

GAN을 이용한 달의 영구 그림자 영역 관찰에 관한 연구

박성욱*, 김준영*, 박준*, 이한성**, 정세훈**, 심준보*

*순천대학교 IT-Bio융합시스템전공

**안동대학교 창의융합학부

411050@scnu.ac.kr, jungsh@anu.ac.kr, cbsim@scnu.ac.kr

A Study on Observation of Lunar Permanently Shadowed Regions Using GAN

Sung-Wook Park*, Jun-Yeong Kim*, Jun Park*, Han-Sung Lee**, Se-Hoon Jung**,
Chun-Bo Sim*

*Interdisciplinary Program in IT-Bio Convergence System, Suncheon National University

**School of Creative Convergence, Andong National University

요 약

일본 우주항공연구개발기구(Japan Aerospace Exploration Agency, JAXA)는 2007년부터 2017년까지 달 탐사선 셀레네(Selenological and Engineering Explorer, SelEnE)가 관측한 데이터를 수집하고 연구했다. JAXA는 지구 상층 대기에 존재하는 산소가 자기장의 꼬리 부분에 실려 달로 이동한다는 사실을 발견했다. 하지만 이 연구는 아직 진행 중이며 달의 산화 과정 규명에 추가 연구가 필요하다.

본 논문에서는 생성적 적대 신경망(Generative Adversarial Networks, GAN)으로 달 분화구의 영구 그림자 영역을 제거하고, 물과 얼음을 발견하여 선행 연구의 완성도를 향상하고자 한다. 실험에 사용할 모델은 CIPS(Conditionally Independent Pixel Synthesis)다. CIPS는 실제 같은 영상을 고해상도로 합성한다. 합성할 데이터의 최적의 가중치 초기화 및 파라미터 갱신 방법, 활성 함수 조합은 실험을 통해 확인한다. 필요에 따라 앙상블 학습을 할 수도 있다. 성능평가는 FID(Frechet Inception Distance), 정밀도, 재현율을 사용한다. 제안한 방법은 진행 중인 연구의 시간과 비용을 절약하고, 인과관계를 더욱 명확히 밝히는 데 도움 될 수 있다고 사료된다.

1. 서론

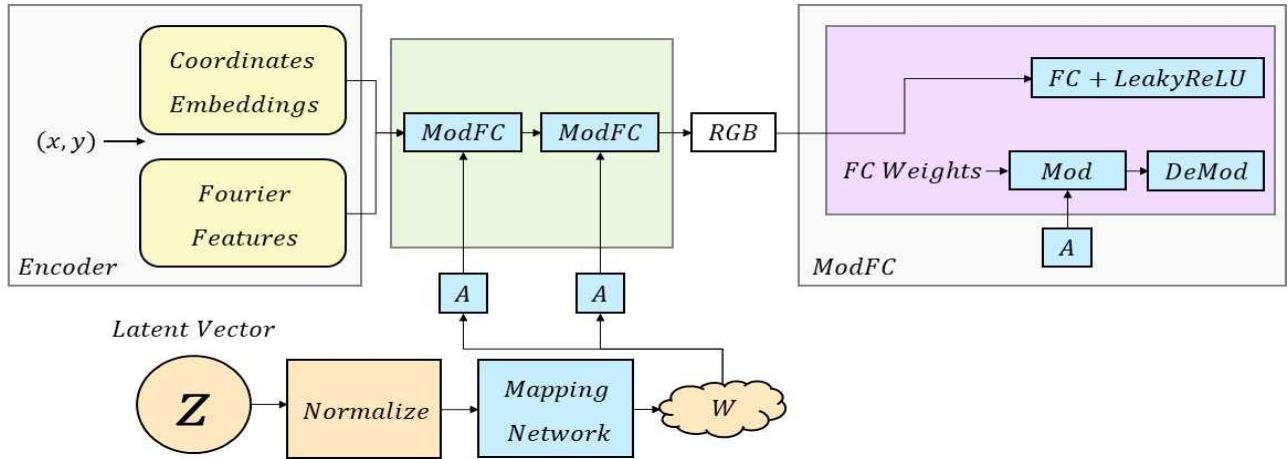
화성(Mars) 표면에 있는 철 성분은 수십억 년 전 물과 산소(Oxygen)의 영향으로 산화철(Iron Oxide)로 바뀌었다. 화성이 주황색인 이유는 물과 산소로 인해 녹슬어서다. 달은 물과 산소가 표면에 없어 회색으로 보인다. 그런데 달 표면이 녹슬고 있다는 연구 결과가 발표됐다[1].

2008년 인도의 우주 연구기관은 달 탐사선 찬드라얀 1호(Chandrayaan-1)를 쏘아 올렸다. 찬드라얀 1호의 탐사 목표는 달 표면과 지하에 있는지 모를 얼음 및 광물 지도를 작성하는 것이다. 찬드라얀 1호에는 미국항공우주국(National Aeronautics and Space Administration, NASA)의 제트추진 연구소(Jet Propulsion Laboratory)에서 제작한 달 광물 지도작성기(Moon Mineralogy Mapper, M3)가 장착돼있다. 연구자들은 M3로 달 표면을 일 년 가까이 측정해 광물의 분포도를 만들었다. 슈아이 리(Shuai Li)는 관측한 데이터에서 적철석(Hematite)을 발견했다. 적철석은 철이 녹슬면서 생성된 광석이다. 철이 녹슬기 위해선 물과 산소가 필요하다. 물이 달에 존재한다는 사실은 2008년 찬드라얀 1호를 통해 확인했다. 2009년 NASA도 우주선을 달

표면에 고의로 충돌시키고, 여파로 돌출된 물질을 조사했다. 그 결과 달의 극지방에 상당한 물이 존재한다는 사실을 확인했다.

유성(Meteor)은 태양계 형성 과정에서 남아있던 먼지 같은 물질들이 지구 중력에 끌려들어 오는 현상이다[2]. 속도가 매우 빠르지만 대기와의 마찰로 모두 타버린다. 대기가 없는 달은 유성이 지표면에 바로 충돌해 흙을 파헤친다. 몇몇 유성들에 의해 지표면 아래 있던 수분이 올라와야 산소와 결합해 지표면에 존재하는 철분을 녹슬게 한다.

그동안 영구적으로 그림자가 드리워진 달 분화구에는 물과 얼음이 포함돼 있지만 이를 영상화해서 증명하기는 어려웠다. 본 논문에서는 딥러닝 알고리즘 생성적 적대 신경망(Generative Adversarial Networks, GAN)으로 달 분화구의 영구 그림자 영역을 제거하고, 물과 얼음을 발견하여 달의 산화 과정 규명에 기여하고자 한다[3]. 훈련에 사용될 GAN 모델은 아노킨(Anokhin)의 CIPS(Conditionally Independent Pixel Synthesis)다. 실험에 사용할 주 데이터는 NAC EDR(Narrow Angle Camera Engineering Data Record)이고, 보조 데이터는 LOLA(Lunar Orbiter Laser Altimeter)의 결과물이다[4-6].



(그림 1) Image generators with CIPS(Conditionally Independent Pixel Synthesis)

합성할 데이터의 최적인 가중치 초기화 및 파라미터 갱신 방법, 활성 함수 조합은 실험을 통해 확인한다[7-8]. 필요에 따라 앙상블 학습을 할 수도 있다[9]. 딥러닝 라이브러리는 텐서플로(Tensorflow)를 사용한다[10]. 텐서플로는 복잡한 신경망을 구성하여 딥러닝 문제를 효과적으로 해결하는 공개소스 소프트웨어 라이브러리다.

2. 관련 연구

한국항공우주연구원은 2022년 8월 한국형 달 탐사선(Korea Pathfinder Lunar Orbiter, KPLO) 발사를 준비하고 있다. 탐사선을 이용한 항공우주 임무 및 연구다. KPLO는 미국 케이프커내버럴 공군기지(Cape Canaveral Air Force Station)에서 스페이스X(SpaceX)의 팰컨 9(Falcon 9) 발사체를 통해 발사할 예정이다. 임무는 달 표면을 촬영해 우주 자원을 찾고, 지구로 동영상 스트리밍(Streaming)하는 것이다. 우주 자원으로는 물과 산소를 포함해 청정 에너지원인 철, 헬륨-3 등이 있다. 헬륨-3은 가볍고 안정한 헬륨의 동위 원소 중 하나로, 두 개 양성자와 한 개 중성자를 갖고 있다. 지구에서 헬륨-3은 헬륨-4의 100만분의 1 밖에 존재하지 않는다.

달 탐사선에는 한국항공우주연구원의 고해상도 카메라(Lunar Terrain Imager, LUTI), 한국천문연구원의 광시야 편광카메라(Wide-angle Polarimetric Camera, PolCam), 경희대학교의 자기장 측정기(KPLO Magnetometer, KMAG), 한국지질자원연구원의 감마선분광기(KPLO Gamma Ray Spectrometer, KGRS), 한국전자통신연구원의 우주 인터넷(Disruption Tolerant Network, DTN) 검증기, NASA의 새도우 캠(Shadow Cam) 등 6가지 탑재체가 장착돼있다. 5개 탑재체는 국내 기술로 개발하고, 1개 탑재체는 해외 기술로 개발한다. LUTI는 달 표면의 주요 지역을 촬영하고, PolCam은 약 100m 해상도로 달 표면의 편광영상을 찍는다. KMAG는 달 주위의 미세한 자기장을 측정하고, KGRS는 달 표면의

감마선 입자 분광 관측을 한다. DTN 검증기는 지구와 달 탐사선 간 우주 인터넷 통신 기술을 검증하고, 새도우 캠은 얼음이 있을 것으로 예상하는 달 남극을 관찰한다.


3. 제안하는 방법

고급인력과 탐사 위성을 투입해 연구 시간을 단축할 수 있지만, 천문학적 비용이 필요하다. 탐사 위성만 봐도 그렇다. 스페이스X는 팰컨 9 개발에 약 5,000억 원을 투자했고, 한국항공우주연구원은 KPLO 개발에 약 2,300억 원을 투자했다. GAN은 위 문제를 해결하는데 기여할 수 있고, 고급인력과 탐사 위성을 투입하는 방법보다 비용 효율적이다. 이미 산업의 많은 분야에서 GAN 기반 애플리케이션을 사용하고 있다[11].

GAN은 생성자(Generator, G)와 판별자(Discriminator, D) 두 네트워크가 경쟁한다. G 는 랜덤 노이즈(Random Noise)를 실제 같은 샘플(Sample)로 변환하고, D 는 입력 샘플이 실제인지 G 가 만든 합성인지 구별한다.

G 는 D 의 판별 결과에서 피드백을 받아 학습한다. 피드백은 정분류율(Recognition Rate)과 오분류율(Misclassification Rate)로 나뉜다. D 는 현재 예측과 정답 간의 차이를 통해 학습한다. 따라서 G 가 실제 같은 샘플을 만들수록 D 도 실제와 합성을 더 잘 판별한다. 결과적으로 G 와 D 모두 성능이 향상된다.

GAN은 실제 샘플과 구별하기 힘든 샘플을 합성할 수 있다[12]. 언어를 모델링 하거나 음악을 작곡할 수도 있다[13-14]. 소량의 데이터로 가능하다. 이는 인력과 자본의 제약을 최소화할 수 있어 대안으로 적절하다. 궁극적인 목표는 실제 관측데이터 분포처럼 보이는 샘플의 합성 분포를 찾는 것이다. 실험에 사용할 GAN 모델은 CIPS다[15]. CIPS는 최신 기술(State-of-the-art) 중 하나인 StyleGANv2와 동등한 품질의 영상을 합성한다[16]. CIPS의 G 구조는 그림 1과 같다.



(그림 2) Structure and operation of the discriminator that is a DAE(Denoising Autoencoders)

그림 1의 상단은 생성 파이프라인(Pipeline), 하단은 변조된 전 결합(Modulated Fully Connected, ModFC) 층의 구조다. Mod는 값의 변조, DeMod는 Mod의 역연산이다. 그림 1의 잠재 벡터(Latent Vector) z 는 정규화(Normalization)를 거쳐 매핑 네트워크(Mapping Network)에 입력된다. 매핑 네트워크는 영상의 모든 픽셀이 공유하는 W 를 출력한다. ModFC는 W 를 입력받아 변조한다. 인코더는 푸리에 특징(Fourier Feature)과 좌표 임베딩(Coordinate Embedding)을 이용해 각 픽셀의 좌표 x, y 를 인코딩한다. FC는 인코딩된 값을 해당 픽셀의 RGB 값으로 반환한다. ModFC의 활성화 함수는 누출 정규화 선형 유닛(Leaky Rectified Linear Unit, Leaky ReLU)을 사용하며 식(1)과 같다[17].

$$a_{i,j,k} = \max(z_{i,j,k}, 0) + \lambda \min(z_{i,j,k}, 0) \quad \text{식 (1)}$$

식(1)에서 하이퍼파라미터 λ 는 0부터 1의 범위를 가진다. Leaky ReLU는 음수 부분을 정규화 선형 유닛(Rectified Linear Unit, ReLU)처럼 상수 0으로 매핑하지 않고 압축한다. 따라서 함수가 비활성화 상태여도 1보다 작은 양수 값이 출력된다[18].

ReLU는 함수가 활성화하지 않을 때 가중치를 조정하지 않기 때문에 기울기가 0이 된다. 기울기가 0이 되 최소화하면 GAN 훈련에 방해가 될 수 있고, 학습 속도 또한 느려진다. 딥러닝 알고리즘에서 희소는 바람직한 현상일 때가 많지만 GAN은 그렇지 않다. 이런 문제

예방을 위해 Leaky ReLU를 사용한다. Leaky ReLU는 음수의 활성화 값을 허용하기 때문에 희소가 완화된다. 그림 1의 G 는 기본 구성으로 출력에 대한 잔차 연결(Skip Connection)도 포함한다. D 는 그림 2와 같이 DAE(Denoising Autoencoders)로 변경한다.

CIPS는 퍼셉트론(Perceptron) 기반 모델로써 색상 정보를 랜덤 노이즈와 위치 좌표만 사용해 계산한다[19]. 픽셀 간 정보 공유가 특정 상황에서는 합성작업능력을 떨어뜨릴 수 있기 때문에 공간적 컨볼루션(Spatial Convolution)과 업 샘플링(Upsampling) 연산, 셀프 어텐션(Self-attention) 메커니즘은 사용하지 않는다.

4. 결론

현재 달은 극지방을 기준으로 녹슬고 있다. 달 표면 아래 있는 물과 지구에서 온 산소가 그 이유라고 설명할 수 있다. 이 연구는 아직 진행 중이며 완성도를 높이기 위해 추가 연구가 필요하다. 달 반대편에도 소량의 적철석이 존재하고 있기 때문이다. 해당 이론은 발표하기까지 10년이 걸렸고, 완전히 정립되는데 앞으로도 적지 않은 시간이 소요될 것으로 보인다.

본 논문에서는 GAN으로 달의 햇빛을 받지 않는 분화구와 기타 함몰부의 영구 그림자 영역을 제거하고, 물과 얼음을 발견하여 선행 연구의 완성도를 향상하고자 한다. 실험에 사용할 모델은 CIPS다. CIPS는 실제 같은 영상을 고 해상도로 합성한다. 성능평가는 FID, 정밀도, 재현율을 사

용한다. 우주 탐사선의 임무 및 계획에는 미리 그 지역 지형과 지질에 대한 정확한 영상이 필요하다. 탐사로봇이나 우주 비행사의 잠재적인 장애물과 위험을 쉽게 식별할 수 있게 해주기 때문이다. 제한한 방법으로 진행 중인 연구의 시간과 비용을 절약하고, 인과관계를 더욱 명확히 밝힐 수 있으며 달그림자가 가려진 지역의 지질학을 이전보다 훨씬 더 잘 이해할 수 있게 될 것이라고 사료된다.

민간 우주개발은 세계적 추세다. 세계에서 가장 큰 투자은행 및 국제 금융 서비스 업체 중 하나인 모건 스탠리(Morgan Stanley)는 향후 우주 산업 시장 규모가 민간기업 주도하에 2040년 약 1,220조 원까지 성장할 것으로 전망했다. 국내도 해외 민간 우주 사업의 추세를 모니터링하고, 연구 방향과 비즈니스 모델을 설정해야 한다. 나아가 스페이스X처럼 국제 경쟁력을 확보하기 위해서 더 많은 투자가 필요하다. 향후 과제로 한국항공우주연구원의 영상 탐체제 기술과 본 논문에서 제안한 영상 합성기술을 융합한 서비스 개발을 검토해 볼 수 있다.

Acknowledgment

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education(2020R111A3054843) and this work was supported by the BK21 plus program through the National Research Foundation (NRF) funded by the Ministry of Education of Korea(5199990214660).

참고문헌

- [1] <https://www.nasa.gov/feature/jpl/the-moon-is-rusting-and-researchers-want-to-know-why> (accessed Feb., 7, 2022).
- [2] https://solarsystem.nasa.gov/asteroids-comets-and-meteors/meteors-and-meteorites/overview/?page=0&per_page=40&order=id+asc&search=&condition_1=meteor_slower%3Abody_type (accessed Feb., 7, 2022).
- [3] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, et al., "Generative adversarial nets," *In Advances in neural information processing systems*, pp. 2672-2680, 2014.
- [4] <http://lroc.sese.asu.edu/data/> (accessed Mar., 14, 2022).
- [5] <https://pds.nasa.gov/> (accessed Mar., 14, 2022).
- [6] <https://www.usgs.gov/centers/astrogeology-science-center/data> (accessed Mar., 14, 2022).
- [7] S.W. Park and D.Y. Kim, "Performance Comparison of Convolution Neural Network by Weight Initialization and Parameter Update Method," *Journal of Korea Multimedia Society*, Vol. 21, No. 4, pp. 441-449, 2018.
- [8] S.W. Park and D.Y. Kim, "Comparison of Image Classification Performance by Activation Functions in Convolutional Neural Networks," *Journal of Korea Multimedia Society*, Vol. 21, No. 10, pp. 1142-1149, 2018.
- [9] S.W. Park, J.C. Kim and D.Y. Kim, "A Study on Classification Performance Analysis of Convolutional Neural Network using Ensemble Learning Algorithm," *Journal of Korea Multimedia Society*, Vol. 22, No. 6, pp. 665-675, 2019.
- [10] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, et al., "TensorFlow: Large-scale Machine Learning on Heterogeneous Systems," *arXiv preprint, arXiv:1603.04467*, 2015.
- [11] S.W. Park, J.S. Ko, J.H. Huh and J.C. Kim, "Review on Generative Adversarial Networks: Focusing on Computer Vision and Its Applications," *Electronics*, Vol. 10, No. 10, pp. 1216-1255, 2021.
- [12] S.W. Park, J.H. Huh and J.C. Kim, "BEGAN v3: Avoiding Mode Collapse in GANs Using Variational Inference," *Electronics*, Vol. 9, No. 4, pp. 688-718, 2020.
- [13] A. Radford, J. Wu, R. Child, D. Luan, D. Amodei and I. Sutskever, "Language models are unsupervised multitask learners," *OpenAI Blog*, Vol. 1, No. 8, pp. 9, 2019.
- [14] C. Payne, "MuseNet," <https://openai.com/blog/musenet> (accessed Mar., 15, 2022).
- [15] I. Anokhin, K. Demochkin, T. Khakhulin, G. Sterkin, V. Lempitsky, and D. Korzhenkov, "Image Generators with Conditionally-Independent Pixel Synthesis," *arXiv preprint, arXiv:2011.13775*, 2020.
- [16] T. Karras, S. Laine, M. Aittala, J. Hellsten, J. Lehtinen and T. Aila, "Analyzing and improving the image quality of stylegan," *In Proceedings of the IEEE E/CVF Conference on Computer Vision and Pattern Recognition*, pp. 8110-8119, 2020.
- [17] A.L. Mass, A. Y. Hannun, and A. Y. Ng, "Rectifier Nonlinearities Improve Neural Network Acoustic Models," *In Proceeding of International Conference on Machine Learning*, Vol. 30, No. 1, pp. 3, 2013.
- [18] V. Nair and G. Hinton, "Rectified Linear Units Improve Restricted Boltzmann Machines," *In Proceedings of the 27th International Conference on Machine Learning*, pp. 807-814, 2010.
- [19] I. Stephen, "Perceptron-based learning algorithms," *IEEE Transactions on neural networks*, Vol. 50, No. 2, p. 179, 1990.