

Deep Learning: 기계학습의 새로운 트렌드

김 인 중
한동대학교

요약

Deep learning은 많은 수의 계층으로 이루어진 깊은 신경망을 학습하기 위한 연구 분야이다. 지난 수 년 동안 deep learning은 다양한 분야에 적용되어 기존 방법들을 능가하는 높은 성능을 보였으며, 그 결과 기계학습 및 패턴인식 분야에서 가장 중요한 기술적 트렌드가 되어가고 있다. 깊은 신경망의 장점과 그 동안 깊은 신경망의 학습이 어려웠던 이유를 설명하고 이러한 어려움을 극복한 새로운 알고리즘들을 소개한다. 마지막으로 deep learning의 성공적 응용 사례에 대해 소개한다.

I. 서론

수 년 전부터 기계학습(machine learning)에 대한 관심이 높아지고 있다. 기계학습은 컴퓨터가 수행해야 할 작업을 데이터로부터 스스로 배우도록 하는 방법론을 연구하는 학문분야이다. 기계학습은 오랫동안 연구되어 온 학문 분야이다. 과거에 깊이는 있었으나 실생활과 다소 거리가 있는 학문분야였다면, 지금은 기계학습기술 자체의 발전과 함께 빅데이터 및 하드웨어 등 연관분야의 발전에 힘입어 실질적인 부가가치를 창출할 수 있는 실용성 높은 기술이 되었다. 소셜 네트워크의 활성화와 함께 다양한 형태의 미디어들이 폭발적으로 증가하였는데, 이는 새로운 기계학습의 응용 분야들을 창출하였을 뿐 아니라, 기계학습에 필수적인 학습데이터를 비교적 적은 비용과 시간으로 수집할 수 있는 기회를 제공하였다. 그 결과 기계학습 기술은 눈부신 속도로 발전하면서, 다양한 분야에 적용되어 우수한 성능을 보이고 있다.

이와 같은 최근 기계학습 기술의 발전 및 실용화의 중심에는 deep learning이 있다. Deep learning에 기반한 시스템들은 최근 수 년 동안 다양한 응용분야에서 기존 방법들을 압도하는 탁월한 성능을 보여왔다[1]. 그 결과, deep learning은 기계학습 분야에서 기술 발전을 이끄는 가장 중요한 기술이 되었으며,

빠른 속도로 그 응용 분야를 넓혀가고 있다.

Deep learning은 많은 수의 계층으로 구성된 깊은 신경망(deep neural networks)을 학습하기 위한 기술이다. 과거에 사용되었던 신경망은 적은 수의 계층으로 구성된 얇은 신경망(shallow neural network)이었다. 깊은 신경망을 사용하지 못했던 가장 중요한 이유는 기존의 학습 알고리즘으로는 많은 계층으로 구성된 깊은 신경망을 학습하는 것이 어려웠기 때문이다[1]. 적은 수의 계층으로 구성된 신경망만으로는 복잡한 문제들을 해결하는데 있어서 좋은 성능을 얻을 수 없었다. 그러나, 수년 전부터 깊은 신경망을 학습할 수 있는 새로운 방법들이 개발되면서 기술적 장벽이 극복되어 깊은 신경망들이 실용적인 응용분야에 널리 적용되었다[2][3].

본 글에서는 이와 같이 기계학습에서 가장 중요한 트렌드로 떠오른 deep learning에 대한 소개와 함께 deep learning 분야의 기술적 장벽을 극복한 방법론, 그리고, 다양한 응용 분야에 deep learning을 적용한 성공사례들을 소개한다.

II. 깊은 신경망(deep neural networks)




그림 1. 신경망의 구조

신경망은 하나 이상의 계층으로 구성되며, 각 계층은 여러 개의 노드들을 포함한다. 각 계층의 노드들은 하위 계층 노드들의

출력값들을 가중 합(weighted sum)의 형태로 결합한다. 예를 들어, 널리 사용되는 신경망의 종류인 퍼셉트론(perceptron)의 n 번째 계층의 j 번째 노드의 출력값 X_j^n 은 $(n-1)$ 번째 계층의 출력값 X_i^{n-1} 와 두 계층 사이의 가중치 w_{ij}^n 로부터 식 (1)에 의해 계산된다[4]. 여기에서 θ_i^n 는 노드 i 의 편향(bias)이다.

$$X_j^n = f\left(\sum_i w_{ij}^n X_i^{n-1} + \theta_i^n\right) \quad (1)$$

여기에서 각 계층이 수행하는 동작은 가중치 w_{ij}^n 에 의해 결정되는데 가중치가 적절히 학습되었을 경우 각 계층은 하위 계층이 출력한 낮은 수준(low-level)의 특징으로부터 좀 더 높은 수준(high-level)의 특징을 추출한다. 따라서, 최하위 계층에서는 가장 낮은 수준의 특징을 추출하며, 상위 계층으로 갈수록 점점 더 높은 수준의 특징으로 결합되고, 그 결과 최상단 계층에서는 가장 높은 수준의 특징을 추출하거나, 출력 결과를 결정한다. 이러한 원리로 인해, 신경망을 구성하는 계층의 수가 증가하면 할수록 더 높은 수준의 특징을 추출할 수 있게 된다. 그러므로, 깊은 신경망은 높은 수준 특징을 필요로 하는 복잡한 작업을 수행하는데 있어서 탁월한 성능을 갖는다.

깊은 신경망이 갖는 또 다른 장점은 특징 추출과 인식(classification)를 하나의 신경망에서 수행할 수 있다는 점이다. 기존 방법들은 먼저 입력 패턴으로부터 특징추출 알고리즘을 통해 특징 벡터를 추출한 후, 특징 벡터를 인식기에 입력하여 인식 결과를 얻는다. 그러나, 깊은 신경망에서는 각 계층이 특징 추출, 또는 좀 더 높은 수준의 특징으로의 추상화를 수행하기 때문에 깊은 신경망의 중하단 계층들은 특징추출 및 추상화를, 최상단 계층은 인식을 수행하는 것으로 해석할 수 있다. 따라서, 깊은 신경망은 별도의 특징 추출 알고리즘 없이 입력 패턴을 직접 인식할 수 있다. 이와 같이 특징 추출과 인식이 통합되어 수행되는 구조는 추가적인 장점을 갖는다. 기존의 특징 추출 방법들이 고정된 알고리즘에 기반하여 학습이 불가능한데 반해, 깊은 신경망의 특징 추출 계층들은 데이터로부터 학습된다는 점이다. 뿐만 아니라, 특징 추출 및 추상화를 수행하는 중하위 계층의 학습과 인식을 수행하는 상단계층이 동일한 신경망 내에서 통합적으로 학습되기 때문에 이루어지기 때문에 더 좋은 성능을 얻을 수 있다.

또한, 깊은 신경망은 많은 수의 가중치, 즉 학습 파라미터를 포함할 수 있다. 학습 파라미터가 많아지면 과대적합(overfitting)이 발생하여 일반화 능력이 저하되고, 그 결과 학습되지 않은 패턴에 대한 성능이 저하된다. 반면, 학습 파라미터가 많아지면 학습 수용력(capacity)은 증가하기 때문에 매우 많은 수의 학습 데이터가 사용 가능한 경우는 그로부터 많은 정

보를 학습할 수 있게 된다. 이러한 관점에서 신경망은 계층 및 노드의 수를 변화시킴으로써 학습 파라미터의 수를 조절할 수 있다는 장점을 갖는다. 특히, deep learning 기술의 발전으로 인해 계층 수의 제한이 크게 완화됨에 따라, 많은 수의 학습 데이터로부터 많은 정보를 학습기에 충분한 규모의 신경망을 사용할 수 있게 되었는데, 이러한 신경망은 풍부한 학습 데이터로부터 많은 정보를 학습하여 높은 성능을 제공할 수 있다.

이와 같은 깊은 신경망의 장점에도 불구하고, 최근까지는 깊은 신경망을 실제적 응용분야에 적용하는데 현실적인 어려움이 있었다. 가장 중요한 이유는 기존의 알고리즘으로는 깊은 신경망을 학습하기 어렵다는 것이다. 뿐만 아니라, 깊은 신경망을 학습할 수 있는 충분한 학습 데이터를 수집하기 어려웠던 것과 컴퓨터의 성능이 deep learning에 필요한 막대한 계산량을 감당하기에는 충분하지 않았던 것 역시 현실적인 어려움이었다. 그러나, 최근에는 이와 같은 기술적, 현실적 장벽들이 기술의 발전으로 인해 극복되면서 다양한 응용분야에 깊은 신경망을 성공적으로 적용할 수 있게 되었다. 먼저, 빅데이터 기술의 발전으로 인해 대규모 학습 데이터를 수집할 수 있게 되었다. 이는 깊은 신경망이 많은 수의 학습데이터를 요구한다는 단점을 극복하게 함과 동시에 학습 수용력이 크다는 강점을 극대화할 수 있는 계기가 되었다. 또한, 2000년대 중반부터 실용화 된 GPU 기반 대용량 병렬처리 기술은 deep learning에 필요한 계산 능력을 제공하였다[5]. 무엇보다도 기존 학습 알고리즘의 한계를 극복할 수 있는 새로운 알고리즘들이 개발되었다.

III. Deep learning

신경망 학습에 가장 널리 사용되는 알고리즘은 오류 역전사 알고리즘(error back-propagation algorithm)이다[6]. 오류 역전사 알고리즘은 경사도 기반(gradient-based) 방법의 일종이다. 출력값과 희망출력값(desired output)의 차이로부터 오차 함수 E 를 정의한다. 신경망의 출력값은 입력 데이터와 가중치 벡터에 의해 결정된다. 입력 데이터와 희망출력값이 고정될 경우 오차 E 는 가중치 벡터의 함수가 되어 $E(W)$ 로 표기할 수 있다. 오류 역전사 알고리즘은 먼저 $E(W)$ 를 미분하여 오차를 증가시키는 경사도 $\frac{\partial E}{\partial w_{ij}}$ 를 계산한 후, 식 (2)와 같이 $\frac{\partial E}{\partial w_{ij}}$ 의 반대 방향으로 W 를 이동시킴으로써 학습 데이터에 대한 오류를 점차적으로 감소시키는 알고리즘이다.

$$w_{ij} \leftarrow w_{ij} - \eta \frac{\partial E}{\partial w_{ij}} \quad (2)$$

식 (1)에서 활성화 함수의 인자 $\sum_i w_{ij}^n X_j^{n-1} + \theta_i^n$ 를 net_i 로 정의하고 미분법칙을 적용하면, 경사도 $\frac{\partial E}{\partial w_{ij}}$ 는 $\frac{\partial E}{\partial net_j} \frac{\partial net_j}{\partial w_{ij}}$ 로 분할할 수 있다. 여기에서 $\frac{\partial net_j}{\partial w_{ij}}$ 는 입력벡터에 해당한다. $\frac{\partial E}{\partial net_j}$ 는 오차 신호(error signal)로 해석되며 보통 δ_j 로 표기된다. 최상단 계층의 δ_j 는 E(W)로부터 직접 계산할 수 있지만, 하위 계층의 δ_i 는 상단 계층의 δ_j 으로부터 식 (3)과 같이 계산된다.

$$\delta_i = f'(net_i) \sum_j w_{ij} \delta_j \quad (3)$$

식 (3)은 상위 계층의 오차 신호를 결합하여 하위 계층의 오차 신호를 생성하는데, 이 과정에서 서로 다른 방향을 갖는 오차 신호들이 섞여서 서로 상쇄되기 때문에 하위 계층으로 내려갈수록 오차 신호가 점점 희미해진다. 따라서, 계층이 많은 깊은 신경망에 오류 역전파 알고리즘을 적용할 경우, 상위 계층은 학습이 잘 이루어지지만 하위 계층에서는 학습이 잘 이루어지지 않는다.

이와 같이 오차 신호가 약해지는 문제는 가중치 값이 학습되지 않았고, 노드간 연결이 많을 때 특히 심각해진다. 각 계층의 노드들이 모두 연결된(fully-connected) 신경망을 랜덤 가중치로부터 학습한다면 위의 두 조건에 모두 해당되므로 학습이 잘 이루어지지 않는다.

수 년 전부터 이러한 문제점을 극복할 수 있는 학습 알고리즘들이 개발되었는데, 이들은 deep learning 연구를 활성화하는데 결정적인 공헌을 하였다[2][3]. Deep learning 알고리즘은 크게 두 가지로 분류할 수 있다. 첫 번째 방법은 먼저 자율학습(unsupervised learning) 알고리즘에 의해 가중치 값을 사전학습(pre-training)한 후 가중치 값이 성숙하면 기존의 학습 알고리즘에 의해 미세 조정(fine-tuning)하는 것이다. 가중치의 초기값을 랜덤 지정하였을 때에는 기존 학습 알고리즘의 문제점이 심각하게 나타나지만, 사전 학습 알고리즘을 통해 어느 정도 학습된 가중치를 추가적으로 학습할 때에는 그와 같은 문제점이 심각하게 발생하지 않는다. 두 번째 방법은 각 계층의 노드들간 연결의 수를 제한함으로써 오차 신호가 섞이는 문제를 완화하는 것이다. 전자에 해당하는 방법들으로는 DBN(deep belief networks)[2], stacked auto-encoder[7] 등이 있으며 후자의 방법으로는 CNN(convolution neural networks)이 대표적이다[3][8][9].

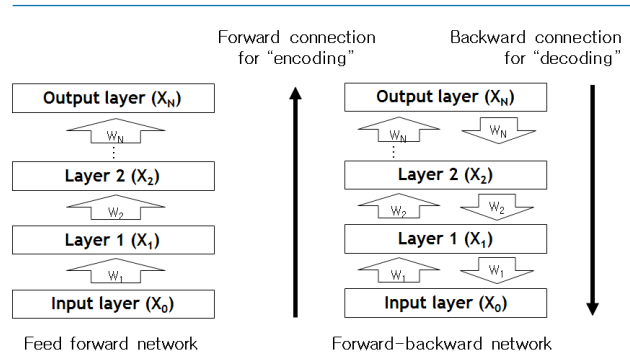


그림 2. 순방향 신경망과 양방향 신경망

사전 학습을 이용한 deep learning 알고리즘들은 순방향 연결과 역방향 연결을 모두 가진 양방향 신경망에 기반한다. 순방향 신경망이 <그림 2>의 좌측과 같이 하위 계층에서 상위 계층으로의 순방향 연결만 갖는데 반해 양방향 신경망은 <그림 2>의 우측과 같이 순방향 연결 뿐 아니라, 상위 계층에서 하위 계층으로 연결된 역방향 연결도 갖는다. 이 때, 순방향 연결은 하위 특징에서 상위 특징을 추출하는 인코딩을 수행하며, 역방향 연결은 상위 특징으로부터 하위 특징을 생성하는 디코딩을 수행한다. 따라서, 순방향과 역방향 연결을 모두 가진 양방향 신경망은 하위 계층에서 상위 계층으로 전파(propagate)한 후 다시 상위 계층에서 하위 계층으로 역전파 함으로써 하위 계층의 특징, 또는 입력 패턴을 복원할 수 있다. 이와 같은 신경망으로는 DBN(deep belief network)에 사용된 RBM(restricted Boltzmann machine)이나 auto-encoder 등이 있다.

양방향 신경망을 이용한 사전학습은 다음과 같이 수행한다. 학습 데이터를 입력 계층에 입력한 다음 첫 번째 은닉 계층(layer 1)으로 인코딩한 후 다시 입력 계층으로 디코딩한다. 이렇게 재생성(reproduce)된 입력 계층의 값이 원래 입력된 학습 데이터와 최대한 일치되도록 첫 번째 계층의 가중치를 학습한다. 첫 번째 계층의 학습이 끝나면 학습된 첫 번째 계층의 가중치를 이용해 두 번째 가중치를 학습한다. 학습데이터를 입력한 후 layer 1의 가중치를 이용해 layer 1의 출력값을 계산한다. 이렇게 생성한 layer 1의 출력값을 학습 데이터로 사용하여 동일한 방법으로 layer 2를 학습한다. 이러한 방법으로 최하위 계층에서 시작해 점차 상위 계층으로 학습을 진행한다. 이 알고리즘은 신경망에 입력 데이터가 주어졌을 때 순방향 및 역방향 전파를 통해 동일한 데이터를 복원하도록 신경망의 가중치를 학습한다. 그 결과 학습된 신경망은 입력 데이터들의 정보를 최대한 보관해야 하기 때문에 입력 데이터로부터 중요한 특징을 추출하는 동작을 수행한다. 이와 같은 사전 학습 과정이 끝나면, 기존의 관리 학습(supervised learning) 알고리즘을 이용해 목표 하는 동작을 수행하도록 추가로 최적화 한다.




그림 3. Convolutional Neural Network의 구조

Deep learning 연구의 또 다른 중심인 CNN(convolutional neural networks)은 사람이나 동물의 시각 처리 과정을 모방하기 위해 개발된 신경망이다. CNN의 주요 개념 및 네트워크 구조는 1980년에 제안된 Neocognitron에서 제안되었다[10]. 그 후, 1990년대 후반 LeCun이 경사도 기반 학습 알고리즘을 CNN 성공적으로 적용함으로써 다양한 영상 인식 분야에 널리 적용되었다[3].

CNN의 구조는 <그림 3>과 같다. CNN은 세 가지 종류의 계층으로 이루어진다. CNN의 중하위 계층은 convolution 계층과 max-pooling 계층으로 구성된다. 이들은 특징을 추출하고 추상화하면서 점차로 높은 수준의 특징을 추출한다. CNN의 최상위 계층들은 fully-connected 계층으로 구성된다. 이들은 convolution 계층과 max-pooling 계층이 추출한 높은 수준의 특징으로부터 최종 결과를 계산한다. Convolution 계층과 max-pooling 계층은 복수의 특징맵(feature map)으로 구성된다. 각 특징맵은 다수의 노드들이 2차원적으로 배열된 구조를 갖는다.

Convolution 계층의 특징맵은 복수의 입력 특징맵과 연결된다. 특징맵의 노드들은 연결된 하위 계층 특징맵 중 특정한 위치의 윈도우 내의 노드들과 연결된다. 이 때 동일한 특징맵의 노드들은 동일한 가중치를 공유하는데, 이는 2차원 영상 처리 및 특징 추출에 많이 사용되는 컨볼루션과 동일한 효과를 갖는다. 여기에서 가중치는 컨볼루션 마스크의 역할을 수행하는데, 기존 컨볼루션 알고리즘이 고정된 마스크를 이용한 반면 CNN에서는 컨볼루션 마스크가 신경망 가중치로 구현되기 때문에 데이터로부터 자동으로 학습된다.

Max-pooling 계층은 하위 계층에 위치한 convolution 계층과 동일한 수의 특징맵을 가지며 각 특징맵은 입력 특징맵과 1:1로 연결된다. Max-pooling 계층의 각 노드들 역시 연결된

입력 특징맵 중 특정좌표에 위치한 윈도우내의 입력 노드들과 연결된다. Max-pooling 노드들의 동작은 매우 단순하다. 자신과 연결된 입력 노드들의 값 중 최대값을 선택해서 자신의 값으로 가져온다. Max-pooling의 동작은 매우 단순하나, 영상 인식에 있어서 매우 중요한 두 가지 역할을 담당한다. 첫째는 각 특징이 추출되는 위치상의 변이를 흡수하는 것이다. Max-pooling node들은 윈도우 내의 특징값 중 최대값을 취하지만, 그 좌표는 무시한다. 그 결과 특징의 위치가 윈도우 내에서 변할 경우 출력값에 아무 영향을 받지 않기 때문에 특징값은 보존하되 작은 위치 변이는 흡수하는 역할을 한다. 또한 max-pooling 계층은 입력 특징맵을 그보다 작은 크기의 특징맵으로 매핑하는데, CNN에 여러 개의 max-pooling 계층이 있다면 이들을 지나는 동안 특징맵의 크기가 빠르게 감소하여 적은 수의 계층으로도 큰 영상을 인식할 수 있게 한다.

CNN의 최상단에는 fully-connected 계층이 위치하는데, 이들은 하위 계층에서 추출한 높은 수준의 특징으로부터 최종 인식 결과를 결정한다. Fully-connected 계층의 각 노드들은 하위 계층의 모든 노드들과 연결된다.

CNN은 기존 오류 역전파 알고리즘과 동일한 원리의 경사도 기반 방법에 의해 학습될 수 있다. CNN의 중하위 계층을 이루는 convolution 계층과 max-pooling 계층의 노드들은 매우 제한된 수의 입력 노드들과 연결된다. 따라서, 계층간 연결이 많은 신경망에 비해 오차 신호가 섞여서 상쇄되는 문제가 훨씬 적게 발생한다. 또한 CNN은 특징 추출에 매우 효과적인 convolution 계층과 위치 변이 흡수에 효과적인 max-pooling 계층을 통해 높은 수준의 특징을 추출하기 때문에 다양한 변이에도 잘 적응한다. 그 결과, CNN은 다양한 영상 인식 분야에 적용되어 매우 높은 성능을 보이고 있다.

IV. Deep learning의 성공적 응용사례

Deep learning은 다양한 패턴 인식 문제에 적용되어 매우 높은 성능을 나타내었다. 필기숫자인식에 있어서는 가장 널리 사용되는 MNIST 데이터에 대하여 0.23%의 오류율을 보였다[11]. 수 년 전까지 성능이 좋다고 평가되었던 SVM의 최저 오류율이 0.56%였던 것과 비교하면 deep learning을 통해 성취한 오류율은 매우 낮은 수준이다[11]. Deep learning은 중국어 인식에도 매우 높은 성능을 보이고 있다. 최근까지 중국어 인식에는 mQDF(modified quadratic discriminant function)이 가장 널리 사용되었다. 그러나, 2011년도 ICDAR(International conference on document analysis and recognition)에서

개최된 컨테스트에서 CASIA(Chinese Academy of Science, Institute of Automation) 데이터에 대해 CNN을 사용한 시스템이 가장 높은 성능을 보였다[12]. 이 같은 트렌드는 2013년에도 이어졌는데, CNN은 최고 94.77%의 인식률을 보여 기존 방법으로 얻은 가장 높은 인식률 92.64%를 크게 상회하였다[13].

또한 가장 큰 규모의 물체 인식 컨테스트인 ImageNet large Scale Visual Recognition Challenge 2013에서는 1위 뿐 아니라 대부분의 상위 랭커들이 CNN에 기반을 둔 방법을 사용하였다[14]. 얼굴인식 분야에서도 CNN은 기존의 최고 기록을 갱신하였다. 얼굴인식에서 널리 사용되는 LFW (labeled faces in the wild) 데이터에 대하여 기존 최고 성능이 96.33%였으나, 2014년 CNN을 적용한 시스템이 97.35%로 더 높은 성능을 보였다[15]. Deep learning은 음성인식 분야에서도 높은 성능을 제공하였다. 기존에 널리 사용되는 방법은 HMM(hidden Markov Model)과 GMM(Gaussian mixture model)을 결합한 continuous HMM이었다. 그러나, GMM대신 DBN을 HMM과 결합함으로써 기존 방법보다 더 높은 성능을 얻었다[16].

필기한글 인식에서도 CNN은 높은 성능을 나타내었다. 가장 널리 사용되는 필기한글 데이터는 SERI95a와 PE92이다. 2000년대 초반까지 구조적 방법이 높은 성능을 보였고, 2011년도에 이르러서는 통계적 방법도 유사한 성능을 나타내었다. 기존 방법에 의한 최고 인식률은 SERI95a에 대하여 93.71%, PE92에 대하여 87.7%에 머물렀었다. 그러나, 최근 CNN을 필기한글에 적용하였을 때 SERI95a에 대하여 95.96%, PE92에 대하여 92.92%의 성능을 나타내었다[17]. 이는 기존 최고 성과와 비교하여 35.71%, 42.44%의 상대적 오류 감소율에 해당한다.

V. 결론

수 년 전부터 깊은 신경망을 학습할 수 있는 알고리즘이 개발된 이후 deep learning 연구는 매우 빠른 속도로 발전하고 있다. Deep learning은 다양한 응용 분야에 적용되어 우수한 성능을 보임으로써 최근 각광받고 있는 기계학습의 핵심 방법론이 되었다. 문자인식, 물체인식, 음성인식 등 다양한 분야에서 기존 최고 성능을 능가하는 우수한 결과를 보였으며, 그로 인해 더 많은 연구자들의 주목을 받고 있다. 뿐만 아니라, deep learning 분야에는 매우 많은 연구자들이 다양한 연구를 수행하면서 지속적으로 그 성능을 개선하고 있어서 향후 더욱 큰 발전이 기대된다.

참고 문헌

- [1] Y. Bengio, Learning deep architectures for AI, Foundations and Trends in Machine Learning, vol. 2, iss. 1, pp. 1-127, 2009.
- [2] G. E. Hinton, S. Osindero, Y. Teh, A fast learning algorithm for deep belief nets, Neural Computation vol. 18, no. 7, pp. 1527-1554, 2006.
- [3] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, Gradient-based learning applied to document recognition, Proceedings of the IEEE, vol. 86, no. 11, pp. 2278-2324, 1998.
- [4] http://en.wikipedia.org/wiki/Multilayer_perceptron
- [5] <https://developer.nvidia.com/cuda-zone>
- [6] <http://en.wikipedia.org/wiki/Backpropagation>
- [7] P. Vincent, H. Larochelle, Y. Bengio, and P.-A. Manzagol, Extracting and composing robust features with denoising autoencoders, in Proceedings of the Twenty-fifth International Conference on Machine Learning (ICML'08), (W. W. Cohen, A. McCallum, and S. T. Roweis, eds.), pp. 1096-1103, ACM, 2008.
- [8] D. C. Cireşan, U. Meier, J. Schmidhuber, Multi-column Deep Neural Networks for Image Classification, IEEE Conf. on Computer Vision and Pattern Recognition 2012.
- [9] D. C. Cireşan and J. Schmidhuber, Multi-column Deep Neural Networks for Offline Handwritten Chinese Character Classification, IDSIA Technical Report No. IDSIA-05-13, 2013.
- [10] K. Fukushima, Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, Biological Cybernetics, vol. 36, no. 4, pp. 193-202, 1980.
- [11] <http://yann.lecun.com/exdb/mnist>
- [12] Cheng-Lin Liu, Fei Yin, Qiu-Feng Wang, Da-Han Wang, ICDAR 2011 Chinese Handwriting Recognition Competition, 2011. (<http://www.nlpr.ia.ac.cn/events/HRcompetition/Report.html>)
- [13] Fei Yin, Qiu-Feng Wang, Xu-Yao Zhang, Cheng-Lin Liu, ICDAR 2013 Chinese Handwriting Recognition Competition, 2011. (<http://www.nlpr.ia.ac.cn/events/HRcompetition/Report.html>)

ia.ac.cn/events/CHRcompetition2013/competition/Report.html)

- [14] <http://www.image-net.org/challenges/LSVRC/2014/results>
- [15] Yaniv Taigman, Ming Yang, Marc'Aurelio Ranzato, Lior Wolf, DeepFace: Closing the Gap to Human-Level Performance in Face Verification, CVPR2013.
- [16] Hinton, Geoffrey, et al. "Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups." Signal Processing Magazine, IEEE 29,6 (2012): 82-97.
- [17] In-Jung Kim, Xiaohui Xie, Handwritten Hangeul recognition using deep convolutional neural networks, International Journal on Document Analysis and Recognition (IJ DAR) Sep. 2014. (<http://link.springer.com/article/10.1007/s10032-014-0229-4>)

약 력



김 인 중

1994년 KAIST 공학사
 1995년 KAIST 공학석사
 2001년 KAIST 공학박사
 2001년~2006년 (주)인지소프트 책임연구원
 (Mobile Reader 팀장)
 2006년~현재 한동대학교 전산전자공학부 조교수
 2011년~2013년 U.C. Irvine Visiting Scholar
 관심분야: deep learning, machine learning,
 pattern recognition, document recognition,
 computer vision, mobile programming