

카테고리 계층을 고려한 회선신경망의 이미지 분류

정노권[†], 조수선^{††}

Image Classification Using Convolutional Neural Networks Considering Category Hierarchies

Nokwon Jeong[†], Soosun Cho^{††}

ABSTRACT

In order to improve the performance of image classifications using Convolutional Neural Networks (CNN), applying a category hierarchy to the classification can be a useful idea. However, the visual separation of object categories is very different according to the upper and lower category levels and highly uneven in image classifications. Therefore, it is doubtful whether the use of category hierarchies for classification is effective in CNN. In this paper, we have clarified whether the image classification using category hierarchies improves classification performance, and found at which level of hierarchy classification is more effective. For experiments we divided the image classification task according to the upper and lower category levels and assigned image data to each CNN model. We identified and compared the results of three classification models and analyzed them. Through the experiments, we could confirm that classification effectiveness was not improved by reduction of number of categories in a classification model. And we found that only with the re-training method in the last network layer, the performance of lower category classification was not improved although that of higher category classification was improved.

Key words: Convolutional Neural Networks, Image Classification, Category Hierarchy

1. 서 론

최근 인간의 시신경을 모사하기 위하여 만들어진 회선신경망(Convolutional Neural Networks, CNN)을 이용한 이미지 분류 연구가 활발하게 진행되어왔다. 대규모 이미지 데이터베이스를 운영하는 Image Net에서 해마다 개최한 세계적인 이미지 인식 대회인 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)에서 탁월한 성능을 입증한 회선신경망 모델들[1-4]의 이미지 분류 성능을 살펴보면 이 분야의 연구가 얼마나 활발하게 이루어져 왔으며, 얼마나

빠르게 성장하는지를 알 수 있다. 또한 분류 연구[5]와 같이 회선신경망을 접목한 응용 연구도 점점 늘어나고 있다.

하지만 대부분의 회선신경망 모델에서는 평면적인 단일 분류기를 사용할 뿐 분류 카테고리명 자체가 포함하고 있는 계층구조(hierarchy)를 이용하고자 하는 연구는 매우 드물었다. 이는 일반적인 선형 분류기에서 계층 구조를 적극 이용하고 있는데 비하면 의외의 현상이라 할 수 있다. 카테고리 명이 나타나고 있는 계층구조를 이용하고자 하는 연구가 활발하지 않은 이유는 전통적인 선형 분류기와는 다르게

※ Corresponding Author : Soosun Cho, Address: (16106) 157, Cheoldobangmulgwan-ro, Uiwang-si, Gyeonggi-do, Republic of Korea, TEL : +82-31-460-0584, FAX : +82-31-462-8208, E-mail : sscho@ut.ac.kr
Receipt date : Aug. 16, 2018, Revision date : Nov. 1, 2018

Approval date : Nov. 21, 2018

[†] IS Technology Inc.

(E-mail : aretian@naver.com)

^{††} Dept. of Computer Science and Information Eng., Korea National University of Transportation

회선신경망에서는 카테고리 계층을 이용하는 것보다 평면적인 N-way 분류기가 더 효과적이기 때문일 수도 있다.

본 논문은 회선신경망 모델에서 평면적인 단일 분류기와 카테고리 계층을 이용한 분류기의 성능을 비교하고, 카테고리의 상/하위 레벨에 따라 분류 성능이 어떻게 달라지는지 알아보고자 한다. 논문의 구성은 다음과 같다. 이어지는 2절에서는 관련 연구로 회선신경망을 이용한 이미지 분류와 특히 카테고리 계층을 이용한 분류에 관하여 설명한다. 3절에서는 본 연구의 카테고리 계층 및 분류 모델에 대하여 설명하고, 4절에서는 카테고리 계층을 이용한 분류의 성능을 평면적인 단일 분류기를 사용한 경우와 비교하기 위한 실험을 소개하고 그 결과 및 분석을 다룬다. 마지막으로 5절에서는 본 논문의 결론을 내린다.

2. 관련 연구

2.1 회선신경망을 이용한 이미지 분류

회선신경망은 회선(Convolution, 합성곱)이라 불리는 연산을 이용하는 인공신경망(Artificial Neural Network)의 일종이다. 영상처리분야에서 사용되는 회선 연산은 이미지의 픽셀과 그 주변 픽셀의 값을 커널 혹은 마스크 혹은 필터라 불리는 것과 대응되는 요소끼리 곱하고, 그 곱한 값들을 모두 더한 값을 결과 값으로 반환한다. 이러한 과정을 이미지의 픽셀들을 돌며 반복 수행하는 연산을 회선 연산이라 말한다. 신경망에서 뉴런의 가중치와 편향을 학습한다고 할 때, 가중치에 해당하는 것이 이 합성곱 커널의 가중치이다.

회선신경망은 주로 세 가지 타입의 레이어(layer)가 쌓인 것인데, 그 세 가지 타입은 회선 연산을 수행하는 Convolutional 레이어, 데이터 수를 줄이는 서브 샘플링을 위한 연산을 수행하는 Pooling 레이어, 마지막으로 모든 값을 연결하고 모아서 이를 바탕으로 분류를 수행하는 Fully-connected 레이어로 구성된다. Fully-connected 이전의 레이어들은 필터를 통해 특징을 추출하는 역할을 하게 되며, 이러한 특징들을 모으고 이를 바탕으로 Fully-connected 레이어에서는 실제적인 분류(classification)를 수행하게 된다. GoogLeNet[3] 이후의 최근 회선신경망 모델들에서는 Pooling 레이어를 사용하지 않고 합성곱의 진

전(stride)을 높이는 경향을 보이는 등, 다소의 변형들은 있지만 대부분 위와 같이 세 가지 타입의 레이어로 구성되어 있다.

이러한 회선신경망을 이용한 이미지 분류는 2012년 ImageNet의 세계적인 대규모 이미지 인식 경연 대회인 ILSVRC에서 AlexNet[1]이 압도적인 성능을 보여주며 우승을 한 이후로 빠르게 성장하였다. 그리하여 AlexNet 이후로 VGGNet[4], GoogLeNet(Inception)[3], ResNet[4] 등의 모델이 나타나 회선신경망의 이미지 인식 성능은 점점 향상되었다.

이러한 회선신경망을 이용한 이미지 분류는 ImageNet과 같은 대규모의 정제된 이미지 데이터를 기반으로 수행되었기 때문에 소셜 네트워크 상에서 일반 대중들에 의하여 생성되는 비정제된 이미지들에 대해서도 과연 효과적인가 하는 의문이 있을 수 있다. 이러한 의문을 바탕으로 비정제된 소셜 네트워크 상의 이미지를 이용한 분류에 관심을 둔 연구들[6, 7]이 있었으며, 대규모의 정제된 이미지들을 바탕으로 학습된 회선신경망이 비정제된 소셜 네트워크 이미지의 분류에서도 효과적이라는 점을 확인하였다.

2.2 카테고리 계층을 이용한 이미지 분류

회선신경망의 이미지 분류성능을 더욱 높이기 위하여 기본적인 소프트웨어 알고리즘 기법 중 하나인 분할 정복(Divide and Conquer)을 적용해보고자 하는 시도는 매우 자연스러운 발상이다. 즉, 분류하고자 하는 카테고리를 계층구조로 구성하여 추상성이 높은 상위 카테고리들과 그 아래에 추상성이 낮은 하위 카테고리를 둔다. 분류는 계층구조에서 상위에 있는 카테고리를 먼저 분류하고 차츰 하위 카테고리로서 이어지며, 마지막에 최하위 카테고리로서 분류하는 방식이다.

회선신경망 기반의 분류 이전에, 다수의 클래스들을 다루는 선형 분류기 기반의 이미지 분류에서는 이미 분류기들의 계층을 이용하는 것이 일반적인 방식이었다[8]. 연구[9]에서는 ImageNet에서 미리 정의된 카테고리 계층을 이용하였으며 연구[10]에서는 계층적 레이블 트리를 구성하여 최종 판단을 위한 확률적 결합을 시도하였다.

회선신경망 기반의 이미지 분류에 카테고리 계층 구조를 이용하고자 하는 시도 중 하나는 연구[11]에 소개되어 있다. 이 연구의 목적은 충분하지 못한 혼

런 데이터로 분류기를 학습시킬 때, 분류 성능을 높이기 위해서 클래스들 간에 정보를 전달하는 것이었다. 예를 들어 포유동물 ‘치타’를 분류하기 위한 회선신경망 분류기에서 훈련에 사용할 수 있는 ‘치타’ 이미지 개수가 아주 적다면 분류기 성능은 낮을 수밖에 없을 것이다. 이 때 계층구조 상 이웃한 클래스인 ‘호랑이’, ‘사자’, ‘표범’, ‘재규어’ 등의 이미지를 활용하여 훈련 데이터의 정보를 확대시킴으로써 분류기 성능이 높일 수 있음을 밝히고 있다. 이 연구는 충분한 훈련 데이터 정보를 확보하고자 분류 클래스의 계층을 이용한 것인데 반해 본 논문의 연구에서는 분류 클래스의 계층을 직접적으로 이용함으로써 단일 분류 방법에 비해 계층 분류 방법에서 회선신경망분류기의 성능 향상을 기대할 수 있는지를 밝히고자 한다. 연구[12]에서는 분류 카테고리에 해당하는 여러 가지 레이블들 간의 상호관계를 계층구조로 표현하였다. 일반적인 회선신경망분류기의 성능 향상은 소개되지 않았으며 훈련 이미지의 일부가 계층 클래스 트리의 내부 노드 명으로 다시 레이블링됐을 때에만 분류 정확도가 향상되었다고 밝히고 있다.

그러나 선형 분류기에서 계층 구조를 적극 이용하고 있는데 비하여 회선신경망 기반의 이미지 분류에서는 카테고리 계층구조를 이용하고자 하는 시도가 많지 않은 것을 확인할 수 있었다. 그 이유 중 하나로 회선신경망에서는 카테고리 계층의 레벨에 따라서 평면적인 단일 분류기보다 효과가 떨어지기 때문이라고 짐작해볼 수 있다. 본 논문에서는 회선신경망 모델에서 평면적인 단일 분류기와 카테고리 계층을 이용한 분류기의 성능을 비교하고자 한다. 특히 카테고리 계층의 레벨에 따라 분류 성능이 어떻게 달라지는지 알아보하고자 한다.

3. 카테고리 계층구조 및 분류 모델

3.1 분류 카테고리의 계층구조

본 연구에서는 상/하위 2계층의 구조로 카테고리 레벨을 설정하고 각각의 회선신경망 모델을 적용하여 상/하위 카테고리에 해당하는 분류를 수행하게 한다. 분류할 이미지들의 카테고리는 ImageNet의 카테고리 계층구조 중 일부인 domestic animal - domestic dog, domestic cat 의 카테고리를 이용하였다. 해당 카테고리는 domestic cat 5종, domestic dog

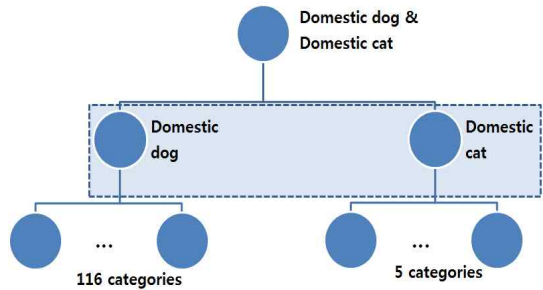


Fig. 1. Category hierarchy of upper & lower levels.

116종, 총 121개의 카테고리로 구성하였다.

Fig. 1은 본 연구의 상/하위 2계층의 카테고리 구조를 보여준다. 음영 박스로 표시된 영역인 상위 카테고리명(domestic dog 및 domestic cat)이 추가됨으로써 단일 구조의 분류기가 계층구조를 갖게 되었다. 단일 분류기에서 하나의 회선신경망 분류 모델로 121개 카테고리를 한꺼번에 분류하는 것에 비하여 상/하위 2계층의 카테고리로 단계적으로 분류할 때, 각각의 회선신경망 모델에서 분류 카테고리 수가 줄어들기 때문에 특정 카테고리에 대한 집중된 학습 효과를 얻어 전체적으로 분류 성능이 올라가는지 확인하고자 한다.

3.2 카테고리 분류 모델

본 연구에서는 실험을 통하여 총 3가지의 분류작업을 수행하였으며, 각각의 분류작업 및 모델은 아래와 같다.

- A. ImageNet 카테고리 레이블을 기반으로 학습되어 1,000개의 카테고리 분류를 수행하는 평면적인 단일 Pretrained 회선신경망 모델에서 이미지 분류
- B. ImageNet의 domestic dog 및 domestic cat에 속하는 총 121개의 카테고리 레이블을 갖도록 모델 A의 마지막 레이어를 조정하여 단일 회선신경망 모델에서 이미지 분류
- C. 카테고리 상/하 관계를 갖도록 설정한 다음의 3가지 재조정된 회선신경망 모델에서 이미지 분류
 - C.1 Domestic dog와 Domestic cat을 분류하는 모델
 - C.2 Domestic cat 5종을 분류하는 모델
 - C.3 Domestic dog 116종을 분류하는 모델

Fig. 2는 분류 모델 A와 B의 비교를 보여준다. A와 B의 비교를 통하여 분류할 카테고리 수가 적어지면 회선신경망 모델이 특정 분야에 집중하여 분류 성능이 올라가는가를 파악한다. Fig. 3은 분류 모델 B와 C의 비교를 보여준다. B와 C의 비교를 통하여 본 연구에서 제안하는 카테고리 계층 구조를 이용하면 이미지 분류 성능이 올라가는지를 확인한다.

각 모델의 Transfer Learning은 마지막 Fully-connected 레이어를 재조정 하였으며, batch_size : 32, learning_rate: 0.01, epoch : 1, optimizer : RMS Prop 로 설정하여 실시하였다. 여기서, batch_size는 한 번의 반복(iteration)에 이용되는 이미지의 수를 나타내며, learning_rate는 학습하는 속도, epoch는 모든 이미지를 한 번씩 다 학습한 것을 나타낸다. optimizer의 RMSProp은 적절하게 learning_rate를 조금씩 수정하는 최적화 방식을 말한다.

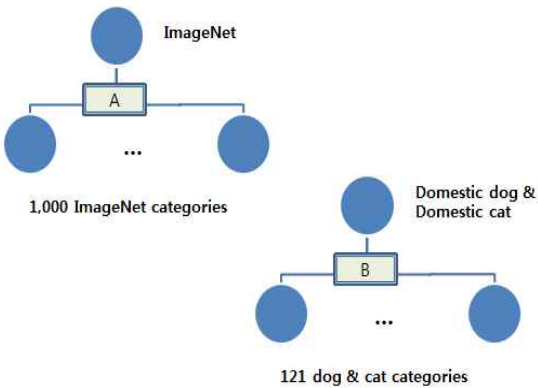


Fig. 2. Comparison of classification model A and B.

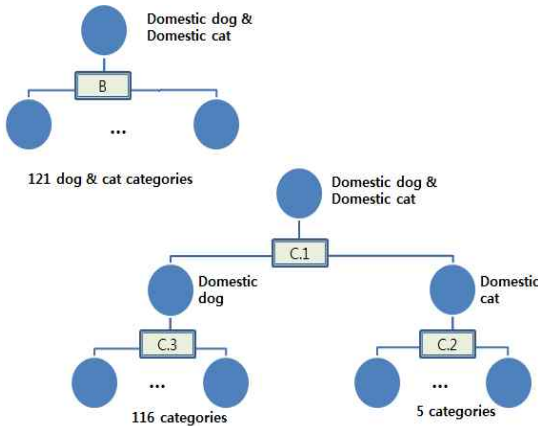


Fig. 3. Comparison of classification model B and C.

4. 실험 및 분석

4.1 실험 데이터 및 실험환경

실험을 위한 데이터 셋은 Training set/Validation set/Test set의 세 가지로 구성된다. Training set은 회선신경망 모델을 학습시키기 위해서 사용하며, Validation set은 회선신경망 모델이 제대로 학습되었는지, 데이터에 과적합(Overfitting)된 것은 아닌지 확인하기 위해서 사용한다. 마지막으로 Test set은 최종적으로 모델을 평가하기 위하여 사용한다. Training과 Validation set은 ImageNet 2012 대회 데이터셋[13]을 사용하였으나, ImageNet 2012 대회의 Test set은 정답 레이블을 제공하지 않기 때문에 Test set은 선행 연구[7]와 같이 플리커와 인스타그램을 통하여 수집한 이미지 데이터를 사용하였다.

ImageNet 2012 대회의 데이터셋은 Training set 약 130만장, Validation set 5만장으로 구성되어 있으며, 이 데이터들 중 121개의 카테고리에 해당하는 이미지는 Training set 약 152,000 장, Validation set 6,050 장으로 구성되어 있다. Test set인 플리커와 인스타그램 이미지는 121개의 카테고리 별로 50장씩 6,050장으로 구성하였다. 실험을 위해서 사용하는 회선신경망 모델은 선행연구[6]에서 사용한 Google의 Inception V3 모델[3]로 설정하였다.

실험이 진행된 PC의 사양과 소프트웨어는 환경은 Table 1과 같다. 딥러닝에서 학습속도를 높이기 위한 아키텍처이자 소프트웨어인 CUDA 8.0을 이용하여 GPU 연산을 수행하였다.

4.2 실험 결과

Validation set 및 Test set에 대한 실험의 결과를 요약하면 Table 2와 Table 3과 같다.

Table 1. Experimental conditions

CPU	Intel(R) Core(TM) i7-6700 CPU @ 3.40 GHz
RAM	64 GB
SSD	250 GB
GPU	NVIDIA GeForce GTX 1080
OS	Ubuntu 16.04.1 LTS (4.4.0-71-generic)
SW	Cuda 8.0
	TensorFlow 1.2.1
	Python 3.5

Table 2. Classification results from Validation sets

Model	Top-1 Error rate	Top-5 Error rate
B. 121 single	21.65%	4.08%
C.1. domestic animal	1.00%	0.00%
C.2. cat	28.67%	0.00%
C.3. dog	21.48%	3.95%

Table 3. Classification results from Test sets

Model	Top-1 Error rate	Top-5 Error rate
A. 1000 single	24.67%	6.78%
B. 121 single	27.21%	7.88%
C. 121 3models	27.55%	8.03%

Table 2는 각각의 모델들의 Validation Set에 대한 Top-1, Top-5 error rate를 보여주고 있다. Domestic dog와 Domestic cat을 합친 Domestic animal의 121개의 카테고리에 적용된 단일 모델 B의 결과는 Top-1 Error rate 21.65%, Top-5 Error rate 4.08%를 보여주고 있다. Domestic cat과 Domestic dog, 두 가지 카테고리 레이블을 반환하는 C.1 모델은 Top-1 error 1.00%를 보여주고 있다. C.1과 C.2에서는 각각의 모델이 분류하는 카테고리 수가 2와 5이기 때문에 Top-5 이내에 해당 카테고리 레이블이 반드시 나타나게 되어 Top-5 error rate가 0이 된다.

116개의 Domestic dog 카테고리에 대한 결과를 반환하는 C.3는 Top-1 및 Top-5 error rate가 각각 21.48% 3.95%로 나타났다. 5개의 Domestic cat 카테고리에 대한 결과를 반환하는 C.2는 Top-1 error rate가 28.67%로 나타났다. Inception V3의 ImageNet 테스트셋의 결과가 Top-1 및 Top-5 error rate 각각 22%, 6.1% 정도인 점을 고려할 때 Table 2의 Validation Set에 대한 결과에서 각각의 모델들의 Transfer Learning이 잘 이루어진 것으로 판단된다.

Table 3은 모델 A, B, C의 세 가지 경우에 해당하는 Test set의 평가 결과이다. ImageNet 1,000개 카테고리의 단일 분류에 해당하는 A의 결과가 Top-1 error rate 24.67% Top-5 error rate 6.78%로 나타났다. Domestic cat과 Domestic dog를 합친 121개의 평균적인 카테고리를 분류하는 B의 결과는 Top-1 error rate 27.21%, Top-5 error rate 7.88%로 나타나

A의 결과보다 좋지 못하였다. 카테고리 계층구조를 이용하여, Domestic cat과 Domestic dog를 분류하는 C.1, 5개의 Domestic cat 카테고리를 분류하는 C.2, 116개의 Domestic dog 카테고리를 분류하는 C.3를 포함하는 3개의 모델을 사용한 C의 결과는 Top-1 error rate 27.55% , Top-5 error rate 8.03%로 분류 성능이 B보다 약간 더 낮았다.

4.3 실험 결과 분석

실험 결과에서 ImageNet 1,000개 카테고리의 단일 분류에 해당하는 모델 A의 결과가 같은 단일 분류이지만 카테고리 수를 121개로 줄인 B의 결과보다 오히려 좋았다. 즉, 카테고리 수를 줄이는 것이 분류 성능에는 도움이 되지 않았음을 알 수 있다. 또한 B와 같은 수의 카테고리 레이블을 이용하되 2단계의 계층 구조를 적용한 모델 C의 분류 성능이 B와 유사한 것을 알 수 있었다. 즉, 카테고리 계층 구조를 이용하는 분류 방법에서 특별히 성능 향상의 효과는 없었다.

Table 4, Table 5, Table 6은 C에서의 분류 실패 케이스들을 좀 더 면밀히 분석해보기 위한 것이다. Table 4는 B, C에 대한 상위 Top-1 결과에서 분류 성공과 실패를 나타내는 True/False 횟수의 비교를 보여주고 있다. Table 4를 보면 상위 Top-1 결과로 B에서는 분류 성공했지만 C에서 실패한 경우(B-T

Table 4. Comparison of True(T)/False(F) from model B and C

	B-T C-T	B-T C-F	B-F C-T	B-F C-F	Total
Top-1	4,150	254	233	1,413	4,404

Table 5. Classification errors of model C.1

	Domestic cat Error	Domestic dog Error	Total Error
Top-1	3	33	36

Table 6. Classification errors of model C affected by failures of model C.1

	B-T C-F	B-F C-F	Total
Domestic cat Error	2	1	3
Domestic dog Error	10	23	33
Total	12	24	36

C-F)가 254이며 반대로 B에서 실패, C에서 성공한 경우(B-F C-T)가 233으로 나타났다. B-T C-F의 경우가 B-F C-T의 경우보다 많다는 것은 모델 C에서 카테고리를 계층적으로 적용했을 때, 모델 B에서는 분류 실패한 것을 제대로 분류하게 된 경우보다 그 반대의 경우가 더 많다는 것을 의미한다.

카테고리를 계층적으로 적용한 모델 C에서 최종 분류인 C.2와 C.3에서 실패한 것은 상위 분류인 C.1에서의 실패가 전파되었을 가능성이 있다. 즉, 오류가 전파되었을 가능성을 의심해 볼 수 있다. Table 5와 Table 6은 이에 대하여 분석한 것이다. Table 5의 Domestic cat Error는 Domestic cat에 분류되어야 할 대상을 Domestic dog로 잘못 분류한 경우를 말하며, Domestic dog Error는 그 반대를 말한다. 전체적으로 잘못 분류한 경우가 36건이고, 이는 Table 4에서의 B-T C-F의 경우와 B-F C-F의 경우에 영향을 주었을 것이다. 이에 대한 영향을 Table 6에서 보여주고 있다. 12건의 Domestic dog/cat Error가 B-T C-F의 경우에 부정적인 영향을 미쳤으며, 24건의 Domestic dog/cat Error가 B-F C-F의 경우에 영향을 주었다. 이는 계층구조상 상위 분류에서의 36건의 분류 실패가 하위 카테고리 분류에 전파되었다고 볼 수 있다. 즉, 상위 카테고리에서 이미 잘못 분류된 결과는 고스란히 하위 카테고리 분류에서도 오류로 나타날 수밖에 없는 구조적인 한계가 존재한다는 것을 알 수 있다.

Fig. 4는 Domestic dog/cat Error를 일으킨 이미지들의 일부를 보여주고 있으며, 이들은 분류 성공한



Fig. 4. Representative images occur classification errors.

이미지들에 비하여 해당 카테고리에 속하는 객체들의 특징을 상대적으로 잘 파악할 수 없거나, 복수의 다른 객체들이 혼재되어 있는 모습을 볼 수 있다.

이상의 실험 결과로부터 다음과 같은 분석 및 고찰이 가능하다.

첫째, 단일 회선신경망 모델에서 분류하는 카테고리의 수를 줄이는 것이 분류성능을 높이는데 기여하는 바는 거의 없다. Table 2에서 모델 B, 그리고 C.2와 C.3는 A 모델에서 분류하는 카테고리의 수를 줄인 경우가 된다. 하지만 카테고리의 수를 줄여도 성능이 향상되지 않고, 성능이 유지되거나 감소하는 경향을 보이고 있다.

둘째, 실제적인 분류를 수행하는 마지막 레이어만을 재학습(Transfer Learning)하는 방식으로는, 상위 카테고리를 분류하는 성능은 높아질 수 있지만 하위 카테고리를 분류하는 모델의 성능은 기존 모델의 그것과 거의 비슷한 수준이다. Table 2와 Table 3을 보면 상위 카테고리를 분류하는 C.1은 분류 성능이 뛰어난 반면, 하위 카테고리를 분류하는 나머지 B, C.2, 및 C.3의 경우는 성능이 기존의 A와 비슷하다.

5. 결 론

일반적인 선형 분류기에서 계층적인 구조를 적극 이용하고 있는데 비하여 대부분의 회선신경망 모델에서는 평면적인 단일 분류기를 사용할 뿐 분류 카테고리 레이블 자체가 포함하고 있는 계층구조를 이용하고자 하는 연구가 매우 드물었다. 본 연구에서는 회선신경망 모델에서 평면적인 단일 분류기와 카테고리 계층을 이용한 분류기의 성능을 비교하고, 카테고리 계층의 상/하위 레벨에 따라 분류 성능이 어떻게 달라지는지 알아보려고 하였다.

실험을 통하여 다음을 확인할 수 있었다. 먼저, 하나의 모델이 분류하는 카테고리 수를 줄이는 것이 분류성능을 높이는데 생각보다 기여하는 바가 없었다. 또한, 실제적인 분류를 수행하는 마지막 레이어만을 재학습하는 방식으로는, 상위 카테고리를 분류하는 성능은 높아질 수 있지만 하위 카테고리를 분류하는 모델의 성능은 기존 모델의 그것과 거의 비슷한 수준이었다.

계층적으로 신경망을 구성하여 성능 향상을 기대하기 위해서는 하위 카테고리를 분류하는 모델에서 성능 향상이 있어야 한다. 물론, 상위 카테고리를 분

류하는 모델에서도 충분히 강력한 분류 성능을 보장하여야 한다. 그럼으로써, 상위 카테고리 분류에 실패하여 받게 되는 불이익보다 하위 카테고리를 분류하는 모델에서 성공 이익이 더 커져야 한다. 이를 위하여 향후에는 단순히 분류를 수행하는 마지막 레이어만을 재학습시키는 것이 아니라 특징 추출을 담당하는 깊은 쪽의 레이어들을 튜닝하는 방향으로 연구를 진행할 계획이다.

REFERENCE

- [1] A. Krizhevsky, I. Sutskever, and G.E. Hinton, "Imagenet Classification with Deep Convolution Neural Networks," *Proceeding of Neural Information Processing System*, pp. 1097-1105, 2012.
- [2] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *Computer Vision and Pattern Recognition*, arXiv:1409.1556, 2014.
- [3] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," *Proceeding of 2016 IEEE Conference on Computer Vision and Pattern Recognition*, arXiv:1512.00567, 2015.
- [4] K. He, X. Zhang, S. Ren, and J. Sun, "Identity Mappings in Deep Residual Networks," *Proceeding of European Conference on Computer Vision*, arXiv:1603.05027, 2016.
- [5] Y. Park, S. Gang, J. Chae, and J. Lee, "Classification Method of Plant Leaf Using Dense Net," *Journal of Korea Multimedia Society*, Vol. 21, No. 5, pp. 571-582, 2018.
- [6] H. Jang and S. Cho, "Automatic Tagging for Social Images Using Convolution Neural Networks," *Journal of Korean Institute of Information Scientists and Engineers*, Vol. 43, No. 1, pp. 47-53, 2016.
- [7] N. Jeong and S. Cho, "Instagram Image Classification with Deep Learning," *Journal of Internet Computing and Services*, Vol. 18, No. 5, pp. 61-67, 2017.
- [8] A.M. Tousch, S. Herbin, and J.Y. Audibert, "Semantic Hierarchies for Image Annotation: A Survey," *Pattern Recognition*, Vol. 45, No. 1, pp. 333-345, 2011.
- [9] J. Deng, J. Krause, A.C. Berg, and L. Fei-Fei, "Hedging Your Bets: Optimizing Accuracy-Specificity Trade-Offs in Large Scale Visual Recognition," *Proceeding of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 16-21, 2012.
- [10] B. Liu, F. Sadeghi, M. Tappen, O. Shamir, and C. Liu, "Probabilistic Label Trees for Efficient Large Scale Image Classification," *Proceeding of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 843-850, 2013.
- [11] N. Srivastava and R. Salakhutdinov, "Discriminative Transfer Learning with Tree-Based Priors," *Proceeding of Neural Information Processing System*, pp. 2094-2102, 2013.
- [12] J. Deng, N. Ding, Y. Jia, A. Frome, K. Murphy, S. Bengio et al., "Large-Scale Object Classification Using Label Relation Graphs," *Proceeding of European Conference on Computer Vision*, pp. 48-64, 2014.
- [13] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, et al., "ImageNet Large Scale Visual Recognition Challenge," *Journal of Computer Vision*, Vol. 115, No. 3, pp. 211-252, 2015.



정 노 권

2018년 2월 한국교통대학교 컴퓨터정보공학과 석사
2018년 6월 ~ ㈜이즈테크놀로지 연구원
관심분야 : 영상처리, 딥러닝 등



조 수 선

1987년 서울대학교 계산통계학과 이학사
1989년 서울대학교 대학원 계산통계학과 이학석사
2004년 충남대학교 대학원 컴퓨터과학과 이학박사

1994년 6월 ~ 2004년 3월 한국전자통신연구원 선임연구원
2006년 7월 ~ 2007년 7월 미시간대학교(앤아버) 통계학과 방문연구원
2004년 4월 ~ 현재 한국교통대학교 컴퓨터정보공학과 교수
관심분야 : 데이터 마이닝, 빅데이터 분석, 인공지능