

2022년 지질자원 데이터 활용 및 인공지능 경진대회 최종 제안서

R-DoGAN: GAN 기반 인지 손실함수와 DoG 멀티스케일 입력을 활용한 절리선 분할 특화 모형

김진언¹⁾, 임준수²⁾, 송재준³⁾

I. 모형 개발 배경

1. 절리선 조사 자동화를 위한 기계학습 기반 모형 개발

일반적인 암반면 절리선 조사는 조사자가 직접 수동으로 수행하지만, 이러한 방법은 오랜 시간과 비용이 소요되며 조사면의 위치와 크기 등에 따라 수행 자체가 제한되는 경우가 많다. 따라서, 절리선 조사 자동화를 위해 암반 이미지를 입력받아 이미지에 나타난 절리선을 분할(혹은 추정)하는 기계학습 모형을 개발하고자 한다.

2. 기존의 기계학습 기반 절리선 분할 모형

절리선 조사 자동화를 위해 CNN(convolutional neural network) 기반의 절리선 분할 모형들이 제안된 바 있다(Chen et al., 2021; Byun et al., 2021; Lee et al., 2022). 해당 모형들은 모두 encoder-decoder의 U-Net 모형을 기본으로 하여 ASPP(atrous spatial pyramid pooling) 모듈을 encoder에 적용시킨 공통점이 있으며, convolution layer 개수(Chen et al., 2021), skip connection 개수 및 전처리·후처리 적용(Byun et al., 2021)과 encoder backbone 구조(Lee et al., 2022) 등에 차이가 있다. 제안된 절리선 분할 모형 모두 전통적인 이미지 처리 기법에 비해 성능이 우수하지만, 분할된 절리선의 두께가 상대적으로 두꺼우며 분할 결과에 잡음(noise)이 다수 존재하여 정밀도(precision)가 낮다는 한계점이 있다(Byun et al., 2021; Lee et al., 2022). 컴퓨터 비전 연구에서 일반적으로 다루는 도시 전경 이미지, 도로 이미지 및 방 내부 이미지를 위해 개발된 CNN 모형에서 레이어 일부를 수정하여 절리선 분할에 적용하기 보다는, 절리선 분할 과제의 특성을 고려한 과제특화된(task-specific) CNN 모형을 제안 및 개발하여 기존 모형들의 한계점을 극복하고자 하였다.

1) 서울대학교/에너지시스템공학부/에너지자원공학과/김진언 (kjineon@snu.ac.kr)

2) 서울대학교/에너지시스템공학부/에너지자원공학과/임준수 (sooyalim@snu.ac.kr)

3) 서울대학교/에너지시스템공학부/에너지자원공학과/송재준 (songjj@snu.ac.kr)

3. AI 모형 개발 부문의 암반 이미지 데이터

제안한 모델을 학습시키기 위해 KIGAM에서 제공하는 디지털 카메라로 촬영한 암반 이미지 150개 및 각 이미지에 상응하는 절리선 레이블(label) 이미지로 구성된 데이터셋을 이용하였다. 데이터셋은 관악산, 북한산, 동해시 임계면, 포천시 신북면, 정선 남면 및 화암면 일대에서 촬영하였고, 임의 형상의 조사면에서 임의 크기, 빈도, 방향성의 절리를 포함한다.

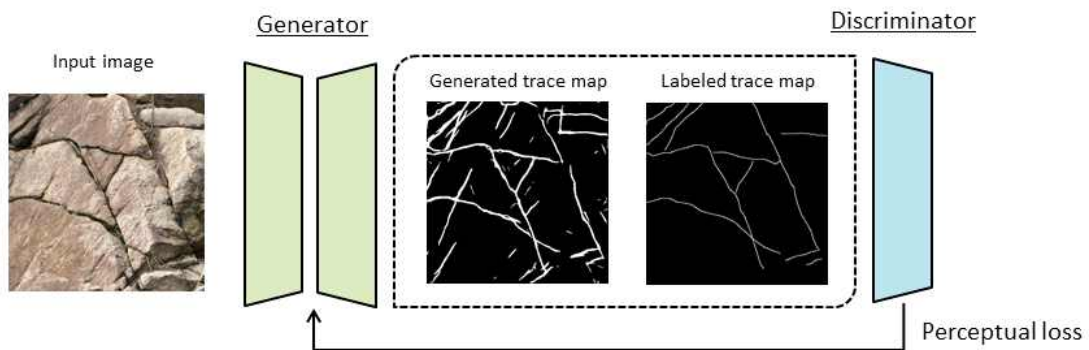
II. 모형 개발

1. 절리선 분할에 특화된(task-specific) 모형 개발

(1) 절리선 분할에 특화된 손실함수: GAN 기반의 인지 손실함수(perceptual loss)

기존의 절리선 분할 모형들은 픽셀별(pixel-wise) 개별 비교를 통해 연산되는 Cross-Entropy를 손실함수로 사용하였는데, 분할 결과를 픽셀별로 비교하여 도출한 손실함수는 대상 객체의 거시적인 공간 분포 특성 및 형태를 반영하지 못해(Zhang et al., 2018) 절리선의 공간적 분포 및 형태가 중요시되는 절리선 분할 모형 학습에는 한계가 있다.

이를 극복하기 위해 저차원의 픽셀 정보로 연산되는 기존 손실함수와 달리, 사람이 인지하는 절리선 레이블(label)과 인공지능 모형의 절리선 분할 결과의 차이를 표현한 인지 손실함수(perceptual loss)(Zhang et al., 2018)를 절리선 분할 모형 학습에 활용하고자 하였다. 인지 손실함수를 구성하기 위해 그림 1과 같이 GAN 구조의 절리선 분할 CNN 모형을 개발하였으며, GAN 구조에서 판별기의 encoder 레이어 내 고차원 특성맵(feature map)에서의 결과 간 차이를 활용해 인지 손실함수를 연산하였다.




[그림 1] GAN 구조를 이용한 절리선 분할 및 인지 손실함수 구성

(2) 절리선 분할에 특화된 입력층: 멀티스케일 경계정보(DoG pyramid)

절리선 분할 과제는 이미지 내에 존재하는 선 형태의 경계(edge) 중에서 절리선인 것과 아닌 것을 구분하는 과제로 볼 수 있다. 이와 같은 관점에서, 절리선 분할 모형의 입력자료로 암반 이미지 원본뿐만 아니라, 해당 이미지의 경계정보도 함께 입력하면 CNN 모형이 더욱 효과적으로 절리선 분할을 학습 및 수행할 수 있을 것으로 판단하였다.

이미지의 경계정보는 이미지 특성 추출 기법 중 하나인 SIFT(scale invariant feature transform)의 연산 방식(Lowe, 1999)에서 착안하여, 이미지를 여러 해상도로 변환한 뒤 경계 특성을 추출하는


DoG(difference of Gaussian) pyramid를 활용하였다. 그림 2와 같이, 원본 이미지에 단계별로 Gaussian 블러링(blurring)을 적용하고, 블러된 이미지 간의 차이를 계산하여 DoG pyramid를 도출한다. 이렇게 도출한 DoG pyramid는 단계별 블러링 및 샘플링(sampling)을 통해 다양한 이미지 스케일의 경계정보를 담게 되는데, 본 모형의 개발과정에서는 연산 효율성 및 CNN 모형 입력층 크기를 고려하여 블러링 ($\sigma = \sqrt[3]{2}$)만을 적용한 DoG pyramid를 입력자료로 활용하였다. DoG pyramid를 입력자료로 활용하여 동일한 이미지에 대해 다양한 해상도의 경계정보를 고려하여 암반 이미지 해상도(혹은 암반 노두면 규모)와 무관하게(scale-invariant) 절리선을 분할하는 강건한 모형을 학습시키고자 하였다.



[그림 2] 멀티스케일 경계정보를 추출한 DoG 이미지

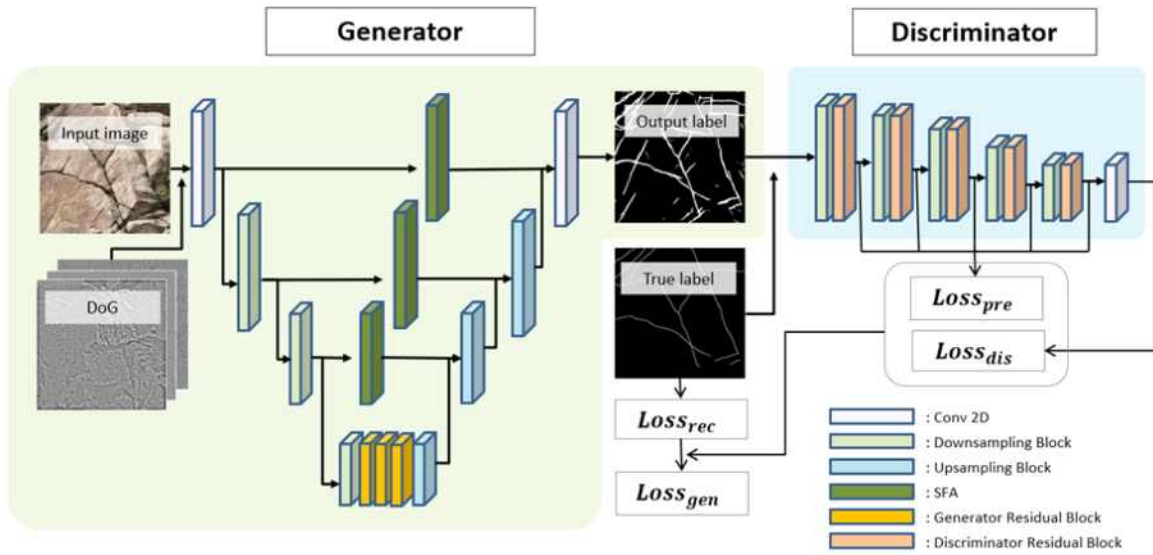
2. 모형 설계 및 실행 환경

앞서 제안한 인지 GAN 기반 손실함수와 DoG 입력자료를 적용한 절리선 분할에 특화된 CNN 모형으로서, R-DoGAN (Rock-DoG-GAN)을 새롭게 설계 및 개발하였다. GAN 기반 CNN 모형의 기초 모형(baseline model)으로서 안구 이미지의 안구 혈관 분할 과제에서 현재 최고 성능(state-of-the-art; SOTA)을 보여주는 RV-GAN (Karman et al., 2019) 구조를 활용하였다. 이는 안구 혈관 분할 과제와 절리선 검출 과제가 선형의 특징을 지니는 대상으로 하기 때문에 기타 비선형 대상의 검출 과제를 수행하는 모형 구조를 활용하는 것보다 더 적합하다고 판단했다. 두 과제의 유사성은 그림 3에서 확인할 수 있다.

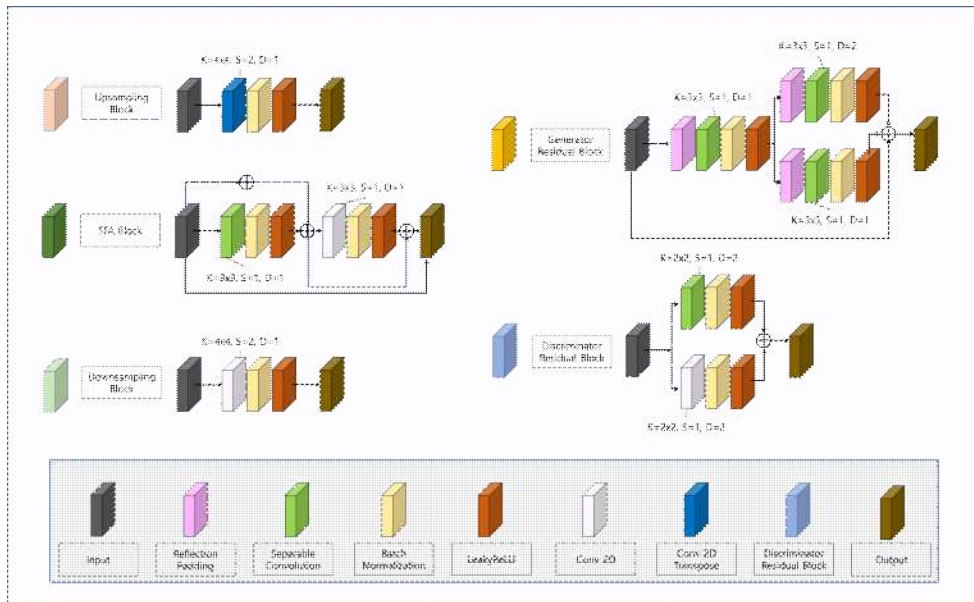


[그림 3] 절리선 검출 과제에 대한 안구 혈관 분할 과제와 비선형 대상 분할 과제의 유사성 비교

Karman et al (2019)은 이미지 특징을 잘 보존하기 위해 생성기와 판별기용 residual block, SFA (Spatial Feature Aggreagation) block를 이용하였고, 모델을 가볍게 하기 위해 판별기를 auto encoder 형태로 구현하였다는 특징이 있다. 결과적으로, RV-GAN 구조를 활용함으로써 선형의 대상을 검출하는 절리선 분할 결과와 매우 유사한 분할 결과를 생성하는 고성능 모델을 계획하였다. Github에 게시된 Karman et al., (2019)의 RV-GAN 모델 코드를 기초로 활용하였으며, 절리선 분할 과제에 적합하도록 모델 구조를 수정하였다. 2개의 채널(fine과 coarse)로 구성되었던 기존의 모델 구조를 1개의 채널로 통일시키고, 기존 연구(Byun et al., 2021; Chen et al. 2021; Lee et al., 2022)의 샘플링 횟수를 참고하여 생성기의 레이어 개수를 수정하였으며, 절리선 분할 결과 특성을 고려하여 판별기의 decoder 부분을 제거하였다. 개발한 R-DoGAN 모델의 전체 구조는 그림 4 및 그림 5와 같다. 기반 코드는 Python, 주요 라이브러리는 Tensorflow 및 Keras를 활용하여 R-DoGAN을 개발하였다.



[그림 4] R-DoGAN 모델 구조



[그림 5] R-DoGAN을 구성하는 블록들의 상세 구조

3. 모형 학습

모형 학습을 위해 총 150장의 암반 이미지 중 140장을 학습 데이터로 활용하였다. 학습된 모형의 성능을 평가하기 위한 테스트 데이터로 10장의 이미지를 활용하였으며, 해당 이미지들은 기존 연구 (Byun et al. 2021; Lee et al., 2022)에서 제시된 이미지를 참고하였다. 데이터 증강과 학습 연산량을 고려하여 256x256 크기의 이미지로 분할하였으며, 추가로 이미지 회전 및 이미지 대비 변화를 통해 총 11624장의 학습 데이터를 활용하여 모형을 학습시켰다. 모형은 총 20 epoch 학습하였다.

인지 손실함수($Loss_{pre}$)에는 absolute difference분류 오차($Loss_{dis}$)에는 hinge loss, 생성기의 절리선 분할 생성 오차 ($Loss_{rec}$)에는 클래스 불균형을 고려하여 balanced hinge loss을 활용하였다. 클래스 가중치는 Lee et al. (2022)과 동일하게 각 클래스에 해당하는 픽셀 개수의 역수로 설정하였다.


III. 모형 성능 평가

1. 절리선 분할 성능 평가 및 손실함수(GAN)와 입력(DoG) 효과 확인


(1) R-DoGAN, R-GAN 및 baseline 모형의 성능 평가

R-DoGAN의 성능을 평가하고 인지 손실함수 및 DoG 입력의 효과를 검증하기 위해, R-DoGAN 모형 구조에서 DoG 입력을 제거한 R-GAN 모형과 R-DoGAN 모형 구조에서 DoG 입력과 인지 손실함수를 모두 제거한 baseline 모형도 함께 학습하여 R-DoGAN과 성능을 비교하였다.

학습된 R-DoGAN, R-GAN 및 baseline 모형의 절리선 분할 테스트 결과는 그림 6과 같다. 세 모형의 절리선 분할 결과가 전반적으로 유사하나 R-DoGAN 및 R-GAN의 분할 결과에서 잡음이 상대적으로 적은 것을 확인할 수 있다.



[그림 6] R-DoGAN, R-GAN 및 baseline 모형의 절리선 분할 결과 (계속)



[그림 6] R-DoGAN, R-GAN 및 baseline 모형의 절리선 분할 결과 (계속)

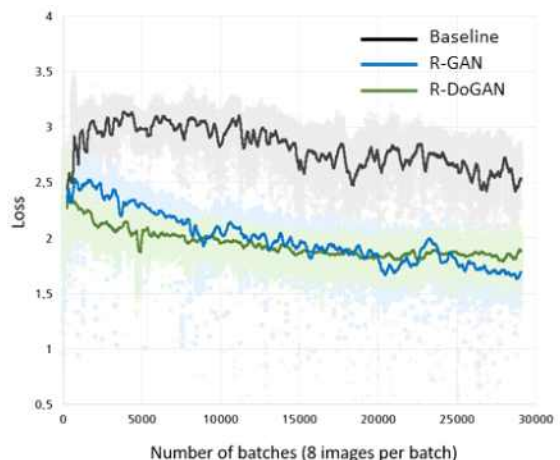
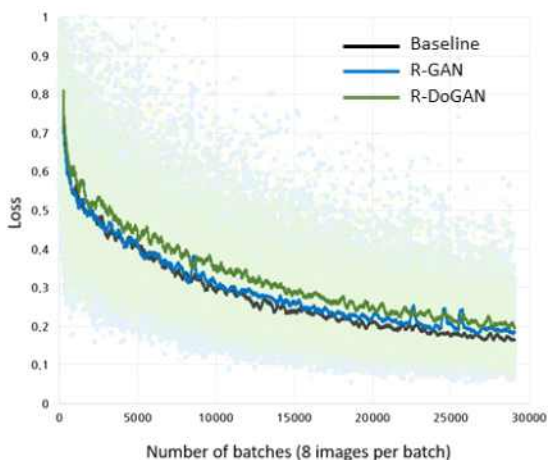
각 모형의 성능 지표를 정리하면 표 1과 같다. Baseline 모형에 비해 R-GAN의 절리선 분할 결과의 IoU 및 precision이 더 높았다. 이는 판별자의 인지 손실함수를 이용하여 더 높은 정밀도로 절리선을 분할할 수 있음을 의미한다. R-DoGAN과 R-GAN을 비교했을 시에는, R-DoGAN의 recall이 더 높았으나 전반적인 성능을 대표하는 IoU는 R-GAN이 더 높았다. DoG 입력을 통해 성능 개선을 기대하였으나 원본 이미지만으로 학습하여도 R-GAN 모형이 절리선 분할에 요구되는 이미지 특성을 충분히 도출하는 것으로 보인다. DoG 입력이 없더라도 학습하는 과정에서 DoG에 해당하는 이미지 특성을 모형의 은닉층에서 스스로 학습하여 절리선을 분할한 것으로 판단된다.

[표 1] R-DoGAN, R-GAN 및 baseline의 비평탄 암반 이미지의 절리선 분할 결과

	IoU	Precision	Recall	Mean IoU
(1) Baseline	0.332	0.359	0.815	0.651
(2) R-GAN	0.345	0.391	0.743	0.660
(3) R-DoGAN	0.326	0.361	0.766	0.649

(2) 손실 변화로 살펴본 인지 손실함수 및 DoG 입력의 효과

인지 손실함수 및 DoG 입력의 효과를 확인하기 위해 R-DoGAN, R-GAN 및 baseline 모형의 학습과정 중 손실(loss)을 그림 7과 같이 비교해보았다. 각 모형의 성능지표에는 차이가 있었으나 생성기의 절리선 분할 오차($Loss_{rec}$)만으로 고려했을 경우 세 모형 모두 유사한 경향으로 감소하였다. 그러나 인지 손실($Loss_{pre}$)의 경우, Baseline 모형과 R-DoGAN 및 R-GAN 간에 뚜렷한 차이가 있었다. Baseline 모형은 절리선 분할 오차가 유사하게 감소했음에도 불구하고 인지 손실은 거의 변화하지 않았으며, R-DoGAN과 R-GAN은 절리선 분할 오차와 함께 인지 손실함수도 감소하였다. 인지 손실함수를 감소시키는 방향으로 학습된 R-GAN이 baseline에 비해 높은 성능을 나타내는 것으로 보아 인지 손실함수가 모형의 성능 개선에 직접적으로 기여했음을 알 수 있다. 더 나아가, GAN의 판별기에서 도출한 인지 손실함수가 기존의 절리선 분할 오차에는 반영되지 않았던 절리선 분할 결과 간 차이를 반영했다고 볼 수 있다. 참고로 baseline 모형의 인지 손실은 학습에는 반영되지 않았으며 R-DoGAN 및 R-GAN과 비교를 위해 학습과정에서 도출하였다.




[그림 7] 학습과정에서의 (좌) 생성기 절리선 분할 오차와 (우) 인지 손실 변화

R-DoGAN과 R-GAN을 비교했을 시에, R-DoGAN의 손실이 학습과정에서 변동성(fluctuation)이 더 적었으며, 학습 초기에 인지 손실이 R-GAN에 비해 더 빠르게 감소하였다. 이는 R-DoGAN이 이미지 경계 정보를 담은 DoG를 입력자료로 활용하여 학습이 더 안정적으로 이뤄진 것으로 판단된다. 그러나, 학습 후반부에 R-DoGAN의 손실 감소세가 약화되어 R-GAN과 역전된다는 점에서 추후 연구를 통해 DoG 자료의 입력 및 학습 방식을 개선할 필요가 있다.

2. 기존 모형과의 성능 비교

개발된 R-DoGAN의 성능을 Lee et al. (2022)와 Byun et al. (2021)의 모형과 비교해보았다. 그림 8과 같이, R-DoGAN의 분할 결과가 Lee et al. (2022)에 비해 절리선 두께가 얇고, 잡음이 적으며, 미세 절리에 대한 인식률이 높았다. 성능 지표를 도출하여 기존 모형들의 지표와 비교한 결과(표 2와 표 3 참조), R-DoGAN 및 R-GAN의 IoU가 기존의 모형들에 비해 높았으며, Byun et al. (2021)에 비해서는 recall이 상대적으로 높았으며, Lee et al. (2022)에 비해서는 precision이 상대적으로 높았다.

R-DoGAN 및 R-GAN의 파라미터 개수가 Byun et al. (2021)과 Lee et al. (2022)에 비해 약 2배 그리고 약 10배 이상 작다는 점을 고려했을 때, 향후 본 개발에서 제안한 GAN 기반 인지 손실함수와 DoG 입력을 더 큰 모형에 적용하여 고성능 절리선 분할 모형을 개발할 수 있을 것으로 기대된다.



[그림 8] R-DoGAN과 Lee et al. (2022)의 절리선 분할 결과: (좌) 평탄 이미지와 (우) 비평탄 이미지

[표 2] Byun et al. (2021)과 R-DoGAN 및 R-GAN의 평탄 이미지 절리선 분할 성능 비교

	IoU	Precision	Recall	Number of parameters
(1) Byun et al.	0.380	0.510	0.643	4.88×10^6
(2) R-GAN	0.453	0.532	0.754	2.02×10^6
(3) R-DoGAN	0.444	0.502	0.794	2.02×10^6

[표 3] Lee et al. (2022)과 R-DoGAN 및 R-GAN의 절리선 분할 성능 비교

	IoU	Precision	Recall	Number of parameters
(1) Lee et al.	0.321	0.325	0.961	more than 2.28×10^7
(2) R-GAN	0.345	0.391	0.743	2.02×10^6
(3) R-DoGAN	0.326	0.361	0.766	2.02×10^6

IV. 활용방안 및 추후계획

절리선 분할에 특화된 모형인 R-DoGAN을 활용하여 노동집약적이고 시간소모적인 절리선 조사 작업의 형상의 조사면에서도 신속·정확하게 수행할 수 있을 것으로 기대된다. 모형의 성능을 향상시키기 위해 R-DoGAN에 적용된 DoG 자료의 입력 및 학습 방식을 개선하여 R-GAN 역전 현상을 방지하는 방법을 탐구할 계획이다. 더 나아가 고성능 절리선 분할 모형 개발을 목적으로 기존의 모형 규모를 확장하고 추가 학습자료를 습득 및 증강하는 방안도 구상하고 있다.

참고문헌

- Byun H., Kim J., Yoon D., Kang I.-S. and Song J.-J., 2021, A deep convolutional neural network for rock fracture image segmentation, *Earth Science Informatics*, <https://doi.org/10.1007/s12145-021-00650-1>
- Chen J., Zhou M., Huang H., Zhang D. and Peng Z., 2021, Automated extraction and evaluation of fracture trace maps from rock tunnel face images via deep learning, *International Journal of Rock Mechancis and Mining Sciences*, <https://doi.org/10.1016/j.ijrmms.2021.104745>
- Kamran S. A., Hossain K. F., Tavakkoli A., Zuckerbrod S. L., Sanders K. M. and Baker S. A., 2021, RV-GAN: Segmenting retinal vascular structure in fundus photographs using a novel multi-scale generative adversial network, *arXiv:2101.00535v2*
- Lee Y.-K., Kim J., Choi C.-S. and Song J.-J., 2022, Semi-automatic calculation of joint trace length from digital images based on deep learning and data structuring techniques, *International Journal of Rock Mechancis and Mining Sciences*, <https://doi.org/10.1016/j.ijrmms.2021.104981>
- Lowe D.G, 1999, Object recognition from local scale-invariant features, *Proc. of the International Conference on Computer Vision*, Sept. 1999
- Zhang R., Isola P., Efros A.A, Shechtman E. and Wang O., 2018, The unreasonable effectiveness of deep features as a perceptual metric, *arXiv:1801.03924v2*