

그라운드-롤 제거를 위한 CNN과 GAN 기반 딥러닝 모델 비교 분석

조상인 · 편석준*

인하대학교 에너지자원공학과

Comparison of CNN and GAN-based Deep Learning Models for Ground Roll Suppression

Sangin Cho and Sukjoon Pyun*

Department of Energy Resources Engineering, Inha University

요약

그라운드-롤(ground roll)은 육상 탄성파 탐사 자료에서 가장 흔하게 나타나는 일관성 잡음(coherent noise)이며 탐사를 통해 얻고자 하는 반사 이벤트 신호보다 훨씬 큰 진폭을 가지고 있다. 따라서 탄성파 자료 처리에서 그라운드-롤 제거는 매우 중요하고 필수적인 과정이다. 그라운드-롤 제거를 위해 주파수-파수 필터링, 커브릿(curvelet) 변환 등 여러 제거 기술이 개발되어 왔으나 제거 성능과 효율성을 개선하기 위한 방법에 대한 수요는 여전히 존재한다. 최근에는 영상처리 분야에서 개발된 딥러닝 기법들을 활용하여 탄성파 자료의 그라운드-롤을 제거하고자 하는 연구도 다양하게 수행되고 있다. 이 논문에서는 그라운드-롤 제거를 위해 CNN (convolutional neural network) 또는 cGAN (conditional generative adversarial network)을 기반으로 하는 세가지 모델(DnCNN (De-noiseCNN), pix2pix, CycleGAN)을 적용한 연구들을 소개하고 수치 예제를 통해 상세히 설명하였다. 알고리즘 비교를 위해 동일한 현장에서 취득한 송신원 모음을 훈련 자료와 테스트 자료로 나누어 모델을 학습하고, 모델 성능을 평가하였다. 이러한 딥러닝 모델은 현장자료를 사용하여 훈련할 때, 그라운드-롤이 제거된 자료가 필요하므로 주파수-파수 필터링으로 그라운드-롤을 제거하여 정답자료로 사용하였다. 딥러닝 모델의 성능 평가 및 훈련 결과 비교는 정답 자료와의 유사성을 기본으로 상관계수와 SSIM (structural similarity index measure)과 같은 정량적 지표를 활용하였다. 결과적으로 DnCNN 모델이 가장 좋은 성능을 보였으며, 다른 모델들도 그라운드-롤 제거에 활용될 수 있음을 확인하였다.

주요어

그라운드-롤 제거, 합성곱 신경망, 순환 적대적 생성 신경망, pix2pix

ABSTRACT

The ground roll is the most common coherent noise in land seismic data and has an amplitude much larger than the reflection event we usually want to obtain. Therefore, ground roll suppression is a crucial step in seismic data processing. Several techniques, such as f-k filtering and curvelet transform, have been developed to suppress the ground roll. However, the existing methods still require improvements in suppression performance and efficiency. Various studies on the suppression of ground roll in seismic data have recently been conducted using deep learning methods developed for image processing. In this paper, we introduce three models (DnCNN (De-noiseCNN), pix2pix, and CycleGAN), based on convolutional neural network (CNN) or conditional generative adversarial network (cGAN), for ground roll suppression and explain them in detail through numerical examples. Common shot gathers from the same field were divided into training and test datasets to compare the algorithms. We trained the models using the training data and evaluated their performances using the test data. When training these models with field data, ground roll removed data are required; therefore, the ground roll is suppressed by f-k filtering and used as the ground-truth data. To evaluate the performance of the deep learning models and compare the training results, we utilized quantitative indicators such as the correlation coefficient and structural similarity index measure (SSIM) based on the similarity to the ground-truth data. The DnCNN model exhibited the best performance, and we confirmed that other models could also be applied to suppress the ground roll.

Received: 27 February 2023; Revised: 28 April 2023; Accepted: 7 May 2023

*Corresponding author

E-mail: pyunsj@inha.ac.kr

Address: Department of Energy Resources Engineering, Inha University, 100 Inharo, Michuhol-gu, Incheon 22212, Korea

©2023, Korean Society of Earth and Exploration Geophysicists

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

KEYWORDS

Ground roll attenuation, CNN, CycleGAN, pix2pix

서 론

그라운드 롤(Ground roll)은 표면파 중 레일리 파(Rayleigh wave)가 불균질 매질에서 분산(dispersion) 특성을 갖고 나타나는 이벤트이며, 육상 탄성과 탐사 자료에서 가장 흔하게 나타나는 일관성 잡음(coherent noise)이다. 탄성과 송신원 모음에서 그라운드-롤은 상대적으로 작은 진폭을 가지고 있는 반사 이벤트를 왜곡하고(Naghizadeh and Sacchi, 2018), 종종 공간 알리아싱(spatial aliasing)을 유발하여 근거리 천부 반사신호와 원거리 심부 반사신호의 해석을 방해한다(Pham and Li, 2022). 자료취득 과정에서 그룹 수신기를 사용하여 그라운드-롤 에너지를 제한할 수 있으나 탐사 비용이 높아지므로 효율적인 방법은 아니다. 따라서 탄성과 자료의 정확한 해석을 위해 반사법 자료 처리 과정에서의 그라운드-롤 억제는 중요하고 필수적이다.

그라운드-롤은 다른 탄성과 신호들에 비해 낮은 속도 범위와 저주파수 대역, 큰 진폭을 갖는다는 특징이 있다. 이러한 표면파 특성에서 비롯된 이벤트 기울기(dip)와 주파수 성분 차이가 그라운드-롤을 제거할 때 사용하는 주된 특징이다. 이러한 특징을 이용하여 그라운드-롤을 제거하는 기법으로는 고주파 통과 필터링(Embree *et al.*, 1963), 띠 통과 필터링(Treitel *et al.*, 1967), 주파수-파수 필터링(Yilmaz, 2001) 등이 있다. 또한, 그라운드-롤이 선형 이벤트인데 비해 반사 신호는 쌍곡선 이벤트로 나타난다는 특성을 활용하여 파동장을 분리하는 접근법을 사용할 수 있다. 이러한 방식으로는 카루넨-루베(Karhunen-Loève) 변환(Liu, 1999), 파형요소(wavelet) 변환(Deighan and Watts, 1997), 라돈(Radon) 변환(Russell *et al.*, 1990a, 1990b), 커브릿(curvelet) 변환(Yarham *et al.*, 2006) 등의 기법들이 개발되었다.

주파수 필터링을 기반으로 하는 방법들은 저주파수 성분의 반사 신호와 그라운드-롤을 완벽하게 구분하기 어려워 반사신호에 심한 왜곡이 생길 수 있고, 표면파의 공간 알리아싱을 제거하지 못한다는 단점이 있다(Serdyukov, 2022). 이를 해결하기 위한 여러 변환 기반 기법들은 적절한 매개변수 조합을 선정할 때 많은 시행착오가 필요하기 때문에 그 과정이 복잡하고 많은 시간이 소요된다. 이러한 단점들을 해결하기 위해 다양한 기계학습 기법들이 그라운드-롤 제거에 적용되었다. Jia *et al.* (2018)은 합성곱 신경망(convolutional neural network, CNN) 구조를 이용하여 공통 송신원 모음(common shot gather, CSG)에서 반사신호와 그라운드-롤을 분리했고, Li *et al.* (2018)은 그라운드-롤을 제거하기 위한 목적으로 CNN에서 발전된 De-noise CNN 구조를 적용하였다. 적대적 생성 신경

망(generative adversarial network, GAN)을 그라운드-롤 제거에 적용하려는 연구도 수행되었는데, CycleGAN을 이용한 연구(Kaur *et al.*, 2019)와 pix2pix 모델을 적용한 연구(Yuan *et al.*, 2020) 등이 대표적이다. 최근에는 비지도 학습을 기반으로 탄성과 탐사 자료에서 그라운드-롤을 제거하고자 하는 연구들도 수행되고 있다. 비지도 학습을 적용하여 공통 송신원 모음을 반사신호와 그라운드-롤이 포함된 나머지 부분으로 분리하는데 기계학습이 사용되거나(Guo *et al.*, 2020), 이 영역 분리 과정에서 낮은 주파수 범위 등 그라운드-롤이 가지는 주요 특성들과 관련한 두 개의 딥러닝 블록을 추가하여 성능을 개선하고자 하는 연구가 수행된 바 있다(Pham and Li, 2022).

이 논문에서는 탄성과 자료의 그라운드-롤 제거를 위한 대표적인 딥러닝 모델로서 DnCNN (Zhang *et al.*, 2017), pix2pix (Isola *et al.*, 2017), CycleGAN (Zhu *et al.*, 2017)의 특징을 소개하고, 각 모델이 그라운드-롤 제거에 적용되는 절차를 기술한다. 또한, 각 딥러닝 모델의 성능을 비교하기 위해 동일한 탄성과 자료를 사용하여 그라운드-롤 제거 기법을 구현해 본다. 정량적 비교를 위해 몇 가지 성능 지표와 평가 방법을 제시하고 3가지 모델의 성능을 비교함으로써 그라운드-롤 제거에 효과적인 딥러닝 모델에 대해 논의한다.

이 론

기계학습은 훈련방식에 따라 지도학습(supervised learning), 비지도학습(unsupervised learning), 준지도 학습(semi-supervised learning), 강화학습(reinforcement learning)으로 구분할 수 있다. 이 중 지도학습은 입력 자료와 예측(또는 추론)하고자 하는 자료, 즉 정답(ground truth)에 해당하는 라벨(label)이 필요하다(Choi *et al.*, 2020). 기계학습 훈련은 모델을 구성하는 매개변수(parameter)가 손실함수(loss function)를 감소시키는 방향으로 업데이트되고 이 과정을 반복하는 방식으로 진행된다. 일반적으로 훈련에 사용되는 모델이 신경망 구조이고 은닉층의 개수가 많은 깊은 신경망인 경우 딥러닝 모델이라고 부른다. DnCNN의 기반이 되는 CNN 구조는 대표적인 딥러닝 모델로서 라벨링된 훈련자료를 이용하여 지도학습 형태로 사용될 수 있다. pix2pix와 CycleGAN의 기초가 되는 조건부 적대적 생성 신경망(conditional GAN, cGAN)은 비지도학습으로 분류하기는 하지만 생성하고자 하는 자료에 관련한 추가 정보(extra information)가 훈련에 필요하다. 따라서 DnCNN, pix2pix, CycleGAN 모델을 그라운드-롤 제거에 적용하기 위해서는 사전에 그라운드-롤을 제거한 탄성과 자료가 필요하다.

CNN은 시각 피질에서 영상(image)을 인식하는 원리를 모방

하여 개발된 딥러닝 모델로 복잡한 영상 처리 문제에 좋은 성능을 보인다(Géron, 2017). 일반적으로 CNN 모델은 컨볼루션층(convolutional layer), 풀링층(pooling layer), 완전 연결층(fully-connected layer)의 3 가지 종류로 구성되어 있는데, 일반적인 신경망과 달리 컨볼루션 연산으로 훈련이 진행되기 때문에 모델을 더 깊게 구성할 수 있다. 따라서 훈련이 용이한 CNN 모델의 깊은 구조는 매우 복잡한 비선형적 관계를 구현할 수 있다. 풀링층은 입력 영상의 서브 샘플링을 통해 자료의 크기를 줄이는 과정이며 계산량과 메모리 사용량을 줄이고 파라미터 수를 조절하여 과대적합의 위험을 줄일 수 있다(Géron, 2017). 마지막으로 완전 연결층은 앞선 층 등에서 추출된 특성들이 최종 출력에 반영되도록 하는 역할을 한다.

GAN은 Goodfellow *et al.* (2014)에 의해 처음으로 제안되었다. 일반적으로 하나의 신경망을 훈련하는 기존 기법과 달리 GAN은 생성자(generator)와 판별자(discriminator)라 불리는 두 개의 심층 신경망을 사용한다. 생성자 신경망은 무작위 벡터를 입력 받아 실제 자료와 유사한 합성 영상을 출력하는 한편, 판별자 신경망은 생성자 신경망이 만들어낸 영상이 입력으로 들어왔을 때 이를 가짜라고 판단하거나 실제 자료가 들어오면 진짜라고 판별하는 역할을 한다. 생성자 신경망은 판별자 신경망을 더 잘 속일 수 있도록, 판별자 신경망은 생성된 영상과 실제 영상을 더 잘 구분하도록 훈련되고, 그 결과 무작위 잡음으로부터 실제 자료와 가까운 자료를 생성할 수 있다(Jo *et al.*, 2020). GAN의 훈련 과정은 이론적으로 생성자와 판별자의 경쟁 학습으로 실제 데이터와 생성 데이터의 분포 차이가 최소화되도록 진행된다. 이러한 과정은 아래의 식으로 표현된다.

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

여기서 V 는 손실함수이고, G 는 생성자 신경망, D 는 판별자 신경망, x 는 실제 데이터 샘플을 나타내는 변수, z 는 무작위 벡터이다. E 는 확률변수 또는 확률변수의 함수에 대한 기댓값을 의미하고, 아래첨자 $x \sim P_{data}(x)$ 는 실제 자료에 대한 확률 분포에서 추출한 샘플, $z \sim P_z(z)$ 는 무작위 확률 분포에서 추출한 무작위 벡터를 의미한다.

De-noise CNN

Zhang *et al.* (2017)은 영상에서의 잡음 제거를 위해 잡음이 제거된 영상이 아닌 잔차 영상(residual image)을 예측하는 심층 합성곱 신경망 구조(DnCNN)를 제안하였다(Fig. 1). 그들은 CNN 기반으로 영상의 잡음을 제거할 때 잔차 학습(residual learning)과 배치 정규화(batch normalization)를 사용하면 빠르고 안정적인 훈련을 수행할 수 있고, 잡음 제거 성능이 매우 높아지는 것을 확인하였다. 잔차 학습은 신경망 구조가 깊어질수록 훈련 정확도가 감소하는 성능 저하(performance degradation) 문제를 해결하기 위해 He *et al.* (2016)이 제안한 기법이다. 다만 DnCNN 구조에서는 여러 개의 잔차 유닛(residual unit)으로 구성된 기존 방법과 달리 한 개의 잔차 유닛만이 사용되었다. 배치 정규화는 CNN 구조에서 일반적으로 사용하는 정규화 기법으로 신경망의 훈련 속도를 향상시키고 그래디언트 소실 문제와 가중치 초기화에 대한 민감도 문제를 개선하는 효과가 있다(Ioffe and Szegedy, 2015).

잡음 제거를 위한 기계학습 훈련 시 잡음을 포함한 영상(x)을 입력으로 하고 잡음이 없는 영상(y)을 라벨로 하여 훈련하는 것이 일반적이다. 그러나 DnCNN은 잔차 영상(v)이 실제 잡음과 가깝게 예측되도록 훈련자료를 구성한다. 잔차 영상(v)은 잡음이 있는 영상(x)과 잡음이 없는 영상(y)의 차이로 나타낼 수 있고, 그 차이를 라벨로 하여 아래 손실함수를 최적화하도록 모델이 훈련된다.

$$l(\theta) = \frac{1}{2N} \sum_{i=1}^N \|R(x_i; \theta) - v_i\|_F^2 \quad (2)$$

여기서 $R(x; \theta)$ 은 가중치 θ 로 추정된 잔차 영상이므로 훈련을 통해 예측된 결과가 원래 영상이 가지고 있는 잡음 ($v = x - y$)과 가까워지도록 훈련됨을 의미한다.

Li *et al.* (2018)은 이러한 DnCNN 구조를 적용하여 현장에서 취득한 151개 송신원 모음 중 2개의 송신원 모음을 훈련자료로 사용하고 나머지 송신원 모음에서 그라운드-롤을 제거하는 연구를 수행하였다. 훈련자료로 사용될 2개의 송신원 모음에 전통적인 그라운드-롤 제거 기법 중 하나인 LTFD (Local Time-Frequency Decomposition) 기법(Liu and Fomel, 2013)을 적용하고, 송신원 모음을 20×20 크기의 패치로 잘라 DnCNN




Fig. 1. DnCNN architecture (modified after Zhang *et al.*, 2017).




Fig. 2. Workflow of ground roll prediction using DnCNN (Li *et al.*, 2018).

네트워크를 훈련했다(Fig. 2). 총 17개 층으로 구성된 깊은 CNN이 잡음 특성을 자동으로 학습하고 복잡한 자료에서 만족할 만한 정도의 그라운드-롤 제거 성능을 확인하였다. 이 방법은 LTFD 기법과 비교하여 빠른 시간 내에 그라운드-롤 제거가 가능하고, 적용 과정 중 추가적인 파라미터 조정 없이 그라운드-롤을 제거할 수 있다는 장점이 있다. 그렇지만, 그라운드-롤을 성공적으로 제거하기 위해서는 높은 품질의 훈련자료가 필요하고 라벨을 만들 때 사용한 LTFD 기법의 성능을 넘어설 수 없다는 근원적인 한계가 있다.

pix2pix

pix2pix (Isola *et al.*, 2017)는 영상에서 영상으로의 변환을 수행하는데 cGAN 구조를 적용한 알고리즘이다. cGAN은 계층 라벨(class label)이나 형태(modality) 등의 보조 정보(c)를 생성자와 판별자 신경망의 입력층에 영상자료와 함께 입력하여 GAN 훈련에 조건을 주는 구조이다(Mirza and Osindero,

2014). 원래 GAN 구조의 생성자 신경망은 무작위 벡터(z)가 실제 영상 자료(y)에 가까운 영상으로 생성되도록 훈련되는 반면($G: \{z\} \rightarrow \{y\}$), cGAN은 보조 정보(c)가 조건으로 작용하여 무작위 벡터(z)와 함께 생성 모델에 입력으로 들어간다($G: \{z, c\} \rightarrow \{y\}$). cGAN의 손실함수는 식 (1)을 참고하여 다음과 같이 표현할 수 있다.

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)} [\log D(y|c)] + E_{z \sim P_z(z)} [\log(1 - D(G(z|c)|c))] \quad (3)$$

이러한 cGAN을 이용하여 사용자가 원하는 특성을 갖는 영상을 생성하도록 응용한 것이 pix2pix 모델이다. 즉, pix2pix 모델은 조건과 무작위 벡터를 입력으로 받고 조건에서 주어진 특성을 보유한 영상을 생성하게 된다. Fig. 3과 같이 판별자 신경망은 생성자 신경망으로 합성된 영상 $G(z, c)$ 과 실제 영상 (y)을 구분하도록 훈련된다. 이 때, 판별자 신경망은 보조 정보 (c)와 판별할 영상을 입력으로 받는다.

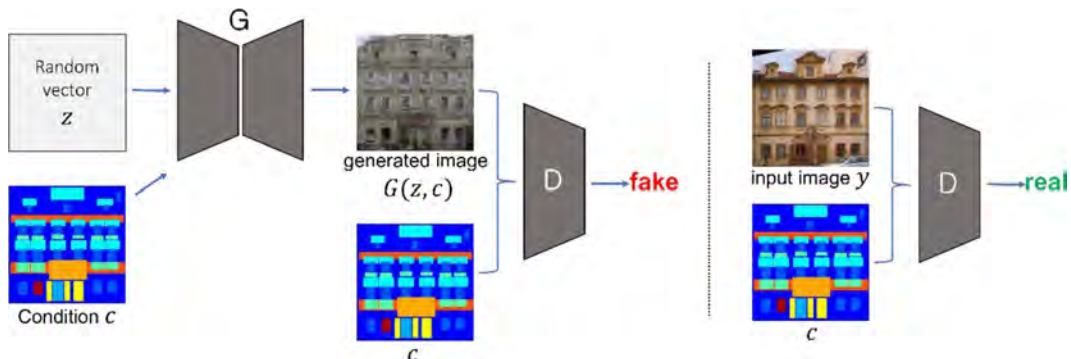


Fig. 3. pix2pix architecture (modified after Isola *et al.*, 2017).

GAN의 훈련에서 생성자 신경망은 판별자 신경망을 더 잘 속일 수 있도록, 판별자 신경망은 입력된 영상이 실제인지 가짜인지 더 잘 판별하는 방향으로 학습하도록 손실함수가 정의된다. cGAN은 기본적으로 GAN 손실함수와 거의 동일한데 조건(c)이 입력값으로 추가(조건부 확률)된다는 차이만 있다. pix2pix의 손실함수는 cGAN과 구조적으로 동일한데 조건이 영상이라는 점과 학습이 잘 되도록 하기 위해 생성자 신경망의 출력 $G(z, c)$ 가 정답 영상인 y 와 가까워지도록 하는 l_1 -노름(norm)이 추가된다. 따라서 pix2pix의 손실함수는 다음과 같이 L_{cGAN} (식 (3))와 l_1 손실의 가중합으로 표현된다.

$$L_l = E_{c,y,z} [\|y - G(z, c)\|_1] \quad (4)$$

$$G^* = \arg \min_G \max_D L_{cGAN} + \lambda_l L_l(G) \quad (5)$$

여기서 $E_{c,y,z}$ 는 훈련 자료 분포에 속하는 자료로 신경망의 출력과 정답 영상의 차이를 계산한 것의 기댓값을 의미하고 λ_l 는 l_1 -노름의 가중치이다.

이러한 pix2pix 알고리즘을 탄성과 자료에 적용하여 공통 송신원 모음 자료에서 그라운드-롤을 제거할 수 있다. Yuan *et al.* (2020)은 합성 자료와 현장 자료가 혼합된 훈련자료를 사용하여 그라운드-롤 제거를 위한 pix2pix 구조를 훈련시켰다. 먼저 그라운드-롤이 없는 600개의 공통 송신원 모음 자료를 합성하고 여기에 여러 주파수의 그라운드-롤을 추가하는 방식으로 합성 훈련자료를 생성하였다. 현장자료의 경우 1,000개의 공통 송신원 모음 자료에 AGRA (adaptive ground roll attenuation) 기법(Yuan *et al.*, 2005)을 적용하여 그라운드-롤이 제거된 자료를 만들었다. 합성자료와 현장자료를 합쳐 총 1,600개 영상을 구성하였고, 이 중 1,300개를 훈련자료로 300개를 테스트 자료로 사용하였다. 모든 영상 데이터는 픽셀 값 범위를 -1에서 1까지로 정규화하였으며, 식 (5)에서의 λ_l , 즉 L_{cGAN} 과 L_l 사이의 가중치 값은 100으로 고정하여 훈련하였다.

CycleGAN

CycleGAN은 pix2pix와 마찬가지로 GAN을 활용하여 소스 영역(source domain)에 속하는 영상을 타겟 영역(target domain)으로 변환한다($G: \{x\} \rightarrow \{y\}$). 다만 pix2pix가 훈련을 위해 쌍(pair)을 이루는 훈련자료가 필요한 반면 CycleGAN은 훈련자료가 쌍을 이룰 필요가 없다. 따라서 입력 자료(x)가 생성자 신경망을 통과해 나온 결과($G(x)$)와 타겟 영역에 속하는 영상(y)이 비슷한 분포가 되도록 훈련하는 것을 학습 목표로 설정하는데, 안정적인 학습을 위해 역 사상(inverse mapping; $F: \{y\} \rightarrow \{x\}$)과 순환 일관성(cycle consistency) 손실($F(G(x)) \approx x$)을 추가하여 구현된다. 어떤 영상 x 가 속하는 영역을 A 영역, 그와 다른 영상 y 가 속하는 영역을 B 영역이라 하면, 순환 일관성은 Fig. 4에서 나타난 바와 같다. 즉, 영상 x 가 생성자 신경망 G 를 통과하여 B 영역에 속하는 영상

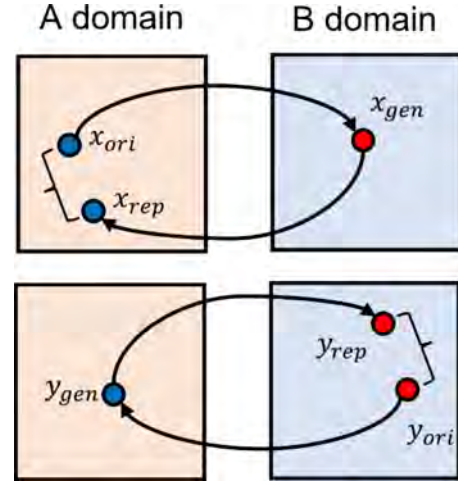


Fig. 4. Forward cycle-consistency and backward cycle-consistency (modified after Zhu *et al.*, 2017).

으로 변환된 후 역 생성자 신경망 F 를 통과하여 다시 A 영역으로 돌아왔을 때 원래 영상(x)과 동일해야 한다는 개념이다. 반대로 B 영역에 속하는 영상(y)은 생성자 신경망 F 와 G 를 순서대로 거치면 원래 영상(y)과 동일 해져야 하고 이를 수식으로 나타내면 식 (6)과 같다.

$$L_{cyc}(G, F) = E_{x \sim P_{data}(x)} [\|F(G(x)) - x\|_1] + E_{y \sim P_{data}(y)} [\|G(F(y)) - y\|_1] \quad (6)$$

CycleGAN 모델은 두 개의 사상(생성자 신경망) G 와 F 를 포함하고 이에 따른 두 판별자 신경망 D_X 와 D_Y 가 모두 훈련되어야 한다. 타겟 영역의 판별자 신경망 D_Y 가 영상 y 와 $G(x)$ 를 구분하도록 훈련되는 것처럼 소스 영역의 판별자 신경망 D_X 는 영상 x 와 $F(y)$ 를 판별하도록 훈련된다(Fig. 5). 전체 손실함수는 생성된 영상의 분포가 타겟 영역 영상의 분포에 가까워지도록 하는 기본적인 GAN 손실항과 두 매핑 G 와 F 가 서로 모순되는 것을 방지하는 순환 일관성 손실항의 가중합으로 표현된다. 식 (7)에서의 λ_{cyc} 는 GAN 손실에 대한 순환 일관성 손실의 가중치를 의미한다.

$$L(G, D, D_X, D_Y) = L_{GAN}(G, D_Y, X, Y) + L_{GAN}(F, D_X, Y, X) + \lambda_{cyc} L_{cyc}(G, F) \quad (7)$$

추가적으로 CycleGAN 결과를 개선하기 위해 여러 제약조건을 줄 수 있다. 변환 과정에서 영상을 너무 많이 바꿔 입력 영상에서 보존해야 하는 특성이 출력 영상에서 사라지는 것을 규제하기 위한 identity 손실항이 대표적이다(Taigman *et al.*, 2016). 이는 타겟 영역의 영상(y)을 입력 자료로 하여 순방향 생성자 신경망(G)에 적용했을 때 결과가 그대로 타겟 영상(y)과 일치하도록 하고(타겟 영역의 영상은 굳이 변환할 이유가 없으므로), 소스 영역의 영상(x)을 역방향 생성자 신경망(F)의

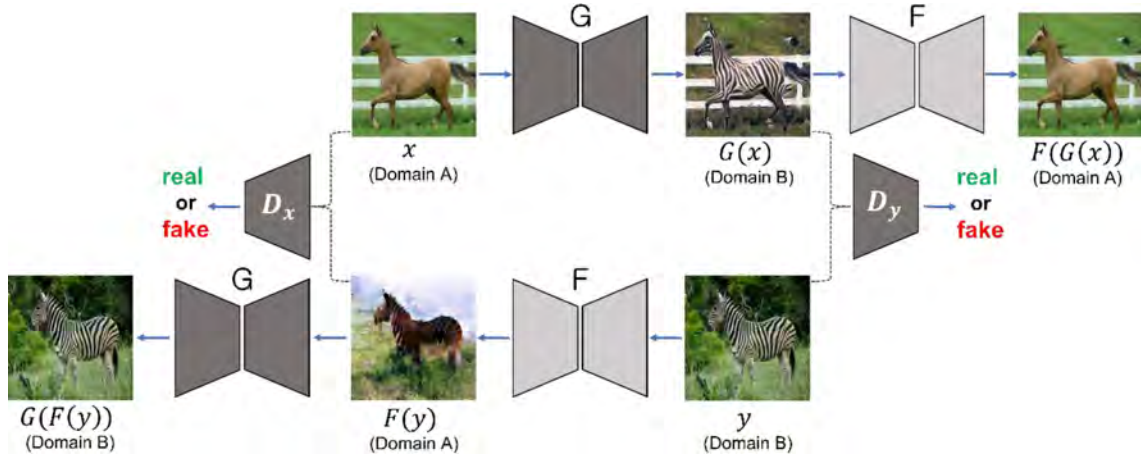


Fig. 5. CycleGAN architecture (modified after kaji and Kida, 2019).

입력으로 사용한 결과가 입력 영상(x)과 일치하도록 하는 것으로 식 (8)과 같다(Zhu *et al.*, 2017).

$$L_{identity}(G, F) = E_{y \sim P_{data}(y)} [\|G(y) - y\|_1] + E_{x \sim P_{data}(x)} [\|F(x) - x\|_1] \quad (8)$$

또한, 영역 변환 과정에서 자기 거리 손실(self-distance loss)을 통해 함수 공간이 너무 커지지 않도록 제약 조건을 줄 수도 있다(Benaïm and Wolf, 2017). 자기 거리 손실은 동일 영역에 속하는 자료 사이의 거리를 줄이기 위해 도입되었고, 이 거리는 각 영역(A, B)에 속하는 자료들 간의 평균(μ_A, μ_B)과 표준편차(σ_A, σ_B)로 각각 정규화하여 적용된다(식 (9)).

$$L_{self-distance}(G) = E_{x \sim P_{data}(x)} \left| \frac{1}{\sigma_A} (\|x_i - x_j\|_1 - \mu_A) - \frac{1}{\sigma_B} (\|G(x_i) - G(x_j)\|_1 - \mu_B) \right| \quad (9)$$

Kaur *et al.* (2019)은 CycleGAN 알고리즘에 위 두가지 추가적인 손실함수(identity, 자기 거리 손실)를 적용하여 반사 신호를 방해하지 않고 그라운드-롤 만들 억제하는 기법을 제안했다. 3차원 육상 탄성과 탐사를 통해 취득한 공통 송신원 모음을 200×200 크기의 패치로 나눠 훈련자료와 검증자료를 구성하였다. 훈련자료의 타겟 영상을 생성하기 위해 평면파 제거 필터(plane wave destruction filters)(Fomel, 2002)와 정규화된 비정상 회귀(regularised nonstationary regression) 기법(Fomel, 2009)을 이용하여 그라운드-롤을 제거하였다. 훈련에 사용된 손실함수는 기본적인 CycleGAN 알고리즘에 identity 손실과 자기 거리 손실을 추가한 4가지 종류의 손실함수를 아래 식 (10)과 같은 가중치를 가지는 합으로 설정하였다.

$$L_{total}(G, F, D_x, D_y) = L_{GAN}(G, D_y) + L_{GAN}(F, D_x) + 10L_{cyc}(G, F) + 10L_{cyc}(F, G) + L_{self-distance}(G) + L_{self-distance}(F) + 5L_{identity}(G) + 5L_{identity}(F) \quad (10)$$

모델 평가 지표

앞서 설명된 세 가지 알고리즘은 그라운드-롤이 포함된 공통 송신원 모음을 정답(그라운드-롤이 제거된 공통 송신원 모음)에 가까워지도록 훈련한다는 동일한 학습 목표를 갖는다. 그렇지만 각각의 모델은 신경망 구조와 손실함수, 훈련 방식 등에 많은 차이가 있어 모델 성능에 대한 정량적인 비교를 위해서는 객관적인 평가 지표를 선정하는 것이 중요하다. 이 연구에서는 각각의 모델을 적용하여 그라운드-롤을 제거한 결과와 라벨 사이의 상관계수(correlation coefficient)와 SSIM (Structural Similarity Index Measure) 값을 비교하여 모델의 성능을 비교하고자 하였다.

통계학적으로 상관계수는 두 확률 변수 벡터 X, Y 간의 선형 상관 관계를 계량화한다. 상관계수는 +1과 -1 사이의 값을 가지며, +1은 완벽한 양의 선형 상관 관계, 0은 선형 상관 관계없음, -1은 완벽한 음의 선형 상관 관계를 의미한다. 상관계수를 이용하여 라벨과 모델 예측 결과의 유사도를 비교할 수 있다. 이 때 상관계수 계산은 동일한 송신원과 수신기 위치에 해당하는 트레이스들을 사용해야 한다. 두 트레이스 X, Y 사이의 상관계수 r_{XY} 는 식 (11)을 통해 계산할 수 있다.

$$r_{XY} = \frac{\sum_i^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_i^n (X_i - \bar{X})^2} \sqrt{\sum_i^n (Y_i - \bar{Y})^2}} \quad (11)$$

상관계수는 두 모집단의 공분산을 각 모집단의 표준편차를 곱한 항으로 나누어서 계산할 수 있는데, 여기서 모집단은 두 벡터 X, Y 이고 n 은 벡터의 길이(한 모집단에 속하는 샘플의 개수)를 의미한다. 공분산과 표준편차를 구하기 위해 필요한 각 모집단의 평균은 \bar{X}, \bar{Y} 이다. 그러나 상관계수는 경우에 따라 자료 분포를 정확하게 대표하지 않을 수도 있기 때문에, 영상 자료에 대한 유사도를 측정하는 다른 방법을 추가적으로 사용하고자 한다.

SSIM (structural similarity index measure)은 두 영상 자료 사이의 유사도를 정량화 한다. SSIM은 휘도, 대비, 구조의 유사도를 각각 수치화 하여 가중합 하는 형태로 구성되는데, 일반적으로 식 (12)로 간략하게 표현할 수 있다.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_1)} \quad (12)$$

여기서 μ 는 평균, σ 는 표준편차를 의미하며, c_1 과 c_2 는 값의 범위를 고려하여 결정되는 상수로 식 (13)의 관계로 정의된다.

$$\begin{aligned} c_1 &= (k_1L)^2 \\ c_2 &= (k_2L)^2 \end{aligned} \quad (13)$$

식 (13)에서 k_1, k_2 는 일반 상수로 보통 각각 0.01, 0.03을 사용한다. L 은 자료가 가지는 픽셀 값의 범위이며, 모든 자료는 -1에서 1사이의 값을 가지도록 정규화 되어 있으므로 L 값은 2로 사용했다. SSIM 값은 각 영상 자료에 11×11 픽셀 크기의 가우시안 커널(Gaussian kernel)을 적용하여 두 영상에서 동일한 위치의 윈도우(window) 별로 계산된다. 가우시안 함수를 2차원 자료에 적용하여 윈도우별 평균과 표준편차를 구할 수 있고 이 값들을 식 (12)에 대입하여 SSIM 값을 도출한다. 모든 윈도우에 대한 SSIM의 평균을 구해 주파수-파수 필터링으로 생성된 라벨 영상과 각 기계학습 결과 영상 사이의 구조적 유사성을 지표로 나타낼 수 있다.

수치 예제

자료 준비

이론 절에서 설명한 딥러닝 기반 그라운드-롤 제거 연구는 서로 다른 현장자료 또는 현장자료와 합성자료의 조합으로 구성된 훈련자료가 사용되었다. 이 연구에서는 비교를 위해 동일한 현장자료를 사용하여 각 신경망 모델을 훈련했는데, 이 현장 자료는 알버타(Alberta) 지역의 Blackfoot 필드에서 취득된 육상 탄성과 탐사 자료 중 하나의 축선에 해당하는 201개의 공통 송신원 모음이다(Gallant *et al.*, 1995).

훈련자료 생성을 위한 기본적인 자료처리로 공통 송신원 모음 자료에 자동 이득 제어(automatic gain control, AGC)와 뮤팅(muting)을 적용하였고, 테스트 자료에도 동일한 자료처리를 적용한 후 학습된 모델의 입력자료로 사용했다. 지도학습을 위한 라벨은 입력 탄성과 자료에서 그라운드-롤을 제거하여 만들어야 하는데, 이를 위해 전통적인 그라운드-롤 제거 기법을 적용할 수밖에 없다. 여러가지 그라운드-롤 제거 기법 중 가장 직관적이고 간단한 방법인 주파수-파수 필터링을 통해 그라운드-롤이 제거된 공통 송신원 모음 자료를 생성하였다. 이 연구에서 선택한 현장자료를 기존 연구에서 제안된 신경망 구조에 사용하기 위해 입력자료의 크기를 재조정(resizing)하는 과정

이 필요하였다. 200개의 트레이스(trace)와 1,801개의 시간 샘플을 가진 공통 송신원 모음을 64×512 크기의 영상으로 변환하였다. 크기 변환은 파이썬(Python)의 cv2 라이브러리를 사용하여 수행되었는데, 영상의 크기를 변환하는 과정에서 알리아싱(aliasing) 문제가 발생하였다. 이를 해결하기 위해 영상의 크기를 줄일 때 알리아싱으로 생성되는 무이레(moire) 패턴이 발생하는 것을 방지하는 Inter_area 보간법(interpolation)을 사용하였다. 또한 딥러닝 모델의 안정적인 훈련을 위해 최소-최대 스케일링(min-max scaling)을 적용하여 공통 송신원 모음 자료의 범위가 -1에서 1이 되도록 정규화 하였다. 전처리 과정을 적용한 201개의 영상 중 20%인 34개 영상은 테스트 자료로 사용하였다. 나머지 167개 영상자료는 무작위로 섞은 후 훈련 자료로 사용하였는데 서로 다른 딥러닝 모델 훈련에서 그 순서가 동일하지는 않다. 훈련 자료 중 20%는 훈련 중 모델의 성능을 평가하여 과적합(over-fitting)을 예방하기 위한 검증자료로 사용되었다.

모델 학습

이 연구에서 사용한 3개의 딥러닝 모델(DnCNN, pix2pix, CycleGAN) 모두 배치사이즈는 8로 설정하여 훈련시켰다. 모델에 관계없이 훈련은 총 500번 반복(500 에포크(epoch))하였으며 각 모델마다 기준이 되는 손실함수 항을 정해 그 값이 최소가 되는 에포크의 결과를 출력했다. 각 기계학습 모델에 적용된 하이퍼파라미터(hyperparameter)를 간단히 정리하면 Table 1과 같다.

DnCNN은 그라운드-롤을 예측하는 신경망으로 설계되어 있다. 따라서 전처리된 공통 송신원 모음과 그라운드-롤이 제거된 공통 송신원 모음의 차이를 라벨로 사용한다. 배치 정규화, ReLU 활성화 함수를 포함한 15개 층으로 이루어진 CNN 구조를 사용하였고(Fig. 6a), 훈련자료를 구성하는 값의 범위를 고려하여 마지막 층에는 tanh 활성 함수를 사용하였다. 학습률(learning rate)은 0.001로 설정하였고 신경망 훈련을 위한 최적화 기법으로는 Adam (adaptive moment estimation) 옵티마이저를 선택하였다.

훈련 과정 중 손실함수로 사용한 최소 제곱 오차(mean squared error, MSE)의 값은 Fig. 6b와 같고, 이 오차가 최소가

Table 1. Hyperparameters used for training each machine learning model.

Hyperparameter	DnCNN	pix2pix	CycleGAN
Learning rate	0.001	0.0002	0.0002
Optimizer	Adam	Adam	Adam
Batch size	8	8	8
Num. of hidden layer	15	10+5	10+5+10+5
Filter size (Conv. layer)	(3, 3)	(4, 4)	(4, 4)
Activation function	ReLU+tanh	LeakyReLU	LeakyReLU

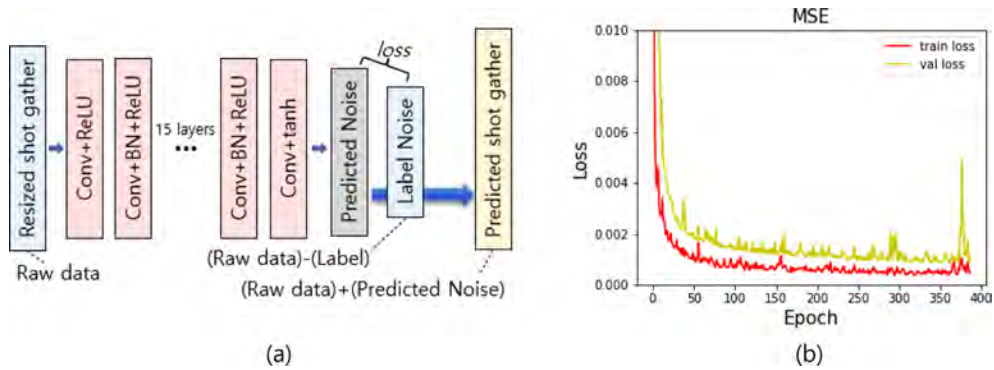


Fig. 6. DnCNN model training: (a) structure of the DnCNN used, and (b) training (yellow) and validation losses (red) versus the number of epochs.

되는 352번째 에포크의 결과를 모델 훈련의 최종 결과로 하여 다른 방법들과 비교하였다.

GAN 기반 알고리즘들은 생성자와 판별자 신경망이 쌍으로 구성된 네트워크가 필요하다. 이 연구에서 생성자 신경망은

10개의 합성곱 층을 가지고 LeakyReLU를 활성화 함수로 사용한 U-Net 구조를 사용한다(Fig. 7a). 판별자 신경망은 이진 크로스 엔트로피(binary cross entropy) 손실함수를 최적화함으로써 실제 자료와 생성자 신경망을 통해 생성된 자료가 구분되

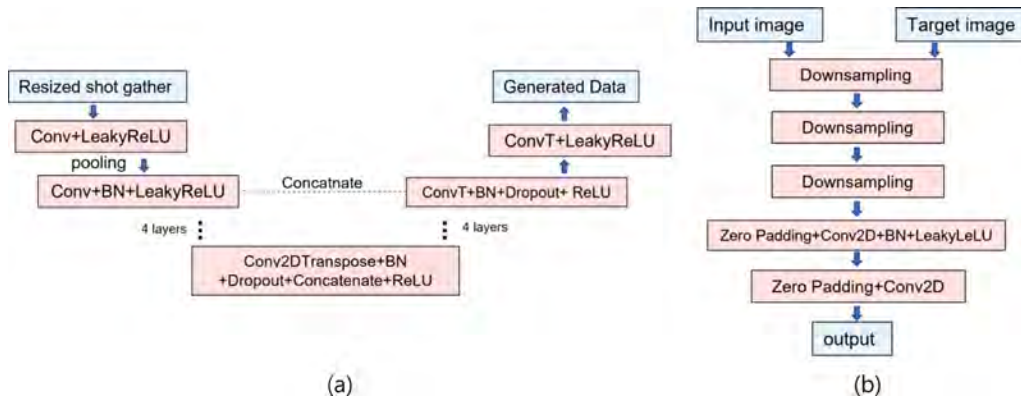


Fig. 7. Structure of the GAN: (a) U-Net (Ronneberger *et al.*, 2015) architecture used for the generator, and (b) 5 layers (3 downsampling layers plus 2 convolutional layers) for the discriminator.

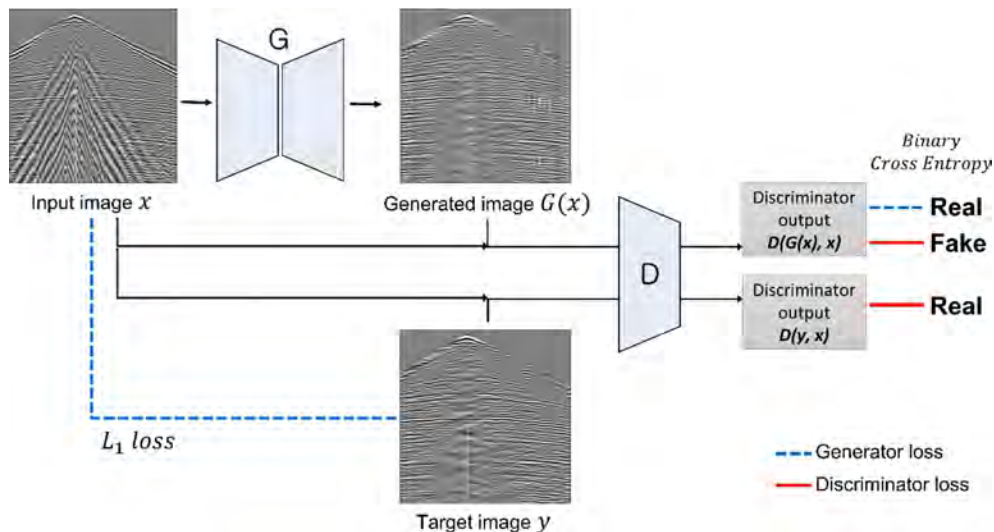


Fig. 8. Workflow of training the pix2pix algorithm for ground roll attenuation.

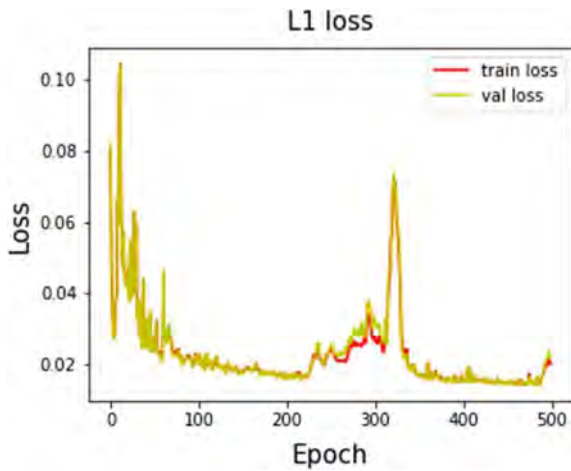


Fig. 9. pix2pix model training: training (yellow) and validation losses (red) versus the number of epochs

도록 훈련된다. 판별자 신경망의 구조는 Fig. 7b와 같이 3개의 다운 샘플링(down sampling) 층과 2개의 합성곱 층으로 구성했다.

pix2pix 모델 훈련에서는 생성자 신경망과 판별자 신경망의 학습률(learning rate)을 0.0002로 설정하고 Adam 옵티마이저를 사용하였다. 그라운드-롤이 제거되지 않은 원자료를 x , 주파수-파수 필터링으로 그라운드-롤을 제거한 데이터(라벨)를 y 라 명시했을 때 훈련과정은 Fig. 8과 같다.

500번의 에포크 중 최적의 훈련 결과를 내는 에포크를 결정하기 위해 생성자 신경망의 출력 자료($G(x)$)와 타겟 자료(y) 사이의 l_1 -노름을 기준으로 사용하였다. 생성자 신경망이 생성한 영상과 타겟 영상 사이의 l_1 -노름이 최소가 되는 결과를 선택하면 outlier에 해당하는 그라운드-롤은 최대한 제거되고 나머지 반사 신호를 유지하는 생성 모델을 얻을 수 있다. 이러한 기준으로 선택한 결과는 Fig. 9와 같이 486번째 에포크 결과이다.

CycleGAN의 훈련과정은 pix2pix와 동일한 학습률과 옵티마이저를 사용하였다. CycleGAN 모델은 pix2pix 모델과 달리 훈련자료가 일대일 대응되는 쌍(pair)으로 존재하지 않아도 되는 대신 두 개의 생성자 신경망과 판별자 신경망이 필요하다. 이 연구에서 사용한 CycleGAN 알고리즘은 Fig. 10과 같은 과정에 따라 훈련된다. 여기서는 두 개의 생성자 신경망과 판별자 신경망을 구별하기 위해 각각 G, F, D_x, D_y 로 명시한다.

다른 알고리즘들과 마찬가지로 500번의 에포크 중 최적의 결과라 판단되는 392 번째 에포크에서 훈련 결과를 도출했다. 이 연구에서 CycleGAN의 경우에는 순환 일관성 손실이 최소가 되는 지점을 기준으로 최적의 모델을 도출하였다(Fig. 11). 앞서 설명한 바와 같이 순환 일관성 손실은 두 생성자 신경망의 성능에 의해서 그 값이 결정된다. 다른 두 모델의 결과가 생성자 신경망의 출력과 라벨 사이의 차이가 최소가 되는 지점으로 결정되기 때문에 CycleGAN의 경우에도 생성자 신경망의 성능만으로 결정되는 순환 일관성 손실을 그 기준으로

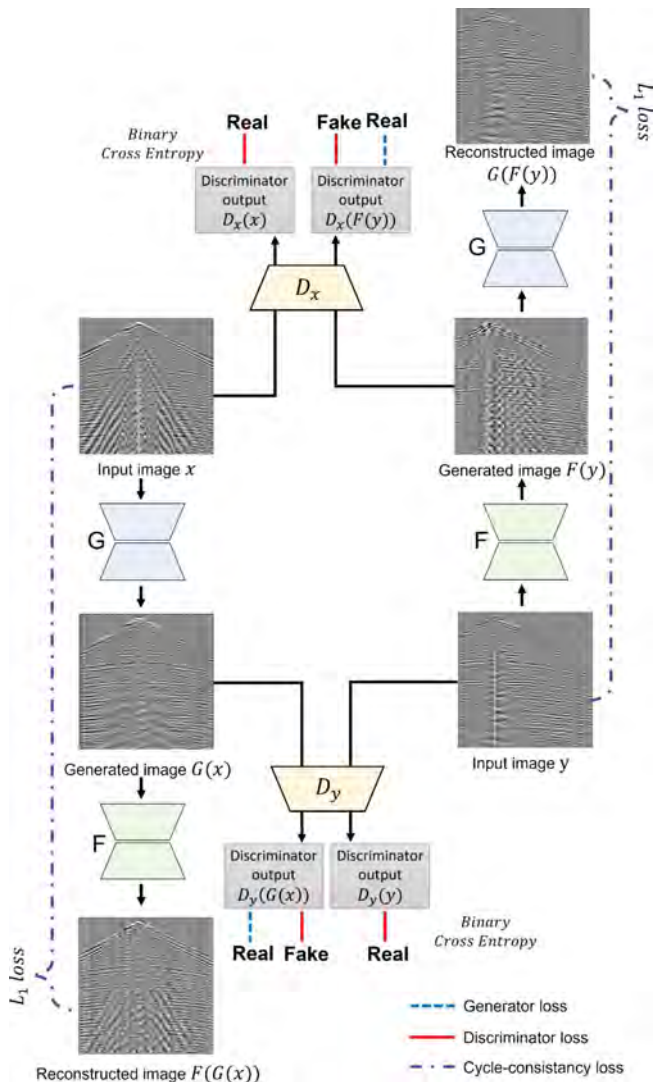


Fig. 10. Workflow of training the CycleGAN algorithm for ground roll attenuation.

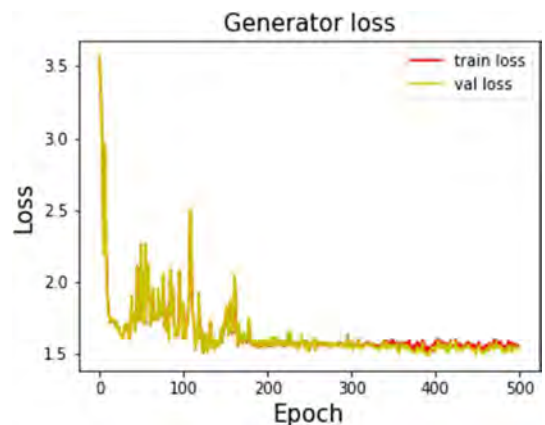


Fig. 11. CycleGAN model training: training (yellow) and validation losses (red) versus the number of epochs.

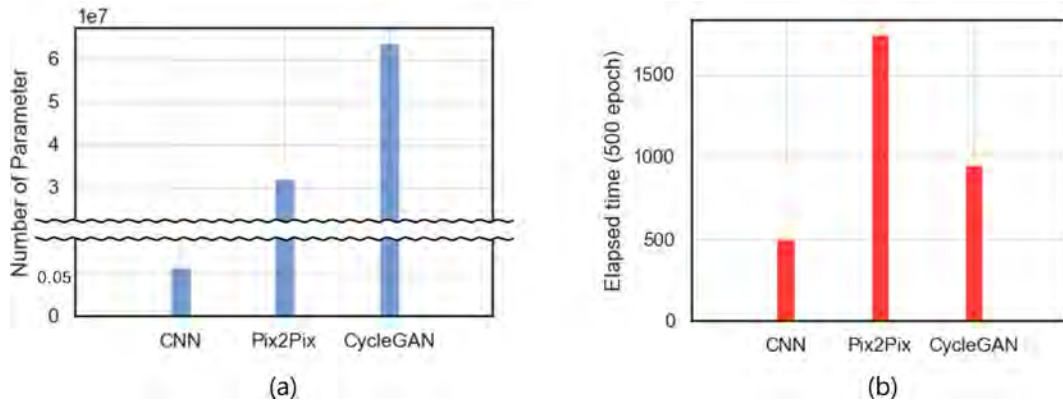


Fig. 12. Comparison between (a) the number of trainable parameters of CNN, pix2pix and CycleGAN and, (b) elapsed time for those models to train.

하는 것이 적절하다.

세 알고리즘은 모두 동일한 성능의 그래픽 연산 장치 (GeForce RTX 2080, 12 GB)를 사용하여 훈련하였다. 정량적인 비교를 위해 각 알고리즘의 학습 매개변수(신경망 가중치) 수와 소요시간을 Fig. 12의 히스토그램으로 도시하였다. 그러나 DnCNN은 하나의 네트워크만을 사용하는데 비해, pix2pix는 한 쌍의 생성자 신경망과 판별자 신경망, CycleGAN은 두 쌍의 생성자 신경망과 판별자 신경망을 훈련하는 구조이기 때문에 학습 매개변수 수와 소요시간을 직접적으로 비교하는 것은 다소 무리가 있다고 생각된다.

결과 분석

DnCNN, pix2pix, CycleGAN 알고리즘의 훈련 중 각각 최소 제곱 오차, L_1 오차, 순환 일관성 오차를 기준으로 하여 오차가 최소가 되는 에포크의 결과를 저장하고 비교하였다. 훈련에 사용되지 않은 테스트 자료(110 번째 공통 송신원 모음)를 훈련된 모델에 적용한 결과를 도시하면 Fig. 13과 같다.

이 연구에서 사용된 기계학습 모델을 적용한 결과(Figs. 13c-e) 모두 주파수-파수 필터링으로 그라운드-롤을 제거하여 라벨로 사용한 Fig. 13b와 유사하게 그라운드-롤이 사라지고 반사신호가 강조되는 결과를 확인할 수 있다. DnCNN 구조로 예측한 결과(Fig. 13c)는 약한 진폭의 그라운드-롤이 남기는 했지만 기계학습 훈련 결과로 추가적인 잡음이 생성되지 않아 가장 깔끔한 결과를 보인다. pix2pix 기법을 사용한 예측(Fig. 13d)에서 그라운드-롤 성분은 육안 상으로 완전히 제거되었으나 원래의 자료에는 없는 수직 잡음이 나타났다. 이는 모델을 통과한 영상과 정답 영상과의 차이를 DnCNN에서는 l_2 -노름을 사용했으나 pix2pix 기법에서는 l_1 -노름으로 손실함수에 포함했기 때문이라고 생각된다. 일반적으로 l_2 -노름을 손실함수로 사용했을 때 결과가 평탄화(smooth)되는 경향이 있는데, 이 특성이 반영되어 DnCNN 알고리즘의 결과에서 정답 영상에 존재하는 수직 잡음이 흐려진 것이라 추정된다. CycleGAN을 적

용한 결과(Fig. 13e)도 그라운드-롤 제거와 반사파 강조에 좋은 성능을 보이지만 pix2pix를 사용했을 때와 마찬가지로 수직 잡음이 나타난다. 각 기법을 통해 제거된 성분을 파악하기 위해 원래 자료(Fig. 13a)와 그라운드-롤을 제거한 영상(Figs. 13b-e)의 차이를 나타냈다(Figs. 13f-i). DnCNN 기법(Fig. 13g), pix2pix 기법(Fig. 13h), CycleGAN 기법(Fig. 13i)으로 제거된 성분에 그라운드-롤만이 포함된다고는 볼 수는 없다. 그러나 주파수-파수 필터링으로 제거된 성분(Fig. 13(f))과 비교했을 때, 그라운드-롤에 겹쳐진 탄성과 신호의 손실은 기계학습의 영향이 아님을 확인할 수 있다.

라벨 생성에 사용된 주파수-파수 필터링은 그라운드-롤이 있는 공통 송신원 모음(Fig. 13a)을 영역 변환하여 주파수-파수 영역의 자료(Fig. 14a)를 생성하고 부채꼴(fan) 형태의 필터를 적용함으로써(Fig. 14b) 수행된다. 필터링된 자료(Fig. 14b)를 시간-공간 영역으로 역변환 하면 그라운드-롤이 제거된 공통 송신원 모음(Fig. 13b)이 생성된다. 따라서 그라운드-롤 제거 효과는 시간-공간 영역훈련 결과 자료(Fig. 13)를 주파수-파수 영역으로 변환하여 비교할 수 있다. Figs. 14c-e는 각각 DnCNN, pix2pix, CycleGAN으로 그라운드-롤을 제거한 결과(Figs. 13c-e)를 주파수-파수 영역으로 나타낸 것인데, 적용 결과 모두 라벨과 비슷한 형태로 주파수 성분들이 제거됨을 확인할 수 있다. 특히 DnCNN을 적용한 결과(Fig. 14c)의 그라운드-롤에 해당하는 주파수-파수 성분이 가장 깨끗하게 지워지는 것을 확인할 수 있다.

정량적인 성능 평가를 위해 기계학습 모델로 그라운드-롤을 제거한 결과와 라벨과의 유사도를 상관계수와 SSIM 값으로 나타내어 비교하였다. 상관계수는 트레이스 사이의 구조적 유사도를 수치화 하므로 동일한 송신원, 수신기 위치에 해당하는 기계학습 적용 결과의 트레이스와 라벨의 트레이스에 적용하여 기계학습 결과의 품질을 정량적으로 평가할 수 있다. Figs. 15a, b는 테스트 자료에 해당하는 임의의 두 공통 송신원 모음의 라벨과 기계학습 적용 결과에 속하는 트레이스들 사이의




Fig. 13. Ground roll attenuation of the (a) 110th common shot gather. Attenuation results using (b) f-k filtering, (c) DnCNN, (d) pix2pix, and (e) CycleGAN. (f), (g), (h) and (i) are differences between original data and ground roll attenuated data: (a)-(b), (a)-(c), (a)-(d) and (a)-(e) in order.

상관계수를 그래프로 나타낸 것이다. DnCNN은 파란색, pix2pix는 빨간색, CycleGAN은 초록색 점으로 라벨 자료와의 상관계수를 표현했다. 분홍색 점선은 그라운드-롤이 제거되지 않은 입력자료와 주파수-파수 필터링으로 그라운드-롤이 제거

된 라벨의 상관계수이다. 이는 기계학습 기법을 적용한 결과가 원래의 입력 자료보다는 라벨에 가까워졌음을 확인하기 위한 기준으로서 결과들과 함께 도시하였다. 3가지 모델 결과 모두 그라운드-롤이 있는 원래 자료보다 그라운드-롤이 제거된 라




Fig. 14. F-k spectrum of (a) 110th CSG, and ground roll attenuation results using (b) f-k filtering, (c) DnCNN, (d) pix2pix, and (e) CycleGAN.

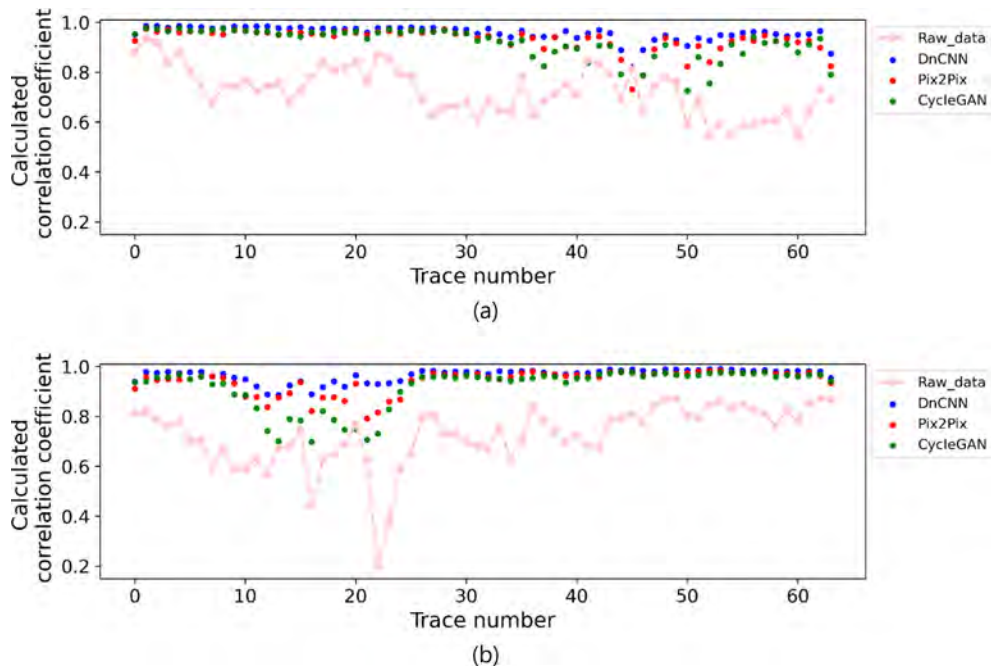


Fig. 15. Comparison of Pearson correlation coefficient between the traces in f-k filtered data and the traces in raw data (pink dotted line), DnCNN results (blue dot), pix2pix results (red dot), and CycleGAN results (green dot). The correlation coefficient of two test data, (a) and (b), are plotted.

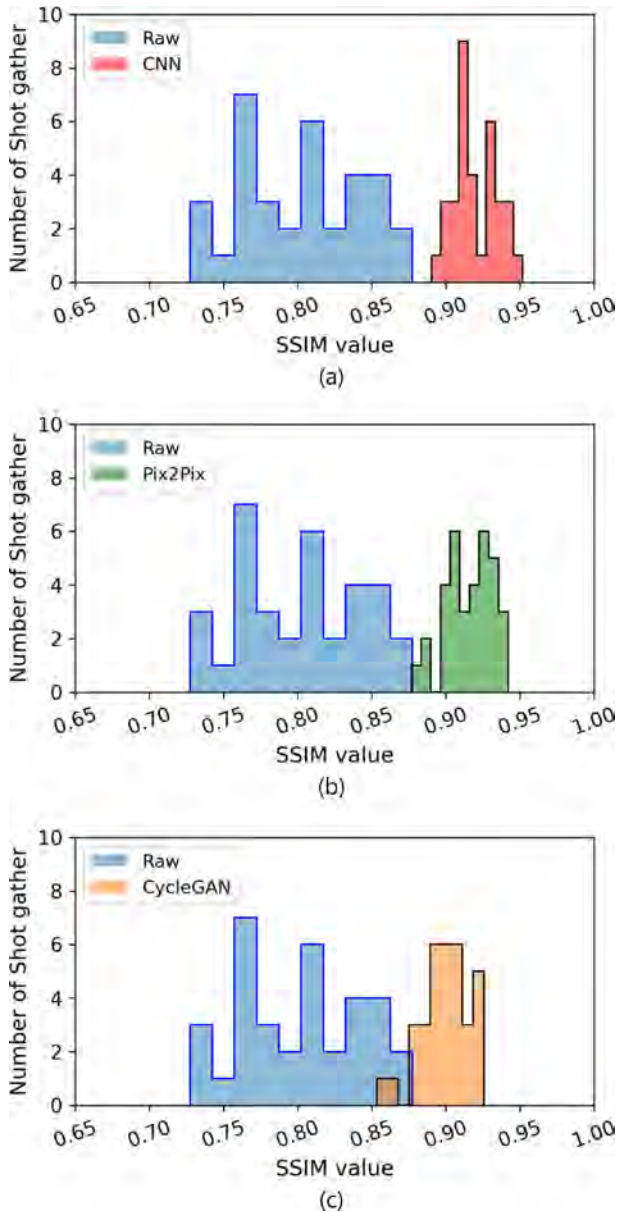


Fig. 16. Comparison of SSIM distributions using the histogram. Each SSIM is calculated between the f-k filtered data and (a) DnCNN, (b) pix2pix, and (c) CycleGAN results. The distribution of SSIM values between f-k filtered data and raw data is shown as a blue histogram in all figures.

벨에 가까운 결과를 도출한다. 기계학습 결과만 비교해보면, DnCNN이 라벨과의 트레이스 유사도가 대체적으로 가장 높았고, pix2pix, CycleGAN 순으로 라벨과의 트레이스 상관도가 높다는 것을 확인할 수 있다.

두 영상 사이의 구조적 유사도를 측정하는 SSIM 값은 송신 원 모음 사이의 유사도를 평가하기 위해 사용하였다. 테스트 자료에 속하는 34개의 주파수-파수 필터링이 적용된 라벨과 기계학습으로 그라운드-롤을 제거한 결과 사이의 SSIM 값을

구하면 총 34개의 값이 계산된다. 이 값들의 분포를 비교하기 위해 Fig. 16과 같이 히스토그램을 도시하였다. 상관계수 비교와 마찬가지로 DnCNN (Fig. 16a), pix2pix (Fig. 16b), CycleGAN (Fig. 16c)으로 얻은 결과의 SSIM 값을 히스토그램으로 도시하였다. 성능 비교를 위해 입력자료(그라운드-롤이 포함된 원자료)와 라벨(그라운드-롤이 제거된 자료)사이의 SSIM값을 파란색 히스토그램으로 도시하여 기준으로 사용하였다. 그라운드-롤이 제거되지 않은 입력자료와 주파수-파수 필터를 적용한 결과 사이의 SSIM 값은 약 0.8 ± 0.075 이다. 기계학습을 적용한 후 CNN과 pix2pix는 대부분 0.9 이상, CycleGAN은 대부분 0.85이상의 SSIM 값을 나타낸다. 이를 통해 라벨로 사용된 주파수-파수 필터링이 적용된 자료와의 구조적인 유사도는 DnCNN, pix2pix, CycleGAN 순으로 높음을 알 수 있다.

결론

이 연구에서는 기존 문헌으로 발표된 그라운드-롤 제거를 위한 기계학습 알고리즘 중 DnCNN, pix2pix, CycleGAN을 이용한 방법을 구현하고 현장 자료에 적용하여 성능을 비교하였다. 각각의 딥러닝 모델을 훈련시키는 방식이 다르기 때문에 엄밀한 정량적 비교는 어렵지만 신경망 매개변수 개수와 훈련에 소요된 시간, 수치 예제 결과의 상관계수 및 SSIM 분석 등을 통해 최대한 정량적 비교 결과를 제시하였다. 수치 예제로 사용된 탄성과 자료의 시간-공간 영역 및 주파수-파수 영역 비교와 상관계수, SSIM 결과를 통해 DnCNN이 가장 좋은 결과를 보였다. 그러나 이러한 결과는 품질 차이가 그리 크지 않고 딥러닝 모델의 설계와 훈련 과정의 미세조정을 통해 달라질 수 있으므로 특정 알고리즘이 그라운드-롤 제거에 더 적합하다는 결론을 내리는 데에는 신중해야 한다. 이 연구에서 실증한 딥러닝 모델은 현장 자료를 사용하여 훈련할 때, 라벨과 보조자료로서 전통적인 그라운드-롤 제거 기법을 통해 생성된 정답 자료가 필요하다. 따라서 그라운드-롤 제거를 위해 학습된 딥러닝 모델로 얻을 수 있는 최선의 결과는 전통적인 그라운드-롤 제거 기법의 성능을 넘어설 수는 없다는 한계가 분명히 존재한다. 다만, 훈련된 딥러닝 모델을 적용하는 것은 전통적인 그라운드-롤 제거 기법보다 그 과정이 단순하고 효율적이므로 적용해야 하는 자료의 양에 따라 충분히 효과적인 제거 기법이 될 수 있다.

감사의 글

이 논문은 2023년도 정부(산업통상자원부)의 재원으로 한국 에너지기술평가원의 지원을 받아 수행된 연구임(20226A10100030, 고성능 해양 CO₂ 모니터링 기술개발).

References

- Benaim, S., and Wolf, L., 2017, One-sided unsupervised domain mapping, *Advances in Neural Information Processing Systems*, 30. <https://doi.org/10.48550/arXiv.1706.00826>
- Choi, W. C., Lee, G. H., Cho, S. I., Choi, B. H., and Pyun, S. J., 2020, Fault Detection for Seismic Data Interpretation Based on Machine Learning: Research Trends and Technological Introduction, *Geophysics and Geophysical Exploration*, **23(2)**, 97-114 (In Korean with English abstract). <https://doi.org/10.7582/GGE.2020.23.2.097>
- Deighan, A. J., and Watts, D. R., 1997, Ground-roll suppression using the wavelet transform, *Geophysics*, **62(6)**, 1896-1903. <https://doi.org/10.1190/1.1444290>
- Embree, P., Burg, J. P., and Backus, M. M., 1963, Wide-band velocity filtering; The Pie-Slice process, *Geophysics*, **28(6)**, 948-974. <https://doi.org/10.1190/1.1439310>
- Fomel, S., 2002, Applications of plane-wave destruction filters, *Geophysics*, **67(6)**, 1946-1960. <https://doi.org/10.1190/1.1527095>
- Fomel, S., 2009, Adaptive multiple subtraction using regularized nonstationary regression, *Geophysics*, **74(1)**, V25-V33. <https://doi.org/10.1190/1.3043447>
- Gallant, E. V., Stewart, R. R., Bertram, M. B., and Lawton, D. C., 1995, Acquisition of the Blackfoot broad-band seismic survey, *CREWES*, **7(36)**, 1-9. <https://www.crewes.org/Documents/ResearchReports/1995/1995-36.pdf>
- Géron, A., 2017, *Hands-on machine learning with scikit-learn and tensorflow: Concepts, Tools, and Techniques to build intelligent systems*, O'Reilly Media. <https://www.oreilly.com/library/view/hands-on-machine-learning/9781491962282/>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y., 2014, Generative adversarial networks, arXiv preprint arXiv:1406.2661. <https://doi.org/10.48550/arXiv.1406.2661>
- Guo, R., Maniar, H., Di, H., Moldoveanu, N., Abubakar, A., and Li, M., 2020, Ground roll attenuation with an unsupervised deep learning approach, *In SEG Technical Program Expanded Abstracts 2020*, Society of Exploration Geophysicists, 3164-3168. <https://doi.org/10.1190/segam2020-3425792.1>
- He, K., Zhang, X., Ren, S., and Sun, J., 2016, Deep residual learning for image recognition, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778. https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/He_Deep_Residual_Learning_CVPR_2016_paper.pdf
- Ioffe, S., and Szegedy, C., 2015, Batch normalization: Accelerating deep network training by reducing internal covariate shift, *In International Conference on Machine Learning*, 448-456. <https://doi.org/10.48550/arXiv.1502.03167>
- Isola, P., Zhu, J. Y., Zhou, T., and Efros, A. A., 2017, Image-to-image translation with conditional adversarial networks. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1125-1134. <https://doi.org/10.48550/arXiv.1611.07004>
- Jia, Z., Lu, W., Zhang, M., and Miao, Y., 2018, Separating ground-roll from land seismic record via convolutional neural network, *In SEG 2018 Workshop: SEG Maximizing Asset Value Through Artificial Intelligence and Machine Learning*, 60-63. DOI: 10.1190/AIML2018-16.1
- Jo, Y. J., Bae, K. M., and Park, J. Y., 2020, Research Trends of Generative Adversarial Networks and Image Generation and Translation, *Electronics and Telecommunications Trends*, **35(4)**, 91-102 (In Korean with English abstract). <https://doi.org/10.22648/ETRI.2020.J.350409>
- Kaji, S., and Kida, S., 2019, Overview of image-to-image translation by use of deep neural networks: denoising, super-resolution, modality conversion, and reconstruction in medical imaging, *Radiological Physics and Technology*, **12**, 235-248. DOI: 10.1007/s12194-019-00520-y
- Kaur, H., Fomel, S., and Pham, N., 2019, Ground roll attenuation using generative adversarial network, *81st Annual International Conference and Exhibition, EAGE, Extended Abstracts*, 1-5. DOI: <https://doi.org/10.3997/2214-4609.201900762>
- Li, H., Yang, W., and Yong, X., 2018, Deep learning for ground-roll noise attenuation, *In SEG Technical Program Expanded Abstracts 2018*, Society of Exploration Geophysicists, 1981-1985. <https://doi.org/10.1190/segam2018-2981295.1>
- Liu, X., 1999, Ground roll suppression using the Karhunen-Loeve transform, *Geophysics*, **64(2)**, 564-566. <https://doi.org/10.1190/1.1444562>
- Liu, Y., and Fomel, S., 2013, Seismic data analysis using local time-frequency decomposition, *Geophysical Prospecting*, **61(3)**, 516-525. DOI: 10.1111/j.1365-2478.2012.01062.x
- Mirza, M., and Osindero, S., 2014, Conditional generative adversarial nets. arXiv preprint arXiv:1411.1784. <https://doi.org/10.48550/arXiv.1411.1784>
- Naghizadeh, M., and Sacchi, M., 2018, Ground-roll attenuation using curvelet downscaling, *Geophysics*, **83(3)**, V185-V195. <https://doi.org/10.1190/geo2017-0562.1>
- Pham, N., and Li, W., 2022, Physics-constrained deep learning for ground roll attenuation, *Geophysics*, **87(1)**, V15-V27. <https://doi.org/10.1190/geo2020-0691.1>
- Ronneberger, O., Fischer, P., and Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, *In Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference*, Springer International Publishing, 234-241. https://link.springer.com/chapter/10.1007/978-3-319-24574-4_28
- Russell, B., Hampson, D., and Chun, J., 1990a, Noise elimination and the Radon transform, part 1, *The Leading Edge*, **9(10)**, 18-23. <https://doi.org/10.1190/1.1439677>
- Russell, B., Hampson, D., and Chun, J., 1990b, Noise elimination and the Radon transform, part 2, *The Leading Edge*, **9(11)**, 31-37. <https://doi.org/10.1190/1.1439700>
- Serdyukov, A. S., 2022, Ground-roll extraction using the Karhunen-Loeve transform in the time-frequency domain, *Geophysics*, **87(2)**, A19-A24. <https://doi.org/10.1190/geo2021-0453.1>

- Taigman, Y., Polyak, A., and Wolf, L., 2016, Unsupervised cross-domain image generation, arXiv preprint arXiv:1611.02200. <https://doi.org/10.48550/arXiv.1611.02200>
- Treitel, S., Shanks, J. L., and Frasier, C. W., 1967, Some aspects of fan filtering, *Geophysics*, **32(5)**, 789-800. <https://doi.org/10.1190/1.1439889>
- Yarham, C., Boeniger, U., and Herrmann, F., 2006, Curvelet-based ground roll removal, *76th Annual International Meeting, SEG, Expanded Abstracts*, 2777-2782. DOI: [10.1190/1.2370101](https://doi.org/10.1190/1.2370101)
- Yilmaz, Ö., 2001, *Seismic data analysis: Processing, inversion, and interpretation of seismic data*, Society of exploration geophysicists. <https://doi.org/10.1190/1.9781560801580>
- Yuan, Y., Si, X., and Zheng, Y., 2020, Ground-roll attenuation using generative adversarial networks, *Geophysics*, **85(4)**, WA255-WA267. <https://doi.org/10.1190/geo2019-0414.1>
- Yuan, Y., Zhou, Z., Niu, B., Wang, H., and Xiang, A., 2005, A method for improving the signal to noise ratio in seismic data, *Oil Geophysical Prospecting*, **40**, 168-171.
- Zhang, K., Zuo, W., Chen, Y., Meng, D., and Zhang, L., 2017, Beyond a gaussian denoiser: Residual learning of deep CNN for image denoising, *IEEE Transactions on Image Processing*, **26(7)**, 3142-3155. <https://doi.org/10.1109/TIP.2017.2662206>
- Zhu, J. Y., Park, T., Isola, P., and Efros, A. A., 2017, Unpaired image-to-image translation using cycle-consistent adversarial networks, *In Proceedings of the IEEE International Conference on Computer Vision*, 2223-2232. <https://doi.org/10.48550/arXiv.1703.10593>