

심층학습을 이용한 전이대 두께 예측

장성형* · 이동훈 · 김병엽

한국지질자원연구원 해저지질에너지연구본부

Thickness Estimation of Transition Layer using Deep Learning

Seonghyung Jang*, Donghoon Lee, and Byoungyeop Kim

Marine Geology & Energy Research Div., KIGAM

요약

CO₂ 주입 후 저류층은 암석물리 특성이 변하므로 이 연구에서는 저류층을 물성이 선형으로 변하는 전이대 지층모델로 구성한다. 울프 반사계수 함수는 전이대 상하지층의 속도비, 주파수, 전이대 두께 함수로 구성되어 있어 저류층 두께나 해저면 전이대 두께를 추정하는데 활용할 수 있다. 이 연구에서는 심층학습을 이용하여 전이대 두께를 예측 방법을 제안한다. 심층학습을 적용하기 위해 사암 저류층, 셰일 덮개암으로 구성된 인공 전이대 지층모델에 두께에 따른 울프 반사계수 모델링을 수행하고 시간-스펙트럼 영상자료를 확보하였다. 두께 별 시간-주파수 스펙트럼 영상과 중합단면도 트레이스에서 구한 시간-주파수 스펙트럼 비교로부터 구한 두께 추정결과는 항상 정확하게 전이대의 두께를 제시하지는 못하였다. 그러나 다양한 환경에서 학습자료를 확보하고 정확도를 높이면 현장자료적용이 가능할 것으로 본다.

주요어

전이대, 해저면 퇴적층, 저류층, 울프 반사계수, 심층학습

ABSTRACT

The physical properties of rocks in reservoirs change after CO₂ injection, we modeled a reservoir with a transition zone within which the physical properties change linearly. The function of the Wolf reflection coefficient consists of the velocity ratio of the upper and lower layers, the frequency, and the thickness of the transition zone. This function can be used to estimate the thickness of a reservoir or seafloor transition zone. In this study, we propose a method for predicting the thickness of the transition zone using deep learning. To apply deep learning, we modeled the thickness-dependent Wolf reflection coefficient on an artificial transition zone formation model consisting of sandstone reservoir and shale cap rock and generated time-frequency spectral images using the continuous wavelet transform. Although thickness estimation performed by comparing spectral images according to different thicknesses and a spectral image from a trace of the seismic stack did not always provide accurate thicknesses, it can be applied to field data by obtaining training data in various environments and thus improving its accuracy.

KEYWORDS

transition zone, water bottom sediment, reservoir, wolf reflectivity, deep learning

서론

전이대는 지층 속도가 연속적으로 변하는 구간이다. 대표적인 예로 속도가 연속적으로 증가하는 해저면 구간이나 속도가 연속적으로 감소하는 저류층을 들 수 있다. 전이대 두께는 저

류층 평가, 매장량 계산, 연안에서 해양공학 설계 등에서 필요한 중요한 요소중 하나이다. 전이대 지층모델에서 탄성파 반사계수 계산은 연속으로 속도가 변하는 수직입사 반사계수를 이용한다. 반사층 두께가 파장의 1/4 보다 작은 얇은 지층이 서로 겹겹이 쌓여 있는 곳에 하향파가 반사되면 반사파는 중첩

Received: 21 September 2023; Revised: 20 October 2023; Accepted: 06 November 2023

*Corresponding author

E-mail: shjang@kigam.re.kr

Address: 124 Gwahak-no, Yuseong-gu, Daejeon 34132, 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.

되어 보강 또는 소멸 간섭이 발생하고 탄성과 진폭 변화가 일어난다(Widess, 1982). 또한 반사파 간섭효과로 주파수와 반사파 속도가 변하게 되어 반사계수가 달라진다(Liner and Bodmann, 2010; Liner, 2012). 전이대에서 수직입사파에 대한 대표적인 반사계수 모델링으로 울프 모델링(Wolf, 1937)을 들 수 있다. 울프 모델링에서 반사계수는 상하지층의 속도비, 주파수, 전이대 두께의 함수로 구성되어 있어 저류층 두께나 해저면 전이대 두께를 예측하는데 활용할 수 있다. 전통적으로 시간영역 탄성과 단면도에서 지층두께 예측은 최대, 최소 반사파 진폭을 이용하는 경우(Widess, 1982), 시간-주파수 스펙트럼 분해를 이용하여 두께와 지층경계면을 구별하는 경우(Partyka *et al.*, 1999; Marfurt and Kirlin, 2001), 탄성과 트레이스의 순간 최대 주파수 이용하는 경우(Liu and Marfurt, 2006)를 들 수 있다. Liner(2012)는 구조보정을 적용한 시간영역 중합단면도에서 해저면 전이대를 추정하는 방법으로 울프 모델링과 시간-주파수 스펙트럼을 제안하였다. 이 방법은 현장 중합단면도의 특정 트레이스에 해당하는 시간-주파수 스펙트럼과 전이대 두께별 울프 모델링 결과에 해당하는 시간-주파수 스펙트럼을 비교하여 간접적으로 두께를 추정하는 방식이다. 이 방법은 시간-주파수 스펙트럼 차이를 육안으로 비교하여 모델링에 적용한 전이대 두께를 정성적으로 예측하므로 주관적이며 실제 현장자료에 적용하기에도 한계가 있다. 따라서 시간-주파수 스펙트럼 차이 구별에 기계학습을 이용할 수 있다면 객관적이면서도 수월하게 그 차이를 판단할 수 있다.

탄성과 자료처리는 이론기반 방식과 자료기반 방식 두 가지로 나눌 수 있다(Harsuki and Alkhalifah, 2022). 이론기반 방식은 파동전파에 관한 물리적 현상을 이용하는 전통적인 자료처리라고 할 수 있다. 자료기반 방식은 복잡한 현장조건에서 취득한 자료가 품질이 좋지 않은 경우 적용할 수 있는 방법이다. 이 방법은 자료 자체에만 의존하고 또한 물리적 이론에 제한을 받지 않아 복잡한 원시자료를 유연하게 처리할 수 있는 장점이 있다. 대표적인 자료기반 방식으로 기계학습을 이용하는 자료처리 방법을 들 수 있다. 기계학습은 인공지능의 한 분야로 자료에서 특징을 찾아내고 이것을 학습하여 유용한 정보를 찾아낸다(Jia and Ma, 2017). 탄성과 자료처리 분야에서는 전통적인 자료처리 방법보다 쉽고 간편하게 적용할 수 있거나 해결하기 어려운 자료에 대해 기계학습 방법을 적용하는 노력이 지속되고 있다. 자료처리 기술 발전, 컴퓨터 계산능력 향상, 다양한 인공 신경망 알고리즘 및 라이브러리(Application Programming Interface, API) 개발, 쉽게 접근할 수 있는 프로그래밍 언어 개발로 기계학습 기술을 적용할 수 있는 기회가 많아졌으며 자료처리 분야에서도 새로운 기술을 개발하려는 노력이 계속되고 있다(Naeini and Prindle, 2018). 다양한 인공 신경망 알고리즘으로 생성적 대립 신경망(Generative Adversarial Network, GAN)(Goodfellow *et al.*, 2020), 유넷(U-shaped Network, U-Net) 합성곱 신경망(Convolution Neural Network,

CNN)(Ronneberger *et al.*, 2015), 자연어 처리(Natural Language Processing, NLP)에 이용하는 장단기 기억 모델(Long-Short Term Memory, LSTM)(Sak *et al.*, 2014) 등 영상처리 및 분석에 적합한 기계학습 알고리즘을 들 수 있다. 이러한 신경망은 최근 몇 년 동안 기계학습을 기반으로 하는 자료처리 연구의 초기 발전을 주도하고 있다. 석유탐사분야에서는 탐사설계, 자료취득, 자료처리 및 자료해석에서 많은 자료가 생산되고 있어 기계학습 활용사례가 증가하고 있다(Jia and Ma, 2017). 탄성과 자료처리에서 기계학습 적용 사례는 잡음 줄이기 분야(Yu *et al.*, 2019; Zhang *et al.*, 2019; Zhong *et al.*, 2021; Cho and Pyun, 2023), 탄성과 트레이스 내삽 분야(Oliveira *et al.*, 2018; Kaur *et al.*, 2020; Ovcharenko and Hou, 2020; Yeeh *et al.*, 2023), 탄성과 역산 분야(Röth and Tarantola, 1994; Lewis and Vigh, 2017; Yang and Ma, 2019; Mosser *et al.*, 2020; He and Wang, 2021; Park *et al.*, 2021; Li *et al.*, 2022; Jo and Ha, 2023), 신호대 잡음비를 높이는 연구(Ovcharenko, *et al.*, 2019; Sun and Alkhalifah, 2019; Li and Ma, 2021; Kim and Jun, 2022), 탄성과 초동 결정문제(Ma and Luo, 2018; Tsai, *et al.*, 2019; Wang, *et al.*, 2019; Ozawa, 2023), 탄성과 자료 복원을 위한 탄성과 외삽 문제에 적용한 경우(Ovcharenko *et al.*, 2019; Plotnitskii, *et al.*, 2019; Fang *et al.*, 2021; Sun *et al.*, 2023)를 들 수 있다.

이 연구에서는 수치모델링을 통해 전이대 두께에 따른 반사계수 특성을 살펴보고 속도가 연속적으로 감소하는 탄화수소 또는 CO₂ 저류층과 같은 모델에서 시간 변화에 따른 주파수 변화 특성을 이용하여 전이대 두께를 추정하는 방법을 제안한다. 저류층 두께 예측은 영오프셋(zero offset) 탄성과 신호음에 해당하는 시간-스펙트럼 영상과 두께별 시간-스펙트럼 영상을 비교하여 가장 근접한 영상을 효과적으로 찾을 수 있는 심층학습을 이용한다. 심층학습은 인공 신경망을 여러 층으로 구성하여 학습에 적용하는 기계학습의 한 분야이다(Deng and Yu, 2014). 합성곱 신경망(Convolutional Neural Network: CNN, ConvNet)(LeCun *et al.*, 2015)은 심층학습 알고리즘의 하나로 완전연결 신경망에 비해 계산량이 줄어들어 영상자료에서 객체검출, 분류, 회귀 또는 음성, 시계열, 신호자료를 분류하는데 매우 효과적이다. CNN은 합성곱 층과 풀링 층으로 구성하고 영상자료를 처리하는 심층학습에서 중요한 역할을 한다. 이 연구에서는 CNN 알고리즘 가운데 VGGNet-19(Visual Geometry Group Net)(Simonyan and Zisserman, 2015)을 이용한다.

울프 전이대에서 탄성과 반사계수

임피던스 차이가 있는 매질에서 탄성과가 수직입사 할 때 탄성과 반사계수는 수직입사 탄성과 파장 함수로 정의할 수 있다(Wolf, 1937; Liner and Bodmann, 2010). 탄성과 파장이 전이대 두께보다 훨씬 큰 경우 임피던스 변화는 무시할 수 있

어 반사계수는 밀도가 일정할 경우 단순히 상하 지층 속도함수로 표현할 수 있다. 그러나 파장이 매우 짧은 경우 전파 매질에는 의미 있는 불연속면이 존재하지 않아 전혀 반사가 일어나지 않기 때문에 반사계수를 단순한 상하지층 속도함수로 나타낼 수 없게 된다(Sezawa and Kanai, 1935; Wolf, 1937). 탄성과 속도가 선형적으로 변하는 전이대에서는 반사파가 주파수 영향을 받는다(Wolf, 1937; Liner and Bodmann, 2010). 임피던스 불연속으로 탄성과 반사계수가 발생하고 반사파가 주파수에 따라 달라지면 반사계수 간섭이 일어나게 된다. 단일 반사파에서는 고유 반사계수 분산(intrinsic reflectivity dispersion)이 일어나고, 여러 탄성과 이벤트의 상호 간섭으로 겹보기 반사계수 분산(apparent reflectivity dispersion)이 발생한다. 혼합형 분산은 위 두 가지 분산 조합으로 볼 수 있다. 탄성과 반사계수 분산 발생 원인이 밝혀진 경우는 많지 않지만 대체로 그 원인을 i) 고르지 못한 반사 경계면에서 발생하는 산란(Clay and Medwin, 1977), ii) 다공질 매질을 분리하는 경계면에서 발생하는 반사파(Dutta and Ode, 1983), iii) 수직 전이대 구간에서 발생하는 경우(Wolf, 1937; Liner and Bodmann, 2010)로 들 수 있다. 반사파 분산 모델링과 분산을 구별하는 것은 탄성과 정량적 해석에도 필요하다. Wolf(1937)는 점차로 속도가 변하는 전이대에서 P 파 수직입사 반사파를 연구하였다. 이 연구에서는 Wolf 반사계수를 살펴보고 탄성과 속도가 연속으로 변하는 해저면 전이대, 저류층 전이대에서 두께를 예측하는 방법을 살펴본다.

연속으로 탄성과 속도가 변하는 전이대에서 P 파의 수직입사 반사계수는 다음과 같이 1 차원 파동방정식에서 구할 수 있다(Wolf, 1937).

$$\frac{\partial^2 u}{\partial t^2} = \frac{\partial}{\partial z} \left(V^2 \frac{\partial u}{\partial z} \right). \tag{1}$$

여기서 u 는 수직방향 P 파 파동장이다. 전이대를 포함하고 있는 속도모델 V 는




Fig. 1. Transition layer model. V is the velocity of the transition layer, and V_1 and V_2 are the velocities above and below the transition layer.

$$\begin{aligned} V &= v && \text{for } z < 0, \\ V &= v \left(1 + \frac{k-1}{h} z \right) && \text{for } 0 < z < h, \\ V &= kv && \text{for } h < z, \end{aligned} \tag{2}$$

으로 정의할 수 있다(Fig. 1). 여기서 h 는 전이대 두께이다. 평면 조화파를 식 (1)에 대입하고 개별 속도층에서 파동장을 구하면

$$\begin{aligned} u(x,t) &= \exp^{i\omega(t \pm x/v)} && \text{for } z < 0, \\ u(x,t) &= \exp^{i\omega(t \pm x/kv)} && \text{for } h < z, \end{aligned} \tag{3}$$

이다. 전이대($0 < z < h$)에서 속도를 다음과 같이 s 로 정의하고

$$s(z) = v \left(1 + \frac{k-1}{h} z \right), \tag{4}$$

깊이에 대해 미분하면

$$\frac{\partial s}{\partial z} = \frac{v(k-1)}{h}, \tag{5}$$

이다. 식 (1)에서 변수 z 에 대한 편미분을 변수 s 에 대한 편미분으로 변환하면 각각

$$\frac{\partial}{\partial z} = \frac{\partial s}{\partial z} \frac{\partial}{\partial s} = \frac{v(k-1)}{h} \frac{\partial}{\partial s}, \tag{6}$$

$$\frac{\partial u}{\partial z} = \frac{\partial s}{\partial z} \frac{\partial u}{\partial s} = \frac{v(k-1)}{h} \frac{\partial u}{\partial s},$$

이다. 위식을 식 (1)에 대입하고 주파수 영역으로 변환하면

$$\frac{v^2}{h^2} (k-1)^2 \frac{\partial}{\partial s} s^2 \frac{\partial u}{\partial s} = -\omega^2 u, \tag{7}$$

이다. 여기서 $u = u(s, w)$ 이고 w 는 각주파수이다(angular frequency). 흡수계수를 포함한 주파수 변수

$$\bar{\omega} = \frac{\omega}{v \left(1 + \frac{k-1}{h} \right)}, \tag{8}$$

를 적용하면 주파수 영역으로 변환한 파동방정식은

$$s^2 \frac{\partial^2 u}{\partial z^2} + 2s \frac{\partial u}{\partial s} + \bar{\omega}^2 u = 0, \tag{9}$$

이다. 여기서 $u = u(s, \bar{\omega})$ 이다. 이와 같은 미분방정식은 멱급수(power series)

$$u = cs^m, \tag{10}$$

를 이용하여 해를 구하는 것이 편리하다. 여기서 c 는 전이대에서 속도함수 s 의 상수이다. 시험해(trial solution)를 설정하

여 변환 파동방정식에 대입하면 초월함수로 이루어진 다항식 선형조합 방정식이 된다.

$$m(m-1) + 2mu + \bar{\omega}^2 u = 0, \quad (11)$$

$$m^2 + m + \frac{\omega^2 h^2}{(k-1)^2 v^2} = 0. \quad (12)$$

여기서 m 은 위 다항식에서 두 개 근호값에 해당한다. 탄성계수는 $z=0$ 과 $z=h$ 에서 연속함수이므로 u 와 $\frac{\partial u}{\partial z}$ 도 연속이 되어야 한다. 이 경계조건을 적용하고 식 (3)과 식 (12)로부터 전이대에서 주파수에 종속하는 수직입사 반사계수를 구할 수 있다(Wolf, 1937; Liner and Bodmann, 2010).

$$R_w(f) = \frac{1}{2\sigma + 2\gamma \coth(\gamma \log k)}. \quad (13)$$

여기서 σ 와 γ 는 주파수에 따라 변하는 함수로 각각

$$\sigma(f) = \frac{i2\pi fh}{(k-1)v}, \quad (14)$$

$$\gamma(f) = \sqrt{1/4 + \sigma^2}, \quad (15)$$

이며, k 는 상부층과 하부층의 속도비율, f 는 주파수(Hz)를 나

타낸다. $R_w(f)$ 는 주파수에 대한 복소수 함수이며 주파수가 “0” 일 때 절댓값이 최대이다. 이때 전이대 두께는 파장에 비해 무시할 수 있을 정도가 되어 전이대층이 없는 수직 반사계수식이 된다. 주파수가 “0”에서부터 점점 커질수록 반사계수는 초기에는 조금씩 작아지다가 급격하게 감소한다(Wolf, 1937). 울프 반사계수를 $R_w=0$ 으로 하면 다음과 같이 단절 주파수(cut-off frequency)를 구할 수 있다.

$$f_n = \frac{v(k-1)}{2h} \sqrt{\left(\frac{n}{\log k}\right)^2 + \frac{1}{4\pi^2}}. \quad (16)$$

시간영역 탄성과 트레이스 신호음에 대한 스펙트럴 분해를 이용하여 전이대 반사계수 특성을 분석하면 전이대 두께와 속도비율을 구할 수 있다(Liner and Bodmann, 2010). 울프 전이대 속도모델에서 구한 시간영역 신호음에 스펙트럴 분해를 적용하고 시간-주파수 영역에서 스펙트럼 거동 분석으로 두께와 속도비율을 예측하게 된다.

울프 전이대 수치모형실험

속도가 증가하는 전이대의 경우는 해저면 모델을, 속도가 감소하는 전이대 모델을 저류층 모델로 가정하여 수치모델링을 수행하였다. 해저면 모델의 경우 전이층에서 탄성과 속도가

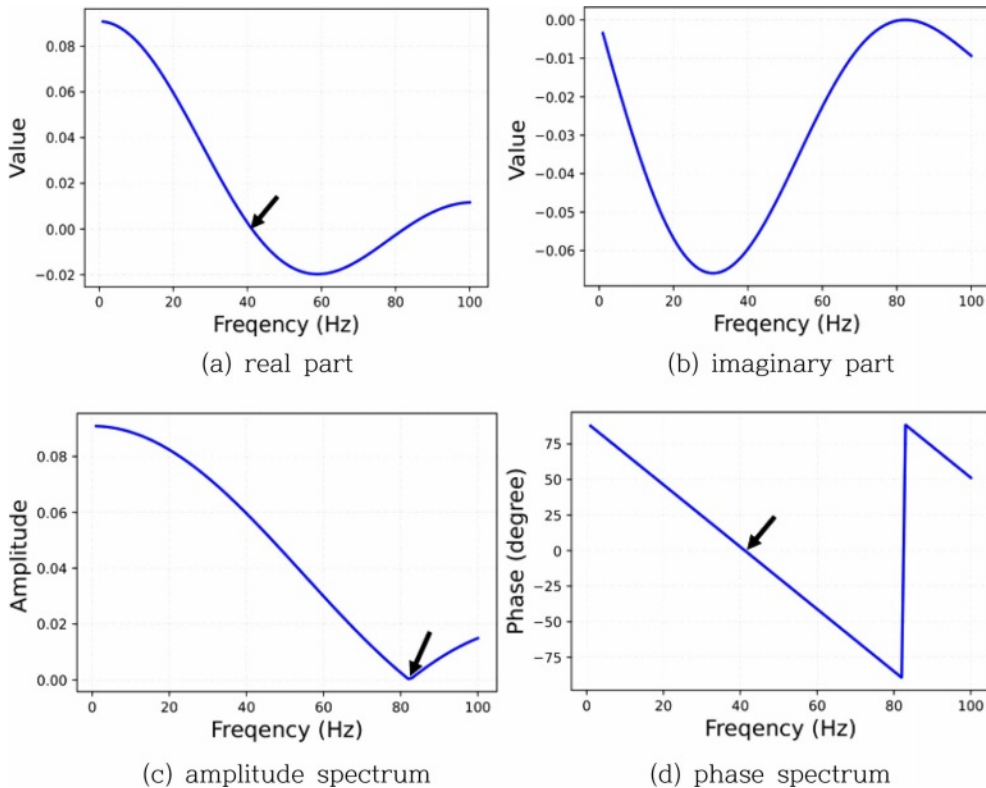


Fig. 2. Wolf reflectivity modeling at a 10 m thick transition zone for a water bottom model. Each arrow indicates the zero-crossing frequency, which is the phase-change point.

1500 m/s에서 1800 m/s까지 증가하고 전이대 최대 두께는 10 m, 50 m로 반사계수 모델링을 수행하였다. 저류층 모델의 경우 전이층에서 탄성파 속도는 3000 m/s에서 2200 m/s까지 감소하고 전이대 최대 두께는 10 m, 50 m로 반사계수 모델링을 수행하였다. Fig. 2는 해저면 전이대 두께가 10 m 일 때 모델링 결과이다. Fig. 2a는 울프 반사계수의 실수부이며 화살표 41 Hz에서 위상변화가 발생하는 것을 알 수 있다. Fig. 2b는 울프 반사계수의 허수부, Fig. 2c는 진폭, 그리고 Fig. 2d는 위상을 나타낸다. Fig. 2c를 살펴보면 진폭은 첫 번째 단절 주파수인 82 Hz까지 주파수가 증가함에 따라 감소하고 이후 조금씩 증가하는 현상이 나타난다. Fig. 2d 위상변화 그래프를 보면 41 Hz에서 위상이 바뀌는 것을 확인할 수 있다. Fig. 3은 해저면 전이대 두께가 50 m 일 때 모델링 결과이다. Fig. 3a는 울프 반사계수의 실수부, Fig. 3b는 울프 반사계수의 허수부, Fig. 3c는 진폭 그리고 Fig. 3d는 위상을 나타낸다. 울프 반사계수 실수부 그래프에서 위상을 살펴보면 8.4 Hz, 16 Hz, 23 Hz에서 반복적으로 위상변화가 일어나는 것을 알 수 있다. 진폭 그래프 Fig. 3c에서 대표적인 단절 주파수는 16 Hz, 23 Hz, 28 Hz, 33 Hz 이다. 첫 번째 단절 주파수까지는 진폭이 크게 감소하고 이후 단절 주파수에서는 증가하다가 감소하는 경향이 반복적으로 나타난다. 위상 그래프 Fig. 3d는 16 Hz,

23 Hz, 28 Hz, 33 Hz에서 위상이 바뀌는 것을 알 수 있다. 한편, 저류층 모델에서 전이대 두께에 따른 진폭 및 위상 변화는 Fig. 4와 Fig. 5에 있다. 저류층 구간을 사암층으로, 상부 덮개 암은 셰일층으로 구성하여 전이대 지층모델을 구성하였다. Fig. 4는 저류층 전이대 두께가 10 m 일 때 울프 모델링 결과이다. 주파수가 커질수록 진폭이 작아지고 64 Hz에서 위상이 변한다. Fig. 5는 전이대 두께가 50 m 일 때 울프 모델링 결과로 진폭 및 위상 변화 그래프이다. Fig. 5a와 Fig. 5b는 울프 반사계수 실수부와 허수부, Fig. 5c와 Fig. 5d 그래프는 진폭변화 그래프로 단절 주파수가 각각 25 Hz, 52 Hz, 77 Hz임을 알 수 있다. 위상 그래프 Fig. 5d에서는 13 Hz, 38 Hz, 64 Hz, 90 Hz에서 위상이 변한다. 전이대 수치모델링으로부터 속도모델, 전이대 두께, 주파수 성분에 따라 진폭과 위상 변화를 확인할 수 있다. 일반적으로 주파수 성분에 영향을 받는 반사파 거동을 살펴보기 위해서 시간-주파수 영역 스펙트럼 분해를 이용한다. 시간영역 신호음에 대한 푸리에 변환은 주파수 정보만을 확인할 수 있다. 이를 보완한 국소 푸리에 변환(Short Time Fourier Transform: STFT)(Allen, 1977; Chakraborty and Okaya, 1995)은 주파수 정보의 시간 단위로 주파수를 분석할 수 있으나 해상도가 좋지 못하다. 연속 파형요소 변환(Continuous Wavelet Transform: CWT)은 싸인(sine), 코싸인

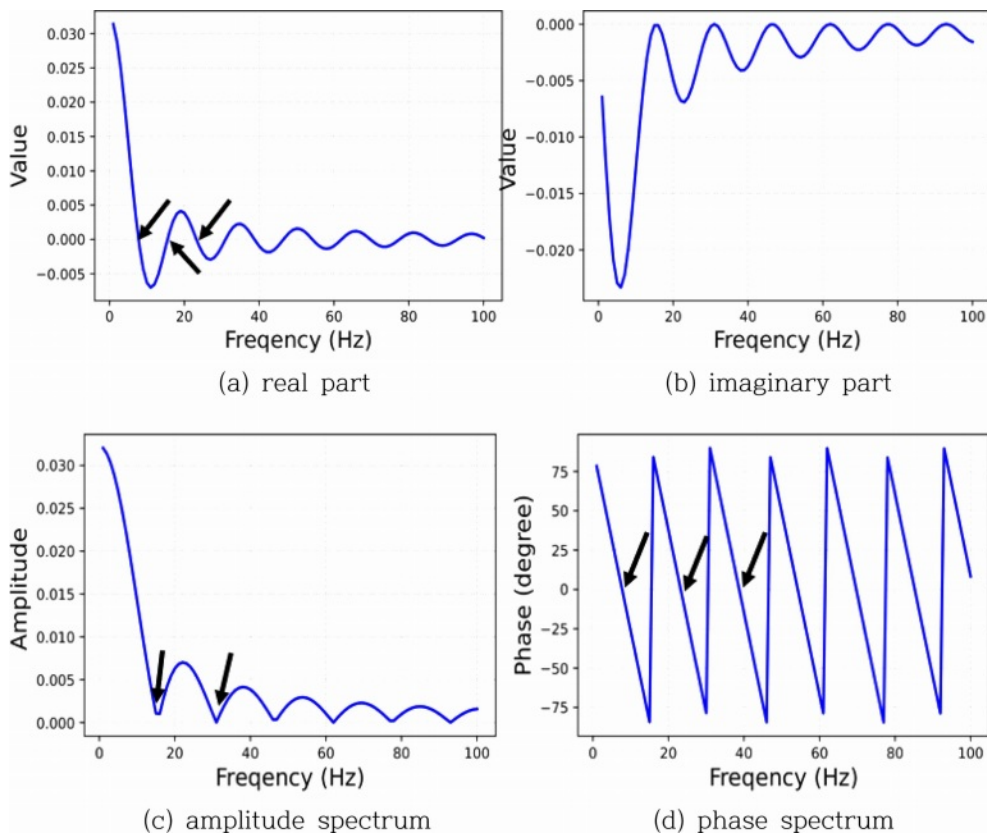


Fig. 3. Wolf reflectivity modeling at a 50 m thick transition zone for a water bottom model. Each arrow indicates the zero-crossing frequency, which is the phase-change point.




Fig. 4. Wolf reflectivity modeling at a 10 m thick transition zone for a reservoir model.

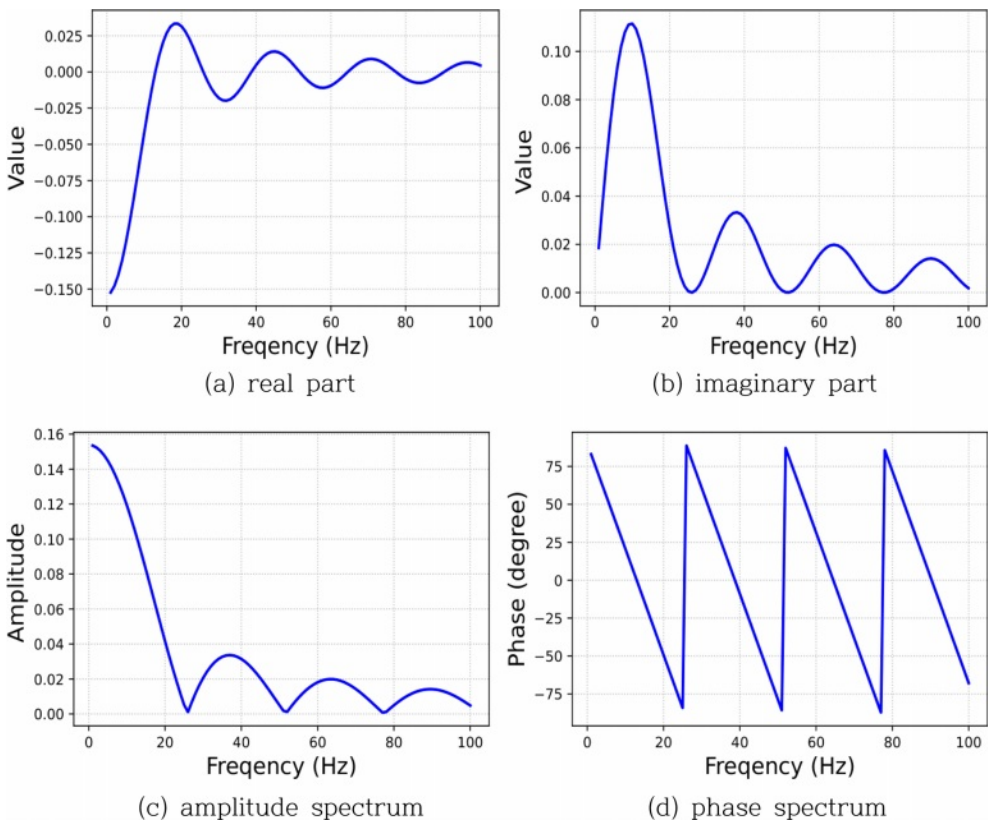


Fig. 5. Wolf reflectivity modeling at a 50 m thick transition zone for a reservoir model.




Fig. 6. Time-frequency spectrum for different thicknesses of transition layers with a water bottom model. Each arrow shows the estimated-cutoff frequency.

(cosine) 함수 대신 다양한 파형요소를 기저함수로 이용하고 있어 시간과 주파수 영역에서 높은 해상도를 유지할 수 있다 (Goupillaud *et al.*, 1984; Addison, 2018). 연속 파형요소 변환 결과는 시간-주파수 영역에서 에너지 크기 정도를 나타내고 있어 전이대 두께에 따라 달라지는 단절 주파수 변화를 이용하여 해저면 전이대 두께를 예측하는데 응용할 수 있다. Fig. 6은 속도가 점점 커지는 해저면 전이대 두께에 대한 시간-주파수 스펙트럼 결과이다. 그림에서 보듯이 전이대 두께가 커질수록 세로방향으로 나타나는 단절 주파수가 점점 증가하는 양상을 볼 수 있다. 주파수에 따라 에너지 연속성이 단절되는 부분이 발생하고 특정 주파수 대역보다 높은 곳에서는 에너지가 감소하는 현상을 관찰할 수 있다. 이 연구에서는 탄성과 중합 단면도 트레이스에 대한 시간-주파수 스펙트럼 분석을 심층학습을 통해 분석하여 전이대 두께를 예측하고자 한다. 전이대 두께는 탄화수소 매장량 평가나 연안에서 해양 구조물 설치를 위한 공학설계에 주요 인자이므로 구조보정을 마친 중합 단면도에서 전이대 두께를 구할 수 있는 방법이 필요하다. 탄성과 중합자료는 영음셋 수직 반사파 자료로 울프 반사파 모델링을 적용할 수 있는 자료구조이다. 시간-주파수 스펙트럼은 탄성파 트레이스에 연속 파형요소 변환으로 구하고 이로부터 단절 주파수와 에너지 감소영역을 확인하여 전이대 두께를 예측하고자 한다.

심층학습 이용 전이대 두께 추정

심층학습을 이용하여 전이대 두께를 추정하는 것은 전이대 두께 별 모델링 결과에 대한 시간-주파수 스펙트럼 영상자료와 입력 트레이스의 시간-주파수 스펙트럼 영상자료가 가장 유사한 영상자료를 찾는 문제로 영상자료 분류에 해당한다. 이 연구에서는 심층학습 가운데 합성곱 신경망을 이용하여 육안으로 식별하기 어려운 시간-주파수 스펙트럼 차이를 효과적으로 구별하고 전이대 두께를 예측하는 방법을 제안한다. CNN은 합성곱 계층과 풀링 계층으로 구성되어 있다. 특히 비선형 자료처리가 용이하여 영상분류, 목적지 방향 결정, 영상자료 증강(image augmentation) 분야에 적용하고 있다. 또한 입력영상을 여러 층으로 구성된 신경망에 적용하기 전에 1차원 배열로 펼치는 과정 없이 각 층이 2차원 배열과 연결이 쉽기 때문에 영상자료를 처리하는 심층학습에 유용하다. CNN 장점중 하나는 입력정보에서 특정 정보만을 추출하고 이것을 학습에 사용하기 때문에 학습과정에서 발생하는 복잡한 연산량을 줄이면서 필요한 정보를 충분히 활용할 수 있다는 것이다. 여기에서는 여러 CNN 알고리즘(LeNet, LeCun *et al.*, 1989; AlexNet, Krizhevsky *et al.*, 2017; ZFNet, Zeiler and Fergus, 2014; GoogLeNet, Szegedy *et al.*, 2015; VGGNet, Simonyan and Zisserman, 2015; ResNet, He *et al.*, 2016) 가운데




Fig. 7. VGGNet-19 model architecture comprised of 16 convolutional layers, seven max poolings, and three fully connected layers.




Fig. 8. Time-frequency spectrum for transition layers with different thickness. The number on the top of each image is the transition layer thickness within the reservoir model.

VGGNet-19을 전이대 두께를 예측에 이용하였다. VGGNet-19 모델 예제는 손모양 비교 사례에서 쉽게 찾을 수 있다 (Nithyashree, 2021). VGGNet-19 기본 모델은 16개 합성곱 층, 3개 완전연결 층, 5개 최댓값 풀링(Maxpooling) 층, 그리고 1개 소프트맥스(SoftMax) 층으로 구성되어 있다(Fig. 7). 그림에서 보듯이 영상분류 과정은 입력 영상자료에 대해 16개 합성곱 계층에 합성곱을 적용 후 5개 최댓값 풀링 계층을 통과하고 있다, 이후 완전연결 계층을 통과하면 소프트맥스를 적용하여 학습을 마치게 된다. 16개 합성곱 층은 상하/좌우에서 선택할 수 있는 가장 작은 크기인 3×3으로 구성되어 있다.

VGGNet에서 모든 은닉 층은 지수함수와 나눗셈으로 구성된 시그모이드(Sigmoid) 활성화 함수보다는 입력값이 음수일 때는 “0”, 양수일 때는 입력 값을 출력하는 ReLU 활성화 함수가 계산효율이 좋아 주로 이용한다. 그러나 여기에서는 입력값을 “0”과 “1” 사이의 값으로 정규화하여 출력하고 출력값의 전체 합이 항상 “1” 되는 소프트 맥스 활성화 함수가 정밀도 함수, 손실함수 곡선 수렴 정도가 우수하여 활성화 함수로 적용한다. 손실함수 최적화에는 AdaGrad(Adaptive Gradient) (Duchi *et al.*, 2011)를 이용한다. 심층학습에 필요한 학습자료, 평가자료, 검증자료는 수치모형실험에서 전이대 두께를 10 m 부터 120 m까지 5 m씩 증가시키면서 모델링을 수행하고 모델링 결과에 대해 연속 파형요소 변환을 적용하여 시간-주파수 스펙트럼 단면도 영상을 생성하였다(Fig. 8). Fig. 8은 임의 전이대 두께에서 대표적인 스펙트럼 영상자료이다. 학습자료를 확보하기 위해 두께별 모델링 결과에 무작위 잡음을 2%에




Fig. 10. Distribution of the time-frequency spectrum images. The dataset is divided with a training, validation, test ratio of 64%, 16%, and 20%, respectively. The total number of images with 23 classes is 2,231.

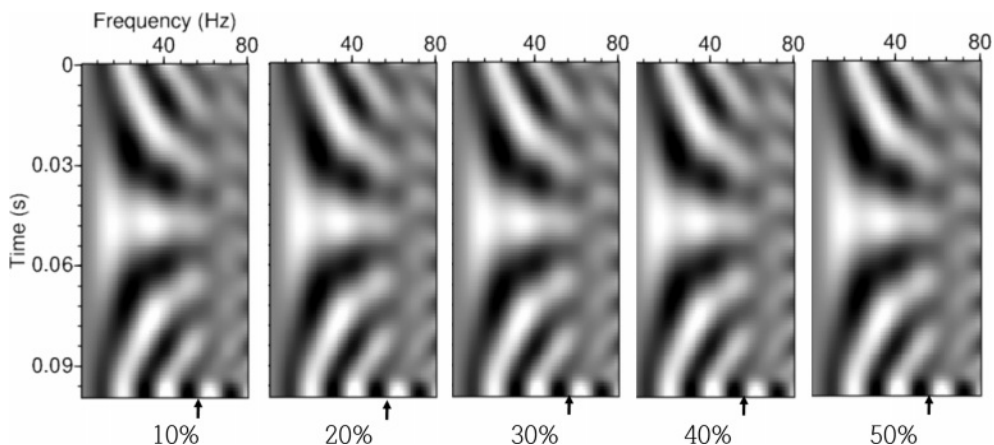


Fig. 9. Time-frequency spectrum for different signal-to-noise ratio levels when the transition thickness is 30 m.

Table 1. Results of training using deep learning, VGGNet-19.

Class	Thickness (m)	Precision	Recall	F1-score	Support
0	10	0.93	0.93	0.93	15
1	15	0.93	0.93	0.93	15
2	20	0.93	1.00	0.97	14
3	25	1.00	1.00	1.00	15
4	30	0.93	1.00	0.97	14
5	35	0.93	0.88	0.90	16
6	40	0.93	0.88	0.90	16
7	45	0.93	1.00	0.97	14
8	50	1.00	1.00	1.00	15
9	55	1.00	0.94	0.97	16
10	60	1.00	1.00	1.00	15
11	65	1.00	1.00	1.00	15
12	70	1.00	0.94	0.97	16
13	75	0.93	1.00	0.97	14
14	80	1.00	1.00	1.00	15
15	85	1.00	1.00	1.00	15
16	90	0.93	1.00	0.97	14
17	95	1.00	0.94	0.97	16
18	100	1.00	1.00	1.00	15
19	105	1.00	1.00	1.00	15
20	110	1.00	1.00	1.00	15
21	115	1.00	0.94	0.97	16
22	120	0.93	1.00	0.97	14

서 98%까지 1%씩 신호대 잡음비를 증가시키면서 추가 영상 자료를 준비하였다(Fig. 9). Fig. 9는 전이대 두께가 30 m 일 때 임의의 신호대 잡음비에서 시간-주파수 스펙트럼 영상 단면도이다. 시간-주파수 스펙트럼 영상자료 속성은 300×200 RGB 이다. 기계학습 모델을 학습시키기 위해 자료를 학습자료 1428 개(전체 영상자료의 64%), 검증자료 357 개(전체 영상자료의 16%), 평가자료 446 개(전체 영상자료의 20%)로 분리하였다(Fig. 10). VGGNet-19 알고리즘을 이용한 분류문제 결과는 Table 1에 있다. 전이대 두께 별 레이블에 대한 정밀도, 재현율, F1 점수 나타내고 있다. Table 1에서 정밀도는 모델






Fig. 11. Confusion matrix: The vertical axis is each thickness's true label, and the horizontal axis is for the predicted label.

예측값이 얼마나 정확하게 되었는지를, 재현율은 실제값 중에서 모델이 검출한 실제값의 비율을 나타내는 지표이며 그리고 F1 점수는 정밀도와 재현율의 조화평균으로 0과 1 사이 값으로 정밀도와 재현율이 한 쪽으로 치우치지 않을 때 높은 값을 나타낸다. 예측오류가 어느 정도인지 그리고 어떤 유형의 예측 오류가 있는지를 나타내는 오차행렬(confusion matrix)은 Fig. 11에 있다. 오차행렬 세로축에는 전이대 두께에 따른 실제값을 그리고 가로축에는 예측값을 나타내어 전이대 두께별 실제값과 예측값의 정도를 확인할 수 있다. 학습결과에서 보듯이 정밀도, 재현율, F1 점수 모두 “1”에 수렴하고 정확도 그래프는 0.97에, 손실값 그래프는 0.174에 수렴하고 있어서 상당 부분 신뢰도가 높은 것으로 볼 수 있다(Fig. 12). 전이대 두께가 10



(a) loss function



(b) accuracy function

Fig. 12. Loss and accuracy function after 400 epochs.

m 일 때 시간-주파수 스펙트럼 영상자료를 입력하여 예측한 결과는 두께를 10 m로 바르게 예측하였으나 50 m에서 시간-주파수 입력자료의 경우 예측 전이대 두께를 20 m로, 100 m에서 시간-주파수 입력자료의 경우에는 10 m로 예측하였다. 인공자료를 적용하고 있음에도 전이대 두께를 항상 정확하게 예측하지 못했다. 학습결과 평가지표에 나타나는 높은 정밀도와 재현율과는 달리 입력자료 두께와 예측결과 두께와 차이가 발생하고 있다. 차이 발생 원인으로는 가장 먼저 훈련자료 부족을 들 수 있다. 훈련자료 확보 방법으로 영상자료 증가와 속도모델과 잡음수준을 고려한 다양한 환경에서 모델링 결과 등을 고려할 수 있다. 이 연구에서는 제한적인 학습자료를 이용하여 전이대 두께에 대한 심층학습 적용 가능성을 살펴 보았지만 실제 현장자료에 적용하기 위해서는 CO₂ 저류층과 유사한 저류층 깊이와 두께, 지층속도 모델, 송신음원 파형요소, 중합단면도, 물리검층 자료, 여러 잡음 수준 등을 고려한 다양한 환경에서 울프 모델링을 실시하고 충분한 학습자료 확보하는 것이 필수적이다. 여기서 사용한 컴퓨터 환경은 CUDA 코어 6144, 메모리 8 GB를 갖춘 Nvidia GeForce RTX 3070 GPU 이고, 계산시간은 1회 반복에 4 s, 400회 반복학습을 적용하였을 때 1600 s 정도이다. 이 연구에서 제안한 심층학습 이용 전이대 두께 예측방법을 현장자료에 적용할 경우 그 수행과정을 요약하면 i) 중합 단면도에서 트레이스 한 개를 선택한 후 시간-주파수 스펙트럼 영상자료 확보, ii) 중합단면도에서 다양한 전이대 두께와 잡음을 고려한 울프 반사계수 모델링과 시간-주파수 스펙트럼 영상자료 확보, iii) 심층학습 적용이다. CO₂ 주입 대상 저류층 두께 예측에서는 상부 덮개암과 하부 사암으로 속도가 감소하는 모델을 적용하고, 해저면 두께 예측에서는 속도가 점차 증가하는 모델을 적용하여 탄성과 신호음을 구한다. 이 연구에서 제안하는 심층학습이용 전이대 두께 예측 방법은 시간-스펙트럼 영상자료 차이를 이용한다. 현장자료에 적용하기 위해서는 정확도를 더 높일 수 있는 노력이 필요하다. 좀 더 다양한 환경에서 전이대 모델링 학습자료를 확보한다면 CO₂ 지층저장 모니터링, 해안공학 분야에서 활용 가능성이 있을 것으로 생각한다.

결 론

저류층 전이대나 해저면 전이대 두께 예측은 CO₂ 지층저장 감시, 저류층 평가, 해안공학에서 중요한 지구물리변수중 하나이다. 이 연구에서는 심층학습을 이용한 전이대 두께 예측 방법을 제안하였다. 탄성과 중합자료는 영습셋 수직반사파 자료이므로 울프 반사파 모델링을 적용할 수 있는 자료구조를 지니고 있다. 따라서 현장자료 적용 가능성도 높다. 전이대 두께별 울프 반사계수 모델링 결과에 대한 시간-주파수 스펙트럼 단면도에서 단절 주파수와 에너지 변화 영역을 확인할 수 있었다. 전이대 두께 예측은 입력 중합단면도 트레이스의 시간-

주파수 스펙트럼과 가장 유사한 두께별 모델링 시간-주파수 스펙트럼 영상자료를 비교하여 간접적으로 추정한다. 시간-주파수 스펙트럼 차이는 심층학습 알고리즘중 하나인 VGGNet-19를 이용하였다. 탄성과 속도가 감소하는 CO₂ 저류층 모델 수치모형실험에서 시간-주파수 스펙트럼 영상자료를 전이대 두께, 신호대 잡음비에 따라 학습자료, 검증자료, 평가자료를 확보하였다. 심층학습 적용 결과는 정밀도, 재현율, F1 점수 모두 “1”에 근접하게 수렴하였다. 그러나 전이대 두께 예측결과는 인공자료적용에도 불구하고 차이가 있음을 확인하였다. 따라서 다양한 환경에서 학습자료를 확보하고 정확도를 높이고 현장자료 적용도 필요하다. 충분한 현장자료 적용으로 안정성이 확보한다면 저류층 전이대 두께, 해저면 전이대 두께 정보가 필요한 저류층 평가, 해안공학분야에서 활용이 가능할 것으로 기대한다.

감사의 글

이 논문은 2023 년도 정부(산업통상자원부)의 재원으로 한국에너지기술평가원의 지원을 받아 수행한 연구입니다 (20226A10100030).

References

- Addison, P. S., 2018, Introduction to redundancy rules: the continuous wavelet transform comes of age, *Philosophical Transactions of the Royal Society A*, **376(2126)**, 1-5, doi: <http://doi.org/10.1098/rsta.2017.0258>
- Allen, J., 1977, Short Time Spectral Analysis, Synthesis, and Modification by Discrete Fourier Transform, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, **25(3)**, 235-238, doi: <https://doi.org/10.1109/TASSP.1977.1162950>
- Chakraborty, A., and Okaya, D., 1995, Frequency-time decomposition of seismic data using wavelet-based methods, *Geophysics*, **60(6)**, 1906-1916, doi: <https://doi.org/10.1190/1.1443922>
- Cho, S. I., and Pyun, S. J., 2023, Comparison of CNN and GAN-based Deep Learning Models for Ground Roll Suppression, *Geophysics and Geophysical Exploration*, **26(2)**, 37-51, doi: <https://doi.org/10.7582/GGE.2023.26.2.037> (In Korean with English abstract)
- Clay, C. S., and Medwin, H., 1977, *Acoustical oceanography: Principal & applications*, John Wiley & Sons Inc. doi: [10.1016/S0022-460X\(78\)80104-7](https://doi.org/10.1016/S0022-460X(78)80104-7)
- Deng, L., and Yu, D., 2014, Deep Learning: Methods and Applications, *Foundations and Trends in Signal Processing*, **7(3-4)**, 197-387, doi: <http://doi.org/10.1561/20000000039>
- Duchi, J., Hazna, E., and Singer, Y., 2011, Adaptive Subgradient Methods for Online Learning and Stochastic Optimization, *Journal of Machine Learning Research*, **12(7)**, 2121-2159, doi: <https://dx.doi.org/10.5555/1953048.2021068>

- Dutta, N. C., and Odé, H., 1983, Seismic reflections from a gas-water contact, *Geophysics*, **48(2)**, 148-162, doi: <https://dx.doi.org/10.1190/1.1441454>
- Fang, W., Fu, L., Zhang, M., and Li, Z., 2021, Seismic data interpolation based on U-Net with texture loss, *Geophysics*, **86(1)**, V41-V54, doi: <https://dx.doi.org/10.1190/geo2019-0615.1>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y., 2020, Generative adversarial networks, *Commun. ACM*, **63(11)**, 139-144, doi: <https://doi.org/10.1145/3422622>
- Goupillaud, P., Grossmann, A., and Morlet, A., 1984, Cycle-octave and related transforms in seismic signal analysis, *Geophysical Exploration*, **23(1)**, 85-102, doi: [https://dx.doi.org/10.1016/0016-7142\(84\)90025-5](https://dx.doi.org/10.1016/0016-7142(84)90025-5)
- Harsuki, R., and Alkhalifah, T., 2022, StorSeismic: A new paradigm in deep learning for seismic processing, *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-15, doi: <https://doi.org/10.1109/TGRS.2022.3216660>
- He, K., Zhang, X., Ren, S., and Sun, J., 2016, Deep residual learning for image recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, 770-778, doi: <https://doi.org/10.1109/CVPR.2016.90>
- He, Q., and Wang, Y., 2021, Reparameterized full-waveform inversion using deep neural networks, *Geophysics*, **86(1)**, V1-V13, doi: <https://doi.org/10.1190/geo2019-0382.1>
- Jia, Y., and Ma, J., 2017, What can machine learning do for seismic data processing? An interpolation application, *Geophysics*, **82(3)**, V163-V177, doi: <https://dx.doi.org/10.1190/geo2016-0300.1>
- Jo, J., and Ha, W., 2023, Deep-Learning Seismic Inversion using Laplace-domain wavefields, *Geophysics and Geophysical Exploration*, **26(2)**, 84-93, doi: <https://doi.org/10.7582/GGE.2023.26.2.084> (In Korean with English abstract)
- Kaur, H., Pham, N., and Formel, S., 2020, Seismic data interpolation using deep learning with generative adversarial networks, *Geophysical Prospecting*, **69(11)**, 307-326, doi: <https://doi.org/10.1111/1365-2478.13055>
- Kim, S., and Jun, H., 2022, The Use of Unsupervised Machine Learning for the Attenuation of Seismic Noise, *Geophysics and Geophysical Exploration*, **25(2)**, 71-84, doi: <https://doi.org/10.7582/GGE.2022.25.2.071>
- Krizhevsky, A., Sutskever, I., and Hinton, G. E., 2017, ImageNet classification with deep convolutional neural networks, *Communications of the ACM*, **60(6)**, 84-90, doi: <https://dx.doi.org/10.1145/3065386>
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., and Jackel, L. D., 1989, Backpropagation applied to handwritten zip code recognition, *Neural Computation*, **1(4)**, 541-551, doi: <https://doi.org/10.1162/neco.1989.1.4.541>
- LeCun, Y., Bengio, Y., and Hinton, G. E., 2015, Deep learning, *Nature*, **521**, 436-444, doi: <https://doi.org/10.1038/nature14539>
- Lewis, W., and Vigh, D., 2017, Deep learning prior models from seismic images for full-waveform inversion. In: *SEG Technical Program Expanded Abstracts 2017*, Society of Exploration Geophysicist, 1512-1517, doi: <https://doi.org/10.1190/segam2017-17627643.1>
- Li, H., Li, X., Dong, H., Han, F., and Wang, C., 2022, Full-waveform inversion with adversarial losses via deep learning, *Journal of Applied Geophysics*, **205**, 1-11, doi: <https://doi.org/10.1016/j.jappgeo.2022.104763>
- Li, Y., and Ma, Z., 2021, Deep learning-based noise reduction for seismic data, *Journal of Physics: Conference Series*, 1861 012011 IWAACE 2021, doi: <https://doi.org/10.1088/1742-6596/1861/1/012011>
- Liner, C. L., and Bodmann, B. G., 2010, The Wolf ramp: Reflection characteristics of a transition layer, *Geophysics*, **75(5)**, A31-A35, doi: <https://doi.org/10.1190/1.3476312>
- Liner, C., 2012, Elements of Seismic Dispersion: A Somewhat Practical Guide to Frequency-Dependent Phenomena, Society of Exploration Geophysicists, 109-124, doi: <https://doi.org/10.1190/1.9781560802952.ch6>
- Liu, J., and Marfurt, K. J., 2006, Thin bed thickness prediction using peak instantaneous frequency, SEG/New Orleans annual meeting, 968-972, doi: <https://doi.org/10.1190/1.2370418>
- Ma, Y., and Luo, Y., 2018, Automatic first-arrival picking with Reinforcement Learning, SEG Global Meeting Abstracts, 493-497, doi: <https://doi.org/10.1190/IGC2018-121>
- Marfurt, K. J., and Kirlin, R. L., 2001, Narrow-band spectral analysis and thin-bed tuning, *Geophysics*, **66(4)**, 1274-1283, doi: <https://doi.org/10.1190/1.1487075>
- Mosser, L., Dubrule, O., and Blunt, M. J., 2020, Stochastic seismic waveform inversion using generative adversarial networks as a geological prior, *Mathematical Geosciences*, **52(1)**, 53-79, doi: <https://doi.org/10.1007/s11004-019-09832-6>
- Naeini, E. Z., and Prindle, K., 2018, Machine learning and learning from machines, *The Leading Edge*, **37(12)**, 886-893, doi: <https://doi.org/10.1190/tle37120886.1>
- Nithyashree, V., 2021, <https://github.com/Nithyashree-2022/VGG-19-for-Rock-Paper-and-Scissors-classification> (July 18, 2023 Accessed)
- Oliveira, D. A., Ferreira, R. S., Silva, R., and Brazil, E. V., 2018, Interpolating seismic data with conditional generative adversarial networks. *IEEE Geoscience and Remote Sensing Letters*, **15(12)**, 1952-1956, doi: <https://doi.org/10.1109/LGRS.2018.2866199>
- Ovcharenko, O., Kazei, V., Kalita, M., Peter, D., and Alkhalifah, T., 2019, Deep learning for low-frequency extrapolation from multioffset seismic data, *Geophysics*, **84(6)**, R989-R1001, doi: <https://doi.org/10.1190/geo2018-0884.1>
- Ovcharenko, O., and Hou, S., 2020, Deep learning for seismic data reconstruction: Opportunities and challenges, in *Proc. 1st EAGE Digitalization Conference Exhibition*, no. 1, 1-5, doi: <https://doi.org/10.3997/2214-4609.202032054>
- Ozawa, M., 2023, Automated picking of seismic first arrivals using a single-to multidomain self-trained network, *Geophysics*, **89(1)**, WA25-WA38, doi: <https://doi.org/10.1190/geo2022->

- 0666.1
- Park, J., Choi, J., Seol, S. J., Byun, J., and Kim, Y., 2021, A method for adequate selection of training data sets to reconstruct seismic data using a convolutional U-Net, *Geophysics*, **86(5)**, V375-V388, doi: <https://doi.org/10.1190/geo2019-0708.1>
- Partyka, G. A., Gridley, J., and Lopez, J., 1999, Interpretational applications of spectral decomposition in reservoir characterization, *The Leading Edge*, **18(3)**, 353-360, doi: <https://doi.org/10.1190/1.1438295>
- Plotnitskii, P., Alkhalifah, T., Ovcharenko, O., and Kazei, V., 2019, Seismic model low wavenumber extrapolation by a deep convolutional neural network, ASEG Extended Abstracts, 2nd Australasian Exploration Geoscience, **2019(1-5)**, doi: <https://doi.org/10.1080/22020586.2019.12073206>
- Ronneberger, O., Fischer, P., and Brox, T., 2015, U-Net, convolutional net-works for biomedical image segmentation, *Proc. Int. Conf. Med. Image Comput. Comput.-Assist. Intervent.* Cham, Switzerland: Springer, 234-241, doi: https://doi.org/10.1007/978-3-319-24574-4_28
- Röth, G., and Tarantola, A., 1994, Neural networks and inversion of seismic data, *J. Geophys. Res.: Solid Earth*, **99(B4)**, 6753-6768, doi: <https://doi.org/10.1029/93JB01563>
- Sak, H., Senior, A., and Beaufays, F., 2014, Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition, *Proc. Interspeech*, 338-342, doi: <https://doi.org/10.21437/Interspeech.2014-80>
- Sezawa, K., and Kanai, K., 1935, Discontinuity in dispersion curves of Rayleigh-waves, *Proceedings of the Imperial Academy*, **11**, 13-14, <https://doi.org/10.2183/pjab1912.11.13>
- Simonyan, K., and Zisserman, A., 2015, Very deep convolutional networks for large-scale image recognition, *3rd International Conference on Learning Representations (ICLR 2015)*, 1-14, doi: <https://doi.org/10.48550/arXiv.1409.1556>
- Sun, B., and Alkhalifah, T., 2019, ML-descent: An optimization algorithm for full-waveform inversion using machine learning, *Geophysics*, **85(6)**, R477-R492, doi: <https://doi.org/10.1190/geo2019-0641.1>
- Sun, H., Sun, Y., Nammour, R., Rivera, C., Williamson, P., and Demanet, L., 2023, Learning with real data without real labels: a strategy for extrapolated full-waveform inversion with field data, *Geophysical Journal International*, **235(2)**, 1761-1777, doi: <https://doi.org/10.1093/gji/ggad330>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., 2015, Going deeper with convolutions, 2015 *IEEE Conference on Computer Vision and Pattern Recognition*, 1-9, doi: <https://doi.org/10.1109/CVPR.2015.7298594>
- Tsai, K., Hu, W., Wu, X., Chen, J., and Han, Z., 2019, Automatic First Arrival Picking via Deep Learning with Human Interactive Learning, *IEEE Transactions on Geoscience and Remote Sensing*, **58(2)**, 1380-1391, doi: <https://ieeexplore.ieee.org/abstract/document/8880673>
- Wang, J., Xiao, Z., Liu, C., Zhao, D., and Yao, Z., 2019, Deep Learning for Picking Seismic Arrival Times, *J. Geophys. Res. Solid Earth*, **124(7)**, 6612-6624, doi: <https://doi.org/10.1029/2019JB017536>
- Widess, M. B., 1982, Quantifying resolving power of seismic systems, *Geophysics*, **47(8)**, 1160-1173, doi: <https://doi.org/10.1190/1.1441379>
- Wolf, A., 1937, The reflection of elastic waves from transition layers of variable velocity, *Geophysics*, **2(4)**, 357-363, doi: <https://doi.org/10.1190/1.1438104>
- Yang, F., and Ma, J., 2019, Deep-learning inversion: A next-generation seismic velocity model building method, *Geophysics*, **84(4)**, R583-R599, doi: <https://doi.org/10.1190/geo2018-0249.1>
- Yeoh, Z., Park, J., Seol, S. J., Yoon, D., and Byun, J., 2023, Trace-based Interpolation Using Machine Learning for Irregularly Missing Seismic Data, *Geophysics and Geophysical Exploration*, **26(2)**, 62-72, doi: <https://doi.org/10.7582/GGE.2023.26.2.062> (In Korean with English abstract)
- Yu, S., Ma, J., and Wang, W., 2019, Deep learning for denoising, *Geophysics*, **84(6)**, V333-V350, doi: <https://doi.org/10.1190/geo2018-0668.1>
- Zeiler, D., and Fergus, R., 2014, *Visualizing and understanding convolutional networks*, Springer International Publishing, 818-833, https://link.springer.com/chapter/10.1007/978-3-319-10590-1_53
- Zhang, M., Liu, Y., and Chen, Y., 2019, Unsupervised seismic random noise attenuation based on deep convolutional neural network, *IEEE Access*, **7**, 179810-179822, doi: <https://doi.org/10.1109/ACCESS.2019.2959238>
- Zhong, T., Cheng, M., Dong, X., and Wu, N., 2021, Seismic random noise attenuation by applying multiscale denoising convolutional neural network, *IEEE Trans. Geoscience Remote Sens*, **60**, 1-13, doi: <https://doi.org/10.1109/TGRS.2021.3095922>