

# 생성적적대신경망을 이용한 소나 데이터 생성

김동환, 김석찬\*  
부산대학교, \*부산대학교

dongh@pusan.ac.kr, \*sckim@pusan.ac.kr

## Generating Sonar Data using Generative Adversarial Networks

Donghwan Kim, Suk Chan Kim\*  
Pusan National Univ., \*Pusan National Univ.

### 요 약

본 논문에서는 오픈 소나 데이터를 입력으로 가지는 생성적적대신경망을 사용해 데이터를 생성하는 딥러닝 모델을 설계하고, 학습 반복 횟수에 따른 평가지표와 생성된 데이터를 육안으로 확인하여 모델 성능을 평가한다.

### I. 서 론

소나(Sound Navigation And Ranging, SONAR)란 음파를 사용하여 수중 물체를 탐지/식별/추적하는 음파 탐지기를 말한다. 소나는 구동방식에 따라 능동 소나와 수동 소나로 나뉜다. 능동 소나는 수중으로 음파를 발사한 후 물체에 부딪쳐 돌아오는 반사파를 분석하여 수중 물체를 탐지한다[1]. 반면 수동 소나는 선체 등 수중에서 물체가 이동할 때 발생하는 소음으로 물체를 탐지한다.

소나 시스템에서 표적 유무 판단은 특정한 임계값을 기준으로 소나 운용자의 주관적인 판단에 의해 결정된다. 그렇기 때문에 표적 탐지에 실패할 수가 있다. 이러한 문제점을 극복하기 위해 인공지능을 활용한 자동표적식별 기술이 활발하게 연구되고 있다[2].

인공지능 기반의 자동표적식별 기술을 설계하기 위해서 대량의 학습 데이터가 필요하다. 대량의 데이터를 확보하기 위해서는 시간, 비용, 인력 등 많은 자원이 필요하다. 이러한 자원을 아끼기 위해서 본 논문에서는 생성적적대신경망(Generative Adversarial Networks, GAN)을 사용하여 소나 데이터를 생성한다.


GAN은 생성기(generator)와 판별기(discriminator), 두 개의 신경망을 사용한다[3]. 생성기와 판별기는 같은 목적함수를 각각 최대/최소화 시켜 경쟁하며 데이터를 생성한다. 판별기는 생성기가 만들어낸 가짜 데이터와 진짜데이터를 구분하도록 훈련한다. 반면, 생성기는 판별기를 속일 수 있는 데이터를 생성하도록 훈련한다. 하지만 GAN은 생성기와 판별기의 성능에 차이가 클 때 모드붕괴에 빠지기 쉽고, 생성한 데이터의 해상도가 좋지 못하다는 단점이 있다.

따라서 본 논문에서는 이러한 GAN의 단점을 보완한 WGAN-GP(Wasserstein GAN-Gradient Penalty)를 사용한다[4]. 본론에서는 WGAN-GP의 구조, 사용한 데이터셋, GAN의 평가지표에 대하여 설명하고, 실험결과에서는 평가지표와 생성한 데이터를 통해 모델

성능을 평가한다. 마지막으로 결론에서는 실험 결과와 설계한 모델의 성능 분석을 통한 추후 연구 진행 방향에 대하여 논한다.

### II. 본론

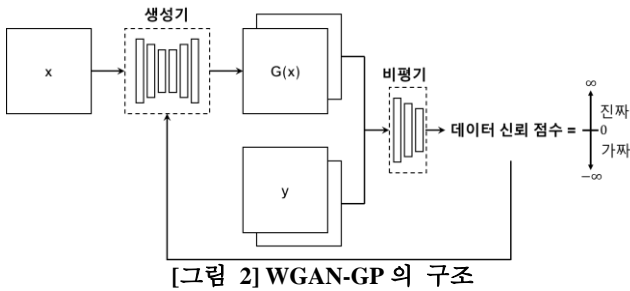
#### 1. 데이터셋



[그림 1] 수중 지뢰, 암석 데이터 샘플

소나 데이터는 UCI Machine Learning Repository에서 제공하는 수중 지뢰와 암석을 구분하는 데이터셋(Connectionist Bench)를 사용한다.[5] 데이터는 111개의 수중 지뢰 데이터와 97개의 암석 데이터로 구성된다. 이 데이터의 형태는 그림 1과 같이 주파수 차원에서 일정 주기로 적분된 에너지이다. 따라서 해당 데이터는 분석에 어려움이 있다. 데이터의 값은 하나의 데이터 당 60개의 에너지 값으로 이루어진 벡터이다. 따라서 본 논문에서는 생성기와 식별기 모두 1차원의 데이터를 처리할 수 있는 모델로 설계한다. GAN은 훈련 데이터셋으로 가짜 데이터를 만들어 내고 가짜 데이터를 기반으로 모델의 성능을 평가하기 때문에 본 논문에서는 훈련 데이터셋과 테스트 데이터셋의 구분을 두지 않는다. 또한 본 모델은 데이터의 수가 적기 때문에 수중 지뢰 데이터와 암석 데이터를 구분 없이 사용한다.

## 2. 생성적적대신경망 모델





본 논문에서는 가짜 소나 데이터를 생성하는 알고리즘 설계를 위해 GAN 을 사용한다. 그 중 GAN 의 여러 단점을 보완한 WGAN-GP 를 사용한다. WGAN-GP 는 기존 GAN 에 있던 데이터 생성 과정에서 판별기가 생성기에게 전해주는 정보가 없어 생기는 문제를 완화한다. 바로 가중치의 최댓값을 제한하는 방식이다. 가중치의 최댓값을 제한함으로써 판별기가 진짜 데이터를 가짜 데이터라고 거짓말을 할 수 있게 되는 것이다. 그 결과 생성기는 판별기를 속이기 위해 더욱 더 진짜 같은 데이터를 생성해내게 된다. WGAN 에서 판별기는 기존 GAN 에서 진짜인지 가짜인지 구별하거나, 진짜 혹은 가짜일 확률을 계산하는 것이 아니라 이를 점수화 하기 때문에 비평가(critic)이라고 불린다.[5]

본 논문에서 GAN 의 평가지표로는 FID(Fr chet Inception Distance)를 사용한다. FID 란 IS(Inception Scores) 이후로 널리 사용되는 평가지표이며, 미리 학습된 특징추출기를 사용하여 생성된 데이터와 원본 데이터의 분포 거리를 측정한다. 이 때 분포 거리가 0 에 가까울수록 생성된 데이터의 분포가 원본 데이터의 분포와 가깝다. 본 논문에서 미리 학습된 특징추출기로 Inception v3 를 사용한다. 하지만 FID 란 미리 학습된 모델을 사용하는 GAN 의 평가 지표 이므로 미리 학습된 모델에 사용된 데이터와 생성하고자 하는 데이터의 클래스가 다른 경우 특징 포착에 어려움이 있을 수 있다.

## III. 실험결과

WGAN-GP 모델을 사용하여 생성된 데이터는 그림 3 에서 볼 수 있다. 육안으로 그림 1 의 원본 데이터와 생성된 데이터의 차이점을 찾기 어렵다. 또한 본문에서 언급했듯이 데이터는 분석에도 어려움이 있다. 따라서 본 논문에서는 생성된 데이터의 질을 FID 를 이용하여 보고자 한다. 1 epoch 당 3 개의 데이터를 생성하도록 모델을 설계하였으며 총 100epoch 동안 학습을 진행하였다. 그 결과로 300 개의 생성된 데이터와 원본 데이터 간의 FID 는 3.855 로 준수한 값이 나왔다.



시행횟수당 FID 는 그림 4 와 같이 진동하며 감소하는 경향을 보여 학습이 진행됨에 따라 원본데이터와 비슷한 데이터를 생성한다는 것을 알 수 있다. 시행횟수당 FID 와 모든 생성된 데이터를 이용한 FID 는 큰 차이를 보인다. FID 는 데이터 간의 분포 거리를 측정하기 때문에 데이터의 다양성도 FID 에 영향을 주기 때문이다.

## IV. 결론

본 논문에서는 생성적적대신경망 기반 소나데이터 생성 시스템을 설계하였다. 추후 더 많은 데이터셋을 확보하고, FID 에 사용되는 사전 훈련된 특징추출기의 확보의 필요성을 확인하였다.

## ACKNOWLEDGMENT

본 연구는 2020 년도 산업통상자원부의 재원으로 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제(No.202004030200030)입니다.

본 연구는 2020 년도 환경부의 재원으로 한국환경산업기술원(KEITI)의 지원을 받아 수행한 과제입니다.

## 참 고 문 헌

- [1] Knight, William C., Roger G. Pridharm, and Steven M. Kay. "Digital signal processing for sonar.", Proceedings of the IEEE 69.11, 1451-1506, 1981.
- [2] 김동욱, 석종원, and 배건성, "CNN 을 이용한 능동소나 표적/비표적 분류.", 멀티미디어학회논문지. 1062-1067, 2018.
- [3] I.Goodfellow, J.Pouget-Abadie, M.Mirza, B.Xu, D.Wardevfarley, S.Ozair, A.Courville, and Y.Bengio, "Generative adversarial nets", Proc.Advances Neural Information Processing Systems Conf., 2672-2680, 2014.
- [4] Gulrajani, I.,Ahmed, F.,Arjovsky, M.,Dumoulin, V., and Courville, A., "Improved training of Wasserstein gans", arXiv:1704.00028., 2017
- [5] [http://archive.ics.uci.edu/ml/datasets/connectionist+benc h+\(sonar,+mines+vs.+rocks\)](http://archive.ics.uci.edu/ml/datasets/connectionist+benc h+(sonar,+mines+vs.+rocks))
- [6] Arjovsky, Martin, S.Chintala, L.Bottou. "Wasserstein generative adversarial networks.", International conference on machine learning. PMLR, 214-223, 2017