

소 부류 객체 분류를 위한 CNN기반 학습망 설계

임수창¹ · 김승현² · 김연호² · 김도연^{3*}

Training Network Design Based on Convolution Neural Network for Object Classification in few class problem

Su-chang Lim¹ · Seung-Hyun Kim² · Yeon-Ho Kim² · Do-yeon Kim^{3*}

^{1,2}Department of Computer Science, Suncheon National University, Suncheon 57922, Korea

^{3*}Department of Computer Engineering, Suncheon National University, Suncheon 57922, Korea

요 약

최근 데이터의 지능적 처리 및 정확도 향상을 위해 딥러닝 기술이 응용되고 있다. 이 기술은 다층의 데이터 처리 레이어들로 구성된 계산 모델을 통해 이루어지는데, 이 모델은 여러 수준의 추상화를 거쳐 데이터의 표현을 학습한다. 딥러닝의 한 부류인 컨볼루션 신경망은 인간 행동 추정, 얼굴 인식, 이미지 분류, 음성 인식 같은 연구 분야에서 많이 활용되고 있다. 이미지 분류에 좋은 성능을 보여주는 컨볼루션 신경망은 깊은 학습망과 많은 부류를 이용하면 효과적으로 분류율을 높일수 있지만, 적은 부류의 데이터를 사용할 경우, 과적합 문제가 발생할 확률이 높아진다. 따라서 본 논문에서는 컨볼루션 신경망기반의 소부류의 분류를 위한 학습망을 제작하여 자체적으로 구축한 이미지 DB를 학습시키고, 객체를 분류하는 연구를 실험 하였으며, 1000개의 부류를 분류하기 위해 제작된 기존 공개된 망들과 비교 실험을 통해 기존 망보다 평균 7.06% 이상의 상승된 분류율을 보여주었다.

ABSTRACT

Recently, deep learning is used for intelligent processing and accuracy improvement of data. It is formed calculation model composed of multi data processing layer that train the data representation through an abstraction of the various levels. A category of deep learning, convolution neural network is utilized in various research fields, which are human pose estimation, face recognition, image classification, speech recognition. When using the deep layer and lots of class, CNN that show a good performance on image classification obtain higher classification rate but occur the overfitting problem, when using a few data. So, we design the training network based on convolution neural network and trained our image data set for object classification in few class problem. The experiment show the higher classification rate of 7.06% in average than the previous networks designed to classify the object in 1000 class problem.

키워드 : 딥러닝, 신경망, 객체 분류, 컨볼루션신경망

Key word : Deep learning, Neural Network, Object Classification, Convolution Neural Network

Received 02 August 2016, Revised 04 August 2016, Accepted 09 August 2016

* Corresponding Author Do-Yeon Kim(E-mail:dykim@sunchon.ac.kr, Tel:+82-61-750-3628)

Department of Computer Engineering, Suncheon National University, Suncheon 57922, Korea

Open Access <http://doi.org/10.6109/jkice.2017.21.1.144>

print ISSN: 2234-4772 online ISSN: 2288-4165

©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.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

최근 다양한 분야에서 데이터의 지능적 처리 및 정확도 개선을 위해 딥 러닝 기술을 응용하고 있다. 딥 러닝은 다층의 데이터 처리 레이어들로 구성된 계산 모델을 통해 이루어지는데, 이 모델은 여러 수준의 추상화를 거쳐 데이터의 표현(representation)을 학습한다[1].

컨볼루션 신경망(Convolutional Neural Networks)은 딥 러닝을 위한 심층 신경망(Deep Neural Networks) 모델의 한 종류이다. 얼굴 인식(face recognition), 이미지 분류(image classification), 음성 인식(voice recognition)과 같은 연구 분야에서 많이 활용되며[2], 최근에는 1000개의 부류를 분류하며 성능을 검증하는 대회인 ILSVRC(ImageNet Large Scale visual Recognition Challenge)[3]를 통해 높은 성능의 분류 및 탐지 능력이 가진 네트워크들이 소개되고 있다. 대표적 네트워크인 AlexNet[4], GoogleNet[5], VGGNet[6]은 컨볼루션 신경망을 이용해, 이 대회에서 우수한 결과를 보여주었으며, 깊은 레이어 구성을 통해 수백 개의 클래스를 높은 정확도로 분류해 냈다. 그러나 이러한 네트워크가 모든 분류 문제에 적합한 것은 아니다.

과적합(overfitting)은 신경망 학습에 사용된 데이터는 잘 분류하지만 새로운 패턴의 데이터는 잘 분류해내지 못하는 현상을 의미한다. 원인으로서는 지나친 학습(overtraining)이나 튜닝, 학습 데이터 부족 또는 데이터 셋 클래스 범주의 잘못된 설정 등이 있다. 특히, 데이터 셋 클래스 범주 설정 문제는 상기에서 기술한 네트워크들을 특수한 분류 문제에 적용시킬 때 많이 발생한다. ILSVRC에서 사용된 클래스 범주보다 적은 경우가 더 많기 때문이다. 과적합이 발생했는지의 여부는 학습 과정에서 출력되는 학습 오차(training error)와 테스트 오차(test error)값을 그래프 형태로 변환시켜 확인 할 수 있다. 테스트 오차 값이 학습 오차 값과 상당히 떨어진 경우 과적합이 발생한 것으로 판단할 수 있다.

본 논문에서는 기존 침입자를 판별하기 위해 침입탐지 시스템의 판별 성능을 높여주기 위하여 딥 러닝(Deep Learning)의 부류인 컨볼루션 신경망(CNN)을 기반으로 사람, 개, 고양이의 소 부류 이미지 데이터 DB를 자체적으로 구축한 후, 해당 부류를 효과적으로 분류하기 위해 최적의 하이퍼 파라미터(hyper parameter)를 찾아 모델링한 Network를 제작한 후 학습을 통해, 분류에 최적의

성능을 보여주는 네트워크를 제안한다.

본 논문의 구성은 다음과 같다. 2장에서는 학습 알고리즘을 이용하여 분류를 하는 기존의 연구를, 3장은 제안하는 학습 Network를 제작하는 방법을 제시하며, 4장에서는 실험의 결과, 5장은 결론에 대해 기술한다.

II. 관련 연구

2.1. 기존 기계학습 기반의 분류기

기계학습 기반의 분류기는 학습데이터에서 추출된 특징값들을 학습 알고리즘을 이용하여 학습시킨 후 새로운 데이터에 대해 예측을 진행 하는 것이다. 기계학습 알고리즘은 사용되는 목적에 따라 여러 알고리즘이 존재한다. 분류 목적에서 대표적인 알고리즘은 SVM(Support Vector Machine)[7]과 여러 형태의 학습 알고리즘에서 분류된 결과물에 가중치를 두어 강한 특징을 선택하는 AdaBoost(Adaptive boosting)[8] 등이 있다. 하지만 기계학습 알고리즘은 스스로 특징을 추출하며 학습하는 CNN과 달리 학습 데이터들에 다양한 특징을 추출하기 위한 최적의 모델을 결정하는 것은 어렵다.

2.2. CNN(Convolution Neural Network)

Convolution은 특정 필터를 이용해, 입력된 이미지에서 적절한 특징(feature)을 추출하기 위해 사용되는 방법으로, 이런 방법이 적용된 모델이 CNN(Convolution Neural Network)이다. CNN은 사람의 시각 피질의 원리에서 영감을 받아 설계된 모델로서, LeCun[9]은 해당 방법을 필기체 인식에 적용하여 좋은 성능을 보여주었다. 하지만 CNN은 깊은 은닉층과 수많은 뉴런, 방대한 학습 샘플을 요구하기 때문에 학습에 많은 연산이 요구되고 시간이 오래 걸린다. 하지만 GPU의 발달로 인해, 이런 문제점은 해결이 되었고, 마찬가지로 높은 하드웨어의 성능으로 인해 거대한 네트워크도 제작이 가능하여 학습에 좋은 성능을 보여주고 있다. 최근 ILSVRC에서 1000개의 대량의 부류에 대해 CNN을 이용한 방법들이 우수한 분류성능을 보여주었다. 2012년에는 AlexNet이 CNN과 GPGPU를 이용하여 분류율에서 큰 성능을 보이며 우승을 하였고, 2013년에는 GoogleNet과 VGGNet이 우수한 성능을 보여주었다. 두 학습망의 차이점은 다음과 같다. 우승팀인 GoogleNet의 경우 기

존 AlexNet과 달리 인셉션이라는 모듈을 이용해서 네트워크를 제작하였다. 하지만 GoogleNet의 구조는 깊고 복잡하다. 하지만 에러율에서 근소한 차이로 2위를 한 VGGNet의 경우 3x3커널만을 이용해서 네트워크를 제작하였기 때문에, GoogleNet에 비해 구조적인 측면에서 훨씬 간단한 구조로 되어있다. 따라서 쉽게 CNN의 구조를 변경할 수 있다는 장점이 있다.

는 전 단의 레이어에서 적용된 커널사이즈에 따라 결정된다. 분류단에 속한 풀리 커넥티드 레이어는 MLP라고 불리우며, 각각 레이어에 속한 노드들은 서로서로 연결되어 있으며, 가장 많은 파라미터와 연산량을 가지고 있다. 이러한 형태로 구성되는 CNN은 마지막 레이어부터 초기 레이어까지 역전파(back propagation)하며 학습율에 따라 오차를 줄여주기 위해 각 레이어의 파라미터를 학습시킨다.

III. 제안하는 CNN기반 학습 Network

3.1. 기본적인 CNN의 구성

그림 1과 같이 CNN의 기본적인 구조는 컨볼루션 레이어(convolution Layer)와 풀링 레이어(pooling Layer), 풀리 커넥티드 레이어(Fully-Connected Layer)로 구성 되어 있다. 각각 레이어의 역할은 다음과 같다.

컨볼루션 레이어와 풀링 레이어는 입력된 이미지 데이터에서 특징을 추출하는 레이어고, 풀리 커넥티드 레이어는 추출된 특징들을 이용하여 분류를 하는 레이어다. 특징 추출단에 속한 컨볼루션 레이어는 정의된 커널사이즈의 필터를 cross-correlation 연산을 입력 이미지에 적용해서 이미지의 특징들을 추출하고, 풀링 레이어는 입력 이미지의 크기를 절반으로 줄여줌과 동시에 강한 특징 값을 추출한다. 이러한 역할을 가진 컨볼루션과 풀링 레이어들이 반복된 형태로 네트워크는 구성 되어있는데, 입력 이미지는 레이어를 거치면서 컨볼루션과 풀링 연산이 적용되며 강한 특징들로 구성된 특징 맵(feature Map)을 뽑아낸다. 각각의 특징 맵의 사이즈

3.2. 제안하는 CNN 네트워크

본 논문에서 제안하는 신경망은 VGGNet을 기반으로 설계하였다. 아직까지 분류 결과에 좋은 영향을 주는 최적의 하이퍼 파라미터 값은 정립되어 있지 않기 때문에 최적의 네트워크 설계를 위하여 레이어들의 순서, 컨볼루션 레이어의 커널 개수, 사이즈 그리고 스트라이드 값을 변경하며 반복 학습을 통해 가장 좋은 결과를 보여주는 네트워크를 제작 하였다. 제안한 소 부류의 데이터를 분류하기 위한 최적의 네트워크의 구성은 그림 2와 같이, 6개의 컨볼루션 레이어와 3개의 풀리 커넥티드 레이어로 구성되어있다. 이미지는 다층의 컨볼루션 레이어를 거치며 cross-correlation 연산이 적용되고, 가중치 공유 특성을 통해, 같은 형태의 특징맵, 가중치 벡터, 바이어스(bias)를 공유한다. 이러한 컨볼루션 레이어의 특성으로 인하여 이동, 왜곡, 회전등에 불변한 특징 맵이 추출된다. 제안하는 신경망의 상세 구조는 다음과 같다.

첫 번째 컨볼루션 레이어 Conv1_1은 입력되는 이미지가 크기 때문에 커널사이즈: 7x7, stride : 4, pad : 3의

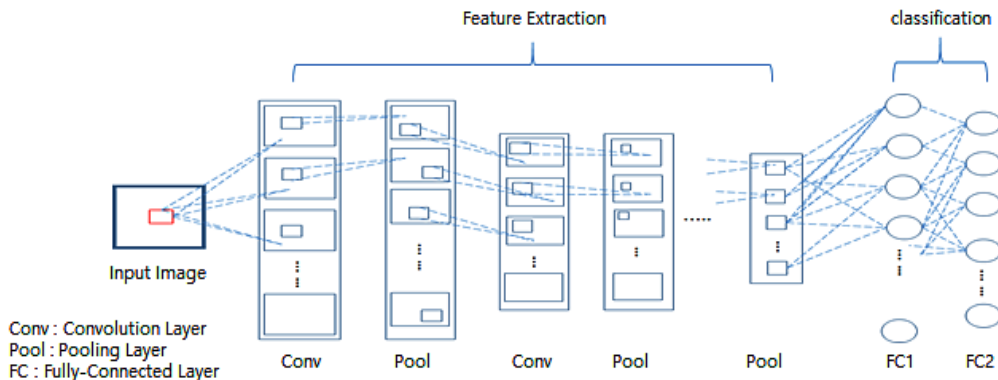


Fig. 1 Base Architecture of Convolution neural network

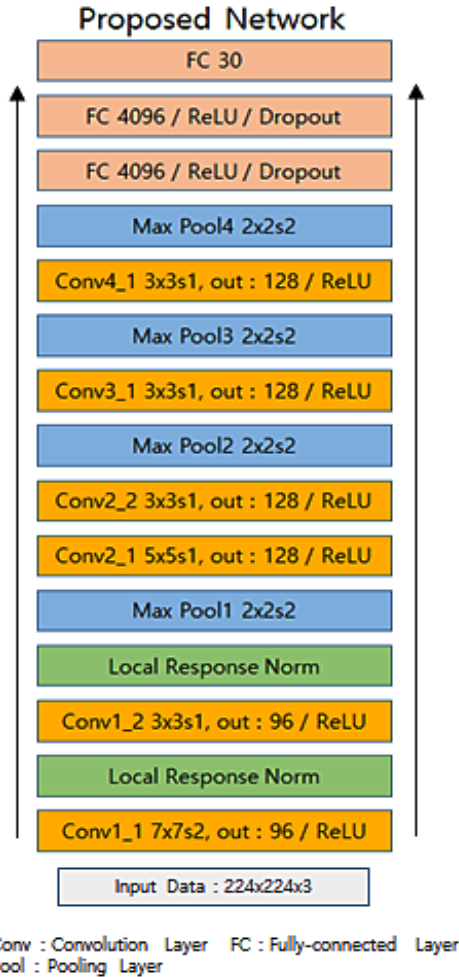


Fig. 2 Proposed full architecture of our convolution neural network

값을 적용하여 사이즈가 절반으로 줄어든 96개의 특징 맵을 출력한다. 이어서 Rectified Linear Unit(ReLU)활성 함수를 사용하였으며, 뒤이어 출력된 특징 맵에서 약한 특징이 연산에 적용되지 않고 강한 특징이 전달될 수 있도록 LRN(local respond normalization)[4]을 사용하였다. 두 번째 컨볼루션 레이어 Conv1_2는 3x3사이즈의 커널을 이용해서 이미지의 크기 변동없이 특징을 추출하여 96개의 특징 맵을 출력하고, 뒤이어 ReLU활성 함수를 사용하였으며, 첫 번째 컨볼루션 레이어와 마찬가지로 LRN을 사용하였다.

출력된 특징 맵은 112x112사이즈로 아직 해상도가 높

기 때문에, 풀링 레이어에서 서브 샘플링을 통해 사이즈를 줄여야 하는데, 최소값 풀링, 평균 풀링, 최대값 풀링 중 맥스 풀링을 사용하였고, 2x2사이즈의 커널을 이용해 최대값을 가진 특징을 추출하고 이미지의 사이즈를 절반으로 줄여준다.

Conv2_1과 Conv2_2는 3x3 사이즈의 커널과 ReLU활성 함수로 연속되게 제작하였으며, 더 강한 특징을 추출하기 위해 출력되는 특징 맵은 128개로 증감시켰다. 이어서 풀링 레이어를 통해 이미지의 사이즈를 절반으로 줄여준다. 뒤이어 연속되는 컨볼루션 레이어는 모두 커널 사이즈가 3x3으로 고정되어 있으며, 출력되는 모든 특징 맵은 128개로 고정되어있다.

첫 번째 풀리 컨넥티드 레이어는 Conv4_1의 출력 결과를 받아들이고 4096의 뉴런을 포함한다. 뒤이어 ReLU와 학습과정에서 오버피팅(over fitting)을 줄이기 위해 일부의 뉴런을 생략하며 학습을 진행하는 Dropout 레이어를 포함한다. 최종단의 레이어는 30개의 클래스에서 결과를 낼 수 있도록 Softmax함수를 사용하였다.

IV. 실험 및 결과

4.1. 실험 샘플 구성

본 논문에서는 흔히 주변에서 볼 수 있는 사람, 개, 고양이 영상을 분류하기 위한 목적으로 3가지 부류를 training 데이터로 구축하였다.

최초 학습 집합은 부류별 1만장씩 총 3만장으로 구축하였다. 실험에 사용한 학습 집합은 천만 장 이상의 이미지를 각 부류별로 모아놓은 ImageNet을 이용해서 구축하였으며, 사람 이미지는 자체적으로 촬영해서 획득한 데이터와 결합해서 구축 하였다. 검증 집합은 부류별 2500장씩 총 7500장을 사용해서 구축하였으며, 학습 집합과 중복되지 않도록 선별하였다. 하지만 학습 결과물을 이용해 테스트를 한 결과 오버 피팅이 발생하였고, 분류율은 30% 미만으로 출력되었다.

따라서, 분류율을 올리고 오버피팅을 줄여주기 위해 학습 집합을 세분화하였다. 다시 구축한 학습 집합은 총 30개의 클래스로 0~9번 클래스는 사람, 10~19번 클래스는 개, 20~29번 클래스는 고양이로 나눠 주었다. 학습 집합이 부족한 경우 이미지를 증감시켜주기 위해서 5°, 10°, 35°, 35° 로 어파인 변환을 시켜주었고, 각 이미

지에 가우시안 잡음 추가 및 명암, 채도를 변경시켜 학습 집합을 구축하였다. 각 클래스의 학습 집합은 2,000장씩 총 60,000장으로 구축하였고, 검증 집합은 500장씩 총 15,000장으로 구축하였다.

4.2. 제안하는 CNN 모델 실험

본 논문에서 제안한 네트워크를 실험하기 위한 환경은 표1과 같다. 네트워크를 학습할 때, 한 장의 이미지를 학습할 때 필요한 메모리 양과 입력된 배치 사이즈(batch_size)에 따라 필요한 그래픽 카드의 메모리가 달라진다. 배치사이즈를 줄여 학습을 진행 하게 될 경우, 사용되는 메모리는 적지만 과적합 상태에 빠질 수 있다. 따라서 사용된 그래픽 카드는 12GB의 용량을 가진 Titan X를 사용하였다. 사용된 딥러닝 프레임 워크는 공개된 소스인 caffe[10]를 사용하였다.

Table. 1 Experimental environments.

CPU/RAM	Intel Xeon 3.3Ghz / 32GB
GPU	NVIDIA GTX Titan X 12GB
framework	caffe

네트워크 모델을 학습하는데 고려할 점은 학습에 영향을 주는 파라미터 값의 설정이다. 본 논문에서는 파라미터 설정을 위해 GoogleNet[5]과 비슷한 설정 값을 사용한다. 초기 학습율의 값이 클 경우 발산을 하는 대신 학습 속도가 빨라진다. 반대로 값이 작을 경우 수렴은 느려진다. 따라서 0.01을 초기값으로 주고, 일정 구간마다 학습율을 감소하도록 하였다.

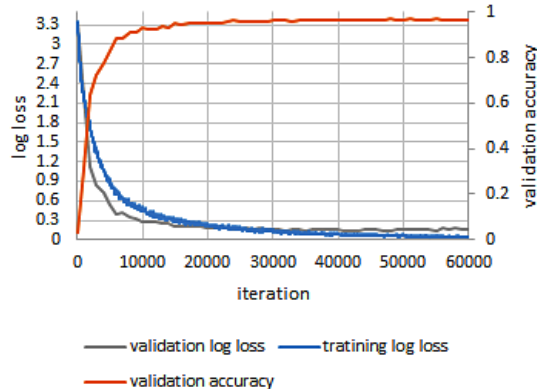


Fig. 3 Graph of Training own Network

깊은 네트워크 모델을 학습하는 경우 경사 하강법(Gradient descent)을 이용해 최적값을 찾아가는 경우가 발산하거나 지역 최솟점에 빠지는 현상이 발생한다. 따라서 이런 문제를 방지하도록 weight_decay와 momentum은 0.0002, 0.9로 설정하였다. 그림 3은 제안한 네트워크가 학습 횟수(iteration)에 따라 변하는 accuracy와 loss값을 보여주고 있다.

4.3. 실험 결과

3개 부류(사람, 개, 고양이)를 분류하기 위해 제안한 네트워크를 이용해 학습을 진행하였다. 전체 학습은 60,000을 반복하였으며, 10시간의 시간이 소요되었다. 5,000번의 학습 횟수마다 스냅샷을 통해 분류 결과를 획득 하였다. 제안한 네트워크의 분류율을 평가하기 위해 사람, 개, 고양이 클래스별 500장 씩, 총 1,500장의 테스트 이미지를 구축하였다.

그림 4와 같이 테스트 이미지를 입력한 후, 0~9(사람), 10~19(개), 20~29(고양이) 영역에 출력되는 각각의 확률 값들을 덧셈하여 가장 높은 확률을 가진 영역을 출력되는 부류로 결정한다.

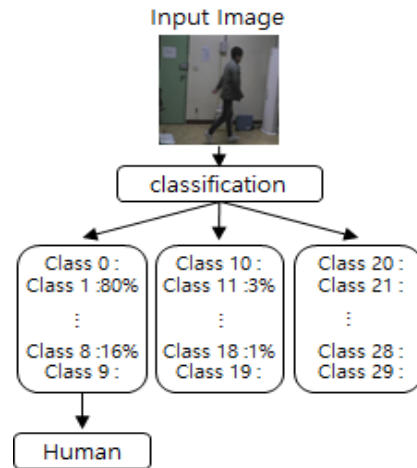


Fig. 4 Method of classification

제안한 네트워크와 기존의 공개된 네트워크와 비교를 위해 같은 학습 집합, 검증 집합, 테스트 집합을 이용해 실험을 진행 하였고, 표 2는 분류 결과를 보여준다.

AlexNet, GoogleNet 그리고 VGGNet의 사람 분류율은 90% 이상으로 비슷한 결과를 보여주었다. 하지만 개

분류율에서는 GoogleNet이 84%로 가장 높았으며, 고양이 분류율에서는 대부분 80%를 넘지 못하였다.

Table. 2 Result of classification

Network	classification probability		
	Human	Dog	Cat
AlexNet	92.6%	77.2%	71.2%
GoogleNet	93.4%	84.6%	75.4%
VGGNet	91.8%	82.8%	77.6%
proposed Net	96.8%	90.8%	89.2%

제안한 네트워크는 iteration 40,000번째에서 Google Net보다 약 3.4% 상승한 96.8%의 사람 분류율을 보여주었으며, 개, 고양이 분류율에서는 각각 6.2%, 11.6%의 상승된 분류율을 보여주었다.

사람을 포함하고 있기 때문에, 출력되는 특징들이 중첩되어 다른 부류로 분류되었다. 그림 5(b)의 경우, 좌측의 이미지는 고양이 부류와 비슷한 형태를 가졌기 때문에 고양이로 분류 되었다고 추정할 수 있으며, 우측의 이미지의 경우 개보다 사람 부류에서 특징을 더 많이 추출하여 사람으로 오 분류 한 것으로 추정 할 수 있었다. 그림 5(c)의 경우도 (b)와 유사한 형태로 구성 되어 있기 때문에 고양이로 분류 하지 않고 각각 개와 사람으로 분류 되었다.

V. 결론

본 논문에서는 CNN을 이용해 소 부류를 분류하기 위한 네트워크를 제안하였으며, 실험을 통해 소부류에 최적의 네트워크와 파라미터 값을 찾았고, 기존 공개된 네트워크와 비교하여 더 효과적인 성능을 보여주었다. 제안된 네트워크를 통해 학습된 결과물은 추후 감시 시스템에서 움직이는 객체중 사람 객체만 분류하여 추적할 목적으로 사용이 가능하다. 또한 기존 학습 집합에 다양한 이미지를 추가함으로써, 다양한 분야에 적용 가능할 것이다.



Fig. 5 Example of incorrect classification

그림 5는 잘못 분류된 입력 이미지를 보여주고 있다. 그림 5(a)의 경우 학습에 사용된 사람DB보다 더 많은

ACKNOWLEDGMENTS

This work was supported by the Nuclear Safety Research Program through the Korea Foundation Of Nuclear Safety (KOFONS), granted financial resource from the Nuclear Safety and Security Commission (NSSC), Republic of Korea (No.1403025)

REFERENCES

- [1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no.7553, pp. 436-444, May 2015.
- [2] M. D. Zeiler, and R. Fergus, "Visualizing and understanding convolutional networks," in *Proceedings of the 13th European Conference on Computer Vision*, Zurich: CH, pp. 818-833, 2014.

- [3] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, and A.C. Berg, "ImageNet large scale visual recognition challenge," *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211-252, Dec. 2015.
- [4] K. Alex, S. Ilya, and H. Geoffrey, "ImageNet classification with deep convolutional neural networks," in *Proceedings of Advances in Neural Information Processing System*, Nevada: NV, pp. 1097-1105, 2012.
- [5] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Boston: MA, pp. 1-9, 2015.
- [6] S. Karen and Z. Andrew, "Very deep convolutional networks for large-scale image recognition," arXiv preprint arXiv:1409.1556, 2014.
- [7] J.A.K. Suykens, and J. Vandewalle, "Least squares support vector machine classifiers," *Neural processing letters* 9, no.3, pp.293-300, 1999.
- [8] R. Gunnar, T. Onoda, and K. Müller, "Soft margins for adaBoost," *Machine learning*, vol. 42, no. 3, pp.287-320. 2001.
- [9] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the Institute of Electrical and Electronics Engineers*, vol. 86, no.11, pp.2278-2324, 1998.
- [10] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, and T. Darrell, "Caffe: An open source convolutional architecture for fast feature embedding," in *Proceedings of the 22nd ACM international conference on Multimedia*, pp.675-678, 2014.



임수창(Su-Chang Lim)

2015년 순천대학교 컴퓨터공학과(공학사)
2015년 ~ 현재 순천대학교 컴퓨터공학과 석사과정
※관심분야: 영상처리, 컴퓨터비전, 기계학습



김승현(Seung-Hyun Kim)

2014년 순천대학교 컴퓨터공학과(공학사)
2016년 순천대학교 대학원 컴퓨터공학과 졸업(공학석사)
2016년 ~ 현재 순천대학교 컴퓨터비전 및 보안 실험실 참여 연구원
※관심분야: 기계학습, 빅데이터



김연호(Yeon-Ho Kim)

2016년 순천대학교 컴퓨터공학과(공학사)
2016년 ~ 현재 순천대학교 컴퓨터공학과 석사과정
※관심분야: 컴퓨터비전, 기계학습



김도연(Do-Yeon Kim)

1986년 충남대학교 계산통계학과 졸업(이학사)
2000년 충남대학교 대학원 정보통신공학과 졸업(공학석사)
2003년 충남대학교 대학원 컴퓨터공학과 졸업(공학박사)
1986년 ~ 1996 한국원자력연구원 선임연구원
1997년 ~ 2008 한국전력기술(주) 책임연구원
2008년 ~ 현재 순천대학교 컴퓨터공학과 교수
※관심분야: 컴퓨터비전, 컴퓨터보안