

전이학습을 이용한 전반사가 있는 월패드 분류

이용준^o, 조근식^{*}

^o인하대학교 컴퓨터공학과,

^{*}인하대학교 컴퓨터공학과

e-mail: lyj4032@naver.com^o, gsjo@inha.ac.kr^{*}

Glaring Wall Pad classification by transfer learning

Yong-Jun Lee^o, Geun-Sik Jo^{*}

^oDept. of Computer Engineering, Inha University,

^{*}Dept. of Computer Engineering, Inha University

● 요약 ●

딥러닝을 이용한 이미지 처리에서 데이터 셋이 반드시 필요하다. 월패드는 널리 보급되는 다양한 성능을 포함한 IoT가전으로 그 기능의 사용을 돕기 위해서는 해당 월패드에 해당하는 매뉴얼을 제공해야 하고 이를 위해 딥러닝을 이용한 월패드 분류를 이용 할 수 있다. 하지만 월패드 중 일부 모델은 화면의 전반사가 매우 심해 기존의 작은 데이터 셋으로는 딥러닝을 이용한 이미지 분류 성능이 좋지 못하다. 본 논문은 이를 해결 하기 위해 추가적으로 데이터 셋을 구축하고 이를 이용해 대규모 데이터로 사전 학습된 VGG16, VGG19, ResNet50, MobileNet 등을 이용해 전이학습을 통해 월패드를 분류한다.

키워드: 이미지 분류(Image classification), 사전 학습(pre-train), 전이 학습(transfer learning), 월패드(Wall Pad)

I. Introduction

월패드는 가정에 널리 보급되는 가전기기로서 홈 IoT 시장이 갈수록 성장함에 따라 그 기능이 다양해지고 많은 서비스들이 제공되고 있다. 월패드의 기능들을 활용하기 위해서 월패드 분류를 통한 매뉴얼 제공을 서비스 할 수 있다. 월패드는 제품에 따라 Fig1과 같이 전반사가 있는 제품과 Fig 2 와 같이 전반사가 없는 제품이 있다. 이러한 제품들을 분류할 때 기존의 월패드 데이터셋으로 학습할 경우 월패드 중 전반사가 있는 모델들에서 낮은 분류 정확도를 보였다. 이를 해결하기 위해 본 논문은 데이터 셋을 추가적으로 구축하고 이 데이터 셋 크기에 적합한 사전 학습된 모델들을 이용해 전반사가 있는 월패드 분류의 성능을 향상 시켰다.

등을 고려하여 촬영하였다. 촬영자의 위치는 총 월패드를 기준으로 정면, 상하좌우, 대각 4방향으로 카메라를 조금씩 이동하며 촬영을 진행하였다. 월패드가 꺼져있을 경우 월패드의 표면이 전반사 되어 다른 물체가 반사되어 월패드에 비춰지는 경우가 있다. 실내에서 주로 촬영되는 특성상 플래시가 터지는 경우가 있는데 이 경우 플래시가 월패드 표면위에 반사된다. 이러한 경우도 고려하여 촬영해 데이터를 생성하였다. 이렇게 생성된 데이터는 각 클래스별로 약 2700장이며 총 데이터는 5개의 클래스, 13300장의 데이터를 생성하였다.

II. The Proposed Scheme

1. 학습 데이터 셋 구축

기존의 데이터셋은 한 클래스당 200장 내외로 총 945장의 데이터가 있었다. 추가적인 데이터 셋 구축을 하기 위해서 직접 다양한 환경을 가정하여 촬영하여 데이터를 수집 하였다. 일반적으로 월패드는 가정 집 벽에 걸려있기 때문에 벽의 문양과 색상 등과 촬영자의 위치



Fig. 1. 전반사가 있는 월패드.



Fig. 2. 전반사가 없는 월패드

2. 실험

모든 실험은 수집된 데이터를 train set 70%, validation set 20%, test set 10%로 나누어 진행되었다. 또한 과적합을 방지하고자 데이터 증강기법을 이용해 리사이징, 이동, 뒤집기 등의 기법을 사용하였다. 다만 크롭은 제외하였다.

2.1 전이 학습

본 실험에서는 vgg16[1], vgg19, ResNet50[2], MobileNet[3]을 이용해 전이학습을 실행한다. 위 모델들은 대규모 데이터 셋인 ImageNet 데이터를 이용해 사전 학습 (pre-trained) 되었으며 학습데이터는 네트워크를 통해 특성을 추출한다. 이 때 모델들의 분류기 (classifier)를 제외한 부분은 추가적으로 학습하지 않고 마지막 분류기만 학습 데이터의 추출된 특성을 추가적으로 학습한다. 분류기는 완전 연결 계층(fully connected layer)과 평균 풀링 계층 (Global average pooling), 두 가지 구조를 각각 사용해 비교했다.

2.2 실험 결과

실험 결과는 Table 1과 같다. 기존의 데이터 셋을 CNN을 이용해 분류한 결과는 59.8% 였으며 그 중 전반사가 있는 모델은 약 40%로 전체 정확보다 낮은 정확도를 보였다. 데이터셋을 추가적으로 구축하고 사전 학습을한 모델로 실험한 결과 모든 모델에서 90% 이상의 성능을 보였다. 분류기를 완전 연결층으로 사용하였을 경우에는 VGG16이 94.4%로 가장 좋은 성능을 보였고 분류기를 평균 풀링 계층으로 사용하였을 때는 ResNet50이 96.8%로 가장 좋은 성능을 보였으며 이는 전체에서도 가장 좋은 성능이다.

Table 1. 모델에 따른 분류 정확도.

		Classifier	
		Full Connected Layer	Global Max Pooling
CNN		59.8	-
Transfer Learning	VGG16	94.4	95.2
	VGG19	94.2	95.3
	ResNet50	91.8	96.8
	MobileNet	92.3	93.4

III. Conclusions

월패드를 딥러닝으로 분류함에 있어서 월패드 제품중 전반사가 있는 제품에서 그 성능이 매우 낮아 어려움이 있었다. 본 논문은 이를 해결하기 위해 추가적으로 데이터 셋을 구축하고 데이터 셋 크기에 적합한 전이 학습을 진행하였고 그 결과 ResNet50 + Global Pooling layer의 구조가 정확도 96.8%로 기존의 59.8%의 성능에서 크게 성능 향상을 이뤘다.

향후 사용자들의 데이터가 쌓이고 모델을 추가하여 데이터 셋을 확장하여 더 많은 모델을 분류할 수 있게끔 추가적인 연구가 필요할 것으로 보인다.

ACKNOWLEDGEMENT

"본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학CT 연구센터육성지원사업의 연구결과로 수행되었음" (IITP-2017-0-01642)

REFERENCES

- [1] K.Simonyan and A.Zisserman. "Very deep convolutional networks for large-scale image recognition". In ICLR (The International Conference on Learning Representations), 2015
- [2] He et al. "Deep Residual Learning for Image Recognition". In IEEE Conference on Computer Vision and Pattern Recognition. 2016.
- [3] Andrew G. Howard et al. "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications". CoRR, abs/1704.04861, 2017.