



(19) 대한민국특허청(KR)  
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0078217  
(43) 공개일자 2023년06월02일

(51) 국제특허분류(Int. Cl.)

A61B 5/055 (2006.01) A61B 5/00 (2021.01)  
G01R 33/48 (2006.01) G01R 33/56 (2006.01)  
G06T 7/00 (2017.01)

(52) CPC특허분류

A61B 5/055 (2022.01)  
A61B 5/0042 (2013.01)

(21) 출원번호 10-2021-0165765

(22) 출원일자 2021년11월26일

심사청구일자 2021년11월26일

(71) 출원인

연세대학교 산학협력단

서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)

(72) 발명자

김동현

서울특별시 서초구 남부순환로323길 56-18, 101동 502호(서초동, 경남아너스빌 101동)

정규진

서울특별시 강동구 고덕로 360, 322동 504호(상일동, 고덕아르테온)

(74) 대리인

특허법인우인

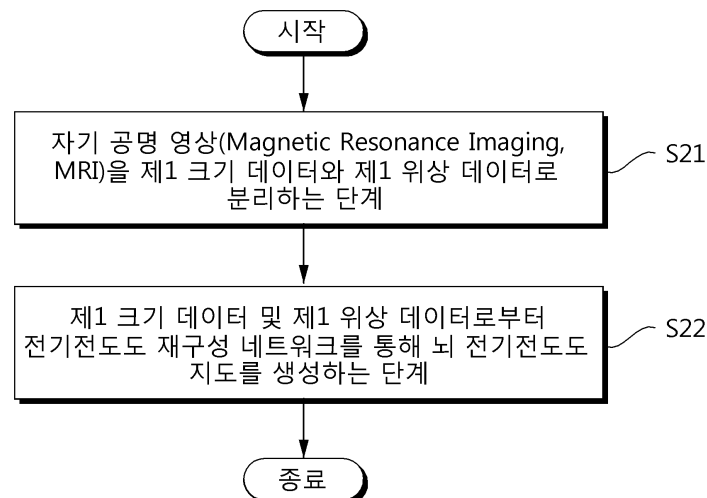
전체 청구항 수 : 총 20 항

(54) 발명의 명칭 자기 공명 영상으로부터 뇌 전기전도도 지도를 재구성하는 방법 및 장치

(57) 요약

본 실시예들은 시뮬레이션 데이터를 기반으로 가상의 자기 공명 영상 데이터와 검증 전기전도도 지도 데이터를 생성하고, 가상의 자기 공명 영상 데이터에 노이즈를 추가하여 미리 설계된 딥러닝 네트워크를 훈련시킴으로써, 낮은 SNR을 갖는 고해상도의 임상 데이터에 대해서 뇌 전기전도도 지도를 재구성 가능한 뇌 전기전도도 지도 재구성 장치 및 방법을 제공한다.

대표도 - 도13



(52) CPC특허분류

*A61B 5/4064* (2021.01)  
*A61B 5/7203* (2013.01)  
*G01R 33/4806* (2013.01)  
*G01R 33/5608* (2013.01)  
*G06T 7/0012* (2013.01)  
*G06T 2207/10088* (2013.01)  
*G06T 2207/20081* (2013.01)  
*G06T 2207/30016* (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711142634
과제번호	2019R1A2C1090635
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	중견연구자지원사업
연구과제명	물리기반 머신러닝을 이용한 자기공명영상 생리적 아티팩트 범용 보정 기법

개발(3/4)

기 여 율	1/2
과제수행기관명	연세대학교
연구기간	2021.03.01 ~ 2022.02.28

이 발명을 지원한 국가연구개발사업

과제고유번호	1711120084
과제번호	2020-0-01461-001
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성(R&D)
연구과제명	지능형 의료영상 진단 솔루션 개발
기 여 율	1/2
과제수행기관명	아주대학교산학협력단
연구기간	2020.07.01 ~ 2020.12.31

---

## 명세서

### 청구범위

#### 청구항 1

뇌 전기전도도 지도 재구성 방법에 있어서,

자기 공명 영상(Magnetic Resonance Imaging, MRI)을 제1 크기 데이터와 제1 위상 데이터로 분리하는 단계;

상기 제1 크기 데이터 및 상기 제1 위상 데이터로부터 전기전도도 재구성 네트워크를 통해 뇌 전기전도도 지도를 생성하는 단계를 포함하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 2

제1항에 있어서,

상기 전기전도도 재구성 네트워크는,

시뮬레이션 데이터를 기반으로 노이즈가 없는 가상 MRI 영상을 합성하는 단계;

상기 시뮬레이션 데이터를 기반으로 검증 전기전도도 지도를 생성하는 단계;

상기 가상 MRI 영상에 노이즈를 추가하는 단계;

상기 노이즈가 추가된 가상 MRI 영상 및 상기 검증 전기전도도 지도를 이용하여 네트워크 학습을 수행하는 단계를 거쳐 학습되는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 3

제2항에 있어서,

상기 시뮬레이션 데이터는,

시뮬레이션 인체 팬텀 및 무선 주파수(Radio Frequency, RF) 코일을 이용하여 시뮬레이션 환경을 구성하고 노이즈가 없는 RF 자기장, 전류밀도, 전기장에 관한 데이터를 획득하여 형성되는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 4

제3항에 있어서,

상기 노이즈가 없는 가상 MRI 영상은,

상기 RF 자기장, 콘트라스트를 설정하는데 필요한 반복 시간(TR) 및 에코 시간(TE), 인체 뇌 영역을 구분하는데 필요한 제1 이완 시간(T1) 및 제2 이완 시간(T2)를 포함하는 관계식을 통해 획득되는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 5

제3항에 있어서,

상기 검증 전기전도도 지도는,

상기 전류밀도 및 상기 전기장을 포함하는 관계식을 통해 획득되는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 6

제2항에 있어서,

상기 가상 MRI 영상에 노이즈를 추가하는 단계는,

상기 가상 MRI 영상을 제1 실수 데이터와 제1 허수 데이터로 분리하고, 상기 제1 실수 데이터 및 상기 제1 허수 데이터 각각에 노이즈를 추가하고, 다시 통합하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 7

제2항에 있어서,

상기 네트워크 학습을 수행하는 단계는,

상기 노이즈가 추가된 가상 MRI 영상을 제2 크기 데이터와 제2 위상 데이터로 분리하고, 상기 제2 크기 데이터 및 상기 제2 위상 데이터 각각을 전기전도도 재구성 네트워크에 입력하여 상기 제2 크기 데이터 및 상기 제2 위상 데이터의 커널 매트릭스로부터 커널 포인트에 대한 전기전도도를 추정하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 8

제7항에 있어서,

상기 네트워크 학습을 수행하는 단계는,

상기 전기전도도 재구성 네트워크의 레이블을 상기 검증 전기전도도 지도를 기반으로 동일한 위치에 매칭하는 커널의 중심에 해당하는 값으로 지정하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 9

제7항에 있어서,

상기 네트워크 학습을 수행하는 단계는,

매 훈련 과정마다 상기 제1 크기 데이터에 바이어스를 인가하여 위상에 대한 의존성을 생성하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 10

제7항에 있어서,

상기 네트워크 학습을 수행하는 단계는,

매 훈련 과정마다 상기 제1 실수 데이터 및 상기 제1 허수 데이터에 반영하는 노이즈 분포를 상이하게 업데이트 하여 훈련하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 방법.

#### 청구항 11

프로세서 및 상기 프로세서에 의해 실행되는 프로그램을 저장하는 저장 매체를 포함하는 뇌 전기전도도 지도 재구성 장치에 있어서,

상기 프로세서는,

자기 공명 영상(Magnetic Resonance Imaging, MRI)을 제1 크기 데이터와 제1 위상 데이터로 분리하고,

상기 제1 크기 데이터 및 상기 제1 위상 데이터로부터 전기전도도 재구성 네트워크를 통해 뇌 전기전도도 지도를 생성하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

#### 청구항 12

제11항에 있어서,

상기 전기전도도 재구성 네트워크는,

시뮬레이션 데이터를 기반으로 노이즈가 없는 가상 MRI 영상을 합성하고,

상기 시뮬레이션 데이터를 기반으로 검증 전기전도도 지도를 생성하고,

상기 가상 MRI 영상에 노이즈를 추가하고,

상기 노이즈가 추가된 가상 MRI 영상 및 상기 검증 전기전도도 지도를 이용하여 네트워크 학습을 수행하는 과정을 거쳐 학습되는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

#### 청구항 13

제12항에 있어서,

상기 시뮬레이션 데이터는,

시뮬레이션 인체 팬텀 및 무선 주파수(Radio Frequency, RF) 코일을 이용하여 시뮬레이션 환경을 구성하고 노이즈가 없는 RF 자기장, 전류밀도, 전기장에 관한 데이터를 획득하여 형성되는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

#### 청구항 14

제13항에 있어서,

상기 노이즈가 없는 가상 MRI 영상은,

상기 RF 자기장, 콘트라스트를 설정하는데 필요한 반복 시간(TR) 및 에코 시간(TE), 인체 뇌 영역을 구분하는데 필요한 제1 이완 시간(T1) 및 제2 이완 시간(T2)를 포함하는 관계식을 통해 획득되는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

#### 청구항 15

제13항에 있어서,

상기 검증 전기전도도 지도는,

상기 전류밀도 및 상기 전기장을 포함하는 관계식을 통해 획득되는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

#### 청구항 16

제12항에 있어서,

상기 전기전도도 재구성 네트워크는,

상기 가상 MRI 영상을 제1 실수 데이터와 제1 허수 데이터로 분리하고, 상기 제1 실수 데이터 및 상기 제1 허수 데이터 각각에 노이즈를 추가하고, 다시 통합하는 과정을 거쳐, 상기 노이즈가 추가된 가상 MRI 영상을 적용하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

#### 청구항 17

제12항에 있어서,

상기 전기전도도 재구성 네트워크는,

상기 노이즈가 추가된 가상 MRI 영상을 제2 크기 데이터와 제2 위상 데이터로 분리하고, 상기 제2 크기 데이터 및 상기 제2 위상 데이터 각각을 전기전도도 재구성 네트워크에 입력하여 상기 제2 크기 데이터 및 상기 제2 위상 데이터의 커널 매트릭스로부터 커널 포인트에 대한 전기전도도를 추정하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

#### 청구항 18

제17항에 있어서,

상기 전기전도도 재구성 네트워크는,

상기 전기전도도 재구성 네트워크의 레이블을 상기 검증 전기전도도 지도를 기반으로 동일한 위치에 매칭하는 커널의 중심에 해당하는 값으로 지정하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

#### 청구항 19

제17항에 있어서,

상기 전기전도도 재구성 네트워크는,

매 훈련 과정마다 상기 제1 크기 데이터에 바이어스를 인가하여 위상에 대한 의존성을 생성하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

## 청구항 20

제17항에 있어서,

상기 전기전도도 재구성 네트워크는,

매 훈련 과정마다 상기 제1 실수 데이터 및 상기 제1 허수 데이터에 반영하는 노이즈 분포를 상이하게 업데이트 하여 훈련하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치.

## 발명의 설명

### 기술 분야

[0001] 본 발명이 속하는 기술 분야는 자기 공명 영상(MRI) 장치를 사용하여 인체 조직의 전기적 특성을 측정하는 비침습적 영상 기술인 전기적 특성 영상 재구성(Electrical Properties Tomography, EPT)에 관한 것이다.

### 배경 기술

[0002] 이 부분에 기술된 내용은 단순히 본 실시예에 대한 배경 정보를 제공할 뿐 종래기술을 구성하는 것은 아니다.

[0003] EPT(Electrical properties tomography)는 자기 공명 영상(Magnetic Resonance Imaging, MRI) 장치를 사용하여 인체 조직의 전기적 특성 (전기전도도  $\sigma$  및 유전율  $\epsilon$ )을 측정하는 비침습적 영상 재구성 기술이다. 이러한 전기적 특성은 MRI 장치로부터 체내에 유도되는 무선 주파수(Radio Frequency, RF) 자기장 정보를 활용하여 측정할 수 있다.

### 선행기술문헌

#### 특허문헌

[0004] (특허문헌 0001) KR 10-1995900 (2019.06.27)

#### 비특허문헌

[0005] (비특허문헌 0001) MANDIJA, Stefano, et al. Opening a new window on MR-based Electrical Properties Tomography with deep learning. Scientific reports, 2019, 9.1: 1-9.

(비특허문헌 0002) LEIJSEN, Reijer, et al. Combining deep learning and 3D contrast source inversion in MR-based electrical properties tomography. NMR in Biomedicine, 2019, e4211.

(비특허문헌 0003) HAMPE, Nils, et al. Investigating the challenges and generalizability of deep learning brain conductivity mapping. Physics in Medicine & Biology, 2020, 65.13: 135001.

(비특허문헌 0004) LEE, Mun Bae, et al. High-frequency conductivity at Larmor-frequency in human brain using moving local window multilayer perceptron neural network. Plos one, 2021, 16.5: e0251417.

## 발명의 내용

### 해결하려는 과제

[0006] 본 발명의 실시예들은 시뮬레이션 데이터를 기반으로 가상의 자기 공명 영상 데이터와 검증 전기전도도 지도 데이터를 생성하고, 가상의 자기 공명 영상 데이터에 노이즈를 추가하여 미리 설계된 딥러닝 네트워크를 훈련시킴

으로써, 낮은 SNR을 갖는 고해상도의 임상 데이터에 대해서 뇌 전기전도도 지도를 재구성하는데 주된 목적이 있다.

[0007] 본 발명의 명시되지 않은 또 다른 목적들은 하기의 상세한 설명 및 그 효과로부터 용이하게 추론할 수 있는 범위 내에서 추가적으로 고려될 수 있다.

### 과제의 해결 수단

[0008] 본 실시예의 일 측면에 의하면 뇌 전기전도도 지도 재구성 방법에 있어서, 자기 공명 영상(Magnetic Resonance Imaging, MRI)을 제1 크기 데이터와 제1 위상 데이터로 분리하는 단계; 상기 제1 크기 데이터 및 상기 제1 위상 데이터로부터 전기전도도 재구성 네트워크를 통해 뇌 전기전도도 지도를 생성하는 단계를 포함하는 뇌 전기전도도 지도 재구성 방법을 제공한다.

[0009] 상기 전기전도도 재구성 네트워크는, 시뮬레이션 데이터를 기반으로 노이즈가 없는 가상 MRI 영상을 합성하는 단계; 상기 시뮬레이션 데이터를 기반으로 검증 전기전도도 지도를 생성하는 단계; 상기 가상 MRI 영상에 노이즈를 추가하는 단계; 상기 노이즈가 추가된 가상 MRI 영상 및 상기 검증 전기전도도 지도를 이용하여 네트워크 학습을 수행하는 단계를 거쳐 학습될 수 있다.

[0010] 상기 시뮬레이션 데이터는, 시뮬레이션 인체 팬텀 및 무선 주파수(Radio Frequency, RF) 코일을 이용하여 시뮬레이션 환경을 구성하고 노이즈가 없는 RF 자기장, 전류밀도, 전기장에 관한 데이터를 획득하여 형성될 수 있다.

[0011] 상기 노이즈가 없는 가상 MRI 영상은, 상기 RF 자기장, 콘트라스트를 설정하는데 필요한 반복 시간(TR) 및 에코 시간(TE), 인체 뇌 영역을 구분하는데 필요한 제1 이완 시간(T1) 및 제2 이완 시간(T2)를 포함하는 관계식을 통해 획득될 수 있다.

[0012] 상기 검증 전기전도도 지도는, 상기 전류밀도 및 상기 전기장을 포함하는 관계식을 통해 획득될 수 있다.

[0013] 상기 가상 MRI 영상에 노이즈를 추가하는 단계는, 상기 가상 MRI 영상(복소수)을 제1 실수 데이터와 제1 허수 데이터로 분리하고, 상기 제1 실수 데이터 및 상기 제1 허수 데이터 각각에 노이즈를 추가하고, 다시 통합할 수 있다.

[0014] 상기 네트워크 학습을 수행하는 단계는, 상기 노이즈가 추가된 가상 MRI 영상을 제2 크기 데이터와 제2 위상 데이터로 분리하고, 상기 제2 크기 데이터 및 상기 제2 위상 데이터 각각을 전기전도도 재구성 네트워크에 입력하여 상기 제2 크기 데이터 및 상기 제2 위상 데이터의 커널 매트릭스로부터 커널 포인트에 대한 전기전도도를 추정할 수 있다.

[0015] 상기 네트워크 학습을 수행하는 단계는, 상기 전기전도도 재구성 네트워크의 레이블을 상기 검증 전기전도도 지도를 기반으로 동일한 위치에 매칭하는 커널의 중심에 해당하는 값으로 지정할 수 있다.

[0016] 상기 네트워크 학습을 수행하는 단계는, 매 훈련 과정마다 상기 제1 크기 데이터에 바이어스를 인가하여 위상에 대한 의존성을 생성할 수 있다.

[0017] 상기 네트워크 학습을 수행하는 단계는, 매 훈련 과정마다 상기 제1 크기 데이터 및 상기 제1 위상 데이터에 반영하는 노이즈 분포를 상이하게 업데이트하여 훈련할 수 있다.

[0018] 본 실시예의 다른 측면에 의하면 프로세서 및 상기 프로세서에 의해 실행되는 프로그램을 저장하는 저장 매체를 포함하는 뇌 전기전도도 지도 재구성 장치에 있어서, 상기 프로세서는, 자기 공명 영상(Magnetic Resonance Imaging, MRI)을 제1 크기 데이터와 제1 위상 데이터로 분리하고, 상기 제1 크기 데이터 및 상기 제1 위상 데이터로부터 전기전도도 재구성 네트워크를 통해 뇌 전기전도도 지도를 생성하는 것을 특징으로 하는 뇌 전기전도도 지도 재구성 장치를 제공한다.

### 발명의 효과

[0019] 이상에서 설명한 바와 같이 본 발명의 실시예들에 의하면, 시뮬레이션 데이터를 기반으로 가상의 자기 공명 영상 데이터와 검증 전기전도도 지도 데이터를 생성하고, 가상의 자기 공명 영상 데이터에 노이즈를 추가하여 미리 설계된 딥러닝 네트워크를 훈련시킴으로써, 낮은 SNR을 갖는 고해상도의 임상 데이터에 대해서 뇌 전기전도도 지도를 재구성할 수 있는 효과가 있다.

[0020] 여기에서 명시적으로 언급되지 않은 효과라 하더라도, 본 발명의 기술적 특징에 의해 기대되는 이하의 명세서에서 기재된 효과 및 그 잠정적인 효과는 본 발명의 명세서에 기재된 것과 같이 취급된다.

### 도면의 간단한 설명

[0021] 도 1은 기존의 EPT 재구성 방식에서 수식적 가정에 따른 에러를 예시한 도면이다.  
 도 2는 기존의 EPT 재구성 방식에서 잡음 증폭을 예시한 도면이다.  
 도 3은 수학적 극복을 시도하는 EPT 재구성 방식에서 수식적 가정에 따른 에러를 예시한 도면이다.  
 도 4 및 도 5는 수학적 극복을 시도하는 다른 EPT 재구성 방식의 문제를 예시한 도면이다.  
 도 6은 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치를 예시한 도면이다.  
 도 7은 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치의 시뮬레이션 환경을 예시한 도면이다.  
 도 8 내지 도 10은 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치의 시뮬레이션 데이터를 예시한 도면이다.  
 도 11은 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치의 전기전도도 재구성 네트워크를 예시한 도면이다.  
 도 12는 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치의 네트워크 학습을 예시한 도면이다.  
 도 13 및 도 14는 본 발명의 다른 실시예에 따른 뇌 전기전도도 지도 재구성 방법을 예시한 도면이다.  
 도 15 내지 도 17은 본 발명의 실시예들에 따라 시뮬레이션을 수행한 결과를 예시한 도면이다.

### 발명을 실시하기 위한 구체적인 내용

[0022] 이하, 본 발명을 설명함에 있어서 관련된 공지기능에 대하여 이 분야의 기술자에게 자명한 사항으로서 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명을 생략하고, 본 발명의 일부 실시예들을 예시적인 도면을 통해 상세하게 설명한다.

[0023] 도 1은 기존의 EPT 재구성 방식에서 수식적 가정에 따른 에러를 예시한 도면이고, 도 2는 기존의 EPT 재구성 방식에서 잡음 증폭을 예시한 도면이고, 도 3은 수학적 극복을 시도하는 EPT 재구성 방식에서 수식적 가정에 따른 에러를 예시한 도면이고, 도 4 및 도 5는 수학적 극복을 시도하는 다른 EPT 재구성 방식의 문제를 예시한 도면이다.

[0024] 전기전도도와 같은 인체 조직의 전기적 특성은 MRI 장치로부터 체내에 유도되는 RF 자기장 정보를 활용하여 측정할 수 있다. 임상 환경에서 활용되는 스핀-에코 기반의 영상에 맥스웰(Maxwell) 방정식 및 수학적 가정들을 통해 유도된 헬름홀츠(Helmholtz) 방정식을 사용하여 체내 전기전도도 값을 추정할 수 있다. 예컨대, 페이즈(Phase) 기반 전기전도도 재구성 방법을 적용할 수 있다. 인체 조직에 대한 전기전도도 지도는 MRI 장치에 의한 SAR 측정 및 병리 진단을 위한 정량적 바이오마커로 활용 가능하다.

[0025] 헬름홀츠 방정식(Helmholtz equation)은 수학적 1과 같이 표현된다.

### 수학적 1

$$-\nabla^2 \mathbf{H} = \frac{\nabla \kappa}{\kappa} \times (\nabla \times \mathbf{H}) + \omega^2 \mu \kappa \mathbf{H}$$

[0026]

[0027] H는 자기장이고,  $k = \sigma + i\omega\epsilon$  이고  $\sigma$ 는 conductivity (전기전도도)이고,  $\epsilon$ 는 permittivity (유전율)이고,  $\omega$ 는 angular frequency (각 주파수)이고,  $\mu$ 는 permeability (투자율)이고,  $\kappa$ 는 complex permittivity (복소수 유전율 =  $a + bi$  형태의 표현, a부분은 실수, bi부분은 허수를 의미)를 나타낸다.

[0028] 수학적 1로부터 Truncated-Helmholtz equation (페이즈 기반 전기전도도 재구성을 사용하기 위한 수식) 유도가 가능하다.



## 수학식 2

$$-\nabla^2 \mathbf{H} = \frac{\nabla(\sigma + i\omega\epsilon)}{\sigma + i\omega\epsilon} \times (\nabla \times \mathbf{H}) - i\omega\mu(\sigma + i\omega\epsilon)\mathbf{H}$$

[0029]

[0030]

조각 상수(piecewise constant) 가정 ( $\nabla \kappa \approx \mathbf{0}$ ): 체내의 전기전도도나 유전율은 변하지 않는다. 하지만 실제로는 다양한 신체 조직 구성(예: 뇌척수액, 백색질, 회색질)으로 인해 변하기 때문에 오류가 발생하게 된다.

[0031]

페이즈 기반 전기전도도 재구성 수식(Phase-based EPT)은 수학식 3 및 수학식 4와 같이 표현된다.

## 수학식 3

$$\sigma(\mathbf{r}) + i\omega\epsilon(\mathbf{r}) \approx \frac{\nabla^2 H^+(\mathbf{r})}{i\omega\mu H^+(\mathbf{r})}$$

[0032]

## 수학식 4

$$\sigma \approx \frac{\nabla^2 \varphi_{\pm}}{2\mu_0 \omega}$$

[0033]

[0034]

도 1을 참조하면, Helmholtz 수식은 수많은 수학적 가정들이 포함되어 있기 때문에 정답(Ground-truth)과 비교하여 상이한 결과를 보여준다.

[0035]

전기전도도 지도 재구성 과정에는 몇 가지 문제점들이 존재한다. 잡음 증폭, 경계 아티팩트, 제한적인 실질적 영상 해상도, 검증(Ground-truth) 전기전도도 값에 대한 측정 곤란 등이 대표적인 예시이다.

[0036]

재구성 연산에 사용되는 공간적 도함수 '라플라시안(Laplacian) 연산자'는 재구성 과정에서 잡음을 증폭시켜 결과 영상의 관찰을 어렵게 한다. 전기전도도 재구성 과정에서 사용하는 라플라시안 연산자는 이미지 프로세싱 관점에서 하이 패스 필터(High pass filter)에 해당한다.

[0037]

MRI 하드웨어 관점에서 대상에 대한 촬영 해상도를 낮추거나 반복적인 촬영을 시행하면 획득된 영상의 잡음 억제 효과를 기대할 수 있으나, 실제 임상 환경에서는 환자를 대상으로 하기 때문에 한정된 시간 동안 고해상도 촬영이 요구되어 이러한 접근 방법이 활용되기에는 어려움이 있다.

[0038]

도 2를 참조하면, MRI 이미지는 반드시 잡음을 포함하며, 임상 환경에서 획득하는 스핀-에코 MRI 이미지는 SNR(Signal-to-Noise Ratio)이 대략 20정도에 해당한다. SNR 수치가 낮을수록 잡음을 더욱 많이 포함하고 있음을 의미한다.

[0039]

전기전도도 지도 재구성 과정의 한계점을 극복하고자 다양한 알고리즘 개선의 노력들이 시도되어 왔다. 대표적으로 기존  $N \times N$  크기의 Laplacian 연산자를 큰 사이즈의 이미지 필터로 대체하여 연산 과정에 적용하는 방법이 제안되었다.

[0040]

경계 아티팩트 문제를 해결하기 위해 MRI 영상 속 조직에 대한 분할 정보를 사용하거나 대류-반응 항을 추가한 편미분 방정식 기반 알고리즘들이 제안되었다. 하지만 억제하고자 하는 잡음의 세기만큼 늘어나는 커널 사이즈는 재구성된 전기전도도 지도에 대해 실질적 해상도를 저하시킨다는 한계가 존재한다.

[0041]

다른 재구성 방식으로 미분 연산자의 직접적인 연산을 피하기 위한 적분 기반 방식이 제안되었다. 미분 기반 방식과 비교하여 잡음 증폭, 경계 아티팩트, 실질적 해상도 저하 및 Ground-truth 전기전도도 지도 재구성에 대해 현저히 개선된 성능을 보여주었지만, 연산 과정에서 코일 소스에 대한 사전 정보를 필요로 할 뿐만 아니라

Phase 기반 전기전도도 재구성 알고리즘에는 응용할 수 없기 때문에 임상 환경 적용에는 여전히 어려움이 있다.

[0042] cr(convection-reaction)-EPT(convection-reaction 페이즈-기반 전기전도도 이미지)는 수학식 5와 같이 표현된다.

### 수학식 5

$$-c\nabla^2\rho+(\nabla\varphi^{tr}\cdot\nabla\rho)+\nabla^2\varphi^{tr}\rho-2\omega\mu_0=0$$

[0043]

[0044] c는 diffusion 계수이고, w는 angular frequency (각 주파수)이고,  $\rho$ 는  $1/\sigma$  (=1/전기전도도)이고,  $\mu$ 는 permeability (투자율)이고,  $\varphi^{tr}$ 는 페이즈를 나타낸다.

[0045] 도 3을 참조하면, convection-reaction 페이즈-기반 전기전도도 이미지 수학적 역시 가정으로 인해 Ground-truth 지도와는 거리가 있다.

[0046] 도 4 및 도 5를 참조하면, Volume Integral / CSI EPT (full-equation 기반 전기전도도 이미지)는 Ground-truth 지도에 가까운 도전을 지도를 재구성할 수 있으나 스핀-에코 MRI 영상만으로 재구성이 불가능하다. 재구성 과정에서 B1 크기 영상 및 Coil에 대한 Source 정보가 필요하다. 즉, 실제 임상 데이터에 알고리즘 적용이 현실적으로 곤란하다.

[0047] 이러한 문제를 해결하기 위해서 MRI 뇌 영상으로부터 전기전도도 지도를 재구성하는 딥러닝 네트워크를 제공한다.

[0048] 도 6은 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치를 예시한 도면이다.

[0049] 뇌 전기전도도 지도 재구성 장치(11)는 적어도 하나의 프로세서(120), 컴퓨터 판독 가능한 저장매체(13) 및 통신 버스(17)를 포함한다.

[0050] 프로세서(120)는 장치(11)로 동작하도록 제어할 수 있다. 예컨대, 프로세서(12)는 컴퓨터 판독 가능한 저장 매체(130)에 저장된 하나 이상의 프로그램들을 실행할 수 있다. 하나 이상의 프로그램들은 하나 이상의 컴퓨터 실행 가능 명령어를 포함할 수 있으며, 컴퓨터 실행 가능 명령어는 프로세서(12)에 의해 실행되는 경우 장치(11)로 하여금 예시적인 실시예에 따른 동작들을 수행하도록 구성될 수 있다.

[0051] 컴퓨터 판독 가능한 저장 매체(13)는 컴퓨터 실행 가능 명령어 내지 프로그램 코드, 프로그램 데이터 및/또는 다른 적합한 형태의 정보를 저장하도록 구성된다. 컴퓨터 실행 가능 명령어 내지 프로그램 코드, 프로그램 데이터 및/또는 다른 적합한 형태의 정보는 입출력 인터페이스(15)나 통신 인터페이스(16)를 통해서도 주어질 수 있다. 컴퓨터 판독 가능한 저장 매체(13)에 저장된 프로그램(14)은 프로세서(12)에 의해 실행 가능한 명령어의 집합을 포함한다. 일 실시예에서, 컴퓨터 판독 가능한 저장 매체(13)는 메모리(랜덤 액세스 메모리와 같은 휘발성 메모리, 비휘발성 메모리, 또는 이들의 적절한 조합), 하나 이상의 자기 디스크 저장 디바이스들, 광학 디스크 저장 디바이스들, 플래시 메모리 디바이스들, 그 밖에 뇌 전기전도도 지도 재구성 장치(11)에 의해 액세스되고 원하는 정보를 저장할 수 있는 다른 형태의 저장 매체, 또는 이들의 적합한 조합일 수 있다.

[0052] 통신 버스(17)는 프로세서(12), 컴퓨터 판독 가능한 저장 매체(13)를 포함하여 뇌 전기전도도 지도 재구성 장치(11)의 다른 다양한 컴포넌트들을 상호 연결한다.

[0053] 장치(11)는 또한 하나 이상의 입출력 장치를 위한 인터페이스를 제공하는 하나 이상의 입출력 인터페이스(15) 및 하나 이상의 통신 인터페이스(16)를 포함할 수 있다. 입출력 인터페이스(15) 및 통신 인터페이스(16)는 통신 버스(17)에 연결된다. 입출력 장치(미도시)는 입출력 인터페이스(15)를 통해 장치(11)의 다른 컴포넌트들에 연결될 수 있다.

[0054] 뇌 전기전도도 지도 재구성 장치(11)의 프로세서(12)는 자기 공명 영상(Magnetic Resonance Imaging, MRI)을 제1 크기 데이터와 제1 위상 데이터로 분리하고, 제1 크기 데이터 및 제1 위상 데이터로부터 전기전도도 재구성 네트워크를 통해 뇌 전기전도도 지도를 생성한다.

[0055] 전기전도도 재구성 네트워크는 시뮬레이션 데이터를 기반으로 노이즈가 없는 가상 MRI 영상을 합성하고, 시뮬레이션 데이터를 기반으로 검증 전기전도도 지도를 생성하고, 가상 MRI 영상에 노이즈를 추가하고, 노이즈가 추가

된 가상 MRI 영상 및 검증 전기전도도 지도를 이용하여 네트워크 학습을 수행하는 과정을 거쳐 학습된다.

- [0056] 시뮬레이션 데이터는 시뮬레이션 인체 팬텀 및 무선 주파수(Radio Frequency, RF) 코일을 이용하여 시뮬레이션 환경을 구성하고 노이즈가 없는 RF 자기장, 전류밀도, 전기장에 관한 데이터를 획득하여 형성된다.
- [0057] 노이즈가 없는 가상 MRI 영상은 RF 자기장, 콘트라스트를 설정하는데 필요한 반복 시간(TR) 및 에코 시간(TE), 인체 뇌 영역을 구분하는데 필요한 제1 이완 시간(T1) 및 제2 이완 시간(T2)를 포함하는 관계식을 통해 획득된다.
- [0058] 검증 전기전도도 지도는 전류밀도 및 전기장을 포함하는 관계식을 통해 획득된다.
- [0059] 전기전도도 재구성 네트워크는 가상 MRI 영상을 제1 실수 데이터와 제1 허수 데이터로 분리하고, 제1 실수 데이터 및 제1 허수 데이터 각각에 노이즈를 추가하고, 통합하는 과정을 거쳐, 노이즈가 추가된 가상 MRI 영상을 적용한다.
- [0060] 전기전도도 재구성 네트워크는 노이즈가 추가된 가상 MRI 영상을 제2 크기 데이터와 제2 위상 데이터로 분리하고, 제2 크기 데이터 및 제2 위상 데이터 각각을 전기전도도 재구성 네트워크에 입력하여 제2 크기 데이터 및 제2 위상 데이터의 커널 매트릭스로부터 커널 포인트에 대한 전기전도도를 추정한다.
- [0061] 전기전도도 재구성 네트워크는 전기전도도 재구성 네트워크의 레이블을 검증 전기전도도 지도를 기반으로 동일한 위치에 매칭하는 커널의 중심에 해당하는 값으로 지정한다.
- [0062] 전기전도도 재구성 네트워크는 매 훈련 과정마다 제1 크기 데이터에 바이어스를 인가하여 위상에 대한 의존성을 생성한다. 전기전도도 재구성 네트워크는 매 훈련 과정마다 제2 크기 데이터 및 제2 위상 데이터에 반영하는 노이즈 분포를 상이하게 업데이트하여 훈련한다.
- [0063] 도 7은 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치의 시뮬레이션 환경을 예시한 도면이고, 도 8 내지 도 10은 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치의 시뮬레이션 데이터를 예시한 도면이다.
- [0064] 임상 목적으로 획득하는 MRI 영상은 전기전도도 재구성 과정에서 재구성 영상 왜곡의 원인이 되는 잡음을 높은 강도(이미지의 낮은 SNR)로 포함하고 있으므로, 이에 대한 영향을 최소화하는 것이 중요하다.
- [0065] 기존 수학적 재구성 알고리즘으로는 스핀-에코 기반 영상으로부터의 체내 Ground-truth 전기전도도 지도 재구성이 어렵다는 한계가 존재한다.
- [0066] 본 실시예에서는 FDTD(Finite Difference Time Domain) 시뮬레이션으로 생성한 RF 자기장 데이터와 딥러닝 네트워크를 활용하여 스핀-에코 MRI 영상으로부터 뇌내 Ground-truth 전기전도도 지도를 재구성한다.
- [0067] 딥러닝 훈련용 데이터를 생성하기 위해 FDTD(Finite-Difference Time-Domain) 시뮬레이션 소프트웨어와 인체 머리 팬텀을 활용하여 실제 3T MRI 환경을 모사하고, 노이즈가 존재하지 않는 RF 자기장(B1), 전류밀도(J), 전기장(E) 데이터를 생성한다. 시뮬레이션 인체 팬텀에는 인체 장기에 대한 전기적 물성치가 미리 설정되어 있다. 실제 임상 MRI처럼 3T (자기장의 단위)에서 RF 코일이 공명할 수 있도록 시뮬레이션 코일의 전류 주파수를 128 MHz로 설정할 수 있다.
- [0068] 시뮬레이션 데이터를 기반으로 가상의 스핀-에코 MRI 영상 데이터와 그에 해당하는 Ground-truth 전기전도도 지도를 합성한다. 합성한 훈련 데이터 셋을 기반으로 훈련 목적에 적합한 딥러닝 네트워크를 개발한다. 실제 MRI 영상 속 잡음 강도에 맞춘 임의의 노이즈와 바이어스를 훈련 데이터 세트에 매 훈련 과정마다 추가하며 딥러닝 네트워크를 훈련한다.
- [0069] 수학적 가정에 의한 바이어스가 존재하지 않는 Ground-truth 전기전도도 정보를 인체로부터 획득하는 것은 현실적으로 많은 어려움이 있다.
- [0070] 본 실시예는 RF 시뮬레이션을 활용한 네트워크 훈련 데이터를 생성한다. 시뮬레이션을 활용하여 실제 스핀-에코 MRI 영상을 모사한 데이터와 Ground-truth 전기전도도 데이터를 생성하고 네트워크 훈련에 사용한다. 시뮬레이션 환경은 3T MRI를 모사하기 위해 128MHz에서 공진하는 버드케이저 RF 코일을 구성하고 내부에 머리 팬텀을 위치시켜 노이즈가 존재하지 않는 B1+, B1-, 전류밀도 및 전기장 데이터를 생성한다. 데이터의 최종 이미지 파라미터는 해상도=1.0 X 1.0 mm<sup>2</sup>, 두께=2 mm로 설정될 수 있다. 생성된 데이터를 기반으로 잡음이 존재하지 않는 가상의 스핀-에코 MRI 영상 및 Ground-truth 전기전도도 지도가 합성되었고 수학적 6(Ground-truth 전기전도도

$\sigma$ ) 및 수학식 7(가상 MRI 이미지 S)과 같이 표현된다.

## 수학식 6

$$\sigma = J/E$$

도 8 및 도 9를 참조하면, 코일 속 전류의 회전 방향을 반시계 방향으로 하거나 코일 속 전류의 회전 방향을 시계 방향으로 하여 데이터 생성을 위한 시뮬레이션을 수행한다. 최종적으로 얻고자하는 정보는 전기전도도 지도이기 때문에 해당 계산에서는 field의 방향을 고려할 필요는 없다.

## 수학식 7

### Approximated MRI Image

$$\begin{aligned} &= V_1 \cdot M_0(r) \cdot \left(1 - \exp\left(-\frac{TR}{T_1}\right)\right) \cdot \exp\left(-\frac{TE}{T_2}\right) \cdot H^-(r) \cdot \exp(i\Phi^+(r)) \\ &\quad \cdot \sin(V_2 \alpha |H^+(r)|) \end{aligned}$$

$V_1$ 과  $V_2$ 는 MRI 기계에 의해 결정되는 스케일 팩터(Scaling factor)이다.

$\alpha$ 는 MRI 장치에서 RF 펄스를 적용하는 동안 Magnetization(M)이 경험하는 회전량이며, 임상데이터로부터 정보가 존재한다.

$M_0(r)$ 는 조직에서 MRI 스캔 과정 이전에 가장 큰 자화값  $M_0$ 를 가진다.

TR/TE는 MRI 영상의 Contrast를 만들어주기 위해 설정하는 값으로 임상 데이터로부터 정보가 존재한다.

$H^+$ (Nuclear precession 방향과 동일하게 회전하는 자기장 성분),  $H^-$ (Nuclear precession 방향과 반대로 회전하는 자기장 성분),  $H^- = \text{abs}(H^+) \cdot \exp(i \cdot \text{angle}(H^+))$ ,  $\Phi^+ = \text{angle}(H^+)$ ,  $|H^+| = \text{abs}(H^+)$ 를 나타낸다.

T1과 T2는 인체 뇌속 부위마다 다른 값을 가지며, 부위마다 일반적으로 알려진 값이 있다.

즉, 시뮬레이션 데이터에 대해 인체 영역을 구분하는 정보가 있어야 합성 가능하다. 도 10을 참조하면, 최종적으로 임상 데이터를 참고하여 MRI 영상이 합성된다.

본 실시예는 Ground-truth 전기전도도 지도 재구성을 위한 ANN(Artificial Neural Network)를 설계한다.

기존에 제안된 딥러닝 기반 전기전도도 재구성 방법들은 재구성하고자 하는 Label 이미지 커널 크기를 입력(Input)과 동일하게 고정시킨다(Image-to-image estimation). 이러한 접근 방식은 출력(Output) 커널 전체에 대한 재구성 성능을 강제함으로써 네트워크의 높은 연산적 부하를 요구할 가능성이 있을 뿐만 아니라 실제 MRI 데이터 적용에 있어서 일반화 성능의 저하로 이어질 수 있다.

도 11은 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치의 전기전도도 재구성 네트워크를 예시한 도면이고, 도 12는 본 발명의 일 실시예에 따른 뇌 전기전도도 지도 재구성 장치의 네트워크 학습을 예시한 도면이다.

딥러닝 네트워크 ANN(Artificial Neural Network)는 의료 영상 처리에 있어서 ill-conditioned 문제를 처리하는데 좋은 효율을 보여줄 뿐만 아니라, 노이즈와 이상 값에 대한 모델의 견고성을 보여준다.

본 실시예에서는 ANN 네트워크를 활용하여 패치화된 이미지 커널로부터 커널 중심(Image-to-point estimation)의 전기전도도를 측정하도록 구현한다. 네트워크는 Batch Normalization와 ReLU Activation 함수를 포함하는 3개의 히든 레이어로 구성되어 있으며 각 레이어의 뉴런 개수는 각각 512, 512, 256개이다. 전체적인 과정은 도

12에 도시된다.

- [0086] 시뮬레이션 데이터는 다음과 같은 과정으로 네트워크 훈련에 사용된다. 사용되는 MRI 영상은 Complex value(a+bi)로 이루어져 있다.
- [0087] 첫번째, 제안된 네트워크 Input에 사용될 시뮬레이션 데이터는 stride=1을 가지는 11 X 11 사이즈의 커널로 패치화되었고 네트워크의 Label은 Ground-truth 전기전도도 지도로부터 Input과 동일한 위치 커널의 중심에 해당하는 값으로 지정할 수 있다.
- [0088] 두번째, 네트워크 훈련 과정에서 Phase에 대한 의존성을 생성하기 위해 매 Epoch마다 Input의 Magnitude 정보에 바이어스를 가해 줄 수 있다.
- [0089] 세번째, 잡음에 대한 네트워크 모델의 견고성을 훈련하기 위해 Input 데이터에 매 Epoch마다 잡음 분포(잡음 강도: SNR=20~40)를 업데이트하여 추가할 수 있다.
- [0090] 마지막으로 바이어스와 잡음이 업데이트된 Input 데이터는 Magnitude와 Phase 정보로 나뉘는 뒤 벡터화되어 네트워크에 사용되었으며 수학적 식 8과 같이 표현된다.

### 수학적 식 8

$$Input = \begin{pmatrix} Magnitude(pixel_1) \\ \vdots \\ Magnitude(pixel_n) \\ Phase(pixel_{n+1}) \\ \vdots \\ Phase(pixel_{2n}) \end{pmatrix} \quad where \quad Manitude = |S_{kernel}|, Phase = \angle S_{kernel}$$

- [0091]
- [0092] 훈련 과정에서 네트워크는 learning rate=0.0001을 가지는 Adam Optimization을 활용하여 최적화되었고 배치의 크기는 64, Epoch은 200로 설정될 수 있다.
- [0093] 도 13 및 도 14는 본 발명의 다른 실시예에 따른 뇌 전기전도도 지도 재구성 방법을 예시한 도면이다.
- [0094] 뇌 전기전도도 지도 재구성 방법은 자기 공명 영상(Magnetic Resonance Imaging, MRI)을 제1 크기 데이터와 제1 위상 데이터로 분리하는 단계(S21), 제1 크기 데이터 및 상기 제1 위상 데이터로부터 전기전도도 재구성 네트워크를 통해 뇌 전기전도도 지도를 생성하는 단계(S22)를 포함한다.
- [0095] 전기전도도 재구성 네트워크는 시뮬레이션 데이터를 기반으로 노이즈가 없는 가상 MRI 영상을 합성하는 단계(S31), 시뮬레이션 데이터를 기반으로 검증 전기전도도 지도를 생성하는 단계(S32), 가상 MRI 영상에 노이즈를 추가하는 단계(S33), 노이즈가 추가된 가상 MRI 영상 및 검증 전기전도도 지도를 이용하여 네트워크 학습을 수행하는 단계(S34)를 거쳐 학습될 수 있다.
- [0096] 시뮬레이션 데이터는 시뮬레이션 인체 팬텀 및 무선 주파수(Radio Frequency, RF) 코일을 이용하여 시뮬레이션 환경을 구성하고 노이즈가 없는 RF 자기장, 전류밀도, 전기장에 관한 데이터를 획득하여 형성될 수 있다.
- [0097] 노이즈가 없는 가상 MRI 영상은 RF 자기장, 콘트라스트를 설정하는데 필요한 반복 시간(TR) 및 에코 시간(TE), 인체 뇌 영역을 구분하는데 필요한 제1 이완 시간(T1) 및 제2 이완 시간(T2)를 포함하는 관계식을 통해 획득될 수 있다.
- [0098] 검증 전기전도도 지도는 전류밀도 및 전기장을 포함하는 관계식(수학적 식 6)을 통해 획득될 수 있다.
- [0099] 가상 MRI 영상에 노이즈를 추가하는 단계(S33)는 가상 MRI 영상을 제1 실수 데이터와 제1 허수 데이터로 분리하고, 제1 실수 데이터 및 제1 허수 데이터 각각에 노이즈를 추가하고, 다시 통합할 수 있다.
- [0100] 네트워크 학습을 수행하는 단계(S34)는 노이즈가 추가된 가상 MRI 영상을 제2 크기 데이터와 제2 위상 데이터로 분리하고, 제2 크기 데이터 및 제2 위상 데이터 각각을 전기전도도 재구성 네트워크에 입력하여 제2 크기 데이터 및 제2 위상 데이터의 커널 매트릭스로부터 커널 포인트에 대한 전기전도도를 추정할 수 있다.



- [0101] 네트워크 학습을 수행하는 단계(S34)는 전기전도도 재구성 네트워크의 레이블을 검증 전기전도도 지도를 기반으로 동일한 위치에 매칭하는 커널의 중심에 해당하는 값으로 지정할 수 있다.
- [0102] 네트워크 학습을 수행하는 단계(S34)는 매 훈련 과정마다 제1 크기 데이터에 바이어스를 인가하여 위상에 대한 의존성을 생성할 수 있다.
- [0103] 네트워크 학습을 수행하는 단계(S34)는 매 훈련 과정마다 제2 크기 데이터 및 제2 위상 데이터에 반영하는 노이즈 분포를 상이하게 업데이트하여 훈련할 수 있다.
- [0104] 도 15 내지 도 17은 본 발명의 실시예들에 따라 시뮬레이션을 수행한 결과를 예시한 도면이다.
- [0105] 도 15를 참조하면, 비특허문헌 1은 full equation 기반 알고리즘이고, 네트워크(CNN), Network Input & Output size(2D slice whole brain image), 훈련 데이터(시뮬레이션 데이터세트), Label data(Ground-truth 전기전도도 지도), 데이터 해상도( $2 \times 2 \text{ mm}^2$ ), 테스트를 위한 시뮬레이션 데이터 SNR(100 성공적), 인체 데이터 테스트는 적용 가능하고, 임상 데이터 테스트는 실시되지 않았음을 확인할 수 있다.
- [0106] 비특허문헌 2는 딥러닝 구성은 비특허문헌 1과 동일하고(full equation 기반), 테스트를 위한 시뮬레이션 데이터 SNR(100 성공적), 인체 및 임상 데이터 테스트는 실시되지 않았음을 확인할 수 있다.
- [0107] 비특허문헌 3은 페이즈 기반 전기전도도 재구성 알고리즘으로, 네트워크(Patch 기반 CNN), 훈련 데이터(시뮬레이션+인체 데이터세트), Label data(시뮬레이션:Ground-truth 전기전도도 지도 + 인체: 인체 조직 정보 및 Bilateral denoising median filter를 활용해 재구성한 페이즈 기반 전기전도도 지도), 데이터 해상도( $2 \times 2 \text{ mm}^2$ ), 훈련 데이터에 사용된 인체 데이터의 Ground-truth는 적절히 가공되어 재구성된 데이터만을 활용하고, 테스트를 위한 시뮬레이션 데이터 SNR(100)(결과는 비특허문헌 1과 2에 비해 성능이 낮음), 인체 데이터 테스트는 적용 실패(떨어지는 성능)이고, 임상 데이터 테스트는 적용 실패(떨어지는 성능)인 것을 확인할 수 있다.
- [0108] 비특허문헌 4는 페이즈 기반 전기전도도 재구성 알고리즘으로, 네트워크(Patch 기반 ANN), Network Input & Output size(2D patch matrix:  $9 \times 9$ ), 훈련 데이터(인체 데이터세트), Label data(cr-EPT 재구성 전기전도도 지도), 데이터 해상도( $1.875 \times 1.875 \text{ mm}^2$ ), 훈련 데이터에 사용된 인체 데이터의 Label 데이터는 적절히 가공되어 재구성된 데이터만을 활용하고, 테스트를 위한 시뮬레이션 데이터 SNR(Data acquisition 정보로부터 추측했을때, SNR 높을 것, 최소 100 이상), 인체 데이터 테스트는 적용 가능하나 Label에 cr-EPT 결과의 사용으로, Ground-truth 전기전도도 지도와는 거리가 있고, 임상 데이터 테스트는 실시되지 않았음을 확인할 수 있다.
- [0109] 본 실시예는 페이즈 기반 전기전도도 재구성 알고리즘으로, 네트워크(Patch 기반 ANN), Network Input size(2D patch matrix:  $11 \times 11$ ), Network Output size(2D patch matrix:  $1 \times 1$ ), 훈련 데이터(시뮬레이션 데이터세트), Label data(Ground-truth 전기전도도 지도), 데이터 해상도( $1 \times 1 \text{ mm}^2$ ), 테스트를 위한 시뮬레이션 데이터 SNR(20), 인체 데이터 테스트는 적용 가능하고, 임상 데이터 테스트는 적용 가능한 것을 확인할 수 있다.
- [0110] 실험 데이터세트로 훈련된 딥러닝 모델을 평가하기 위해 시뮬레이션 데이터 및 병원의 MRI 뇌 데이터를 활용했고, 작업에 사용한 데이터는 총 세가지 종류로 (1) 네트워크 훈련에 포함되지 않은 스핀-에코 시뮬레이션 데이터, (2) 건강한 지원자에 대한 스핀-에코 MRI 영상, (3) 실제 임상 환경에서 촬영된 Meningioma 환자에 대한 스핀-에코 MRI 영상이다.
- [0111] (1) 데이터는 (2)와 (3)의 실제 MRI 영상 및 스캔 파라미터를 참고하여 합성되었고, 이미지 합성 파라미터는  $TR/TE=4500/80 \text{ [ms]}$ , 이미지 해상도= $1.0 \times 1.0 \text{ [mm}^2]$ , 슬라이스 개수=20, 두께=2 [mm]이다.
- [0112] (2) 영상의 MRI 스캔 파라미터는 2D 획득,  $TR/TE=4500/80 \text{ [ms]}$ , 이미지 해상도= $1.0 \times 1.0 \text{ [mm}^2]$ , 슬라이스 개수=25, 두께=3 [mm]. (3) 영상의 경우 2D 획득,  $TR/TE=4363/95 \text{ [ms]}$ , 해상도= $0.625 \times 0.75 \text{ [mm}^2]$ , 슬라이스 개수=100, 두께=2 [mm]이다.
- [0113] (3) 실험 데이터의 이미지 해상도는 네트워크 훈련에 사용된 이미지 파라미터와 맞추기 위해  $1.0 \times 1.0 \text{ [mm}^2]$ 로 재구성하여 실험에 활용되었다.
- [0114] 획득한 신체 데이터에 대한 Ground-truth 전기전도도 정보를 얻는 것은 현실적으로 곤란하다. 따라서 정량적 평가를 위해 Ground-truth 전기전도도 정보를 허용하는 시뮬레이션 데이터를 활용하여 각 팬텀 ROI(뇌척수액, 백

색질, 회색질 영역)에 대한 전기전도도 값(mean/std)을 측정하고 정답과 비교하였다. 또한 (2)-(3) 실험에서는 실제 MRI 영상에 알고리즘을 적용해보고 ROI 분석 결과를 문헌 값과 비교하였다.

[0115] (1) 첫번째 실험: 실제 스핀-에코 MRI 영상을 모사한 시뮬레이션 데이터

[0116] 해당 실험에서는 네트워크 훈련에 포함되지 않은 시뮬레이션 데이터를 활용하여 네트워크의 성능을 조사하였다. 알고리즘 결과는 도 16의 (a)에서 보여지는 것과 같다. 테스트에 사용된 시뮬레이션 데이터는 뇌척수액, 백색질, 회색질, 총 세가지 영역(도 16의 (b))으로 구성되어 있으며 각각 2.14, 0.34, 0.59 [S/m]의 전기전도도 값을 가진다. 알고리즘 결과는 각각의 영역에 대해 2.10 (0.28), 0.34 (0.05), 0.59 (0.29) [S/m]의 평균 (표준편차) 전기전도도 값을 나타냈다(도 16의 (c)). 반면 3 X 3 Laplacian 연산자를 사용하는 기존 Phase 기반 재구성 알고리즘에 의해 계산된 전기전도도 값은 각각 1.63 (32.97), 0.47 (8.83), 0.80 (6.96) [S/m]으로 제안된 알고리즘 결과의 안정성을 보여주고 있다.

[0117] (2) 두번째 실험: 건강한 지원자에 대한 MRI 영상

[0118] 두번째 실험에서는 건강한 지원자 MRI 영상에 대한 훈련된 네트워크의 일반화 성능을 조사하였다. 알고리즘 결과는 도 17의 (A-a)에서 보여지는 것과 같으며 정성적으로 관찰했을 때, 큰 바이어스를 포함하고 있지 않았다. 알고리즘 결과는 각각의 영역(뇌척수액, 백색질, 회색질에 대해 1.94 (0.37), 0.36 (0.087), 0.61 (0.30) [S/m]의 평균 (표준편차) 전기전도도 값을 보여주었고 분포는 도 17의 Boxplot, B: Healthy Volunteer와 같다. 문헌을 통해 알려져 있는 전기전도도 값은 뇌척수액, 백색질, 회색질에 대해 각각 1.65~2.14, 0.30~0.43, 0.59~0.63 [S/m]이다. 따라서 시뮬레이션 데이터만으로 훈련된 딥러닝 네트워크는 실제 인체 MRI 데이터에 대해 납득할 수 있는 적정 범위 내에서 전기전도도 값을 추정했음을 나타낸다.

[0119] (3) 세번째 실험: 환자에 대한 MRI 영상

[0120] 마지막으로 Meningioma 병변이 존재하는 환자 MRI 영상에 대해 훈련된 네트워크의 일반화 성능을 조사하였다. 알고리즘 결과는 도 17의 (A-b)에서 보여지는 것과 같다. (2) 실험 결과와 비교하여 잡음에 좀 더 영향을 받은 것으로 보이나 큰 바이어스가 관찰되진 않았다. 알고리즘 결과는 각각의 영역(뇌척수액, 백색질, 회색질에 대해 1.90 (0.44), 0.39 (0.16), 0.64 (0.42) [S/m]의 평균 (표준편차) 전기전도도 값을 보여주었고 분포는 도 17의 Boxplot B: Meningioma Patient와 같다. 추가적으로 Meningioma 병변 ROI에 대해 전기전도도 값을 측정하고 문헌 값과 비교했다. 제안된 알고리즘은 병변 전체 영역에 대해 0.96 (0.47) [S/m]의 평균 (표준편차) 전기전도도 값을 측정했으며 문헌에 의해 추정된 해당 병변 전기전도도 값은 0.83 (0.49)이었다. 체내 Ground-truth 전기전도도 측정의 어려움 때문에 환자 데이터에 대한 정량적 분석에는 어려움이 있으나 제안된 알고리즘 네트워크는 뇌 내에서 병변 부분을 구분해내고 문헌에서 추정한 값에 근접한 수치를 나타냈다.

[0121] EPT 기법이 소개된 이후로 한계점들을 해결하고자 수많은 전기전도도 재구성 알고리즘 개선의 노력들이 시도되어 왔다. 하지만 종래에 제안된 Phase 기반 EPT 알고리즘 결과에는 수학적 가정들과 데이터의 잡음에 의해 발생하는 바이어스를 포함하고 있기 때문에 Ground-truth 전기전도도 지도와 차이를 보인다. 일부 적분 기반 알고리즘들은 Ground-truth 전기전도도 지도 재구성에 대해 현저한 성능을 보여주었지만, 연산 과정에서 필요한 코일 소스에 대한 사전 정보, 긴 연산 시간 및 위상 기반 전기전도도 재구성 알고리즘에 응용이 불가능 등의 한계점으로 임상 환경에 적용이 어렵다.

[0122] 최근 딥러닝 알고리즘은 EPT분야에서 많은 관심을 받고 있지만, Phase 기반 정보로부터 딥러닝 기반의 Ground-truth 전기전도도 지도 재구성하는 방법은 한가지만이 제안되었다. 기존의 알고리즘에는 몇 가지 한계점이 존재하는데, 본 발명은 이러한 한계를 극복할 수 있다.

[0123] 첫번째로 기존의 알고리즘은 잡음에 대한 모델의 견고성이 떨어진다. 기본 모델은 데이터의 잡음에 대한 견고성을 SNR=100에 대해서만 고려한다. 본 발명에서 실험에 활용되었던 임상 데이터 잡음 정도는 SNR=20이었다. 따라서 종래에 제안된 딥러닝 기반 재구성 방법은 고해상도 이미지와 제한된 촬영 시간을 요구하는 일부 임상 환경에서 적용이 어려울 수 있다. 반면 본 발명은 종래 딥러닝 방법에서 실험한 것보다 낮은 SNR의 데이터에서도 전기전도도 재구성을 무리 없이 수행할 수 있다.

[0124] 두번째로 기존의 알고리즘은 이미지 해상도를 제한한다. 기존의 딥러닝 방법은 1.875 X 1.875 및 2.0 X 2.0 [mm]<sup>2</sup>의 해상도 데이터 적용을 목적으로 제안되었다. MRI 이미지 획득 관점에 있어서 이미지 해상도를 낮추면 영상의 SNR이 증가하지만, 재구성된 전기전도도 지도로부터 관찰할 수 있는 구조의 디테일이 떨어진다. 반면 본 발명에서는 1.0 X 1.0 [mm]<sup>2</sup> 해상도 데이터에 적용을 수행함으로써 기존 딥러닝 방법보다 더욱 높은 해상도의


전기전도도 지도 관찰을 가능하게 한다.

- [0125] 세번째로 기존의 알고리즘은 딥러닝 네트워크의 낮은 일반화 성능을 보여준다. 기존에 제안된 딥러닝 방법에서도 건강한 지원자 및 환자에 대한 MRI 영상을 실험하였으나 성공적이지 못했다. 반면 본 발명은 실제 인체 데이터 실험에서 큰 바이어스 없이 전기전도도 재구성을 수행할 수 있음을 보여준다.
- [0126] 실제 임상 환경에서는 환자에 대해 제한된 시간안에 고해상도 촬영이 요구되기 때문에 EPT 재구성을 위한 영상 획득 환경을 갖추기 어렵다. 이것은 촬영된 MRI 영상에 대해 낮은 SNR을 강요하게 되기 때문에 기존 알고리즘만으로는 병리 진단의 타당성 연구를 위한 임상적 관찰을 어렵게 하며, 한계점을 극복하기 위해서는 영상의 SNR을 높이기 위한 추가적인 조치를 요구한다.
- [0127] 본 발명에서 제안된 방식을 이용하면 이러한 비효율성을 극복하고, 전기전도도 영상에 대한 타당성 연구에 이바지할 수 있다.
- [0128] 장치는 하드웨어, 펌웨어, 소프트웨어 또는 이들의 조합에 의해 로직회로 내에서 구현될 수 있고, 범용 또는 특정 목적 컴퓨터를 이용하여 구현될 수도 있다. 장치는 고정배선형(Hardwired) 기기, 필드 프로그램 가능한 게이트 어레이(Field Programmable Gate Array, FPGA), 주문형 반도체(Application Specific Integrated Circuit, ASIC) 등을 이용하여 구현될 수 있다. 또한, 장치는 하나 이상의 프로세서 및 컨트롤러를 포함한 시스템온칩(System on Chip, SoC)으로 구현될 수 있다.
- [0129] 장치는 하드웨어적 요소가 마련된 컴퓨팅 디바이스 또는 서버에 소프트웨어, 하드웨어, 또는 이들의 조합하는 형태로 탑재될 수 있다. 컴퓨팅 디바이스 또는 서버는 각종 기기 또는 유무선 통신망과 통신을 수행하기 위한 통신 모듈 등의 통신장치, 프로그램을 실행하기 위한 데이터를 저장하는 메모리, 프로그램을 실행하여 연산 및 명령하기 위한 마이크로프로세서 등을 전부 또는 일부 포함한 다양한 장치를 의미할 수 있다.
- [0130] 도 13 및 도 14에서는 각각의 과정을 순차적으로 실행하는 것으로 기재하고 있으나 이는 예시적으로 설명한 것에 불과하고, 이 분야의 기술자라면 본 발명의 실시예의 본질적인 특성에서 벗어나지 않는 범위에서 도 13 및 도 14에 기재된 순서를 변경하여 실행하거나 또는 하나 이상의 과정을 병렬적으로 실행하거나 다른 과정을 추가하는 것으로 다양하게 수정 및 변형하여 적용 가능할 것이다.
- [0131] 본 실시예들에 따른 동작은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능한 매체에 기록될 수 있다. 컴퓨터 판독 가능한 매체는 실행을 위해 프로세서에 명령어를 제공하는 데 참여한 임의의 매체를 나타낸다. 컴퓨터 판독 가능한 매체는 프로그램 명령, 데이터 파일, 데이터 구조 또는 이들의 조합을 포함할 수 있다. 예를 들면, 자기 매체, 광기록 매체, 메모리 등이 있을 수 있다. 컴퓨터 프로그램은 네트워크로 연결된 컴퓨터 시스템 상에 분산되어 분산 방식으로 컴퓨터가 읽을 수 있는 코드가 저장되고 실행될 수도 있다. 본 실시예를 구현하기 위한 기능적인(Functional) 프로그램, 코드, 및 코드 세그먼트들은 본 실시예가 속하는 기술분야의 프로그래머들에 의해 용이하게 추론될 수 있을 것이다.
- [0132] 본 실시예들은 본 실시예의 기술 사상을 설명하기 위한 것이고, 이러한 실시예에 의하여 본 실시예의 기술 사상의 범위가 한정되는 것은 아니다. 본 실시예의 보호 범위는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 실시예의 권리범위에 포함되는 것으로 해석되어야 할 것이다.




도면


도면1



도면2




도면3




도면4

### 시뮬레이션 예시 (without noise)

전기전도도 지도 정답  
(Ground-truth)




Volume Integral  
전기전도도




도면5

### 시뮬레이션 예시 (without noise)

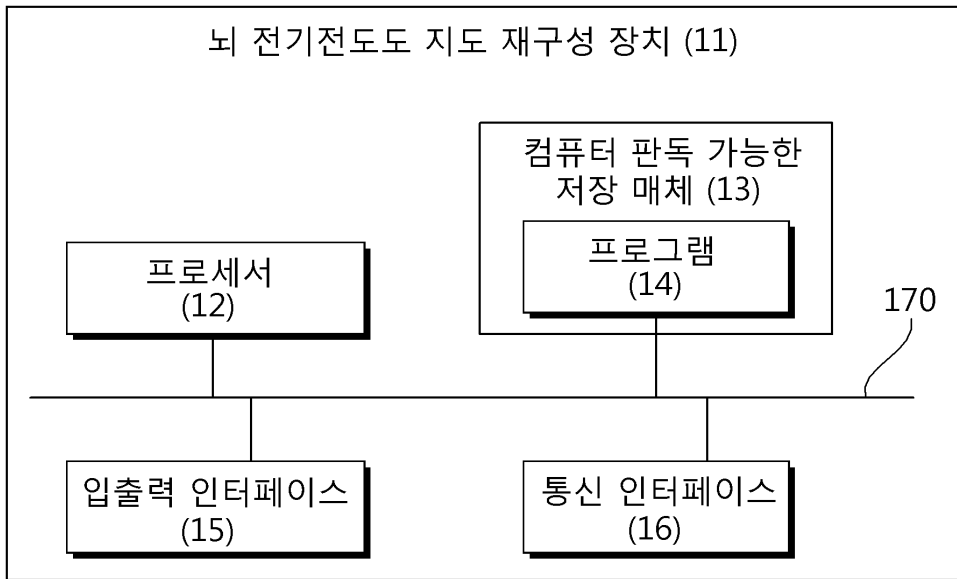
전기전도도 지도 정답  
(Ground-truth)



CSI  
전기전도도



도면6

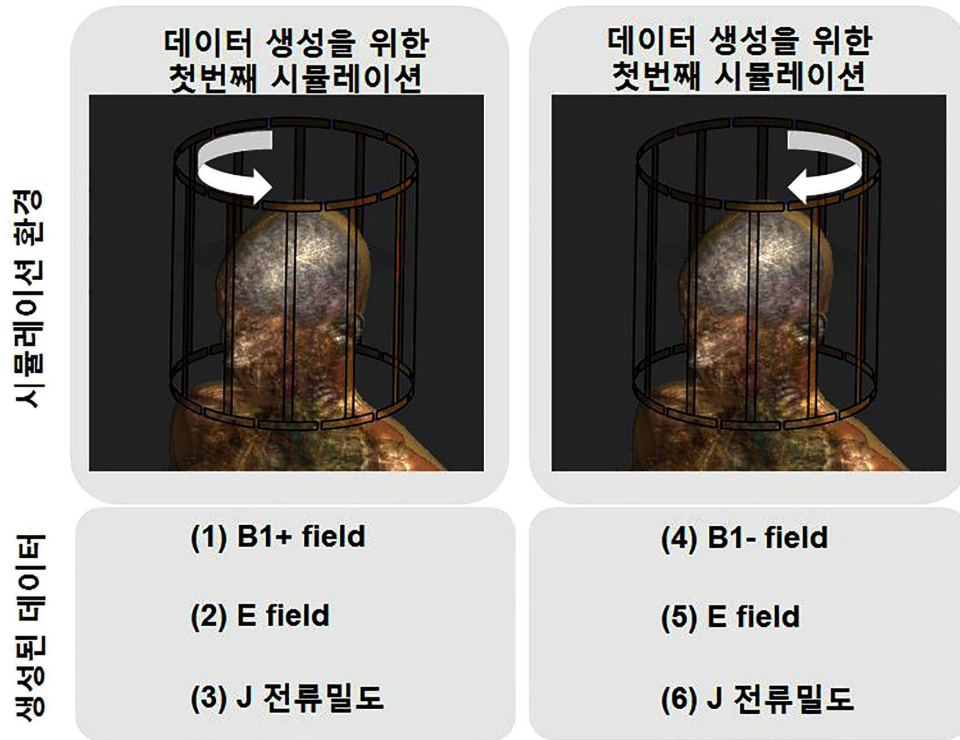


도면7




시뮬레이션 인체 팬텀 및 RF 코일 구성

도면8






도면9




도면10

가상의 MRI 영상 (Complex value)      Ground-truth 전기전도도 지도      실제 MRI 영상: SNR 20 (Complex value)

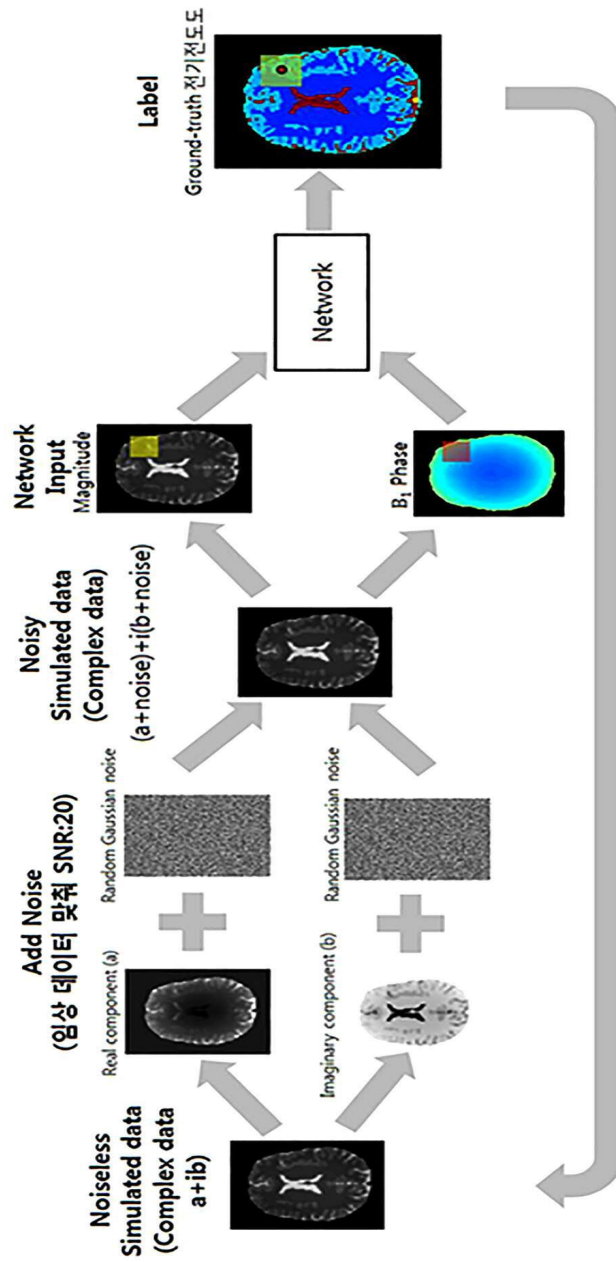


도면11

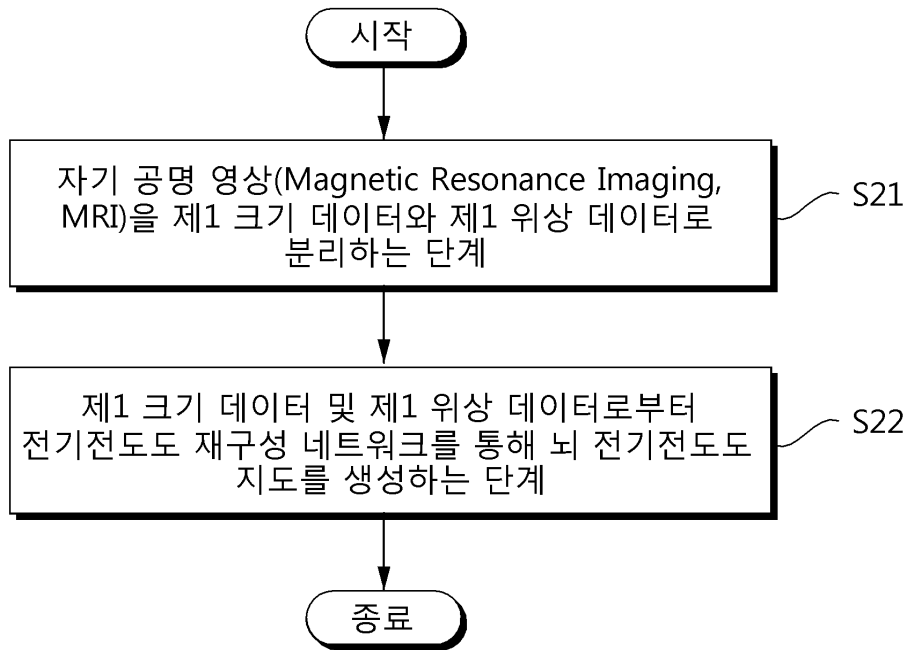




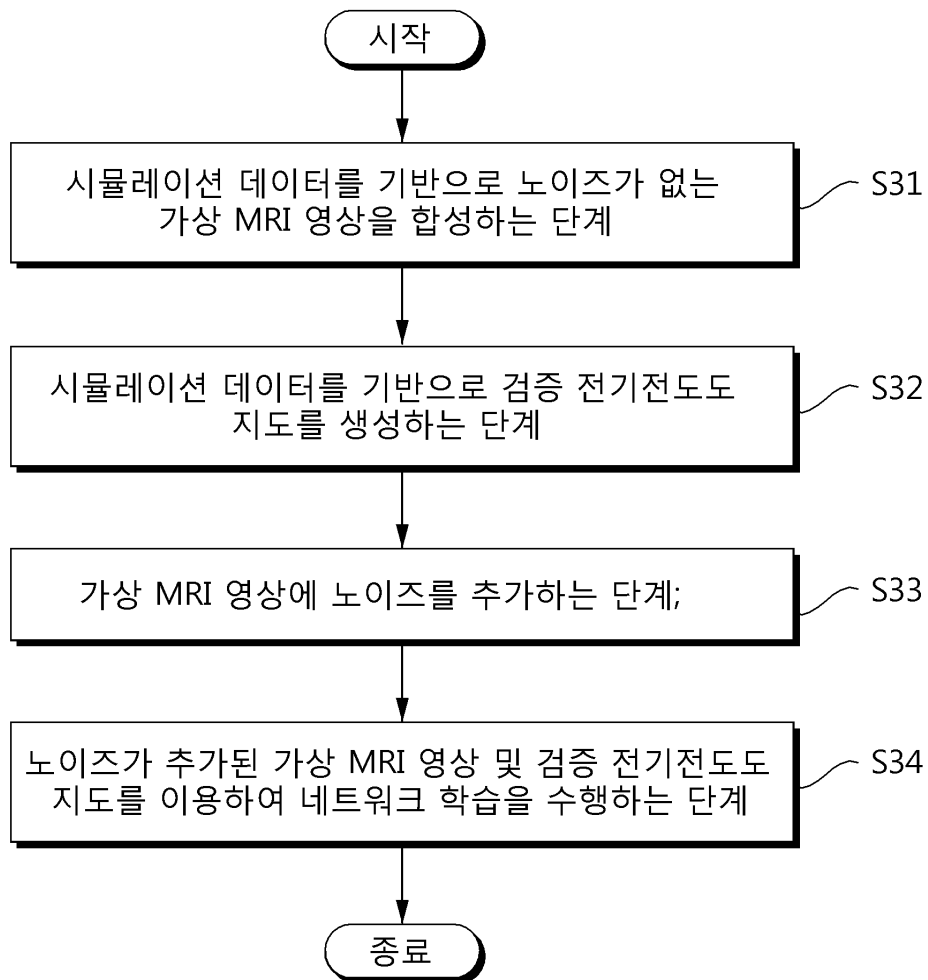
도면12



도면13

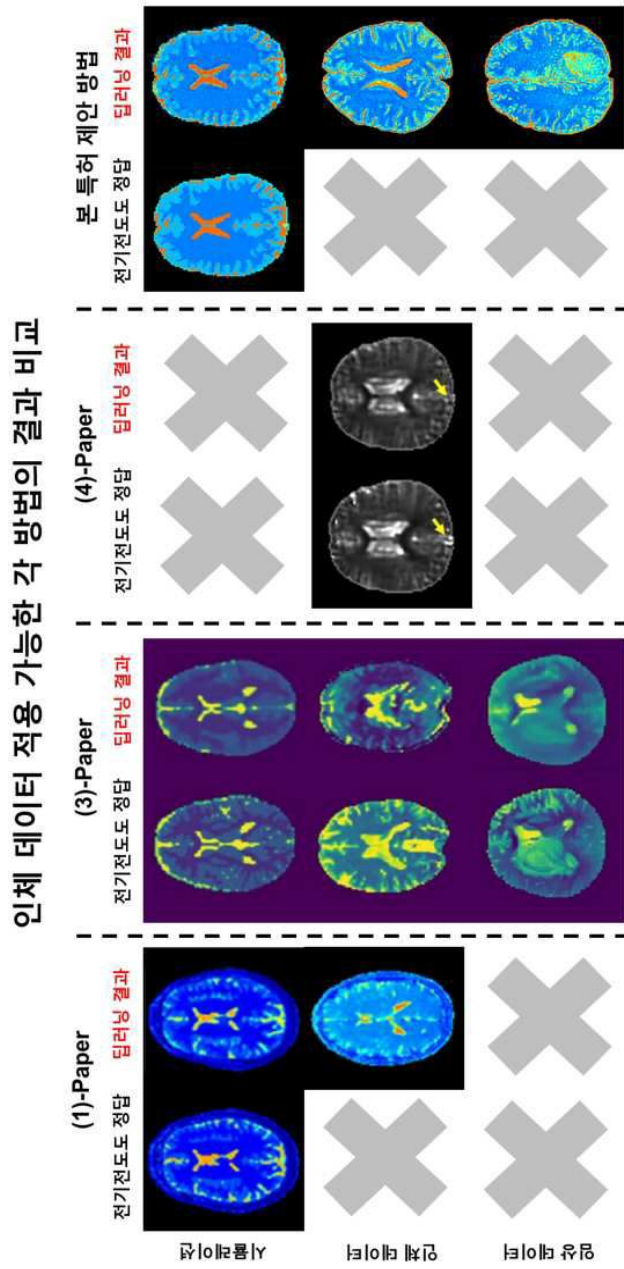


도면14



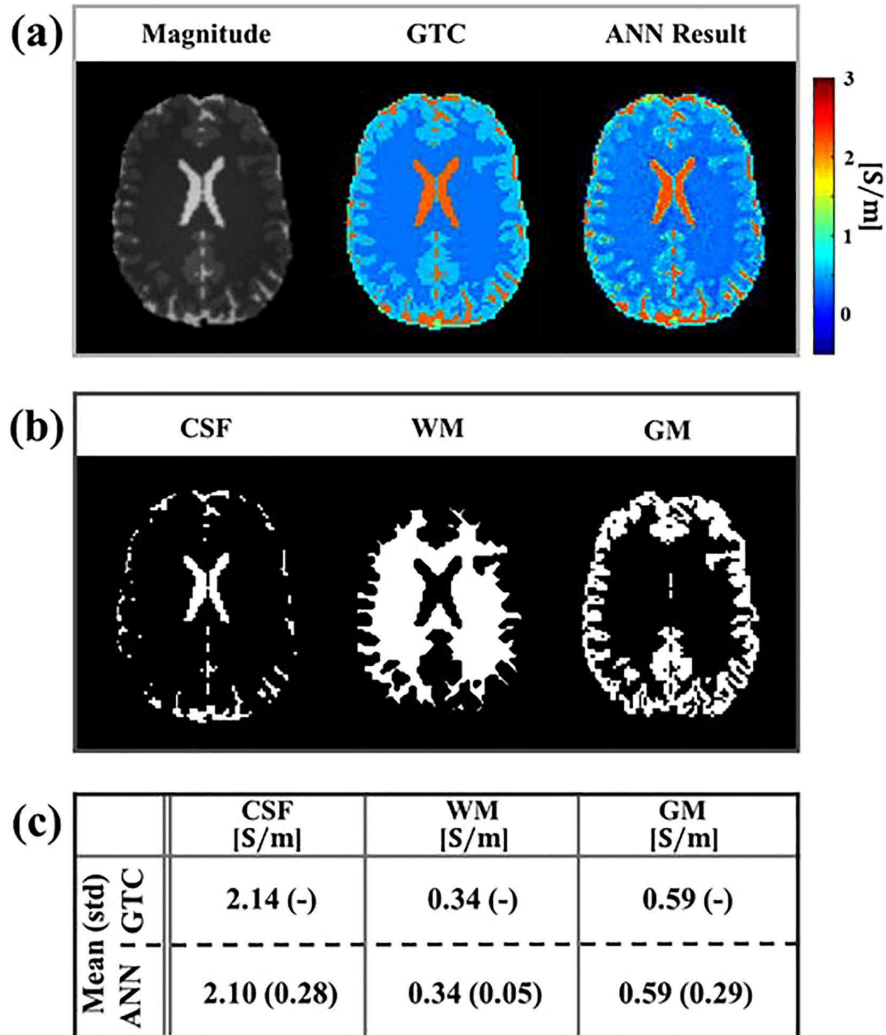


도면15



도면16

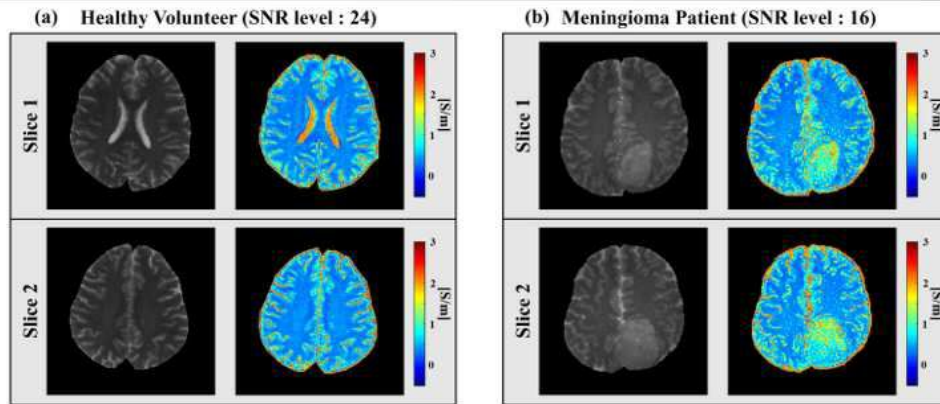
## Experiment 1: Simulation Data (SNR=20)



도면17

## Experiment 2 : In-vivo Dataset

### (A) Conductivity Reconstruction Result



### (B) ROI Analysis

