



Article

# 제주분지 내 석유시스템 모델링을 위한 탄성파 자료와 암상모델의 3차원 확장 기법 연구

이주완<sup>1</sup>, 한승훈<sup>1</sup>, 박수환<sup>1</sup>, 이준우<sup>2</sup>, 전재호<sup>3</sup>, 백세익<sup>3</sup>, 조용채<sup>1,\*</sup>

<sup>1</sup>서울대학교 에너지시스템공학부

<sup>2</sup>한국지질자원연구원 탄소저장연구센터

<sup>3</sup>한국석유공사 국내사업개발처

## Research on the expansion method of 3D seismic data and lithology estimation data for petroleum system modeling in the Jeju Basin

Juan Lee<sup>1</sup>, Seunghun Han<sup>1</sup>, Soohwan Park<sup>1</sup>, Jun-Woo Lee<sup>2</sup>, Jaeho Jun<sup>3</sup>, Seik Paik<sup>3</sup>, Yongchae Cho<sup>1,\*</sup>

<sup>1</sup>Energy Systems Engineering, Seoul National University, Seoul, Republic of Korea

<sup>2</sup>Geological Carbon Storage Research Center, Korea Institute of Geoscience and Mineral Resources, Daejeon, Republic of Korea

<sup>3</sup>Korea National Oil Corporation, Ulsan, Republic of Korea

Received: December 16, 2025 / Revised: February 20, 2026 / Accepted: February 23, 2026

\*Corresponding author: +82-2-880-7397 / E-mail: yc.cho@snu.ac.kr

**요약:** 암석의 특성과 퇴적학적 특징을 분석하여 지하구조를 해석하고, 이를 통해 석유 시스템 모델링을 정밀하게 수행하기 위해서는 취득한 데이터의 품질 향상이 필수적이다. 이는 석유 시스템 모델링에 필요한 기초를 제공하는 역할을 한다. 본 연구에서는 인공지능을 기반으로 한 2차원 탄성파 자료의 3차원 체적 확장 및 이를 활용한 3차원 암상 분류 기법을 개발한다. 3차원 체적 확장 기법은 생성형 인공지능경망을 기반으로 개발되었다. 무작위한 잡음 벡터를 활용한 생성형 인공지능경망 기반 3차원 체적 변환 기술은 넓은 간격의 2차원 자료의 공백을 보간하는 데에 높은 성능을 보였다. 또한 암상 분류 기법은 U-Net을 기반으로 한 인공지능경망 모델을 기반으로 개발되었다. 본 연구에서는 취득한 자료를 대상으로 암상 역산이 완료된 자료를 학습 자료로 사용하여 네트워크를 학습하였고, 이를 통해 탄성파 자료와 암상 분포의 상관관계를 반영하였다. 이후 지구통계학적 방법을 활용하여 3차원 암상 분포를 제작할 때, 체적 확장 기법으로 변환된 3차원 탄성파 자료를 보조자료로 활용하였다. 이를 통해 최종적으로 탄성파 자료의 특성을 반영한 대상 지역 내의 3차원 암상 모델을 취득하였다.

**주요어:** 탄성파 자료, 체적 변환, 암상 분류, 인공지능경망, 석유시스템 모델링

**ABSTRACT:** To analyze rock properties and sedimentological characteristics to interpret subsurface structures and accurately model petroleum systems, improving the quality of acquired data is essential. This process serves as a foundation for petroleum system modeling. In this research, we develop an AI-based 3D volume expansion method for 2D seismic data and a 3D lithofacies classification method using the expansion method. The 3D volume expansion method was developed based on a generative artificial neural network. The 3D volume transformation method, based on an artificial neural network utilizing random noise vectors, demonstrated high performance in interpolating gaps in widely spaced 2D data. Furthermore, the lithofacies classification method was developed based on an artificial neural network model based on U-Net. In this research, the network was trained using data with completed lithofacies inversion from the acquired data, thereby reflecting the correlation between seismic data and lithofacies distribution. The 3D seismic data expanded using the volume expansion method were then used as supplementary data when generating a 3D lithofacies distribution using geostatistical methods. Through this, a 3D lithofacies model within the target area reflecting the characteristics of the elastic wave data was finally obtained.

**Key words:** seismic data, volume expansion, lithofacies classification, artificial neural network, petroleum system modeling

## 1. 서론

지구 내부 구조를 상세하게 파악하고자 하는 목적으로 탄성과 탐사는 오랜 기간 널리 사용되어 왔다(Yilmaz, 2001). 해양 탄성과 탐사는 주로 석유 등과 같은 자원 탐사 및 부존량 평가 등에 사용되어 왔다. 최근에는 탄소와 같은 유체 지층 저장 목적의 부지 선정 및 주입 이후의 유체 거동을 파악하는 목적으로도 활용된다. 탄성과 탐사의 궁극적인 목적은 광범위한 지하 구조의 물성과 암상 등을 파악하여 석유 시스템 모델링을 통해 탐사나 유체 지층 저장의 성공 확률을 높이는 것이다(Magoon and Dow, 1994; Hantschel and Kauerauf, 2009). 탄성과 탐사는 탐사 대상이 되는 공간의 규모에 따라 2차원 탄성과 탐사와 3차원 탄성과 탐사로 나뉜다. 2차원 탄성과 탐사는 인공적인 탄성과 송신원과 탄성과 수신기를 하나의 측선에 배치하여 해당 측선에 수직인 지하구조 평면 데이터를 얻는다. 반면, 3차원 탄성과 탐사는 인공적인 탄성과 송신원과 탄성과 수신기를 격자와 같은 평면 형태로 배치한다.

3차원 탄성과 탐사로 취득하는 데이터가 2차원 탄성과 탐사로 취득하는 데이터에 비해서 질적으로 우수함은 자명하다. 단층, 층서구조 등 지구 내부의 지질학적 구조를 파악하는 데에는 3차원 탄성과 탐사가 훨씬 용이하며, 탐사의 목적을 달성하는 데 훨씬 크게 기여한다(Brown, 2011). 다만 3차원 탄성과 탐사 과정은 2차원 탄성과 탐사 과정에 비해 높은 경제적 비용을 소모하며, 훨씬 더 많은 시간을 필요로 한다. 또한 3차원 탐사 수행 시 취득되는 데이터의 양 역시 2차원 탐사에 비해 방대하며, 이를 처리하여 의미 있는 데이터로 가공하는 과정도 큰 연산비용을 소모한다. 현실적인 제약으로 인해 넓은 구조에 대해 2차원 탄성과 탐사를 우선적으로 진행한 후, 유망성이 예상되는 좁은 지역에 대해 3차원 탄성과 탐사를 수행하는 방식으로 진행되는 경우가 보편적이다.

또한 암상 분류의 경우 전통적으로 시추공을 통해 취득한 물리검층 자료를 바탕으로 암상을 분류하지만(Ma and Zhang, 2019; Datta *et al.*, 2021), 해당 암상 추정 결과를 광범위한 영역에 확장하는 것은 본질적으로 불확실성을 내재하고 있다는 단점이 존재한다. 지구통계학적인 방법을 통하여 추정한 암상을 3차원으로 확장하는 경우 다양한 이방성 변수 등을 투입하여 불확실성을 줄일 수 있지만(Chiles and Delfiner, 2012), 추정하고자 하는 영역이 넓어질수록 그 불확실성은 기하급수적으로 올라가기 때문에 광범위한 영역의 암상을 추정하는 경우 보조자료로서 지형학적 구조나 탄성과 자료 등을 활용하게 된다(Miall, 2013).

따라서 2차원 탄성과 자료의 체적 확장 기술은 지질학적 해석 및 의사결정에 매우 크게 기여한다. 비단 탄성과 자료

뿐만 아니라, 이를 통해 해석한 암상 분포 자료를 3차원으로 확장하는 것은 궁극적으로 보다 정확한 석유시스템 모델링에 기여할 수 있다. 실제로 2차원 평면을 활용하여 체적으로 확장하는 방법론에 대한 연구는 꾸준히 진행되어 왔다. 전통적인 방법으로는 SCI (Structurally Conformable Interpolation)가 있다(Whiteside *et al.*, 2013). 이 기법은 2차원 자료에 대해 구조 보정을 수행한 후 역과정을 반복하고, 이후 3차원으로 구조 보정을 수행하는 과정이다. 다만 전처리 과정이 매우 복잡하고, 전문가의 층서 해석(horizon picking)이 필요하다는 한계점도 지닌다. 크리깅(Kriging) 방법을 기반으로 보간을 진행하는 지구통계학적 방법도 존재한다(Deutsch and Journel, 1992). 다만 복잡한 구조를 표현하기 어렵고, 보간 주체의 주관이 개입된다는 단점이 존재한다. 최근에는 머신러닝 기법 및 인공신경망의 기술 발전으로, 이를 기반으로 한 체적 확장 기법이 개발되고 있다(Lu *et al.*, 2019; Lee *et al.*, 2024, 2025). 이러한 방법론은 본질적으로 결정론적 방법에 입각해있으며, 단일한 해를 추정하는 경향성을 보인다. 또한 조밀하게 분포되지 않은 2차원 자료를 입력받는 경우, 가능한 구조의 평균치를 보여주기에 2차원 자료에서 상대적으로 먼 부분은 무의미한 값을 반환한다. 각 위치에서 추론 가능한 값의 기댓값을 근사하는 방식인 것이다.

암상 분류의 경우에도 최근 머신러닝 기법의 발전과 함께 직접적으로 추론할 수 없는 영역을 추론하고자 하는 시도가 진행되고 있다. 전통적인 머신러닝으로 암상을 추정하거나(Yin *et al.*, 2023), 나아가 딥러닝 모델을 활용하여 암상을 분류하고자 하는 모델(Abdullah *et al.*, 2024) 등이 최근 활발하게 진행되어 광범위한 영역의 암상을 추정함에 있어 불확실성을 줄이고자 하였다.

본 연구에서는 제한된 2차원 탐사의 한계를 극복하기 위해 인공신경망을 기반으로 탄성과 자료의 체적 변환 기법과 암상 분류 기법을 개발하고, 해당 기법을 모두 이용하여 최종적으로 관심영역의 3차원 암상 모델링을 추정한다. 이를 통해 기존 시추공 정보 기반의 암상 모델링 기법에 비해 더욱 많은 자료의 경향성이 반영되어 보다 현실적이고 정교한 석유시스템 모델링에 기여하는 암상 모델링 결과를 제시하는 것이 목표이다.

## 2. 배경이론

### 2.1. 변분 오토인코더(Variational Auto-Encoder; VAE)

변분 오토인코더는 확률적 잠재 공간을 통해 입력 데이터의 분포를 모델링하는 인공신경망 모델로, 입력 데이터의 구조적인 패턴을 효과적으로 포착하여 압축하고, 이를 다시 재구성할 수 있다는 장점을 갖는다(그림 1). VAE는

인코더(encoder), 디코더(decoder), 잠재공간의 세 요소로 구성된다. 인코더는 입력된 값을 하나의 값이 아니라 평균과 분산으로 이루어진 정규분포 형태로 매핑하고, 디코더는 이 분포에서 샘플링된 값을 이용해 입력을 재구성한다(Kingma and Welling, 2013).

이와 같은 구조는 잠재 공간을 연속적이고 정규화된 형태로 유지하기 때문에, 서로 다른 데이터 간의 전역적 특징을 잘 포착하도록 유도한다. 반면, 국부적인 경향성이나 고주파 성분과 같은 지역적 특징은 상대적으로 덜 강조되는데, 이는 VAE가 구조적 특성을 중점적으로 학습하는 데 유리하게 작용한다.

이러한 이유로 VAE는 입력 데이터의 세부 노이즈나 지역적 변화를 지나치게 모사하려 하기보다는, 데이터 내 잠재적 구조와 전역적 형태를 잡아내는 데 강한 특징을 갖는다. 따라서 복잡한 지질 구조의 전반적인 형태를 파악하거나, 여러 입력이 서로 다른 특성을 가지고 있을 때 공통적인 구조적 패턴을 학습해야 하는 문제에 효과적으로 적용될 수 있다.

## 2.2. 벡터양자화 변분 오토인코더(Vector-Quantized Variational Auto-Encoder; VQ-VAE)

벡터양자화 변분 오토인코더는 기본적인 VAE 구조에서 연속적인 잠재공간을 이산적인 ‘코드북(codebook)’으로

치환한 모델로, 입력 데이터를 이산화되고 구조화된 잠재 표현으로 변환하는 특징을 갖는다(그림 2). VAE가 입력된 자료를 정규분포와 같은 연속적 확률분포로 모델링하는 것과 달리, VQ-VAE는 입력을 미리 정의된 여러 개의 코드벡터 중 하나로 양자화한다(Van *et al.*, 2017). 인코더의 잠재 표현 정의 방식은 아래와 같다.

$$z_{q(x)} = \arg \min_{e_k} |z_e(x) - e_k|$$

모든 입력은 코드북에 존재하는 한정된 표현 중 하나로 강제 매핑되며, 디코더는 이 이산 잠재벡터를 기반으로 원래 데이터를 복원한다. 이러한 벡터 양자화 과정은 잠재공간의 표현을 크게 단순화시키고, 모델이 데이터의 전역적 구조나 패턴을 강하게 포착하도록 만드는 효과가 있다.

이러한 구조로 인해 VQ-VAE의 잠재공간은 해석 가능하며, 구조적 패턴을 더 명확히 분리하는 특징을 갖는다. 특히 세부 텍스처보다 전역적 형태가 중요한 문제에서 강력한 성능을 보이며, 데이터 내의 지역적인 변동이나 잡음이 심하더라도 일관된 구조적 특징을 보존하는 데 유리하다.

따라서 VQ-VAE는 복잡한 지질 구조나 대규모 3차원 볼륨처럼, 전역적 구조를 안정적으로 추출해야 하는 문제에서 효과적으로 활용될 수 있다. 실제로 해당 인공지능망 구조를 활용하여 지층 해석을 자동화한 연구도 존재한다(Yuan




Fig. 1. Structure of VAE (modified from Kingma and Welling, 2013).

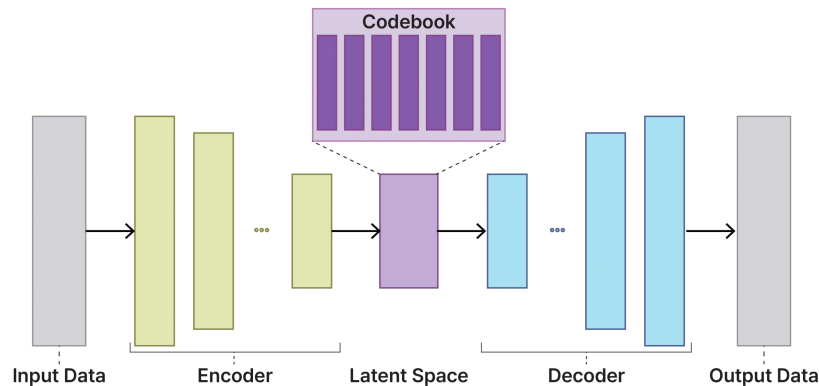


Fig. 2. Structure of VQ-VAE (modified from Van *et al.*, 2017).

et al., 2022). 또한 잠재공간이 이산적으로 구성되어 있기 때문에, 이후 타 인공지능망과의 결합이 용이하다.

### 2.3. 생성적 적대 신경망(Generative Adversarial Network; GAN)

생성적 적대 신경망은 생성 신경망 모듈과 판별 신경망 모듈이 서로 적대적인 구조로 경쟁하여 데이터 분포를 학습하는 대표적인 생성모델이다(그림 3). 생성 신경망 모듈은 실제 데이터처럼 보이는 샘플을 만들어내고, 판별 신경망 모듈은 그것이 실제인지 가짜인지를 구분하도록 학습한다. 이러한 두 신경망 모듈 간의 적대적인 관계를 통해 전체 신경망이 학습된다(Goodfellow et al., 2020).

GAN의 생성 신경망 모듈은 임의의 잠재변수를 입력받아 데이터와 유사한 샘플을 만들어낸다. 반면 판별 신경망 모듈은 주어진 입력이 실제 데이터인지 생성된 샘플인지 판별하는 확률값을 출력한다. 판별 신경망 모듈은 실제 데이터를 높은 확률로, 생성자의 출력을 낮은 확률로 판정하려고 하고, 생성 신경망 모듈은 판별 신경망 모듈을 속이기 위해 보다 사실적인 샘플을 만들어내려 한다.

이 모델의 가장 큰 장점은 명시적 확률모델링 없이도 매우 높은 표현력의 생성 결과를 얻을 수 있다는 점이다. GAN은 고주파 성분 및 지역적 특성을 사실적으로 재현하는데 매우 뛰어나다. 이 특성 때문에 본 구조는 고해상도 이미지 생성 및 자료의 고품질 복원 등에서 폭넓게 활용된다. 지구물리 분야에서도, 탄성과 신호의 품질 향상을 위해 사용된 연구사례가 존재한다(Goyes-Peñañiel et al., 2024).

### 2.4. 스타일GAN(StyleGAN)

생성적 적대 신경망은 고해상도 이미지를 생성하고자 기존 GAN 구조에서 파생된 인공지능망 구조이다(Karras et al., 2019). 이는 기존 GAN과 달리 생성 과정에 존재하는 변수의 의미를 보다 명확하게 분리하고 제어할 수 있도록 설계되었다. 기존 GAN에서는 입력되는 잡음이 곧바로 생성 신경망 모듈에 전달되어 이미지를 생성한다. 하지만 StyleGAN은 잠재 공간을 먼저 비선형 매핑 네트워크를 거치게 한 후 생성 신경망 모듈에 전달한다(그림 4). 이렇게 변환된 잠재벡터는 이미지의 전반적인 구조와 세부적인 특




Fig. 3. Structure of GAN (modified from Goodfellow et al., 2020).

성을 보다 잘 분리해 표현하도록 유도하며, 생성 과정에서 “스타일(style)”로 해석되어 사용된다. 이러한 설계는 잠재공간에서의 보간(interpolation)을 자연스럽게 만들고, 세부적인 특징을 유지한 채 이미지 변형을 가능하게 한다.

생성기는 합성 네트워크(synthesis network)로 구성되며, 각 단계마다 스타일 파라미터를 사용해 특징맵을 조절한다. 저해상도 층에서는 이미지의 전체적인 형태와 같은 전역적 구조를, 고해상도 층에서는 국소적 세부 특징을 주로 제어함으로써 이미지 속 다양한 속성들이 계층적으로 분리되어 표현된다. 또한 잡음은 여러 단계에 걸쳐 주입되어 미세한 확률적 변동을 표현하고, 이를 통해 사실감이 향상된다.

### 2.5. 유넷(U-Net)

유넷(U-Net)은 2015년 개발된 합성곱 신경망 구조의 모델이며(Ronneberger et al., 2015), 본래 이미지 분할을 위해 설계되었지만, 범용성과 확장성이 뛰어나 이미지 생성, 잡음 제거, 시계열 데이터 분석, 자료 분류 등 다양한 영역에 적용되어 활용되고 있다. 본 네트워크의 가장 큰 특징으

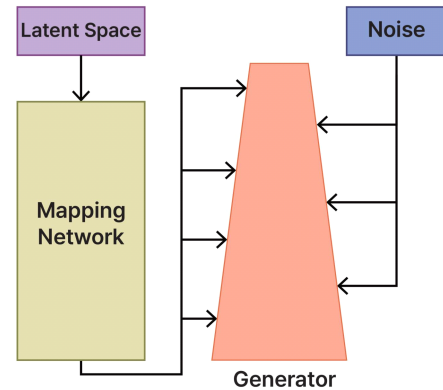


Fig. 4. Structure of StyleGAN (modified from Karras et al., 2019).

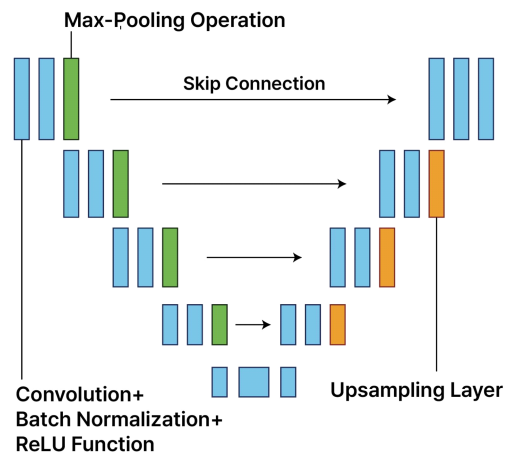


Fig. 5. Structure of U-Net.

로는 입력된 자료를 압축하는 인코더와 압축된 자료를 복원하는 디코더가 대칭적으로 연결되어 있다는 점이며(Veit *et al.*, 2016), 이러한 점에서 입력 자료와 출력 자료의 차원이 동일한 특성을 가진다. 본 네트워크에서 탄성파 자료 볼륨이 투입 자료로써 활용되고, 동일한 크기의 암상 모델이 산출물로 작용한다.

본 연구에서 제시하는 암상 분류 기법은, 입력되는 자료와 출력되는 자료의 차원이 동일하다는 특성이 있다. 따라서 다양한 인공신경망 모델 중 U-Net 기반 네트워크를 채택하였다.

### 3. 연구방법

#### 3.0. 탐사자료 개요

본 연구에서는 제주분지에서 취득한 해양 탄성파 탐사 자료를 활용하였다. 제주분지는 한반도 남쪽 대륙붕에 위치하며, 수심이 최대 150 m에 달하는 비교적 얇은 분지 지역이다(Kwon, 1996). 지리적으로는 동중국해 대륙붕에서 북동쪽 부분에 해당하며, 북서쪽으로는 제구 용기대를 맞대고 있다. 제주분지 남동쪽으로는 타이완-신지대와 오키나와 해곡이 위치하고 있다(Liu *et al.*, 2017). 해당 지역은 태평양 판이 유라시아 판 아래로 섭입함에 따라 제주분지 지역에 강한 인장력이 가해져 생성되었으며, 신생대를 거치며 전반적인 퇴적 작용과 변형 작용이 이루어졌다. 팔레오세 이전의 지층들은 상부의 신생대 퇴적층과 달리 장기간 구조적 변형을 받아 탄성파 단면상에서 불규칙한 구조를 나타낸다. 이후 에오세 시대에 제주분지에 가해진 횡압력에 의해 해수면 위로 융기하여 부정합면을 형성하였다. 에오세 후기부터 마이오세 중기까지 퇴적 작용이 활발하게 이루어지다 마이오세 후기를 기점으로 부정합면이 형성 후 플라이오세부터 현세까지 해양 퇴적 환경에서 퇴적이 이루어지고 있다. 에오세 후기부터 마이오세 중기까지 이루어진 퇴적층은 훌륭한 근원암이자 저류암으로 평가되어 탄화수소의 존재 가능성이 높다고 여겨지며, 동중국해 내 다른 분지에서는 탄화수소의 생산이 이루어지고 있는 곳도 존재한다(Ye *et al.*, 2007; Wang *et al.*, 2019). 따라서 본 연구에서는 제주분지 내 탄화수소의 발견 가능성을 높이기 위해 해당 지역의 탐사 자료를 활용하였다.

#### 3.1. 물리탐사 자료의 체적 변환 기법

물리탐사 자료의 체적 변환을 위하여, 상술한 VQ-VAE 구조와 StyleGAN 구조를 융합하였다. 전체 구조는 코드북 내 사용 빈도가 낮은 벡터를 다른 벡터로 대체하여 코드북의 모든 벡터를 골고루 활용할 수 있게 하는 전략인 노이즈 대체 벡터 양자화 기법(Noise Substitution in Vector Quantization;

NSVQ) 기반 VQ-VAE 구조에 StyleGAN의 스타일 변조 기법을 결합한 생성 네트워크로 구성되어 있다. 해당 구조는 3차원 체적 형태로 재구성된 2차원 탄성파 자료의 분포(그림 6 내 ‘라인 볼륨’) 및 밀도 정보(그림 6 내 ‘라인 마스크’)를 입력받아 확률론적 기반의 다양한 3차원 구조를 생성할 수 있도록 설계되었다. 네트워크는 크게 인코더, NSVQ 양자화 모듈, StyleGAN 기반 스타일 변조 모듈, 판별 신경망 모듈로 이루어진다. 이러한 접근은 제한된 관측 정보로부터 단일 결정론적 해를 추정하는 기존 방법과 달리, 지질 구조의 불확실성과 비유일성을 자연스럽게 반영할 수 있는 장점을 갖는다.

훈련 단계는 크게 총 3개의 단계로 나뉘어진다. 우선 초기 단계에는 입력 자료와 출력 자료에 모두 3차원 탄성파 자료를 배치하여, VQ-VAE의 구조가 3차원 탄성파 자료의 패턴을 학습하도록 한다. 이 과정에서 인코더는 연속적인 입력 체적을 이산적인 잠재 표현으로 압축한다. 훈련 과정에서 인코더는 지질 구조의 연속성 및 의미있는 지질학적 정보를 학습한다. VQ-VAE의 양자화 모듈은 잠재 공간을 코드북 기반의 이산 표현으로 변환함으로써 표현 안정성과 재현성을 확보한다. 이를 통해 3차원 탄성파 자료의 통계적 분포와 구조적 특성이 잠재 공간에 내재화된다. 이때 VQ-VAE의 디코더는 잠재공간 내의 각 코드북으로부터 지질학적 구조가 반영된 원본 체적을 복원하는 방식을 학습한다.

이후 단계에는 훈련된 VQ-VAE 구조 전체를 복제하여, 2차원 라인 볼륨에서 3차원 체적을 추정하도록 인코더와 디코더를 학습한다. 인코더에 입력되는 자료는 2차원 탄성파 자료로 구성된 희소한 3차원 체적(그림 6 왼쪽 하단부 라인 볼륨) 및 해당 체적 내 어느 위치에 자료가 분포하는지를 의미하는 동일한 차원의 체적(그림 6 왼쪽 하단부 라인 마스크)이다. 이때 인코더와 디코더는 전 단계에서 학습한 모델을 그대로 사용하는데, 인코더는 두 동일한 차원의 체적 형태의 자료를 입력받음으로써 어느 부분에 자료가 존재하는지에 대한 여부와 존재하는 자료의 명확한 형태를 명시적으로 인지한다. 연속적인 지질학적 구조를 학습한 인코더는 희소한 입력 자료 중 실제 자료가 존재하는 부분에 집중하여, 유효한 잠재 공간을 생성한다.

마지막 단계에는 직전 단계까지 훈련된 VQ-VAE 구조의 인코더 부분만을 복제하여, 2차원 라인 볼륨 및 2차원 라인 마스크를 입력받아 다양한 3차원 체적을 생성한다. 이를 위해 복제된 인코더가 생성하는 잠재 공간을 입력 자료로 하는, StyleGAN을 차용한 학습 구조가 추가된다. 생성 신경망 모듈은 가짜 잠재 공간을 생성하고, 판별 신경망 모듈은 가짜 잠재 공간과 실제 잠재 공간을 판별한다. 해당 과정을 반복하며 생성 신경망 모듈과 판별 신경망 모듈의 성능이 모두 균형 있게 향상될 때까지 학습을 진행한다.

두 모듈이 균형 있게 향상된 이후, 초기에 학습된 VQ-VAE의 디코더는 생성 신경망 모듈에 의해 생성된 잠재 공간을 이용하여 입력 자료와 동일한 차원의 3차원 체적 형태의 탄성파 자료를 예측한다. 디코더는 희소 체적 및 스타일 벡터로부터 생성된 잠재 공간을 입력받아 3차원 탄성파 자료를 생성한다. 이러한 전략을 통해 동일한 입력 조건 하에서도 서로 다른 지질 구조적 특성이 반영된 다양한 3차원 탄성파 체적이 생성된다. 이때 입력하는 잡음의 정도를 조정해 준다면, 출력되는 다양한 탄성파 체적 자료의 분산 및 다양성을 제어할 수 있다.

### 3.2. 2차원 암상 예측

탄성파 자료로부터 암상 모델링을 진행하기 위해서는 탄성파 자료에서 암상을 변환하는 과정이 필요하다. 기계 학습을 통하여 암상을 변환하기 위해서는 탄성파 자료와 암상 사이의 관계를 학습하는 과정이 선행되어야 한다. 학습에 사용되는 자료는 제주분지에 위치한 국소 3차원 탄성파 자료와, 해당 볼륨에 대해 암상 분류가 완료된 암상 볼륨

을 활용한다.

학습자료에 사용될 암상 모델을 역산하기 위해서 탄성파 자료를 활용하여 중합 전 동시 탄성파 역산(Pre-Stack Simultaneous Seismic Inversion)를 수행하여 3차원 볼륨에서의 밀도, P파 속도, S파 속도 등을 추정한다(Hampson *et al.*, 2005). 해당 방법은 상술한 여러 물성들을 동시에 계산하는 방법으로, 시추공 물리검층 자료에서 획득한 음원을 활용하여 초기모델로부터 광범위한 물성 모델을 획득할 수 있다.

암상 추정에는 탄성파 속도와 밀도 외에도 공극률이 큰 영향을 미치므로 광역 암상 추정을 위해서는 공극률 모델이 필수적이다. 그러나 중합 전 동시 탄성파 역산에서는 직접적으로 공극률을 추정할 수 없으므로 본 연구에서는 간접적으로 공극률 모델을 얻고자 하였다. 시추공 물리검층 자료에서 검층 자료와 암상 사이의 관계를 파악하고자 인공신경망(Neural Net)을 활용한다. 이때 시추공 공극률 로그와 시추공 위치에서의 탄성파 혹은 역산 속성 볼륨들을 입력하여 상관관계를 학습하고, 최종적으로 공극률을 산출한다. 직접적인 물성적 상관관계가 없는 자료에 대해 간접

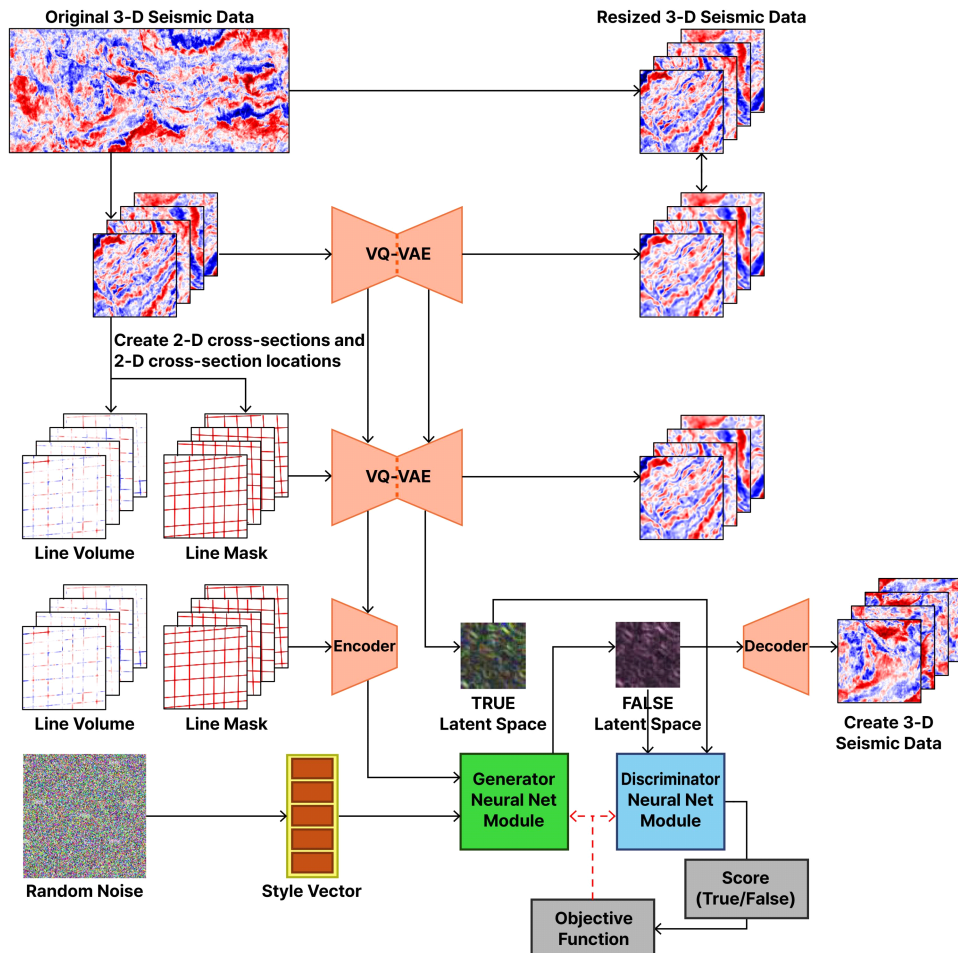


Fig. 6. Volumetric transformation method training workflow.

적인 상관관계가 있을 것을 전제로 속성 볼륨들과 공극률을 학습하여 상관도가 높은 속성들을 활용하여 공극률 볼륨을 산출하였다.

상술한 방법으로 취득한 3차원 물성 체적은 시추공 물리검층 자료에서 암상과의 상관관계를 통하여 암상 볼륨으로 변환된다(Odegaard and Avseth, 2003). 본 연구에서는 시추공 O와 시추공 G를 암상 상관관계 파악에 활용하였으며, 분류에는 P-임피던스와 공극률, Vp/Vs 비 등이 사용되었다.

암상 분석 결과 사암과 셰일이 주 암상을 이루었으며, 이외에 명확한 분류가 가능하지 않은 화성암 기원의 암상이 소량 포함된 것으로 파악되었다. 분류된 암상은 시추공 O와 시추공 G의 물리검층 자료와 교차검증하여 시추공 주변 암상 분류 결과와 물리검층 자료가 유사하게 나타남을 확인함으로써 신뢰도를 확보하였다.

3차원 탄성파 자료와 암상 자료 사이의 관계를 학습하는 네트워크는 그림 7과 같이 U-Net 기반의 완전 합성곱 신경망 네트워크를 사용한다. 해당 네트워크는 인코더와 디코더가 대칭을 이루며 암상 역산이 완료된 볼륨 자료를 학습 자료로 활용하여 암상의 공간적 분포를 학습한다. 인코더는 네트워크에서 입력 이미지로부터 특징을 추출하며, 그림 7에서는 ResBlock으로 나타내었다. 본 연구에서는 잔차 학습을 적용하여 네트워크를 구성하였으며 잔차 학습은 학습 과정에서 원본 자료의 일부분을 전달하는 방법으로 네트워크 학습 시 기울기 소실 문제를 일부 완화한다고 알려져 있다. 각 ResBlock은 3×3 합성곱 층으로 구성되어 있으며, 합성곱 연산 이후 학습 안정성을 위해 정규화를 진행하였다. 디코더는 추출된 특징을 바탕으로 원본 해상도의 암

상으로 분류하는 역할을 하며, 그림 7에서는 DecodeBlock으로 나타내었다. 디코더는 이중 선형 업샘플링을 진행한 후, 인코더에서 전달된 정보와 특징을 연결하여 자기 어텐션 단계로 전달한다. 본 네트워크에서는 자기 어텐션 적용 단계에서 수평 방향에 대해서만 자기 어텐션을 적용하여 수평 방향의 변화를 파악함과 동시에 연산의 효율성도 확보하였다. 인코더와 디코더 사이에는 특징 피라미드망을 배치하여 네트워크 가장 깊은 층에서 다양한 수용 영역을 확보하고 전역 문맥 정보를 포착할 수 있도록 하였다. 일반적인 합성곱 기반 신경망은 국소적인 변화에 가중치가 발생하지만, 특징 피라미드망은 디코더의 암상 복원 시 전체적인 지질학적 구조를 함께 고려할 수 있도록 한다. 특징 피라미드망은 그림 7에서 FPA로 나타내었다.

학습자료에 사용되는 자료는 3차원 중합후 탄성파 자료와, 암상 역산 결과에 따라 클래스 숫자를 부여한 암상 자료가 투입된다. 두 자료의 크기는 동일하며, 암상 자료의 경우는 이산적인 특징을 제한하여 분류 결과 역시 이산적인 클래스로 출력되도록 하였다. 투입되는 자료의 경우 암상 역산 결과 8개의 분류 결과가 존재하였지만, 화성암 기반의 암상으로 추정되는 영역들은 전체 암상 중 구성 비율이 1% 정도로 매우 적은 비율을 차지하여 화성암의 클래스로 통합하였다. 이는 분류 결과로 출력되는 클래스의 종류를 제한하여 석유 시스템 모델링의 중요한 요소로 작용하는 사암과 셰일의 분포 안정성을 높이기 위함이다.

암상 분류 결과는 사암, 셰일, 화성암의 클래스(class)로 분류하였으며, 암상 모델링 목표 영역 외에 존재하는 암상은 천부와 심부의 클래스를 부여하여 총 5개의 클래스를 사

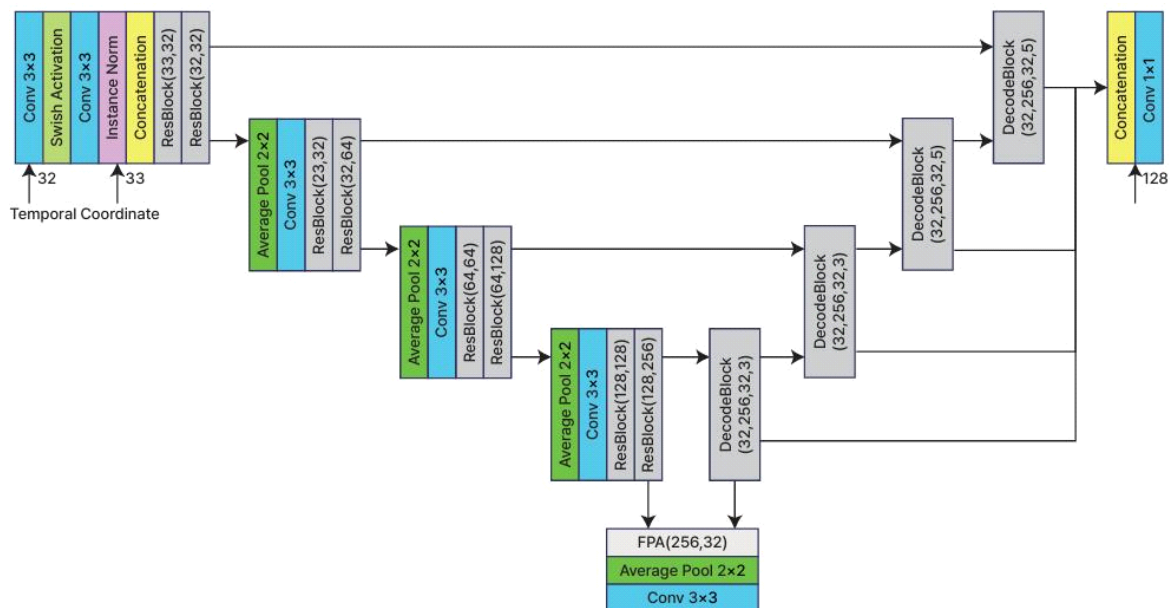


Fig. 7. Structure of lithofacies classification.

용하였다. 암상 분류 작업이 전 깊이에 대해 수행되지 않았기 때문에 목표 영역 상하부로 분류가 되지 않은 부분이 일부 존재하게 되며, 천부에는 1번 클래스를 부여하고 학습에 사용하지 않았다. 심부 영역에는 기반암을 나타내는 2번 클래스를 부여하여 학습에는 포함하였지만, 추후 진행할 3차원 암상 모델링에서는 목표 영역에 포함되지 않아 제하였다.

전체 볼륨 중 일부를 학습 과정에서 제하고 이를 암상 예측 네트워크의 검증 자료로 활용하여 인공지능경망의 성능을 평가 및 개선하였다. 전체 2667개의 횡단선 중 2000개의 횡단선 자료를 학습에 사용하였고, 나머지 667개의 횡단선을 검증자료에 활용하였다.

### 3.3. 3차원 암상 모델링

지하구조의 암상 분포를 예측 및 평가하는 방법은 여러 가지가 있으며, 석유 시스템 모델을 구축하기 위해 지구통계학적 기법을 필두로 많은 연구가 이루어져 왔다. 이는 암상 모델링을 수행함에 있어 신뢰할 수 있는 암상 정보가 시추공 근방으로 극히 제한되기 때문이다. 제한된 정보를 확장함에 있어 다양한 수학적/통계적 방법을 활용하여 그 불

확실성을 줄이고자 하지만, 예측하고자 하는 공간 범위 대비 극히 적은 시추공 정보는 암상 모델링 정확성 및 신뢰도를 높게 평가할 수 없는 주요한 원인으로 작용한다.

이러한 점을 해결하기 위해, 본 연구에서는 시추공 암상 정보 대신 2차원 탄성과 자료를 활용한 2차원 암상 자료를 지구통계학적 방법으로 확장한다. 제한된 양의 정보를 넓은 지역에 확장하는 지구통계학적인 방법에는 여러 방법이 있고, 대표적으로 크리깅(Kriging), SIS 등이 존재한다(Oliver and Webster, 2014). 두 방법 모두 이방성과 연속성을 설명하는 베리오그램(variogram)을 활용하지만, 그 목적에 차이가 존재한다. 크리깅은 추정 영역의 분산을 최소화하여 평균적인 추정이 필요한 경우 효과적인 반면, SIS는 추정 영역에서 변동성이 주어지고 이를 보존하며 추정하는 방식이기 때문에 추정 영역에 있어 국지적인 변동성이 중요한 경우 효과적이다(Mizuno and Deutsch, 2022).

본 연구에서는 추정 영역 전체에 걸쳐 2차원 암상 분포가 고정된 상태에서 남은 부분을 추정하는 것이 목표이므로 국지적인 변동성을 보존하는 것이 중요하다고 판단하여 SIS를 암상 모델링에 활용하였다. 이 과정에서 경향(trend)




Fig. 8. Extended 3D volume data and lithology distribution modeling area in the Korea South Sea (3D view).

를 반영함에 있어 3차원으로 보간된 탄성파 자료를 함께 투입하여 암상 확장에 활용하였다.

#### 4. 연구 결과

##### 4.1. 체적 변환 결과

그림 8 및 그림 9는 실제 남해 대륙붕 내 확장된 체적 자료와 3차원 암상 분포 모델링을 수행하고자 하는 지역(빨간 육각형)을 도시한 자료이다. 체적 변환 기법은 기존 비교적 세밀하게 분포된 2차원 평면 자료의 사이를 보간하였으며, 구조적인 연속성이 전반적으로 개선되었음을 확인하였다. 다만 각 위치에서의 2차원 평면 자료의 분포는 불균일하므로, 3차원 체적 변환을 위해 생성한 입력 자료 내에 2차원 평면 자료가 존재하지 않는 국소적인 구역이 있다. 그러한 입력 자료로 생성된 체적의 해당 구역은 지질학적으로 무의미한 신호를 생성하는 경향을 보인다.

본 연구에서 개발한 3차원 체적 변환 기법은 다양한 지질학적 구조가 반영되는 탄성파 자료를 생성한다. 동일한

자료를 입력하더라도, 무작위한 잡음 벡터가 함께 입력되어 출력되는 구조를 다양화한다. 그림 10 및 11은 각각 동일한 입력 자료로부터 생성된 3차원 체적의 수평 및 횡단선 2차원 단면을 보인다.

이러한 다양성은 본 연구에서 개발한 기법 내의 생성형 인공지능경망 모델인 StyleGAN에서 기인한다. StyleGAN의 초기 레이어는 대규모 층서 구조 등의 거시적인 지질학적 특징을 결정하고, 후반부 레이어는 세밀하고 지역적인 지질학적 특징이 결정된다. 이러한 인공지능경망 모델의 특성은 비교적 넓은 간격을 가지는 입력 자료를 효과적으로 보간한다.

희소하게 분포한 2차원 탄성파 자료로부터 3차원 구조를 추정하고자 하는 본 연구는 본질적으로 비유일해를 추론하는 과정(ill-posed Problem)이다. 희소한 정보를 제공하는 불확실한 2차원 탄성파 자료로 생성된 3차원 탄성파 자료는 실재하는 3차원 지하 구조를 완벽히 반영하지 못한다. 동일한 입력에 대해 생성되는 여러 결과는 입력 자료와 부합하면서도 지질학적으로 그럴듯한 구조의 부분 집합을

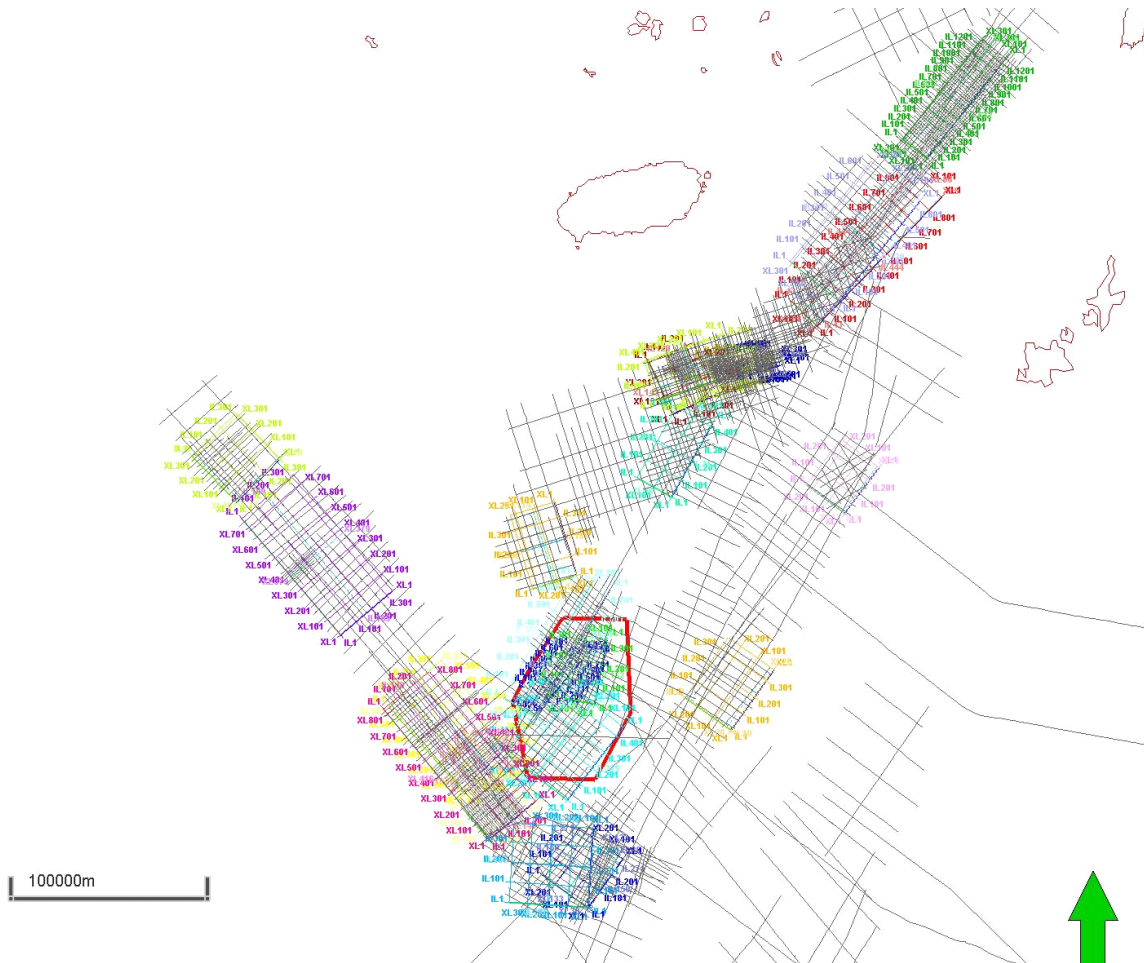


Fig. 9. Extended 3D volume data and lithology distribution modeling area in the Korea South Sea (2D view).




Fig. 10. (a) Time-slice examples of (b)~(d) different results generated from the same input data.

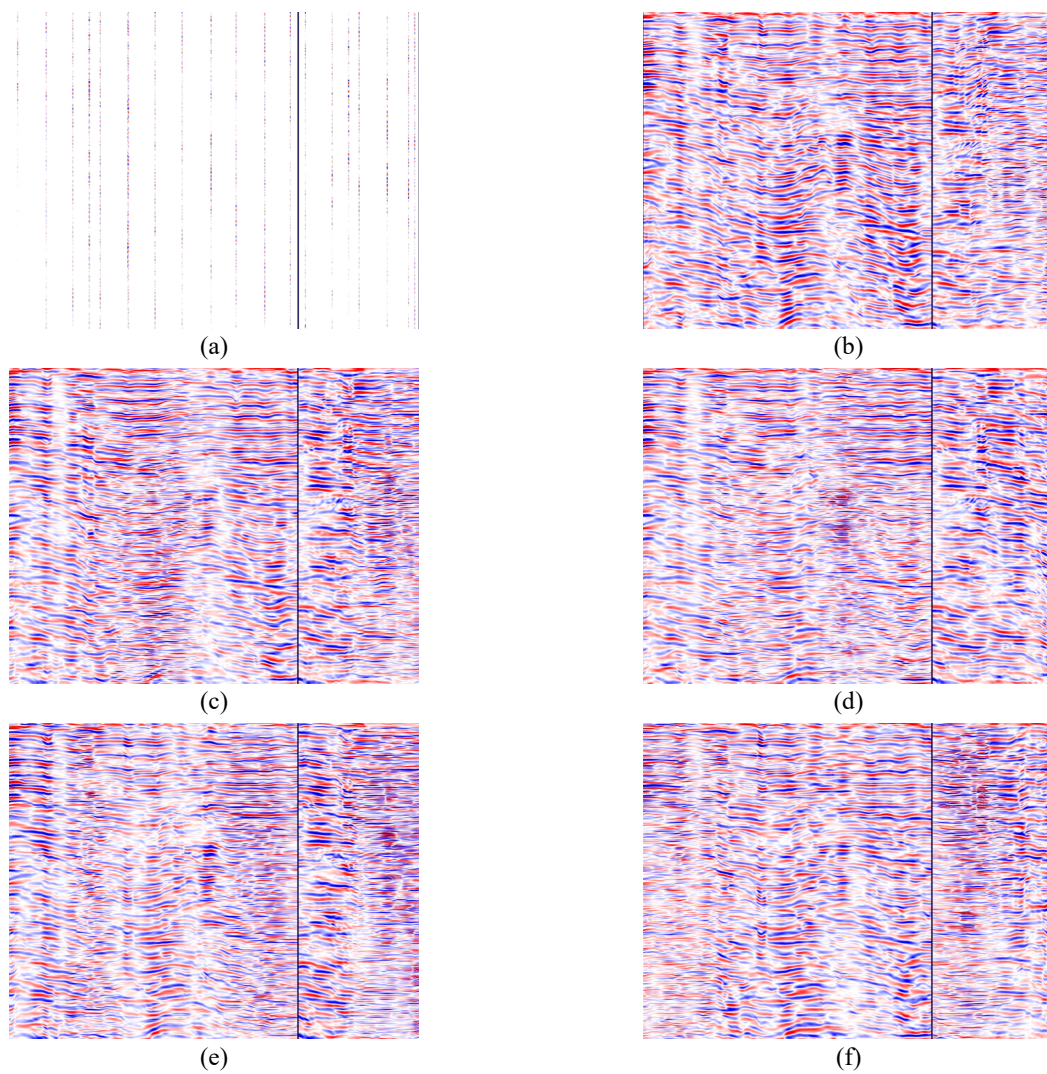


Fig. 11. (a) Examples of Inline and Xline Sections of (b)~(f) results generated from the same input data.

반환한다.

추후 각 예측 결과를 앙상블(ensemble)화한다면, 특정 구역에서의 통계적 수치를 계산하여 추정 불확실성을 정량적으로 평가할 수 있으며, 이는 실제 탐사를 수행한 이후 추가적인 탐사나 세부 검증이 필요한 구역을 파악하는 데 기여할 수 있다. 일례로, 다양한 시나리오에서 특정 지질구조가 공통적으로 나타난다면 이는 높은 신뢰도를 가지는 것으로 판단하여, 시추공 위치 선정 등과 같은 의사 결정에 핵심적인 근거로 작용할 수 있다. 이처럼 각각의 다중 해석은 각 탐사 구역에 대한 불확실성을 정량화하는 데 도움을 주어, 높은 경제적 위험이 수반되는 프로젝트에서 효율적인 보조도구로 활용할 수 있다.

#### 4.2. 2차원 암상 예측

실제 2차원 자료에 적용하기 전, 학습자료에 사용하지 않은 일부 영역에 학습이 완료된 네트워크를 적용하여 네트워크의 성능을 평가하였다. 그림 12는 검증 자료 영역에서 임의의 2차원 측선을 선택하여 네트워크를 적용한 결과와 실제 정답을 나타낸 결과이다.

적용 결과 암상 예측 네트워크는 탄성파 자료로부터 사암과 셰일의 분포를 정확하게 예측하고, 나아가 심부와 천부 역시 정확하게 구분한다는 것을 확인하였다. 특히 단층 등 암상 분포 외에도 구조적인 분포 역시 예측하여 추후 암상 확장에 정교한 암상 모델링이 가능함을 시사하였다.

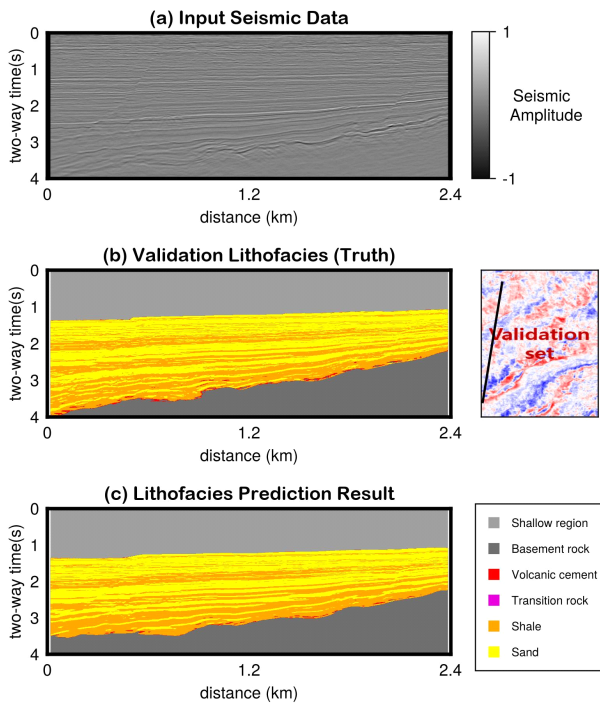


Fig. 12. Lithofacies classification result via trained network in validation dataset.

검증 자료를 통해 신뢰성을 확보한 후 목표 영역에 존재하는 2차원 측선 자료에 암상 예측 네트워크를 적용하여 광역 2차원 암상 모델을 구축하였다. 그림 13은 목표 영역에 존재하는 2차원 탄성파 자료를, 그림 14는 해당 탄성파 자료를 암상으로 변환한 결과이다.

그림 15는 암상 예측 결과를 비교하기 위해 변환에 사용된 2차원 측선 중 일부를 임의로 선택하여 비교한 그림이




Fig. 13. 2D seismic lines in target area (Red polygon).




Fig. 14. 2D lithofacies lines converted from 2D seismic lines via classification network.

다. 노란색 암상이 사암, 주황색 암상이 셰일에 해당하며, 상부의 하늘색 영역은 천부 영역으로 예측되고, 하부의 파란색 영역은 심부 영역으로 예측하였다. 비교 결과 암상 예측 결과가 탄성과 단면에서의 지층 구조와 층간 경계 경향을 잘 따라가며 사암과 셰일의 암상 분포를 잘 모사하고 있

는 것을 확인할 수 있다.

### 4.3. 3차원 암상 모델링

2차원 암상 데이터에 더하여, 본 연구에서 추정한 다양한 3차원 탄성과 자료의 평균치(그림 16)를 보조자료로 함

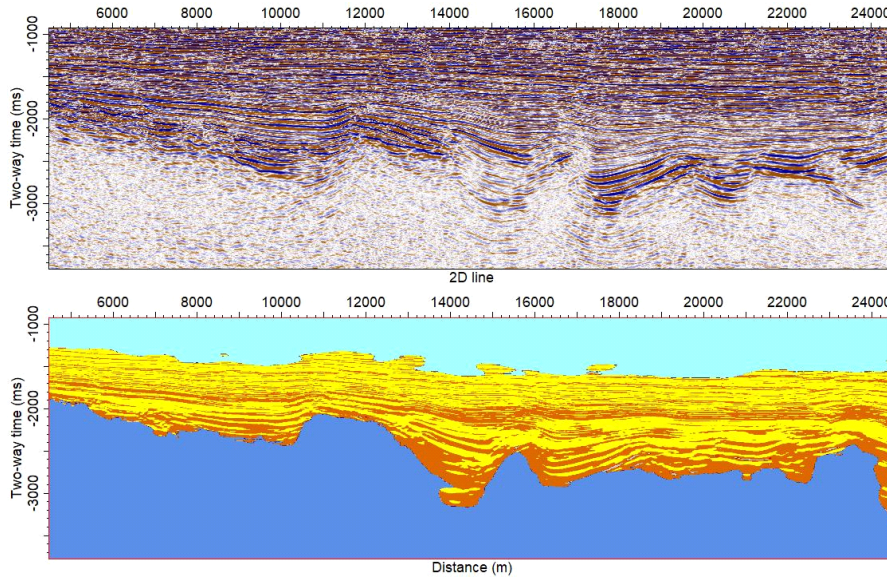


Fig. 15. Comparison between seismic data and lithofacies classification result for arbitrary line.

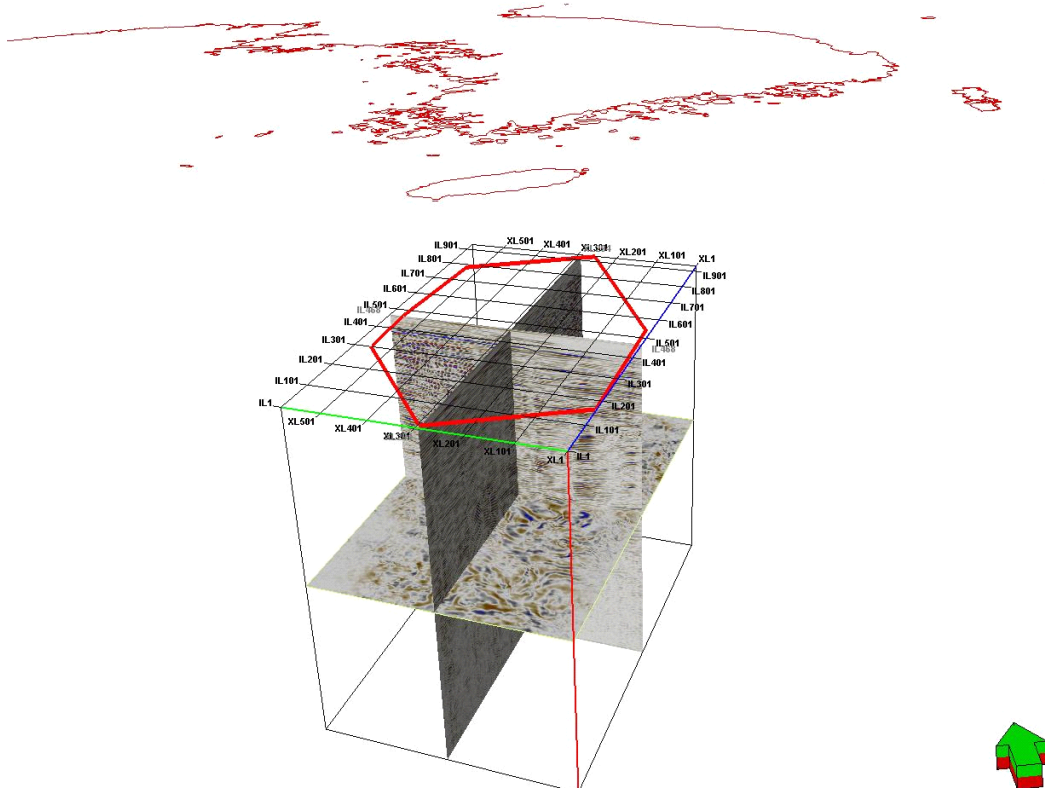
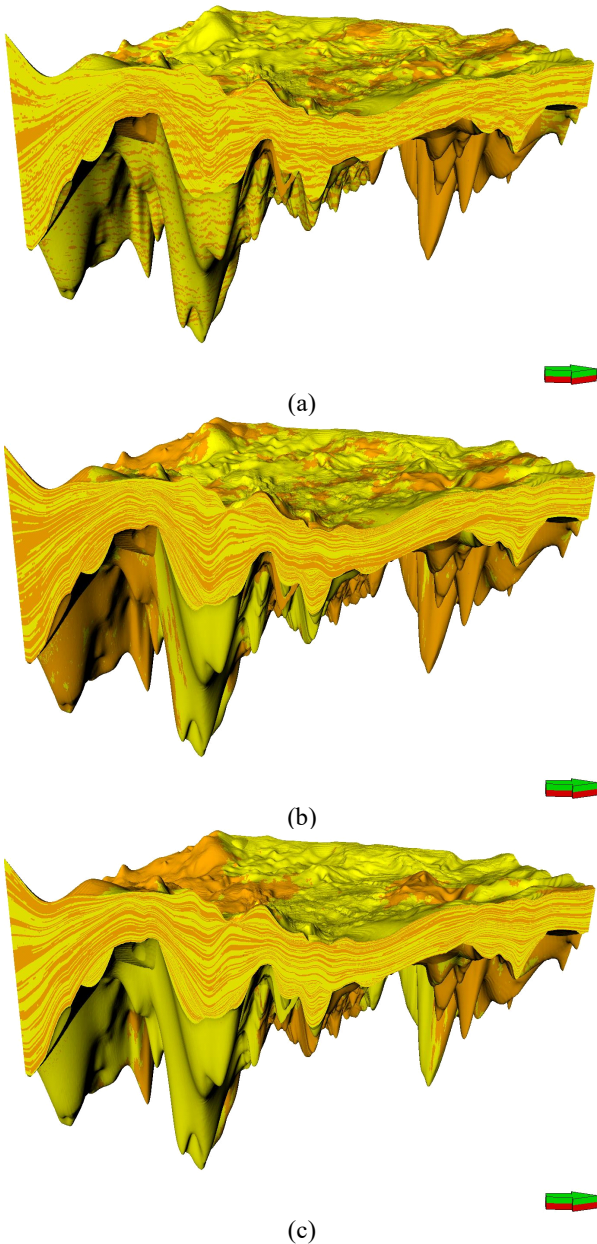


Fig. 16. 3D interpolated-Seismic cube used for trend property in 3D lithofacies modeling.


계 투입하여 SIS를 통해 3차원으로 확장한 결과를 그림 17a에 나타내었다. 이는 다양한 지질학적 구조를 암시하는 각 자료 중 신뢰도가 높은 부분을 더욱 강조하기 위함이다. 또한 3차원 탄성파 자료의 영향을 분석하기 위하여 탄성파 자료를 활용하지 않은 모델링과 2차원 암상 데이터를 사용하지 않은 모델링도 추가적으로 수행하였으며 해당 결과들을 각각 그림 17b와 17c에 나타내었다. 또한 해당 모델 내부의 암상 분포를 평가하기 위하여 모델을 관통하는 임의의 단면(그림 18)을 생성한 후 단면에 나타난 암상 분포를




**Fig. 17.** 3D lithofacies model via: (a) SIS with 3D interpolated-Seismic cube and 2D lithofacies lines, (b) SIS with only 2D lithofacies lines, (c) SIS with only well-log data.

그림 19에 나타내었다. 분석 결과 2차원 암상 데이터를 사용하지 않고 물리검층 시추 자료만 사용한 경우(그림 19c)는 지층의 이방성과 비균질성을 충분히 표현하지 못하고 수평적 연결성만 강조되는 것을 확인할 수 있다. 반면 2차원 암상 데이터를 활용한 암상 모델링의 경우에는 국소적 이방성과 비균질성 등 현실적인 지층의 분포를 나타냄을 확인할 수 있다.

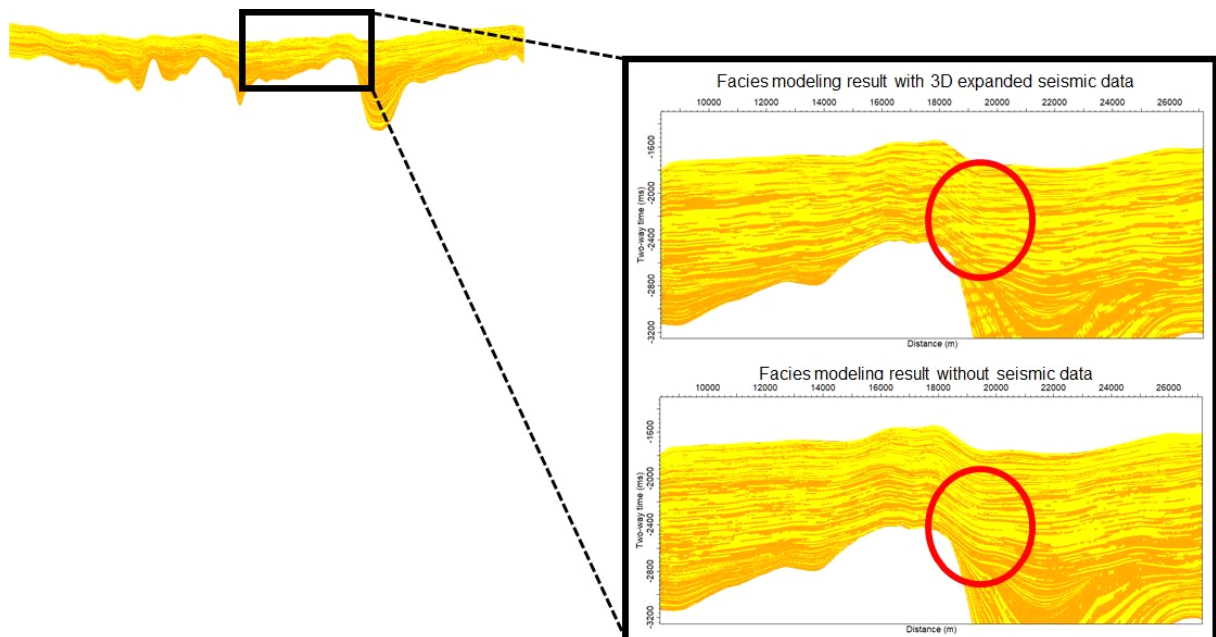
암상 모델링 결과를 평가하기 위해, 그림 19에서 2차원 암상 데이터를 활용한 두 모델의 일부분을 확대하여 그림 20에 나타내었다. SIS를 통한 3차원 암상 모델링의 경우, 확장하고자 하는 입력 자료의 투입량이 많아질수록 더 현실적인 지층의 생김새를 반영할 수 있지만 자료와 자료 사이를 보간하는 경우에는 주변 영역을 참고하는 방식 특성상 연결성이 과도하게 강조되는 경향이 있다. 이는 그림 20에서 탄성파 자료 없이 암상 모델링을 한 경우 전체적인 지



**Fig. 18.** The (a) bird view and (b) 3D view of Randomly chosen 2D intersection of 3D lithofacies model.



**Fig. 19.** Randomly chosen 2D section of 3D lithofacies model: (a) SIS with 3D interpolated-Seismic cube and 2D lithofacies lines, (b) SIS with only 2D lithofacies lines, (c) SIS with only well-log data.



**Fig. 20.** The enlarged part of the 2D section of lithofacies model.

층 양상은 적절히 모사하지만, 대다수의 지층이 부드럽게 연결되어 있다는 점에서 확인할 수 있다. 반면 3차원 탄성파 자료를 함께 투입한 경우는 전체적인 지층 양상은 유사하게 나타나지만, 지층의 연결성에 다양성을 부여하고 단층 등 지질학적으로 유의미한 구조 등이 암상 모델링 결과에 반영되는 것을 확인할 수 있다. 따라서 모델링, 결과 탄성파 자료를 보조자료로 활용하여 3차원 모델링을 진행할 경우 지층의 분포와 구조 등이 더욱 정교하고 현실적으로 모사될 수 있음을 알 수 있다.

그림 21은 암상 모델링 과정에서 탄성파 자료의 영향을 확인하기 위하여 다양한 탄성파 자료를 활용한 암상 모델링 결과를 비교한 그림이다. 3차원 탄성파 체적 예측 과정

에서 입력되는 잡음의 정도를 임의로 다르게 하여 복수의 3차원 탄성파 자료를 생성한 후, 이를 암상 모델링에 함께 반영하여 생성된 암상 모델링 결과를 동일한 단면에 대해서 도시하였다. 암상 모델링에 투입되는 2차원 암상 자료는 모두 동일하게 사용하였으며, 모델링 방법은 모두 동일하게 설정하여 탄성파 자료에 의한 차이만 반영되도록 하였다. 분석 결과 투입되는 탄성파 자료의 지층 연결성에 따라 암상 모델링의 연결성도 함께 변화함을 확인하였으며, 정확한 탄성파 자료가 암상 모델링에 활용될 경우 암상 모델링 결과 역시 크게 향상될 수 있음을 시사한다. 또한 3차원 탄성파 체적 예측 과정에서 다양한 후보군들을 생성함으로써, 암상 모델링의 불확실성 역시 정량적으로 분석할 수 있




Fig. 21. Placeholder.

는 초석을 제공한다.

## 5. 결론

본 연구에서는 인공지능 기반 기술을 활용하여 2차원 탄성과 자료를 3차원 체적으로 확장하고, 이를 바탕으로 3차원 암상 모델을 구축하는 통합 기법을 개발하였다. 개발된 기법은 제한된 2차원 탄성과 탐사 자료로부터 보다 정밀한 지하구조 해석을 가능하게 하며, 궁극적으로 석유 시스템 모델링의 정확도 향상에 기여할 수 있다.

체적 변환 기법은 VQ-VAE와 StyleGAN을 융합한 생성형 인공지능경망 구조를 기반으로 개발되었다. 이 기법은 무작위 잡음 벡터를 활용하여 확률론적으로 다양한 3차원 구조를 생성할 수 있으며, 넓은 간격으로 배치된 2차원 탄성과 자료 사이의 공백을 효과적으로 보간하는 성능을 보였다. 특히 입력 잡음의 정도를 조정함으로써 출력되는 탄성과 체적 자료의 다양성을 제어할 수 있어, 불확실성을 고려한 복수의 실현 모델 생성이 가능하다는 장점을 지닌다.

암상 분류 기법은 U-Net 기반 인공지능경망 모델을 활용하여 개발되었다. 중합 전 동시 탄성과 역산을 통해 획득한 P파 속도, S파 속도, 밀도 등의 물성 볼륨과 인공지능경망 기법으로 산출한 공극률 볼륨을 이용하여 암상 역산을 수행하였고, 이를 학습 자료로 활용하여 탄성과 자료와 암상 분포 간의 상관관계를 학습시켰다. 시추공 물리검층 자료와의 교차검증을 통해 분류 결과의 신뢰도를 확보하였으며, 사암, 셰일 등 주요 암상의 공간적 분포를 효과적으로 예측할 수 있음을 확인하였다.

최종적으로 Sequential Indicator Simulation을 기반으로 한 지구통계학적 방법을 적용하여 3차원 암상 모델을 구축하였다. 이 과정에서 체적 변환 기법으로 생성된 3차원 탄성과 자료를 보조자료로 활용하여 경향성을 반영하였다. 이를 통해 국지적 변동성이 보존된, 보다 현실적인 암상 분포 모델을 얻을 수 있었다.

본 연구에서 개발된 암상 분류 기법은 실제 라인 자료에서도 지층 경계와 단층 등의 라인 자료 특징을 보존하며 암상 분포를 성공적으로 분류하였으며, 3차원 공간상의 대략적인 암상의 분포 구축을 가능케 했다. 해당 암상 분류 기법이 석유 시스템 모델링에 큰 영향을 미치는 사암과 셰일에 더욱 집중하게 하는 전략을 이용하여, 두 암상의 분포를 위주로 자세한 3차원 암상 구조를 복원하는 데 성공하였다. 본 연구에서 개발한 기법은 향후 지질구조의 다양한 해석과 이를 기반으로 한 석유 시스템 모델링에 기여할 것으로 예상된다.

## 감사의 글

본 연구는 한국석유공사 “남해대륙붕 종합기술평가” 사

업과 산업통상부 유전개발사업출자의 지원을 받아 수행되었습니다.

## REFERENCES

- Abdullah, M.A., Mohammed, A.A. and Awad, S.R., 2024, Rockdnet: Deep learning approach for lithology classification. *Applied Sciences*, 14, 5511.
- Brown, A.R. 2011, Interpretation of three-dimensional seismic data. Society of Exploration Geophysicists and American Association of Petroleum Geologists, Tulsa, Oklahoma, U.S.A.
- Chiles, J.P. and Delfiner, P., 2012, Geostatistics: modeling spatial uncertainty. John Wiley & Sons, U.S.A.
- Datta, D., Singh, G., Routray, A., Mohanty, W.K. and Mahadik, R., 2021, Automatic classification of lithofacies with highly imbalanced dataset using multistage svm classifier. In: *IECON 2021-47th Annual Conference of the IEEE Industrial Electronics Society*, IEEE. p. 1-6.
- Deutsch, C.V. and Journel, A.G., 1992, Geostatistical software library and user's guide. New York, 119, 578.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S. and Bengio, Y., 2020, Generative adversarial networks. *Communications of the ACM*, 63, 139-144.
- Goyes-Peñafiel, P., Suarez-Rodriguez, L., Correa, C.V. and Arguello, H., 2024, GAN-supervised seismic data reconstruction: An enhanced-learning for improved generalization. *IEEE Transactions on Geoscience and Remote Sensing*, 62, 1-10.
- Hantschel, T. and Kauerauf, A.I., 2009, Fundamentals of basin and petroleum systems modeling. Springer Science & Business Media.
- Hampson, D.P., Russell, B.H. and Bankhead, B., 2005, Simultaneous inversion of pre-stack seismic data. In: *SEG Technical Program Expanded Abstracts 2005*. Society of Exploration Geophysicists, Houston, Texas, November 6-11, SEG-2005-1633.
- Karras, T., Laine, S. and Aila, T., 2019, A style-based generator architecture for generative adversarial networks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Californian, June 16-20, p. 4401-4410.
- Kingma, D.P. and Welling, M., 2013, Auto-encoding variational bayes. In *International Conference on Learning Representations*.
- Kwon, Y.I., 1996, Sequences Stratigraphy and Rift-related Sediment Characteristics in the Cheju Basin. Ph.D. thesis, Yonsei University, Seoul, 302 p (in Korean with English abstract).
- Lee, J.W., Lee, M.J., Min, D.J. and Cho, Y., 2024, Reviving Legacy Seismic Data via Machine learning Technique Part 1: Expanding 3D Seismic Survey Coverage with Gated Convolution GAN. *IEEE Transactions on Geoscience and Remote Sensing*, 63, 1-18.
- Lee, J.W., Lee, M.J., Min, D.J. and Cho, Y., 2025, Reviving Legacy Seismic Data via Machine Learning Technique Part 2: Estimating 3D Seismic Volumes from 2D Seismic Lines with VQ-VAE. *IEEE Transactions on Geoscience and Remote Sensing*, 63, 1-21.
- Liu, B., Li, S., Jiang, S., Suo, Y., Guo, L., Wang, Y. and Zhang, H., 2017, Origin and model of transform faults in the okinawa trough. *Marine Geophysical Research*, 38, 137-147.

- Lu, P., Xiao, Y., Zhang, Y. and Mitsakos, N., 2019, Deep learning for 3D seismic compressive-sensing technique: A novel approach. *The Leading Edge*, 38, 698-705.
- Ma, Y.Z. and Zhang, X., 2019, Quantitative geosciences: Data analytics, geostatistics, reservoir characterization and modeling. Springer Nature Switzerland AG, <https://doi.org/10.1007/978-3-030-17860-4>.
- Magoon, L.B. and Dow, W.G., 1994, The petroleum system. In: Magoon, L.B., Dow, W.G. (Eds.), *The Petroleum System—From Source to Trap*, AAPG Memoir, 60, 3-24.
- Miall, A.D., 2013, *The geology of fluvial deposits: sedimentary facies, basin analysis, and petroleum geology*. Springer-Verlag Berlin Heidelberg.
- Mizuno, T.A. and Deutsch, C.V., 2022, Sequential indicator simulation (SIS). *Geostatistics Lessons*.
- Ødegaard, E. and Avseth, P., 2003, Interpretation of elastic inversion results using rock physics templates. 65th EAGE Conference & Exhibition, European Association of Geoscientists & Engineers, cp-6-00337.
- Oliver, M.A. and Webster, R., 2014, A tutorial guide to geostatistics: Computing and modelling variograms and kriging. *Catena*, 113, 56-69.
- Ronneberger, O., Fischer, P. and Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*. MICCAI 2015, Springer, Cham., 9351.
- Van Den Oord, A. and Vinyals, O., 2017, Neural discrete representation learning. *Advances in neural information processing systems*, 30, 6309-6318.
- Veit, A., Wilber, M.J. and Belongie, S., 2016, Residual networks behave like ensembles of relatively shallow networks. *Advances in neural information processing systems*, 29.
- Wang, B., Doust, H. and Liu, J., 2019, Geology and petroleum systems of the east china sea basin. *Energies*, 12, 4088.
- Whiteside, W., Wang, B., Bondeson, H. and Li, Z., 2013, 3D imaging from 2D seismic data, an enhanced methodology. Paper presented at the 2013 SEG Annual Meeting, Houston, Texas, September 22-27, SEG-2013-1148.
- Ye, J., Qing, H., Bend, S.L. and Gu, H., 2007, Petroleum systems in the offshore xihu basin on the continental shelf of the east china sea. *AAPG bulletin*, 91, 1167-1188.
- Yilmaz, Ö., 2001, Seismic data analysis: Processing, inversion, and interpretation of seismic data. *Society of exploration geophysicists*, 10, <https://doi.org/10.1190/1.9781560801580>.
- Yin, S., Lin, X., Huang, Y., Zhang, Z. and Li, X., 2023, Application of improved support vector machine in geochemical lithology identification. *Earth Science Informatics*, 16, 205-220
- Yuan, C., Su, M., Ni, C., Liu, X., Xu, Y. and Cui, X., 2022, Horizon auto-picking with quantitative uncertainty evaluation by using a modified VQ-VAE framework. *Journal of Geophysics and Engineering*, 19, 788-806.