

딥러닝을 활용한 강릉지역 적외선 산불 이미지 생성

박 범 순*, 이 원 재*, 김 재 현^o

Establishment and Utilization of Infrared Forest Fire Image Generation Model in Gangneung Area Using Deep Learning

Beom-sun Park*, Won-jae Lee*, Jae-hyun Kim^o

요 약

강원지역 등 대형 산불의 지속적인 발생으로 인명 및 재산 피해가 발생하고 있다. 산불 분석시 활용되는 광학이나 적외선 위성 영상은 데이터 세트의 양이 부족하다는 제한사항이 발생한다. 이는 산불 이미지 분석 등 각종 목적에 적합한 영상을 얻기 어렵다는 것이다. 이러한 문제점은 딥러닝을 이용해 부족한 데이터 세트의 양을 보완할 수 있다. 딥러닝 모델인 CycleGAN(Cycle Generative Adversarial Network)을 통한 강릉지역 산불 이미지 생성에 대해 소개한다. 원본 적외선 이미지나 광학 이미지와 유사한 이미지를 생성하여 산불 이미지 분석에 활용할 수 있다. 생성 모델의 정밀도를 비교하기 위해 평가지표인 SSIM(Structural Similarity Index Measure)과 PSNR(Peak Signal-to-Noise Ratio)를 이용하여 정밀도를 측정하였다.

키워드 : 딥러닝, 산불, 적외선, 광학, 이미지

Key Words : Deep learning, Forest fire, Infrared, Optical, Image

ABSTRACT

Due to the continuous occurrence of large-scale forest fires in the Gangwon region, human life and property damage are occurring. Optical or infrared satellite images used in forest fire analysis are limited by the lack of data sets. This means that it is difficult to obtain images suitable for various purposes such as forest fire image analysis. This problem can be compensated for by the insufficient amount of data set using deep learning. We introduce forest fire image generation in the Gangneung region through CycleGAN(Cycle Generative Adversarial Network), a deep learning model. Images similar to the original infrared or optical images can be generated and used for forest fire image analysis. In order to compare the accuracy of the generative model, the accuracy was measured using SSIM(Structural Similarity Index Measure) and PSNR(Peak Signal-to-Noise Ratio), which are evaluation indicators.

* 본 연구는 한국연구재단의 지원을 받아 수행된 기초연구사업(No. 2021R1A4A1030775)과 정보통신기획평가원(IITP-2023-2018-0-01424)의 지원을 받아 수행된 연구입니다.

• First Author : Catholil Kwan Dong University Department of Aviation Maintenance, moon5bsp5@gmail.com, 정회원

o Corresponding Author : Ajou University Department of Electrical and Computer Engineering, jkim@ajou.ac.kr, 종신회원

* Ajou University Department of Artificial Intelligence Convergence Network, ljmwon@ajou.ac.kr, 학생회원

논문번호 : 202307-007-C-RN, Received July 6, 2023; Revised August 28, 2023; Accepted September 21, 2023

I. 서 론

강릉, 동해, 삼척 등 대형 산불로 인해 산림, 재산, 문화재(강원도 양양 낙산사) 피해 등이 지속적으로 발생하고 있다. 최근 10년 동안 산불 발생은 총 474건이며, 피해 면적은 1,120 ha 이다. 최근의 강원도 강릉 옥계 및 동해 산불사례 등을 보면 향후 대형 산불 위험은 여전히 존재할 것으로 예상된다. 산불 발생의 원인을 보면 실화인 인위적 요인이 대부분을 차지하고 있다. 인위적 원인인 실화를 통해 시작되어 자연 산림에 피해를 줄 만큼의 발화, 연소, 확산을 위해서는 기온, 풍속, 습도 등의 자연적인 원인과 산림 내에 가연성 물질이 소화할 수 있는 소량의 습도 등 연소 환경이 갖춰진 기상적 요인에 영향을 받을 수 있다. 인위적, 자연적 요인에 의한 산불 연구에는 산불 영상 분석이 다양하게 활용되고 있다. 이에 위성 영상 이미지에 대한 연구가 필요하였다^{1,2}.

본 논문은 적외선, 광학을 활용한 산불 영상 이미지 처리에 대해 딥러닝 모델을 활용하여 이미지를 생성하는 것을 목적으로 한다. 산불에 사용되는 영상 이미지는 충분한 양의 데이터가 부족하고, 획득된 원시 위성 영상 데이터는 원시 영상을 인식하는 것이 제한되어 연구에 사용하기 위해서는 여러 가지 처리 과정을 거쳐 데이터로 변환되어야 한다. 또한 위성 이미지에 필터링이 없는 경우에는 표면 또는 물체에서 산란되는 전자기적 간섭으로 인해 스펙클 노이즈가 발생 된다. 스펙클 노이즈는 위성 영상 이미지에 본질적으로 존재하는 하위 간섭으로, 이미지의 품질을 저하시키는 원인이 된다. 위성 영상 이미지를 사용하기 위해서는 스펙클 노이즈를 줄이는 디스펙클링(despeckling) 과정 등이 필요하다³⁻⁶.

최근 논문들은 딥러닝을 결합하여 데이터 이미지 처리에 대해 다양하게 연구하고 있다. 딥러닝은 다양한 레이어로 구성된 신경망 모델을 사용하여 레이어를 학습하는 기계 학습의 한 분야이다. 최근에는 딥러닝을 자연재해 분석 및 객체 탐지 등 다양한 분야에서 활용되고 있다. 산불 위성 영상의 단점은 기상 요인 등에 따른 원본 산불 위성 영상 데이터가 부족하다는 것이다. 이는 산불 이미지 분석에 충분한 데이터가 제한된다는 것이다⁹⁻¹⁵.

본 논문은 CycleGAN을 활용하여 부족한 산불 위성 영상 데이터 세트를 확장하여 원본 광학이나 적외선 이미지와 유사한 산불 이미지 생성에 대해 기술한다. 생성된 산불 영상 이미지를 원본 광학 이미지나 적외선 이미지와 양적 비교를 위해 SSIM(Structural Similarity Index Measure), PSNR(Peak Signal-to-Noise Ratio)

평가지표를 이용하여 정밀도를 측정하여 수치로 확인할 수 있다. 논문의 구성은 다음과 같다. 서론에서 연구 배경 및 내용, 구성을 기술하고 본문에서 상용 위성을 활용한 산불 탐지, 산불 영상 이미지에 활용하기 위한 GAN 관련 연구와 산불 이미지 생성에 대해 기술한다. 딥러닝 모델을 활용한 실험 결과를 서술하고 마지막에 결론을 도출하겠다^{16,17}.

II. 연구 동향

2.1 국내·외 산불 탐지 위성⁹⁻¹⁵

국내·외의 산불 탐지 관련 위성 중에 MODIS(Moderate Resolution Imaging Spectroradiometer)는 근적외선 파장으로부터 가시광선 파장에 해당하는 총 36개 채널을 활용 중이다. 산불에서 발생하는 플룸과 관련된 열적외선 채널 대역인 ch 21, ch 22, ch 31에서 측정된 절대온도에 따른 화염 영역을 탐지하고 있다고 알려져 있다.

KOMPSAT-3A 위성(2015년 3월 발사)은 적외선(IR) 영상, 광학(Electro-Optical) 영상 자료를 제공하고 있다. 촬영된 영상 이미지는 지리정보시스템(Geographic Information System), 해양·환경·농업 모니터링, 재난, 도시계획, 자원관리 등의 다양한 분야에서 활용되고 있다. KOMPSAT-3A 위성 영상의 공간해상도를 보면 전정색(Pan) 채널은 0.55 m, MS(Multi Spectral) 1에서 MS 4(Blue, Green, Red, NIR) 채널은 2.20 m, MWIR(Mid Wave Infra-Red) 채널은 5.5 m의 공간해상도를 활용하고 있다.

Sentinel-2 A/B MSI는 ESA(European Space Agency)에서 발사한 Sentinel-2A(2015년 발사) 위성과 Sentinel-2B(2017년 발사) 위성으로 구성된 극궤도 위성이다. Sentinel-2A MSI는 13개의 분광 밴드로 구성되어 있으며 RGB(Red, Green, Blue)와 NIR(Near Infrared) 밴드는 10 m의 공간 해상도를 가지고 있다.

2.2 위성영상정보를 활용한 산불 탐지

대형 산불의 발생은 산림자원의 소실, 생태계의 파괴, 인명과 재산의 피해를 생성한다. 따라서 산불에 대한 감시, 탐지(발화, 잠재적 발화 예상 지역 등), 산불의 확산 방향과 규모의 관측을 위해 산불 발생 전·후 영상을 비교하여 산불 피해 예방과 소방기관의 진화대책 수립, 긴급한 의사결정, 산불 관련 기관의 산불 발생 후 수습 대책 수립에 커다란 영향을 끼친다. 극궤도 기상위성에 탑재된 고해상도의 센서는 식생 및 산불의 탐지 등에 다양하게 활용되고 있다^{11,21}.

Terra/Aqua MODIS 등 전 지구적인 산불의 진행과 연소지역에 대한 탐지를 위하여 다양한 위성 자료가 사용되고 있다. 이러한 위성 영상 자료를 이용한 산불의 탐지는 크게 열적외선 구간에서 방사된 열에너지를 통해 산불의 위치, 강도 등을 실시간으로 탐지하는 진행되는 산불의 탐지와 연소지역의 분광적 특징을 이용하여 산불의 연소지의 위치 규모 등 산불 피해 정도를 분석한다. 진행되는 산불탐지는 위성의 열적외선 센서를 활용하여 산불 발생을 확인하여 대응할 수 있는 재해 방지를 목표로 한다. 진행되는 산불의 경우 위성영상이 촬영하는 시간에 발생하는 산불만 탐지하기 때문에 전체적인 산불 발생 정보 제공에는 한계가 있다. 연소지에 대한 추정은 주기적인 위성자료의 공급을 통해 산불 전후의 변화를 탐지하여 정확한 산불 피해지역의 면적 및 산림 상태를 추정하게 되고, 산림 생태량의 손실로 인한 생태계의 변화 및 산불 후 복구 연구가 진행되며, 산불 피해지역의 면적을 통해 대기 중에 발생하는 가스화 에어로졸의 양을 추정할 수 있다고 알려져 있다⁹⁻¹⁵⁾.

강릉 등 대형 산불 피해지역을 대상으로 KOMPSAT-3A MWIR(Mid Wave Infrared), SENTINEL-2A 위성 영상 정보로부터 적외선 및 광학시기 차이 영상을 확인하였다. 시기 차이 영상의 경우 비교적 산불 피해지역을 시각적으로 확인할 수 있다.




그림 1. 고성 산불 발생 후(KOMPSAT-3A)(‘19. 4. 5)
Fig. 1. After a forest fire in Goseong(KOMPSAT-3A)(‘19. 4. 5)



그림 2. 울진 산불 발생 후(SENTINEL-2A)(‘22. 5. 29)
Fig. 2. After a forest fire in Uljin(SENTINEL-2A)(‘22. 5. 29)

KOMPSAT-3A 실제 영상을 보면 산불 피해지역의 근적외선 합성영상은 근적외선과 가시광선 영상을 합성한 이미지 자료로서 화재로 소실된 산불의 피해지역은 어렵게 나타났고, 산불 비피해지역은 상대적으로 푸르게 나타났다. 이는 온도 차이에 기인한다¹²⁻¹⁴⁾.

2.3 GAN 구조 및 참조 모델³⁻⁸⁾

딥러닝 모델 중 하나인 GAN(Generative Adversarial Network)은 Ian Goodfellow가 처음 제안했다. GAN의 구조는 생성자와 판별자로 이루어져 있다. 생성자는 판별자가 진위여부를 구별할 수 없도록 이미지를 생성하고, 판별자는 생성자가 만든 이미지를 판별한다.

GAN에서는 먼저 분류 모델을 학습하고, 이후 서로 교환하면서 생성 모델의 학습 과정을 반복한다. 분류 모델 학습 과정은 두 가지 단계로 이루어져 있다. 첫 번째 단계는 실제 데이터를 입력하고, 실제 데이터를 분류하기 위해 네트워크를 학습하는 과정이다. 두 번째는 생성 모델에 의해 만들어진 가짜 데이터를 입력하고, 가짜 데이터를 분류하기 위해 학습하는 과정이다. 이 과정을 통해 분류 모델은 실제와 가짜 데이터를 구별할 수 있게 된다. 분류 모델을 학습한 후에 GAN은 학습된 분류 모델을 속일 수 있도록 생성 모델을 학습한다. GAN은 생성 모델이 만든 가짜 데이터를 판별 모델에 입력하고, 가짜 데이터를 실제 데이터로 분류할 수 있는 데이터를 생성할 수 있도록 학습한다. GAN에는 ConditionalGAN(Conditional Generative Adversarial Network), LSGAN(Least Square Generative Adversarial Network, CycleGAN(Cycle Generative Adversarial Network) 등 여러 종류가 있다. LSGAN은 GAN을 사용할 때 발생하는 미분값 소실 문제를 해결하기 위해 제안된 모델이다.

CycleGAN은 쌍을 이루지 않는 데이터 세트로부터 이미지를 변환하는 모델이다. 그림에서, x 와 y 는 각각 도메인 X 와 Y 에 속하는 샘플을 나타내며, CycleGAN은 추가적으로 D_x 와 D_y 라 적대적인 판별자를 도입한다. $G : X \rightarrow Y$ 와 $F : Y \rightarrow X$ 는 모델의 두 매핑 함수이




그림 3. CycleGAN 개략도
Fig. 3. Overview of CycleGAN

다. 이러한 매핑 함수들이 도메인을 서로 적용할 수 있도록 하는 것이 판별자의 목표이다. CycleGAN의 목적 함수는 적대적 손실과 사이클 일관성 손실 두가지 손실로 구성된다. 적대적 손실에 대해서는 함수 $G : X \rightarrow Y$ 와 D_Y 에 대하여 다음과 같은 목적 함수가 적용된다.

$$\mathcal{L}_{GAN}(G, D_Y, X, Y) = E_{y \sim p_{data}(y)} [\log D_Y(y)] + E_{x \sim p_{data}(x)} [1 - D_Y(G(x))], \quad (1)$$

생성자는 이 값을 줄이려고 하고, 판별자는 이 값을 높이려고 한다. 사이클 일관성 손실을 사용하면 재구성 이미지 $F(G(x))$ 가 입력 이미지 x 와 유사해진다. 전체 목적 함수는 $\mathcal{L}_{GAN}(G, F, D_X, D_Y)$ 로 이 식은 적대적 손실, 판별자의 목적 함수가 중첩된 형태이다.

$$\mathcal{L}(G, F, D_X, D_Y) = \mathcal{L}_{GAN}(G, D_Y, X, Y) + \mathcal{L}_{GAN}(F, D_X, Y, X) + \lambda \mathcal{L}_{cyc}(G, F), \quad (2)$$

위의 식에서 λ 는 식의 첫 번째와 두 번째 항의 상대적 중요성에 따라 결정되는 변수이다.

III. 제안하는 GAN 모델 구축 및 환경

3.1 이미지 생성 모델 구축 및 생성 모델 환경^[12,16]

CycleGAN 모델을 사용하여 부족한 산불 이미지 생성에 대해 연구하였다. CycleGAN의 구조는 두 개의 생성자(generator)와 두 개의 판별자(discriminator)로 구성되어 있다. 생성자는 합성곱 레이어, 배치 정규화 및 ReLU로 구성되어 있다. 생성자는 인코더, 트랜스포머 및 디코더로 구성된다. 입력 이미지는 바로 인코더로 들어가며, 인코더는 세 개의 컨볼루션 레이어로 구성된다. 생성된 이미지는 판별자에서 평가된다.

모든 과정을 거친 후, 이미지는 출력 레이어를 통해 출력 이미지를 생성한다. CycleGAN 구조에서 합성곱은 한 함수를 다른 함수의 역수 값과 곱한 후 구간을 적분하여 새로운 함수를 얻는 수학적 연산자이다. 합성곱 레이어는 특정한 수의 입력 채널을 받아들이고 특정한 수의 출력 채널을 계산한다. 이러한 레이어에서 필요한 매개변수의 수는 $I \times O \times K$ 로 계산할 수 있다. 여기서 I 는 입력 채널의 수, O 는 출력 채널의 수, K 는 입력의 수이다. 합성곱 층은 커널 크기, 스트라이드(stride), 패딩(padding), 채널(channel) 등의 매개변수를 갖고 있다. 커널 크기는 합성곱의 범위를 결정하고, 스트라이드

는 이미지를 훑어가는 커널의 크기를 결정한다. 기본값은 1이지만, 다운샘플링(downsampling)을 위해 값을 늘리는 경우도 있다.

배치 정규화는 신경망의 각 레이어에서 데이터의 분포를 정규화하는 작업이다. 이는 활성화 함수의 출력 값 또는 출력 값의 정규화를 통해 수행된다. 학습 속도가 높게 설정될 수 있기 때문에 학습 속도를 높일 수 있다. 또한 기울기 소실 및 과적합 문제도 해결된다.

일반적인 네트워크는 간단하게 합성곱 연산을 구축하지만 ResNet(Residual Network)은 블록 단위에서 매개 변수를 전달하기 전에 이전 값을 추가하는 방법이다. 따라서 ResNet은 residual block을 쌓아서 구성된 구조이다. 일반적인 딥러닝 모델에서 사용되는 함수는 일반적으로 최소화하려는 비용 함수의 형태와 동일하다. 따라서 이전값을 다음 블록의 입력에 추가하면 데이터가 일종의 bypass로 전달되어 기존 블록보다 더 많은 정보를 유지할 수 있다. 이러한 구조는 기울기소실(gradient vanishing) 문제를 완화하는 데 도움이 되며, 네트워크를 깊게 쌓는 데 도움이 된다.

사용한 데이터 세트는 KARI(Korea Aerospace Research Institute)의 데이터 세트이다. 이 데이터 세트는 강원도 강릉과 고성 & 속초 산불 데이터 세트를 포




그림 4. KOMPSAT-3A 강릉 산불 이미지(근적외선 합성 이미지)
Fig. 4. KOMPSAT-3A Gangneung forest fire Image (Near-Infra Red composite Image)



그림 5. KOMPSAT-3A 강릉 산불 이미지(광학 합성 이미지)
Fig. 5. KOMPSAT-3A Gangneung forest fire image (optical composite image)

함하고 있다.

본 논문에서는 강릉 산불 지역을 선택했다. 이 데이터 세트는 KOMPSAT-3A 근적외선 합성 이미지와 컬러 합성 이미지를 기반으로 생성되었으며 고해상도 이미지와 대기 품질 정보를 제공한다. 이 데이터 세트중 강릉지역의 이미지를 사용하였으며 학습 데이터 세트와 검증 데이터 세트로 나누어 총 2000여개의 이미지로 분할하여 사용하였다. 학습을 위해 이미지를 256 x 256 크기로 조정하였다. 모든 실험은 NVIDIA GeForce GPU를 사용하여 수행되었다.

사용한 데이터 세트에는 나무, 땅, 도로 등 다양한 지리적 특성이 포함되어 있다. 이미지의 크기는 목표인 256 x 256 픽셀보다 훨씬 크므로 크기 조정이 필요하다. 이미지를 256 x 256 픽셀로 나누어 생성자를 통해 입력 이미지를 전달할 수 있도록 하고 있다. 입력 이미지의 크기가 레이어 입력의 크기보다 크기 때문에 이미지에 대한 조정이 요구되어 데이터 증강을 사용하여 이미지를 조정하였다. 데이터 증강은 원본 데이터의 양을 증가시켜 모델의 성능을 향상시키는 방법으로 과적합을 방지하고 있다. 데이터 증강의 예는 이미지의 회전, 이동, 크기 조정, 뒤집기, 기울기 조정 및 밝기 조절 등이 있다. 사용된 딥러닝 모델의 학습 매개변수 중 Epoch는 전체 데이터 세트가 신경망을 한 번 학습하는 것을 의미하고, Iteration은 한 Epoch을 달성하기 위해 필요한 배치 수를 나타낸다. 학습률은 기울기 하강법에 곱해지는 스칼라 값이다.

경사 하강법 알고리즘이란 비용 함수를 최소화할수 있는 지점으로 가는 방향이 경사 하강 방향이다라는 개념에서 출발한다. 학습률은 적절한 수준으로 설정되어야 한다. 학습률이 너무 크면 그래프에서 벗어나는 overshooting 현상이 발생한다. 반대로 학습률이 너무 작으면 학습이 진행되지 않고 매우 오랜 시간이 걸릴 수 있다. 딥러닝에서 배치(batch)는 가중치를 업데이트 하기 위해 사용되는 샘플 묶음을 의미한다.

표 1. 딥러닝 모델의 학습파라미터
Table 1. Learning parameters of deep learning model

| Parameter | Number |
|------------------|--------|
| Epoch | 100 |
| Learning rate | 0.0002 |
| Batch size | 1 |
| Training dataset | 2000 |

IV. 시뮬레이션 실험 및 결과

4.1 원본 이미지와 생성 이미지

CycleGAN을 사용하여 강원도 강릉과 고성 & 속초 데이터 세트 중 강릉 산불 지역을 선택하여 산불 이미지 생성 모델의 실험 결과이다. 강릉지역에서 생성된 산불의 원본 이미지와 생성된 이미지 간의 질적, 양적 분석을 보여주고 있다. 질적 분석은 원본 이미지와 생성된 이미지를 비교하고, 양적 분석은 이전 장에서 소개된 지표를 사용하여 결과를 검증하였다.

그림 6은 논문에서 사용된 강릉지역 산불 발생지 원본 근적외선 합성 이미지와 원본 광학 합성 이미지 그리고 딥러닝을 사용하여 생성된 산불 이미지를 보여주고 있다. 맨 위 줄은 원본 근적외선 이미지이고, 중간 줄은 원본 광학 이미지이다. 맨 아래 줄은 CycleGAN을 사용하여 생성된 이미지이다. 생성된 이미지는 광학 이미지의 형태를 유지하며 원본 근적외선 이미지의 색상을 적용한 이미지가 생성되었음을 알 수 있다. 산불이 발생한 강릉지역 위주로 8개 지역으로 구분하였다^{12,16}.

위의 표에서는 CycleGAN으로 생성된 이미지와 원본 이미지를 여러 지표로 비교하였다. 표의 결과는 생성된 근적외선 이미지가 원본 이미지와 얼마나 유사한지

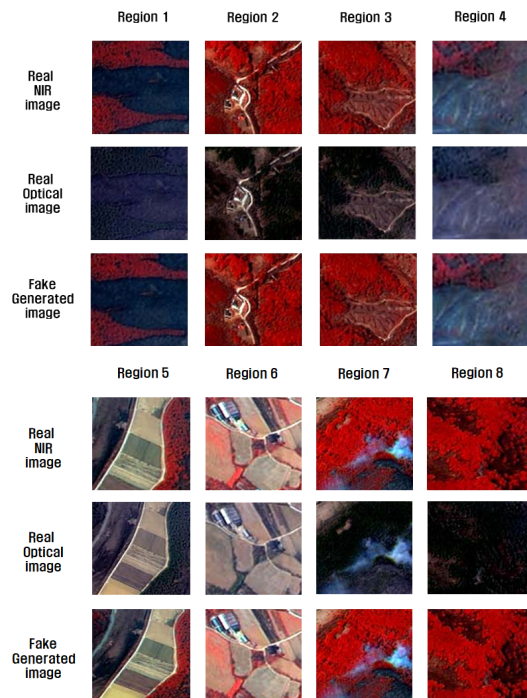


그림 6. 원본 이미지 및 CycleGAN 생성 이미지
Fig. 6. Original image and CycleGAN generated image

표 2. CycleGAN의 SSIM, PSNR 값
Table 2. SSIM, PSNR values of CycleGAN

| Parameter | SSIM | PSNR |
|-----------|--------|---------|
| Region 1 | 0.4244 | 30.4046 |
| Region 2 | 0.2555 | 29.1784 |
| Region 3 | 0.5256 | 29.8648 |
| Region 4 | 0.3086 | 29.5176 |
| Region 5 | 0.1061 | 28.0695 |
| Region 6 | 0.1389 | 28.3676 |
| Region 7 | 0.0904 | 27.9649 |
| Region 8 | 0.2218 | 28.6084 |

를 보여주고 있다. SSIM의 평균은 0.26이고, PSNR의 평균은 29.00가 산출되었다. 이는 산불 지역에서 생성된 이미지들이 원본 이미지와 구조적으로 얼마나 유사한 이미지인지를 수치로 보여주고 있다. 산불 발생시 기상현상 등 다양한 요인에 의해 부족한 적외선이나 광학 이미지를 CycleGAN을 활용하여 적외선이나 광학 이미지와 유사한 이미지를 생성할 수 있다는 것을 보여주고 있다¹¹⁾.

V. 결 론

국내의 산불 관련해서 강원지역, 경상지역 등 대형 산불의 지속적인 발생으로 인명 및 재산 피해, 특히 산림의 피해가 꾸준히 발생하고 있다. 대형 산불 이미지 분석을 위해 KOMPSAT-3A, SENTINEL-2A, Google EARTH, Chullian-2A 등 위성 이미지를 활용하였다. 산불 이미지 분석시 활용되는 광학이나 적외선 위성 이미지는 데이터 세트의 양이 부족하다는 점을 확인할 수 있다. 이는 산불 이미지 분석 등 각종 목적에 적합한 영상을 얻기 어렵다는 것이다. 이러한 데이터 세트가 부족하다는 제한사항은 딥러닝을 이용해 보완할 수 있다.

딥러닝은 대량의 데이터를 처리하여 원하는 연구를 수행할 수 있으며 다양한 분야에서 활용되고 있다. 산불 이미지 분석에 활용할 수 있는 딥러닝 종류인 CycleGAN을 활용하여 산불 이미지를 생성하였다. CycleGAN은 페어링 되지 않은 데이터 세트를 이용하여 이미지를 생성하는 방법이다. 원본 적외선이나 광학 이미지와 유사한 이미지를 생성할 수 있어 산불 이미지 분석에 활용할 수 있다.

시뮬레이션 결과 강릉 산불 피해지역 이미지 수를 증대할 수 있었다. 산불 이미지 생성 모델의 정밀도를 비교하기 위해 평가지표를 이용하여 양적 분석을 수행하였다. 실제 산불 이미지와 유사한 생성 이미지를 산출

하여 평가지표인 SSIM, PSNR를 이용한 정밀도를 측정할 결과, 생성된 산불 이미지는 원본 광학 이미지의 특징을 유지하며 원본 적외선 이미지 색상을 적용하여 생성되었음을 확인하였고 이는 원본 이미지와 유사하다는 것을 확인할 수 있었다.

향후 연구에서는 구축한 산불 이미지 생성 모델을 사용하여 자연재해 등 더욱 다양한 데이터 세트를 적용하여 화산 분화 탐지, 각종 지형 탐사, 지구 온난화 등 자연재해의 예측과 예방 등의 분야에서 활용할 수 있을 것으로 기대한다. 본 논문에서 미처 다루지 못한 내용에 대해서는 향후 지속적인 연구를 통해 계속 보완하도록 하겠다.

References

- [1] M. S. Won, K. H. Kim, and S. W. Lee, "A study on damage characteristics and development of burn severity evaluation methods," Korea Forest Research Institute, Research Report 13-37, pp. 1-229, Dec. 2013. (<http://www.kfri.go.kr>)
- [2] S. S. Lim and S. R. Go, "Yearbook of forest fire statistics for 2021," *Forest Service*, pp. 1-173, Feb. 2022. (<http://www.forest.go.kr>)
- [3] I. Goodfellow et al., "Generative adversarial nets," *Advances in NIPS*, vol. 27, pp. 2672-2680, Jun. 2014. (<http://papers.nips.cc/paper/5423-generative-adversarial-nets.pdf>)
- [4] X. Mao et al., "Least squares generative adversarial networks," in *Proc. 2017 IEEE Int. Conf. Comput. Vision*, pp. 2794-2802, Venice, Italy, Oct. 2017. (<https://arxiv.org/abs/1611.04076>)
- [5] J. Y. Zhu, T. Park, P. Isola, and A. A. Efros, "Unpaired image-to-image translation using cycle-consistent adversarial networks," in *Proc. 2017 IEEE Int. Conf. Comput. Vision*, pp. 2242-2251, Venice, Italy, Oct. 2017. (<https://ieeexplore.ieee.org/document/8237506>)
- [6] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," in *Proc. 32nd Int. Conf. Mach. Learn.*, vol.

- 37, pp. 448-456, Lille, France, Jul. 2015.
(<https://dl.acm.org/doi/10.5555/3045118.3045167>)
- [7] M. Mirza and S. Osindero, "Conditional generative adversarial nets," *arXiv preprint arXiv:1411.1784*, Nov. 2014.
(<https://doi.org/10.48550/arXiv.1411.1784>)
- [8] P. Isola, J.-Y. Zhu, T. Zhou, and A. A. Efros, "Image-to-image translation with conditional adversarial networks," in *Proc. IEEE Conf. CVPR 2017*, pp. 1125-1134, Honolulu, USA, Nov. 2017.
(<https://doi.org/10.1109/CVPR.2017.632>)
- [9] B. Maccherone and S. Frazier, *MODIS*, Jul. 2023.
(https://modis.gsfc.nasa.gov/about/specification_s.php)
- [10] Y. Kaufman and C. O. Justice, "Algorithm technical background document," *MODIS ATBD: Fires, MODIS Sci. Team*, pp. 1-77, Jan. 1998.
(<https://www.researchgate.net/publication/242167755>)
- [11] E. H. Kim, J. H. Lim, H. S. Kim, and G. S. Kim, "Foreign development status and applications of infrared imaging satellite," *Korea Aerospace Res. Inst.*, vol. 6, no. 2, pp. 51-59, Dec. 2008.
(<https://koreascience.kr/journal/HKOJDS.jsp-kj=SSMHB4&py=2012&vnc=v27n6&sp=588>)
- [12] "Arirang Satellite Image Search & Order System," 2022.
(<https://ksatdb.kari.re.kr/arirang/map/map.jsp>)
- [13] "SENTINEL Hub EO Browser," 2022.
(<https://apps.sentinel-hub.com/eo-browser/?zoo m=10&lat=41.89972&lng=12.49969&themeId=DEFAULT-THEME&toTime=2022-09-14T10%3A42%3A46.238Z>)
- [14] "SENTINEL-2A Spectral bands as seen by the satellite's MSI camera. Sentinel Online," 2022.
(<https://sentinels.copernicus.eu/web/sentinel/technical-guides/SENTINEL-2A-msi/msi-instrument>)
- [15] S. H. Kim, "Development of fan algorithm for detecting sub-pixel scale forest fires using MODIS data," Ph.D. dissertation, Inha University, Feb. 2009.
(<https://lib.inha.ac.kr/kor>)
- [16] "KARI TV & IMAGE," 2023.
(https://www.kari.re.kr/kor/kariimg/list.do?img_gbn=VDO&img_tp=SG&mno=sub10_01&listType=2)
- [17] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: From error visibility to structural similarity," *IEEE Trans. on Image Process.*, vol. 13, no. 4, pp. 600-612, Apr. 2004.
(<https://doi.org/10.1109/TIP.2003.819861>)

박 범 순 (Beom-sun Park)



1995년 2월 : 안양대학교 정보통신공학과 학사
2004년 8월 : 성균관대학교 전기전자공학과 석사
2023년 8월 : 아주대학교 우주전자정보공학과 박사
2020년~현재 : 가톨릭관동대학교 항공정비학과 조교수

<관심분야> 이동통신, 위성시스템

[ORCID:0009-0005-9230-4347]

이 원 재 (Won-Jae Lee)



2016년~2019년 : 아주대학교 전자공학과 공학사
2019년~현재 : 아주대학교 AI융합네트워크학과 석박사통합과정

<관심분야> 이동통신, 위성통신, 무선 MAC 프로토콜, 국방 전술네트워크

[ORCID:0000-0002-2122-3292]

김 재 현 (Jae-Hyun Kim)



1987년~1996년: 한양대학교 전
산과 학사 및 석/박사

1997년~1998년: 미국 UCLA
전기전자과 박사 후 연수

1998년~2003년: Bell Labs, NJ,
USA, 연구원

2003년~현재: 아주대학교 전자
공학과 교수

<관심분야> QoE/QoS, 무선 MAC 프로토콜, IEEE
802.11/15, B5G 통신 시스템, 국방 기술네트워크,
위성시스템 등

[ORCID:0000-0003-4716-6916]