KSMER Journal of The Korean Society of Mineral and Energy Resources Engineers

Vol. 61, No. 1 (2024) pp. 61-81, https://doi.org/10.32390/ksmer.2024.61.1.061

ISSN 2288-0291(print)
ISSN 2288-2790(online)

총설

물리탐사 분야에서의 딥러닝 기술: 현황, 도전 과제 및 미래 방향

유지윤[1] · 오종찬[1] · 공신혜[1] · 이창훈[1] · 임지원[1] · 윤대웅[1]*

[1]전남대학교 에너지자원공학과

Deep Learning in Geophysics: Current Status, Challenges, and Future Directions

Jiyun Yu[1], Jongchan Oh[1], Shinhye Kong[1], Changhoon Lee[1], Jiwon Lim[1] and Daeung Yoon[1]*

[1]Energy & Resource Engineering, Chonnam National University, Gwangju, Korea

***Corresponding Author.** Daeung Yoon, duyoon@jnu.ac.kr, Energy & Resource Engineering, Chonnam National University, Gwangju, Korea

Received
13 February 2024

Final version Received
23 February 2024

Accepted
27 February 2024

Abstract

With the rapid development of artificial intelligence technology, machine learning and deep learning techniques have been actively applied in the field of exploration geophysics. In this study, we extensively investigated the application of deep learning in geophysical techniques including seismic, gravity, magnetic, electromagnetics, ground penetrating radar, and joint inversion. Recent research has confirmed that deep learning techniques optimized for geophysical problems are being developed that transcend traditional theory-based approaches, suggesting that deep learning is becoming a new paradigm in the field of geophysics. Despite these technological advances, there are still challenges to be overcome, such as a lack of training data, model opacity, and heterogeneity between training data and field data, and this study suggests future research directions to address these aspects.

Key words : exploration geophysics, machine learning, deep learning, research trends

요 약

인공지능 기술의 급속한 발전과 함께, 물리탐사 분야 또한 기계학습 및 딥러닝 기술이 활발히 적용되고 있다. 이 논문에서는 탄성파, 중력, 자력, 전기 및 전자, 지표투과 레이다 탐사 그리고 복합역산을 포함한 여러 물리탐사 기법에서 딥러닝의 적용 사례를 광범위하게 조사하였다. 이를 통해, 최근 연구들에서 전통적인 이론 기반 접근법을 뛰어넘는 물리탐사 분야에 최적화된 딥러닝 기술이 개발되고 있음을 확인하였고, 이는 딥러닝이 물리탐사 분야에서 새로운 패러다임으로 자리 잡고 있음을 시사한다. 하지만, 이러한 기술적 진보에도 불구하고 학습자료의 부족, 모델의 불투명성, 학습자료와 현장자료 간의 이질성 등 여전히 극복해야 할 도전 과제가 존재하고, 이 논문에서는 이를 해결하기 위한 앞으로의 연구 방향을 제시하였다.

주요어 : 물리탐사, 기계학습, 딥러닝, 연구 동향

서 론

물리탐사는 지구 물리학의 원리를 활용하여 지질 구조와 물리적 특성을 조사하는 방법으로, 탄성파, 중력, 자력, 전기, 전자, 지표투과 레이다(ground pentrating radar, GPR) 탐사 등을 포함한다. 각각의 탐사 기술은 일반적으로 표준화된 자료처리 및 해석 절차를 따르는데, 최근 탐사 기기의 발전으로 자료의 크기가 커지고, 자료의 복잡성 또한 증가

Copyright ⓒ 2024, The Korean Society of Mineral and Energy Resources Engineers

함에 따라, 이를 처리하고 해석하는 기술 또한 빠르게 발전하고 있다. 최근 들어 컴퓨터 하드웨어의 발전과 방대한 탐사자료의 효율적인 처리 및 해석의 필요성이 증가함에 따라 기존 물리 이론 기반의 접근방식뿐만 아니라 자료 기반의 확률 및 통계적 접근방식이 활발히 적용되고 있고, 특히 인공지능(artificial intelligence, AI)의 핵심 기술인 기계학습(machine learning, ML)과 딥러닝(deep learning, DL) 기술에 대한 선호도가 폭발적으로 증가하고 있다(Choi *et al*., 2020).

기계학습은 자료에서 패턴을 인식하여 자동으로 예측이나 결정을 내리는 인공지능의 하위 분야로서, 다양한 알고리즘과 모델을 통해 구현된다. 딥러닝은 기계학습의 하위 집합으로, 다수의 은닉층(hidden layer)을 가진 인공신경망을 사용하여 복잡한 자료 구조에서 추상적인 특징을 학습할 수 있는 능력이 특징이다. 이는 선형회귀, SVM(support vector machine), 결정트리(decision tree), 랜덤포레스트(random forest), 그래디언트부스팅(gradient boosting) 등의 전통적 기계학습 방법과는 구분되며, 이러한 전통적 방법들은 비교적 간단한 자료구조에서 패턴을 찾는 데 주로 사용된다. 반면에 딥러닝은 복잡하고 고차원의 자료에서도 학습이 가능하며, 이는 신경망의 깊이, 즉 은닉층의 수가 증가함에 따라 더욱 명확해진다(Goodfellow *et al*., 2016).

딥러닝의 시작은 2006년 Hinton *et al*.(2006)에 의해 개발된 제한된 볼츠만 머신(restricted boltzmann machines, RBMs)으로 볼 수 있다. 이 연구에서는 심층 신경망의 효율적 학습을 가능하게 하는 새로운 방법론을 소개했으며, 이는 딥러닝 분야의 급속한 발전을 촉진시켰다. 이후 심층 신경망(deep nerual network, DNN), 합성곱 신경망(convolutional neural network, CNN), 순환 신경망(recurrent neural network, RNN) 분야로 구분되어 발전하였고, 특히 비전 분야에서는 AlexNet(Krizhevsky *et al*., 2012), VGGNet (Simonyan and Zisserman, 2014), ResNet(He *et al*., 2016)과 같은 합성곱 신경망 기반의 혁신적인 네트워크들이 등장했다. 또한, 이미지 생성 영역에서는 변형 오토인코더(variational autoencoder, VAE)(Kingma and Welling, 2013), 생성적 적대 신경망(generative adversarial networks, GAN) (Goodfellow *et al*., 2014), 그리고 디퓨전 모델(diffusion models)(Ho *et al*., 2020)이 주요 알고리즘으로 자리매김했다. 한편, 자연어 처리(natural language processing, NLP) 분야에서는 기존 순환 신경망을 넘어서는 트랜스포머(transformer)(Vaswani *et al*., 2017)가 등장하였으며, 이를 기반으로 한 BERT(bidirectional encoder representations from transformers)(Devlin *et al*., 2018) 및 GPT(generative pre-trained transformer) 시리즈가 연이어 소개되었다. 강화학습 영역에서는 DeepMind의 AlphaGo와 OpenAI의 ChatGPT에 적용되어, 인공지능 기술의 혁신적 진보를 이끌었다. 이러한 딥러닝 기술의 발전은 물리탐사 분야에서도 새로운 가능성을 열고 있으며, 특히 복잡한 탐사 자료의 처리 및 해석에 있어서 더욱 정교하고 효율적인 접근을 가능하게 만들고 있다.

물리탐사 분야에서 자료 처리 및 해석은 주로 이론 기반의 접근법이 사용되어왔다. 이러한 접근법은 물리학의 기본 원리와 수학적 모델을 사용하여 수행되기 때문에 자료 처리 과정에 대한 명확한 물리학적 이해를 제공하며, 결과의 해석에 있어 투명성과 물리학적 타당성이 보장된다 (Telford *et al*., 1990). 이와는 다르게 기계학습은 수많은 자료를 이용하여 입력과 출력 간의 패턴을 학습하여 모델을 생성하고, 이를 바탕으로 예측이나 의사 결정을 할 수 있도록 도와주는 기술이다. 하지만 기존 이론 기반 접근법과는 다르게 기계학습 모델은 일반적으로 블랙박스로 취급되어 예측 결과의 물리학적 의미를 해석하는 것이 어려울 수 있다(Goodfellow *et al*., 2016).

이러한 한계에도 불구하고, 최근 물리탐사 분야에 기계학습 활용이 증가하고 있는 이유는 기존 이론 기반 접근법의 한계를 보완할 수 있기 때문이다(Khosro Anjom *et al*., 2024). 기계학습을 학습 단계와 추론 단계로 구분할 때, 특히 추론 단계에서 기계학습 모델이 가지는 여러 장점을 들 수 있다. 첫째로, 기계학습 모델은 전통적인 방법에 비해 빠른 추론 속도를 제공한다. 예를 들어 결정론적 역산법과 같은 전통적인 방법은 반복적인 물리 모델링으로 인해 많은 연산 비용 및 시간을 요구하지만, 기계학습 모델은 미리 학습된 패턴을 활용하여 신속한 추론을 가능하게 한다. 둘째, 기계학습 모델은 복잡한 자료처리 과정을 단순화하여 비전문가도 쉽게 활용할 수 있는 사용의 효율성을 제공한다. 셋째, 주관적 판단 없이 일관된 결과를 도출하는 객관성을 보장한다. 넷째, 기계학습 모델은 반복적이고 지루한 작업을 자동화하여 작업 효율을 크게 향상시킨다. 마지막으로, 복잡한 자료들 속에서도 특정 패턴을 식별해내는 능력이 있어 물리 법칙만으로는 해석하기 어려운 자료도 분석 가능하다. 이러한 이유로, 기계학습 기술은 물리탐사 분야에서의 활용도가 점차 확대되고 있다.

비록 기계학습 모델이 추론 단계에서 여러 장점을 보이지만, 학습 과정에서는 여전히 주목해야 할 몇 가지 한계가 있다. 기계학습 모델을 효과적으로 학습시키기 위해서는 대량의 자료가 필요한데, 물리탐사 분야에서는 현장자료를 수집하는 데 비용이 많이 들고, 기관의 정보 보안 정책으로 인해 자료의 공유가 제한되는 경우가 많다. 이를 대체하기 위해 합성자료를 사용하기도 하지만, 자료 생성에 많은 연산 비용이 발생하고 현장자료와 합성자료의 이질성이 문제가 되기도 한다. 또한, 모델 학습에 있어서 최적화 과정이

많은 연산 비용을 요구하며, 학습 자료의 구성, 자료 전처리, 하이퍼 파라미터(hyper parameter) 설정 등에 따라 모델의 편향이 발생할 수 있다. 이러한 문제들을 해결하기 위해, 기계학습의 단점을 보완하고 장점을 극대화할 수 있는 방법에 관한 연구가 활발히 진행되고 있으며(e.g., Kim and Byun, 2020; Jo *et al*., 2022; Kong *et al*., 2023), 이는 물리탐사 분야에서 기계학습의 성공적인 적용을 위한 중요한 과제 중 하나이다.

기계학습은 일반적으로 지도학습(supervised learning), 비지도학습(unsupervised learning), 준지도학습(semi-supervised learning), 그리고 강화학습(reinforcement learning)으로 분류된다. 기계학습이 물리탐사 분야에 적용된 초기(2010~2020)에는 대부분 지도학습 위주로 적용되었다. 하지만 지도학습은 입력에 해당하는 레이블(label)이 필요하기 때문에, 최근에는 레이블이 없거나 자료가 부족한 상황에 적합한 비지도학습과 준지도학습도 활발히 활용되고 있다. 또한, 물리탐사 분야 기계학습 활용의 초기 단계에서는 전통적인 기계학습 알고리즘이 적용되었으나, 최근에는 대부분의 연구에 딥러닝 기술이 활용되고 있다.

이 논문에서는 최근 약 4년간(2020~2024) 물리탐사 분야에서 딥러닝 기술이 어떻게 적용되고 있는지를 탄성파 탐사 자료 처리 및 해석, 중력 및 자력 탐사, 전기 및 전자 탐사, 지표투과 레이다 탐사, 그리고 복합역산 분야를 중심으로 조사하였다. 또한 물리탐사에서 딥러닝의 성공적인 정착을 위해 넘어서야 할 주된 도전 과제들과 앞으로 나아가야 할 연구 방향에 대해 논의한다.

본 론

연구 동향

지난 10년간 물리탐사 분야에서 기계학습 기술의 활용이 기하급수적으로 증가했다. 이에 따라, 2015년부터 2023년까지의 자료를 바탕으로 탄성파, 중력, 자력, 전기 및 전자, 지표투과 레이다 탐사, 복합역산 등 7개 주요 분야에서의 기계학습 기반 연구 동향을 분석하였다(Figs. 1, 2). 분석은 IEEE Geoscience and Remote Sensing Letters, IEEE Transactions on Geoscience and Remote Sensing, SEG와 EAGE에 의해 발간된 저널들과 같은 주요 저널을 통해 진행되었으며, “machine-learning“, “deep-learning“ 등의 기계학습 관련 핵심 키워드를 사용했다. 분석 결과, 7개의 주요 물리탐사분야 모두에서 기계학습 기반 연구가 해마다 증가하는 추세를 보여주며, 특히 탄성파 탐사에 대한 기계학습 기반 연구가 다른 탐사들에 비해 월등히 높게 나타난다.

또한, 물리탐사 분야에서 기계학습 기반 연구를 다룬 논문들의 주요 저널별 비율도 분석하였다(Fig. 3). 이 분석에

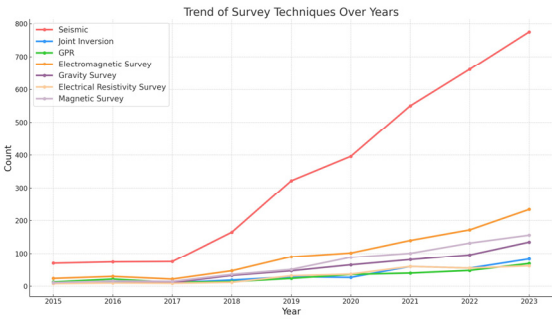

Fig. 1. Comparative analysis of ML-based research trends in five key geophysical survey areas from 2015 to 2023.

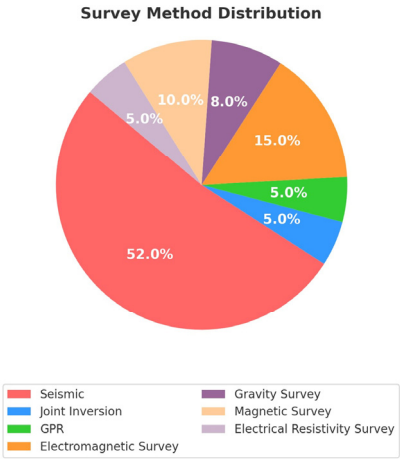

Fig. 2. Proportional distribution of ML-based research by exploration.

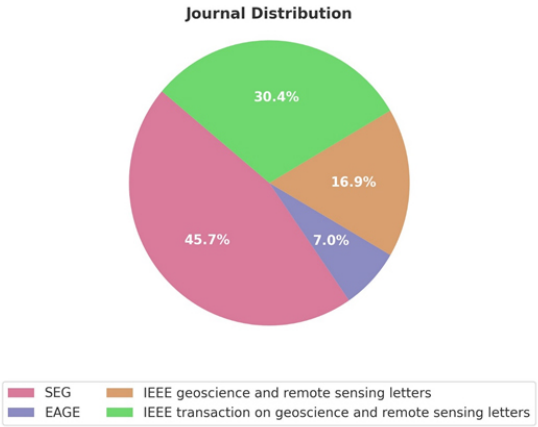

Fig. 3. Distribution of ML-based geophysical research publications across leading journals.

서는 SEG 저널이 전체의 45.7%로 가장 큰 비중을 차지했으며, IEEE Transactions on Geoscience and Remote Sensing이 30.4%로 뒤를 이었다. 이를 통해 물리탐사 분야의 기계학습 기반 연구가 다양한 학술지에서 주목받고 있음을 확인할 수 있다.

탄성파 탐사 자료 처리 및 해석

트레이스 보간법

탄성파 탐사 자료는 경제적, 환경적 제약 또는 기계적 결함으로 인해 일부 자료가 손실된 채로 획득될 가능성이 있으며, 이러한 손실은 자료 품질 및 정확도의 저하로 이어져 자료처리와 해석에 악영향을 줄 수 있다. 이 문제에 대응하기 위해, 특히 기계학습을 활용한 보간(interpolation) 기술 연구가 활발히 진행 중이다. 이 기술들은 자료처리의 효율성과 해석의 정확성을 향상시켜 비용 절감과 투자 결정에 있어서 올바른 판단을 가능하게 한다.

기계학습을 트레이스(trace) 보간에 처음 도입했던 시기에는 주로 이미 개발된 알고리즘들을 직접 적용하였으나(Jia and Ma, 2017), 최근의 연구는 이전의 단순 적용을 넘어서, 탄성파 자료에 특화된 새로운 모델을 개발하는 방향으로 진화하고 있다. Park *et al*.(2022)은 푸리에 손실(Fourier loss)과 평균 제곱 오차 손실(mean squared error, MSE)를 결합한 새로운 손실함수를 포함하는 CFunet(coarse-refine U-Net)을 제안하였다(Fig. 4). 제안한 방법은 높은 주파수 성분의 손실로 인한 알리아싱 문제를 완화하고, 픽셀 단위 손실로 인한 오버스무딩(oversmoothing) 문제를 해결한다. Li *et al*.(2022a)은 구조적 유사성(Structural Similarity Index Measure, SSIM)과 L1 손실을 결합한 하이브리드 손실함수를 사용하여 네트워크의 보간 성능을 향상시키는 방법을 제안하였다. 합성 및 실제자료에 대한 실험을 통해 기존의 U-Net보다 높은 정확성을 가진 합리적인 보간 결과를 제공한다는 것을 입증하였다. Li *et al*.(2022b)은 연속적으로 누락된 탄성파 자료 보간을 위해 좌표 어텐션 블록(coordinate attention block)을 적용한 새로운 U-Net 기반 모델인 CA-Unet(coordinate attention block Unet)을 제안하였다. CA-Unet은 좌표 어텐션 블록을 통해 장거리 의존성을 포착하고, 중요한 정보를 포함하는 피처맵(feature map)을 최대한 활용한다. 이때 좌표 어텐션 블록은 네트워크가 자료의 글로벌 정보를 포착하고, 효과적으로 누락된 트레이스를 복원할 수 있도록 한다.

또한, 고차원의 탄성파 자료에 보간을 수행하는 연구도 활발히 진행 중이다. Yu and Yoon(2023)은 해양 탄성파 탐사에서 발생하는 자료 손실 문제를 해결하기 위해 3D cWGAN(conditional Wasserstein generative adversarial network) 모델을 제안하였다. Yeeh *et al*.(2023)은 불규칙하게 손실된 트레이스를 포함하는 탄성파 탐사 자료를 위한 크로스라인(crossline) 방향의 트레이스 보간법을 제안하였다. 제안된 방법과 기존의 모델 제약조건이 적용된 MWNI(minimum weighted norm interpolation) 방법을 비교하였고, 제안된 방법이 모든 주파수 대역에서 높은 보간 성능을 보임을 확인하였다. Fang *et al*.(2023)은 5차원 합성곱 신경망(CCNet-5D)을 개발하였다(Fig. 5). CCNet-5D는 여러 저차원 합성곱을 연속적으로 결합하여 구성된 네트워크로, 5차원 연산을 효과적으로 처리한다. 합성 및 현장 자료 세트들에 대해 평가한 결과, CCNet-5D는 3D U-Net 방법과 비교하여 더 높은 신호 대 잡음비(S/N)를 달성하였다.

거대 언어 모델에 주로 사용되는 트랜스포머를 활용한

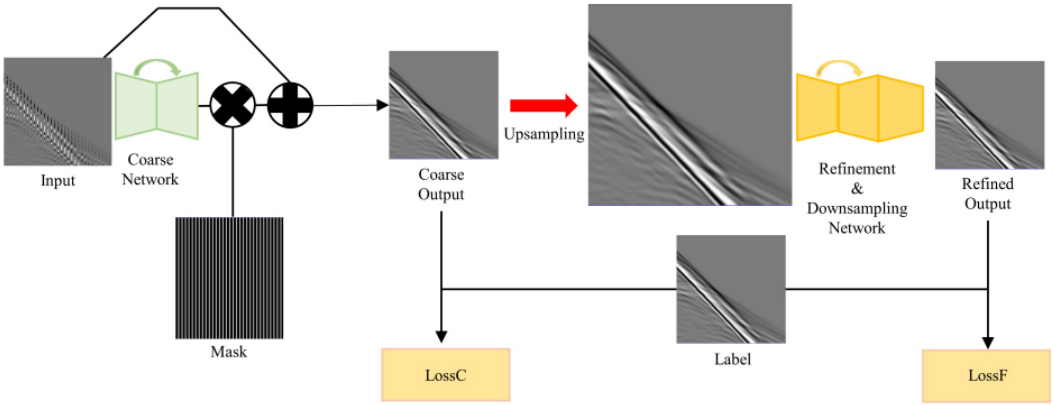

Fig. 4. Schematic showing the structure of CFunet for seismic trace interpolation. This network contains two different U-Nets (indicated by coarse and refinement as well as downsampling networks) and an additional upsampling process with zero-padding (indicated by the red arrow) (Park *et al*., 2022).

연구도 소개되었다. Guo *et al*.(2023)은 기존의 합성곱 신경망이 지역적인 자료의 의존성만 포착하는 데 반해, 전역 의존성을 포착하는 데에 한계가 있다는 점을 해결하고자 새로운 멀티 스케일 트랜스포머(multi scale transformer, MST)를 기반으로 하는 보간법을 제안하였다. Ding *et al*.(2024)은 자기 주의 메커니즘(self-attention mechanism)을 포함한 생성적 적대 신경망을 사용하여 탄성파 신호의 보간 및 잡음 제거를 동시에 수행하는 방법인 SAGAN(self-attention generative adversarial network)을 제안하였다. SAGAN은 자기 주의 메커니즘을 통해 글로벌 의존성을 포착하고, 탄성파 신호의 보간 및 잡음 제거 과정에서 높은 정확도를 나타내었다.

기존 이론 기반 접근법과 딥러닝 기술을 결합하는 연구도 수행되고 있는데, Wu *et al*.(2024)은 기존의 POCS(projection onto convex sets) 방법과 딥러닝 기법을 결합하여 개발한 새로운 네트워크인 Sparse Prior-net(Sp-net)을 제안하였다. Sp-net은 합성 및 실제 자료를 사용한 실험을 통해 빠른 계산 속도를 유지하면서 만족스러운 보간 성능을 달성한다는 것을 입증하였다.

잡음 제거

탄성파 탐사 자료는 자연적 또는 인위적인 원인으로 인해 잡음이 섞여 자료의 정확성과 해석에 부정적인 영향을 줄 수 있다. 잡음은 탄성파 신호의 품질을 저하시키고, 신호

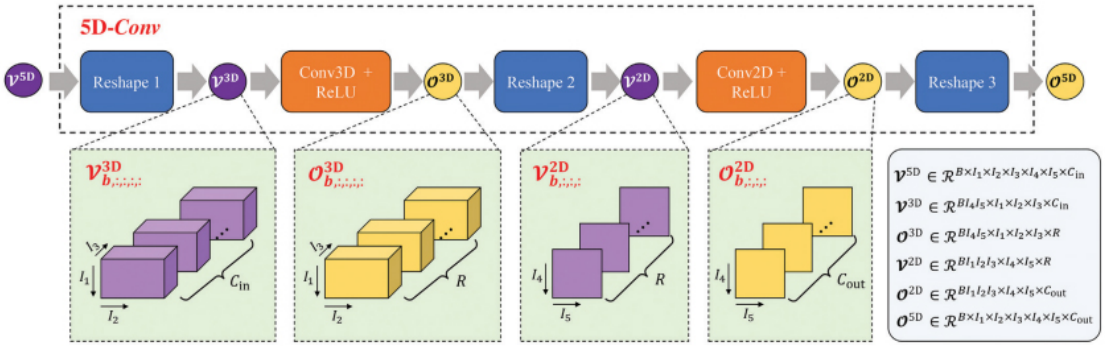

Fig. 5. Designed 5D convolutional layer (CC-3D2D module), which uses the cascade of a 3D convolutional layer and a 2D convolutional layer to approximate the 5D convolutional layer (Fang *et al*., 2023).

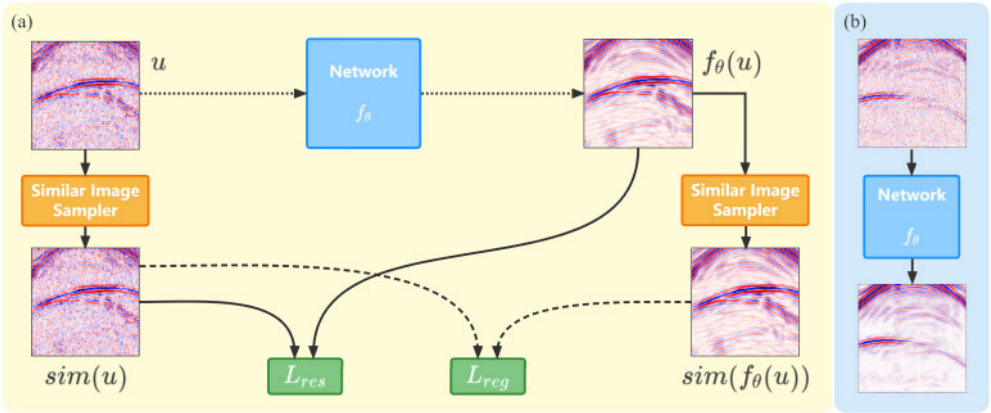

Fig. 6. Overview of the SISL model. (a) Training process. The original noisy image u is fed into the similar image sampler to generate the similar noisy images sim(u). Then, u and sim(u) are used as the input and the target of the denoising network, respectively. The hybrid loss function is divided into two components: L_{res} is computed between the network output and the target; considering the difference between the ground truth of the input and the target, the regularization constraint L_{res} is introduced on the right. Notably, the similar image sampler used twice for a training round adopts the same strategy as pixel replacement. (b) Inference using the trained denoising network (Liu *et al*., 2022a).

대 잡음비를 낮추어 정확한 지하 구조의 해석을 방해한다. 이를 해결하기 위해 효과적인 잡음 제거 방법에 대한 개발이 필요하며, 특히 기계학습과 같은 자료처리 기술을 이용한 잡음 제거 연구가 활발히 진행되고 있다. 이러한 방법들은 탐사 자료의 품질을 향상시키고, 탐사 및 개발 프로젝트의 비용 효율성과 성공률을 높이는 데 중요한 역할을 한다.

탄성파 자료의 무작위 잡음 제거를 위해 Wang *et al.*(2022)은 비지도 학습 기반의 새로운 접근방식을 제안하였다. 이들은 기존 잡음 제거 방법을 능가하는 심층 신경망의 잠재력을 발휘하면서도, 수학적 한계를 극복하기 위해, 수정된 반복 소프트 임계값 알고리즘(ISTA) 기반 네트워크를 개발하였다. Dong *et al.*(2022)은 멀티스케일 합성곱과 공간적 주의 메커니즘을 통합한 멀티스케일 공간 주의 잡음 제거 네트워크(multiscale spatial attention network, MSSA- Net)을 도입하여 강한 잡음과 약한 반사 신호를 효과적으로 처리하였다. Liu *et al.*(2022a)은 기존 지도학습 한계를 극복하는 유사성 정보 자가 학습(Similarity-Informed Self-Learning, SISL) 모델을 제안하여 탄성파 이미지의 잡음을 자가 학습 방식으로 제거하였다(Fig. 6). Li *et al.*(2022a)은 탄성파 이미지의 초해상도 및 잡음 제거를 동시에 달성하기 위한 심층 합성곱 신경망을 개발하였다. Yao *et al.*(2022)은 사막 탄성파 자료의 특성에 맞는 DnResNeXt 네트워크를 통해 잡음을 효과적으로 감소시켰고, Iqbal(2023)은 DeepSeg 프레임워크를 통해 탄성파 신호의 잡음을 적응적으로 제거하였다. Luiken *et al.*(2024)은 해양 탐사 자료의 디블렌딩(deblending) 과정에서 자가 학습 잡음 제거 네트워크를 적용하여 우수한 결과를 얻었다. 마지막으로, Lee *et al.*(2024)은 Sparker 탄성파 자료의 무작위 잡음을 억제하기 위해 BiLSTM(bidirectional long short-term memory)과 FrFT(fractional Fourier transform)를 결합한 방법을 제안하였다. 이러한 연구들은 탄성파 데이터 처리에 기계학습 기술을 적용하여 잡음을 효과적으로 제거하고 자료 품질을 향상시키는 새로운 가능성을 보여준다.

이벤트 분리

탄성파 자료는 복잡한 지질 구조, 신호와 잡음의 혼합, 다양한 파동의 존재 등으로 인해 자료처리와 해석에 어려움을 겪을 수 있다. 이를 해결하기 위해 이벤트 분리(event separation)의 중요성이 대두되고 있다. 이벤트 분리는 잡음을 제거하여 유용한 신호를 명확히 식별함으로써 이미지 품질을 향상시키고, 다양한 유형의 파동(예: P파, S파)을 정확히 구분하여 각각의 지질학적 정보를 추출한다. 또한, 효율적인 자료처리 및 해석을 가능하게 하며, 탐사 및 모니터링의 정확성을 높인다. 최근에는 기계학습 기술의 발전으

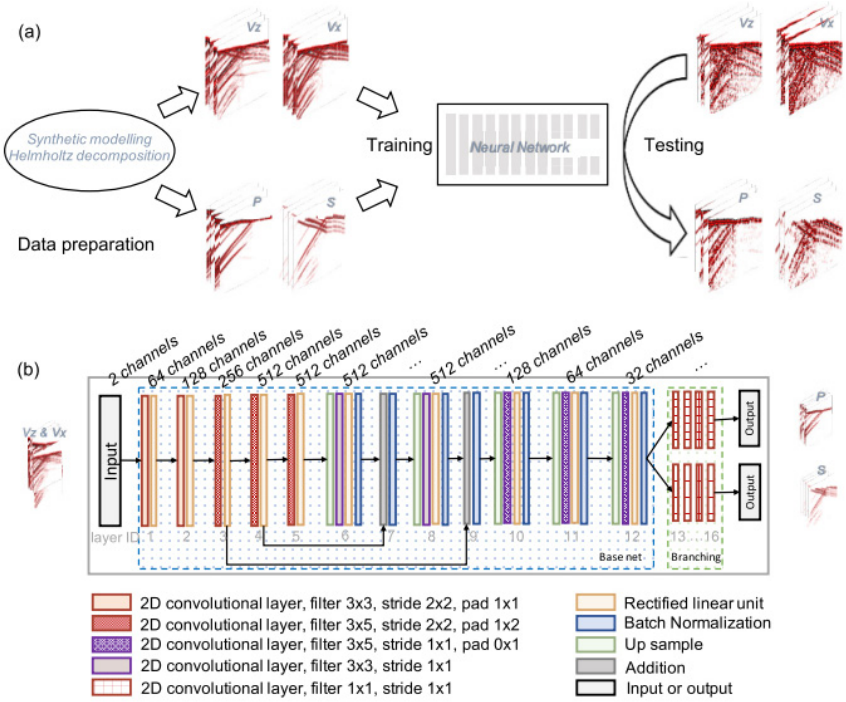

Fig. 7. Overall design of the proposed deep learning method. (a) Workflow. (b) Structure of the neural network (Wei *et al.*, 2022b).

로 이벤트 분리 기법의 연구가 활발히 진행되고 있다.

Wei *et al*.(2022b)은 VSP(vertical seismic profile) 자료에서 P파와 S파를 효과적으로 분리하기 위한 딥러닝 기반 방법을 제안하였다(Fig. 7). VSP 자료의 고해상도 이미지 생성에 필수적인 P파와 S파 분리를 자동화하여 복잡한 지질학적 조건에서의 한계를 극복하였다. 다중 구성 요소의 VSP 측정에서 P파와 S파 자료를 추출하기 위해 탄성파 시뮬레이션과 헬름홀츠 분해(helmholtz decomposition)를 기반으로 하는 완전 합성곱 신경망(fully convolutional neural network)을 사용한다. 결과적으로 기존 f-k 필터링 방법과 비교하여 딥러닝 방법의 우수성을 입증하였고, L1 손실 함수를 사용하여 더 나은 일반화 능력을 보여주었다.

Tao *et al*.(2023)은 지하 매체의 복잡한 구조를 분석하는데 어려움을 겪는 VSP 자료의 파동장 분리 문제를 해결하기 위해 고성능 GPU(graphic processing unit)를 사용한 딥러닝 방법을 제안하였다. 중국의 다양한 지질 환경에서 검증자료를 기반으로 한 학습자료 세트를 구축하고, 이를 이용해 다중 작업 학습 신경망을 학습시켜 효율적이고 정확한 파동장 분리를 달성하였다. 제안된 방법은 기존 파동장 분리 방법들에 비해 빠르고 정확하며, 복잡한 지질 조건을 가진 투포타이 지역의 실제 VSP 데이터에서도 일반화 능력과 입증하였다.

Abbasi *et al*.(2023)은 탄성파 자료에서 선형 및 비선형 이벤트, 그라운드 롤(ground roll), 무작위 잡음 등을 분리하기 위한 ALMD(adaptive linear-mode decomposition) 방법을 제안하였다. 탄성파 자료에서 반사 신호를 가리는 그라운드 롤 및 무작위 잡음을 효과적으로 분리하는 기존의 LMD(linear-mode decomposition) 방법을 확장한 방법이다. LMD는 Wiener 필터를 사용하여 이벤트를 진폭-주파수 모드로 분해하며, ALMD는 LMD의 분해 수준을 결정하기 위해, 분해된 모드와 입력 자료 간의 상관관계를 사용한다. 이를 통해 자료를 최소한의 혼합으로 선형 모드로 나누고, 순열 엔트로피와 첨도 기준을 사용하여 신호, 소음 및 혼합 모드를 자동으로 분리한다. ALMD는 최적의 모드 수 추정 및 자동 잡음 분리를 통해 입력 자료의 정확한 분리 및 재구성을 가능하게 한다.

초동 발췌

탄성파 탐사에서 초동(first break) 발췌는 근거리 속도 모델 구축에 필수적인 단계이다. 그러나 대규모 탄성파 탐사 자료처리는 시간이 많이 소요되며, 이는 특히 복잡한 근거리 구조에서 초동의 시간 변화를 고려할 때 더욱 어려워진다. 또한, 실제 자료에서 첫 도달 파형은 트레이스마다 크게 달라질 수 있으며, 이는 잡음에 의해 복잡해질 수 있다. 이러한 문제를 해결하기 위해 많은 연구자들이 자동화된 초동 발췌 알고리즘을 연구하고 있으며, 이 중에서도 특히 합성곱 신경망을 기반으로 하는 방법이 주목받고 있다. 이러한 연구들은 더 빠르고 정확한 초동 선택을 가능하게 하여 탄성파 자료의 품질을 향상시키고, 자료 해석과 모델링에 중요한 기여를 할 수 있다.

Yuan *et al*.(2022)은 수동으로 밀집된 초동을 발췌하는 시간 소모적인 작업을 해결하기 위해 완전 합성곱 SegNet을 사용한 자동 초동 발췌 방법을 제안하였다(Fig. 8). SegNet을 활용하여 CSG(common shot gather)에서 초동 자료와 배경을 자동으로 세분화하고, 채널 정규화된 확률 맵을 통해 웨이브폼(waveform) 분류와 초동 발췌의 품질을 통계적으로 평가한다. 또한, 25개의 층으로 이루어진 네트워크는 확률적 경사 하강법(stochastic gradient descent, SGD)을 사용하여 학습된다. 결과적으로 두 개의 자료 세트에서 약 97%의 재현율을 달성함으로써, 제안한 방법이 초동 발

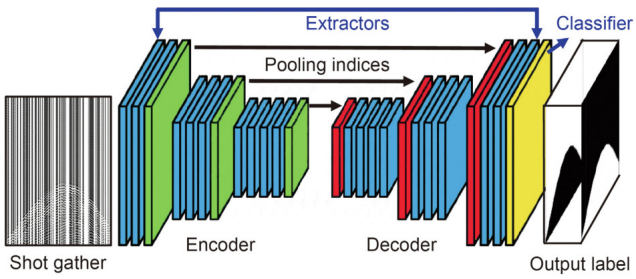

Fig. 8. SegNet architecture for seismic waveform classification and first-break picking directly from shot gathers with sparsely distributed traces. Blue boxes represent the convolution layers containing a convolution operation, a batch normalization operation, and an activation operation; green boxes represent the pooling operators; red rectangles represent the unpooling operators implemented by pooling indices computed in the pooling step; and the yellow box represents the Softmax classifier (Yuan *et al*., 2022).

췌의 자동화와 효율성을 향상시키는 동시에, 초동 발췌를 위한 앙상블 학습의 가능성을 입증하였다.

Loginov *et al*.(2022)은 탄성파 자료처리에 필요한 근거리 속도 모델을 구축하기 위해, 자동화되고 견고한 초동 발췌 알고리즘을 제안하였다. 대규모 탄성파 탐사 자료를 효율적으로 처리하기 위한 초동 발췌 전략과 CNN 모델구조를 개발하였다. 두 개의 자료 세트에서 알고리즘을 평가한 결과, 두 자료 세트 모두 원본과 예측된 초동 사이의 오차는 대부분의 트레이스에서 세 개의 샘플링 간격을 초과하지 않았다. 또한 트레이스 길이가 다른 트레이스에 적용 가능한 CNN 모델을 사용하며, 잡음, 초동, 신호 등 세 가지 클래스로 구성된 마스크를 학습 목표로 사용하였다. 결과적으로, 제안한 모델이 초동 발췌에 효과적임을 입증하였다.

Zwartjes and Yoo(2022)은 탄성파 자료에서 초동을 자동으로 발췌하기 위한 다양한 CNN 모델구조를 비교 및 평가하였다. 초동 발췌를 이미지 세분화 문제로 접근하고, 기계학습 기반 기법을 활용하여 자료에서 기본적인 특징을 학습하는 방식을 적용하였다. 결과적으로, 기본 U-Net이 ResNet 기능을 포함한 U-Net보다 우수함을 나타내었다.

탄성파속도 역산

지구 내부의 속도 구조에 대한 정확한 이해는 탄성파 자료의 해석과 지구 물리학적 연구에 필수적이다. 그러나 지질 구조의 복잡성, 탄성파 자료의 한계, 측정 환경의 제약으로 인해 정확한 속도 모델을 구축하기 어렵다. 이러한 문제를 해결하기 위해 많은 연구자들이 탄성파의 전파 경로와 속도 변화를 보다 정확하게 알아낼 수 있는 방법론을 개발하는 데 집중하고 있다. 특히, 컴퓨터 시뮬레이션, 알고리즘 최적화, 그리고 기계학습 기술을 활용한 속도 모델 역산 연구가 활발히 진행되고 있다.

Chen *et al*.(2022)은 저주파 탄성파 자료가 손실된 경우 발생하는 전체 파형 역산(full waveform inversion, FWI)의 국부 최소점(local minima) 문제를 해결하기 위한 새로운 속도 모델 역산 방법을 제안하였다. SCD(sparse-constrained deconvolution) 방법을 도입하여 자료의 시간 정보를 반사 시퀀스(sequence)로 전환함으로써, 시간 역산의 복잡성을 최소화하였다. 또한 위상변이(phase shift)에 영향을 받지 않는 E-SCD(envelope-based sparse-constrained deconvolution)를 개발하여, 재구성된 저주파 탄성파 자료로 다중 스케일 FWI를 수행하는 E-SCDI(envelope-based sparse-constrained deconvolution inversion) 방법을 제안하였다. E-SCDI는 시간 정보를 활용하는 효율적인 FWI 방법으로서, SCD를 통해 탄성파 자료의 시간 정보를 희소하게 표현할 수 있다.

Yang *et al*.(2023)은 복잡한 지질 영역에서 FTT(first arrival time tomography)의 한계를 해결하기 위해 FTT와 지도학습 기반 딥러닝(supervised deep learning, SDL)을 결합한 새로운 방법을 제안하였다. U-Net 네트워크 구조를 사용하여 FTT로 역산된 모델의 특성을 포착하고, 이를 정확한 실제 모델과 연결한다. 이 방법은 중국 서부 산악 지역의 현장 탄성파 자료에 적용되어 만족스러운 결과를 얻었으나, 학습된 신경망의 일반화 능력에는 한계가 있음을 보여주었다.

단층 및 암염 돔 탐지

탄성파 탐사 자료를 활용한 지하 구조 역산에서는 3차원 탄성파 자료를 통해 단층, 암염 돔(salt dome)등의 지질 구조를 식별하는 것이 핵심적인 작업이다. 기존 방식에서 탄성파 자료의 해석은 주로 통계적 방법이나 수동으로 라벨(label)을 붙이는 등의 방법으로 이루어졌으나, 이러한 접근법은 해석의 주관성이 높고 해석자의 지식 및 경험에 의존적이다. 이에 반해, 기계학습 기술을 이용한 접근법은 패턴 인식과 자동 특징 분류를 통해 지질 구조를 자동으로 예측하는 모델 개발로 이어지고 있다.

특히 단층 및 암염 돔 탐지 분야에서는 기계학습 기반의 네트워크에 지도학습 방식이 주로 적용되고 있다. 이러한 네트워크를 효과적으로 학습시키기 위해서는 단층이 명확히 식별된 학습자료가 필수적이며, 이를 위해 합성자료 생성, 라벨링 작업, 또는 실제 현장자료에 기반한 단층 정보 라벨링 등이 수행된다(Choi *et al*, 2020).

Liu *et al*.(2020d)은 자동 단층 감지 목표로 이미지 분할 문제의 접근방식을 제안하였다. U-Net 구조에서 잔차 연결을 사용한 ResUNet 모델을 사용하여 오프셋(offset) 벡터 타일 자료를 기반으로 한 단층 대 방위각 분석에 관해 연구하였다. 본 연구에서는 방위각 자료와 후처리 자료를 사용하여 단층 해석 결과를 비교하였으며, 비교 결과, 방위각 자료를 통해 단층을 해석할 경우 단층 구조가 잘 나타나는 결과를 확인하였다. 따라서 ResUNet을 방위각 자료에 적용하면 단층 탐지의 정밀도를 높이고, 단층의 측면 해상도 향상에 기여한다.

Wu *et al*.(2019)은 지도학습 기반 합성곱 신경망을 사용하여 단층 탐지를 이진 이미지 분할 문제로 접근하였다. 네트워크 학습을 위해 단층의 유무로 표시되는 이진 결함 이미지를 합성자료로 생성하였고, 생성한 단층 자료의 불균형을 조정하기 위해 클래스 균형 이진 교차 엔트로피 손실 함수를 사용하였다. 모델은 기존 U-Net 모델을 단순화한 모델을 사용하였으며, 해당 모델을 사용하여 합성자료로만 학습을 진행하였음에도 Fig. 9와 같이 현장자료에서도 단층을 정확하게 감지하는 것을 보여준다.

Gao *et al*.(2022)은 자동화된 단층 탐지를 위해 다중 스케

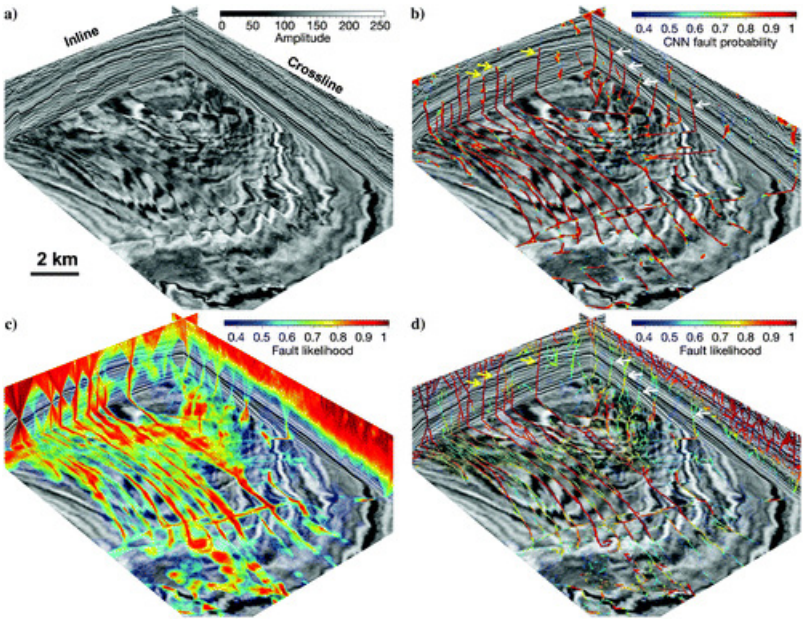

Fig. 9. (a) Three-dimensional seismic image displayed with faults that are detected using (b) the trained CNN model, (c) fault likelihood, and (d) thinned fault likelihood (Wu *et al*., 2019).

일 공간-채널 어텐션 합성곱 신경망(multiscale attention CNN, MACNN)을 개발하였다. MACNN을 통해 다양한 공간 해상도의 인코더 피쳐 맵을 병합하고 개선하기 위해, 다중 스케일 공간-채널 어텐션 메커니즘을 사용하였다. 연구 결과, 기존의 자동화된 단층 탐지 모델에 비해 더 높은 해상도와 향상된 단층 탐지 성능을 보인 것을 확인할 수 있다.

Yuan *et al*.(2019)에서 개발한 단층 탐지 방법은 적응형 스펙트럼 분해와 초해상도 딥러닝을 결합하여 지하 단층의 복잡한 구조를 고해상도로 파악한다. 이 방법은 3D 탄성파 자료의 스펙트럼 분해를 일반화된 S 변환으로 처리하고, 시간-주파수 스펙트럼에서 최적화된 3D 진폭 스펙트럼을 추출한다. 또한, 고해상도와 저해상도 이미지를 사용하여 SR 딥러닝 자료 세트를 구성하고, CNN을 통한 단층 탐지에서 우수한 성능을 보여준다.

암염 돔 경계면의 탐지 분야에서는 탄성파 영상에 대해서 지도학습을 이용하여 이미지 분할을 수행하는 연구가 주로 진행되고 있다. Shi *et al*.(2019)은 인코더-디코더 구조를 가진 심층 합성곱 신경망 모델을 기반으로 자동 암염 분할 방식을 제안하였다. 제안된 모델은 자료 증강 및 대규모 서브 볼륨(volume)으로 효과적인 학습을 수행하며, 암염의 특징을 자동으로 포착하고, 높은 정확도와 일반화 능력을 보인다.

앞서 설명한 지도학습 기반의 암염 탐지 모델에서 많은 양의 학습 자료가 필요하다는 단점을 보완하기 위해, Geng

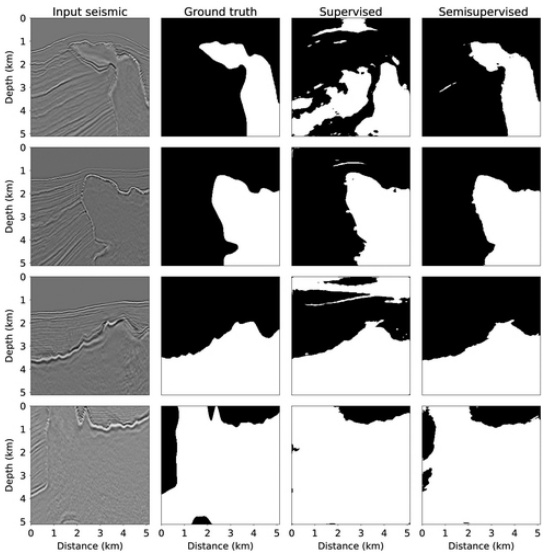

Fig. 10. Salt segmentation using semi-supervised learning (Geng *et al*., 2022).

et al.(2022)은 소량의 레이블이 지정된 자료만 필요로 하는 준지도학습 기반 암염 분할 기법을 제안하였다. 제안된 방법은 교사 모델(adopting the mean teacher method)을 채택하고, 지도학습 손실과 비지도학습 일관성 손실을 결합하여 입력 이미지가 다르게 증강될 때, 제안한 방법을 통해 일

관된 예측을 나타냄을 증명하였다. 더불어 합성자료 및 실제 현장자료를 적용한 지도학습 방법과의 비교를 통해 제안한 방법의 우수한 성능을 입증하였다(Fig. 10).

중력, 자력, 전기 및 전자 탐사 역산

전통적인 결정론적 역산법은 관측 자료에 기반한 모델을 반복적인 접근을 통해 최적화하는 과정으로 진행된다(Tarantola, 2005). 하지만 이러한 역산법은 높은 연산 비용, 불량 조건(ill-posed), 비 유일해, 불안정성, 비선형성, 낮은 수직 해상도 등의 문제를 내포하고 있다(Tikhonov and Arsenin, 1977; Zhdanov, 2015; Kim and Nakata, 2018). 또한, 역산 결과의 정확성은 초기 모델 설정과 제약조건, 그리고 역산 변수 설정에 크게 의존하고(Liu *et al*., 2021b), 이러한 문제를 해결하기 위해 역산 분야에 기계학습을 접목하는 연구가 다수 수행되어왔다.

Yang *et al*.(2021)에서는 U-Net 구조를 활용한 3차원 중력 역산을 제안하였다. 직육면체 이상체의 합성 밀도 모델로 합성자료를 생성하여 딥러닝 모델을 학습하였고, 전통 역산의 결과와 비교하여 제안된 기법의 성능을 입증하였다. Zhang *et al*.(2022)에서는 딥러닝 기반 중력 역산 모델인 DecNet을 제안하였다. DecNet은 하나의 인코더에 여러 디코더를 연결하여 이상체의 경계, 중심 오차, 이상체의 두께 그리고 이상체의 밀도값을 예측하는 네트워크로 설계되었다.

중력 탐사 역산과 유사하게, 자력 탐사에서도 합성곱 신경망을 이용한 역산 모델 개발 연구가 다양하게 진행되었다(Guo *et al*., 2021; Hu *et al*., 2021a). Shi *et al*.(2023)은 자력 필드의 세 가지 성분 자료와 여섯 가지 기울기 텐서 자료를 활용하여 3D U-Net 구조를 학습하였다(Fig. 11).

전기비저항 탐사 분야에서도 합성곱 신경망을 사용한 연구가 활발히 진행되었다(Aleardi *et al*., 2021; Aleardi *et al*., 2022). Liu *et al*.(2020a)은 겉보기 전기비저항 자료의 수직적인 패턴으로 인해, CNN을 사용할 때 야기되는 모호성 문제를 해결하기 위해서 U-Net을 적용하여 ERSInvNet을 설계하였다. 입력 자료에 계층 피쳐 맵을 추가하여 U-Net의 깊이 정보를 보완하였으며, 깊이 가중 함수와 평활화 제약 조건(smoothness constraint)을 통해 깊은 영역에 대한 역산 정확도를 높이고, 가짜 이상체(false anomaly) 반응을 억제하였다. Liu *et al*.(2020b)은 앞에서 소개한 방법과 달리, 인공적인 특성을 추가하지 않고 적응형 합성곱

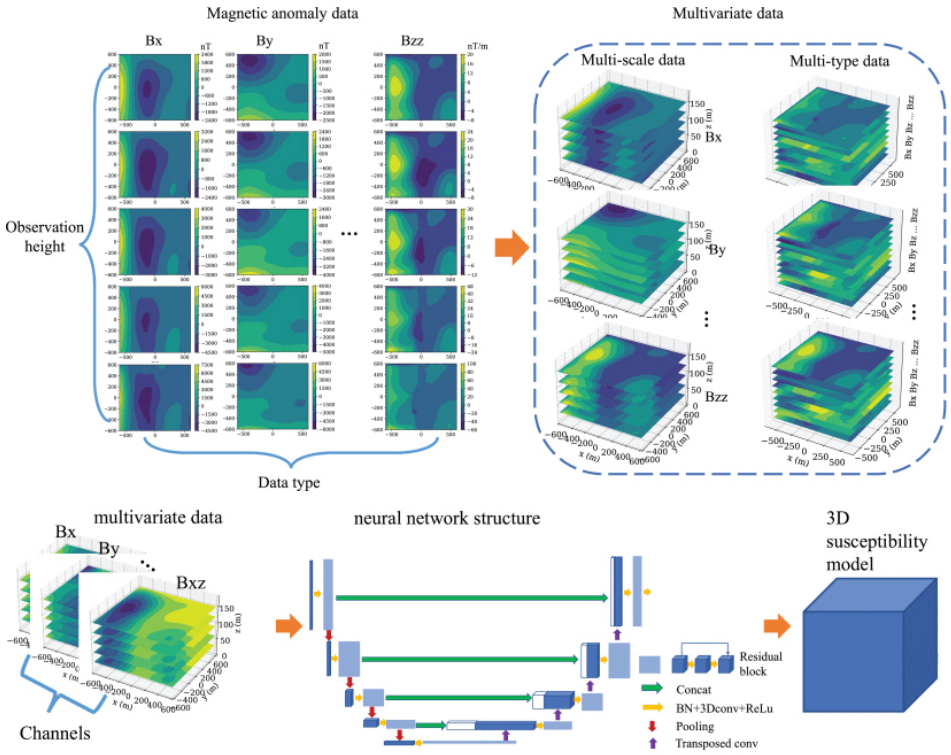

Fig. 11. Multiple types of magnetic field data and deep learning-based 3D magnetic inversion architecture (Shi *et al*., 2023).

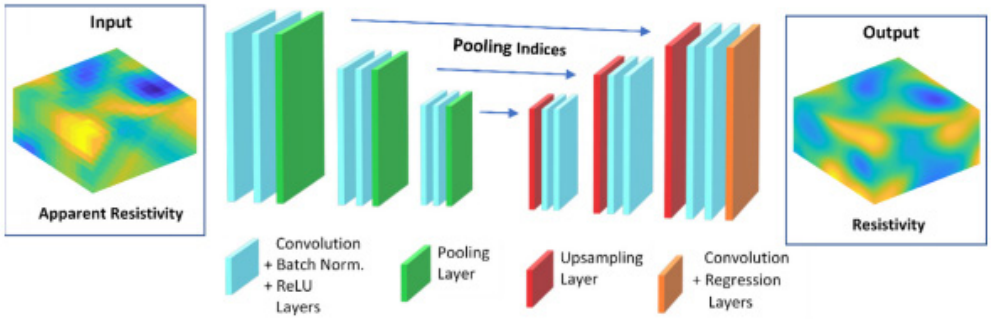

Fig. 12. Illustration of the proposed SegNet architecture. The architecture is developed with three-level encoder–decoder structure, including 45 layers in total; the classification layer at the output is replaced by a regression layer to recover the electrical resistivity map. The apparent resistivity from measurements feeds the input data for the network (Vu and Jardani, 2021).

신경망(adaptive convolution neural network, ACN)을 설계하여 겉보기 전기비저항 자료와 전기비저항 모델 쌍의 고유한 특성에 맞춰 합성곱 커널을 적응시켰다. 추가로, 모호한 패턴을 포착하기 위해 하위 2개의 계층은 수직 적응형 합성곱 커널(vertically adaptive convolutional kernels, VAC)을 사용하였으며, 손실함수는 자료 항, 평활화 항, 적대적 항 등으로 구성하였다. 정성적 및 정량적 평가를 통해 ACN이 ERSInvNet을 능가하는 성능을 보였다.

Vu and Jardani(2021)는 전기비저항 모델의 3차원 재구성을 위해 딥러닝 알고리즘을 제안하였다. 전기비저항 모델은 지리통계적 이방성 가우스 생성기로 생성하여 네트워크의 입력으로 사용하였으며, 그에 대응하는 겉보기 전기비저항은 3차원 푸아송 방정식(poisson's equation)을 수치적으로 해결하여 생성하였고, 이를 SegNet의 출력으로 사용하였다. 검증 자료의 분석을 통해 학습자료의 특성이 예측 결과의 품질에 상당한 영향을 미친다는 사실을 확인하였으며, 이는 목적에 맞는 학습자료 구축이 중요함을 시사한다(Fig. 12).

Wilson *et al*.(2022)은 변이형 인코더-디코더(variational encoder-decoder, VED) 네트워크를 설계하여 전기비저항 역산 모델을 개발하였다. 합성자료 및 현장자료 테스트에서 U-Net, U-Net with depth layer, Attention U-Net, Attention U-Net with depth layer models와 결과 비교를 통해 VED의 우수성을 입증하였다.

Aleardi *et al*.(2021)는 CNN을 사용하여 겉보기 전기비저항 자료를 이용하여 2차원 전기비저항 모델을 역산하였다. ERT(electrical resistivity tomography)의 과소 결정 문제(underdetermined problem)를 해결하기 위해, 이산 코사인 변환(discrete cosine transform, DCT)를 사용하여 CNN의 입력 및 출력의 차원을 압축하였고, DCT 재매개변수화를 모델 정규화를 위해 사용하였다. 전기비저항 모델은 단순 크리깅 지리통계학적 방법(Azevedo and Soares, 2017)을 사용하여 생성하였으며, 유한 요소법(Karaoulis *et al*., 2013)을 사용하여 생성된 모델에 대한 겉보기 전기비저항 자료를 계산하였다. 역산 모델은 모델의 불확실성을 추정하기 위해 몬테 카를로 시뮬레이션(monte carlo simulation)과 결합시켰고, 합성자료 및 현장자료 테스트 결과, 제안한 방법의 사용가능성을 보여 주었다.

Kong *et al*.(2023)은 단층 탐지에 최적화된 합성곱 신경망 기반 전기비저항 역산 모델을 개발하였다. 기존 박스형 전기비저항 모델과는 달리 복잡한 층서형 단층 모델을 생성하여 합성자료를 구성하였으며, U-Net에 시추 정보를 넣을 수 있도록 네트워크를 설계하였다. 또한 기존 전통 역산과 딥러닝 모델의 결과를 결합하여 역산 결과의 성능을 높였다.

전자탐사 분야에서도 앞서 소개한 탐사들과 유사하게 합성곱 신경망을 이용한 연구가 다수 소개되었다. Oh *et al*.(2018)는 해양 환경에서 암염 돔 구조를 식별하는 기술을 개발하였으며, 해양 전자탐사 자료를 사용하여 지하의 전기비저항 구조를 예측하는 데 합성곱 신경망을 적용하였다. Colombo *et al*.(2020b)은 유체 흐름 시뮬레이터(fluid flow simulators)와 결합된 전자탐사 기반 저류층 특성화 및 모니터링 구현을 위해 딥러닝 기술을 적용하였다. 물-가스 교대 주입(water-alternating-gas, WAG)을 시뮬레이션하여 저류층 내의 유체 포화도를 모델링하고, 이를 전자 탐사자료로 변환 후, U-Net을 이용하여 저류층의 전기비저항 변화를 예측하였다. 다양한 전자탐사 구성 요소, 잡음 테스트, 일반화 성능, 3차원 재구성에 대한 민감도 평가 등을 통해 제안한 방법의 효율성을 입증하였다.

합성곱 신경망 외에도 시계열 자료처리에 특화된 RNN 계열의 네트워크를 이용한 연구 사례도 있다. Li *et al*.(2020)은 시간영역 항공 전자 탐사(airborne electromagnetic, AEM)

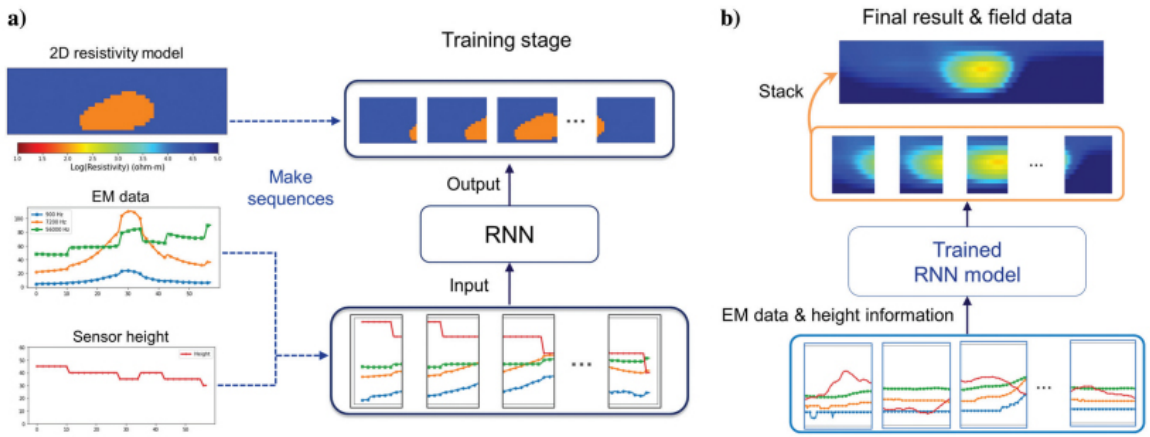

Fig. 13. (a) Schematic diagram of the workflow for training the RNN and (b) application of the trained RNN model to the field data set (Bang *et al*., 2021).

자료 역산에 4개의 CNN과 장단기 메모리(long short-term memory, LSTM) 네트워크를 결합하여 깊은 계층 구조를 구축하였다. 합성곱 신경망은 공간적 연결성을 활용하여 전자탐사 자료 내의 인접 채널 간 상관관계를 효과적으로 추출하였고, LSTM은 각 층의 전기비저항 값을 순차적으로 계산하였다. 입력 자료로는 비행 고도과 전자탐사 자료를 사용하였으며, 1차원 전기비저항 모델을 레이블로 활용하였다. 합성자료 테스트를 통해, 네트워크는 다양한 비행 고도에서 측정된 자료에 대해 안정적인 성능을 입증하였다. 더불어 잡음 수준에 대한 견고성 테스트를 통해, 네트워크의 강인성을 입증하였다. 캐나다 앨버타주의 포트 맥머레이(Fort McMurray, Alberta, Canada)에서 수집한 현장 자료에 대한 적용 결과, 전통적인 이론 기반의 1차원 occam 역산 방법과 비교하여 빠른 자료처리 속도를 나타냈다.

한편, Noh *et al*.(2020)은 DNN을 사용해 주파수 영역 항공 전자탐사 자료의 1차원 역산 연구를 수행하였고, 전통 가우스-뉴턴 역산(gauss-newton inversion)과 결과를 비교하였다. 하지만, 1차원 딥러닝 기반 역산은 고립된 전도성 이상체에 대한 예측 정확도가 낮아진다는 한계점이 있고(Kang *et al*., 2013), 이러한 문제점을 해결하고 공간 연속성을 고려하기 위해, Bang *et al*.(2021)은 RNN을 사용한 2차원 해석 방법을 제안하였다. 합성자료 및 현장자료를 사용하여 2차원 RNN 역산의 성능을 검증하였고, 클러스터링 방법인 t-SNE(t-distributed stochastic neighbor embedding)를 사용하여 합성자료와 현장자료의 유사성을 파악하여 RNN의 성능을 향상시켰다(Fig. 13).

복합 역산

기계학습 적용으로 역산의 정확도와 연산 효율은 높아졌지만, 단일 자료를 사용하였을 때는 여전히 비 유일해 문제를 가지고 있고, 이상체의 정확한 경계면과 수직적인 위치의 해석이 어렵다는 한계를 가진다(Oh *et al*., 2019; Huang *et al*., 2021).

이를 극복하기 위해 최근 기계학습 기반 복합역산 연구들이 제안되었다(Oh *et al*., 2019; Colombo *et al*., 2020a; Sun *et al*., 2020; Pratap Singh *et al*., 2021; Hu *et al*., 2021b; Wei *et al*., 2022a; Hu *et al*., 2023b). 탄성파 자료를 추가적인 제약 조건으로 한 CSEM(controlled source electromagnetic) 암염 돔 탐지(Oh *et al*., 2019), 중력자료와 자력자료를 동시에 사용하는 복합 역산(Wei *et al*.., 2022a; Jiao *et al*., 2023), 중력자료와 자력자료, 그리고 MT(magnetotelluric)을 활용하는 복합역산(Wei *et al*., 2021; Zeng *et al*., 2023), 그리고 탄성파 자료와 전자탐사 자료를 사용하여 암염 돔을 재구성하는 연구(Sun *et al*., 2020) 등이 수행되었다. Hu *et al*.(2023c)는 중력 기울기 자료와 자력 자료를 활용하여 딥러닝 기반 복합역산을 수행하였고, 제안한 방법이 기존 단일 역산 보다 높은 성능을 나타냄을 입증하였다.

딥러닝의 적용은 역산의 효율성과 성능을 향상시키지만, 학습된 모델이 학습자료에 지나치게 의존하는 경향이 있다. 현장자료가 학습자료와 다른 분포를 가질 경우, 모델이 정확한 예측을 수행하지 못한다. 이 문제를 해결하는 방법으로는, 합성자료를 활용해 사전 학습된 모델을 현장자료에 맞게 전이학습(transfer learning)하거나, 다양하고 복잡한 형태의 학습자료를 대규모로 생성하는 방법이 있다. 전자는 충분한 양의 학습자료를 확보하기 어렵고, 후자는 자료 생성에 높은 연산 비용이 든다고 알려져 있다. 또한, Li *et al*.(2019)은 기계학습 기반 탄성파 역산으로 얻은 속도 모

델과 탄성파 자료 간의 공간적 상관성 부재를 지적하며, 이는 기계학습 기반 역산 결과의 이론적 근거가 부족함을 시사한다. 이에 따라, 기계학습 기반 역산 결과의 신뢰성을 높이기 위해 신경망에 물리적 정보를 통합하거나 물리학 기반 학습을 진행하는 연구가 진행되고 있다(Biswas *et al*., 2019; Colombo *et al*., 2020a; Liu *et al*., 2022b; Noh *et al*., 2023b; Dhara and Sen, 2023).

지표투과 레이다 탐사

이 논문에서는 지표투과 레이다 자료에 기계학습 기법을 적용한 사례를 분류(classification), 객체 탐지(object detection), 그리고 위치 추정(localization and estimation) 등 세 가지 접근방식으로 분류하여 연구 내용을 조사하였다. 첫 번째는 GPR 자료에서 이상체의 존재 여부 및 해당 객체의 종류를 판별하는 분류 문제로, Liu *et al*.(2023)은 Instance segmentation과 Semantic segmentation을 이용한 M-YOLACT 모델을 개발하였다. B-scan 라벨을 사용하여 결함 위치에 대한 사전 정보로 이미지 마스크를 생성하고, 결함 검출과 쌍곡선 신호 검출 간의 충돌을 피하기 위한 피쳐 맵을 기반으로 터널의 라이닝과 쌍곡선 모양의 미세 식별을 수행함으로써 터널 내부의 복잡한 결함 반사 신호의 형태를 정확하게 식별하였다. Alpdemir and Sezgin (2023)은 클래스 활성화 맵(CAM) 기법의 여러 변형을 사용하여 B-scan 이미지에 색상 코드가 있는 열 지도를 중첩시켜 특정 공간 영역이 딥러닝 모델의 예측에 기여하고, 합성곱 신경망 기반 모델을 통해 2D 이미지의 특징을 효과적으로 추출하였다. 이는 GPR 처리 파이프라인에 대한 이전의 신호 처리 기술보다 정확한 설계로 이어져 GPR 이미지 식별 과정 수준이 향상되었음을 알 수 있다.

두 번째는 자료 내에서 이상체의 위치를 박스로 표시하는 객체 탐지로, 이 기술은 주로 공동, 파이프, 지반 이완대 등 지하 매설물을 파악하는 목적으로 사용된다. GPR 탐사 자료로부터 지하공동을 특정해 내기 위해 Choi *et al*.(2022)는 쌍곡선 신호를 자동으로 탐지하는 YOLOv3 모델을 학습하고, 3차원 입체 영상에 제안된 모델을 적용함으로써, 시간과 비용을 절약하고 탐사 정확도를 향상시켰다. Liu *et al*.(2023)은 B-scan 및 C-scan GPR 이미지를 통해 FDL (four-scale detection layers) 구조를 기반으로 한 YOLOv3 모델을 적용하여 도로 내부의 작은 균열에 대한 탐지 효과를 향상시켰다. 이는 균열의 스케일이 변하더라도 다방면으로 정확하게 검출할 수 있어 균열 탐지 네트워크의 정확도를 높인 결과를 보였다. Hu *et al*.(2023a)은 도심 도로 내부의 결함을 정확하고 효율적으로 탐지하기 위해 ECA (attention module)가 추가된 YOLOv5 기반 지하 결함 인식 모델을 제안하였다. 또한, GPR 자료를 기반으로 후행 간섭(trailing interference)을 필터링하고 지하 결함을 탐지하도록 설계된 M2FNet(Liu *et al*., 2023)은 하이브리드 CNN과 트랜스포머 인코더를 결합한 듀얼 백본(dual backbone)으로 다중 모드(multimodal) GPR 자료의 표현 학습(representing learning)을 향상시켰다. 이는 실제 공항 활주로의 GPR 자료에 대한 후행 간섭을 구별할 수 있는 현장 적용성이 우수한 면을 보여주었다. 아울러, 지하 파이프를 탐지하는 객체 탐지법 중에서 Yang *et al*.(2023)은 지하 파이프라인을 탐지할 때 발생하는 거대한 잡음 간섭 제거와 대상 반응 향상을 위해 CI-Net(clutter-immune net)을 제안하였다. 또한, Yang *et al*.(2023)에서는 convolution triplet attention module을 잔여 모듈(RSU)에 통합하여 다양한 스케일 특성을 가진 중요 지역을 식별하고, 네트워크의 적응적 기제(adaptive mechanism)을 통해 정확하고 포괄적인 객체 반응을 얻는 방법을 제안하였다. Choi *et al*.(2022)은 GPR 탐사자료의 공동을 탐지하기 위해 딥러닝 기반 방조제 공동 탐지 모델을 개발하였다. 동일한 방조제에서 자료 증강을 통해 학습자료 세트를 구축하였고, YOLOv5 모델을 이용하여 초기 모델 개발 후 앵커 박스 클러스터링, 전이학습, 자체 앙상블, 모델 앙상블 기법 등을 적용하여 최적의 모델을 도출하였다.

세 번째는 지하의 이상체 및 물체의 위치와 반경을 직접 예측하는 위치 추정 문제이다. GPR 자동 해석 연구의 초기 단계에서는 주로 이미지 처리 기술을 사용하여 이미지 특징을 분석하고 쌍곡선을 찾는 데 초점을 맞추었으며, 주로 허프 변환(hough transform, HT), 템플릿 매칭(template matching, TM), 에지 검출(edge detection) 등이 사용되었다(Su *et al*., 2023). 그러나 이와 같은 지하 매설물의 정보를 얻는 전통적인 방법들은 몇 가지 한계점이 존재한다. GPR 지하 시설물의 위치를 추정하기 위한 전통적인 방법에서 Terrasse *et al*.(2016)은 파이프의 이론적인 측정치와 지도학습 체계를 결합한 사전(dictionary)을 사용하여 가스관의 위치를 파악하는 방법을 제시하였으나, 이는 매개변수를 사전에 수동으로 설정해야 하고, 배경 잡음에 민감하다는 평가가 있었다. 또한, GPR 이미지 분석법 중 이론에 기반한 방법에서 Dou *et al*.(2016)은 GPR 이미지를 이진화하기 위한 적응형 임계값(adaptative threshold) 방법을 채택하여 쌍곡선 클러스터링을 수행하기 위해 열 연결 클러스터링(C3) 알고리즘을 설계했고, 직교 거리에 기반한 쌍곡선 피팅(fitting) 알고리즘을 제안하며, 매개변수 초기화 방법을 제공하였다. 하지만 이러한 방법들은 쌍곡선 매개변수에 민감하기 때문에, 지하 매설물의 반경을 추정하는 데 성능이 떨어지는 단점이 있다.

위와 같은 문제점들을 보완하기 위해, 인공지능의 발전 속도에 맞춰 GPR 이미지 처리 분야에도 딥러닝이 적용되

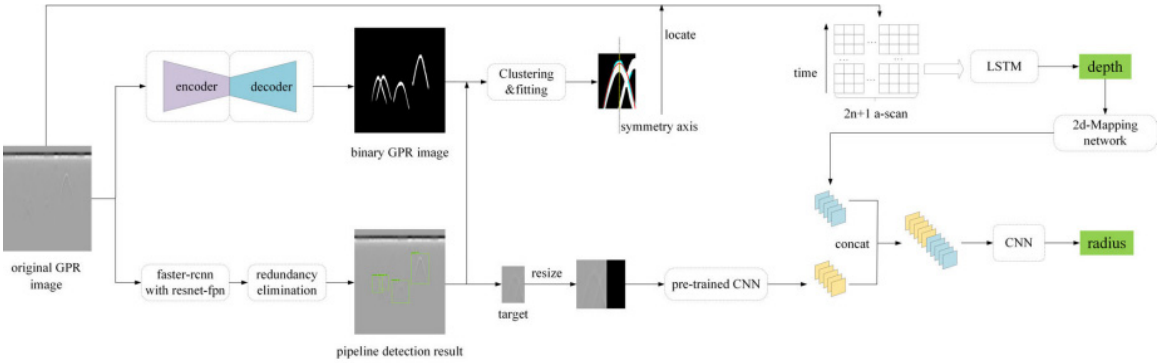

Fig. 14. Framework of depth and radius estimation (Xu *et al*., 2023).

어 지하에 존재하는 구조물이나 물체의 위치, 반경, 매몰된 깊이 등의 정보를 파악하는 연구가 진행되고 있다. Zhang *et al*.(2021)은 철도 인프라 모니터링 응용 프로그램에서 GPR B-scan 이미지를 사용하여 자료 부족을 해결하고, 자동으로 특징을 학습하는 GAN을 기반으로 한 딥러닝 프레임워크를 통해 지하 객체에 대한 평균적인 위치의 정확도를 향상시켰으며, 결과적으로 다른 단일 CNN 모델에 비해 높은 정확도를 나타냈다. Su *et al*.(2023)은 지하 매설물의 위치를 파악하기 위해 GPR B-scan 이미지를 자동적으로 해석하는 엔드 투 엔드 딥러닝 모델을 제안하여, 박스 피팅 모드(box fitting mode)가 아닌 키포인트 회귀 모드(key-point regression mode)를 채택했다. 또한 지하 매설물의 위치 좌표를 생성하였으며, 본 모델에 ECA를 추가하여 잡음 간섭을 관리하고, 높은 정확도를 보장하였다. Xu *et al*.(2023)은 지하 파이프의 깊이와 반경을 추정하는 것을 목적으로 연구를 진행하였는데, 자동 인코더 구조 네트워크로 이미지를 이진화하고, 반경 추정 단계에서 LSTM과 사전 훈련된 CNN을 통해 GPR 이미지 특징을 추출하는 작업을 수행하였다. 동시에 1차원의 깊이 정보를 2D 매핑 네트워크에 적용하여 이미지 정보와 유연하게 연결해줌으로써 제안된 모델의 실현 가능성과 효율성을 높게 평가하였다(Fig. 14).

도전 과제 및 향후 방향

이상의 연구 사례에서 살펴본 바와 같이 물리탐사 분야에서 기계학습, 특히 딥러닝 기술이 적극적으로 활용되고 있다. 초기 단계에서는 기존에 개발된 알고리즘의 적용에 초점을 맞춘 연구가 주를 이루었으나, 최근에는 물리탐사 분야의 지식을 활용하여 특수 환경에 최적화된 새로운 딥러닝 기술들이 개발되고 있으며, 실제 현장자료에 적용하기 위한 연구로 확장되고 있다. 그러나 물리탐사 자료를 활용한 딥러닝 기술의 실질적 적용에 있어서는 다음과 같이 아직 극복해야 할 여러 도전 과제들이 존재한다.

자료 부족 문제

일반적으로 딥러닝 기술의 성공 여부는 자료의 양에 비례하며, 특히 지도학습의 경우에는 정답 레이블이 필수적이다. 물리탐사 분야의 특성상 대량의 현장자료 및 레이블의 수집이 어려워, 이 문제를 해결하기 위한 다양한 접근법이 모색되고 있다. 자료 부족 문제에 대응하기 위한 직접적인 방법으로는 자료 증강 기술을 들 수 있다. 이 기술은 탄성파 자료 처리, 잡음 생성, 저류층 특성화, 역산 등의 분야에서 도메인의 지식과 생성모델을 활용한 연구들이 활발히 진행 중이다(e.g., Kim and Byun, 2020; Feng *et al*., 2021; Yang *et al*., 2022; Zhao *et al*., 2022; Zhou *et al*., 2023). 또한, 비지도학습, 준지도학습, 전이학습과 같은 접근법으로 자료 부족 문제를 해결하기 위한 연구들도 수행되고 있고(e.g., Alfarraj and AlRegib, 2019; Di *et al*., 2020; Liu *et al*., 2021a; Song *et al*., 2022), 최근에는 물리 법칙 기반의 지배 방정식을 기계학습에 적용하여 부족한 자료에서의 학습 성능을 높이고자 하는 물리정보 기계학습(physics-informed ML) 기법도 소개되고 있다(Rasht-Behesht *et al*., 2022; Song and Wang, 2023; Zhang *et al*., 2023). 또한, 부족한 현장자료를 대체하기 위해 합성자료를 사용하여 모델을 학습하는 경우, 학습자료와 현장자료의 이질성이 주요한 문제가 된다. 이를 보완하기 위해 다양한 연구가 진행되고 있으며, 이 중에는 학습자료와 현장자료를 전처리 단계에서 클러스터링을 통해 분석하거나, 도메인 적응(domain adaptation) 기법을 적용하는 접근방식 등이 포함된다(Park *et al*., 2021; Liu *et al*., 2024). 이 외에도 One-shot, Few-shot, Zero-shot learning(Pourpanah *et al*., 2022)과 같이 적은 양의 자료를 이용하여 학습을 수행하는 기법과 Active learning(Konyushkova *et al*., 2017)과 같이 사용자의 개입을 이용하는 방식 또한 부족한 자료를 보완하는 데 활용 가능할 것으로 판단된다. 이처럼 물리탐사 분야에서는 자료 부족 문제를 해결하기 위한 다양한 연구가 활발히 진행되고 있으며, 이 문제

의 해결은 현장에서의 성공적인 딥러닝 기술 적용을 위해 여전히 필수적인 과제이다.

기계학습 모델의 불투명성

또 다른 문제로는 기계학습 모델의 불투명성을 들 수 있다. 대부분의 딥러닝 모델은 블랙박스로 취급되어 예측 결과의 물리학적 타당성 및 투명성을 보장하기 어렵다. 특히, 석유 및 가스 탐사와 같이 높은 정확성과 결과의 신뢰성이 요구되는 물리탐사 응용 분야에서는 이러한 불투명성이 모델의 실용성을 제한할 수 있다. 따라서 이 문제를 해결하기 위해 물리 법칙을 내재한 물리정보 기계학습 기술이 도입되고 있고(Rasht-Behesht *et al*., 2022), 모델의 결정 과정을 해석할 수 있도록 하는 설명 가능한 인공지능(explainable artificial intelligence, XAI) 기법도 적용되고 있다(Maffezzoli, 2022; Birnie and Ravasi, 2023; Noh *et al*., 2023a). 모델 예측의 신뢰도를 정량적으로 평가하는 불확실성 추정(uncertainty estimation) 연구는 기계학습 분야에서 활발히 진행되고 있으며(e.g., Gal and Ghahramani, 2016), 이러한 연구는 물리탐사 분야에서도 기계학습 기반 자료처리 모델의 신뢰성과 해석 가능성 향상에 기여하고 있다(Liu *et al*., 2020c; Pham and Fomel, 2021; Oh and Byun, 2022). 따라서, 물리탐사 분야에서 기계학습 모델의 신뢰도 및 해석 가능성을 높이는 연구가 앞으로 더욱 중요해질 것이며, 이러한 연구는 딥러닝 기술의 현장 적용을 실질적으로 가능하게 하는 기반을 제공할 것으로 기대된다.

멀티모달 자료 통합 해석

현재는 대다수의 연구가 탐사자료에 딥러닝 기술을 개별적으로 적용하는 단계에 있지만, 앞으로는 다양한 유형의 탐사자료를 통합하여 분석하는 멀티모달(multimodal) 딥러닝 방식의 복합적 해석 연구가 확대될 것으로 보인다. 멀티모달 모델은 텍스트, 이미지, 오디오 등 다양한 형태의 자료를 통합하여 처리하는 방법으로, 자료 및 네트워크의 통합 방식에 따라 초기 통합(early fusion), 중간적 통합(intermediate fusion), 순차적 통합(late fusion) 방식으로 구분된다(Stahlschmidt *et al*., 2022). 초기 통합 방식은 다양한 입력을 동시에 하나의 네트워크만으로 학습하는 방법이며, 개발이 용이하지만 다양한 자료의 유용한 특징을 추출하기 어려운 단점이 있다(Fig. 15a). 중간적 통합 방식은 각 자료에서 추출된 특징들이 더 깊은 네트워크 층에서 결합되는 방식이다(Fig. 15b). 다양한 자료 간의 복잡한 상호작용을 정밀하게 모델링할 수 있으나, 모델의 복잡성이 증가하여 학습 및 최적화가 어렵다는 단점이 있다. 순차적 통합 방식은 개별 자료에서 독립적으로 특징을 추출한 후, 최종 단계에서 이를 통합한다(Fig. 15c). 이 방식은 모델의 복잡성을 줄이고 다양한 자료의 특성을 보존할 수 있으나, 자

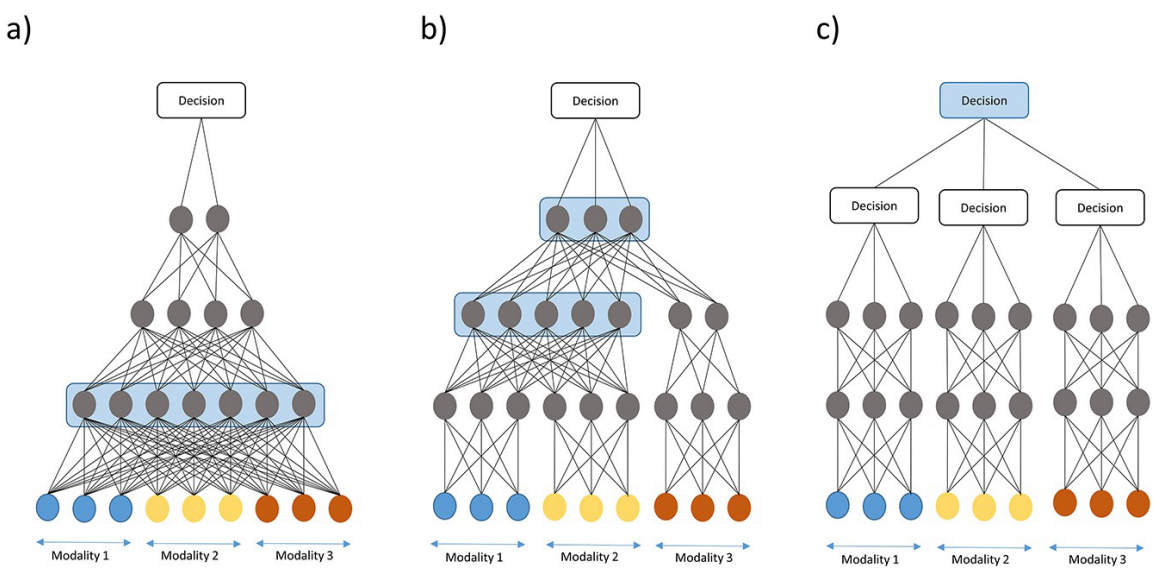

Fig. 15. DL-based fusion strategies Layers marked in blue are shared between modalities and learn joint representations. (a) Early fusion strategies take as input a concatenated vector. No marginal representations are learned. (b) Intermediate fusion strategies first learn marginal representations and fuse these later inside the network. This can occur in one layer or gradually. (c) Late fusion strategies combine decisions by sub-models for each modality (Stahlschmidt *et al*., 2022).

료 간의 상호작용을 직접적으로 모델링하는 데 제한이 있어 성능 저하의 가능성이 있다.

최근 물리탐사 분야 딥러닝 기반 복합역산 관련 연구의 대부분이 규격화된 자료를 통합하여 사용하는 초기 통합 방식을 따른다(e.g., Wei *et al*.., 2022a; Jiao *et al*., 2023). 하지만, 규격화된 자료가 아닌 다양한 자료 유형에서, 유용한 특성을 추출하고 자료들 간의 상관성을 최대화하여 해석의 정확도를 향상하기 위해서는 중간적 통합 방식으로의 연구가 필요할 것으로 생각된다. 또한, 이러한 접근법은 물리탐사 자료뿐만 아니라, 검층 자료, 지질 정보, 인공위성 자료 등 다방면의 자료를 포괄하는 멀티모달 통합 시스템 개발 연구로 발전할 것으로 예상되며, 이는 지구과학 분야에서의 자료 분석 및 해석 방식을 한 단계 진보시킬 것으로 기대된다.

결 론

이 논문에서는 물리탐사 분야에서 기계학습 및 딥러닝 기술의 최신 적용 사례와 발전 동향을 소개하였다. 탄성파 탐사, 중력 및 자력 탐사, 전기 및 전자 탐사, 지표투과 레이다 탐사, 그리고 복합역산 분야에서 딥러닝 기술의 활용 현황을 광범위하게 조사하였고, 다수의 연구에서 기존 이론 기반 접근법을 능가하는 성능을 보이는 딥러닝 기술의 적용 사례를 확인하였다. 또한, AI 분야에서 이미 개발된 딥러닝 기술을 단순히 적용하는 수준을 넘어, 물리탐사 자료에 최적화된 새로운 딥러닝 기술이 개발되고 있음을 확인하였고, 이는 물리탐사 분야에서 딥러닝이 새로운 패러다임으로 자리매김하고 있음을 시사한다.

그러나 이러한 기술적 진보에도 불구하고, 자료 부족, 모델의 불투명성, 학습자료와 현장자료 간의 이질성과 같은 도전 과제들이 여전히 존재한다. 따라서 이러한 문제를 해결하기 위한 연구와 기술개발이 지속적으로 이루어져야 하며, 이는 물리탐사 분야에서 딥러닝 기술이 효과적으로 활용되기 위한 필수 과정일 것이다. 향후 연구 방향에 있어서는, 모델의 투명성과 타당성을 향상시킬 수 있는 설명 가능한 인공지능(explainable artificial intelligence, XAI) 기법의 적용 확대, 다양한 탐사자료를 통합적으로 분석할 수 있는 멀티모달 및 데이터 퓨전 기법의 개발, 그리고 물리탐사 분야만이 가지고 있는 고유한 문제 해결을 위한 맞춤형 딥러닝 모델의 개발이 중요한 연구 주제가 될 것으로 보인다. 이러한 연구는 물리탐사 분야에서의 인공지능 기술의 성공적인 정착과 발전을 촉진할 것이며, 이를 통해 자원공학 및 지구과학 분야의 발전에 기여할 수 있을 것으로 기대된다.

사 사

본 연구는 2024년 해양수산부 재원으로 해양수산과학기술 진흥원의 지원을 받아 수행되었습니다(머신러닝 기반 해저면 특성 분류 기술개발)(관리번호: 20220254).

References

Abbasi, S., Yu, S., Akram, J., Alam, M.I., and Sarosh, B., 2023. An adaptive linear-mode decomposition for effective separation of linear and nonlinear seismic events, ground roll, and random noise, *Geophysics*, 88(4), p.V303-V315.

Aleardi, M., Vinciguerra, A., and Hojat, A., 2021. A convolutional neural network approach to electrical resistivity tomography, *Journal of Applied Geophysics*, 193, p.104434.

Aleardi, M., Vinciguerra, A., Stucchi, E., and Hojat, A., 2022. Probabilistic inversions of electrical resistivity tomography data with a machine learning-based forward operator, *Geophysical Prospecting*, 70(5), p.938-957.

Alfarraj, M. and AlRegib, G., 2019. Semi-supervised learning for acoustic impedance inversion, *Proceedings of the SEG Technical Program Expanded Abstracts 2019*, SEG, San Antonio, USA, p.2298-2302.

Alpdemir, M.N. and Sezgin, M., 2023. Analysis of Deep CNN-based Ground Penetrating Radar (GPR) Image Classification Process using Explainable AI, *2023 Innovations in Intelligent Systems and Applications Conference (ASYU)*, Sivas, Turkiye, IEEE, p.1-7.

Azevedo, L. and Soares, A., 2017. Geostatistical Methods for Reservoir Geophysics, *Berlin: Springer*, 141p.

Bang, M., Oh, S., Noh, K., Seol, S.J., and Byun, J., 2021. Imaging subsurface orebodies with airborne electromagnetic data using a recurrent neural network, *Geophysics*, 86(6), p.E407-E419.

Birnie, C. and Ravasi, M., 2023. Explainable artificial intelligence-driven mask design for self-supervised seismic denoising, *Geophysical Prospecting*, p.1-16.

Biswas, R., Sen, M.K., Das, V., and Mukerji, T., 2019. Prestack and poststack inversion using a physics-guided convolutional neural network, *Interpretation*, 7(3), p.SE161-SE174.

Chen, G., Yang, W., Liu, Y., Luo, J., and Jing, H., 2022. Envelope-Based Sparse-Constrained Deconvolution for Velocity Model Building, *IEEE Transactions on Geoscience and Remote Sensing*, 60, p.1-13.

Choi, B., Pyun, S., Choi, W., Jo, C., and Yoon, J., 2022. Deep-Learning-Based GPR Data Interpretation Technique for Detecting Cavities in Urban Roads, *Geophysics and Geophysical Exploration*, 25(4), p.189-200.

Choi, W.C., Lee, G.H., Cho, S.G., 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), p.97-114.

Colombo, D., Li, W., Rovetta, D., Sandoval-Curiel, E., and Turkoglu, E., 2020a. Physics-driven deep learning joint inversion, *Proceedings of SEG Technical Program Expanded Abstracts*, SEG, Virtual, p.1775-1779.

Colombo, D., Li, W., Sandoval-Curiel, E., and McNeice, G. W., 2020b. Deep-learning electromagnetic monitoring coupled to fluid flow simulators, *Geophysics*, 85(4), p.WA1-WA12.

Devlin, J., Chang, M.W., Lee, K., and Toutanova, K., 2018. *Bert: Pre-training of deep bidirectional transformers for language understanding*, arXiv preprint arXiv:1810.04805.

Dhara, A. and Sen, M.K., 2023. Elastic Full Waveform Inversion using a Physics guided deep convolutional encoder-decoder, *IEEE Transactions on Geoscience and Remote Sensing*, 61, p.5913118.

Di, H., Chen, X., Maniar, H., and Abubakar, A., 2020. Semi-supervised seismic and well log integration for reservoir property estimation, *Proceedings of SEG International Exposition and Annual Meeting*, SEG, Virtual, p.D031S061 R004.

Ding, M., Zhou, Y., and Chi, Y., 2024. Self-Attention Generative Adversarial Network Interpolating and Denoising Seismic Signals Simultaneously, *MDPI remote sensing*, 16, p.1-28.

Dong, X., Ling, J., Lu, S., Wang, H., and Li, Y., 2022. Multiscale Spatial Attention Network for Seismic Data Denoising, *IEEE Transactions on Geoscience and Remote Sensing*, 60, p.1-17.

Dou, Q., Wei, L., Magee, D.R., and Cohn, A.G., 2016. Real-Time Hyperbola Recognition and Fitting in GPR Data, *IEEE Transactions on Geoscience and Remote Sensing*, 55(1), p.51-62.

Fang, W., Fu, L., Xu, W., Bian, A., and Li, H., 2023. CCNet-5D: 5D convolutional neural network for seismic data interpolation, *Geophysics*, 88(4), p.V333-V344.

Feng, Q., Li, Y., and Wang, H., 2021. Intelligent random noise modeling by the improved variational autoencoding method and its application to data augmentation, *Geophysics*, 86(1), p.T19-T31.

Gal, Y. and Ghahramani, Z., 2016. Dropout as a bayesian approximation: Representing model uncertainty in deep learning, *Proceedings of the International Conference on Machine Learning*, PMLR, NY, USA, p.1050-1059.

Gao, K., Huang, L., Zheng, Y., Lin, R., Hu, H., and Cladohous, T., 2022. Automatic fault detection on seismic images using a multiscale attention convolutional neural network, *Geophysics*, 87(1), p.N13-N29.

Geng, Z., Hu, Z., Wu, X., Liang, L., and Fomel, S., 2022. Semisupervised salt segmentation using mean teacher, *Interpretation*, 10(3), p.SE21-SE29.

Goodfellow, I., Bengio, Y., Courville, A., and Bengio, Y., 2016. *Deep Learning*, MIT press, Cambridge, England, p.767.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., and Bengio, Y., 2014. Generative adversarial nets, *Advances in Neural Information Processing Systems*, 27.

Guo, J., Li, Y., Jessell, M. W., Giraud, J., Li, C., Wu, L., Li, F., and Liu, S., 2021. 3D geological structure inversion from Noddy-generated magnetic data using deep learning methods, *Computers & Geosciences*, 149, p.1-11.

Guo, Y., Fu, L., and Li, H., 2023. Seismic Data Interpolation Based on Multi-Scale Transformer, *IEEE Geoscience and Remote Sensing Letters*, 20, p.1-5.

He, K., Zhang, X., Ren, S., and Sun, J., 2016. Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, NV, USA, p.770-778.

Hinton, G.E., Osindero, S., and Teh, Y.W., 2006. A fast learning algorithm for deep belief nets, *Neural Computation*, 18(7), p.1527-1554.

Ho, J., Jain, A., and Abbeel, P., 2020. Denoising diffusion probabilistic models, *Advances in neural information processing systems*, 33, p.6840-6851.

Hu, H., Fang, H., Wang, N., Ma, D., Dong, J., Li, B., Di, D., Zheng, H., and Wu, J., 2023a. Defects identification and location of underground space for ground penetrating radar based on deep learning, *Tunnelling and Underground Space Technology*, 140, p.1-12.

Hu, Y., Chen, J., Wu, X., and Huang, Y., 2021a. Deep Learning Enhanced Joint Inversion of Multiphysics Data with Nonconforming Discretization, *Proceedings of the IEEE International Symposium on Antennas and Propagation and USNC-URSI Radio Science Meeting (APS/URSI)*, Marina Bay Sands, Singapore, p.1489-1490.

Hu, Y., Wei, X., Wu, X., Sun, J., Chen, J., Huang, Y., and Chen, J., 2023b. A deep learning-enhanced framework for Multi-physics joint inversion, *Geophysics*, 88(1), p.K13-K26.

Hu, Y., Wei, X., Wu, X., Sun, J., Huang, Y., and Chen, J., 2023c. 3D Joint Inversion of Multi-physics Data Using Deep Learning Techniques, *Proceedings of the URSI GASS 2023*, Sapporo, Hokkaido, Japan, p.1-4.

Hu, Z., Liu, S., Hu, X., Fu, L., Qu, J., Wang, H., and Chen, Q., 2021b. Inversion of magnetic data using deep neural networks, *Physics of the Earth and Planetary Interiors*, 311, p.1-18.

Huang, R., Liu, S., Qi, R., and Zhang, Y., 2021, Deep learning

3D sparse inversion of gravity data, *Journal of Geophysical Research: Solid Earth*, 126(11), e2021JB022476.

Iqbal, N., 2023. DeepSeg: Deep Segmental Denoising Neural Network for Seismic Data, *IEEE Transactions on Neural Networks and Learning System*, 34(7), p.3397-3404.

Jia, Y. and Ma, J., 2017. What can machine learning do for seismic data processing? An interpolation application, *Geophysics*, 82(3), p.V163-V177.

Jiao, J., Dong, S., Zhou, S., Zeng, Z., and Lin, T., 2023. 3-D Gravity and Magnetic Joint Inversion Based on Deep Learning Combined with Measurement Data Constraint. *IEEE Transactions on Geoscience and Remote Sensing*, 62, p.5900814.

Jo, Y., Choi, Y., Seol, S., and Byun, J., 2022. Machine learning-based vertical resolution enhancement considering the seismic attenuation, *Journal of Petroleum Science and Engineering*, 208:109657

Kang, S., Seol, S.J., Chung, Y., and Kwon, H.S., 2013. Pitfalls of 1D inversion of small-loop electromagnetic data for detecting man-made objects, *Journal of applied geophysics*, 90, p.96-109.

Karaoulis, M., Revil, A., Tsourlos, P., Werkema, D.D., and Minsley, B.J., 2013. IP4DI: a software for time-lapse 2D/3D DC-resistivity and induced polarization tomography, *Computers & Geosciences*, 54, p.164-170.

Khosro Anjom, F., Vaccarino, F., and Socco, L.V., 2024. Machine learning for seismic exploration: Where are we and how far are we from the holy grail?, *Geophysics*, 89(1), p.WA157-WA178.

Kim, D. and Byun, J., 2020. Data augmentation using CycleGAN for overcoming the imbalance problem in petrophysical facies classification, *Proceedings of the SEG International Exposition and Annual Meeting*, SEG, Virtual, p.D031S041R004.

Kim, Y. and Nakata, N., 2018. Geophysical inversion versus machine learning in inverse problems, *The Leading Edge*, 32(12), p.894-901.

Kingma, D.P. and Welling, M., 2013. *Auto-encoding variational bayes*, arXiv preprint arXiv:1312.6114.

Kong, S., Oh, J., Yoon, D., Ryu, D.W., and Kwon, H.S., 2023. Integrating Deep Learning and Deterministic Inversion for Enhancing Fault Detection in Electrical Resistivity Surveys, *Applied Sciences*, 13(10), p.6250.

Konyushkova, K., Sznitman, R., and Fua, P., 2017. Learning active learning from data, *Advances in Neural Information Processing Systems*, 30.

Krizhevsky, A., Sutskever, I., and Hinton, G.E., 2012. Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, 25.

Lee, D., Shin, S.R., Yeo, E.M., and Chung, W., 2024. Denoising sparker seismic data with Deep BiLSTM in fractional Fourier transform, *Elsevier Computers & Geosciences*, 184, p.1-9.

Li, J., Liu, Y., Yin, C., Ren, X., and Su, Y., 2020. Fast imaging of time-domain airborne EM data using deep learning technology, *Geophysics*, 85(5), p.E163-E170.

Li, J., Wu, X., and Hu, Z., 2022a. Deep Learning for Simultaneous Seismic Image Super-Resolution and Denoising, *IEEE Transactions on Geoscience and Remote Sensing*, 60, p.1-11.

Li, S., Liu, B., Ren, Y., Chen, Y., Yang, S., Wang, Y., and Jiang, P., 2019. *Deep-learning inversion of seismic data*. arXiv preprint arXiv:1901.07733.

Li, X., Wu, B., Zhu, X., and Yang, H., 2022b. Consecutively Missing Seismic Data Interpolation Based on Coordinate Attention Unet, *IEEE Geoscience and Remote Sensing Letters*, 19, p.1-5.

Liu, B., Guo, Q., Li, S., Liu, B., Ren, Y., Pang, Y., Guo, X., Liu, L., and Jiang, P., 2020a. Deep learning inversion of electrical resistivity data, *IEEE Transactions on Geoscience and Remote Sensing*, 58(8), p.5715-5728.

Liu, B., Guo, Q., Wang, K., Pang, Y., Nie, L., and Jiang, P., 2020b. Adaptive Convolution Neural Networks for Electrical Resistivity Inversion, *IEEE Sensors Journal*, 21(2), p.2055-2066.

Liu, B., Pang, Y, Jiang, P, Liu, Z., Liu, B., Zhang, Y., Cai, Y., and Liu, J., 2023. Physics-Driven Deep Learning Inversion for Direct Current Resistivity Survey Data, *IEEE Transactions on Geoscience and Remote Sensing*, 61, p.1-11.

Liu, J., Lin, Z., Padhy, S., Tran, D., Bedrax Weiss, T., and Lakshminarayanan, B., 2020c. Simple and principled uncertainty estimation with deterministic deep learning via distance awareness, *Advances in Neural Information Processing Systems*, 33, p.7498-7512.

Liu, N., He, T., Tian, Y., Wu, B., Gao, J., and Xu, Z., 2020d. Common-azimuth seismic data fault analysis using residual UNet, *Interpretation*, 8(3), p.SM25-SM37.

Liu, N., Wang, J., Gao, J., Chang, S., and Lou, Y., 2022a. Similarity-Informed Self-Learning and Its Application on Seismic Image Denoising, *IEEE Transactions on Geoscience and Remote Sensing*, 60, p.1-13.

Liu, N., Zhang, Y., Yang, Y., Wang, Z., Liu, R., and Gao, J., 2024. Domain Adaptation-based Sparse Time-frequency Analysis and Its Application on Seismic Attenuation Estimation, *Geophysics*, 89(3), p.1-55.

Liu, W., Wang, H., Xi, Z., Zhang, R., and Huang, X., 2022b. Physics-driven deep learning inversion with application to magnetotelluric, *Remote Sensing*, 14(13), p.3218.

Liu, X., Li, B., Li, J., Chen, X., Li, Q., and Chen, Y., 2021a. Semi-supervised deep autoencoder for seismic facies classification, *Geophysical Prospecting*, 69(6), p.1295-1315.

Liu, Z., Chen, H., Ren, Z., Tang, J., Xu, Z., Chen, Y., and Liu, X., 2021b. Deep learning audio magnetotellurics inversion

using residual-based deep convolution neural network, *Journal of Applied Geophysics*, 188, p.104309.

Loginov, G.N., Duchkov, A.A., Litvichenko, D.A., and Alyamkin, S.A., 2022. Convolution neural network application for first-break picking for land seismic data, *EAGE Geophysical Prospecting*, 70, p.1093-1115.

Luiken, N., Ravasi, M., and Birnie, C., 2024. Integrating self-supervised denoising in inversion-based seismic deblending, *Geophysics*, 89(1), p.WA39-WA51.

Maffezzoli, F., 2022. *Salt segmentation of geophysical images through explainable CNNs*, MS Thesis, Polytechnic University of Milan, Italy, 108p.

Noh, K., Kim, D., and Byun, J., 2023a. Explainable deep learning for supervised seismic facies classification using intrinsic method, *IEEE Transactions on Geoscience and Remote Sensing*, 61, p.1-11.

Noh, K., Pardo, D., and Torres-Verdin, C., 2023b. Physics-guided deep-learning inversion method for the interpretation of noisy logging-while-drilling resistivity measurements, *Geophysical Journal International*, 235(1), p.150-165.

Noh, K., Yoon, D., and Byun, J., 2020. Imaging subsurface resistivity structure from airborne electromagnetic induction data using deep neural network, *Exploration Geophysics*, 51(2), p.214-220.

Oh, S. and Byun, J., 2022. Bayesian uncertainty estimation for deep learning inversion of electromagnetic data, *IEEE Geoscience and Remote Sensing Letters*, 19, p.1-5.

Oh, S., Noh, K., Yoon, D., Seol, S.J., and Byun, J., 2018. Salt delineation from electromagnetic data using convolutional neural networks, *IEEE Geoscience and Remote Sensing Letters*, 16(4), p.519-523.

Oh, S., Noh, K., Yoon, D., Seol, S.J., and Byun, J., 2019. Cooperative deep learning inversion: Seismic-constrained CSEM inversion for salt delineation, *Proceedings of the SEG Technical Program Expanded Abstracts*, SEG, San Antonio, USA, p.1055-1059.

Park, H., Lee, J.W., Hwang, J., and Min, D.J., 2022. Coarse-Refine Network With Upsampling Techniques and Fourier Loss for the Reconstruction of Missing Seismic Data, *IEEE Transactions on Geoscience and Remote Sensing*, 60, p.1-15.

Park, J., Choi, J., Jee Seol, S., 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), p.V375-V388.

Pham, N. and Fomel, S., 2021. Uncertainty and interpretability analysis of encoder-decoder architecture for channel detection, *Geophysics*, 86(4), p.49-58.

Pourpanah, F., Abdar, M., Luo, Y., Zhou, X., Wang, R., Lim, C.P., Wang, X.Z., and Wu, Q.J., 2022. A review of generalized zero-shot learning methods, *IEEE transactions on pattern analysis and machine intelligence*, 45(4), p.4051-5070.

Pratap Singh, A., Vashisth, D., and Srivastava, S., 2021. Deep learning for joint geophysical inversion of seismic and MT data sets, *Proceedings of the SEG International Exposition and Annual Meeting*, SEG, Houston, USA, p.D011S071R006.

Rasht-Behesht, M., Huber, C., Shukla, K., and Karniadakis, G. E., 2022. Physics-informed neural networks (PINNs) for wave propagation and full waveform inversions, *Journal of Geophysical Research: Solid Earth*, 127(5), p.e2021JB023120.

Shi, X., Jia, Z., Geng, H., Liu, S., and Li, Y., 2023. Deep Learning Inversion for Multivariate Magnetic Data, *IEEE Transactions on Geoscience and Remote Sensing*, 62, p.1-10.

Shi, Y., Wu, X., and Fomel, S., 2019. SaltSeg: Automatic 3D salt segmentation using a deep convolutional neural network, *Interpretation*, 7(3), p.SE113-SE122.

Simonyan, K. and Zisserman, A., 2014. *Very deep convolutional networks for large-scale image recognition*, arXiv preprint arXiv:1409.1556.

Song, C. and Wang, Y., 2023. Simulating seismic multifrequency wavefields with the Fourier feature physics-informed neural network, *Geophysical Journal International*, 232(3), p.1503-1514.

Song, L., Yin, X., Zong, Z., and Jiang, M., 2022. Semi-supervised learning seismic inversion based on Spatio-temporal sequence residual modeling neural network, *Journal of Petroleum Science and Engineering*, 208, p.109549.

Stahlschmidt, S. R., Ulfenborg, B., and Synnergren, J., 2022. Multimodal deep learning for biomedical data fusion: a review, *Briefings in Bioinformatics*, 23(2), bbab569.

Su, Y., Wang, J., Li, D., Wang, X., Hu, L., Yao, Y., and Kang, Y., 2023. End-to-end deep learning model for underground utilities localization using GPR, *Automation in Construction*, 149, p.1-16.

Sun, Y., Denel, B., Daril, N., Evano, L., Williamson, P., and Araya-Polo, M., 2020. Deep learning joint inversion of seismic and electromagnetic data for salt reconstruction, *Proceedings of the SEG Technical Program Expanded Abstracts*, SEG, San Antonio, USA, p.550-554.

Tao, B., Yang, Y. Zhou, H., Wang, Y., Lyu, F., and Li, W., 2023. Deep learning-based upgoing and downgoing wavefield separation for vertical seismic profile data, *Geophysics*, 88(6), p.D339-D355.

Tarantola, A., 2005. Inverse Problem *Theory and Methods for Model Parameter Estimation*, Society for Industrial and Applied Mathematics, Philadelphia, USA, 333p.

Telford, W.M., Geldart, L.P., and Sheriff, R.E., 1990. *Applied geophysics (2nd Ed.)*, Cambridge University Press, Cambridge, England, 751p.

Terrasse, G., Nicolas, J.M., Trouvé, E., and Drouet, É., 2016. *Sparse decomposition of the GPR useful signal from hyperbola dictionary*, 24th European Signal Processing Conference (EUSIPCO), p.2400-2404.

Tikhonov, A.N. and Arsenin, V.Y., 1977. *Solutions of ill-posed problems*, Halsted Press, Winston, USA, 258p.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I., 2017. Attention is all you need, *Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017)*, Long Beach, CA, USA.

Vu, M.T. and Jardani, A., 2021. Convolutional neural networks with SegNet architecture applied to three-dimensional tomography of subsurface electrical resistivity: CNN-3D-ERT, *Geophysical Journal International*, 225(2), p.1319-1331.

Wang, F., Yang, B., Wang, Y., and Wang, M., 2022. Learning From Noisy Data: An Unsupervised Random Denoising Method for Seismic Data Using Model-Based Deep Learning, *IEEE Transactions on Geoscience and Remote Sensing*, 60, p.1-14.

Wei, N., Yang, D., Li, Y., Shi, Y., and Wang, Y., 2021. Joint 3D inversion of gravity, magnetic and magnetotelluric data using deep learning, *Proceedings of the Sixth International Conference on Engineering Geophysics*, SEG, Virtual, p.307-310.

Wei, N., Yang, D., Wang, Z., and Lu, Y., 2022a. Joint 3D inversion of gravity and magnetic data using deep learning neural networks, *Proceedings of the SEG International Exposition and Annual Meeting*, Houston, USA, p.D011S07 7R002.

Wei, Y., Li, Y.E., Zong, J., Yang, J., Fu, H., and Sun, M., 2022b. Deep Learning-Based P- and S-Wave Separation for Multicomponent Vertical Seismic Profiling, *IEEE Transactions on Geoscience and Remote Sensing*, 60, p.1-16.

Wilson, B., Singh, A., and Sethi, A., 2022. Appraisal of resistivity inversion models with convolutional variational encoder-decoder network, *IEEE Transactions on Geoscience and Remote Sensing*, 60, p.1-10.

Wu, M., Fu, L., Fang, W., and Cao, J., 2024. Sparse prior-net: A sparse prior-based deep network for seismic data interpolation, *Geophysics*, 89(1), p.V37-V47.

Wu, X., Liang, L., Shi, Y., and Fomel, S., 2019. FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation, *Geophysics*, 84(3), p.IM35-IM45.

Xu, Q., Wang, Z., and Li, X., 2023. Depth and Radius Joint Estimation for Underground Pipeline Using GPR, *IEEE Sensors Journal*, 23(13), p. 1-16.

Yang, H., Li, P., Ma, F., and Zhang, J., 2023. Building near-surface velocity models by integrating the first-arrival travel-time tomography and supervised deep learning, *Geophysical Journal International*, 235(1), p.326-341.

Yang, Q., Hu, X., Liu, S., Jie, Q., Wang, H., and Chen, Q., 2021. 3-D gravity inversion based on deep convolution neural networks, *IEEE Geoscience and Remote Sensing Lettters*, 19, p.1-5.

Yang, Y., Zhang, X., Guan, Q., and Lin, Y., 2022. Making invisible visible: Data-driven seismic inversion with spatio-temporally constrained data augmentation, *IEEE Transactions on Geoscience and Remote Sensing*, 60, p.1-16.

Yao, H., Ma, H., Li, Y., and Feng, Q., 2022. DnResNeXt Network for Desert Seismic Data Denoising, *IEEE Geoscience and Remote Sensing Letters*, 19, p.1-5.

Yeeh, 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), p.62-76.

Yu, J. and Yoon, D., 2023. Crossline Reconstruction of 3D Seismic Data Using 3D cWGAN: A Comparative Study on Sleipner Seismic Survey Data, *MDPI applied sciences*, 13(10), p.1-22.

Yuan, S.Y., Zhao, Y., Xie, Tao, Qi, J., and Wang, S.X., 2022, SegNet-based first-break picking via seismic waveform classification directly from shot gathers with sparsely distributed traces, *KeAi Petroleum Science*, 19(1), p.162-179.

Yuan, Z., Huang, H., Jiang, Y., Tang, J., and Li, J., 2019. An enhanced fault-detection method based on adaptive spectral decomposition and super-resolution deep learning, *Interpretation*, 7(3), p.T713-T725.

Zeng, Z., Han, J., Wang, T., Liu, L., and Chen, X., 2023. 3D Sequential Joint Inversion of Magnetotelluric, Magnetic and Gravity Data Based on Co-reference Model and Wide-range Petrophysical Constraints, *IEEE Transactions on Geoscience and Remote Sensing*, 61, p.4506213.

Zhang, S., Yin, C., Cao, X., Sun, S., Liu, Y., and Ren, X., 2022. DecNet: Decomposition network for 3D gravity inversion, Geophysics, 87(5), p.G103-G114.

Zhang, X., Han, L., Robinson, M., and Gallagher, A., 2021. A GANs-Based Deep Learning Framework for Automatic Subsurface Object Recognition From Ground Penetrating Radar Data, *IEEE Access*, 9, p.39009-09018.

Zhang, Y., Zhu, X., and Gao, J., 2023. Seismic inversion based on acoustic wave equations using physics-informed neural network, *IEEE transactions on geoscience and remote sensing*, 61, p.1-11.

Zhao, Y.X., Li, Y., and Wu, N., 2022. Data augmentation and

its application in distributed acoustic sensing data denoising, *Geophysical Journal International*, 228(1), p.119-133.

Zhdanov, M.S., 2015. *Inverse theory and applications in geophysics (2nd Ed.)*, Elsevier, Amsterdam, Netherlands, 730p.

Zhou, X., Chen, Z., Lv, Y., and Wang, S., 2023. 3-D Gravity Intelligent Inversion by U-Net Network With Data Augmentation, *IEEE Transactions on Geoscience and Remote Sensing*, 61, p.1-13.

Zwartjes, P. and Yoo, J., 2022, First break picking with deep learning – evaluation of network architectures, *Geophysical Prospecting*, 70, p.318-342.

유 지 윤

2023년 전남대학교 공과대학 에너지자원공학과 공학석사

현재 전남대학교 에너지자원공학과 박사과정
(E-mail; ujun917@gmail.com)

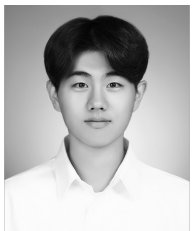

오 종 찬

2022년 전남대학교 공과대학 에너지자원공학과 공학사

현재 전남대학교 에너지자원공학과 석·박사통합과정
(E-mail; jongchano97@gmail.com)

공 신 혜

2023년 전남대학교 공과대학 에너지자원공학과 공학사

현재 전남대학교 에너지자원공학과 석사과정
(E-mail; kongsh9820@gmail.com)

이 창 훈

2023년 전남대학교 공과대학 에너지자원공학과 공학사

현재 전남대학교 에너지자원공학과 석사과정
(E-mail; chlee201220@gmail.com)

임 지 원

현재 전남대학교 에너지자원공학과 학사과정
(E-mail; alligator4252@gmail.com)

윤 대 웅

2018년 한양대학교 연구교수

현재 전남대학교 에너지자원공학과 교수
(E-mail; duyoon@jnu.ac.kr)