

웹 크롤링과 전이학습을 활용한 이미지 분류 모델

Image Classification Model using web crawling and transfer learning

이 주 혁*, 김 미 희**

Lee-JuHyeok*, Kim-Mi Hui**

Abstract

In this paper, to solve the large dataset problem, we collect images through an image collection method called web crawling and build datasets for use in image classification models through a data preprocessing process. We also propose a lightweight model that can automatically classify images by adding category values by incorporating transfer learning into the image classification model and an image classification model that reduces training time and achieves high accuracy.

요 약

딥러닝의 발전으로 딥러닝 모델들이 이미지 인식, 음성 인식 등 여러 분야에서 활발하게 사용 중이다. 하지만 이 딥러닝을 효과적으로 사용하기 위해서는 대형 데이터 세트가 필요하지만 이를 구축하기에는 많은 시간과 노력 그리고 비용이 필요하다. 본 논문에서는 웹 크롤링이라는 이미지 수집 방법을 통해서 이미지를 수집하고 데이터 전처리 과정을 거쳐 이미지 분류 모델에 사용할 수 있게 데이터 세트를 구축한다. 더 나아가 전이학습을 이미지 분류 모델에 접목해 카테고리값을 넣어 자동으로 이미지를 분류할 수 있는 경량화된 모델과 적은 훈련 시간 및 높은 정확도를 얻을 수 있는 이미지 분류 모델을 제안한다.

Key words : Data preprocessing, web crawling, CNN, transfer learning, image classification

1. 서론

기계학습 방법 중 사람의 신경 세포처럼 기계가 학습하는 방법을 딥러닝이라고 한다. 이 딥러닝이 개발된 이후부터 이미지 인식, 음성 인식 등 미디어 관련 데이터 처리나 다양한 분야에서 사용된다. 이미지 인식 분야에서는 딥러닝 방식 중 합성곱 신경망(CNN: Convolutional Neural Network)을 이용하는 방법이 많이 사용된다.

CNN은 인공 신경망과 합성곱 신경망을 여러 층으로 쌓아 만든 모델로 입력값의 특징들을 추출해 얻은 특성을 이용해 결과값을 매칭시키는 흐름을 가진다[1]. 딥러닝과 CNN이 좋은 성능을 보이려면, 대형 데이터세트가 필수적이다. 자신이 원하는 카테고리의 이미지 데이터세트를 구하기에는 많이 시간이 필요하며, 직접 데이터 세트를 만들기에는 많은 시간과 노력이 필요하다[2]. 이런 CNN을 포함한 딥러닝을 학습시키기 위해서 대용량 데이터세

* Dept. of Computer Science and Engineering, Hankyong National University

★ Corresponding author

E-mail : mhkim@hknu.ac.kr, Tel : +82 31-670-5167

※ Acknowledgment

This research was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No.2018R1A2B6009620)

Manuscript received Nov. 9, 2022; revised Dec. 18, 2022; accepted Dec. 19, 2022.

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.

트를 사용하면 데이터에 대한 학습을 더욱 많이 할 수 있어 딥러닝에서 이점이 있다. 이에 선행 연구인 [3]에서는 대형 데이터셋 수작업을 간소화시키기 위해 웹 크롤링이라는 기술을 통해 이미지 수집 방법을 제안하였고, 자신이 분류하고자 하는 카테고리의 이미지를 웹 크롤링을 통해 수집하며, 전처리 작업을 거쳐, 전이학습을 적용한 이미지 분류모델에 더 적은 훈련 시간과 정확도를 높이는 것을 목표로 한 이미지 분류 모델을 제안하였다. 그러나, 전처리과정 중 이미지의 특징 손실이 발생하고 CNN 모델 성능이 부족하여, 본 논문에서는 선행연구인 [3]의 모델을 보완하여 전처리과정과 분류 모델을 강건화한 모델을 제안한다. 또한, 제안한 모델의 성능을 보이기 위해 CNN과 이미지 분류모델을 비교 실험하여 성능 향상을 보인다.

본 논문에서는 웹 크롤링을 이용해 데이터 세트의 이미지를 수집하고, 전처리과정을 통해 카테고리 작업을 완료한다. 데이터셋의 유효성을 확인하고자, 이미지 인식 분야에서 많이 사용 중인 CNN을 통해 확인하고자 한다. 이미지 데이터 수집을 자동화하고 완료된 데이터 세트를 자동으로 분류할 수 있는 이미지 분류모델을 만든다. 더 나아가 모델의 경량화를 위해서 전이학습을 통해 훈련시간의 감소와 높은 정확도를 목표로 이미지 분류모델을 제안한다.

서론에 이어 2장에서는 제안 기법에 사용된 관련 기술에 대한 배경 지식을 소개하고, 3장에서는 전처리과정과 분류모델 구조를 제안한다. 4장에서는 실험결과를 분석하고, 마지막으로 결론 및 향후 연구를 제시한다.

II. 배경 지식

2장에서는 본 논문에서 제안하는 기법의 배경 지식이 되는 기술들을 설명한다.

1. 웹 크롤러 모델 및 전처리 과정

컴퓨터나 온라인 웹 상에 수많은 비정형 데이터를 분석 및 연구하는 것을 빅 데이터 기술이라고 하며, 빅 데이터 기술도 발전 중이다[4]. 이 빅 데이터 기술 중 웹 상에 퍼져 있는 비정형 데이터를 수집하는 기술을 크롤링이라 부르고 이를 자동화 시켜 시스템처럼 구현한 것을 크롤러라고 한다. 크롤링 중에서도 웹 상에서만 데이터를 추출, 수집하는 것을 웹 크롤링[5]이라고 한다. 웹 크롤링은 기술의 특성 상 비정형 데이터를 포함한 데이터들을 수집한다.

웹 크롤러를 통해서 얻은 데이터들을 바로 CNN 모델의 입력값으로 사용할 수 있는 것은 아니며, 바로 전처리 과정이 필요하다. 이 전처리과정에서는 모델 입력값에 맞춰 데이터 크기 조절, 부족한 데이터 증강 등 여러 작업을 진행할 수 있다. 본 논문에서는 웹 크롤러 특성상 여러 데이터의 형태가 분포된 웹상에서 자료를 수집하기에 다양한 데이터 형태를 똑같이 정제할 필요가 있다. 따라서 형식과 크기를 모델에서 정한 입력값과 같게 데이터를 정제한다. 또한 크롤러를 통해 많은 자료를 수집해도, 이미지 분류모델 특성상 데이터가 많으면 많을수록 모델의 가중치 즉 학습정확도가 높아지기에 데이터를 부풀리는 작업도 중요하다. 본 논문에서는 이미지 데이터를 회전하거나, 이동시키거나, 축소, 뒤집기 등을 통해서 하나의 이미지를 여러 개의 이미지로 부풀릴 수 있게 된다. 전처리과정에 대한 자세한 내용은 3장의 전처리 모델에서 자세히 그 과정을 서술하고자 한다.

2. CNN

CNN은 1980년대부터 이미지 처리 분야에 사용되었다. CNN에서 가장 중요한 구성 요소는 합성곱 층(Convolutional layer)으로, 특징은 이미지 내의 픽셀들을 바탕으로 합성곱 층 계산에서 픽셀들의 특징 즉 특성에 집중을 하게 되고, 이 특징들을 바탕으로 합성곱 층 연산 중에 계산을 점점 거치면서 고수준으로 특성들을 조합 해, 이미지 내의 특성을 파악하고, CNN은 이 이미지 특성들을 통해 인식률을 높게 측정할 수 있게 한다 [6]. CNN은 이 합성곱 층 이외에도 커널, 패딩, 필터 등 여러 층으로 구성이 되어있다. 본 논문에서 사용한 CNN의 구조와 요소는 3.2절 이미지 분류모델에서 자세히 설명하고자 한다.

또한, 인공신경망에서 중요한 활성화함수는 입력 신호의 총합을 출력 신호로 변환하는 함수이다. 본 논문에서는 CNN에 속한 층들이 계산을 할 수 있도록 신호를 전달하는 역할을 하여 이전 층들의 결괏값을 올바르게 전달하는 요소이다. 활성화 함수는 층이 많아질수록 복잡해지는 계산들을 정렬해주는 역할이기에 인공신경망에서 빠질 수 없는 요소이다. 사용한 활성화 함수와 그 역할을 3장에서 서술하고자 한다.

본 논문에서는 웹 크롤링을 통해 생성된 데이터셋을 검증하기 위해서 이미지 처리 부분에서 많이 활용하는 CNN을 사용한다. CNN은 전이학습의 기반으로만 사용하고, 전이학습으로 생성된 이미지 분류 모델을 통해 이미지 분류의 정확도와 훈련 시간을 비교한다.

3. 전이학습

딥러닝 모델을 제작하다 보면 모델끼리 유사한 작업을 하는 경우가 생기게 되는데, 이런 경우 비슷한 모델들은 하위층에서 비슷한 문제를 해결할 수 있는 층들이 있고, 이 층들을 재사용하여 처음부터 다시 훈련하는 불필요함을 없애주는 기술을 전이학습이라고 한다. 이 전이학습은 모델간 유사한 작업을 할수록 더 많은 하위 층들을 공유할 수 있으며, 모델끼리 정말 비슷한 작업이라면 모든 층이 공유가능하고 출력층을 바꿔 결과값만 바꿀 수 있는 장점을 가지고 있다[6]. Fig. 1은 비슷한 모델 A와 B가 하위 층을 공유하는 즉, 사전훈련 완료된 층을 공유할 경우의 예시이다.

본 논문에서는 사용자가 원하는 카테고리만 다를 뿐, 하나의 이미지를 분류하는 같은 목적이 있기에 이 전이 학습 기술을 사용할 수 있다. 작업이 유사할수록 많은 하위 층을 공유할 수 있는 전이학습 특징을 이용해 CNN이 처음부터 훈련하는 수고를 덜어 전체 훈련 시간을 줄일 수 있고, 하나의 카테고리에 대해서 더 많이 학습도 할 수 있으므로 분류 정확도를 높일 수 있는 장점을 이용하기 위해 전이학습 기술을 사용한다.

전이학습을 거쳐서 이미지 인식 모델을 경량화시킬 수 있다. 모델 층의 수가 줄고, 가중치들이 학습된 상태에서 넘어갔기 때문에 모델은 미세조정 수준의 학습만 진행해 가중치를 재조정할 수 있다. 이를 통해서 사용자는 카테고리만 넣게 되면 자동화를 통해 데이터세트도 얻고, 이미지 분류를 할 수 있는 모델을 통해 결과값까지 얻을 수 있다.

4. 기존 연구

이미지 처리 방법 중, 이미지 분류는 이미지 내 특정 사물을 분류하는 처리 방법이다. 이미지 분류 방식도 인공지능과 딥러닝을 통해 많은 연구가 진행되고 있고, 성능을 계속 향상 중이다. 인공지능을 통해 이미지 내의 특징들을 학습하게 되고 이후 학습된 데이터를 바탕으로 이미지를 분류한다. 딥러닝이 발전되면서 컴퓨터 비전에서 뛰어난 결과를 보여주고 있지만, 대용량 데이터세트에 의존하는 문제점이 있다. 이 문제를 해결하기 위해서 레이블이 없는 데이터를 훈련 프로세스에 통합해서 더 적은 레이블로 동일한 결과에 도달하는 것이 일반적이다. 다른 방법으로는 레이블 접근법에서 연속형 속성에 대한 임계값을 특정 값으로 대체해서 레이블을 처리하는 방법이나, 레이블이 학습된 클러스터를 정하고 서로 다른 클러스터를 결합하는 전이학습 같은 방식도 사용한

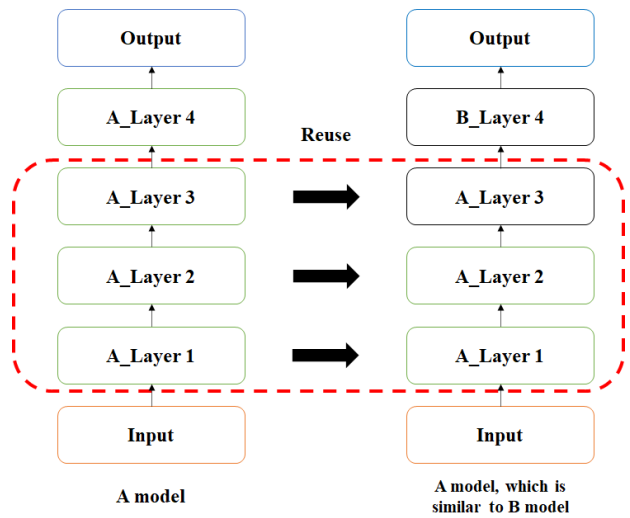


Fig. 1. Example of Reused Pre-Trained Layer.

그림 1. 전이학습의 예시

다. 또한, 이미 정립된 데이터 세트를 변형하여 비슷한 결과값이 나오는 이미지로 재성립하여 사용하기도 한다 [6]-[8].

본 논문에서는 이러한 대용량 데이터 세트 문제를 웹 크롤러로 해결하고자 하고, 앞서 소개한 방법처럼 전이 학습을 이용하여 적은 데이터 세트에서도 성능이 향상할 수 있도록 한다.

III . 제안하는 모델

Fig. 2는 본 논문에서 제안하는 전처리 모델의 전체 흐름도이다. Fig. 2는 최종으로 제안하는 모델로 웹 크롤러 과정, 수집한 데이터 전처리 과정, 이미지 분류 모델을

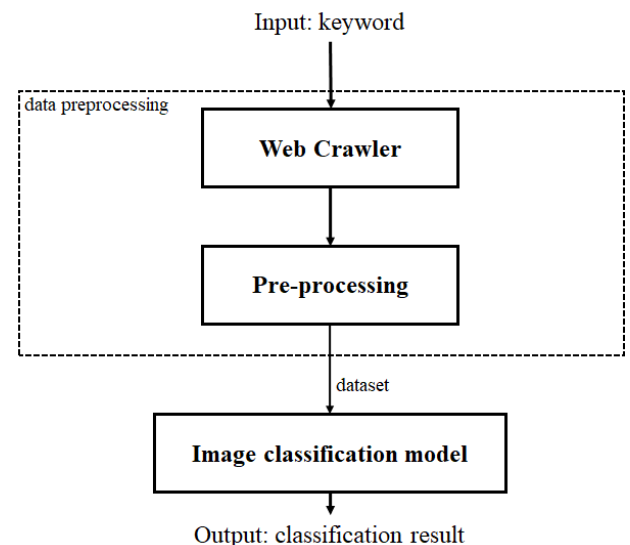


Fig. 2. Flowchart of the proposed model.

그림 2. 전처리모델의 흐름도

모두 합친 모델로, 사용자가 입력값으로 원하는 카테고리만 입력하게 되면 자동으로 이미지 분류를 할 수 있는 모델까지 제공한다.

1. Web Crawler

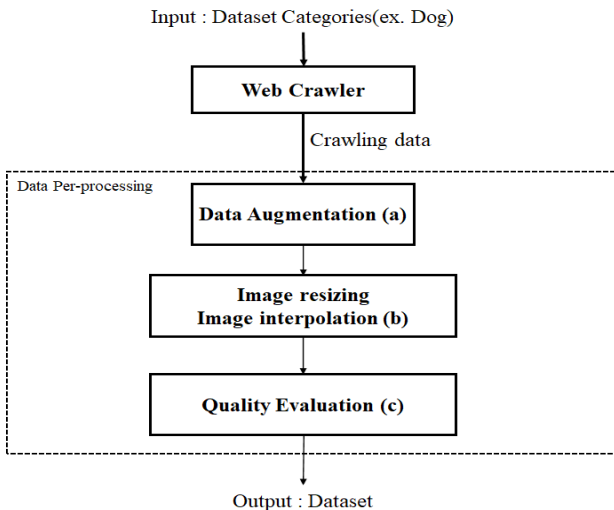


Fig. 3. Flowchart of the web crawler & pre-processing.
그림 3. 웹 크롤러와 전처리과정의 흐름도

본 논문에서 제안하는 웹 크롤러는 Fig. 3처럼 구성되어 있다. 웹 크롤러의 입력 값은 사용자가 분류대상 이미지를 입력으로 받는다. 입력한 카테고리의 이미지를 웹 크롤링을 통해 수집하는데, 웹 크롤링은 selenium[9]과 chromedriver[10]을 이용해 구글의 이미지 검색을 통해 입력값의 이미지 자료들을 크롤링해서 1차 저장을 하게 된다. 1차 저장된 데이터는 데이터 전처리 과정을 거쳐야 이미지 분류 모델에 사용할 수 있게 된다. 전처리 과정을 거치는 이유는 웹 크롤링을 사용했기에 비정형 데이터를 많이 수집했고, 이미지 분류 모델은 정형화된 데이터를 입력값으로 받을 뿐만 아니라 입력값으로 획득한 이미지가 실제 해당 입력값에 매칭되지 않는 이미지가 수집됐을 수도 있기에 전처리 과정을 거쳐야 한다.

크롤러를 통해서 데이터를 수집해도 데이터셋의 이미지가 부족할 수 있다. 이 경우 data augmentation (Fig. 3(a))을 통해서 데이터를 증강한다. 데이터 증강은 Fig. 4처럼 이미지를 회전시키거나, 좌우 반전시키는 등 여러 가지 방법으로 증강할 수 있다. 본 논문에서는 이미지를 회전시키는 경우만 포함시켰다. 이미지를 확대하거나 축소하는 것 방법을 포함시키지 않은 이유는 Fig. 3(b) 과정에서 이미지 조정을 진행하기에 중복되는 절차이기 때문이다.

딥러닝 모델 안의 레이어 네트워크는 정형화된 데이터

구조와 일정한 크기의 이미지로 입력데이터를 사용해 학습하기에 이미지 조절과정을 거쳐 이미지 분류 모델에 입력값으로 사용할 수 있게 조절해줘야 한다. 이미지 크기 조절(Fig. 3(b))은 보간법을 통해서 진행한다. 보간법은 이미지를 축소할 때 픽셀로 이루어진 이미지가 커지거나 작아질 때 생기는(픽셀들을 채우기 위한 고안된 방법에서 나온 기술이다. openCV에서 제공하는 여러 보간법을 통해서 빈 픽셀들을 채웠다. 치수를 늘리면 바이큐빅 보간법을 치수를 줄일 때는 영역 보간법을 이용했다. Fig. 5는 image resizing과 image interpolation의 예시이다.

사용자 카테고리에 맞게 데이터가 완성되면 이미지를 변형하는데 이때 새로운 방법을 통해서 진행한다. Fig. 3(c)의 품질평가 항목을 추가했다. 원래의 데이터를 축소하거나, 팽창시켰을 때 원래의 이미지의 특성이 손상될 수도 있다. 품질평가는 이 특성이 원본 이미지와 얼마나 차이가 있는지 확인할 수 있는 평가 항목으로 이 평가를 통해서 알맞은 보간법을 선택하여 원본 이미지의 특성을 살릴 수 있다[11]. 보간법 특징을 이용해 원본 이미지의 특징을 살리게 된다면, 더욱 효과적으로 이미지 분류 모델의 훈련에 좋은 영향을 주기에 이미지 분류 모델에 삽입하였다.




Fig. 4. Example of Fig. 3(a) data augmentation.
그림 4. 그림 3(a)의 데이터 증강의 예시




Fig. 5. Example of Fig. 3(b) image resizing & image interpolation.
그림 5. 그림 3(b)의 이미지 재조정 및 이미지 보간법의 예시

2. 이미지 분류 모델

이미지 분류 모델에서 전이학습을 사용하기 전 전이학습을 사용하기 위해 비슷한 목적을 가진 CNN 분류 모델 틀을 설계해야 한다. 이 CNN 분류 모델은 전이학습을 통해 사전학습된 하위층을 공유하기 위해서 설계한다. 본 논문에서 사용할 CNN은 resnet-50[12]의 변형으로 이미지의 크기와 이미지 컬러를 흑백으로 변형시킨 후, 전이학습의 기반으로 사용했다. Fig. 6은 본 논문에서 제안하는 이미지 분류 모델이다.

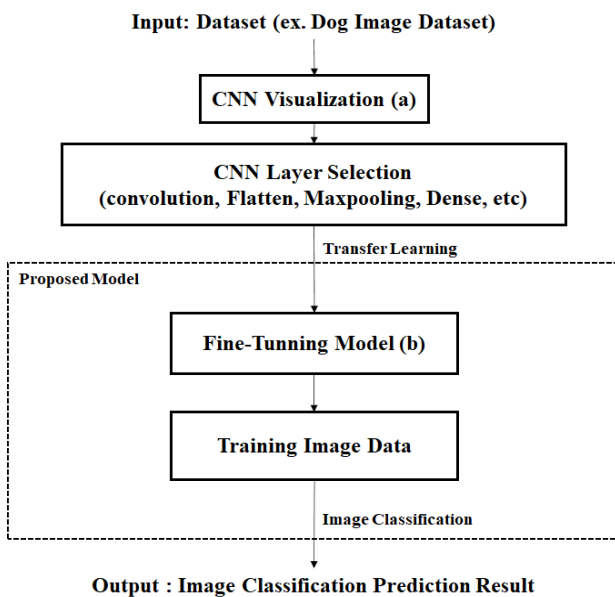


Fig. 6. Processing the proposed classification model.
그림 6. 제안하는 분류모델의 과정

본 논문에서 사용된 주요 층은 합성곱 층, 맥스 풀링 층, 플래튼 층, 은닉층을 사용하였다. 합성곱 층은 합성곱 연산을 통해 이미지 내의 픽셀들의 특징을 추출한다. 맥스 풀링 층은 합성곱층 이후에 주로 위치하게 되며, 맥스 풀링 층을 거치게 되면 합성곱 층을 통해서 얻은 데이터의 크기를 줄이고, 특징을 더 강조하기 위해서 사용이 된다. 맥스 풀링 층 특징은 합성곱 연산처럼 데이터의 특정 영역안에 최댓값을 모아 특징을 더욱 뚜렷하게 만드는 연산을 거친다. 플래튼 층은 합성곱 층과 맥스 풀링 층등을 거친 이미지 데이터를 1차원으로 줄여주는 층이다. 이 플래튼 층을 사용하는 이유는 은닉층으로 데이터를 전달해주기 위해서 사용이 되고, 플래튼 층을 통해서 마지막 은닉층을 거치게 되면 연산과정을 통해서 얻은 결과값을 토대로 CNN이 완성된다.

또한, 중간 활성화 함수가 모델에 포함되게 되는데 활

성화 함수는 2장에서 설명했듯이 이전 층의 결과값을 변환하여 다른 층 뉴런에 신호를 전달하기 위해서 사용했다[13].

본 논문에서는 활성화 함수 relu함수와 softmax 함수를 사용했다. relu함수는 활성화 함수에서 발생하는 현상 중 레이어가 거치면 거칠수록 값이 비이상적으로 작아지게 되는 기울기 손실을 막기 위해서 사용된다. 이 장점 이외에도 이미지 분류 모델의 학습률을 높이기 위해서 사용한다. relu함수는 편미분 즉, 기울기가 1로 일정하므로 가중치 업데이트 속도가 빠르므로 훈련 속도가 다른 활성화함수와 비교해 빠르다.

전이학습 후, 중요 레이어를 옮기는 과정에서 중간중간 특징들을 과도하게 집중하여 학습하기에 과대 적합을 방지하기 위해서 드롭아웃(drop-out)을 사용하였다.

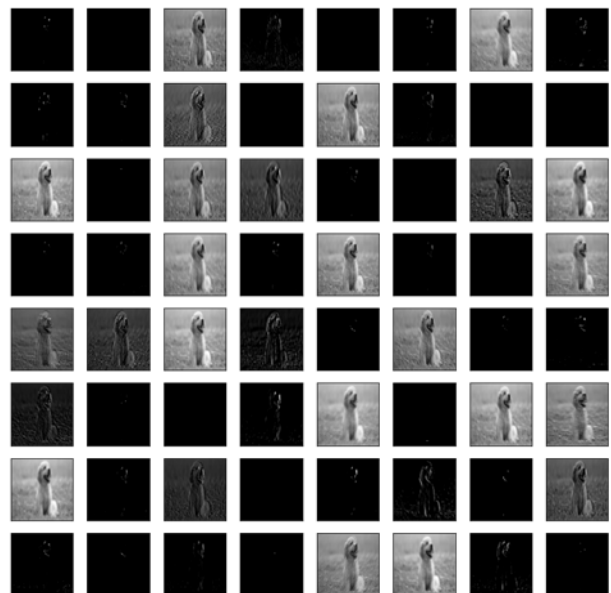


Fig. 7. Visualization of CNN Model Layer.
그림 7. CNN 모델 레이어 시각화

비슷한 작업을 하는 CNN 모델을 바탕으로 전이학습을 통해 짧은 훈련 시간과 높은 정확도를 위해 CNN의 하위층들의 가중치를 전이학습 모델의 한 층으로 삽입을 시켜준 후, 은닉층과 활성화 함수를 통해 결과값을 도출할 수 있게 하는 모델이다.

Fig. 7처럼 레이어의 시각화를 통해서 전이학습의 레이어 선택과정을 더 확실하게 할 수 있다. Fig. 6(a)인 시각화를 통해 각 레이어가 얼마나 학습을 많이하고 있는지, 어떤 가중치가 학습되었는지 파악가능하다. 위의 과정을 거친 후 전이학습 모델을 설계하였다. 모델을 설

계하기 위해 딥러닝 모델 내부 동작에 대해서 알기 위해 위와 같은 작업을 거쳤다. 위의 작업을 통해 커널과 레이어의 학습 과정을 파악할 수 있게 되었다. 레이어의 수와 커널의 수를 줄이는 이유는 레이어와 커널이 많을수록 정확도 향상에 좋으나 너무 줄이게 되면 오히려 정확도가 떨어지는 문제점이 있다. 모델의 경량화를 위해서 레이어와 커널의 중요 부분을 파악하기 위해서이다[14].

Fine-tuning은 기존에 학습되어있는 모델을 기반으로 새로운 목적에 맞게 변형하기 위해 사용한다. 또한 학습된 모델의 가중치를 미세 조정하여 학습시킨다. Fig. 6(b) Fine-tuning을 사용한 이유는 여러 가중치가 학습되었던 기존 CNN을 입력 값에 맞게 모델을 변형하고 가중치를 더욱 학습시키기 위해 사용했다.

IV. 실험 결과

카테고리의 예시로 강아지로 정하고 웹 크롤러를 통해 전 처리된 약 3,000장의 이미지를 데이터셋으로 변환하였다. 훈련데이터와 테스트 데이터를 각각 7대3의 비율로 분리해 실험을 진행했다. 실험 모델에 입력 값으로 넣기 전 전처리 모델을 거쳐, 데이터 증강과 데이터 포맷 변경을 진행하고 실험을 진행하였다. 실험 모델은 전이 학습 이전의 CNN과 제안 모델 2가지로 비교 실험을 진행하였으며, 모델의 정확도와 훈련 시간을 비교하였다. Fig. 8은 Fig. 7에서 진행한 모델레이어 시각화를 통한 레이어 선택과정을 거치고 최종 제안 모델의 레이어 훈




Fig. 8. Visualization of proposed Model Layer.
그림 8. 제안하는 모델 레이어 시각화

련 결과를 시각화한 이미지이다. Fig. 7과 비교하면 더 다양한 레이어에 가중치와 훈련이 잘된 것도 확인할 수 있다. 위에서 전이학습의 기반으로 사용된, resnet50을 CNN으로 표기해 실험을 진행하였다.

Fig. 9와 Fig. 10은 테스트 데이터 세트를 전이학습에 사용되기 전 CNN(resnet50)과 제안 모델의 정확도와 훈련 시간을 비교했다.

Fig. 9의 정확도 결과로는 CNN이 0.95의 정확도를 제안 모델은 0.97의 정확도를 얻었다. 제안모델이 2%의 정확도가 향상했으며 선행 연구[3]의 정확도였던 0.6보다 약 61% 상승했다. 정확도가 높아진 이유는 CNN과 비교해 제안 기법이 입력 데이터를 Fig. 6(b)의 Fine-tuning을 거쳤기 때문이다. 제안 기법 모델이 새로운 목적에 맞게 변형되고 이미 학습된 CNN의 가중치를 미세하게 조정하여 학습을 시켰기 때문에 정확도가 향상했다.

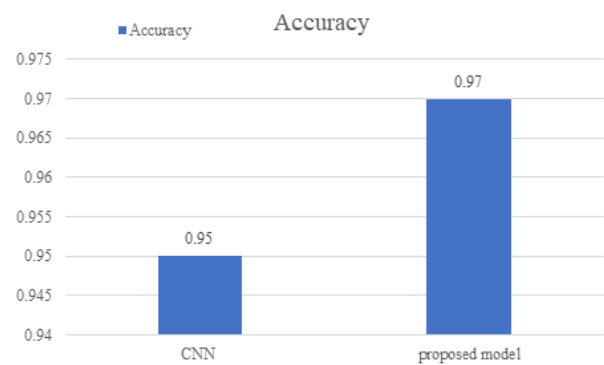


Fig. 9. Accuracy.
그림 9. 정확도 비교

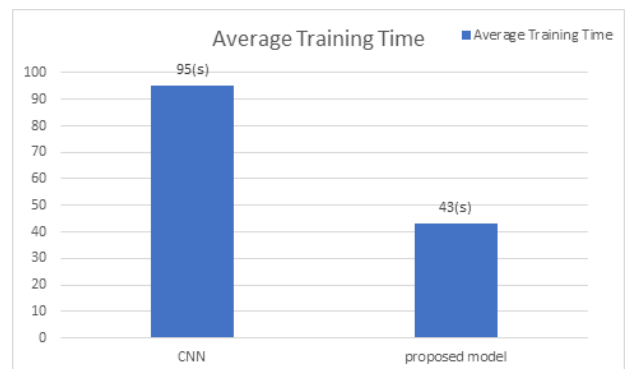


Fig. 10. Average Training Time.
그림 10. 평균 훈련시간 비교

Fig. 10에서 보이는 것처럼 훈련 시간의 결과로 CNN은 평균 95초의 시간이 제안 모델은 평균 43초의 시간이 걸렸다. 훈련 속도가 빨라진 이유 또한 CNN처럼 처

음부터 데이터를 학습하는 것이 아니기에 모델 훈련에 걸리는 시간이 감소했다. 기존 CNN보다 전이학습을 통해 제안 모델은 처음부터 훈련하지 않고, 기존 CNN의 가중치로만 학습하며 데이터 전처리까지 완료하기에 새로 CNN을 설계하고 데이터를 정제하는 과정이 대폭 축소가 된다.

Fig. 11은 제안 모델의 학습과 검증 데이터에 대한 손실값 비교의 그래프다. 훈련을 진행하지 않은 epoch 0에서도 높은 정확도와 적은 손실값을 보여주며, epoch가 많이 진행될수록, 더 높은 정확도와 낮은 손실값을 보여준다. 제안하는 모델을 사용함으로써 사용자는 모델을 많이 훈련할 필요도 줄어들어 사용자 카테고리만 입력하게 되면 높은 정확도와 낮은 손실 값을 제공한다.




Fig. 11. Training and validation Loss.
그림 11. 훈련과 검증 손실값 비교

V. 결론 및 향후 연구

본 논문에서는 자동화된 데이터 구축과 이미지 분류 모델을 제안하였다. 전이학습을 이용해서 하나의 카테고리에 대해서 학습된 가중치들이 추후 다중클래스 이미지 분류 모델을 원할 때도 학습한 카테고리들을 그대로 넘겨주어 높은 정확도와 낮은 손실 값을 제공하고, 다중 이미지 분류도 가능하게 하였다.

향후 연구로서 웹 크롤링을 통해서 데이터를 얻다 보니, 웹사이트에서 무분별한 크롤링을 대비해 한 번에 얻을 수 있는 데이터 수를 제한하거나 데이터 형식을 바꾸는 현상이 있어 데이터 수집에 어려움이 있었는데, 이 문제를 해결할 방안을 연구하려 한다. 이미지 내의 노이즈 제거를 통해 이미지 학습에 불필요한 노이즈를 제거함으로써 학습효과를 높이고, 이미지를 흑백으로 변환할 필요 없이 컬러와 흑백을 모두 분류할 수 있는 모델을 설계할 계획이다.

References

- [1] S. Y. Ahn, Y. M. Park, E. J. Lim, E. J. Lim, W. Choi, "Trends on Distributed Frameworks for Deep Learning," *Electronics and Telecommunications Trends*, Vol.31, No.3, pp.131-141, 2016.
- [2] H. Kwon, Y. C. Kim, "Adversarial Case Technology Trends for Deep Learning Models," *Institute of Information Security and Cryptology*, Vol.31, No.2, pp.5-12, 2021.
DOI: 10.1016/j.eng.2019.12.012
- [3] J. H. Lee, H. M. Kim "Automated Image Classification Model Using Web Crawling," *Proceedings of the Korea Information Processing Society Conference*, pp.719-722, 2021.
DOI: 10.3745/PKIPS.y2021m11a.719
- [4] J. S. Kim, "A consideration on Big Data Utilization and Related Technologies," *Review of Korea Contents Association*, Vol.10, No.1, pp.34-40, 2012.
- [5] D. M. Seo, H. M. Jung, "Intelligent Web Crawler for Supporting Big Data Analysis Services," *The Journal of the Korea Contents Association*, Vol.13, No.12, pp.575-584, 2013.
DOI: 10.5392/JKCA.2013.13.12.575
- [6] Aurelien Geron, "*Hands-On machine Learning with Scikit-Learn, Keras & TensorFlow 2nd Edition*," O'Reilly Media, 2019.
- [7] V. H. Marin H. george, V. O. Elena. "A new generation of the IMAGIC image processing system," *Journal of structural biology*, Vol.160, pp.17-24, 1966. DOI: 10.1006/jsbi.1996.0004
- [8] L. Schmarje, M. Santarossa, S. -M. Schröder and R. Koch, "A Survey on Semi-, Self- and Unsupervised Learning for Image Classification," *in IEEE Access*, Vol.9, pp.82146-82168, 2021.
DOI: 10.1109/ACCESS.2021.3084358
- [9] "Selenium", <https://www.selenium.dev/ko/>, 2021.
- [10] "Chromedriver", <https://sites.google.com/a/chromiumorg/chromedriver/>, 2021.
- [11] Z. Cui, Z. Gan, G. Tang, F. Liu, X. Zhu, "Image Signature Based Mean Square Error for image Quality Assessment," *Chinese Journal of*

Electronics, Vol.24, No.4, pp.755-760, 2015.

DOI: 10.1049/cje.2015.10.015

[12] K. He, X. Zhang, S. Ren, J. Sun "Deep Residual Learning for image Recognition," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.770-778, 2016.

DOI: 10.48550/arXiv.1512.03385

[13] S. W. Park and D. Y. Kim, "Comparison of Image Classification Performance by Activation Functions in Convolutional Neural Networks," *Journal of Korea Multimedia Society*, vol.21, no.10, pp.1142-1149, 2018.

DOI: 10.9717/kmms.2018.21.10.1142

[14] J. B. Kong and M. S Jang "Association Analysis of Convolution Layer, Kernel and Accuracy in CNN," *Journal of the KIECS*. vol.14, no.6, pp.1153-1160, 2019. DOI: 10.13067/JKIECS.2019.14.6.1153

BIOGRAPHY

Lee-Ju Hyeok (Member)



2022 : BS degree in Computer Science and Engineering, Hankyong National University
 2022~present : MS student in School of Computer Engineering & Applied Mathematics, Hankyong National University

Kim-Mi Hui (Member)



1997 : BS degree in Computer Science and Engineering, Ewha Womans University.
 1999 : MS degree in Computer Science and Engineering, Ewha Womans University.

1999~2003 : Researchers at Switching & Transmission Technology Lab.(ETRI)

2007 : Ph.D. degree in Computer Science and Engineering, Ewha Womans University

2009~2010 : postdoctoral researcher of the department of computer science, North Carolina State University

2011~present : School of Computer Engineering & Applied Mathematics, Computer System Institute, Hankyong National University.