

딥러닝 기술을 활용한 압축센싱 신호 복원방법 분석

성진택*

Analysis of Signal Recovery for Compressed Sensing using Deep Learning Technique

Jin-Taek Seong*

요약 압축센싱(Compressed Sensing)은 선형 역문제(inverse problem)를 다루고 있으며, 그 이론적 연구결과는 관련 분야에 많은 영향을 주어 놀랄 만한 연구성과를 발표하였다. 그러나 압축센싱을 실제 환경에 적용하기 위해서는 두 가지 중요한 문제가 남아 있다. 하나는 실시간에 가까운 복원 성능이 보장되어야 하며, 다른 하나는 신호가 희소성을 갖도록 전처리가 가능해야 한다는 점이다. 이에 대한 문제들을 해결하고자 딥러닝(deep learning) 기술을 활용한 압축센싱 신호 복원방법이 최근에 등장하였다. 본 논문에서는 딥러닝 기반의 압축센싱 신호 복원방법을 고찰하고 최신 연구결과를 비교·분석하고자 한다. 관련 연구결과에서는 실시간에 가까운 복원 시간에 도달하였으며, 기존 복원방법 대비 더 우수한 복원 성능을 보여 주었다. 최근 연구에서 보여준 딥러닝을 활용한 압축센싱 신호 복원방법은 압축센싱의 활용가치를 더욱 높일 뿐만 아니라 신호처리와 통신분야에서 크게 활용될 수 있을 것으로 기대된다.

Abstract Compressed Sensing(CS) deals with linear inverse problems. The theoretical results of CS have had an impact on inference problems and presented amazing research achievements in the related fields including signal processing and information theory. However, in order for CS to be applied in practical environments, there are two significant challenges to be solved. One is to guarantee in real time recovery of CS signals, and the other is that the signals have to be sparse. To this end, the latest researches using deep learning technology have emerged. In this paper, we consider CS problems based on deep learning and discuss the latest research results. And the approaches for CS signal reconstruction using deep learning show superior results in terms of recovery time and performance. It is expected that the approaches for CS reconstruction using deep learning shown in recent studies can not only raise the possibility of utilization of CS, but also be highly exploited in the fields of signal processing and communication areas.

Key Words : Approximate Message Passing, Compressed Sensing, Convolutional Neural Network, Deep Learning, Sparse Signal

1. 서론

압축센싱(Compressed Sensing)은 지난 2006년 Donoho에 의해 발표된 이후, 지금까지 다양한 응용분야에 걸쳐 놀랄 만한 연구결과를 발표하였으며, 그 중에서 나이퀴스트 샘플링 이론을 반박하는 주장으로 관련 학계에서는 큰 관심을 받았다[1]. 사실 압축센싱은 역문제(inverse problem)의 일종

이며, linearly undetermined 문제를 해결하고자 하는 데에서 시작되었다. 이것을 수학적으로 표현하면 다음과 같다. 측정 신호(measurement signal) $y \in R^m$ 는 선형 사상(linear mapping)하여 $y = Ax$ 이며, 여기서 $A \in R^{m \times n}$ 는 센싱행렬(sensing matrix)이고, 또한, $x \in R^n$ 은 찾고자 하는 신호(unknown signal)이며, $n > m$ 이다. 압축센싱은 위

*Corresponding Author : Department of Information and Communication Engineering, Honam University (jtseong@honam.ac.kr)

Received June 20, 2017

Revised June 26, 2017

Accepted July 04, 2017

의 역문제를 해결하기 위해 기본적으로 두 가지의 전제조건을 바탕으로 접근하고 있다. 첫 번째 조건은 신호 x 가 어느 특정 도메인(e.g., DCT, 웨이브렛 등)에서 희소(sparse) 신호로 변환(transformation) 가능하여야 하며, 두 번째 조건은 센싱행렬이 신호 x 를 에너지의 손실 없이 선형 사상하여 측정할 수 있어야 한다는 점이다.

지난 10여 년에 걸쳐 압축센싱은 괄목할 만한 연구결과를 보여 주었지만 두 가지 중요한 도전과제에 직면하고 있다. 그 중 하나는 신호의 크기가 아주 클 경우 신호를 복원하는데 실시간에 가까운 효율적인 복원방법이 없다는 것이다. 다른 하나는 신호 x 가 특정 도메인에서 최소한 성질을 갖게끔 변환이 되어야 하지만 그렇지 않은 경우가 많다는 것이다[2]. 이와 같은 문제들을 해결하고자 최근에 압축센싱 선두 그룹에서는 딥러닝[3] 기술을 활용하여 그 해법을 제시하고 있다[4]-[9].

딥러닝 기술은 위에서 언급한 압축센싱 문제를 해결할 수 있는 새로운 프레임워크를 제공하고 있다. 본 논문은 최근 학계에서 주목 받고 있는 딥러닝 기술이 압축센싱 문제를 어떻게 해결할 수 있는지에 대한 사례를 보여 주고 각 모델에 대해서 분석한다. 그리고 기존 압축센싱 신호 복원방법 대비 딥러닝 기술 기반의 신호 복원방법이 복원 시간과 성능 면에서 우수성을 보여 준다. 이를 위해 기존 압축센싱 신호 복원방법을 살펴보고, 딥러닝 기술을 활용한 최신의 접근법을 살펴보고자 한다. 그리고 최근 연구결과를 비교·분석하여 딥러닝 기술 기반의 압축센싱 신호 복원방법의 활용 가능성을 제시한다.

2. 딥러닝(Deep Learning) 소개

2.1 딥러닝 발전

딥러닝은 1960년대 후반에 제안된 기계학습(machine learning) 한계를 뛰어 넘어서려는 노력의 일환으로 발전되어 왔다. 특히 다층 퍼셉트론과 역전파(backpropagation) 알고리즘[10]의 등장으로 기계학습은 새로운 전성기를 맞이하였지만, 학습과

정에서 발생하는 ‘vanishing gradient problem’와 ‘overfitting’ 문제로 위기를 맞이하게 된다[3]. 이로 인하여 심층 구조 학습의 어려움이 가중되었으나, 2006년 Hinton 교수에 의해 사전학습(pretraining)을 이용한 DBN (Deep Belief Networks)이 제안되면서부터 본격적인 딥러닝(또는 심층 신경망(deep neural network)) 연구가 시작되었다[11]. 또한 GPU(Graphics Processing Unit) 활용은 기존 대비 10내지 20배 이상 빠른 학습속도를 경험하게 되면서 딥러닝의 연구를 앞당기는 계기가 되었다[3].

딥러닝이 학계로부터 관심을 받게 된 이유는 2012년 ILSVRC(Imagenet Large Scale Visual Recognition Challenge)에서 딥러닝 기반의 콘볼루션 신경망(Convolutional Neural Network : CNN) 모델인 AlexNet가 인식 에러율 15.3%를 기록하면서 딥러닝의 우수성이 입증되었기 때문이다[12]. 이것은 2위 팀보다 10%이상 높은 기록이었고, 이후에 ILSVRC 객체 분류 과제에서 CNN을 활용한 모델들이 상위권을 차지하게 된다. CNN 기반의 딥러닝 방법들은 비지도 사전훈련(unsupervised pretraining)과 드랍아웃(drop-out) [13] 등의 기술이 더해지면서 발전되었다. GoogLeNet은 인셉션 모듈을 이용해서 학습 파라미터 수를 상당량 줄였으며, 2014년 ISLVRC에서 우승을 하였다[14]. 그리고 인간의 평균 인식 에러율은 5% 수준인데 비해 이보다 낮은 3.57%의 결과를 기록한 ResNet은 2015년 ISLVRC에서 우승을 차지한다[15].

2.2 콘볼루션 신경망(CNN)

사람이 이미지를 볼 때는 이미지의 픽셀 단위로 인지하기 보다는 전체적인 요소(형태, 특징 등)를 판단하여 이미지를 이해한다. 콘볼루션 신경망은 이와 같이 사람의 인지방법을 모방한 형태이다. CNN은 MLP의 한 종류로써 이미지에서 인접하는 픽셀 간의 관계를 이용하여 개체 분류를 하고자 제안되었다[16]. CNN은 종합적이고 통합적인 속성 인자를 찾기 위해 콘볼루션(convolution)과 풀링(pooling)을 이용한다.

CNN은 데이터 전체를 모델링하기 보다는 해석하고자 하는 인접 영역만을 선택하여 모델링하기 때문에 구조가 간단하다. 이미지의 경우 이러한 CNN의 국부적 해석이 유용하다. 예를 들어, 이미지의 선은 인접한 픽셀들이 모여서 하나의 패턴을 형성하고, 물체의 형상은 인접한 선과 곡면들이 형성하여 하나의 객체를 나타내고 있다. 이 경우 선이나 곡면, 물체의 형상은 이미지의 전체가 아닌 특정 영역에 한정되어 나타난다. 또한 특정 패턴이 이미지 전체에서 나타날 수 있기 때문에 CNN은 커널 형태로 이미지 전체를 통합하여 모델링하기에 적절하다. CNN의 콘볼루션 계층은 커널을 일정한 간격을 두고서 순차적으로 해당 영역에서 콘볼루션 연산을 하며, 이것은 이미지 처리에서 말하는 필터링과 흡사하다. 이렇게 커널을 이미지 전체 영역을 일정한 간격으로 나누어서 콘볼루션을 수행한다. CNN은 이것을 확장하여 여러 층에 걸쳐서 콘볼루션 연산을 수행하기 때문에 물체의 추상적인 패턴까지 추출할 수 있다[16].

CNN을 구성하는 다른 요소는 풀링(pooling)이다. 풀링은 다른 용어로는 subsampling이라고 말한다. 이것은 데이터의 크기를 줄여주는 역할을 한다. 풀링은 최대 풀링(max-pooling)과 평균 풀링(average pooling)을 사용되는데, 콘볼루션 과정에서 도출한 정보의 속성인자에 대한 공간 불변성을 제공한다. 즉, 입력 크기를 줄여주는 기능뿐만 아니라 속성에 대한 위치 변동에 대한 영향을 최소화 한다. 예를 들어 이미지 상에서 물체 인식을 위해서는 물체가 무엇인지가 중요하지 물체가 이미지의 어느 부분에 위치하는지는 중요하지 않게 된다. 그래서 풀링 과정은 CNN 처리 중에 발생할 수 있는 불필요한 정보를 제거한다. 오히려 이로 인하여 잡음에 강인한 효과를 가져 온다[16].

CNN은 콘볼루션 연산과 풀링 연산을 여러 차례 반복하여 수행한다. 그리고 최종적으로 위치 정보가 없는 패턴 정보를 이용하여 속성인자들을 추출한다. 높은 인식률을 얻기 위해 이들 속성인자들 간의 상관관계와 연관성을 모델링하여 인식 결과를 높인다[12].

2.3 딥러닝 학습과정

딥러닝 학습을 위해 오류 역전파(error back-propagation) 알고리즘을 이용한다. 이 과정은 전파(feed-forward)와 역전파(back-propagation) 단계로 구성되어 있으며, 오류 역전파를 통하여 딥러닝 모델링에서 최적의 가중치(weight)와 바이어스(bias) 값을 찾는다. 먼저 전파 단계에서는 훈련 데이터(training data)와 가중치를 선형 결합하여 오차를 구한다. 그리고 역전파 단계에서는 훈련 데이터에서 발생한 오차 값을 이용하여 가중치와 바이어스 값을 계속해서 최적화한다. 오류 역전파 알고리즘은 훈련 데이터를 이용하여 학습과정을 진행하기 때문에 오차를 줄인다. 최종적으로 줄어든 오차만큼 훈련 데이터에 최적화된 가중치와 바이어스 값을 찾았음을 확인할 수 있다[15].

딥러닝에서 최적화 방법은 손실 함수(loss function)를 이용하여 네트워크 파라미터의 집합을 찾는 단계이다. 많은 최적화 방법이 있지만, 학습률(learning rate)을 파라미터로 조정하기 위한 방법으로 SGD(Stochastic Gradient Descent)가 대표적이다. 이 밖에도 AdaGrad 알고리즘, RMSProp 알고리즘, Adam 알고리즘 등의 최적화 방법을 이용하여 손실 함수를 최소화하고자 한다[17]. 가장 많이 알려진 SGD는 기울기 하강 기반의 최적화 알고리즘이다. 이것은 가장 단순하지만, 수렴하는 지점에 다가갈수록 기울기가 작아져서 수렴속도가 느려지는 단점이 있다. 뿐만 아니라 학습을 더 많이 시키더라도 그 학습효과는 미미한 수준에 그친다. 최근에 개발된 RMSProp 알고리즘은 AdaGrad 방법을 개선한 방법으로써 효율적인 방법으로 알려져 있다. 이 방법은 기울기 평균을 이용하기 때문에 AdaGrad에서 발생한 급격한 학습률 강하를 보완할 수 있다[17].

딥러닝에서는 각 계층별로 신호를 입력받아 새로운 신호를 발생시킨다. 이때 활성화 함수(activation function)를 이용하게 되는데, 입력 값에 가중치 값을 곱하고 바이어스를 더하여 입력 신호로 사용한다. 이 경우에 활성화 함수 종류에 따라 같은 입력 값이더라도 다른 결과를 보여 준

다. 2000년대 이전 딥러닝 연구에서는 주로 활성화 함수로써 시그모이드(sigmoid) 함수를 이용하였다. 그러나 출력값 0과 1 근처에서 시그모이드 함수의 기울기는 0에 가까운 값이기 때문에 기울기 사라짐 문제(vanishing gradient problem)가 발생하였다[17]. 이를 해결하고자 ReLU(Rectified Linear Unit) 함수가 활성화 함수로 대체되어 현재는 주로 이용되고 있다[18]. ReLU 함수는 $f(x) = \max(0, x)$ 으로 정의된다. 다시 말하면, 결과값은 음수가 없고, 양수 입력일 경우 선형성 때문에 SGD 알고리즘 수렴에서 빠른 가속이 일어나고, 연산이 간단해 빠른 학습을 돕는다.

3. 딥러닝 기반의 압축센싱

3.1 압축센싱 신호 복원방법

3.1.1 주요 압축센싱 알고리즘

압축센싱은 많은 연구자들에 의해 지금까지 수많은 복원 알고리즘이 개발되었다. 본 장에서는 비교적 최근에 개발되었거나 복원 시간과 복원 성능 측면에서 우수하다고 알려져 있는 압축센싱 신호 복원 알고리즘들을 간단히 살펴본다. 이들 알고리즘에 대한 자세한 내용은 관련 인용문헌에서 더욱 깊이 있게 다루고 있다.

각 알고리즘을 살펴보기 전에, 반복 실행을 통한 일반적인 압축센싱 신호 복원 방법은 다음의 최적화 문제를 이용한다[19].

$$\hat{x} = \arg \min_x \frac{1}{2} \|y - Ax\|_2^2 + \lambda \|x\|_1, \quad (1)$$

여기서 $\lambda > 0$ 는 신호의 희소성과 측정의 정확성 사이의 trade-off 상수이다.

1) IST : 최적화 문제 (1)를 가장 간단히 해결하기 위해 IST(iterative shrinkage thresholding) 알고리즘을 이용하였다[20]. 이 알고리즘은 매 실행마다 다음의 값들을 갱신하면서 해를 찾는다.

$$z^t = y - A\hat{x}^t, \quad (2)$$

$$\hat{x}^{t+1} = \eta_\tau(\hat{x}^t + A^\top z^t), \quad (3)$$

여기서 z_t 는 t 번째 실행에서 잔여 측정 오차(residual measurement error)이고, $\eta_\tau(\cdot)$ 는 다음과 같이 정의되는 축소 함수(shrinkage function)의 soft thresholding이다.

$$\eta_\tau(r) := \text{sgn}(r) \max\{|r| - \tau, 0\}. \quad (4)$$

2) AMP : 최근에 개발된 AMP(approximate message passing) 알고리즘은 기본적으로 간단한 구조를 갖고 있으면서 복원 성능을 향상시킬 뿐만 아니라 복원 시간도 줄일 수 있게 되어 학계로부터 많은 관심을 받았다[21]. AMP 알고리즘은 매 반복 실행 시에 다음의 수학적 표현에 따라 압축센싱 문제에 대한 해를 찾고 있다.

$$z^t = y - A\hat{x}^t + \frac{n}{m} z^{t-1} \langle \eta'_\tau(A^\top z^{t-1} + x^{t-1}) \rangle, \quad (5)$$

$$\hat{x}^{t+1} = \eta_\tau(\hat{x}^t + A^\top z^t), \quad (6)$$

여기서 (5)에서 $\langle \cdot \rangle$ 는 벡터의 평균을 의미하고, $\eta'_\tau(\cdot)$ 은 $\eta_\tau(\cdot)$ 의 미분(derivative)을 말한다. 그리고 $\frac{n}{m} \langle \eta'_\tau(A^\top z^{t-1} + x^{t-1}) \rangle$ 은 “Onsager correction” 향으로 정의된다. 이것은 IST 알고리즘과 비교하여 AMP 알고리즘이 갖고 있는 큰 특징 중의 하나이다. 그리고 Onsager correction 항은 유효 잡음(effective noise)을 발생시킨다.

3) D-AMP : 가장 최근 연구 [22]에서는 AMP 알고리즘을 개선한 방법으로써 신호에 포함되어 있는 잡음을 제거하고자 적절하게 Onsager correction 항을 변형하여 D-AMP(Denoising-based AMP) 알고리즘을 제안하였다. 이 알고리즘은 매 반복과정에서 다음과 같은 방법으로 신호를 갱신한다.

$$z^t = y - A\hat{x}^t + \frac{1}{m} z^{t-1} \nabla D_{\hat{\sigma}^{t-1}}(A^\top z^{t-1} + x^{t-1}), \quad (7)$$

$$\hat{x}^{t+1} = D_{\hat{\sigma}^t}(\hat{x}^t + A^\top z^t), \quad (8)$$

$$(\hat{\sigma}^t)^2 = \frac{\|z^t\|_2^2}{m}, \quad (9)$$

여기서 $\nabla D_{\hat{\sigma}}(\cdot)$ 은 다음과 같은 denoiser의 수

렴값을 나타내며[22],

$$\nabla D_\sigma(x) := \sum_{i=1}^n \frac{\partial D_\sigma(x)}{\partial x_i}, \quad (10)$$

여기서,

$$D_\sigma(x) = \operatorname{argmin}_x \|x_0 + \sigma z - x\|_2^2, \quad \text{subject to } x \in C. \quad (11)$$

AMP 알고리즘과는 달리 D-AMP 알고리즘은 (7)의 Onsager correction 항으로 인해 반복 실행 과정 중에 발생하는 바이어스 값을 제거할 수 있게 됨에 따라 AWGN 형태의 잡음으로 신호를 분석할 수 있다[22].

이 밖에도 압축센싱 문제를 다루었던 많은 신호 복원방법은 다음의 알고리즘들을 주로 이용한다. TVAL3 [23]은 고속의 total variation을 사용하였으며, NLR-CS [24]는 매우 느린 알고리즘 처리속도를 갖고 있지만 복원 성능은 비교적 높은 편이다. BM3D-AMP [2]는 NLR-CS만큼 정확한 복원 성능을 갖고 있으며, 가우시안 센싱행렬을 이용할 경우 TVAL3보다는 더 빠르게 압축센싱 신호 복원을 하게 된다. 그리고 가장 최근에 개발된 VAMP [25]는 AMP를 확장한 형태로서 센싱행렬의 적용 범위를 가우시안에서 SVD(singular value decomposition)으로 변환 가능한 행렬까지 활용할 수 있는 장점이 있고, AMP보다 더 빠른 신호 복원 처리속도를 갖고 있다.

3.1.2 CNN을 활용한 압축센싱 신호 복원 방법

최근 연구 [6]에서는 CNN을 이용한 압축센싱 신호 복원방법 DeepInverse을 제안하였다. 그림 1에

서 보는 바와 같이 첫 번째 단계는 측정 신호 y 를 fully connected linear 층의 입력으로 인가하여 크기가 확장된 신호 $\hat{x} \in R^n$ 를 얻는다. 이 과정에서 센싱행렬을 변환 Φ^T 하여 가중치를 결정한다. 그리고 훈련 데이터 $\Omega = \{(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(d)}, y^{(d)})\}$ 은 신호 x 에 대응하는 측정 신호 y 로 구성된 d 개의 데이터를 이용한다. 학습과정을 통하여 확장된 신호 \hat{x} 에서 신호 x 을 찾을 수 있도록 비선형 과정이 진행된다. 논문 [6]에서는 1개의 fully connected 층과 3개의 컨볼루션 층을 이용하였고, LeRU 함수를 이용하여 비선형성을 적용하였다.

더 자세하게 CNN이 압축센싱에서 어떻게 적용되었는지 구체적인 방법을 살펴보기 위해 수학적 표현을 이용하면 다음과 같다. 확장 신호 $\hat{x} = \Phi^T y$ 으로 정의된다. 그리고 확장 신호 \hat{x} 의 크기 $N = n_1 \times n_2$ 으로 변환된다. 첫 번째 컨볼루션 층에서 k 번째 feature map의 (i, j) 번째 원소는 확장 신호 \hat{x} 를 입력으로 하여 다음의 출력 신호 $(x_{cl})_{i,j}^k$ 를 얻게 된다.

$$(x_{cl})_{i,j}^k = S(\operatorname{ReLU}((W_1^k * x)_{i,j} + (b_1^k)_{i,j})), \quad (12)$$

여기서, $W_1^k \in R^{k_1 \times k_2}$ 와 $b_1^k \in R^{(n_1 + k_1 - 1) \times (n_2 + k_2 - 1)}$ 는 각각 k 번째 feature map의 필터와 바이어스를 말한다. 그리고 함수 $S(\cdot)$ 는 subsampling으로써 ReLU의 출력값을 얻는다. 같은 방법으로 두 번째와 세 번째 컨볼루션 층에서도 동일하게 적용할 수 있지만, 각 층에서 사용하게 되는 필터의 형태나 바이어스는 조금씩 다르게 설정된다.

l_1, l_2, l_3 를 각각 세 개의 컨볼루션 층에서 사용하게 되는 필터의 수라고 정의하자. 그러면 전체 CNN에서 이




그림 1 컨볼루션 신경망을 이용한 DeepInverse 구조 [6].
Fig. 1. Structure of DeepInverse using a convolutional neural network [6]

용한 집합 $P = \left\{ \{W_1^k, b_1^k\}_{k=1}^L, \{W_2^k, b_2^k\}_{k=1}^L, \{W_3^k, b_3^k\}_{k=1}^L \right\}$ 이라고 정의하면, 알고자 하는 신호에 대해 다음과 같은 $\bar{x} = \theta(y, P)$ 비선형 함수라고 할 수 있다. 마지막으로 손실 함수는 훈련 데이터에 대해 최소 제곱 오차(mean squared error) 방법을 적용한다. $\lambda = \frac{1}{d} \sum_{i=1}^d \|\theta(y^{(i)}, P) - x^{(i)}\|_2^2$, 여기서 손실 함수가 최소화될 수 있도록 오류 역전파 알고리즘을 이용하여 파라미터 집합을 학습시킨다[6].

3.1.3 Unrolled 기반 압축센싱 신호 복원 방법

앞서 언급한 논문 [6]은 비록 CNN을 이용하여 압축센싱 신호 복원 모델 DeepInverse를 제안하여 다른 신호 복원방법들과 비교하여 우수한 성능 개선을 보여 주었다. 그러나 딥러닝을 더 효율적으로 활용 가능하기 위해서는 다음의 압축센싱 문제들을 생각해 보아야 한다: i) 어려운 학습과정, ii) 특정한 센싱행렬에서 적용 가능, iii) 무원칙의 접근법과 같은 문제들에 대해 새로운 해결방법을 제시할 필요가 있다. 논문 [7]에서 이와 같은 문제를 해결할 수 있었던 주된 아이디어는 반복 신호 복원 알고리즘에서 사용된 반복 실행 횟수만큼 여러 개의 은닉층으로 분리하여 심층 신경망을 구성하는 것이다. 다시 말하면, 기존 압축센싱에서 L개 반복 실행은 L개의 은닉층으로 구성된 심층 신경망으로 생각해 볼 수 있다는 점이다. 이렇게 함으로써 학습이 쉬어지고, 다양한 형태의 센싱행렬이 적용 가능했으며, 기존에 제시된 성능보다 크게 향상된 결과를 보여 주었다[7].

다음으로 논문 [7]의 자세한 신호 복원방법을 알아보자. 먼저 AMP는 식 (5)과 (6)를 이용하여 매 반복 실행 시마다 신호를 갱신하면서 복원하게 된다. 이때, 식 (5)과 (6)를 하나의 은닉층으로 생각한다면, AMP 반복 실행 수만큼의 은닉층으로 구성된 심층 신경망을 고려해 볼 수 있다. 다시 말하면, 알고리즘 반복 실행 수만큼의 은닉층을 구성하여 딥러닝을 구성한다 그리고 딥러닝에 사용하게 될 가중치는 알고리즘의 파라미터 값들을 이용한다. 그래서 논문 [7]에서는 AMP 알고리즘을 다

음과 같이 매 반복 실행 시와 동일하게 풀어진 (unrolled) 형태의 L-AMP(Learned-AMP)를 고려하고 있다. 첫 번째 은닉층은 다음과 같고,

$$z^0 = y - Ax^0, \quad (13-a)$$

$$\hat{x}^1 = \eta_{\tau_1}(x^0 + A^\top z^0), \quad (13-b)$$

여기서 x^0 는 0벡터이다. 두 번째 은닉층은

$$z^1 = y - A\hat{x}^1 + \frac{n}{m} z^0 \langle \eta'_{\tau_2}(A^\top z^0 + x^0) \rangle, \quad (14-a)$$

$$\hat{x}^2 = \eta_{\tau_2}(\hat{x}^1 + A^\top z^1). \quad (14-b)$$

같은 방법으로 세 번째 은닉층은 다음과 같다.

$$z^2 = y - A\hat{x}^2 + \frac{n}{m} z^1 \langle \eta'_{\tau_3}(A^\top z^1 + x^1) \rangle, \quad (15-a)$$

$$\hat{x}^3 = \eta_{\tau_3}(\hat{x}^2 + A^\top z^2). \quad (15-b)$$

계속 반복하여 l번째 은닉층에서는 \hat{x}^l 와 z^{l-1} 를 얻는다. 그리고 각기 다른 비선형 함수 $\eta_{\tau_l}(\cdot)$ 를 적용한다. 학습과정을 통하여 이들의 파라미터 값들은 계속해서 갱신된다.

L-AMP에서 이용한 방법과 동일하게 풀어진 (unrolled) 형태의 D-AMP를 고려해 볼 수 있으며, 이것을 LDAMP라고 한다[7]. 앞서 정리된 D-AMP 알고리즘의 식 (7)-(9)를 다음과 같이 l번째 은닉층으로 다시 적용한다.

$$z^l = y - A\hat{x}^l + \frac{1}{m} z^{l-1} \nabla D_{w^{l-1}(\hat{\sigma}^{l-1})}^{l-1}(A^\top z^{l-1} + x^{l-1}), \quad (16)$$

$$\hat{x}^{l+1} = D_{w^l(\hat{\sigma}^l)}^l(x^l + A^\top z^l), \quad (17)$$

$$(\hat{\sigma}^l)^2 = \frac{\|z^l\|_2^2}{m}, \quad (18)$$




그림 2. 2개 은닉층으로 구성된 LDAMP 구조 [7].
Fig. 2. Structure of LDAMP with two hidden layers [7].




그림 3. 성능비교를 위해 사용된 7개의 이미지 [7].
Fig. 3. The seven images for comparison of performance [7].

여기서 $D_{w(\hat{\sigma}^l)}^l$ 은 l 번째 은닉층에서 가중치 w^l 과 잡음 분산 $\hat{\sigma}^l$ 을 갖는 denoiser D^l 을 말한다.

그림 2는 2개 은닉층으로 구성된 LDAMP구조를 보여 준다. 여기서 각 은닉층은 다시 2개의 DnCNN(Denoising Convolutional Neural Network)를 포함하고 있다. 이때 DnCNN은 16개에서 20의 컨볼루션 층을 형성하여 신호의 잡음 성분을 제거할 목적으로 사용된다.

3.2 성능비교

본 장에서는 딥러닝 기술을 활용한 압축센싱 문제를 다루었던 관련 연구결과를 검토하여 그 성능결과를 비교·분석하고자 한다. 기존의 압축센싱 신호 복원방법과 비교를 통하여 복원 시간과 성능 측면에서 딥러닝 기술 기반의 압축센싱 신호 복원 방법의 우수성을 보여 주고자 한다. 본 장에서 보여준 연구결과는 논문 [6]과 [7]에서 다루었던 내용을 참고하였고, 자세한 내용은 인용문헌에서 상세히 언급하고 있다.

논문 [6]에서는 성능비교를 위해 D-AMP [2], TV(total variation) minimization [26], P-AMP [27] 알고리즘을 이용하였다. 그리고 논문 [7]에서

는 그림 3에서 보여 주는 바와 같이 7개의 이미지를 이용하여 성능을 비교하였다. 이때 성능비교를 위해 사용된 알고리즘은 TVAL3 [23], BM3D-AMP [2], NLR-CS [24]의 신호 복원 알고리즘이 이용되었다. 논문 [6]과 [7]에서 성능비교를 위해 이용한 기존의 압축센싱 신호 복원 알고리즘에 대한 상세한 설명은 각 인용문헌에서 자세히 다루고 있다.

3.2.1 복원 시간

딥러닝을 압축센싱 문제에 적용함으로써 가장 큰 이점은 신호 복원 시간이 매우 크게 줄어들었다는 것이다. 물론 딥러닝을 적용하기 위해서는 사전에 학습과정이 필요하지만, 한 번의 학습만으로 실시간에 가까운 복원 시간이 필요하다면 그 적용 범위는 매우 확대 될 수 있다. 표 1은 논문 [6]에서 얻은 결과로써, 기존의 최신 알고리즘들과 비교하여 압축센싱의 신호 복원이 굉장히 빨라졌음을 보여준다.

표 2와 3은 각각 가우시안 센싱행렬과 coded diffraction 센싱행렬과 측정 잡음이 없을 때, 128×128 크기의 이미지를 복원하는데 소요된 시

간을 보여 준다. 논문 [7]에서 제안하는 신호 복원 방법(LDIT와 LDAMP)이 기존의 압축센싱에서 복원 성능이 우수하다고 평가 받은 알고리즘들보다 많게는 수십 배에서 수백 배 더 빠른 복원 시간을 얻었다.

표 1, 2, 3에서 보여준 연구결과는 딥러닝을 활용한 압축센싱 신호 복원방법의 큰 장점을 말해주고 있다. 기존에 제시된 복원 알고리즘 보다 실 시간에 가까운 복원 시간을 필요하게 됨에 따라 객체 분류뿐만 아니라 비디오 영상처리에 이르기 까지 압축센싱이 직면한 실시간 처리를 해결할 수 있는 방법으로 고려된다.

표 1. 알고리즘에 따른 신호 복원 시간 (sec) [6].
Table 1. Runtimes for signal recovery with several algorithms (sec) [6].

m/n	[6]	D-AMP	TV	P-AMP
0.2	0.01	3.41	2.53	1.53
0.1	0.01	2.93	2.34	1.23
0.01	0.01	2.56	2.26	0.94

표 2. 가우시안 센싱행렬과 측정 잡음이 없을 때 128×128 크기의 이미지 복원 시간 (sec) [7].
Table 2. Runtimes for recovery of 128×128 images with i.i.d. Gaussian measurements and no measurement noise (sec) [7].

m/n	0.05	0.1	0.15	0.20	0.25
TVAL3	1.36	2.24	2.87	3.58	4.33
BM3D-AMP	3.85	4.80	4.45	4.24	4.10
LDIT[7]	0.21	0.28	0.36	0.42	0.48
LDAMP[7]	0.34	0.40	0.49	0.55	0.61
NLR-CS	67.83	85.91	103.87	124.35	146.29

표 3. Coded diffraction 센싱행렬과 측정 잡음이 없을 때 128×128 크기의 이미지 복원 시간 (sec) [7].
Table 3. Runtimes for recovery of 128×128 images with coded measurements and no measurement noise (sec) [7].

m/n	0.05	0.1	0.15	0.20	0.25
TVAL3	0.62	0.52	0.46	0.43	0.41
BM3D-AMP	3.80	4.55	4.29	3.67	3.40
LDIT[7]	0.13	0.14	0.14	0.14	0.14
LDAMP[7]	0.26	0.26	0.26	0.27	0.26
NLR-CS	87.26	87.82	87.43	87.18	86.87

3.2.2 복원 성능

다음으로 PSNR(peak signal-to-noise ratio) 을 비교하여 압축센싱의 신호 복원 알고리즘의 성능을 평가한다. 그림 4에서는 평균 PSNR을 보여 주며, m/n 이 0.05보다 작을 때는 논문 [6]에서 제안한 결과가 가장 우수하였다. 그림 4에서는 보여준 결과는 전영역의 m/n 에 걸쳐 딥러닝 기반의 압축센싱 신호 복원방법이 기존 알고리즘 보다 우수하지는 않지만, 지금까지 알려진 알고리즘 중에서 가장 성능이 좋다고 알려진 D-AMP 알고리즘에 비해 대등한 성능을 보여 주었다.

표 4와 5는 논문 [7]에서 보여준 결과로써, 7개의 이미지에 대해 $m/n=0.1$ 일 때, 주요 복원 알고리즘에 대한 PSNR를 측정된 값이다. 표 4와 5에서 알 수 있듯이, 딥러닝을 적용한 신호 복원방법이 대부분의 이미지에서 최신의 복원 알고리즘보다 더 좋은 성능을 보여주고 있다.

표 6은 가우시안 센싱행렬과 측정 잡음의 표준편차에 따라 각 신호 복원 알고리즘의 PSNR를 보여준다. 표 6에서 보는 바와 같이 딥러닝을 이용한 LDAMP 알고리즘이 측정 잡음이 있더라도 다른 알고리즘과 비교하여 우수한 복원 성능을 보여주고 있다.

표 4, 5, 6에서 보여준 결과를 살펴보면 기존 압축센싱 신호 복원 알고리즘들에 비해 딥러닝 기반의 신호 복원방법은 센싱행렬이 가우시안이거나 coded diffraction을 사용하여 측정 잡음이 있을 때에도 우수한 PSNR를 보여 주었다.

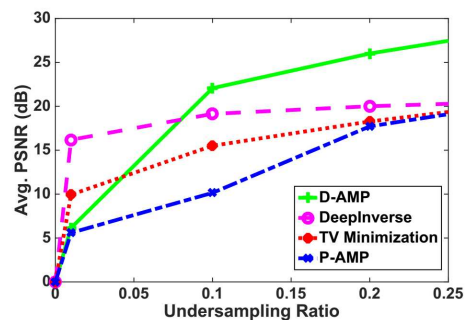


그림 4. m/n 에 따른 평균 PSNR : DeepInverse는 논문 [6]에서 제안함.

Fig. 4. Averaged PSNR over m/n : DeepInverse is proposed in [6].

표 4. 가우시안 센싱행렬과 측정 잡음이 없을 때 128×128 크기의 이미지 복원의 PSNR [7].

Table 4. PSNR for recovery of 128×128 images with i.i.d. Gaussian measurements and no measurement noise [7].

이미지	TVAL3	BM3D-AMP	LDIT[7]	LDAMP [7]	NLR-CS
Barbara	21.75	24.36	19.39	25.80	25.17
Boat	22.95	24.04	21.49	24.67	23.84
Finger print	16.77	18.07	17.23	17.36	17.84
Mandrill	23.21	24.12	22.17	24.37	23.56
Peppers	21.98	24.44	19.13	26.00	25.18
Couple	23.07	24.79	21.24	25.43	24.91
Stream& Bridge	20.86	22.05	19.82	22.52	21.80

표 5. Coded diffraction 센싱행렬과 측정 잡음이 없을 때 128×128 크기의 이미지 복원의 PSNR [7].

Table 5. PSNR for recovery of 128×128 images with coded diffraction measurements and no measurement noise [7].

이미지	TVAL3	BM3D-AMP	LDIT[7]	LDAMP [7]	NLR-CS
Barbara	25.08	25.40	24.02	27.90	24.12
Boat	25.39	24.48	24.77	26.50	21.56
Finger print	17.34	18.68	17.31	17.56	17.11
Mandrill	24.79	24.48	24.74	25.57	21.15
Peppers	25.83	25.52	24.36	28.18	24.05
Couple	26.13	25.53	25.24	27.24	22.27
Stream& Bridge	23.13	22.56	20.21	23.87	21.04

표 6. 가우시안 센싱행렬과 측정 잡음이 있을 때 128×128 크기의 이미지 복원의 PSNR [7].

Table 6. PSNR for recovery of 128×128 images with Gaussian measurements and measurement noise [7].

측정잡음 표준편차	m/n	0.1	0.2	0.3	0.4	0.5
		10	TVAL3	21.08	22.84	24.06
	BM3D-AMP	16.99	23.98	25.40	26.79	27.64
	LDAMP	22.41	24.56	26.36	27.63	28.56
30	TVAL3	20.90	22.23	22.74	22.74	22.57
	BM3D-AMP	18.43	23.34	24.09	24.46	24.80
	LDAMP	22.11	23.80	24.55	25.10	25.34
50	TVAL3	20.58	21.33	21.17	20.53	19.84
	BM3D-AMP	19.45	22.69	23.13	23.28	23.38
	LDAMP	21.58	22.96	23.44	23.65	23.76

4. 결론

본 논문에서는 최근 학계에서 주목 받고 있는 딥러닝 기술이 압축센싱의 신호 복원방법으로써 적용 가능하며 활용가치가 크다는 점을 알 수 있었다. 특히, 압축센싱 문제에서 직면한 실시간 신호 복원에 대한 요구사항을 딥러닝 기술이 해결할 수 있었다. 또한, 딥러닝 기반의 신호 복원방법이 최신의 신호 복원 방법들과 비교하여 복원 성능 측면에서도 우수함을 알 수 있었다. 이와 더불어서 기존의 압축센싱 문제에서 직면한 신호의 희소성 문제도 해결할 수 있었으며, 센싱행렬 RIP(Restricted Isometry Property) 제약조건의 비의존성과 신호 복원방법의 고속의 고성능 처리 등이 가능함을 보여 주었다. 본 논문에서 비교·분석한 관련 연구결과는 향후 압축센싱의 활용가치를 더욱 높여 줄 것으로 기대하며, 딥러닝 기술이 통신과 신호처리 분야에서도 크게 활용될 수 있을 것으로 기대된다.

REFERENCES

- [1] D. L. Donoho, "Compressed Sensing," *IEEE Tran. on Inf. Theory*, vol. 52, no. 4, pp. 1289-1306, Apr. 2006.
- [2] C. A. Metzler, A. Maleki, and R. G. Baraniuk, "From Denoising to Compressed Sensing," *IEEE Tran. on Inf. Theory*, vol. 62, no. 9, pp. 5117-5144, Sep. 2016.
- [3] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature* 521, pp. 436-444, 2015.
- [4] A. Mousavi, A. B. Patel, R. G. Baraniuk, "A deep learning approach to structured signal recovery," *53rd Annual Allerton Conference on Communication, Control, and Computing*, pp. 1226-1343, 2015.
- [5] K. Kulkarni, S. Lohit, P. Turaga, R. Kerviche, A. Ashok, "ReconNet: Non-Iterative Reconstruction of Images from Compressively Sensed Measurements," *IEEE Conference on Computer Vision and*

- Pattern Recognition*, pp. 449-458, 2016.
- [6] A. Mousavi and R. G. Baraniuk, "Learning to invert: Signal recovery via deep convolutional networks," arXiv preprint arXiv:1701.03891, 2017.
- [7] C. A. Metzler, A. Mousavi, R. G. Baraniuk, "Learned D-AMP: Principled Neural-Network-based Compressive Image Recovery," *arXiv preprint arXiv:1704.06625*, 2017.
- [8] M. Borgerding, P. Schniter, and S. Rangan, "AMP-Inspired Deep Networks for Sparse Linear Inverse Problems," *IEEE Trans. Sig. Processing*, early access, May 2017.
- [9] H. Palangi, R. Ward, and L. Deng, "Distributed Compressive Sensing: A Deep Learning Approach," *IEEE Trans. Sig. Processing*, vol. 64, no. 17, pp. 4504-4518, Sep. 2016.
- [10] D. E. Rumelhart, G. Hinton and R. J. Williams, "Learning presentations by back-propagation errors," *Nature* 323, pp. 533-536, 1986.
- [11] G. Hinton, S. Osinder, and Y. W. The, "A fast learning algorithm for deep belief nets," *Neural computation*, vol. 18, no. 7, pp. 1527-1554, Jul. 2006.
- [12] A. Krizhevsky, I. Sutskever, and G. Hinton, "Imagenet classification with Deep Convolutional Neural Networks," *Advances in Neural Information Processing Systems*, pp. 1097-1105, Dec. 2012.
- [13] N. Srivastava, G. Hinton, A. Krizhevsky, "Dropout: A simple way to prevent neural networks from overfitting," *The Journal of Machine Learning Research* 15.1, pp. 1928-1958, 2014.
- [14] C. Szegedy et al, "Going deeper with convolutions," *CoRR, abs/1409.4842*, 2014.
- [15] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," *IEEE International Conference on Computer Vision and Pattern Recognition*, Nevada, USA, pp. 770-778, Nov. 2016.
- [16] Y. Lecun, L. Bottou, Y. Bengio, P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998.
- [17] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning, *The MIT Press*, 2016.
- [18] G. Dahl, T. Sainath, and G. Hinton, "Improving deep neural networks for LVCSR using rectified linear units and dropout," *IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP)*, BC, Canada, pp. 8609-8613, 2013.
- [19] D. L. Donoho and Y. Tsaig, "Fast Solution of L1-norm Minimization Problems When the Solutioni May Be Sparse," *IEEE Trans. Info. Theory*, vol. 54, no. 11, pp. 4789-4812, Nov. 2008.
- [20] A. Chambolle, R. A. DeVore, N. Lee, and B. J. Lucier, "Nonlinear wavelet image processing: Variational problems, compression, and noise removal through wavelet shrinkage," *IEEE Trans. Image Process.*, vol. 7, no. 3, pp. 319-335, Mar. 1998.
- [21] D. L. Donoho, A. Maleki, and A. Montanari, "Message passing algorithms for compressed sensing," *Proc. Nat. Acad. Sci.*, vol. 106, pp. 18914-18919, Nov. 2009.
- [22] Christopher A. Metzler, A. Maleki, and R. G. Baraniuk, "From Denoising to Compressed Sensing," *IEEE Trans. Info. Theory*, vol. 62, no. 9, pp. 5117-5144, Sep.

2016.

[23] C. Li, W. Yin, and Y. Zhang, "User's guide for tval3: TV minimization by augmented lagrangian and alternating direction algorithms," *CAAM report*, vol. 20, pp. 46-47, 2009.

[24] W. Dong et al, "Compressive Sensing via Nonlocal Low-Rank Regularization," *IEEE Trans. Image Processing*, vol. 23, no. 8, pp. 3618-3632, Aug. 2014.

[25] P. Schniter, S. Rangan, and A. Fletcher, "Vector approximate message passing for the generalized linear model," *2016 50th Asilomar Conference on Signals, Systems and Computers*, CA, USA, Nov. 2016.

[26] E. J. Candes, J. Romberg, and T. Tao, "Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information," *IEEE Trans. Info. Theory*, vol. 52, no. 2, pp. 489-509, Feb. 2006.

[27] A. Mousavi, A. Maleki, R. G. Baraniuk, "Consistent parameter estimation for LASSO and approximate message passing," *Annals of Statistics*, 2017.

저자약력

성진택(Jin-Taek Seong)

[정회원]



- 2014년 8월 : 광주과학기술원
정보통신공학 (공학박사)
- 2008년 ~ 2010년 : LG전자
- 2014년 ~ 2016년 : 대구경북첨단
의료산업진흥재단
- 2016년 ~ 2017년 : 방위사업청
- 2017년 4월 ~ 현재 : 호남대학교
정보통신공학과 조교수

<관심분야>

통신이론, 정보이론, 신호처리