

국방용 합성이미지 데이터셋 생성을 위한 대립훈련신경망 기술 적용 연구

양 훈 민^{*,1)}

¹⁾ 국방과학연구소 국방고등기술원

Synthetic Image Dataset Generation for Defense using Generative Adversarial Networks

Hunmin Yang^{*,1)}

¹⁾ *Institute of Defense Advanced Research, Agency for Defense Development, Korea*

(Received 19 September 2018 / Revised 14 November 2018 / Accepted 9 January 2019)

ABSTRACT

Generative adversarial networks(GANs) have received great attention in the machine learning field for their capacity to model high-dimensional and complex data distribution implicitly and generate new data samples from the model distribution. This paper investigates the model training methodology, architecture, and various applications of generative adversarial networks. Experimental evaluation is also conducted for generating synthetic image dataset for defense using two types of GANs. The first one is for military image generation utilizing the deep convolutional generative adversarial networks(DCGAN). The other is for visible-to-infrared image translation utilizing the cycle-consistent generative adversarial networks(CycleGAN). Each model can yield a great diversity of high-fidelity synthetic images compared to training ones. This result opens up the possibility of using inexpensive synthetic images for training neural networks while avoiding the enormous expense of collecting large amounts of hand-annotated real dataset.

Key Words : Generative Adversarial Networks(대립훈련신경망), Synthetic Image(합성이미지), Deep Learning(딥러닝), Machine Learning(머신러닝), Dataset(데이터셋)

기 호 설 명

G : Generator model

D : Discriminator model

L : Loss function

V : Value function

E : Expectation

x : Real data

z : Latent vector

* Corresponding author, E-mail: hmyang@add.re.kr

Copyright © The Korea Institute of Military Science and Technology

c : Class label

1. 서론

최근 대용량 학습데이터를 사용한 인공지능 학습 및 추론 기술이 비약적 발전을 거듭하고 있다. 사람의 능력을 뛰어 넘는 수준의 영상과 음성 인식 성능을 보이고 있으며 높은 정확도로 사람의 언어도 이해할 수 있게 되었다. 지도학습 기반 딥러닝 기술을 이용한 이미지 인식의 경우 수천에서 수백만 장에 이르는 대용량의 학습데이터가 필요하다. 기존의 전통적인 머신러닝 기법은 학습데이터의 양에 따른 성능 포화도가 높지만 딥러닝 기반 학습에서는 성능 포화도가 상대적으로 낮기 때문에, 레이블 정보가 포함된 대규모의 학습데이터를 확보하는 것이 매우 중요하다. 하지만 레이블 정보가 포함된 대용량의 학습데이터를 획득하는 과정은 많은 시간과 노력을 필요로 하기 때문에, 기술 적용 이전에 데이터 확보에서부터 병목이 발생하는 경우가 대다수이다. 국방 분야에서도 감시정찰, 탐지인식, 무인자율화 등 다양한 분야에서 빅데이터 기반 인공지능 기술의 적용 시도가 활발히 진행되고 있다. 하지만 보안상의 이유로 데이터의 확보와 공유가 더욱 더 어려운 실정이다. 이러한 데이터 부족문제 현상을 합성(synthetic) 데이터를 생성하여 학습데이터로 활용하고자 하는 다양한 연구결과들이 발표되고 있으며^[1-8], 그와 관련하여 대립훈련 기반으로 새로운 데이터를 생성하는 대립훈련신경망 또는 생성적 적대신경망(Generative Adversarial Networks, GANs)^[9] 기술이 크게 발전하고 있다.

본 논문에서는, 대립훈련신경망 기술의 주요 아키텍처와 응용분야들에 대한 기술 분석을 수행하고 국방 빅데이터 분야에의 활용 방안에 관해 기술하고자 한다. 이를 위해, 대립훈련신경망을 이용하여 탱크, 항공모함, 적외선영상과 같은 국방용 합성이미지 데이터를 생성하는 실험을 수행하고 결과를 분석하도록 한다.

2. 대립훈련신경망 기술 분석

본 장에서는 대립훈련신경망 기술과 주요 아키텍처들에 대한 기술 분석을 수행하였고, 이미지 생성 및 변환, 준지도학습, 시뮬레이션 등의 적용 가능한 응용

분야들에 대해서 검토하였다.

2.1 대립훈련신경망

생성모델이란 비지도학습 기반으로 실제 데이터의 확률분포를 모델링하여 실제 데이터와 매우 유사한 합성 데이터를 생성하는 모델이며, 대립훈련신경망은 생성모델의 일종이다. 생성모델은 모델이 실제 데이터와 유사한 데이터를 생성해 낼 수 있다면, 그 모델은 데이터의 내부 특성을 잘 학습했을 것이라는 가정을 바탕으로 한다. 학습된 특성들을 잘 활용한다면, 유사한 데이터를 생성하거나, 새로운 데이터가 주어졌을 때 그것을 분류하고 평가하는 것이 용이하다. 대립훈련신경망은 생성모델학습의 어려움을 두 신경망 모델의 경쟁구도로 전환하여 해결함과 동시에 탁월한 성능을 냄으로써 여러 분야에서 응용되고 있다.

대립훈련신경망은 생성기와 판별기 두 모델들이 내쉬 균형(Nash equilibrium)을 기반으로 최소극대화(minimax) 게임을 진행함으로써 교대로 학습을 진행하는 비지도학습 기반 머신러닝 기법이다(Fig. 1). 생성기 모델은 잡음(noise)을 입력으로 받아서 가짜 샘플을 생성하고, 판별기 모델은 생성기 모델과 실제 학습 데이터셋으로부터 각각 샘플을 받아서 샘플이 실제인지 가짜인지를 판별한다. 판별기 모델은 입력되는 샘플이 실제인지 가짜인지의 확률을 계산하는 로지스틱(logistic) 회귀를 수행하는 분류기로 구현된다. 두 신경망 모델의 학습이 진행됨에 따라서, 생성기 모델은 더욱 더 실제같은 가짜 샘플들을 생성할 수 있게 되고, 판별기 모델은 실제 샘플과 생성된 가짜 샘플을 더 잘 구별할 수 있게 된다. 판별기 모델이 실제 샘플과 구별하지 못할 정도로 생성기 모델이 실제같은 가짜 샘플을 생성할 때까지 학습은 지속된다. 생성기와 판별기 모델의 경쟁구도는 가치함수의 최적화 문제로써 다음과 같이 수식 (1)로 정의된다.

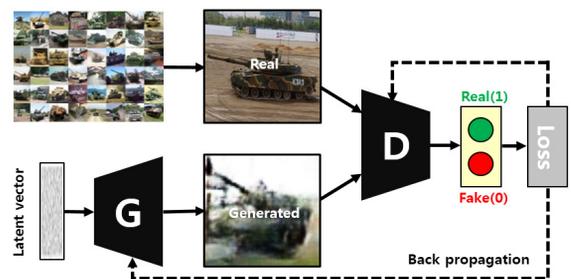


Fig. 1. Generative adversarial network

$$\min_G \max_D V(D, G) = E_x [\log D(x)] + E_z [\log(1 - D(G(z)))] \quad (1)$$

2.2 주요 아키텍처

생성기와 판별기 두 개의 모델로 구성되는 대립훈련 신경망의 주요 아키텍처들을 Fig. 2에 나타내고, 각 모델들의 특성을 대표하는 손실함수(loss function)를 정리하여 Table 1에 나타내었다⁴⁾.

GAN⁹⁾ 또는 컨볼루션 신경망을 사용하여 고화질 영상 생성을 최초로 가능케 한 DCGAN¹⁰⁾의 경우 레이블 정보가 없는 비지도 학습을 수행한다. WGAN¹¹⁾은 워셔스테인(Wasserstein) 거리라는 새로운 확률분포 거리 지표를 사용한다. LSGAN¹²⁾은 최소 자승값을 손실함수로 사용한다. BiGAN¹³⁾은 샘플 공간으로부터 다시 잠재 공간(latent space)으로 투사하는 방법을 사용한다. InfoGAN¹⁴⁾은 생성기 모델의 입력잡음과 함께 보조정보를 포함시킨다. ss-infoGAN¹⁵⁾은 infoGAN을 기반으로 준지도학습을 수행한다. SGAN¹⁶⁾은 판별기 모델에서만 레이블 정보를 받아 준지도학습을 수행한다. CGAN¹⁷⁾은 레이블이 포함된 데이터를 받고 샘플을 생성한다. ACGAN¹⁸⁾은 데이터셋에서 다수의 클래스

스 레이블 정보를 받아서 학습을 수행하고 클래스를 판별한다. EBGAN¹⁹⁾과 BEGAN²⁰⁾은 모두 판별기 모델에 오토인코더(auto-encoder)를 사용한다. EBGAN은 에너지 기반으로 손실함수를 정의하고, BEGAN은 오토인코더의 손실분포를 학습한다.

2.3 응용분야

대립훈련신경망은 지도학습뿐 아니라 준지도학습, 비지도학습의 범위까지 확장되어 다양한 학습 환경과 데이터 및 문제들에 적용될 수 있기 때문에 매우 폭넓은 응용범위를 갖고 있다. 또한 대립훈련을 통해서 데이터의 내부 표현들을 잘 학습하고 그것을 응용하여 새로운 데이터를 생성하거나 변환할 수 있기 때문에, 컴퓨터 비전이나 제어, 시뮬레이션 등 다양한 연구개발 분야들에 적극 활용되고 있다. 대립훈련신경망의 주요 응용분야들은 다음과 같다.

- 이미지 / 동영상 / 텍스트 / 시계열데이터 생성
- 이미지 초해상도 / 이미지 복원 / 이미지 캡션
- 이미지-이미지 변환 / 텍스트-이미지 변환
- 비지도학습 / 준지도학습 / 지도학습
- 시뮬레이션 / 강화학습 / 역강화학습

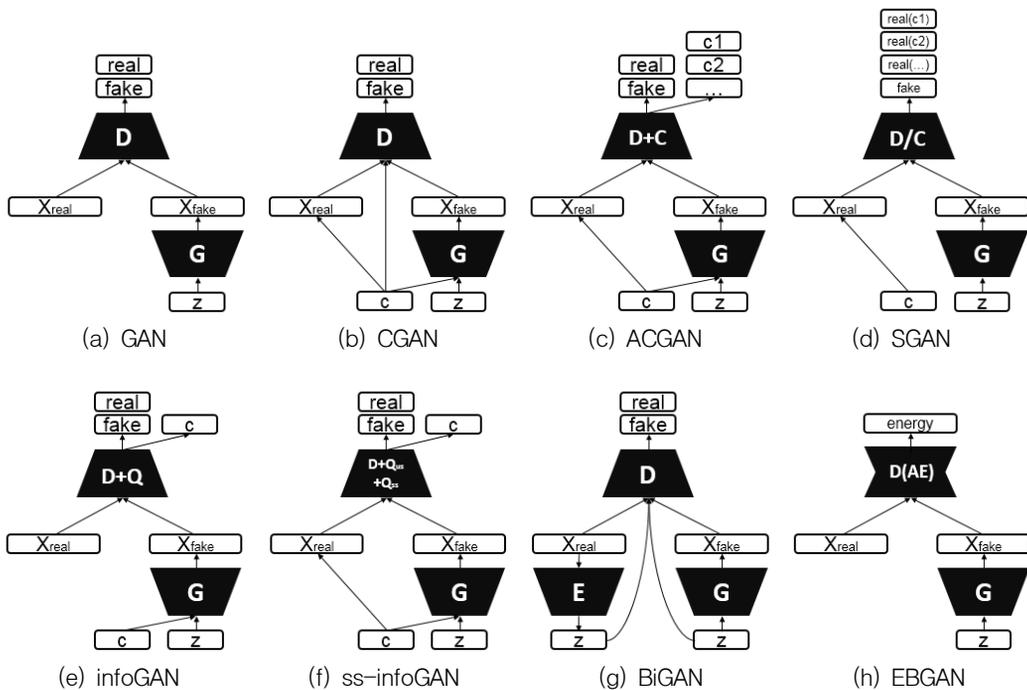


Fig. 2. Architecture of GAN's variants

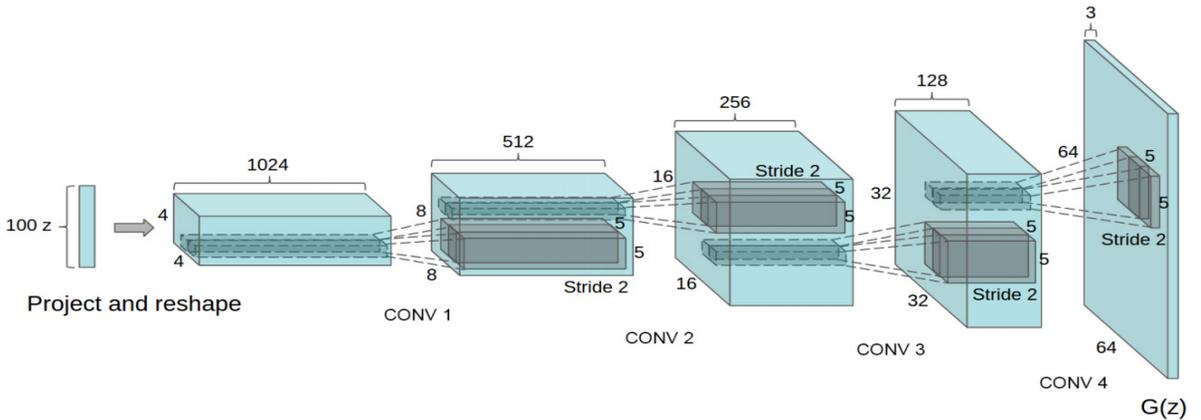


Fig. 3. Generator model of DCGAN^[10]

Table 1. Loss functions of GAN's variants

Type	Loss function
DCGAN ¹⁾	$L_D = E[\log D(x)] + E[\log(1 - D(G(z)))]$ $L_G = E[\log D(G(z))]$
WGAN ²⁾	$L_D = E[D(x)] - E[D(G(z))]$ $L_G = E[D(G(z))]$ $w \leftarrow \text{clip}(w, [-c, c])$
LSGAN ³⁾	$L_D = \frac{1}{2} E[(D(x) - b)^2] + \frac{1}{2} E[(D(G(z)) - a)^2]$ $L_G = \frac{1}{2} E[(D(G(z)) - c)^2]$
BiGAN ⁴⁾	$L_{D,E} = E[\log D(x, E(x))] + E[\log(1 - D(G(z), z))]$ $L_G = E[\log D(G(z), z)]$
InfoGAN ⁵⁾	$L_{D, Q_w, Q_s} = L_{D(GAN)} - \lambda_1 L_I(G, Q_{u,s})$ $L_G = L_{G(GAN)} - \lambda_1 L_I(G, Q_{u,s})$
ss-InfoGAN ⁶⁾	$L_{D, Q_w, Q_s} = L_{D(infoGAN)} - \lambda_2 L_{IS}(G, Q_{ss})$ $L_G = L_{G(infoGAN)} - \lambda_2 L_{IS}(G, Q_{ss})$
SGAN ⁷⁾	$L_D = E[\log D(x c)] + E[\log(1 - D(G(z)))]$ $L_G = E[\log D(G(z))]$
CGAN ⁸⁾	$L_D = E[\log D(x c)] + E[\log(1 - D(G(z c)))]$ $L_G = E[\log D(G(z c))]$
ACGAN ⁹⁾	$L_{D,C} = L_{D(GAN)} + E[P(c x)] + E[P(c G(z))]$ $L_G = L_{G(GAN)} + E[P(c G(z))]$
EBGAN ¹⁰⁾	$L_D = D_{AE}(x) + \max(0, m - D_{AE}(G(z)))$ $L_G = D_{AE}(G(z)) + \lambda \cdot PT$
BEGAN ¹¹⁾	$L_D = D_{AE}(x) - k_i D_{AE}(G(z))$ $L_G = D_{AE}(G(z))$ $k_{i+1} = k_i + \lambda_k (\gamma D_{AE}(x) - D_{AE}(G(z)))$

1) DCGAN: Deep Convolutional Generative Adversarial Networks
2) WGAN: Wasserstein Generative Adversarial Networks

3. 국방용 객체 합성이미지 생성 실험

대립훈련신경망을 학습하여 국방용 객체 합성이미지를 생성하는 실험을 수행하였다. 학습용 데이터와 모델 및 학습 세부사항에 대해서 기술하였고, 생성되는 샘플들을 분석하였다. 모든 연산은 Nvidia Titan Xp GPU 4개와 Intel Xeon(R) E5-1680 CPU가 장착된 단일 워크스테이션에서 수행하였다.

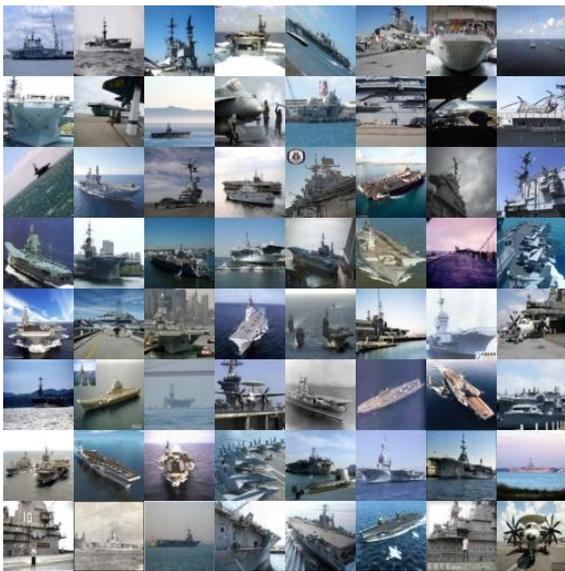
3.1 학습데이터

대립훈련신경망 학습데이터는 스탠포드 대규모 시각 인식 대회용 데이터셋인 ILSVRC2012^[12]을 사용하였다. 대회용 전체 데이터셋은 1,000여 가지의 카테고리들을 포함하고, 각 카테고리는 1,300장씩의 각기 다른 픽셀크기의 사진들로 구성된다. 본 실험에서는 국방용 객체인 탱크(army tank)와 항공모함(aircraft carrier)을 학습 데이터로 사용하였다(Fig. 4). 모든 학습 이미지들은 바이큐빅 보간법(bicubic interpolation)을 통해 64×64의 해상도로 재조정하는 이미지 전처리 작업이 수행되었다.

3) LSGAN: Least Squares Generative Adversarial Networks
4) BiGAN: Bidirectional Generative Adversarial Networks
5) InfoGAN: Information Maximizing Generative Adversarial Networks
6) ss-infoGAN: Semi-supervised Information Maximizing GANs
7) SGAN: Semi-supervised Generative Adversarial Networks
8) CGAN: Conditional Generative Adversarial Networks
9) ACGAN: Auxiliary Classifier Generative Adversarial Networks
10) EBGAN: Energy-based Generative Adversarial Networks
11) BEGAN: Boundary Equilibrium Generative Adversarial Networks
12) ILSVRC2012: ImageNet Large Scale Visual Recognition Challenge 2012



(a) Army tank



(b) Aircraft carrier

Fig. 4. Training images of DCGAN

3.2 학습모델

대립훈련신경망 학습모델은 DCGAN^[10]을 사용하였다. DCGAN은 이미지 생성 입부에서 기존 GAN이 갖고 있던 학습의 불안정성과 모드 붕괴 현상을 완화하기 위해서 풀링(pooling)과 완전연결(fully-connected) 계층을 제거하고 이미지 특징 해석과 표현에 효과적인

컨볼루션 계층을 도입한 것을 주요 특징으로 한다. 또한 생성기와 판별기 심층신경망 모델에 배치 정규화(batch normalization)를 도입하고 각 모델의 특성에 따라 ReLU, Leaky-ReLU, Tanh 등의 다양한 활성화 함수를 활용한다. 생성기 모델에서는 잠재 공간(latent space)의 100차원 입력잠음 벡터 z 가 다양한 특징 맵을 갖는 컨볼루션 표현으로 투사되어 64×64 픽셀크기의 합성이미지 $G(z)$ 로 변환된다(Fig. 3).

3.3 학습 세부사항

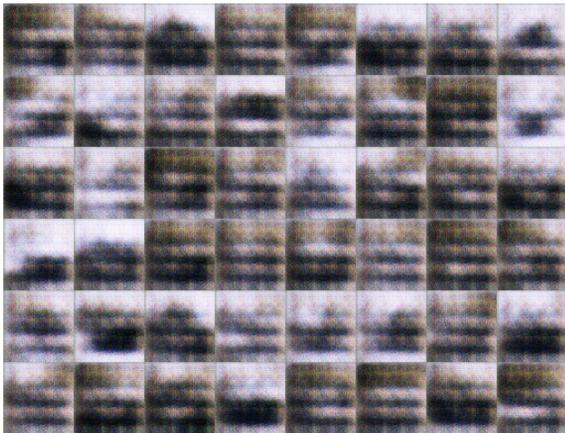
DCGAN의 생성기 및 판별기 모델 학습을 위한 학습 세부사항은 다음과 같다. 모든 모델들은 미니배치 확률 경사 하강법(mini-batch stochastic gradient descent)으로 학습을 수행하였으며, 미니배치 크기는 64를 사용하였다. 심층신경망 모델들의 모든 웨이트(weight)들은 평균 0과 표준편차 0.02를 갖는 정규분포로 초기화하였다. 기존의 GAN의 경우 학습을 위해 모멘텀(momentum) 방법을 사용했지만, 본 연구에서는 아담 최적화기(Adam optimizer)와 모멘텀 계수 0.5, 학습률 0.0002를 사용하였다.

3.4 탱크 합성이미지 생성결과

실제 국방용 탱크 이미지 1,300장과 DCGAN을 사용하여 탱크 합성이미지 생성을 위한 대립훈련신경망 학습을 수행하였다(Fig. 5). 미니배치 크기는 64를 사용하고, 에포크(epoch)는 200을 목표로 하여 학습을 수행하면서 중간 과정에서 생성되는 이미지 샘플들을 분석하였다. 학습 과정을 초기, 중기, 말기로 분류하고, 각 과정에서의 합성이미지 샘플들의 특성을 분석하였다.

학습 초기과정(에포크=10)의 합성이미지 샘플들은 생성기 모델의 입력으로 주어지는 균일분포(uniform distribution) 값을 갖는 잠음 형태에서 크게 벗어나지 못하는 양상을 보인다. 생성기 모델은 실제 국방용 탱크 이미지들의 저수준 또는 고수준의 이미지 특징들을 아직 파악하지 못하고, 심층신경망 모델들의 웨이트 초기값이 단순히 곱해진 형태로써의 이미지들을 출력한다.

학습 중기과정(에포크=52)의 합성이미지 샘플들은 탱크의 전체적인 형태, 배경과의 구분 등과 같은 고수준의 이미지 특징들을 학습하고 표현하는 양상을 나타낸다. 노이즈로써 의미론적인 형태를 찾을 수 없었던 학습 초기과정에 비해서 국방용 탱크 객체의 전체적인 형태가 잡히고 탱크와 비슷한 색상을 표현한다.



(a) epoch = 10



(b) epoch = 52



(c) epoch = 189

Fig. 5. Generated army tank images

심층신경망 모델들의 파라미터 값들이 판별기 모델이 산출하는 손실함수 값의 역전과 학습을 통해 갱신되어 생성기 모델이 더 실제 같은 이미지를 생성하기 시작한다.

학습 말기과정(에포크=189)에서 합성이미지 샘플들은 탱크의 전체적인 형태뿐만 아니라 포의 형태, 사격 방향 등과 같이 세부적인 저수준의 추상화된 특징들까지 파악하여 표현하는 것을 확인할 수 있다. 학습된 생성기 모델은 실제 학습이미지 데이터셋과 유사하지만 답습되지는 않은 새로운 탱크 이미지들을 합성할 수 있고, 판별기 모델은 이미지 특징 추출 및 분류기로써 활용 가능하다.

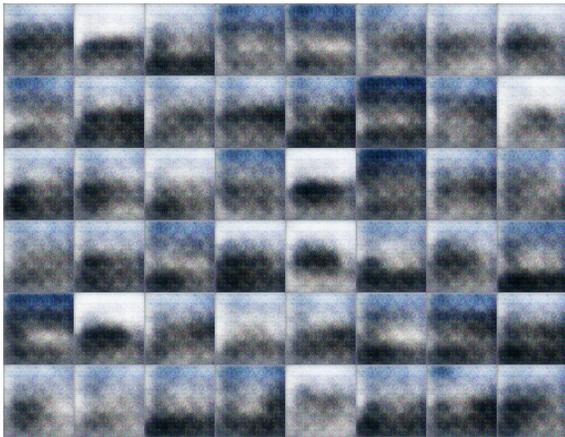
3.5 항공모함 합성이미지 생성결과

실제 항공모함 이미지 1,300장과 DCGAN을 사용하여 항공모함 합성이미지 생성을 위한 대립훈련신경망 학습을 수행하였다(Fig. 6). 미니배치 크기는 64를 사용하고, 에포크는 200을 목표로 하여 학습을 수행하면서 중간 과정에서 생성되는 이미지 샘플들을 분석하였다. 학습 과정을 초기, 중기, 말기로 분류하고, 각 과정에서의 합성이미지 샘플들의 특성을 분석하였다.

학습 초기과정(에포크=11)의 합성이미지 샘플들은 생성기 모델의 입력으로 주어지는 균일분포 값을 갖는 잡음 형태이다. 생성기 모델은 실제 항공모함 이미지들의 이미지 특징들을 아직 파악하지 못하고, 심층신경망 모델들의 웨이트 초기 값이 단순히 곱해진 형태로써의 잡음 형태의 이미지를 출력한다.

학습 중기과정(에포크=49)의 합성이미지 샘플들은 항공모함의 전체적인 윤곽, 배경과의 구분 등과 같은 고수준의 이미지 특징들을 학습하고 표현하는 양상을 나타낸다. 의미론적인 형태를 찾을 수 없었던 학습 초기과정에 비해서 항공모함의 전체적인 윤곽이 어느정도 잡히고 실제 학습이미지들과 비슷한 색상을 표현하기 시작한다. 심층신경망 모델들의 파라미터 값들이 판별기 모델이 산출하는 손실함수 값의 역전과 학습을 통해 생성기 모델이 더 실제 같은 이미지를 생성하도록 갱신되었다.

학습 말기과정(에포크=199)에서 합성이미지 샘플들은 항공모함의 전체적인 형태뿐만 아니라 선두의 위치, 배의 진행 방향 등과 같이 세부적인 저수준의 이미지 특징들까지 파악하여 표현하는 것을 확인할 수 있다. 학습된 생성기 모델은 실제 학습이미지 데이터셋과 유사하지만 답습되지는 않은 새로운 항공모함



(a) epoch = 11



(b) epoch = 49



(c) epoch = 199

Fig. 6. Generated aircraft carrier images

이미지들을 합성할 수 있고, 판별기 모델은 이미지 특징 추출 및 분류기로서 활용 가능하다.

대립훈련을 통해 학습된 생성기 심층신경망 모델을 이용하면, 항공모함 또는 탱크 같은 국방용 객체의 합성이미지를 무제한으로 생성 가능하다. 특히, 대립훈련신경망의 생성기 모델의 입력으로 들어가는 잠재공간 입력잠음 벡터 z 값을 미세 조정하면, 생성되는 합성이미지 $G(z)$ 에서 다양한 특성 변화를 연속적으로 가져올 수 있다. 탱크의 경우 합성되는 포의 형태와 사격방향 등을 변화시킬 수 있고, 항공모함의 경우 배의 크기와 항해 방향 등을 변화시킬 수 있다.

4. 국방용 적외선 합성이미지 생성 실험

대립훈련신경망을 학습하여 국방용 적외선 합성이미지를 생성하는 실험을 수행하였다. 학습용 데이터와 모델 및 학습 세부사항에 대해서 기술하고, 생성되는 샘플들을 분석하였다. 모든 연산은 Nvidia Titan Xp GPU 4개와 Intel Xeon(R) E5-1680 CPU가 장착된 단일 워크스테이션에서 수행하였다.

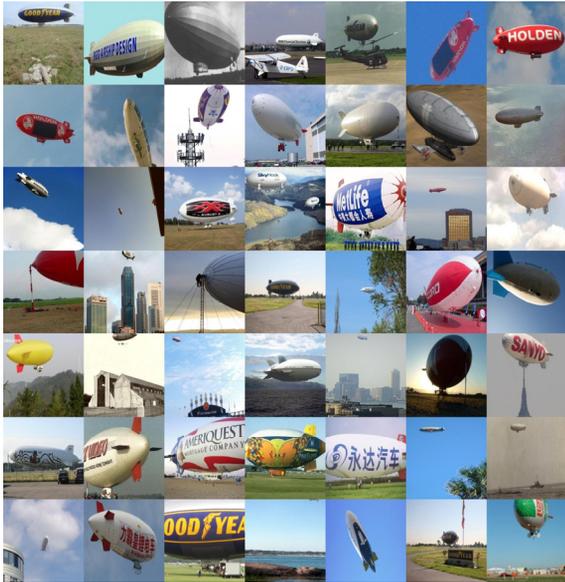
4.1 학습데이터

대립훈련신경망 학습데이터는 ILSVRC2012 데이터셋 중에서 비행선(airship) 카테고리의 이미지들을 사용하였다(Fig. 7). 이미지들을 가시광과 적외선의 이미지 특성에 따라 분류하여, 가시광 1,111장과 적외선 161장 각각을 학습데이터로 사용하였다. 모든 학습 이미지들은 바이큐빅 보간법을 통해 256×256의 해상도로 재조정하는 이미지 전처리 작업이 수행되었다.

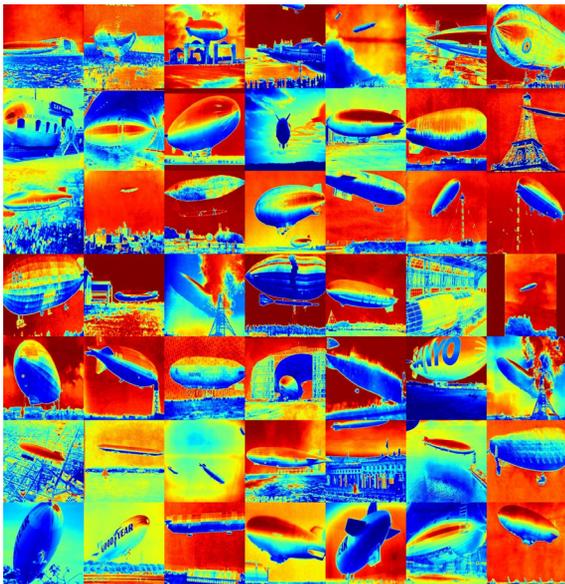
4.2 학습모델

가시광과 적외선 학습이미지 데이터셋들은 서로 짝지어지지 않고 독립적이기 때문에, 레이블 정보가 사용되지 않는 비지도학습 기반으로 학습을 수행해야 한다. 또한 비행선의 모양은 유지하면서 가시광 또는 적외선의 영상 특성만을 변화시키는 것이 학습 목표이므로, 서로 다른 이미지 도메인 간에 물체의 형태는 유지하면서 스타일의 변화만을 가져오는 CycleGAN¹³⁾^[22]을 적외선 영상 변환용 대립훈련신경망 학습모델로 사용하였다(Fig. 8).

13) CycleGAN: Cycle-Consistent Generative Adversarial Networks



(a) Visible domain X



(b) Infrared domain Y

Fig. 7. Training images of CycleGAN

CycleGAN의 학습 목표는 가시광 도메인 X 와 적외선 도메인 Y 사이의 교차 변환을 위한 맵핑 함수를 학습하는 것이다. 맵핑 함수는 실제 가시광 이미지에서 적외선 합성 이미지를 생성하는 $G: X \rightarrow Y$ 와 그 반대인 $F: Y \rightarrow X$ 로 정의된다. 또한 실제 이미지와

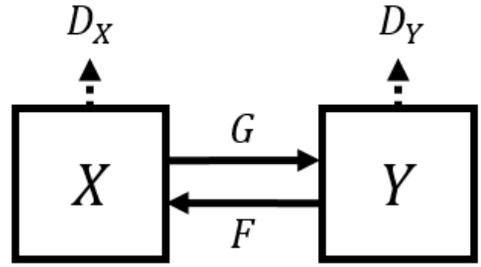


Fig. 8. Training architecture of CycleGAN

맵핑으로 변환된 합성 이미지를 분별하여 손실을 계산하는 판별기 모델은 D_X, D_Y 로 정의된다. CycleGAN은 G, F, D_X, D_Y 총 4개 모델들이 대립훈련을 기반으로 학습을 진행하며, 순환 손실(Cycle consistency loss)을 위한 하이퍼-파라미터(hyper-parameter) λ 와 함께 전체 손실함수는 다음과 같이 정의된다.

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

CycleGAN의 생성기(G, F) 모델은 기존 연구들에서 이미지 스타일 변환과 초해상도에서 뛰어난 성능을 보인 심층신경망 모델 구조^[23]를 사용하였다. 신경망은 2개의 스트라이드(strided) 컨볼루션 계층과, 9개의 레지듀얼 블록(residual block), 그리고 2개의 부분-스트라이드(fractionally-strided) 컨볼루션 계층을 포함한다. 판별기(D_X, D_Y) 모델은 기존의 대립훈련 기반 이미지 초해상도에서 뛰어난 성능을 보인 70×70 PatchGANs^[24] 심층신경망을 사용하였다.

4.3 학습 세부사항

CycleGAN의 생성기(G, F) 및 판별기(D_X, D_Y) 모델 학습을 위한 학습 세부사항은 다음과 같다. 대립훈련 손실함수에서 일반적으로 사용되는 로그(log)값 대신에 학습이 더 안정적인 최소자승값을 사용하였다. 아담 최적화기를 사용하였으며 모멘텀 계수는 0.5, 미니배치 크기는 4, 학습률은 0.0002로 설정하였다. 초기에는 학습률을 고정하고, 에포크 50을 기점으로 학습률이 선형적으로 감소하도록 설정하였다. 심층신경망 모델들의 모든 웨이트들은 평균 0과 표준편차 0.02를 갖는 가우시안 분포로 초기화하였다.

4.4 적외선 합성이미지 생성결과

가시광 및 적외선 학습이미지 데이터셋들과 CycleGAN 기반으로 이미지-이미지 변환 학습을 수행하였다. 미니배치 크기는 4를 사용하고, 에포크가 200이 될 때까지 미니배치 학습을 수행한 후에 학습된 생성기 모델을 이용하여 이미지 샘플들을 생성하였다 (Fig. 9). 비행선의 실제 가시광 이미지 x 는 G 변환을 통해 적외선 합성이미지 $G(x)$ 로 변환되고, 변환된 적외선 합성이미지는 F 변환을 통해서 다시 가시광 합성이미지 $F(G(x))$ 로 복원된다. 마찬가지로, 비행선의 실제 적외선 이미지 y 는 F 변환을 통해 가시광 합성이미지 $F(y)$ 로 변환되고, 변환된 가시광 합성이미지는 G 변환을 통해 다시 적외선 합성이미지 $G(F(y))$ 로 복원된다.

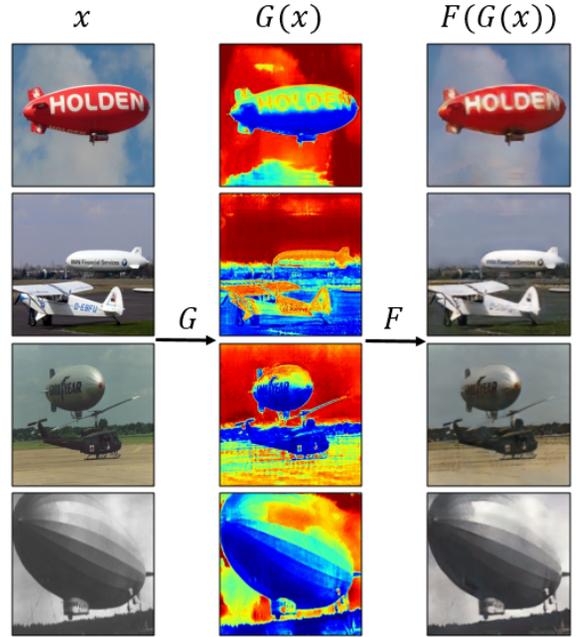
합성영상의 실효성 검증을 위해 Fig. 9에서 실제 적외선 이미지 y 와 변환을 통해 생성된 합성 적외선 이미지 $G(F(y))$ 의 최대 신호 대 잡음비(Peak Signal-to-Noise Ratio, PSNR)를 계산하였다. 최대 신호 대 잡음비는 다음과 같이 수식 (3)으로 정의된다.

$$PSNR = 20 \log_{10} \left(\frac{MAX_I}{\sqrt{MSE}} \right) \quad (3)$$

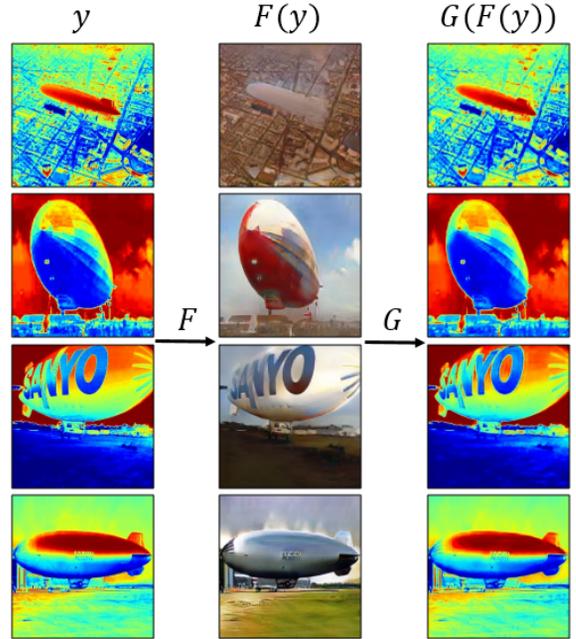
$$(MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - K(i,j)]^2, MAX_I = 2^8 - 1)$$

최대 신호 대 잡음비는 신호가 가질 수 있는 최대 전력에 대한 잡음의 전력을 나타내는 것으로, 주로 영상 압축이나 변환 과정에서 생기는 화질의 손실 정보를 평가할 때 사용되는 평가지표이다. 실제 적외선 이미지와 합성 이미지의 최대 신호 대 잡음비는 평균 32 dB로 이미지 초해상도 복원기술의 최신 성능지표 (31~34 dB)^[26] 수준과 비교했을 때 훌륭한 변환이 수행되었다고 판단된다.

대립훈련을 통해 학습된 생성기 모델 G 를 이용하면 임의의 가시광 이미지를 해당 적외선 합성이미지로 변환 가능하고, 또한 생성기 모델 F 를 이용하면 임의의 적외선 이미지를 해당 가시광 합성이미지로 변환 가능하다. 적외선 합성영상 획득이 필요하거나, 가시광 영역의 영상으로 재변환이 필요한 경우에 학습된 모델들을 활용 가능할 것으로 판단된다.



(a) Visible to infrared(X → Y)



(b) Infrared to visible(Y → X)

Fig. 9. Image-to-image translation results

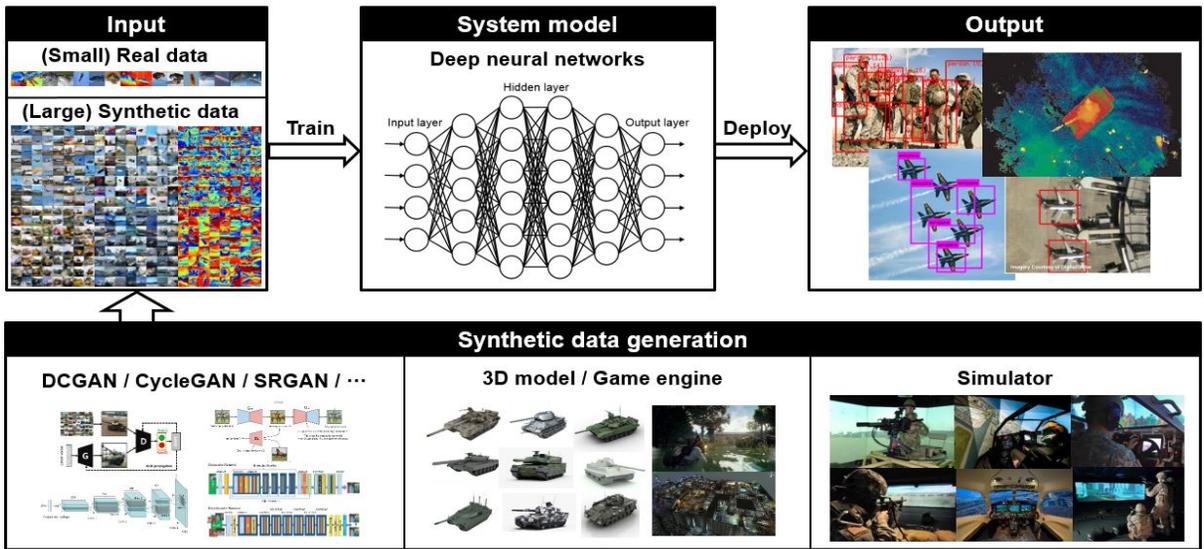


Fig. 10. Concept diagram for synthetic data generation and its applications

5. 합성 가상데이터의 국방 인공지능 분야 활용

인공지능 기술을 이용한 연구개발을 위해서는 보통 수천에서 수백만의 관련 학습데이터가 필요한데, 국방에서는 실제 데이터 확보가 현실적으로 매우 어렵다. 이를 해결하기 위한 다양한 연구개발이 시도되고 있고, 대립훈련신경망을 활용한 분야도 최근 급증하고 있다. 대립훈련신경망과 같은 비지도학습 기반 생성모델을 통해 대량의 합성데이터들을 생성하고, 기존의 소량의 데이터에 증강하여 학습데이터로 활용했을 때 높은 학습 성능을 얻을 수 있다고 알려져 있다^[1-8]. 본 연구에서 DCGAN과 CycleGAN 기반으로 생성한 탱크, 항공모함, 비행선 적외선영상과 같은 국방용 합성이미지 데이터셋은 이미지 인식, 객체 검출, 객체 분할 등을 수행하기 위한 머신러닝 관련 분야에서 학습데이터로써 활용 가능할 것으로 판단된다. 대립훈련신경망을 통해 생성된 합성이미지 빅데이터는 지능 자율형 응용기술, 지능형 무기체계, 무인로봇 시뮬레이션 등 인공지능 기술이 적용되는 다양한 국방 연구개발 분야의 학습용 데이터로써 활용 가능할 것이다.

국방과학연구소에서는 국방용 어플리케이션에서 데이터 부족문제 현상을 극복하기 위해 시뮬레이터, 게임 엔진, 3차원 CAD¹⁴⁾ 모델링, 컴퓨터 그래픽 기술 등을

이용하여 실제와 유사한 양질의 가상데이터를 생성하여 학습데이터로 활용하고자 하는 연구가 진행 중에 있다 (Fig. 10). 국방용 시뮬레이터 영상의 실사화를 위해 대립훈련신경망 기술 적용이 가능하고, 대립훈련신경망 학습을 돕기 위해 학습 초기이미지로써 시뮬레이터 영상을 활용할 수 있다. 또한 학습용 가상데이터 생성 관련 연구로써 데이터 다양성을 증가시켜서 컨볼루션 신경망 등이 수행하는 머신러닝 기반 특징 학습에 도움을 주고자 하는 도메인 랜덤화(domain randomization) 기법, 레이블 스무딩(label smoothing) 기법 관련 연구들도 급증하고 있다^[1-2]. 합성 및 가상데이터를 대규모 빅데이터로 생성하여 활용하고자 한다면, 기존의 IT 처리기술로 감당하기 어렵기 때문에^[25] 빅데이터 분산 저장 및 처리기술의 활용이 필수적이라고 판단된다.

6. 결론

본 연구에서는 대립훈련신경망에 대한 기술 분석을 수행하고, 대회용 벤치마크 데이터셋을 활용하여 탱크, 항공모함, 적외선영상과 같은 국방용 합성이미지 데이터를 생성하는 실험을 수행하였다. 학습된 모델을 통해 생성된 합성이미지들은 머신러닝을 이용하는 국방 연구개발 분야의 학습데이터로써 활용 가능할 것이다. 아울러 초대용량의 학습용 데이터를 효율적으로

14) CAD: Computer-Aided Design

처리하기 위한 빅데이터 분산 저장 및 처리기술을 적절히 활용하면, 대규모 머신러닝용 데이터 처리시스템 구축도 가능할 것으로 판단된다. 컴퓨터 비전 분야뿐만 아니라, 음성인식, 신호처리, 자연어처리, 강화학습, 제어 및 시뮬레이션 등 다양한 분야에 활용 가능한 대립훈련 기반 학습기술을 감시정찰, 탐지인식, 자율주행, 무인로봇 등의 관련 국방 연구개발 분야에 선제적으로 활용하는 것이 필요하다.

References

- [1] J. Tremblay et al., "Training Deep Networks with Synthetic Data: Bridging the Reality Gap by Domain Randomization," Computer Vision and Pattern Recognition(CVPR), 2018.
- [2] Z. Zheng et al., "Unlabeled Samples Generated by GAN Improve the Person Re-identification Baseline in Vitro," International Conference on Computer Vision(ICCV), 2017.
- [3] M. V. Giuffrida et al., "ARIGAN: Synthetic Arabidopsis Plants using Generative Adversarial Network," International Conference on Computer Vision(ICCV) CVPPP Workshop, 2017.
- [4] H. Yang et al., "Unsupervised Learning Based GANs Technology Review," KIMST Annual Conference Proceedings, 2017.
- [5] H. Yang et al., "GANs Based Machine Learning Training Image Generation," KIMST Annual Conference Proceedings, 2017.
- [6] H. Yang et al., "Visible-to-Infrared Image Translation using Adversarial Training," KIMST Annual Conference Proceedings, 2018.
- [7] H. Yang et al., "Cross-domain Image Translation for Large Shape Transformation using Generative Adversarial Networks," Korea Computer Congress (KCC), 2018.
- [8] H. Yang et al., "GANs Technology and Big Data Applications for Defense," Defense Science & Technology Plus, Vol. 239, 2018.
- [9] I. Goodfellow et al., "Generative Adversarial Network s," arXiv:1406.2661.
- [10] A. Radford et al., "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks," arXiv:1511.06434.
- [11] M. Arjovsky et al., "Wasserstein GAN," arXiv:1701.07875.
- [12] X. Mao et al., "Least Squares Generative Adversarial Networks," arXiv:1611.04076.
- [13] J. Donahue et al., "Adversarial Feature Learning," arXiv:1605.09782.
- [14] X. Chen et al., "InfoGAN: Interpretable Representation Learning by Information Maximizing Generative Adversarial Nets," arXiv:1606.03657.
- [15] A. Spurr et al., "Guiding InfoGAN with Semi-Supervision," arXiv:17.07.04487.
- [16] A. Odena, "Semi-Supervised Learning with Generative Adversarial Networks," arXiv:1606.01583.
- [17] M. Mirza et al., "Conditional Generative Adversarial Nets," arXiv:1411.1784.
- [18] A. Odena et al., "Conditional Image Synthesis with Auxiliary Classifier GANs," arXiv:1610.09585.
- [19] J. Zhao et al., "Energy-Based Generative Adversarial Networks," arXiv:1609.03126.
- [20] D. Berthelot et al., "BEGAN: Boundary Equilibrium Generative Adversarial Networks," arXiv:1703.10717.
- [21] O. Russakovsky et al., "ImageNet Large Scale Visual Recognition Challenge," International Journal of Computer Vision(IJCV), 2015.
- [22] J. Zhu, T. Park, P. Isola, A. Efros, "Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks," International Conference on Computer Vision(ICCV), 2017.
- [23] J. Johnson, et al., "Perceptual Losses for Real-Time Style Transfer and Super-Resolution," European Conference on Computer Vision(ECCV), 2016.
- [24] C. Ledig, et al., "Photo-realistic Single Image Super-Resolution using a Generative Adversarial Network," Computer Vision and Pattern Recognition(CVPR), 2017.
- [25] D. Chung et al., "Getting the Most Out of Multi-GPU on Inference Stage using Hadoop-Spark Cluster," GPU Technology Conference(GTC), 2018.
- [26] E. Agustsson et al., "NTIRE 2017 Challenge on Single Image Super-Resolution: Dataset and Study," CVPR Workshop, 2017.