

뇌 MRI를 이용한 LSTM 딥러닝 모델 기반의 산소추출률 예측

김원태*, 이해연**

Prediction of Oxygen Extraction Fraction based on LSTM Deep Learning Model using Brain MRI

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 질환 진단을 위해 자기공명영상을 사용하여 뇌 조직 내 혈액의 산소추출률을 산출하여 뇌 조직의 활성화 정도를 파악할 수 있다. 기존 연구들은 주로 클러스터 분석과 같은 방법을 적용했지만, 본 논문에서는 QQ 모델을 기반으로 LSTM(Long Short-Term Memory) 딥러닝 모델을 사용해 산소추출률에 대한 예측을 수행하는 방법을 제안한다. 이 LSTM 딥러닝 모델은 하나의 입력 계층, 네 개의 LSTM 계층, 세 개의 Dense 계층, 그리고 하나의 출력 계층으로 구성되어 있으며, 성능 향상을 위해 추가적인 최적화가 수행되었다. 실험에서는 총 17명 환자의 자기공명영상 신호 감쇄 및 자화율 데이터를 사용하여 이 모델을 훈련시키고 검증하였으며, 평균 RMSE 값 5.33으로 산소추출률을 안정적으로 예측할 수 있음을 보여주었다.

Abstract

For the diagnosis of brain disease, magnetic resonance imaging(MRI) can be used to determine the degree of activation of brain tissue by calculating the oxygen extraction fraction(OEF) of blood within brain tissue. Although previous studies mainly applied methods such as cluster analysis, this paper proposes a method to predict OEF using a Long Short-Term Memory(LSTM) deep learning model based on the QQ model. This LSTM deep learning model consists of one input layer, four LSTM layers, three Dense layers, and one output layer, and additional optimization was performed to improve the performance. In the experiment, we trained and validated the proposed model using MRI signal attenuation and susceptibility data from a total of 17 patients, and showed that this model could reliably predict OEF with an average RMSE value of 5.33.

Keywords

oxygen extraction fraction, brain MRI, QQ model, long short-term memory model

* 국립금오공과대학교 컴퓨터소프트웨어공학과 학사과정
- ORCID: <https://orcid.org/0009-0002-1568-3820>
** 국립금오공과대학교 컴퓨터소프트웨어공학과 교수(교신저자)
- ORCID: <http://orcid.org/0000-0002-6081-1492>

· Received: Mar. 11, 2024, Revised: Apr. 06, 2024, Accepted: Apr. 09, 2024
· 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

뇌 질환은 세계적으로 주요한 건강 문제로, 한국에서도 암과 심장 질환, 폐렴에 이어 네 번째로 흔한 사망 원인이다[1]. 뇌 조직의 활성화 상태와 건강 여부를 정확히 파악하는 것은 뇌 질환의 진단과 치료에서 중대한 역할을 하며, 이러한 질환의 조기 진단과 효과적 관리는 환자의 생존 가능성을 높이고, 후유증을 줄임으로써 삶의 질을 향상시킨다.

뇌 조직 내 혈액의 산소추출률(OEF, Oxygen Extraction Fraction) 측정은 뇌 질환 진단에 중요한 지표로서, 뇌의 대사 상태와 활성화 정도에 대한 정보를 제공한다. 산소추출률 예측을 위해 다양한 연구들이 수행되었고 QUIXOTIC(QUantitative Imaging of eXtraction of oxygen and Tissue consumption)[2], Calibrated fMRI[3], qBOLD(quantitative Blood Oxygenation Level Dependent)[4], qBOLD 및 QSM(Quantitative Susceptibility Mapping)을 결합한 QQ[5][6]와 같은 여러 모델이 제안되었다. 이들 중에서 특정한 가정 없이 OEF를 예측할 수 있는 QQ 모델을 기반으로 하는 클러스터 분석이나 딥러닝 기술을 적용한 연구도 진행 중이다[7]-[10].

본 논문에서는 OEF 예측의 정확도와 안정성 개선을 위해서, 뇌 자기공명영상(MRI, Magnetic Resonance Imaging) 데이터를 활용하여 OEF를 보다 효과적으로 예측하는 방법을 제시한다. 이를 위해 QQ 모델을 기반으로 LSTM(Long Short-Term Memory) 딥러닝 모델을 구성하였다. 이 모델은 하나의 입력 계층, 네 개의 LSTM 계층, 세 개의 Dense 계층, 그리고 하나의 출력 계층으로 구성되어 있으며, 복잡한 시계열 데이터 처리에 탁월한 LSTM의 특성을 활용한다. 제안한 모델은 17명의 환자로부터 수집된 MRI 데이터를 사용하여 학습 및 검증을 진행하였고, 특히, 성능을 극대화하기 위한 최적화 과정을 거쳐, OEF 예측의 정확도를 높이고자 하였다.

DNN(Deep Neural Network) 기반의 기존 모델들과 다르게 데이터가 시간 정보를 포함할 수 있도록 시퀀스화 하고, 이 시퀀스 데이터에 특화된 인공지능 모델인 LSTM에 적용하였다. LSTM 딥러닝 모델의 활성화 함수로 tanh를 사용하여 GPU 기반 실험

환경에서 빠른 속도로 학습할 수 있게 하였다. 최종 출력값을 예측할 때는 Dense 계층을 사용함으로써 성능을 향상시켰다.

본 논문은 다음과 같이 구성되어 있다. 2장에서 관련 연구를 요약하고, 3장에서는 제안하는 LSTM 딥러닝 모델 기반의 OEF 예측 방법을 상세히 설명한다. 4장에서는 실험 결과와 분석을 제시하며, 5장에서는 연구 결과의 결론을 도출한다.

II. 관련 연구

인간 뇌의 산소 소비량이 전체 소비량의 20%에 달하는 것은 뇌와 산소 사이의 중요한 연관성을 의미한다. 뇌의 산소 사용률은 혈류와 OEF를 통해 파악할 수 있으며, 이는 다양한 뇌 질환에서 중요한 바이오마커로 활용되고 있다. 특히, 진단에 사용되는 MRI 기술의 발전은 OEF 측정 방법론에 새로운 가능성을 열었다. 15O PET(15 Oxygen Positron Emission Tomography)이 OEF 측정의 표준으로 여겨지지만, MRI 기반의 OEF 측정 기술은 비침습적이며 방사선 노출이 없고, 더 넓은 범위에서 사용될 수 있다는 장점을 갖고 있다[11].

2.1 QQ 모델

QSM 모델은 정맥 내 디옥시헤모글로빈의 영향과 비혈액 조직의 자화율을 구별할 수 있는 능력을 갖추고 있으며, qBOLD 모델은 mGRE(multi-echo Gradient Echo) 시퀀스 MRI 신호의 강도를 활용해 OEF의 영향을 모델링할 수 있다. QQ 모델은 두 모델을 결합하였고 QSM과 qBOLD 모델에서 요구되는 파라미터들을 서로 보완하며, 기존 OEF 계산 모델들이 필요로 하는 특정한 가정 없이 작동한다.

이론적으로는 QQ 모델이 mGRE 시퀀스 MRI 신호의 크기와 위상을 사용하여 계산할 수 있지만, 실제로 정맥 혈액량과 산소포화도 사이의 관계, 그리고 qBOLD 역변환의 잡음 민감도 등으로 인해 계산이 복잡하다[6][7]. 이와 같은 문제의 해결을 위해 CAT(Cluster Analysis of Time evolution) 방법[6]과 CCM(Cluster-based Classification and Matching) 방법[7] 등이 연구되었다.

2.2 CCM

클러스터 기반 분류 및 정합(CCM, Cluster-based Classification and Matching) 방법은 QQ 모델이나 CAT 방법의 문제점들을 개선하고 안정적인 OEF 계산을 위하여 제안되었다[7].

이 방법에서는 먼저 QQ 모델에 실제 값들을 입력하여 출력값을 계산한 후, 클러스터 기반 분류를 통해 클러스터 데이터베이스를 생성한다. 그 후 미지의 샘플을 정합하는 단계에서는 MRI를 통해 에코 시간에서의 측정된 신호 값을 활용하여 입력값을 추정한다. 이 경우, 미지의 출력값을 기반으로 데이터베이스에 대해 정합과 보간 작업을 수행하여 입력값을 추론하며, 이를 통해 OEF를 산출한다.

2.3 DNN 기반 딥러닝 모델

MRI 신호를 활용한 OEF 계산을 위해 신경망 기술을 적용하는 연구들이 진행 중이다[8]-[10]. 특히, QQ 모델을 기반으로 한 딥러닝 모델을 활용하여 OEF를 예측하는 연구들이 진행되고 있으며, QQ 모델의 입력 및 출력 데이터로 DNN 모델을 구성하여 학습하고 뇌 MRI를 통해 수집한 (출력) 신호 데이터를 사용하여 입력 OEF에 대한 예측을 수행하는 방법 등이 있다[10].

III. 뇌 MRI의 QQ 모델에 대해 LSTM 딥러닝 모델 기반 OEF 예측 방법

본 절에서는 빠르고 정확한 OEF 계산을 위해, 뇌 MRI 데이터에 QQ 모델을 적용하고 이를 기반으로 LSTM(Long Short-Term Memory) 딥러닝 모델을 수립하고 사용하여 OEF를 예측하는 새로운 방법을 제안한다.

3.1 LSTM

LSTM은 주로 시퀀스 데이터를 처리하기 위해 설계된 딥러닝 모델의 요소로 그림 1과 같이 기본적으로 두 가지 주요 경로, 즉 장기 기억을 유지하

는 경로와 단기 기억을 처리하는 경로로 구성된다 [12][13]. 장기 기억 경로는 시퀀스의 중요한 정보를 장기간 유지하며, 이는 네트워크의 셀 상태(Cell state)를 통해 관리한다. 단기 기억 경로는 현재 입력과 과거의 단기 기억을 결합하여 현재의 출력을 생성하며 이 경로는 장기 기억과 함께 작동하여 필요한 정보를 단기적으로 활용하고, 불필요한 정보는 소거한다.




그림 1. LSTM 내부 구조
Fig. 1. LSTM internal structure

3.2 딥러닝 모델 입력 및 출력과 OEF

OEF 예측을 위한 QQ 모델은 QSM과 qBOLD를 결합하여 식 (1)과 같이 정의된다[6]-[8].

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

이 수식에서 Y는 정맥 산소 포화도를 의미하며, v는 정맥의 혈액량을 나타내고, R2는 BOLD(Blood Oxygenation Level Dependent) 효과가 없는 조직의 가로 방향 이완을 나타낸다. S0는 에코 타임(TE, Echo Time)이 0일 때의 신호 강도를 의미하며, χ_{nb} 는 비혈류 물질의 자화율(Non-blood susceptibility)을 나타낸다. 추가로 w는 QSM 가중치 및 λ 는 정규화 가중치를 의미한다. FQSM 모델과 SqBOLD 모델은 Lee와 Cho et al에 자세히 설명되어 있다[6][7].

OEF는 식 (2)과 같이 정맥 산소포화도(Y)를 이용하여 계산할 수 있다. Y_a 는 동맥 산소화 값으로, 일반적으로 0.98 값으로 가정되며, 이는 동맥에서 산소화에 대한 실험을 통하여 얻어진다[6].

$$OEF = 1 - \frac{Y}{Y_a} \quad (2)$$

코넬대학교 의과대학의 CAT 방법에 사용된 것과 동일한 데이터셋을 딥러닝 모델의 입력과 출력 데이터로 사용하였다[6]. 이 데이터셋은 QQ 모델의 입력 변수들인 정맥 산소포화도(Y), 정맥 혈액량(v), 조직의 가로 이완(R2), 에코 타임 0에서의 신호 강도(S0), 비혈류 물질의 자화율(χ_{nb})과 7개 에코 타임에서의 MRI 신호값 및 자화율로 구성되어 있다[7].

제안하는 딥러닝 모델에서는 MRI 촬영으로 얻은 3차원 구조의 데이터를 선형화하여 1차원 데이터를 얻어내고, 여기서 획득한 8개 에코 타임에서의 신호 값과 1개 자화율을 시간 개념을 포함하는 타임 스텝이 5인 시퀀스 데이터로 전처리한 후 입력 데이터로 사용한다. 또한, 이 모델은 OEF 계산에 활용하는 QQ 모델에서 요구되는 파라미터들인 정맥 산소포화도, 정맥 혈액량, 조직의 가로 이완, 에코 타임(TE) 0에서의 신호 강도, 비혈류 물질의 자화율을 출력으로 구성하였다.

3.3 LSTM 딥러닝 모델의 구조 설계

본 논문에서 제안한 LSTM 기반의 딥러닝 모델 구조는 에코 타임에서 측정된 8개의 MRI 신호 값과 1개의 자화율을 포함하는 총 9개의 입력에 대한 5개의 타임 스텝으로 구성된 시퀀스 데이터를 사용하는 입력 계층으로 시작한다. LSTM 모델은 짧은 시간 스텝에서도 데이터 내의 복잡한 관계와 동적 변화를 더 잘 학습하고 예측할 수 있는 능력이 있기 때문에 5개 타임 스텝으로 구성하였고, 이를 통해 학습 과정에서의 계산 부담을 줄이면서도 모델의 성능을 향상시킬 수 있다. 또한 기존 데이터를 시퀀스화 하여 사용하는 이유는 데이터에 시간 정보를 포함하고 LSTM에 입력값으로 사용하기 위함

이다. 이후 모델은 총 4개의 LSTM 은닉 계층을 거친다. 이 은닉 계층들에서는 노드의 수를 512개에서 시작하여 점차 줄여나가는 구조로 되어 있다. 입력층 이후 3개의 LSTM 계층에서는 각 시간 단계에 대한 출력을 모두 반환한다. 즉, 시퀀스의 각 요소에 대해 출력 벡터를 생성하고 이를 통해 다음 레이어가 시퀀스 데이터를 처리할 수 있도록 한다. 마지막 LSTM 계층에서는 마지막 시간 단계의 출력만 반환함으로써 마지막 요소에 대한 출력 벡터만 생성하여 시퀀스 전체에 대한 하나의 결과만 나오게 한다. 이후 Dense 계층에서 적용하기 위해 다차원의 입력 데이터를 1차원으로 평탄화하는 기능을 수행하는 Flatten 계층을 거친다. 평탄화 후에는 3개의 Dense 계층을 거치고 최종적으로 QQ 모델의 입력 파라미터에 해당하는 정맥 산소포화도, 정맥 혈액량, 가로 이완, 에코 타임(TE) 0에서의 신호 강도, 비혈류 물질의 자화율을 예측하기 위한 5개 노드로 구성된 출력 계층을 생성하였다. 이와 같은 모델에 대한 전반적인 구조를 그림 2에 도시하였다.

이러한 구조를 통해, LSTM 딥러닝 모델은 MRI 데이터를 바탕으로 QQ 모델의 중요한 변수들을 효과적으로 예측하고 OEF를 정확하게 계산할 수 있도록 설계되었다.

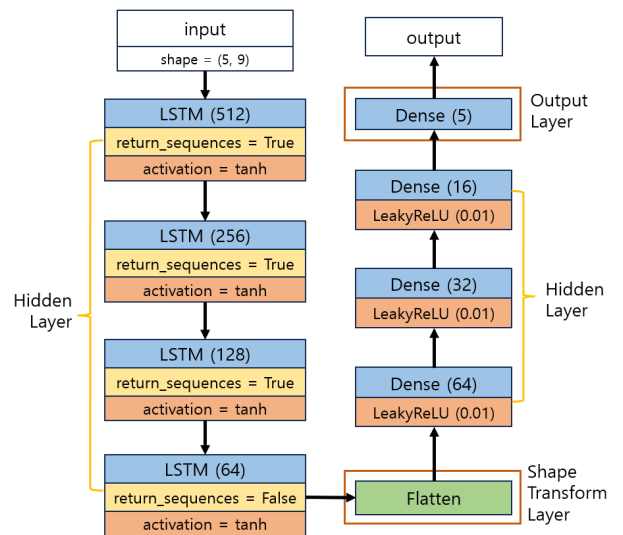


그림 2. OEF 예측을 위한 LSTM 딥러닝 모델 구조도
Fig. 2. Structure of LSTM deep learning model for OEF prediction

은닉 계층에서 노드의 수를 점차 줄이면서 여러 계층을 쌓는 방식으로 설계되었는데, 이러한 구조는 네트워크의 복잡성을 점진적으로 감소시키면서도, 필요한 정보를 효과적으로 전달하도록 돕는다.

가중치 업데이트를 위한 활성화 함수로는 LSTM 계층에서는 GPU 환경에서의 빠른 학습 및 최적의 성능을 위하여 하이퍼볼릭 탄젠트(tanh), Dense 계층에서는 LeakyReLU를 활성화 함수로 사용했다. LeakyReLU에서 음의 입력값에 대해서는 0.01로 스케일링하여 처리하였다. 이는 모델이 음수 입력에 대해서도 일정한 반응을 보일 수 있도록 하여, 활성화 함수가 완전히 0이 되는 것을 방지하고, 네트워크의 비선형 학습 능력을 향상시킨다.

IV. 실험 결과 및 분석

제안하는 방법은 Intel i9-11900 CPU, NVIDIA RTX 3090 GPU, 64GB RAM 하드웨어 및 Windows 10 Pro 운영체제에서 Tensorflow의 Keras로 구현하였다.

4.1 학습과 검증 정확도

코넬대학교 의과대학에서 구축한 데이터셋을 사용하여 LSTM 딥러닝 모델의 학습과 검증을 진행했다. 이 데이터셋에는 17명의 환자로부터 수집된 3차원 뇌 MRI 신호 값과 자화율 데이터가 포함되어 있으며, 이에 대응하는 QQ 모델의 정맥 산소포화도, 정맥 혈액량, 조직의 가로 이완, 에코 타임(TE) 0에서의 신호 강도, 비혈류 물질의 자화율에 대한 Ground Truth 값이 함께 제공된다[6][7].

먼저 3차원 구조의 데이터를 1차원으로 선형화하여 메모리에 적재한 후, 데이터를 학습, 검증 및 평가에 적합하게 분할하여 사용하였다. 이 과정에서 총 17명의 환자 데이터 중 6명(P1, P2, P10, P14, P15, P17)의 데이터를 학습과 검증에 Train : Validation = 8 : 2의 비율로 분할하여 활용하였다. 개별 신호로는 총 11,498,589개 데이터이며, 학습에 9,198,871개, 검증에 2,299,718개가 사용되었다. 나머지 11명의 환자 데이터는 모델의 성능 평가에 사용

되었다.

모델 학습에는 학습률을 $1e-4$ 로 설정했으며, 손실 함수로 Huber, 최적화 함수로 Adam를 사용하였고, 평가지표로 평균 제곱근 오차(Root Mean Square Error, RMSE)를 사용하였다. 이러한 설정은 모델이 데이터를 효과적으로 학습하고, 결과의 정확도를 높이는 데 중요한 역할을 한다.

LSTM 딥러닝 모델의 학습 과정은 512개의 배치 크기를 가지고 최대 100 에포크(epoch) 동안 진행되었다. 학습 과정에서 중요한 점은 검증 데이터에 대한 손실값 변화를 모니터링하여, 이 값이 더 이상 개선되지 않으면 학습을 조기에 종료하도록 설정한 것이다. 이러한 조치는 학습 시간을 최적화하고 과적합을 방지하는 데 도움을 준다.

그림 3과 표 1에는 각 에포크에 따른 OEF 예측의 RMSE와 손실률이 나타나 있다.

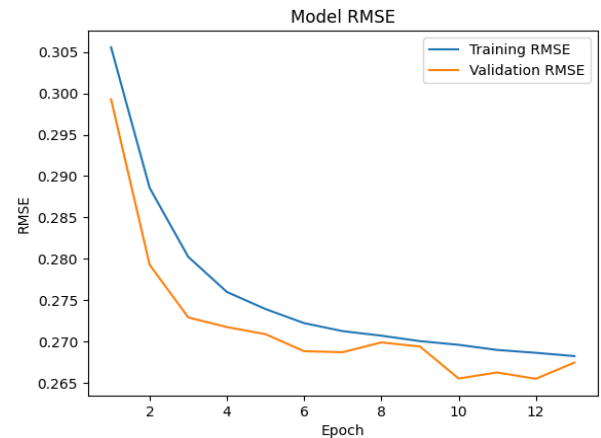


그림 3. Epoch에 따른 학습 및 검증 RMSE

Fig. 3. Prediction and validation RMSE at each epoch

표 1. Epoch에 따른 예측 RMSE와 손실률 추세

Table 1. Prediction RMSE and loss rate at each epoch

Epoch	Loss	RMSE	Epoch	Loss	RMSE
1	0.0357	0.2993	8	0.0329	0.2699
2	0.0333	0.2793	9	0.0327	0.2694
3	0.0332	0.2792	10	0.0321	0.2655
4	0.0333	0.2717	11	0.0323	0.2662
5	0.0332	0.2709	12	0.0321	0.2655
6	0.0327	0.2688	13	0.0324	0.2674
7	0.0327	0.2687			

이 데이터에서 RMSE와 손실률이 점진적으로 수렴하는 경향을 볼 수 있다. 특히, 10번째 에포크에서는 손실률이 0.0321로 가장 낮았으며, RMSE 또한 0.2655로 가장 높은 정확도를 보였다. 이는 기존 DNN 기반 딥러닝 모델과 비교했을 때 0.0014 더 낮은 손실률과 0.008 더 낮은 RMSE 값이다[10]. 수렴 이후에는 다른 에포크들과 RMSE 및 손실률의 차이가 크지 않았다. 이러한 경향은 학습 과정이 진행됨에 따라 학습 데이터가 변화하면서 발생하는 미세한 차이들을 반영하는 것으로 보인다.

4.2 평가 정확도

제안한 LSTM 딥러닝 모델의 성능 평가는 학습과 검증에 사용되지 않은 11명의 환자 데이터를 이용해 진행되었다. 이 평가에서는 모델이 예측한 OEF 값의 정확도를 평가하기 위해 평균 RMSE를 계산했다. LSTM 딥러닝 모델의 출력은 QQ 모델의 5개 매개변수, 즉 정맥 산소포화도를 포함한 OEF 예측에 필요한 변수들로 구성되어 있다. 따라서, 모델의 성능을 정확하게 평가하기 위해서는 모델의 출력과 Ground Truth 데이터를 비교할 필요가 있다.

표 2에는 본 논문에서 제안하는 LSTM 딥러닝 모델에 대해 Ground Truth 데이터 간의 RMSE 값이 제시되어 있다. 이를 통해 기존 DNN 모델[10]에 비하여 LSTM 딥러닝 모델이 TE 0에서 신호 강도(S0), BOLD 효과가 없는 조직의 가로 이완(R2), 정맥 산소포화도(Y)가 낮은 오차로 예측됨을 확인할 수 있다. 하지만 정맥 혈액량(v), 비혈류 물질의 자화율(χ_{nb})에 대해서 상대적으로 큰 오차가 발생하는 단점이 있다. 일단 OEF 계산에 중요한 Y에 대한 정확도가 향상된 것에 큰 의미가 있으며, 상대적으로 오차가 큰 요소는 향후 모델 구성을 변경하거나 파라미터 조정을 통해 해결할 수 있을 것으로 보인다.

그림 4에 Ground Truth 데이터와 DNN 모델, LSTM 모델을 이용하여 예측한 OEF의 비교 결과를 도시하였다. DNN 모델과 LSTM 모델 모두 Ground Truth와 거의 유사하지만 LSTM의 경우 DNN 모델보다 전체적으로 더 선명하게 예측하였다. 또한

Ground Truth와 비교한 OEF RMSE 값에서 LSTM이 DNN 모델보다 약 0.7 정도 높은 성능을 보였다. 따라서 예측된 OEF가 Ground Truth와 상당한 정도로 일치함을 볼 수 있다. 이러한 결과는 모델이 OEF 예측에서 높은 정확도를 보임을 의미한다.

표 2. 평가 데이터에 대한 LSTM 딥러닝 모델의 RMSE
Table 2. RMSE of LSTM deep learning model for evaluation data

	S0	R2	Y	v	χ_{nb}
P3	0.0045	0.5614	0.0627	0.0044	0.0330
P4	0.0086	0.6202	0.0527	0.0054	0.0350
P5	0.0049	0.6033	0.0552	0.0035	0.0334
P6	0.0091	0.5406	0.0440	0.0039	0.0301
P7	0.0055	0.7784	0.0308	0.0118	0.0349
P8	0.0097	0.5685	0.0656	0.0031	0.0290
P9	0.0057	0.6497	0.0584	0.0037	0.0378
P11	0.0049	0.5458	0.0538	0.0050	0.0330
P12	0.0051	0.6241	0.0605	0.0039	0.0302
P13	0.0092	0.6036	0.0498	0.0052	0.0446
P16	0.0088	0.5441	0.0402	0.0030	0.0316
Avg.	0.0069	0.6036	0.0522	0.0048	0.0339

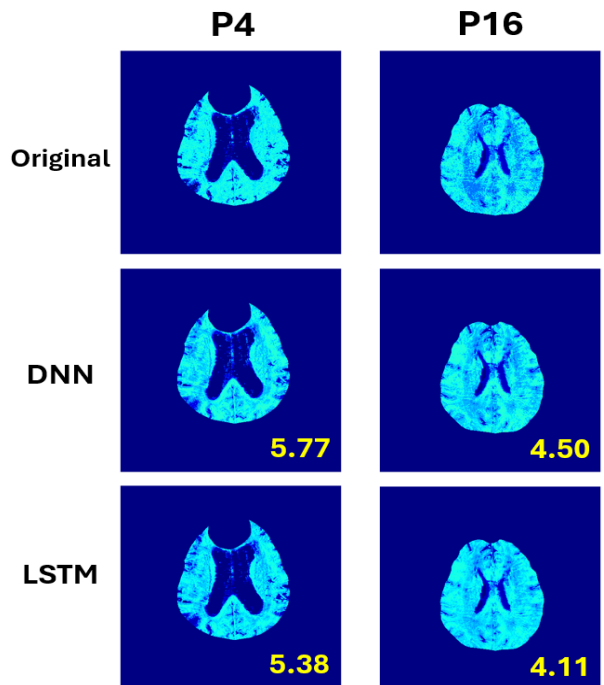


그림 4. Ground truth와 제안하는 방법의 OEF 예측 결과
Fig. 4. Ground truth and OEF prediction result of proposed method

표 3에는 기존의 CCM 방법[7], DNN 기반 딥러닝 방법[10] 및 제안한 방법 간 OEF 예측에 대한 평균 RMSE를 비교하였다. 이 비교는 동일한 코넬대학교 의과대학의 데이터셋을 사용하여 수행되었으며, 비록 학습 및 평가에 사용된 환자의 번호에는 차이가 있지만, 제안된 방법이 OEF 예측에 대해 높은 수준의 RMSE를 달성한 것을 확인할 수 있다.

실험 결과를 통해 뇌 MRI 데이터에 대해 QQ 모델을 이용하고 이를 바탕으로 LSTM 기반의 딥러닝 모델을 적용하여 OEF를 효율적으로 계산할 수 있음을 알 수 있다. 또한, 제안된 방법은 기존의 CCM 및 DNN 방법에 비해 더 높은 정확도를 달성할 수 있음을 확인하였다. 이는 제안한 LSTM 딥러닝 모델이 뇌 MRI 신호 분석에 있어서 기존 방법들보다 우수한 성능을 제공할 수 있음을 시사한다.

표 3. 기존 방법 및 제안하는 방법의 OEF RMSE 비교
Table 3. Comparison of OEF RMSE for CCM method, DNN method and proposed method

	CCM method[6]	DNN method[10]	Proposed method
Method	6.20	6.00	5.33

V. 결론 및 향후 과제

뇌 질환을 진단하는 방법 중에는 뇌 내의 조직을 통해 혈액의 산소 사용량을 측정하는 기술이 있다. 이 기술을 이용해 뇌 조직이 얼마나 활성화되어 있는지를 확인하고, 그 상태가 정상인지를 판단할 수 있다. 이 과정에서 조직에서의 OEF을 계산하는 것이 중요하다.

여러 알고리즘이 OEF 계산을 위해 제안되었으나, 딥러닝을 활용한 방법은 아직 초기 단계에 머물러 있다. 본 연구에서는 QQ 모델을 바탕으로 한 LSTM 딥러닝 모델을 개발하여, 뇌 MRI에서 얻은 9가지 신호 데이터를 사용해 QQ 모델의 매개변수를 추정하고 OEF를 높은 정확도로 예측하는 새로운 방법을 제안했다.

이 방법은 17명의 환자 데이터를 사용해 모델을 학습시키고 평가했다. 본 연구의 차별점은 기존의 정적이거나 단일 차원적 데이터 처리 방식에서 벗

어나, 시간에 따라 변화하는 뇌의 생리학적 신호를 다루기 위해 순환신경망을 사용하는 LSTM 딥러닝 모델을 수립하였고, 이에 대해 최적화를 수행한 것이다. 또한 실험을 통해 5.33 OEF RMSE를 달성함으로써 제안한 딥러닝 모델이 OEF 계산에 유의미한 기여를 할 수 있음을 입증하였다. 이 모델은 데이터를 시간 개념을 포함하는 시퀀스 형식으로 가공하여 모델이 시간에 따른 신호의 변화와 패턴을 더욱 정확하게 포착하고 이해할 수 있게 하여 기존보다 더욱 뛰어난 성능을 보였다.

향후 연구로는 정맥 혈액량(v), 비혈류 물질의 소화율(χ_{nb})에 대해서도 더 낮은 RMSE 오차 값을 가지게 발전시킬 필요가 있으며, 더욱 정밀한 뇌 질환 진단을 위해 본 연구에서 제안한 LSTM 딥러닝 모델보다 더 우수한 성능이나 GRU와 같이 변형된 인공신경망을 도입하는 연구가 필요하다[14].

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://www.doi.org/10.5124/jkma.2023.66.2.132>.
- [2] 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>.
- [3] 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>.
- [4] 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>.
- [5] 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>.
- [6] 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>.
- [7] 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>.
- [8] 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>.
- [9] 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>.
- [10] 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>.
- [11] 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>.
- [12] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory", *Neural Computation*, Vol. 9, No. 8, pp. 1735-1780, Nov. 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>.
- [13] J. Oh and S. Kum, "A Study on Estimating Geomagnetic Azimuth using LSTM", *The Journal of The Institute of Internet, Broadcasting and Communication*, Vol. 22, No. 6, pp. 137-141, Dec. 2022. <https://doi.org/10.7236/JIIBC.2022.22.6.137>.
- [14] S.-M. Lee, Y.-G. Sun, J. Lee, D. Lee, E.-I. Cho, D.-H. Park, Y.-B. Kim, I. Sim, and J.-Y. Kim, "Short-term Power Consumption Forecasting Based on IoT Power Meter with LSTM and GRU Deep Learning", *The Journal of The Institute of Internet, Broadcasting and Communication*, Vol. 19, No. 5, pp. 79-85, Oct. 2019. <https://doi.org/10.7236/JIIBC.2019.19.5.79>.

저자소개

김 원 태 (Won-Tae Kim)



2019년 3월 : 국립금오공과대학교
컴퓨터소프트웨어공학과
학사과정
관심분야 : Image Processing,
Deep Learning

이 해 연 (Hae-Yeoun Lee)



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

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