

딥러닝 알고리즘을 활용한 SAR 이미지 채색

이정훈, 김경록*, 김재현*

아주대학교 AI융합네트워크학과, *아주대학교 전자공학과
{geniuslee20, nowhere1104, jkim}@ajou.ac.kr

SAR Image Coloring using Deep Learning Algorithm

Jung-Hoon Lee, Kyeongrok Kim*, and Jae-Hyun Kim*

Department of AI Convergence Network, Ajou Univ.

*Department of Electrical and Computer Engineering, Ajou Univ.

요약

본 논문에서는 흑백의 SAR 이미지를 채색하기 위해 cycle generative adversarial network (GAN)을 사용하여 원본 이미지와 유사한 이미지를 생성하고, 생성한 이미지와 원본 이미지와의 정확도를 비교한다. 광학 이미지 및 SAR 이미지는 중국 도시의 이미지를 사용하였다. SAR 이미지의 단점인 데이터셋의 부족은 data augmentation을 사용하여 보완한다. 생성된 이미지 및 원본 이미지의 유사도는 SSIM, MSE 및 PSNR을 사용하여 계산되며, 평균 SSIM은 0.7358, 평균 MSE는 934.3575, 평균 PSNR은 18.5310으로 측정되었다. 측정 결과, 생성된 이미지는 원본 이미지와 유사함을 확인할 수 있다.

I. 서론

Synthetic aperture radar (SAR) 기술은 밤낮 구분 없이 전천후로 관측이 가능하다는 장점이 있지만, SAR 인공위성이 적기 때문에 데이터셋이 부족하여 가격이 비싸다는 것과 후방 산란된 전파들이 가시 스펙트럼에 없기 때문에 색상이 지정되지 않아 흑백으로만 영상이 제공되는 단점이 존재한다. 이 단점들을 보완하기 위해 원본과 유사한 이미지를 생성하는 방법을 시도하고 있으며, 최근에는 딥러닝을 이용하여 SAR 영상 이미지를 처리하는 연구가 늘어나고 있다 [1]. 딥러닝 모델 중에서 대표적인 모델은 generative adversarial network (GAN)이다. 생성자는 판별자가 구분할 수 없도록 진짜 같은 가짜 이미지를 생성하며, 판별자는 생성자가 만든 이미지가 진짜인지 가짜인지 판별한다. 본 논문에서는 SAR 이미지를 컬러화하기 위해 CycleGAN 모델을 사용한다. 사용한 프로그램은 Python이며, Sentinel-1의 SAR 이미지를 사용하였다.

II. 이론

본 논문에서 사용한 GAN 모델은 CycleGAN이다. CycleGAN를 선택한 이유는 서로 다른 데이터셋을 가지고도 이미지를 생성할 수 있는 모델이기 때문이다. CycleGAN은 생성자와 판별자가 각각 2개씩으로 이루어져 있으며, 구조는 그림 1과 같다. 2개의 생성자와 판별자는 원본 이미지와 생성된 이미지를 반복적으로 학습하면서 순환 손실 함수를 점차 줄여간다. 순환 손실 함수는 2개의 생성자와 판별자를 거쳐 생성된 이미지와 원본 이미지와의 차이를 나타낸 함수이다. 이미지의 정확도를 판별하기 위해 보편적으로 사용되는 지표인 MSE, PSNR, 그리고 SSIM을 사용한다. 첫 번째 지표는 평균 제곱 오차 (Mean squared error, MSE)이며, 원본

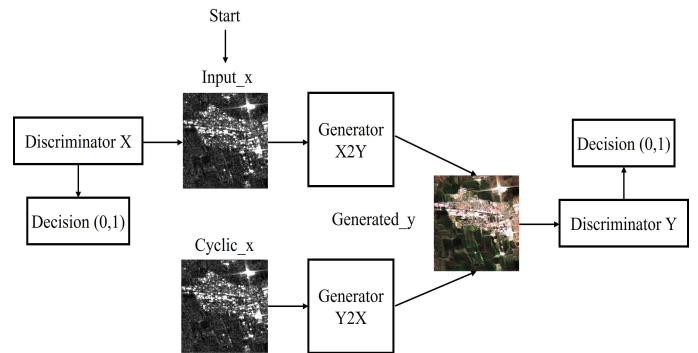


그림 1. CycleGAN의 구조

이미지와 출력 이미지, 두 이미지의 픽셀 값들의 차이에 대한 측정값을 나타낸다. 식은 다음과 같다.

$$SE = \frac{1}{IJ} \sum_{i=0}^{I-1} \sum_{j=0}^{J-1} e(i,j)^2, \quad (1)$$

$e(i,j)^2$ 은 이미지의 픽셀 값들의 평균 오차를 의미하며, I 와 J 는 이미지의 행과 열이다. 두 번째 지표는 최대 신호 대 잡음비 (Peak signal-to-noise ratio, PSNR)이다. PSNR은 신호가 가질 수 있는 최대 전력에 대한 잡음의 전력을 나타낸 것이며, MSE처럼 영상 또는 동영상에서 화질이 얼마나 손실되었는지 평가할 때 사용한다. PSNR을 계산할 때 식은 다음과 같다.

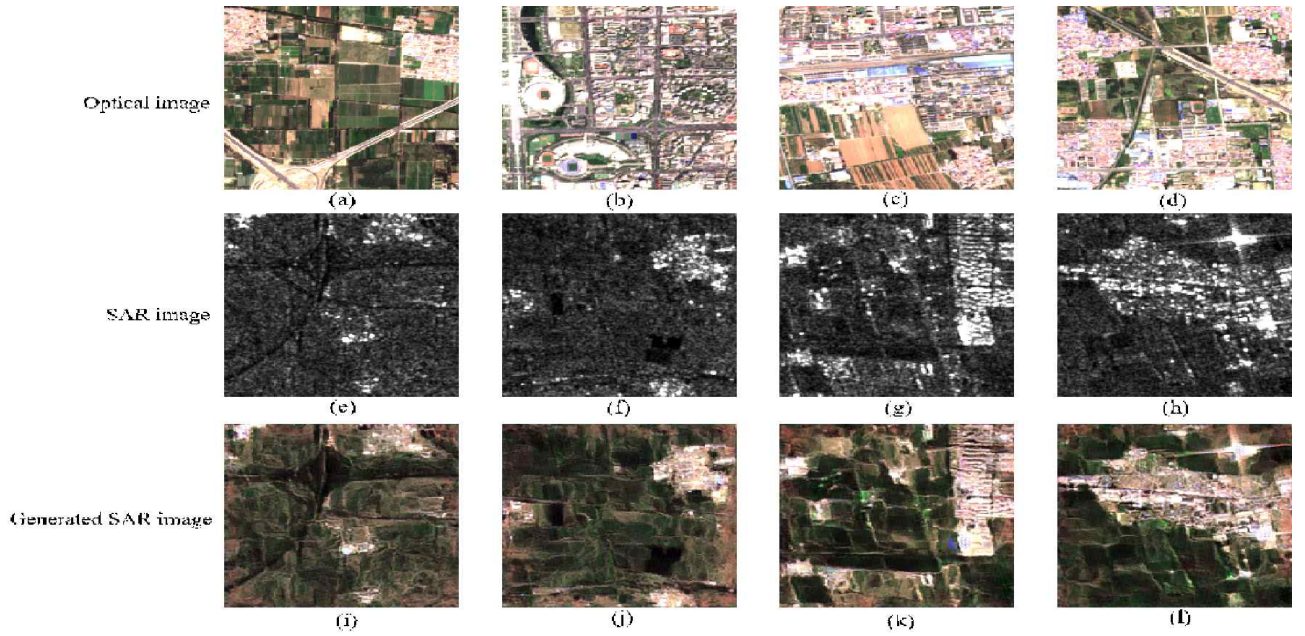


그림 2. 원본 광학-SAR 이미지와 생성된 SAR 이미지

표 1. 원본 이미지와 생성된 이미지의 정확도 비교 지표

이미지	SSIM	MSE	PSNR(dB)
(e), (i)	0.7606	639.4379	20.0728
(f), (j)	0.7306	883.2196	18.6701
(g), (k)	0.7356	1016.5152	18.0597
(h), (l)	0.7165	1198.2574	17.3453

$$SNR = 10 \log_{10} \left(\frac{MAX^2}{MSE} \right), \quad (2)$$

MAX^2 는 해당 이미지의 최댓값을 의미하며, 해당 채널의 최댓값에서 최솟값을 소거하면 되며, 마지막 지표는 구조적 유사도 지수 (Structural similarity, SSIM)이다. SSIM은 압축 및 변환 등 발생하는 현상들에 대하여 원본 영상과 얼마나 유사한지 측정하는 지표이다. SSIM의 수식은 다음과 같다.

$$SSIM(a,b) = [l(a,b)^\alpha \ c(a,b)^\beta \ s(a,b)^\gamma], \quad (3)$$

a, b 는 비교할 두 이미지이며, l, c, s 는 각각 휘도, 대비, 구조를 의미한다. α, β, γ 는 이미지를 비교할 때 사용되는 계수이다.

III. 설계 및 결과

본 논문에서 사용한 데이터셋은 중국의 32 도시의 SAR 및 광학 이미지 중 두 개의 도시이다. WHU-SEN-City에서 사용한 두 개의 도시는 베이징과 상하이이다 [2]. 데이터셋에는 도로, 지형, 건물 등이 포함되어 있다. 이미지의 크기가 매우 크기 때문에 256×256 으로 사이즈를 조절한다. 또한 데이터셋의 양을 늘리기 위해 data augmentation을 시행하며, 이를 통해 늘린 데이터셋은 100개에서 2,177개이다. 늘어난 2,177개의 데이터셋 중 2,000개는 train에 사용하고, 나머지는 test에 사용한다. 이렇게 조절한 데이터셋을 입력 데이터로 사용한다. 딥러닝 모델의 epoch는 100, learning rate는 0.0002, batch size는 1로 설정하여 설계를 진행한다.

이미지 생성 결과, 생성된 SAR 이미지는 원본의 SAR 이미지의 특징을 가지고 있으면서 광학 이미지의 색깔이 입혀진 것을 확인할 수 있었다.

정확도를 수치로 알아보기 위해 SSIM, MSE, PSNR을 계산한다. 원본 이미지와 생성된 이미지의 SSIM, MSE, PSNR은 표 1과 같다. SSIM은 1에 가까울수록 두 이미지가 유사하다는 것을 나타낸다. 네 개의 원본 이미지와 생성된 이미지를 비교해보면, 지방 쪽이 도시보다 더 나은 지표를 가지고 있다는 것을 알 수 있다. 그 이유는 도시에는 건물에 반사되는 빛이나 가로등과 같은 인공조명이 있어, SAR 이미지를 촬영할 때 이미지를 왜곡시키기 때문이다.

IV. 결론

본 논문에서는 CycleGAN 모델을 활용하여 이미지를 생성하는 모델을 설계하였다. 실험 결과, 생성된 SAR 이미지는 원본 SAR 이미지의 형태를 유지하면서 광학 이미지의 색체에 따라 색칠되는 것을 확인하였다. 특히, 이미지끼리 비교한 결과 도시의 이미지 보다는 지방의 이미지가 더 정확하다는 것을 알 수 있었다. SAR 이미지의 단점인 흑백 이미지는 SAR 이미지의 컬러화로 보완이 가능하며, 데이터셋의 부족 역시 딥러닝을 통해 늘릴 수 있다. 추후 연구에서는 생성된 데이터셋을 이용해 자연재해 분석을 진행할 예정이다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구 센터지원사업의 연구결과로 수행되었음. (IITP-2021-2018-0-01424)

참고 문헌

- [1] J. Hwang, C. Yu, and Y. Shin, "SAR-to-Optical Image Translation Using SSIM and Perceptual Loss Based Cycle-Consistent GAN," in *Proc. ICTC 2020*, pp. 191-194, Jeju Island, Korea, Oct. 2020.
- [2] L. Wang et al. "SAR-to-optical image translation using supervised cycle-consistent adversarial networks," *IEEE Access*, vol. 7, pp. 129136-129149. Sep. 2019.