

데이터 확장과 전이학습을 이용한 독초 분류 시스템

김민제*, 이수민*, 박주찬*, 이혜원*, 권찬민*, 원일용*

*서울호서직업전문학교 사이버해킹보안과

e-mail : minje0611@naver.com

A Poisonous Plants Classification System Using Data Augmentation And Transfer Learning

Min-Je Kim*, Su-Min Lee*, Ju-Chan Park*, Hye-Won Lee*, Chan-Min Kwon*, Il-Young Won*

*Dept. of Cyber Hacking Security, Seoul Hoseo Vocational College

요 약

최근 5년간 식용 나물과 독초를 구별하지 못한 채 섭취하여 다수의 환자가 발생하였다. 본 논문에서는 인체에 치명적인 결과를 일으킬 수 있는 독초를 CNN 을 통해 분류하는 시스템을 제안한다. 부족한 양의 샘플 데이터는 데이터 확장 기법을 통해 확보하였고, 연구에 사용된 하드웨어의 한계를 극복하기 위해 전이학습을 적용하였다. 실험은 데이터 확장과 전이 학습 적용 여부에 따라 4 가지 유형별로 진행되었으며, 각 유형은 20 회씩 반복한 테스트의 결과를 종합하여 평균을 내었다. 이와 같은 실험에서 의미 있는 결과를 얻었다. 본 논문의 시스템을 이용한 독초 섭취 사고의 예방이 기대된다.

1. 서론

최근 딥러닝에 대한 사람들의 관심이 매우 높아졌다. 딥러닝은 방대한 데이터를 분석해 이들의 차이점을 가려내고 유사한 것들을 분류하는데 강점을 지니고 있다. 이러한 딥러닝은 교통, 금융, 영상, 게임 등 다양한 도메인에서 실험되고 있으며, 일부 영역에서는 긍정적인 결과를 도출하고 있다[1][2]. 딥러닝이 이와 같은 효과를 내기 위해서는 학습할 데이터가 충분해야 하며, 높은 사양의 하드웨어가 필요하다는 제약이 따른다[3].

독초는 식용 나물과 유사한 부분이 많아서 잘못 섭취하면 위험하다. 식용 나물과 독초를 구분하기 위해서는 전문적인 지식이 요구된다. 그러므로 이러한 독초를 자동으로 분류하는 연구가 필요하다. 독초의 이미지를 다양한 방법으로 가공하여 분류하는 시스템들이 연구되고 있지만, 아직까지 좋은 결과는 발표되고 있지 않다[4].

본 논문은 독초를 분류하는 방법에 관한 연구이다. 접근방법은 딥러닝 알고리즘 중 컨볼루션 신경망(Convolutional Neural Network)을 이용하여 학습하는 방법을 사용한다. CNN 은 다층 인공 신경망의 일종으로 이미지 데이터를 효과적으로 인식하기 위해 제안되었다[5]. CNN 이 효과를 내기 위해서는 학습 데이터가 충분해야 하는데, 일반적으로 확보할 수 있는 독초 이미지의 사례는 적다. 이 문제는 데이터 확


장(data augmentation)이라는 방법을 적용하여 해결하였다. 또한, 일반적인 사양의 하드웨어에서도 학습할 수 있도록 전이학습(transfer learning)을 사용하였다. 제안되는 시스템의 성능은 실험으로 검증하였다.

본 논문의 구성은 다음과 같다. 2 장에서는 관련 연구를 언급하였고, 3 장에서는 제안한 시스템을 설명하였다. 4 장에서는 제안된 시스템의 성능 실험 및 결과분석을 하였고, 마지막 5 장에서는 결론 및 향후 과제를 언급하였다.

2. 관련 연구

2.1 데이터 확장

학습을 위한 데이터의 양이 적으면 학습이 제대로 되지 않을 가능성과 모델의 성능이 낮아질 확률이 높아진다[6]. 이와 같은 문제점을 보완하기 위해 데이터 확장 기법을 사용한다. 데이터 확장은 모델에 대한 오버피팅을 줄이고 학습을 위한 데이터를 개선하는 효율적인 방법이다[7]. 이 기법은 하나의 샘플로 여러 개의 샘플을 사용한 효과를 내기 때문에 학습 시 보다 양질의 결과를 얻을 수 있다[8]. 이미지를 확장하는 방법은 회전, 좌우 이동, 상하 이동, 확대-축소, 수평 뒤집기, 수직 뒤집기 등이 있다.



(그림 1) Data augmentation algorithm

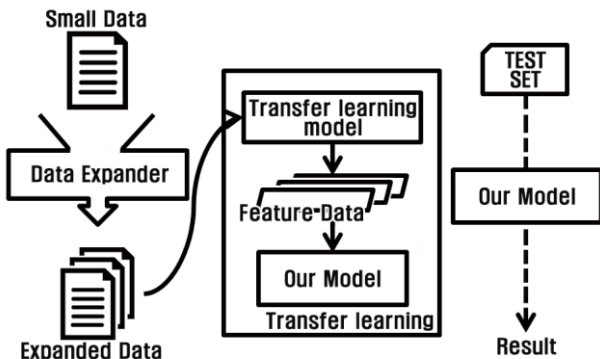
2.2 전이학습

전통적인 머신러닝 알고리즘은 독립적으로 학습하는 반면, 사람은 이전의 경험을 바탕으로 더 쉽게 학습한다.

전이학습은 사람의 학습방법처럼 여러 학습을 통해 습득한 지식을 전이하기 위한 방법을 개발한다. 이러한 방식은 연관된 작업에 대한 학습의 성능을 향상시킨다[9].

전이학습이란 이미 사전에 학습이 완료된 모델을 이용하여 새로운 모델을 제작하는 방법으로 학습 속도와 성능을 크게 향상시킨다. 공개된 이미지 분류 모델에는 VGGNet, GoogLeNet, AlexNet 이 있다[10].

3. 독초 분류 시스템



(그림 2) The proposed system structure

본 논문에서 제안하는 시스템은 (그림 2)와 같다. 먼저 전처리 단계에서는 수집된 적은 양의 데이터를 데이터 확장 기법을 사용하여 데이터의 양을 확장한다. 확장된 데이터를 사전에 학습이 완료된 이미지 분류기 모델의 입력 데이터로 사용한다. 이미지 분류기 모델을 거친 데이터들은 특징을 추출하는 과정을 거쳐 비교적 정확한 특징을 가진 중간 데이터로 가공된다.

독초의 종류를 판단하는 간단한 분류 신경망을 만들고 앞 단계에서 만들어진 중간 데이터를 학습 데이터로 활용하여 분류 기능을 하는 최종 모델을 완성한다.

다.

실제 테스트 단계에서는 분류하고자 하는 데이터를 만들어진 최종 모델에 입력하여 독초 종류를 판단한다.

4. 실험결과 및 성능평가

제안된 시스템은 tensorflow 기반의 keras 인터페이스에서 python으로 구현되었다.

4.1 데이터 구성

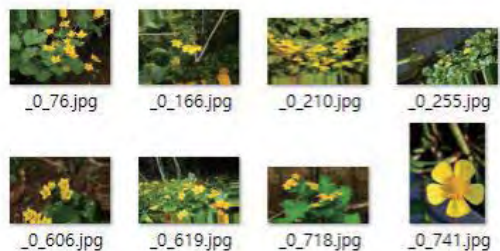
독초 분류를 위한 데이터베이스의 구성은 파리, 노루귀, 독말풀, 동의나물, 박주가리, 애기똥풀, 여로, 으아리, 은방울꽃, 투구꽃 등 10 종류로 이루어져 있다. 그리고 데이터는 종류당 20 장씩, 총 200 장으로 구성된다. 전체 데이터는 훈련 셋 140 장, 검증 셋 40 장과 시험 셋 20 장으로 나누어지며, 훈련 셋의 예시는 다음과 같다.



(그림 3) Example of training data set

4.2 데이터 확장

keras 에서 제공하는 다양한 패키지 중 하나인 ImageDataGenerator 클래스를 이용하여 데이터 셋을 각각 10 장씩 총 2000 장으로 확장한다. 이 클래스 안의 파라미터 값들을 조정하여 이미지 데이터를 변형하고, 유사한 특징들을 가진 이미지 데이터를 추가로 확보한다. (그림 4)는 확장된 데이터의 예시이다.

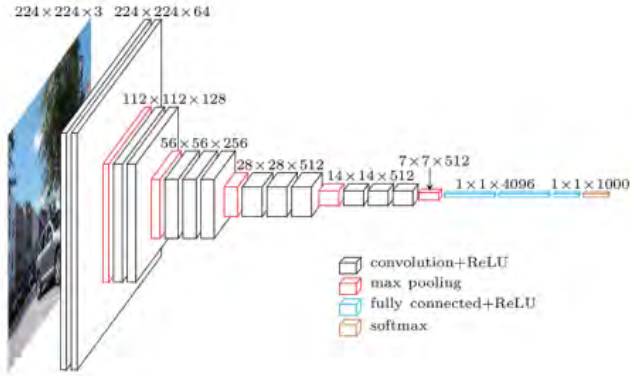


(그림 4) Extended training data set

4.3 전이학습

본 실험에서는 ImageNet 데이터베이스에 전이학습 모델인 VGG16 모델을 사용하여 구현하였다. VGG16 은 16 개의 컨볼루션 레이어, 5 개의 max pooling 레이어 그리고 soft max 레이어로 구성되어 있다[11].

입력은 VGG16 의 224 x 224 x 3 의 입력층을 그대로 사용하였고, 특징 출력층은 7 x 7 x 512 의 max pooling 레이어를 사용하였다.



(그림 5) VGG16 model structure

추출된 특징 데이터를 학습하기 위해 7 x 7 x 512 형식의 데이터를 입력으로 받는다. 입력 받은 데이터는 5 개의 층과 Dropout 으로 이루어진 모델을 거쳐 분류하고자 하는 10 가지의 독초인지 확인한다.

4.4 실험 및 결과

성능 분석을 위해 4 가지 유형의 실험을 시행하였다. 첫 번째 유형은 원본 데이터로 전이학습 없이 CNN 을 사용하여 학습하였으며, 두 번째 유형은 원본 데이터를 확장하여 학습하였다. 세 번째 유형은 원본 데이터에 전이학습만을 사용하여 학습하였고, 마지막 네 번째 유형은 본 논문에서 최종적으로 제시하는 시스템으로써, 전이학습을 사용하여 하드웨어적 문제를 해결하고 데이터 확장을 통해 소량의 데이터를 대량으로 부풀려 학습한 결과이다.

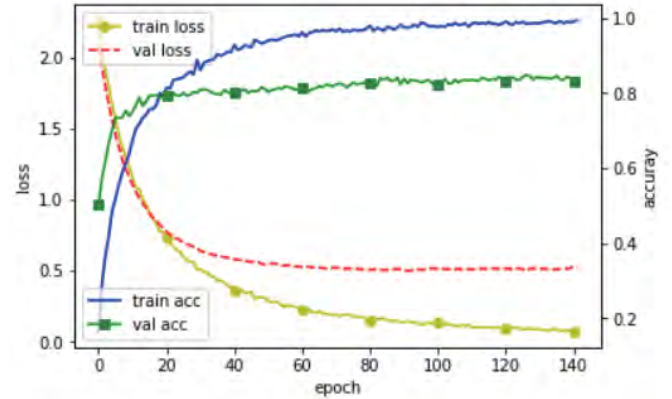
<표 1> Performance comparison between data augmentation and transfer learning

유형	데이터 확장	전이학습	평균 성능 (%)	최고 성능 (%)
1	사용 안함	사용 안함	38.50	42.00
2	사용함	사용 안함	49.25	53.50
3	사용 안함	사용함	59.50	62.25
4	사용함	사용함	75.00	78.5

<표 1>은 데이터 확장과 전이 학습 적용 여부에 따른 실험 결과이다. 유형 별로 20회씩 반복한 테스트

의 결과를 종합하여 평균을 낸 수치를 평균 성능으로 표기하였고, 유형별로 가장 성능이 좋은 결과를 최고 성능으로 표기 하였다. 위의 표에서 나타난 바와 같이, 데이터 확장과 전이학습을 모두 적용한 유형 4가 가장 높은 정확도를 기록하였다.

(그림 6)은 유형 4의 학습과 검증 적중률과 손실을 그래프로 나타낸 것이다.



(그림 6) Real-time monitoring for type 4

train acc 와 loss 는 학습의 적중률과 손실률을 나타내며, val acc 와 loss 는 검증 셋의 적중률과 손실률을 의미한다. val loss 는 점차 낮아지다가 학습이 완료된 시점에서 완만해지며 val acc 는 80 퍼센트에 수렴하는 것을 확인하였다. 이는 모델의 학습이 안정적으로 이루어지고 있음을 의미한다.

5. 결론

본 논문에서는 식용 식물과의 분별이 어려운 독초를 자동으로 분류하는 시스템을 제안하였다. 제안된 시스템은 먼저 소량의 데이터를 확보한 후 데이터 확장 기법을 사용하여 데이터의 양을 늘리고, 일반적인 하드웨어 사양에서도 학습할 수 있도록 전이학습을 적용한 뒤 특징을 추출한다. 추출된 특징을 다시 CNN 을 사용하여 학습한 뒤 CNN 의 최종 계층인 softmax 계층에 적용되어 독초의 종류를 효과적으로 분류할 수 있음을 확인하였다.

실험은 데이터 확장과 전이학습 적용 여부에 따라 4 가지의 유형으로 실시하였다. 실험의 결과, 유형 1 보다 유형 3 이 더 높은 정확도를 기록한 것을 통하여 전이학습이 하드웨어적 문제점을 보완할 뿐만 아니라 성능개선에도 영향을 미친다는 것을 알 수 있다.

따라서 본 논문에서 제안하는 시스템을 통해 등산객들이나 일반인들이 식용 나물과 독초를 오인하여 발생하는 사고 발생의 예방이 기대된다.

향후 과제는 다음과 같다. 다양한 전이학습 모델을 사용하여 그 결과를 비교 분석하는 작업, 하이퍼 파라미터를 좀 더 최적화하는 실험, 독초의 종류와 원본 데이터의 양을 늘리는 작업이 필요하다.

참고문헌

- [1] Ku Donggyun, "Taxi Passengers Demand Prediction using Deep Learning", Department of Transportation Engineering, Graduate School of The University Of Seoul, December 2017
- [2] Sung, Jae-Kyung, Park, Sang-Min, Sin, Sang-Yun, Kim, Yung-Bok, and Kim, Yong-Guk, "Deep learning based image retrieval system for O2O shopping mall platform service design ", Journal of digital convergence, vol. 15, no. 7, pp.213–222, Jul. 2017.
- [3] Jung woo geun, "Hardware system and Software library for deep running", Communications of the Korean Institute of Information Scientists and Engineers, v.34 no.9, 2016, pp.10 – 20
- [4] Seong-Jung Kim, Hwi-Yoon Ju, Hyun-Jung Kim, Il-Yong Won, "Automatic Recognition System for Wild edible greens using Leaf External Form", Proceedings of the Korea Information Processing Society Conference, November 2014, pp.980-983
- [5] Yeon-Ho Kim, Sung-Wook Park, Do-Yeon Kim, "Research on Robust Face Recognition against Lighting Variation using CNN", Journal of the KIECS, vol. 12, no. 2, April 2017, pp. 325-330
- [6] Sesong Kim, Seung-Won Jung, "CBIR-based Data Augmentation and Its Application to Deep Learning", Journal of broadcast engineering, vol. 23, no. 3, May 2018, pp.403 ~ 408.
- [7] Junbong Kim, Kisung Seo, "Performance Analysis of Data Augmentation for Surface Defects Detection", The Transactions of the Korean Institute of Electrical Engineers, vol. 66, no. 5, 2018, pp. 669 ~ 674
- [8] Anton Ragni, Kate M. Knill, Shakti P. Rath and Mark J. F. Gales, "Data augmentation for low resource languages", INTERSPEECH 2014.
- [9] Lisa Torrey and Jude Shavlik, "Transfer Learning" in Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods, and Techniques. IGI Global, 2010, ch. 11, pp.242–264.
- [10] Euncheol Kang, Yeongtae Han, Il-Seok Oh, "Mushroom Image Recognition using Convolutional Neural Network and Transfer Learning", KIISE Transactions on Computing Practices, vol. 24, no. 1, January 2018, pp.53-57
- [11] K. Gopalakrishnan, S. K. Khaitan, A. Choudhary, and A. Agrawal, "Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection," Construction and Building Materials, vol. 157, pp. 322–330, 2017