 산소포화도, 정맥 혈액량, 조직에서 가로 이완, TE 0에서 신호 강도, 비혈류 물질 자화율에 대한

Ground Truth 값도 함께 제공한다[7][8].

총 17명 환자 데이터 중 13명 데이터를 학습에 사용하고 4명 데이터를 테스트에 활용하였다. 2D LSTM 기반 딥러닝 모델[15]과 성능을 객관적으로 비교하기 위하여 학습과 테스트 데이터의 분할 기준을 동일하게 유지하였으며, 해당 데이터 분할 과정에서 선정된 환자는 무작위로 결정하였다.

먼저 3차원 구조의 데이터에서 중앙 부위를 중심으로 일정 크기를 크롭(Crop)하여 모델에 입력될 데이터 크기를 통일하고, 불필요한 영역을 제외한다. 이는 뇌 영역만 유효 데이터로 사용해 ROI에 집중할 수 있도록 처리하여 모델이 학습하는 과정에서 하드웨어 한계를 극복하고 학습 속도 및 정확도를 향상하기 위함이다. 이렇게 크롭된 데이터를 학습 및 평가에 적합하게 분할하여 사용하였다. 표 1에는 전체 및 ROI 인덱스의 크롭 전후 변화가 나타나 있다. 원본 데이터를 그대로 사용하였다면 필요한 데이터인 22,893,241개 ROI 인덱스를 활용하기 위해 218,628,096개의 데이터 인덱스 모두를 사용해야 했지만, 크롭을 통해서 ROI 인덱스는 21,529,398개로 최대한 유지하고 전체 인덱스를 70,070,000개로 줄일 수 있었다. 결과적으로 전체 데이터 크기는 67.96% 줄어들었지만 ROI는 5.96%만 줄어서 학습 속도 및 성능을 크게 향상시켰다.

표 1. 크롭 후 관심영역 데이터 인덱스 수

Table 1. Number of ROI data indexes after cropping

	Original data Index	Crop data Index	Original ROI index	Crop ROI index
P4	18,350,080	5,390,000	2,183,535	1,986,130
P6	18,350,080	5,390,000	1,832,351	1,616,669
P11	18,350,080	5,390,000	1,756,037	1,637,179
P13	12,058,624	5,390,000	1,445,815	1,445,815
P14	12,058,624	5,390,000	1,397,273	1,397,273
P15	17,301,504	5,390,000	1,854,907	1,751,592
P16	15,728,640	5,390,000	1,625,143	1,568,897
P17	18,350,080	5,390,000	1,792,448	1,656,776
P26	17,825,792	5,390,000	1,643,140	1,534,186
P28	18,350,080	5,390,000	1,860,538	1,745,085
P29	17,301,504	5,390,000	1,896,303	1,773,194
P31	17,301,504	5,390,000	1,721,313	1,669,085
P34	17,301,504	5,390,000	1,884,438	1,747,517
SUM	218,628,096	70,070,000	22,893,241	21,529,398

모델 학습 단계에서 학습률은 $1e-4$ 로 설정하였고, 손실 함수로 MSE를 적용했으며 최적화 알고리즘으로는 Adam을 사용하였다. 또한 모델의 성능을 평가하기 위해 평균 제곱근 오차(RMSE, Root Mean Square Error)를 지표로 삼았다. 이와 같은 설정은 제안한 모델이 효율적으로 데이터를 학습하고, 예측 정확도를 향상하는데 핵심적인 역할을 한다.

3D CNN 모델의 학습 과정은 1개의 배치 크기를 가지고 13개의 학습 데이터를 전부 학습하였다. 각각의 데이터 학습 후, 현재 학습에서 기록된 최소 loss와 지금까지 학습했던 데이터의 최고 성능을 비교하여 더 나은 성능이면 해당 가중치를 최종 저장하는 방식으로 진행하였다.

그림 3과 표 2에는 각 학습 데이터에 따른 OEF 예측에서의 RMSE 및 손실률을 제시하였다.




그림 3. 각 환자 데이터에 따른 학습 MSE
Fig. 3. Learning MSE based on each patient data

표 2. 각 학습 데이터에 따른 예측 RMSE와 손실률 추세
Table 2. Predicted RMSE and loss rate trends for each training data

Data	Loss	RMSE	Data	Loss	RMSE
1	0.2464	0.4963	8	0.0922	0.3036
2	0.0886	0.2976	9	0.1067	0.3266
3	0.0865	0.2941	10	0.0654	0.2557
4	0.1000	0.3162	11	0.0967	0.3109
5	0.0832	0.2884	12	0.0984	0.3136
6	0.0789	0.2808	13	0.1039	0.3223
7	0.0793	0.2816			

그림과 표를 통하여 RMSE 및 손실률이 점진적으로 수렴하는 방향성을 확인할 수 있다. 10번째 학

습 데이터에서 손실률이 0.0654로 최저치를 기록했고, RMSE 또한 0.2557로 높은 정확도를 나타냈다. 이는 기존의 2D LSTM 기반 모델에 비해 RMSE가 0.0098 낮은 결과이다[15]. 수렴 이후에는 다른 학습 데이터 간의 RMSE와 손실률 차이가 미미하였다. 이러한 현상은 학습 과정에서 데이터 변화에 따른 미세한 차이를 반영하는 것으로 생각된다.

4.2 평가 정확도

본 논문에서 제안한 3D CNN 모델의 성능 평가는 학습 및 검증에 사용되지 않은 4명 환자 데이터를 대상으로 진행하였다. 본 평가에서는 예측한 OEF 값의 정확도를 측정하기 위해 평균 RMSE를 산출하였다. 3D CNN 모델의 출력은 QQ 모델에서 5개 입력 매개변수, 즉 OEF 예측에 필요한 정맥 산소포화도(Y)를 포함하는 변수들로 구성된다.

표 3은 제안한 3D CNN 모델의 예측값과 Ground Truth 데이터 간의 RMSE를 제시하며, 특히 정맥 산소포화도(Y)가 낮은 오차로 예측되었다. 반면, TE 0에서 신호 강도(S_0), 조직에서 가로 이완(R_2), 정맥 혈액량(v), 비혈류 물질의 자화율(χ_{nb})은 기존의 2D LSTM 방식에 비해 성능 향상이 나타나지 않았다. 그러나 OEF 계산에 중요한 Y의 예측 정확도가 개선되었다. 다른 요소들은 향후 모델 구성 및 학습 방식 변경이나 추가 데이터 확보를 통해 보완할 수 있을 것으로 판단된다.

표 3. 평가 데이터에 대한 3D CNN 모델의 RMSE
Table 3. RMSE of 3D CNN model for evaluation data

	S_0	R_2	Y	v	χ_{nb}
P5	0.0070	0.7583	0.0386	0.0041	0.0186
P12	0.0075	0.7329	0.0232	0.0040	0.0177
P23	0.0070	0.7193	0.0291	0.0043	0.0212
P27	0.0100	0.9025	0.0265	0.0049	0.0228
Avg.	0.0078	0.7782	0.0293	0.0043	0.0200

그림 4는 Ground Truth 데이터와 3D CNN 모델을 이용해 예측한 OEF 값을 비교한 결과를 나타낸다. 4명 환자 데이터 모두에서 예측값이 Ground Truth와 유사하게 나타났으며, OEF RMSE 측면에서도 3D CNN 모델이 2D LSTM 모델보다 약 0.14 정

도 우수한 성능을 보였다. 이는 예측된 OEF와 Ground Truth 간의 상당한 일치도를 의미하며, 제안한 모델이 OEF 예측에서 높은 정확도를 달성했음을 시사한다.




그림 4. Ground truth와 제안하는 방법의 OEF 예측 결과
Fig. 4. Ground truth and OEF prediction result of proposed method

표 4는 기존 CCM 방법[8], DNN 기반 방법[11], 2D LSTM 기반 방법[15]과 제안한 방법 간의 OEF 예측 평균 RMSE를 비교한 결과를 보여준다. 본 비교는 모두 코넬대학교 의과대학의 동일 데이터셋을 활용하여 수행되었으며, 학습과 테스트에 사용된 데이터셋의 비율은 차이가 있지만, 제안한 방법이 OEF 예측에서 우수한 RMSE 성능을 달성함을 확인할 수 있다.

표 4. 기존 CCM, DNN, 2D LSTM 방법 및 제안한 방법의 OEF RMSE 비교

Table 4. OEF RMSE comparison for CCM, DNN, 2D LSTM and proposed method

	CCM method[8]	DNN method[11]	2D LSTM method [15]	Proposed method
Method	6.20	6.00	5.33	5.19

이와 같은 실험 결과들을 종합하면 뇌 MRI 데이터를 대상으로 QQ 모델과 결합한 제안하는 3D CNN 기반 모델이 효율적으로 OEF를 예측할 수 있음을 알 수 있다. 또한, 제안한 방법이 기존에 연구된 CCM, DNN 및 2D LSTM 방식보다 더 높은 OEF 예측 정확도를 보였으며, 뇌 MRI 신호 분석 분야에서 기존 방법들보다 유의미하고, 우수한 성능을 보임을 의미한다.

V. 결론 및 향후 과제

뇌 질환 진단에는 뇌 조직 내 혈액의 산소 사용량을 측정하는 기술이 활용된다. 이를 통해 뇌 조직의 활성화 정도를 파악하고 정상 여부를 평가할 수 있으며, 이 과정에서 조직 내 OEF 계산은 중요한 역할을 한다.

다양한 알고리즘이 OEF 계산을 위해 제안되었으나, 3D 데이터에 대해 3D 딥러닝 모델의 활용은 아직 초기 단계에 있다. 본 연구에서는 QQ 모델을 기반으로 3D CNN 모델을 설계하여, 뇌 MRI를 기반으로 하는 QQ 모델의 매개변수를 추정하고 높은 정확도로 OEF를 예측하는 방법을 제안하였다. 또한, 17명 환자 데이터를 사용해 모델의 학습과 평가를 하였고, OEF RMSE 5.19를 달성하여 OEF 계산에 기여할 수 있음을 제시하였다.

제안하는 방법은 기존에 2D 형태로 가공한 데이터를 활용하는 방식과 달리, 4D 데이터를 별도의 전처리 없이 3D 모델에 직접 적용하여 차별성을 두었다. 또한, ROI에 하드웨어 자원을 집중하기 위해 크롭을 적용하여 정보 손실을 최소화하며 전체 데이터 크기를 크게 줄이는 전략을 사용하였다. 아울러 강화 학습을 통해 모델을 학습시킴으로써, 향후 추가 데이터셋이 도입되어도 기존 성능을 유지하면

서 성능 향상이 가능함을 기대할 수 있다.

그러나 본 연구는 다음과 같은 한계점을 가진다. 첫째, 총 데이터셋이 17명이라는 소규모로 구성되어 일반화 가능성에 제약이 존재한다. 소규모 데이터셋으로 학습한 모델은 과적합 위험이 크고, 다른 환자군이나 외부 데이터에 대한 검증이 미흡하여 실제 임상 환경에서 안정적으로 활용될 수 있는지 추가적인 검증이 필요하다. 따라서 추후에는 더욱 다양한 환자군을 포함한 대규모 데이터셋을 확보하여 모델의 일반화 능력을 높이고 외부 데이터를 통한 독립적인 검증을 수행해야 한다.

TE 0에서 신호 강도(S_0), 조직의 가로 이완(R_2), 정맥 혈액량(v), 비혈류 물질의 자화율(χ_{nb})과 같은 다른 변수들의 예측 정확도는 상대적으로 낮았다. 이를 해결하기 위해 해당 변수들 각각에 특화된 개별 예측 모델을 설계하거나 추가적인 특성 추출 기법 및 데이터 전처리 방식을 도입하여 각 지표에 대한 RMSE 오차를 더욱 낮출 필요가 있다.

또한, 더 정밀한 뇌와 관련된 질환들의 진단을 위해 본 연구에서 제안한 3D CNN 모델보다 우수한 성능의 최신 딥러닝 기법 도입을 통해 성능과 효율성을 모두 만족하는 최적의 방법론을 도출하는 방향으로 추가적인 연구가 가능하다.

References

- [1] H. Noh, J. Seo, S. Lee, N. Yi, S. Park, Y.-J. Choi, and S. Huh, "Cause-of-death statistics in 2020 in the Republic of Korea", *Journal of the Korean Medical Association*, Vol. 66, No. 2, pp. 132-142, Feb. 2023. <https://doi.org/10.5124/jkma.2023.66.2.132>.
- [2] Y.-S. Hong and C.-P. Han, "Analysis for Heart Disease and Predictive Predictions Factor", *The Journal of The Institute of Internet, Broadcasting and Communication*, Vol. 24, No. 5, pp. 111-116, Oct. 2024. <https://doi.org/10.7236/JIIBC.2024.24.5.111>.
- [3] D. S. Bolar, B. R. Rosen, A. Sorensen, and E. Adalsteinsson, "Quantitative imaging of extraction of oxygen and tissue consumption (QUIXOTIC) using venular-targeted velocity-selective spin labeling", *Magnetic Resonance in Medicine*, Vol. 66, No. 6, pp. 1550-1562, Jun. 2011. <https://doi.org/10.1002/mrm.22946>.
- [4] R. G. Wise, A. D. Harris, A. J. Stone, and K. Murphy, "Measurement of OEF and absolute CMRO2: MRI-based methods using interleaved and combined hypercapnia and hyperoxia", *NeuroImage*, Vol. 83, pp. 135-147, Dec. 2013. <https://doi.org/10.1016/j.neuroimage.2013.06.008>.
- [5] X. He and D. A. Yablonskiy, "Quantitative BOLD: mapping of human cerebral deoxygenated blood volume and oxygen extraction fraction: default state", *Magnetic Resonance in Medicine*, Vol. 57, No. 1, pp. 115-126, Dec. 2006. <https://doi.org/10.1002/mrm.21108>.
- [6] J. Cho, Y. Kee, P. Spincemaille, T. D. Nguyen, J. Zhang, A. Gupta, S. Zhang, and Y. Wang, "Cerebral metabolic rate of oxygen (CMRO2) mapping by combining quantitative susceptibility mapping (QSM) and quantitative blood oxygenation level-dependent imaging (qBOLD)", *Magnetic Resonance in Medicine*, Vol. 80, No. 4, pp. 1595-1604, Mar. 2018. <https://doi.org/10.1002/mrm.27135>.
- [7] J. Cho, S. Zhang, Y. Kee, P. Spincemaille, T. D. Nguyen, S. Hubertus, A. Gupta, and Y. Wang, "Cluster analysis of time evolution (CAT) for quantitative susceptibility mapping (QSM) and quantitative blood oxygen level-dependent magnitude (qBOLD)-based oxygen extraction fraction (OEF) and cerebral metabolic rate of oxygen (CMRO2) mapping", *Magnetic Resonance in Medicine*, Vol. 83, pp. 844-857, Sep. 2019. <https://doi.org/10.1002/mrm.27967>.
- [8] H. Y. Lee, "OEF Calculation Method through Cluster-based Classification and Matching of QQ Model on Brain MRI Images", *Journal of KIIT*, Vol. 18, No. 10, pp. 15-23, Oct. 2020. <https://doi.org/10.14801/jkiit.2020.18.10.15>.

- [9] J. Cho, J. Zhang, P. Spincemaille, H. Zhang, S. Hubertus, Y. Wen, R. Jafari, S. Zhang, T. D. Nguyen, A. V. Dimov, A. Gupta, and Y. Wang, "QQ-NET - using deep learning to solve quantitative susceptibility mapping and quantitative blood oxygen level dependent magnitude (QSM+qBOLD or QQ) based oxygen extraction fraction (OEF) mapping", *Magnetic Resonance in Medicine*, Vol. 87, No. 3, pp. 1583-1594, Oct. 2021. <https://doi.org/10.1002/mrm.29057>.
- [10] S. Hubertus, S. Thomas, J. Cho, S. Zhang, Y. Wang, and L. R. Schad, "Using an artificial neural network for fast mapping of the oxygen extraction fraction with combined QSM and quantitative BOLD", *Magnetic resonance in medicine*, Vol. 82, No. 6, pp. 2199-2211, Jul. 2019. <https://doi.org/10.1002/mrm.27882>.
- [11] H. S. Kim and H.-Y. Lee, "DNN-based Oxygen Extraction Fraction Prediction Method for QQ Model of Brain MRI", *The Journal of Korean Institute of Information Technology*, Vol. 21, No. 6, pp. 35-41, Jun. 2023. <https://doi.org/10.14801/jkiit.2023.21.6.35>.
- [12] W. M. Tavares, S. A. de França, W. S. Paiva, and M. J. Teixeira, "Early tracheostomy versus late tracheostomy in severe traumatic brain injury or stroke: A systematic review and meta-analysis", *Australian Critical Care*, Vol. 36, No. 5, pp. 734-741, Sep. 2023. <https://doi.org/10.1016/j.aucc.2022.12.012>.
- [13] D. Jiang and H. Lu, "Cerebral oxygen extraction fraction MRI: Techniques and applications", *Magnetic Resonance in Medicine*, Vol. 88, No. 2, pp. 575-600, May 2022. <https://doi.org/10.1002/mrm.29272>.
- [14] H. Jeong and H.-J. Kim, "A Dynamic Correction Technique of Time-Series Data using Anomaly Detection Model based on LSTM-GAN", *The Journal of The Institute of Internet, Broadcasting and Communication*, Vol. 23, No. 2, pp. 103-111, Apr. 2023. <https://doi.org/10.7236/JIIBC.2023.23.2.103>.
- [15] W. T. Kim and H. Y. Lee, "Prediction of Oxygen Extraction Fraction based on LSTM Deep Learning Model using Brain MRI", *The Journal of Korean Institute of Information Technology*, Vol. 22, No. 6, pp. 143-151, Jun. 2024. <https://doi.org/10.14801/jkiit.2024.22.6.143>.

저자소개

김 원 태 (Won-Tae Kim)



2019년 3월 : 국립금오공과대학교
컴퓨터소프트웨어공학과(공학사)
관심분야 : Image Processing,
Deep Learning

이 해 연 (Hae-Yeoun Lee)



1997년 : 성균관대학교 정보공학과
(학사)
1999년 : KAIST 전산학과
(공학석사)
2006년 : KAIST 전자전산학과
(공학박사)
2008년 3월 ~ 현재 :

국립금오공과대학교 컴퓨터소프트웨어공학과 교수
관심분야 : Digital Forensics, Image Processing, IoT