

2022년 지질자원 데이터 활용 및 인공지능 경진대회 최종 제안서

제목 : YOLO 딥러닝 알고리즘을 활용한 암석 분류 연구

주정헌¹⁾, 이제윤²⁾, 송세훈³⁾, 정희정⁴⁾

I. 서론

1. 연구배경

암석은 형성 요인, 형성 환경 등에 따라 다양한 광물 조성, 조직, 형태와 색을 가질 수 있으며, 동일한 암석 유형에 대해서도 다양한 형태로 나타날 수 있다. 암석 분류는 지질 현장에서 지질학적 형성 환경을 추론하기 위한 기본적인 정보를 제공할 수 있다는 점에서 중요하며, 특히 암석의 형태는 육안으로 확인 가능한 대표적인 암석의 외형적 특징으로, 야외 지질 현장에서 암석의 분류에 있어 중요한 요소이다. 그러나 암석은 실제 자연에서 다양한 형태로 분포하므로, 암석의 형태를 이용하여 암석의 종류를 식별하고 분류하기 위해서는 깊은 지질학적 지식과 경험이 필수적으로 요구된다.

딥러닝 (Deep Learning) 기반 객체 분류 및 탐지 기법은 대규모 데이터로 학습된 인공신경망 (Artificial Neural Network)을 통해 결과를 도출하며, 패턴 인식과 객체 및 이미지 분류에서 우수한 성과를 보인다. 본 연구에서는 동일한 암석임에도 불구하고 다양한 형태를 가지는 야외 현장에서의 암석 분류를 위한 딥러닝 기반의 자동 암석 유형 분류 모델을 제작하고자 한다. 지오빅데이터 오픈 플랫폼에서 제공하는 암석 이미지 자료들을 활용하여 우수한 객체 인식 및 분류가 가능하다고 알려진 YOLO (You Only Look Once) v5 딥러닝 알고리즘 기반의 암석 분류 모델을 생성하였다. 또한, 고성능 GPU를 탑재한 소형 보드인 Jetson Nano 머신에서 획득한 훈련모델을 사용해 실제 촬영한 암석 이미지에 대한 암석 분류 수행을 통해 실제 야외 현장에서의 활용 가능성을 평가하였다.

1) 부산대학교 대학원 지구환경시스템학부 지질환경과학전공 박사과정 (teateahun@pusan.ac.kr)
2) 부산대학교 대학원 지구환경시스템학부 지질환경과학전공 석사과정 (201714133@pusan.ac.kr)
3) 부산대학교 대학원 지구환경시스템학부 지질환경과학전공 석사과정 (sehoon8030@pusan.ac.kr)
4) 부산대학교 대학원 지구환경시스템학부 지질환경과학전공 석사과정 (y333jhhd@pusan.ac.kr)

2. 연구대상

(1) 퇴적암

퇴적암은 형성 조건에 따라 쇄설성, 화학적, 유기적 퇴적암으로 구분 가능하며, 본 연구에서는 외형적 특징으로 구분이 용이한 쇄설성 퇴적암을 주 연구 대상으로 선정하였다. 쇄설성 퇴적암은 풍화와 침식작용을 거쳐 생긴 암석 부스러기인 쇄설성 퇴적물이 유수, 바람, 빙하에 의해 운반되고, 퇴적된 후 오랜 시간 숙성작용을 받아 만들어진 퇴적암이다. 쇄설성 퇴적물은 Udden-Wentworth scale을 통해 입자의 크기를 기준으로 분류할 수 있다 (Wentworth, 1922). 분류는 크게 자갈(Gravel), 모래(Sand), 실트(Silt), 점토(Clay)로 나눌 수 있으며, 입자의 크기가 2mm 이상일 때는 자갈, 0.0625mm - 2mm일 때 모래, 4 μ m - 0.0625mm일 때 실트, 4 μ m 이하일 때 점토로 분류할 수 있다.

Millimeters (mm)	Micrometers (μ m)	Phi (ϕ)	Wentworth size class
4096		-12.0	Boulder
256		-8.0	Cobble
64		-6.0	Pebble
4		-2.0	Granule
2.00		-1.0	Very coarse sand
1.00		0.0	Coarse sand
1/2	500	1.0	Medium sand
1/4	250	2.0	Fine sand
1/8	125	3.0	Very fine sand
1/16	63	4.0	Coarse silt
1/32	31	5.0	Medium silt
1/64	15.6	6.0	Fine silt
1/128	7.8	7.0	Very fine silt
1/256	3.9	8.0	Clay
0.00006	0.06	14.0	

그림 1. 쇄설성 퇴적물의 분류 (출처 : The Planetary society)

퇴적암은 주로 한 종류가 아닌 다양한 크기의 퇴적물을 함께 포함하고 있으며, 퇴적암을 구성하고 있는 퇴적물의 입자 크기와 비율에 따라 크게 역암(Conglomerate), 사암(Sandstone), 이암(Mudrock)으로 분류할 수 있다.

역암의 경우, 입자의 크기가 모래보다 큰 2mm 이상의 자갈 크기의 입자들이 30% 이상 포함되어 있는 퇴적암이다 (Raymond, 1999). 역암에 포함된 조립질의 자갈 모양으로부터 역암과 각력암을 구분할 수 있는데, 역암은 원마도가 각력암보다 좋으며, 자갈 모양의 각진 경우 각력암(Breccia)으로 분류한다.

사암은 1/16mm에서 2mm 크기의 모래 입자들로 주로 구성된 퇴적암이다. 사암을 구성하는 주요 광물들로는 석영, 장석과 암편 등이 있으며, 석영, 장석, 암편, 기질의 함량에 따라 사암을 세분화하여 분류할 수 있다.

이암은 자갈이 30% 이하를 차지하고, 모래 입자보다 더 작은 실트와 점토 입자들이 우세하게 함유되어있는 퇴적암이며, 가장 풍부하게 존재하는 퇴적암으로 전체 퇴적암의 45~55%를 차지한다. 실트와 점토의 구성 비율에 따라 실트암, 이암(mudstone), 점토암으로, 박리성의 유무에 따라 세일로 상세하게 분류할 수 있다. 실트암, 이암, 세일, 점토암은 입자의 크기가 작아 육안으로는 서로 구분하기 힘들며, 입도 분석 후 보다 상세하게 분류할 수 있다.

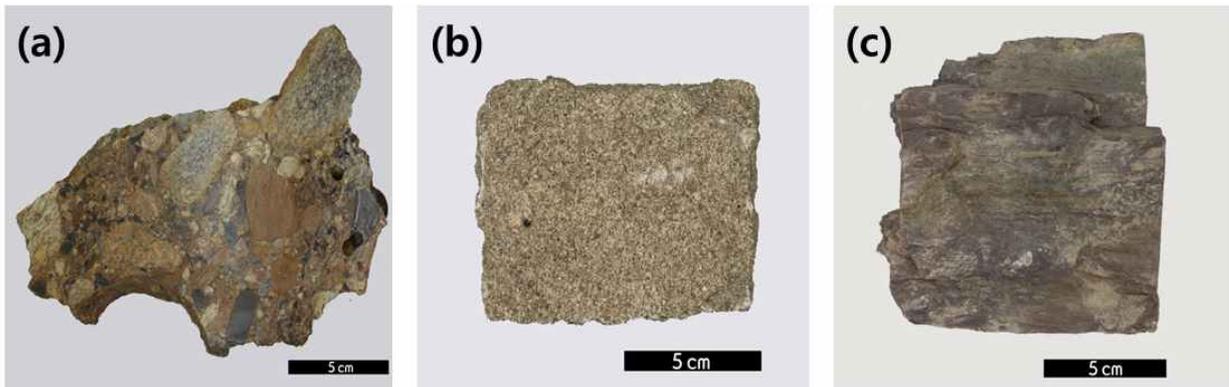


그림 2. 퇴적암 사진.

- (a) 역암 (지오빅데이터 오픈플랫폼, <https://doi.org/10.22747/data.20210421.3697>)
- (b) 사암 (지오빅데이터 오픈플랫폼, <https://doi.org/10.22747/data.20210422.3758>)
- (c) 이암 (지오빅데이터 오픈플랫폼, <https://doi.org/10.22747/data.20210422.3755>)

(2) 화성암 및 변성암

암석은 성인에 따라 퇴적암, 화성암, 변성암으로 분류되며, 자연에서 수많은 종류의 암석들이 존재한다. 본 연구에서는 퇴적암에 화성암 및 변성암을 추가하여 보다 다양한 암석의 분류 모델을 제작하고자 하였다. 우수한 암석 분류 모델을 획득하는 것을 목적으로 두었기 때문에, 외형적 특징이 뚜렷하여 퇴적암과도 외형적 차이가 분명하게 나타나는 암석들을 위주로 선정하였으며, 외형의 특징이 잘 나타나는 암석으로 화성암에 현무암(Basalt), 화강암(Granite), 변성암에 편마암(Gneiss)을 추가 연구 대상으로 선정하였다.

화성암은 마그마가 식어서 만들어진 암석이다. 마그마가 화산 활동 등으로 지표로 분출되어 급히 식으면 화산암이, 지각 심부에서 천천히 식으면 조립질의 심성암이 된다.

현무암은 고철질, 초고철질 화산암 중 가장 풍부한 암석으로 성분적으로 실리카 함량이 45~52%이다. 주로 Ca-사장석과 휘석 및 다양한 기타 광물들로 구성된 세립 내지 비현정질의 고철질 화성암이다 (안건상, 2012). Mg, Fe가 풍부하고, 유색광물을 상대적으로 많이 포함하고 있어 주로 흑색 계통의 어두운색을 띠나, 풍화를 받아 갈색이나 붉은색으로 보이기도 하며, 다공질인 경우도 흔하게 발견된다.

화강암은 K가 풍부한 알칼리장석과 석영을 많이 갖는 암석으로 성분적으로 실리카 함량이 66% 이상인 심성암이다. 상대적으로 밝은 색상의 화성암으로, 화강암을 구성하고 있는 입자들이 충분히 육안으로 볼 수 있을 만큼 큰 것이 특징이다. 지구 표면 아래에서 마그마가 천천히 결정화되어 형성된 심성암 중 하나이기 때문에 현무암과 같은 화산암과 비교하였을 때 입자가 크게 나타난다. 화강암은 주로 석영과 장석으로 구성되며 운모, 각섬석 및 기타 광물들이 소량 포함된다. 이러한 광물성분은 일반적으로 화강암에 담홍색, 분홍색, 회색 또는 흰색을 띠며 암석 전체에서 짙은 검은색의 입자들을 볼 수 있다.

변성암은 높은 온도와 압력에 의해 변성작용을 받아 성질이 변하여 만들어진 암석이다. 편마암은 변성암의 일종으로 중립 내지 조립질인 광물이 한 방향으로 배열되어 편마 조직을 갖는 암석이다. 편마암의 명칭은 비교적 고온에서 형성된 광역변성암에 적용되며 화성기원의 편마암을 정편마암, 퇴적기원의 편마암을 준편마암이라고 한다. 입도가 큰 두 종류 이상의 광물들이 불규칙한 호층을 이루며 편마구조가 나타나는 것이 특징이며, 편마 구조에 따라 안구상 편마암(augen gneiss), 호상 편마암(banded gneiss), 반상변정질 편마암(porphyroblastic gneiss)으로 분류할 수 있다 (Raymond et al., 2003).

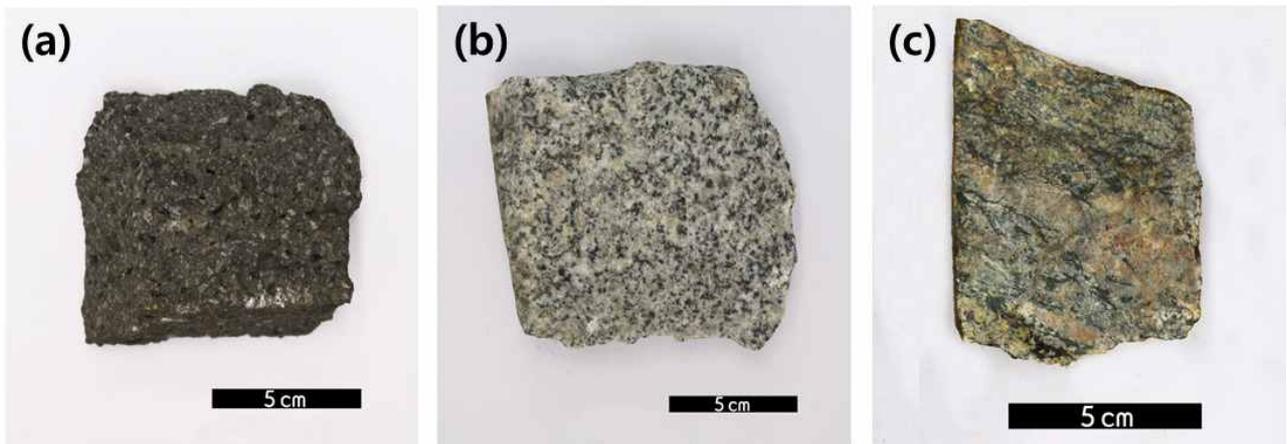


그림 3. 화성암 및 변성암 사진.

- (a) 현무암 (지오빅데이터 오픈플랫폼, <https://doi.org/10.22747/data.20210407.3350>)
- (b) 화강암 (지오빅데이터 오픈플랫폼, <https://doi.org/10.22747/data.20210408.3493>)
- (c) 편마암 (지오빅데이터 오픈플랫폼, <https://doi.org/10.22747/data.20210419.3668>)

II. 기초 이론

1. 인공지능 (Artificial Intelligence, AI)

최근 일상생활에서도 쉽게 접할 수 있는 인공지능 (Artificial Intelligence)이라는 분야는 개발 및 적용되는 분야의 관점에서 보면 매우 광범위하다. 인공지능은 다양한 학문이 상호 연계된 전형적인 융합 학문이라 할 수 있으며, 컴퓨터과학, 통계, 수학, 물리를 중심으로 철학, 의학, 공학, 자연과학, 언어학 등의 많은 분야와 연결되어 있다. 인공지능은 전문가들의 관점에 따라서 여러 가지로 정의된다. Russell과 Norvig (2002)은 인공지능의 사고과정·추론 및 행동에 따라 인공지능을 다음과 같은 4가지의 영역으로 정의하였으며, 현재까지 가장 활발하게 연구되고 있는 인공지능 분야는 ‘인간처럼 행동하는 시스템’이다.

표 1. 인공지능의 정의 (Russell & Norvig, 2002)

사고과정·추론 (Thinking process & reasoning)	인간처럼 생각하는 시스템 (Systems that think like humans)	합리적으로 생각하는 시스템 (Systems that think rationally)
행동 (Behaviour)	인간처럼 행동하는 시스템 (Systems that act like humans)	합리적으로 행동하는 시스템 (Systems that act rationally)

인공지능은 인간의 뇌에서 작용하는 처리 능력을 컴퓨터가 실행할 수 있도록 프로그램으로 구현하는 기술이다 (국경완, 2019). 인간처럼 사고하여 문제를 해결하는 인공지능은 인간이 활동하고, 생활하는 어느 분야라도 활용될 수 있다. 인공지능의 도입으로 사람이 직접 수행했던 일들을 인공지능이 대체할 수 있게 되어 산업 현장에서의 위험성이 감소하고, 시스템이 자동화되어 효율성이 증가하였으며, 경제적 이익과 생활의 편리함을 가져왔다. 인공지능은 컴퓨터과학, 철학, 공학, 언어학 등 다양한 분야의 학문들과 결합하여, 현재는 의료, 금융, 정보보안, 지능형 로봇, 자동 프로그래밍, 제조업에서의 자동 공정 등 수많은 분야에서 인공지능 기술이 활용되고 있다.

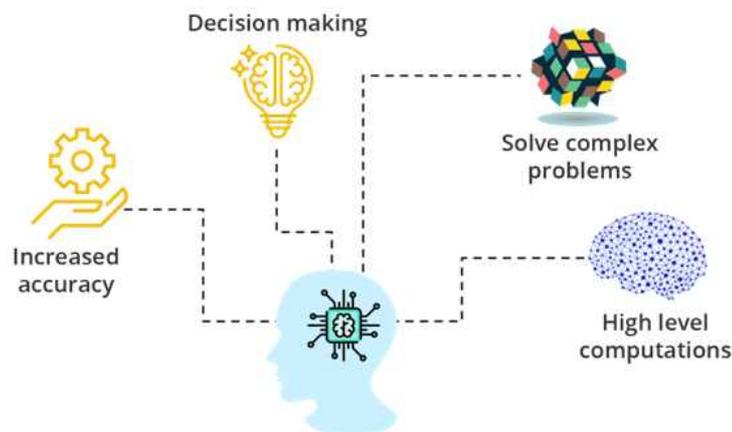


그림 4. 인공지능의 활용 (<https://aksharaontech.com>)

2. 딥 러닝 (Deep Learning)

인공신경망 (Artificial Neural Network, ANN)은 생물의 신경망에서 영감을 얻은 통계학을 기반으로 한 학습 알고리즘이다. 인간의 뇌는 뉴런이라는 신경세포로 신경망을 구성하고 있으며, 복잡한 인지 작업을 수행하는 각 신경세포는 수천, 수만 개의 다른 신경세포와 시냅스를 통해 서로 연결되어 정보를 전달한다 (그림 5). 이와 같은 인간 두뇌의 기능과 유사하게 인공신경망은 노드(node) 혹은 처리 요소 (Processing element, PE)라고 하는 수많은 뉴런들이 복잡하게 연결된 망으로 구성되며, 인공신경망은 시냅스의 결합으로 네트워크를 형성한 인공 뉴런이 학습을 통해 시냅스의 결합 세기를 변화시켜, 문제 해결 능력을 가지는 모델 전반을 가리킨다.

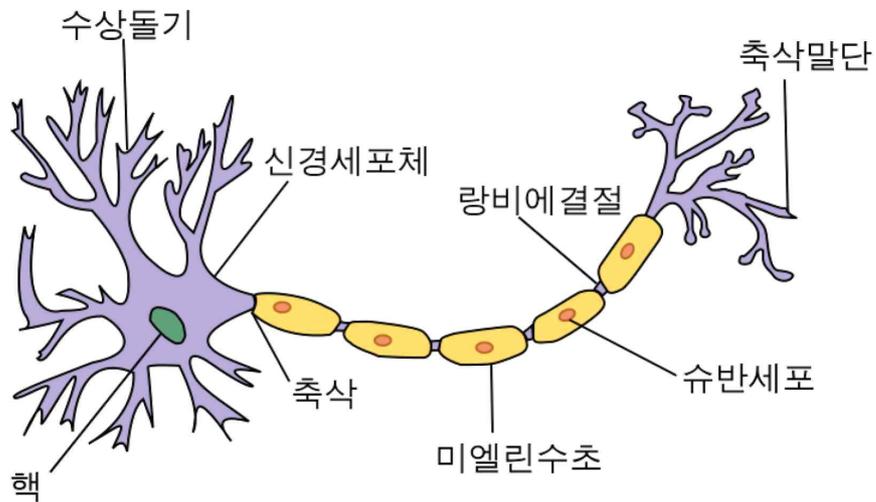


그림 5. 뉴런의 구조 (출처: 위키피디아, 인공신경망)

인공신경망은 머신 러닝 (machine learning)의 세부 방법론 중 하나로, 구조 및 기능에 따라 여러 종류로 구분되며 간단한 인공신경망은 구조적으로 한 개의 입력층과 그 뒤에 은닉층이 하나, 마지막으로 출력층이 있다. 일반적인 인공신경망은 데이터를 입력받기 위한 입력층과 입력된 데이터에 대한 학습을 수행하는 여러 개의 은닉층, 그리고 최종적인 범주를 결정하기 위한 출력층으로 이루어져 있다. 각 층은 입력된 값들을 처리하기 위한 유닛 또는 노드로 이루어져 있으며, 각각의 노드들은 활성화 함수를 통해 입력된 값들을 다음 층으로 전달할 것인지 말 것인지를 결정한다 (이재성, 2016).

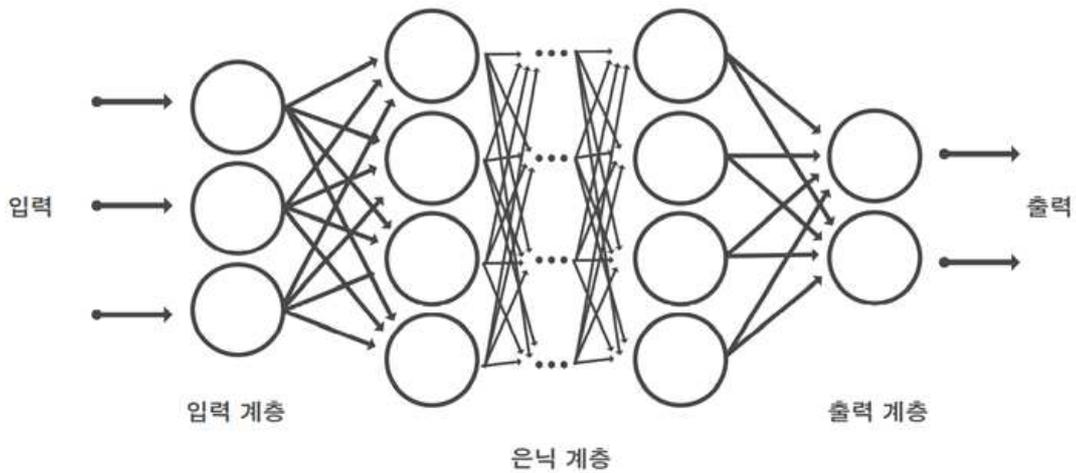


그림 6. 딥러닝 심층 신경망 구조 (<https://kr.mathworks.com/>)

인공신경망의 가장 간단한 구조는 단층 퍼셉트론이고, 여기서 모형 구조의 복잡도를 다층으로 변경하면 다층 퍼셉트론 또는 다층 전방향 인공신경망이라고 한다. 입력층과 출력층 사이에 여러 개의 은닉층을 가진 신경망을 심층 신경망이라고 하고, 여기에 적용된 학습 방법이 딥러닝 (Deep Learning)이다(그림 6). 딥러닝은 여러 비선형 변환기법의 조합을 통해 높은 수준의 추상화 (abstractions)를 시도하는 기계 학습 알고리즘의 집합으로 정의되며 (Bengio et al., 2013), 큰 틀에서 사람의 사고방식을 컴퓨터에게 가르치는 기계학습의 한 분야이다. 안성만 (2016)은 딥러닝을 인공신경망(neural network)이라는 인공지능 분야의 모형이 발전된 형태로서, 계층구조로 이루어진 인공신경망의 내부계층(hidden layer)이 여러 단계로 이루어진 구조로 정의하였다. 데이터를 컴퓨터가 처리 가능한 형태인 벡터나 그래프 등으로 표현하고 이를 학습하는 모델을 구축하는 연구를 포함한다. 얼굴이나 표정을 인식하는 등의 특정 학습 목표에 대해, 딥러닝은 학습을 위한 더 나은 표현 방법과 효율적인 모델 구축에 초점을 맞춘다. 최근의 딥러닝 모형은 내부계층이 많아져서 노드(node)를 연결하는 가중치(weight, 연결강도를 의미함)의 수가 최대 수십억 개가 되기도 한다.

딥러닝은 대규모 데이터를 통해 학습하며, 자연어 처리, 음성 인식, 패턴 인식, 영상처리, 로봇틱스, 자율주행 자동차 등 수많은 분야에 활용되어 성과를 보이고 있다.

3. You Only Look Once (YOLO)

YOLO는 “You Only Look Once”의 약자로 영상에서 다양한 물체를 실시간으로 감지하고 인식하며, 이미지 내에 존재하는 객체와 해당 객체의 위치를 추측할 수 있는 딥러닝 기반 알고리즘이다.

YOLO의 가장 큰 특징은 이미지 전체를 한 번만 보는 것으로 개체를 감지할 수 있다는 것이다. YOLO 이전의 객체 감지에 활용된 딥러닝 알고리즘인 R-CNN은 이미지를 여러 장으로 분할한 후 모델을 이미지를 분석하므로 이미지 한 장이지만 실제로는 여러 장의 이미지를 모델에 통과하여 분석하는 것과 같다. 반면 YOLO는 이와 다르게 이미지를 한 번만 보는 특징을 가지고 있으며, 이미지 전체를 한 번에 보기 때문에 배경을 사물로 인식하는 background error가 적게 나타난다. 또한, YOLO 알고리즘은 실시간으로 물체를 예측할 수 있어 객체 감지 속도가 향상되고, 물체의 일반화된

부분을 학습하여 객체 감지에 적용할 수 있는 뛰어난 학습 능력을 갖추고 있다는 장점이 있다 (Redmon et al., 2016).

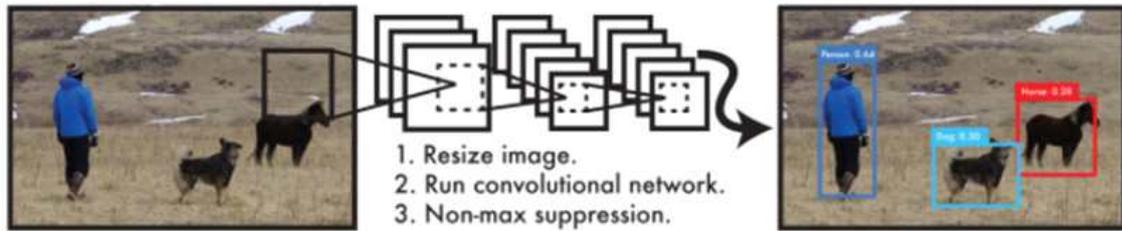


그림 7. The YOLO Detection System (Redmon et al., 2016)

YOLO 알고리즘의 진행 과정은 크게 세 단계로 나눌 수 있다(그림 7). 먼저 입력된 이미지를 $S \times S$ 의 격자로 분할한다. 그 후 합성곱 신경망의 실행을 통해 여러 bounding box와 해당 상자에 대한 클래스 확률을 동시에 예측한다. 각 격자 셀은 B개의 bounding box를 예측하고, 각 신뢰 점수를 제공하며, 각 격자 셀은 객체의 클래스를 설정하기 위해 클래스 확률을 예측한다. 마지막으로 Non-max suppression 과정을 통해 이미지 내 불필요하게 중복되는 bounding box를 제거하고, 객체에 맞는 고유한 bounding box들로 구성된 최종 객체 감지 결과를 제시한다. 그림 8은 YOLO 알고리즘의 실행을 통해 최종 객체 감지의 결과를 생성하는 예시이다.

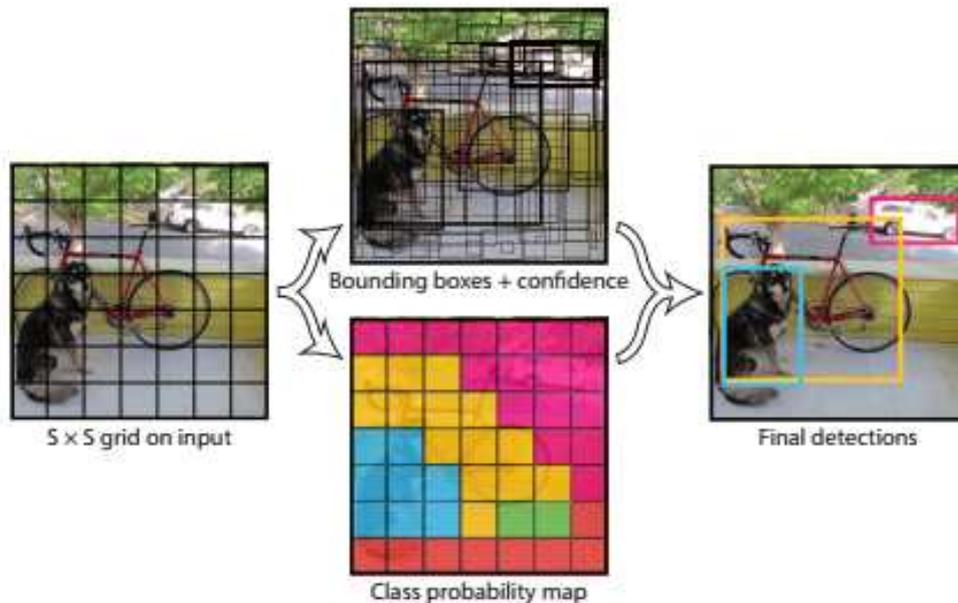


그림 8. YOLO 알고리즘의 객체 감지 시스템 (Redmon et al., 2016)

YOLO v5는 2020년 6월 Glenn Jocher에 의해 발표된 YOLO 딥러닝 알고리즘이다. 이전의 YOLO 버전들에 비해 낮은 용량과 빠른 속도를 보이며, 파이썬 기반의 오픈 소스 머신 러닝 라이브러리인 Pytorch 구현으로 고속도 자료 처리가 가능하다는 특징이 있다. YOLO v5는 n, s, m, l, x의 5가지

버전의 모델이 존재하며, 순서대로 n이 가장 가벼운 모델이고 x가 가장 무거운 모델이다. 본 연구에서는 성능과 처리 속도인 Frame per seconds(FPS)을 동시에 고려하여 상대적으로 가벼운 모델이지만, 처리 속도가 빠른 YOLO v5s 모델을 사용하여 훈련을 진행하였다.

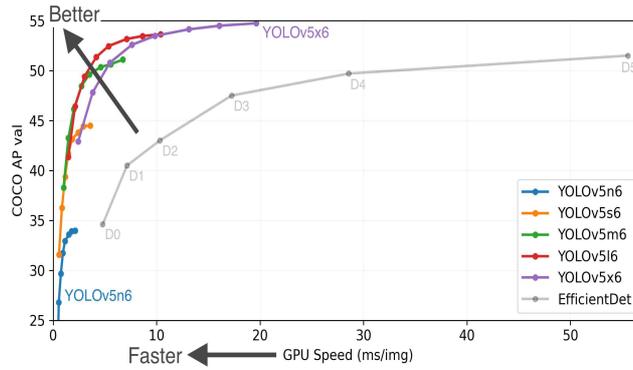


그림 9. YOLO v5 모델별 성능 비교
(<https://github.com/ultralytics/yolov5/>)

훈련 모델의 정확도는 그림 10의 지표를 사용하여 다음 식 (1)과 (2)로 계산되는 precision과 recall 값을 통해 평가된다. Precision 값이 높을수록 모델의 성능이 우수한 것으로 판단한다. Recall 역시 값이 높을수록 모델의 성능이 우수한 것으로 판단한다.

$$\text{Precision} = \frac{TP}{(TP + FP)} \tag{1}$$

$$\text{Recall} = \frac{TP}{(TP + FN)} \tag{2}$$

		실제 정답	
		True	False
분류 결과	True	True Positive	False Positive
	False	False Negative	True Negative

그림 10. 딥러닝 모델 검증에 사용되는 지표를 나타내며, precision과 recall 계산에 사용됨

3. Jetson Nano

Jetson Nano는 NVIDIA가 개발한 2019년 6월에 처음 출시된 소형 단일보드 컴퓨터이다. Jetson Nano는 이미지 분류, 개체 감지, 세분화 및 음성 처리 등의 애플리케이션에서 다수의 뉴럴 네트워크를 병렬로 실행하게 해주는 강력한 소형 컴퓨터이다. Jetson Nano는 소형 보드로 고성능의 GPU를 사용할 수 있어 딥러닝, 머신러닝을 손쉽게 구현할 수 있다는 장점이 있다. 최근에는 AI가 적용되는 영역에서 젯슨 나노가 메인보드로 많이 쓰이는 추세를 보이며, 물체 식별, 컴퓨터 비전, 로봇 공학, 자율 기계, 헬스케어, 지능형 비디오 분석, 인공지능 사물인터넷(AIoT) 등의 다양한 분야에서 활용될 수 있다.

그림 11은 Jetson Nano의 구성으로 몇 가지 인터페이스(interface)를 통해 기타 장치들을 연결하여 사용할 수 있다. 소형 모니터, 카메라 등의 연결이 가능하며, USB, Ethernet, MIPI CSI-2를 통해 카메라를 연결할 수 있다. 카메라의 연결 및 실행을 통해 화면에 영상을 나타내고, 사진을 찍으며, 디스크에 저장할 수 있다.



그림 11. Jetson Nano 구성 (<https://developer.nvidia.com/>)

II. 연구 자료 및 방법

1. 연구 자료

본 연구에서는 지오빅데이터 오픈플랫폼에서 제공하는 퇴적암 이미지와 부산대학교 지질환경과학과 소장 암석을 직접 촬영한 이미지를 훈련, 검증 자료 및 테스트 자료로 사용하였다. 전체 6종류의 암석 분류 연구에 사용된 총 자료의 수는 935장이며, 훈련: 검증: 테스트 = 7 : 2 : 1 비율로 암석 이미지 자료를 나누어 연구를 진행하였다 (표 2). 우수한 성능의 훈련 모델을 제작하기 위해 훈련 자료의 비율을 높게 두었으며, 암석의 구분 경계가 모호한 암석 이미지는 연구 자료에서 제외하였다.

표 2. 연구에 사용한 암석 자료

	훈련 (70)	검증 (20)	테스트 (10)	계
역암	79	23	11	113
사암	85	24	13	122
이암	121	35	18	174
현무암	100	30	14	144
화강암	145	41	21	207
편마암	123	35	17	175
계	653	188	94	935

2. 연구 방법

본 연구에서는 표 2의 암석 이미지 자료를 사용하여 크게 두 단계로 나누어 연구를 진행하였다. 첫 번째로 퇴적암을 역암, 사암, 이암으로 분류하는 퇴적암 분류 연구를 실시하였다. 이후 퇴적암에 화성암 및 변성암 이미지를 추가하여 총 6종류의 암석 분류 연구를 진행하였다.

YOLO v5 알고리즘 및 Jetson Nano를 이용한 암석 분류 모델 획득 및 분류 과정은 그림 12와 같다. 수집한 자료에 어노테이션을 실시하여 딥러닝 훈련 모델 제작에 필요한 훈련 및 검증 자료에 객체의 클래스를 부여하는 과정을 진행하였다. 이후 Google Colab에서 YOLO v5 딥러닝 알고리즘을 사용하여 암석 분류를 위한 훈련 모델을 제작하고, 검증을 통해 모델의 성능을 평가하였다. 최종적으로 획득한 YOLO v5 암석 분류 훈련 모델을 Jetson Nano로 이동 후 실행하여 실제 촬영한 퇴적암, 화성암, 변성암 이미지에 대한 암석 분류 테스트 결과를 획득하였다.

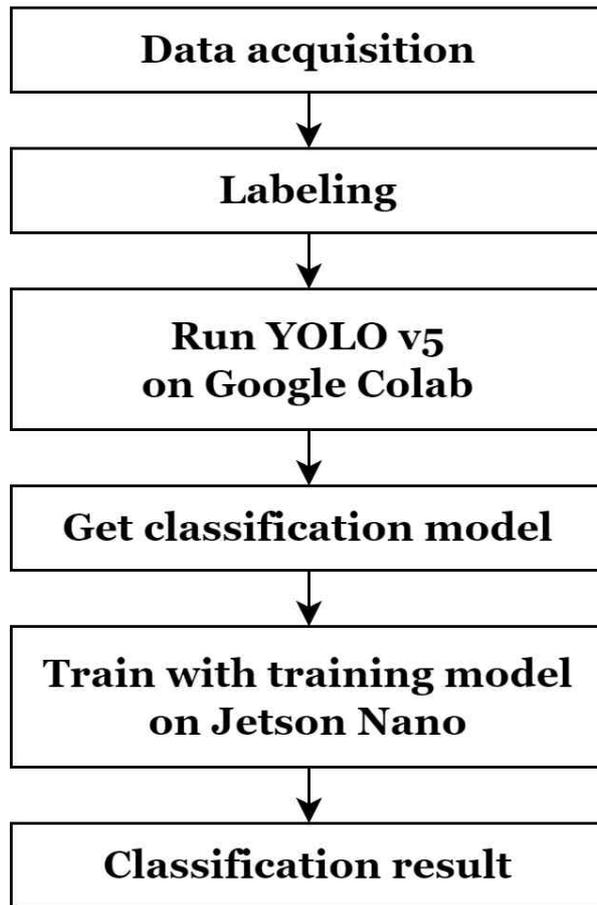


그림 12. YOLO v5 알고리즘과 Jetson Nano를 이용한 압석 분류 모델 획득 및 이미지 분류 과정

(1) Image labeling (Annotation)

본격적인 딥러닝 알고리즘을 활용한 암석 분류를 진행하기에 앞서 이미지 라벨링 과정이 필요하다. 어노테이션은 인공지능이 스스로 학습할 수 있는 형태로 데이터를 가공하여 객체의 클래스를 부여하는 전처리 작업이다.

본 연구에서는 어노테이션 툴로 LabelImg를 선택하여 훈련 및 검증 자료에 라벨링을 실시하였다. LabelImg 어노테이션 툴을 사용하여 훈련 및 검증 자료 내 암석의 위치를 바운딩 박스로 선택하여 각 암석의 클래스를 부여하였다.

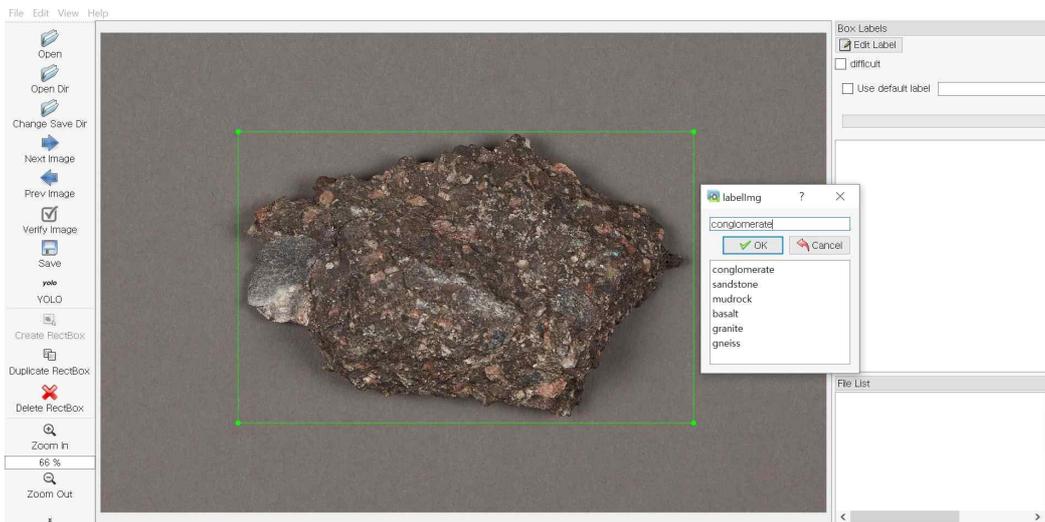


그림 13. LabelImg 어노테이션 툴을 사용한 image labeling

그림 13과 같이 LabelImg를 이용하여 특정 암석에 해당하는 이미지에 암석 위치에 맞게 바운딩 박스를 선택하고, 클래스를 지정하여 라벨링을 실시할 수 있다. 어노테이션이 완료된 후 이미지 파일들과 생성된 label 파일들을 훈련 및 검증 자료 비율에 맞게 나누어 연구를 진행하였다.

(2) YOLO v5 훈련모델 제작 및 검증

본 연구에서는 Google Colab의 GPU를 사용해 YOLO v5를 실행하였다. Google Colab은 GPU를 제공하여 딥러닝 학습을 시킬 수 있는 오픈 클라우드 기반 서비스로 Google Colab을 활용하여 암석 분류를 위한 YOLO v5 훈련 모델을 제작 및 검증하였다.

어노테이션 과정 이후 훈련 및 검증 자료로 나눈 암석 데이터와 YOLO v5 딥러닝 알고리즘을 사용하여 암석 분류 모델을 제작 및 검증하였다. 검증 과정은 객체 분류를 위한 적합한 파라미터와 모델을 결정하기 위해 필요한 과정이다. 암석 이미지 데이터와 label 데이터를 사용해 img 640, batch 16, epochs 100의 파라미터를 설정한 후 YOLO v5를 실행하여 훈련 모델을 제작하고, 검증 자료를 사용하여 제작한 훈련 모델의 검증을 시행하였다.

```

train: ../train_data_r/images/train # train images - 653 images
val: ../train_data_r/images/val # val images - 188 images

# Classes
nc: 6 # number of classes
names: ['conglomerate', 'sandstone', 'mudrock', 'basalt', 'granite', 'gneiss'] # class names

```

그림 14. YOLO v5 실행을 위한 훈련 및 검증 자료

```

# Train YOLOv5s on rock_classification for 100 epochs
!python train.py --img 640 --batch 16 --epochs 3 --data rock_classification.yaml --weights yolov5s.pt --cache

train: weights=yolov5s.pt, cfg=, data=rock_classification.yaml, hyp=data/hyps/hyp.scratch.yaml, epochs=100, batch_
github: up to date with https://github.com/ultralytics/yolov5 ✓
YOLOv5 v5.0-379-g2da6444 torch 1.9.0+cu102 CUDA:0 (Tesla K80, 11441.1875MB)

hyperparameters: lr0=0.01, lrf=0.2, momentum=0.937, weight_decay=0.0005, warmup_epochs=3.0, warmup_momentum=0.8,
Weights & Biases: run 'pip install wandb' to automatically track and visualize YOLOv5 runs (RECOMMENDED)
TensorBoard: Start with 'tensorboard --logdir runs/train', view at http://localhost:6006/
Downloading https://github.com/ultralytics/yolov5/releases/download/v5.0/yolov5s.pt to yolov5s.pt...
100% 14.1M/14.1M [00:00<00:00, 21.4MB/s]

Overriding model.yaml nc=80 with nc=18

      from  n  params module  arguments
      ----  -  -  -  -  -
0         -1  1    3520 models.common.Focus  [3, 32, 3]
1         -1  1   18560 models.common.Conv  [32, 64, 3, 2]
2         -1  1   18816 models.common.C3    [64, 64, 1]
3         -1  1   73984 models.common.Conv  [64, 128, 3, 2]

```

그림 15. Google Colab에서의 YOLO v5 훈련 모델 제작

(3) Jetson Nano 암석 분류 테스트

테스트 자료에 해당하는 자료 사용하였으며, YOLO v5 딥러닝 알고리즘을 활용하여 이전 단계에서 획득한 암석 분류 훈련모델을 Jetson Nano로 이동 후 실행하여 실제 촬영한 암석 이미지에 대해 암석 분류 테스트 실시하였다.



그림 16. Jetson Nano 설치 모습(좌) 및 실행 화면(우)

앞서 훈련 모델을 제작했던 것과 같이 테스트도 두 단계로 나누어 진행하였다. 첫 번째로 퇴적암을 역암, 사암, 이암으로 분류하는 훈련 모델을 제작 후 퇴적암 이미지에 대해 테스트를 진행하였다. 퇴적암 분류 훈련 모델 테스트 결과는 획득한 분류 모델을 사용하였을 때 예측한 암석 클래스와 실제 암석의 클래스에 해당하는 이미지 수를 바탕으로 오류율(Error Rate)과 분류 정확도를 계

산하여 분석하였다.

다음으로 퇴적암 이미지에 화강암 및 변성암 이미지를 추가한 후 제작한 총 6종류 암석 분류 훈련 모델을 사용하여 역암, 사암, 이암, 현무암, 화강암, 편마암 이미지에 대해 분류 테스트를 진행하였다. 암석 6종 분류 훈련 모델 테스트 결과는 퇴적암 분류 모델에서의 방법과 동일하게 실제 암석의 클래스에 해당하는 이미지 수와 획득한 분류 모델을 사용하여 예측한 암석 클래스에 해당하는 이미지 수를 바탕으로 계산한 오류율과 분류 정확도를 통해 분석하였다.

III. 연구 결과

1. 퇴적암 분류 결과

YOLO v5를 활용하여 획득한 훈련 모델의 검증을 위해 검증 자료를 사용하여 퇴적암 분류 모델의 역암, 사암, 이암 분류 정확도를 평가하였다. Precision(정밀도), Recall(재현율)은 모델의 검증에 사용되는 지표로, Precision, Recall 값이 높을수록 모델의 성능은 우수한 것으로 판단한다. 그림 17은 퇴적암 분류 훈련모델의 Precision-Recall Curve로 훈련 모델의 정확도를 확인할 수 있으며, 그래프에서 정밀도가 높아져도 재현율이 높게 유지될수록 우수한 모델로 평가된다. Mean Average Precision (mAP)는 Precision-Recall Curve의 아래 면적에 해당하는 값으로, 객체 탐지 정확도 평가 지표로 사용되며 mAP 값이 높을수록 분류 모델의 성능이 우수한 것으로 평가된다.

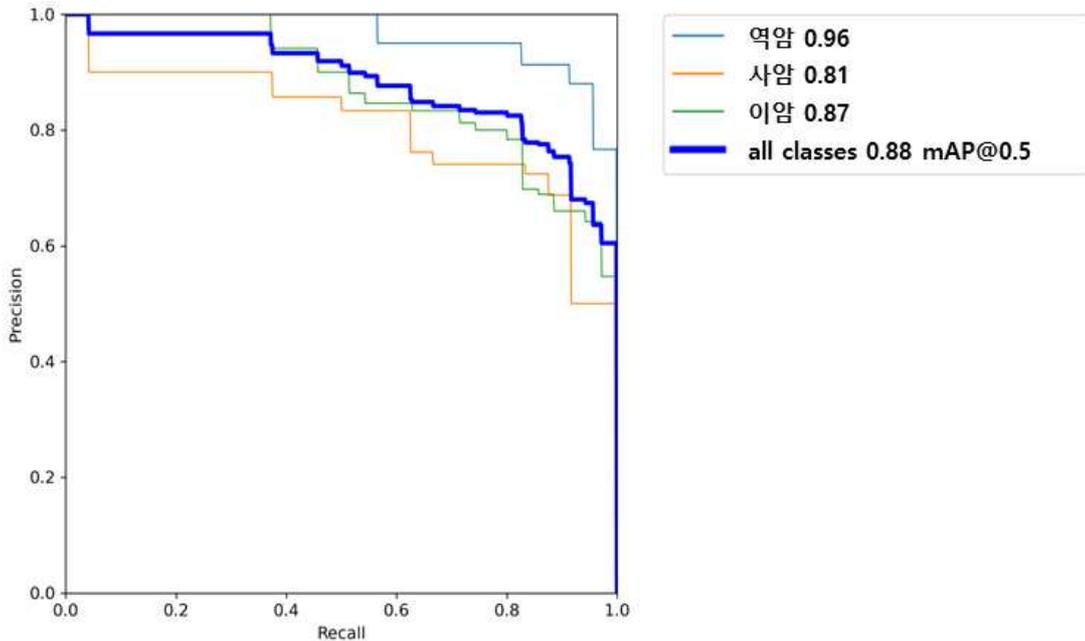


그림 17. 퇴적암 분류 훈련 모델의 Precision-Recall Curve와 클래스별 mAP 값

해당 훈련 모델은 역암 0.96, 사암 0.81, 이암 0.87의 높은 정확도 값을 보이며, 전체 객체 분류 정확도는 0.88로 나타났다.

표 3. 퇴적암 분류 훈련 모델 테스트 결과

Predicted \ Actual	역암	사암	이암	Error Rate(%)
역암	11	0	0	0.0
사암	0	12	1	7.7
이암	0	1	17	5.6

표 3은 훈련으로 획득한 분류 모델을 사용하여 실제 촬영한 퇴적암 이미지에 대한 분류 테스트 결과를 나타내는 표이다. 실제 암석의 클래스와 예측한 암석 클래스에 해당하는 이미지 수를 나타내고 있다. 역암의 경우 100%의 분류 정확도로, 역암 이미지를 모두 역암으로 분류하였다. 사암의 경우 92.3%의 분류 정확도로 비교적 높은 오류율을 가지며 이암으로 분류된 경우가 발견되었다. 이암은 94.4%의 확률로 높은 분류 정확도를 가지나 사암으로 분류한 경우가 발견되었다.

훈련 모델을 사용하여 직접 촬영한 퇴적암 이미지를 분류한 결과, 이미지 내의 암석의 위치가 바운딩 박스로 나타나며, 해당 암석의 클래스 및 예측 확률이 표시된다. 그림 18에서 각각 역암, 사암, 이암 이미지에 대해 바운딩 박스와 예측 클래스 및 확률이 표시된 것을 확인할 수 있다.

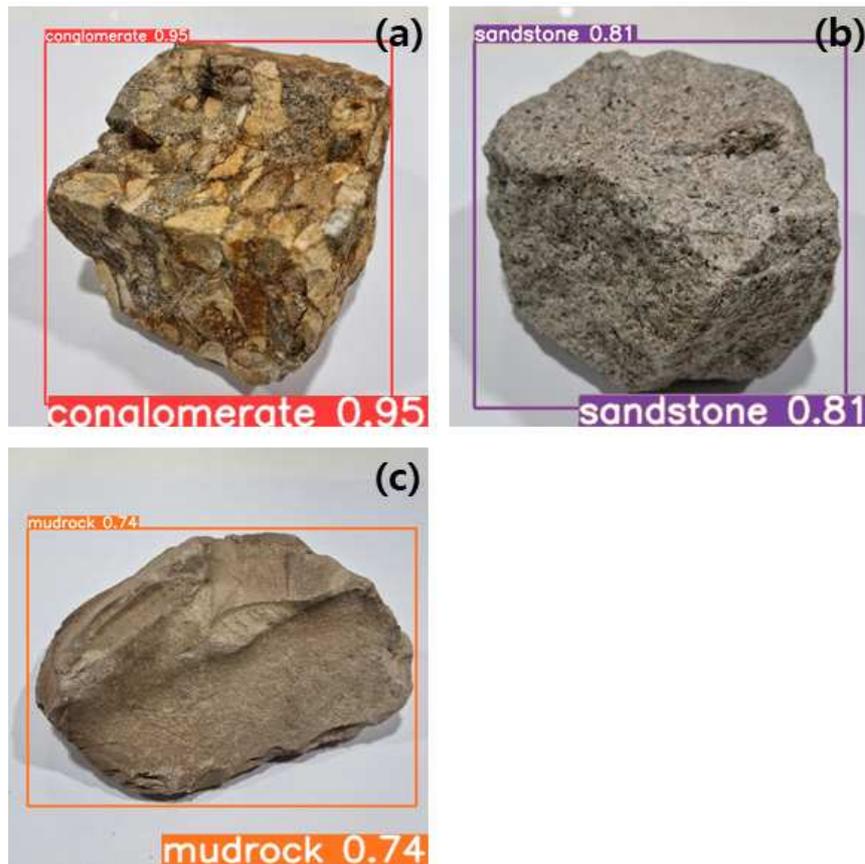


그림 18. 퇴적암 이미지 분류 결과. 각각 (a) 역암, (b) 사암, (c) 이암의 분류 결과

2. 암석 6종 분류 결과

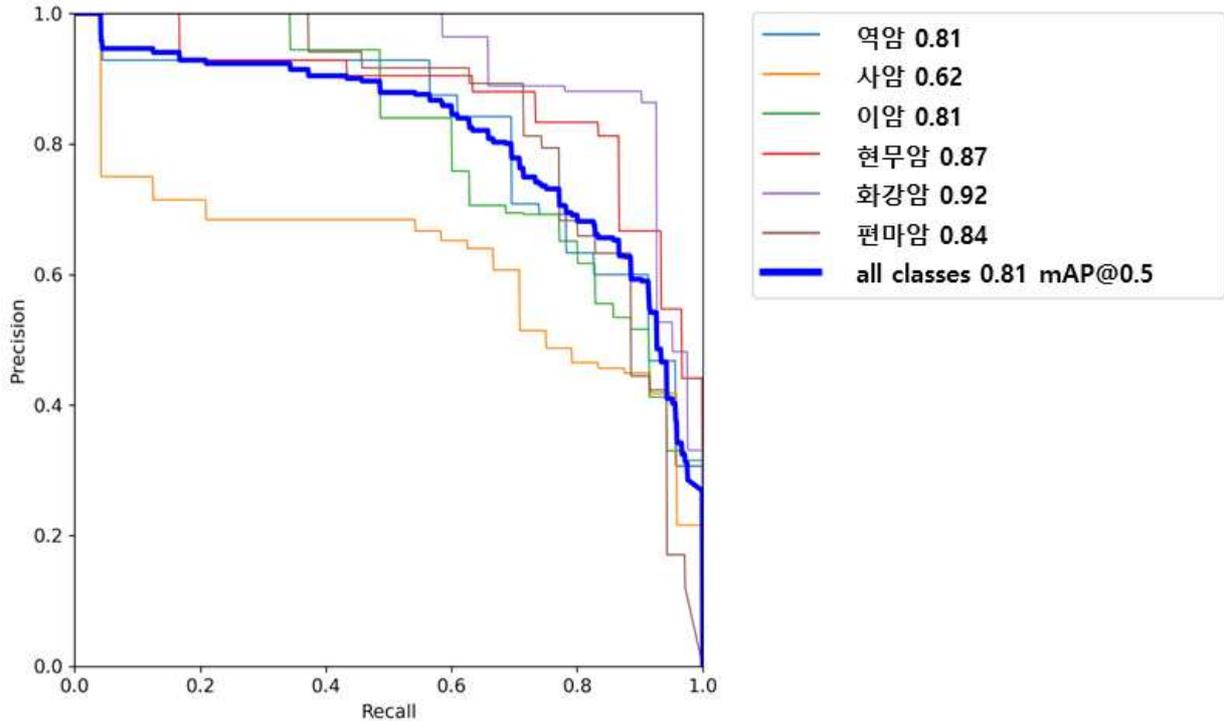


그림 19. 암석 6종 분류 훈련 모델의 Precision-Recall Curve와 클래스별 mAP 값

퇴적암 이미지에 화강암 및 변성암 이미지를 추가한 총 6종류의 암석 분류 훈련 모델을 제작하였으며, 훈련 모델의 검증을 위해 검증 자료를 사용하여 역암, 사암, 이암, 현무암, 화강암, 편마암의 분류 정확도를 평가하였다. 암석 6종 분류 훈련 모델은 역암 0.81, 이암 0.81, 현무암 0.87, 화강암 0.92, 편마암 0.84의 높은 정확도 값을 보이며, 사암은 0.62의 다소 낮은 값을 보였다. 훈련 모델의 전체 객체 분류 정확도는 0.81로 나타났다.

표 4. 퇴적암 분류 모델 클래스별 mAP 값

Class	mAP@.5
All (average)	0.88
역암	0.96
사암	0.81
이암	0.87

표 5. 암석 6종류 분류 모델 클래스별 mAP 값

Class	mAP@.5
All (average)	0.81
역암	0.81
사암	0.62
이암	0.81
현무암	0.87
화강암	0.92
편마암	0.84

표 5는 암석 6종류 분류 모델의 정확도를 나타낸다. 이 중 화강암과 현무암, 편마암은 평균보다 높은 0.92, 0.87, 0.84의 값을 보였으며, 사암은 0.62의 다소 낮은 값을 보이는 것을 확인할 수 있었다.

또한, 표 4와 표 5에 나타나는 퇴적암과 암석 6종 분류 모델의 클래스별 mAP 값을 통해 퇴적암 분류 결과와 현무암, 화강암, 편마암을 포함한 6종류의 암석 분류 결과를 비교해보았다. 퇴적암만을 분류했을 때보다 역암, 사암, 이암에 현무암, 화강암, 편마암의 이미지를 함께 사용하여 암석을 분류한 결과에서 퇴적암의 분류 정확도가 떨어짐을 확인할 수 있었다.

표 6. 암석 6종 분류 훈련 모델 테스트 결과

Predicted \ Actual	역암	사암	이암	현무암	화강암	편마암	Error Rate(%)
역암	11	0	0	0	0	0	0.0
사암	0	12	0	1	0	0	7.7
이암	0	1	16	1	0	0	11.1
현무암	0	1	0	12	0	0	7.1
화강암	0	0	0	0	19	2	9.5
편마암	1	0	0	0	2	14	17.6

훈련 모델을 사용하여 실제 촬영한 암석 이미지에 대해 분류 테스트를 실시한 결과, 분류 정확도는 역암 100%, 사암 92.3%, 화강암 90.5%, 이암 88.9%, 현무암 82.9%, 편마암 82.4% 순으로 높게 나타났다 (표 6). 80% 이상의 대체로 높은 분류 정확도를 보였으며, 사암의 경우 현무암으로, 이암은 사암과 현무암으로, 현무암은 사암으로, 화강암은 편마암으로, 편마암은 화강암으로 분류된 경우가 발견되었다.

그림 20은 실제 촬영한 암석 이미지 분류 결과의 예시이다. 퇴적암에 화성암과 변성암 이미지를 추가한 총 6가지 종류의 암석 분류 결과이며, 각각 역암, 사암, 이암, 현무암, 화강암, 편마암 이미지이다. 앞선 퇴적암 분류 결과와 마찬가지로 이미지 내의 암석의 위치가 바운딩 박스로 나타나며, 6종류의 암석 이미지에 대해 해당 암석의 클래스 및 예측 확률이 표시되는 것을 확인할 수 있다.

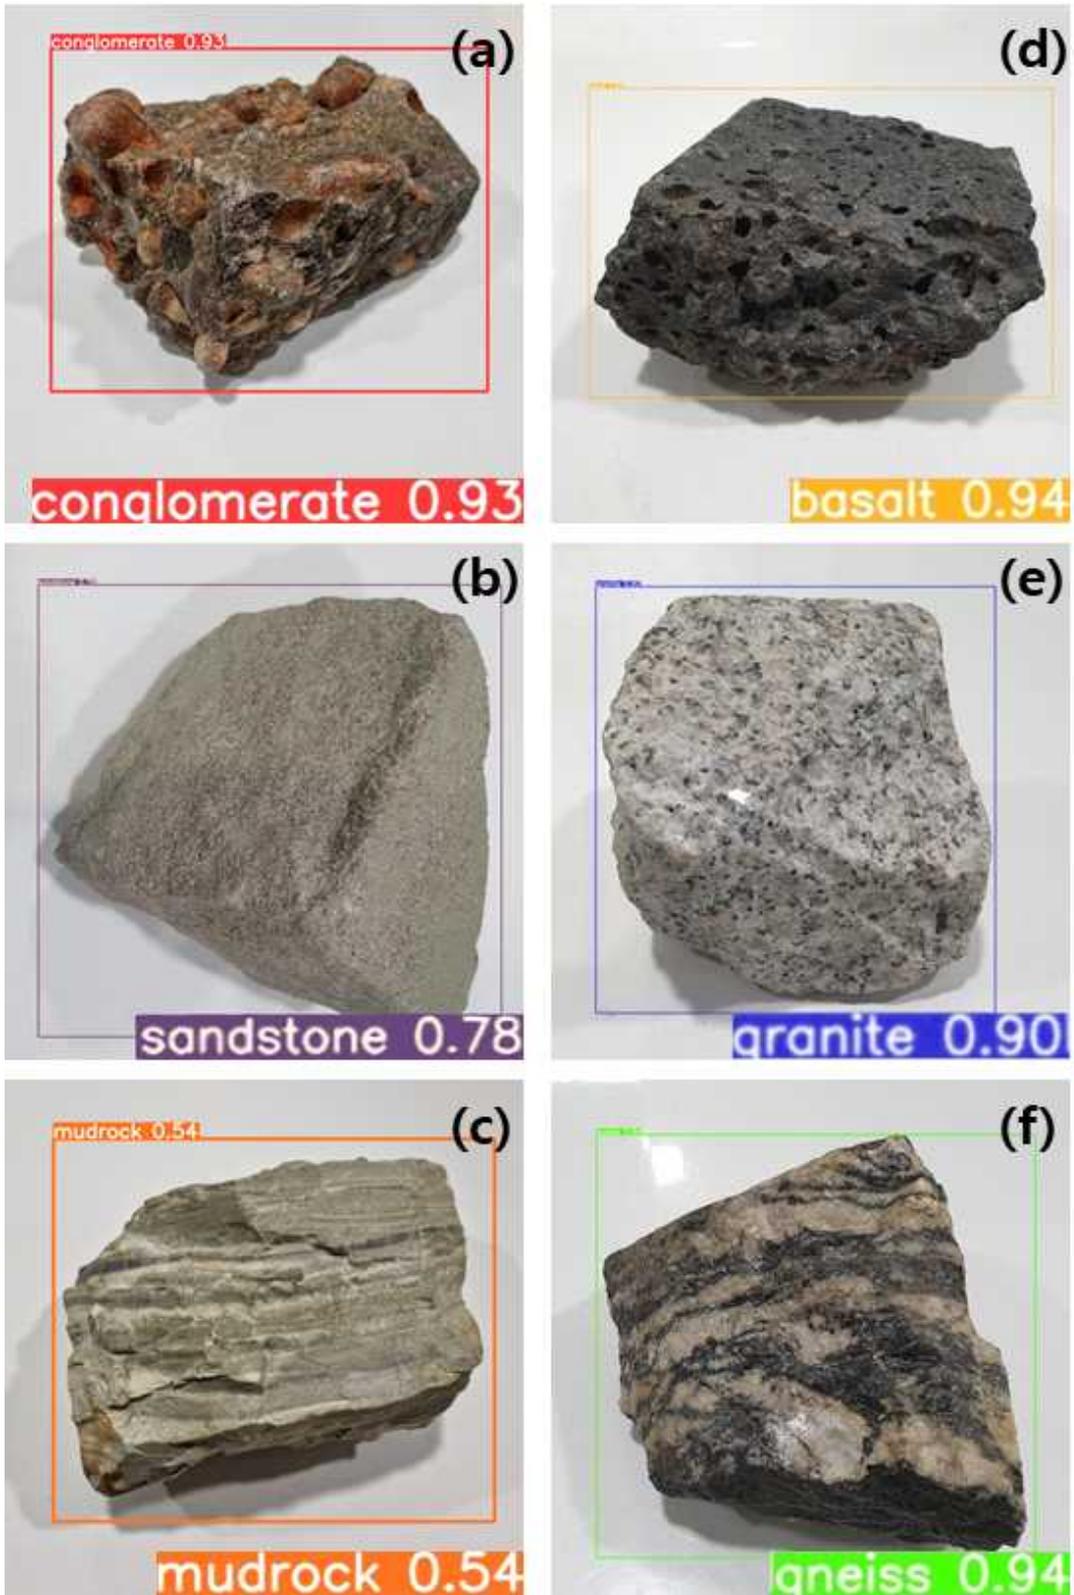


그림 20. 암석 이미지 분류 결과 예시. 각각 (a) 역암, (b) 사암, (c) 이암, (d) 현무암, (e) 화강암, (f) 편마암의 분류 결과

3. 결과 분석 및 토의

퇴적암 분류 연구 결과, mAP 0.88의 높은 정확도의 훈련 모델을 획득하였으며, 이를 통한 실제 촬영한 암석 이미지의 분류는 역암 100%, 사암 92.3%, 이암 94.4%로 성공적임을 확인하였다. 훈련 모델의 정확도는 역암에서 가장 높게 나타나며, 이는 부족한 데이터 수입에도 불구하고 큰 자갈이 보이는 역암의 외형적 특징이 뚜렷하여 가능한 것으로 추정된다. 훈련 모델의 정확도와 테스트 결과는 사암에서 가장 낮게 나타나며, 표 3에서 확인할 수 있듯이 실제 암석 분류 결과에서 특정 이암을 사암으로 분류한 것을 통해 사암이 역암과 이암의 중간 특성을 가졌기 때문이라고 추정하였다. 이암의 경우 역암에 비해 낮은 훈련 모델에서의 정확도를 보이며, 이는 이암, 실트암, 점토암, 셰일 등 다양한 형태와 색상을 가지는 이암 이미지를 통한 학습에 의한 것으로 추정하였다.

현무암, 화강암, 편마암을 추가한 6 종류의 암석 분류 연구 결과, mAP 0.81의 높은 정확도의 훈련 모델을 획득하였으며, 화강암, 현무암, 편마암, 역암, 이암에서는 0.80 이상의 높은 정확도를 보였으나 사암의 경우 비교적 낮은 0.62의 정확도 값을 보였다. 훈련 모델의 정확도는 비교적 외형적 특징이 뚜렷하게 나타나는 역암, 현무암, 화강암에서 높게 나타났으며, 데이터 수가 많았던 화강암, 편마암, 현무암에서 가장 높은 정확도가 나타나는 것으로 보아 정확도는 훈련 자료의 수와도 연관이 있을 것으로 추측된다.

다음으로 표 6에서 발견되는 잘못 분류된 암석 분류 결과 예시를 분석하여 분류 정확도가 낮게 나타나는 암석 이미지를 특성을 살펴보았다(그림 21). 육안으로 보았을 때 유사성을 띠는 암석 간 잘못 분류된 결과가 발생하며, 이는 충분한 훈련 자료를 확보하지 못해 발생하는 오류로 추정된다.

(a)는 이암이 사암으로 분류된 결과이다. 그림에 나타나는 이암은 사질 이암으로 일반적인 이암보다 모래의 비율이 높다. 따라서 구성 입자의 크기가 사암과 비슷하여 사암으로 분류된 것으로 추정된다.

(b)는 사암이 현무암으로 분류된 결과이다. 그림에 나타나는 사암은 매우 어두운 색을 띠고 있으며, 암석의 색이 육안으로 보기에 현무암과 비슷하여 현무암으로 분류된 것으로 생각된다.

(c)는 편마암이 화강암으로 분류된 결과이다. 그림에 나타나는 편마암은 전기석 우백질 편마암으로 우흑대와 우백대가 번갈아 나타나는 모습을 볼 수 있다. 유색광물을 적게 포함하여 우백대를 나타내는 모습이 화강암에서 나타나는 광물 조성 및 조직과 유사하여 화강암으로 분류된 것으로 추정된다.



Actual : 이암
Predict : 사암



Actual : 편마암
Predict : 화강암



Actual : 사암
Predict : 현무암

그림 21. 잘못 분류된 결과 예시. (a) 이암이 사암으로 분류, (b) 사암이 현무암으로 분류, (c) 편마암이 화강암으로 분류 (지오빅데이터 오픈플랫폼)

IV. 결론

본 연구는 YOLO v5 딥러닝 알고리즘을 활용하여 암석 이미지 분류를 수행하였다. 전체 6종류의 암석에 대해 총 935장의 암석 이미지가 연구에 사용되었으며, 훈련: 검증: 테스트 = 7 : 2 : 1 비율로 암석 이미지 자료를 나누어 연구를 진행하였다. 훈련 모델 제작에 앞서 LabelImg 어노테이션 툴을 이용하여 훈련 및 검증 자료에 대해 라벨링을 실시하였고, Google Colab에서 YOLO v5 딥러닝 알고리즘을 활용하여 암석 분류 모델을 제작 및 검증하였다. 최종적으로 획득한 암석 분류 모델을 Jetson Nano으로 이동 후 실제 촬영한 암석 이미지에 대해 테스트를 실시하였다.

퇴적암 분류를 위한 훈련 모델을 제작하였으며, 분류 모델의 성능을 평가하기 위해 검증을 시행하였다. 연구 결과, 평균 0.88의 높은 정확도를 가진 훈련 모델을 획득하였으며, 훈련 모델을 이용하여 실제 촬영한 암석 이미지를 분류한 결과 역암 100%, 사암 92.3%, 이질암 94.4%의 분류 정확도로 성공적인 분류가 가능함을 확인하였다.

현무암, 화강암, 편마암을 추가한 6종류의 암석 분류 연구 결과, 평균 0.81의 높은 정확도의 훈련 모델을 획득하였으며, 화강암, 현무암, 편마암, 역암, 이질암에서는 0.80 이상의 높은 정확도를 보였으나 사암의 경우 비교적 낮은 0.62의 정확도 값을 보였다. 훈련 모델을 이용하여 실제 촬영한 암석 이미지 분류 결과, 훈련 모델의 정확도는 비교적 외형적 특징이 뚜렷하게 나타나는 역암, 현무암, 화강암에서 높게 나타나는 것으로 확인할 수 있었다.

퇴적암 분류 모델과 퇴적암에 화성암 및 변성암을 추가한 6종 암석 분류 모델의 정확도를 비교한 결과, 퇴적암만을 분류하였을 때보다 화성암, 변성암을 추가한 모델에서 퇴적암의 분류 정확도가 떨어짐을 확인하였다. 잘못 분류된 암석 이미지를 통해 살펴본 토의 결과, 암석의 색, 구성 입자의 크기, 광물 조성, 조직 등의 특성에 유사함을 보이는 암석들은 분류 정확도가 다소 낮게 나타나는 것으로 확인하였으며, 이는 훈련 자료의 부족으로 인해 오류가 발생한 것으로 추정하였다.

마지막으로, 본 연구 결과, YOLO v5 딥러닝 알고리즘을 활용한 암석 분류 모델의 제작은 우수한 암석 분류 결과를 제공하여 향후 충분한 훈련 데이터의 확보 및 훈련 모델의 정확도 개선을 통해 실제 야외 지질 답사에서 다양한 종류의 암석 분류에 활용 가능할 것으로 기대된다.

V. 활용방안 및 추후계획

1. 실제 현장에서의 활용

본 연구를 통해 YOLO v5 딥러닝 알고리즘을 활용한 암석 분류 모델의 제작으로 우수한 암석 분류 결과를 얻을 수 있었다. 충분한 훈련 데이터의 확보와 훈련 모델의 정확도 개선을 통해 Jetson Nano를 활용하여 실제 야외 지질 답사에서 다양한 종류의 암석 분류에 활용 가능할 것으로 기대된다. 특히 분류 결과 낮은 정확도를 보이는 암석 종류에 대한 추가적인 데이터 확보와 지속적인 훈련자료 업데이트를 통해 개선된 분류 모델의 획득이 가능할 것으로 판단된다.

Jetson Nano는 전원 연결 후 USB 어댑터를 사용해 소형 모니터 등의 이동 가능한 장치를 연결하여 야외에서 편리하게 사용 가능하다. Jetson Nano는 CSI(Camera Serial Interface) 카메라인 라즈베리파이 V2 카메라를 쉽게 지원하여 자주 사용되며, 카메라를 사용하여 사진 및 동영상 촬영이 가능하다. 본 연구에서 진행하였던 암석 이미지를 통한 Jetson Nano에서의 분류뿐만 아니라 Jetson Nano 장치를 사용하여 영상 내 객체 탐지 및 분류, 카메라 연결을 통한 실시간 객체 탐지가 가능하다. 추후 이동식 모니터 및 소형 카메라의 장착이 가능한 Jetson Nano 장치를 이용하여 실제 야외 지질 현장에서의 실시간 암석 분류 연구에 활용할 수 있을 것으로 기대된다.

2. 확장된 암석 분류 모델 제작

본 연구에서는 암석 6종류를 선정하여 암석 분류 연구를 진행하였다. 실제 자연에는 다양한 암석 종류가 존재하며, 추후 다양한 암석 종류들을 추가하여 추가된 암석들을 포함한 분류 모델을 제작할 수 있다. 지오빅데이터 오픈플랫폼에서 제공하는 응회암(Tuff), 반려암(Gabbro), 석회암(Limestone) 등 본 연구에서 사용하지 않은 암석 이미지를 활용하여 추가 자료 수집 후 분류 모델의 암석 종류를 확장할 수 있다. 또한, 암석 종류의 확대가 아닌 암석 세분화를 통한 분류 모델 확장도 필요할 것으로 판단된다. 현무암, 화강암과 같은 암석 종류 하나씩에 대해서도 광물 조성 및 구성 비율 등에 따라 더욱 세분화하여 분류할 수 있다. 본 연구에서 분류 대상으로 선정하였던 이암 역시 실트암, 점토암 등 보다 구체적인 암석의 분류가 가능하다. 실제 현장에서의 활용 상황을 고려할 때, 결론적으로 암석 종류의 추가, 세분화된 암석 분류를 목적으로 하는 추가 자료 수집과 확장된 분류 모델 제작을 위한 지속적인 연구가 필요할 것으로 사료되며, 지오빅데이터 오픈플랫폼의 암석 데이터를 활용한 꾸준한 암석 분류 모델의 업데이트가 가능할 것으로 기대된다.

3. 새로운 지질자원 데이터 분류 및 활용

지오빅데이터 오픈플랫폼에서 제공하는 국토지질 및 시료분석에 해당하는 자료로는 암석 자료 이외에 화석, 광물 및 광물 박편 사진 등이 있다. 실제 이들을 인공지능 분류 모델 제작을 위한 훈련 자료로 사용하여 지질학적 현장 및 실험실에서의 분류에 활용할 수 있다. 그중에서도 특히 박편 사진을 활용하면 보다 상세한 암석의 분류가 가능하다. 구성하고 있는 광물들의 조성, 비율 등의 정보를 모두 반영한 암석 분류를 위하여 딥러닝을 통해 분류 모델을 제작할 수 있을 것으로 기대된다. 또한 화석 자료의 경우, 지질학 현장에서의 화석 탐지 및 분류 이외에도 특정 화석에 해당하는 지질 연대 추정이 가능하여 지질 답사 시 교육 목적으로도 유용하게 사용될 수 있을 것으로 기대할 수 있다.

VI. 참고문헌

- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798–1828.
- Brownlee, J. (2018). What is the Difference Between a Batch and an Epoch in a Neural Network?. *Machine Learning Mastery*, 20.
- Devarakonda, A., Naumov, M., & Garland, M. (2017). Adabatch: Adaptive batch sizes for training deep neural networks. *arXiv preprint arXiv:1712.02029*.
- Pham, C., & Shin, H. S. (2020). A Feasibility Study on Application of a Deep Convolutional Neural Network for Automatic Rock Type Classification. *Tunnel and Underground space*, 30(5), 462–472.
- Ran, X., Xue, L., Zhang, Y., Liu, Z., Sang, X., & He, J. (2019). Rock classification from field image patches analyzed using a deep convolutional neural network. *Mathematics*, 7(8), 755.
- Raymond, L. A. (1999). *퇴적암석학*. 시그마프레스.
- Raymond, L. A., 정지근, & 이종만. (2003). *화성암석학*. 시그마프레스.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779–788).
- Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.
- Ren, W., Zhang, M., Zhang, S., Qiao, J., & Huang, J. (2020). Identifying rock thin section based on convolutional neural networks.
- Russell, S., & Norvig, P. (2002). *Artificial intelligence: a modern approach*.
- Sharma, O. (2019, February). Deep challenges associated with deep learning. In *2019 international conference on machine learning, big data, cloud and parallel computing (COMITCon)* (pp. 72–75). IEEE.
- Su, C., Xu, S. J., Zhu, K. Y., & Zhang, X. C. (2020). Rock classification in petrographic thin section images based on concatenated convolutional neural networks. *Earth Science Informatics*, 13(4), 1477–1484.
- Wentworth, C. K. (1922). A scale of grade and class terms for clastic sediments. *The journal of geology*, 30(5), 377–392.
- Zhang, Y., Wang, G., Li, M., & Han, S. (2018). Automated classification analysis of geological structures based on images data and deep learning model. *Applied Sciences*, 8(12), 2493.
- 국경완. (2019). 인공지능 기술 및 산업 분야별 적용 사례. *주간기술동향*, 20, 15–27.
- 박진아, & 용환승. (2018). 텐서플로우 기반의 콘볼루션 신경망을 이용한 암석 이미지 분류. *한국정보과학회 학술발표논문집*, 1121–1123.
- 안건상. (2012). *암석학 개론*. 북스힐.
- 안성만. (2016). 딥러닝의 모형과 응용사례. *지능정보연구*, 22(2), 127–142.
- 이재성. (2016). 심층 신경망의 발전 과정과 이해. *한국통신학회지(정보와 통신)*, 33(10), 40–48.