

## 적은 데이터 세트를 기반으로 한 동물 이미지의 향상된 딥 러닝

신성윤<sup>o</sup>, 신광성\*, 이현창\*

<sup>o</sup>군산대학교 컴퓨터정보통신공학부,

\*원광대학교 디지털콘텐츠공학과

e-mail: s3397220@kunsan.ac.kr<sup>o</sup>, waver0920@wku.ac.kr\*, hclglory@wku.ac.kr\*

## An Enhanced Deep Learning for Animal Image Based on Small Datasets

Seong-Yoon Shin<sup>o</sup>, Kwang-Seong Shin\*, Hyun-Chang Lee\*

<sup>o</sup>School of Computer Inf. & Communication Eng., Kunsan National University,

\*Dept. of Digital Contents Eng, Wonkwang University

### ● 요약 ●

본 논문은 동물 이미지 분류를 한 작은 데이터 세트를 기반으로 개선된 딥 러닝 방법을 제안한다. 먼저, 소규모 데이터 세트에 대한 훈련 모델을 구축하기 위한 CNN이 사용되는 반면, 데이터 보강은 훈련 세트의 데이터 샘플을 확장하는 데 사용된다. 둘째, VGG16과 같은 대규모 데이터 세트에서 사전 훈련된 네트워크를 사용하여 소규모 데이터 세트의 병목 현상 기능을 추출하여 두 개의 NumPy 파일에 새로운 학습 데이터 세트 및 테스트 데이터 세트로 저장한다. 마지막으로 새로운 데이터 세트로 완전히 연결된 네트워크를 학습한다.

**키워드:** 딥 러닝(deep learning), 훈련 모델(training model), 소규모 데이터 세트(small data set)

### I. Introduction

최근에는 딥 러닝 방법에 기반한 CNN (Convolutional Neural Network) 기술[1]이 컴퓨터 비전 분야에서 대단한 성과를 거두었으며 주로 얼굴 인식, 이미지 분류, 자연어 처리 등에 적용된다[2-5].

그러나 CNN은 예측 정확도를 향상시키기 위해 훈련을 위한 충분한 데이터 샘플이 필요하다[6].

### II. Related Study

특정 학습 및 고도 비선형 변환의 특성으로 인해 딥 러닝 모델은 데이터 처리에서 복잡한 데이터 패턴을 획득할 수 있는 강력한 잠재력을 가지고 있다. 따라서 컴퓨터 비전에서 딥 러닝이 대중화되었기 때문에, 다수의 잘 표시된 이미지 데이터 세트가 소개되었다. 그러나 작은 데이터 집합의 경우 네트워크를 학습하는 데 사용되는 샘플 데이터가 제한되고 예측 결과가 정확하지 않으며 너무 작은 데이터 볼륨으로 인해 과적합이 발생한다. 따라서 데이터 확대, 정규화 및 Dropout 방법을 사용하여 예측 결과의 과적합을 억제한다.

### III. Proposed Method & Experiment

컨볼루션 신경망의 기본 구조와 잘 알려진 대규모 데이터 세트 훈련 모델 VGG16 컨볼루션 신경망의 구조는 다음과 같다. 주로 사용되는 모델 정규화 방법에는 데이터 확대 및 제거가 포함된다.

1) 데이터 기능 보강: 데이터 기능 보강은 과적합을 효과적으로 억제할 수 있는 방법이다. 이 방법은 원래 이미지의 특정 범위의 값 내에서 회전, 스케일링, 시프트, 미러링 등과 같은 연산을 수행함으로써 원래 이미지 데이터 특징을 갖는 새로운 샘플을 생성할 수 있으며, 그에 따라 데이터 샘플의 수를 증가시키는 목적을 달성할 수 있다.

본 논문에서는 훈련 샘플의 데이터를 보강하기 위해 무작위 변환이 사용된다. 데이터 확대 임의 변환의 매개 변수 구성 테이블이 표 1에 표시된다. 원본 이미지는 40°의 범위에서 무작위로 회전한다. 이미지의 너비와 높이는 20% 범위 내에서 임의로 이동한다. 무작위 트리밍은 20% 이내에 수행된다. 랜덤 스케일링은 20% 범위에서 수행된다. 이미지가 무작위로 수평으로 뒤집히고 마지막으로 가장 가까운 모델로 채워진다.

Table 1. Data augmentation parameters

No.	Parameter	Augmentation
1	Rotation(°)	40
2	Width_shift(%)	20
3	Height_shift(%)	20
4	Shear(%)	20
5	Zoom(%)	20
6	Horizontal_flip	TRUE
7	Fill_mode	Nearest

2) 제거 : 데이터 확대는 훈련 샘플 수의 증가 일 뿐이며 어느 정도 초과 피팅을 억제 할 수 있다. 그러나 데이터 확대 후 훈련 샘플에 다양성이 없기 때문에 딥 러닝 모델에서 과적 합을 제거하는 것만으로는 충분하지 않다. 따라서 과적 합을 추가로 제거하기 위해 드롭 아웃 방법도 필요하다. 이는 신경망 훈련 동안 확률  $p$ 에 의해 신경 단위의 랜덤 감소를 말함으로써, 신경망의 파라미터의 수를 줄이고 훈련 결과의 과적 합 문제를 제거한다. 이 논문에서 드롭 아웃 방법은 마지막으로 완전히 연결된 레이어에만 적용되며 랜덤 확률은 활성화 함수 ReLU 및 Sigmoid와 함께  $p = 0.5$ 로 설정된다. 향상된 완전 연결된 계층 네트워크 구조가 그림 1에 나와 있다. 여기서 "Input #"은 병목 현상이 있는 입력 파일을 나타낸다. 컨볼루션 신경망 및 최적화 된 완전 연결된 계층 네트워크 구조가 각각 표 2 및 표 3에 나와 있다.




Fig. 1. Improved fully connected layer network structure

Table 3. Arch. of implemented CNN fully connected layer

No.	Layer	Output size	Dopout
1	Fatten	1×1×8192	—
2	Fully connected	1×1×256	—
3	ReLU	1×1×256	—
4	Dropout	1×1×256	0.5
5	Fully connected	1×1×256	—
6	ReLU	1×1×256	—
7	Dropout	1×1×256	0.5
8	Fully connected	1×1×257	—
9	Sigmoid	1×1×257	—

#### IV. Conclusions

이 논문은 동물 이미지 분류를 위한 작은 데이터 세트를 기반으로 개선 된 딥 러닝 방법을 제시했다. Kaggle Dogs vs Cats 데이터 세트에서 2 가지 범주의 실험이 수행되었다. Kaggle Dogs vs Cats 데이터 세트는 레이블이 있는 개와 고양이 사진을 위한 25,000 개의

훈련 세트와 레이블이 없는 개와 고양이 사진을 위한 12500 테스트 세트로 구성된다. 각 훈련 세트에서 1,000 개의 그림이 무작위로 선택되었고, 실험 훈련 세트가 작성되었으며, 각 테스트 세트에서 400 개의 실험 샘플이 무작위로 선택되었다.

#### REFERENCES

- [1] J. Lemley, S. Bazrafkan, and P. Corcoran, 2017, ‘Deep learning for consumer devices and services: Pushing the limits for machine learning’, artificial intelligence, and computer vision,” IEEE Consumer Electronics Magazine, vol. 6, no. 2, pp. 48-56.
- [2] Alex Krizhevsky,Ilya Sutskever,Geoffrey E. Hinton, 2012, ‘ImageNet Classification with Deep Convolutional Neural Networks’, Advances in Neural Information Processing Systems 25, pp.1-9.
- [3] Karen Simonyan, Andrew Zisserman. 2014, ‘Very Deep Convolutional Networks for Large-Scale Image Recognition’, Computer Science, pp. 1-14.
- [4] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich, 2015, ‘Going Deeper With Convolutions’, The IEEE Conference on Computer Vision and Pattern Recognition, pp. 1-9.
- [5] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, 2016, ‘Deep Residual Learning for Image Recognition’, The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778.
- [6] Joseph Lemley,Shabab Bazrafkan and Peter Corcoran, 2017, ‘Smart Augmentation Learning an Optimal Data Augmentation Strategy,’ IEEE Access, vol. 5, pp. 5858-5869.