

**연구논문**

## 이산화탄소 지중저장을 위한 기계학습 기반 4-D 탄성파자료 통합 및 배사구조 채널대수층 특성화

김현민<sup>1</sup> · 김남화<sup>1</sup> · 신현돈<sup>1</sup> · 조홍근<sup>1\*</sup>

<sup>1</sup>인하대학교 에너지자원공학과

## Machine Learning-based 4-D Seismic Data Integration and Characterization of Channelized Anticline Aquifer for Geological Carbon Sequestration

Hyunmin Kim<sup>1</sup>, Namhwa Kim<sup>1</sup>, Hyundon Shin<sup>1</sup> and Honggeun Jo<sup>1\*</sup>

<sup>1</sup>Department of Energy Resources Engineering, Inha University, Incheon, Korea

**\*Corresponding Author.** Honggeun Jo, [honggeun.jo@inha.ac.kr](mailto:honggeun.jo@inha.ac.kr), Assistant Professor, Department of Energy Resources Engineering, Inha University, Incheon, Korea

**Received**

1 December 2023

**Final version Received**

17 January 2024

**Accepted**

27 February 2024

### Abstract

This study introduces a 4-D seismic data integration approach based on Pix2Pix to quantify uncertainty and enhance reliability in subsurface CO<sub>2</sub> storage within channelized aquifers. We address geological uncertainties, such as the azimuth of channel direction, using multi-point statistics to generate diverse channelized aquifer models, to form the Pix2Pix training dataset. After successfully training the Pix2Pix, we realize the channelized aquifer models by assimilating 4-D seismic data changes from a reference channelized aquifer. The Pix2Pix dataset is crafted with (1) disconnections in artificial neural networks using dropout and (2) the addition of random noise to the input layer, yielding an ensemble of models that align with the provided data for quantifying uncertainty. Generating channelized aquifers using the suggested method improves prediction of channel direction, facies distribution, and accurate forecasts of future CO<sub>2</sub> plume movement. As an advanced monitoring technology, our method integrates 4-D seismic data for effective CO<sub>2</sub> storage in channelized aquifers.

**Key words :** carbon capture and sequestration, time-lapse seismic image, channelized aquifer characterization, Pix2Pix

### 요약

본 연구에서는 채널대수층의 이산화탄소 지중저장에서 4-D 탄성파자료를 통합해 불확실성을 정량화하고 신뢰도를 향상하기 위해 기계학습의 하나인 Pix2Pix 기반의 4-D 탄성파자료 통합기법을 제안한다. 다점지구통계 기법으로 다양한 지질학적 시나리오를 따르는 2차원 채널대수층 모델을 바탕으로 Pix2Pix을 학습시킨 후, 참조 채널대수층의 4-D 탄성파 변화를 입력하여 채널대수층 모델을 특성화한다. Pix2Pix을 구성하는 인공신경망 모델의 일부 연결을 끊는(1) dropout을 이용하는 방법과(2) 인공신경망의 입력층에 랜덤 노이즈 맵을 추가하는 방법을 이용해 주어진 자료를 만족하며 지질학적 사실성을 보전하는 다양한 모델을 생성하고 이들로부터 불확실성을 정량화 한다. Pix2Pix을 이용해 생성된 채널대수층은 참조 모델의 채널 방향성과 암상분포의 예측을 개선하였고, 나아가 미래 이산화탄소 액적군의 이동을 정확하게 예측한다. 제안한 방법은 채널대수층에서 이산화탄소 지중저장을 하는 경우 4-D 탄성파자료를 통합해 불확실성을 평가함으로 이산화탄소 지중저장의 모니터링 기술로 활용될 수 있다.

**주요어 :** 이산화탄소 포집 및 지중저장, 시간경과 탄성파 이미지, 채널대수층 특성화, Pix2Pix

## 서 론

탄소중립 2050 실현을 위한 핵심 기술 중 하나인 이산화탄소 포집 및 지중저장(Carbon Capture and Sequestration, CCS)은 신재생에너지 이용, 연료 효율개선 및 저탄소에너지 전환과 함께 온실가스 배출량 저감 기술로 주목받고 있다(IEA, 2023). 이산화탄소 지중저장 후 주입된 이산화탄소가 상부 지층 및 대기로 누출되면 큰 피해가 발생할 수 있으므로 저류층 내 이산화탄소 액적군( $\text{CO}_2$  plume)의 이동을 예측하고 모니터링하는 작업이 필수적이다(Hovorka *et al.*, 2005; Sharma *et al.*, 2007; Kim and Nam, 2012; Tang *et al.*, 2022). 전 세계적으로 약 265여개의 대규모 CCS 프로젝트가 진행 중이며, 이 중 40여개는 운용 단계, 100여개는 초기 설계단계에 있다(Statista, 2023). 특히 전 세계의 CCS 사업규모는 2021년 기준 30억 달러를 상회하며, 2028년까지 연간 약 6.1%의 성장률로 46억 달러의 규모가 될 것으로 전망된다(Market Report Worlds, 2022). 한국은 2030년까지 480만 톤의 이산화탄소를 지중 저장하는 것을 목표로 하며(Park and Jin, 2023), CCS의 핵심이 되는 이산화탄소 액적군 이동예측 및 모니터링 기술 개발에 대한 수요가 증가하고 있다.

일본의 나가오카 CCS 프로젝트에서는 관측정에서 측정한 물리검증자료와 탄성파 토모그래피를 분석하여 주입된 이산화탄소의 거동을 모니터링하는 연구를 진행한 바 있다(Xue *et al.*, 2006; Sato *et al.*, 2011). 또한 노르웨이의 슬라이프너 CCS 프로젝트에서는 이산화탄소 액적군의 이동에 따른 시간별 탄성파 진폭 변화를 분석하여 액적군이 계획한 영역에 안정적으로 격리됨을 확인하였다(Furre *et al.*, 2017; Cheong *et al.*, 2022). 이산화탄소 주입 시 지층 압력 증가로 인한 지표면 높이 변화를 합성개구레이더(Interferometric Synthetic Aperture Radar, InSAR)로 측정하여 이산화탄소의 거동을 분석하는 연구 또한 활발하게 진행되고 있다(Tang *et al.*, 2021, 2022).

CCS 대상 저류층의 지질학적 퇴적환경이 하천(fluvial), 삼각주(deltaic) 및 심해(deepwater submarine)인 경우, 유체투과도가 높은 사암체(sand facies)가 퇴적물의 흐름 방향에 따라 강한 연결성을 유지하며 발달하는 채널시스템(channel system)이 형성된다. 사암의 높은 유체투과도와 연결성은 유체의 거동에 큰 영향을 미치므로 채널의 발달 방향과 그 연결성 예측이 중요하다(Jo *et al.*, 2017; Wang *et al.*, 2019; Lee *et al.*, 2019; Kim *et al.*, 2020). Lee *et al.*(2015)은 채널대수층 불확실성 정량화를 위해 거리기반 양상을 스무더를 도입하여 기존의 양상을 기반 저류층 특성화 기법의 한계를 극복하고 2차원 저류층 모델을 성공적으로 예측한 바 있다. 이산화탄소 지중저장을 위한 채널대수층

의 특성화 수행 시 지질학적 사실성을 보존하면서 모니터링 자료에 부합하는 모델을 생성하는 것이 중요하다. 이를 바탕으로 이산화탄소 저장용량을 더욱 정확히 평가할 수 있으며 이산화탄소 주입정의 최적 운영조건에 대한 현장 적용성을 담보할 수 있다.

최근 기계학습 기법의 발달로 저류층 모델링에 대한 기계학습 적용사례가 증가하고 있다(Jo *et al.*, 2021, 2022; Pan *et al.*, 2022, 2023; Tang *et al.*, 2022; Ahn and Choe, 2022). Jo *et al.*(2021, 2022)은 적대적 생성 신경망(generative adversarial networks, GAN)을 이용해 정적자료와 동적자료를 통합하여 심해 퇴적환경의 저류층을 특성화하였다. Pan *et al.*(2022)은 GAN의 변형인 Pix2Pix을 이용해 심해 퇴적환경 저류층의 계층적 구조를 보전하는 모델링 방법을 제안하였다. Tang *et al.*(2022)은 합성곱 신경망(convolutional neural network, CNN)과 주성분 분석(principal component analysis)으로 3차원 채널대수층 모델 정보를 차원축소하여 이산화탄소 지중저장에 관한 저류층 특성화를 수행하였다. Ahn and Choe(2022)은 autoencoder의 변형인 variational autoencoder에 ES-MDA(ensemble smoother with multiple data assimilation)를 결합하여 2차원 채널대수층을 특성화하였다.

본 연구에서는 기계학습 기법인 Pix2Pix(Isola *et al.*, 2017)을 기반으로 이산화탄소 주입 3년 뒤 관측된 탄성파자료 변화를 입력자료로 사용하여 채널대수층을 특성화 한다. 기계학습 활용 방법을 소개하고 이를 이용한 채널대수층의 특성화 결과를 비교 및 분석하여 이산화탄소 지중저장을 위한 채널대수층 특성화 방법을 제안한다. 나아가 제안한 방법의 상용화를 위해 추가적으로 필요한 기술에 대해 논의한다.

## 본 론

### 합성곱 신경망

합성곱 신경망은 일련의 합성곱층과 풀링층 구조로 구성된 심층신경망 모델이다. 이미지의 공간적인 정보를 유지한 채 주요 특성을 추출하므로 이미지 처리 문제해결에 좋은 성능을 보인다. 합성곱층(convolutional layer)은  $(n \times m)$  크기의 행렬인 필터(filter)가 이미지 상에서 순차적으로 이동하면서 필터와 이미지 픽셀 사이의 합성곱 연산을 수행하여 특성 맵(feature map)을 추출한다. 풀링층은 특성 맵을 다운샘플링하여 특성 맵의 크기를 줄임으로써 신경망 모델의 과적합(overfitting)을 방지하고 특성 맵의 크기를 조절한다(LeCun and Bengio, 1995).

U-Net은 인코더(encoder)와 디코더(decoder)가 결합된 합성곱 신경망이며, 입력된 이미지 정보를 바탕으로 다른

형태의 이미지를 예측한다(Ronneberger *et al.*, 2015). 인코더에서는 합성곱층을 이용해 입력된 이미지의 특성을 저차원 정보로 압축하며, 디코더는 전치합성곱층(transposed convolutional layer)를 통해 인코더로부터 전달된 압축 정보의 채널 수를 줄이고 특성 맵을 확장하여 새로운 이미지를 생성한다. 또한 U-Net은 디코딩 과정에서 디코더 특성 맵 뿐만 아니라 고차원의 특성 맵이 결합된 정보를 입력하는 건너뛸 연결(skip connection)과 잔차 연결(residual connection)을 적용하여 효과적으로 예측 정확도를 개선한다(He *et al.*, 2016).

### 적대적 생성 신경망

적대적 생성 신경망(GAN)은 합성곱 신경망으로 구성된 생성 모델과 판별 모델이 적대적으로 학습하는 심층 신경망이다(Goodfellow *et al.*, 2014; Radford *et al.*, 2015). 지구통계적 기법으로 생성한 채널 저류층 모델을 학습자료로 활용한 적대적 생성 신경망 모식도는 Fig. 1과 같다.

생성 모델은 학습자료로부터 특징을 추출하여 학습자료의 특징을 모사하는 새로운 이미지를 생성하고, 판별 모델은 학습자료의 이미지와 생성 모델로부터 생성된 이미지를 비교하여 진위 여부를 판별한다. 생성 모델과 판별 모델은 서로가 경쟁하는 과정으로 학습을 진행하며 이때 GAN 훈련 시 사용되는 목적함수는 식(1)과 같다.

$$\min_G \max_D L_{GAN}(D, G) = E_{x \sim p_{data}} [\log D(x)] + E_{z \sim p_z} [\log(1 - D(G(z)))] \quad (1)$$

여기서  $x$ 는 학습자료,  $z$ 는 입력 노이즈 자료,  $G$ 는 생성 모델,  $D$ 는 판별 모델,  $L_{GAN}$ 은 GAN의 목적함수,  $E_{x \sim p_{data}}$ 는 학습자료에 대한 기대값,  $E_{z \sim p_z}$ 는 입력 노이즈 자료에 대한 기대값을 의미한다. 같은 목적함수에 대해 생성 모델은 이를 최소화하는 방향으로, 판별 모델은 이를 최대화하는 방향으로 학습이 진행된다.

기존의 GAN 모델은 랜덤 노이즈만 입력 자료로 사용하여 이미지를 생성하기 때문에 추가적인 관측 이미지가 있는 경우라도 이를 이용해 원하는 형태의 이미지를 얻기 어렵다. 이와 달리, Pix2Pix은 U-net을 기반으로 하는 생성 모델을 구축하여 관측 이미지 자료를 생성 모델의 입력층에 추가한다. 이를 통해 Pix2Pix의 생성 모델은 관측 이미지 자료와 관련된 이미지를 생성할 수 있다(Isola *et al.*, 2017). Pix2Pix의 학습에 이용되는 목적함수는 식(2) 및 (3)과 같다.

$$G^* = \arg \min_G \max_D L_{GAN}(D, G) + \lambda L_1(G) \quad (2)$$

$$L_1(G) = E[\|x - G(h, z)\|_1] \quad (3)$$

여기서  $\|\cdot\|_1$ 은 맨하튼 노름(Manhattan Norm),  $h$ 는 관측 이미지 자료,  $\lambda$ 는 가중치 인자를 의미한다.

### Pix2Pix 기반 4-D 탄성파자료 통합기법

본 연구는 Pix2Pix 기반으로 4-D 탄성파자료 변화를 입력하여 이에 해당하는 이산화탄소 지중저장 채널대수층 모

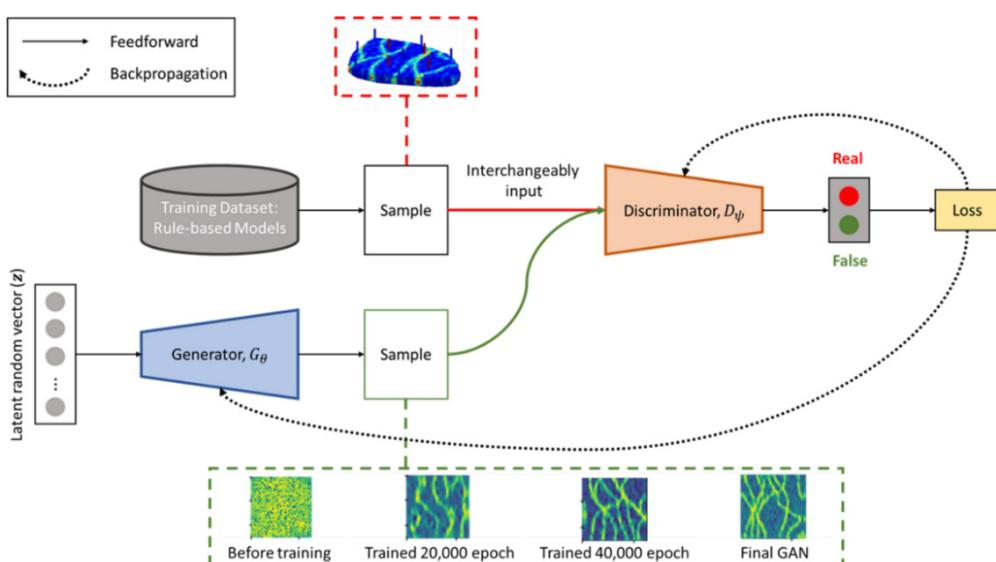
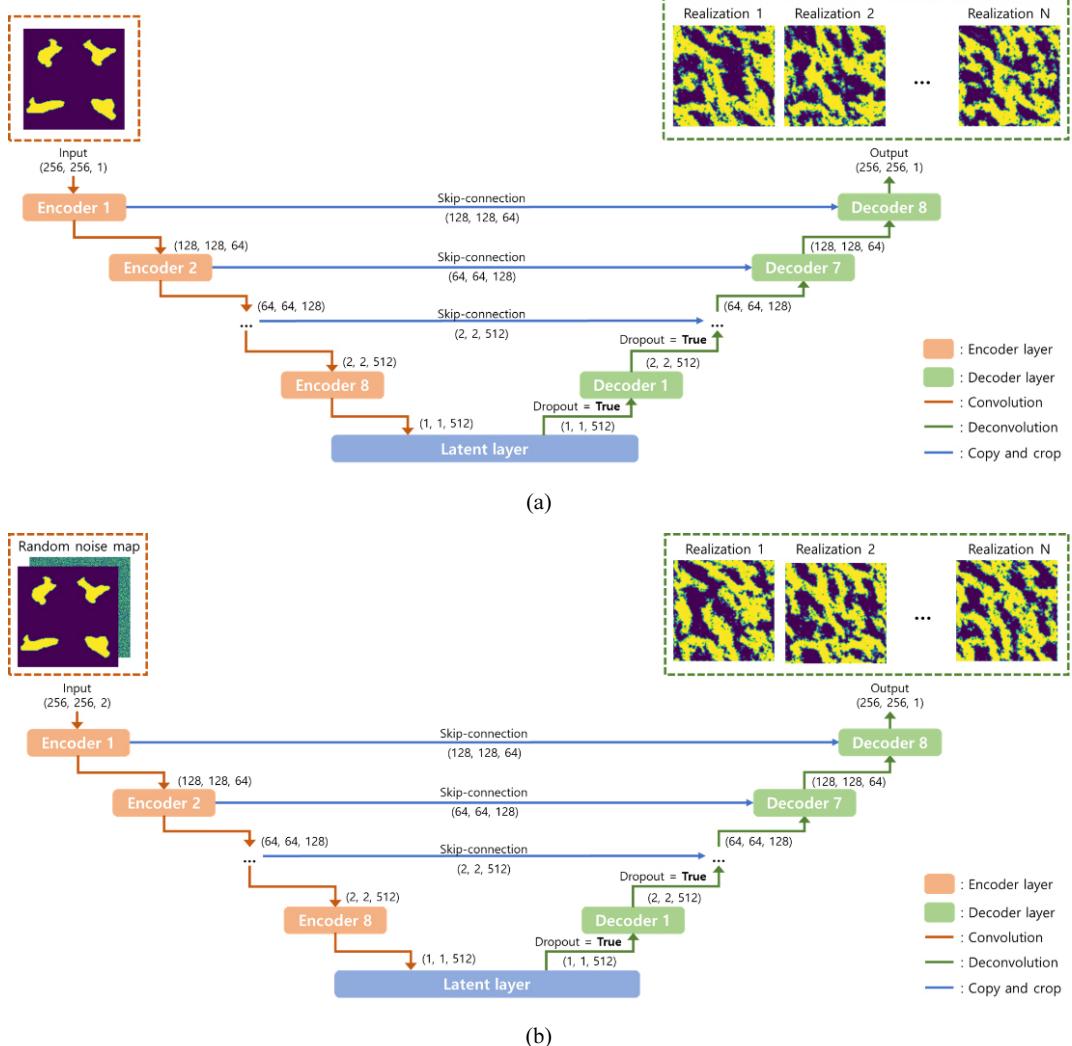


Fig. 1. Schematic diagram of GAN for channelized reservoirs (modified from Jo *et al.*, 2021).

델을 생성하는 방법을 제안한다. 즉, 이산화탄소 액적군의 발달을 감지하는 이산화탄소 주입전과 후의 4-D 탄성파자료 변화를 Pix2Pix에 입력하면 Pix2Pix의 생성 모델은 입력된 이산화탄소 액적군의 발달양상을 모사하는 채널대수총 모델을 생성한다. 본 연구에서는 Pix2Pix로 하나의 결정론적 모델(deterministic model)을 생성하는 것이 아닌 불확실성 정량화를 위한 다양한 확률론적 모델(probabilistic ensemble)을 생성할 수 있는 두 가지 방법을 제안한다.

첫 번째 방법으로 Pix2Pix의 생성 모델 내 인공신경망 연결을 의도적으로 끊어 dropout을 통해 다양한 채널대수총 모델을 생성하도록 하였다(Fig. 2(a)). 즉, 매번 생성 모델에

조금씩 다른 인공신경망을 끊어 다양한 채널대수총 모델을 생성할 수 있도록 한다. 두 번째 방법으로 Pix2Pix 생성 모델에 탄성파자료 변화 이미지와 표준정규분포를 따르는 랜덤 노이즈 맵을 추가로 입력하여 동일한 탄성파자료 변화 이미지를 입력하더라도 랜덤 노이즈 맵의 변화에 따라 다양한 채널대수총 모델을 생성하도록 하였다(Fig. 2(b)). 첫 번째 방법과 두 번째 방법의 Pix2Pix 모두 학습과정에는 dropout을 사용하여 과적합을 방지하였다. 학습종료 후 모델 생성 시 첫 번째 방법은 dropout을 사용하였으며, 두 번째 방법은 dropout을 사용하지 않았다. 본 연구에서 사용한 Pix2Pix 모델의 신경망 구조는 Table 1에 요약하였다.



**Fig. 2.** Schematic structure of the generator in the proposed methods. (a) dropout-based realizations and (b) random noise-based realizations.

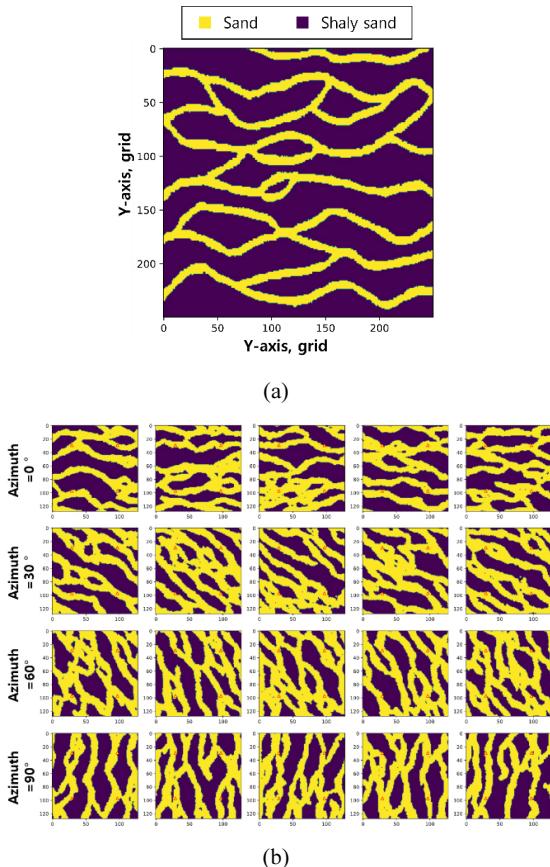
**Table 1.** Summary of the suggested model

Block	Layer	Output shape	Input shape	Number of Parameters
Encoder 1	Conv2d	[1, 64, 128, 128]	[1, 1, 256, 256]	1,088
	LeakyReLU			
	Conv2d	[1, 128, 64, 64]	[1, 64, 128, 128]	131,456
Encoder 2	BatchNorm2d			
	LeakyReLU			
	Conv2d	[1, 256, 32, 32]	[1, 128, 64, 64]	525,056
Encoder 3	BatchNorm2d			
	LeakyReLU			
	Conv2d	[1, 512, 16, 16]	[1, 256, 32, 32]	2,098,688
Encoder 4	BatchNorm2d			
	LeakyReLU			
	Conv2d	[1, 512, 8, 8]	[1, 512, 16, 16]	4,195,840
Encoder 5	BatchNorm2d			
	LeakyReLU			
	Conv2d	[1, 512, 4, 4]	[1, 512, 8, 8]	4,195,840
Encoder 6	BatchNorm2d			
	LeakyReLU			
	Conv2d	[1, 512, 2, 2]	[1, 512, 4, 4]	4,195,840
Encoder 7	BatchNorm2d			
	LeakyReLU			
	Conv2d	[1, 512, 1, 1]	[1, 512, 2, 2]	4,194,816
Encoder 8	Conv2d			
	LeakyReLU			
	ReLU			
Decoder 8	ConvTranspose2d	[1, 512, 2, 2]	[1, 512, 1, 1]	4,195,840
	BatchNorm2d			
	Dropout2d			
Decoder 7	ReLU			
	ConvTranspose2d	[1, 512, 4, 4]	[1, 1024, 2, 2]	8,390,144
	BatchNorm2d			
Decoder 6	Dropout2d			
	ReLU			
	ConvTranspose2d	[1, 512, 8, 8]	[1, 1024, 4, 4]	8,390,144
Decoder 5	BatchNorm2d			
	Dropout2d			
	ReLU			
Decoder 4	ConvTranspose2d	[1, 512, 16, 16]	[1, 1024, 8, 8]	8,390,144
	BatchNorm2d			
	Dropout2d			
Decoder 3	ReLU			
	ConvTranspose2d	[1, 256, 32, 32]	[1, 1024, 16, 16]	4,195,072
	BatchNorm2d			
Decoder 2	ReLU			
	ConvTranspose2d	[1, 128, 64, 64]	[1, 512, 32, 32]	1,048,960
	BatchNorm2d			
Decoder 1	ReLU			
	ConvTranspose2d	[1, 64, 128, 128]	[1, 256, 64, 64]	262,336
Decoder 1	BatchNorm2d			
Decoder 1	ConvTranspose2d	[1, 1, 256, 256]	[1, 128, 128, 128]	2,049

## 2차원 참조 채널대수층 생성

본 연구에서 제안된 Pix2Pix 기반의 모델 특성화 방법을 2차원 채널대수층에 적용하고 그 결과를 분석하였다. 참조 채널대수층 및 학습자료로 활용할 채널대수층 양상을 생성을 위해 Fig. 3(a)의 트레이닝 이미지를 바탕으로 다점지구 통계기법(multi-points statistics, MPS)를 적용하였으며, 채널의 방위각은  $0^{\circ}$ 에서  $90^{\circ}$ 의 범위에서  $10^{\circ}$ 간격으로 다양한 지질학적 시나리오에 따른 채널대수층 모델을 제작하였다(Fig. 3(b)). 채널대수층 양상을 생성 시 지구통계 소프트웨어인 GSLIB(Deutsch and Journel, 1992)과 이를 Python에서 구현할 수 있는 Geostatspy(Pyrcz et al., 2021)을 이용하였다.

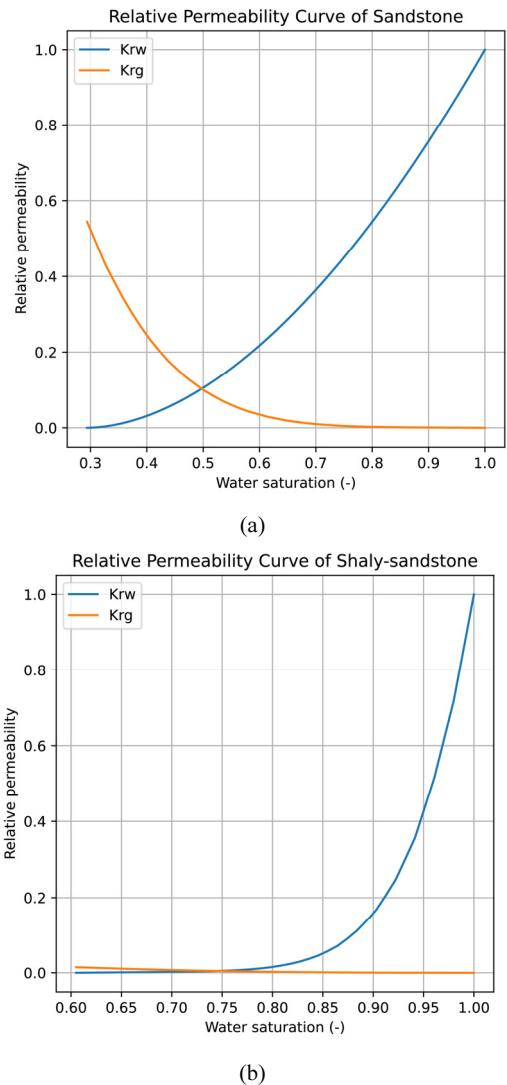
채널대수층 모델의 암상은 사암(sandstone)과 이질사암(shaly-sandstone) 두 종류로 구성하였으며, 모델링 결과에



**Fig. 3.** Training image and channel reservoir realizations through multi-point statistics (MPS). (a) the fluvial channel training image and (b) various MPS realizations with different azimuths indicating channel directions, where  $0^{\circ}$  is west-to-east, and  $90^{\circ}$  is north-to-south.

서 사암은 채널의 방향에 따라 연결성을 보인다. 사암과 이질사암의 유체투과도는  $450\text{mD}$  및  $25\text{mD}$ , 공극률은  $20\%$  및  $10\%$ 로 가정하였다. 또한, Bennion and Bachu(2005, 2007)의 이산화탄소 상대유체투과율 측정 결과를 참고하여 사암과 이질사암의 상대유체투과도를 가정하였다(Fig. 4).

참조 채널대수층 모델은 배사구조 형태인 2차원 모델로 제작하였으며 총 4개의 이산화탄소 주입정을 모델의 모서리 인근에 위치시켰다(Fig. 5). Fig. 6(a)은 참조 채널대수층의 암상분포를 나타내며 채널의 방위각이  $40^{\circ}$ 으로 형성되었다. 참조 채널대수층에 4개의 주입정으로 3년간 이산화탄소를 주입 시, 이산화탄소 포화도는 Fig. 6(b)과 같다. 탄



**Fig. 4.** Relative permeability curves by rock facies: (a) sandstone (b) shaly-sandstone.

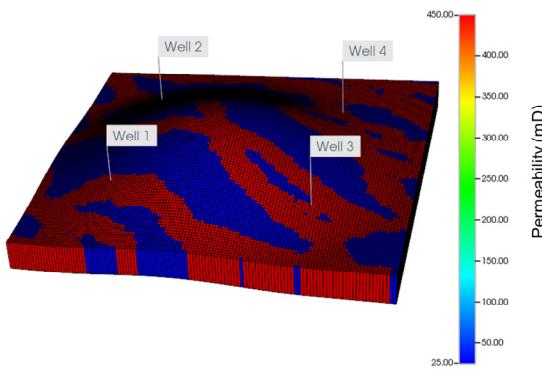


Fig. 5. Structure and ground-truth permeability of an aquifer.

성파 탐사의 수평방향 해상도는 150 m × 150 m로 가정하여 이산화탄소 포화도 맵에 150 m 크기의 가우시안 필터를 적용하였으며 문턱값(threshold) 0.25를 사용하여 이산화탄소 주입으로 인한 탄성파자료의 변한 부분과 변하지 않은 부분을 각각 1과 0으로 나타내었다(Fig. 6(c)). 제안한 방법의 Pix2Pix는 Fig. 6(c)의 탄성파자료 이미지를 입력 시 Fig. 6(a)과 같은 채널대수층 모델의 암상분포를 예측한다.

제안된 Pix2Pix 학습을 위해 총 2,500개의 채널대수층 모델을 생성하였으며, 각 모델의 암상분포와 모델을 Computer modeling group(CMG)社의 다상유체 유동 시뮬레이터인 GEM(Computer Modelling Group, 2020)에 입력하여 이산화탄소 주입 시뮬레이션을 수행하였다. 그 후 채널대수

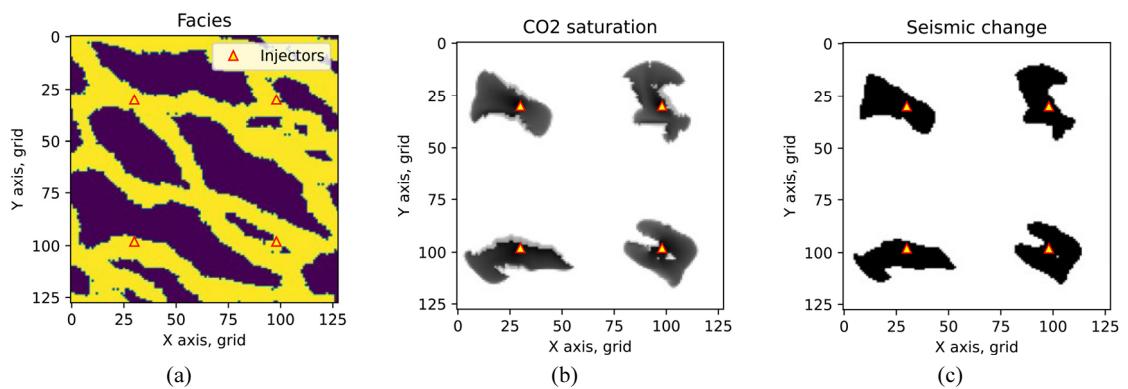


Fig. 6. Ground truth model. (a) rock facies, (b) gas saturation after 3 years of injection, (c) seismic changes after 3 years.

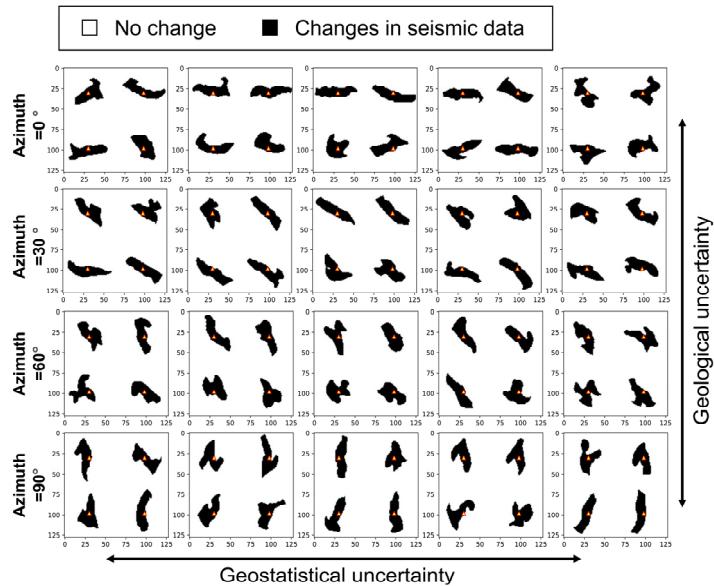


Fig. 7. Seismic changes of the training dataset after 3 years of CO<sub>2</sub> injection.

층 모델 정보와 시뮬레이션 결과를 Pix2Pix 학습자료로 사용하였다. 다상유체 유동 시뮬레이션에 사용된 주입정의 운영조건 및 대수층 인자는 Table 2와 같다. Fig. 7은 Fig. 3(b)에서 채널의 방위각에 따라 생성된 저류층 모델에 3년간 이산화탄소 주입 시뮬레이션 수행 후 그에 따른 탄성파자료의 변화를 예측한 것이다. 이를 통해 사암 채널의 방향을 따라 이산화탄소 액적군이 발달함을 확인할 수 있다.

### Pix2Pix 기반 채널대수층 특성화 기법 학습과정

동적자료인 이산화탄소 주입 3년간의 탄성파자료 변화를 이용하여 채널대수층을 예측하는 Pix2Pix을 학습시켰다. 이때 신경망의 입출력층 및 특성맵은 평균이 0이고 그

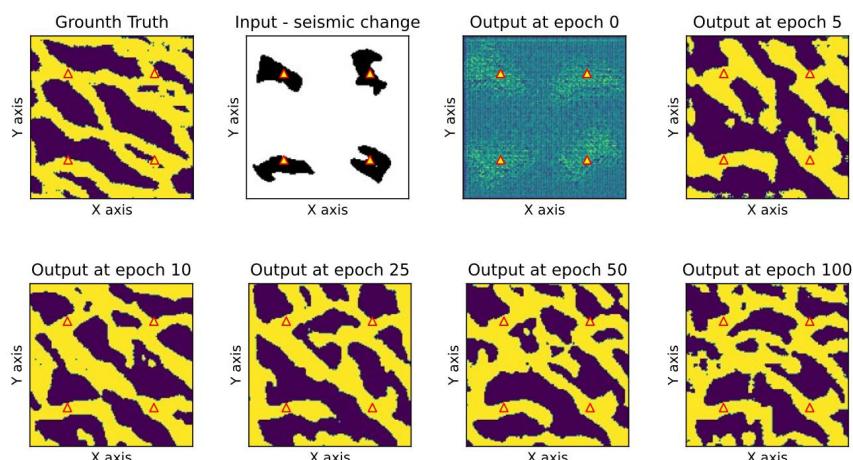
주변으로 값이 분포할 때 활성함수의 비선형성을 최대로 이용할 수 있다. 이는 학습성능 개선에 효과적이므로 Pix2Pix의 신경망 출력층에서 채널대수층의 사암과 이질 사암을 각각 1과 -1로 변환하였으며, 입력층에서 탄성파자료 변화 또한 변한 부분과 변하지 않은 부분은 각각 1과 -1로 변환하였다. Pix2Pix의 출력층에서 예측한 채널대수층 모델 결과가 1과 -1만으로 구성되지 않을 수 있어 문턱값 0을 사용하여 후처리(thresholding)를 수행하였다.

Pix2Pix의 총 2,500개의 학습자료를 매번 128개 모델의 batch로 2,000 epochs만큼 학습시켰으며, Fig. 8은 epoch별 학습된 모델의 예측결과를 보여준다. Epoch가 작은 경우에는 채널의 연결성이 보존되지 않으며 입력자료로 사용

**Table 2.** Grid system, reservoir properties, and operational parameters used in reservoir simulation

Parameters	Value	Unit
Aquifer model size ( $I \times J \times K$ )	$9,000 \times 9,000 \times 500$	$\text{ft} \times \text{ft} \times \text{ft}$
Grid cell number ( $I \times J \times K$ )	$128 \times 128 \times 1$	-
Grid cell size ( $I \times J \times K$ )	$70 \times 70 \times 500$	$\text{ft} \times \text{ft} \times \text{ft}$
Initial aquifer pressure	1803.16	psi (at top of anticline)
Sandstone porosity	20	%
Shaly-sandstone porosity	10	%
Sandstone permeability	450	mD
Shaly-sandstone permeability	25	mD
Salinity of aquifer	20,000	ppm*
Maximum BHP of wells	2,814	psi
Total CO <sub>2</sub> injection rate for 4 injection wells	2	Mt/year
Injection time	3	Years

\*ppm: parts per million.



**Fig. 8.** Training process of the suggested workflow.

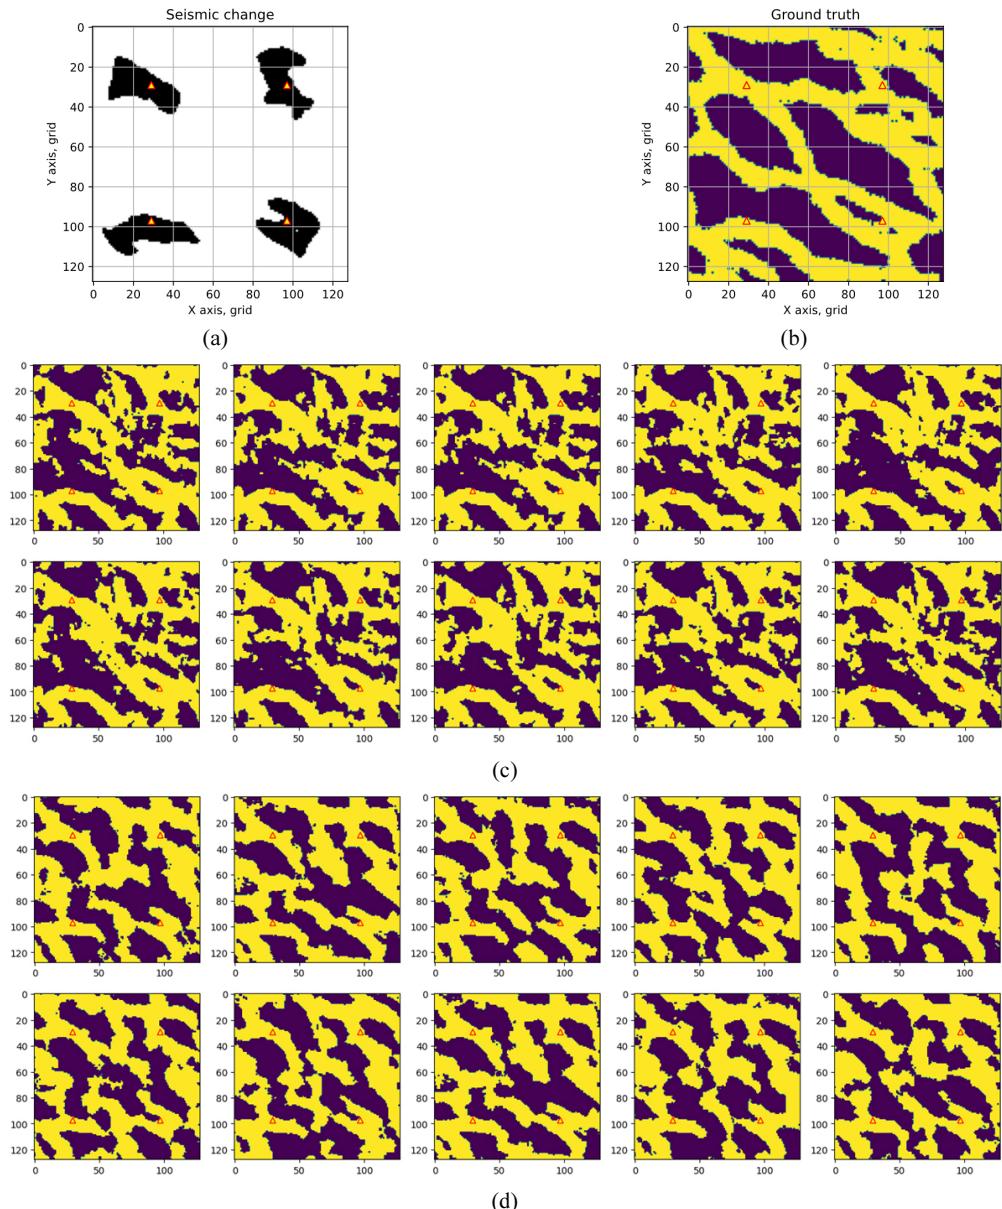
된 탄성파자료 변화 형태에 따라 채널이 구현되지 않는다. 하지만, 100 epochs 이상 학습 시 참값과 유사한 채널대수층이 생성되었다.

Pix2Pix는 앞서 설명한 두 가지 방법을 통해 동일 한 탄성파 변화 정보를 입력하더라도 다양한 채널대수층 모델을 생성할 수 있다. 첫번째 방법은 신경망 모델의 학습이 끝난 후 dropout을 사용해 확률성(stochasticity)을 추가하는 것

이고, 두번째 방법은 Pix2Pix의 입력층을 2개로 구성하여 탄성파 변화 자료와 표준정규분포를 따르는 랜덤 노이즈 맵을 함께 입력하는 방법이다.

#### 동적자료를 결합한 Pix2Pix 기반 채널대수층 특성화 결과

Pix2Pix 학습 시 사용되지 않은 참조 모델의 탄성파자료 변화를 입력하여 해당 모델의 채널대수층을 예측하였다



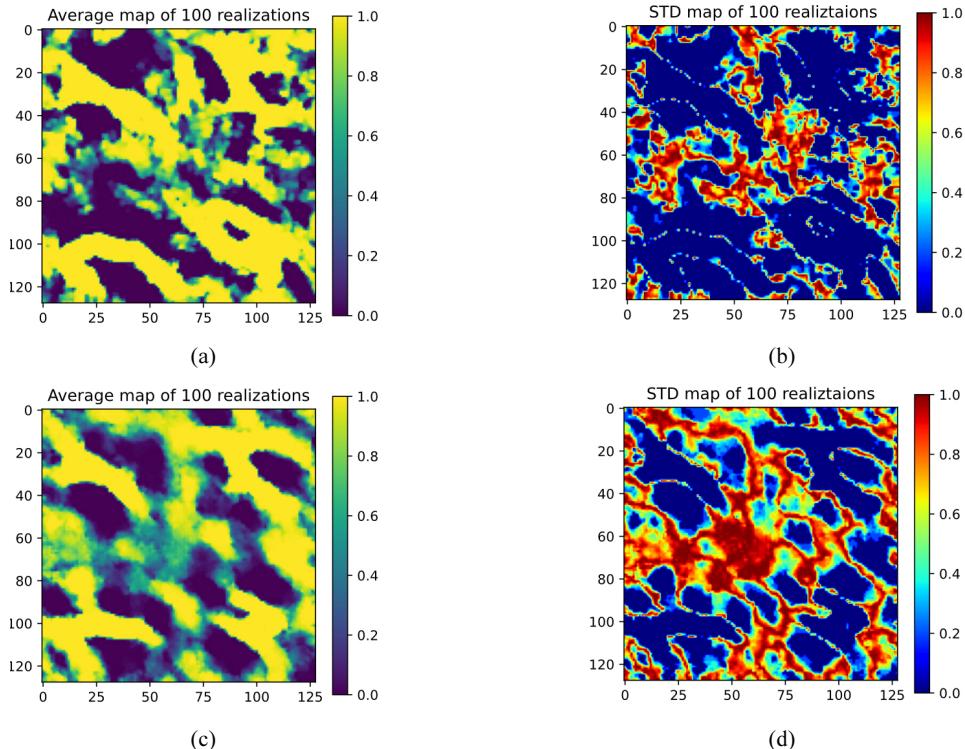
**Fig. 9.** Illustration of the outcomes generated by the proposed workflows. (a) seismic changes in the reference case, (b) ground-truth reservoir model, (c) realizations obtained through dropout, and (d) realizations achieved by incorporating a random noise map.

(Fig. 9). Fig. 9(a)와 Fig. 9(b)는 각각 참조 탄성파자료 변화 및 참조 채널대수층을 나타내며, Fig. 9(c)와 Fig. 9(d)는 학습된 Pix2Pix을 통한 10개 채널대수층 모델 결과이다. Fig. 9(c)는 dropout만을 이용하여 다양한 모델을 예측한 결과이며, Fig. 9(d)는 랜덤 노이즈 맵을 추가로 입력하여 예측한 결과이다. 두 방법 모두 약  $40^{\circ}$ 의 방위각을 가지는 채널 대수층을 사실적으로 예측한다. 특히, 주입정 주변의 이산화탄소 액적군의 발달 형태를 따라 채널이 모사되었으며, 학습자료로부터 얻은 지질학적 사실성에 기반하여 채널의 연결성이 보전되었다. 주입정에서 멀리 떨어진 모델 중심 지역은 입력자료에 아무런 정보가 없음에도 불구하고 채널이 연결된 모델과 연결되지 않는 모델이 모두 예측된 것은 Pix2Pix 모델의 학습과정에서 과적합이 발생하지 않음을 의미한다.

Fig. 10은 제안된 방법으로 각각 100개의 채널대수층 모델을 생성 후 암상의 평균과 표준편차의 분포를 산출한 것이다. 즉, 사암은 1, 이질사암은 0으로 수치화하여 각 격자마다 100개의 평균과 표준편차를 나타낸 것이다. Fig. 10(a)와 Fig. 10(b)는 dropout만을 이용하여 만든 채널대수층 모

델의 평균과 표준편차이고, Fig. 10(c)와 Fig. 10(d)는 랜덤 노이즈 맵을 추가로 입력하여 만든 채널대수층 모델의 평균과 표준편차이다. 두 방법 모두 평균 맵에서 참조 채널대수층과 유사한 방위각으로 채널이 발달하며 주입정 주변으로는 이산화탄소 액적군의 발달 형태를 따르는 채널이 예측됨을 확인하였다(Fig. 10(a) and Fig. 10(c)). 하지만, 모델 중심 지역의 채널은 입력자료에서 정보가 주어지지 않아 약한 연결성을 보인다. 표준편차 맵에서 주입정 주변은 낮은 값을 보이지만 주입정에서 멀리 떨어진 지역은 높은 표준편차를 나타내며, 이는 이산화탄소 액적군에 대한 정보가 주어지지 않은 지역에 대한 예측 결과는 불확실성이 높음을 의미한다(Fig. 10(b) and Fig. 10(d))。

학습자료로 사용한 2,500개의 모델과 제안된 방법으로 예측한 100개 모델의 암상분포와 참조 채널대수층 간 Intersection over Union(IoU)를 측정하였다. IoU는 예측 모델과 참조 모델의 암상분포 간 교집합 넓이(Area of intersection)를 합집합 넓이(Area of Union)로 나눈 것이다. 즉, IoU는 두 모델 간 암상분포의 유사도를 측정하는 지표로, 두 모델의 암상분포가 일치할수록 1에 가까우며 일치



**Fig. 10.** Visualization of the ensemble characteristics based on 100 realizations from the proposed methods. (a) average map and (b) standard deviation map of Pix2Pix realizations with dropout. (c) average map, and (d) standard deviation of Pix2Pix realizations with random noise input.

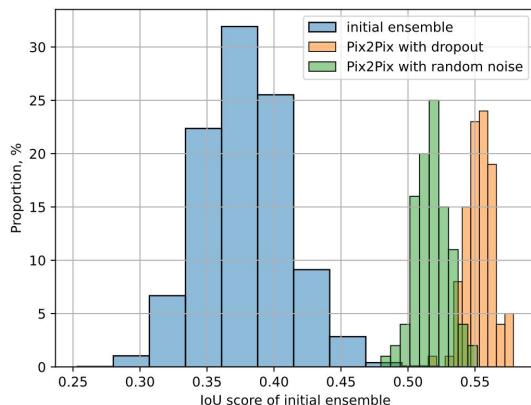


Fig. 11. IoU performance of the proposed methods.

하지 않을수록 0에 가까운 값을 보인다. Fig. 11은 2,500개 채널대수층 모델의 IoU 지표를 히스토그램으로 나타내었다. 학습에 사용된 2,500개의 모델은 참조 모델과의 IoU가 0.27 ~ 0.46로 낮은 반면, 제안된 방법으로 특성화된 모델은 참조 모델과의 IoU가 0.48 ~ 0.57로 분포한다. 이는 제안된 방법이 참조 채널대수층 모델의 암상분포를 보다 정확하게 모사하고 있음을 의미한다.

### 미래 이산화탄소 액적군 발달 예측

제안한 Pix2Pix 기반으로 탄성파자료 변화를 이용해 생성한 100개의 채널대수층 모델에 5년간 이산화탄소를 주입한 뒤 이를 참조 채널대수층의 결과와 비교하였다. Fig. 12(a)는 참조 채널대수층에서 이산화탄소 포화도의 변화

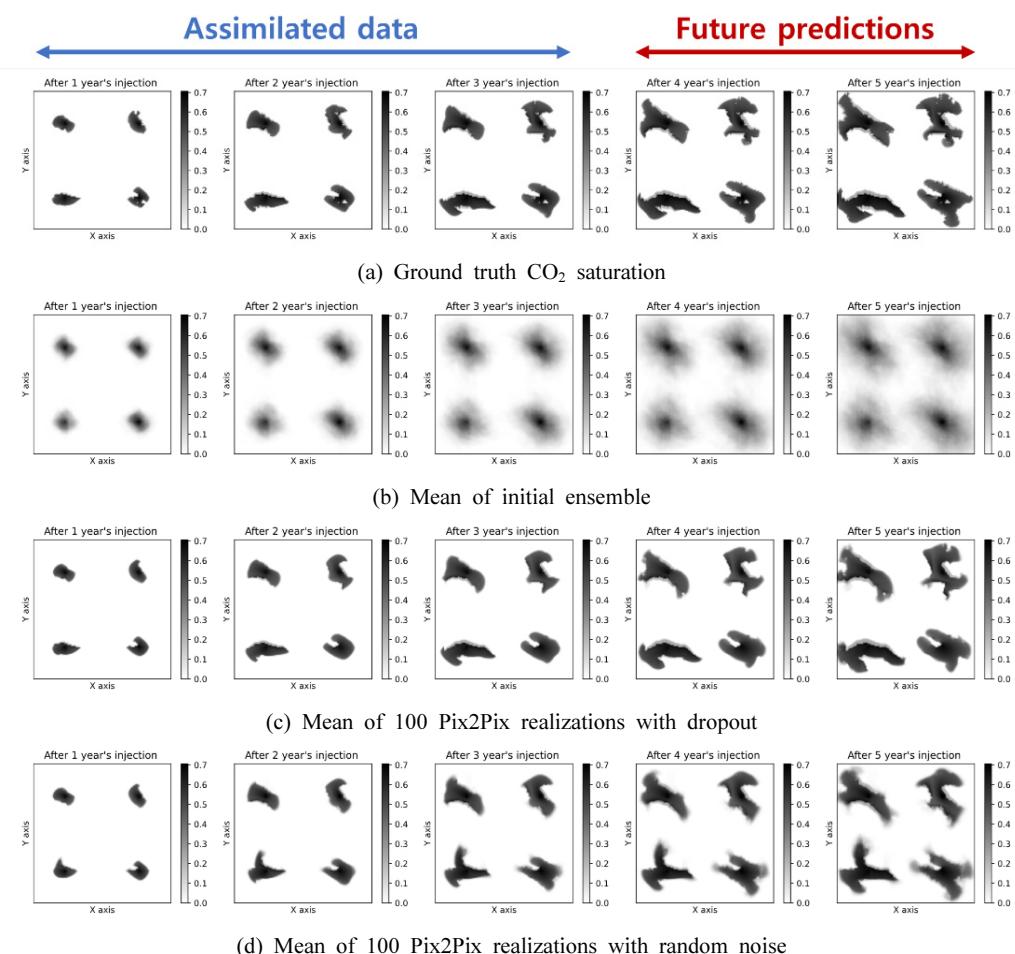


Fig. 12. Future prediction comparison: gas saturation maps up to 5 years of CO<sub>2</sub> injection. (a) ground truth CO<sub>2</sub> saturation from the reference channel reservoir model, (b) mean CO<sub>2</sub> saturation map of the 100 initial ensemble, (c) mean CO<sub>2</sub> saturation map of 100 Pix2Pix realization with dropout, and (d) mean CO<sub>2</sub> saturation map of 100 Pix2Pix realization with random noise.

를 나타낸 것으로, 처음 3년은 본 연구에서 제안된 Pix2Pix 학습에 이용되었고 그 뒤 2년간 미래 이산화탄소 액적군 발달을 예측한 결과이다. Fig. 12(b)는 학습자료로 사용한 2,500개 모델 중 100개의 양상을 채널대수층 모델로 5년간 이산화탄소 포화도의 예측한 결과의 평균을 나타낸다. 초기 양상들은 채널의 방위각이  $0^{\circ}$ 부터  $90^{\circ}$ 로 변하는 모든 경우를 포함함으로 이들의 평균 이산화탄소 포화도는 상당히 높은 불확실성을 보인다.

Fig. 12(c)와 Fig. 12(d)는 제안한 Pix2Pix기반 4-D 탄성파자료를 통합하여 생성된 100개의 채널대수층 모델로부터 이들의 평균 이산화탄소 포화도를 나타낸다. 모델생성에 이용한 초기 3년간 이산화탄소 액적군의 발달을 잘 모사할 뿐 아니라, 미래 4년과 5년뒤의 이산화탄소 액적군도 Fig. 12(a) 참조 채널대수층의 값과 유사하게 예측하고 있다. 이를 통해 제안한 방법이 미래 이산화탄소 액적군 분포의 불확실성을 효과적으로 정량화 할 수 있음을 보여준다.

## 결 론

본 연구에서는 4-D 탄성파 탐사자료를 통합하여 2차원 배사구조의 채널대수층 특성화를 위한 기계학습 방법을 제시하였다. Pix2Pix을 사용하여 이산화탄소 주입 3년 뒤의 탄성파 변화 정보로부터 지질학적으로 사실적인 형태의 채널대수층을 생성하였으며 다음의 결론을 도출하였다.

- 1) Pix2Pix을 통해 채널의 연결성을 보존하여 지질학적 사실성을 개선한 채널대수층 모델을 예측하였다. 또한, 학습이 완료된 인공신경망은 추가적인 계산시간이 필요하지 않으며 신속한 예측결과를 주는 장점이 있다.
- 2) Pix2Pix에 dropout과 랜덤 노이즈 맵을 적용하는 방법을 이용해 하나의 결정론적 모델 예측이 아닌 다양한 채널대수층 모델을 만들 수 있음을 보였고, 이는 추후 양상을 기반의 대수층 특성화 및 이산화탄소 주입 운영 최적화 등에 유용하게 쓰일 수 있다.
- 3) 제안한 방법을 통해 4-D 자료를 통합한 양상들은 참조 모델에 근사한 채널대수층을 생성할 뿐만 아니라 이산화탄소 액적군 이동에 대한 미래예측결과도 효과적으로 개선하였다.
- 4) 본 연구는 채널의 방위각의 변화에만 제한하여 지질학적 시나리오를 구축하였으나, 연구의 실용성 제고를 위해 채널의 방위각 이외에 채널의 너비, 채널의 굽이 정도(sinuosity), 암상의 비율 등 다양한 지질학적 시나리오에 대한 확장을 향후 연구주제로 고려할 수 있다. 또한 생성된 모델의 정량적인 분석에 IoU를 사용하였지만, 신경망 기반의 모델생성의 타당성 검증

을 위해 이와 관련한 추가적인 통계분석 및 평가방법에 대한 연구가 필요하다.

- 5) 본 연구에서는 2차원 채널대수층 모델에 이산화탄소 주입 시뮬레이션을 수행하여 도출한 이산화탄소 포화도 자료를 탄성파자료로 가정하였다. 이로 인해 현실적인 탄성파자료를 모사하는데 한계가 있으며, 2차원 모델 사용으로 인해 이산화탄소의 수직 유동을 반영하지 못한다. 후속 연구에서 대수층 모델을 3차원으로 확장하고, seismic forward modeling을 통한 탄성파자료를 사용하여 방법론을 개선한다면 현장 적용성을 높일 수 있을 것으로 기대한다.

## 사 사

이 논문은 2023년도 정부(산업통상자원부)의 재원으로 한국에너지기술평가원의 지원(20212010200010, CO<sub>2</sub> 저장효율 향상 기술 개발)과 산업통상자원부/해외자원개발 협회의 지원(2021060002, 디지털 오일필드 전문인력 양성)을 받아 수행된 연구입니다.

## References

- Ahn, Y. and Choe, J., 2022. Reliable channel reservoir characterization and uncertainty quantification using variational autoencoder and ensemble smoother with multiple data assimilation, *Journal of Petroleum Science and Engineering*, 209, 109816.
- Bennion, D.B. and Bachu, S., 2005. Relative permeability characteristics for supercritical CO<sub>2</sub> displacing water in a variety of potential sequestration zones in the western Canada sedimentary basin, In *SPE Annual Technical Conference and Exhibition*, SPE-95547.
- Bennion, D.B. and Bachu, S., 2007. Permeability and relative permeability measurements at reservoir conditions for CO<sub>2</sub>-water systems in ultralow-permeability confining caprocks, In *SPE Europec featured at EAGE Conference and Exhibition*, SPE-106995.
- Cheong, S., Kim, B., Park, Y., Park, Y., Kim, D., and Kim, H., 2022. Test processing of seismic monitoring using Sleipner 4D data, *Journal of the Korean Society of Mineral and Energy Resources Engineers*, 59(1), p.31-41.
- Computer Modelling Group, 2020. *GEM user's guide version 2020*, CMG, Canada.
- Deutsch, C.V. and Journel, A.G., 1992. *Geostatistical software library and user's guide*, New York, 119(147), p.578.
- Furre, A.K., Eiken, O., Alnes, H., Vevatne, J.N., and Kiær, A.F., 2017. 20 years of monitoring CO<sub>2</sub>-injection at Sleipner,

- Energy procedia*, 114, p.3916-3926.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y., 2014. Generative adversarial nets, In *Neural Information Processing Systems*, p.2672-2680.
- He, K., Zhang, X., Ren, S., and Sun, J., 2016. Deep residual learning for image recognition, In *Proceedings of the IEEE conference on computer vision and pattern recognition*, p.770-778.
- Hovorka, S.D., Doughty, C.K., Sakurai, S., and Holtz, M., 2005. Frio brine pilot: field validation of numerical simulation of CO<sub>2</sub> storage, In *Abstract, AAPG Annual Convention*, Calgary, Alberta, Canada, p.1-23.
- International Energy Agency (IEA), 2023. *Net zero roadmap a global pathway to keep the 1.5°C goal in reach*, IEA, Paris, France, 226p.
- Isola, P., Zhu, J.Y., Zhou, T., and Efros, A.A., 2017. Image-to-image translation with conditional adversarial networks, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, p.1125-1134.
- Jo, H., Cho, Y., Pyrcz, M., Tang, H., and Fu, P., 2022. Machine-learning-based porosity estimation from multifrequency poststack seismic data, *Geophysics*, 87(5), p.217-233.
- Jo, H., Jung, H., Ahn, J., Lee, K., and Choe, J., 2017. History matching of channel reservoirs using ensemble Kalman filter with continuous update of channel information, *Energy Exploration & Exploitation*, 35(1), p.3-23.
- Jo, H., Pan, W., Santos, J.E., Jung, H., and Pyrcz, M.J., 2021. Machine learning assisted history matching for a deepwater lobe system, *Journal of Petroleum Science and Engineering*, 207, 109086.
- Kim, J.W. and Nam, M.J., 2012. A review on monitoring the behavior and saturation of CO<sub>2</sub> at a CO<sub>2</sub> injection field, Nagaoka, Japan, *Journal of the Korean Society for Geosystem Engineering*, 49(5), p.677-688.
- Kim, S., Lee, K., Lim, J., Jeong, H., and Min, B., 2020. Development of ensemble smoother-neural network and its application to history matching of channelized reservoirs, *Journal of Petroleum Science and Engineering*, 191, 107159.
- LeCun, Y. and Bengio, Y., 1995. Convolutional networks for images, speech, and time series, *The handbook of brain theory and neural networks*, 3361(10), p.255-258.
- Lee, K.B., Jung, S.P., and Choe, J.G., 2015. Uncertainty quantification of channelized reservoirs using ensemble smoother with a distance-based method, *Journal of the Korean Society of Mineral and Energy Resources Engineers*, 52(2), p.139-147.
- Lee, K., Kim, S., Choe, J., Min, B., and Lee, H.S., 2019. Iterative static modeling of channelized reservoirs using history-matched facies probability data and rejection of training image, *Petroleum Science*, 16, p.127-147.
- Market Report Worlds, 2022. *Global carbon capture and storage (CCS) market insights, forecast to 2028*, Pune, India, 115p.
- Pan, W., Chen, J., Mohamed, S., Jo, H., Santos, J.E., and Pyrcz, M.J., 2023. Efficient subsurface modeling with sequential patch generative adversarial neural networks, In *SPE Annual Technical Conference and Exhibition*, SPE-214985-MS
- Pan, W., Jo, H., Santos, J.E., Torres-Verdin, C., and Pyrcz, M.J., 2022. Hierarchical machine learning workflow for conditional and multiscale deep-water reservoir modeling, *AAPG Bulletin*, 106(11), p. 2163-2186.
- Park, H. and Jin, J., 2023. Carbon neutrality/green growth national strategy and the first national basic plan and carbon neutrality in the urban sector (in Korean), *Urban planners*, 10(3), p.5-8.
- Pyrcz, M.J., Jo, H., Kupenko, A., Liu, W., Gigliotti, A.E., Salomaki, T., and Santos, J., 2021. GeostatsPy python package. Python Package Index, <https://pypi.org/project/geostatspy>
- Radford, A., Metz, L., and Chintala, S., 2015. Unsupervised representation learning with deep convolutional generative adversarial networks, *arXiv preprint arXiv:1511.06434*.
- Ronneberger, O., Fischer, P., and Brox, T., 2015. Convolutional networks for biomedical image segmentation, In *International Conference on Medical Image Computing and Computer-assisted Intervention*, p.234-241.
- Sato, K., Mito, S., Horie, T., Ohkuma, H., Saito, H., Watanabe, J., and Yoshimura, T., 2011. Monitoring and simulation studies for assessing macro-and meso-scale migration of CO<sub>2</sub> sequestered in an onshore aquifer: experiences from the Nagaoka pilot site, Japan, *International Journal of Greenhouse Gas Control*, 5(1), p.125-137.
- Sharma, S., Cook, P., Berly, T., and Anderson, C., 2007. Australia's first geosequestration demonstration project—the CO<sub>2</sub>CRC Otway basin pilot project, *The APPEA Journal*, 47(1), p.259-270.
- Statista, 2023.11.29., <https://www.statista.com/statistics/726624/large-scale-carbon-capture-and-storage-projects-worldwide-by-status/#:~:text=There%20were%20approximate ly%20265%20projects,are%20located%20in%20North%20America>
- Tang, H., Fu, P., Jo, H., Jiang, S., Sherman, C.S., Hamon, F., Azzolina, N.A., and Morris, J.P., 2022. Deep learning-accelerated 3D carbon storage reservoir pressure forecasting based on data assimilation using surface displacement from InSAR, *International Journal of Greenhouse Gas Control*, 120, 103765.
- Tang, H., Fu, P., Sherman, C.S., Zhang, J., Ju, X., Hamon, F.,

- Azzolina, N.A., Kurton-Kelly, M., and Morris, J.P., 2021. A deep learning-accelerated data assimilation and forecasting workflow for commercial-scale geologic carbon storage, *International Journal of Greenhouse Gas Control*, 112, 103488.
- Wang, Z., Bai, B., Long, Y., and Wang, L., 2019. An investigation of CO<sub>2</sub>-responsive preformed particle gel for conformance control of CO<sub>2</sub> flooding in reservoirs with fractures or fracture-like channels, *SPE Journal*, 24(05), p.2398-2408.
- Xue, Z., Tanase, D., and Watanabe, J., 2006. Estimation of CO<sub>2</sub> saturation from time-lapse CO<sub>2</sub> well logging in an onshore aquifer, Nagaoka, Japan, *Exploration Geophysics*, 37(1), p.19-29.

---

### 김 현 민

2023년 인하대학교 공과대학 에너지자원  
공학과 공학사



현재 인하대학교 대학원 에너지자원공학과 석사과정  
(E-mail; hyun\_0210@inha.edu)

---

### 신 현 돈

2006년 University of Alberta 석유공학  
박사



현재 인하대학교 에너지자원공학과 교수  
(E-mail; hyundon.shin@inha.ac.kr)

---

### 김 남 화

2020년 인하대학교 대학원 에너지자원공  
학과 공학석사



현재 인하대학교 대학원 에너지자원공학과 박사과정  
(E-mail; namhwa.kim@inha.edu)

---

### 조 홍 근

2021년 University of Texas at Austin 석  
유공학 박사



현재 인하대학교 에너지자원공학과 조교수  
(E-mail; honggeun.jo@inha.ac.kr)