

딥뉴럴네트워크 기반의 흡연 탐지기법 설계*

이 상 현*, 윤 현 수**, 권 현***

요 약

컴퓨팅 기술의 발전과 데이터를 저장할 수 있는 클라우드 환경, 그리고 스마트폰의 보급으로 인하여 많은 데이터가 생산되는 환경에서 인공지능 기술이 발전되고 있다. 이러한 인공지능 기술 중에서 딥뉴럴네트워크는 이미지 인식, 이미지 분류 등에서 탁월한 성능을 제공하고 있다. 기존에는 이러한 딥뉴럴네트워크를 이용하여 산불 및 화재 예방을 위한 이미지 탐지에 대해 많은 연구가 있었지만 흡연 탐지에 대한 연구는 미흡한 실정이었다. 한편 군 부대에서는 각종 시설에 대한 감시체계를 CCTV를 통해 구축하고 있는데 화재, 폭발사고 예방을 위해 단야고 주변에서의 흡연이나 금연구역에서의 흡연을 CCTV로 탐지하는 것이 필요한 상황이다. 본 논문에서는 딥뉴럴네트워크를 이용하여 흡연 여부를 탐지하는 방법에 대한 성능 분석을 하였으며 활성화함수, 학습률 등 실험적으로 최적화된 수치를 반영하여 흡연사진과 비흡연사진을 두 가지 경우로 탐지하는 것을 하였다. 실험 데이터로는 인터넷 상에 공개되어 있는 흡연 및 비흡연 사진을 크롤링하여 데이터를 구축하였으며, 실험은 머신러닝 라이브러리를 이용하였다. 실험결과로 학습률 0.004로 최적화 알고리즘 Adam을 사용하였을 때, 93%의 accuracy와 92%의 F1-score를 갖는 것을 볼 수 있었다. 또한 이로써 이미지의 연속인 CCTV 영상도 딥뉴럴네트워크를 이용하여 흡연 여부를 탐지할 수 있음을 알 수 있었다.

Design of detection method for smoking based on Deep Neural Network

Sanghyun Lee*, Hyunsoo Yoon**, Hyun Kwon***

ABSTRACT

Artificial intelligence technology is developing in an environment where a lot of data is produced due to the development of computing technology, a cloud environment that can store data, and the spread of personal mobile phones. Among these artificial intelligence technologies, the deep neural network provides excellent performance in image recognition and image classification. There have been many studies on image detection for forest fires and fire prevention using such a deep neural network, but studies on detection of cigarette smoking were insufficient. Meanwhile, military units are establishing surveillance systems for various facilities through CCTV, and it is necessary to detect smoking near ammunition stores or non-smoking areas to prevent fires and explosions. In this paper, by reflecting experimentally optimized numerical values such as activation function and learning rate, we did the detection of smoking pictures and non-smoking pictures in two cases. As experimental data, data was constructed by crawling using pictures of smoking and non-smoking published on the Internet, and a machine learning library was used. As a result of the experiment, when the learning rate is 0.004 and the optimization algorithm Adam is used, it can be seen that the accuracy of 93% and F1-score of 94% are obtained.

Key words : Smoking detection, Machine learning, Detection method, Neural network

접수일(2021년 01월 11일), 수정일(2021년 03월 12일),

계재확정일(2021년 03월 26일)

* 본 논문은 화랑대연구소의 2021년도(21-군학-5) 저술활동비 지원을 받아 연구되었음.

* 한국과학기술원 정보보호대학원 석사과정(주저자)

** 한국과학기술원 정보보호대학원 교수(공동저자)

*** 육군사관학교 전자공학과 조교수(교신저자)

1. 서 론

현대의 군부대는 부대 입구, 창고, 건물 내부 등 각종 시설에 대한 감시체계를 CCTV를 통해 구축하고 있다. 이를 통해 군은 감시 인력을 줄일 수 있고 기록된 영상을 필요시 다시 확인할 수 있게 되었다. 이외에도 군에서 CCTV를 유용하게 활용할 수 있는 부분은 금연구역에서의 흡연여부 확인이다. 군부대 내에는 각종 유류, 탄약, 수류탄 등 인화물질, 폭발물들이 다량 보유하고 있으며 이러한 것들을 저장하는 곳 주변에서의 흡연은 자칫 큰 사고로 이어질 수 있기에 흡연을 금지하고 있다. 한 예로 군에서는 초소 근무자가 상주하는 탄약고 지역, 화재위험이 높은 유류탱크 주변지에서의 흡연을 금지하고 있다.

한편으로 컴퓨팅기술과 빅데이터 및 클라우드 환경의 발전으로 인하여 인공지능에 대한 관심이 많아지고 있다. 군도 이러한 시대 흐름에 맞춰서 첨단 과학기술군의 도입을 위해 인공지능 기술을 다양한 분야에 접목하는 연구를 진행하고 있다[1]. 이러한 연구는 감시 장비 면에서 두드러지고 있으며 한 예로 군 감시 장비에 인공지능 기술을 적용하여 적군이나 아군과 관련된 인물 또는 장비를 탐지하는 것이 있다[2][3]. 이러한 인공지능 기술의 이미지 탐지 및 인식 부문에 있어서 딥뉴럴네트워크는 좋은 성능을 제공하고 있다. 딥뉴럴네트워크는 수많은 뉴런들이 여러 개의 층으로 구성되어 있는 사람의 뇌를 모방한 수학적 모델로써 많은 수의 학습데이터를 모델이 스스로 훈련하여 특정한 입력값이 들어올 때, 어떠한 수치를 예측하는 문제에 탁월한 성능을 보여주고 있다[4][5]. 또한 최근에는 기존의 컴퓨팅기술과 빅데이터 기반의 많은 학습데이터, 급격히 발전한 GPU 병렬연산 능력을 통해 더 뛰어난 성능을 제공하고 있다[6].

이 논문에서는 딥뉴럴네트워크를 이용하여 흡연을 탐지하는 기법에 대하여 연구를 하였다. 클래스를 두 개로 구분하여 흡연 탐지에 대한 정확도를 높이도록 딥뉴럴네트워크를 구성하였으며 이를 위한 여러 가지 파라미터 및 딥뉴럴네트워크에 대한 구조에 대한 연구를 하였다.

이 논문의 구성은 다음과 같다. 2장에서는 관련연구에 대한 내용을, 3장에서는 딥뉴럴네트워크에 대한

구조를 설명한다. 4장에서는 흡연 탐지 실험환경 및 실험결과를 논하였고 5장에서는 이 논문의 결론으로 마무리하였다.

2. 관련연구

흡연이미지 탐지 기반에 대해서 딥뉴럴네트워크 기술이 아닌 다른 방법에 의한 탐지 방법들이 있다. 먼저, Inoue et al. 연구진[7]은 subspace 이론을 이용하여 차원 공간을 낮게 하여 탐지하는 방법을 제안하였다. 이 방법은 특정 기준치를 넘으면 흡연으로 탐지하는 것을 기반으로 하였는데, 오탐지 비율이 높아서 성능이 다소 떨어지는 단점이 있었다. 두 번째로 Wu et al. 연구진[8]에 의하면 Gaussian mixture model를 통해서 백그라운드로부터 현재 프레임을 추출하여 흡연을 탐지하는 방법을 적용하였다. 이 방법에서는 얼굴, 담배, 손 모양 등을 이용하여 탐지하는 방법을 적용하였다. 세 번째로 Odetallah et al. 연구진[9]은 담배 연기에 켈러 특징을 이용해서 탐지하는 방법을 적용하였다. 이 방법은 RGB 값을 이용하여 전체 이미지 영역 중에 담배 형상과 관련된 이미지를 추출하여 탐지하는 방법을 적용하였다. 네 번째로 Bien et al. 연구진[10]은 흡연하는 사람의 행동으로 탐지하는 방법을 연구 하였다. 사람의 손 모양이나 팔 모양으로 흡연을 탐지를 하였으며 약 83.33% 확률의 탐지율을 보여주었다. 하지만 이러한 방법들은 보다 복잡한 각 특징의 추출들이 필요하고 시간이 어느 정도 소요되며 성능이 딥뉴럴네트워크에 비해서 좋지 못한 특징이 있다. 반면에 딥뉴럴네트워크 구조를 이용하여 연기에 대한 탐지로 산불 및 화재에 대한 탐지 기술은 많이 있지만 흡연을 탐지하는 방법에 대한 연구가 미흡한 실정이다. 따라서 이 논문에서는 흡연 탐지에 대한 방법을 딥뉴럴네트워크를 이용하여 최적의 파라미터를 실험적으로 설정하였고 흡연 탐지에 대하여 다각적으로 분석하였다.

이 논문의 공헌점은 다음과 같다. 먼저, 딥뉴럴네트워크에 대한 구조를 분석하고 최적의 파라미터를 설정하는 연구를 하였다. 두 번째로, 탐지와 관련된 영역 및 확률값에 대한 분석을 하였으며 인터넷 상에 있는 흡연과 관련된 데이터를 수집하여 흡연이미지에 대한

탐지를 실험을 하여 성능을 분석을 하였다. 세 번째로, 군복 입는 사진을 이용하여 군대상황에서도 흡연 여부를 확인할 수 있었고 실제상황에서 적용할 수 있는 가능성을 확인하였다.

3. 딥뉴럴네트워크를 이용한 흡연 탐지

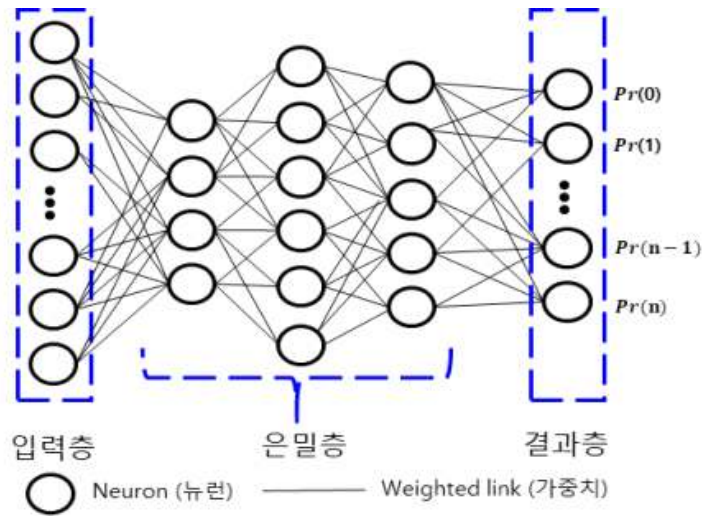
딥뉴럴네트워크의 구조는 (그림 1)과 같다. (그림 1)에서 보면 딥뉴럴네트워크의 구조는 노드와 가중치에 결합으로 이루어져 있으며 전체적으로 입력층, 은밀층, 출력층으로 구성되어 있다. 입력층에서는 입력데이터에 해당되는 값이 각각 노드에 할당이 되고 선형적인 연산인 곱셈과 덧셈을 통해 계산된 결과값을 활성화함수를 거쳐 어떤 수치 이하이면 0값을 제공하고 그 이상이면 1값 또는 그 수치대로 반영을 한다. 이는 활성화함수 LeRU[11], sigmoid[12] 등에 따라서 달라지는 데 그 계산된 결과값이 다음층에게 전달이 된다. 은밀층은 내부적으로 여러 개의 층이 구성되어 있고 이 층이 많아지면 많아질수록 연산량이 많아지는 특징이 있다. 기존의 컴퓨팅 기술로는 연산속도가 빠르지 않았지만 컴퓨팅 기술과 병렬연산의 발전으로 매우 빠른 연산이 가능해졌다. 은밀층 내부에서도 마찬가지로 각 노드에 할당된 값이 곱셈과 덧셈을 통해 계산된 결과값을 활성화함수를 거쳐서 어떤 수치 이하이면 0값을 제공하고 그 이상이면 1값 또는 그 수치대로 반영을 한다. 출력층에서는 은밀층의 마지막 층에 계산된 값이 전달이 되고 softmax층[13]을 통해서 요구되는 클래스의 수에 따라서 각 클래스의 확률값을 계산을 한다. 그 확률값 중에 가장 큰 값이 입력데이터에 대하여 인식되는 클래스가 되며 각 클래스의 확률값을 다 더하면 1이 된다. 흡연 탐지 딥뉴럴네트워크에서는 흡연 여부만 구분하기 때문에 두 개의 class로 구성하였고 각 클래스의 확률값이 제공되도록 하였다.

딥뉴럴네트워크가 학습하는 과정에서는 입력값에 대한 예측값과 실제 class와의 일치성을 보면서 cross entropy 손실함수[14]와 gradient descent 방법[15] 등을 이용하여 딥뉴럴네트워크 각 노드의 가중치 파라미터를 최적화 시킨다. 그렇게 딥뉴럴네트워크가 학습이 다 된 이후에 새로운 테스트 데이터가 딥뉴

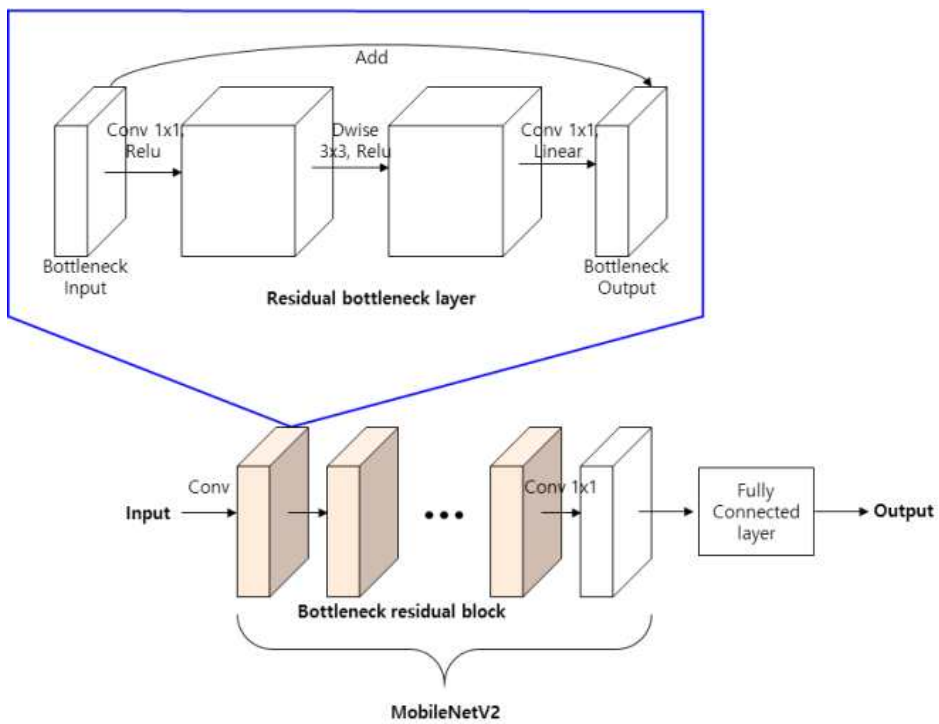
럴네트워크에 입력값으로 제공되었을 때 딥뉴럴네트워크는 신뢰성 있는 예측값을 제공해준다. 이 논문에서는 좀 더 개선된 방법인 convolutional neural network(CNN)[16]이 적용된 MobileNetV2 모델[17]을 이용하였고 마지막 층에 Fully connected layer 층을 추가하여 모델을 구성을 하였다. MobileNetV2 모델의 가장 큰 특징으로는 그 이름에서 알 수 있듯이 모바일장치 등 각종 기기에서 구동할 수 있기 위해 상대적으로 적은 계산량과 적은 파라미터의 수를 갖고 있어 경량화된 모델이면서 성능은 높았다는 점이다. 이를 통해 우리는 각종 기기(CCTV 등)에 흡연탐지모델을 적용하는 것을 고려할 수 있기 때문에 MobileNetV2 모델을 흡연탐지에 적용하였다. (그림 2)와 같이 MobileNetV2는 MobileNetV1 모델을 개선한 것으로써 MobileNetV1의 효율성을 더 높이는 효과를 가져왔다. (그림 2)에서 보면 MobileNetV2의 구조는 여러개의 bottleneck residual block으로 이루어져 있으며 전체적으로 입력층, residual bottleneck layer, 완전연결계층, 결과층으로 구성되어 있다. 입력층에서는 입력데이터에 해당하는 이미지 또는 영상에 해당하는 값을 받아 fully convolution layer에 입력된다. 이후 19개의 residual bottleneck layer에 입력되어 bottleneck residual block의 연산을 거치게 된다. 딥뉴럴네트워크에서 비선형성 함수(ReLU 함수 등)와 1x1 convolution을 거치면서 데이터손실이 일어나게 되는데 이것을 방지하기 위해 중요한, 필수 데이터만 남겨진 압축된 저차원 데이터에 pointwise convolution을 하고(채널 수 증가, 확장) depth-wise convolution로 필요연산을 줄이고 1x1 convolution으로 다시 압축을 하는 과정이 Residual bottleneck layer에서 이루어진다. 이처럼 MobileNetV2에서는 inverted residual 구조의 연산과정을 거친다. 자세한 내용은 4.2에서 설명을 하였다.

4. 실험 및 평가

흡연 탐지에 대한 성능을 보여주기 위해서 실험환경으로는 텐서플로우 머신러닝 라이브러리를 이용하였고, 흡연과 관련된 이미지 데이터셋과 딥뉴럴네트워



(그림 1) 뉴럴네트워크의 기본 구조



(그림 2) MobileNetV2와 Fully connected layers 연결된 탐지 구조

크를 구축하여 실험평가를 하였다.

4.1 데이터셋 구축

딥뉴럴네트워크에서 데이터셋을 구축하는 것은 중요한 부분이다. 흡연사진과 관련하여 인터넷상에 공유된 이미지를 이용하고 augmentation한 것과 합쳐서 860장의 흡연사진과 656장의 비흡연 사진으로 데이터셋을 구축을 하였다. 입에 담배를 물고 있는 사진을 기준으로 하였으며 눈, 코, 입이 다 보이는 사진을 기준으로 하였다. 데이터 사이즈는 각기 다르게 하여 일반적인 사진에서도 흡연 탐지가 가능하게 하였으며 여러 명의 사람이 있더라도 사람 얼굴 윤곽을 탐지해서 각각 흡연 여부를 탐지하도록 다중 인물 사진에 대하여 혼합하여 데이터를 구축하였다. 훈련데이터로써 흡연사진과 비흡연사진을 688장, 525장으로 구성하였고 테스트 데이터로 흡연사진과 비흡연사진을 172장, 131장으로 구축을 하였다.

4.2 딥뉴럴네트워크의 구성 및 파라미터

딥뉴럴네트워크 모델은 <표 2>과 같이 변형된 MobileNetV2 모델[17]을 이용하였다. <표 1>과 같이 파라미터로써 활성화함수로는 ReLU 함수를 사용하였고 배치사이즈는 32, 학습률은 0.004를 적용하였다. 최적화 알고리즘은 Adam 알고리즘[18]을 사용하여 흡연 여부를 탐지를 하였다. 위의 수치는 실험적으로 성능이 잘 나오는 수치값을 적용하였다.

<표 1> 딥뉴럴네트워크의 파라미터

| 제원 | 값 |
|---------------|-------|
| Optimizer | Adam |
| Learning rate | 0.004 |
| Batch size | 32 |
| Epochs | 20 |

<표 2> 딥뉴럴네트워크의 구성(MobileNetV2)

| Layer | 값 (블록 내부에 팽창사실 배수, 채널수, 반복수, stride) |
|--------------------------|---|
| $224^2 \times 3$ | conv2d(-, 32, 1, 2) |
| $112^2 \times 32$ | bottleneck(6, 16, 1, 1) |
| $112^2 \times 16$ | bottleneck(6, 16, 1, 1) |
| $56^2 \times 24$ | bottleneck(6, 16, 1, 1) |
| $28^2 \times 32$ | bottleneck(6, 16, 1, 1) |
| $14^2 \times 64$ | bottleneck(6, 16, 1, 1) |
| $14^2 \times 96$ | bottleneck(6, 16, 1, 1) |
| $7^2 \times 160$ | bottleneck(6, 16, 1, 1) |
| $7^2 \times 320$ | conv2d 1x1 (-, 32, 1, 2) |
| $7^2 \times 1280$ | avgpool 7x7 (-, 1280, 1, 1) |
| $1 \times 1 \times 1280$ | conv2d 1x1 (-, k, -, -) |
| Average Pool | (7, 7) |
| Fully Connected | 128 |
| Fully Connected | 2 |

4.3 실험결과

실험평가는 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1-score를 기준으로 흡연 탐지 성능을 평가하였다. 정확도는 모든 분류 결과 중에서 True-Positive(TP)와 True-Negative(TN)의 비율을 의미한다. 수식으로는 아래와 같다.

$$Accuracy : \frac{TP + TN}{TP + FP + TN + FN}$$

정밀도는 분류기가 True로 분류한 결과로 True-Positive(TP)와 False-Positive(FP) 중에 실제 True-Positive(TP)의 비율을 의미한다. 수식은 아래와 같다.

$$Precision : \frac{TP}{TP + FP}$$

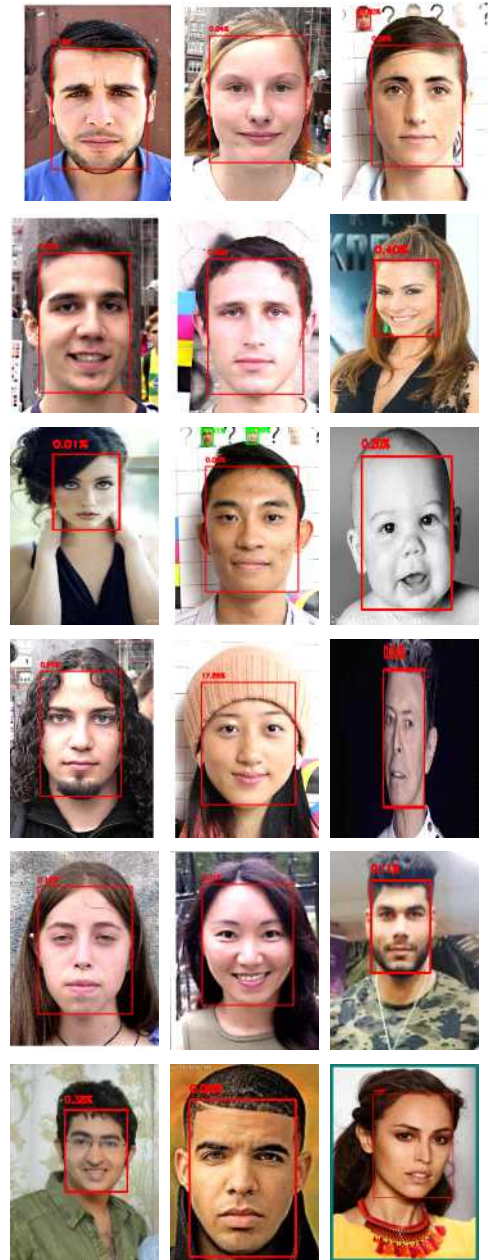
재현율은 실제 True 값을 분류기가 True로 분류한 결과로 True-Positive(TP)와 False-Negative(FN) 중에 실제 True-Positive(TP)의 비율을 의미한다. 수식은 아래와 같다.

$$Recall : \frac{TP}{TP + FN}$$


F1-score는 정밀도와 재현율의 가중치를 각각 0.5씩 부여한 조화평균을 의미한다. 수식적으로 표현하면 아래와 같다.

$$F1 - score : 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

(그림 3)은 딥뉴럴네트워크를 이용하여 비흡연사진에 대하여 비흡연자로 탐지된 이미지를 보여준다. 확률값이 50% 미만이면 비흡연자로 인식이 되는 데 그림 상에 보면 비흡연자의 탐지율이 좋은 것을 볼 수 있다.



(그림 3) 비흡연자의 탐지된 이미지 예시



(그림 4) 흡연자의 탐지된 이미지 예시

(그림 4)는 딥뉴럴네트워크를 이용하여 흡연자에 대한 탐지된 이미지를 보여준다. 이 그림에서 상당히 높은 99% 이상의 확률로 사람의 흡연사진을 탐지하는 것을 볼 수가 있다. 이를 통해서 제안방법을 CCTV에 적용하면 특정인의 흡연 여부를 탐지하는

데 좋은 성능을 제공할 수 있음을 알 수 있다.

<표 3> 딥뉴럴네트워크를 이용한 결과값

| 실제 \ 예측 | 흡연 | 비흡연 |
|---------|-------------|-------------|
| 흡연 | 162 (TP) | 16 (FN) |
| 비흡연 | 13 (FP) | 212 (TN) |

<표 3>은 테스트에 대한 결과값을 보여준다. 표에서 보면 재현율은 0.91, 정밀도는 0.93, 정확도는 0.93, F1-score는 0.92인 것을 알 수 있다. 따라서 딥뉴럴네트워크 기반으로 흡연 사진을 탐지할 경우 약 93% 이상의 정확도와 F1-score 0.92의 좋은 성능을 가진다.

<표 4> 딥뉴럴네트워크를 이용한 결과값에 대한 확률값. 50% 이상이면 흡연으로 탐지하고 50% 미만이면 비흡연으로 탐지한다.

| 구분 | 흡연 | 비흡연 |
|------|--------|---------|
| 평균 | 97.18% | 19.95% |
| 표준편차 | 7.751 | 16.83 |
| 최대값 | 100% | 48.89% |
| 최소값 | 50.71% | 0.0072% |

<표 4>는 테스트한 결과값에 대한 확률값을 보여준다. 전체 사진 중에 흡연관련 사진을 평균 97.18%로 높은 확률로 탐지하는 것을 볼 수 있다. 반면 비흡연관련 사진은 19.95%의 확률로 탐지하는 것을 볼 수 있다. 상대적으로 비흡연 사진의 평균값이 약 19%로 더 낮기에 흡연사진에 대한 탐지성능이 더 좋은 것을 볼 수 있다. 왜냐하면 비흡연 사진이더라도 입 주변에 마스크나 다른 물건 등이 있을 경우 흡연으로 오인시킬 확률이 있어서 비흡연사진의 평균 확률값이 약 19%정도 되는 것을 볼 수 있었다.

이로써 딥뉴럴네트워크를 이용하면 흡연 여부를 탐

지하는 데 좋은 성능을 가지는 것을 볼 수가 있었다. 또한 사진의 크기나 인물의 수에 제한이 없이 탐지가 가능한 특징이 있었다. 이 방법은 사진 중에 먼저 사람의 얼굴 형태에 대한 탐지를 먼저 한 후에 얼굴 입술 부분에 담배가 있는지 여부를 탐지하였는데 이를 통해 보다 좋은 성능을 가져온 것을 볼 수가 있었다.

또한 딥뉴럴네트워크를 구성할 때 기존 MobileNetV2 모델을 이용하였고 말단 층에 추가적으로 Fully connected layer를 부착하여 구성하였다. 현재 데이터에서 흡연여부만 탐지하기 위해서 두 개 클래스로 softmax를 구성하였지만 설계자가 추가적으로 다른 구분해야하는 요소를 설정할 경우 softmax에서 클래스의 수를 증가시킬 수 있다.

딥뉴럴네트워크는 학습률, 각 층의 노드의 수, 활성화 함수, 최적화 알고리즘에 따라서 성능이 달라질 수 있다. 이 논문에서는 몇 가지 파라미터에 대해 실험적으로 최적의 값을 설정하였고 그 외는 기존 모델에서 최적화된 파라미터를 준용하였다. 또한, 약 92% 정도의 F1-score로 좋은 성능을 보여주기 때문에 적절한 파라미터 설정으로 차후 후속연구에 이 파라미터 설정을 활용할 수 있을 것이다.

5. 결론

이 논문에서는 딥뉴럴네트워크를 이용하여 흡연 여부를 탐지하는 방법을 분석을 하였다. 기존 연구에서 화재예방이나 산불예방을 위해 불이나 연기에 대한 탐지를 시도한 것은 많이 있었지만 흡연 탐지에 대한 연구는 미흡한 실정이었다. 이번 연구에서는 실험적으로 최적화된 딥뉴럴네트워크 파라미터를 적용하였다. 또한 인터넷상에 공개되어 있는 실제 이미지를 이용하여 흡연을 탐지하였다. 실험결과로써 딥뉴럴네트워크를 이용한 흡연 탐지 모델이 정확도 약 93%, F1-score 약 92%의 좋은 성능을 제공하는 것을 볼 수가 있었다. 또한 이로써 흡연 탐지모델을 이미지의 연속인 비디오에 적용하면 CCTV를 통해서 흡연여부를 확인 할 수 있음을 알 수 있었다.

제한사항으로 제안 방법은 흡연 사진과 비흡연 사진을 인터넷상 공개된 사진을 이용하여 흡연 사진 여부를 탐지하였다. 하지만 비흡연 사진 중에도 사람의

흡연이 아닌 유사한 물질을 입에 뱉 가능성에 대하여 분석을 하지 않았다. 하지만 제안 방법으로 담배와 유사한 물건을 탐지되더라도 의미는 있을 것이라고 판단이 된다. 왜냐하면 CCTV에서 입 주변에 담배와 유사한 물건을 탐지가 될 경우, 알람 기능을 통해서 감시병에게 전달이 되면 감시병에 의해서 흡연 여부에 대해서 재차 검증이 될 것이라고 판단이 되기 때문이다. 따라서 사람 입 주변에 유사한 물건이 있을 경우 탐지하고 경고하는 정도로도 실제 사용에 있어서 유용하다고 판단이 된다. 하지만 향후 연구에서는 사람의 입에 담배가 아닌 비슷한 크기의 다른 물체가 있을 경우 흡연으로 오인식 하는 부분에 대해서 추가적으로 연구할 필요가 있다. 또한 이번 연구에서는 주로 얼굴이 뚜렷이 보이는 사진들을 대상으로 하였기에 실제 야외환경에서 얻어지는 다양한 사진들에 대한 연구는 부족하다. 인터넷 상 제공되는 사진 구축이 제한되기 때문에 야외에서 실제 직접 구축하는 등에 추가적인 연구가 필요하다. 향후 연구로 침입감내 분야 [19]와 적대적 샘플 분야[20][21][22]에 대해서 강건한 방어방법을 병행하여 연구하는 것도 흥미로운 연구주제일 것이다.

참고문헌

- [1] 대한민국 국방부, "2020 국방백서", 대한민국 국방부, 2020
- [2] 정춘일, "4차 산업혁명과 군사혁신 4.0", 전략연구, 제24권, 제2호, pp. 183-211, 2017.
- [3] Kim, Young-Jin, and Eun-Gyung Kim, "Image based fire detection using convolutional neural network", Journal of the Korea Institute of Information and Communication Engineering, Vol. 20, No. 9, pp. 1649-1656, 2016.
- [4] F Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain.", Psychological review, Vol. 65, No. 6, pp. 386-408, 1958.
- [5] GE Hinton, S Osindero, YW Teh, "A fast learning algorithm for deep belief nets", Neural computation, Vol. 18, No. 7, pp. 1527-1554, 2006.

- [6] SM Ahn, "Deep Learning Architectures and Applications", *Journal of Intelligence and Information Systems*, Vol. 22, No. 2, pp. 127-142, 2016.
- [7] Inoue, H., "Image-based smoke detection with k-Subspaces clustering", *Proc. of 2009 RISP International Workshop on Nonlinear Circuits and Signal Processing (NCSP'09)*, pp. 321-324, 2009.
- [8] Wu, Pin, et al., "Human smoking event detection using visual interaction clues", *2010 International Conference on Pattern Recognition IEEE*, pp. 4344-4347, 2010.
- [9] Odetallah, Amjad D., and Sos S. Aghaian., "Human visual system-based smoking event detection", *Mobile Multimedia/Image Processing, Security, and Applications 2012*, Vol. 8406, 2012.
- [10] Bien, Tse-Lun, and Chang Hong Lin., "Detection and recognition of indoor smoking events", *Fifth International Conference on Machine Vision (ICMV 2012): Algorithms, Pattern Recognition, and Basic Technologies*, Vol. 8784, 2013.
- [11] Agarap, Abien Fred., "Deep learning using rectified linear units (relu)", *arXiv preprint arXiv:1803.08375*, 2018.
- [12] Marreiros, A. C., Daunizeau, J., Kiebel, S. J., & Friston, K. J., "Population dynamics: variance and the sigmoid activation function", *Neuroimage*, Vol. 42, No. 1, pp. 147-157, 2008.
- [13] Joulin, Armand, et al., "Efficient softmax approximation for gpus", *Proceedings of the 34th International Conference on Machine Learning, PMLR*, Vol. 70, pp. 1302-1310, 2017.
- [14] Qin, Zhenyue, Dongwoo Kim, and Tom Gedeon, "Rethinking softmax with cross-entropy: Neural network classifier as mutual information estimator" *arXiv preprint arXiv:1911.10688*. 2019.
- [15] Du, Simon, et al., "Gradient descent finds global minima of deep neural networks" *Proceedings of the 36th International Conference on Machine Learning, PMLR*, Vol. 97, pp. 1675-1685, 2019.
- [16] Kalchbrenner, Nal, Edward Grefenstette, and Phil Blunsom, "A convolutional neural network for modelling sentences" *arXiv preprint arXiv:1404.2188*, 2014.
- [17] Sandler, Mark, et al., "MobileNetV2: Inverted residuals and linear bottlenecks" *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, pp. 4510-4520, 2018.
- [18] Kingma, Diederik P., and Jimmy Ba., "Adam: A method for stochastic optimization" *arXiv preprint arXiv:1412.6980*, 2014.
- [19] Kwon, Hyun, et al. "Optimal cluster expansion-based intrusion tolerant system to prevent denial of service attacks." *Applied Sciences* 7.11 (2017): 1186.
- [20] Kwon, Hyun, et al. "Classification score approach for detecting adversarial example in deep neural network." *Multimedia Tools and Applications* (2020): 1-22.
- [21] Kwon, Hyun, and Jun Lee. "AdvGuard: Fortifying Deep Neural Networks against Optimized Adversarial Example Attack." *IEEE Access* (2020).
- [22] Kwon, Hyun, Hyunsoo Yoon, and Ki-Woong Park. "Acoustic-decoy: Detection of adversarial examples through audio modification on speech recognition system." *Neurocomputing* 417 (2020): 357-370.

— [저자 소개] —



이 상 현 (Sanghyun Lee)
2013년 2월 육군사관학교 컴퓨터공학과
학사 졸업
2020년 3월~현재 한국과학기술원 정보
보호대학원 석사과정
email : skipalong@kaist.ac.kr



윤 현 수 (Hyunsoo Yoon)
1979년 2월 서울대학교 전자공학과 학
사 졸업
1981년 2월 한국과학기술원 컴퓨터공
학과 석사 졸업
1988년 8월 Ohio state University 컴퓨
터공학과 박사 졸업
email : hyoon@kaist.ac.kr



권 현 (Hyun Kwon)
2010년 2월 육군사관학교 수학(운영분석)
학사 졸업
2015년 8월 한국과학기술원 전산학부
석사 졸업
2020년 2월 한국과학기술원 전산학부
박사 졸업
email : hkwon.cs@gmail.com