



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0024278
(43) 공개일자 2025년02월18일

(51) 국제특허분류(Int. Cl.)
G01R 33/56 (2006.01) A61B 5/00 (2021.01)
A61B 5/055 (2006.01) G01R 33/565 (2006.01)
G06N 3/08 (2023.01) G06V 10/82 (2022.01)
(52) CPC특허분류
G01R 33/5608 (2013.01)
A61B 5/0033 (2025.01)
(21) 출원번호 10-2023-0105565
(22) 출원일자 2023년08월11일
심사청구일자 2023년08월11일

(71) 출원인
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암
동5가)
(72) 발명자
김무경
서울특별시 성북구 안암로9나길 14, 나동 239호
정원주
서울특별시 강남구 삼성로64길 5, 107동 302호
(74) 대리인
김동용


전체 청구항 수 : 총 7 항

(54) 발명의 명칭 연쇄 선조건 켤레 기울기 네트워크 기반의 자기공명영상 가속화 장치 및 방법

(57) 요약

자기공명영상(Magnetic Resonance Imaging, MRI) 가속화를 위한 연쇄 선조건 켤레 기울기 네트워크를 이용한 MRI 이미지 복원 방법이 개시된다. 상기 MRI 이미지 복원 방법은 적어도 프로세서(Processor)를 포함하는 컴퓨팅 장치에 의해 수행되는, CS-MRI(Compressed Sensing-MRI) 기반의 MRI 이미지 복원 방법으로써, 수학적 1에 의해 정의되는 목적 선형방정식을 설정하는 단계, 상기 목적 선형방정식을 풀이하기 위한 CNN(Convolutional Neural Network) 기반의 학습 모델을 생성하는 단계, 및 학습 데이터를 이용하여 상기 학습 모델을 학습하여 이미지 복원 모델을 생성하는 단계를 포함한다.

대표도 - 도4



(52) CPC특허분류

A61B 5/055 (2022.01)

G01R 33/565 (2013.01)

G06N 3/08 (2023.01)

G06V 10/82 (2022.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711193973
과제번호	2019-0-00079-005
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성
연구과제명	인공지능대학원지원(고려대학교)
기 여 율	1/1
과제수행기관명	고려대학교산학협력단
연구기간	2023.01.01 ~ 2023.12.31

명세서

청구범위

청구항 1

적어도 프로세서(Processor)를 포함하는 컴퓨팅 장치에 의해 수행되는, CS-MRI(Compressed Sensing-Magnetic Resonance Imaging) 기반의 MRI 이미지 복원 방법에 있어서,

수학식 1에 의해 정의되는 목적 선형방정식을 설정하는 단계;

상기 목적 선형방정식을 풀이하기 위한 CNN(Convolutional Neural Network) 기반의 학습 모델을 생성하는 단계; 및

학습 데이터를 이용하여 상기 학습 모델을 학습하여 이미지 복원 모델을 생성하는 단계를 포함하고,

$$\text{상기 수학식 1은 } \begin{bmatrix} I & \mathbb{O} \\ \text{diag}([\alpha^\top, \alpha^\top]^\top) \frac{\partial \Psi(\mathbf{u})^\top}{\partial \mathbf{u}} & K_s \end{bmatrix} \mathbf{q} = - \begin{bmatrix} f(\mathbf{w}, \mathbf{u}) \\ g(\mathbf{w}, \mathbf{u}) \end{bmatrix} \text{이고,}$$

상기 $\text{diag}(\cdot)$ 은 대각 행렬(diagonal matrix)이고,

상기 $\alpha \in \mathbb{R}^N$ 는 정규화된 트레이드-오프 파라미터(generalized trade-off parameter)이고,

상기 $\mathbf{u} \in \mathbb{R}^{2N}$ 는 원본 MRI 이미지이고,

상기 $\Psi(\cdot)$ 는 희소변환이고,

상기 K_s 는 $K_s = D^H M_s D$ 를 만족하고,

상기 $D \in \mathbb{R}^{N \times N}$ 는 푸리에 변환행렬이고,

상기 $M_s \in \mathbb{R}^{M \times N}$ 는 언더샘플링 연산자를 나타내는 행렬이고,

$$\text{상기 H는 } \begin{bmatrix} I & \mathbb{O} \\ \text{diag}([\alpha^\top, \alpha^\top]^\top) \frac{\partial \Psi(\mathbf{u})^\top}{\partial \mathbf{u}} & K_s \end{bmatrix} \text{이고,}$$

상기 $\mathbf{q} \in \mathbb{R}^{4N}$ 는 이미지와 쌍대 벡터를 업데이트하는 방향을 나타내고,

상기 $\mathbf{w}$ 는 쌍대 변수이고,

상기 $f(\mathbf{w}, \mathbf{u})$ 와 상기 $g(\mathbf{w}, \mathbf{u})$ 는 수학식 2에 의해 정의되고,

$$\text{상기 수학식 2는 } \begin{cases} f(\mathbf{w}, \mathbf{u}) = \mathbf{w} - \text{sgn}(\Psi(\mathbf{u})) = 0 \\ g(\mathbf{w}, \mathbf{u}) = K_s \mathbf{u} - D^H \mathbf{y} + \alpha \frac{\partial \Psi(\mathbf{u})^\top}{\partial \mathbf{u}} \mathbf{w} = 0 \end{cases} \text{이고,}$$

상기 $\mathbf{y}$ 는 언더샘플링된 k-스페이스(k-space) 데이터를 나타내는,

MRI 이미지 복원 방법.

청구항 2

제1항에 있어서,

상기 학습 모델은 현재 상태의 $\mathbf{w}$ 와 $\mathbf{u}$ 를 입력받아 다음 상태의 $\mathbf{w}$ 와 $\mathbf{u}$ 를 출력하는 제1 신경망을 적어도 하나 포함하는,

MRI 이미지 복원 방법.

청구항 3

제2항에 있어서,

상기 학습 모델은 직렬로 연결된 복수의 제1 신경망을 포함하는,

MRI 이미지 복원 방법.

청구항 4

제2항에 있어서,

상기 제1 신경망은 현재 상태의 w 와 현재 상태의 u 를 입력받아 제1 출력(μ_w)과 제2 출력(μ_u)을 출력하는 μ 연산자, 현재 상태의 u 를 입력받아 희소변환하는 $\Psi(\cdot)$ 연산자, 현재 상태의 u 를 입력받아 a 를 출력하는 a 연산자, 및

$f(w, u)$ 의 결과와 $g(w, u)$ 의 결과를 병합한 값, 희소변환의 결과, a 연산의 결과를 입력으로 받고, 입력을 갱신하는 적어도 하나의 제2 신경망을 포함하고,

상기 제1 신경망은 상기 제2 신경망의 출력과 μ 연산의 결과 사이의 요소별 곱셈의 결과와, 현재 상태의 w 의 요소별 덧셈의 결과를 다음 상태의 w 로 출력하고,

상기 제1 신경망은 상기 제2 신경망의 출력과 μ 연산의 결과 사이의 요소별 곱셈의 결과와, 현재 상태의 u 의 요소별 덧셈의 결과를 다음 상태의 u 로 출력하는,

MRI 이미지 복원 방법.

청구항 5

제4항에 있어서,

μ 연산자, $\Psi(\cdot)$ 연산자, 및 상기 a 연산자 각각은 CNN 모델로 구현되는,

MRI 이미지 복원 방법.

청구항 6

제5항에 있어서,

상기 제2 신경망은 각각이 CNN 모델로 구현되는 $I(\cdot)$ 연산자, $A(\cdot)$ 연산자, $\Omega(\cdot)$ 연산자를 포함하는,

MRI 이미지 복원 방법.

청구항 7

제6항에 있어서,

$I(\cdot)$ 연산자는 $A(\cdot)$ 연산자의 출력, b , p , 및 H_p 를 입력으로 받고,

$A(\cdot)$ 연산자는 b 를 입력으로 받고,

$\Omega(\cdot)$ 연산자는 $A(\cdot)$ 연산자의 출력, $A(\cdot)$ 연산자의 이전 출력, b , 및 이전 상태의 b 를 입력으로 받고,

상기 제2 신경망의 초기값은 수학식 3으로 설정되고,

상기 제2 신경망은 수학식 4의 계산을 수행하고,

상기 수학식 3은

$$\begin{aligned}\alpha &= \alpha(u) \\ b_0 &= -[f(w, u)^\top, g(w, u)^\top]^\top \\ p_0 &= \Lambda(b_0) \\ q_0 &= 0 \\ z_0 &= \Lambda(b_0)\end{aligned}$$

이고,

상기 수학식 4는

$$\begin{aligned}\gamma_k &= \Gamma(b_k, z_k, p_k, H p_k) \\ q_{k+1} &= q_k + \gamma_k \circ z_k \\ b_{k+1} &= b_k - \gamma_k \circ H p_k \\ z_{k+1} &= \Lambda(b_{k+1}) \\ \omega_k &= \Omega(b_k, b_{k+1}, z_k, z_{k+1}) \\ p_{k+1} &= z_{k+1} + \omega_k \circ p_k\end{aligned}$$

인,

MRI 이미지 복원 방법.

발명의 설명

기술 분야

[0001] 본 발명은 자기공명영상(Magnetic Resonance Imaging, MRI)에 관한 것이며, 보다 상세하게는 압축 센싱 자기공명영상(Compressed Sensing Magnetic Resonance Imaging, CS-MRI) 알고리즘에 관한 것이다.

배경 기술

[0002] 자기공명영상(Magnetic Resonance Imaging, MRI)은 비침습적인 방법으로 인체 내부의 고화질 영상을 얻을 수 있는 방법으로 의학적으로 많이 활용되고 있다. 하지만, MRI는 순차적인 데이터 측정 방식으로 인해 측정 시간이 오래 걸리고, 높은 비용이 요구된다. 따라서, 신호처리적인 접근을 통해 원본 이미지를 복원하기 위해 필요한 측정의 횟수를 줄여서 MRI에 필요한 측정 시간을 줄이기 위한 연구가 활발히 진행되고 있다.

[0003] 최소 변환의 특성을 이용해 적은 양의 측정만으로 원본 신호를 복원하는 기법인 압축 센싱(Compressed Sensing, CS)은 다양한 분야에서 널리 사용되는 신호처리 기법이다. CS 기법은 MRI 분야에서도 적용되고 있다. 압축 센싱 자기공명영상(Compressed Sensing Magnetic Resonance Imaging, CS-MRI)는 ℓ_1 -노름 제한조건 하에서 블록 최적화 문제를 푸는 방식으로 원본 이미지를 복원한다. 제한조건은 원본 이미지에 특정 변환을 취했을 때, 변환된 이미지의 ℓ_1 -노름이 작은 값을 가지게 강제한다. 이러한 정규화된 블록 최적화 문제는 수학적으로 닫힌 형태의 해가 없기 때문에, 반복 알고리즘을 통해 근사해를 찾아야 한다. 대표적인 방법들로는 분산 베르그만 알고리즘, ADMM(Alternating Direction Method of Multipliers), CP(Chambolle-Pock) 알고리즘 등이 있다.

[0004] 최근에는 딥러닝 기법을 MRI 가속에 적용하는 방법이 활발하게 연구되고 있다. 이미지 처리분야에서 널리 사용되는 CNN(Convolutional Neural Network)을 이용한 구조가 주로 사용되고 있으며, 더 나아가서 MRI 분야의 지식을 적용한 구조도 활발하게 연구되고 있다. 대표적인 예로, ADMM이나 CP 알고리즘의 반복 알고리즘을 풀어서 각각의 업데이트 단계를 한 층의 신경망 계층으로 하고, 이 신경망 계층들을 일렬로 쌓아 종단간(end-to-end) 훈련으로 학습하게 하는 언폴딩(unfolding) 기법이 있다.

[0005] 본 발명에서는, ℓ_1 정규화 CS-MRI 최적화 문제를 직접적으로 풀기 위해 원시-쌍대 문제(또는 원초-쌍대 문제)의 최적화 조건을 이용해 연립방정식을 구성한다. 이 방정식을 풀기 위해, 선조건 켤레 기울기법(Preconditioned Conjugate Gradient, PCG)을 언폴딩(unfolding)한 신경망들을 일렬로 쌓아 종단간(end-to-end) 방식으로 학습시킨다. 본 발명에서 이용하는 원시-쌍대 문제는 최소 변환 신경망과 연관된 쌍대 연결을 고려하여 최소 변환을 효과적으로 학습할 수 있다. 기존 방법들과 다르게, 본 발명은 원시 및 쌍대 변수들을 번갈아가며 업데이트 하는 기존의 기법과는 다르게 동시에 업데이트한다. 이에 따라, 본 발명은 기존 방법들에 비해 더 선명한 영상을 복원할 수 있다.

선행기술문헌

특허문헌

- [0006] (특허문헌 0001) 대한민국 공개특허 제2022-0082302호 (2022.06.17. 공개)
(특허문헌 0002) 대한민국 공개특허 제2017-0078516호 (2017.07.07. 공개)
(특허문헌 0003) 대한민국 공개특허 제2019-0109141호 (2019.09.25. 공개)

발명의 내용

해결하려는 과제

- [0007] 본 발명의 목적은 교대 최적화 알고리즘의 구조적 복잡성을 계승하는 것을 피하기 위해 CS-MRI의 블록 최적화 문제를 직접적으로 푸는 신경망을 설계하여 더 선명한 MRI를 제공하는 것이다.

과제의 해결 수단

- [0008] 본 발명의 일 실시예에 따른 MRI 이미지 복원 방법은, 적어도 프로세서(Processor)를 포함하는 컴퓨팅 장치에 의해 수행되는, CS-MRI(Compressed Sensing-Magnetic Resonance Imaging) 기반의 MRI 이미지 복원 방법으로써, 수학적 1에 의해 정의되는 목적 선형방정식을 설정하는 단계, 상기 목적 선형방정식을 풀이하기 위한 CNN(Convolutional Neural Network) 기반의 학습 모델을 생성하는 단계, 및 학습 데이터를 이용하여 상기 학습 모델을 학습하여 이미지 복원 모델을 생성하는 단계를 포함한다.

발명의 효과

- [0009] 본 발명의 실시예들에 의하면, 언더샘플링된 MRI 이미지 복원에서 기존의 언폴딩(unfolding) 방법들에 비해 더 선명한 이미지를 복원할 수 있으며, 또한 언폴딩(unfolding)에 기반하지 않은 방법들에 비해 적은 양의 신경망 파라미터를 사용한다는 장점이 있다.

도면의 간단한 설명

- [0010] 본 발명의 상세한 설명에서 인용되는 도면을 보다 충분히 이해하기 위하여 각 도면의 상세한 설명이 제공된다.

도 1은 최소변환 신경망을 나타내는 블록도이다.

도 2는 본 발명에서 제안하는 각 연산자를 학습하는 CNN 구조를 나타내는 블록도이다.

도 3은 $N_{PCG}=2$ 인 경우의 PCG 신경망(선조건 켄레 기울기 신경망)을 나타내는 블록도이다.

도 4는 연쇄 신경망의 구체적인 구조를 나타내는 블록도이다.

도 5는 본 발명에서 제안하는 연산자를 학습하는 신경망 구조를 나타내는 블록도이다.

도 6은 본 발명의 일 실시예에 따른 이미지 복원 모델 생성 방법을 설명하기 위한 흐름도이다.

발명을 실시하기 위한 구체적인 내용

- [0011] 본 명세서에 개시되어 있는 본 발명의 개념에 따른 실시예들에 대해서 특정한 구조적 또는 기능적 설명들은 단지 본 발명의 개념에 따른 실시예들을 설명하기 위한 목적으로 예시된 것으로서, 본 발명의 개념에 따른 실시예들은 다양한 형태로 실시될 수 있으며 본 명세서에 설명된 실시예들에 한정되지 않는다.

- [0012] 본 발명의 개념에 따른 실시예들은 다양한 변경들을 가할 수 있고 여러 가지 형태들을 가질 수 있으므로 실시예들을 도면에 예시하고 본 명세서에서 상세하게 설명하고자 한다. 그러나, 이는 본 발명의 개념에 따른 실시예들을 특정한 개시 형태들에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물, 또는 대체물을 포함한다.

- [0013] 제1 또는 제2 등의 용어는 다양한 구성 요소들을 설명하는데 사용될 수 있지만, 상기 구성 요소들은 상기 용어들에 의해 한정되어서는 안 된다. 상기 용어들은 하나의 구성 요소를 다른 구성 요소로부터 구별하는 목적으로만, 예컨대 본 발명의 개념에 따른 권리 범위로부터 벗어나지 않은 채, 제1 구성 요소는 제2 구성 요소로 명명될 수 있고 유사하게 제2 구성 요소는 제1 구성 요소로도 명명될 수 있다.

- [0014] 어떤 구성 요소가 다른 구성 요소에 "연결되어" 있다거나 "접속되어" 있다고 언급된 때에는, 그 다른 구성 요소에 직접적으로 연결되어 있거나 또는 접속되어 있을 수도 있지만, 중간에 다른 구성 요소가 존재할 수도 있다고 이해되어야 할 것이다. 반면에, 어떤 구성 요소가 다른 구성 요소에 "직접 연결되어" 있다거나 "직접 접속되어" 있다고 언급된 때에는 중간에 다른 구성 요소가 존재하지 않는 것으로 이해되어야 할 것이다. 구성 요소들 간의 관계를 설명하는 다른 표현들, 즉 "~사이에"와 "바로 ~사이에" 또는 "~에 이웃하는"과 "~에 직접 이웃하는" 등도 마찬가지로 해석되어야 한다.
- [0015] 본 명세서에서 사용한 용어는 단지 특정한 실시예를 설명하기 위해 사용된 것으로서, 본 발명을 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "포함하다" 또는 "가지다" 등의 용어는 본 명세서에 기재된 특징, 숫자, 단계, 동작, 구성 요소, 부분품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성 요소, 부분품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.
- [0016] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가진다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥상 가지는 의미와 일치하는 의미를 갖는 것으로 해석되어야 하며, 본 명세서에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.
- [0017] 이하, 본 명세서에 첨부된 도면들을 참조하여 본 발명의 실시예들을 상세히 설명한다. 그러나, 특허출원의 범위가 이러한 실시예들에 의해 제한되거나 한정되는 것은 아니다. 각 도면에 제시된 동일한 참조 부호는 동일한 부재를 나타낸다.
- [0018] N (N 은 임의의 자연수) 개의 픽셀을 가지는 (2 채널) 이미지를 나타내는 벡터 $\mathbf{u} \in \mathbb{R}^{2N}$, (2D) 푸리에 변환행렬 $D \in \mathbb{R}^{N \times N}$, 언더샘플링 연산자를 나타내는 행렬 $M_s \in \mathbb{R}^{M \times N}$, CNN으로 학습된 최소 변환 $\Psi(\cdot)$ 에 대한 ℓ_1 -노름 정규화 볼록 최적화 문제는 아래의 수학적 1과 같다.
- [0019] [수학적 1]
- [0020]
$$\min_{\mathbf{u}} \frac{1}{2} \|\mathbf{M}_s \mathbf{D} \mathbf{u} - \mathbf{y}\|_2 + \alpha \|\Psi(\mathbf{u})\|_1$$
- [0021] 수학적 1에서, $\mathbf{u}$ 는 원본 MRI 이미지를, $\mathbf{y}$ 는 언더샘플링된 k-공간(k-space) 데이터를 나타내는 행렬을 의미할 수 있다.
- [0022] 수학적 1의 해를 구하기 위해, 아래 수학적 2의 원시-쌍대 형태를 본다.
- [0023] [수학적 2]
- [0024]
$$\begin{aligned} \hat{\mathbf{u}} &= \min_{\mathbf{u}} \max_{\mathbf{w}} L(\mathbf{w}, \mathbf{u}) \\ &= \min_{\mathbf{u}} \max_{\mathbf{w}} -G^*(\mathbf{w}) + \frac{1}{2\alpha} \|\mathbf{M}_s \mathbf{D} \mathbf{u} - \mathbf{y}\|_2^2 + \langle \mathbf{w}, \Psi(\mathbf{u}) \rangle \end{aligned}$$
- [0025] 수학적 2에서, $\mathbf{w}$ 는 쌍대 변수(dual variable)이고, $G^*(\mathbf{w})$ 는 $\|\Psi(\mathbf{w})\|_1$ 의 쌍대 켤레(convex conjugate)로 아래 수학적 3과 같이 정의된다.
- [0026] [수학적 3]
- [0027]
$$G^*(\mathbf{w}) = \begin{cases} 0 & \text{if } \|\mathbf{w}\|_{\infty} \leq 1 \\ \infty & \text{otherwise} \end{cases}$$
- [0028] 최적화 조건을 구하기 위한 $L(\mathbf{w}, \mathbf{u})$ 의 $\mathbf{w}$ 에 대한 하방미분은 아래 수학적 4와 같고, $\mathbf{u}$ 에 대한 하방미분은 아래 수학적 5와 같다.

[0029] [수학식 4]

$$\begin{aligned} \partial_w L(w, u) &= -\partial_w G^*(w) + \Psi(w) \\ &= \Psi(w) - \{v | \langle v, z \rangle \leq \langle v, w \rangle, \text{ for all } \|z\|_\infty \leq 1\} \end{aligned}$$

[0030]

[0031] [수학식 5]

$$\partial_u L(w, u) = \frac{1}{\alpha} (D^H M_s D u - D^H y) + \frac{\partial \Psi(u)^T}{\partial u} w$$

[0032]

따라서, 수학식 1의 해는 아래 수학식 6의 최적화 조건을 만족한다.

[0034] [수학식 6]

$$\begin{cases} f(w, u) = w - \text{sgn}(\Psi(u)) = 0 \\ g(w, u) = K_s u - D^H y + \alpha \frac{\partial \Psi(u)^T}{\partial u} w = 0 \end{cases}$$

[0035]

수학식 6에서, $K_s = D^H M_s D$ 으로써, 이미지 도메인에서 서브샘플링 연산(subsampling operation)의 효과(또는 영향)를 나타낸다.

[0037]

본 발명에서 제안하는 신경망 구조는 주어진 임의의 $(w, u) \in \mathbb{R}^{4N}$ 보다 $[w^T, u^T]^T$ 를 수학식 2를 더 잘 최적화하는 $q \in \mathbb{R}^{4N}$ 을 찾는 것을 목표로 한다. 이를 위해, 본 발명의 신경망 구조는 아래 수학식 7의 선형 방정식을 푸는 것을 기반으로 설계된다.

[0038] [수학식 7]

$$\begin{bmatrix} I & \mathbb{O} \\ \text{diag}([\alpha^T, \alpha^T]^T) \frac{\partial \Psi(u)^T}{\partial u} & K_s \end{bmatrix} q = - \begin{bmatrix} f(w, u) \\ g(w, u) \end{bmatrix}$$

[0039]

이때, 대각 행렬(diagonal matrix) $\text{diag}(\cdot)$ 는 벡터를 대각 성분으로 가지는 행렬을 의미하는 연산자이며, $\alpha \in \mathbb{R}^N$ 는 소정의 파라미터로써 정규화항의 트레이드-오프(trade-off) 파라미터를 일반화한 것, 즉 정규화된 트레이드-오프 파라미터(generalized trade-off parameter)를 나타낸다. 또한, q 는 이미지와 쌍대 벡터를 업데이트하는 방향을 나타낼 수 있다.

[0041]

실시예에 따라, 수학식 7은 $Hq=b$ 로 나타낼 수도 있다. 여기서, $H \in \mathbb{R}^{4N \times 4N}$ 와 $b \in \mathbb{R}^{4N}$ 는 다음 수학식과 같이 정의된다.

$$H = \begin{bmatrix} I & \mathbb{O} \\ \text{diag}([\alpha^T, \alpha^T]^T) \frac{\partial \Psi(u)^T}{\partial u} & K_s \end{bmatrix}$$

[0042]

$$b = - \begin{bmatrix} f(w, u) \\ g(w, u) \end{bmatrix}$$

[0043]

[최소 변환 신경망]

[0045]

CS-MRI에서 최적의 최소변환 $\Psi(\cdot)$ 은 알려져 있지 않기 때문에, CNN을 이용하여 데이터에서 학습한다. 최소변환을 학습하는 CNN구조는 아래 수학식 8과 같은 2층의 CNN을 사용할 수 있다.

[0046] [수학식 8]

$$\Psi(u) = Ah(Bu)$$

[0047]

수학식 8에서, $A \in \mathbb{R}^{2N \times 32N}$ 와 $B \in \mathbb{R}^{32N \times 2N}$ 는 각 CNN 계층의 3x3 합성곱 연산을 나타내는 행렬이며, $h(\cdot)$ 는 PReLU(Parameterized Rectified Linear Unit)을 나타낸다. 이때, 수학식 7의 $\partial \Psi(u)^T / \partial u$ 항은 아래 수

학식 9와 같이 계산할 수 있다.

[수학식 9]

$$\frac{\partial \Psi(\mathbf{u})^\top}{\partial \mathbf{u}} = \mathbf{B}^\top \text{diag}(h'(\mathbf{B}\mathbf{u})) \mathbf{A}^\top$$

여기서, h' 은 파라미터 a 를 갖는 h 의 미분을 나타내며, 아래 수학식 10과 같이 계산된다.

[수학식 10]

$$h'(x) = \begin{cases} 1 & \text{for } x > 0 \\ (a+1)/2 & \text{for } x = 0 \\ 0 & \text{otherwise} \end{cases}$$

전치 행렬(transposed matrix) $\mathbf{A}^\top$ 와 $\mathbf{B}^\top$ 은 해당 합성곱 신경망층의 필터와 같은 값을 가지는 필터를 이용한 전치 합성곱(Transposed Convolution) 연산으로 계산한다.

더 좋은 성능을 위해, Fire Module을 이용하여 최소변환 신경망 $\Psi(\mathbf{u})$ 를 더 복잡한 CNN 구조로 설계할 수 있으며, 아래 수학식 11과 같다.

[수학식 11]

$$\Psi(\mathbf{u}) = \mathbf{A}h\left(\begin{bmatrix} \mathbf{B} \\ \mathbf{C} \end{bmatrix}h(Dh(E\mathbf{u}))\right)$$

$\mathbf{A} \in \mathbb{R}^{2N \times 32N}$, $\mathbf{C} \in \mathbb{R}^{16N \times 4N}$, $\mathbf{E} \in \mathbb{R}^{32N \times 2N}$ 은 3x3 크기의 합성곱 커널(convolution kernel, 또는 필터)을 갖는 합성곱 신경망 층을 나타내는 행렬이며, $\mathbf{B} \in \mathbb{R}^{16N \times 4N}$, $\mathbf{D} \in \mathbb{R}^{4N \times 32N}$ 은 1x1 크기의 합성곱 커널(또는 필터)을 갖는 합성곱 신경망 층을 나타내는 행렬이다. 수학식 11의 최소변환 신경망을 사용하는 경우에도, 수학식 9와 유사하게 연쇄 법칙을 이용해 $\partial \Psi(\mathbf{u})^\top / \partial \mathbf{u}$ 를 계산할 수 있다. 수학식 8와 수학식 11에 나타낸 최소변환 신경망은 도 1에서 블록도로 나타내어져 있다.

[PCG 신경망 및, PCG 연쇄 신경망]

수학식 7에 나타내어진 연립방정식을 풀기 위해, PCG 알고리즘을 언폴딩(unfolding)한 신경망인 PCG 신경망을 설계한다. PCG 신경망은 수학식 12와 같이 초기값을 설정할 수 있으며, PCG 신경망의 각 계층은 아래의 수학식 13의 계산을 N_{PCG} 번 반복 수행한다.

[수학식 12]

$$\begin{aligned} \alpha &= \alpha(\mathbf{u}) \\ \mathbf{b}_0 &= -[\mathbf{f}(\mathbf{w}, \mathbf{u})^\top, \mathbf{g}(\mathbf{w}, \mathbf{u})^\top]^\top \\ \mathbf{p}_0 &= \mathbf{A}(\mathbf{b}_0) \\ \mathbf{q}_0 &= \mathbf{0} \\ \mathbf{z}_0 &= \mathbf{A}(\mathbf{b}_0) \end{aligned}$$

[수학식 13]

$$\begin{aligned} \gamma_k &= \mathbf{I}(\mathbf{b}_k, \mathbf{z}_k, \mathbf{p}_k, \mathbf{H}\mathbf{p}_k) \\ \mathbf{q}_{k+1} &= \mathbf{q}_k + \gamma_k \circ \mathbf{z}_k \\ \mathbf{b}_{k+1} &= \mathbf{b}_k - \gamma_k \circ \mathbf{H}\mathbf{p}_k \\ \mathbf{z}_{k+1} &= \mathbf{A}(\mathbf{b}_{k+1}) \\ \omega_k &= \mathbf{\Omega}(\mathbf{b}_k, \mathbf{b}_{k+1}, \mathbf{z}_k, \mathbf{z}_{k+1}) \\ \mathbf{p}_{k+1} &= \mathbf{z}_{k+1} + \omega_k \circ \mathbf{p}_k \end{aligned}$$

위 수학식 12와 수학식 13에서 $\alpha(\cdot)$, $\mathbf{I}(\cdot)$, $\mathbf{A}(\cdot)$, $\mathbf{\Omega}(\cdot)$ 연산자는 CNN으로 학습되며, 구체적인 구조는 도 2의 블록도를 참조할 수 있다. $N_{\text{PCG}}=2$ 인 경우의 PCG 신경망의 예시는 도 3에 블록도로 나타내져 있다. 즉, 도 3에서, PCG 신경망은 2 개의 단일 PCG 신경망이 직렬로 연결되어 있는 형태를 갖는다.

[0066] 구체적으로, $\alpha(\cdot)$ 연산자(또는 네트워크)는 u 를 이용하여 트레이드-오프 파라미터 α 를 벡터 $\mathbf{a}$ 로 일반화한다 (generalize). $I(\cdot)$ 연산자(또는 네트워크)는 $\mathbf{b}_k$, $M^{-1}\mathbf{b}_k$, $\mathbf{p}_k$, 및 $H\mathbf{p}_k$ 로부터 γ_k 를 근사한다 (approximate). $A(\cdot)$ 연산자(또는 네트워크)는 $\mathbf{b}_k$ 로부터 $\mathbf{z}_k := M^{-1}\mathbf{b}_k$ 를 근사한다. $\Omega(\cdot)$ 연산자(또는 네트워크)는 $\mathbf{b}_{k+1}$, $M^{-1}\mathbf{b}_k$, $\mathbf{b}_k$, 및 $M^{-1}\mathbf{b}_{k+1}$ 로부터 ω_k 를 근사한다.

[0067] 본 발명의 전체적인 구조는 $N_{\text{PD-PCG}}$ 개의 PCG 신경망을 연속적으로 연결하여 만들어 진다. 연쇄 신경망의 구체적인 구조는 도 4에 블록도로 나타나져 있다. 데이터 적응 업데이트 스텝 크기를 위해, 도 5에 나타내어진 신경망으로 이루어진 $\mu(\cdot)$ 연산자를 이용해 아래 수학적 식 14와 같이 PCG 신경망들의 입력과 출력이 연결된다.

[0068] [수학적 식 14]

$$\begin{bmatrix} w_{l+1} \\ u_{l+1} \end{bmatrix} = \begin{bmatrix} w_l \\ u_l \end{bmatrix} + \mu \left(\begin{bmatrix} w_l \\ u_l \end{bmatrix} \right) \circ p_l$$

[0070] 수학적 식 14에서, p_l 은 1번째 PCG 신경망의 출력값이며, (w_{l+1}, u_{l+1}) 은 $(l+1)$ 번째 PCG 신경망의 입력값 초기화에 사용된다.

[0071] [실시예]

[0072] 이하에서는, 본 발명의 가속 MRI 일 실시예에 따른 이미지 복원 성능을 다른 기법과 비교하기로 한다. 가속 MRI를 위해 사용한 MRI 데이터는 NYU fastMRI single-coil knee 데이터셋이 사용될 수 있다. 데이터셋은 학습 및 검증(validation) 데이터를 포함해 584개의 PD(Positron Density without Fat Supression), 588개의 PDFS(Positron Density with Fat Suppression) 볼륨으로 구성되어 있다. 효율적인 훈련을 위해, 대부분의 신호가 볼륨의 중심부에 위치한다는 사실을 이용하여, 각 학습 데이터의 볼륨의 중심부분 8개의 슬라이스만 사용하였다. 실험에서는, 아래 표 1과 같이 훈련, 검증(validation), 평가 데이터셋으로 나누어 사용하였다. 언더샘플링을 위해 각 데이터의 k-공간의 12.5% (center fraction 0.08), 25% (center fraction 0.04)의 샘플만 사용했으며, 샘플링 마스크는 도 5와 같이 균일공간 및 랜덤 카르테시안 마스크를 사용했다. 신경망의 학습은 언더샘플링된 이미지를 신경망을 이용해 복원한 이미지와 원본 이미지 사이의 ℓ_1 을 학습 로스로 설정하여 종단간(end-to-end) 학습 기법으로 진행했으며, 로스의 역전파에서 ADAM 옵티마이저(optimizer)를 사용하였다. 학습률은 0.001을 사용했으며, 모든 신경망은 50 에폭(epoch) 동안 학습하였다. fastMRI 데이터셋의 정답 이미지는 중심 근처의 320x320 크기의 이미지로 설정되어 있기 때문에, 성능측정 시에 복원 이미지의 중심 320x320를 잘라내어 비교하였다.

[0073] [표 1]

	볼륨		슬라이스	
	PD	PDFS	PD	PDFS
학습	424	429	3392	3432
Validation	60	60	2130	2130
평가	60	60	2194	2114

[0075] 표 2, 표 3, 표 4, 및 표 5는 여러 종류의 언더샘플링 마스크를 사용했을 때, 본 발명과 기존의 가속 MRI 기법들의 성능을 NMSE(Normlized Mean Squared Error), PSNR, SSIM(Structural Similarity), 1개 볼륨 복원에 걸린 시간 및 학습 파라미터의 수로 비교한 것이다.

[0076] [표 2]

	NMSE		PSNR (dB)		SSIM		time (ms)		파라미터
	PD	PDFS	PD	PDFS	PD	PDFS	PD	PDFS	
U-Net (Complex)	0.0174	0.0557	33.40	29.46	0.8063	0.6150	3.899	3.944	3M
PD-Net	0.0161	0.0557	33.85	29.50	0.8122	0.6177	13.32	13.09	224K
ISTA-Net	0.0155	0.0551	34.06	29.53	0.8143	0.6150	12.10	12.66	196K
ISTA-Net+	0.0151	0.0552	34.18	29.52	0.8161	0.6178	14.18	15.36	381K
본 발명 ($N_{\text{PCG}} = 2, N_{\text{PD-PCG}} = 7$)	0.0142	0.0543	34.52	29.60	0.8218	0.6190	43.16	42.29	162K
본 발명 ($N_{\text{PCG}} = 3, N_{\text{PD-PCG}} = 7$)	0.0140	0.0541	34.61	29.63	0.8232	0.6204	54.93	57.17	243K

[0078] 표 2는 25% 랜덤 카르테시안 언더샘플링 마스크를 사용한 평가 결과를 나타낸다.

[표 3]

	NMSE		PSNR (dB)		SSIM		time (ms)		파라미터
	PD	PDFS	PD	PDFS	PD	PDFS	PD	PDFS	
U-Net (Complex)	0.0166	0.0555	33.60	29.49	0.8105	0.6132	4.741	4.555	3M
PD-Net	0.0157	0.0552	33.92	29.53	0.8140	0.6172	13.79	14.14	224K
ISTA-Net	0.0154	0.0550	34.03	29.53	0.8146	0.6147	13.06	12.99	196K
ISTA-Net+	0.0146	0.0546	34.34	29.59	0.8202	0.6189	15.83	15.37	381K
본 발명 ($N_{PCG} = 2, N_{PD-PCG} = 7$)	0.0142	0.0543	34.51	29.62	0.8218	0.6186	44.48	44.07	162K
본 발명 ($N_{PCG} = 3, N_{PD-PCG} = 7$)	0.0139	0.0543	34.60	29.62	0.8239	0.6175	57.41	56.97	243K

[0080]

[0081] 표 3은 25% 균일 카르테시안 언더샘플링 마스크를 사용한 평가 결과를 나타낸다.

[표 4]

	NMSE		PSNR (dB)		SSIM		time (ms)		파라미터
	PD	PDFS	PD	PDFS	PD	PDFS	PD	PDFS	
U-Net (Complex)	0.0349	0.0742	30.13	28.11	0.7408	0.5316	4.780	4.617	3M
PD-Net	0.0339	0.0751	29.79	28.08	0.7312	0.5305	13.74	14.11	224K
ISTA-Net	0.0347	0.0750	30.20	28.07	0.7338	0.5259	13.04	12.82	196K
ISTA-Net+	0.0314	0.0724	30.69	28.25	0.7428	0.5335	15.01	15.19	381K
본 발명 ($N_{PCG} = 2, N_{PD-PCG} = 7$)	0.0299	0.0729	30.89	28.22	0.7481	0.5317	44.08	46.10	162K
본 발명 ($N_{PCG} = 3, N_{PD-PCG} = 7$)	0.0295	0.0718	30.94	28.30	0.7489	0.5347	60.84	59.58	243K

[0083]

[0084] 표 4는 12.5% 랜덤 카르테시안 언더샘플링 마스크를 사용한 평가 결과를 나타낸다.

[표 5]

	NMSE		PSNR (dB)		SSIM		time (ms)		파라미터
	PD	PDFS	PD	PDFS	PD	PDFS	PD	PDFS	
U-Net (Complex)	0.0325	0.0731	30.42	28.17	0.7474	0.5325	4.822	4.699	3M
PD-Net	0.0376	0.0738	29.85	28.13	0.7346	0.5317	14.06	13.73	224K
ISTA-Net	0.0334	0.0752	30.31	28.03	0.7357	0.5233	13.45	13.08	196K
ISTA-Net+	0.0316	0.0722	30.62	28.25	0.7429	0.5319	15.51	15.68	381K
본 발명 ($N_{PCG} = 2, N_{PD-PCG} = 7$)	0.0299	0.0723	30.83	28.24	0.7467	0.5332	44.81	44.75	162K
본 발명 ($N_{PCG} = 3, N_{PD-PCG} = 7$)	0.0276	0.0712	31.18	28.32	0.7523	0.5347	57.16	58.23	243K

[0086]

[0087] 표 5는 12.5% 균일 카르테시안 언더샘플링 마스크를 사용한 평가 결과를 나타낸다.

[0088] 상기 표를 참고하면, 대부분의 경우에 본 발명을 이용해 더 선명한 MRI 이미지를 복원할 수 있음을 알 수 있다. 예시로, 25% 랜덤 카르테시안 언더샘플링 마스크를 사용한 시행의 경우, U-Net과 비교해 최대 1.21 dB 더 높은 PSNR의 이미지를 복원할 수 있다. 또한, ISTA-Net+와 비교했을 때, 본 발명을 이용해 0.43 dB 더 높은 PSNR의 이미지를 복원할 수 있다. 상기 표에서, PSNR 이외의 성능 지표에서도 본 발명이 기존 방법들과 비교해 높은 성능을 보여주는 것을 확인할 수 있다.

[0089] 도 6은 본 발명의 일 실시예에 따른 이미지 복원 모델 생성 방법을 설명하기 위한 흐름도이다.

[0090] 도 6을 참조하면, 이미지 복원 방법 등으로 명명될 수도 있는 이미지 복원 모델 생성 방법은 적어도 프로세서(Processor) 및/또는 메모리(Memory)를 포함하는 컴퓨팅 장치에 의해 수행될 수 있다. 따라서, 이미지 복원 모델 생성 방법을 이루는 단계를 중 적어도 일부는 컴퓨팅 장치에 포함되는 프로세서의 동작으로 이해될 수도 있다. 컴퓨팅 장치는 PC(Personal Computer), 서버(Server), 랩탑 컴퓨터, 태블릿 PC, 노트북 등으로 구현될 수 있다. 이하, 이미지 복원 모델 생성 방법을 설명함에 있어, 앞선 기재와 중복되는 내용에 관하여는 그 구체적인 설명을 생략하기로 한다.


[0091] 우선, 풀이의 대상이 되는 목적 선형방정식(연립방정식)이 설정된다(S110). 목적 선형방정식은 수학식 7과 같다.

[0092] 다음으로, 목적 선형방정식을 풀이기 위한 학습 모델이 생성된다(S120). 학습 모델은 CNN 기반의 모델로써, 도 5와 같은 구조를 가질 수 있다.


- [0093] 소정의 학습 데이터를 이용하여 학습 모델을 학습함으로써, 이미지 복원 모델이 생성될 수 있다(S130). 학습 모델은 각각이 원본 MRI 이미지와 복원된 MRI 이미지를 포함하는 이미지 쌍들을 포함할 수 있다.
- [0094] 추가적으로, 본 발명에 대한 보다 상세한 설명은 Moogyong Kim 등의 논문(Moogyong Kim, and Wonzoo Chung, A cascade of preconditioned conjugate gradient networks for accelerated magnetic resonance imaging, Computer Methods and Programs in Biomedicine 225 (2022)) 등이 참조될 수 있다.
- [0095] 이상에서 설명된 장치는 하드웨어 구성 요소, 소프트웨어 구성 요소, 및/또는 하드웨어 구성 요소 및 소프트웨어 구성 요소의 집합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성 요소는, 예를 들어, 프로세서, 컨트롤러, ALU(Arithmetic Logic Unit), 디지털 신호 프로세서(Digital Signal Processor), 마이크로컴퓨터, FPA(Field Programmable array), PLU(Programmable Logic Unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(Operation System, OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술 분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(Processing Element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 컨트롤러를 포함할 수 있다. 또한, 병렬 프로세서(Parallel Processor)와 같은, 다른 처리 구성(Processing Configuration)도 가능하다.
- [0096] 소프트웨어는 컴퓨터 프로그램(Computer Program), 코드(Code), 명령(Instruction), 또는 이들 중 하나 이상의 조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(Collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성 요소(Component), 물리적 장치, 가상 장치(Virtual Equipment), 컴퓨터 저장 매체 또는 장치, 또는 전송되는 신호 파(Signal Wave)에 영구적으로, 또는 일시적으로 구체화(Embody)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.
- [0097] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(Magnetic Media), CD-ROM, DVD와 같은 광기록 매체(Optical Media), 플롭티컬 디스크(Floptical Disk)와 같은 자기-광 매체(Magneto-optical Media), 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다. 상기된 하드웨어 장치는 실시예의 동작을 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.
- [0098] 본 발명은 도면에 도시된 실시예를 참고로 설명되었으나 이는 예시적인 것에 불과하며, 본 기술 분야의 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 타 실시예가 가능하다는 점을 이해할 것이다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성 요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성 요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다. 따라서, 본 발명의 진정한 기술적 보호 범위는 첨부된 등록청구범위의 기술적 사상에 의해 정해져야 할 것이다.

도면


도면1




도면2




도면3



도면4



도면5



도면6

