

딥러닝 기반 교량 손상추정을 위한 Generative Adversarial Network를 이용한 가속도 데이터 생성 모델

Generative Model of Acceleration Data for Deep Learning-based Damage Detection for Bridges Using Generative Adversarial Network

이강혁¹⁾, 신도형²⁾

Lee, Kanghyeok¹⁾ · Shin, Do Hyoung²⁾

Received March 7, 2019; Received March 8, 2019 / Accepted March 8, 2019

ABSTRACT: Maintenance of aging structures has attracted societal attention. Maintenance of the aging structure can be efficiently performed with a digital twin. In order to maintain the structure based on the digital twin, it is required to accurately detect the damage of the structure. Meanwhile, deep learning-based damage detection approaches have shown good performance for detecting damage of structures. However, in order to develop such deep learning-based damage detection approaches, it is necessary to use a large number of data before and after damage, but there is a problem that the amount of data before and after the damage is unbalanced in reality. In order to solve this problem, this study proposed a method based on Generative adversarial network, one of Generative Model, for generating acceleration data usually used for damage detection approaches. As results, it is confirmed that the acceleration data generated by the GAN has a very similar pattern to the acceleration generated by the simulation with structural analysis software. These results show that not only the pattern of the macroscopic data but also the frequency domain of the acceleration data can be reproduced. Therefore, these findings show that the GAN model can analyze complex acceleration data on its own, and it is thought that this data can help training of the deep learning-based damage detection approaches.

KEYWORDS: Generative Adversarial Network, Generative Model, Damage Detection, Digital Twin, Maintenance

키워드: Generative Adversarial Network, 생성모델, 손상추정기법, 디지털 트윈, 유지관리

1. 서론

1.1 연구의 배경 및 목적

최근 노후화 구조물의 증가와 함께 노후화 구조물의 유지관리는 사회적 이슈로 대두되고 있다(Lee, 2015). 이러한 노후화 구조물의 유지관리를 위해서 건설 산업에서 유용하게 사용되는 BIM에 기반한 디지털 트윈이 구조물 유지관리에 도움을 줄 수 있다. 디지털 트윈을 노후화 구조물의 유지관리에 효과적으로 사용하기 위해서는 구조물의 손상이 디지털 트윈에 정확히 반영되는 것이 필요하다. 이를 위해서는 먼저 구조물의 손상을 정

확히 추정하는 것이 선행되어야 하며, 구조물의 정확한 손상 추정을 위해서는 구조물 건전도 모니터링 기법(Structural Health Monitoring, SHM)이 유용하게 이용될 수 있다(Oh et al., 2017).

구조물 건전도 모니터링 기법이란 구조물에 가속도계, 변위계, 변형률계 등의 여러 센서를 설치한 뒤, 실시간으로 구조물의 거동 이상여부를 파악하고, 이러한 거동 데이터들을 종합적으로 분석하여 구조물의 손상 여부 및 건전도를 파악하는 기법을 말한다. 구조물 건전도 모니터링을 기반으로 한 구조물 손상 추정은 웨이블릿(Wavelet) 분석과 같은 신호처리기법을 이용하는 방법(Hou et al., 2000; Noh et al., 2011; Pnevmatikos &

¹⁾학생회원, 인하대학교 토목공학과 박사과정 (kanghyeok0117@gmail.com)

²⁾정회원, 인하대학교 사회인프라공학과 부교수 (dshin@inha.ac.kr) (교신저자)

Hatzigeorgiou 2017; Soman et al., 2018)과 인공신경망(Artificial Neural Network; ANN)과 같은 머신러닝기법을 이용하는 방법 (e.g. Mehrjoo et al., 2008; Park et al., 2009; Hakim et al., 2015; Padil et al., 2017) 등 여러 방법론을 이용하여 현재까지 연구 및 개발되고 있다. 특히 최근에는 인공신경망을 기반으로 한 딥러닝은 여러 분야에서 두각을 보이고 있는데, 이러한 딥러닝을 교량 건전도 모니터링 기법에 이용하여 손상추정기법을 더욱 고도화하고 지능화하려는 연구들도 수행되고 있다(Abdeljaber et al., 2017; Lin et al., 2017; Lee et al., 2018).

한편, 딥러닝 기반 손상추정기법의 개발을 위해선 구조물에서 많은 데이터를 얻어야 하며 더욱 정밀한 손상추정기법의 개발을 위해선 구조물의 손상 전과 손상 후의 데이터 모두를 확보하여야 한다. 이 때, 구조물 건전도 모니터링 시스템은 손상이 생기기 전의 데이터를 확보할 때에는 큰 문제가 없다. 하지만 일반적으로 실제 구조물에 손상이 생기게 되면, 시설물 이용자의 안전에 위협을 줄 수 있으므로, 안전 확보를 위해 구조물의 유지관리 프로세스가 즉각적으로 시행되게 된다. 따라서 손상이 발생한 뒤에 데이터를 대량으로 얻어내는 것은 쉽지가 않다. 이러한 이유로, 딥러닝 기반 손상추정기법이 실무에서 활용된다면, 손상 전의 데이터양과 손상 후의 데이터양이 균형을 이루지 못하게 된다. 이로 인해, 손상 전의 데이터양이 손상 후의 데이터양보다 많게 되는데, 이러한 데이터로 학습된 딥러닝 모델은 어떠한 데이터가 입력값으로 사용되더라도 분류 결과를 손상 전이라고 평가할 확률이 높아지는 과적합 문제를 일으킬 수 있다. 이러한 문제를 해결하기 위해선 손상 후의 데이터를 더 얻어내거나 수학적 모델을 통해 데이터의 분포를 학습하는 과정이 필요하게 된다.

이러한 데이터의 부족 문제를 해결하기 위해선, 수학적 모델을 통해 데이터의 분포를 학습하여 비슷한 데이터를 생성할 수 있는 생성모델(Generative model)을 이용한 방법이 활용될 수 있다. 생성모델에서 가장 대표적인 방법론은 가우시안 혼합 모델(Gaussian Mixture Model, GMM)이며, GMM은 여러 개의 표준정규분포를 조합하여 다양한 신호데이터를 만들어내는데 자주 사용되고 있다. 한편 손상 추정기법에 주로 사용되는 데이터의 종류는 가속도 데이터이며, 실제 가속도계를 통해 얻어지는 가속도 데이터의 패턴은 백색 잡음(white noise)과 비슷하여 그 패턴을 찾기가 쉽지 않다. 따라서 GMM을 이용하여 가속도 데이터의 패턴을 재현해내기 위해선 수많은 가우시안 분포의 조합이 필요하게 되는데, 이러한 방법으로 가속도 데이터의 패턴을 재현하게 되면 학습해야 할 모델의 파라미터가 너무 많아져 모델 생성에 비효율을 가져올 수 있다. 즉, 가속도 데이터의 패턴을 학습하고 이와 비슷한 데이터를 생성해내기 위해서 파라미터 없이 데이터만을 사용하여 복잡한 패턴의 분석이 가능한 생성모델의 이용이 필요하다.

이러한 한계에 대해, 딥러닝 기반의 생성모델(Deep Generate

Model)을 이용한 방법을 활용할 수 있다. 딥러닝 기반의 생성 모델은 GMM과 달리 데이터만을 통해 학습할 수 있고, 딥러닝을 이용하기 때문에 복잡한 패턴의 분석과 학습이 가능하다는 장점이 있다. 최근 가장 널리 사용되는 딥러닝 기반의 생성모델로, Generative Adversarial Network (GAN)은 다양한 데이터의 학습 및 모사에 좋은 성능을 보이고 있다. GAN은 준지도학습(semi-supervised learning)을 기반으로 하여 적은 양의 데이터를 가지고도 그 패턴을 학습하여 유사한 다량의 데이터의 모사가 가능하다는 장점이 있다. 특히 이러한 GAN은 이미지 프로세싱 분야에서 실제와 비슷한 이미지를 만들어내는데 두각을 나타내고 있으며 실제로 GAN이 만들어낸 이미지를 다시 딥러닝 모델의 학습에 이용하여 학습데이터가 적은 경우 큰 효과를 얻을 수 있도록 도와줄 수 있다.

이러한 장점에 기반을 두어, 구조물에서 얻을 수 있는 손상 후 데이터가 소량만 있어도 이를 이용하여 GAN을 학습한 뒤 실제와 유사한 다량의 데이터를 생성하게 되면 손상추정을 위한 딥러닝 모델의 학습에 유효할 것으로 보인다. 따라서 본 연구에서는 소량의 가속도 데이터만으로도 실제 가속도의 데이터와 유사한 성질을 가진 다량의 데이터를 생성할 수 있는 GAN 기반의 생성 모델을 제시하고자 한다. 또한, 생성모델을 통해 생성된 데이터가 실제 데이터와 비슷한 패턴을 지니고 있는지를 비교하여 제시된 생성모델을 검증하였다.

1.2 연구의 범위 및 방법

GAN을 이용하여 실제 가속도 데이터와 비슷한 가짜 가속도 데이터를 만들어내기 위해서는 먼저 소량의 실제 가속도를 이용한 학습이 필요하다. 본 연구에서는 교량과 비슷한 시뮬레이션 모델을 먼저 구축하여 GAN에 이용될 기초 가속도 데이터를 확보하였다. 시뮬레이션 모델 구축을 위하여 본 연구에서는 MOLIT(2018)의 “2018 도로 교량 및 터널 현황조사”를 참고하여 국내 일반국도에 설치된 교량형식 중 가장 많은 숫자를 차지하고 있는 PSC-교를 모델링하고자 하였다. 시뮬레이션을 위한 하중 시나리오는 여러 차량이 동적거동하며 재하될 수 있도록 조정하였으며, 이를 통해 다양한 동적 하중이 적용된 가속도 데이터를 생성하도록 하였다. 가속도 데이터를 측정하는 센서의 위치는 교량의 슬래브의 정중앙으로 설정하였으며, 시뮬레이션을 통해 생성된 가속도 데이터들을 통해 GAN을 학습하도록 하였다.

특히 본 연구에서는 학습된 GAN 모델의 생성자(Generator)를 이용하여 실제와 비슷한 가속도를 생성하는데 초점을 두었다. 또한 GAN이 생성한 가속도 데이터와 실제 가속도가 가지고 있는 신호에 대해 고속 푸리에 변환(Fast Fourier Transform, FFT)을 수행하여 GAN이 생성한 가속도가 학습에 사용된 가속도와 비슷한 분포를 지니고 있는지 확인하고자 하였다.

2. 선행연구조사

디지털 트윈모델을 활용한 구조물의 유지관리를 위해서는 구조물의 손상 추정치 우선되어야 한다. 최근 딥러닝 기반 손상추정기법의 개발이 다수 진행되고 있으나, 딥러닝 기반 손상추정기법은 많은 데이터가 필요하다는 한계가 있다. 이러한 한계를 극복하기 위해 데이터의 분포를 학습하고 새로운 데이터를 생성해 낼 수 있는 생성모델을 활용한 방법이 사용될 수 있다.

2.1 가우시안 혼합 모델 기반 생성 모델

일반적으로 생성모델은 머신러닝을 이용한 분류문제에서 자주 사용되고 있다. 머신러닝 기반 분류문제에는 크게 두 가지 해결방법이 존재하는데, 데이터가 속한 클래스를 직접적으로 구분하는 분류모델(Discriminative model)을 이용하는 방법과, 데이터가 속한 그룹을 파악하는데 목적을 둔 생성모델 모델이다. 즉, 분류모델은 각각의 데이터가 가진 클래스를 파악하는데 목적을 두는데 반해, 생성모델은 전체적인 데이터가 군집된 그룹들을 파악하는데 목적을 둔다. 특히 생성모델의 경우 데이터가 가진 군집을 파악하기 위해서 데이터의 분포 자체를 학습하는 과정을 내포하게 되는데, 이러한 분포 학습을 통해 학습된 생성모델은 학습된 데이터와 비슷한 분포를 생성하는데도 사용이 가능하다.

데이터 분포의 학습은 군집 분류 뿐 아니라 데이터 생성의 정확도에도 가장 직접적인 영향을 주게 된다. 이러한 데이터 분포의 학습을 위해 가장 많이 사용되는 방법론은 가우시안 분포를 다수 중첩시켜 다양한 패턴으로 활용하는 GMM을 활용한 방법이며, GMM은 최근까지도, 음성신호, 전자기 신호 등의 다양한 신호 데이터의 분석에도 널리 활용되고 있다(Park and Kim, 2000; Wakita et al., 2006; Mayorga et al., 2010; Bruno et al., 2013; Glowacz et al., 2018)

예를 들어, Park and Kim (2000)은 광대역을 통해 음성 신호를 전달하기 위하여 GMM을 통해 음성신호를 모델링하여 신호화 시키는데 이용하였다. Wakita et al. (2006)은 자동차 운전 중 가속 페달, 브레이크 페달 등을 통해 얻을 수 있는 운전 환경 정보들을 GMM으로 모델링하여 운전자의 동적 행위를 파악하는데 이용하였다. Mayorga et al. (2010)은 폐에서 측정되는 진동소리를 GMM을 통해 학습하고 폐의 질병이 있어 진동소리의 패턴이 달라질 경우 이를 추정할 수 있는 방법론을 제안하였다. Bruno et al. (2013)은 손목에 부착된 3축 가속도 센서로부터 얻은 가속도 데이터를 모델링하는데 GMM을 활용하였으며, 이를 통해 사람이 현재 어떤 활동을 하고 있는지를 분석하는데 이용하였다. Glowacz et al. (2018)은 베어링이나 코일이 설치된 기기에서 관측되는 음향신호를 GMM으로 모델링하고 기기의 초기 결함을 진단할 수 있는 방법론을 제시하였다.

특히 이러한 그룹 분류의 장점을 가진 GMM을 이용하여 구조물 손상의 여부를 파악하기 위해 활용한 사례도 다수 존재한다(Nair and Kiremidjian, 2007; Kullaa, 2014; Banerjee et al., 2010). 예를 들면, Nair and Kiremidjian (2007)는 손상 전 후의 가속도 데이터를 각각 샘플링하여, 샘플링 된 가속도 데이터를 Autoregressive Model로 변환한 뒤, 각각의 Autoregressive Model의 parameter들의 분포를 GMM으로 학습하여, 구조물의 손상 여부를 구분하는 방법을 제시하였다. 이와 비슷하게 Kullaa (2014)는 Autoregressive Model 대신 Local Linear Model을 이용하였으며, 샘플링 된 가속도 데이터를 각각의 Local Linear Model의 parameter들의 분포를 GMM으로 학습하여, 교량의 손상을 구분하고자 하였다. 또한 Banerjee et al. (2010)은 신호데이터를 에너지 모델 기반 feature로 변환한 뒤, feature들의 분포를 GMM으로 학습하여 구조물 손상을 파악하는 기법을 제시하였다.

이러한 구조물 건전도 모니터링에 활용된 GMM은 주로 구조물의 손상을 구분하는데 주목적을 두고 있으며, GMM의 학습역시 가속도 데이터의 feature를 학습하는데 사용되었다. 즉, GMM은 feature의 분포에 최적화 되도록 학습되었기 때문에, feature를 통해 가속도 데이터를 복원하는데 사용하기에는 한계가 있다. 따라서 생성모델을 활용하여 가속도 데이터 자체를 학습할 수 있는 방법의 개발이 필요할 것으로 판단된다.

한편 Deng et al. (2013)은 음성 신호를 기반으로, 음성 인식에 대한 GMM과 딥러닝 모델 중 하나인 Deep neural network (DNN) 모델을 비교한 바 있는데, GMM 보다 DNN 모델이 더욱 높은 인식률을 나타낸 바 있다. 즉 GMM 보다 딥러닝 기반 방법론이 음성 신호의 패턴을 더 잘 분석한다고 판단할 수 있다. 특히 음성 신호의 경우 구조물의 가속도 데이터가 가진 패턴과 유사한 경향이 있으므로 본 연구에서는 이러한 연구 결과에 주목하여 딥러닝 기반 생성모델을 가속도 생성에 이용하고자 하였다.

2.2 Generative Adversarial Network 기반 생성모델

딥러닝 기반의 대표적 생성모델로는 GAN이 존재한다. GAN은 최근 딥러닝 분야에서 가장 주목 받고 있는 비지도 학습기반의 알고리즘으로써, 2014년 Goodfellow et al. (2014)에 의해 소개되었다. GAN은 생성자(Generator)와 판별자(Discriminator)의 상호 적대적 학습을 통해 딥러닝 네트워크를 최적화 시킨다. GAN의 생성자는 데이터를 생성하는 역할을 하며, 판별자는 생성된 데이터가 실제 데이터에 상응하는 데이터로 판별될 수 있는지 구분하는 역할을 한다. GAN은 주로 이미지 프로세싱에서 주로 사용되고 있으며 학습 이미지가 많지 않은 딥러닝의 학습데이터를 만드는데도 큰 성과를 보이고 있다 (Goodfellow et al., 2014; Radford et al., 2015; Mao et al., 2017). 예를 들면, Goodfellow et al. (2014)는 GAN을 통해 손글씨, 얼굴, 동물 등

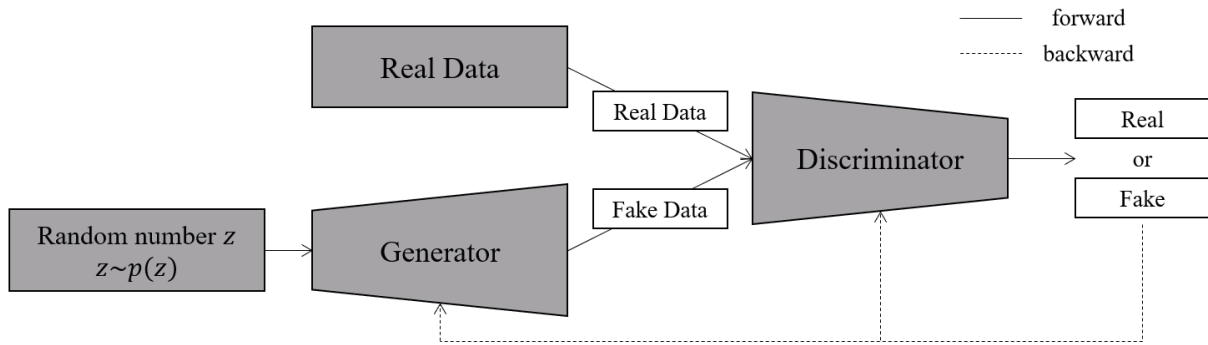


Figure 1. General architecture of a generative adversarial network

의 다양한 이미지를 생성하는 것을 제안하였으며, 상당히 유사한 이미지를 생성하고 있음을 증명하였다. Radford et al. (2015)는 생성자에 GAN에 이미지 데이터의 feature를 잘 추출하는데 사용될 수 있는 convolutional layer를 함께 이용할 수 있는 Deep Convolutional GAN을 구현하여 생성자의 성능을 높일 수 있는 방법을 제안하였다. Mao et al. (2017)은 GAN에서 일어날 수 있는 Vanishing Gradient 문제를 해결하기 위해 판별자에 sigmoid cross entropy loss 대신 least square loss를 사용하는 Least Square GAN을 제안하여 이미지 데이터에 대한 GAN 활용성을 높이고자 하였다.

또한 이미지 프로세싱 뿐 아니라 음성 신호의 생성에도 유용한 결과를 보이고 있음을 확인하였다(e.g. Pascual et al., 2017; Yang et al., 2017). 예를 들면, Pascual et al. (2017)은 소음이 포함된 음성 신호의 소음을 제거하기 위해 GAN을 이용하여 분포를 재생성하는 방법을 제안하였으며, Yang et al. (2017)은 Convolutional GAN을 이용하여 다양한 멜로디와 박자를 가진 실제와 비슷한 음악을 생성할 수 있는 기법을 제안하였다.

한편 구조물 가속도 데이터에 이러한 GAN을 이용한 생성모델을 구축한 연구결과는 찾아볼 수 없었다. 하지만, 이러한 결과를 종합하여 볼 때, GAN을 이용하게 되면 SHM 시스템에서 얻어낸 가속도 데이터의 패턴을 분석하여 이와 유사한 데이터를 충분히 만들어 낼 수 있을 것이라 판단된다. 이러한 GAN의 장점에 입각하여 본 연구에서는 가속도 데이터의 생성을 위해 GAN을 활용하고자 하였다. GAN을 이용해 생성된 데이터는 GAN의 기초 데이터로 활용되었던 가속도 데이터와 비교 분석되었으며, 분석된 결과를 토대로 생성된 데이터를 딥러닝 기반 손상추정의 학습 데이터로 사용될 수 있을지 여부를 판단하고자 하였다.

3. Generative Adversarial Network (GAN)

본 연구에서는 실제 환경에서 취득하기에 어려움이 있는 교량의 가속도 데이터를 생성해 내기 위한 방법론으로 GAN을 이용하고자 하였다. 본 장에서는 가속도 데이터 생성을 위한 GAN의 구조와 이를 기반으로 하여 본 연구에서 활용한 GAN의 학습 방식에 대해 서술하였다.

3.1 GAN의 기본 구조

figure 2에서 볼 수 있듯이, GAN의 기본적인 구조는 데이터가 실제 데이터인지 가짜 데이터인지 구분하기 위한 판별자와 실제와 같은 데이터를 생성하는 것을 목표로 하는 생성자로 나누어진다.

먼저 GAN의 판별자는 실제 데이터와 가짜 데이터를 정확히 구분하기 위한 목적을 가진다. 이러한 목적의 구현을 위하여 GAN에서는 일반적으로 식 (1)과 같은 크로스 엔트로피 가치함수(Cross entropy Value function)를 활용한다. 이러한 가치함수는 판별자의 구별이 양호하다면 1로, 양호하지 않다면 0으로 나타내도록 구성되어 있다. 먼저 어떠한 데이터가 입력되게 되면, 판별자의 입장에서는 입력 데이터가 실제 데이터로 판별될 수 있는지를 검토한다. 이 때, 입력 데이터가 실제 데이터라면 판별자는 1이라는 라벨을 내놓게 된다. 판별자의 입장에서는 실제 데이터가 입력 값으로 들어왔을 때, 가장 높은 가치를 보이는 것이므로 1에 가깝게 최대화 되도록 판별자가 학습되게 된다. 반대로 생성자의 입장에서는 실제 데이터와 가장 가까운 데이터를 만들어 낸 뒤 판별자가 실제 데이터라고 착각을 일으킬 수 있도록 하는 것을 목적으로 한다. 만약 만들어낸 데이터에 대해 판별자가 실제 데이터라고 판정한다면, 판별자는 큰 오류를 범하게 되므로 가치함수는 생성자를 최소화하여 0에 수렴하도록 한다.

즉, 판별자는 binary classification에 최적화하는 형태로 학습

하게 되고 입력데이터로는 실제 데이터와 생성자로 만들어진 가짜 데이터 모두가 이용되며, 상반된 목적을 가진 판별자와 생성자의 대립관계를 통해 학습이 진행되게 된다.

$$\min_{D, G} \max V(D, G) = E_{x \sim P_{\text{data}}(x)}[\log D(x)] + E_{z \sim P_z(z)}[\log(1 - D(G(z)))] \quad (1)$$

이 때, V 는 가치함수,
 G 는 GAN 모델의 생성자,
 D 는 GAN 모델의 판별자,
 x 는 데이터들의 샘플,
 z 는 생성된 랜덤 넘버

이후, 판별자는 역전파 과정을 통해 가치함수로부터 계산된 에러를 판별자와 생성자에 분배하게 된다. 이 때, 생성자는 해당 에러를 생성자의 가중치에 적절하게 분배하여 생성자의 성능을 조정하는 가중치들을 학습하게 된다. 이러한 학습은 생성자가 만든 가짜 데이터가 판별자의 입력 데이터로 활용될 때, 판별자의 출력값이 1이 되도록 하는 목적을 가진다. 즉, 생성자의 목적은 생성된 가짜데이터가 실제 데이터와 최대한 비슷할 수 있도록 하는데 목적을 두고 있다. 이 때, 생성자의 입력 값으로는 일반적으로는 랜덤하게 추출된 난수들로 구성된 벡터들로 구성하게 된다. 이는 랜덤하게 추출된 난수들을 통해 다양한 입력 값을 만들어내기 위함이며, 이를 통해 다양한 출력 값을 나타내도록 학습하게 된다.

3.2 가속도 데이터 생성을 위한 GAN 알고리즘

이러한 GAN의 기본적인 구동 방식을 기초로 하여 본 연구에서 사용하고자 하는 GAN의 학습 순서를 그림 2와 같이 pseudo code로 나타내었다. 먼저 시뮬레이션을 통해 소량의 가속도 데이터를 생성한 뒤, GAN의 생성자와 판별자 아키텍처(architecture)를 각각 정의한다. 또한 이를 학습하기 위한 하이퍼파라미터(hyperparameter)들을 정의 한 뒤 정의된 하이퍼파라미터를 활용하여 판별자와 생성자 순으로 학습을 수행한다. 본 연구에서는 1 epoch 당 생성된 데이터의 수만큼 판별자와 생성자를 학습하고자 하였다. epoch는 모든 트레이닝 데이터가 한번 학습되는 것을 의미한다. 판별자의 학습에는 가속도 데이터와 생성자로 만든 가속도 데이터가 순차적으로 학습되도록 하였다. 생성자와 판별자의 학습에 활용되는 랜덤한 숫자의 벡터는 매 학습마다 생성되도록 하였다.

이러한 과정을 통해 생성자와 판별자는 대립적으로 학습하게 되고 생성자는 가속도 데이터를 생성할 수 있도록 학습하게 된다.

4. 기초 가속도 데이터생성을 위한 시뮬레이션 PSC-I교 모델링

샘플링된 각각의 가속도 데이터를 비교 분석하기 위해선 먼저 가속도 데이터를 생성하는 것이 필수적이다. 따라서 본 연구에서는 먼저 가속도 데이터를 생성하기 위한 시뮬레이션 모델을 제작하고자 하였다.

```

Select the sample of acceleration data x
Define architecture: generator G, discriminator D
Initialize hyperparameters for G and D : epoch, learning rate, size of layers and etc.
FOR number of epoch
  Shuffle order of x
  FOR i in number of x
    Train the D with xi and hyperparameters for D
    Generating random number vector z~p(z)
    Train the D with output of G(z) and hyperparameters for D
  ENDFOR
  FOR j in number of x
    Generating random number vector z~p(z)
    Train the G with output of D(G(z)) and hyperparameters for G
  ENDFOR
ENDFOR

```

Figure 2. Algorithm for the proposed generative adversarial network to generate acceleration data

4.1 PSC-I교 모델링

MOLIT(2018)의 교량 현황조사에 따르면 국내 일반국도에 위치한 교량의 상부구조 형식 중 가장 많은 비율을 차지하고 있는 교량 형식은 PSC-I교 이다. 또한 교량의 길이 또한 60m 이하의 중소형 교량이 대다수를 차지하고 있음을 확인할 수 있다. 이에 따라 본 연구에서는 30m 길이의 PSC-I 교량을 MIDAS CIVIL 구조해석 프로그램을 통해 모델링하고자 하였다. 모델링된 교량은 figure 3와 같다. figure 3에서 볼 수 있듯이, 모델링된 교량은 7개의 I형 거더를 가지며, 제원은 길이 29,317.6m, 폭 15m의 크기로 정의하였다. 또한 상부 슬래브에 4차로의 차로를 가지도록 설계하여 시뮬레이션 시 최대 각 차로별 1대씩, 최대 4대의 차량이 교량을 지나갈 수 있도록 설계하였다. PSC-I 교량이 4차로를 가질 수 있도록 설계하였다. 각 차로의 주행방향은 1, 2차로는 상행, 3, 4차로는 하행으로 주행할 수 있도록 구성하였다.

본 연구에서는 실제 차량이 지나가는 것 같은 시뮬레이션을 통해 가속도를 생성하고자 하였다. 따라서 본 연구에서는 figure 3에서 보이는 화살표를 따라 움직이는 점하중을 모사하여 가속도 생성을 위한 시뮬레이션을 진행하도록 계획하였다. 재하된 하중의 크기는 15kN으로 재하되도록 하였으며 해당 하중의 크기는 실제 상용화된 여러 중형차들의 공차중량 평균인 15kN으로 설정하였다.

4.2 다중하중상황을 모사한 기초 가속도 데이터

앞서 생성된 PSC-I 모델을 기반을 두어, 본 연구에서는 실제




Figure 3. PSC-I model for simulation and the position of the accelerometer

와 비슷하게, 다중 차량 하중 시나리오를 적용하여 시뮬레이션하고자 하였으며, 이를 통해 GAN 학습에 사용될 수 있는 가속도 데이터를 생성하고자 하였다. 하지만 이러한 가속도 데이터 생성을 위해서는 수많은 시뮬레이션을 진행해야 한다는 단점이 있으며, 각각의 시뮬레이션은 개별 구조해석을 의미하므로 수많은 시간이 든다는 한계가 있다. 이때 PSC-I 모델의 선형적 특성을 이용하게 되면 적은 시간으로도 원하는 데이터를 생성할 수 있다는 장점이 있다. PSC-I교 모델링의 선형적 특성이란 각각 두 개의 하중이 개별로 작용하여 생성된 두 개의 가속도 데이터는 두 개의 하중이 동시에 작용하여 생성된 가속도 데이터와 같다는 것을 말한다. 즉, 상대적으로 시간이 적게 소요되는 단일 차량 하중의 가속도 데이터를 이용하면 다중 차량 하중의 가속도를 생성하는 것이 가능하다. 본 연구에서는 이러한 시뮬레이션 데이터의 선형적 특성을 활용하여 단일 차량 하중의 가속도를 이용해 다중 차량 하중의 가속도 데이터를 생성하였다. Midas를 통해 생성된 단일 차량 하중의 가속도 데이터는 1,000Hz의 데이터이며, 각각 차량하중은 figure 3에서 보는 것처럼 4개의 레인에 출현할 수 있도록 하였다. 또한 차량하중이 적용되는 위치는 각 레인의 중앙부를 지나는 이동하중으로 사용하였다. 이동하는 차량의 속도는 총

15개의 속도로 각각 20, 25, 30, 35, 40, 45, 50, 55, 60, 65, 70, 75, 80, 85, 90 km/h의 속도를 가지도록 설정하였다.

일반적으로 주파수가 높은 가속도 데이터의 경우는 low-pass filter를 적용하여 잡음을 없애는 것이 일반적이다. 본 연구에선 이러한 잡음을 없애기 위해서, 파이썬(python) 'Scipy' 라이브러리의 signal 클래스에서 제공하고 있는 decimate 함수를 이용하였다. 이용된 decimate 함수는 8차 Chebyshev type I filter를 기본으로 사용하여 가속도 데이터의 앨리어싱(aliasing) 현상을 방지하며, 주파수를 줄임과 동시에 가속도 데이터의 숫자 또한 줄여줄 수 있다. 이를 통해 딥러닝 모델 학습의 효율을 높일 수 있으므로, 본 연구에서는 1,000Hz 데이터를 70Hz로 다운샘플링하여 활용하였다. 다운샘플링 된 단일 차량 하중의 가속도 데이터는 시간을 달리 하여 더해짐으로써 다중 차량의 하중을 모사하였다. 다중하중상황을 모사한 가속도 데이터는 약 17분의 길이를 가진 데이터로 생성하였다. 시뮬레이션을 통해 얻어진 가속도 데이터는 각각 2초간의 길이를 가진 시계열 데이터로 구성할 수 있도록 데이터를 나누었으며, 이를 통해 총 500개의 데이터로 나누어 GAN 모델의 학습에 이용하였다. figure 4는 500개의 가속도 데이터의 예를 보여준다.




Figure 4. Sample of acceleration data for training the generative adversarial network

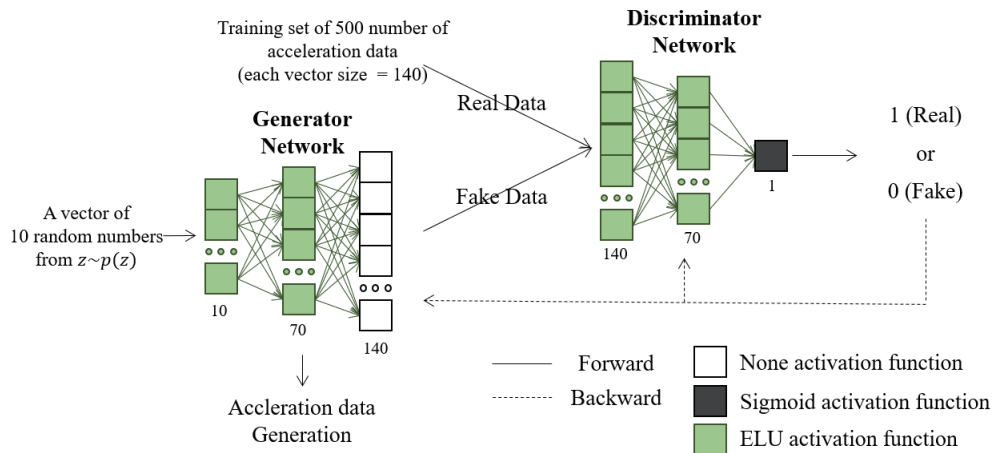


Figure 5. Architecture of the proposed generative adversarial network for generating acceleration data

5. GAN을 통해 생성된 가속도 데이터 비교


본 연구에서는 앞서 구성된 모델링을 통해 얻은 실제 가속도 데이터와 GAN을 통해 얻은 가속도 데이터의 비교 분석을 진행하였다. 각각의 데이터의 비교분석을 위해 신호가 가진 주파수 영역을 분석할 수 있는 FFT 분석을 활용하고자 하였다.

GAN의 학습은 figure 5와 같은 아키텍처를 기반으로 진행되었다. 먼저 GAN 아키텍처의 학습에 사용된 하이퍼파라미터로, 생성자와 판별자는 모두 각각 2개의 은닉층(hidden layer)을 갖도록 설계하였다. 각각의 은닉층은 Exponential Linear Unit 활성화 함수(activation function)를 가지도록 하였으며, 0과 1로 데이터를 구분하기 위한 판별자의 마지막 층에만 시그모이드(sigmoid) 활성화 함수를 이용하였다. 또한 생성자의 마지막 층의 output 데이터는 활성화 함수의 영향을 받지 않도록 설계하였다. gradient method로는 Adam 최적화 기법을 사용하였으며, Adam 최적화 기법의 학습률(learning rate)로는 0.001을 사용하였다. mini-batch의 크기는 따로 설정하지 않고 1로 유지하여 학습을 진행하였다. 또한 모든 학습과정은 파이선 기반, pytorch 딥러닝 라이브러리를 활용하였다. 학습에 이용된 환경은 Intel i7-8700K CPU, 32GB 램, 두 개의 NVIDIA GTX-1080Ti 그래픽 카드로 구성하였다.


학습이 완료된 후, 시뮬레이션을 통해 생성된 데이터의 개형과 FFT결과와 앞서 구성한 아키텍처와 하이퍼파라미터를 기반으로 학습된 GAN 모델의 결과를 figure 6을 통해 비교하였다. GAN

의 생성자는 대체적으로 50-100 epoch 사이에 수렴되는 결과를 보였으며, 학습이 너무 많이 진행될 경우 epoch에 따라 생성하는 생성자가 하나의 결과값에 과적합 되는 경향을 보였다. 따라서 본 연구에서는 50-100 epoch 학습이 진행된 GAN 모델의 생성자가 생성하는 가속도 데이터들을 figure 6b와 같이 나타내었다. 이후, GAN을 통해 생성된 데이터가 실제 구조해석을 통해 얻은 데이터와 유사한 양상을 가지고 있는지를 파악하고자 하였다. 먼저 그림 6a에서 볼 수 있듯이 구조해석을 통해 얻은 데이터를 이용하여 실제 가속도 데이터의 FFT 분석 결과를 도출하였다. 시뮬레이션을 통해 얻은 대다수의 가속도 데이터는 figure 6a에서 볼 수 있듯이 진폭(amplitude)이 최대 -20 ~ 20, 작을 경우 -5 ~ 5 으로 분포하는 것을 볼 수 있다. 또한 FFT 분석결과를 살펴보면 모든 그래프에서 첨두값(peak value)이 16Hz 주변에서 나타남을 확인하였다. FFT 그래프에서 가장 중요한 요소는 첨두값이 나타난 위치의 주파수이며, 첨두값은 해당 가속도 데이터의 성질을 나타낼 수 있는 고유치로 해석될 수 있다.

figure 6b는 GAN을 통해 생성한 가속도 데이터들의 예를 보여준다. GAN을 통해 생성한 가속도 데이터 역시 실제 가속도 데이터가 보이는 모습과 비슷한 수준의 진폭의 분포를 가지고 있음을 확인할 수 있다. 또한 해당 데이터의 FFT 분석 결과를 살펴보면 때도, 주파수가 16Hz 혹은 그 주변에서 첨두값을 보이는 것을 확인할 수 있었다. 이러한 결과를 종합하여 볼 때, GAN을 통하여 생성된 가속도 데이터가 구조해석 시뮬레이션을 통해 얻어진 가속도 데이터와 비슷한 경향을 가지고 있음을 확인할 수 있었다.



(a) Examples of acceleration data from simulation and corresponding FFT analysis results



(b) Examples of acceleration data from generative adversarial network and corresponding FFT analysis results

Figure 6. Comparisons between acceleration data from simulation and acceleration data from generative adversarial network

또한 GAN 학습 시에는 구조물 모델링의 고유진동수와 모드형상 등의 정보를 주지 않았음에도 불구하고, FFT 분석 결과가 비슷한 패턴을 나타내는 데이터의 생성이 가능하다는 것을 보아 GAN 모델이 스스로 가속도 데이터의 거시적 패턴뿐만 아니라 가속도 데이터가 가지고 있는 특성까지 스스로 학습 할 수 있는 것으로 판단된다. 다시 말해, GAN 모델은 복잡한 가속도 데이터에 대하여 패턴 분석에 충분한 성능을 보여주고 있고 이를 바탕으로 복잡한 가속도 데이터를 모사해내는 능력이 있음을 확인하였다. 이러한 결과를 종합하여 볼 때, 소량의 데이터를 통해 학습된 GAN 모델을 이용하게 되면 이와 비슷한 패턴의 데이터를 얻어낼 수 있을 것으로 판단된다.

한편 앞서 서술하였듯이, 디지털 트윈 기반 유지관리를 위해선 손상추정기법의 높은 정확도를 보유하는 것이 필요하다. 특히 딥러닝 기반의 손상추정기법은 높은 정확도를 보여주고 있어 그 활용성이 많이 증명되어왔다. 이러한 딥러닝 기반 손상추정기법은 많은 데이터가 필요하다는 문제가 있으므로, 많은 데이터를 만들어 낼 수 있는 방법론의 적용이 필요하다. 이 때, 본 연구에서 제안하는 GAN 기반 가속도 데이터 생성 모델을 활용하게 된다면 딥러닝 기반 손상추정기법의 정확도를 향상시킬 수 있을 것으로 예상된다.

6. 결론

70년대 급속한 경제 성장과 함께 많은 사회간접자본시설이 건설되었다. 2019년 현재, 이러한 사회간접자본시설들은 노후화되었고 이로 인해 여러 문제가 발견됨에 따라 노후화된 구조물의 유지관리가 사회적으로 주목을 받고 있다. 노후화 구조물의 유지관리는 디지털 트윈의 도입과 함께 효율적으로 수행될 수 있으며, 이러한 디지털 트윈 기반의 구조물 유지관리를 위해선 구조물의 정확한 손상추정이 필요하다. 구조물의 손상추정을 위해선 구조물 건전도 모니터링 기법이 이용될 수 있으며, 최근 딥러닝의 성장과 함께 딥러닝 기반 손상 추정기법이 좋은 성능을 발휘하고 있다. 한편 이러한 딥러닝 기반 손상추정기법의 개발을 위해서는 손상 전, 후의 수많은 데이터를 통한 학습이 필요하나, 실제 현장에서는 손상 전의 데이터양이 손상 후의 데이터양보다 많아 데이터양의 불균형 문제가 존재한다. 이러한 문제를 해결하기 위해 본 연구에서는 손상추정에 주로 사용되는 가속도 데이터를 학습하여 이와 비슷한 데이터를 생성해낼 수 있는 GAN 기반 생성모델을 제시하였다.

GAN 기반 생성모델은 시뮬레이션을 통해 생성된 가속도 데이터를 통해 학습되었으며, 학습이 완료된 이후 GAN 기반 생성모델의 데이터 생성능력이 평가되었다. 시뮬레이션 모델을 위해 선택된 교량은 30m 경간의 PSC-교를 이용하였다. GAN을 통해

생성된 가속도 데이터는 시뮬레이션을 통해 생성된 가속도와 매우 유사한 패턴을 가지고 있음을 확인하였으며, 거시적 데이터의 패턴 뿐 아니라 가속도 데이터가 가진 주파수의 분포까지 재현해 낼 수 있음을 확인하였다. 이는 GAN 모델이 스스로 복잡한 가속도 데이터를 분석할 수 있다는 것을 보여주는 결과이며, 이러한 데이터를 통해 딥러닝 기반 손상추정기법의 학습에 도움을 줄 수 있다고 판단된다.

한편 본 연구에서 생성한 데이터를 딥러닝 기반 손상추정기법의 학습데이터로서 이용해보지는 않았다는 한계가 존재한다. 특히 실제 가속도 데이터는 가속도계가 가진 기계오차, 환경의 변화에 따른 다양한 오차 등이 학습을 방해하는 요소로 작용할 수 있다. 따라서 향후 연구에서는 이러한 요소들을 고려한 GAN 모델의 개발이 필요할 것으로 판단된다. 또한 GAN 모델을 통해 생성된 데이터를 실제 데이터와 함께 학습할 때, 실제 데이터만 학습하는 것 보다 향상된 성능을 보일 수 있는지에 대한 분석이 필요하며, 학습에 필요한 적절한 생성 데이터의 양을 결정하는 것도 또한 향후 연구로서 필요할 것으로 판단된다. 따라서 본 연구진은 이러한 연구의 수행을 계획 중에 있다. 본 연구가 후속 연구의 기초 연구로서 활용되어 궁극적으로 유지관리를 위한 디지털 트윈 활용에 이용될 수 있기를 기대한다.

감사의 글

본 연구는 국토교통부 국토교통기술촉진연구사업의 연구비지원(18CTAP-C117271-03)에 의해 수행되었습니다.

References

- Abdeljaber, O., Avci, O., Kiranyaz, S., Gabbouj, M., Inman, D. J. (2017). Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks. *Journal of Sound and Vibration*, 388, pp. 154-170.
- Banerjee, S., Qing, X. P., Beard, S., Chang, F. K. (2010). Prediction of progressive damage state at the hot spots using statistical estimation. *Journal of Intelligent Material Systems and Structures*, 21(6), pp. 595-605.
- Bruno, B., Mastrogiovanni, F., Sgorbissa, A., Vernazza, T., Zaccaria, R. (2013). Analysis of human behavior recognition algorithms based on acceleration data. In 2013 IEEE International Conference on Robotics and Automation, pp. 1602-1607.

- Deng, L., Hinton, G., Kingsbury, B. (2013). New types of deep neural network learning for speech recognition and related applications: An overview. In 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 8599–8603.
- Glowacz, A., Glowacz, W., Glowacz, Z., Kozik, J. (2018). Early fault diagnosis of bearing and stator faults of the single-phase induction motor using acoustic signals. *Measurement*, 113, pp. 1–9.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Bengio, Y. (2014). Generative adversarial nets. In *Advances in neural information processing systems*, pp. 2672–2680.
- Hakim, S. J. S., Razak, H. A., Ravanfar, S. A. (2015). Fault diagnosis on beam-like structures from modal parameters using artificial neural networks. *Measurement*, 76, pp. 45–61.
- Hou, Z., Noori, M., Amand, R. S. (2000). Wavelet-based approach for structural damage detection. *Journal of Engineering mechanics*, 126(7), pp. 677–683.
- Kullaa, J. (2014). Structural health monitoring under nonlinear environmental or operational influences. *Shock and Vibration*, 2014, pp. 1–9.
- Lee, Y. (2015). A Study of Improvement and Longevity of the Aging Urban Infrastructure in Korea. *Journal of the Korean Society of Civil Engineers*, 63(11), pp. 10–19.
- Lee, K., Park, J., Jung, M., Shin, D. (2018) Methodology for the damage detection of aging bridges based on multi-data and deep learning. *Proceedings of the 7th world conference on structural control and monitoring (7WCSCM)*, pp. 1725–1731.
- Lin, Y. Z., Nie, Z. H., Ma, H. W. (2017). Structural damage detection with automatic feature extraction through deep learning. *Computer Aided Civil and Infrastructure Engineering*, 32(12), pp. 1025–1046.
- Mao, X., Li, Q., Xie, H., Lau, R. Y., Wang, Z., Paul Smolley, S. (2017). Least squares generative adversarial networks. In *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2794–2802.
- Mayorga, P., Druzgalski, C., Morelos, R. L., Gonzalez, O. H., Vidales, J. (2010). Acoustics based assessment of respiratory diseases using GMM classification. In 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology, pp. 6312–6316.
- Mehrjoo, M., Khaji, N., Moharrami, H., Bahreininejad, A. (2008). Damage detection of truss bridge joints using Artificial Neural Networks. *Expert Systems with Applications*, 35(3), pp. 1122–1131.
- MOLIT (Ministry of Land, Infrastructure and Transport). (2018) *Yearbook of Road Bridge and Tunnel Statistics*.
- Nair, K. K., Kiremidjian, A. S. (2007). Time series based structural damage detection algorithm using Gaussian mixtures modeling. *Journal of dynamic systems, measurement, and control*, 129(3), pp. 285–293.
- Noh, H. Y., Krishnan Nair, K., Lignos, D. G., Kiremidjian, A. S. (2011). Use of wavelet-based damage-sensitive features for structural damage diagnosis using strong motion data. *Journal of Structural Engineering*, 137(10), pp. 1215–1228.
- Oh, B. K., Kim, D., Park, H. S. (2017). Modal Response Based Visual System Identification and Model Updating Methods for Building Structures. *Computer Aided Civil and Infrastructure Engineering*, 32(1), pp. 34–56.
- Padil, K. H., Bakhary, N., Hao, H. (2017). The use of a non-probabilistic artificial neural network to consider uncertainties in vibration-based-damage detection. *Mechanical Systems and Signal Processing*, 83, pp.194–209.
- Park, J. H., Kim, J. T., Hong, D. S., Ho, D. D., Yi, J. H. (2009). Sequential damage detection approaches for beams using time-modal features and artificial neural networks. *Journal of Sound and Vibration*, 323(1–2), pp. 451–474.
- Park, K. Y., Kim, H. S. (2000). Narrowband to wideband conversion of speech using GMM based transformation. In 2000 IEEE International Conference on Acoustics, Speech, and Signal Processing. *Proceedings*, 3, pp. 1843–1846.
- Pascual, S., Bonafonte, A., Serrà, J. (2017). SEGAN: Speech enhancement generative adversarial network. *arXiv preprint arXiv:1703.09452*.
- Pnevmatikos, N. G., Hatzigeorgiou, G. D. (2017). Damage detection of framed structures subjected to earthquake excitation using discrete wavelet analysis. *Bulletin of Earthquake Engineering*, 15(1), pp. 227–248.
- Radford, A., Metz, L., Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.

Soman, R., Kyriakides, M., Onoufriou, T., Ostachowicz, W. (2018). Numerical evaluation of multi-metric data fusion based structural health monitoring of long span bridge structures. *Structure and Infrastructure Engineering*, 14(6), pp. 673–684.

Wakita, T., Ozawa, K., Miyajima, C., Igarashi, K., Itou, K., Takeda, K., Itakura, F. (2006). Driver identification using driving behavior signals. *IEICE TRANSACTIONS on Information and Systems*, 89(3), pp. 1188–1194.

Yang, L. C., Chou, S. Y., Yang, Y. H. (2017). MidiNet: A convolutional generative adversarial network for symbolic-domain music generation, arXiv preprint arXiv:1703.10847.