

# 전이학습을 수행한 신경망을 사용한 압축센싱 심장 자기공명영상

## Compressed-Sensing Cardiac CINE MRI using Neural Network with Transfer Learning

박성재\*, 윤종현\*\*, 안창범\*

Seong-Jae Park\*, Jong-Hyun Yoon\*\*, Chang-Beom Ahn\*

### Abstract

Deep artificial neural network with transfer learning is applied to compressed sensing cardiovascular MRI. Transfer learning is a method that utilizes structure, filter kernels, and weights of the network used in prior learning for current learning or application. The transfer learning is useful in accelerating learning speed, and in generalization of the neural network when learning data is limited. From a cardiac MRI experiment, with 8 healthy volunteers, the neural network with transfer learning was able to reduce learning time by a factor of more than five compared to that with standalone learning. Using test data set, reconstructed images with transfer learning showed lower normalized mean square error and better image quality compared to those without transfer learning.

### 요약

전이학습을 수행한 심층 인공신경망을 압축센싱 심혈관 자기공명영상에 적용하였다. 전이학습은 선행학습 신경망의 구조나 필터 커널, 가중치를 현재의 학습이나 응용에 활용하는 방법이다. 전이학습은 학습 속도를 향상시키고, 학습 데이터가 제한적일 때 신경망의 일반화에 도움이 된다. 8명의 건강한 지원자가 참여한 심장 자기공명영상 실험에서 전이학습을 수행한 신경망은 단독학습 신경망에 비해 학습시간이 5배 이상 단축되었다. 시험 데이터에 대해서도 전이학습을 수행한 신경망은 전이학습을 수행하지 않은 신경망에 비하여 낮은 정규화 평균제곱오차와 향상된 재구성 영상화질을 보였다.

*Key words* : Compressed sensing, Deep learning, U-net, Transfer learning, Cardiovascular MRI

\* Dept. of Electrical Engineering, Kwangwoon University

\*\* Neuroscience Research Institute Gachon University

★ Corresponding author

E-mail : cbahn@kw.ac.kr, Tel : +82-2-940-5148

※ Acknowledgment

“The work reported in this paper was conducted during the sabbatical year of Kwangwon University in 2018.

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. NRF-2019R1A2C2005660).

Manuscript received Dec. 9, 2019; revised Dec. 27, 2019; accepted Dec. 30, 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

## I. 서론

심장 CINE(CINeMa) 자기공명영상(Magnetic resonance imaging: MRI)은 심장질환 진단을 위해 필수적인 영상방법이다. 움직이는 심장 영상을 얻기 위해서는 호흡정지와 심전에 동기화된 측정이 필요하며 호흡정지 시간 내에 영상을 고속으로 측정하기 위해서는 나이키스트 비율보다 낮은 성긴 샘플링이 요구된다. 기존의 압축센싱 방법은 재구성영상의 L1-norm을 최소화하기 위해 비선형방정식을 반복적으로 적용하여 수렴하는 해를 구하였다[1-3]. 이러한 방법은 L2-norm 최소화 방법에 비하여 재구성영상이 선명한 장점이 있지만 긴 재구성 시간이 요구된다.

최근에는 다양한 분야에서 데이터 기반의 딥러닝(Deep learning)을 사용한 인공 신경망(Neural network: NN)이 큰 성과를 거두고 있다. 의학영상 분야에서도 영상분할, 재구성, 압축센싱 등에 적용한 사례들이 보고되고 있다[4-9]. 의학 분야에서 딥 신경망의 응용은 임상 데이터의 모집과 라벨(label)의 어려움으로 인해 다른 응용 분야에 비해 상대적으로 제한적이다.

본 연구에서는 심장 CINE MRI의 압축센싱에 심층신경망을 사용하여 영상을 재구성하고자 한다. 신경망의 학습이나 평가에서 제한적인 의학 영상 데이터의 문제를 해결하기 위하여 공개된 데이터[10]를 추가로 사용하는 전이학습을 적용한다[11-12]. 전이학습이 심층신경망의 학습과 성능에 미치는 영향을 분석하였다.

## II. 본론

### 2.1. 데이터

신경망의 학습을 위해 두 종류의 심장 단축면(short axis view) 데이터를 사용하였다. 심장은 동적인 장기로 이를 측정하는 데이터는 총 4개의 변수( $x, y, z, t$ )로 나타내어지는 4차원 데이터이다. 각 변수들의 크기를 나타내는  $N_x, N_y, N_z, N_t$  중  $N_x$ 와  $N_y$ 는 영상의 크기,  $N_z$ 는 심장의 단면 층을 나타낸 slice 수,  $N_t$ 는 심장의 한 주기 움직임을 표현한 프레임 수이다.

#### 가. 풀 샘플링 데이터

심장 단축면 영상을 지도학습으로 사용하기 위

해 나이키스트 샘플링 비율을 만족하는 풀 샘플링 데이터를 정의하였다.

#### (1) K-데이터

K-데이터는 8명의 건강한 지원자를 대상으로 3.0 Tesla MRI(Siemens) 시스템에서 병렬영상기법 중 하나인 SENSE(SENSitivity-Encoding)와 Balanced-SSFP(Steady State Free Precession) 측정기법으로 획득한 비교적 고품질의 데이터이다[13].  $N_x, N_y, N_z, N_t$ 는 각각 256, 256, 12, 16~24이다. 총 2016장의 영상을 획득하였다. 본 연구의 목적은 압축센싱 K-데이터에 대한 심층신경망의 재구성 성능을 향상시키는 데 있다.

#### (2) Y-데이터

Y-데이터는 K-데이터의 적은 양을 보완하기 위해 추가로 사용된 공개된 심장 영상 데이터이다. York University에서 제공한 데이터로 총 33명의 환자에게 대한 데이터이다[10].  $N_x, N_y, N_z, N_t$ 는 각각 256, 256, 5~10, 20이다. 총 3440장의 영상을 사용하였다.

#### 나. 압축센싱 데이터

이론적으로 성긴 신호는 나이키스트 샘플링 비율보다 적게 샘플링하여도 손실없이 원신호를 복원할 수 있다. 심장 CINE MRI의 압축센싱은 데이터의 성긴성을 이용하여 나이키스트 샘플링 비율보다 낮은 샘플링을 하여 데이터 획득시간을 줄이는 방법이다. 그러나 심장 MRI 데이터가 이상적인 성긴 신호가 아니므로 압축비에 따라 손실이 발생한다.

본 논문에서는 컴퓨터 시뮬레이션으로 풀 샘플링 데이터를 시간, 공간주파수 영역에서 압축센싱한 데이터를 만들었다. 공간주파수 영역에서 DC를 평균으로 하는 가우시안 분포를 따라 직교형방식으로 샘플링하였다[3].

#### 다. 학습 및 시험데이터

##### (1) 학습 데이터

심층신경망은 학습한 압축비의 데이터에 대해 뛰어난 성능을 보인다. 임상에서 환자의 상태나 상황에 따라 압축비가 달라질 수 있으므로 압축비 별로 최적의 신경망을 구축한다면 많은 신경망이 있어야 할 것이다. 본 연구에서는 보편적인 압축비 2, 3,

4와 유사시 사용할 수 있는 압축비 8에 대해 압축 센싱 데이터를 만들었고 하나의 신경망이 대부분의 압축비에서 좋은 성능을 보이도록 압축비 4와 8의 데이터를 혼용하여 심층신경망을 학습하였다.

K-데이터에서 8명의 지원자 중 4명의 지원자에 대한 데이터 1104장을 압축비 4와 8로 압축센싱하여 총 2208장의 데이터를 구성하고 3배의 데이터 증강(augmentation)을 통해 총 6624장의 학습 데이터를 사용하였다. 데이터 증강은 좌우반전, 상하반전, 90도 회전을 임의의 확률로 순차적으로 적용하였다.

Y-데이터에서는 22명의 환자에 대한 데이터를 압축비 4와 8로 압축센싱하여 총 6880장의 데이터를 학습 데이터로 사용하였다.

(2) 시험 데이터

본 연구의 목적이 압축센싱된 K-데이터에 대한 심층신경망의 재구성 성능 향상에 있으므로, 시험 데이터를 K-데이터의 4명의 지원자 데이터로 구성하였다. 912장의 데이터를 압축비 2, 3, 4, 8로 압축센싱하여 총 3648장의 시험 데이터를 구성하였다.

2.2. 심층신경망 구조

본 연구에 사용한 심층신경망은 U-net으로 Convolutional Neural Network(CNN)의 한 형태이다[4]. U-net은 인코딩 과정, 디코딩 과정으로 구분된다. 인코딩 과정에서는 convolution(3×3×채널수)과 maxpooling(2×2) 방법으로 입력영상의 중요한 특징들을 추출할 수 있도록 구성하고, 디코딩 과정에서는 transpose

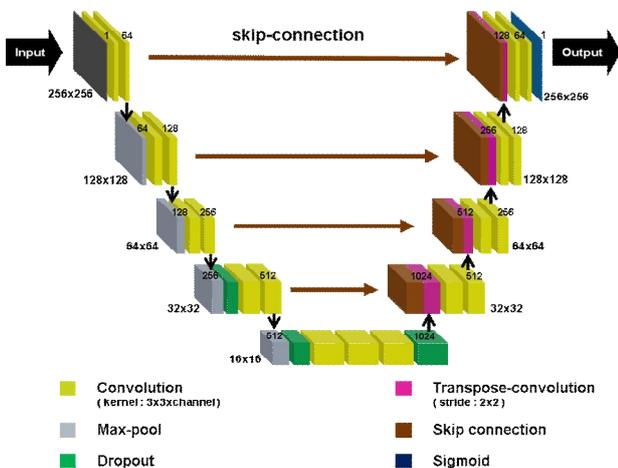


Fig. 1. U-net architecture.  
그림 1. U-net 구조

convolution(2×2)과 convolution(3×3×채널수)으로 인코딩된 데이터가 입력영상과 같은 크기로 재구성되도록 학습한다. convolution 출력은 정류선형유닛(rectified linear unit: ReLU)을 거친다. 최종단의 convolution(1×1×채널수)과 sigmoid 함수는 네트워크가 찾아낸 특징들을 조합하여 ground truth에 근사한 정규화된 영상을 재구성한다.

입력된 영상은 네트워크의 구조를 따라 인코딩과 디코딩 과정을 거쳐 256×256 크기의 영상이 16×16 크기의 feature map으로 변환된 후 다시 256×256 크기의 출력영상으로 전환된다. 이 때 영상의 feature 채널수는 1에서 1024로 증가하고 다시 1로 줄어든다. 사용한 심층신경망의 구조를 그림 1에 도시하였다.

2.3. 학습방법

심층신경망의 학습은 데이터의 양과 질에 의존하는데 적은 양의 데이터는 신경망의 성능을 저하시키거나 신경망의 편향의 원인이 된다.

그림 2는 제안한 신경망의 학습과정과 압축센싱 영상의 재구성 과정의 블록도이다.

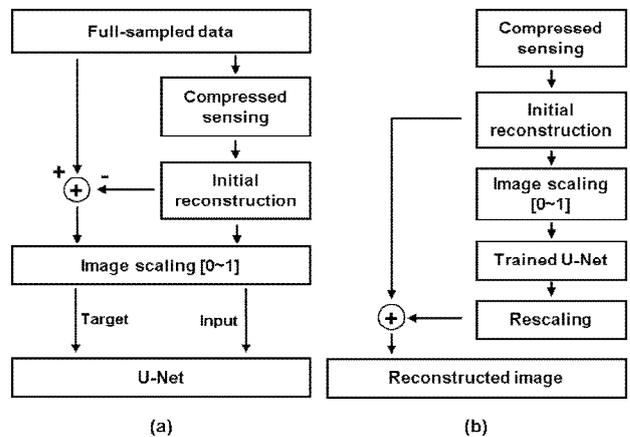


Fig. 2. Block diagrams of learning procedure (a) and reconstruction (b).

그림 2. 학습방법 (a) 및 재구성 (b) 블록도

학습과정에서 압축센싱 데이터에서 샘플링되지 않은 데이터를 근접한 프레임의 데이터로 선형 보간한 후, 2차원 Fourier 변환을 거쳐 초기 재구성영상을 얻는다. 풀 샘플링 데이터를 2차원 Fourier 변환하여 얻은 영상을 ground truth 영상, 그리고 초기 재구성영상과 ground truth 영상과의 차이를 오차영상이라 정의한다.

심층신경망의 학습데이터는 정규화된 초기 재구성영상  $i(x,y)$ 과 정규화된 오차영상  $e(x,y)$ 의 쌍으로 구성된다.  $i(x,y)$ 는 신경망의 입력이고,  $e(x,y)$ 는 신경망의 타겟이 된다. 초기 재구성영상과 오차영상에 대한 정규화는 각각 식 (1), (2)를 따른다.

$$i(x,y) = \frac{I(x,y)}{MAX} \tag{1}$$

$$e(x,y) = \frac{E(x,y)}{MAX} + 0.5 \tag{2}$$

$I(x,y), E(x,y)$ 는 앞서 정의한 초기 재구성영상, 오차영상이고  $MAX$ 는 초기 재구성영상의 최댓값이다. 신경망의 학습과정은 신경망의 입력에 대한 출력이 타겟과 일치하도록 필터 커널과 가중치를 스스로 조절한다.

영상의 재구성은 학습된 신경망에 정규화된 초기 재구성영상  $i(x,y)$ 를 입력하여, 정규화된 오차영상  $\hat{e}(x,y)$ 를 출력한다. 정규화된 오차영상은 역정규화 과정을 거쳐, 오차영상  $\hat{E}(x,y)$ 이 얻어지고, 이를  $I(x,y)$ 에 더함으로써 개선된 재구성이 이루어진다. 영상의 재구성과정에서 초기 재구성영상의 정규화는 식 (1)과 동일하며 역정규화는 식 (3)을 따른다.  $MAX$ 는 식 (1)에서 사용한 값과 동일하다.

$$\hat{E}(x,y) = MAX \cdot (\hat{e}(x,y) - 0.5) \tag{3}$$

신경망의 학습은 신경망의 필터 커널이나 가중치의 초기 값에 의해 영향을 받는다. 본 연구에서는 Xavier Glorot이 제안한 방법[14]으로 필터 커널이나 가중치를 랜덤하게 초기화한 후 신경망을 학습하는 것을 단독학습(standalone learning)이라 정의하였다. 학습에 사용된 하이퍼 파라미터들은 표 1과 같다.

Table 1. Hyper parameters used for learning.

표 1. 학습에 사용된 하이퍼 파라미터들

Optimizer	Adam
Activation	ReLU, Sigmoid
Loss	Binary_crossentropy
Weight Initializer	Glorot Uniform
Batch size	32
Learning Rate	$1 \times 10^{-5}$
Epoch	100

### 2.4. 전이학습

전이학습은 사전학습에서 훈련된 신경망의 필터 커널이나 가중치를 현재 신경망의 초기 값으로 사용하여 학습을 진행하는 방법이다. 전이학습은 신경망의 초기화의 한 방법으로 이용할 수 있다. 본 연구에서는 단독학습과 전이학습을 수행한 신경망들의 학습과 일반화 성능을 비교 검토하려 한다.

사전학습은 본 학습과 동일한 목적(압축센싱 데이터의 재구성)으로 동일한 구조의(U-net) 신경망으로 구성하였고, Y-데이터를 학습데이터로 진행하였다. 사전학습의 결과로 얻어진 신경망의 필터 커널과 가중치를 현재 신경망의 초기 값으로 사용하여 K-데이터를 학습한다. 사전학습에 사용한 하이퍼 파라미터들 중 epoch와 learning rate를 제외한 파라미터들은 표 1과 동일하다. learning rate는 사전학습에 사용된 학습데이터에 맞게 최적화하고 ( $8 \times 10^{-5}$ ), 최대 epoch는 50으로 고정하였다.

전이학습을 거친 신경망은 사전학습과 현재 학습을 통해 두 종류의 데이터를 학습하였으므로 한 종류의 데이터만을 학습하는 단독학습보다 신경망의 일반화가 더 잘 이루어졌다고 볼 수 있다. 본 연구에서는 사전학습을 오픈 데이터베이스(Y-데이터)를 이용하여 별도로 수행하였지만, 이와 달리 비슷한 연구나 응용에서 학습된 신경망을 차용하는 것도 가능할 것이다. 전이학습은 많은 양의 데이터를 효과적으로 학습할 수 있는 방법이다.

### 2.5. 결과

압축센싱 심장 MRI에 심층신경망을 사용하여 재구성영상을 얻었다. 단독학습과 전이학습을 사용한 신경망의 학습특성과 학습이 종료된 신경망의 일반화에 대한 평가를 비교 분석하였다.

#### 가. 학습과정

사전학습량이 현재학습에 미치는 영향을 확인하기 위하여 사전학습의 epoch를 10, 20, 50으로 수행한 신경망의 필터 커널과 가중치를 초기 값으로 현재학습을 진행한 3개의 신경망의 학습곡선을 그림 3에 나타내었다. 범례에서 ‘Transfer’ 다음의 숫자가 사전학습의 epoch를 나타낸다. 또한, 사전학습을 수행하지 않은 단독학습곡선(‘standalone’)도 함께 나타내었다.

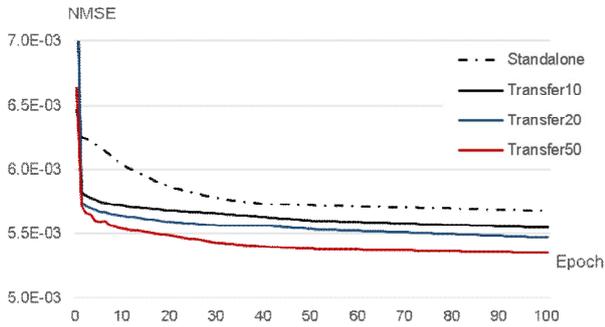


Fig. 3. Learning curves of NNs with standalone learning and transfer learning with different amounts of pre-learning. 그림 3. 단독학습 신경망과 사전학습량이 서로 다른 3개의 전이학습 신경망의 학습곡선

그림 3에서 가로 축은 epoch, 세로 축은 학습데이터에 대한 평균제곱오차(normalized mean square error: NMSE)를 나타낸다. 그림 3에서 보듯이 모든 전이학습의 학습곡선은 사전학습량에 상관없이 단독학습의 학습곡선보다 평균제곱오차가 낮고, 빠르게 줄어들었다. 예를 들면 전이학습을 수행한 신경망의 사전학습의 epoch가 각각 10, 20, 50일 때, 현재학습의 epoch가 20, 5, 2의 미세조정으로도 단독학습의 epoch가 100 일 때 보다 낮은 평균제곱오차를 갖는다. 이는 전이학습으로 단독학습에 비해 학습시간을 5배에서 50배까지 절감할 수 있음을 의미한다. 또한 전이학습은 약간의 추가적인 학습을 통해 단독학습보다 평균제곱오차를 낮출 수 있다. 그림 3은 특정한 신경망(U-net)을 사용한 결과이지만, U-net이 영상과 관련한 심층신경망의 응용에서 뛰어난 성능을 보이고 있고[4-7], 또한 전이학습이 특정한 신경망 구조에 의존적이지 않다. 따라서 전이학습은 신경망의 학습속도를 증가시키고, 학습성능을 향상시키며, 많은 데이터를 경제적으로 학습할 수 있는 효과적인 방법으로 판단된다.

#### 나. 신경망의 일반화

심층신경망의 일반화가 이루어졌는지를 시험 데이터에 대한 재구성영상의 평균제곱오차와 영상 화질, 심장 위상에 따른 라인 프로파일로 비교 평가하였다. 심장 위상에 따른 라인 프로파일은 심장 단면영상에서 하나의 라인을 심장 위상(시간)에 따라 세로로 나열한 것이다.

그림 4의 상단에는 초기 재구성영상(a), 단독학습을 수행한 신경망에 의한 재구성영상(b), 전이학습

을 수행한 신경망에 의한 재구성영상(c), ground truth 영상(d)을 나타내었고, 하단에는 심장 위상에 따른 라인 프로파일을 나타내었다. 라인 프로파일의 위치는 ground truth 영상에 표시하였다. 압축비 4와 8에 대한 재구성영상을 왼편과 오른편에 각각 나타내었다. 그림 4에서 보듯이 신경망에 의한 재구성 영상들(b, c)은 초기 재구성영상(a)에 비해 큰 개선을 보인다. 또한, 전이학습을 수행한 신경망의 재구성영상(c)이 단독학습 신경망의 재구성영상(b)에 비해 심근이 더욱 선명하고, ground truth 영상에 근사함을 알 수 있다. 특히 압축비 8에서 차이

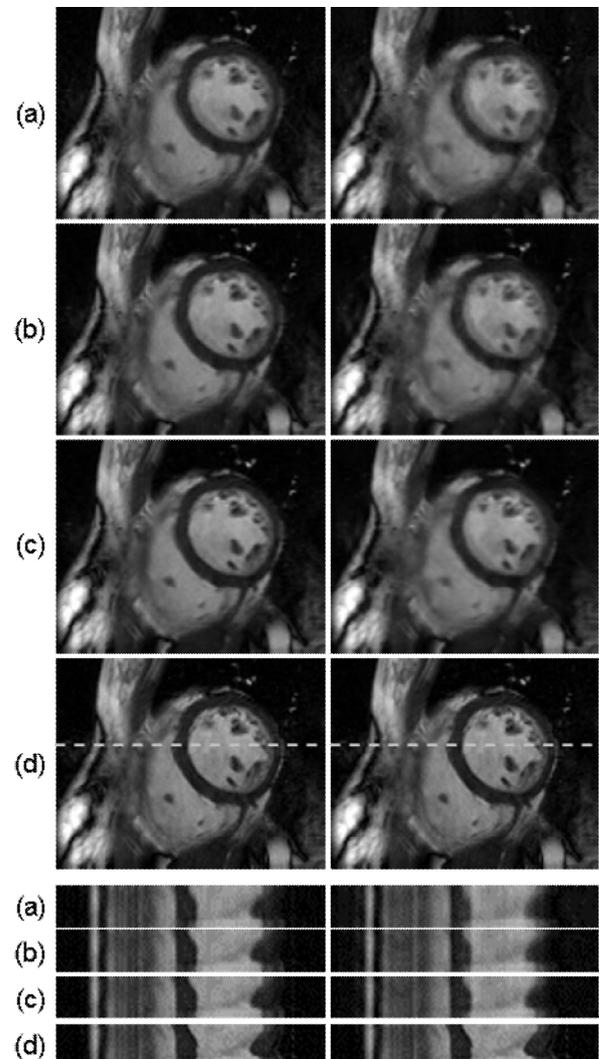


Fig. 4. Comparison of reconstructed Images (upper) and line profiles as a function of time (lower): (a) Initial reconstruction, (b) NN with standalone learning (c) NN with transfer learning, (d) ground truth image.

그림 4. 재구성영상(상단)과 라인 프로파일(하단)의 비교 (a) 초기 재구성, (b) 단독학습 재구성, (c) 전이학습 재구성, (d) ground truth 영상

는 더욱 두드러진다. 하단의 라인 프로파일 또한 전이학습을 수행한 신경망이 단독학습 신경망보다 더 뚜렷한 프로파일을 제공한다.

정량적인 평가를 위하여 초기 재구성영상(IR), 단독학습 신경망의 재구성영상(SL), 전이학습 신경망의 재구성영상(TL)과 ground truth 영상과의 차이를 평균제곱오차로 표 2에 나타내었다. 압축비는 2, 3, 4, 8이다. 평균제곱오차는 시험 데이터 전체에 대해서 심장의 움직임으로 압축센싱으로 인한 아티팩트가 비교적 크게 나타나는 심장과 주변 영역(120×100, 그림 4에서 예시)에서 계산하였다.

표 2에서 보듯이 모든 압축비에서 전이학습 신경망의 재구성영상의 평균제곱오차가 단독학습 신경망의 재구성영상보다 낮음을 알 수 있다. 이는 전이학습을 수행한 신경망이 단독학습 신경망의 성능을 능가했음을 의미한다.

Table 2. NMSE of reconstructed images.

표 2. 재구성영상의 평균제곱오차

	CR2	CR3	CR4	CR8
IR	3.04	5.21	6.81	15.72
SL	2.94	4.70	6.03	13.30
TL	2.75	4.48	5.76	12.89

### III. 결론

심층신경망을 사용하여 압축센싱 심장 CINE 영상을 재구성하였다. 학습에 사용하는 데이터가 충분하지 않을 때 일어나는 신경망의 일반화 문제를 해결하기 위하여 전이학습을 수행하였다. 오픈 데이터베이스(Y-데이터)를 학습데이터로 사용하여 얻어진 신경망의 필터 커널과 가중치를 초기 값으로 사용하여 현재의 학습(K-데이터)을 수행한 결과 학습시간이 5~50배 단축되었다. 또한 학습데이터의 평균제곱오차도 더 낮아졌다. 시험 데이터로 신경망의 일반화를 검증해본 결과 전이학습이 단독학습에 비해 재구성영상의 평균제곱오차가 낮고, 향상된 화질과 선명한 라인 프로파일을 제공하였다.

Y-데이터의 품질이 K-데이터에 비해 떨어지고, 또한 사전학습량도 많이 필요하지 않은 점을 감안하면 사전학습에 사용하는 데이터와 본 학습에 사용하는 데이터 간에 정교한 매칭은 요구되지 않는

것으로 보인다. 따라서 전이학습은 신경망의 학습과 일반화에 효과적인 방법이라고 할 수 있으며, 추 후 보다 상이한 데이터간의 전이학습도 도전할 만한 과제로 판단된다.

### References

[1] J. Tsao, S. Kozerke, "MRI temporal acceleration techniques," *Journal of Magnetic Resonance Imaging*, Vol.36, no.3, pp.543-560, 2012, DOI: 10.1002/jmri.23640.

[2] H. Jung, et al, "k-t FOCUSS: a general compressed sensing framework for high resolution dynamic MRI," *Magnetic Resonance in Medicine*, Vol.61, no.1, pp.103-116, 2009. DOI: 10.1002/mrm.21757.

[3] J. Park, H. Hong, Y. Yang, C. Ahn, "Fast cardiac CINE MRI by iterative truncation of small transformed coefficients," *Investigative Magnetic Resonance Imaging*, Vol.19, no.1, pp. 19-30, 2015, DOI: 10.13104/imri.2015.19.1.19.

[4] O. Ronneberger, F. Philipp, B. Thomas, "U-net: Convolutional networks for biomedical image segmentation," *International Conference on Medical computing and computer-assisted intervention*, Springer, Cham, 2015. DOI: 10.1007/978-3-319-24574-4\_28.

[5] G. Litjens, et al, "A survey on deep learning in medical image analysis," *Medical image analysis*, Vol.42, pp.60-88, 2017. DOI: 10.1016/j.media.2017.07.005.

[6] C. Hyun, H. Kim, S. Lee, S. Lee, J. Seo, "Deep learning for undersampled MRI reconstruction," *Physics in Medicine & Biology*, vol.63, pp.135007, 2018. DOI: 10.1088/1361-6560/aac71a.

[7] D. Lee, J. Lee, J. Ko, J. Yoon, K. Ryu, Y. Nam, "Deep learning in MR image processing," *Investigative Magnetic Resonance Imaging*, Vol.23, no.2, pp.81-99, 2019. DOI:10.13104/imri.2019.23.2.81.

[8] Y. Chen, Y. Xie, Z. Zhou, F. Shi, A. G. Christodoulou, D. Li, "Brain MRI super resolution using 3D deep densely connected neural networks," *In 2018 IEEE 15th International Symposium on Biomedical Imaging*, pp.739-742, 2018.

DOI: 10.1109/ISBL.2018.8363679.

[9] G. Wang, W. Li, M. A. Zuluaga, R. Pratt, P. A. Patel, M. Aertsen, T. Vercauteren, "Interactive medical image segmentation using deep learning with image-specific fine tuning," *IEEE transactions on medical imaging*, Vol.37, no.7, pp.1562-1573, 2018. DOI:10.1109/TMI.2018.2791721.

[10] A. Andreopoulos, J. Tsotsos, "Efficient and generalizable statistical models of shape and appearance for analysis of cardiac MRI," *Medical Image Analysis*, Vol.12, no.3, pp.335-357, 2008. DOI: 10.1016/j.media.2007.12.003.

[11] H. Shin, et al, "Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning," *IEEE Transaction on Medical Imaging*, Vol.35, no.5, pp.1285-1298, 2016. DOI: 10.1109/TMI.2016.2528162.

[12] K. Weiss, T. Khoshgoftaar, D. Wang, "A survey of transfer learning," *Journal of Big Data*, 3: 9, 2016. DOI: 10.1186/s40537-016-0043-6.

[13] J. Yoon, P. Kim, Y. Yang, J. Park, B. Choi, C. Ahn, "Biases in the assessment of left ventricular function by compressed sensing cardiovascular CINE MRI," *Investigative Magnetic Resonance Imaging*, Vol.23, no.2, pp.114-124, 2019. DOI: 10.13104/imri.2019.23.2.114.

DOI: 10.13104/imri.2019.23.2.114.

[14] X. Glorot, Y. Bengio, "Understanding the difficulty of training deep feedforward neural networks," *In Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pp.249-256, 2010.

## BIOGRAPHY

### Seong-Jae Park (Member)



2019 : BS degree in Mathematics, Kwangwoon University.  
2019 : BS degree in Electrical Engineering, Kwangwoon University.  
2019~current : MS degree course of Electrical Engineering, Kwangwoon University.

### Jong-Hyun Yoon (Member)



2013 : B.S. degree in Electrical Engineering, Kwangwoon University.  
2015 : M.S. degree in Electrical Engineering, Kwangwoon University.  
2019 : Ph.D. degree in Electrical Engineering, Kwangwoon University.  
2019~current : Researcher in Neuroscience Research Institute Gachon University

### Chang-Beom Ahn (Member)



1981 : BS degree in Electronics Engineering, Seoul National University.  
1983 : MS degree in Electrical & Electronics Engineering, KAIST.  
1986 : PhD degree in Electrical & Electronics Engineering, KAIST.

1986~1991: Assistant Professor, University of California, Irvine

1991~1992: Associate Professor, Korea Academy of Industrial Technology

1992~present: Professor, Electrical Engineering, Kwangwoon University

Prof. Ahn is a recipient of Sylvia Sorkin Greenfield Award, and a fellow of International Society of Magnetic Resonance in Medicine (ISMRM).