

뇌 MRI에 QQ 모델을 이용한 DNN 기반 산소추출률 예측 방법

김현수*, 이해연**

DNN-based Oxygen Extraction Fraction Prediction Method for QQ Model of Brain MRI

Hyeon-Su Kim*, Hae-Yeoun Lee**

This research was supported by Kumoh National Institute of Technology(2022~2023)

요 약

뇌 질환의 진단 기법 중 뇌 조직의 활성화 정도를 파악하기 위해 자기 공명 영상(MRI)을 사용하여 조직의 혈액 내에 산소추출률(OEF)을 계산하는 방법이 있다. 기존에 OEF를 계산하기 위한 클러스터 분석 등과 같은 다양한 알고리즘이 제시되었지만, 딥러닝 모델을 사용한 연구는 아직 활발히 진행되지 않고 있다. 본 논문에서는 QQ 모델을 이용하여 DNN 모델을 구성한 후에 뇌 MRI를 통해 수집한 신호 데이터를 사용하여 OEF에 대한 예측을 수행하는 방법을 제안하였다. DNN 모델은 1개의 입력 계층, 4개의 은닉 계층, 1개의 출력 계층으로 구성하였고 성능 향상을 위한 최적화를 수행하였다. 총 17명 환자의 MRI 신호 감쇄 및 자화율을 이용하여 DNN 모델의 학습과 검증을 진행하였고, 평균적으로 RMSE 6.0 정확도로 안정적으로 OEF를 예측함을 확인하였다.

Abstract

Among brain disease diagnostic techniques, there is a method of calculating oxygen extraction fraction(OEF) in the blood of a tissue using a magnetic resonance imaging(MRI) in order to determine the degree of activation of brain tissue. Various algorithms such as cluster analysis for calculating OEF have been proposed in the past, but research using deep learning models has not yet been actively conducted. In this paper, we propose a method for calculating OEF using signal data collected through brain MRI after constructing a DNN model for QQ model. The DNN model consisted of 1 input layer, 4 hidden layers, and 1 output layer, and optimization was performed to improve performance. The DNN model was trained and verified using the MRI signal attenuation and susceptibility of a total of 17 patients, and it was confirmed that OEF was stably predicted with average RMSE 6.0 accuracy.

Keywords

oxygen extraction fraction, brain MRI, QQ model, deep neural network

* 금오공과대학교 컴퓨터소프트웨어공학과 학사과정
- ORCID: <https://orcid.org/0000-0001-6640-5041>
** 금오공과대학교 컴퓨터소프트웨어공학과 교수(교신저자)
- ORCID: <https://orcid.org/0000-0002-6081-1492>

• Received: Apr. 24, 2023, Revised: May 04, 2023, Accepted: May 07, 2023
• Corresponding Author: Hae-Yeoun Lee
Dept. of Computer Software Engineering, Kumoh National Institute of Technology, Korea
Tel.: +82-54-458-7548, Email: haeyecoun.lee@kumoh.ac.kr

I. 서 론

뇌 질환은 전 세계적으로 10대 사망원인으로 꼽을 만큼 치명적인 질환이다. 특히 뇌졸중은 전 세계 사망원인 2위이며, 한국에서도 암, 심장질환에 이어 사망원인 4위를 차지하고 있다[1]. 환자의 뇌 질환을 예방하거나 치료하기 위해서는 정확한 진단이 필요하며 자기공명영상(MRI, Magnetic Resonance Imaging), 컴퓨터 단층촬영 등은 생리학적인 진단에 사용되는 데이터를 확보하기 위해 활용된다. 이러한 데이터를 이용한 진단 기법 중에는 조직 내에서 사용되는 혈액 내 산소 사용률을 분석하는 방법이 있다. 이를 통해 뇌 조직의 활성화 여부를 판단하고 정상 여부를 추정할 수 있다.

뇌 조직에서 산소 사용률은 산소추출률(OEF, Oxygen Extraction Fraction)을 이용해서 알 수 있다. QUIXOTIC[2], Calibrated fMRI[3], qBOLD(quantitative Blood Oxygenation Level Dependent)[4], QQ[5] 등 모델이 OEF 예측을 위해 제안되었고, 특정한 가정을 하지 않는 QQ 모델을 기반으로 효율적 OEF 예측을 위해 클러스터 기반 분석이나 딥러닝을 도입한 연구도 수행되고 있다[6]-[10].

안정적이고 정확도가 향상된 OEF 예측의 필요성과 딥러닝 적용에 대한 요구가 증가하고 있어서, 본 논문에서는 QQ 모델에 대하여 DNN을 구성한 후에 뇌 MRI로 수집한 신호 데이터를 이용하여 OEF를 예측하는 방법을 제안한다. DNN 모델은 1개의 입력 계층, 4개의 은닉 계층, 1개의 출력 계층으로 구성하였다. 또한 17명의 환자 데이터로 모델의 학습 및 검증을 진행하였다. 기존 방법들과 다르게 DNN 기반 딥러닝을 도입하였고 성능 향상을 위한 최적화를 통하여 정확도 향상을 모색하였다.

본 논문의 구성은 다음과 같다. 2장에서 관련 연구를 요약하고, 3장에서 제안하는 DNN 기반 OEF 예측 방법을 설명한다. 4장에서 실험 및 분석 결과를 기술하고 5장에서 결론을 제시한다.

II. 관련 연구

인간의 뇌에서 산소 소모량은 20%를 차지하는

만큼 뇌와 산소는 밀접한 관계가 있다. 뇌의 산소 사용률은 혈류 및 OEF에서 알 수 있어서 OEF는 다수의 뇌 질환에서 유용한 바이오마커로 사용되고 있다. 특히 최근에는 진단을 위해 사용하는 MRI 기술 발전으로 OEF를 측정하기 위해서 이를 이용한 방법이 연구되고 있다. OEF 측정의 최적 표준으로 여겨지는 15OPET에 비해 MRI 기반 OEF 측정 기술은 비침습적이고 방사선이 없으며, 더 광범위하게 사용할 수 있다는 장점이 있다[11].

2.1 QSM 모델

QSM(Quantitative Susceptibility Mapping) 모델은 생물학적 조직 내에서 자화율의 공간적인 분포를 정량적으로 매핑하기 위한 모델이다. 초기에는 간단한 커널 분할로 재구성된 자화율 맵에 많은 오류가 발생하는 문제가 있어서 활용에 어려움이 있었다.

그러나 MRI에서 조직의 해부학적 구조에 대한 정보를 통해 베이지안 정규화에서 발생한 역문제를 해결하였고, 다양한 정규화 방법도 개발되어 QSM을 MRI 기반 기술로 사용할 수 있게 되었다[12].

2.2 qBOLD 모델

MRI에서 혈중 산소 농도 의존성(BOLD)이 발견된 후에 대부분 연구는 뇌 활동 중 MRI 신호의 시간적 변화 연구에 집중되었고 뇌 에너지가 비활동 상태를 증명하는 것에 진전은 없었다. 뇌 질환의 진단을 위해 비활성화 상태도 중요한 의미가 있어서 이를 보완하기 위해 qBOLD 모델이 제안되었다.

OEF 등을 정량적으로 평가하기 위해 qBOLD는 뇌 조직 구성에 대한 사전 지식을 통합하고 회백질, 백질, 뇌척수액의 신호를 고려한 MR 신호 모델을 기반으로 한다. qBOLD는 기준 상태에서 정상적인 뇌의 혈류역학 값을 추정하는데 활용된다[4].

2.3 QQ 모델

QSM 모델은 정맥 혈액의 디옥시헤모글로빈 영향과 비혈액 조직의 자화율을 구분할 수 있고,

qBOLD 모델은 mGRE(multi-echo Gradient Echo) 시퀀스 MRI 신호의 세기를 이용하여 OEF 효과를 모델링할 수 있다. QQ 모델은 QSM 모델과 qBOLD 모델을 결합하여 각 모델에서 필요한 파라미터를 상호 보완하여, 기존 OEF 계산 모델들과 달리 특정 가정을 필요로 하지 않는다.

이론적으로 QQ 모델은 mGRE 시퀀스의 MRI 신호의 크기와 위상을 이용해 계산할 수 있지만, 정맥 산소포화도 Y 와 정맥 혈액량 v 의 연관성, qBOLD 역변환에서 잡음 민감성으로 인해 실제 계산이 쉽지 않다[6][7]. 이와 같은 문제를 해결하기 위해 클러스터링을 통해 OEF를 계산한 CCM(Cluster-based Classification and Matching) 방법[6]과 CAT(Cluster Analysis of Time evolution) 방법[7]이 연구되었다.

2.4 딥러닝 이용한 연구

MRI 신호에서 OEF 계산을 위해 신경망을 적용하는 연구도 선행되고 있다[9]. QQ 모델을 기반으로 딥러닝 모델을 적용하여 OEF를 예측하기 위한 연구[8][10]가 진행되었으나 초기 단계이며, 아직까지 관련 연구가 활발히 진행된 사례가 많지 않다.

III. 뇌 MRI에서 QQ 모델을 이용한 DNN 기반 OEF 예측 방법

본 절에서는 빠르고 정확한 OEF 계산을 위해서 뇌 MRI에 대해서 QQ 모델을 기반으로 DNN(Deep Neural Network)을 이용하여 OEF를 예측하는 방법을 제안한다.

3.1 DNN 모델 입력 및 출력

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

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

여기서, Y 는 정맥 산소포화도(Oxygenation), v 는 정맥 혈액량(Blood volume), R_2 는 BOLD 효과가 없는 조직의 가로 이완(Transverse relaxation), S_0 는 에코 타임(TE) 0에서의 신호 세기, χ_{nb} 는 비혈류 물질의 자화율(Non-blood susceptibility)이다. 또한, w 는 QSM 가중치, λ 는 정규화 가중치이다. FQSM 모델 및 SqBOLD 모델은 Lee 및 Cho et al에 구체적으로 제시되어 있다[6][7].

OEF는 식 (2)와 같이 정맥 산소포화도 Y 를 이용하여 계산할 수 있다. Y_a 는 동맥 산소화 값으로서 동맥에서 산소화에 대한 실험을 통해 통상적으로 인정되는 값인 0.98를 가정하였다[7].

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

DNN 모델을 위한 입력 및 출력 데이터는 코넬 대학교 의과대학의 CAT 방법을 위하여 구축한 데이터셋을 이용하였다[7]. 이 데이터셋은 QQ 모델의 입력값($Y, v, R_2, S_0, \chi_{nb}$)와 7개 에코 타임에서의 MRI 신호값과 자화율로 구성되어 있다[6].

제안하는 DNN 모델에서는 MRI 촬영으로 획득한 에코 시간에서 7개의 신호값과 1개의 자화율을 입력으로 이용하였고, OEF 계산에 사용하는 QQ 모델의 파라미터인 정맥 산소포화도, 정맥 혈액량, 조직의 가로 이완, 에코 타임(TE) 0에서의 신호 세기, 비 혈류 물질의 자화율을 출력으로 구성하였다.

3.2 DNN 모델

본 논문에서 설계한 DNN 모델의 구조를 그림 1에 나타내었다. 여러 구조를 설계한 후에 실험을 진행하여 적합한 깊이의 모델을 선정하였고 최적화를 수행하였다.

에코 시간에서 7개의 MRI 신호값과 1개의 자화율을 의미하는 입력 8개에 대응하는 8개 노드의 입력 계층을 생성하였고, 은닉 계층은 총 4개를 생성하였다. 노드 개수를 512개에서 점점 줄여 QQ 모델의 입력 파라미터에 대응하는 5개 노드의 출력 계층을 생성하였다.

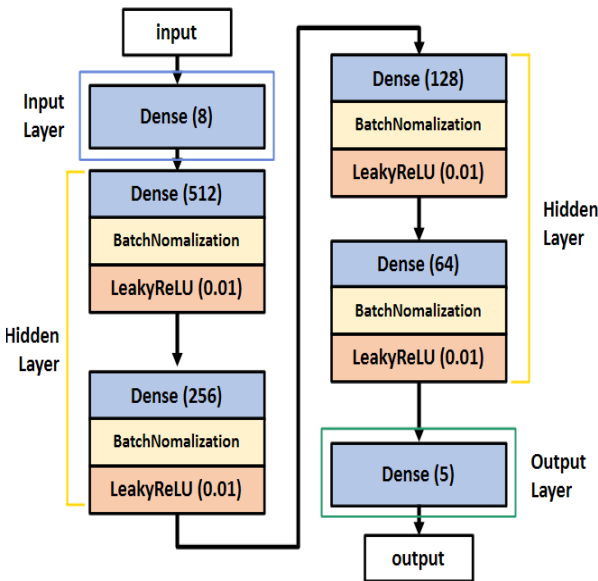


그림 1. OEF 예측을 위한 DNN 모델 구조
Fig. 1. Structure of DNN model for predicting OEF

은닉 계층에서 노드 개수를 줄여가며 Dense 계층을 쌓았고, 과적합 문제를 해소하기 위해 배치 정규화 처리를 반복적으로 수행하였다. 또한 가중치 업데이트를 위한 활성화 함수는 LeakyReLU를 적용하여 양수값은 유지하며, 음수값은 0.01로 스케일링 처리를 하였다.

3.3 DNN 모델 학습과 검증

코넬대학교 의과대학의 데이터셋 중 17명의 환자 데이터를 이용하여 학습과 검증을 수행하였다.

이 데이터셋은 3차원으로 구성된 뇌 MRI 신호값과 자화율을 포함하고 있으며, 대응하는 QQ 모델의 정맥 산소포화도, 정맥 혈액량, 조직의 가로 이완, TE 0에서의 신호 세기, 비 혈류 물질의 자화율의 Ground Truth 값으로 구성되어 있다[6][7].

3차원 구조의 값들을 1차원으로 선형화 변환하여 메모리에 적재한 후 학습과 검증, 평가에 적합하도록 데이터를 분할하여 사용하였다. 환자 17명 중 학습과 검증에 6명의 환자 데이터(P1, P2, P10, P14, P15, P17)를 사용하였고 Train : Validation = 8 : 2의 비율로 분할하였다. 평가는 학습과 검증에 사용한 6명을 제외한 11명의 환자 데이터를 사용하였다.

제안하는 DNN 모델의 학습률은 $1e-4$ 로 설정하

였고, 손실 함수는 평균 제곱근 오차(RMSE, Root Mean Square Error), 최적화 함수는 Huber를 사용하였다.

IV. 실험 결과 및 분석

제안하는 방법은 인텔 i7-7700 CPU, nVidia RTX 3090 GPU, 32GB RAM 하드웨어 및 Windows 10 Pro 운영체제에서 Tensorflow의 Keras로 구현하였다.

4.1 학습과 검증 정확도

DNN 모델의 학습은 256 배치 크기로 최대 100 Epoch으로 진행하였다. 또한, 학습 과정에서 검증 데이터의 손실값에 변화가 없으면 학습을 조기 종료하도록 하였다.

표 1에는 각 Epoch에 따른 OEF 예측 RMSE 정확도와 손실률을 나타내었다. RMSE 및 Loss가 급격히 수렴하는 특성을 보이는 것을 알 수 있다. 19 Epoch에서 Loss가 0.03%로 가장 작았고, 24 Epoch에서 0.27 RMSE로 높은 정확도를 갖고 있었으나 수렴한 이후에는 다른 Epoch과 RMSE와 Loss의 차이가 크지 않은 것을 알 수 있다. 이와 같은 차이는 학습을 계속 수행하며 학습 데이터가 변경되는 것에 의하여 발생하는 미세한 차이이다.

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	0.03751	0.30874	14	0.03372	0.27449
2	0.03608	0.29476	15	0.03368	0.27425
3	0.03550	0.28486	16	0.03384	0.27812
4	0.03520	0.28459	17	0.03412	0.27597
5	0.03635	0.29457	18	0.03540	0.28140
6	0.03564	0.28706	19	0.03358	0.27389
7	0.03493	0.27961	20	0.03513	0.28957
8	0.03489	0.28109	21	0.03390	0.27706
9	0.03428	0.27731	22	0.03379	0.27683
10	0.03400	0.27758	23	0.03387	0.27728
11	0.03479	0.28020	24	0.03364	0.27388
12	0.03465	0.28774	25	0.03429	0.27724
13	0.03425	0.27758	26	0.03380	0.27622

4.2 평가 정확도

OEF 예측을 위해 학습된 제안하는 DNN 모델에 대하여 학습과 검증에 사용하지 않은 환자 11명의 평가 데이터를 사용하여 평균 RMSE를 계산하여 성능 평가를 진행하였다.

DNN 모델의 출력은 OEF를 예측하는데 필요한 정맥 산소포화도를 포함하여 QQ 모델의 5개 매개 변수로서 성능을 확인하기 위해서는 Ground Truth 데이터와 출력된 데이터의 비교가 필요하다. 표 2에는 Ground Truth 데이터와 출력된 데이터에 대한 RMSE를 제시하였다. TE 0에서 신호 세기 S_0 , BOLD 효과가 없는 조직의 가로 이완 R_2 , 정맥 산소포화도 Y , 정맥 혈액량 v , 비혈류 물질의 자화율 χ_{nb} 를 높은 정확도로 예측하는 것을 알 수 있다.

표 3은 전체 환자 데이터에 대하여 학습 데이터 포함 여부, 실제와 예측한 OEF 차이에 대한 RMSE를 나타낸다. 코넬대학교 의과대학 데이터셋은 MRI 신호값에 SNR=100 수준의 가우시안 잡음이 포함되어 있어서 RMSE 오류가 필수적으로 발생한다. 학습에 사용한 데이터의 경우 평균적 OEF RMSE는 5.77이지만 학습에 사용하지 않은 데이터의 경우 6.00으로 약간 RMSE 오류가 증가하는 것을 알 수 있다.

그림 2에 Ground Truth와 뇌 MRI 신호에서 DNN 모델을 이용하여 예측한 OEF를 도시하였다. 예측한 OEF가 Ground Truth와 상당한 수준으로 일치하는 것을 알 수 있다.

표 2. 평가 데이터에 대한 DNN 모델의 RMSE
Table 2. RMSE of DNN model for evaluation data

	S_0	R_2	Y	v	χ_{nb}
P3	0.004494	0.696011	0.062582	0.003044	0.007087
P4	0.011384	1.583853	0.005423	0.002520	0.007004
P5	0.010122	1.803676	0.061239	0.001983	0.004998
P6	0.006819	0.796106	0.053430	0.001996	0.006182
P7	0.006225	1.440337	0.040439	0.010112	0.007598
P8	0.006847	1.361436	0.071900	0.001942	0.007257
P9	0.010827	1.553215	0.061123	0.002045	0.005598
P11	0.004311	0.630823	0.060934	0.003337	0.004594
P12	0.003889	0.676663	0.060858	0.002706	0.005166
P13	0.012415	2.377857	0.077583	0.003289	0.014680
P16	0.005957	1.324784	0.045102	0.001957	0.004201
Average	0.007572	1.294978	0.059038	0.003176	0.006760

표 3. 환자별 OEF 예측의 RMSE

Table 3. RMSE of OEF prediction for each patients

Patient no.	Train	Predicted OEF RMSE
P1	O	5.02
P2	O	7.86
P10	O	3.84
P14	O	7.72
P15	O	5.43
P17	O	4.79
Average		5.77
P3	X	6.14
P4	X	5.77
P5	X	5.83
P6	X	5.49
P7	X	4.02
P8	X	7.05
P9	X	6.07
P11	X	6.57
P12	X	6.31
P13	X	8.26
P16	X	4.50
Average		6.00

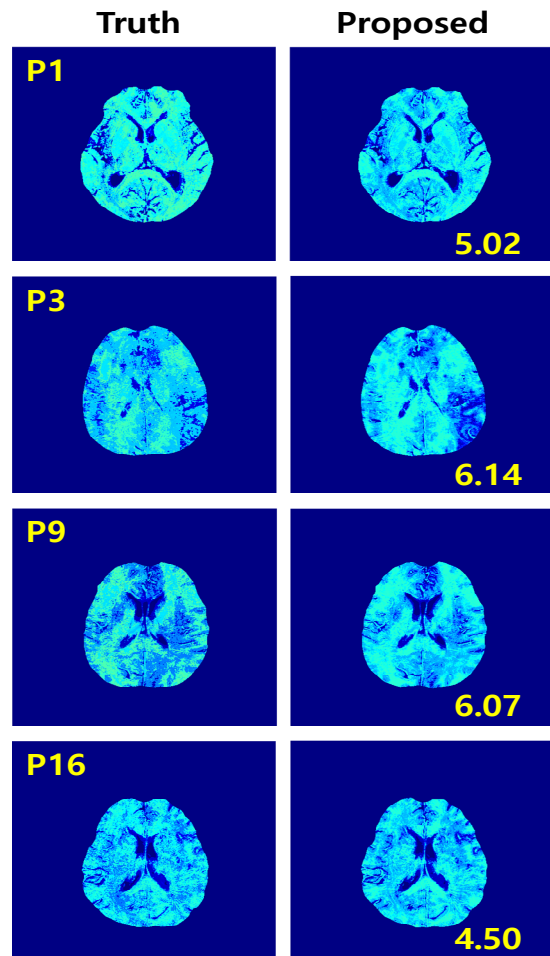


그림 2. Ground truth와 제안하는 방법의 OEF 예측 결과
Fig. 2. Ground truth and OEF prediction result of proposed method

표 4에 기존 CAT 방법[7], CCM 방법[6]과 제안하는 방법에 대하여 OEF 예측에 대한 평균 RMSE를 정리하였다. 동일한 코넬대학교 의과대학의 데이터셋에서 학습과 평가에 사용한 환자의 번호는 차이가 있으나, 제안하는 방법이 높은 수준의 RMSE 정확도를 갖고 있음을 확인할 수 있다.

실험 결과를 통하여 뇌 MRI에 대해서 QQ 모델을 이용하여 DNN 기반 딥러닝 모델로 OEF를 효율로 계산할 수 있는 것을 알 수 있고, 기존 클러스터 기반 CCM 방법[6] 및 CAT 방법[7]에 비해 높은 정확도를 달성할 수 있는 것을 확인할 수 있다.

표 4. 기존 방법 및 제안하는 방법의 OEF RMSE 비교
Table 4. Comparison of OEF RMSE for CAT method, CCM method and proposed method

	CAT method[7]	CCM method[6]	Proposed method
Method	7.66	6.20	6.00

V. 결론 및 향후 과제

뇌 질환의 진단 기법 중 조직 내에서 사용되는 혈액 내 산소 사용률을 파악하는 방법이 있다. 이를 활용하여 뇌 조직의 활성화 여부를 판단하고 정상 여부를 추정할 수 있다.

산소 사용률 파악을 위해서는 조직 내 산소추출률(OEF)의 계산이 필요하다. 현재까지 OEF를 계산하기 위한 다양한 알고리즘이 제시되었지만, 딥러닝 모델을 사용한 연구는 초기 단계로 아직 활발히 진행되지 않고 있다.

본 논문에서는 QQ 모델을 기반으로 DNN 모델을 구성하여 뇌 MRI를 통해 수집한 8개의 신호 데이터를 통해 QQ 모델의 매개변수를 추정하고 OEF를 예측하는 방법을 제안하였다. 총 17명 환자의 신호 감쇄 및 자화율을 이용하여 제안한 모델에 대하여 학습과 평가를 진행하였다. 본 논문에서는 QQ 모델을 기반으로 OEF를 예측하는데 있어서 기존 방법들과 다르게 DNN 기반 딥러닝 모델을 적용하고 최적화를 수행한 것에 차별성이 있으며, 실험을 통하여 평가 데이터에 대하여 6.00 OEF RMSE 정확도를 달성하여 OEF 계산에서 딥러닝 모델이 유의미한 것을 보이는 기여를 하였다.

추후 연구에서는 뇌 질환의 더욱 정확한 진단을 위하여 제안한 DNN 모델보다 성능이 좋은 인공 네트워크 신경망을 도입하여 더 빠르고 정확한 OEF 값을 예측할 수 있는 연구가 필요하다. 또한 다양한 TE를 고려하기 위하여 뇌 MRI 신호에 대하여 일반화된 모델을 활용할 필요가 있다[13].

References

- [1] H. Noh, J. Seo, S. Lee, N. Yi, S. Park, Y. J. Choi, and S. H, "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. Spincemille, 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] 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>.
- [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] 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, Y. U. Choi, and H. Y. Lee, "OEF Calculation on MRI Brain Image using DNN", Proc. of KIIT Conference, Jeju, Korea, pp. 471-473, Jun. 2022.
- [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] W. Yi and T. Liu, "Quantitative susceptibility mapping (QSM): decoding MRI data for a tissue magnetic biomarker", Magnetic Resonance in Medicine, Vol. 73, No. 1, pp. 82-101, Jul. 2014. <https://doi.org/10.1002/mrm.25358>.
- [13] H. Y. Lee, "OEF Calculation Algorithm using Generalized QQ Model Clustering through Brain MRI Signal Decay Modeling", Journal of KIIT, Vol. 20, No. 5, pp. 1-8, May 2022. <https://doi.org/10.14801/jkiit.2022.20.5.1>.

저자소개

김 현 수 (Hyeon-Su Kim)



2023년 6월 현재 : 금오공과대학교
컴퓨터소프트웨어공학과
학사과정
관심분야 : 영상 처리, 딥 러닝

이 해 연 (Hae-Yeoun Lee)



1997년 : 성균관대학교 정보공학과
(공학사)
1999년 : KAIST 전산학과
(공학석사)
2006년 : KAIST 전자전산학과
(공학박사)
2008년 ~ 현재 : 금오공과대학교
컴퓨터소프트웨어공학과 교수
관심분야 : Digital Forensics, Image Processing, IoT