

라플라스 영역 파동장을 이용한 딥러닝 탄성파 역산

조준현 · 하완수*

부경대학교 에너지자원공학과

Deep-Learning Seismic Inversion using Laplace-domain wavefields

Jun Hyeon Jo and Wansoo Ha*

Department of Energy Resources Engineering, Pukyong National University

요약

지도 학습 기반 딥러닝 탄성파 역산은 소규모 영역을 대상으로 하는 합성 자료 예제에서 성공적인 역산 성능을 보여주었다. 지도 학습 기반 딥러닝 탄성파 역산은 시간 영역 파동장을 입력, 지하 속도 모델을 출력으로 사용하는데, 시간 영역 파동장은 다양한 파동 정보를 포함하고 있어 자료의 크기가 상당히 크다. 따라서 대량의 데이터로 훈련하는 지도 학습 기반 딥러닝 탄성파 역산을 현장 규모의 자료에 적용하는 연구는 아직까지 수행되지 못하고 있다. 본 연구에서는 지도 학습 기반 딥러닝 탄성파 역산 기법을 현장 규모의 자료에 적용하기 위해 시간 영역 파동장 대신 라플라스 영역 파동장을 입력으로 사용하여 지하 속도 모델을 예측하였다. 시간 영역 파동장 대신 라플라스 영역 파동장을 사용하면 결과의 해상도는 다소 떨어지지만 입력 자료의 크기가 크게 감소하여 신경망 훈련이 빨라지게 된다. 또한, 큰 격자 간격을 사용할 수 있어 현장 자료 크기의 속도 모델을 효율적으로 예측할 수 있으며 이를 통해 얻은 결과는 후속 역산의 초기 모델로 사용될 수 있다. 신경망 훈련을 위해 현장 자료 크기를 가지는 대량의 합성 속도 모델과 라플라스 영역 파동장을 생성한 후 인공 합성 자료만으로 신경망을 훈련시켰다. 또한, 해양 탄성파 탐사를 시뮬레이션하기 위해 견인 스트리머 취득 조건을 채택하였다. 테스트 자료와 벤치마크 모델을 이용한 수치 예제에서 훈련된 신경망을 테스트한 결과, 적절한 배경 속도 모델들을 얻을 수 있었다.

주요어

딥러닝, 탄성파 역산, 라플라스 영역 파동장

ABSTRACT

The supervised learning-based deep-learning seismic inversion techniques have demonstrated successful performance in synthetic data examples targeting small-scale areas. The supervised learning-based deep-learning seismic inversion uses time-domain wavefields as input and subsurface velocity models as output. Because the time-domain wavefields contain various types of wave information, the data size is considerably large. Therefore, research applying supervised learning-based deep-learning seismic inversion trained with a significant amount of field-scale data has not yet been conducted. In this study, we predict subsurface velocity models using Laplace-domain wavefields as input instead of time-domain wavefields to apply a supervised learning-based deep-learning seismic inversion technique to field-scale data. Using Laplace-domain wavefields instead of time-domain wavefields significantly reduces the size of the input data, thereby accelerating the neural network training, although the resolution of the results is reduced. Additionally, a large grid interval can be used to efficiently predict the velocity model of the field data size, and the results obtained can be used as the initial model for subsequent inversions. The neural network is trained using only synthetic data by generating a massive synthetic velocity model and Laplace-domain wavefields of the same size as the field-scale data. In addition, we adopt a towed-streamer acquisition geometry to simulate a marine seismic survey. Testing the trained network on numerical examples using the test data and a benchmark model yielded appropriate background velocity models.

KEYWORDS

deep-learning, seismic inversion, Laplace-domain wavefield

Received: 20 April 2023; Revised: 12 May 2023; Revised: 15 May 2023

*Corresponding author

E-mail: wansooaha@pknu.ac.kr

Address: 45 Yongso-Ro, Nam-Gu, Busan 48513, Republic of 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.

서 론

탄성과 탐사는 인공적으로 지하 매질에 가한 탄성과 신호를 취득, 처리 및 해석함으로써 석유 가스 저류층을 식별하는 물리탐사 기법이다. 탄성과 탐사를 통해 얻은 관측 자료를 처리하여 지하 지질 구조나 지하 매질의 물성을 파악하는 기법으로는 구조보정 속도 분석(Liu and Bleistein, 1995), 중간점 속도 분석(Yilmaz, 2001), 주시 토모그래피(Zhang *et al.*, 1998), 전파형 역산(Tarantola, 1984) 등이 있다. 전파형 역산의 경우 역산하는 영역에 따라 시간 영역(Tarantola, 1984; Gauthier *et al.*, 1986) 역산, 주파수 영역(Pratt and Worthington, 1990) 역산, 그리고 라플라스 영역(Shin and Cha, 2008) 역산 등으로 구분할 수 있다. 이러한 전통적인 탄성과 역산 기술들은 지난 수십년 동안 알고리즘이 상당히 개선되어 왔으며, 현장 자료 처리에 널리 사용되고 있다. 그러나 석유 가스 탐사에 많이 사용되는 전파형 역산 기법은 불량 조건을 가진 최적화 문제에 해당하여 참 속도 모델과 거리가 먼 초기 속도 모델을 사용하면 지역 최솟값 문제로 인해 역산에 실패할 수 있다는 한계가 있다(Virieux and Operto, 2009).

최근 컴퓨터 하드웨어 성능 발전으로 인해 딥러닝 기법을 탄성과 역산에 적용하는 사례가 점차 늘어나고 있다. 특히 복잡하고 비선형적인 다양한 문제들을 성공적으로 해결할 수 있는 심층 신경망 기법을 주로 이용하는데, 많은 연구들이 종단간 지도 학습(end-to-end supervised learning) 접근법을 채택하였다. 주시 토모그래피 또는 전파형 역산은 역산 매개변수를 반복적으로 갱신하며 속도 정보를 얻는 반면, 심층 신경망은 대량의 데이터로부터 신경망의 가중치를 반복적으로 갱신하며 속도 모델을 출력한다. 훈련을 완료한 신경망은 속도 모델 예측시 전파형 역산과 달리 지하 매개변수를 반복적으로 개선하지 않고, 신경망의 가중치를 통해 계산이 한 번에 이루어진다. 따라서 신경망 훈련은 오래 걸리지만 훈련 후 예측 비용은 무시할 수 있으며 전통적인 최적화 기법들과 달리 초기 모델이 필요하지 않다. 그러나 일반적으로 심층 신경망 기법은 훈련 데이터 세트에 대해 과대적합(overfitting)되기 쉬우므로 훈련 데이터 분포와 전혀 다른 데이터에 대한 신경망의 성능, 즉 일반화 문제에 대한 검증이 반드시 필요하다.

지도 학습 기반 딥러닝 탄성과 역산 연구로, Araya-Polo *et al.* (2019)은 적대적 생성 신경망(generative adversarial network, GAN)을 통해 보다 현실적인 속도 모델을 생성하였으며 자체 설계한 GeoDNN을 가지고 역산을 수행하였다. Yang and Ma (2019)는 탄성과 자료에 맞게 수정한 U-Net 형태의 신경망을 사용하였으며, Wang and Ma (2020)는 자연 이미지를 속도 모델로 변환하여 파동 방정식을 학습시킨 VMB_Net을 제안하였다. Li *et al.* (2020)은 특성 생성기를 추가한 인코더-디코더 구조의 SeisInvNet을 제안하였으며, Liu *et al.* (2021)은 훈련용 속도 모델 생성 알고리즘을 소개하며 SeisInvNet을 개선하였

고, Liu *et al.* (2023)은 자기 지도학습(self-supervised learning)을 도입하였다. 이러한 지도 학습 기반 딥러닝 탄성과 역산 기법들은 소규모 영역을 대상으로 하는 합성 자료 예제에서 성공적인 역산 결과들을 보여주었다. 그러나 위의 연구들은 시간 영역 파동장을 사용하기 때문에 입력 자료의 크기가 상당히 크다. 그에 따른 GPU 메모리 제한과 연산에 필요한 방대한 계산으로 인해 대량의 데이터로 훈련하는 지도 학습 기반 딥러닝 탄성과 역산을 현장 규모의 자료에 적용하는 연구는 아직까지 수행되지 못하고 있다.

본 연구에서는 지도 학습 기반 딥러닝 탄성과 역산 기법을 현장 규모의 자료에 적용하기 위해 시간 영역 파동장 대신 라플라스 영역 파동장을 입력으로 사용하여 지하 속도 모델을 예측하였다. 시간 영역 파동장 대신 라플라스 영역 파동장을 사용하면 결과의 해상도는 다소 떨어지지만 큰 격자를 사용할 수 있다는 장점이 있다. 또한 입력 자료의 크기가 크게 감소하므로 GPU 메모리 사용량과 연산량이 줄어 신경망 훈련이 빨라질 수 있다. 신경망 훈련을 위해 해저 지층 구조를 가진 속도 모델들을 자동으로 생성하였으며, 해양 탄성과 탐사를 시뮬레이션하기 위해 2차원 견인 스트리머 취득 조건을 가지고 각각의 속도 모델로부터 라플라스 영역 파동장을 생성하였다. 이러한 입력 자료를 사용하여 인코더-디코더 형태의 신경망을 훈련시킨 후 테스트 데이터 세트와 벤치마크 모델을 이용해 역산 성능을 평가하였다. 토의 절에서는 제안한 접근법의 한계, 현장 자료 적용 가능성 및 지도 학습 기반 딥러닝 탄성과 역산의 향후 연구 방향에 대해 논의하였다.

이 론

라플라스 영역 파동장을 이용한 딥러닝 역산

탄성과 탐사시 지하 지질 구조를 파악하기 위해서는 인공 탄성과 송신원을 이용해 인공 지진파를 생성하고 수신기 모음을 통해 탄성과 기록을 취득한다. 이렇게 취득한 탄성과 기록은 시간 영역 파동장이며, 본 연구에서는 일정한 밀도를 가진 2차원 음향파 파동 방정식을 사용하여 문제를 단순화하였다.

$$\frac{1}{v^2} \frac{\partial^2 u(t)}{\partial t^2} = \nabla^2 u(t) + f(t). \quad (1)$$

위 식에서 v 는 P파 속도, t 는 시간, ∇^2 은 라플라시안 연산자, $u(t)$ 는 시간 영역 파동장, 그리고 f 는 시간 영역 송신원이다. 라플라스 영역 파동 방정식은 위의 시간 영역 파동 방정식에 라플라스 변환을 적용하여 얻을 수 있다(Shin and Cha, 2008).

$$\frac{s^2}{v^2} \tilde{u}(s) = \nabla^2 \tilde{u}(s) + \tilde{f}(s), \quad (2)$$

위 식에서 s 는 라플라스 감쇠 상수, $\tilde{u}(s)$ 는 라플라스 영역

파동장, 그리고 \tilde{f} 는 라플라스 영역 송신원이다. 라플라스 영역 파동장과 송신원은 각각 시간 영역 파동장과 송신원을 라플라스 변환한 것으로, 다음과 같이 나타낼 수 있다.

$$\tilde{u}(s) = \int_0^{\infty} u(t)e^{-st} dt, \quad (3)$$

$$\tilde{f}(s) = \int_0^{\infty} f(t)e^{-st} dt, \quad (4)$$

라플라스 영역 파동장은 시간 영역에서 감쇠된 파동장의 영(zero)주파수 성분으로 간주할 수 있으며 이를 사용하는 것은 기계 학습에서 널리 사용되는 특성 공학(feature engineering)의 한 예로 볼 수 있다. 특성 공학은 도메인 지식을 활용해 모델의 성능을 향상시키거나 계산 비용을 줄이기 위해 주로 채택된다. 라플라스 영역 파동 전파 모델링시 시간 영역이나 주파수 영역 모델링에 비해 큰 격자를 사용하여 효율적으로 파동장을 얻을 수 있으며, 이를 통해 신경망의 입력 자료 뿐 아니라 출력 속도 모델의 메모리 사용량도 줄일 수 있다. 또한, 감쇠 상수를 변화시켜 천부 및 심부 지층의 정보를 포함시킬 수 있다.

일반적인 지도 학습 기반 딥러닝 탄성파 역산은 다음과 같이 나타낼 수 있다.

$$\bar{V} = N(D; \Theta) \quad (5)$$

위 식에서 \bar{V} 는 예측 속도 모델, N 은 심층 신경망, D 는 입력 탄성파 기록, Θ 는 모델 매개변수인 신경망의 가중치를 의미한다. 신경망은 탄성파 기록을 입력 받아 속도 모델을 출력한다. 앞선 연구들은 입력 탄성파 기록으로 시간 영역 파동장을 사용하였지만(Araya-Polo *et al.*, 2019; Yang and Ma, 2019; Wang and Ma, 2020; Li *et al.*, 2020; Liu *et al.*, 2021; Liu *et al.*, 2023) 본 연구에서는 라플라스 영역 파동장을 사용하였다. 지도 학습 기반 딥러닝 탄성파 역산의 손실 함수는 참 속도 모델과 신경망을 통해 예측한 속도 모델의 차이를 이용해 정의할 수 있으며, 손실 함수가 감소하도록 모델 매개변수

를 반복적으로 갱신한다. 따라서 지도 학습 기반 딥러닝 탄성파 역산은 대량의 데이터 세트(참 속도 모델 및 해당 탄성파 기록) 및 적절한 신경망 구조가 필요하다.

Tomography_CNN

라플라스 영역 파동장으로부터 바로 P파 속도 모델을 예측하기 위해 깊이별 분리 합성곱을 사용한 신경망인 Tomography_CNN을 채택하였다(Jo and Ha, 2022). 기존의 Tomography_CNN 신경망은 인코더-디코더 구조를 따르며 시간 영역 파동장을 입력 받아 속도 모델을 출력하는 구조로 설계되어 있다. 따라서 라플라스 영역 파동장을 입력으로 받고 현장 규모 크기의 속도 모델을 출력하는 신경망 구조로 수정하기 위해 맥스풀링(maxpooling) 및 업샘플링(upsampling)의 매개변수를 조정하였다. 수정된 Tomography_CNN의 구조는 Fig. 1에서 볼 수 있다. 원본 신경망과 비교하여 수정한 사항은 다음과 같다. 먼저 입력 데이터 및 출력 데이터의 크기가 각각 달라졌으며 인코더 마지막 층에 있는 드롭아웃(dropout)의 비율을 20%에서 50%로 증가시켰다. 쌍곡탄젠트(hyperbolic tangent) 활성화 함수 대신 렐루(ReLU) 활성화 함수를 사용하였으며 하나의 블록마다 수행되는 합성곱 연산을 총 세 번에서 두 번으로 축소하였다. 마지막 층에는 채널의 크기가 1이고 1×1 크기의 커널을 가진 일반 합성곱 층 이후 시그모이드(sigmoid) 함수를 추가하여 출력 속도의 범위를 1.5 km/s에서 5 km/s로 제한하였다. 신경망의 가중치 초기화는 ReLU 활성화 함수에 적합하다고 알려진 Kaiming He 초기화를 사용하였다(He *et al.*, 2015). 원본 신경망과 마찬가지로 총 9개의 합성곱 블록과 4개의 전치 합성곱 층으로 구성되어 있으며 수정된 Tomography_CNN의 총 모델 매개변수 수는 15,842,333개이다. 나머지 매개변수는 원본 신경망과 동일하다.

손실 함수

본 연구에서는 손실 함수(loss function)로 평균 절대 오차




Fig. 1. Architecture of Tomography_CNN. The ConvBlock in the model performs two convolution operations, including batch normalization, ReLU activation, and 5×5 depthwise separable convolutions. A dropout layer is implemented to randomly eliminate 50% of the features obtained from the encoder. A sigmoid function is applied to the last layer to constrain the range of the output velocity values.

(mean absolute error, MAE), 평균 제곱 오차(mean square error, MSE), 그리고 구조 유사성 지수(Structural Similarity Index, SSIM)를 함께 사용하였다. MAE는 다음과 같이 나타낼 수 있다.

$$L_{MAE} = \frac{1}{N} \sum_{i=1}^N |\bar{V}^i - V^i|. \quad (6)$$

위 식에서 V^i 는 i 번째 참 속도 모델이며, \bar{V}^i 는 i 번째 예측된 속도 모델이다. MSE는 다음과 같다.

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N (\bar{V}^i - V^i)^2. \quad (7)$$

이미지의 지역 구조를 포착할 수 있는 SSIM은 다음과 같다 (Wang *et al.*, 2004).

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}. \quad (8)$$

위 식에서 x 와 y 는 각각 두 이미지 내의 윈도우(window)를 의미하고 μ_x 와 μ_y 는 x 및 y 윈도우의 국소 평균, σ_x 와 σ_y 는 표준편차, σ_{xy} 는 x 와 y 의 교차 공분산을 나타낸다. SSIM은 추출한 두 이미지 윈도우 사이의 유사성을 측정하며 SSIM 값이 1에 가까울수록 유사성이 높다. 손실 함수 값이 감소하도록 모델 매개변수를 갱신하기 위해 SSIM의 평균 손실은 다음과 같이 정의하였다.

$$L_{ssim} = 1 - \frac{1}{N} \sum_{i=1}^N SSIM(\bar{V}_x^i, V_x^i), \quad (9)$$

Zhang and Lin (2020)은 MSE와 MAE의 조합을 손실 함수로 정의하였을 경우, MSE는 지질학적 단층을 잘 포착하고 MAE는 지질학적 인터페이스를 잘 드러낼 수 있다고 언급하였다. 본 연구에서는 MSE 및 MAE의 조합에 SSIM을 추가하여 최종 손실 함수를 다음과 같이 정의하였다(Jo and Ha, 2022).

$$L_{sum} = L_{MAE} + L_{MSE} + L_{ssim}. \quad (10)$$

훈련 자료 생성

기존의 시간 영역 파동장을 이용한 지도 학습 기반 딥러닝 탄성과 역산은 소규모 영역을 대상으로 하는 합성 속도 모델에만 초점을 맞춰 연구가 수행되었다(Table 1). 따라서 훈련된 신경망을 현장 규모의 자료에 적용하기는 어렵다. 본 연구에서는 2차원 현장 규모의 크기를 가지는 대량의 인공 속도 모델을 자동으로 생성하였으며, 라플라스 영역 파동 전파 모델링을 통해 각 속도 모델에 해당하는 라플라스 영역 파동장을 계산하여 훈련 데이터 세트를 구축하였다. 라플라스 영역 파동장을 입력 데이터로 사용하면 입력 데이터의 크기가 상당히 작아지게 되므로 제한된 계산 자원으로도 심층 신경망 훈련이 가능하며, 큰 격자를 사용한 현장 크기의 속도모델로도 신경망을 훈련시킬 수 있다. 훈련에 사용한 속도 모델은 균일한 밀도의 등방성 2차원 속도 모델들이며, 라플라스 영역 파동장은 2차원 라플라스 영역 음향파 파동 방정식(식 (2))을 이용해 생성하였다.

해저 지층 모델

해저 지층의 특징을 표현하기 위해 층서, 단층, 암염 구조 등을 가진 합성 속도 모델을 생성하였다. 총 40,000개의 속도 모델을 생성하였으며 하나의 속도 모델은 격자 간격이 100 m인 320 × 50 개의 격자점을 가진다. 따라서 속도 모델의 크기는 32 km × 5 km가 된다. 배경 속도는 1.5 km/s를 가진 물층부터 시작하여 최대 3.5 km/s까지 층이 깊어질수록 증가하며, 속도 모델을 생성할 때마다 층 속도에 무작위로 변동을 주었다. 각 속도 모델 내 층의 개수는 최소 5개에서 최대 20개까지의 균일 분포를 따른다. 층서 구조 모델의 경우 각 층의 인터페이스마다 수평 층(flat layer), 경사 층(dipping layer), 습곡 층(fold layer) 등을 무작위로 생성하였으며, 단층 및 암염 구조 모델의 경우 생성된 층서 구조 모델에 단층 또는 암염을 추가하였다. 단층면은 평면으로 가정하여 최소 1개에서 최대 6개까지의 단층을 서로 겹치지 않게 다양한 위치에 다양한 기울기를 가지도록 추가하였고, 암염의 모양은 가우시안 정규분포

Table 1. The input ($N_s \times N_r \times N_t$) and output ($N_x \times N_z$) dimensions used in previous studies that focused on supervised learning-based deep-learning seismic inversion. The last row contains the input and output dimensions used in this study for comparison.

	Number of sources (N_s)	Number of receivers (N_r)	Number of Time samples (N_t)	Velocity model ($N_x \times N_z$)	Model size (km × km)
Araya-Polo <i>et al.</i> (2019)	31	256	300	100 × 100	1 × 1
Yang and Ma (2019)	29	301	400	201 × 301	2 × 3
Wang and Ma (2020)	10	150	200	80 × 150	0.8 × 1.5
Li <i>et al.</i> (2020)	20	32	1000	100 × 100	1 × 1
Liu <i>et al.</i> (2021)	20	32	1000	100 × 100	1 × 1
Liu <i>et al.</i> (2023)	10	32	1000	100 × 100	1 × 1
Our method	200	100	4 (Damping)	320 × 50	32 × 5




Fig. 2. Examples of velocity models in training data. A total of 40,000 synthetic velocity models are categorized into three classes: (a) stratigraphic, (b) fault structure, and (c) salt structure models.

또는 타원 함수를 사용하여 정의한 뒤, 최소 1개에서 최대 3개까지의 암염을 임의의 위치에 추가하였다. 암염에서의 P파 속도는 4.5 km/s에서 5 km/s 사이의 값을 가진다. Fig. 2은 생성된 훈련 속도 모델의 예시를 보여준다. 출력 속도 모델의 크기는 $1 \times 320 \times 50$ (속도 모델 채널 \times 너비 방향 격자 개수 \times 깊이 방향 격자 개수)이다.

라플라스 영역 파동장

라플라스 영역 파동장은 식 (2)를 이용해 계산하였다. 라플라스 감쇠 상수는 4, 6, 8, 그리고 10 s^{-1} 으로 총 4개이며, 송신원 파형은 디랙 델타(dirac delta) 함수, 경계 조건은 PML 경계 조건을 사용하였다(Cohen, 2002). 송수신기 배치의 현장 해양 탄성과 탐사를 시뮬레이션하기 위해 200개의 송신원 및




Fig. 3. Examples of Laplace-domain wavefields using two-dimensional towed streamer acquisition. The acquisition configuration comprises an array of 200 sources and 100 receivers; (a) represents the input data measuring 320×200 , which are to be fed into the network; (b) shows the original Laplace-domain wavefields; and (c) shows the Laplace-domain wavefields generated by the 1st, 50th, 100th, 150th, and 200th sources with a Laplace damping constant of 4 s^{-1} .

100개의 수신기로 구성된 2차원 견인 스트리머 취득 조건을 채택하였다. 송신원 및 수신기 사이의 간격은 100 m이며 최소 오프셋은 200 m, 최대 오프셋은 10.1 km이다. 속도 모델의 간격 또한 100 m이므로 각 송신원마다 320개의 격자점에서 수신기가 위치한 100개의 격자점에만 라플라스 영역 파동장 값이 채워진다. 수신기가 없는 나머지 영역의 값은 0으로 채웠다. 입력 데이터로 사용되는 라플라스 영역 파동장의 크기는 $4 \times 320 \times 200$ (라플라스 감쇠 상수 채널 \times 너비 방향 격자 개수 \times 송신원 개수)이 된다. Fig. 3은 합성 속도 모델로부터 견인 스트리머 취득 조건으로 얻은 라플라스 영역 파동장의 예시를 보여준다.

신경망 훈련

본 절에서는 신경망 입력 자료와 하이퍼파라미터(hyper parameter)에 대해 살펴본다. 앞에서 생성한 전체 데이터 세트는 훈련 세트, 검증 세트, 테스트 세트에 각각 80%, 10%, 10% 만큼 할당하였다. 따라서 신경망에 주입한 훈련 자료는 32,000 쌍이 되고 검증 및 테스트 세트는 각각 4,000쌍을 포함한다.

라플라스 영역 파동장의 경우 다음과 같이 자연로그를 취하여 얻은 음수 값에 -1을 곱하여 입력 데이터 값을 전부 양수로 변환하여 사용하였다(Fig. 3a).

$$D(s) = -\ln(\tilde{u}(s)). \quad (11)$$

라플라스 영역 파동장(Fig. 3b, 3c)을 그대로 입력으로 사용한 경우 훈련 결과가 좋지 않았다. 송신원 근처에서만 큰 값을 가지고 나머지 값들은 송신원으로부터의 거리에 따라 지수적으로 감쇠가 되므로 신경망 업데이트시 송신원 근처의 값만 주로 사용되는 문제가 나타난 것으로 판단된다. 또한, 감쇠 상수가 큰 경우 원본 파동장을 다루기 위해서는 배정도 실수가 필요하므로 로그 파동장을 사용하는 것이 더 효율적이다. 로그 파동장을 입력으로 사용한 경우보다 로그 파동장에 -1을 곱하여 양수로 만들어 사용한 경우의 훈련 결과가 더 좋았기 때문에 수치 예제들에서는 모두 식 (11)을 입력으로 사용하였다(Fig. 3a).

초기 학습률은 $5 \times 10^{-4} \times n_{gpu}$ 이며, 여기서 n_{gpu} 은 GPU의 개수를 의미한다. Adam 옵티마이저의 변형인 AMSGrad 옵티마이저(Reddi *et al.*, 2019)를 채택하였으며, $20 \times n_{gpu}$

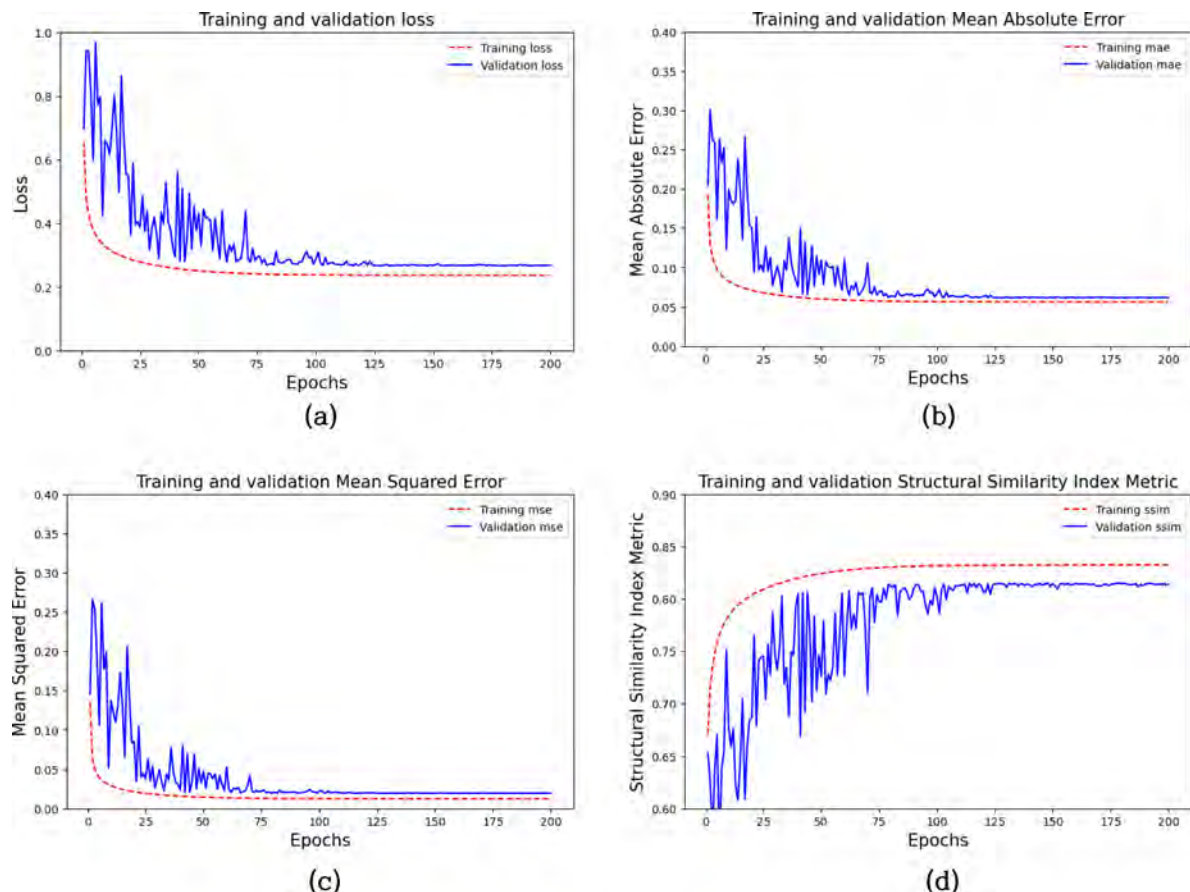


Fig. 4. Training and validation loss curves of Tomography_CNN: (a) shows the overall loss curve, whereas (b), (c), and (d) represent the mean absolute error, mean squared error, and structural similarity index, respectively.

Table 2. The loss values of Tomography_CNN after training is completed.

	Train	Validation
Total loss	0.2363	0.2660
MAE	0.0563	0.0614
MSE	0.0123	0.0195
SSIM	0.8324	0.8150

크기의 배치 사이즈를 가지고 총 200번의 에포크(epochs)로 신경망을 훈련시켰고, 에포크가 진행될 때마다 학습률을 5%씩 감소시키는 학습률 스케줄러를 사용하였다. 실험은 Nvidia Geforce RTX 3090 GPU 카드 4장을 이용하여 수행하였다. 신경망 훈련 결과, Tomography_CNN의 훈련 시간은 에포크 당 약 1분 56초가 소요되었다. 에포크에 따른 훈련 및 검증 손실 함수는 Fig. 4a에 제시하였다. MAE, MSE, SSIM 그래프는 각

각 Fig. 4b-d에 나타내었다. 참 속도모델은 고해상도 모델인 반면에 예측 결과는 저해상도 모델이므로 손실 값이 비교적 크게 나오는 것을 볼 수 있다. 각 에포크 중 가장 낮은 검증 손실을 얻었을 때의 신경망 가중치를 저장하여 테스트에 사용하였으며, 해당 지표 값들은 Table 2에 정리하였다.

결 과

훈련된 신경망과 테스트 자료를 이용해 속도 모델을 예측하였다. 테스트 자료에서 하나의 모델을 예측하는 시간은 약 2 ms가 걸렸다. 테스트 손실은 0.2671가 나왔으며, 테스트 MAE는 0.0619, MSE는 0.0198, SSIM은 0.8147가 나왔다. 예측한 속도 모델은 Fig. 5에 제시하였다. 그림을 보면 전체적으로 참 속도 모델과 유사하지만 해상도는 낮아진 예측 결과를 볼 수 있다. 시간 영역 파동장을 입력 데이터로 사용하는 지도 학습

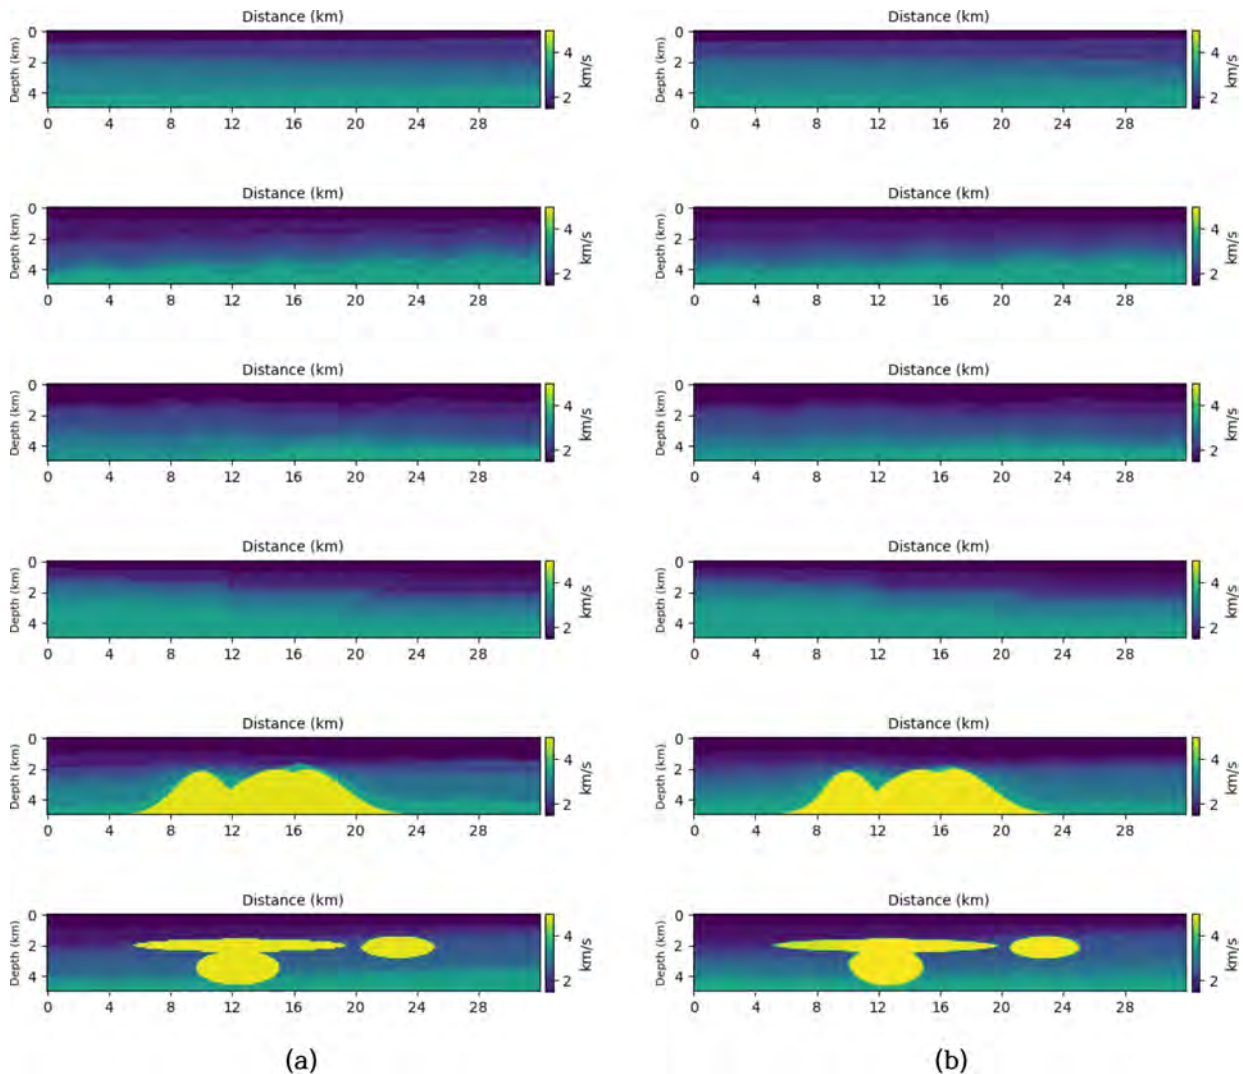


Fig. 5. Prediction results for the test dataset. The left column (a) shows the ground truth or label, and the right column (b) shows the predicted output of Tomography_CNN.




Fig. 6. The prediction result of the Pluto velocity model (Stoughton *et al.*, 2001). (a) Ground truth and (b) predicted output generated by Tomography_CNN.

기반 딥러닝 탄성과 역산에 비해 해상도는 감소하지만, 해저 지층 모델의 두드러진 특징은 잘 학습하여 층의 개수와 경계면, 암염의 위치와 형태 등을 부드럽게 구축하는 것을 확인할 수 있다. 단층의 경우 흐릿하게 예측된 것을 볼 수 있는데, 저해상도의 영향도 일부 존재하지만 라플라스 영역 파동장 이용 시 단층은 암염 구조에 비해 상대적으로 예측하기 어려운 것으로 보인다. 본 연구에서는 라플라스 영역 파동장을 사용하여 빠르게 현장 규모의 저해상도 속도 모델을 얻는 것을 목표로 하였으므로 의도한 결과를 얻은 것으로 판단된다.

Pluto 벤치마크 속도 모델을 이용한 일반화 성능 평가

훈련된 신경망을 벤치마크 모델인 Pluto 속도 모델 (Stoughton *et al.*, 2001)에 대해 테스트함으로써 신경망의 일반화 성능을 평가하였다. Pluto 속도 모델은 훈련 데이터에 사용된 속도 모델보다 훨씬 복잡하며 실제 지질 구조와 더 유사하다. 따라서 테스트 데이터에 비해 예측 성능이 떨어질 것이라 예상할 수 있다. Pluto 속도 모델은 격자 간격이 50 fts (15.24 m)로 너비가 104,000 fts, 깊이가 30,050 fts의 크기를 가진다. 신경망 훈련에 사용한 속도 모델은 격자 간격이 100 m, 너비가 32 km, 깊이가 5 km이므로 원본 Pluto 속도 모델을 바로 이용할 수 없다. 따라서, 신경망 예측을 위해 해당 속도 모델의 격자 간격, 너비 및 깊이를 훈련에 사용된 속도 모델의 크기로 보간하였다(Fig. 6a). 그런 다음, 신경망이 학습한 송수신기 배열과 동일한 견인 스트리머 취득 조건을 가지고 라플라스 영역 파동장을 생성하였다. 이 예제에서는 훈련에 사용한 것과 동일한 크기의 속도 모델을 만든 후 라플라스 영역 파동장을 생성하였으나 실제 자료와 같이 속도 모델을 수정할 수 없는 경우 라플라스 영역 파동장을 먼저 얻은 후 입력 자료 형식에 맞춰 보간하는 것도 가능하다. 훈련된 신경망으로 예측한 결과는 Fig. 6b에 제시하였다. Pluto 속도 모델에서의 총 손실은 0.8384이며, MAE는 0.2280, MSE는 0.2646, SSIM은 0.6541이 나왔다. 앞서 예상한대로 벤치마크 모델에서의 역산 성능은 테스트 데이터 세트에서의 역산 성능보다 저하되었다. 그럼에도 불구하고 배경 속도와 중앙 및 오른쪽에 있는 암염의 모양 및 위치는 잘 예측하였다. 이를 통해 본 연구에서

훈련시킨 신경망이 훈련 자료에 없는 해저 속도 모델에도 적용될 수 있음을 확인하였다.

토 의

지도 학습 기반 딥러닝 탄성과 역산은 주시 토모그래피나 전파형 역산과 같은 기존 역산 기법들과 달리 지구물리학적 지배 방정식이나 사전 지식을 반영한 초기 모델이 필요하지 않다. 대량의 데이터로부터 심층 신경망을 훈련시켜 모델 매개 변수를 자동으로 최적화함으로써 부정확한 초기 속도 모델로 인한 지역 최솟값 문제는 발생하지 않는다. 심층 신경망을 훈련시키는 비용은 상당히 높지만 일단 훈련이 완료되면 예측하는 비용은 무시할 수 있을 정도로 작다. 이러한 장점에도 불구하고 시간 영역 파동장을 입력 데이터로 사용하는 지도 학습 기반 딥러닝 탄성과 역산은 방대한 계산량으로 인해 소규모 영역을 대상으로, 소량의 송신원을 사용하는 합성 자료만 사용하여 수행되었다(Table 1).

본 연구에서는 시간 영역 파동장 대신 라플라스 영역 파동장을 입력 데이터로 사용하여 지도 학습 기반 탄성과 역산을 현장 규모의 속도 모델에도 적용할 수 있음을 보였다. 라플라스 영역 파동장은 시간 영역 파동장에 비해 자료 크기가 상당히 작으므로 신경망 훈련도 가속할 수 있었으며, 일반 합성곱 대신 깊이별 분리 합성곱을 사용함으로써 신경망 훈련을 더욱 가속할 수 있었다. 심층 신경망의 훈련 비용을 크게 줄이는 것은 심층 학습의 단점을 크게 완화할 수 있다는 점에서 중요하다. 단, 라플라스 영역 파동장을 입력 데이터로 사용하면 시간 영역 파동장에 비해 데이터 자체의 정보가 감소하므로 역산 결과의 해상도가 저하된다. 그럼에도 불구하고 해저 지층을 시뮬레이션한 합성 속도 모델 예제에서 뛰어난 결과를 얻을 수 있었으며, 훈련 데이터보다 복잡한 Pluto 속도 모델 예제에서도 합리적인 결과를 얻을 수 있었다. 본 연구에서 예측한 속도 모델은 최종 속도 모델로 사용하기 보다는 전파형 역산과 같은 후속 자료 처리를 위한 초기 모델로 사용하여 역산의 초기 모델에 대한 민감도 문제를 완화하는 것이 바람직하다.

심층 신경망 훈련에 사용한 합성 속도 모델은 실제 지층 속도 구조에 비해 단순하다는 단점이 있다. 본 연구에 사용한 속도 모델은 육상이 아닌 해저 지층만 고려했으며 균일한 밀도

의 등방성 속도 모델만 사용하였다. 라플라스 영역 파동장 또한 2차원 음향파 파동 방정식을 이용하여 생성하였다. 자동으로 대량의 속도 모델을 생성할 수 있다는 점은 장점이지만, 연구에 사용한 속도 모델은 최대 6개의 단층만 포함하며 층 경계면 구조 및 압염의 형태도 제한적이다. 따라서 좀 더 복잡하고 일반적인 속도 모델을 생성하는 방법을 고려할 필요가 있다. Araya-Polo *et al.* (2019)은 GAN을 이용하여 인공 속도 모델을 생성하였는데, 복잡한 여러 벤치마크 모델을 GAN에 주입함으로써 더욱 실제 지질 구조와 유사한 인공 속도 모델을 생성하는 것도 고려해볼 수 있다.

본 연구에서 훈련된 신경망을 실제 자료에 적용하기 위해서는 아직 해결해야 할 부분들이 있다. 비록 Pluto 속도 모델을 포함한 2차원 현장 규모 크기의 합성 속도 모델 예제에서는 충분한 역산 성능을 보여주었지만, 실제 자료에 적용하기 위해서는 잡음에 대한 연구가 필요하다. 이를 위해 추후 훈련 자료에 잡음을 포함시켜 훈련시키거나 라플라스 영역 현장 자료의 잡음을 제거한 후 사용하는 방법을 적용할 수 있다.

본 연구에서는 고정된 송수신기 배열과 고정된 크기의 속도 모델을 사용하였다. 학습에 사용된 설정이 아닌 다른 송수신기 배열 정보나 크기가 다른 속도 모델의 경우 본 연구에서 훈련된 신경망을 바로 적용하기는 어렵다. 그뿐 아니라 불균일한 밀도, 이방성, 훈련 자료 생성에 사용한 파동 방정식 등 다양한 요인들이 신경망의 일반화 성능에 영향을 미친다. 다양한 경우를 모두 고려하여 일반화 성능을 높이기 위해서는 상당히 많은 훈련 자료와 연산이 필요하다. 본 연구에서 사용한 신경망은 훈련 시간이 길지 않으므로 이러한 조건이 바뀌었을 때 해당 조건에 맞는 훈련 자료를 생성하여 새로 훈련시키는 것이 연산 효율면에서 더 바람직할 수 있다.

결 론

지하 속도 모델을 얻기 위한 기존 파형 역산 방법들은 하나의 속도 모델을 예측하는 데 시간이 오래 걸리며 역산 결과가 초기 속도 모델에 크게 의존한다는 단점이 있다. 지도 학습 기반 딥러닝 탄성과 역산은 초기 속도 모델이 필요하지 않으며, 훈련이 완료된 후의 예측 비용은 무시할 수 있다. 그러나 시간 영역 파동장을 입력 데이터로 사용하는 지도 학습 기반 딥러닝 탄성과 역산은 거대한 입력 자료 크기로 인해 신경망 훈련 비용이 상당히 높으며, 현장 규모의 자료에 적용하는 연구는 아직까지 수행되지 못하고 있다. 본 연구에서는 지도 학습 기반 딥러닝 탄성과 역산을 현장 규모의 자료에 적용하기 위해 시간 영역 파동장 대신 라플라스 영역 파동장을 입력 데이터로 사용하여 지하 속도 모델을 예측하였다. 입력 데이터로 라플라스 영역 파동장을 사용하면 역산 결과의 해상도는 떨어지지만 입력 자료의 크기가 감소하여 그만큼 신경망 훈련을 가속할 수 있다. 해저 지층을 시뮬레이션한 합성 속도 모델 예제

에서 훈련된 신경망을 테스트한 결과, 우수한 역산 결과를 얻을 수 있었으며 Pluto 벤치마크 속도 모델 예제를 통해 신경망의 일반화 능력을 확인하였다. 단, 현장 자료에 적용하기 위해서는 잡음, 송수신기 배열 변화, 더 복잡한 훈련 속도 모델, 서로 다른 크기의 속도 모델 등 실제 자료의 다양한 특징을 고려한 추가 연구가 필요하다.

감사의 글

이 성과는 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2021R1F1A1064432).

References

- Araya-Polo, M., Ferris, S., and Florez, M., 2019, Deep learning-driven velocity model building workflow, *Lead. Edge.*, **38(11)**, 872a1-872a9. doi: 10.1190/le38110872a1.1
- Cohen, G., 2002, *High-order numerical methods for transient wave equations*, Springer, 307-320. <https://hal.science/hal-01166961>
- Gauthier, O., Virieux, J., and Tarantola, A., 1986, Two-dimensional nonlinear inversion of seismic waveforms: Numerical results, *Geophysics*, **51(7)**, 1387-1403. <https://doi.org/10.1190/1.1442188>
- He, K., Zhang, X., Ren, S., and Sun, J., 2015, Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification, *Proceedings of the IEEE International Conference on Computer Vision*, 1026-1034. <https://doi.org/10.48550/arXiv.1502.01852>
- Jo, J. H., and Ha, W., 2022, Seismic velocity modeling building using depthwise separable convolutional neural network, *J. Korea Inst. Mineral Mining Eng.*, **59(2)**, 148-160. (in Korean with English abstract) <https://doi.org/10.32390/ksmer.2022.59.2.148>
- Li, S., Liu, B., Ren, Y., Chen, Y., Yang, S., Wang, Y., and Jiang, P., 2020, Deep-learning inversion of seismic data, *IEEE Trans. Geosci. Remote Sens.*, **58(3)**, 2135-2149. <https://ieeexplore.ieee.org/document/8931232>
- Liu, Z., and Bleistein, N., 1995, Migration velocity analysis: Theory and an iterative algorithm, *Geophysics*, **60(1)**, 142-153. <https://doi.org/10.1190/1.1443741>
- Liu, B., Yang, S., Ren, Y., Xu, X., Jiang, P., and Chen, Y., 2021, Deep-learning seismic full-waveform inversion for realistic structural models, *Geophysics*, **86(1)**, R31-R44. <https://doi.org/10.1190/geo2019-0435.1>
- Liu, B., Jiang, P., Wang, Q., Ren, Y., Yang, S., and Cohn, A. G., 2023, Physics-driven self-supervised learning system for seismic velocity inversion, *Geophysics*, **88(2)**, R145-R161. <https://doi.org/10.1190/geo2021-0302.1>
- Pratt, R. G., and Worthington, M. H., 1990, Inverse theory

- applied to multi-source cross-hole tomography. Part 1: acoustic wave-equation method, *Geophys. Prospect.*, **38(3)**, 287-310. <https://doi.org/10.1111/j.1365-2478.1990.tb01846.x>
- Reddi, S. J., Kale, S., and Kumar, S., 2019, On the convergence of adam and beyond, arXiv preprint arXiv:1904.09237. <https://doi.org/10.48550/arXiv.1904.09237>
- Shin, C., and Cha, Y., 2008, Waveform inversion in the Laplace domain, *Geophys. J. Int.*, **173(3)**, 922-931. doi: 10.1111/j.1365-246X.2008.03768.x
- Stoughton, D., Stefani, J., and Michell, S., 2001, 2D elastic model for wavefield investigations of subsalt objectives, deep water Gulf of Mexico, *SEG Technical Program Expanded Abstracts*, 1269-1272. <https://doi.org/10.1190/1.1816325>
- Tarantola, A., 1984, Inversion of seismic reflection data in the acoustic approximation, *Geophysics*, **49(8)**, 1259-1266. <https://doi.org/10.1190/1.1441754>
- Virieux, J., and Operto, S., 2009, An overview of full-waveform inversion in exploration geophysics, *Geophysics*, **74(6)**, WCC1-WCC26. <https://doi.org/10.1190/1.3238367>
- Wang, W., and Ma, J., 2020, Velocity model building in a crosswell acquisition geometry with image-trained artificial neural networks, *Geophysics*, **85(2)**, U31-U46. <https://doi.org/10.1190/geo2018-0591.1>
- Wang, Z., Bovik, A. C., Sheikh, H. R., and Simoncelli, E. P., 2004, Image quality assessment: from error visibility to structural similarity, *IEEE Transactions on Image Processing*, **13(4)**, 600-612. <https://ieeexplore.ieee.org/document/1284395>
- Yang, F., and Ma, J., 2019, Deep-learning inversion: A next-generation seismic velocity model building method, *Geophysics*, **84(4)**, R583-R599. <https://doi.org/10.1190/geo2018-0249.1>
- Yilmaz, Ö., 2001, *Seismic data analysis: processing, inversion and interpretation of seismic data*, Vol. I, *Soc. Expl. Geophys.*, 288-323. doi: 10.1190/1.9781560801580.fm
- Zhang, J., Brink, U. S., and Toksoz, M. N., 1998, Nonlinear refraction and reflection travel time tomography, *J. Geophys. Res. Solid Earth*, **103(B12)**, 29743-29757. <https://doi.org/10.1029/98JB01981>
- Zhang, Z., and Lin, Y., 2020, Data-driven seismic waveform inversion: A study on the robustness and generalization, *IEEE Trans. Geosci. Remote Sens.*, **58(10)**, 6900-6913. <https://ieeexplore.ieee.org/document/9044635>