

초중고 교육을 위한 딥러닝 기반 암석 분류기 개발

박진아*, 용환승**†

Development of deep learning-based rock classifier for elementary, middle and high school education

Jina Park*, Hwan-Seung Yong**†

요 약

최근 딥 러닝(Deep learning)을 이용한 이미지 인식 분야의 연구가 활발히 진행되고 있다. 본 연구에서는 육안으로 관찰하여 분류하기 어려운 암석을 이미지만으로 분류하기 위해 딥 러닝 오픈 소스 프레임워크인 Tensorflow 기반의 CNN모델을 사용하여 고등학교 교육과정에서 다루는 암석 18종(화성암 6종, 변성암 6종, 퇴적암 6종)의 이미지를 통해 암석을 분류하는 시스템을 제안한다. 암석의 이미지를 학습시켜 암석을 구별하는 분류기를 개발하여 분류 성능을 확인하였으며 최종적으로 구현한 모바일 어플리케이션을 통해 교실 내 학습 또는 현장체험학습 등에서 학생들의 학습 보조도구로서 사용할 수 있다.

Abstract

These days, as Interest in Image recognition with deep learning is increasing, there has been a lot of research in image recognition using deep learning. In this study, we propose a system for classifying rocks through rock images of 18 types of rock(6 types of igneous, 6 types of metamorphic, 6 types of sedimentary rock) which are addressed in the high school curriculum, using CNN model based on Tensorflow, deep learning open source framework. As a result, we developed a classifier to distinguish rocks by learning the images of rocks and confirmed the classification performance of rock classifier. Finally, through the mobile application implemented, students can use the application as a learning tool in classroom or on-site experience.

한글키워드 : 딥 러닝, 텐서플로우, 이미지 인식, 암석 이미지, 교육

keywords : deep learning, tensorflow, image recognition, rock image, education

1. 서 론

딥 러닝은 최근 이미지 인식과 패턴 인식 등의

연구 분야에 활용되고 있으며 이미지 인식 성능을 향상시키기 위해 다양한 딥 러닝 구조와 모델이 제안되었다[1]. 딥 러닝 기술이 발전하고 이에 대한 관심이 증가하며 얼굴 인식과 같은 사람의 생체적인 특징을 검출할 때도 딥 러닝을 이용한 연구가 수행되었다.

[2-4]의 연구에서, Tensorflow와 딥 러닝 모델

* 이화여자대학교 컴퓨터공학과

** 이화여자대학교 컴퓨터공학과

† 교신저자: 용환승(email: hsyong@ewha.ac.kr)

접수일자: 2019.05.29. 심사완료: 2019.06.15.

게재확정: 2019.06.20.

인 CNN을 통해 얼굴 인식 연구를 수행하였으며 복잡한 환경에서도 기존의 컴퓨터 비전 분야에서 사용한 전통적인 방법보다 높은 인식 성능을 보여주었다. 기존 수작업을 통한 얼굴 인식 방법에서 포즈나 얼굴 표정 등과 같이 통제하기 어려운 상황에서 발생하는 요소들에 의한 어려움을 개선하고자 딥 러닝 방법을 채택하였으며 CNN을 이용한 얼굴 인식 연구 수행을 통해 기존 결과보다 높은 정확성과 인식 성능을 확인하였다.

또한 의료영상 분류에서도 CNN을 사용한 연구가 수행되었다[5]. 각기 다른 폐 질환의 영상들을 대상으로 이를 질병 그룹별로 구별하기 위해 CNN모델을 사용하였는데 실제로 다른 폐 질환의 영상이라도 이미지 내의 높은 시각적 유사성으로 인해 정확하게 분류하는 데 어려움이 있었다. 따라서 폐 이미지에 맞게 CNN모델을 재구성하여 실험하였으며 학습은 지도 학습 알고리즘을 적용하여 진행하였다. 분류 실험 결과, 실험에서 제안한 CNN모델과 SIFT, RBM 등의 기존 방법과의 Recall과 Precision을 비교함으로써 기존의 분류 결과보다 좋은 결과를 보여주었다.

본 연구에서는 GPU환경에서 Google의 오픈소스 프레임워크인 Tensorflow[6]와 CNN모델인 Inception model[7]을 사용하여 딥 러닝을 이용한 암석 분류기를 제안해 학생들의 학습에 보조도구로서 사용할 수 있는 시스템을 개발하는 것을 목표로 하였다.

고등학교 지구과학 교육과정에서 다루는 암석을 분류할 때 암석의 표면과 구성성분 등 여러 가지 특징을 분류 기준으로 정해 분류할 수 있지만 눈으로만 관찰하여 직관적으로 분류하는 것은 쉽지 않기 때문에 본 연구를 진행하게 되었다. 결과적으로 본 논문을 통해 암석을 이미지만으로 분류하는 암석 분류기를 개발하였으며 구현한 모델을 Tensorflow Android 모델에 적용해 모바일 어플리케이션을 구현하여 암석 분류 성능을 확인

하였다.

본 논문의 구성은 다음과 같다. 2장에서는 딥러닝 기반의 암석 분류 모델에 대하여 서술하고 3장에서는 암석 분류 모델을 개발하기 위한 실험 데이터 및 학습 과정에 대하여 설명하고 실험 결과를 확인한다. 그리고 4장에서 결과에 대하여 논의한 후 결론과 함께 논문을 마무리 짓는다.

2. 딥 러닝 기반의 암석 분류 모델

본 실험에서 사용한 Inception model[7]은 이미 이미지넷(ImageNet)[8]의 데이터를 통해 학습된 모델로, 약 1,000여 가지의 물체들을 사물의 이미지를 통해 분류할 수 있도록 학습된 모델이다. 이미지넷 데이터를 통해 학습된 모델에서 학습 데이터의 종류가 만약 1,000개였다면 이 모델 내 마지막 분류 레이어 역시 1,000개를 갖게 된다. 본 연구에서는 암석의 종류 18종을 분류하는 것을 목적으로 하였으므로 모델의 분류 레이어가 18개가 되도록 학습을 진행하였다. 따라서 암석 18종의 이미지 데이터를 통해 학습이 완료된 모델은 18가지의 종류를 구분할 수 있는 softmax type의 분류 레이어가 형성 된다.

학습은 가장 최적의 분류 성능을 갖는 학습 횟수를 찾기 위해 1,000번에서 15,000번까지 수행하였으며 학습을 10,000번 수행하였을 때 Test accuracy가 가장 높았다.

3. 실험

본 장에서는 실험 시스템 환경에 대하여 소개한 후 실험에 사용한 데이터와 학습 과정, 실험 결과에 대하여 자세히 설명한다.

실험은 PC Intel core i7-6700k CPU, Graphic

card Nvidia GeForce GTX 1070 환경에서 진행되었다. 그리고 최종적으로 구현한 어플리케이션은 안드로이드 기기에서 사용할 수 있도록 Tensorflow Android 모바일 환경에서 구현하였다. 실험을 수행한 시스템 구현 환경은 표 1을 통해 자세히 확인할 수 있다.

표 1. 실험 시스템 구현환경
Table 1. experimental system environment

Operating System	Ubuntu 16.04 64bit
CPU	Intel core i7-6700k CPU
Graphic Card	Nvidia GeForce GTX 1070
Language	Python3, Tensorflow 1.8.0
Android system	Android Studio 3.0 SDK version 27 NDK version 12

실험은 GPU환경에서 수행되었으며, 학습이 1,000번 수행될 때 소요되는 시간은 약 7분정도이다.

3.1 실험 데이터

본 실험에서 사용한 학습 데이터는 암석 18종(화성암 6종, 변성암 6종, 퇴적암 6종)의 이미지 데이터로 표 2를 통해 화성암, 변성암, 퇴적암의 대표 암석 이미지를 확인할 수 있다. 암석 분류기의 정확한 학습을 위해 암석의 학습이미지 데이터는 모두 박물관에서 제공하는 이미지를 사용하였다.

표 2. 학습에 사용된 암석의 종류별 대표 이미지
Table 2. typical rock image in training data

종류	이름	이미지
화성암	현무암	
	반려암	
변성암	점판암	
	편마암	
퇴적암	셰일	
	암염	

학습을 시작하기 전 입력 이미지 데이터의 크기는 제각기 다르기 때문에 학습 전 전처리과정 후에 텐서플로우에서 사용하여야 한다. 모든 JPG 형태의 이미지 파일은 이미지 데이터를 텐서플로우에서 사용할 수 있도록 TFRecord[9] 형태로 전처리 후 학습에 사용하였다. 총 학습 데이터 수량은 734장이며, 암석의 종류 별로 사용된 이미지 개수는 표 3과 같다. JPG형태일 때 암석 입력 이미지의 크기는 모두 다르지만 TFRecord 형태로 바뀐 후 모델에 입력 될 때는 3차원 형태의 [299X299X3]크기로 처리되어 입력 후 학습에 사용된다.

표 3. 학습 이미지 데이터 개수
Table 3. quantity of training image dataset

종류	이름	개수(장)
화성암	현무암	73
	화강암	42
	섬록암	39
	안산암	37
	유문암	34
	반려암	37
변성암	편암	34
	편마암	49
	점판암	36
	규암	37
	대리암	39
	혼펠스	35
퇴적암	사암	40
	셰일	51
	역암	40
	석회암	42
	응회암	34
	암염	35

3.2 실험 결과

암석의 이미지를 통해 학습된 모델의 암석 분류 성능을 테스트하기 위해 학습에 사용하지 않은 임의의 암석 이미지와 학습에 이미 사용한 이미지를 이용하여 분류 성능을 측정하였다. 따라서 테스트 데이터[10]는 두 가지로 나누어 실험하였는데, 먼저 학습에 사용하지 않은 이미지와 학습에 사용한 이미지로 나누어 성능을 평가하였다. 학습에 사용하지 않은 테스트 이미지는 각 암석 별 6장씩 구성하여 총 108장으로 구성하였으며, 학습에 사용한 테스트 이미지는 학습 이미지 데이터와 동일하다.

분류 성능을 테스트 한 결과는 표 4, 표 5를 통해 확인할 수 있다. 표 4는 학습에 사용하지 않은 이미지 데이터로 구성된 테스트 데이터로 실험한 결과이고 표 5는 학습에 사용한 데이터를 통해 테스트한 결과이다. 학습한 모델에게 테스트 이미지를 보여주었을 때 정답을 1가지로 정확하게 분류할 수 있는 성능을 Top 1-Accuracy라고 하고 정답 후보군을 3가지로 추려내 3가지 후보군 중에 정답이 검출 될 확률을 Top 3-Accuracy라고 하였다.

각 테스트 데이터 셋을 통해 암석 18종(화성암 6종, 변성암 6종, 퇴적암 6종)에 대하여 모델의 암석구별 및 분류 성능을 실험한 결과, 학습한 이미지를 이용한 실험에서는 모델의 암석 이미지를 통한 학습 결과를 확인할 수 있었으며 학습한 이미지가 아닌 임의의 테스트 이미지를 통한 실험에서는 모델의 실제 분류 성능을 확인할 수 있었다. 또한 표 4와 표 5를 통해서 알 수 있듯이 학습되지 않은 테스트 이미지로 실험했을 때보다 학습에 사용된 테스트 이미지를 통한 실험 결과에서 Top 1-Accuracy, Top-3 Accuracy 모두 성능이 더 높았음을 확인하였다.

표 4. 학습에 사용하지 않은 테스트 데이터 실험 결과

Table 4. result of experiment with test data not used for learning

종류	이름	Top 1 Accuracy	Top 3 Accuracy
화성암	현무암	83%	100%
	화강암	100%	100%
	섬록암	83%	100%
	안산암	0%	17%
	유문암	33%	67%
	반려암	50%	67%
변성암	편암	0%	17%
	편마암	33%	83%
	점판암	17%	50%
	규암	83%	67%
	대리암	0%	17%
	혼펠스	17%	50%
퇴적암	사암	50%	83%
	셰일	100%	100%
	역암	83%	100%
	석회암	33%	67%
	응회암	0%	17%
	암염	100%	100%

실험 결과를 통해 Top 3-Accuracy가 Top 1-Accuracy보다 성능이 더 높은 것을 확인할 수 있다. 암석을 구별할 때 정답을 한 가지로 정의하는 것보다 정답 후보군을 3가지로 추려내는 것

이 비교적 쉽고 정답이 속해있을 가능성이 높기 때문에 Top 3-Accuracy가 더 실험 결과가 좋고 실제로 암석 분류 사용에 효과적이라고 판단하였다.

표 5. 학습에 사용한 테스트 데이터 실험 결과
Table 5. result of experiment with test data used for learning

종류	이름	Top 1 Accuracy	Top 3 Accuracy
화성암	현무암	100%	100%
	화강암	67%	100%
	섬록암	67%	83%
	안산암	83%	100%
	유문암	50%	83%
	반려암	83%	100%
변성암	편암	83%	100%
	편마암	50%	67%
	점판암	67%	100%
	규암	83%	83%
	대리암	83%	100%
	혼펠스	50%	100%
퇴적암	사암	83%	100%
	셰일	100%	83%
	역암	83%	100%
	석회암	67%	83%
	응회암	83%	100%
	암염	100%	100%

학습된 모델의 성능을 테스트 한 실험을 통해

각 암석 별로 분류 정확성을 알아보았다. 먼저 화성암의 실험에서 사람이 육안으로 관찰하였을 때 표면의 특징이 비교적 뚜렷하여 구별하기 쉬운 암석인 현무암, 화강암과 같은 경우 본 연구를 통해 구현한 암석 분류기도 잘 구별해내는 것을 알 수 있었다. 반대로 화성암에서 안산암의 경우 현무암과 같은 암석과 비교했을 때 표면상의 특징이 두드러지지 않아 구별에 혼동을 겪어 암석 분류기를 통한 실험에서 정확성이 낮게 측정되는 것으로 분석하였다. 변성암의 구별에서는 규암의 구별 정확성이 가장 높았으며 편암, 대리암의 구별 정확성은 낮았다. 퇴적암의 경우 외적으로 구별하기 쉬운 특징을 가진 암염과 셰일의 분류 정확성이 가장 높았으며 응회암의 분류 성능은 낮게 측정되었다.

그림 1은 테스트 하는 모습을 나타낸 것으로 Top 3-Accuracy 구현 결과이다. 그림 1에서의 암석은 섬록암의 이미지로, 학습에 사용되지 않은 임의의 테스트 데이터 셋의 이미지 중 하나이다. 테스트 이미지 데이터를 입력하면 하단에 암석의 이름과 그 암석일 확률을 보여주게 된다.



"섬록암(Diorite)" => Probability 88%
 "화강암(granite)" => Probability 6%
 "반려암(Gabbro)" => Probability 2%

그림 1. 암석 분류 테스트 진행 결과
 Fig. 1. result of rock classification test

학습과 테스트가 완료된 모델을 통해 구현한 안드로이드 어플리케이션을 실행시켜 테스트한 화면은 그림 2와 같다. 모바일 기기에 내장된 카메라를 통하여 구별하고 싶은 암석의 실제 표면이나 이미지를 비추면 상단에 학습된 모델이 예측한 암석의 이름과 그 암석일 확률을 보여준다. 그림 2에서 실제로 모바일 기기에 비춘 암석은 혼펠스(hornfels)이며 약 97%의 확률로 혼펠스일 것이라고 예측한 화면을 나타낸다.



그림 2. 암석 분류 어플리케이션 실행 화면
 Fig. 2. execution screen of rock classification mobile application

4. 결론

본 논문에서는 암석을 눈으로만 관찰하여 다른 특징을 고려하지 않고 외관상으로만 분류하기 위해 딥 러닝을 통해 이미지만으로 학습시켜 구별하는 시스템을 제안하였다. Tensorflow기반의

CNN모델인 Inception model을 암석의 이미지를 통해 재 학습시켜 고등학교 지구과학 과정에서 다루는 암석 18종의 이미지를 분류하는 시스템을 구현하고 실제로 테스트하여 성능을 확인하였다. 학습은 GPU환경에서 진행하였으며 학습 시간은 학습이 10,000번 수행되는 데 약 1시간 정도 소요되었다. 실험 결과를 통해 학습된 모델의 분류 성능을 평가하였는데, 화성암, 변성암, 퇴적암의 암석에서 표면의 특징이 뚜렷한 현무암, 암염 등과 같은 암석은 매우 높은 성능으로 구별하는 것을 확인할 수 있었다. 또한 학습되지 않은 테스트 데이터를 이용한 실험에서, 화성암, 퇴적암의 Top 3-Accuracy가 70%가 넘는 것을 확인하여 실제로 사용가능한 인식률로 평가하였다. 따라서 본 논문을 통해 구현된 암석 분류기를 이용해 자신이 알고 싶은 암석을 이미지나 실제 암석의 표면을 통해 쉽게 분류해 낼 수 있을 것으로 예상된다.

본 실험을 통한 결과에서 화성암, 퇴적암의 분류성능에 비해 변성암의 분류 성능이 비교적 낮은 것을 확인할 수 있는데, 이는 학습 이미지 데이터 셋을 구성할 때 박물관 암석 이미지 확보의 어려움으로 학습 데이터의 수량이 적어 학습 성능에 한계가 있었다고 판단하였다. 따라서 이를 향후 연구의 보완점으로 삼았다. 향후 변성암뿐만 아니라 화성암, 퇴적암의 모든 암석의 이미지 데이터를 더 수집하여 학습 데이터 셋의 양을 추가하고 학습 환경과 모델의 계산과정을 개선한다면 학습 성능이 더욱 높아질 것으로 기대한다.

이 논문은 2017년 대한민국 교육부와 한국연구재단의 지원을 받아 수행된 연구임
(NRF-2017S1A5B6066963)

참 고 문 헌

- [1] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton, "Deep learning", nature 521.7553 436, 2015. <https://www.nature.com/articles/nature14539>
- [2] Yuan, L., Qu, Z., Zhao, Y., Zhang, H., and Nian, Q., "A Convolutional Neural Network based on TensorFlow for Face Recognition", IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC) pp.525-529, 2017. <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8054070>
- [3] Zhang, Yin, and Zhi-Hua Zhou, "Cost-sensitive face recognition", IEEE transactions on pattern analysis and machine intelligence, Vol. 32, No. 10, pp. 1758-1769, 2009, <https://ieeexplore.ieee.org/abstract/document/5342435>
- [4] Hu, G., Yang, Y., Yi, D., Kittler, J., Christmas, W., Li, S. Z., and Hospedales, T., "When face recognition meets with deep learning: an evaluation of convolutional neural networks for face recognition", Proceedings of the IEEE international conference on computer vision workshops, pp.142-150, 2015. https://www.cv-foundation.org/openaccess/content_iccv_2015_workshops/w11/html/Hu_When_Face_Recognition_ICCV_2015_paper.html
- [5] Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., and Chen, M., "Medical image classification with convolutional neural network.", IEEE Control Automation Robotics & Vision (ICARCV 2014), 13th International Conference on, pp.844-848, Dec. 2014, <https://ieeexplore.ieee.org/abstract/document/7064414>
- [6] <https://www.tensorflow.org>, 2018.
- [7] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z., "Rethinking the

inception architecture for computer vision”, Proceedings of the IEEE conference on computer vision and pattern recognition, pp.2818-2826, 2016. https://www.cv-foundation.org/openaccess/content_cvpr_2016/html/Szegedy_Rethinking_the_Inception_CVPR_2016_paper.html

- [8] 이미지넷(ImageNet), <http://www.image-net.org/challenges/LSVRC/2012/>
- [9] TFRecord, https://www.tensorflow.org/api_docs/python/tf/data/TFRecordDataset
- [10] 이화여자대학교 자연사박물관, <https://cms.ewha.ac.kr/>

저 자 소 개



박진아(Jina Park)

2012.3-2017.2 국민대학교 컴퓨터공학부 학사
2017.3-2019.2 이화여자대학교 컴퓨터공학과 석사
<주관심분야> 딥 러닝, 추천 시스템



용환승(Hwan-Seung Yong)

1983년 서울대학교 컴퓨터공학과 학사
1985년 서울대 대학원 컴퓨터공학과 공학석사
1985년 - 1989년 한국전자통신연구소 연구원
1994년 서울대 대학원 컴퓨터공학과 공학박사
2002년 IBM T.J. Watson 연구소 방문연구원
1995년-현재 이화여자대학교 컴퓨터공학과 교수
<주관심분야> 객체-관계 데이터베이스 시스템, 멀티미디어 데이터베이스, 데이터 웨어하우징 및 OLAP, 데이터마이닝, 유비쿼터스 컴퓨팅