

의료영상에서의 딥 러닝

이 한 상 · 박 민 석 · 김 준 모

한국과학기술원 전기 및 전자공학과

Deep Learning in Medical Imaging

Hansang Lee, Minseok Park, Junmo Kim

Department of Electrical Engineering, KAIST, Daejeon, Korea

= Abstract =

As a branch of artificial intelligence, machine learning has been one of the most important technologies not only in computer vision but also in medical image analysis. Currently, the deep learning, a specific model of artificial neural networks, is getting increasing attention with its theoretical novelty and significantly successful performance in computer vision. Furthermore, since deep learning has shifted the paradigm of feature extraction from the hand-crafted features to the learnt-from-data features, deep learning is considered as a promising machine learning framework in medical imaging applications. In this paper, we briefly introduce the concepts of deep learning and its several models. Additionally, we review the related works on deep learning applications in medical image analysis including image classification, detection and segmentation.

Key words: Machine learning, Deep learning, Artificial neural network, Medical imaging, Image analysis

서 론

기계학습(machine learning)은 인공지능의 한 분야로 주어진 데이터로부터 패턴이나 특성을 학습하여 새로운 데이터에 대해 작업을 수행해낼 수 있도록 하는 알고리즘 및 관련 분야를 의미한다. 기계학습은 소프트웨어 기술로부터 금융, 경제에 이르기까지 알고리즘 기반의 모든 분야에 응용되고 있으며 특히 컴퓨터 비전 및 영상처리 분야의 비약적인 발전을 선도하는 핵심 기술로 자리 잡고 있다. 기계학습은 최근 의료영상분석을 포함한 의료기술에도 응용되고 있는데, 의료영상에서 기관이

나 암 부위 등의 추출 및 분할이나 영상 정합, 영상 검색 등 전반적인 의료영상 분석 분야에 널리 활용되고 있다.

최근 딥 러닝(deep learning)이라는 기계학습 기법이 핵심 기술로 대두되면서 관련 기술 및 응용 분야에 대한 관심 또한 높아지고 있다. 딥 러닝은 생물의 신경계를 모방한 인공신경망(artificial neural network)의 하나로서 기존의 인공신경망 모델이 얇은 층의 뉴런 모델들의 연결로 구성되어 있다면, 딥 러닝은 뉴런 모델의 층을 깊게 쌓아올림으로써 신경망의 학습 능력을 높이는 모델이다. 여러 층으로 이루어진 인공신경망으로서의 딥 러닝의 개념은 1970년대에 제안되었으나, 학습 계산의 복잡성 등으로 인해 정체되어 있다가 최근 여러 가지 연구를 통해 그 성능이 개선되고 관련 연구들이 음성인식 및 영상인식 등의 분야에서 뛰어난 결과를 보이면서 그 수요가 빠르게 증가하고 있다.

이 중설에서는 딥 러닝의 개요 및 관련 연구에 대한 고찰 및

통신저자: 김준모, (305-338) 대전광역시 유성구 대학로 291
한국과학기술원 전기 및 전자공학과
Tel: 042-350-3488, Fax: 042-350-3410
E-mail: junmo.kim@kaist.ac.kr

의료영상분석에 있어 딥 러닝의 응용사례에 대해 살펴본다. 2장에서는 딥 러닝의 개요와 관련 주요 기술들에 대해 역사와 원리를 소개한다. 3장에서는 최근 의료영상 분석에 딥 러닝이 응용된 사례에 대해 정리한다. 4장에서는 추후 의료영상 분석에 있어 딥 러닝의 응용 가능성에 대해 언급함으로써 결론을 맺는다.

딥 러닝의 개요

1. 인공신경망

상기한 바와 같이 딥 러닝은 인공지능 및 기계학습의 대표적인 모델 중에 하나인 인공신경망의 일종이다. 인공신경망의 시초는 1943년 McCulloch and Pitts [1]가 사람의 신경 속 뉴런의 활동을 단순한 네트워크로 모형화함으로써 그 개념이 제안되었다. 또한 1949년 Hebb [2]은 두 개의 뉴런이 서로 반복적이고 지속적인 자극을 통해 영향을 받으면, 두 뉴런 사이의 시냅스의 연결강도가 증가함으로써 소위 뉴런의 학습 과정이 이루어진다는 Hebbian learning 이론을 제시했다. 예를 들어, 파블로프의 개 실험에서 종소리에 반응하는 뉴런과 침을 분비하는 반응을 유발하는 뉴런의 연결성이 처음에는 약했으나, 반복되는 실험을 통해 시냅스 연결성이 강화되고 조건 반사가 일어났다는 것이 Hebbian learning의 학습 이론이다. 이러한 학습 규칙은 향후 인공신경망 기술에 있어서도 학습의 중요한 토대가 되었으며, 뉴런 간의 연결성을 효과적으로 추정하는 것을 목표로 다양한 연구가 이루어졌다.

2. 퍼셉트론

1958년 Rosenblatt [3, 4]에 의해 제안된 퍼셉트론(perceptron)은 1세대 인공신경망 모델이라고 할 수 있다. 퍼셉트론은 뉴런이 입력층(input layer) 및 출력층(output layer) 두 층으로 구성되어 있는 가장 간단한 전방향 네트워크(feed-forward network)이다. 상기한 바와 같이 인공신경망의 학습은 기본적으로 입력층의 뉴런과 출력층의 뉴런 사이의 시냅스 연결강도를 모방한 가중치(weight)를 추정하는 것으로서, 이 가중치는 입력된 학습 데이터로부터 인공신경망이 생성하는 출력값이 학습 데이터의 정답과 유사해지는 방향으로 조절하게 된다. 여기서 출력값은 입력층의 뉴런에 입력되는 값과 해당 시냅스에서의 가중치를 곱한 것을 모두 합한 선형모델 수치를, 임계값(threshold) 기반의 활성화함수(activation function)를 거쳐 뉴런의 활성화를 결정하게 된다. 선형모델 기반의 뉴런-시냅스 모델과 활성화함수의 도입을 통해 초기 인공신경망 모델을 구성한 점에서 퍼셉트론은 비교적 정확히 계산된 최

초의 인공신경망 모델이라는 의의가 있으나 선형 분리가 가능한 간단한 분류 문제에서만 학습이 가능하고, XOR과 같이 단순한 문제도 기존 퍼셉트론으로는 학습이 불가능한 한계가 있었으며, 1969년 Minsky and Papert [5]는 퍼셉트론의 심각한 제약성을 수학적으로 입증하는 데에 이르렀다. 이후 이러한 한계점을 극복하기 위해 입력층과 출력층 사이에 은닉층(hidden layer)을 배치한 다층 퍼셉트론(multi-layer perceptron) 방법이 고안되었으며 이와 같이 은닉층을 여러 층 배치한 것이 초기 딥 러닝의 개념이라는 점에서 다층 퍼셉트론의 제안은 매우 중요한 것이었다. 그러나 기존의 퍼셉트론을 학습하는 방식으로는 다층 퍼셉트론의 학습을 수행할 수 없었고, 다층 퍼셉트론 역시 기존 퍼셉트론의 한계를 반복할 것이라는 Minsky and Papert [5]의 가설로 인해 퍼셉트론을 포함한 인공신경망 연구는 1970년대를 전후로 소강기를 맞이하였다.

3. 역전파 알고리즘

소강기에 접어들었던 인공신경망 연구는 1980년대에 이르러 다시금 전환기를 맞게 되는데 이는 역전파 알고리즘(back-propagation algorithm)으로부터 시작되었다. 역전파 알고리즘은 인공신경망에서 뉴런 간의 연결 가중치를 추정하는 방법으로서 학습 결과의 오차를 출력층에서부터 입력층으로 거슬러 올라가는 방향으로 역전파하여 오차의 기울기를 계산하고, 기울기 하강(gradient descent)을 이용하여 오차를 최소화시키는 가중치를 찾는 방법이다. 역전파 알고리즘은 1969년 처음 제안되었다가 1986년 Rumelhart, Hinton and Williams [6]가 역전파 알고리즘을 통해 다층 퍼셉트론의 학습방법을 제안함으로써 많은 관심을 받게 되었다. 여기에는 컴퓨터와 하드웨어의 발전을 통해 뉴런 수가 증가할수록 학습시간이 매우 길어지는 역전파 알고리즘의 한계를 만회한 시대적인 배경도 작용하였다. 그러나 역전파 알고리즘은 초기 상태에 따라 오차를 최소화시키는 과정에서 전역적 최소값(global minimum)이 아닌 지역적 최소값(local minimum)에서 고착화되는 한계가 있었으며, 다른 기계학습 기법에 비해 상당히 많은 학습 데이터를 요구하거나, 학습시간이 오래 걸리고, 지도학습(supervised learning)에 대해서만 모델이 구성되어 있는데다가 과적합(overfitting) 특성을 보이는 등 여러 가지 문제점을 여전히 안고 있었다. 이러한 한계점을 극복하지 못한 상태에서 1995년 지지벡터기계(support vector machine, SVM) 기법의 등장인 기계학습 기술의 구도를 재편하면서 인공신경망 연구는 다시 동면기를 갖게 되었다.

4. 현대 딥 러닝 모델들

인공신경망의 3세대라고 할 수 있는 딥러닝의 연구는 2006년 Hinton이 한정볼츠만기계(restricted Boltzmann machine, RBM)를 쌓아올린 DBN(deep belief network) [7, 8]을 제안하면서 시작됐다. 기존의 인공신경망은 상기했듯이 모든 학습데이터가 정답이 부여된 데이터인 지도학습의 형태로 이루어졌는데, 이로 인해 학습 데이터의 수가 충분히 많아야 학습이 잘 이루어지는 인공신경망의 특성과 과적합 특성 사이에서 지속적으로 제약을 받아와야 했다. 이러한 한계를 극복하기 위해 데이터를 생성할 수 있는 모델(generative model)을 학습시키는 방법을 제안하고, 이 모델의 에너지함수를 정의하여 볼츠만 분포를 따르도록 학습시키는 것이 RBM이다. RBM의 장점은 뛰어난 특징추출(feature extraction)에 있는데, 이는 학습데이터에 정답이 부여되지 않은 비지도학습(unsupervised learning)으로도 가능하다는 장점이 있다. DBN은 다층 퍼셉트론과 구조가 같지만, 기존의 역전파 알고리즘을 상기한 RBM으로 대체하여 학습을 수행하였다. DBN에서는 학습시킬 신경망의 각 층을 차례로 비지도학습 기반의 RBM을 통해 사전훈련(pre-training)을 수행, 과적합을 방지하는 초기 가중치를 찾았으며, 이를 다시 지도학습 기반의 역전파 알고리즘을 통해 미세조정(fine-tuning)하였다.

딥 러닝 모델의 제안 및 관련 연구의 성과가 홍보되면서 많은 연구들이 동시에 이루어졌으며 기존의 인공신경망 기술이 갖고 있던 고질적인 문제들도 상당 부분 보완되고 있다. 대표적인 개선 기술 중에 하나는 기존의 활성화함수로 사용된 S상단위(sigmoid unit)함수를 정류선형단위(rectified linear unit, ReLU)함수 [28]로 대체한 것이다. 정류선형단위는 선형단위의 사용을 통해 오류 역전파 정보가 사라지는 문제(vanishing gradient problem)를 해결함으로써 딥 러닝 모델을 한정볼츠만기계의 도움 없이 지도학습에 이용할 수 있게 하였다. 그 이후에도 2013년 Dahl이 인공신경망을 구성하는 뉴런을 임의로 점멸하는 방식의 드롭아웃(drop-out) 기술 [10]을 제안하여 과적합 문제에 대한 개선이 이루어졌으며, 신경망 규모의 증가에 따른 가중치 수 증가로 인한 학습시간 장

기화나 초기 가중치에 지나치게 영향을 받는 문제 또한 뉴런들이 가중치를 공유하는 방식으로 실질적인 파라미터 개수를 줄인 회전신경망(convolutional neural network, CNN) 모델 [11]의 제안을 통해 상당 부분 해결되었다. 또한 그래픽처리장치(GPU)와 같이 하드웨어의 급진적인 발전과 대용량 데이터(big data)의 보편화 등을 통해 인공신경망 모델을 구성할 최적의 환경이 조성되면서 딥 러닝은 명실상부한 기계학습의 대표적 기술로서의 위치를 확고히 하고 있다.

5. 딥 러닝의 특징

기계학습은 크게 학습 데이터의 정답이 모두 제공되어 있는 지도학습과 정답이 없이 자율적으로 학습하는 비지도학습으로 나눌 수 있다. 딥 러닝 기반의 학습 기술도 이 두 가지 방식으로 나뉘어 연구되어왔다. 비지도학습의 경우 학습 데이터를 기반으로 사전훈련을 거친 후, 지도학습을 통해 역전파 알고리즘 기반의 미세조정을 하는 방식이 일반적으로, 상기했듯이 한정볼츠만기계를 이용한 DBN과 같은 방식이 여기에 해당된다. 지도학습의 경우 다양한 방법으로 초기 가중치를 설정하고 역전파 알고리즘 기반의 확정모델(deterministic model) 추정을 통한 다층 퍼셉트론이나 CNN 모델 등을 일반적으로 사용하고 있다. 표 1은 관련 기술 및 모델을 요약한 것이다.

딥 러닝의 의의는 단순히 인공신경망의 성능 개선을 통해 기계학습의 주류 기술로 자리매김한 데에 그치지 않는다. 기계학습의 근간을 이루는 분류 및 인식 문제에서, 기존의 기계학습 기술은 SIFT [12]나 SURF [13] 등과 같이, 전문가에 의해 고안된 아이디어를 바탕으로 직접 설계된 이른바 수제작특징(hand-crafted feature)들을 추출하고 이들 특징을 기반으로 학습하여 문제를 해결하는 방식이었다. 따라서 특징의 정의 및 추출은 기계학습 기술에서도 매우 큰 비중을 차지하는 중요한 문제였으며, 수행하고자 하는 작업이나 목표 영상의 특성 등에 따라 학습 특성이 좋은 특징의 종류가 천차만별이었기 때문에, 어떠한 특징을 어떻게 추출해서 사용할건지에 대한 결정이 기계학습 기반 문제의 해결에 있어 굉장히 중요하고 까다로운 작업으로 인식되었다. 그러나 딥 러닝에서는 상기했듯이 학습과

표 1. 딥 러닝의 학습 방식에 따른 분류 및 대표 기술

분류	학습 방식	관련 기술	
		모델	제안자
확률 모델 (stochastic model)	- 한정볼츠만기계 [7] 등을 이용한 비지도학습 기반의 사전훈련을 수행함 - 사전훈련을 통해 계산한 초기 가중치를 바탕으로 역전파를 통한 지도학습을 수행함	DBN [8]	Hinton 외
확정 모델 (deterministic model)	- 역전파를 통한 지도학습을 수행함	다층 퍼셉트론 회전신경망 [11]	Rumelhart 외 LeCun 외

정에서 특징을 자체적으로 추출하고 학습까지 함께 수행하는 새로운 패러다임을 제시함으로써 수행하고자 하는 작업이나 대상 영상의 특성에 상관없이 일반적인 모델링이 가능하다. 특히 색이나 테두리선과 같은 하위 수준의 특징들뿐만 아니라, 신경망의 계층적 구조로 인해 기존의 상위 수준의 특징들과 유사한 특징들 역시 추출, 학습할 수 있는 능력이 있다. 이는 경계가 모호하고 불연속성이 심해 기존의 테두리선이나 SIFT와 같은 특징들이 제대로 표현해내지 못했던 의료영상의 경우 딥 러닝을 통한 영상 특징의 추출 및 학습을 통해 의료영상의 특성에 더욱 적합한 특징을 추출하는 여러 가지 사례를 뒷받침한다.

의료영상에서 딥 러닝의 응용

1. 뇌 자기공명영상에서 다양체 학습

다양체 학습(manifold learning)은 데이터의 차원이 매우 높지만 본질적으로는 훨씬 낮은 차원에서 분포하는 데이터의 분석에 필요한 중요 기술이다. 예를 들어 뇌 자기공명영상은 영상의 삼차원 좌표 크기인 S_x, S_y, S_z 에 대하여 각 영상을 $S_x \times S_y \times S_z$ 차원 상의 한 점으로 정의될 수 있다. 그러나 이러한 고차원 좌표계에서의 표현에 비해 뇌 영상의 형상이나 패턴 다양성은 비교적 저차원의 변수의 조합으로 설명될 수 있는데, 이러한 저차원 표현 기반을 다양체(manifold)라고 하며 다양체를 영상 데이터의 학습을 통해 추출하는 방법을 다양체 학습이라고 한다.

지역적 선형 사상(locally linear embedding, LLE) [14], 라플라시안 고유지도(Laplacian eigenmaps, LEM) [15], 아이소맵(Isomap) [16] 등의 기존 다양체 학습 기법들이 의료영상을 포함한 다양한 분야에 활용되고 있으나, 기존의 다양체 학습 기법은 근접성 그래프(proximity graph)의 생성을 위해 다양체 공간이 지역적으로 선형이라는 가정을 하고 설계해야 하는 제약이 따랐다. 또한 Gerber 외 [17]의 분석에 의하면 다양체 학습에서 데이터 간의 상관도를 표현하는 거리 함수로 어떤 것을 사용하느냐에 따라 다양체 학습의 성능이 크게 좌우되는 한계가 있다.

Brosch 외 [18]는 앞서 다룬 딥 러닝의 일종인 DBN [8]을 사용하여 뇌 자기공명영상의 다양체 학습 기법을 제안하였다. 제안방법에서는 다섯 층의 RBM으로 구성된 DBN을 사용하였으며, 앞단에서 고해상도 영상에 의한 계산시간을 줄이기 위해 앞의 세 층을 회선 RBM(convRBMs) [19]을 사용하여 설계하였다. 기존의 다양체 학습 기법과 달리, 딥 러닝을 활용한 제안 기법의 경우 다양체 공간의 지역적 선형성을 가정할 필요

가 없으며, 사전에 정의된 거리 함수의 사용이나 근접성 그래프의 생성 등이 필요 없는 장점이 있다. 제안한 방법을 300개의 정상인 및 알츠하이머(Alzheimer's disease, AD) 환자의 T1강조 뇌 자기공명영상 데이터인 ADNI 데이터 [20]에 대해 실험한 결과, $128 \times 128 \times 128$ 해상도의 영상에 대해 2개의 변수에 대한 2차원 표현만으로 성공적인 다양체를 학습하는 결과를 확인하였다. 학습한 다양체에서 2개의 변수는 각각 영상에서 뇌의 크기와 뇌실(ventricle)의 크기로서 주로 AD 환자에게서 뇌실이 커지는 현상을 딥 러닝을 통해 자동으로 학습하여 특징화한 것을 알 수 있다.

2. 조직병리영상에서 기저세포암 인지

기저세포암(basal-cell carcinoma, BCC)은 가장 흔한 형태의 악성 피부암으로 알려져 있다. 기저세포암은 조직병리영상(histopathology image)의 분석을 통해 진단 및 분석을 수행하게 되는데, 조직병리영상의 경우 색, 형상, 텍스처와 같은 객체 특성이 영상들에 걸쳐 공통적으로 나타나는 일반 영상과는 달리 서로 다른 패턴의 복잡한 조합으로 구성되어 있어 그 분석이 매우 까다로운 문제를 갖고 있다. 조직병리영상의 분석을 위해 이산코사인변환(discrete cosine transform, DCT), 웨이블릿(wavelet) 및 가버 기술자(Gabor descriptor) 등을 이용한 특징 추출에 기반한 여러 가지 분석 연구가 수행되었으며, 여러 가지 지역적 특징의 조합에서 영상의 중요 특징을 학습하는 방식의 BOF(bag of features) 기반의 연구 [21, 22]가 수행되었다. 그러나 이러한 연구의 경우 기존의 수채 특징의 조합을 사용하며, 어떤 조합의 특징을 사용하느냐에 따라 성능이 많은 영향을 받는 한계가 있었다.

Cruz-Roa 외 [23]는 상기한 한계를 극복하기 위해 딥 러닝을 통해 조직병리영상으로부터 영상 분석에 유용한 특징을 자동으로 추출하는 방법을 제안하였다. 제안방법은 RBM과 같은 역할을 하는 딥 러닝의 일종인 오토인코더(autoencoder) [24]를 사용하여 비지도학습 상태에서 조직병리영상의 특징을 학습하고, 이후 학습한 특징 필터를 이용하여 영상의 회선(convolution) 및 통합(pooling)을 통해 영상의 주요 특징들을 인식한 뒤 인식된 특징을 바탕으로 소프트맥스(softmax) 분류 [25]를 수행, 기저세포암의 인식을 수행하였다. 1417장의 조직병리영상에 대해 제안방법을 실험한 결과 기존의 특징을 조합한 BOF 기반의 방법에 비해 개선된 성능의 학습 및 인식을 수행하는 것을 확인하였다. 또한 소프트맥스 분류 단계에서 영상의 특징 지도의 비중에 따라 영상에서 암 영상으로 보이는 영역과 정상 영상으로 보이는 영역을 표시할 수 있는데, 이 과정을 통해 일종의 전자 염색(digital staining)을 하는 효

과를 보이는 것으로 나타났다.

3. 뇌 자기공명영상에서 해마 분할

최근 7.0T 수준의 초고자장 자기공명영상 장치 등이 소개되면서 해당 영상에서의 분석 또한 활발히 연구되고 있다. 그러나 기존의 1.5T나 3.0T 자기공명영상에 비해 매우 세밀하고 고화질의 영상이 출력되는 7.0T 영상의 경우 동일한 기관에 대해서도 내부의 불연속성이 더욱 심화되고 고대비를 이루면서 기존의 영상과 다른 양상을 가지게 된다. 이로 인해 기존 1.5T나 3.0T에 적용되었던 SIFT나 Haar와 같은 수제 특징을 이용한 기계학습 기반 분석 방법을 7.0T 영상에 그대로 적용했을 때 기존의 성능이 보장되지 않은 어려움이 있다. 이와 같은 문제를 극복하기 위해 Kim 외 [26]는 딥 러닝 구조를 이용해 7.0T 자기공명영상에 적합한 특징을 자동으로 학습하고, 해당 특징을 통해 뇌 영상에서 해마의 분할을 수행하는 다중 아틀라스 기반 알고리즘을 제안하였다.

제안방법은 크게 이층으로 구성된 회선 독립부공간해석(independent subspace analysis, ISA) [27] 구조를 통해 자기공명영상의 특징을 학습하고, 자동맥락모델(auto-context model, ACM) 분류 기반의 다중 아틀라스 분할을 통해 해마의 분할을 수행하였다. 독립부공간해석은 RBM과 같이 비지도학습에서 차원축소(dimensionality reduction) 기반의 특징 추출 방법으로서 제안방법에서는 $576 \times 576 \times 576$ 크기의 입력영상에서 첫 번째 층에서는 $16 \times 16 \times 3$, 두 번째 층에서는 $20 \times 20 \times 5$ 크기의 패치들을 추출하여 입력, 학습을 수행하였으며 각각 200차원, 100차원의 특징을 추출하였다. 이렇게 추출한 특징을 이용하여 ACM 기반의 다중 아틀라스 분할을 수행하는데, 제안방법에서는 복수의 영상 및 분할결과로 이루어진 다중 아틀라스에서 각각의 아틀라스에 대해 앞의 특징 추출을 수행하여 아틀라스의 개수만큼의 특징 기반 분류기를 확보하고, 대상 영상에 대한 이들의 분류결과를 반복적으로 통합하여 최종 해마 분할을 수행하였다. 20개의 7.0T 자기공명영상에서 실험을 수행한 결과, 딥 러닝을 통해 특징을 추출, 분할한 제안방법의 결과가 수제 특징 기반의 분할 결과보다 우수함을 확인하였다.

결 론

이 종설에서는 최근 기계학습의 핵심 기술로 부상한 딥 러닝의 역사 및 개요를 소개하고 관련 기술에 대해 요약하였다. 또한 여러 가지 도전적인 의료영상분석 과제에 딥 러닝이 다양하게 활용되는 사례에 대해 살펴보았다. 현대 의료영상분석에서

대용량 영상 분석이나 효과적인 성능 개선을 위해 기계학습 기술의 응용이 필수적이라 함은 주지의 사실이다. 그 중에서도 특히 대용량 데이터의 학습에서 뛰어난 성능을 보이거나 학습 데이터에 알맞은 특징을 스스로 추출, 학습하는 딥 러닝의 특성은 의료영상분석의 여러 한계점들을 극복함으로써 매우 비중 있게 활용되고 있으며, 영상 분류와 질병 인식, 영상 분할 등의 다양한 분야에서 우수하거나 유망한 결과를 보이고 있다. 현재 지속적으로 기계학습 및 컴퓨터 비전 분야에서 딥 러닝의 개선 및 관련 연구가 수행되고 있음에 따라, 다양한 의료영상 분석의 과제들에 대한 딥 러닝 기술의 응용 또한 지속될 것으로 예상된다.

감사의 글

This work was supported in part by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIP) 2010-0028680 and 2014-003140.

참 고 문 헌

- McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. 1943
- Hebb DO. The Organization of Behavior. New York: Wiley & Sons. 1949.
- Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. 1958.
- Rosenblatt F. Principles of neurodynamics. New York: Spartan Books. 1962.
- Minsky M, Papert S. Perceptrons. Cambridge: MIT Press. 1969.
- Rumelhart DE, McClelland JL, PDP Research Group. Parallel Distributed Processing: explorations in the microstructure of cognition. Cambridge: MIT Press. 1986.
- Hinton GE. Learning multiple layers of representation. Trends in Cognitive Sciences. 2007;11:428-434
- Hinton GE, Osindero, S, Teh YW. A fast learning algorithm for deep belief nets. Neural Computation. 2006;18:1527-1554.
- Bengio Y, Lamblin P, Popovici P, Larochelle H. Greedy Layer-Wise Training of Deep Networks. Advances in Neural Information Processing Systems 19. 2007.
- Dahl GE. Improving DNNs for LVCSR using rectified linear units and dropout. ICASSP. 2013.
- LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-Based Learning Applied to Document Recognition. Proceedings of the IEEE. 1998;86(11):2278-2324
- Lowe DG. Distinctive image features from scale-invariant key points. International Journal of Computer Vision. 2004;60(2):91-110.
- Bay H, Ess A, Tuytelaars T, Van Gool L. SURF: Speeded Up Robust Features. Computer Vision and Image Understanding (CVIU), 2008:110(3);346-359.
- Saul, L., Roweis, S. Think globally, fit locally: unsupervised learning of low dimensional manifolds. the Journal of Machine

Learning Research 2003;4:119-155.

15. Belkin, M., Niyogi, P. Laplacian eigenmaps for dimensionality reduction and data representation. *Neural Computation* 2003;15(6):1373-1396.
16. Tenenbaum, J.B., de Silva, B., Langford, J.C. A global geometric framework for nonlinear dimensionality reduction. *Science* 2000;290(5500):2319-2323.
17. Gerber S., Tasdizen, T., Fletcher, P.T., Joshi, S., Whitaker, R. Manifold modeling for brain population analysis. *Medical Image analysis* 2010;14(5):643-653.
18. Brosch, T., Tam, R. Manifold learning of brain MRIs by deep learning. *International Conference on Medical Image Computing and Computer Aided Intervention* 2013;2(8150): 633-640.
19. Lee, H., Grosse, R., Ranganath, R., Ng, A.Y. Unsupervised learning of hierarchical representations with convolutional deep belief networks. *Communications on Machine Learning* 2011;54(10):95-103.
20. Petersen, R., Aisen, R., Beckett, L., Donohue, M. Gamst, A. Alzheimer's disease neuroimaging initiative (ADNI). *Neurology* 2010;74(3):201-209.
21. Cruz-Roa, A, et al. Visual pattern mining in histology image collections using bag of features. *Artif. Intell. Med.* 201;52(2): 91-106.
22. Cruz-Roa, A., Gonzalez, F., Galaro, J., Judkins, A.R., Ellison, D., Baccon, J., Madabhushi, A., Romero, E. A visual latent semantic approach for automatic analysis and interpretation of anaplastic medulloblastoma virtual slides. *MICCAI 2012, Part I* 2012;7510:157-164.
23. Cruz-Roa, A., Ovalle, J.E.A., Madabhushi, A., Osorio, F.A.G. A deep learning architecture for image representation, visual interpretability and automated basal-cell carcinoma cancer detection. *MICCAI 2013, Part II* 2013;8150:403-410.
24. Bengio, Y. Learning deep architectures for AI. *Foundations and Trends in Machine Learning* 2009;2(1):1-127.
25. Krizhevsky, A., et al. Image net classification with deep convolutional neural networks. *NIPS* 2012:1106-1114.
26. Kim, M., Wu, G., Shen, D. Unsupervised deep learning for hippocampus segmentation in 7.0 Tesla MR images. *MLMI* 2013;8184:1-8.
27. Le, Q.V., et al. Learning hierarchical invariant spatio-temporal features for action recognition with independent subspace analysis. *IEEE Conf. on Computer Vision and Pattern Recognition* 2011.
28. Nair V, Hinton GE. Rectified linear units improve restricted Boltzmann machines. *Proc. International Conference on Machine Learning*. 2010.

= 초 록 =

기계학습은 주어진 데이터로부터 패턴이나 특성을 학습하여 스스로 작업을 정의, 수행할 수 있도록 하는 기술 분야로서 영상분할 및 정합과 같은 의료영상분석에도 비중 있게 활용되고 있다. 최근 인공지능의 일종인 딥 러닝 기술이 기계학습의 핵심기술로 대두되면서 관련 기술 및 연구가 주목받고 있다. 특히 기존의 기계학습 기술의 근간을 이루는 수제 특징 추출을 데이터 학습을 통한 특징의 학습으로 대체하면서 기존의 수제 특징 적용이 어려웠던 의료영상 분야에서 딥 러닝의 활용 가능성에 대한 관심이 더욱 높아지고 있다. 본 종설에서는 딥 러닝의 개요 및 역사와 관련 연구 및 기술을 소개한다. 또한 영상 분류, 인식 및 분할 등 최근 의료영상의 분석과 관련된 분야에 딥 러닝이 활용된 사례를 살펴본다.