



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학박사 학위논문

앙상블 기반 방법과 beta-convolutional variational autoencoder를 사용한 3차원 채널저류층 히스토리매칭

3D Channel Reservoir History Matching  
Using Ensemble-Based Method and Beta-Convolutional Variational Autoencoder

2023년 8월

서울대학교 대학원

에너지시스템공학부

안 영 빈

양상블 기반 방법과 beta-convolutional variational autoencoder를 사용한 3차원 채널저류층 히스토리매칭

지도 교수 최 종 근

이 논문을 공학박사 학위논문으로 제출함  
2023년 8월

서울대학교 대학원  
에너지시스템공학부  
안 영 빈

안영빈의 공학박사 학위论문을 인준함  
2023년 8월

위 원 장 \_\_\_\_\_ (인)

부위원장 \_\_\_\_\_ (인)

위 원 \_\_\_\_\_ (인)

위 원 \_\_\_\_\_ (인)

위 원 \_\_\_\_\_ (인)

## 초 록

저류층 모델을 구축하는 것은 시뮬레이션을 통해 미래 생산 거동을 예측하고 그로부터 의사 결정을 할 수 있게 하는 중요한 작업이다. 그러나 제한된 자료만으로 구축된 저류층 모델은 불확실성이 높아 신뢰도가 떨어진다. 따라서 오일 생산량과 같은 관측값을 따르도록 모델을 업데이트하는 히스토리매칭 과정이 필요하다.

양상블 기반 방법은 등가확률을 갖는 다수 모델의 집합인 양상블을 사용해 비선형 데이터를 교정하고 추계학적인 결과를 제공하여 히스토리매칭 알고리즘으로 적합하다. 하지만 양상블 멤버 각각이 정규분포를 따른다고 가정하기 때문에 물성이 이봉분포를 따르고 채널의 연결성이 중요한 채널저류층은 양상블 기반 방법으로 히스토리매칭하기 어렵다.

본 연구에서는 기계학습 알고리즘 중 하나인 beta-CVAE(beta-convolutional variational autoencoder)로 채널저류층의 유체투과율 분포로부터 잠재벡터를 학습한 뒤, ES-MDA(ensemble smoother with multiple data assimilation)로 업데이트하여 채널저류층을 히스토리매칭하는 기법을 제안한다. Beta-CVAE는 잠재벡터가 다변량 정규분포를 따르도록 생성 모델을 학습하기 때문에 잠재벡터를 업데이트할 때 ES-MDA의 가정을 만족할 뿐만 아니라 업데이트 후의 잠재벡터로부터 새로운 채널저류층의 유체투과율 분포를 생성할 수 있다.

네 가지 케이스에 대해 제안한 기법을 적용한 히스토리매칭 결과를 업데이트 후의 유체투과율 분포와 오일 생산량 및 워터컷 예측값으로 나누어 제시하였다. 네 케이스는 각각 초기 양상블이 참조 모델과 유사한 2차원 모델, 초기 양상블이 참조 모델과 다른 2차원 모델, 층에 따라 채널의 위치가 다른 3차원 모델, 층에 따라 채널의 모양이 다른 3차원 모델이다.

히스토리매칭 결과, 제안하는 기법이 비교군으로 제시한 다른 알고리즘을 사용한 결과에 비해 채널의 방향과 연결성 및 층 간의

연결성을 더 알맞게 예측하였다. 또한 앙상블의 평균값이 실제 오일 생산량과 워터컷 경향을 따라가면서 불확실성 범위를 적절하게 감소시켜 신뢰할 수 있는 히스토리매칭 결과를 제시하였다.

**주요어** : 히스토리매칭, 채널저류층, 3D 저류층, 앙상블 기반 방법, 기계 학습, beta-convolutional variational autoencoder

**학 번** : 2017-25078

# 목 차

초 록.....	i
목 차.....	iii
List of Tables.....	iv
List of Figures .....	v
1. 서론.....	1
2. 이론적 배경 .....	8
2.1 앙상블 기반 방법.....	8
2.2 Beta-variational autoencoder.....	14
2.3 합성곱 신경망 .....	20
2.4 저류층 모델 생성 방법.....	25
2.5 제안하는 채널저류층 히스토리매칭 기법 .....	29
3. 제안하는 기법을 사용한 채널저류층 특성화.....	32
3.1 2D 채널저류층 모델.....	32
3.1.1 모델 생성에 사용한 인자 정리.....	32
3.1.2 Case 1 - 좋은 초기 앙상블.....	39
3.1.3 Case 2 - 좋지 않은 초기 앙상블 .....	55
3.2 3D 채널저류층 모델.....	70
3.2.1 모델 생성에 사용한 인자 정리.....	71
3.2.2 Case 3 - 층에 따라 채널의 위치가 다른 모델 .....	79
3.2.3 Case 4 - 층에 따라 채널의 모양이 다른 모델 .....	110
4. 결론.....	143
참고 문헌 .....	146
부록 A. 채널저류층 학습을 위한 VAE 손실함수.....	151
Abstract .....	156

# List of Tables

<b>Table 3.1</b> TiGenerator parameters on 2D training image generation .....	33
<b>Table 3.2</b> Number of 2D realizations generated by SNESim.....	34
<b>Table 3.3</b> SNESim parameters on 2D training image generation ..	35
<b>Table 3.4</b> Parameters on 2D beta-CVAE network training .....	35
<b>Table 3.5</b> 2D reservoir simulation conditions.....	37
<b>Table 3.6</b> MAE of oil rate and watercut prediction, case 1 .....	54
<b>Table 3.7</b> MAE of oil rate and watercut prediction, case 2.....	70
<b>Table 3.8</b> Fluvsim parameters on 3D training image generation...	72
<b>Table 3.9</b> Number of 3D realizations generated by SNESim.....	73
<b>Table 3.10</b> SNESim parameters on 3D training image generation	73
<b>Table 3.11</b> Parameters on 3D beta-CVAE network training .....	74
<b>Table 3.12</b> 3D reservoir simulation conditions .....	77
<b>Table 3.13</b> MAE of oil rate and watercut prediction, case 3.....	110
<b>Table 3.14</b> MAE of oil rate and watercut prediction, case 4.....	142

# List of Figures

<b>Fig. 1.1</b> Example of reservoir characterization: (a) petrophysical data, (b) static data, (c) initial reservoir model, (d) history matching .....	3
<b>Fig. 2.1</b> Procedures of typical ensemble-based methods: (a) EnKF, (b) ES, (c) ES-MDA .....	10
<b>Fig. 2.2</b> Typical VAE network structure .....	15
<b>Fig. 2.3</b> Posteriori probability distributions by difference of KL divergence: (a) high KL divergence, (b) low KL divergence.	18
<b>Fig. 2.4</b> Data reconstruction with VAE network(left) and beta-VAE network(right): first row is original data, second row is the corresponding reconstructions, and the other rows are reconstructions from continuously varying latent vector (Burgess et al., 2018) .....	20
<b>Fig. 2.5</b> Example of convolutional neural network calculation where padding=1, stride=1 .....	22
<b>Fig. 2.6</b> Applying padding and stride for convolutional neural network calculation: (a) adding 1 padding around the input data, (b) initial calculation step, (c) skipping 1 stride for the next calculation	23
<b>Fig. 2.7</b> Comparison of the number of learning parameters between artificial neural network and convolutional neural network....	24

<b>Fig. 2.8</b> Procedure of constructing a search tree: (a) training image, (b) template, (c) example of search tree calculation .....	26
<b>Fig. 2.9</b> Estimation process of rock facies distribution for every grid of a reservoir model using SNESim and partial hard data .....	27
<b>Fig. 2.10</b> Flow chart of the proposed method.....	31
<b>Fig. 3.1</b> Structure of 2D beta-CVAE network for case 1 and case 2 .....	36
<b>Fig. 3.2</b> (a) Training images, (b) hard data, and (c) the reference model of case 1 .....	40
<b>Fig. 3.3</b> Initial permeability distribution of case 1: (a) – (c) selected models, (d) mean permeability .....	41
<b>Fig. 3.4</b> Training loss and validation loss vs epoch in case 1.....	42
<b>Fig. 3.5</b> Model reconstruction using beta-CVAE in case 1: (a) – (c) original models, (d) – (f) corresponding reconstructions.....	43
<b>Fig. 3.6</b> Permeability distribution and well placement of the reference model of case 1 .....	45
<b>Fig. 3.7</b> Mean permeability distribution of case 1, updated by the proposed method .....	45
<b>Fig. 3.8</b> Permeability distribution of the model in Fig. 3.3a, updated by the proposed method .....	46
<b>Fig. 3.9</b> Permeability distribution of the model in Fig. 3.3b, updated by the proposed method .....	46

<b>Fig. 3.10</b> Permeability distribution of the model in Fig. 3.3c, updated by the proposed method .....	47
<b>Fig. 3.11</b> Mean permeability distribution of case 1, updated only by ES-MDA.....	47
<b>Fig. 3.12</b> Permeability distribution of the model in Fig. 3.3a, updated only by ES-MDA .....	48
<b>Fig. 3.13</b> Permeability distribution of the model in Fig. 3.3b, updated only by ES-MDA .....	48
<b>Fig. 3.14</b> Permeability distribution of the model in Fig. 3.3c, updated only by ES-MDA .....	49
<b>Fig. 3.15</b> Performance prediction of the initial ensemble models in case 1: (a) oil production, (b) watercut .....	51
<b>Fig. 3.16</b> Performance prediction of the updated models using the proposed method in case 1: (a) oil production, (b) watercut.....	52
<b>Fig. 3.17</b> Performance prediction of the updated models using only ES-MDA in case 1: (a) oil production, (b) watercut .....	53
<b>Fig. 3.18</b> (a) Training images, (b) hard data, and (c) the reference model of case 2 .....	56
<b>Fig. 3.19</b> Initial permeability distribution of case 2: (a) – (c) selected models, (d) mean permeability.....	57
<b>Fig. 3.20</b> Training loss and validation loss vs epoch in case 2 .....	58

<b>Fig. 3.21</b> Model reconstruction using beta-CVAE in case 2: (a) – (c) original models, (d) – (f) corresponding reconstructions.....	59
<b>Fig. 3.22</b> Permeability distribution and well placement of the reference model of case 2 .....	61
<b>Fig. 3.23</b> Mean permeability distribution of case 2, updated by the proposed method .....	61
<b>Fig. 3.24</b> Permeability distribution of the model in Fig. 3.19a, updated by the proposed method .....	62
<b>Fig. 3.25</b> Permeability distribution of the model in Fig. 3.19b, updated by the proposed method .....	62
<b>Fig. 3.26</b> Permeability distribution of the model in Fig. 3.19c, updated by the proposed method .....	63
<b>Fig. 3.27</b> Mean permeability distribution of case 2, updated only by ES-MDA.....	63
<b>Fig. 3.28</b> Permeability distribution of the model in Fig. 3.19a, updated only by ES-MDA .....	64
<b>Fig. 3.29</b> Permeability distribution of the model in Fig. 3.19b, updated only by ES-MDA .....	64
<b>Fig. 3.30</b> Permeability distribution of the model in Fig. 3.19c, updated only by ES-MDA .....	65
<b>Fig. 3.31</b> Performance prediction of the initial ensemble models in case 2: (a) oil production, (b) watercut .....	67

<b>Fig. 3.32</b>	Performance prediction of the updated models using the proposed method in case 2: (a) oil production, (b) watercut.	68
<b>Fig. 3.33</b>	Performance prediction of the updated models using only ES-MDA in case 2: (a) oil production, (b) watercut	69
<b>Fig. 3.34</b>	Structure of 3D beta-CVAE network for case 3	75
<b>Fig. 3.35</b>	Structure of 3D beta-CVAE network for case 4	76
<b>Fig. 3.36</b>	(a) Training image and (b) hard data of case 3	81
<b>Fig. 3.37</b>	The reference model of case 3.	82
<b>Fig. 3.38</b>	Initial mean permeability distribution of case 3	83
<b>Fig. 3.39</b>	Initial permeability distribution of model #1 in case 3	84
<b>Fig. 3.40</b>	Initial permeability distribution of model #2 in case 3	85
<b>Fig. 3.41</b>	Initial permeability distribution of model #3 in case 3	86
<b>Fig. 3.42</b>	Training loss and validation loss vs epoch in case 3	87
<b>Fig. 3.43</b>	Reconstruction of model #1 using beta-CVAE in case 3: (a) original model, (b) corresponding reconstruction	88
<b>Fig. 3.44</b>	Reconstruction of model #2 using beta-CVAE in case 3: (a) original model, (b) corresponding reconstruction	89
<b>Fig. 3.45</b>	Reconstruction of model #3 using beta-CVAE in case 3: (a) original model, (b) corresponding reconstruction	90
<b>Fig. 3.46</b>	Permeability distribution and well placement of the reference model of case 3	92

<b>Fig. 3.47</b> Mean permeability distribution of case 3, updated by the proposed method .....	93
<b>Fig. 3.48</b> Permeability distribution of the model in Fig. 3.39, updated by the proposed method .....	94
<b>Fig. 3.49</b> Permeability distribution of the model in Fig. 3.40, updated by the proposed method .....	95
<b>Fig. 3.50</b> Permeability distribution of the model in Fig. 3.41, updated by the proposed method .....	96
<b>Fig. 3.51</b> Mean permeability distribution of case 3, updated using CAE instead of beta-CVAE .....	97
<b>Fig. 3.52</b> Permeability distribution of the model in Fig. 3.39, updated using CAE instead of beta-CVAE.....	98
<b>Fig. 3.53</b> Permeability distribution of the model in Fig. 3.40, updated using CAE instead of beta-CVAE.....	99
<b>Fig. 3.54</b> Permeability distribution of the model in Fig. 3.41, updated using CAE instead of beta-CVAE.....	100
<b>Fig. 3.55</b> Mean permeability distribution of case 3, updated using CVAE instead of beta-CVAE .....	101
<b>Fig. 3.56</b> Permeability distribution of the model in Fig. 3.39, updated using CVAE instead of beta-CVAE .....	102
<b>Fig. 3.57</b> Permeability distribution of the model in Fig. 3.40, updated using CVAE instead of beta-CVAE .....	103

<b>Fig. 3.58</b> Permeability distribution of the model in Fig. 3.41, updated using CVAE instead of beta-CVAE .....	104
<b>Fig. 3.59</b> Performance prediction of the initial ensemble models in case 3: (a) oil production, (b) watercut .....	106
<b>Fig. 3.60</b> Performance prediction of the updated models using the proposed method in case 3: (a) oil production, (b) watercut	107
<b>Fig. 3.61</b> Performance prediction of the updated models using CAE in case 3: (a) oil production, (b) watercut .....	108
<b>Fig. 3.62</b> Performance prediction of the updated models using CVAE in case 3: (a) oil production, (b) watercut .....	109
<b>Fig. 3.63</b> (a) Training image and (b) hard data of case 4 .....	112
<b>Fig. 3.64</b> The reference model of case 4.....	113
<b>Fig. 3.65</b> Initial mean permeability distribution of case 4 .....	114
<b>Fig. 3.66</b> Initial permeability distribution of model #1 in case 4 .....	115
<b>Fig. 3.67</b> Initial permeability distribution of model #2 in case 4 .....	116
<b>Fig. 3.68</b> Initial permeability distribution of model #3 in case 4 .....	117
<b>Fig. 3.69</b> Training loss and validation loss vs epoch in case 4 ...	118
<b>Fig. 3.70</b> Reconstruction of model #1 using beta-CVAE in case 4: (a) original model, (b) corresponding reconstruction.....	119

<b>Fig. 3.71</b> Reconstruction of model #2 using beta-CVAE in case 4: (a) original model, (b) corresponding reconstruction.....	120
<b>Fig. 3.72</b> Reconstruction of model #3 using beta-CVAE in case 4: (a) original model, (b) corresponding reconstruction.....	121
<b>Fig. 3.73</b> Permeability distribution and well placement of the reference model of case 4 .....	124
<b>Fig. 3.74</b> Mean permeability distribution of case 4, updated by the proposed method .....	125
<b>Fig. 3.75</b> Permeability distribution of the model in Fig. 3.66, updated by the proposed method .....	126
<b>Fig. 3.76</b> Permeability distribution of the model in Fig. 3.67, updated by the proposed method .....	127
<b>Fig. 3.77</b> Permeability distribution of the model in Fig. 3.68, updated by the proposed method .....	128
<b>Fig. 3.78</b> Mean permeability distribution of case 4, updated using CAE instead of beta-CVAE .....	129
<b>Fig. 3.79</b> Permeability distribution of the model in Fig. 3.66, updated using CAE instead of beta-CVAE.....	130
<b>Fig. 3.80</b> Permeability distribution of the model in Fig. 3.67, updated using CAE instead of beta-CVAE.....	131
<b>Fig. 3.81</b> Permeability distribution of the model in Fig. 3.68, updated using CAE instead of beta-CVAE.....	132

<b>Fig. 3.82</b> Mean permeability distribution of case 4, updated using CVAE instead of beta-CVAE .....	133
<b>Fig. 3.83</b> Permeability distribution of the model in Fig. 3.66, updated using CVAE instead of beta-CVAE .....	134
<b>Fig. 3.84</b> Permeability distribution of the model in Fig. 3.67, updated using CVAE instead of beta-CVAE .....	135
<b>Fig. 3.85</b> Permeability distribution of the model in Fig. 3.68, updated using CVAE instead of beta-CVAE .....	136
<b>Fig. 3.86</b> Performance prediction of the initial ensemble models in case 4: (a) oil production, (b) watercut .....	138
<b>Fig. 3.87</b> Performance prediction of the updated models using the proposed method in case 4: (a) oil production, (b) watercut .....	139
<b>Fig. 3.88</b> Performance prediction of the updated models using CAE in case 4: (a) oil production, (b) watercut .....	140
<b>Fig. 3.89</b> Performance prediction of the updated models using CVAE in case 4: (a) oil production, (b) watercut .....	141

# 1. 서론

석유는 인간 역사에서 천 년 이상 사용되어 온 천연 에너지 자원 중 하나로 현대 사회에서 1차 에너지 소비량의 약 30%를 구성하고 있는 중요한 자원이다(BP p.l.c., 2023). 하지만 그 중요도에 비해 석유가 본격적으로 사용된 건 오래되지 않았다. 19세기 초반까지는 목재의 부식을 방지하기 위해 바르는 도료나 의약품 정도로만 사용했기 때문에 수요가 많지 않았고, 지표면에 자연적으로 침출되어 나온 유정을 근거로 발견한 비교적 얻기 쉬운 석유만으로도 그 수요가 충당되었다.

석유가 본격적으로 사용되기 시작한 계기는 19세기 중반 이후 밤에 불을 밝히기 위한 연료로 석유를 사용한 것이다. 석유 수요가 늘자, Edwin Drake는 땅속을 시추하면 더 많은 석유가 있을 것이라는 생각으로 유정이 있는 곳 주변을 무작위로 시추하기 시작하였다. 수많은 실패 끝에 1859년 8월 27일 펜실베이니아 주의 티튜빌에서 지하 69.5ft에 있는 석유층을 발견하였고 이것이 석유산업의 유래가 되었다.

석유산업의 태동 이후 남북 전쟁과 산업 혁명이 일어나며 미국 내 석유 수요는 폭발적으로 늘어났으며 석유의 높은 수익성으로 인해 석유산업은 빠른 속도로 발전하였다. 1865년 256만 배럴 수준이었던 미국의 연간 원유 생산량은 1870년에는 511만 배럴, 1875년에는 1200만 배럴로 늘어났다(EIA, 2023).

그와 더불어 석유 개발, 탐사, 정제 등 석유산업을 전문적으로 하는 회사도 나타나기 시작하였고, 그 중에는 스탠더드 오일 같은 초대형 회사도 있었다. 이런 석유회사들은 석유산업 초창기의 정립되지 않은 탐사 및 개발 방식에서 벗어나 체계화된 작업을 통해 더 큰 이익을 추구하였다.

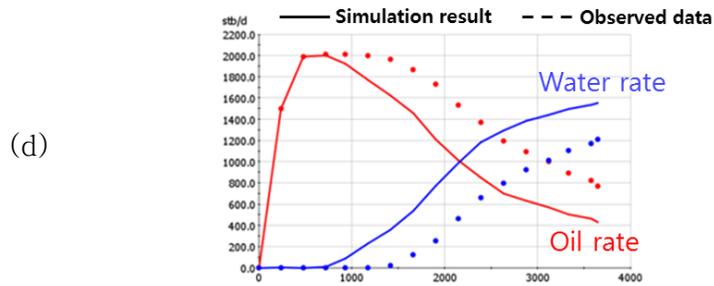
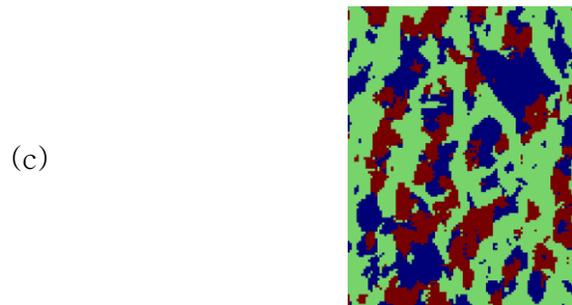
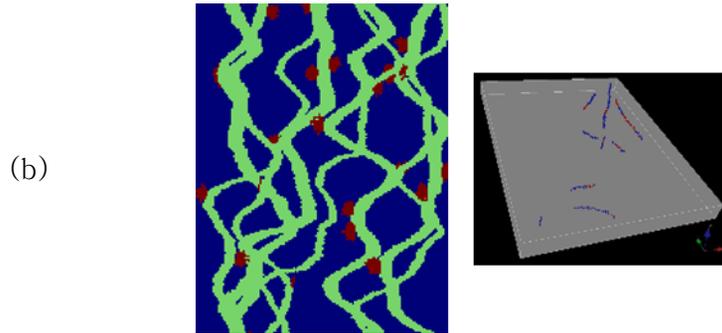
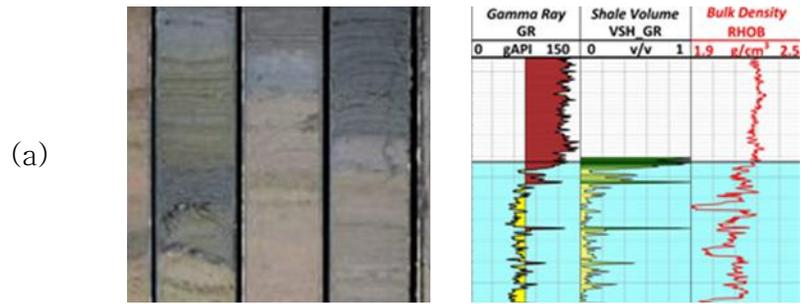
이미 탐사에 성공하여 개발 단계에 들어선 저류층은 생산성을 높이기 위해 저류층특성화를 거친다. 이는 유체 성분, 부존량, 평균 압력, 저류층 암석 및 유체의 물성 등 생산성에 영향을 주는 인자들을 신뢰할

수 있게 추정하여 의사 결정을 위한 근거 자료로 만드는 과정이다.

Fig. 1.1은 저류층특성화의 한 예시를 보여준다. 먼저 탐사와 현장 시험으로 얻은 코어 자료, 로깅 자료와 같은 미가공 상태의 지구물리학적 데이터를 트레이닝 이미지나 하드 데이터와 같은 정적 데이터로 가공한다.

정적 데이터를 바탕으로 적절한 지구통계학 기법을 사용하면 초기 저류층 모델을 생성하여 저류층의 거동을 예측할 수 있다. 그러나 초기 모델은 높은 불확실성으로 인해 신뢰할 수 있는 예측 결과를 얻기는 어렵다.

이를 보완하고자 생산을 진행하며 관측되는 생산량이나 공저압력과 같은 동적자료의 경향을 따르도록 저류층 모델을 업데이트하여 더욱 신뢰성 있는 모델을 만들 수 있으며, 이 과정을 히스토리매칭이라 한다.



**Fig. 1.1.** Example of reservoir characterization: (a) petrophysical data, (b) static data, (c) initial reservoir model, (d) history matching.

전통적인 히스토리매칭은 관측값과 저류층 모델을 바탕으로 공학자가 판단하여 유체투과율과 같이 유동에 영향을 미치는 저류층 인자를 수동으로 바꾸며 모델을 동적 자료에 맞추는 방식을 사용하였다. 하지만 최근에는 컴퓨터의 발전으로 큰 규모의 연산을 빠르게 계산할 수 있게 되면서 수학적 역산 알고리즘을 사용하여 저류층 인자를 업데이트하는 방식도 많이 사용한다.

양상블 기반 방법은 히스토리매칭에 많이 사용되는 역산 알고리즘 중 하나다. 이 알고리즘은 저류층 모델의 예측값과 유정에서 얻은 관측값을 비교해 오차를 최소화하는 방향으로 인자를 업데이트한다.

양상블은 등가확률을 갖는 다수 모델의 집합을 의미하며, 지구통계학 알고리즘을 사용해 히스토리매칭에 사용할 수 있는 양상블을 만들 수 있다. 대표적으로 순차가우시시물레이션(sequential Gaussian simulation, SGS), 단일정규방정식시물레이션(single normal equation simulation, SNESim)과 같은 알고리즘이 있다.

양상블 기반 방법은 기본적으로 업데이트할 인자가 정규분포를 따른다고 가정하기 때문에 물성이 로그정규분포를 따르는 저류층 모델을 업데이트할 때는 좋은 결과를 얻을 수 있다. Wen과 Chen(2007)은 양상블 기반 방법으로 가상 저류층 모델의 유체투과율을 반복 교정하여 기존의 방법보다 더 나은 히스토리매칭 결과를 얻었다. Bianco 등(2007)은 실제 육상 오일 유전을 기반으로 한 저류층 모델의 공극률 분포를 양상블 기반 방법으로 업데이트하여 불확실성을 고려한 미래 생산량 예측 결과를 제시함으로써 양상블 기반 방법이 실제 필드의 히스토리매칭에도 사용될 수 있다는 것을 보였다.

하지만 물성이 이봉분포를 따르는 채널저류층은 양상블 기반 방법의 가정을 만족하지 않기 때문에 양상블 기반 방법만으로는 신뢰할 수 있는 히스토리매칭 결과를 얻을 수 없다. 이를 개선하여 채널저류층을 히스토리매칭 하기 위한 많은 연구들이 있었고, 그 연구들이 제안하는 방법론은 크게 세 가지로 구분된다.

첫 번째로, 업데이트할 인자를 변형하는 알고리즘을 사용하는

방법을 제시한 연구들이 있다. Lorentzen 등(2009)은 이봉분포를 따르는 암상을 가진 채널저류층이 앙상블 기반 방법의 가정과 맞지 않는 것을 해결하기 위해 채널저류층의 각 지점에서 다른 암상을 만나는 지점까지의 거리를 레벨집합 함수로 표현하여 그것을 업데이트하는 방법을 사용하였다. Le 등(2015)은 앙상블 기반 방법으로 업데이트한 유체투과율 분포가 가우시안 혼합 모델에 따라 확률적으로 정해지는 기법을 제시하여 채널저류층을 히스토리매칭 하는 상황에서도 앙상블 기반 방법이 정규분포 가정을 따르도록 하였다. Kim과 Lee(2019)는 유체투과율 분포에 이산코사인변환을 적용하여 중요한 정보를 선별하고, 그것을 앙상블 기반 방법으로 업데이트한 뒤 스펙트럴 군집화를 통해 다시 원래 유체투과율 분포로 복원하여 채널의 형태와 암상 비율을 유지하는 알고리즘을 제시하였다.

두 번째로, 앙상블 기반 방법을 적용하기 전 좋은 앙상블 멤버를 미리 선정하는 방법을 제안한 연구들이 있다. Lee 등(2017)은 초기 앙상블을 K-평균 군집화 방법으로 구분한 뒤 관측값과 가장 비슷한 생산 경향을 보이는 군집을 선별해 평균 유체투과율 분포를 얻고, 그 데이터를 사용해 만든 새로운 앙상블에 위 과정을 다시 한 번 반복하여 초기 앙상블의 불확실성을 줄이고 시뮬레이션 시간을 단축하였다. Kang과 Choe(2017)는 주성분분석과 K-평균 군집화 방법을 사용하여 초기 앙상블을 군집으로 구분하고 관측값과 가장 유사한 생산 경향을 보이는 군집만을 선별하여 사용하는 알고리즘을 제시하였으며, 군집의 크기에 따라 히스토리매칭 결과가 어떻게 달라지는 지에 대한 민감도 분석 결과도 함께 제시하였다. Jung 등(2017)은 초기 앙상블의 오일 생산량 예측값과 관측값을 비교하여 가장 유사한 경향을 보이는 일부 모델을 선별한 뒤, 배수구역을 기준으로 앙상블 기반 방법의 공분산을 지역화하여 업데이트하는 방법으로 채널저류층을 히스토리매칭 하였다.

세 번째로, 기계학습과 앙상블 기반 방법을 함께 사용한 연구들이 있다. Canchumuni 등(2018)은 심층신뢰신경망으로 채널저류층의 암상 자료를 훈련 데이터로 사용하여 잠재벡터를 학습한 뒤 암상 대신

잠재벡터를 앙상블 기반 방법으로 업데이트하고, 업데이트된 새로운 잠재벡터로부터 채널저류층의 암상 분포를 복원하여 간접적으로 암상 분포를 업데이트하는 알고리즘을 제안하였다. Jung 등(2018)은 주성분분석, K-평균 군집화와 함께 데이터 분류에 주로 사용되는 기계학습 알고리즘인 서포트벡터머신을 사용하여 초기 앙상블 중 좋은 모델들을 선별하여 앙상블 기반 방법의 결과를 개선하고 시뮬레이션에 걸리는 시간을 단축시켰다. Kim 등(2020)은 좋은 초기 앙상블을 선별하는 기법들을 사용했을 때 선별된 모델들이 모두 비슷하여 오히려 앙상블 기반 방법의 성능을 떨어뜨리는 문제를 개선하기 위해, 심층신경망과 순환신경망을 사용하여 선별된 모델을 기반으로 새로운 모델을 재생성하는 기법을 제시하였다.

위 연구들이 제안하는 방법들을 사용하면 신뢰할 수 있는 채널저류층을 특성화 결과를 얻을 수 있다. 그러나 현재까지의 연구들은 방법론 검증에 2D 채널저류층을 사용한 연구들이 많기 때문에, 같은 방법을 3D 채널저류층에 적용했을 때는 똑같이 좋은 결과를 얻을 것이라고 기대하기는 어렵다.

실제로 Ahn과 Choe(2021)의 연구에서 2D 채널저류층 특성화를 위해 제안한, variational autoencoder(VAE)와 앙상블 기반 방법을 사용하는 히스토리매칭 기법을 3D 채널저류층에 동일하게 적용했을 때는 좋은 결과를 얻을 수 없었다. 주요한 문제점으로는 2D 채널저류층에 비해 데이터의 크기가 커서 연산에 소요되는 시간이 너무 길어지고, 채널 연결성과 같은 경향을 잘 찾아내지 못하며, 앙상블 기반 방법이 저류층 모델을 업데이트할 때 관측값을 반영한 결과를 제시하지 못하는 점들이 있었다.

본 연구는 위의 문제점들을 해결하여 3D 채널저류층을 성공적으로 히스토리매칭 할 수 있는 알고리즘을 제시하는 방향으로 진행하고자 한다. 먼저 VAE 네트워크의 은닉층에 합성곱층을 추가하여 이미지 형태의 데이터 학습을 용이하게 하고 연산 횟수를 크게 감소시킨다. 다음으로 beta-VAE 알고리즘을 사용하여 채널저류층의 특성이 서로

독립되고 얽히지 않는 방향(disentangled)으로 학습되도록 유도하여  
양상블 기반 방법을 사용한 모델 업데이트가 잘 이루어지도록 한다.

제안하는 방법론을 인공 2D 채널저류층 모델 2세트와 3D  
채널저류층 모델 2세트를 통해 검증하며, 해당 데이터셋은 TiGenerator,  
Fluvsim, 단일정규방정식시물레이션을 사용해 생성한다.

본 논문의 이후 내용은 이론적 배경, 연구 결과, 결론 순으로  
구성된다. 이론적 배경 챕터에서는 이번 연구에 사용한 양상블 기반  
방법, beta-VAE, 합성곱 신경망, 그리고 양상블 생성에 사용한  
TiGenerator 및 Fluvsim에 대해 자세히 설명하고 해당 알고리즘들을  
히스토리매칭에 적용한 방법론에 대해 다룬다. 연구 결과 챕터에서는 본  
논문에서 제안하는 방법론을 2D 채널저류층과 3D 채널저류층에  
적용했을 때 비교군에 비해 히스토리매칭 결과가 어떻게 개선되었는지에  
대해 보여준다. 마지막으로 결론 챕터에서는 연구 결과를 정리하고  
그로부터 얻은 결론을 제시한다.

## 2. 이론적 배경

### 2.1 앙상블 기반 방법

앙상블 기반 방법은 증가확률을 갖는 다수 모델의 집합인 앙상블을 사용해 역학계의 상태를 교정하는 재귀 알고리즘 중 하나다(Mandel, 2007). 이 때 교정은 앙상블의 예측값과 실제 역학계의 반응을 측정한 관측값 간의 오차공분산을 최소로 하는 방향으로 이루어진다.

앙상블 기반 방법은 크기가 큰 비선형 데이터를 교정하는 데 효과적이며 추계학적인 결과를 얻을 수 있다는 장점이 있다. 히스토리매칭 또한 비선형성을 띄는 방대한 양의 저류층 모델 인자를 유정에서 측정한 관측값에 맞도록 교정하는 작업이기 때문에 앙상블 기반 방법을 효과적인 히스토리매칭 알고리즘으로 사용할 수 있다.

대표적인 앙상블 기반 방법에는 앙상블칼만필터(ensemble Kalman filter, EnKF), 앙상블스무더(ensemble smoother, ES), ES-MDA(ensemble smoother with multiple data assimilation)가 있다.

EnKF는 Evensen(1994)이 비선형 모델을 사용하는 해양 역학 문제를 풀기 위해 제안한 방법으로, 기존에 비선형 데이터를 교정하는 데 사용하던 확장칼만필터의 계산 비용이 높은 문제를 해결하기 위해 제시되었다. 이후 Nævdal 등(2002)이 EnKF를 오일 저류층의 유체투과율 특성화에 사용하면서 석유공학 분야에도 처음으로 앙상블 기반 방법이 도입되었다.

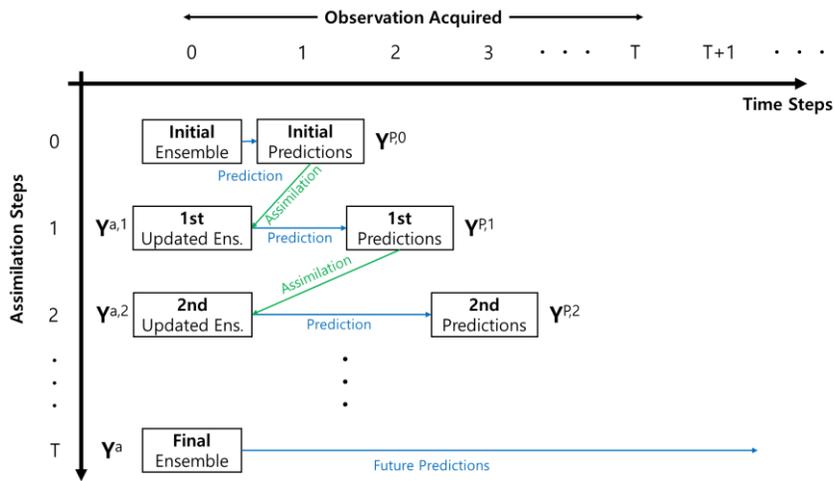
그럼에도 불구하고 EnKF는 여전히 계산 비용이 높았고, 이를 완화하기 위해 Van Leeuwen과 Evensen(1996)이 제시한 알고리즘이 ES다. EnKF는 관측값을 얻을 때마다 교정하는 반면 ES는 모든 관측값을 얻은 후 한꺼번에 교정을 하기 때문에 EnKF에 비해 연산 시간이 크게 줄어든다.

하지만 ES는 교정 단계가 한 번밖에 없기 때문에 해가 불안정하여

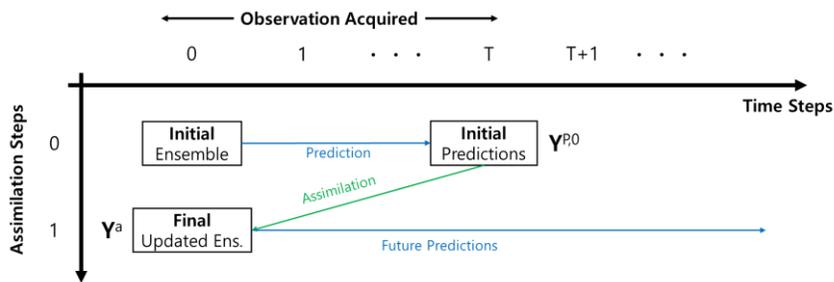
잘 수렴하지 못하고 비정상적으로 높거나 낮은 값으로 교정되는 오버슈팅과 같은 문제가 나타나기 쉽다. 이런 문제를 해결하기 위해 Emerick과 Reynolds(2013)는 ES-MDA를 제시하였다.

ES-MDA는 ES와 유사하게 모든 관측값을 사용하여 교정을 하지만, 알고리즘 사용자가 미리 정해놓은 교정횟수인  $N_a$ 번에 걸쳐 나누어 계산한다는 차이점이 있다. 이로써 ES에 비해 계산에 소요되는 시간은 늘어나지만 해는 더 안정적으로 수렴하게 된다.

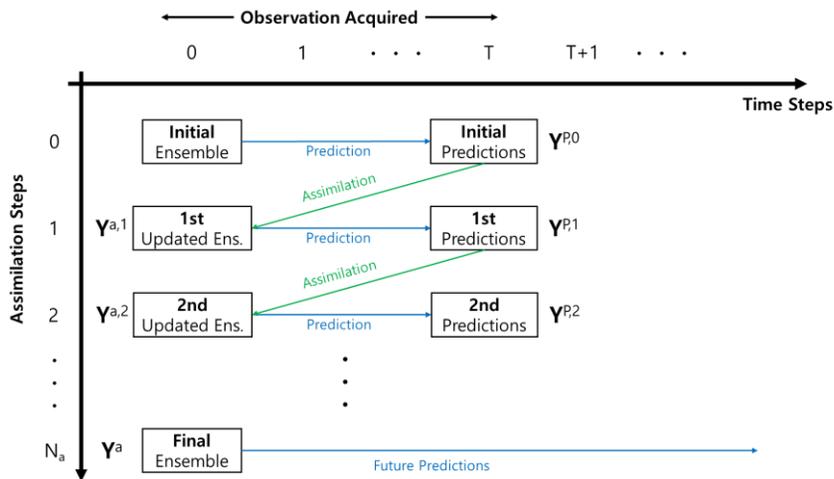
EnKF, ES, ES-MDA가 데이터를 교정하는 방식을 Fig. 2.1로 나타냈다. 본 논문에서는 히스토리매칭을 위한 앙상블 기반 방법으로 ES-MDA만을 사용하기 때문에 이후로는 ES-MDA를 중심으로 서술한다.



(a)



(b)



(c)

Fig. 2.1. Procedures of typical ensemble-based methods: (a) EnKF, (b) ES, (c) ES-MDA.

ES-MDA를 사용하여 히스토리매칭을 할 때 저류층 모델 인자들을 식 (2.1)로 표현하는 상태벡터(state vector) 형태로 정의한다:

$$y = \begin{bmatrix} m^s \\ m^d \\ d \end{bmatrix} \quad (2.1)$$

여기서  $m^s$ 는 정적인자,  $m^d$ 는 동적인자,  $d$ 는 관측인자를 의미한다(Nævdal 등, 2002).

정적인자는 암상, 공극률, 유체투과율과 같이 유전의 전체 생산기간 동안 변하지 않는 것으로 가정할 수 있는 물성들이고, 동적인자는 압력, 유량, 유체포화도와 같이 일반적으로 생산이 진행되면서 값이 변하는 물성들이다. 관측인자는 생산기간 동안 유정에서 계속적으로 측정할 수 있는 데이터로, 주로 유정의 생산 거동과 관련 있는 오일 생산량, 물 생산량, 워터컷, 정두압 등이 이에 해당된다. 앙상블 기반 방법에서  $N_e$ 개 앙상블 멤버들의 상태벡터들은 식 (2.2)와 같이 행렬 형태로 나타낸다:

$$Y = [y_1 \ y_2 \ \dots \ y_{N_e}] \quad (2.2)$$

ES-MDA의 첫 단계인 예측 단계는 전위 시뮬레이터를 사용하여 현재 시점의 정적인자와 동적인자를 가진 저류층 모델이 어떤 거동을 보일 것인지를 예측하는 단계다. 예측 단계는 다음과 같이 식 (2.3)으로 나타낼 수 있다:

$$\begin{bmatrix} m_{t+1}^d \\ d_{p,t+1} \end{bmatrix} = f(m_t^s, m_t^d) \quad (2.3)$$

여기서  $f$ 는 전위 시뮬레이터,  $d_p$ 는 시뮬레이터로 예측한 저류층 모델의 거동, 아래 첨자  $t$ 는 현재 시점,  $t+1$ 은 미래 시점을 의미한다.

본 연구에서 사용한 전위 시뮬레이터는 사용자가 설정한 T개의 시간 간격마다 예측값을 도출하기 때문에 상태벡터는 식 (2.4)처럼 T번째 시간의 동적인자와 1번째부터 T번째 시간 간격까지의 모든 예측값을 포함한다. 이런 형태를 갖는  $N_e$ 개의 앙상블 멤버들의 상태벡터들은 식 (2.5)와 같이 행렬 형태로 표현한다(Emerick과 Reynolds, 2013):

$$y^P = \begin{bmatrix} m^s \\ m^d \\ d_{p,1} \\ d_{p,2} \\ \vdots \\ d_{p,T} \end{bmatrix} \quad (2.4)$$

$$Y^P = [y_1^P \quad y_2^P \quad \dots \quad y_{N_e}^P] \quad (2.5)$$

전위 시뮬레이션을 통해 필요한 예측값을 모두 얻었으면 두 번째 단계인 교정 단계로 넘어간다. 이 단계에서는 실제 생산정에서 얻은 관측값과 예측 단계에서 얻은 예측값을 비교하여 오차공분산이 최소가 되는 방향으로 상태벡터를 교정한다.

교정 단계를 수식으로 나타내면 식 (2.6), (2.7), (2.8)로 표현한다:

$$C_Y^P = \frac{1}{N_e - 1} (Y^P - \bar{Y}^P)(Y^P - \bar{Y}^P)^T \quad (2.6)$$

$$K = C_Y^P H^T (H C_Y^P H^T + \alpha_t C_D)^{-1} \quad (2.7)$$

$$Y^a = Y^P + K(d_{obs} - H Y^P) \quad (2.8)$$

식 (2.6)에서  $C_Y^P$ 는 추정오차공분산으로, 예측 단계에서 얻은 상태벡터의 행렬과 그 행렬의 평균값의 차이로 계산한다. 이 값은 원래 정의에 따르면 상태벡터의 행렬과 참값의 차이를 계산해야 하지만, 참값은 알지 못하기 때문에 대신 상태벡터 행렬의 평균값을 사용한다. Evensen(2003)은 상태벡터 행렬의 평균값이 가장 최적의 예측값이며

양상블 멤버들은 그 주변의 값들을 가진다는 양상블 기반 방법의 기본 가정을 만족할 때, 추정오차공분산 계산식에 참값 대신 상태벡터 행렬의 평균값을 사용할 수 있다는 것을 보였다.

식 (2.7)의  $H$ 는 관측인자연산자로, 0과 1로만 구성되어 상태벡터의 값들 중 관측인자만을 선별하는 역할을 한다.  $\alpha_t$ 는  $N_a$ 번의 교정 과정에서 각각의 관측값이 갖는 민감도를 의미한다. 이 값은 사용자가 직접 설정하는 초매개변수로, 식 (2.9)와 같이 모든  $\alpha_t$ 에 대해 역수의 합이 1이라는 조건을 만족해야 한다.

$C_D$ 는 관측오차공분산이며, 관측값을 얻을 때 사용하는 장비와 자료 취득 방식에 대한 정보를 바탕으로 미리 결정해야 한다. 하지만 이 값은 대부분의 상황에서 알 수 없기 때문에 평균이 0인 랜덤관측오차  $\epsilon$ 을 써서 식 (2.10)과 같이  $C_D$ 를 대신하기도 한다. 이는 양상블 개수  $N_e$ 가 충분히 클 때 타당한 가정이다(Evensen, 2003).

이 값들로 계산한  $K$ 는 칼만게인이라 하며, 상태벡터가 관측값에 의해 얼마나 영향을 잘 받는지에 대한 척도가 된다. 칼만게인의 값이 클 수록 관측값에 더 크게 영향을 받는다.

$$\sum_{t=1}^{N_a} \frac{1}{\alpha_t} = 1 \quad (2.9)$$

$$C_D = \overline{\epsilon\epsilon^T} \quad (2.10)$$

마지막으로 식 (2.8)의  $d_{obs}$ 는  $\epsilon$  만큼의 오차를 더한 관측값,  $Y^a$ 는 최종적으로 교정된 상태벡터 행렬을 의미한다.

## 2.2 Beta-variational autoencoder

Beta-variational autoencoder는 기계학습 알고리즘인 VAE의 목적함수를 변형한 과생 알고리즘이다. 가장 먼저 기계학습은 데이터를 학습하여 분류, 회귀, 예측 등 특정한 작업을 하고자 할 때, 그것을 가능하게 하는 방법을 연구하고 정확도와 성능을 높일 수 있는 알고리즘을 탐구하는 학문이다(Mitchell, 1997).

VAE는 기계학습 알고리즘 중 비지도학습 알고리즘의 하나로, 이 알고리즘을 사용하는 주요 목적은 원본 데이터를 구성하는 데 핵심적인 역할을 하는 정보를 파악하여 특정한 분포를 따르는 잠재벡터(latent vector)를 학습하고 그와 동시에 학습된 모델이 생성 모델(generative model)이 되도록 유도하는 것이다.

학습할 잠재벡터의 분포는 어떤 분포라도 가능하지만 다변량 정규분포를 가정하는 것이 일반적이다. 생성 모델은 원본 데이터와 잠재벡터 간 결합확률을 계산하여 잠재벡터가 변화되었을 때 원본 데이터의 경향성을 따르는 새로운 데이터가 생성되도록 한다(Ng과 Jordan, 2002).

VAE의 일반적인 네트워크 구조는 Fig. 2.2와 같은 형태로 구성된다. 이 구조는 가장 가운데 위치한 잠재벡터층을 기준으로 좌우가 대칭에 가까운 형태로 구성되어 있으며 입력층과 출력층의 차원이 가장 크고 잠재벡터층의 차원이 가장 작다는 특징이 있다.

VAE를 학습할 때는 입력 데이터와 출력 데이터에 동일한 데이터를 입력하기 때문에, 학습 과정은 마치 원본 데이터가 잠재벡터로 부호화된 다음 그로부터 다시 원본 데이터로 복호화되는 것과 유사하다. 이와 같은 특징 때문에 전체 네트워크 구조를 두 개로 분리하여 입력층에서 잠재벡터층까지를 인코더, 잠재벡터층에서 출력층까지를 디코더라고 부르기도 한다.

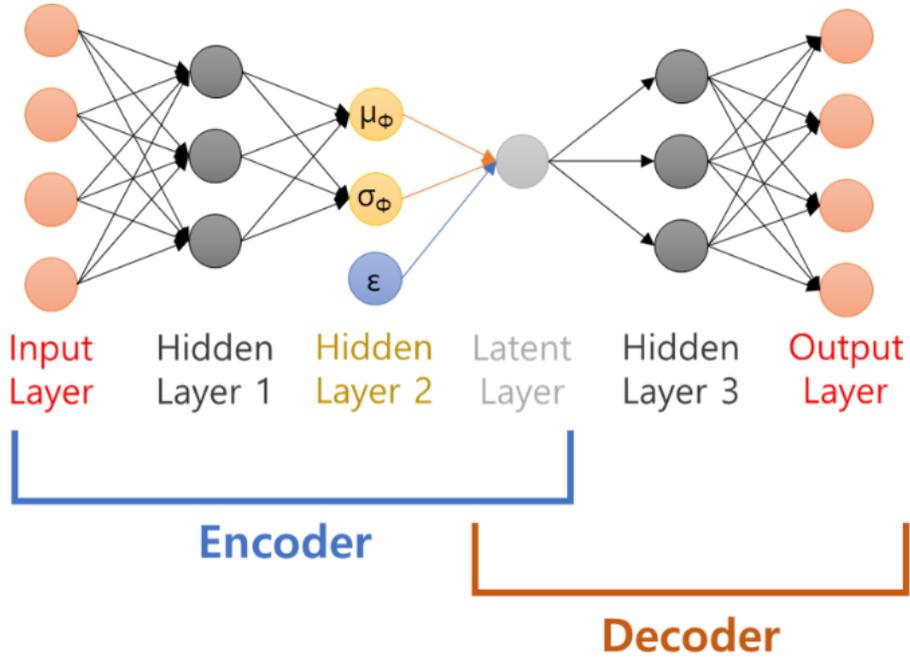


Fig. 2.2. Typical VAE network structure.

식 (2.11)은 Kingma와 Welling(2014)이 제시한, VAE를 학습할 때 최소화 하는 손실 함수다:

$$\mathcal{L}(\theta, \phi; x^i) = -\mathbb{E}_{q_\phi(z|x^i)} \left[ \log(p_\theta(x^i|z)) \right] + D_{KL}(q_\phi(z|x^i) \parallel p(z)) \quad (2.11)$$

$$D_{KL}(q \parallel p) = \sum_{x \in \mathcal{X}} q(x) \log \left( \frac{q(x)}{p(x)} \right) \quad (2.12)$$

여기서  $p_\theta(x|z)$ 는 잠재벡터로부터 원본 데이터를 재현하는 확률분포,  $\mathbb{E}_q(p)$ 는 사후확률분포  $q$ 에 대한 사전확률분포  $p$ 의 기대값,  $D_{KL}(q \parallel p)$ 는 두 확률분포  $p$ 와  $q$  사이의 Kullback-Leibler(KL) 분산을 의미한다.

식 (2.12)로 정의되는 KL 분산은 Kullback과 Leibler(1951)가 제시한 개념으로, 확률공간  $\mathcal{X}$ 에서 정의되는 이산확률분포  $p$ 가 이산확률분포  $q$ 로 대체되었을 때 얻는 정보의 양을 의미한다.

손실 함수 식을 두 항으로 분리해서 봤을 때, 왼쪽의 기대값 항은

원본 자료를 잘 복원하는 방향으로, 오른쪽의 KL 분산 항은 확률분포  $q$ 가 정규분포의 형태에서 벗어나지 않도록 하는 방향으로 학습을 유도한다. 이 손실 함수를 전개하여 실제로 학습에 적용하는 방법에 대해서는 부록 A에서 설명한다.

VAE에서 파생된 알고리즘인 beta-VAE는 Tishby 등(1999)이 발표한, 두 랜덤변수 간 상호 정보량을 최대한 보존하면서 한 변수를 압축하는 기법인 정보병목기법(information bottleneck method)에 근거를 둔다. 이 기법은 원래 정보이론 분야에서 사용하기 위해 제안되었으나, Alemi 등(2017)은 VAE 알고리즘의 핵심 이론 중 하나인 변분추론을 정보병목기법에 적용하여 학습의 정확성과 복잡성 간 최적의 타협점을 찾는 데 사용할 수 있는 deep variational information bottleneck을 제시하여 기계학습에도 사용할 수 있게 하였다.

정보병목기법의 핵심은 식 (2.13)을 최대화하는 것이다:

$$\max[I(Z; Y) - \beta I(X; Z)] \quad (2.13)$$

이 식의  $I(Z; Y)$ 는 디코더가 잠재벡터로부터 얼마나 원본 자료를 잘 복원할 수 있는지를 나타내는 값이고,  $I(X; Z)$ 는 잠재벡터에 입력 자료의 정보가 전달될 때 불필요한 정보가 얼마나 배제되는지를 나타내는 값이다. 마지막으로  $I(X; Z)$  항에 곱해진 값  $\beta$ 는 라그랑주 승수다.

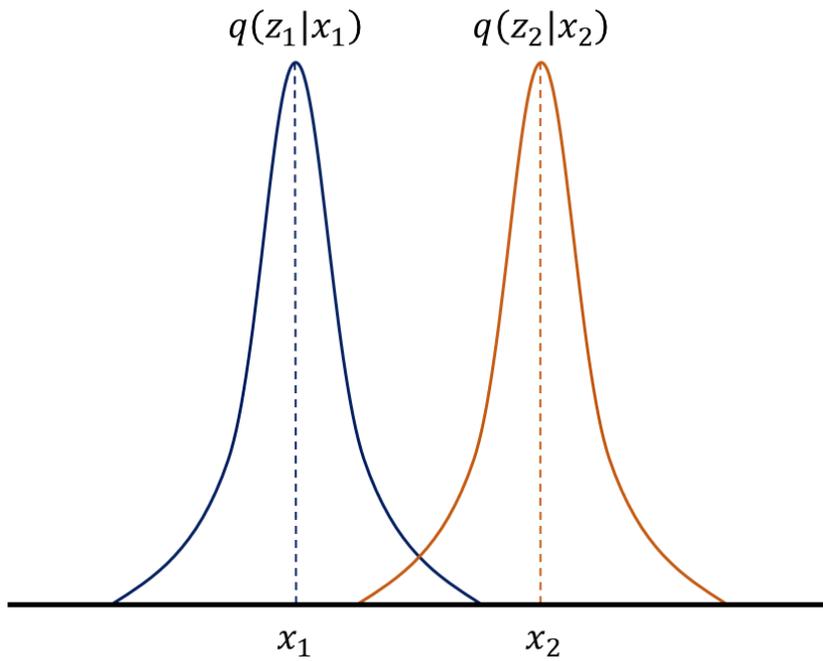
종합적으로, 이 식을 최대화함으로써 입력 자료로부터 얻을 수 있는 최소한의 정보만으로 잠재벡터를 구축하고 그로부터 다시 원본 자료를 복원할 수 있도록 학습을 유도한다.

Burgess 등(2018)은 이 연구 결과를 VAE의 손실 함수에 적용하여 식 (2.11) 대신 식 (2.14)를 손실 함수로 사용하여 VAE의 성능을 개선하는 beta-VAE를 발표하였다.

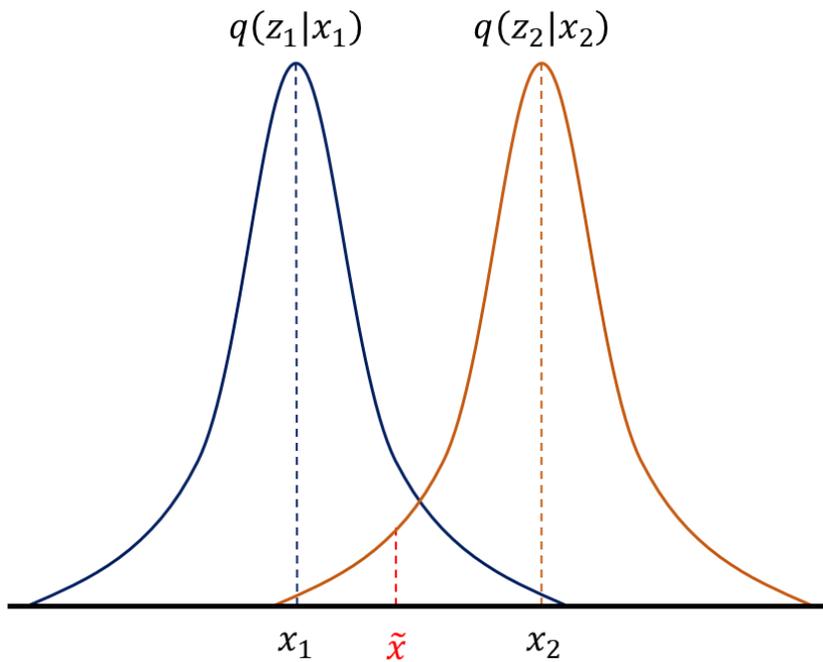
$$\begin{aligned} \mathcal{L}(\theta, \phi; x^i) = & -\mathbb{E}_{q_\phi(z|x^i)} \left[ \log(p_\theta(x^i|z)) \right] \\ & + \beta D_{KL}(q_\phi(z|x^i) \parallel p(z)) \end{aligned} \quad (2.14)$$

이 손실 함수 식의 KL 분산 항은 정보이론적 측면에서 보았을 때 자료 샘플 당 잠재벡터 층의 채널이 전송할 수 있는 정보의 양을 의미한다. 이 값이 작을수록 채널용량이 감소하는데, 그에 따라 Fig. 2.3과 같이 사후확률분포  $q$ 의 평균값이 서로 밀집하고 분산이 넓어지는 방향으로 학습된다.

만약  $q$ 들이 너무 과도하게 밀집되어 서로 공유하는 공간이 커질 경우 VAE 네트워크에 혼란을 가져올 수 있다. 예를 들어, Fig. 2.3b의  $\tilde{x}$ 가  $q(z_2|x_2)$ 에서 추출한 표본이라고 했을 때, 네트워크는 이것을  $q(z_1|x_1)$ 에서 추출한 표본일 가능성이 더 높다고 판단하게 된다.



(a)



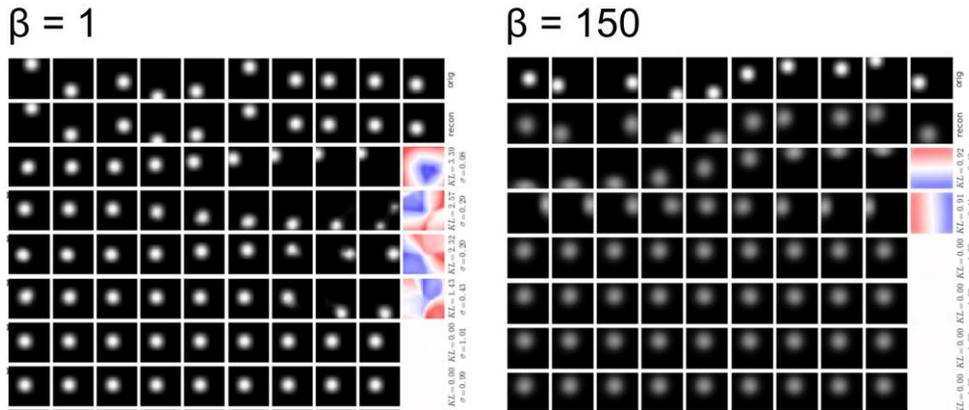
(b)

**Fig. 2.3.** Posteriori probability distributions by difference of KL divergence: (a) high KL divergence, (b) low KL divergence.

학습이 진행되면서 KL 분산 항의 값은 점점 감소하기 때문에 VAE를 사용하여 학습한 결과가 이런 경향성을 보일 경우 대처하기 어렵고, 이는 VAE 네트워크가 생성 모델로서 잘 동작하지 않는다는 것을 의미한다. 반면, beta-VAE를 사용하면 KL 분산 항에 곱해져 있는 초매개변수  $\beta$  값을 조절하여 사후확률분포  $q$ 가 서로 얽히지 않는 방향으로 학습되도록 유도하여 이런 문제를 완화할 수 있다.

기 언급한 Burgess 등(2018)의 연구에서도 beta-VAE의 특징을 보여주기 위한 실험을 진행하였다. 동일한 자료에 대해 일반 VAE 네트워크와  $\beta = 150$ 을 사용한 beta-VAE 네트워크를 각각 학습한 뒤, 잠재벡터에서 한 가지 값만 변화시키고 나머지 값은 고정했을 때 복원되는 데이터를 연속된 그림으로 나타내었다(Fig. 2.4).

그 결과 VAE로 학습한 네트워크에서는 복원된 데이터가 불연속적으로 변화하는 현상이 나타났지만, beta-VAE로 학습한 네트워크에서는 그런 현상이 나타나지 않고 연속적으로 변화하였다. 이를 통해 VAE에서 Fig. 2.3b와 같은 현상으로 인해 생성 모델이 잘 학습되지 않는 문제가 나타날 수 있다는 것을 보였으며, beta-VAE를 사용했을 때 해당 문제가 완화되는 것도 확인하였다.



**Fig. 2.4.** Data reconstruction with VAE network(left) and beta-VAE network(right): first row is original data, second row is the corresponding reconstructions, and the other rows are reconstructions from continuously varying latent vector (Burgess et al., 2018).

### 2.3 합성곱 신경망

합성곱 신경망은 이미지 자료를 학습하는 데 특화되어 있는 인공신경망의 일종이다. 합성곱 신경망의 기원은 Fukushima(1980)가 제시한 Neocognitron으로, 이는 인간이 패턴을 인식하는 감각기관인 시각피질의 단순세포와 복합세포가 동작하는 방식과 유사하게 구성된 인공신경망이다.

이후 LeCun 등(1998)은 Neocognitron으로부터 발전된 합성곱 신경망을 제안하며 손으로 쓴 숫자 자료의 인식 정확도를 높인 연구를 발표하였다. 이 연구에서 합성곱 신경망의 기본이 되는 활성화함수, 합성곱층, 완전연결층, 풀링층 등의 개념들이 정립되었다.

합성곱 신경망이 발표된 이후 다양한 연구 분야에서 이미지 자료 학습에 해당 알고리즘을 사용하는 연구들이 진행되었다. 석유공학 분야에서도 Srisutthiyakorn(2016)이 발표한, 2D 및 3D 엑스레이 이미지로부터 암석의 유체투과율을 추정하는 연구를 필두로 합성곱

신경망을 사용해 이미지 자료를 학습하는 연구들이 나타나기 시작하였다.

합성곱 신경망의 기본 원리는 합성곱 연산을 사용하여 이미지 자료의 공간적인 상관관계를 분석하여 학습하는 것이다. 합성곱은 식 (2.15)에서 \* 기호로 정의되는 연산자로, 두 함수 사이의 연산을 통해 제 3의 함수를 생성한다. 이 때 함수가 이산적인 값을 갖고 있으면 식 (2.15) 대신 식 (2.16)로 정의되는 이산 합성곱 식을 사용한다.

합성곱 신경망의 경우 이산적인 형태를 하고 있으며 가중치를 학습하는 것이 목표이기 때문에 식 (2.16)의 뿔셈 대신 덧셈을 사용해 계산을 단순화시킨 식 (2.17)을 사용하는 경우가 많다.

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau)g(t - \tau)d\tau \quad (2.15)$$

$$(f * g)[n] = \sum_{m=-\infty}^{\infty} f[m]g[n - m] \quad (2.16)$$

$$(f * g)[n] = \sum_{m=-\infty}^{\infty} f[m]g[n + m] \quad (2.17)$$

Fig. 2.5는 4x4 크기의 입력 자료와 3x3 크기의 합성곱 커널에 크기 1의 패딩과 스트라이드 값이 주어졌을 때 합성곱을 계산하는 예시를 나타낸다.

양수의 패딩 값이 주어지면 Fig. 2.6a와 같이 입력 자료의 바깥쪽으로 패딩의 크기만큼 0 값을 갖는 자료를 추가하여 더 큰 크기의 자료를 만든다. 패딩은 꼭지점에 위치한 픽셀의 정보가 손실되는 것을 방지하기 위해 사용된다. 이 예시에서도 패딩이 없을 경우 네 꼭지점의 자료는 합성곱 계산에 한 번 밖에 사용되지 않으나, 패딩이 있는 경우 각각 네 번씩 사용된다.

스트라이드 값은 패딩을 추가한 입력 자료에 합성곱 커널을 겹치고 연산을 할 때 얼마만큼 건너뛰면서 계산할 지를 의미한다. Fig. 2.6b 및 Fig. 2.6c처럼 스트라이드 값이 1이면 건너뛰지 않고 모든 값에 대해

합성곱을 계산하지만 1보다 큰 값을 가질 경우 일부 값을 뛰어넘어 합성곱을 계산하며, 최종 결과로 나오는 행렬의 크기가 작아진다.

$$\begin{array}{|c|c|c|c|} \hline 4 & 3 & 1 & 0 \\ \hline 5 & 2 & 2 & 1 \\ \hline 6 & 4 & 3 & 3 \\ \hline 4 & 5 & 5 & 4 \\ \hline \end{array}
 \times
 \begin{array}{|c|c|c|} \hline 1 & 2 & -1 \\ \hline 2 & 1 & 2 \\ \hline -1 & 2 & 1 \\ \hline \end{array}
 =
 \begin{array}{|c|c|c|c|} \hline 22 & 14 & 10 & 2 \\ \hline 30 & 30 & 18 & 9 \\ \hline 35 & 40 & 31 & 16 \\ \hline 22 & 34 & 30 & 23 \\ \hline \end{array}$$

Fig. 2.5. Example of convolutional neural network calculation where padding=1, stride=1.

0	0	0	0	0	0
0	4	3	1	0	0
0	5	2	2	1	0
0	6	4	3	3	0
0	4	5	5	4	0
0	0	0	0	0	0

(a)

0	0	0	0	0	0
0	4	3	1	0	0
0	5	2	2	1	0
0	6	4	3	3	0
0	4	5	5	4	0
0	0	0	0	0	0

\*

1	2	-1
2	1	2
-1	2	1

$$(1 \times 0) + (2 \times 0) + (-1 \times 0) + (2 \times 0) + (1 \times 4) + (2 \times 3) + (-1 \times 0) + (2 \times 5) + (1 \times 2) = 22$$

(b)

0	0	0	0	0	0
0	4	3	1	0	0
0	5	2	2	1	0
0	6	4	3	3	0
0	4	5	5	4	0
0	0	0	0	0	0

\*

1	2	-1
2	1	2
-1	2	1

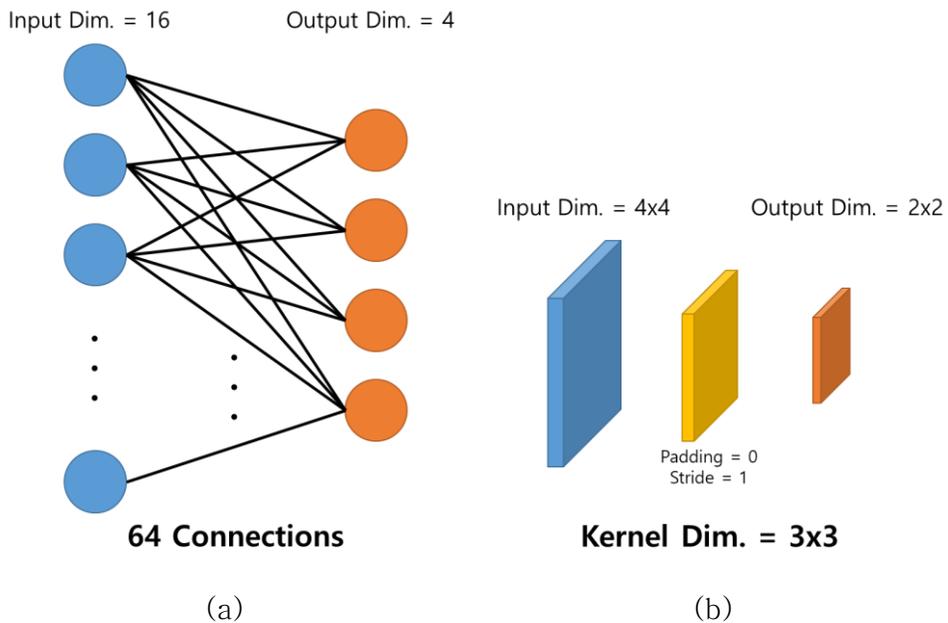
$$(1 \times 0) + (2 \times 0) + (-1 \times 0) + (2 \times 4) + (1 \times 3) + (2 \times 1) + (-1 \times 5) + (2 \times 2) + (1 \times 2) = 14$$

(c)

**Fig. 2.6.** Applying padding and stride for convolutional neural network calculation: (a) adding 1 padding around the input data, (b) initial calculation step, (c) skipping 1 stride for the next calculation.

합성곱 커널을 거친 후의 결과 행렬은 두 가지 특징이 있다. 첫째로, 행렬의 각 픽셀의 값은 입력 자료의 일정 범위를 복합적으로 학습한 결과다. 둘째로, 입력 자료와 은닉층 간의 가중치를 직접 학습하는 일반 인공신경망과는 달리 합성곱 커널의 값을 학습하기 때문에 연산 비용이 크게 감소한다.

Fig. 2.7와 같이 입력층의 차원이 16이고 은닉층의 차원이 4인 인공신경망을 가정했을 때, 일반 인공신경망을 사용하면 입력층과 은닉층이 1:1로 연결되어 학습해야 할 인자 수는 64개지만, 합성곱 신경망을 사용하면 학습해야 할 인자 수가 9개로 감소한다.



**Fig. 2.7.** Comparison of the number of learning parameters between artificial neural network and convolutional neural network.

합성곱 신경망은 단독으로 사용할 수도 있지만 다른 기계학습 알고리즘과 함께 사용할 수도 있다. 본 연구에서는 앞서 언급했던 beta-VAE에 합성곱층을 추가한 beta-CVAE를 사용하였다. 이 경우 합성곱층의 장점과 beta-VAE의 장점을 모두 활용할 수 있는 기계학습 알고리즘이 된다.

## 2.4 저류층 모델 생성 방법

본 연구에서 제안하는 히스토리매칭 기법을 검증하기 위해 4개의 가상 저류층 모델 데이터셋을 생성하였고, 이는 2D 채널저류층 모델 2세트와 3D 채널저류층 모델 2세트로 구성된다.

채널저류층 모델은 공통적으로 SNESim 알고리즘을 사용해 생성했다. SNESim은 Strebelle(2000)가 제시한 지구통계학 기법으로, 트레이닝 이미지의 분포 양상을 탐색트리로 만든 뒤 그것을 바탕으로 다수의 등가모델을 생성하는 기법이다.

탐색트리를 만들기 위해서는 트레이닝 이미지와 템플릿이 필요하다. 트레이닝 이미지는 관심 있는 저류층의 지질학적 혹은 지구물리학적 탐구 자료와 탐사 자료를 바탕으로 만들며, 저류층을 대표할 수 있으면서 지구통계학적으로 불변성을 만족하는 이미지 자료를 말한다. 템플릿은 알고리즘 사용자가 설정한 고유한 모양과 탐색방향을 가지는 도형이다.

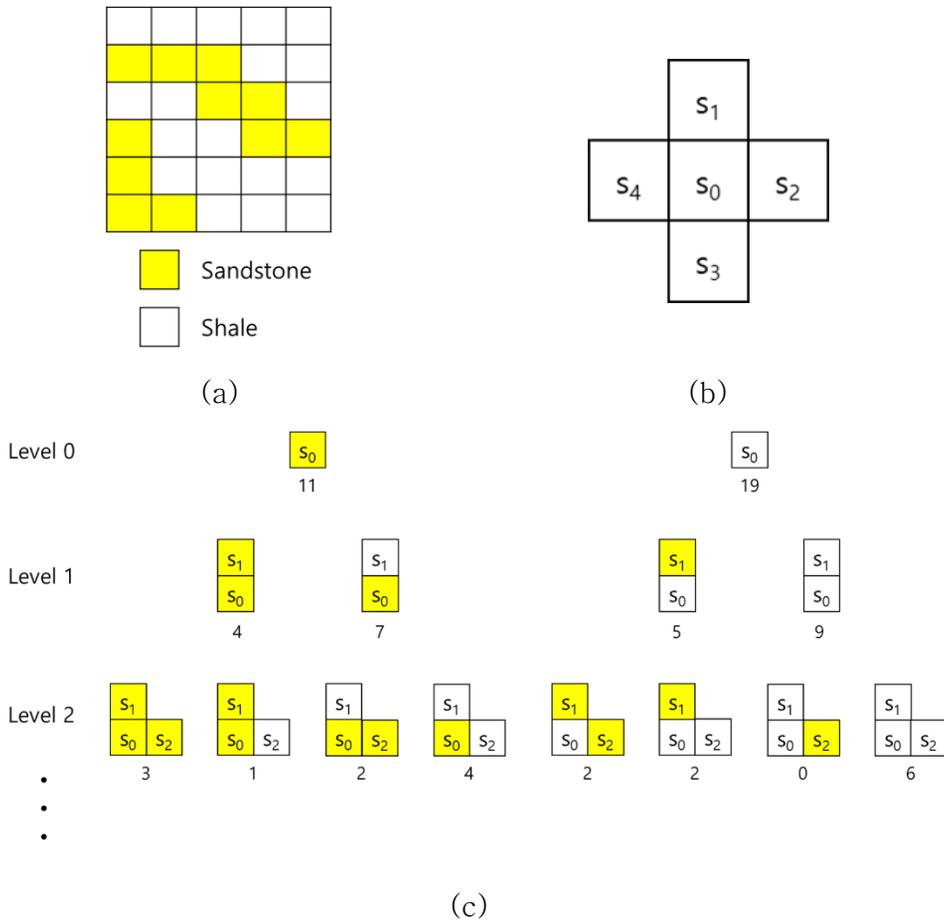
Fig. 2.8은 탐색트리를 만드는 과정을 간단하게 모식화한 것이다. 이 예시에서 트레이닝 이미지는 셰일과 사암의 분포를 나타낸 2D 모델이며, 트레이닝 이미지에 사용하는 템플릿은 십자 모양으로  $s_1, s_2, s_3, s_4$  순으로 탐색한다.

Fig. 2.8c에서 첫 번째로 수행하는 계산은 총 4가지 경우의 수로, 각각  $s_0$ 가 사암일 때  $s_1$ 도 사암인 경우,  $s_0$ 가 사암일 때  $s_1$ 이 셰일인 경우,  $s_0$ 가 셰일일 때  $s_1$ 이 사암인 경우,  $s_0$ 가 셰일일 때  $s_1$ 도 셰일인 경우다. 이 값들은 트레이닝 이미지 전체를 확인하면서 해당 템플릿과 같은 형태가 나오는 횟수를 세어서 계산할 수 있다.

이 값들이 가지는 의미는 한 지점의 암상이 사암인 것을 알지만 바로 위 지점의 암상을 모를 때 그 지점이 사암일 확률을 4/11, 셰일일 확률을 7/11로, 반대로 암상을 아는 지점이 셰일이면 바로 위의 암상이 사암일 확률을 5/14, 셰일일 확률을 9/14로 추정할 수 있다는 것이다.

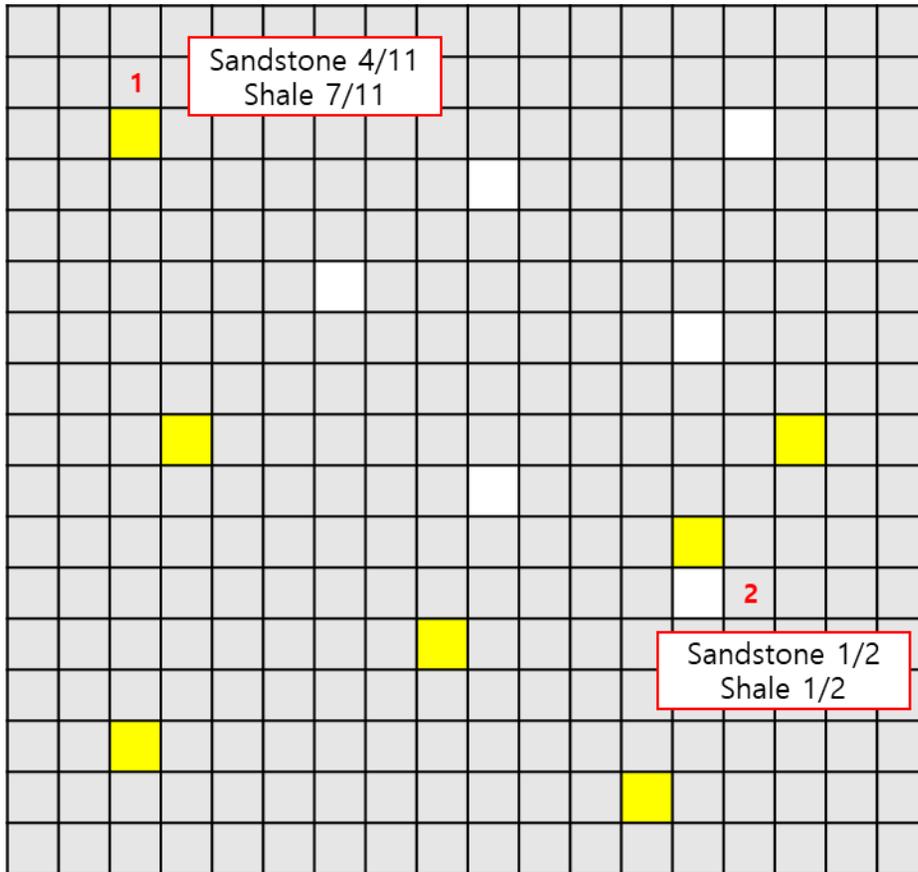
그 다음 계산은 위 네 가지 경우로부터 이어나가 각각  $s_2$ 가 사암인

경우와 세일인 경우의 수를 계산하며, 이와 동일한 방식으로 템플릿의 탐색방향을 모두 거치면서 경우의 수를 계산하면 탐색트리가 완성된다.



**Fig. 2.8.** Procedure of constructing a search tree: (a) training image, (b) template, (c) example of search tree calculation.

Fig. 2.9처럼 저류층의 일부 지점에서의 암상 자료를 하드데이터로 가지고 있는 경우 SNESim은 탐색트리를 사용해서 미지의 지점의 암상을 추정하여 저류층 전체에 대한 암상 분포를 만든다. 이 때 추정할 지점을 정하는 순서는 무작위로 정해지고, 같은 지점이라고 할지라도 어떤 암상으로 정해질지는 탐색트리의 조건부확률을 따라서 결정되기 때문에 SNESim을 사용하면 등가확률을 갖는 다수 모델을 생성할 수 있다.



**Fig. 2.9.** Estimation process of rock facies distribution for every grid of a reservoir model using SNESim and partial hard data.

SNESim을 사용하기 위한 트레이닝 이미지는 2D 채널저류층 모델의 경우 Maharaja(2008)가 제안한 TiGenerator 알고리즘을 사용해서 생성하였다. TiGenerator는 객체기반 알고리즘으로, 관심 지층 내의 지질학적 요소들을 타원, 직선, 삼각형, 사각형, 사인파곡선 등 간단한 객체로 나타내고, 해당 도형들의 고유한 특성값과 목표 비율을 결정한 뒤 시뮬레이션하여 지질학적 요소들이 고려된 트레이닝 이미지를 만든다.

예를 들어, 채널저류층을 트레이닝 이미지로 만들 때 객체로써 주로 사용하는 사인파곡선은 진폭, 파장, 방향, 길이, 두께 등의 특성과 객체가 배경 대비 차지할 비율을 정한다.

한편, 3D 채널저류층 모델의 트레이닝 이미지는 Deutsch와 Tran(2002)이 제안한 Fluvsim을 사용해서 만들었다. Fluvsim은 TiGenerator와 비슷한 객체기반 알고리즘이지만, 보편적인 지질학적 구조를 모두 고려하는 게 아닌 하성 퇴적층만을 모사하기 위해 고안된 알고리즘이다. 따라서 Fluvsim은 하성 퇴적층의 하도, 둑, 탐상퇴적체 등 보다 구체적인 구조를 포함한 모델을 만들 수 있다.

원래 Fluvsim은 SNESim과 유사하게 하드데이터로부터 증가확률을 갖는 다수의 채널저류층 모델을 만들기 위해 제안되었으나, 이후 트레이닝 이미지를 만들 때도 Fluvsim을 사용할 수 있다는 연구 결과가 있었다(Pyrcz 등, 2008). 따라서 본 연구에서도 Fluvsim을 트레이닝 이미지를 만드는 데 사용하였다.

## 2.5 제안하는 채널저류층 히스토리매칭 기법

앞서 네 절에 걸쳐 설명한 방법들을 종합하여 2D 및 3D 채널저류층을 히스토리매칭 하는 기법을 다음과 같이 제안한다. 제안하는 기법의 순서도는 Fig. 2.10으로 나타내었다.

### 1) 트레이닝 이미지 생성

가장 먼저 히스토리매칭 할 저류층에 맞는 트레이닝 이미지를 생성한다. 본 연구에서는 TiGenerator와 Fluvsim을 사용해 트레이닝 이미지를 만들었다. TiGenerator는 2D 채널저류층의 트레이닝 이미지를 만들 때 사용했으며, 사인파곡선만을 그릴 객체로 선택했다. Fluvsim은 3D 채널저류층의 트레이닝 이미지를 만들 때 사용했다. 해당 알고리즘으로 모사할 수 있는 구조 중 독과 침상퇴적체를 제외하고 하도만을 사용해 간단한 3D 채널저류층 트레이닝 이미지를 만들었다.

### 2) 채널저류층 모델 데이터셋 생성

앞서 생성한 트레이닝 이미지와 SNESim 알고리즘을 사용하여 등가확률을 갖는 다수의 채널저류층 모델들을 만든다. SNESim으로 만드는 모델은 정답 자료로 사용할 참조 모델과 그것을 맞추기 위한 기계학습에 사용할 훈련 데이터, 검증 데이터, 시험 데이터 및 히스토리매칭에 사용할 앙상블이며, 이 모든 모델들을 합쳐 하나의 데이터셋을 구성한다. 데이터셋 내의 모델들은 서로 중복되지 않으며 경우에 따라 트레이닝 이미지 및 SNESim의 인자가 서로 다른 모델이 같은 데이터셋에 포함될 수 있다.

### 3) Beta-CVAE 네트워크 학습

앞서 만든 데이터셋 중 기계학습에 사용할 모델들로 beta-

CVAE를 학습한다. 본 연구에서는 0에서 1 사이의 값을 갖도록 정규화된 유체투과율 값을 입력 자료로 사용하였다. 네트워크 구조는 합성곱 계층, 완전 연결 계층, 잠재벡터 계층, 완전 연결 계층, 합성곱 계층으로 이루어지는 좌우 대칭에 가까운 구조다. 학습 도중 손실 함수가 최소가 될 때의 네트워크 모델을 추후 사용하기 위해 선별하여 저장하였다.

#### 4) 초기 앙상블 및 참조 모델 시뮬레이션

앞서 만든 초기 앙상블과 참조 모델에 전위 시뮬레이터를 사용하여 유정에서의 시간 별 오일 생산량과 워터컷을 얻는다. 이 때 참조 모델의 시뮬레이션 결과를 관측값으로 하였다. 전위 시뮬레이터는 Schlumberger 社의 ECLIPSE 100을 사용하였다.

#### 5) 초기 앙상블의 잠재벡터 계산

위에서 학습한 beta-CVAE 모델에 초기 앙상블을 입력하여 잠재벡터 값을 얻는다.

#### 6) ES-MDA를 사용하여 잠재벡터 업데이트

앙상블 기반 방법 중 하나인 ES-MDA를 사용하여 잠재벡터를 업데이트한다. 참조 모델의 시뮬레이션 결과를 관측값으로 가정했기 때문에 ES-MDA의 오차공분산은 참조 모델과 앙상블의 시뮬레이션 결과를 비교하여 계산한다. 업데이트된 잠재벡터는 디코딩하여 다시 원래 유체투과율 분포로 복원한다. 이후 ES-MDA의 반복 횟수만큼 4번과 5번 과정을 반복하여 잠재벡터를 계속 업데이트한다.

#### 7) 최종 히스토리매칭 결과 획득

ES-MDA의 반복 업데이트가 끝난 뒤 최종적으로 계산된 잠재벡터를 디코딩하여 최종 앙상블의 유체투과율 분포를 얻고,

이를 시뮬레이션하여 오일 생산량과 워터컷 예측값을 획득하면 히스토리매칭 과정이 끝난다. 본 연구에서는 이 시뮬레이션 결과를 참조 모델의 생산 그래프와 비교하여 제안 기법을 평가하는 데 사용하였다.

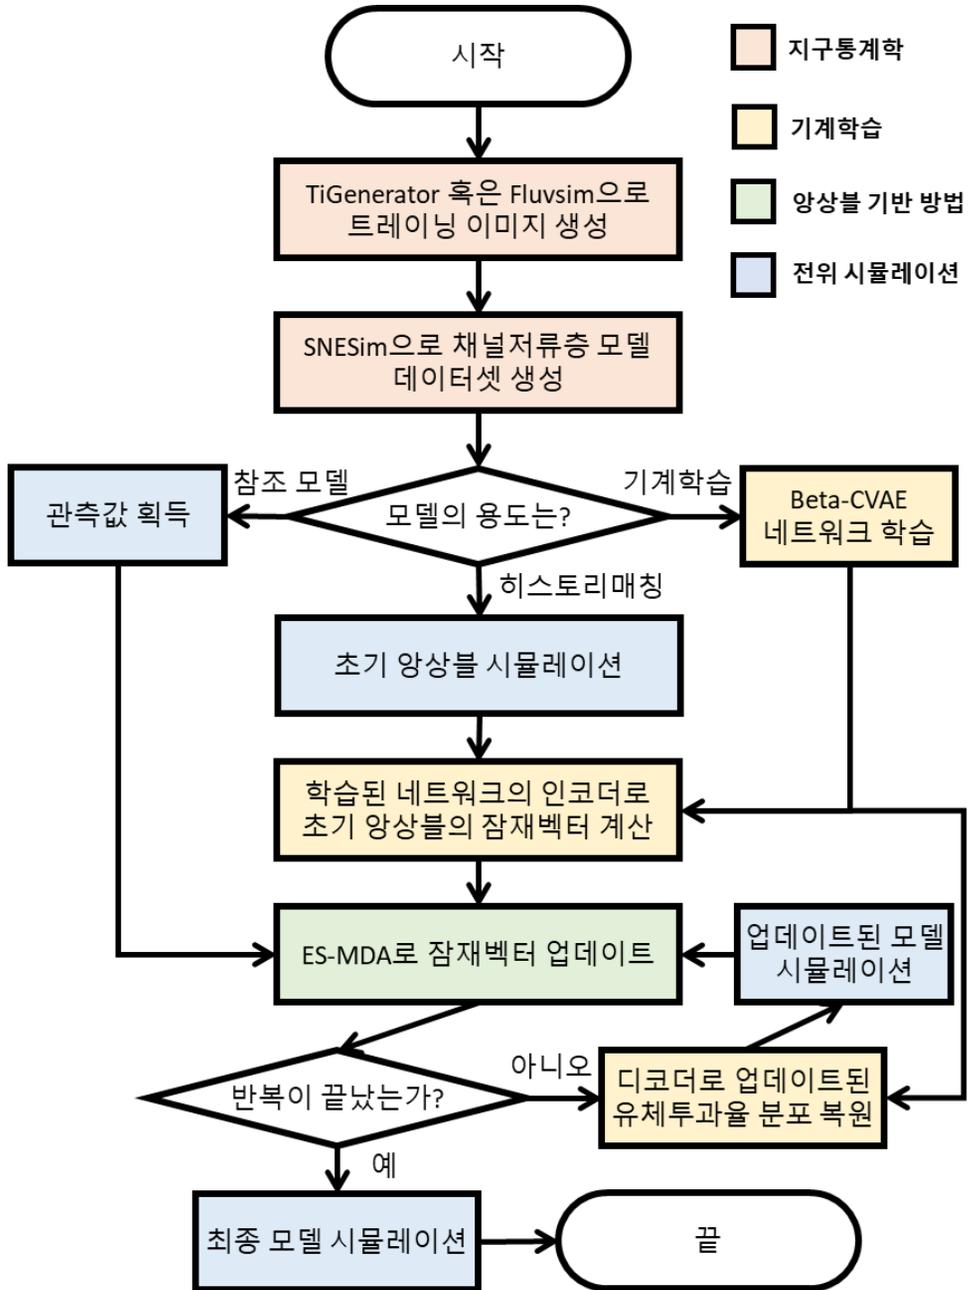


Fig. 2.10. Flow chart of the proposed method.

### 3. 제안하는 기법을 사용한 채널저류층 특성화

3장의 2절부터 5절까지 각각 참조 모델과 앙상블이 유사한 2D 채널저류층, 참조 모델과 앙상블이 다른 2D 채널저류층, 층에 따라 채널의 위치가 다른 3D 채널저류층, 층에 따라 채널의 형태가 다른 3D 채널저류층을 사용한 히스토리매칭 결과를 제시해 제안 기법을 평가하였다. 이후 위 네 가지 케이스를 순서대로 case 1, case 2, case 3, case 4라고 한다.

#### 3.1 2D 채널저류층 모델

3D 채널저류층 모델에 제안하는 기법을 바로 적용하기에 앞서, 그 실효성을 검증하기 위해 2D 채널저류층 모델을 히스토리매칭 하였다. 검증에 사용한 2D 채널저류층 모델은 총 2개 케이스가 있으며 각각 트레이닝 이미지 3개를 사용해 데이터셋을 구축하였다.

Case 1은 3개의 트레이닝 이미지로부터 균등하게 모델을 생성했기 때문에 참조 모델을 만들 때 사용한 트레이닝 이미지로 일부 초기 앙상블 모델 및 기계학습에 사용하는 모델도 만들었다. 따라서 이 케이스의 초기 앙상블은 좋은 히스토리매칭 결과를 기대할 수 있다.

반면, case 2는 1개의 트레이닝 이미지를 오직 참조 모델을 만드는 데에만 사용하고 나머지 2개의 트레이닝 이미지로 기계학습 및 초기 앙상블에 사용할 모델을 만들었다. 따라서 case 1에 비해서 초기 앙상블과 참조 모델의 유사도가 떨어지는, 히스토리매칭에 있어 좋지 않은 케이스다.

##### 3.1.1 모델 생성에 사용한 인자 정리

먼저 두 케이스의 데이터셋을 만드는 데 사용한 알고리즘의 인자들과 시뮬레이션 조건을 Table 3.1, Table 3.2, Table 3.3, Table 3.4,

Fig. 3.1, Table 3.5에 나타냈다. 이들은 각각 순서대로 TiGenerator 알고리즘의 인자, SNESim 시뮬레이션으로 생성한 모델 수, SNESim 시뮬레이션에 사용한 인자, beta-CVAE 훈련에 사용한 인자, beta-CVAE 네트워크 구조, 저류층 및 시뮬레이션 조건을 정리한 표 및 그림이다.

**Table 3.1** TiGenerator parameters on 2D training image generation.

Parameters	Case 1	Case 2
Training image size, $x \times y \times z$	400 × 400 × 1	
Size of grid cell, ft	50	
Number of facies	2	
Target ratio, sandstone:shale	0.25:0.75	
Number of training images	3	
Geobody type	Sinusoid	
Length of sinusoids, pixel	2000 for all TIs	
Amplitude of sinusoids, pixel	Uniform(9, 12) for all TIs	
Wavelength of sinusoids, pixel	Uniform(80, 120) for TI 1 Uniform(135, 165) for TI 2 Uniform(180, 220) for TI 3	Uniform(135, 165) for all TIs
Angle of sinusoids, clockwise from north	Triangular(45, 90, 135) for all TIs	
Width of sinusoids, pixel	10 for all TIs	8 for TI 1 10 for TI 2 12 for TI 3

**Table 3.2** Number of 2D realizations generated by SNESim.

Parameters	Case 1	Case 2
Number of training models	600 Total 200 from TI 1 200 from TI 2 200 from TI 3	600 Total 300 from TI 1 300 from TI 3
Number of validation models	150 Total 50 from TI 1 50 from TI 2 50 from TI 3	150 Total 75 from TI 1 75 from TI 3
Number of test models	200 Total 67 from TI 1 66 from TI 2 67 from TI 3	200 Total 100 from TI 1 100 from TI 3
Number of initial ensemble members	200 Total 67 from TI 1 66 from TI 2 67 from TI 3	200 Total 100 from TI 1 100 from TI 3
Number of reference model	1 from TI 2	1 from TI 2

**Table 3.3** SNESim parameters on 2D training image generation.

Parameters	Case 1	Case 2
Hard data locations, (x, y)	(10, 10), (40, 10), (70, 10), (10, 40), (40, 40), (70, 40), (10, 70), (40, 70), (70, 70), (25, 25), (55, 25), (25, 55), (55, 55)	(10, 10), (30, 10), (50, 10), (70, 10), (10, 30), (30, 30), (50, 30), (70, 30), (10, 50), (30, 50), (50, 50), (70, 50), (10, 70), (30, 70), (50, 70), (70, 70)
Target ratio of channel	0.25	
Number of nodes in search template	60	
Search template geometry ranges, (max, med, min)	(1000, 750, 250)	
Number of multigrids	3	

**Table 3.4** Parameters on 2D beta-CVAE network training.

Parameters	Case 1	Case 2
Type of training data	Normalized permeability	
Batch size	64	
Max epochs	1000	
Learning rate	0.00005	0.0001
Beta	1.5	3

		<b>Dimension</b>	<b># of Channels</b>	<b>Padding</b>	<b>Kernel</b>	<b>Stride</b>
<b>Encoder</b>	<b>Input Layer</b>	80x80	1			
	Convolution 1	80x80	16	1x1	3x3	1x1
	Convolution 2	80x80	32	1x1	3x3	1x1
	Convolution 3	40x40	64	1x1	4x4	2x2
	Convolution 4	20x20	64	1x1	4x4	2x2
	Convolution 5	10x10	64	1x1	4x4	2x2
	Convolution 6	5x5	32	1x1	3x3	1x1
	Fully-Connected	1024				
	Fully-Connected	512				
	Fully-Connected	256				
<b>Decoder</b>	<b>Latent Vector</b>	128				
	Fully-Connected	256				
	Fully-Connected	512				
	Deconvolution 1	5x5	32	1x1	3x3	1x1
	Deconvolution 2	10x10	64	1x1	4x4	2x2
	Deconvolution 3	20x20	64	1x1	4x4	2x2
	Deconvolution 4	40x40	64	1x1	4x4	2x2
	Deconvolution 5	80x80	32	1x1	3x3	1x1
	Deconvolution 6	80x80	16	1x1	3x3	1x1
	<b>Output Layer</b>	80x80	1			

Fig. 3.1. Structure of 2D beta-CVAE network for case 1 and case 2.

**Table 3.5** 2D reservoir simulation conditions.

Parameters	Case 1	Case 2
Grid system, $x \times y \times z$	80 × 80 × 1	
Size of a grid cell in ft, x, y, z	50, 50, 20	
Producer locations, (x, y)	(10, 10), (40, 10), (70, 10), (10, 40), (40, 40), (70, 40), (10, 70), (40, 70), (70, 70)	(10, 50), (70, 50), (10, 10), (70, 10),
Injector locations, (x, y)	(25, 25), (55, 25), (25, 55), (55, 55)	(30, 30)
Depth of the top cells, ft	2700	
Porosity	0.2	
Sandstone permeability, md	500	
Shale permeability, md	5	
Oil density, lb/ft <sup>3</sup>	48.623	
Water density, lb/ft <sup>3</sup>	62.313	
Initial oil formation volume factor, rb/STB	1.01	
Oil viscosity, cp	3	
Water viscosity, cp	1	
Rock compressibility, psi <sup>-1</sup>	3.0 × 10 <sup>-5</sup>	
Water compressibility, psi <sup>-1</sup>	5.0 × 10 <sup>-7</sup>	

Initial BHP of the top cells, psi	2000	
Initial water saturation	0.25	
Production constraint	BHP, 500psi	
Injection constraint	Water rate, 600STB/day	Water rate, 1500STB/day
Assimilation time steps	17 × 30days	20 × 50days
Prediction time steps	34 × 30days	40 × 50days
Observed data	Oil rate (STB/day), watercut	

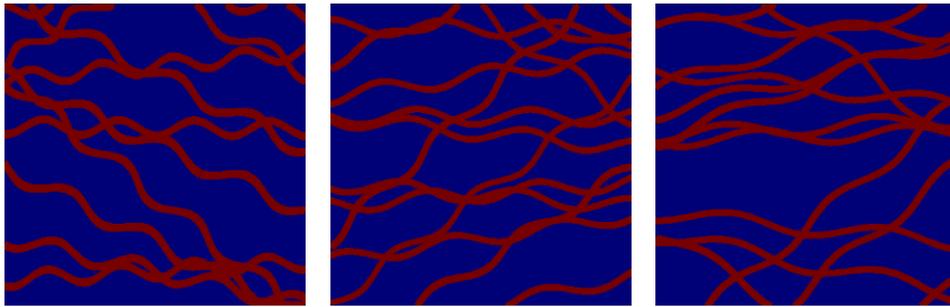
### 3.1.2 Case 1 – 좋은 초기 앙상블

Fig. 3.2a는 case 1에 사용된 세 가지 트레이닝 이미지다. 세 트레이닝 이미지는 공통적으로 동서 방향으로 뻗은 채널 경향성을 보이고 사인파곡선의 진폭과 폭은 유사하지만, 파장에서 큰 차이가 있다.

Fig. 3.2b에는 하드데이터로 제시된 암상 자료다. 총 13개 위치의 암상을 알고 있으며, 10개는 사암, 3개는 셰일이다.

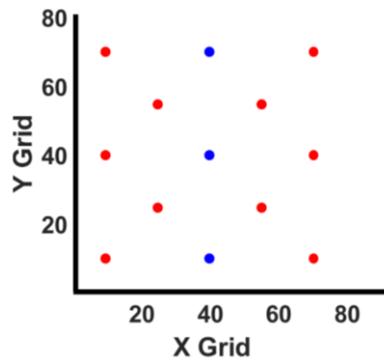
Fig. 3.2c는 2번째 트레이닝 이미지와 하드데이터를 사용해서 만든 참조 모델의 유체투과율 분포와 유정 배치 상황을 나타낸 그림이다. 트레이닝 이미지의 경향성을 따라 동서 방향으로 채널이 형성되어 있으며, 필드 전체를 가로지르는 Y자 모양과 일자 모양의 채널이 특징적이다. 4개의 주입정은 각각 Y자 모양의 채널 위에 2개, 일자 모양의 채널 위에 2개가 위치해 있다. 거기에 더해 9개의 생산정이 각각 Y자 모양의 채널 위에 3개, 일자 모양의 채널 위에 2개, 고립된 사암 위에 1개, 셰일 위에 3개가 위치해 있다.

이러한 채널 형태와 유정 배치로 인해 참조 모델은 채널 위에 존재하는 5개의 생산정에서 오일 및 물 생산이 집중되는 생산 경향을 보인다. 주입정과 연결되지 않은 나머지 4개의 생산정에서는 물이 거의 생산되지 않으며, 오일은 고립된 사암에 설치된 1개 유정에서만 초기에 약간 생산된다. 셰일에 설치된 유정에서는 오일도 거의 생산되지 않는다.

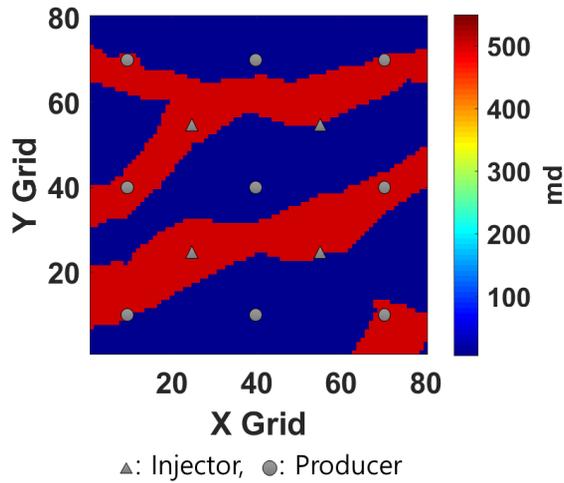


Sandstone
  Shale

(a)



(b)



(c)

**Fig. 3.2.** (a) Training images, (b) hard data, and (c) the reference model of case 1.

Fig. 3.3은 3개의 트레이닝 이미지와 하드데이터를 사용하여 만든 200개 초기 앙상블 중 일부 모델을 선별한 것과 전체 모델의 평균 유체투과율 분포를 그린 것이다. 이 그림에서 확인할 수 있듯이 초기 앙상블의 평균값은 참조 모델의 경향성을 거의 보이지 않으며, 개별 모델도 참조 모델과 다른 것이 다수 포함되어 있다. 특히 채널 연결성이 참조 모델과는 다른 경향을 보이는 모델들은 비록 증가확률을 갖는다고 하더라도 참조 모델과는 생산 경향이 크게 차이난다.

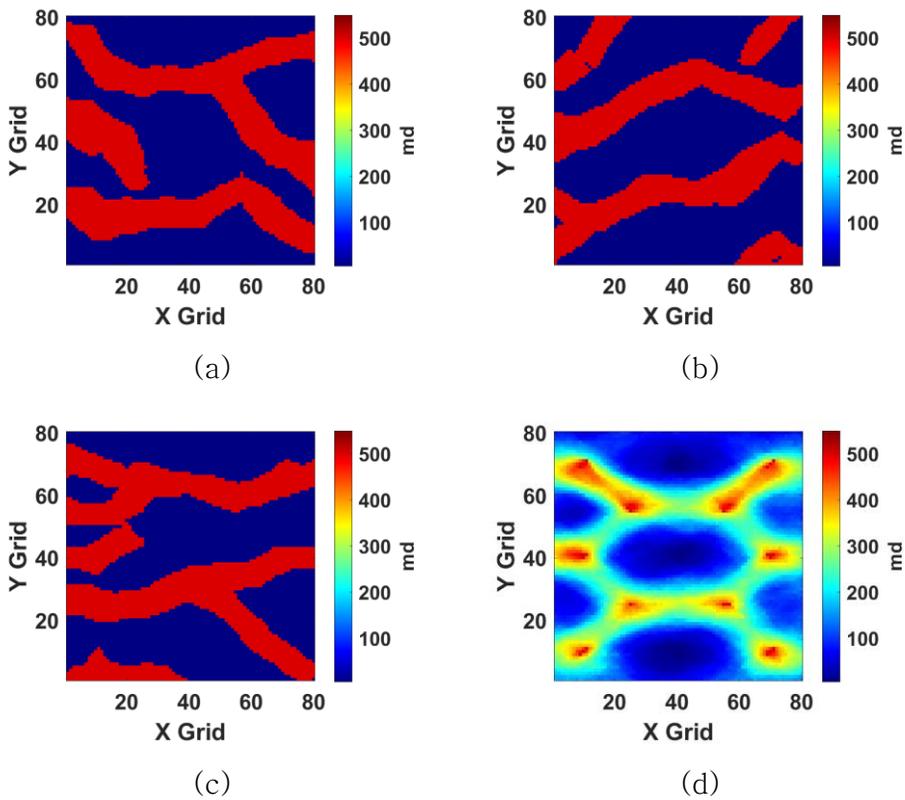
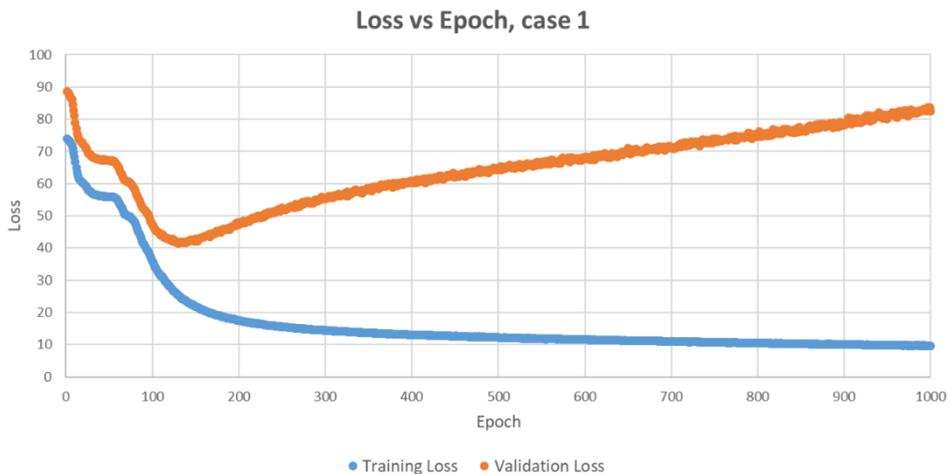


Fig. 3.3. Initial permeability distribution of case 1: (a) – (c) selected models, (d) mean permeability.

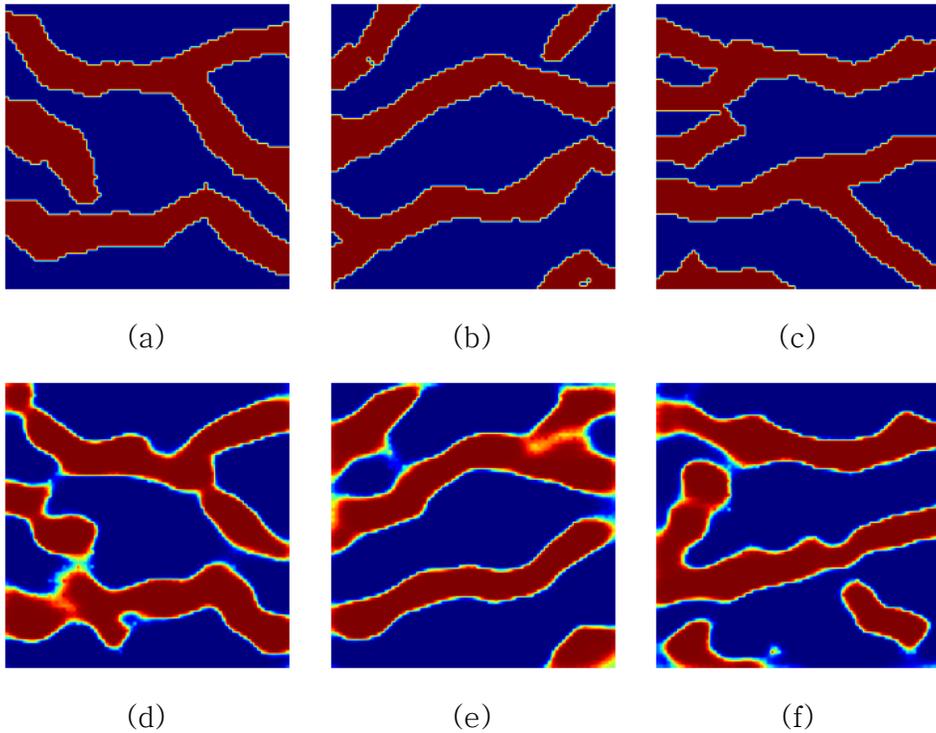
기계학습을 위한 모델을 생성할 때는 초기 모델을 만들 때와 비슷하게 모든 트레이닝 이미지와 하드데이터를 사용하였다. Beta-CVAE 네트워크 학습에 훈련, 검증, 시험 데이터를 합쳐 총 950개의 저류층 모델을 사용했으며 유체투과율 값을 정규화시킨 뒤 입력값과 출력값에 동일한 자료를 넣고 beta-CVAE를 학습하였다.

Fig. 3.4는 훈련 진행에 따른 학습 모델과 검증 모델의 손실 함수 값의 변화를 그린 그래프다. 훈련 초기에는 두 손실 함수 모두 점점 감소하는 경향을 보이지만 일정 시점 이후에는 검증 모델의 손실 함수 값은 다시 증가하는 경향으로 바뀌는데, 이는 학습 모델에 과적합이 일어나고 있기 때문이다. 과적합이 발생하면 새로운 데이터에 대한 정확성이 떨어지기 때문에 epoch이 1000일 때의 모델 대신 검증 모델의 손실 함수 값이 가장 낮은 130번째 epoch의 모델을 이후 사용할 beta-CVAE 모델로 선정하였다.



**Fig. 3.4.** Training loss and validation loss vs epoch in case 1.

Fig. 3.5는 선정한 beta-CVAE 모델을 사용해서 Fig. 3.3a-c에 있는 초기 저류층 모델들을 인코딩 후 디코딩하여 복원한 결과다. 인코딩 시의 데이터 손실로 인해 디코딩 후 채널 경계가 흐릿해지는 등 완벽하게 데이터가 복원되지는 않지만 채널저류층의 생산 거동에 크게 관여하는 채널의 연결성과 방향성 같은 특징들이 잘 보존되는 것을 확인할 수 있다.



**Fig. 3.5.** Model reconstruction using beta-CVAE in case 1: (a)–(c) original models, (d)–(f) corresponding reconstructions.

제안하는 기법을 사용한 히스토리매칭 결과를 평가하는 기준은 크게 세 가지로, 유체투과율 분포와 생산 경향을 얼마나 잘 예측했는지에 대한 평가와 생산 경향 예측치에 대한 MAE(mean absolute error) 값으로 구성된다. Case 1에서는 ES-MDA만을 사용해 유체투과율을 직접 히스토리매칭한 결과를 비교군으로 두고 서로 비교하였다.

ES-MDA만을 사용한 경우 오버슈팅 문제가 심하게 나타났기 때문에 최종 업데이트된 유체투과율에 로그를 취한 값이 사암과 셰일의 로그 유체투과율 평균값보다 높은 경우 사암의 유체투과율을 할당하고 낮은 경우 셰일의 유체투과율을 할당하는 thresholding을 적용하였다. 제안하는 기법을 사용했을 때는 오버슈팅 문제가 없었으나 동등한 비교를 위해 마찬가지로 thresholding을 적용하였다.

먼저 유체투과율 분포 예측이 얼마나 잘 되었는지를 판단하기 위해서는 채널의 형태와 연결성이 참조 모델과 비슷한 지를 확인하는 것이 가장 중요하다.

이런 관점에서 Fig. 3.7의 히스토리매칭 후 평균 유체투과율 분포와 Fig. 3.6의 참조 모델을 비교해 보면, 히스토리매칭 결과가 참조 모델과 비슷한 경향성을 잘 찾아낸 것을 확인할 수 있다. 초기 앙상블에는 존재했지만 참조 모델에는 존재하지 않았던 연결이 모두 사라졌으며, 참조 모델에서 가장 특징적인 Y자 모양과 일자 모양의 채널이 드러나도록 앙상블이 업데이트되었다. 또한 유체투과율 값도 참조 모델과 비슷한 값을 가지며 각 유정 간 연결성도 잘 찾았다.

이는 Fig. 3.8, Fig. 3.9, Fig. 3.10에서 평균 유체투과율이 아닌 일부 모델의 히스토리매칭 결과를 보더라도 마찬가지다.

반면, 제안하는 기법이 아닌 ES-MDA만을 사용해 초기 앙상블을 히스토리매칭한 경우 업데이트 후 채널저류층의 형태가 무너졌다. Fig. 3.12, Fig. 3.13, Fig. 3.14처럼 채널이 매끄럽게 연결되어있지 않고 끊어져 있어 참조 모델과는 다른 경향성을 갖는 모델로 히스토리매칭되었고, 그에 따라 Fig. 3.11의 평균 유체투과율 분포에서도 가운데 채널의 연결성을 약하게 예측한다.

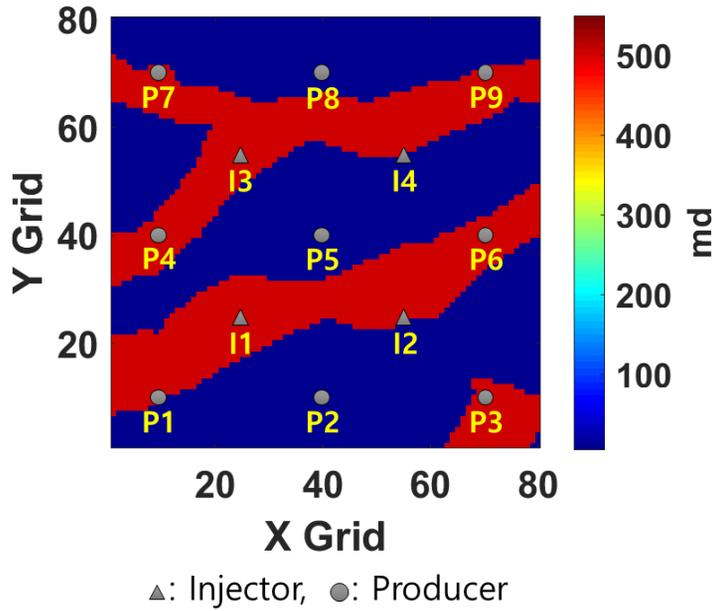


Fig. 3.6. Permeability distribution and well placement of the reference model of case 1.

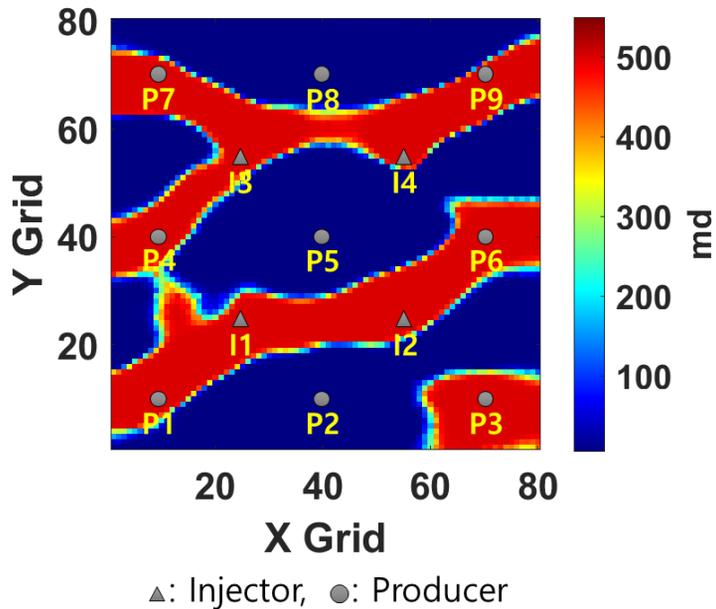


Fig. 3.7. Mean permeability distribution of case 1, updated by the proposed method.

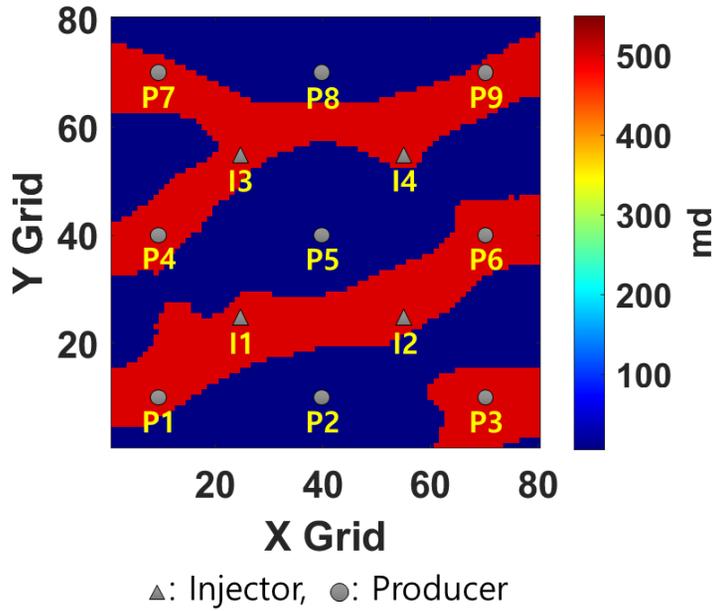


Fig. 3.8. Permeability distribution of the model in Fig. 3.3a, updated by the proposed method.

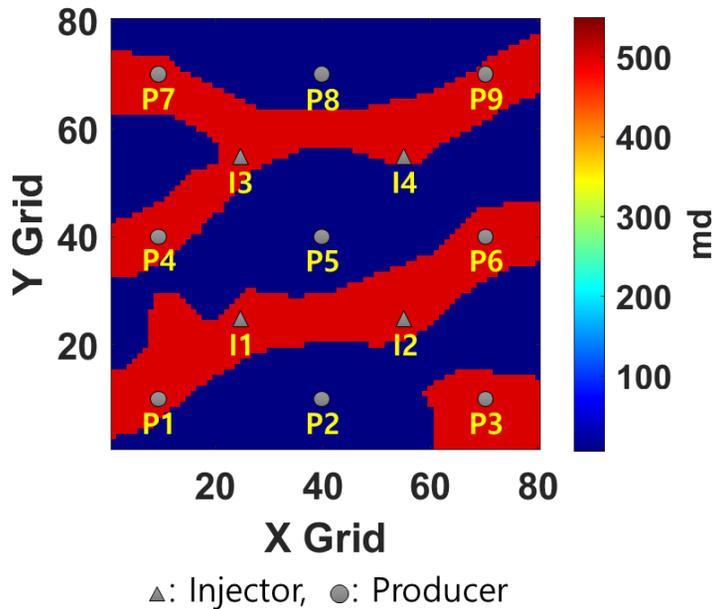


Fig. 3.9. Permeability distribution of the model in Fig. 3.3b, updated by the proposed method.

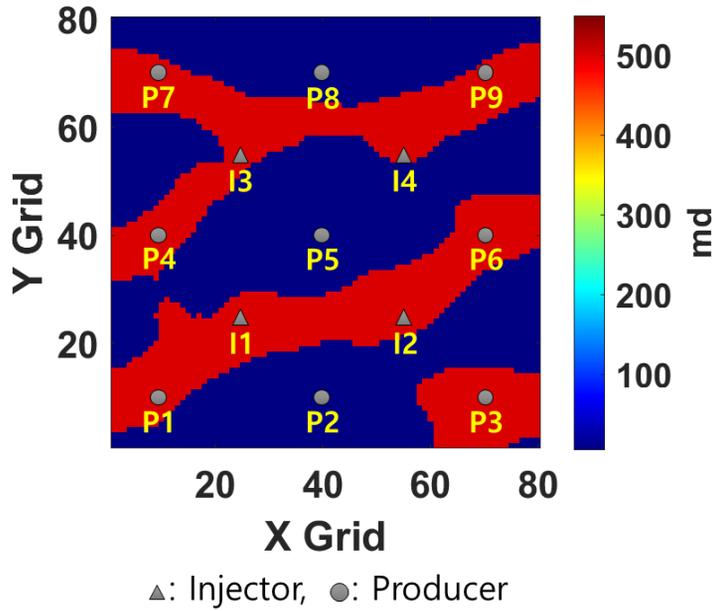


Fig. 3.10. Permeability distribution of the model in Fig. 3.3c, updated by the proposed method.

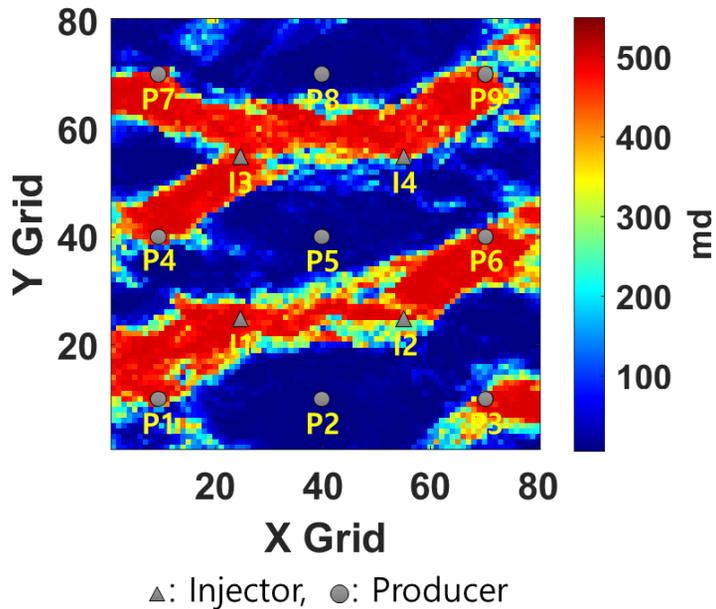


Fig. 3.11. Mean permeability distribution of case 1, updated only by ES-MDA.

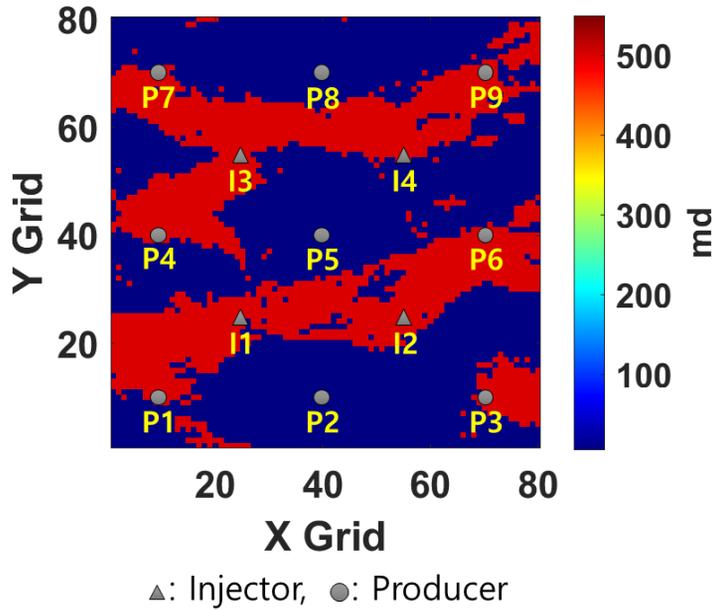


Fig. 3.12. Permeability distribution of the model in Fig. 3.3a, updated only by ES-MDA.

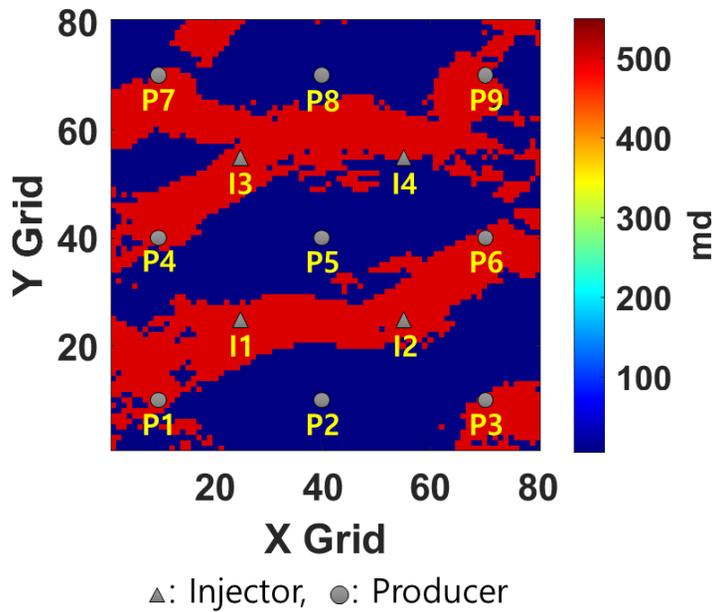


Fig. 3.13. Permeability distribution of the model in Fig. 3.3b, updated only by ES-MDA.

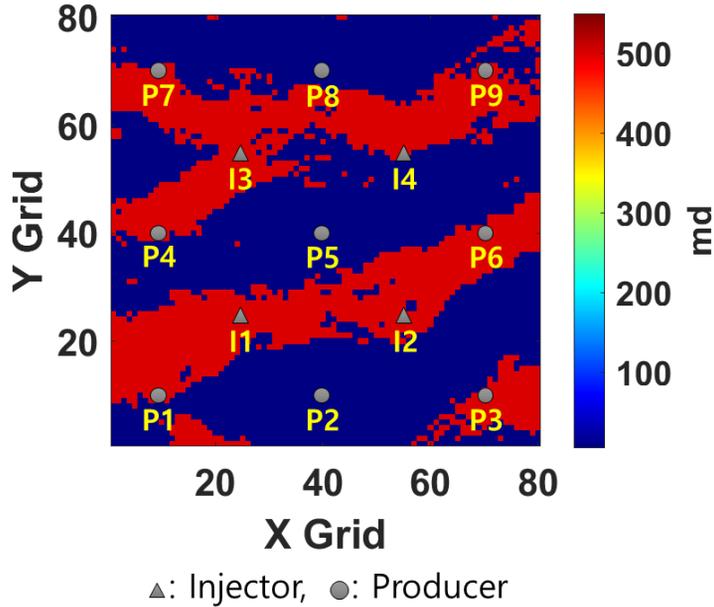


Fig. 3.14. Permeability distribution of the model in Fig. 3.3c, updated only by ES-MDA.

두 번째로, 생산 경향을 잘 예측했는지를 판단하기 위해 히스토리매칭이 끝난 앙상블 모델들을 시뮬레이션하고, 1000일까지의 오일 생산량과 워터컷 생산 경향을 예측한 그래프를 참조 모델과 비교하여 하나의 그래프에 도시하였다.

그래프의 빨간색 실선과 파란색 실선은 각각 참조 모델과 앙상블 멤버들의 평균 생산 거동을 의미한다. 이 두 선이 비슷한 경향을 보이면 예측 결과가 좋은 것이며, 그와 동시에 회색 실선으로 그려진 각 앙상블 멤버들의 생산 거동은 약간의 불확실성 범위를 가져 추계학적인 결과를 내는 것이 이상적이다.

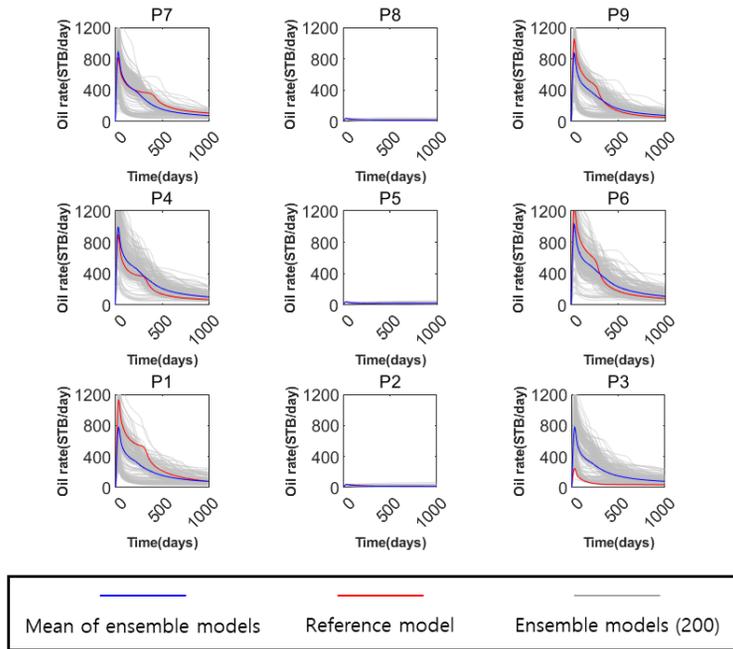
앞서 언급했던 것처럼 초기 앙상블은 참조 모델과 차이가 있기 때문에 Fig. 3.15에서와 같이 초기 앙상블의 생산 거동 또한 참조 모델의 생산 거동과 서로 다른 경향성을 보이며 앙상블 간의 불확실성 또한 매우 크게 나타난다.

Fig. 3.16은 업데이트 후의 모델을 사용해 오일 생산량과 워터컷을

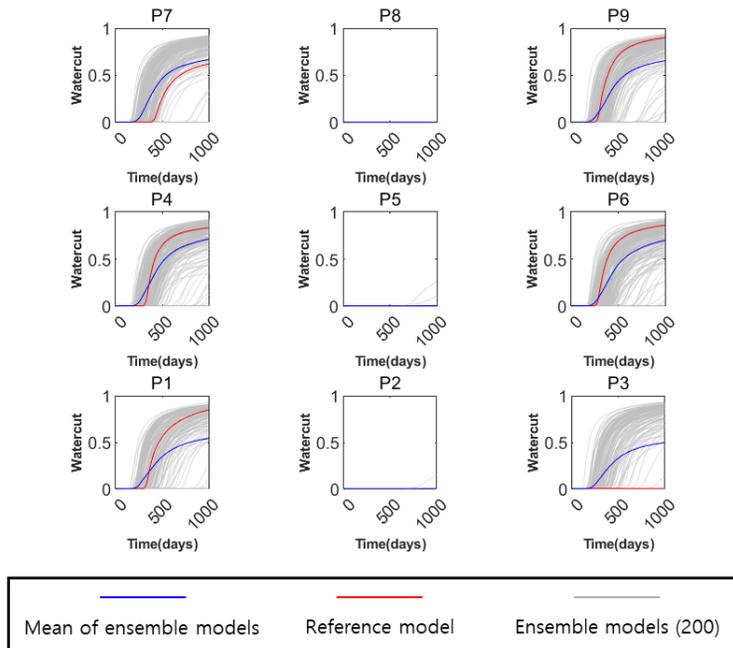
예측한 결과로, 신뢰할 수 있는 히스토리매칭 결과를 얻었다. 앙상블의 평균 오일 생산량과 워터컷 경향이 참조 모델과 유사하게 나타나고 앙상블 간의 불확실성도 적절한 수준으로 줄어들었다. 가장 주목할 만한 개선 결과를 보이는 유정 P3을 보면, 초기 앙상블은 오일 생산량과 워터컷을 모두 참조 모델에 비해 매우 크게 예측하는 반면 업데이트된 앙상블은 참조 모델과 유사한 경향을 갖는 것으로 예측한다.

그에 비해, ES-MDA만을 사용했을 때는 참조 모델의 생산 거동과는 다르게 예측하는 경우가 있다. 특히 Fig. 3.17b 중 유정 P1, P4, P7의 워터컷 그래프에서 이런 경향이 제일 두드러지는데, 참조 모델과 매우 다른 생산 경향을 보이는 모델을 포함하고 있으며 불확실성 범위 또한 넓게 나타난다.

마지막으로, 두 방법으로 예측한 생산 경향의 MAE를 계산하여 Table 3.6에 정리하였다. 제안하는 기법을 사용했을 때 초기 앙상블에 비해 오일 생산량과 워터컷 모두 MAE가 크게 감소한 것을 확인할 수 있다.

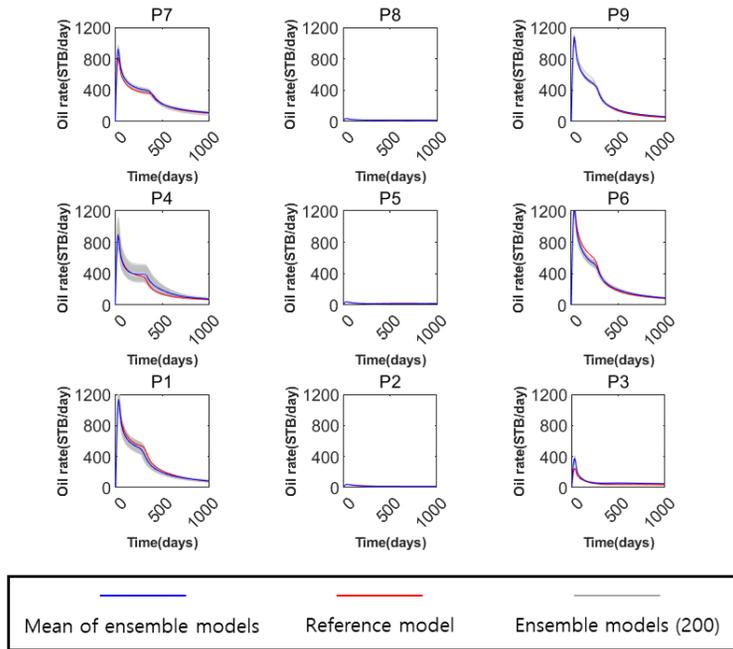


(a)

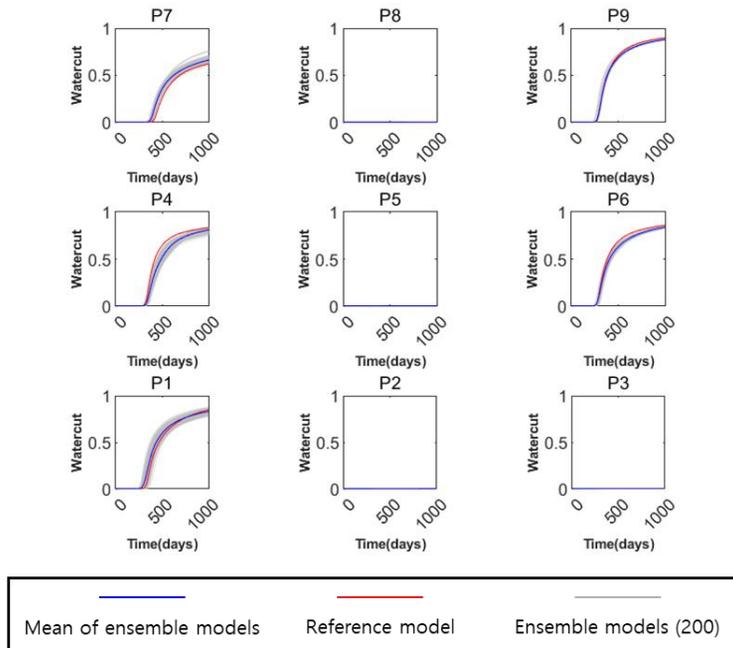


(b)

**Fig. 3.15.** Performance prediction of the initial ensemble models in case 1: (a) oil production, (b) watercut.

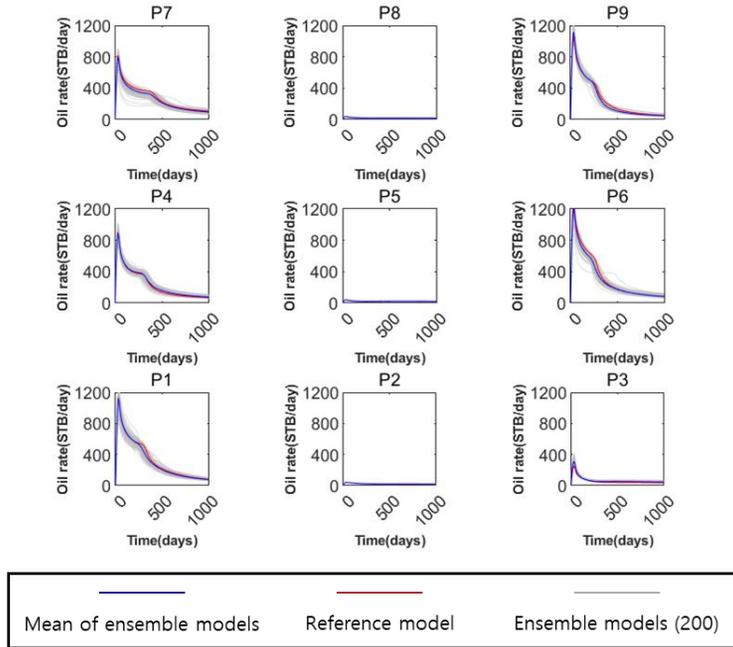


(a)

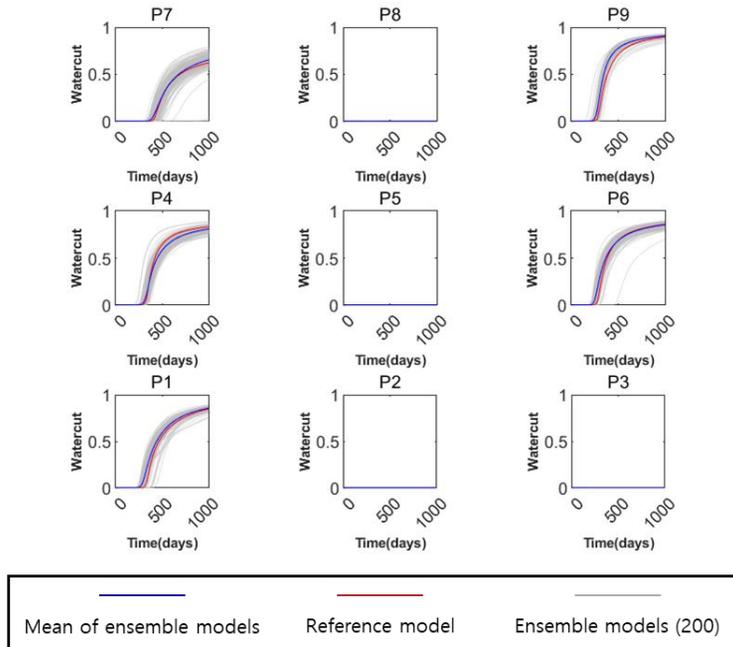


(b)

**Fig. 3.16.** Performance prediction of the updated models using the proposed method in case 1: (a) oil production, (b) watercut.



(a)



(b)

Fig. 3.17. Performance prediction of the updated models using only ES-MDA in case 1: (a) oil production, (b) watercut.

**Table 3.6** MAE of oil rate and watercut prediction, case 1.

Reservoir models	MAE of oil rate	MAE of watercut
Initial models	73.904	$13.551 \times 10^{-2}$
Updated models using the suggested method	16.793	$1.841 \times 10^{-2}$
Updated models using only ES-MDA	15.018	$2.051 \times 10^{-2}$

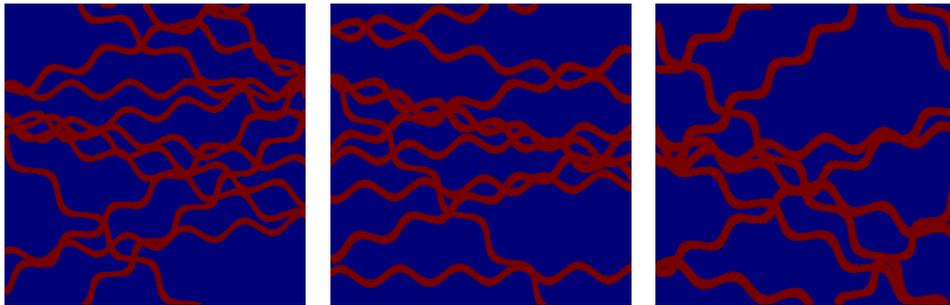
### 3.1.3 Case 2 – 좋지 않은 초기 앙상블

이 케이스는 case 1과 비슷하게 2D 채널저류층 모델을 사용했으나 초기 앙상블을 구성하는 데 사용한 자료가 불확실한 상황을 가정하였다. Fig. 3.18a, Fig. 3.18b는 각각 case 2에 사용된 세 가지 트레이닝 이미지 및 하드데이터다. 세 트레이닝 이미지는 공통적으로 동서 방향으로 채널이 뻗어 있는 경향성을 보이고 사인파곡선의 진폭이나 파장과 같은 특성은 모두 유사하지만, 곡선의 폭에서 차이가 있다. 하드데이터로 제시된 16개 위치에서의 암상 자료는 8개가 사암, 8개가 셰일이다.

초기 앙상블을 구성할 때 사용한 자료가 불확실하다는 가정에 따라 참조 모델을 만들 때 사용한 트레이닝 이미지는 초기 앙상블과 beta-CVAE 학습을 위한 모델 중 어느 쪽에도 사용되지 않았다.

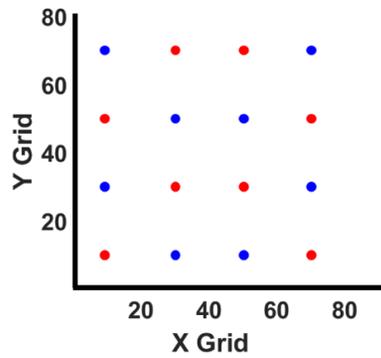
Fig. 3.18c는 SNESim을 사용해서 만든 참조 모델의 유체투과율 분포와 유정 배치 상황을 나타낸 그림이다. 트레이닝 이미지와 유사하게 동서 방향으로 채널이 뻗어있으며, 서쪽 끝에서 채널이 두 갈래로 갈라진 후 정중앙 근처에서 다시 위와 아래로 채널이 갈라지는 형태다. 네 개의 생산정과 한 개의 주입정은 모두 사암 위에 있으나 세 개의 생산정만 주입정과 채널로 연결되어 있고 나머지 한 개의 생산정은 고립된 채널 위에 있다.

따라서 참조 모델의 생산 경향은 주입정과 연결된 세 개의 생산정에서 오일 및 물 생산량이 높게 나타난다. 해당 생산정들도 주입정과 거리 따라 물 생산이 시작되는 시점에 차이가 있으며, P1, P2, P4 순으로 물 생산이 시작되는 것을 확인할 수 있다. 고립된 채널 위에 있는 생산정에서는 물이 거의 생산되지 않으며 오일 생산량 또한 전체 기간 동안 매우 낮은 수준을 유지한다.

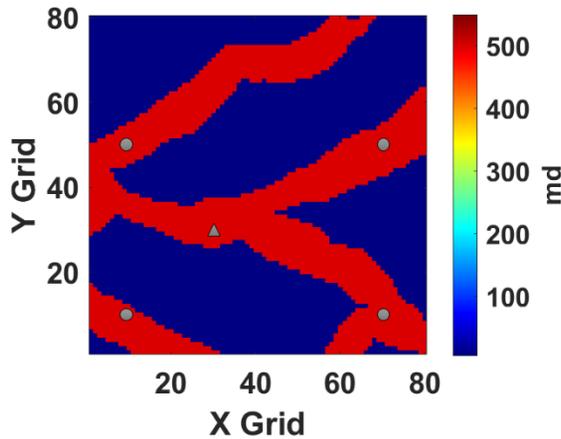


Sandstone
  Shale

(a)



(b)



▲: Injector, ●: Producer

(c)

Fig. 3.18. (a) Training images, (b) hard data, and (c) the reference model of case 2.

Fig. 3.19는 하드데이터와 참조 모델을 만들 때 사용하지 않은 트레이닝 이미지를 사용하여 만든 200개의 초기 앙상블 모델들의 평균 유체투과율 분포와 그 모델들 중 3개 모델을 선별하여 유체투과율 분포를 그린 것이다.

초기 앙상블의 평균 유체투과율 분포는 case 1에서의 초기 앙상블과 유사하게 참조 모델과는 다른 경향을 보이며 특히 고립된 채널에 있는 생산정과도 연결되어 있는 모델도 적지 않다. 이 때문에 해당 생산정의 오일 및 물 생산량이 참조 모델과 큰 차이를 보이는 초기 모델들이 다수 존재한다. 다른 생산정들 또한 채널 연결성이 참조 모델과 다른 경우 생산 경향이 다르게 나타난다.

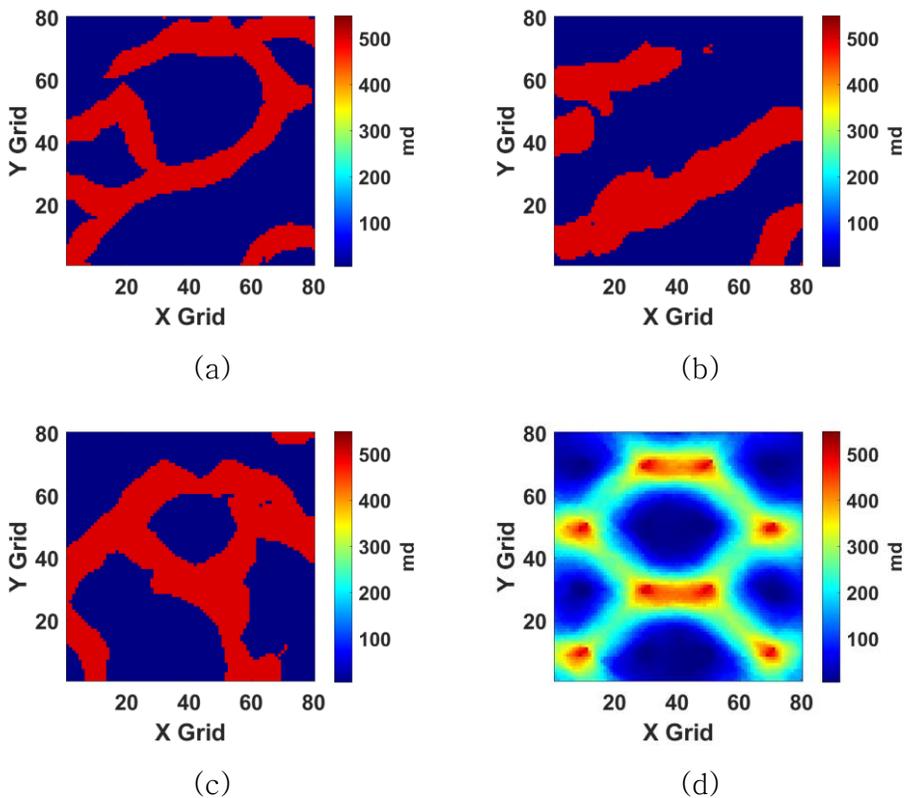


Fig. 3.19. Initial permeability distribution of case 2: (a) – (c) selected models, (d) mean permeability.

기계학습에 사용한 저류층 모델은 초기 모델을 만들 때 사용한 것과 동일한 2개의 트레이닝 이미지와 하드데이터로 생성한 중복되지 않는 950개 모델이다. 이 모델들을 훈련, 검증, 시험 데이터로 나누어 beta-CVAE 네트워크를 학습했으며 훈련에 사용된 값은 정규화된 유체투과율이다. Beta-CVAE의 가정에 맞게 입력값과 출력값에 동일한 자료를 넣고 학습하였다.

훈련이 진행되면서 학습 데이터와 검증 데이터의 손실 함수 값이 변화하는 경향을 Fig. 3.20에 그렸다. Case 1과 유사하게 훈련 초기에는 기계학습 모델이 입력 자료에 맞게 가중치를 학습하면서 두 손실 함수가 모두 감소하지만, 모델이 학습 데이터에 과적합하기 시작하면서 검증 데이터의 손실 함수 값이 증가하는 경향을 보인다.

실제 히스토리매칭 과정에서는 학습 데이터를 전혀 사용하지 않기 때문에 과적합이 발생한 모델이 아닌, 검증 데이터의 손실 함수 값이 가장 낮은 82번째 epoch의 모델을 사용한다.

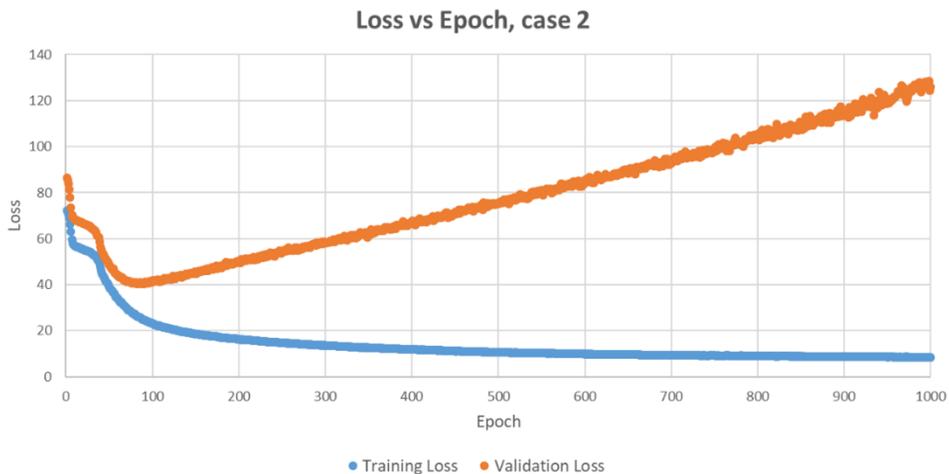
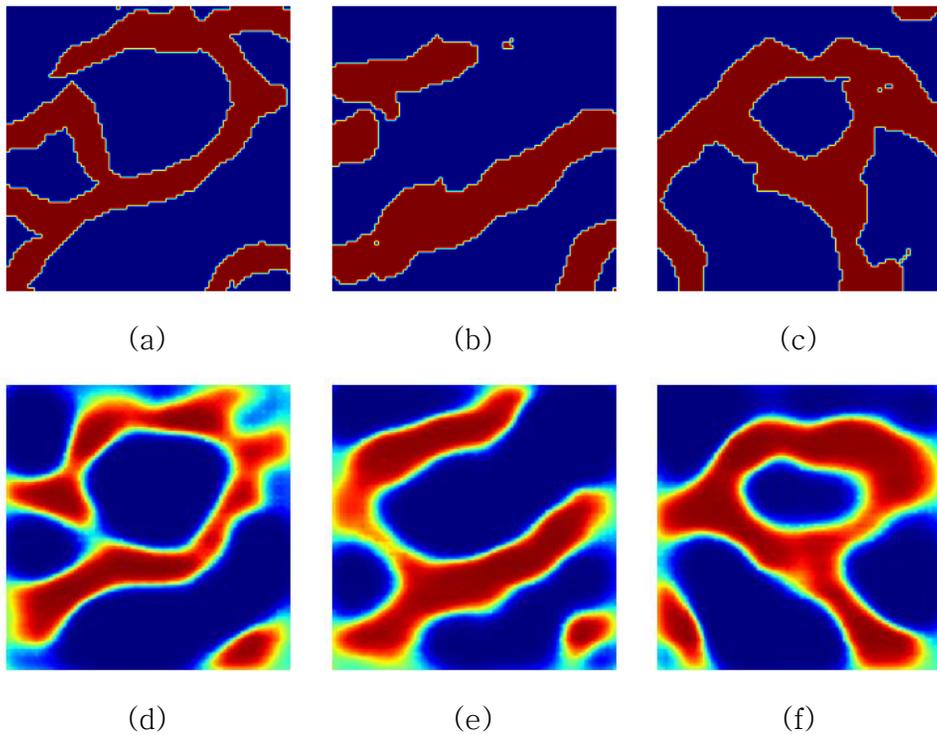


Fig. 3.20. Training loss and validation loss vs epoch in case 2.

해당 beta-CVAE 모델을 사용해서 Fig. 3.19a-c에 있는 초기 저류층 모델들을 인코딩한 후 디코딩하면 Fig. 3.21d-f와 같은 결과를 얻을 수 있다. 입력 데이터의 차원을 축소한 후 다시 원래 차원으로 복원하기 때문에 원본 그대로 데이터를 얻는 것은 불가능하지만, 채널저류층의 생산 경향성에 주요한 영향을 끼치는 채널의 연결성과 방향성 같은 중요한 특성들을 잘 복원하였다.



**Fig. 3.21.** Model reconstruction using beta-CVAE in case 2: (a) – (c) original models, (d) – (f) corresponding reconstructions.

제안하는 기법을 사용한 히스토리매칭한 결과는 case 1과 동일하게 최종 업데이트된 모델의 평균 유체투과율 분포와 오일 생산량 및 워터컷 예측값을 참조 모델과 비교하고 MAE를 계산함으로써 평가했으며, ES-MDA만을 사용한 히스토리매칭 결과를 비교군으로 사용해 제안하는 기법과 비교하였다. Case 1과 마찬가지로 두 기법을 사용한 결과 모두 thresholding을 적용하였다.

먼저 Fig. 3.22와 Fig. 3.23을 통해 참조 모델과 업데이트된 앙상블의 평균 유체투과율 분포를 비교했을 때, 제안하는 기법이 참조 모델의 채널 특성을 잘 찾아내도록 히스토리매칭한 것을 볼 수 있다.

초기 앙상블에서 가장 큰 불확실성 요소로 작용했던 P3과 주입정간의 연결이 모두 사라졌으며 북동쪽에 오른쪽 아래 방향으로 채널이 연결되어 있는 것 또한 사라졌다. 이렇게 잘못된 연결을 모두 제거하여 최종 모델은 참조 모델과 유사하게 서쪽에서 한번 갈라진 후 정중앙 근처에서 다시 한번 더 갈라지는 채널 형태를 하고 있다. 평균 유체투과율뿐만 아니라 Fig. 3.24-26의 개별 모델을 업데이트한 결과에서도 같은 결과를 확인할 수 있다.

또한 주입정과 모든 생산정들 간의 연결성도 알맞게 업데이트했으며 유체투과율 값도 오버슈팅과 같은 문제를 보이지 않고 정상적인 범위 내를 유지하였다.

반면에 ES-MDA만을 사용해 히스토리매칭한 경우에는 참조 모델의 채널 특성을 잘 잡아내지 못하였다. Fig. 3.27에서 볼 수 있듯이, 서쪽에서 남동쪽으로 향하는 채널이 군데군데 끊어져 있어 연결성이 떨어지는 것으로 판단했으며, 북쪽으로 향하는 채널은 완전히 따로 떨어져 있어 채널이 아닌 것으로 업데이트하였다. Fig. 3.28-30의 개별 모델 업데이트 결과를 보면 채널이 떨어져 있는 업데이트 결과가 더욱 두드러지게 나타난다.

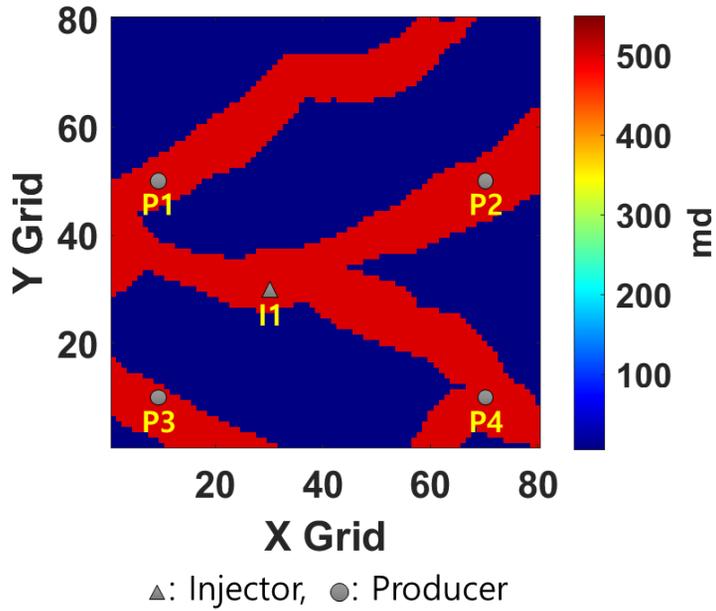


Fig. 3.22. Permeability distribution and well placement of the reference model of case 2.

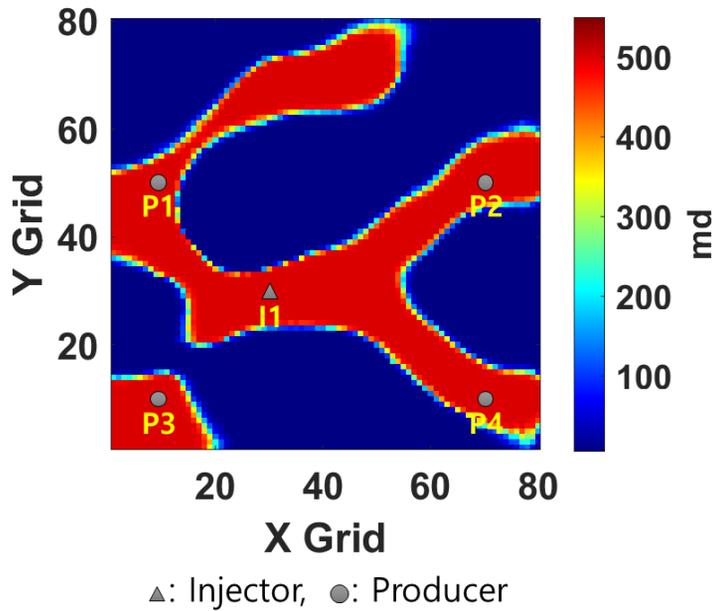


Fig. 3.23. Mean permeability distribution of case 2, updated by the proposed method.

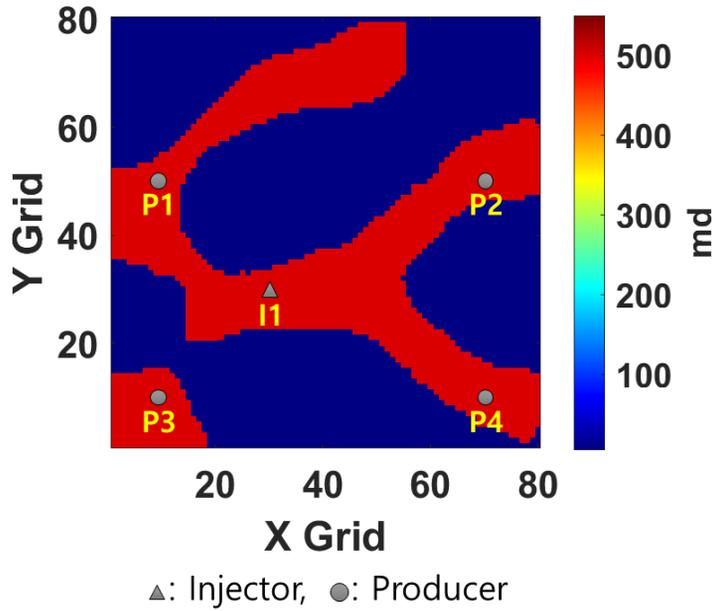


Fig. 3.24. Permeability distribution of the model in Fig. 3.19a, updated by the proposed method.

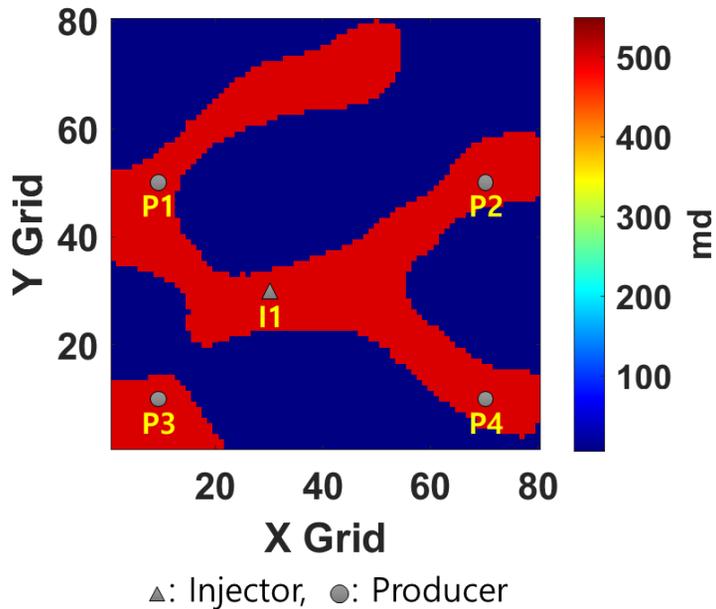


Fig. 3.25. Permeability distribution of the model in Fig. 3.19b, updated by the proposed method.

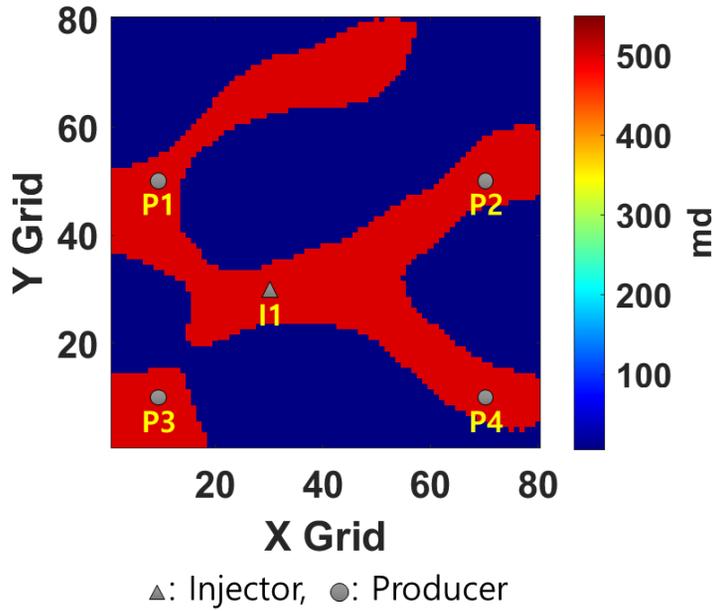


Fig. 3.26. Permeability distribution of the model in Fig. 3.19c, updated by the proposed method.

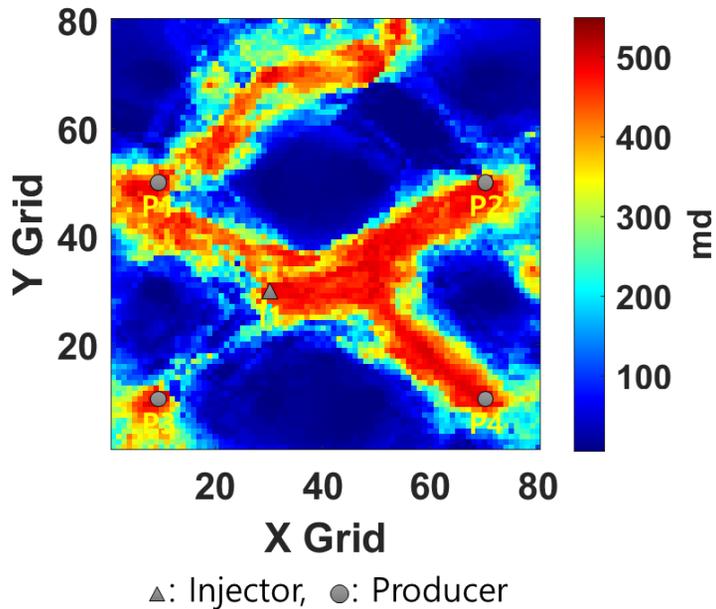


Fig. 3.27. Mean permeability distribution of case 2, updated only by ES-MDA.

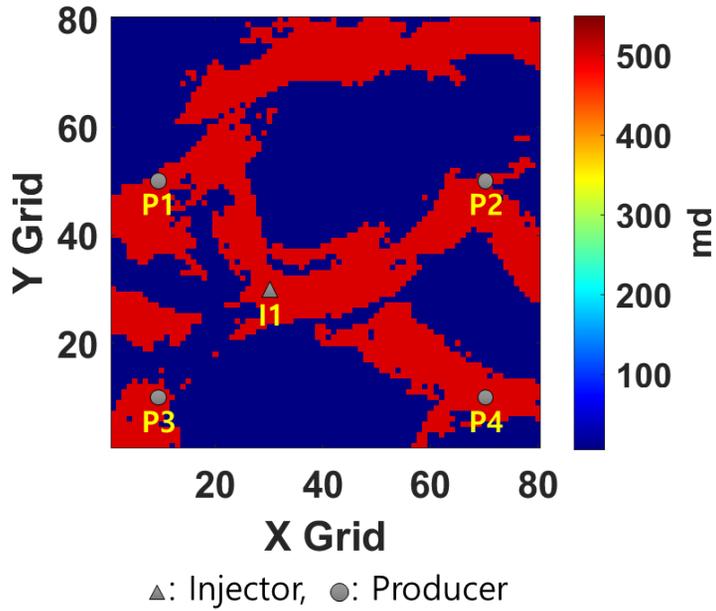


Fig. 3.28. Permeability distribution of the model in Fig. 3.19a, updated only by ES-MDA.

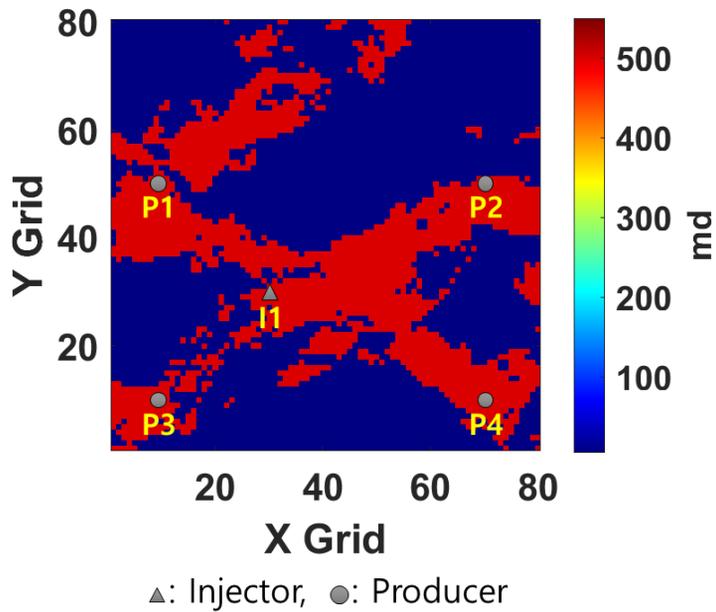


Fig. 3.29. Permeability distribution of the model in Fig. 3.19b, updated only by ES-MDA.

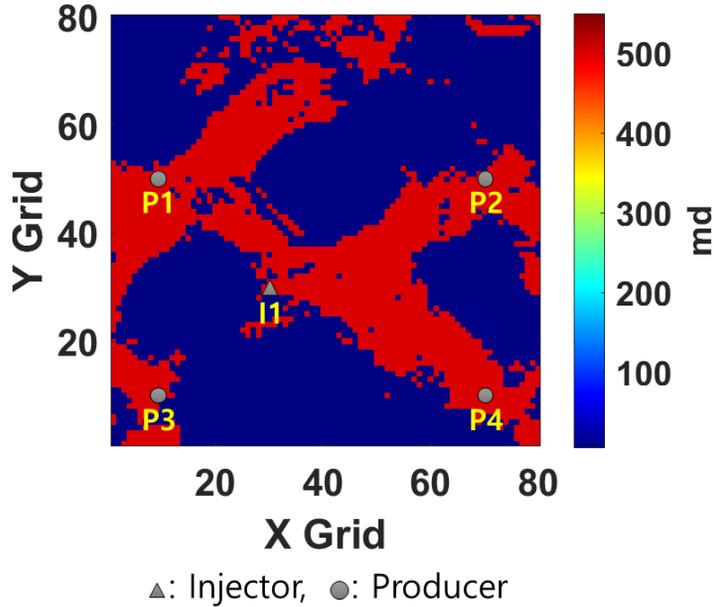


Fig. 3.30. Permeability distribution of the model in Fig. 3.19c, updated only by ES-MDA.

초기 앙상블은 참조 모델과는 차이가 있기 때문에 Fig. 3.31에서 볼 수 있듯이 생산 경향 또한 잘 예측하지 못하며, 초기 앙상블 사이에서도 불확실성이 크다. 특히 생산정 P3의 불확실성이 가장 큰데, 평균 오일 생산량을 참조 모델에 비해 최대 400STB/day 정도 높게 예측하며 물이 전혀 생산되지 않는 참조 모델과는 달리 워터컷도 높게 나타난다. 이와 같은 초기 앙상블의 결점을 해결하는 것이 case 2의 히스토리매칭에 있어 가장 중요하다.

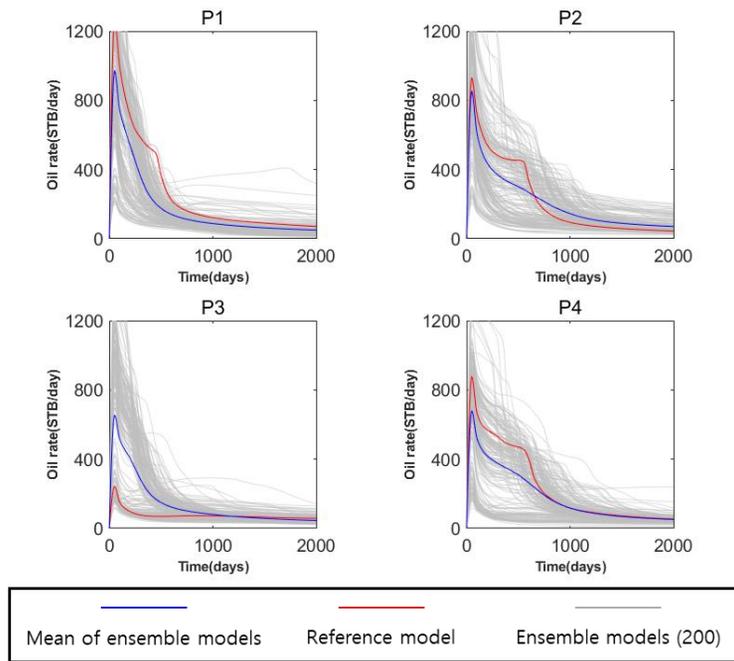
히스토리매칭이 끝난 앙상블 모델들의 오일 생산량과 워터컷을 2000일까지 예측하여 참조 모델과 비교한 그래프를 Fig. 3.32에 제시하였다. 제안하는 기법을 사용하여 히스토리매칭한 앙상블 모델들은 초기 앙상블에 비해 불확실성이 적절히 감소하였으며 참조 모델과 유사한 오일 생산량과 워터컷 경향이 나타난다. 초기 앙상블에서 가장 불확실성이 컸던 생산정 P3도 오일 생산량과 워터컷이 훨씬 낮아졌다.

반면, ES-MDA만을 사용한 히스토리매칭은 제안하는 기법을

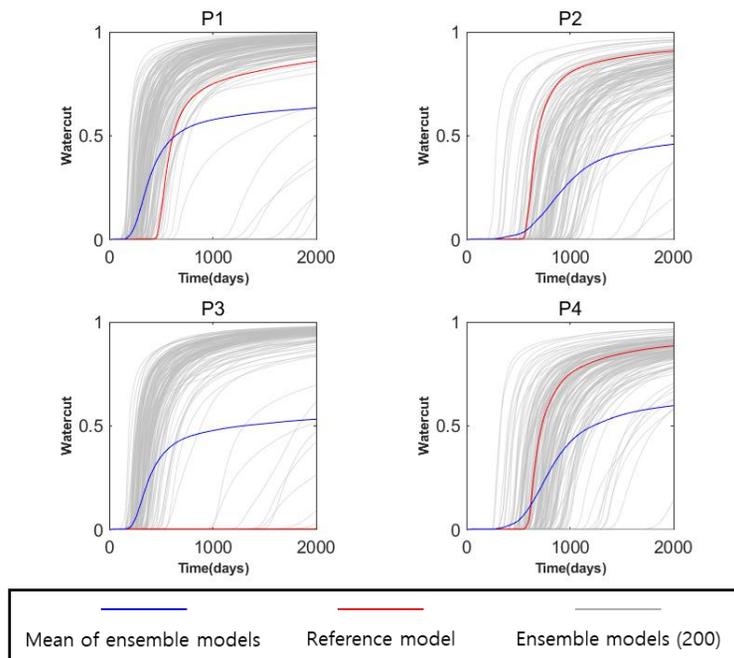
사용한 것과 같은 결과를 얻지 못하였으며, Fig. 3.33처럼 업데이트한 모델의 평균 예측값이 참조 모델의 생산 경향을 잘 따라가지 못하는 경우가 많았다.

특히 채널 연결성을 잘 예측하지 못하였던 생산정 P1의 오일 생산량과 워터컷을 참조 모델보다 훨씬 낮게 예측했으며, 생산정 P3에서도 일부 모델이 1000일 이후 물을 생산하는 등 참조 모델과 다른 생산 경향을 보였다. 앙상블 간의 불확실성 또한 매우 높게 나타나 초기 앙상블과 거의 비슷한 불확실성을 보였고, P1은 오히려 불확실성의 범위가 더 넓어졌다.

초기 앙상블과 각각의 기법으로 업데이트한 앙상블이 예측한 오일 생산량과 워터컷의 MAE를 계산하여 Table 3.7에 정리하였다. 제안하는 기법은 초기 앙상블에 비해서 오일 생산량과 워터컷 모두 MAE가 감소하였고, ES-MDA만을 사용한 예측값으로 계산한 MAE와 비교했을 때 그 감소량이 더욱 크게 나타났다.

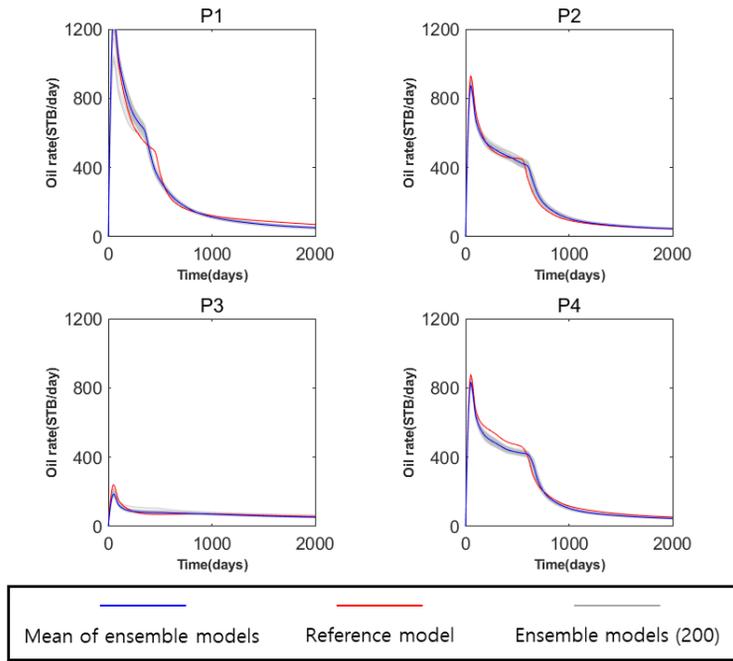


(a)

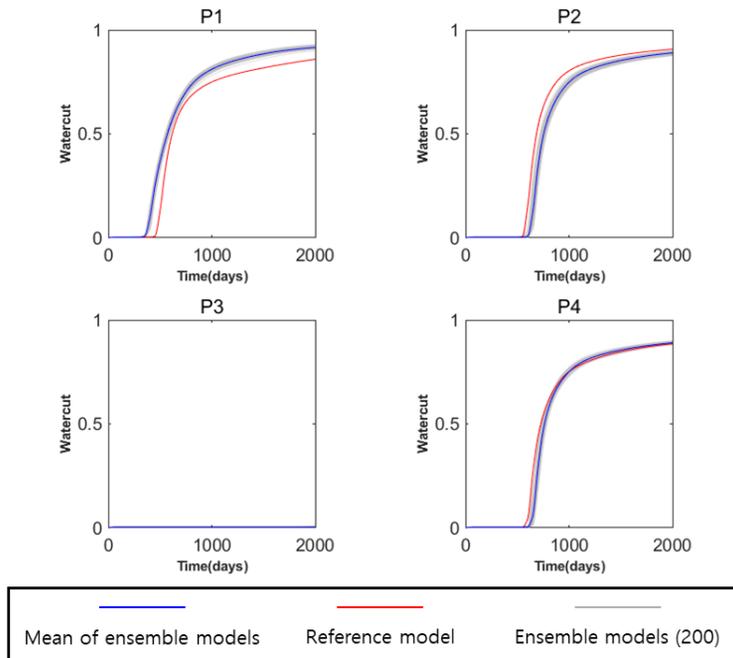


(b)

**Fig. 3.31.** Performance prediction of the initial ensemble models in case 2: (a) oil production, (b) watercut.

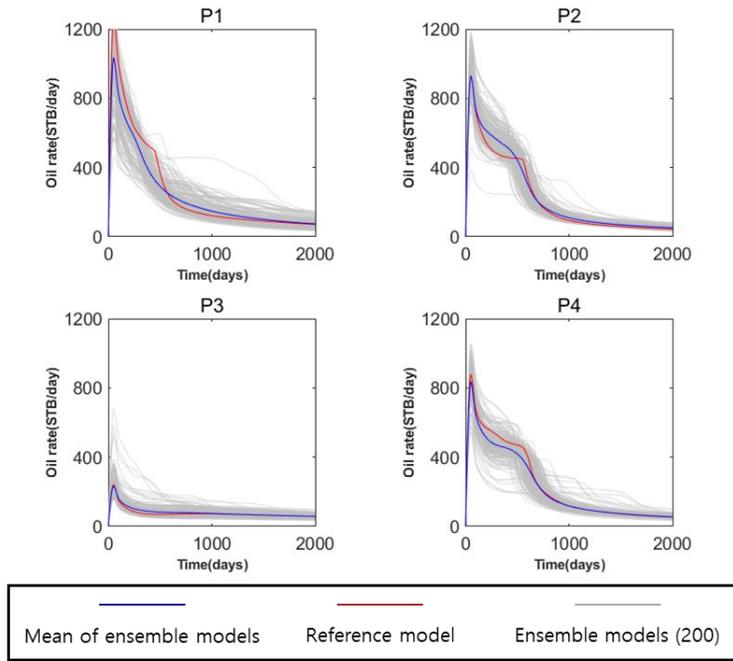


(a)

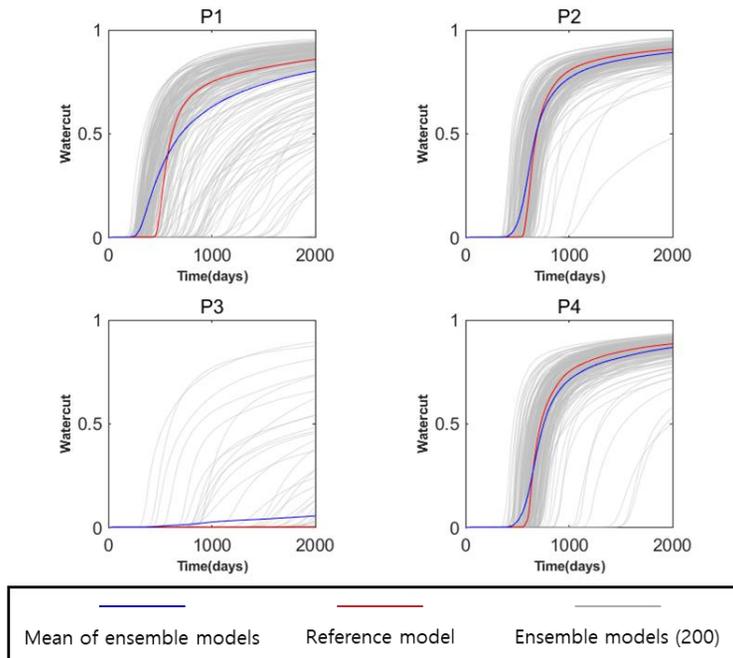


(b)

**Fig. 3.32.** Performance prediction of the updated models using the proposed method in case 2: (a) oil production, (b) watercut.



(a)



(b)

**Fig. 3.33.** Performance prediction of the updated models using only ES-MDA in case 2: (a) oil production, (b) watercut.

Table 3.7 MAE of oil rate and watercut prediction, case 2.

Reservoir models	MAE of oil rate	MAE of watercut
Initial models	93.873	$31.775 \times 10^{-2}$
Updated models using the suggested method	17.569	$3.052 \times 10^{-2}$
Updated models using only ES-MDA	35.266	$6.724 \times 10^{-2}$

### 3.2 3D 채널저류층 모델

앞서 제시한 2D 채널저류층 모델 히스토리매칭 케이스 두 개를 통해 제안하는 기법은 채널저류층 히스토리매칭 기법으로 충분히 사용할 수 있다고 판단하였고, 그에 따라 제안하는 기법을 사용해 3D 채널저류층 모델을 히스토리매칭한다.

2D 채널저류층에 비해 3D 채널저류층은 구조가 복잡하고 데이터의 크기도 커서 연산에 더 많은 시간이 소요되며, 거기에 더해 층 사이에 발생하는 유동 때문에 수많은 경우의 수가 생겨 히스토리매칭이 어렵다. 두 가지의 3D 채널저류층 모델을 사용해 제안하는 기법이 이러한 어려움을 극복하고 신뢰할 수 있는 히스토리매칭 결과를 제시할 수 있는지를 평가하였다.

Case 3은 2차원 평면 상에서 보았을 때는 유사한 형태를 갖는 채널이 수직 방향의 7개 층을 따라 위치가 서쪽에서 동쪽으로 조금씩 이동하는 3D 채널저류층 모델이다. 반면, case 4는 4개 층으로 구성되어 있으며 아래 2개 층의 채널 형태는 비슷하고 위 2개 층도 비슷하지만, 서로를 비교했을 때는 전혀 다른 채널 형태를 갖는 3D 채널저류층 모델이다.

### 3.2.1 모델 생성에 사용한 인자 정리

먼저 두 케이스의 데이터셋을 만드는 데 사용한 알고리즘의 인자들과 시뮬레이션 조건을 Table 3.8, Table 3.9, Table 3.10, Table 3.11, Fig. 3.34, Fig. 3.35, Table 3.12에 나타냈다. 이들은 각각 순서대로 Fluvsim 알고리즘의 인자, SNESim 시뮬레이션으로 생성한 모델 수, SNESim 시뮬레이션에 사용한 인자, beta-CVAE 훈련에 사용한 인자, case 3의 beta-CVAE 네트워크 구조, case 4의 beta-CVAE 네트워크 구조, 저류층 및 시뮬레이션 조건을 정리한 표와 그림이다.

**Table 3.8** Fluvsim parameters on 3D training image generation.

Parameters	Case 3	Case 4
Training image size, $x \times y \times z$	300 × 300 × 15	
Size of grid cell, ft	50	
Number of facies	2	
Target ratio, sandstone:shale	0.15:0.85	
Number of training images	1	
Facies types of Fluvsim	Channel only	
Width of channels, pixel	8	
Width undulation of channels, pixel	2	
Orientation of channels, clockwise from north	Normal(0, 15)	
Average departure from the channel center, ft	300	
Thickness of channels, pixel	33	
Thickness undulation of channels, pixel	2	
Position of maximum thickness	15 pixels east from the center	center

**Table 3.9** Number of 3D realizations generated by SNESim.

Parameters	Case 3	Case 4
Number of training models	600	
Number of validation models	150	
Number of ensemble models	200	
Number of test models	200	
Number of reference model	1	

**Table 3.10** SNESim parameters on 3D training image generation.

Parameters	Case 3	Case 4
Hard data location, (x, y)	(2, 2), (2, 31), (2, 59), (31, 2), (31, 31), (31, 59), (59, 2), (59, 31), (59, 59), (16, 16), (16, 45), (45, 16), (45, 45)	
Target ratio of channel	0.25	
Number of nodes in search template	80	
Search template geometry ranges, (max, med, min)	(1000, 750, 250)	
Number of multigrids	3	

**Table 3.11** Parameters on 3D beta-CVAE network training.

Parameters	Case 3	Case 4
Type of training data	Normalized permeability	
Batch size	32	
Max epochs	500	
Learning rate	0.0001	
Beta	1.5	

		Dimension	# of Channels	Padding	Kernel	Stride
Encoder	Input Layer	60x60x7	1			
	Convolution 1	60x60x7	16	1x1x1	3x3x3	1x1x1
	Convolution 2	60x60x7	32	1x1x1	3x3x3	1x1x1
	Convolution 3	60x60x7	64	1x1x1	3x3x3	1x1x1
	Convolution 4	60x60x7	128	1x1x1	3x3x3	1x1x1
	Convolution 5	30x30x4	128	1x1x1	4x4x3	2x2x2
	Convolution 6	15x15x2	128	1x1x1	4x4x4	2x2x2
	Convolution 7	8x8x1	64	1x1x1	3x3x4	2x2x2
	Convolution 8	8x8x1	32	1x1x1	3x3x3	1x1x1
	Fully-Connected	1024				
Fully-Connected	512					
	Latent Vector	256				
Decoder	Fully-Connected	512				
	Deconvolution 1	8x8x1	32	1x1x1	3x3x3	1x1x1
	Deconvolution 2	8x8x1	64	1x1x1	3x3x4	2x2x2
	Deconvolution 3	15x15x2	128	1x1x1	4x4x4	2x2x2
	Deconvolution 4	30x30x4	128	1x1x1	4x4x3	2x2x2
	Deconvolution 5	60x60x7	128	1x1x1	3x3x3	1x1x1
	Deconvolution 6	60x60x7	64	1x1x1	3x3x3	1x1x1
	Deconvolution 7	60x60x7	32	1x1x1	3x3x3	1x1x1
	Deconvolution 8	60x60x7	16	1x1x1	3x3x3	1x1x1
	Output Layer	60x60x7	1			

Fig. 3.34. Structure of 3D beta-CVAE network for case 3.

		Dimension	# of Channels	Padding	Kernel	Stride
Encoder	Input Layer	60x60x4	1			
	Convolution 1	60x60x4	16	1x1x1	3x3x3	1x1x1
	Convolution 2	60x60x4	32	1x1x1	3x3x3	1x1x1
	Convolution 3	60x60x4	64	1x1x1	3x3x3	1x1x1
	Convolution 4	60x60x4	128	1x1x1	3x3x3	1x1x1
	Convolution 5	30x30x2	128	1x1x1	4x4x4	2x2x2
	Convolution 6	15x15x1	128	1x1x1	4x4x4	2x2x2
	Convolution 7	8x8x1	64	1x1x1	3x3x3	2x2x1
	Convolution 8	8x8x1	32	1x1x1	3x3x3	1x1x1
	Fully-Connected	1024				
Fully-Connected	512					
	Latent Vector	256				
Decoder	Fully-Connected	512				
	Deconvolution 1	8x8x1	32	1x1x1	3x3x3	1x1x1
	Deconvolution 2	8x8x1	64	1x1x1	3x3x3	2x2x1
	Deconvolution 3	15x15x1	128	1x1x1	4x4x4	2x2x2
	Deconvolution 4	30x30x2	128	1x1x1	4x4x4	2x2x2
	Deconvolution 5	60x60x4	128	1x1x1	3x3x3	1x1x1
	Deconvolution 6	60x60x4	64	1x1x1	3x3x3	1x1x1
	Deconvolution 7	60x60x4	32	1x1x1	3x3x3	1x1x1
	Deconvolution 8	60x60x4	16	1x1x1	3x3x3	1x1x1
	Output Layer	60x60x4	1			

Fig. 3.35. Structure of 3D beta-CVAE network for case 4.

**Table 3.12** 3D reservoir simulation conditions.

Parameters	Case 3	Case 4
Grid system, $x \times y \times z$	$60 \times 60 \times 7$	$60 \times 60 \times 4$
Size of a grid cell in ft, $x, y, z$	50, 50, 20	
Producer locations, $(x, y)$	(2, 2), (2, 31), (2, 59), (31, 2), (31, 31), (31, 59), (59, 2), (59, 31), (59, 59)	
Injector locations, $(x, y)$	(16, 16), (16, 45), (45, 16), (45, 45)	
Depth of the top cells, ft	2700	
Porosity	0.2	
Horizontal sandstone permeability, md	500	
Vertical sandstone permeability, md	50	
Horizontal shale permeability, md	5	
Vertical shale permeability, md	0.5	
Oil density, $\text{lb/ft}^3$	48.623	
Water density, $\text{lb/ft}^3$	62.313	
Initial oil formation volume factor, $\text{rb/STB}$	1.01	
Oil viscosity, cp	3	
Water viscosity, cp	1	

Rock compressibility, psi <sup>-1</sup>	3.0 × 10 <sup>-5</sup>	
Water compressibility, psi <sup>-1</sup>	5.0 × 10 <sup>-7</sup>	
Initial BHP of the top cells, psi	2000	
Initial water saturation	0.25	
Production constraint	BHP, 500psi	
Injection constraint	Water rate, 4500STB/day	Water rate, 3000STB/day
Assimilation time steps	17 × 30days	17 × 30days
Prediction time steps	34 × 30days	34 × 30days
Observed data	Oil rate (STB/day), watercut	

### 3.2.2 Case 3 – 층에 따라 채널의 위치가 다른 모델

Fig. 3.36은 case 3에 사용된 트레이닝 이미지와 하드데이터다. 2D 채널저류층과는 다르게 참조 모델, 초기 앙상블, 기계학습을 위한 모델을 만드는 데 하나의 트레이닝 이미지만을 사용하였다.

트레이닝 이미지는 평면 상에서 봤을 때는 남북 방향으로 뻗어 있는 채널이 특징이며, 수직 방향으로로는 아래로 내려갈수록 채널의 폭이 점점 좁아지는 형태를 하면서 동시에 경사져 있다. 하드데이터로 제시된 13개 지점에서의 암상 자료는 9개가 사암, 4개가 셰일이고 Z축 방향으로 암상의 변화는 없다.

위에서 언급한 트레이닝 이미지와 하드데이터를 사용하여 만든 참조 모델의 유체투과율 분포와 유정 배치 상황을 Fig. 3.37에 나타냈다. 트레이닝 이미지에서 보였던 남북 방향의 채널이 참조 모델에서도 드러나며, I자 모양의 채널과 Y자 모양의 채널이 서로 붙어서 따로 떨어진 채널 없이 모두 하나로 연결되어 있는 형태다.

또한, Z축 방향으로 경사진 트레이닝 이미지의 특징에 맞게 아래 층으로 내려갈수록 채널이 전체적으로 점점 오른쪽으로 이동한다. 이는 북쪽에 있는 수직 방향의 생산정이 가장 위층에서는 채널의 오른쪽 가장자리에 존재하지만 가장 아래층에서는 채널의 중심에 위치하는 등 층에 따른 유정의 위치를 보면 알 수 있다.

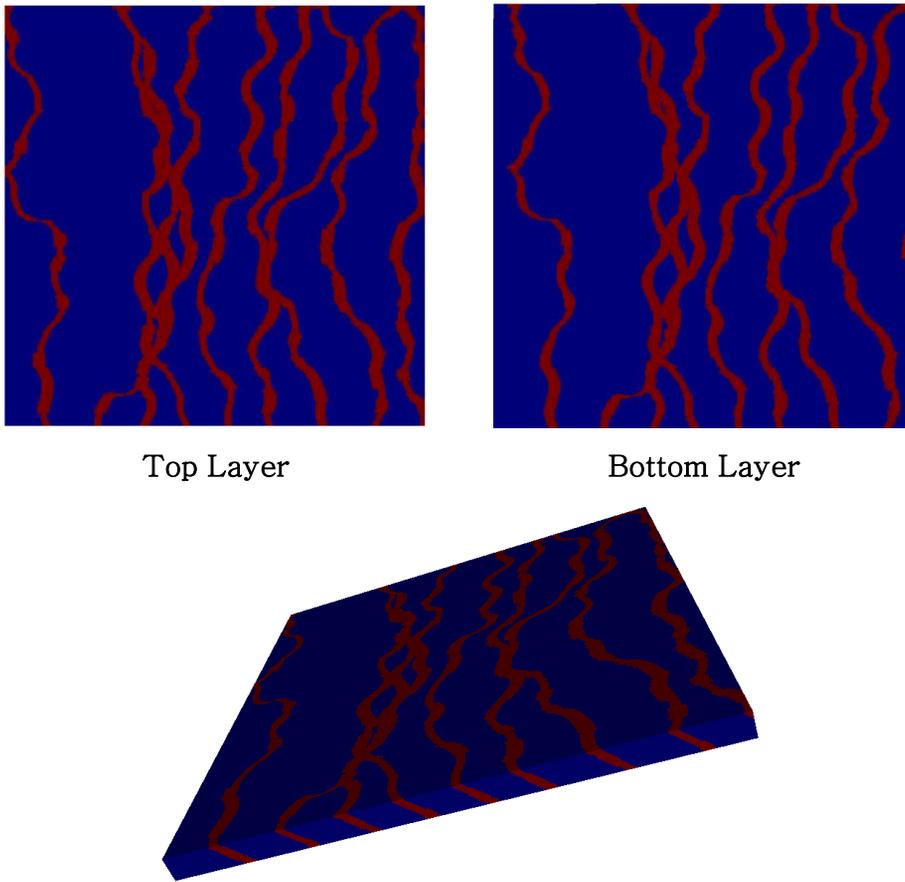
4개의 주입정은 모두 채널 위에 있지만 생산정은 9개 중 5개만이 채널 위에 있는데, 이 생산정들은 모두 주입정의 영향을 받기 때문에 채널의 연결성이 생산 경향에 큰 영향을 끼친다. 그 중 정가운데에 있는 생산정은 다른 생산정들과는 달리 두 주입정의 영향을 직접적으로 받기 때문에 다른 생산정에 비해 오일 생산량이 높게 나타난다. 한편, 채널 위에 있지 않은 4개의 생산정은 모두 전체 기간 동안 오일과 물 생산이 거의 이루어지지 않는다.

채널의 연결성에 따라 생산정에서의 생산 경향이 크게 차이 나는 것은 2D 채널저류층 모델과 유사하지만, 3D 채널저류층 모델은 각 층의 수평 방향 연결성과 수직 방향의 연결성이 모두 중요하게 작용한다는

점이 2D 채널저류층 모델과의 차이점이다.

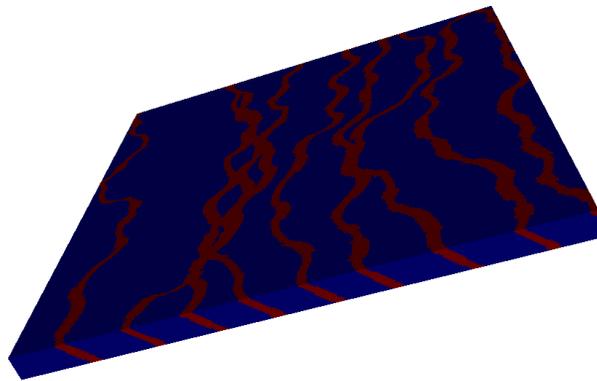
Fig. 3.38는 초기 앙상블 모델을 200개 생성하여 그 모델 전체의 평균 유체투과율 분포를 그린 것이고, Fig. 3.39-41는 그 중 3개 모델을 선별하여 각각 유체투과율 분포를 그린 것이다.

초기 앙상블의 평균 유체투과율 분포는 모든 층에서 참조 모델과 유사한 경향을 찾아볼 수 없다. 남북 방향으로 어느 정도의 연결성을 보이나, 그 이외의 방향으로는 완전히 무작위한 경향을 보이기 때문에 초기 앙상블의 생산 경향은 참조 모델을 전혀 예측하지 못한다. 선별한 모델들도 남북 방향으로 채널이 형성되어 있는 것만 참조 모델과 유사할 뿐, 채널이 서로 떨어져 있거나 층에 따라 연결성이 달라지는 등 참조 모델과 큰 차이를 보인다.



Top Layer

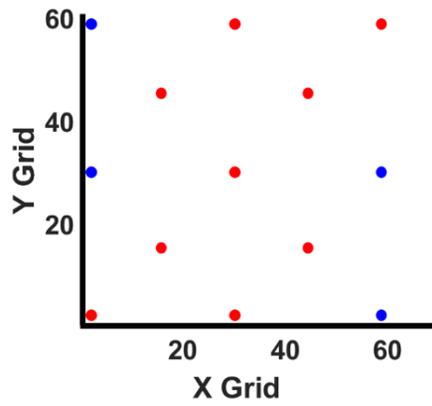
Bottom Layer



Side View



(a)



(b)

Fig. 3.36. (a) Training image and (b) hard data of case 3.

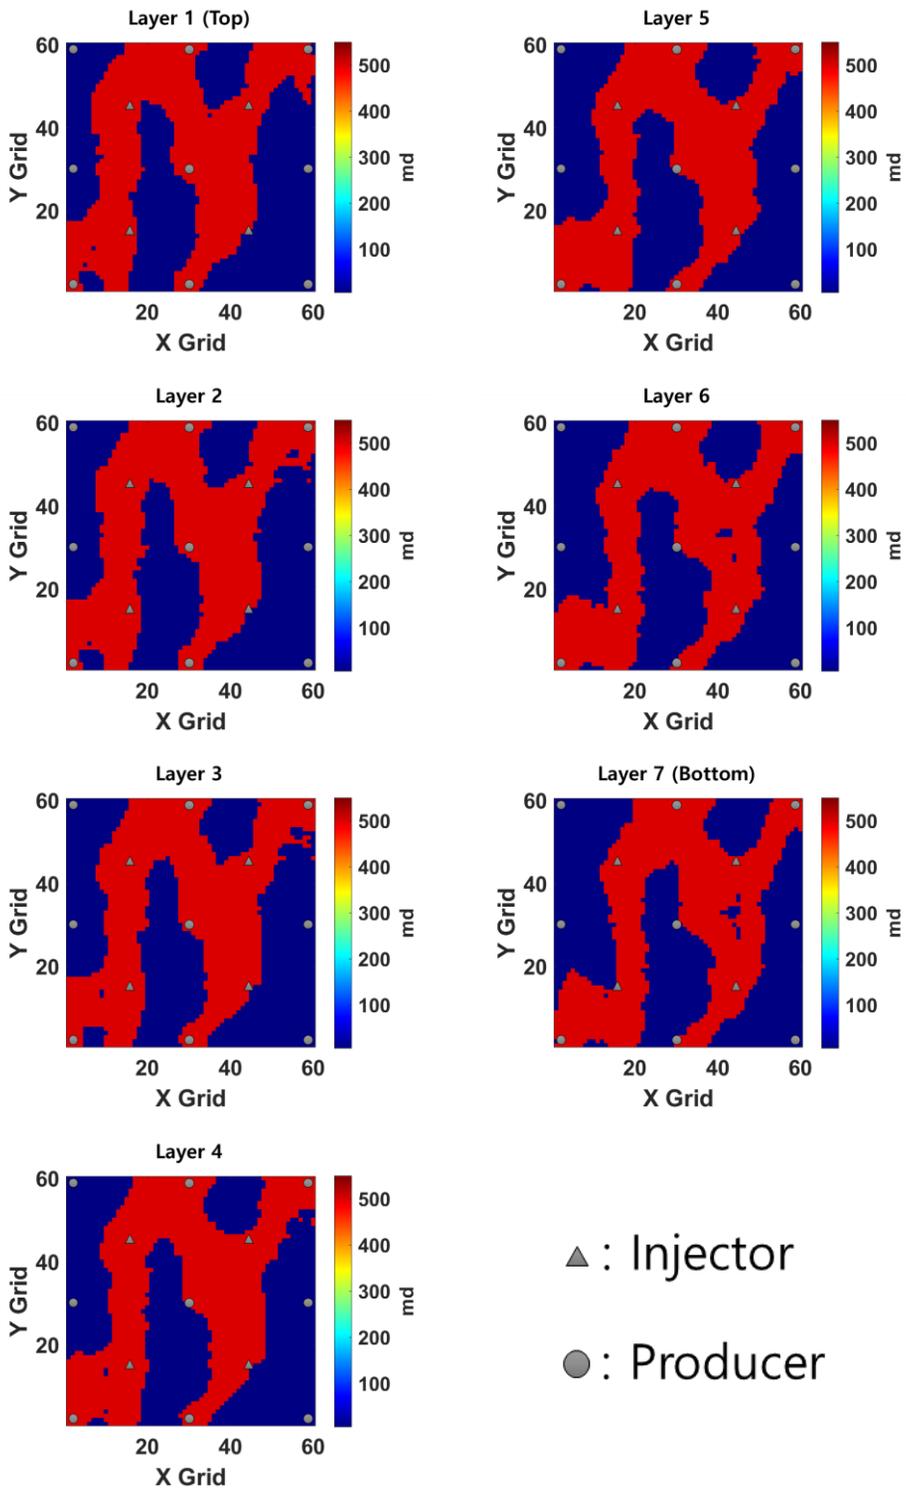


Fig. 3.37. The reference model of case 3.

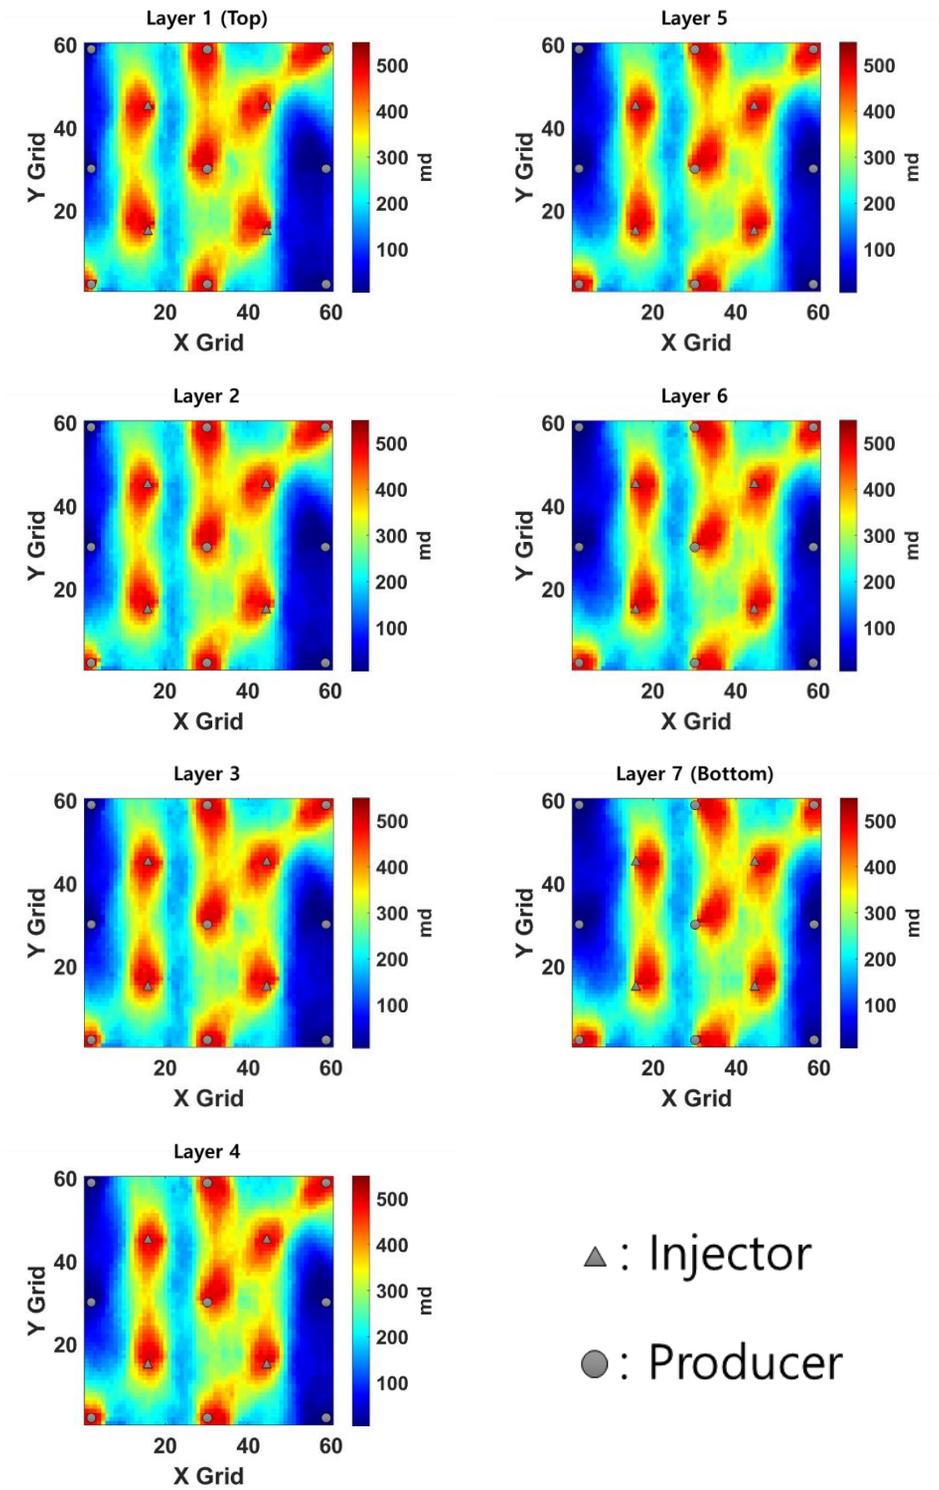


Fig. 3.38. Initial mean permeability distribution of case 3.

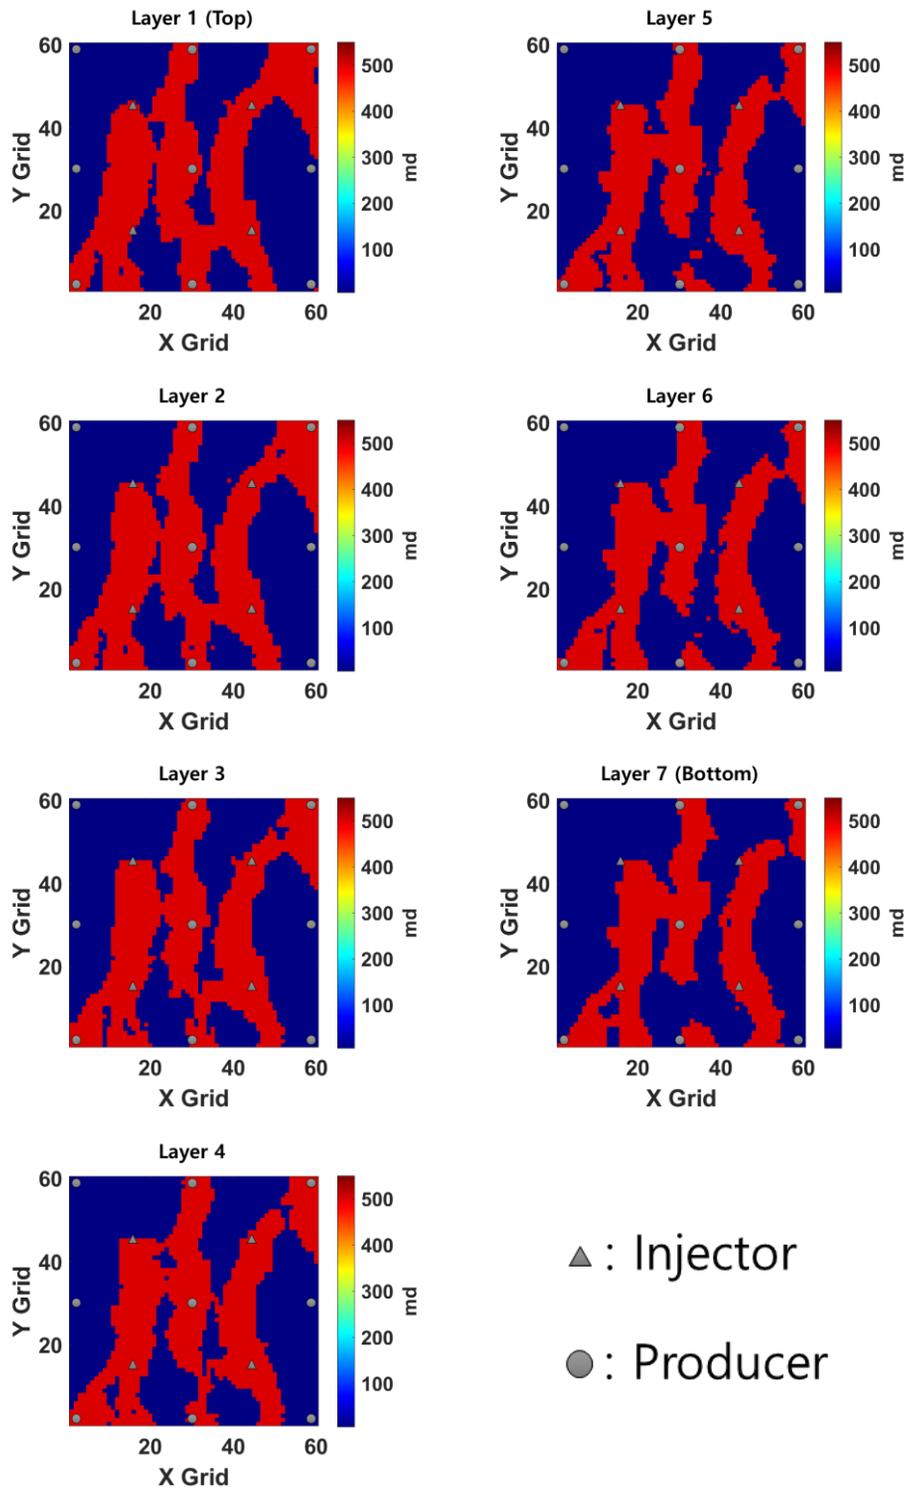


Fig. 3.39. Initial permeability distribution of model #1 in case 3.

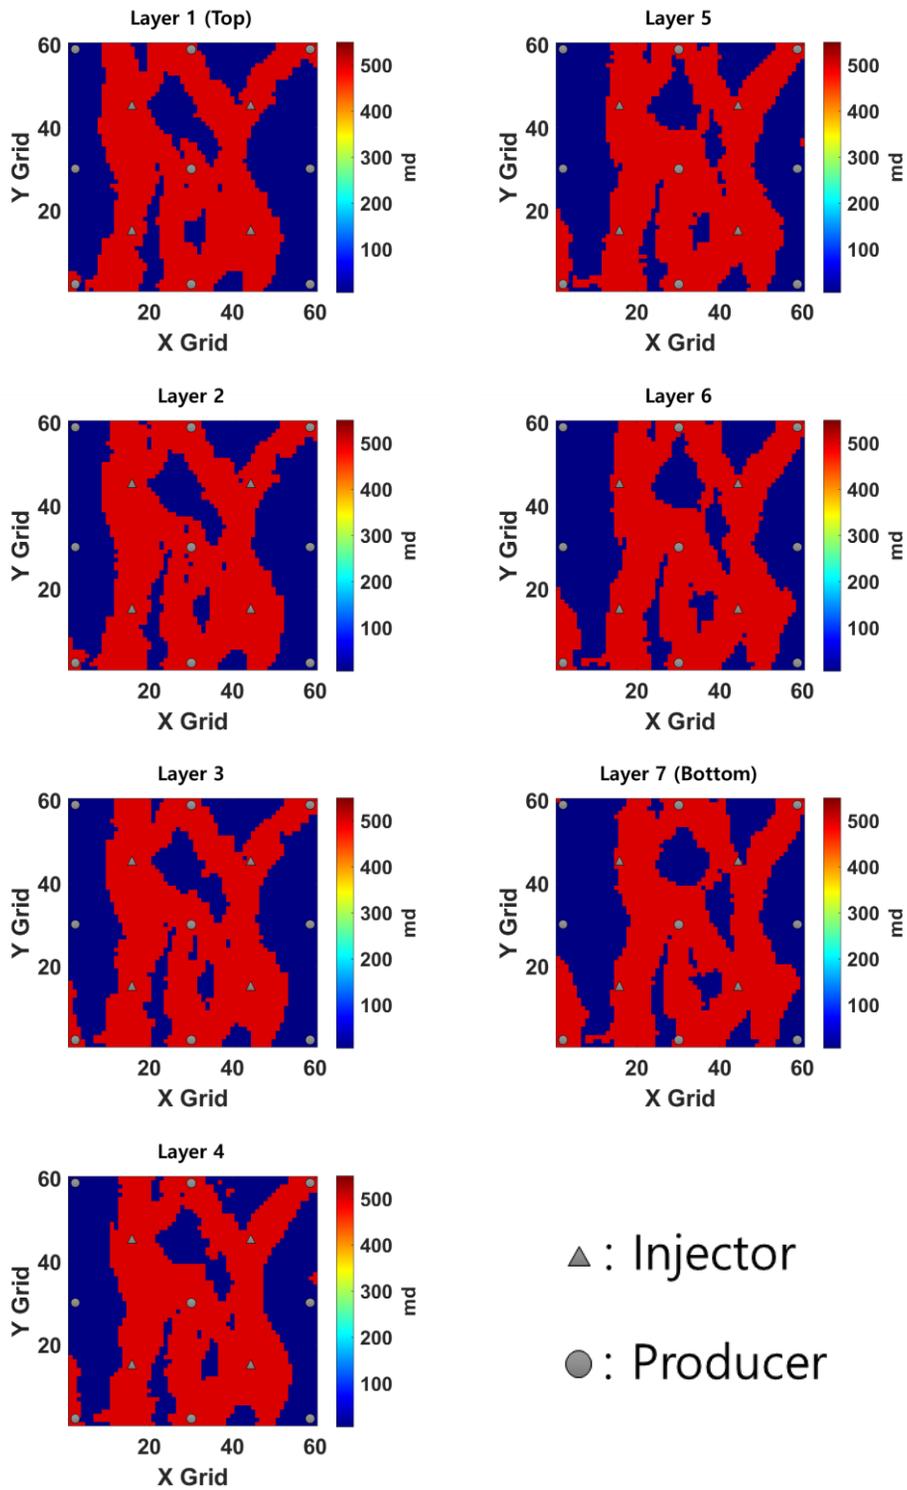


Fig. 3.40. Initial permeability distribution of model #2 in case 3.

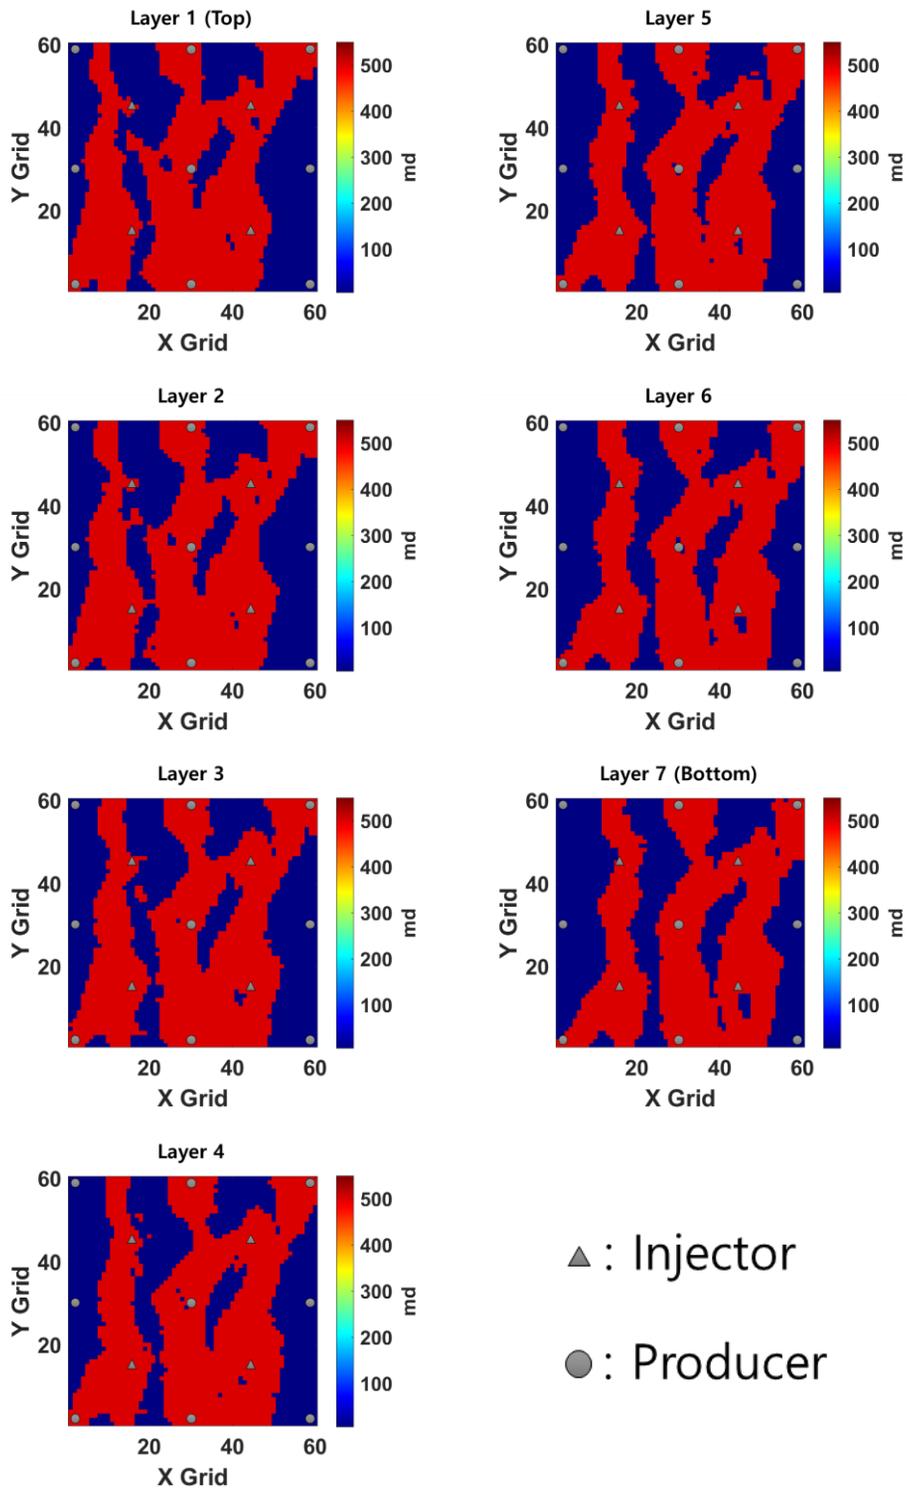


Fig. 3.41. Initial permeability distribution of model #3 in case 3.

2D 채널저류층과 마찬가지로 기계학습을 위한 저류층 모델은 초기 앙상블을 만들 때의 트레이닝 이미지와 하드데이터를 동일하게 사용해서 생성한, 다른 목적의 앙상블 멤버와는 중복되지 않는 950개 모델이다.

Beta-CVAE 네트워크 훈련에 사용한 값은 정규화된 유체투과율로, 3D 채널저류층의 유체투과율을 사용했기 때문에 2D 채널저류층 모델을 사용해 훈련할 때와는 다르게 3D 합성곱 계층을 사용하였다. 입력값과 출력값을 동일하게 설정하여 beta-CVAE 네트워크가 생성 모델을 학습한다.

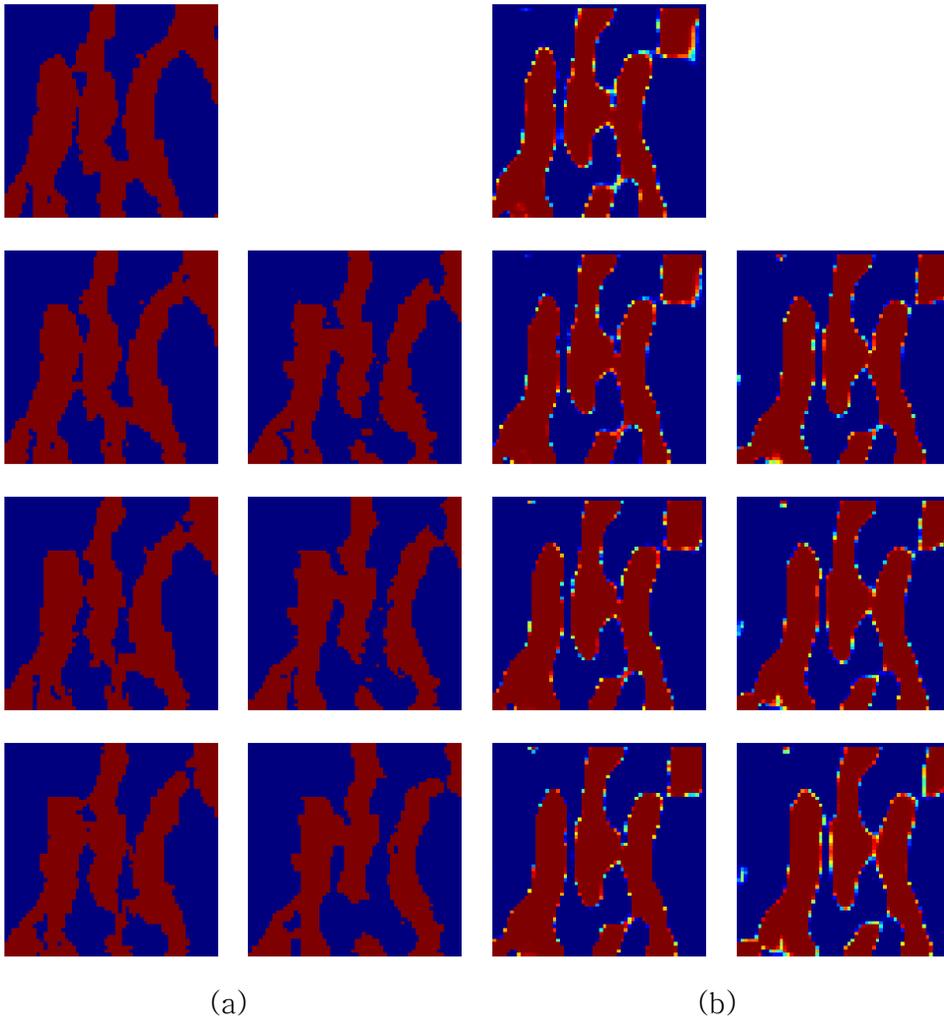
훈련 진행에 따른 학습 데이터와 검증 데이터의 손실 함수 값 변화는 Fig. 3.42의 그래프와 같이 나타난다. 3D 채널저류층을 사용해서 beta-CVAE 네트워크를 학습할 때도 학습과정에서 과적합 현상이 발생하며, 이는 검증 데이터의 손실 함수 값은 감소하다가 미세하게 다시 증가하지만 학습 데이터의 손실 함수 값은 계속해서 감소하는 것으로 확인할 수 있다.

앞의 두 케이스와 마찬가지로 학습 데이터는 이후 사용하지 않으므로 검증 데이터의 손실 함수 값이 가장 낮은 253번째 epoch의 모델을 추후 사용할 네트워크 모델로 선정하였다.

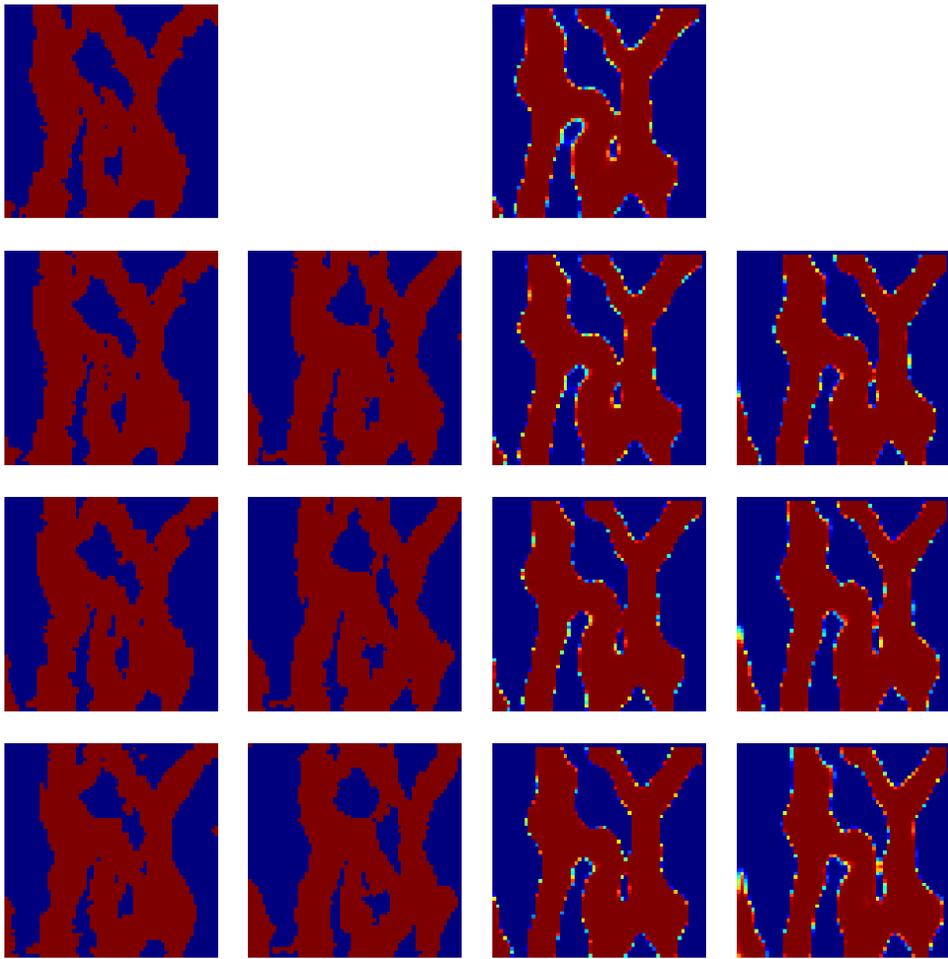


**Fig. 3.42.** Training loss and validation loss vs epoch in case 3.

선정한 beta-CVAE 네트워크를 사용하여 Fig. 3.39-41의 모델들을 인코딩한 후 디코딩한 결과를 Fig. 3.43-45에 그렸다. 이 과정은 차원을 축소한 후 다시 원래 차원으로 복원하기 때문에 원본 데이터를 완벽하게 재현하는 것은 불가능하지만, 채널저류층의 생산 경향에 주요한 영향을 미치는 채널의 연결성 및 방향성과 같이 중요한 특성들은 효과적으로 복원되었다.



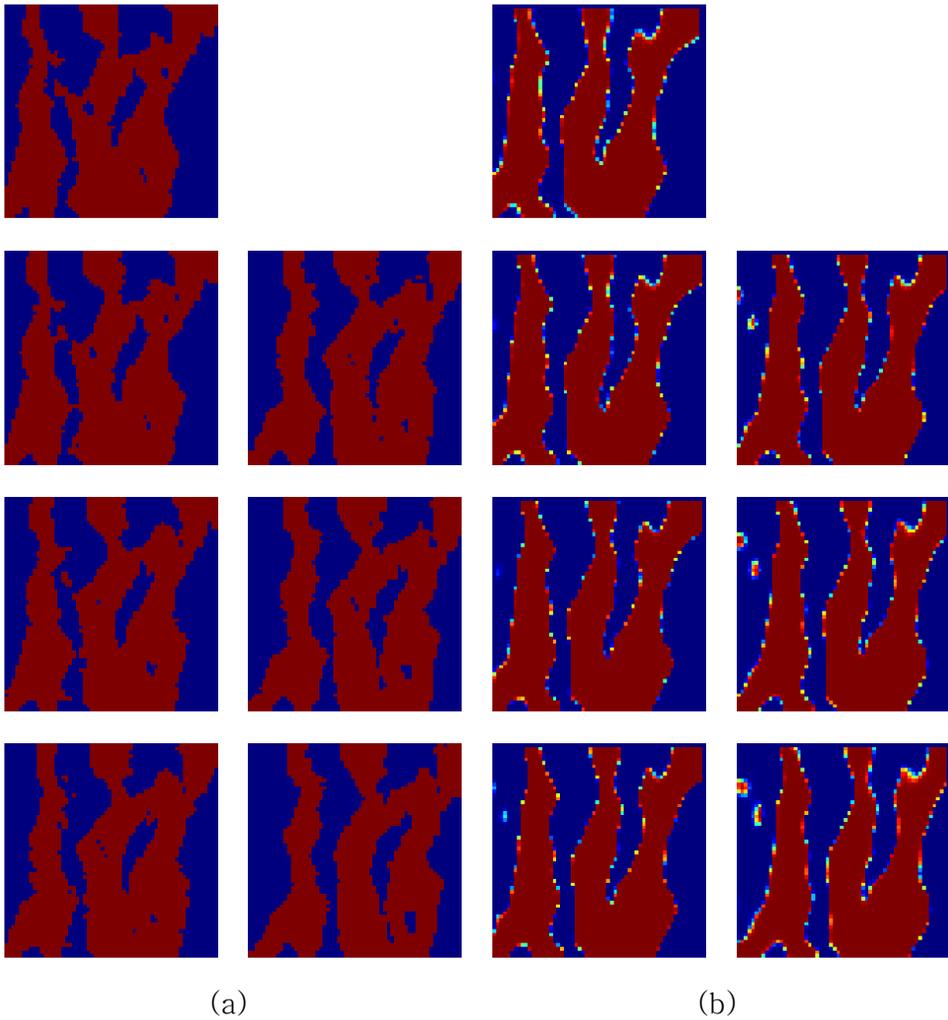
**Fig. 3.43.** Reconstruction of model #1 using beta-CVAE in case 3:  
 (a) original model, (b) corresponding reconstruction.



(a)

(b)

**Fig. 3.44.** Reconstruction of model #2 using beta-CVAE in case 3:  
 (a) original model, (b) corresponding reconstruction.



**Fig. 3.45.** Reconstruction of model #3 using beta-CVAE in case 3:  
 (a) original model, (b) corresponding reconstruction.

두 2D 채널저류층 케이스와 마찬가지로 제안하는 기법을 사용한 히스토리매칭 결과는 최종 업데이트된 모델들의 평균 유체투과율 분포를 참조 모델과 비교하고, 오일 생산량 및 워터컷 예측값이 참조 모델과 얼마나 유사한지를 판단하며, 예측값의 MAE를 계산하여 평가하였다. 비교군으로는 2D 채널저류층 케이스와는 다르게 beta-CVAE 대신 CAE를 사용한 결과와 CVAE를 사용한 결과로 총 2가지를 사용하였다.

Fig. 3.46과 Fig. 3.47은 각각 참조 모델과 업데이트된 모델의 평균 유체투과율 분포를 나타낸 것이다. 두 그림을 비교했을 때 제안하는

기법이 앙상블의 채널 연결성을 참조 모델과 유사한 경향을 갖도록 업데이트한 것을 확인할 수 있다. 참조 모델에서 특징적으로 나타났던 I자 모양의 채널과 Y자 모양의 채널이 붙어 있는 형태가 업데이트된 모델에서도 나타나며, 이 형태가 7개 층 모두에서 잘 드러난다.

또한 아래층으로 내려갈 수록 경사지는 경향도 잘 예측하였으며, 이는 같은 유정에 대해 가장 위층에서는 채널의 오른쪽에 있던 유정이 가장 아래층에서는 채널의 중심이나 왼쪽으로 이동한 것으로 확인할 수 있다. 이 결과는 앞서 선정한 초기 앙상블의 일부 모델들을 업데이트한 결과인 Fig. 3.48-50의 유체투과율 분포에 뚜렷하게 드러난다.

첫 번째 비교군인 CAE를 사용해 업데이트한 앙상블의 평균 유체투과율 분포를 Fig. 3.51에 나타내었다. 그 결과, 참조 모델과 비슷한 채널의 형태는 어렵게 드러나지만 그 연결성을 확실하게 예측하지 못해서 연결성이 매우 약하다. 특히 6번째 층과 7번째 층은 채널이 분리되어 있는 것으로 예측하는 등 제안하는 기법에 비해서 채널의 연결성을 잘 업데이트하지 못하였다. Fig. 3.52-54의 단일 앙상블 멤버에 대한 업데이트 결과에서 이와 같은 현상이 더욱 두드러지게 나타나며, 채널로 연결된 것이 아니라 마치 덩어리가 여러 개 놓여 있는 것 같은 형태가 나타난다.

Fig. 3.55는 두 번째 비교군인 CVAE를 사용한 히스토리매칭 후의 평균 유체투과율 분포다. 업데이트 결과, CAE를 사용한 결과와 다르게 채널의 형태를 띠고는 있으나 그 연결성을 잘못 예측하였다. 참조 모델은 주입정 I1이 왼쪽으로만 연결되어 있지만 해당 결과에서는 오른쪽으로도 연결되어 생산정 P2와 P5에 영향을 끼치고 있으며, 주입정 I2가 생산정 P2와 직접적으로 연결되지 않는 것도 참조 모델과의 큰 차이점이다. 단일 앙상블의 업데이트 결과를 도시한 Fig. 3.56-58에서도 이와 같이 참조 모델과 연결성을 다르게 예측한 것을 확인할 수 있다.

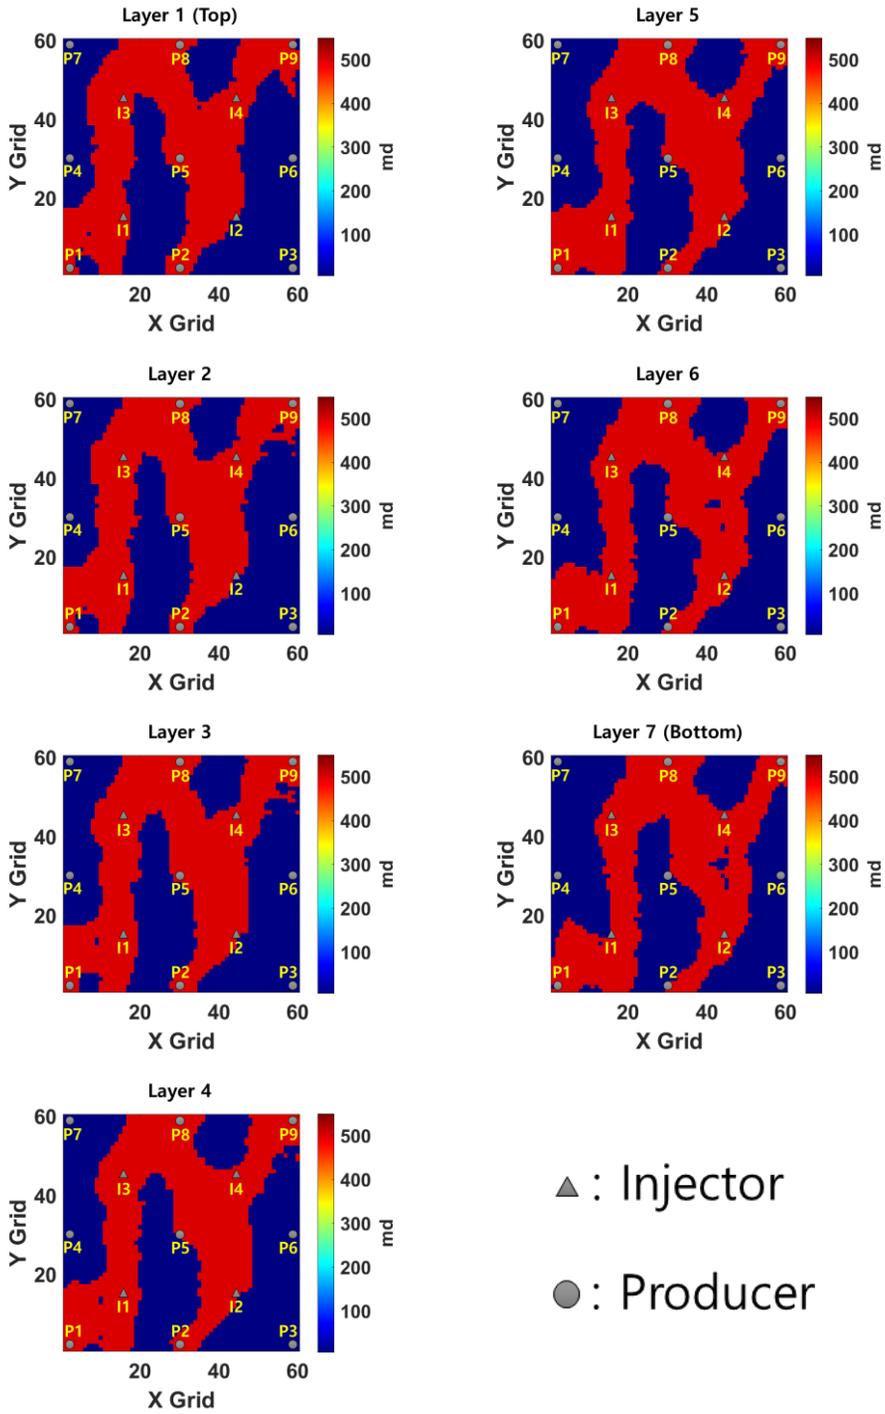


Fig. 3.46. Permeability distribution and well placement of the reference model of case 3.

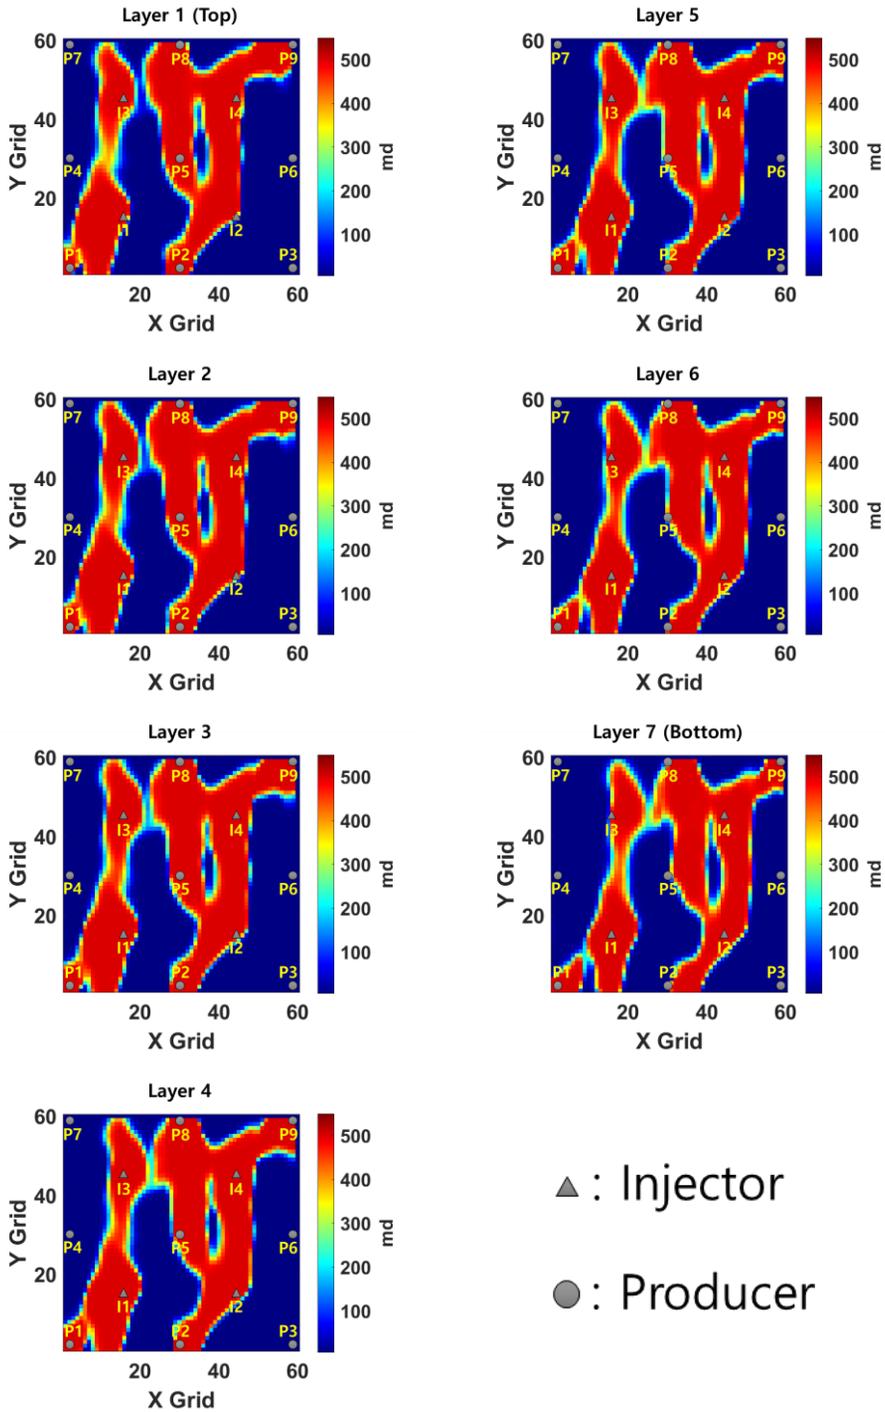


Fig. 3.47. Mean permeability distribution of case 3, updated by the proposed method.

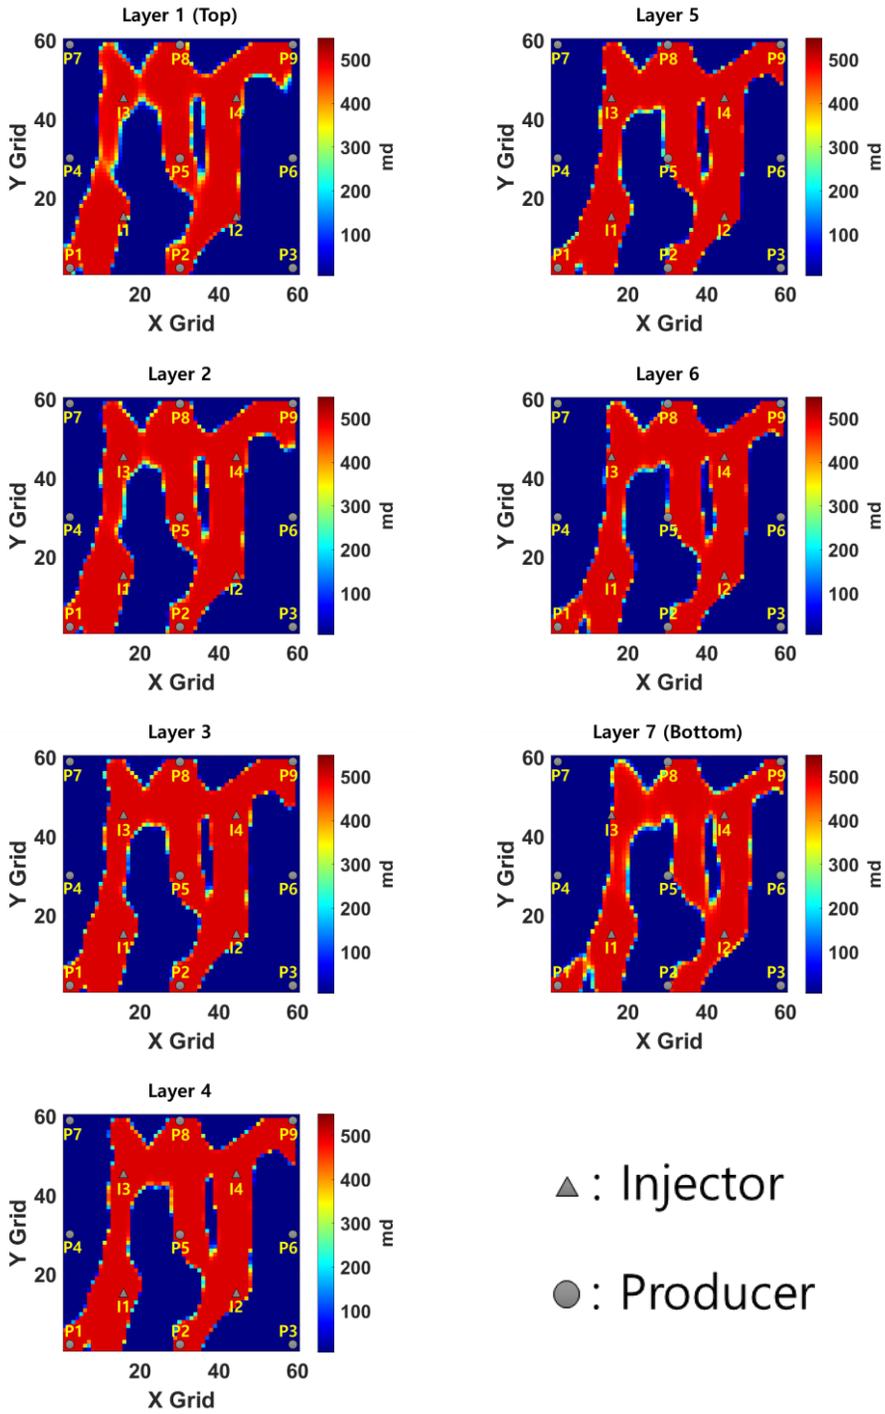


Fig. 3.48. Permeability distribution of the model in Fig. 3.39, updated by the proposed method.

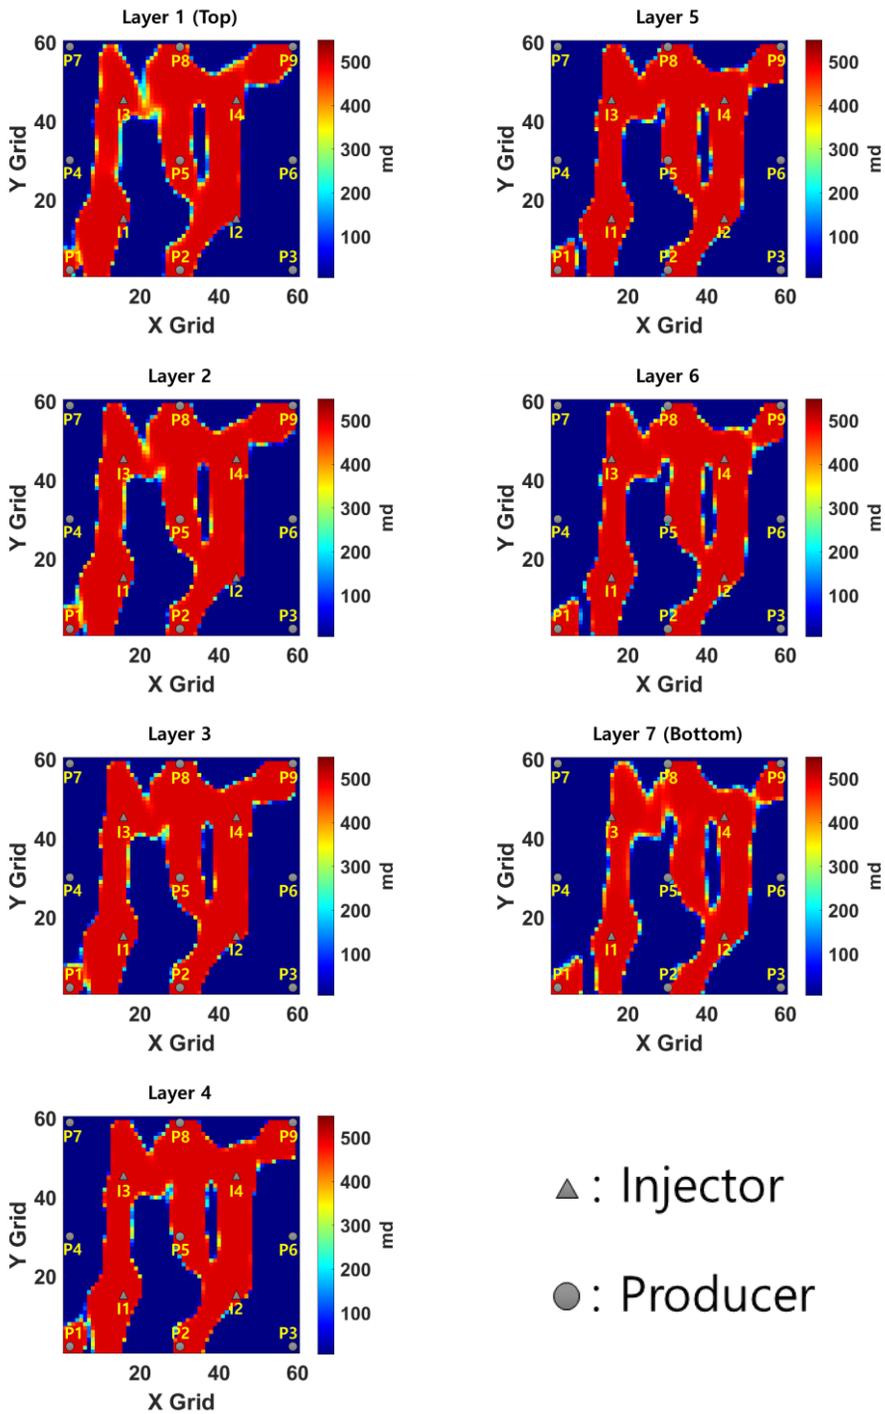


Fig. 3.49. Permeability distribution of the model in Fig. 3.40, updated by the proposed method.

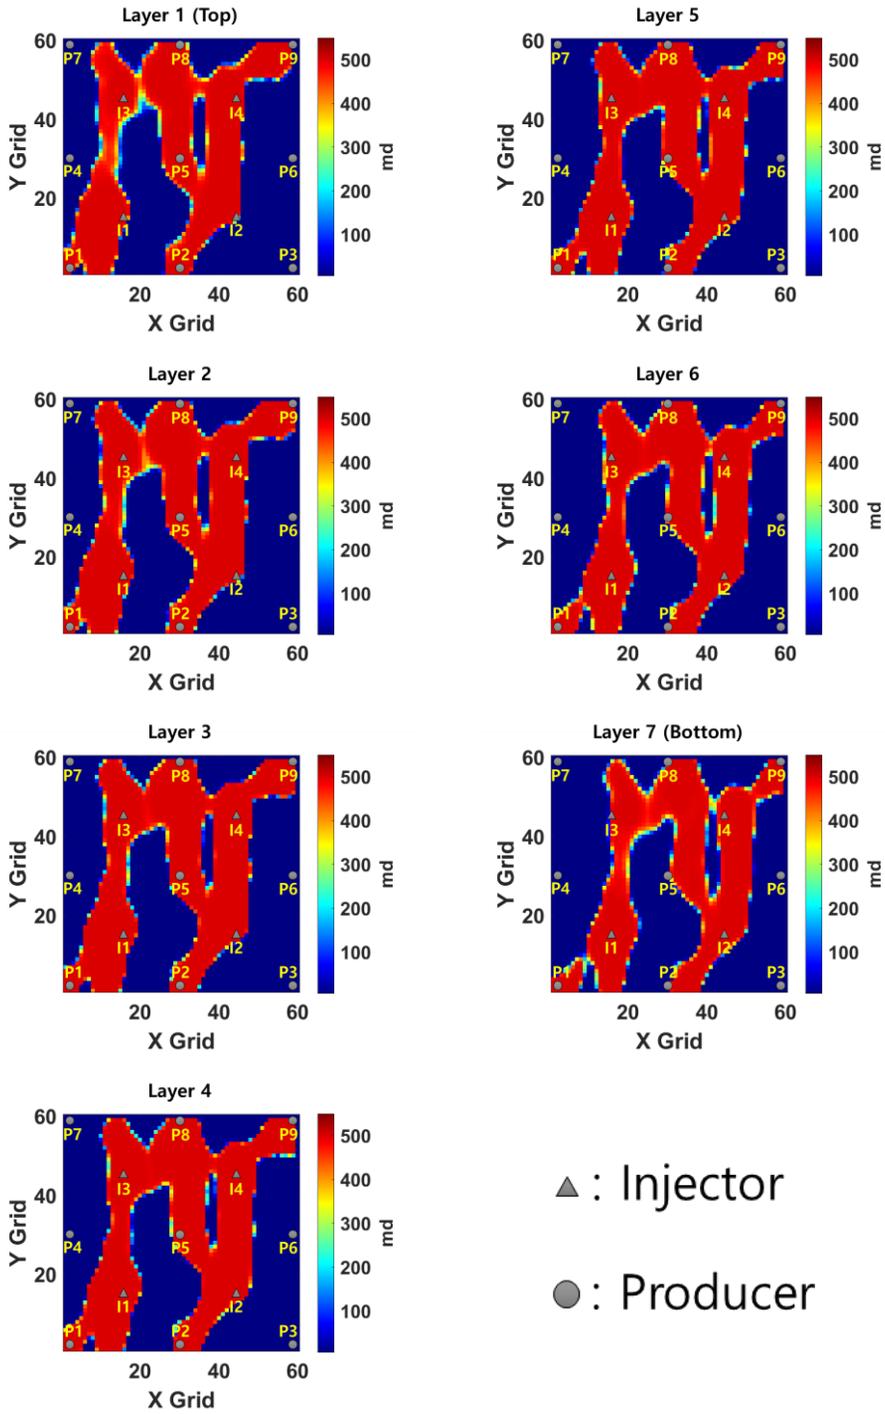


Fig. 3.50. Permeability distribution of the model in Fig. 3.41, updated by the proposed method.

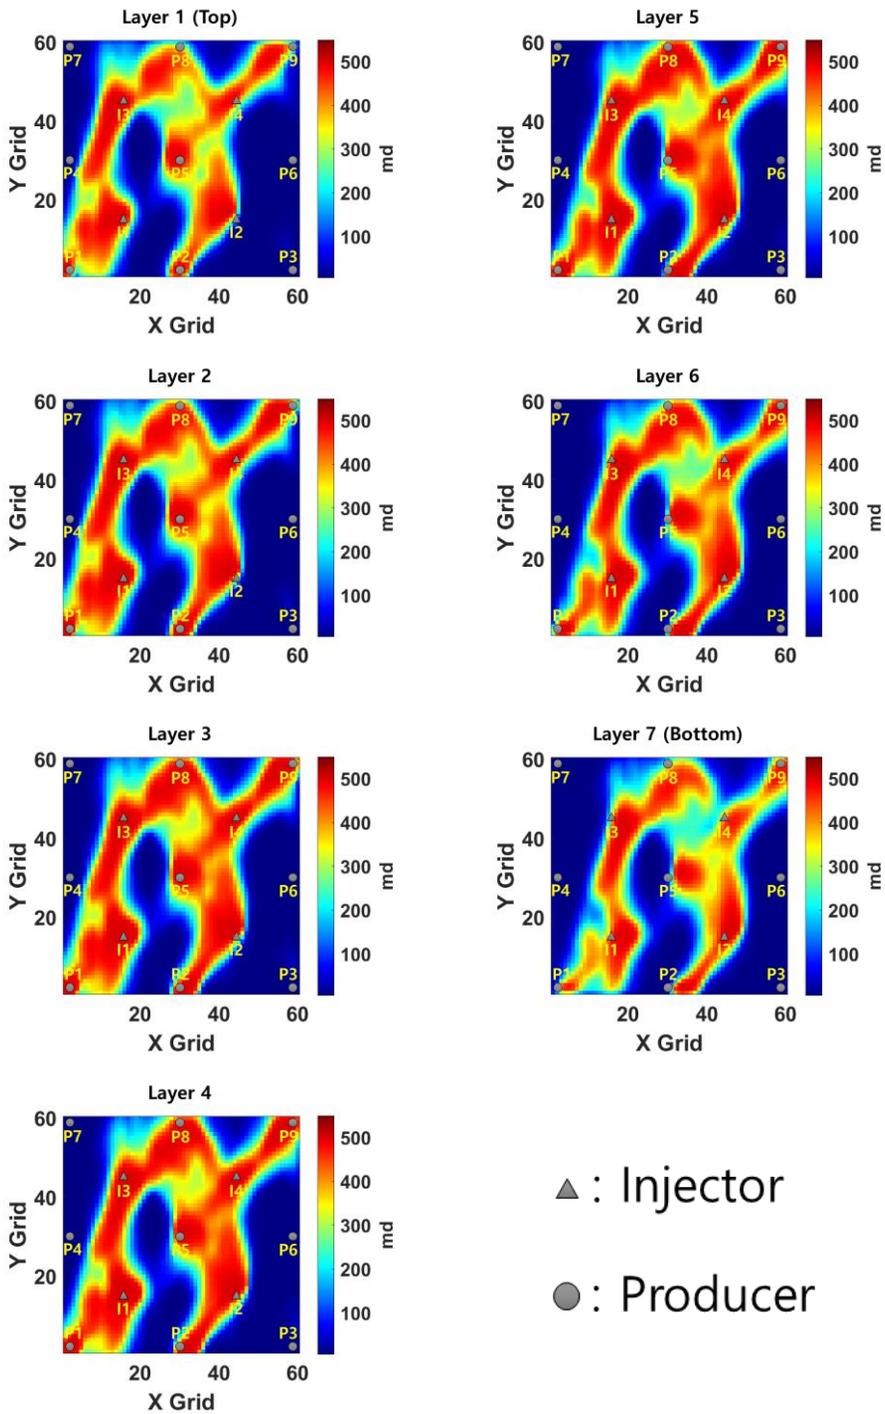


Fig. 3.51. Mean permeability distribution of case 3, updated using CAE instead of beta-CVAE.

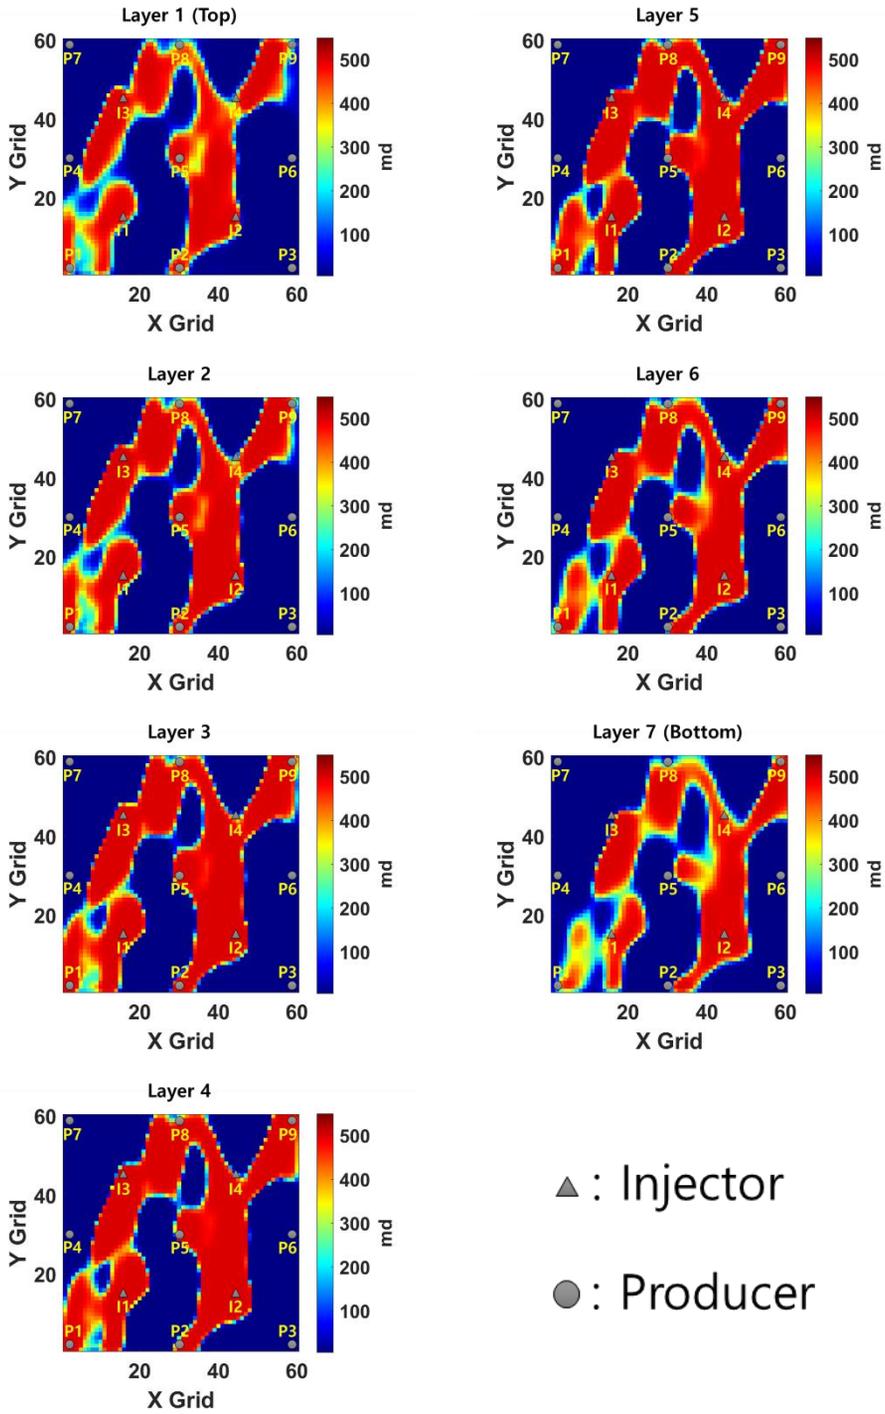


Fig. 3.52. Permeability distribution of the model in Fig. 3.39, updated using CAE instead of beta-CVAE.

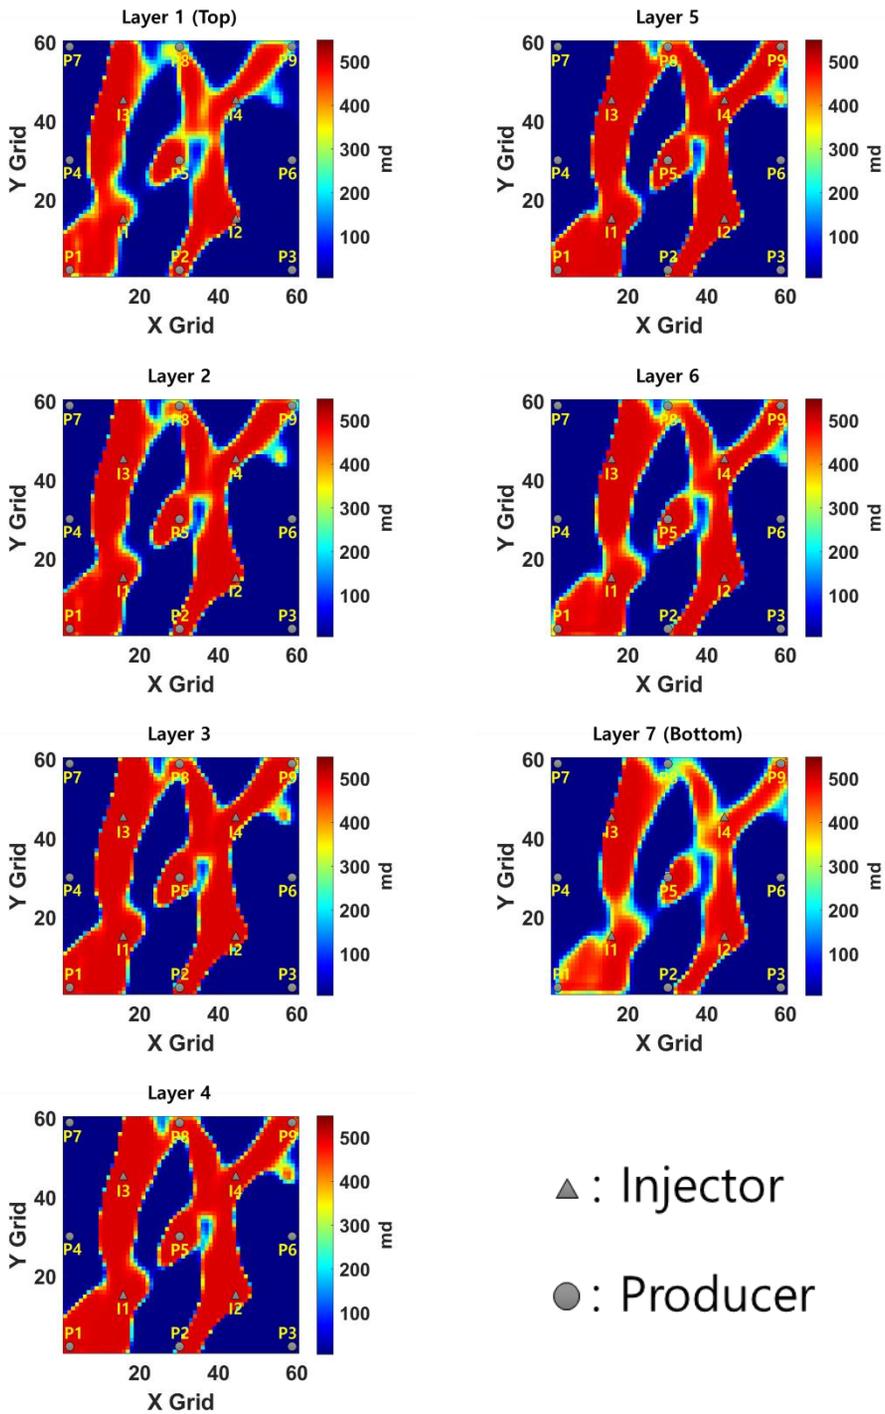


Fig. 3.53. Permeability distribution of the model in Fig. 3.40, updated using CAE instead of beta-CVAE.

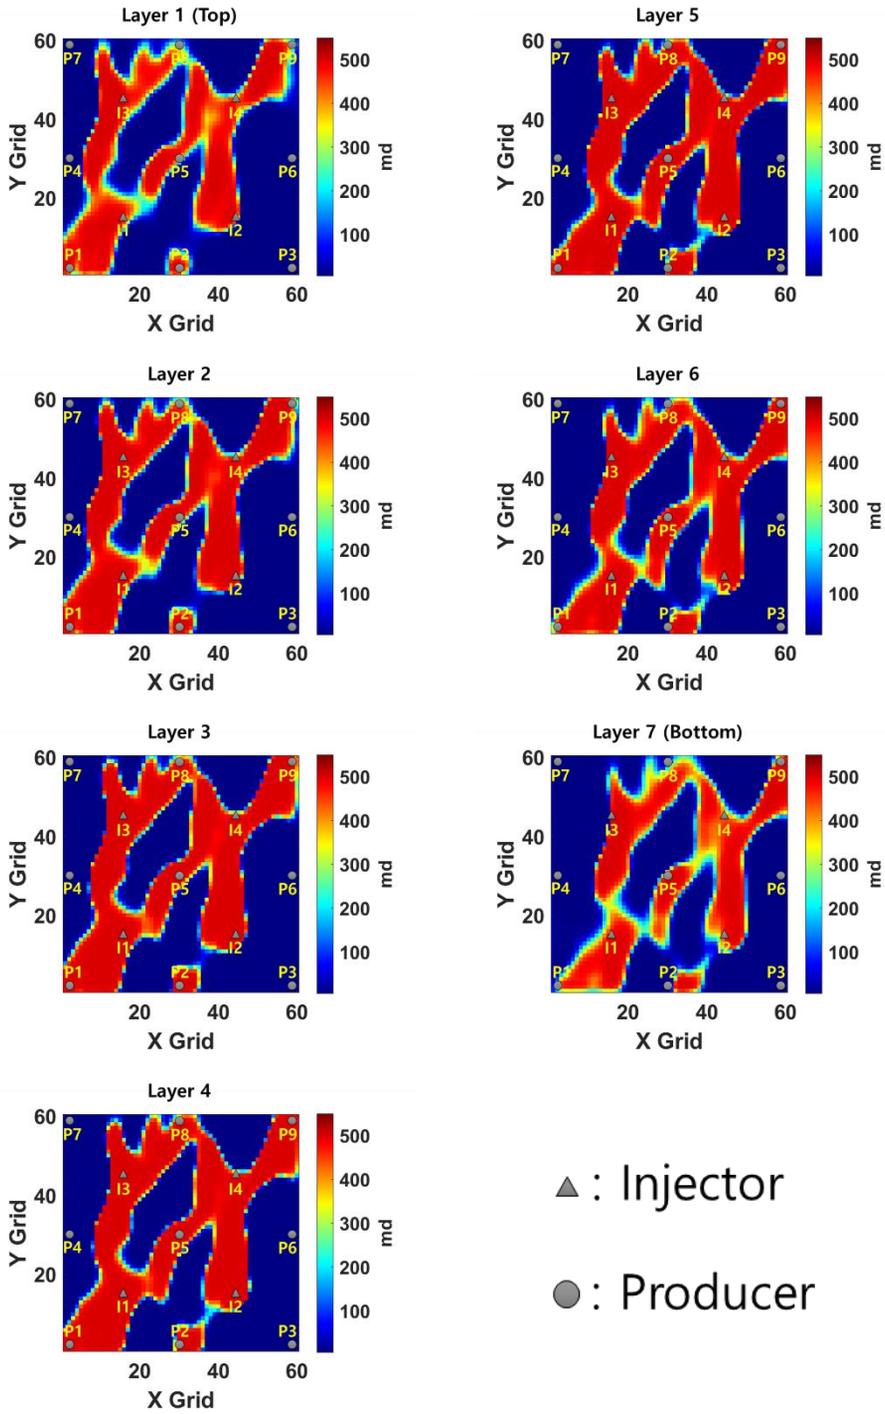


Fig. 3.54. Permeability distribution of the model in Fig. 3.41, updated using CAE instead of beta-CVAE.

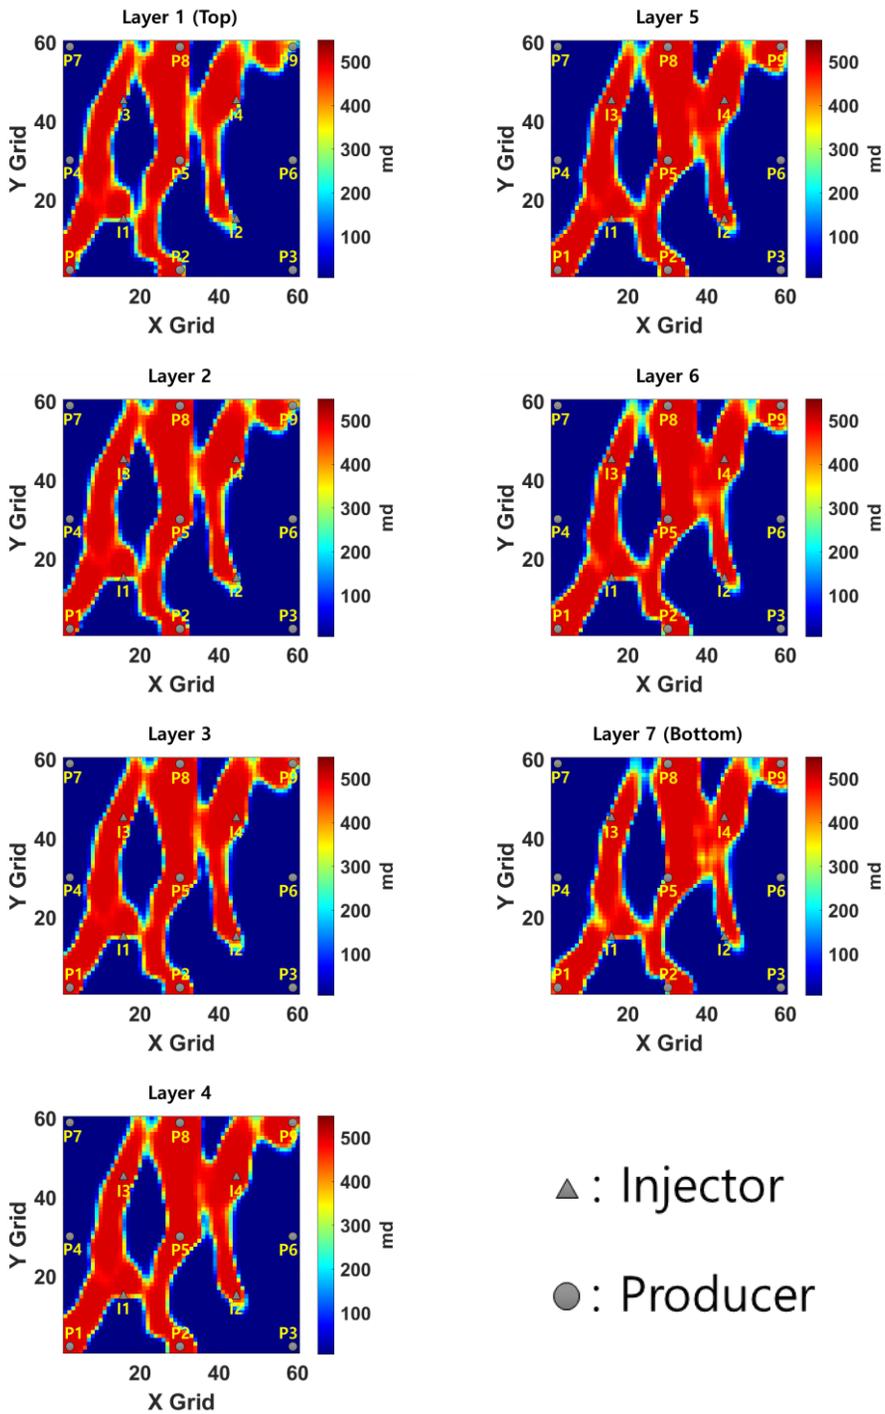


Fig. 3.55. Mean permeability distribution of case 3, updated using CVAE instead of beta-CVAE.

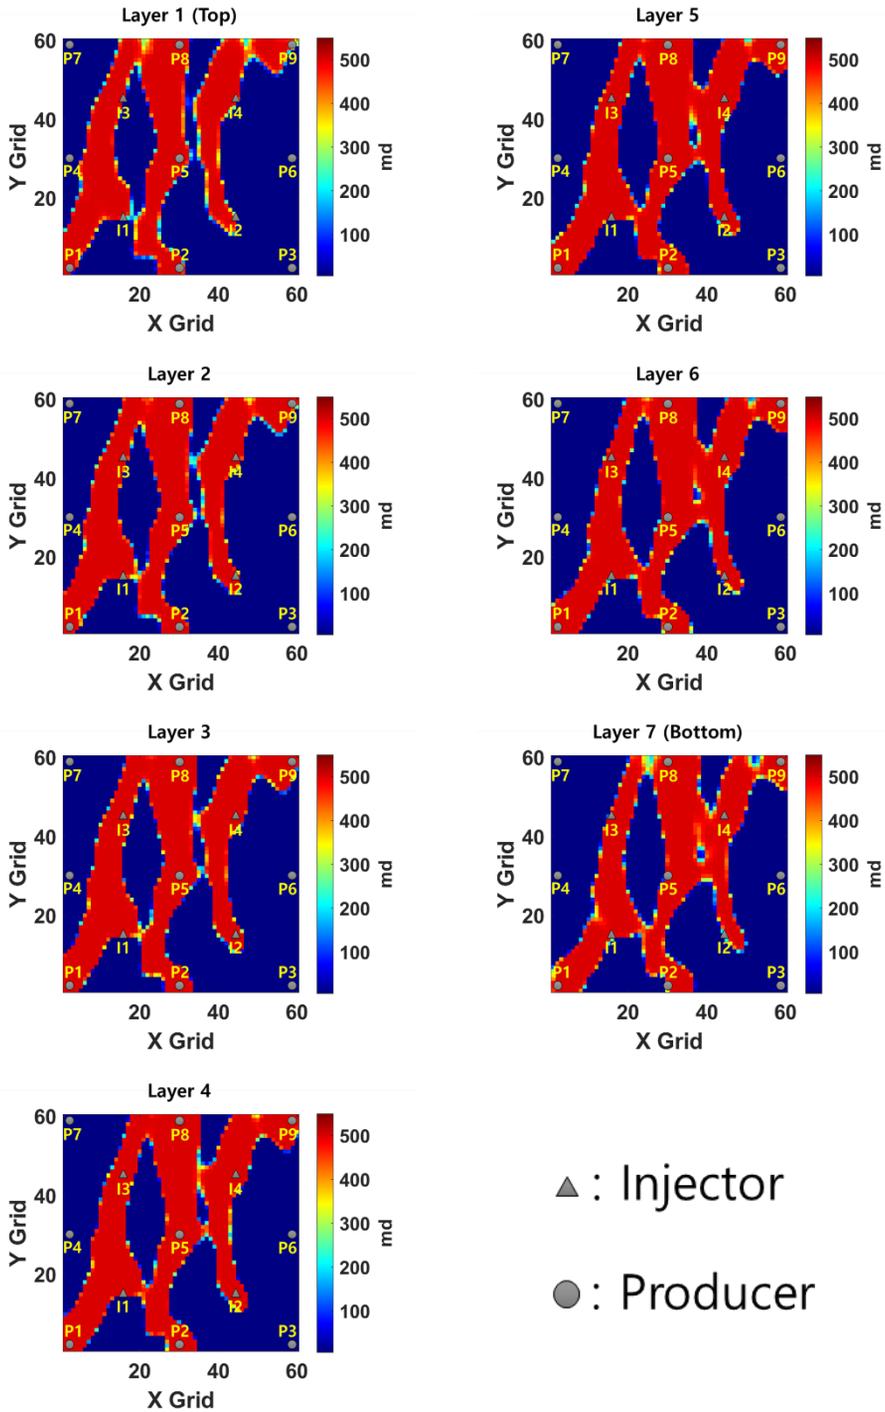


Fig. 3.56. Permeability distribution of the model in Fig. 3.39, updated using CVAE instead of beta-CVAE.

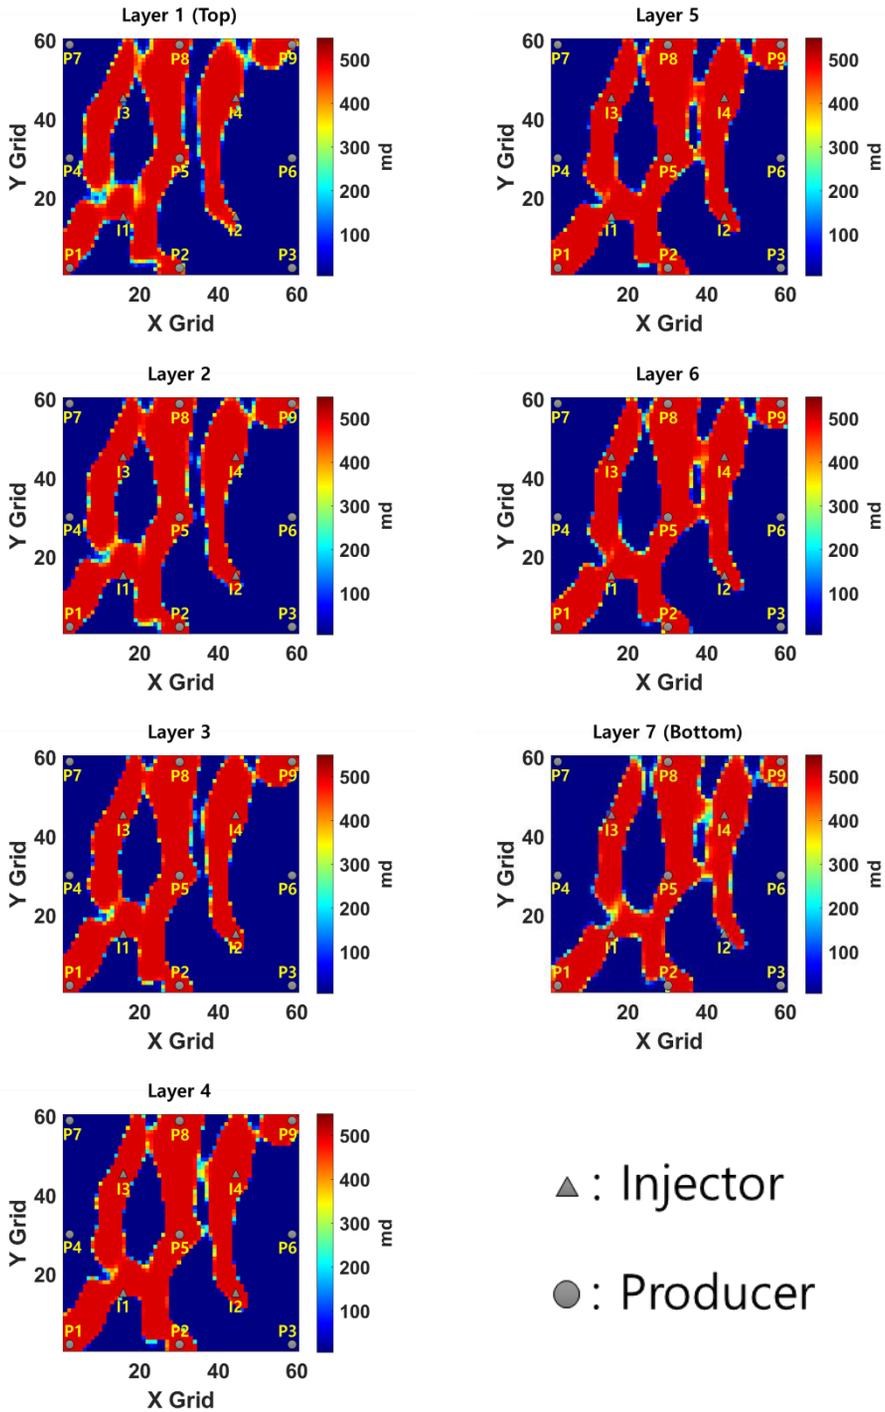


Fig. 3.57. Permeability distribution of the model in Fig. 3.40, updated using CVAE instead of beta-CVAE.

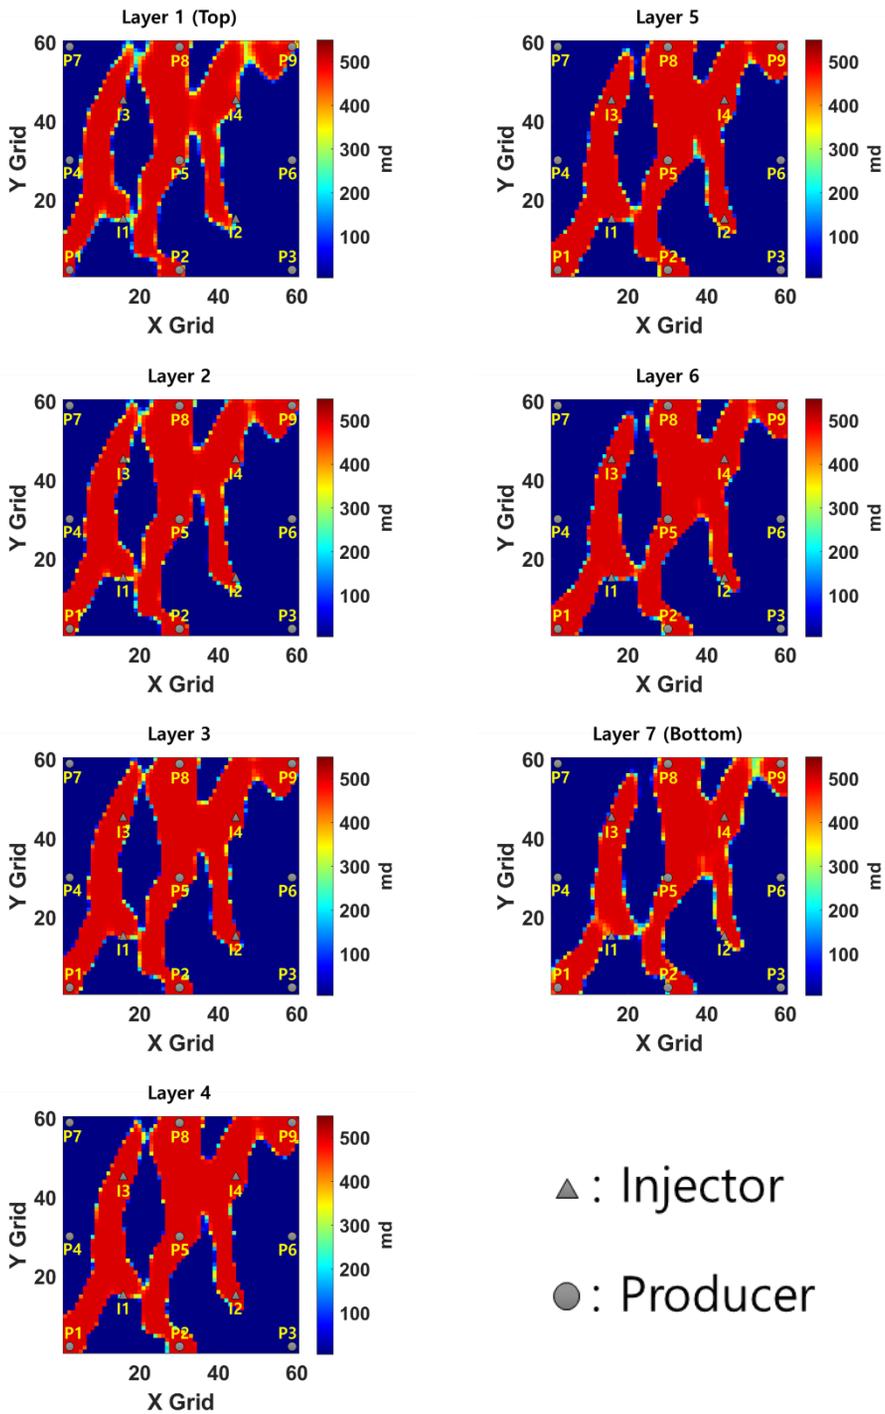


Fig. 3.58. Permeability distribution of the model in Fig. 3.41, updated using CVAE instead of beta-CVAE.

Fig. 3.59에 제시된 초기 앙상블의 생산량 예측은 대부분의 유정에서 완전히 참조 모델을 빗나가는 것을 볼 수 있는데, 이는 초기 앙상블의 채널 연결성이 무작위한 경향을 보였기 때문이다.

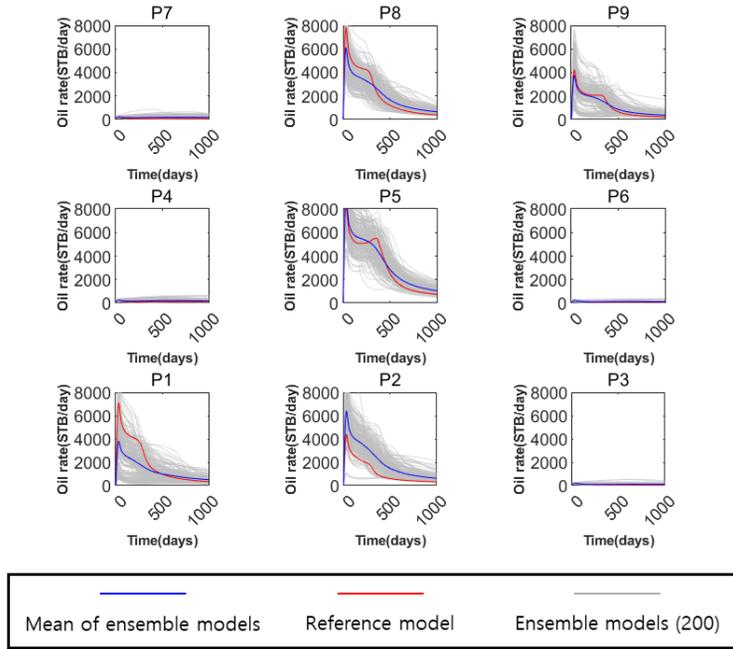
이러한 초기 앙상블을 제안하는 기법 및 두 가지 비교군으로 히스토리매칭한 뒤, 전위 시뮬레이션을 통해 1000일까지 오일 생산량과 워터컷을 예측해 참조 모델과 비교한 그래프를 Fig. 3.60-62에 나타내었다.

먼저 제안하는 기법을 사용한 히스토리매칭 결과, 업데이트된 앙상블들은 모든 유정에서 오일 생산량과 워터컷을 참조 모델과 비슷하게 예측했다. 불확실성 범위 또한 상당히 감소하여 적절한 수준을 유지했으며 참조 모델의 경향성이 불확실성 범위 내에 존재하면서 앙상블의 평균값은 참조 모델과 유사한 경향을 따르는, 앙상블 기법을 사용했을 때 기대할 수 있는 좋은 결과를 얻었다.

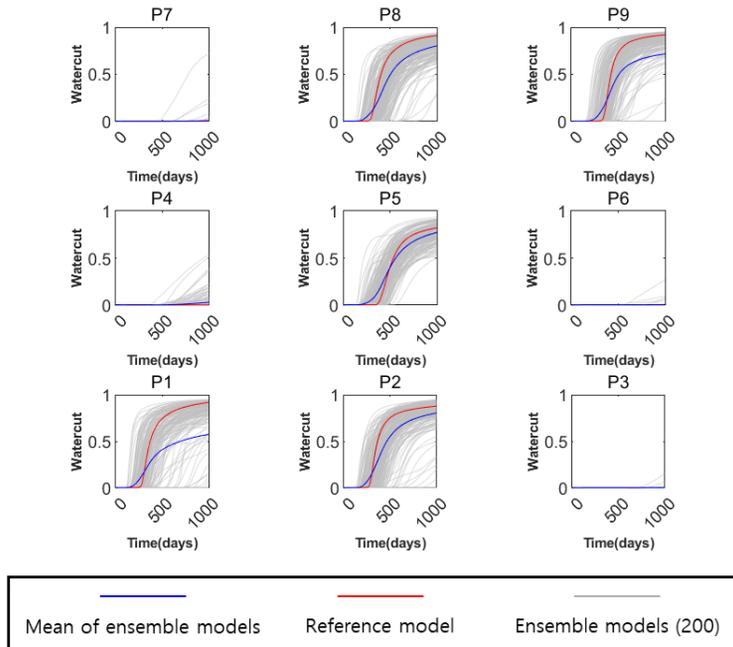
한편, CAE를 사용한 히스토리매칭은 앙상블의 평균값이 참조 모델과 유사한 경향을 따라가기는 한다. 하지만 Fig. 3.52-54에서 유체투과율 분포를 업데이트한 결과로부터 볼 수 있었던 앙상블 멤버 각각은 채널의 연결성을 잘 예측하지 못한 모델이 많았기 때문에 불확실성이 여전히 크게 나타난다. 특히 생산정 P9에서 이런 경향이 가장 두드러지는데, 다수의 앙상블 멤버들이 참조 모델보다 워터컷이 더 늦게 증가하는 것으로 예측하였다.

CVAE를 사용한 히스토리매칭 결과는 앙상블의 평균값이 참조 모델의 경향을 잘 예측하지 못한다. 특히 Fig. 3.55의 유체투과율 분포 예측 결과에서 연결성을 잘 찾지 못했던 주입정 I1 주변에 있는 세 생산정인 P1, P2, P5의 생산량 예측은 참조 모델을 완전히 빗나간다.

세 가지 기법으로 예측한 오일 생산량과 워터컷의 MAE를 계산하여 Table 3.13으로 정리하였다. 제안하는 기법은 참조 모델과 완전히 다른 예측을 했던 CVAE를 사용한 히스토리매칭 결과와 비교했을 때는 훨씬 낮은 MAE를 나타냈으며, CAE를 사용한 결과와 비교했을 때는 오일 생산량과 워터컷을 종합적으로 따졌을 때 약간 좋은 결과를 보였다.

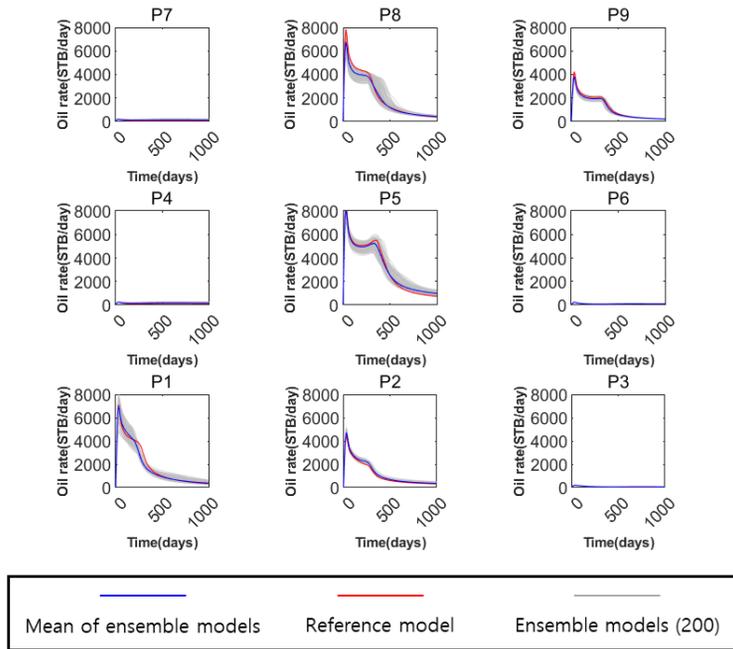


(a)

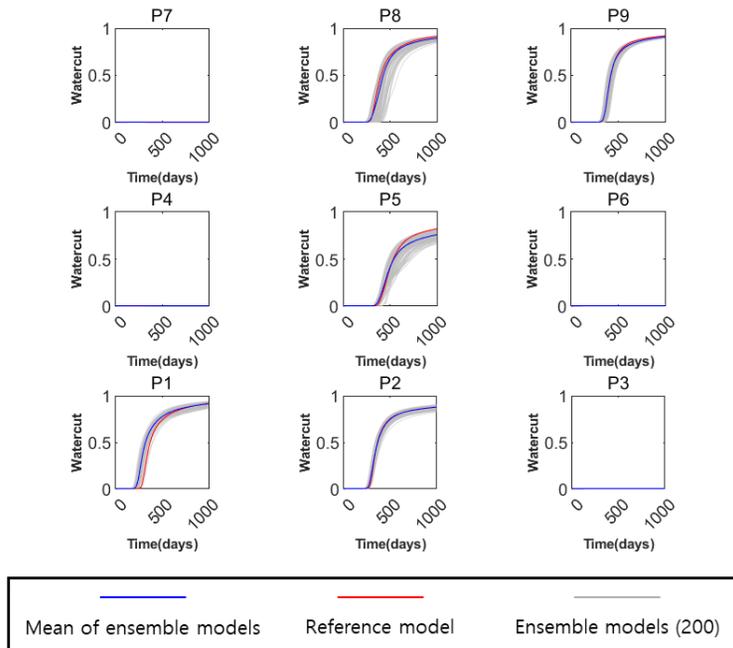


(b)

**Fig. 3.59.** Performance prediction of the initial ensemble models in case 3: (a) oil production, (b) watercut.

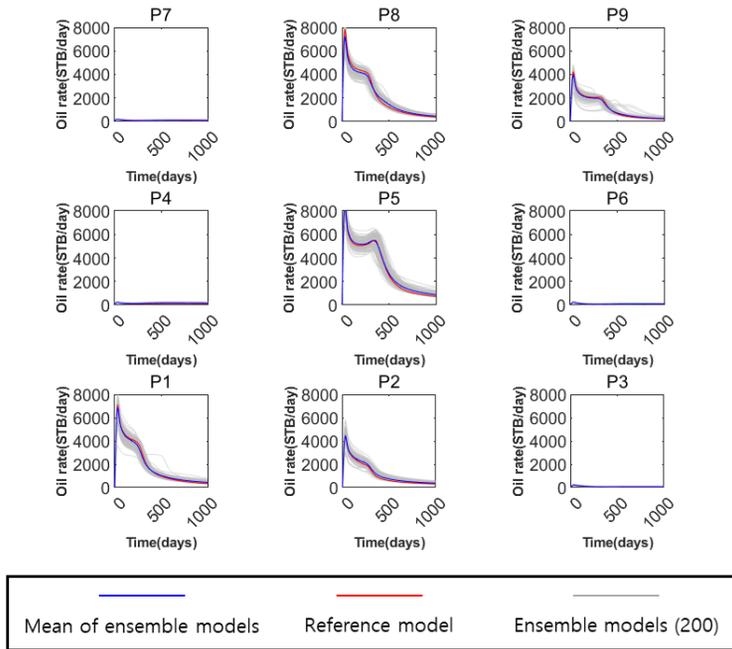


(a)

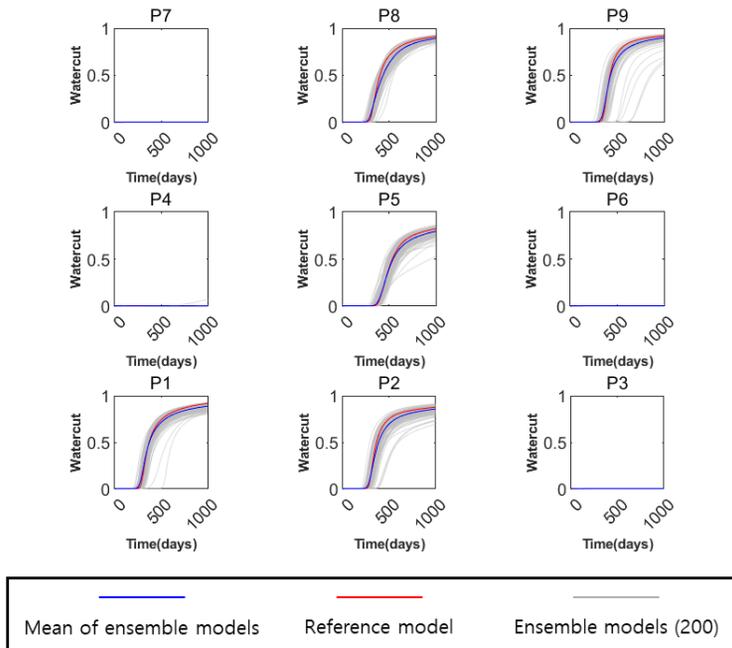


(b)

**Fig. 3.60.** Performance prediction of the updated models using the proposed method in case 3: (a) oil production, (b) watercut.

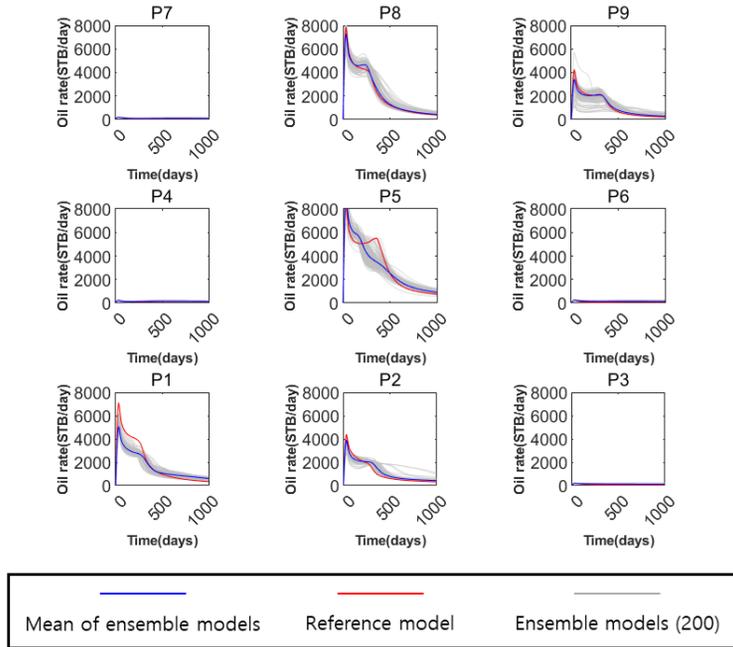


(a)

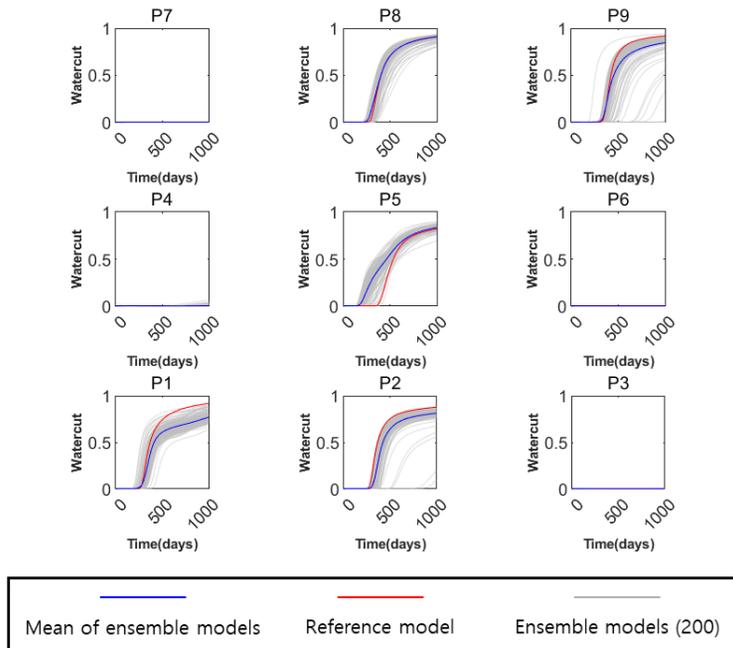


(b)

**Fig. 3.61.** Performance prediction of the updated models using CAE in case 3: (a) oil production, (b) watercut.



(a)



(b)

**Fig. 3.62.** Performance prediction of the updated models using CVAE in case 3: (a) oil production, (b) watercut.

**Table 3.13** MAE of oil rate and watercut prediction, case 3.

Reservoir models	MAE of oil rate	MAE of watercut
Initial models	441.44	$8.651 \times 10^{-2}$
Updated models using the suggested method	114.35	$1.659 \times 10^{-2}$
Updated models using CAE instead of beta-CVAE	110.21	$1.865 \times 10^{-2}$
Updated models using CVAE instead of beta-CVAE	204.25	$4.269 \times 10^{-2}$

### 3.2.3 Case 4 – 층에 따라 채널의 모양이 다른 모델

Fig. 3.63에 case 4의 모델을 만드는 데 사용한 트레이닝 이미지와 하드데이터를 제시하였다. 이 케이스 또한 case 3과 마찬가지로 모든 모델을 만드는 데 하나의 트레이닝 이미지와 하드데이터를 사용하였다. 트레이닝 이미지는 평면 상에서 남북 방향으로 채널이 뻗어 있는 것이 특징적이며, 수직 방향으로로는 아래로 내려갈수록 채널의 폭이 점점 좁아지는 형태를 띠고 있어 옆에서 봤을 때 타원의 일부와 유사한 모양을 하고 있다.

이 케이스는 층에 따라 채널의 경향이 변하는 모델이기 때문에 하드데이터로 제시된 13개 지점에서의 암상 자료 중 7개는 모든 층에서 사암이지만 3개 지점은 위의 2개 층에서는 사암, 아래 2개 층에서는 셰일이고 또 다른 3개 지점은 위의 2개 층에서는 셰일, 아래 2개 층에서는 사암이다.

Fig. 3.64는 이 트레이닝 이미지와 하드데이터로 SNESim을 사용하여 생성한 참조 모델의 유체투과율 분포와 유정 배치다. 트레이닝 이미지에서 특징적으로 나타나는 남북으로 뻗어있는 채널이 참조 모델에서도 마찬가지로 나타나며, 하드데이터의 영향을 받아 위의 2개 층과 아래의 2개 층의 채널 형태가 크게 다르다. 위의 2개 층은 왼쪽과

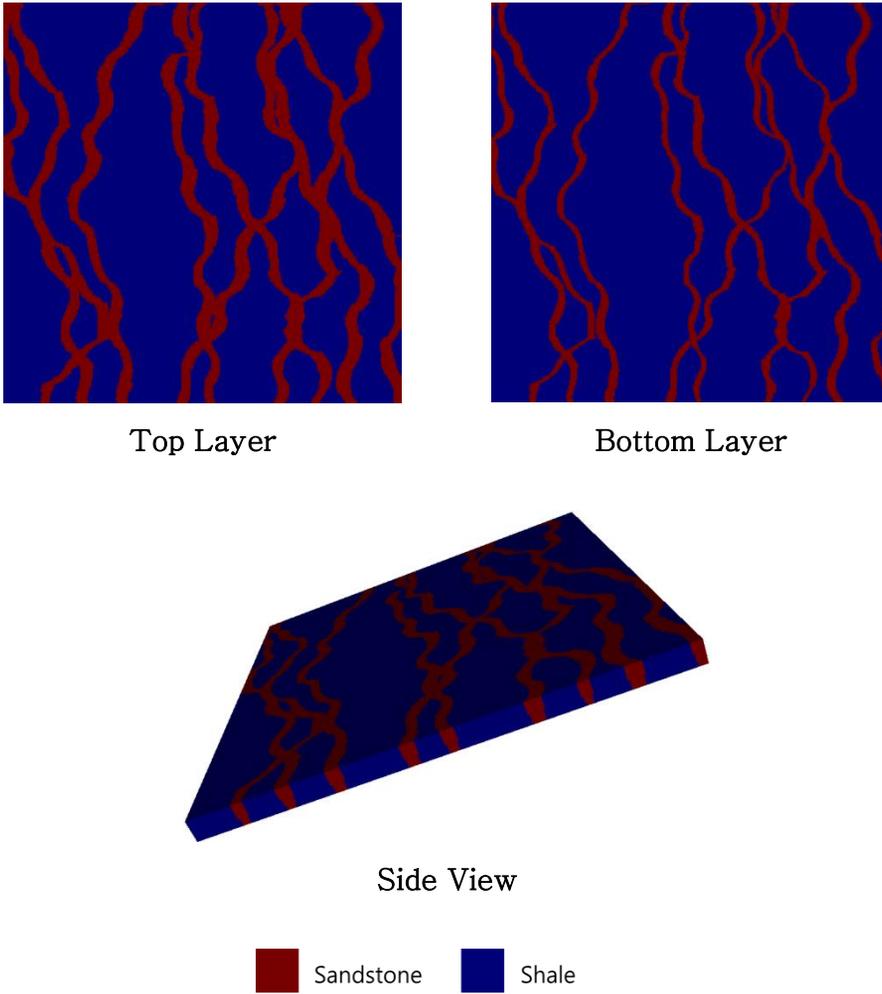
중앙의 남북 방향 채널이 서로 연결되어 있고 그 사이가 비어 있는 형태지만, 아래의 2개 층은 왼쪽과 오른쪽의 남북 방향 채널이 서로 분리되어 있는 형태다.

4개의 주입정과 9개의 생산정은 모두 다 채널 위에 있어 모든 생산정에서 유의미한 생산량이 관측된다. 하지만 가운데 3개의 생산정은 위의 2개 층에서만 채널과 연결되어 있고 오른쪽 3개의 생산정은 아래의 2개 층에서만 채널과 연결되어 있기 때문에 주입정이 각 층에서 영향을 끼치는 생산정이 다르다. 따라서 case 4는 층에 따라 달라지는 채널의 연결성이 생산 경향에 중요하게 작용한다.

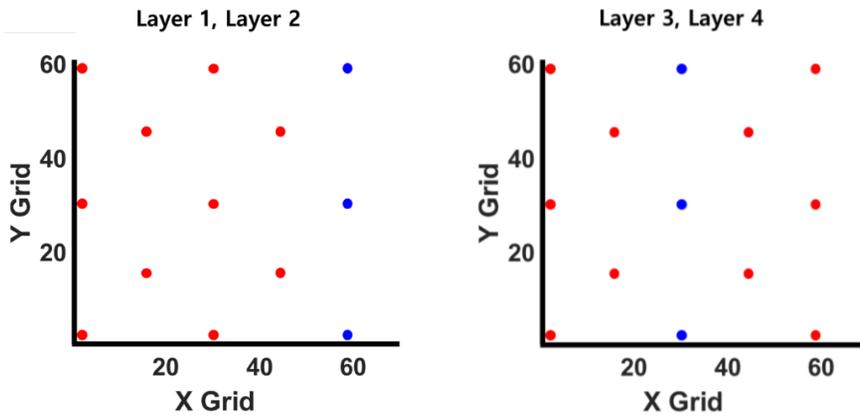
앞선 케이스들과 마찬가지로 초기 앙상블은 200개를 생성했다. 그 모델들의 평균 유체투과율 분포와 앙상블 멤버 중 3개를 선별하여 유체투과율 분포를 그린 것을 Fig. 3.65-68에 나타냈다.

초기 앙상블의 평균 유체투과율 분포는 참조 모델의 채널 형태와는 전혀 다르다. 트레이닝 이미지에서 부각되었던 남북 방향의 연결성은 어느 정도 나타나지만, 그 이외의 방향으로는 참조 모델에서 보이는 연결성을 찾아볼 수 없다. 예를 들어, 참조 모델에서 위의 2개 층은 중앙 왼쪽 부분이 비어 있는 형태를 하고 있지만 이런 경향은 초기 앙상블에서는 전혀 찾아볼 수 없다.

선별한 3개 모델의 유체투과율 분포를 보더라도 아래의 2개 층에서도 왼쪽 채널과 오른쪽 채널이 서로 연결되어 있는 등 참조 모델과 큰 차이를 보인다.



(a)



(b)

Fig. 3.63. (a) Training image and (b) hard data of case 4.

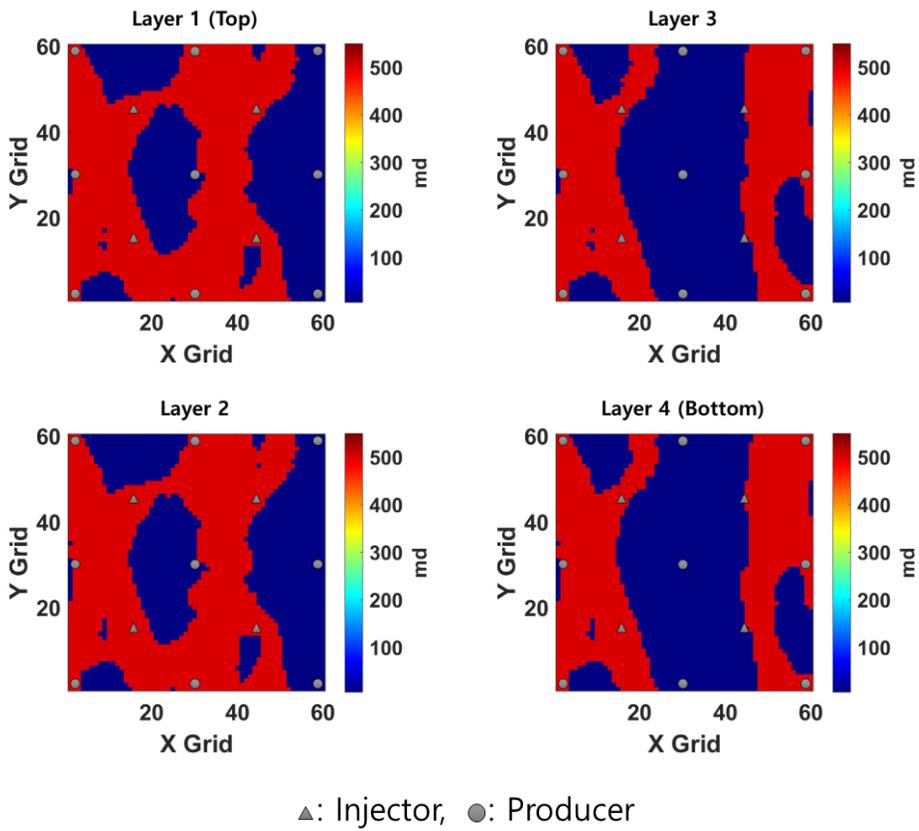


Fig. 3.64. The reference model of case 4.

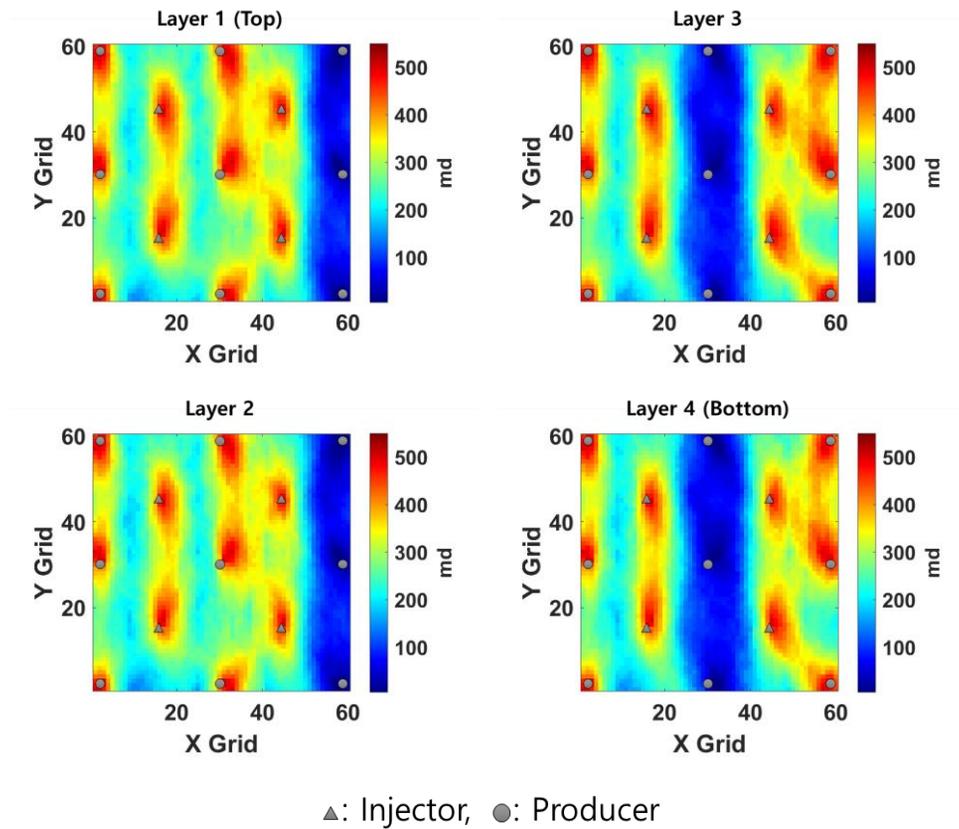


Fig. 3.65. Initial mean permeability distribution of case 4.

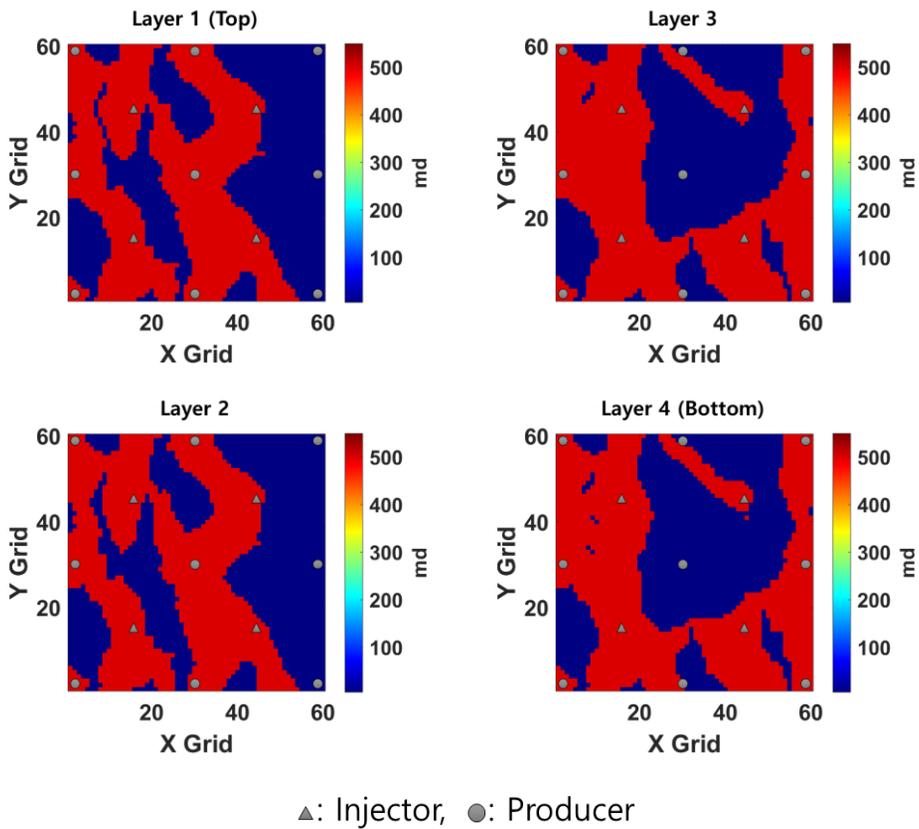


Fig. 3.66. Initial permeability distribution of model #1 in case 4.

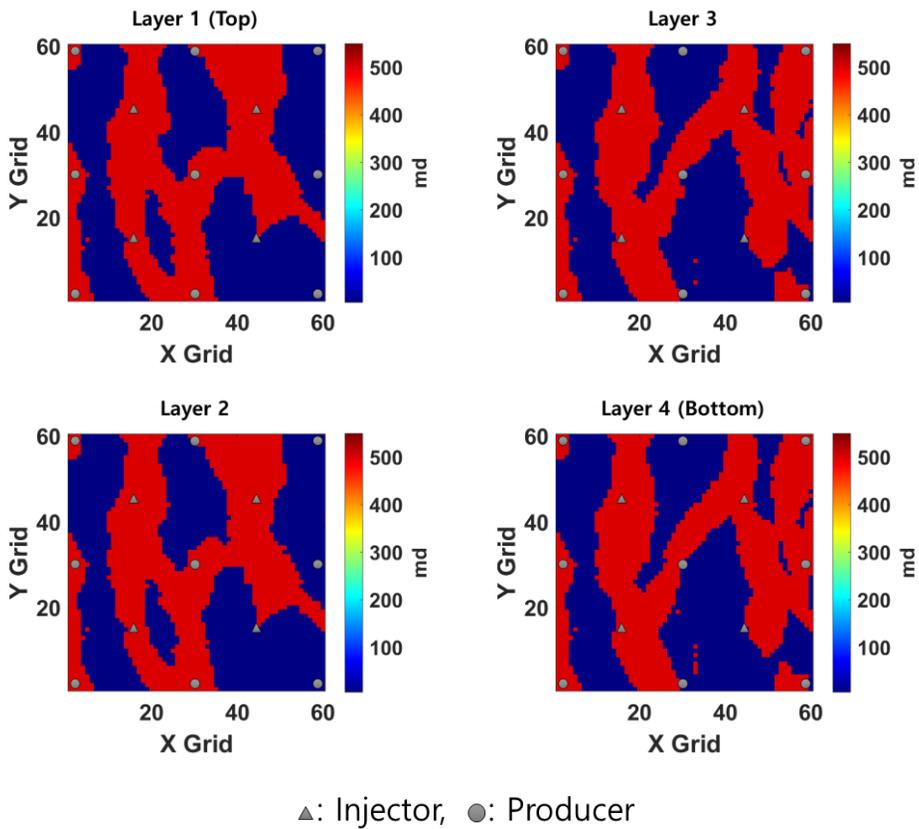
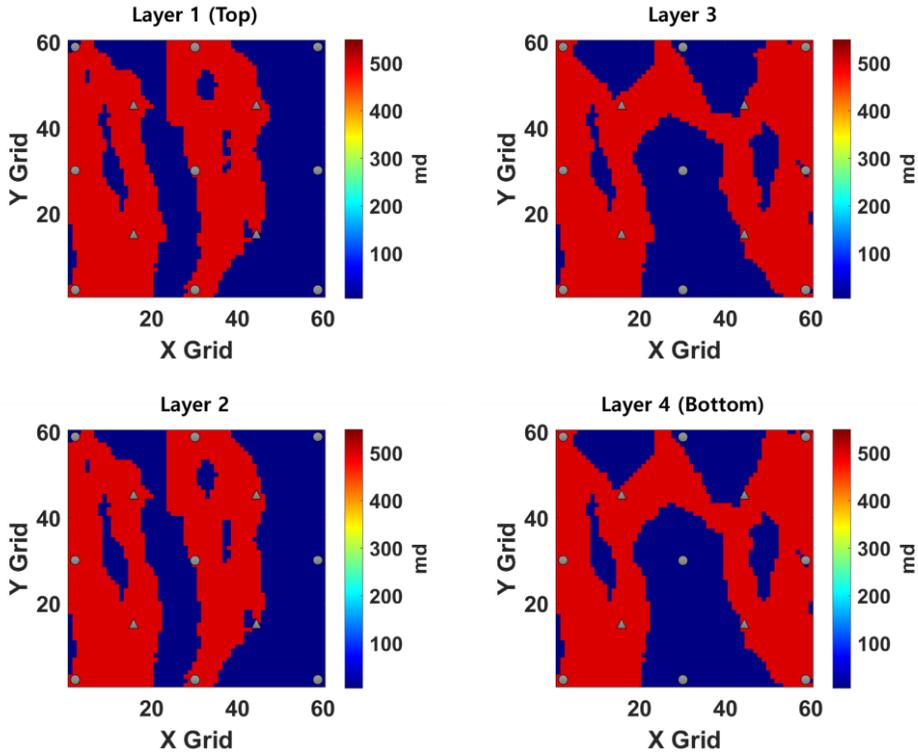


Fig. 3.67. Initial permeability distribution of model #2 in case 4.

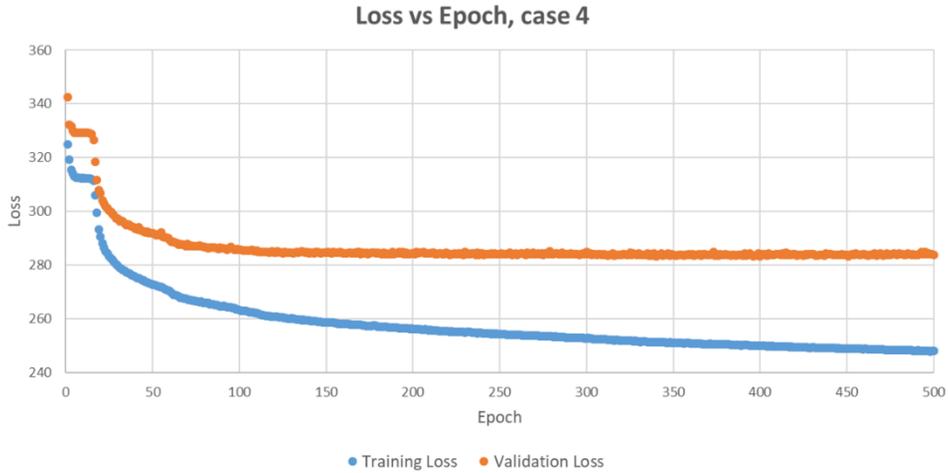


▲: Injector, ●: Producer

Fig. 3.68. Initial permeability distribution of model #3 in case 4.

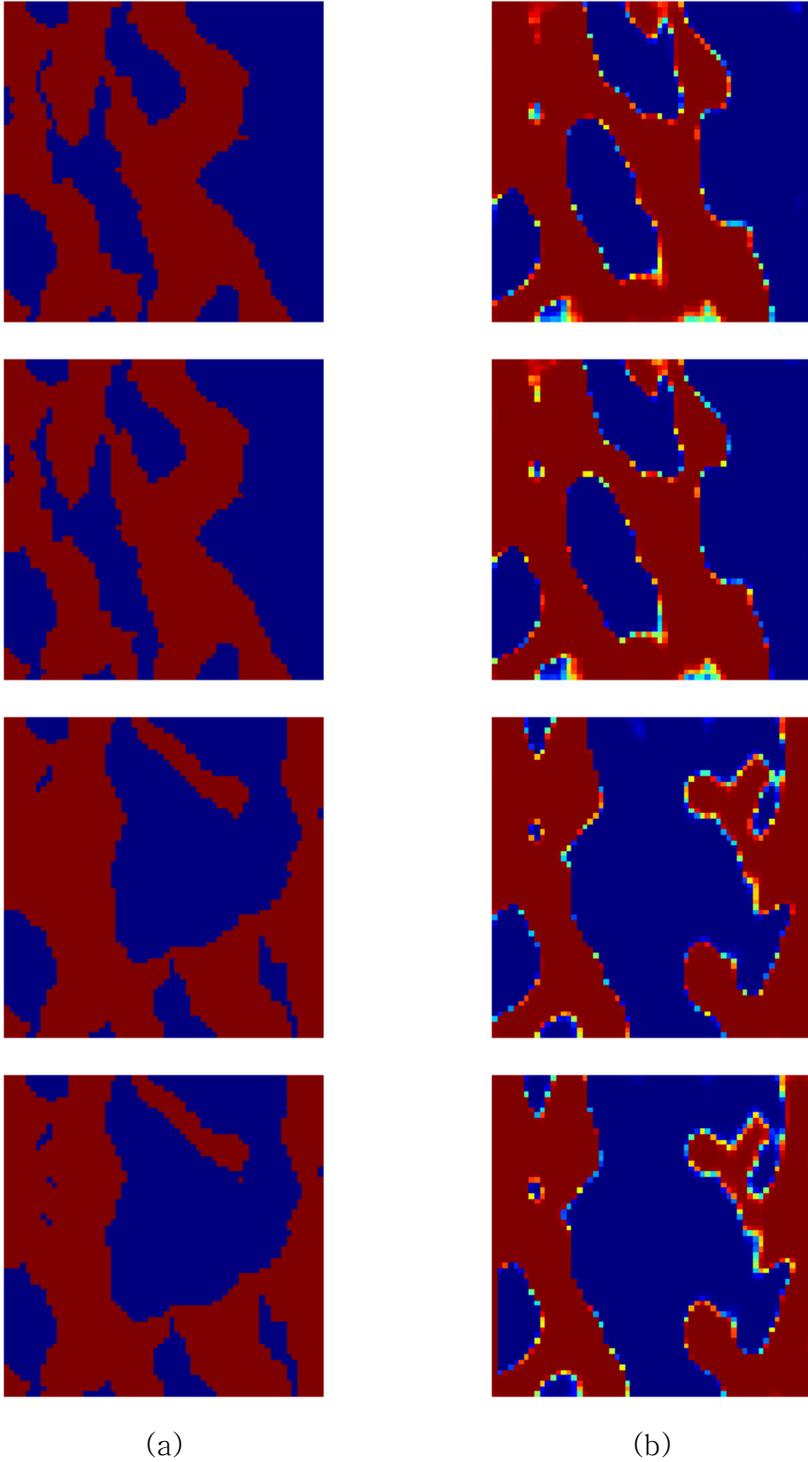
Beta-CVAE 네트워크 학습은 다른 케이스들과 비슷하게 초기 앙상블을 만들 때 사용한 자료를 똑같이 사용해서 중복되지 않는 950개 모델을 만들었다. 3D 저류층 모델이므로 3D 합성곱 계층을 사용하였고, 입력층과 출력층에 동일하게 정규화된 유체투과율 값을 넣어 네트워크를 학습시켰다.

Fig. 3.69는 학습 데이터와 검증 데이터의 손실 함수 값이 학습이 진행되면서 변해가는 양상을 나타낸 그래프다. 이 케이스 또한 학습이 진행될 수록 두 데이터의 손실 함수가 모두 감소하였지만, 어느 정도 진행된 후에 검증 데이터의 손실 함수가 다시 증가하는 과적합 현상이 발생한다. 따라서 과적합이 발생하기 전 검증 데이터의 손실 함수가 가장 낮은 값을 갖는 396번째 epoch의 모델을 선정해 이후 case 4의 히스토리매칭에 사용하였다.

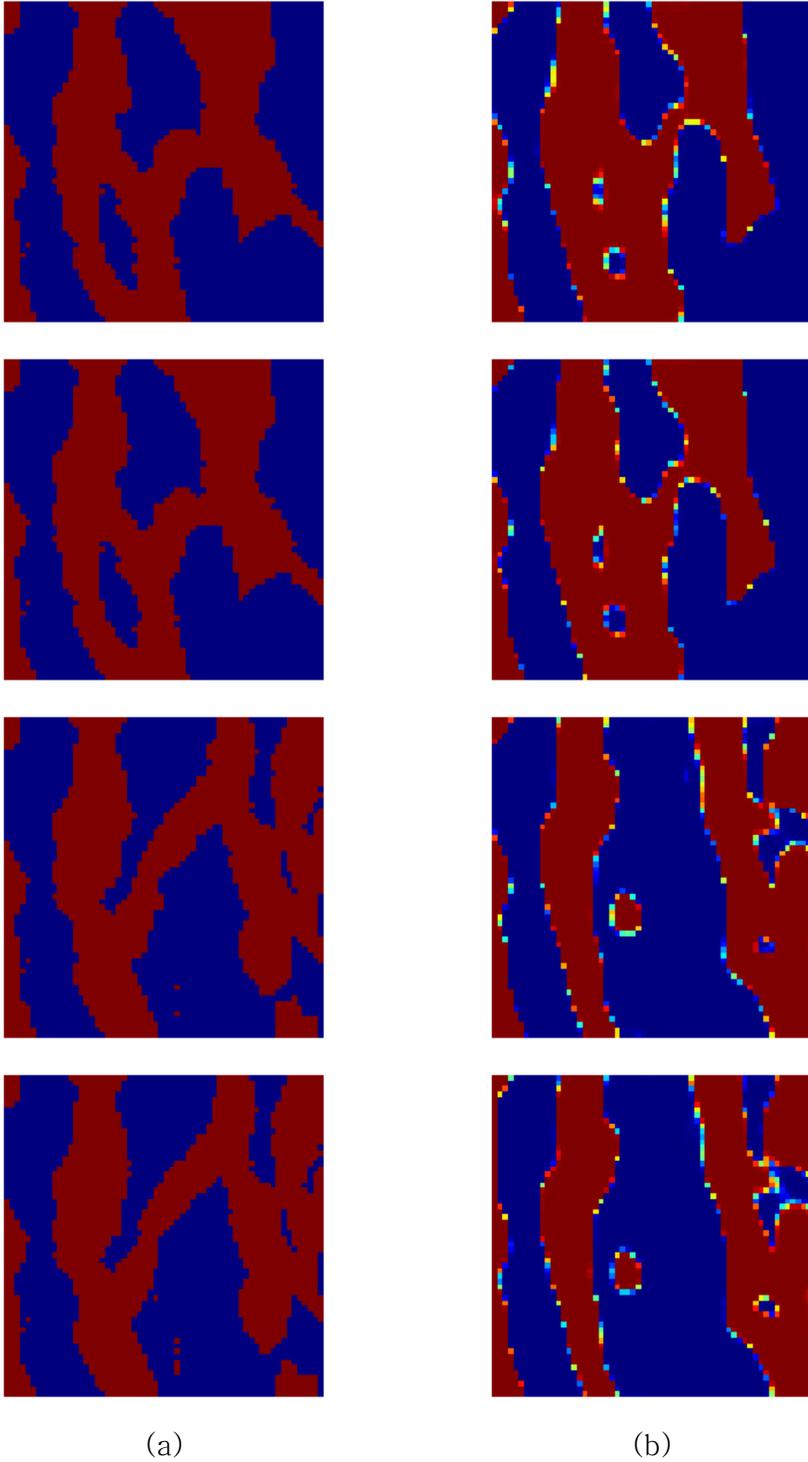


**Fig. 3.69.** Training loss and validation loss vs epoch in case 4.

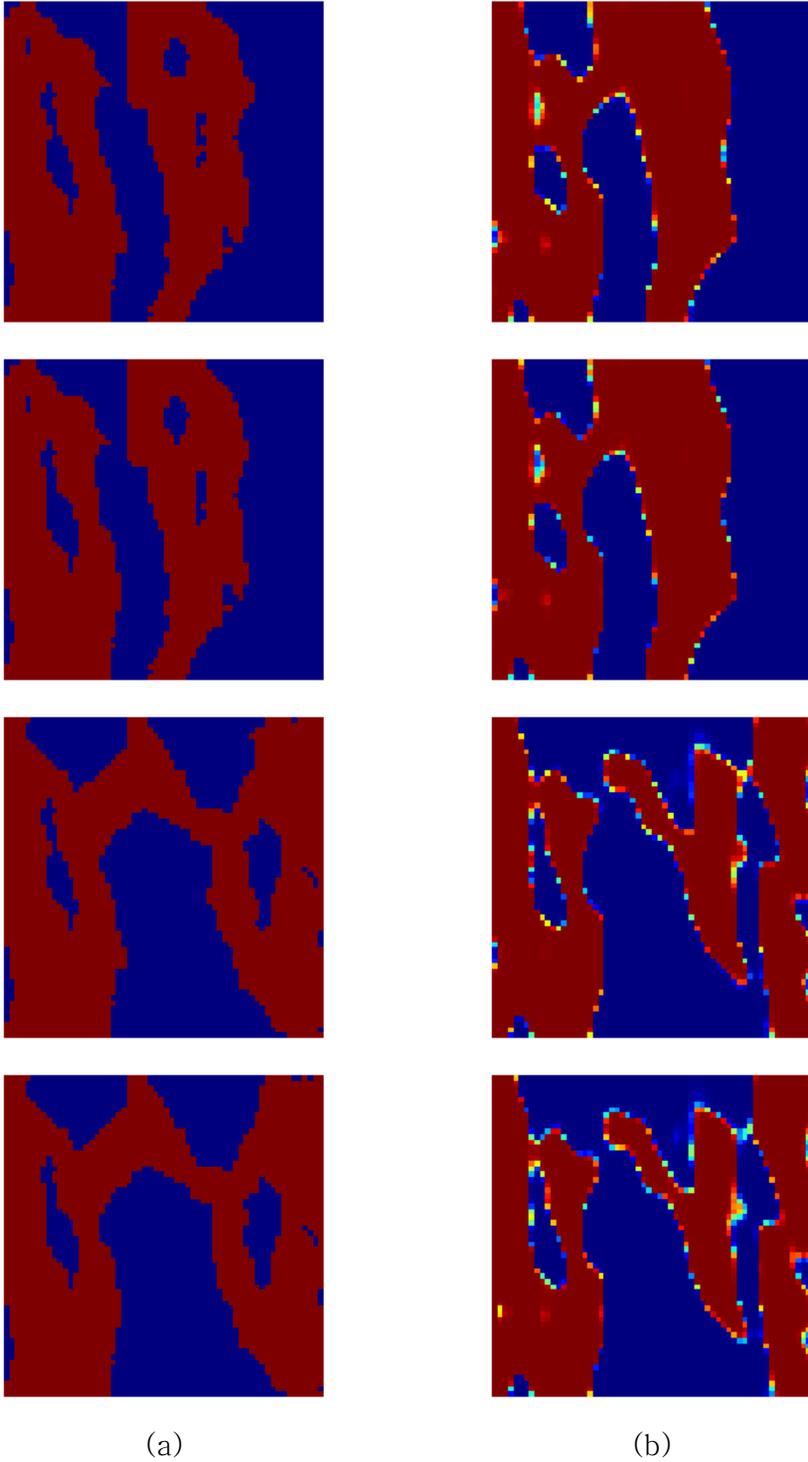
선정한 beta-CVAE 모델을 사용하여 Fig. 3.66-68에 있는 초기 앙상블 중 일부 모델들을 인코딩 후 디코딩한 결과를 Fig. 3.70-72에 나타내었다. 이 과정에서 자료의 손실이 발생하기 때문에 채널의 세부적인 디테일이나 아웃라이어까지 완벽하게 재현할 수는 없었다. 하지만 가장 지배적인 연결 경향인 남북 방향의 연결성을 잘 파악해서 복원했으며, 층에 따라 달라지는 채널 모양 또한 잘 학습한 것을 확인할 수 있다.



**Fig. 3.70.** Reconstruction of model #1 using beta-CVAE in case 4:  
(a) original model, (b) corresponding reconstruction.



**Fig. 3.71.** Reconstruction of model #2 using beta-CVAE in case 4:  
(a) original model, (b) corresponding reconstruction.



**Fig. 3.72.** Reconstruction of model #3 using beta-CVAE in case 4:  
(a) original model, (b) corresponding reconstruction.

제안하는 기법의 히스토리매칭 결과를 평가하기 위해 업데이트 후 앙상블의 평균 유체투과율 분포와 오일 생산량 및 워터컷 예측값, 그리고 예측값의 MAE를 참조 모델과 비교하였다. 비교군은 제안하는 기법에서 beta-CVAE 대신 CAE와 CVAE를 사용한 알고리즘으로 히스토리매칭한 결과로, 총 2가지를 사용하였다.

참조 모델의 유체투과율 분포와 히스토리매칭이 끝난 앙상블의 평균 유체투과율 분포를 각각 Fig. 3.73과 Fig. 3.74에 그려서 비교하였다. 그 결과, 제안하는 기법을 사용했을 때 초기 앙상블에서는 찾아볼 수 없었던 참조 모델과 유사한 채널 연결성을 갖도록 업데이트되었다. 이것이 가장 두드러지게 나타나는 점은 업데이트 후의 모델에서 위의 2개 층에서는 가운데가 비어 있는 형태로 연결된 채널이 나타나며 아래의 2개 층에서는 좌우의 채널이 서로 분리되어 있는 점이다.

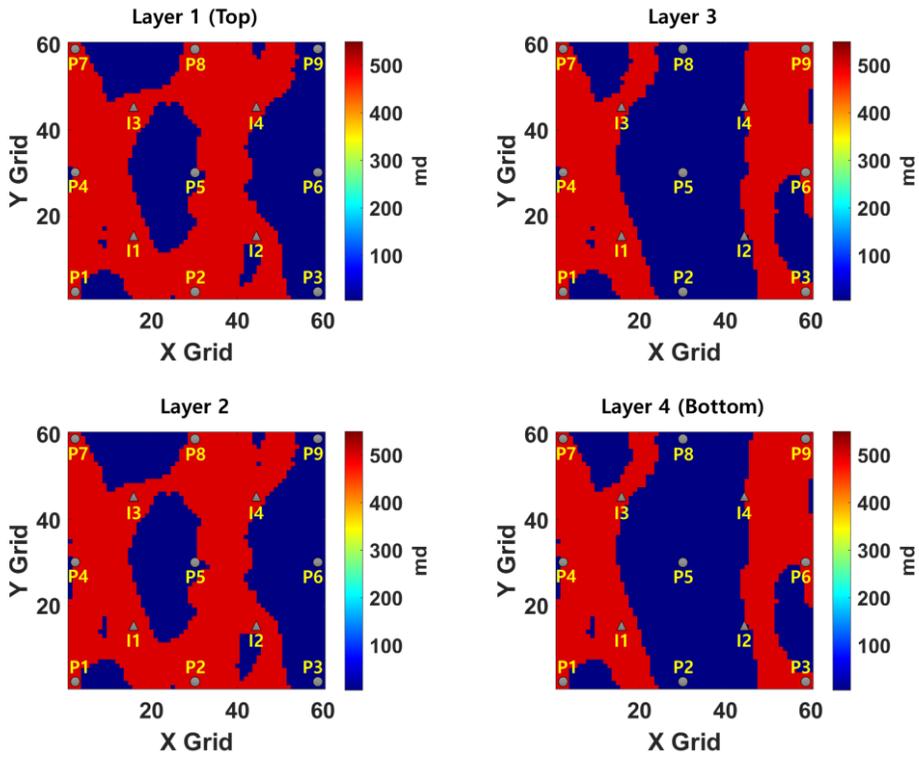
채널의 모양뿐만 아니라 채널의 연결 상태도 잘 파악하였다. 각 주입정으로 물을 주입했을 때 주변의 가까운 생산정들 중 영향을 직접적으로 받는 생산정과 영향을 받지 않는 생산정을 분리했으며 층에 따라 달라지는 연결성 또한 올바르게 찾았다. 이는 평균 유체투과율 분포를 그린 그림을 포함하여, Fig. 3.75-77에 제시된 일부 모델의 히스토리매칭 결과에서도 확인할 수 있다.

Fig. 3.78은 첫 번째 비교군으로 사용한, 제안하는 기법의 beta-CVAE 대신 CAE를 이용하여 히스토리매칭한 모델의 평균 유체투과율 분포를 그린 것이다. 이 비교군의 알고리즘은 채널의 대략적인 경향을 파악하는 데는 성공했으나 참조 모델의 연결성을 잘 예측하지 못하거나 약하게 예측한 부분이 많이 나타난다.

특히 위의 2개 층에서 주입정 I3과 생산정 P8 사이의 연결 및 주입정 I2와 생산정 P2 사이의 연결을 매우 약하게 예측했으며, 아래의 2개 층에서도 오른쪽 채널의 주입정 I2와 생산정 P6 사이의 연결성을 약하게 예측하였다. Fig. 3.79-81의 일부 모델의 히스토리매칭 결과에서도 이와 같은 경향성이 나타나며, 특히 위의 2개 층에서의 연결성을 잘 예측하지 못한 것이 드러난다.

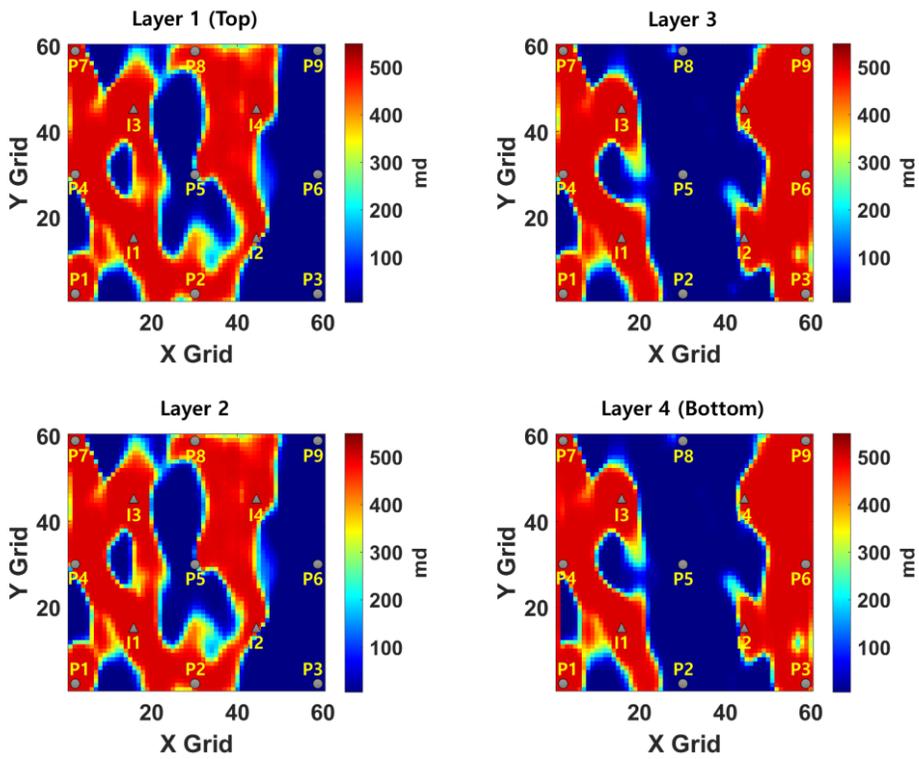
두 번째 비교군으로 사용한, 제안하는 기법의 beta-CVAE 대신 CVAE를 이용하여 히스토리매칭한 모델의 평균 유체투과율 분포와 일부 모델의 유체투과율 분포를 각각 Fig. 3.82와 Fig. 83-85에 제시하였다. 이 비교군은 연결성은 강하게 나타나지만 그 연결성이 참조 모델과 다른 경우가 많다.

첫 번째로, 참조 모델에서 주입정 I1과 생산정 P1은 직선 방향으로 연결되어 있으나 업데이트된 앙상블은 직선 방향은 세일로 막혀 있고 우회하는 방향으로 연결되어 주입한 물이 도착하는 시간에서 참조 모델과 차이가 있다. 두 번째로, 아래의 2개 층에서 주입정 I2가 생산정 P5와 직접 연결되어 있지는 않으나 어느 정도 채널이 형성되어 있어 층간 유동을 통해 P5에 영향을 미칠 가능성이 있다. 이런 점을 고려했을 때 두 번째 비교군 또한 제안하는 기법과 비슷한 수준의 히스토리매칭 결과를 제시했다고 볼 수 없다.



▲: Injector, ●: Producer

Fig. 3.73. Permeability distribution and well placement of the reference model of case 4.



▲: Injector, ●: Producer

Fig. 3.74. Mean permeability distribution of case 4, updated by the proposed method.

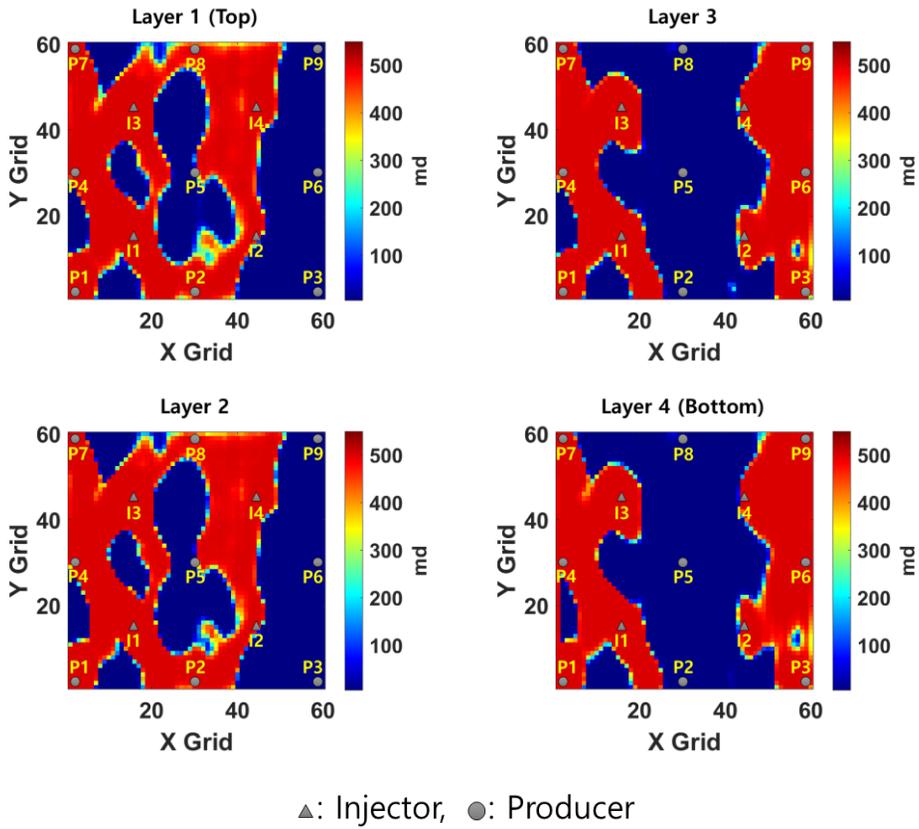
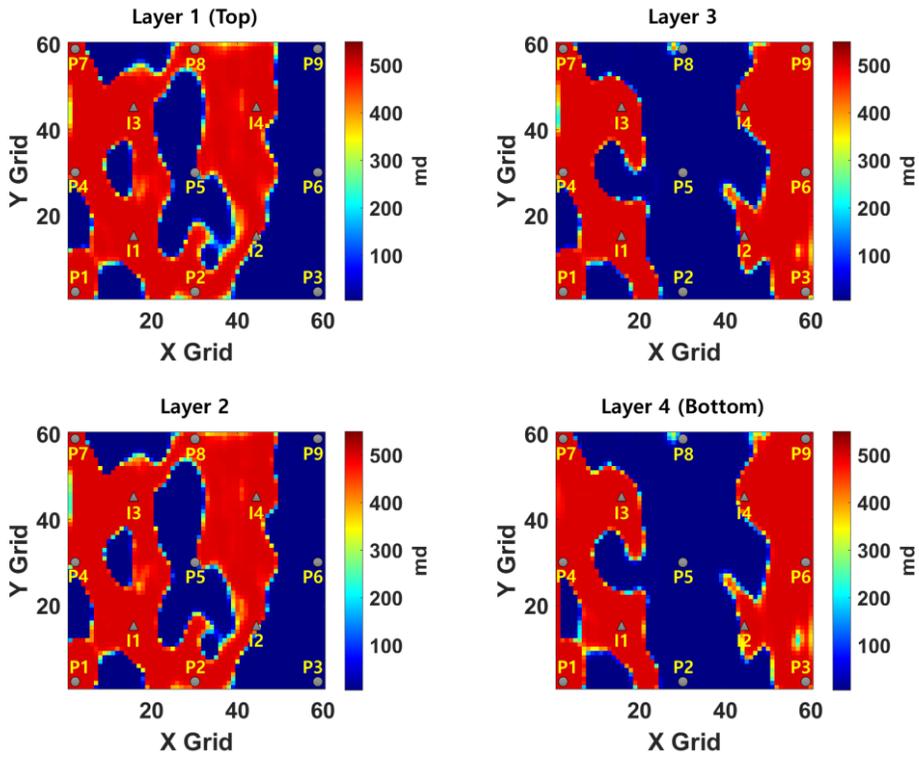
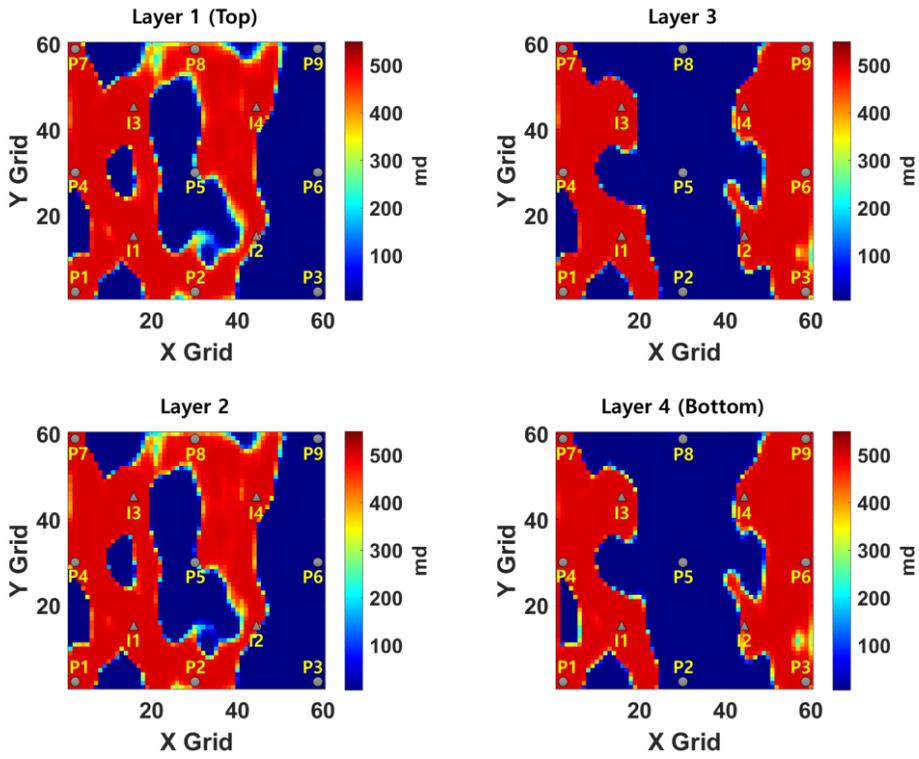


Fig. 3.75. Permeability distribution of the model in Fig. 3.66, updated by the proposed method.



▲: Injector, ●: Producer

Fig. 3.76. Permeability distribution of the model in Fig. 3.67, updated by the proposed method.



▲: Injector, ●: Producer

Fig. 3.77. Permeability distribution of the model in Fig. 3.68, updated by the proposed method.

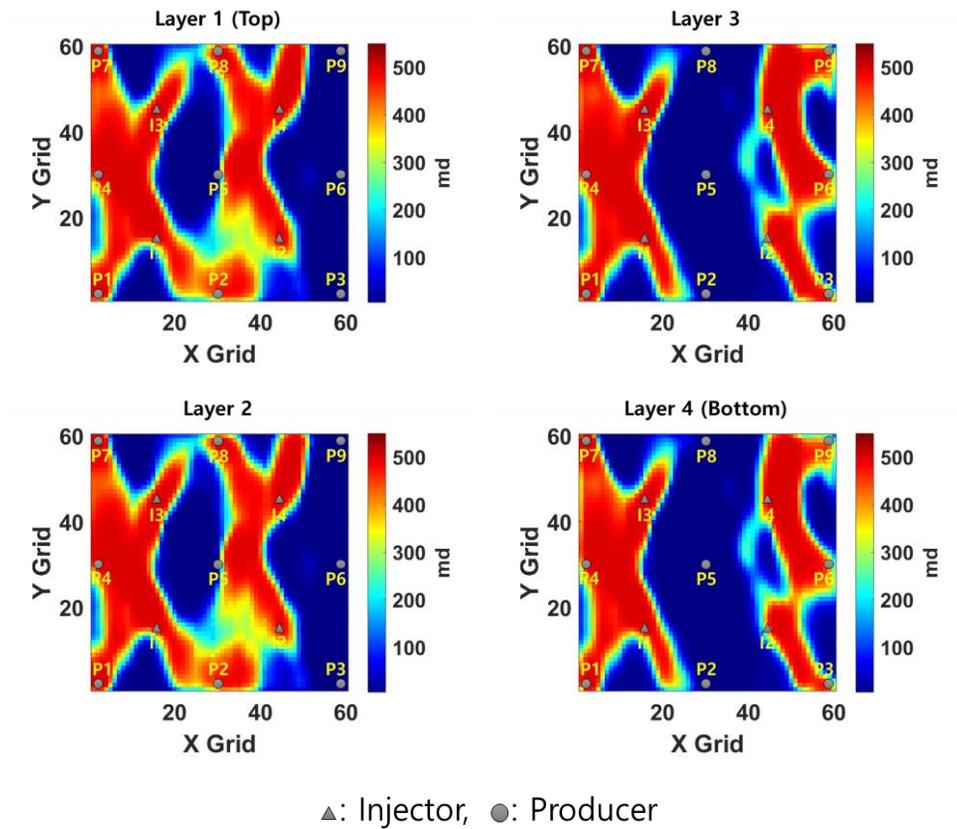
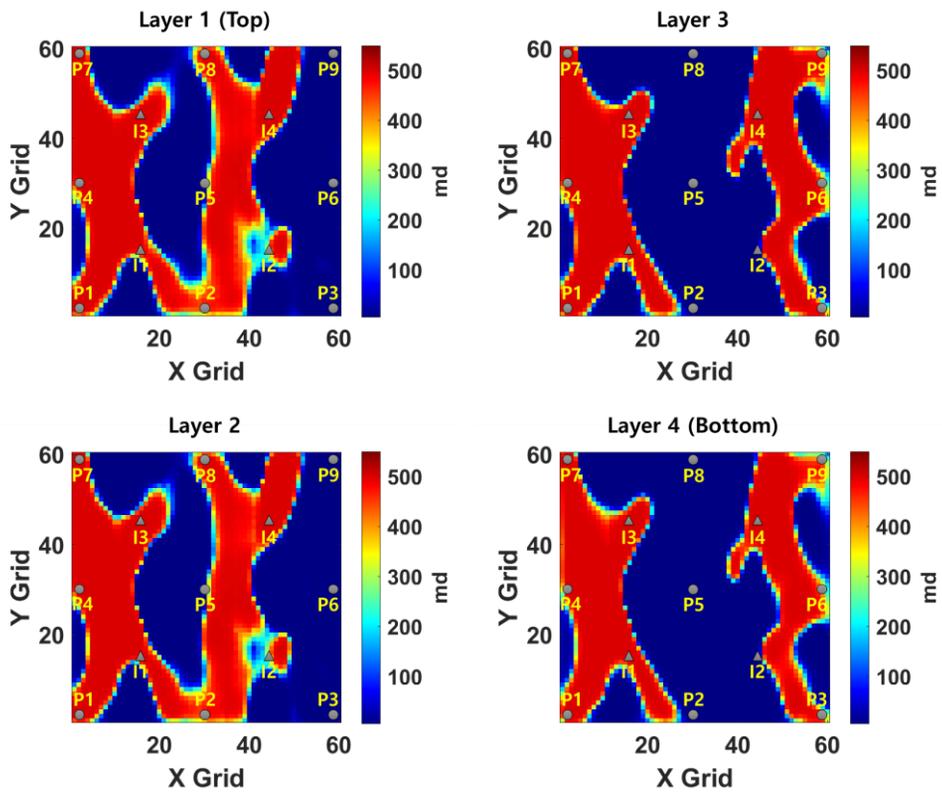
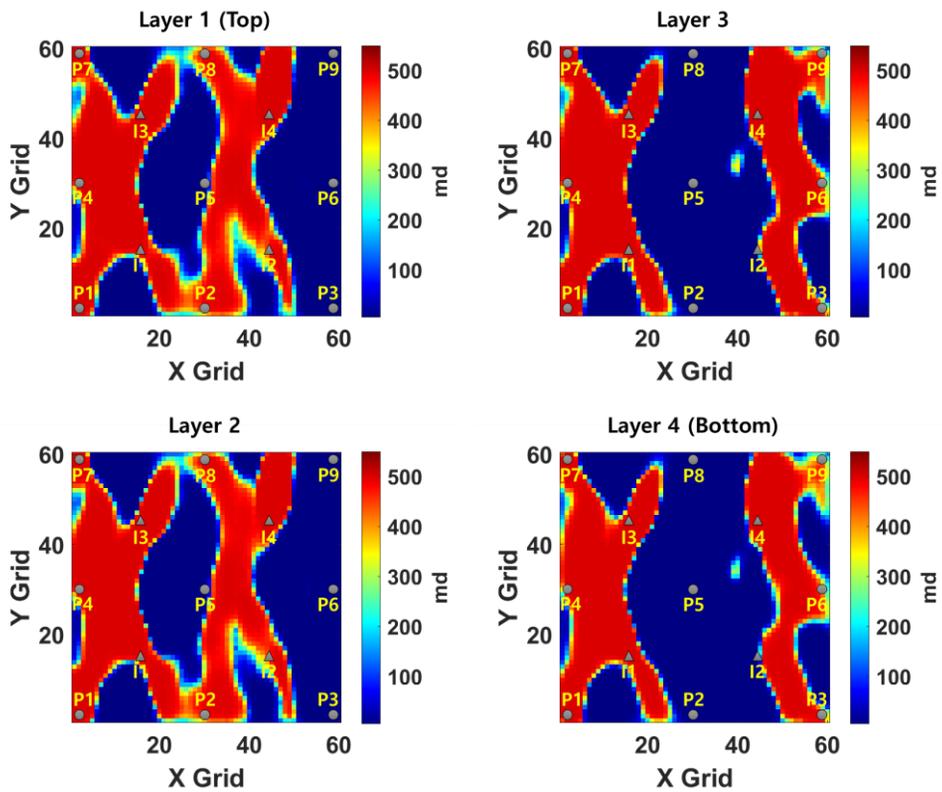


Fig. 3.78. Mean permeability distribution of case 4, updated using CAE instead of beta-CVAE.



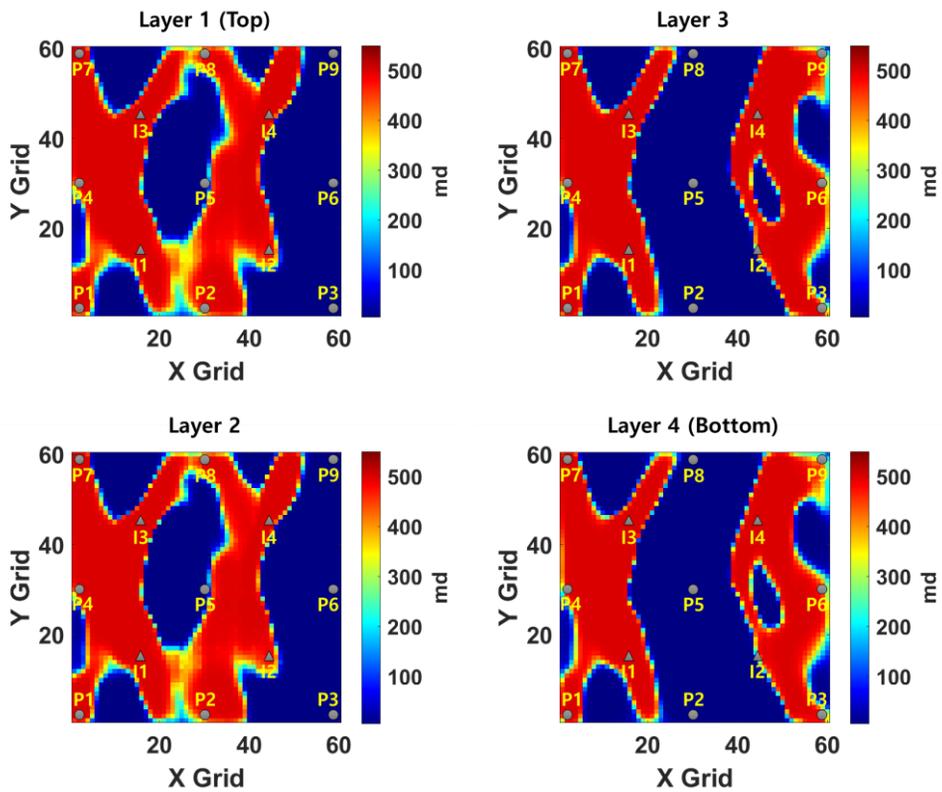
▲: Injector, ●: Producer

Fig. 3.79. Permeability distribution of the model in Fig. 3.66, updated using CAE instead of beta-CVAE.



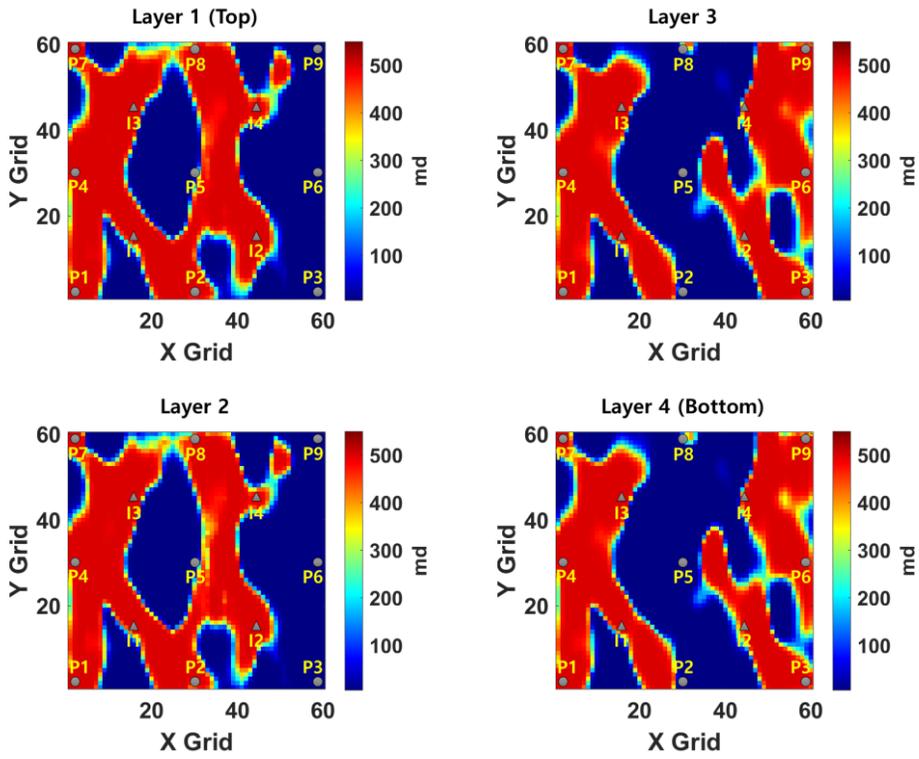
▲: Injector, ●: Producer

Fig. 3.80. Permeability distribution of the model in Fig. 3.67, updated using CAE instead of beta-CVAE.



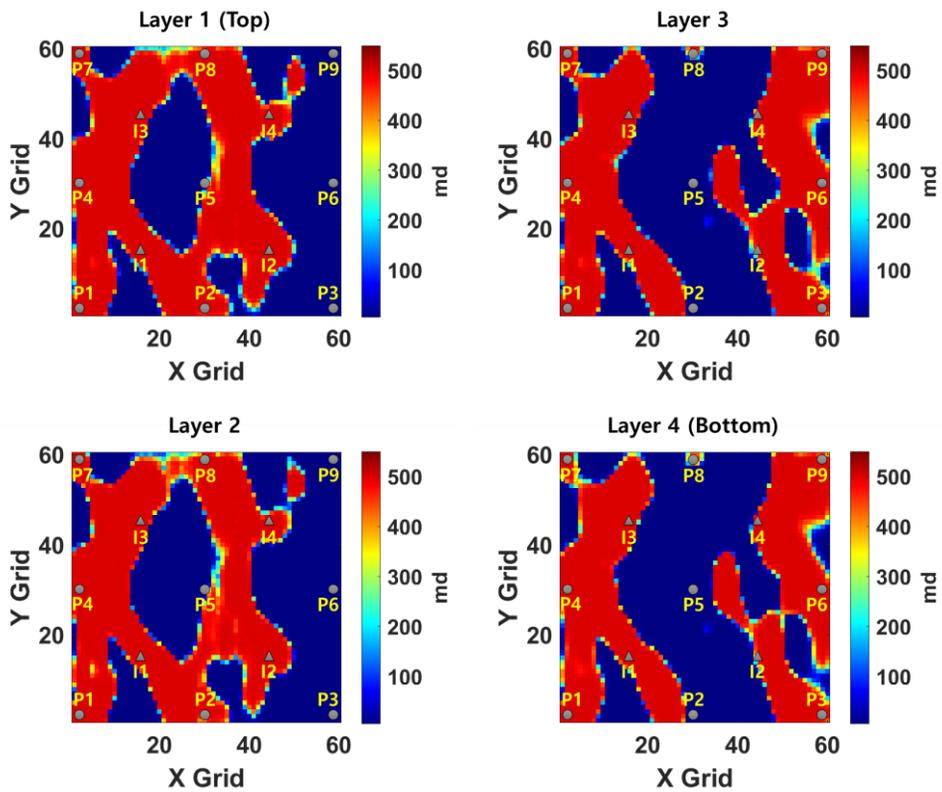
▲: Injector, ●: Producer

Fig. 3.81. Permeability distribution of the model in Fig. 3.68, updated using CAE instead of beta-CVAE.



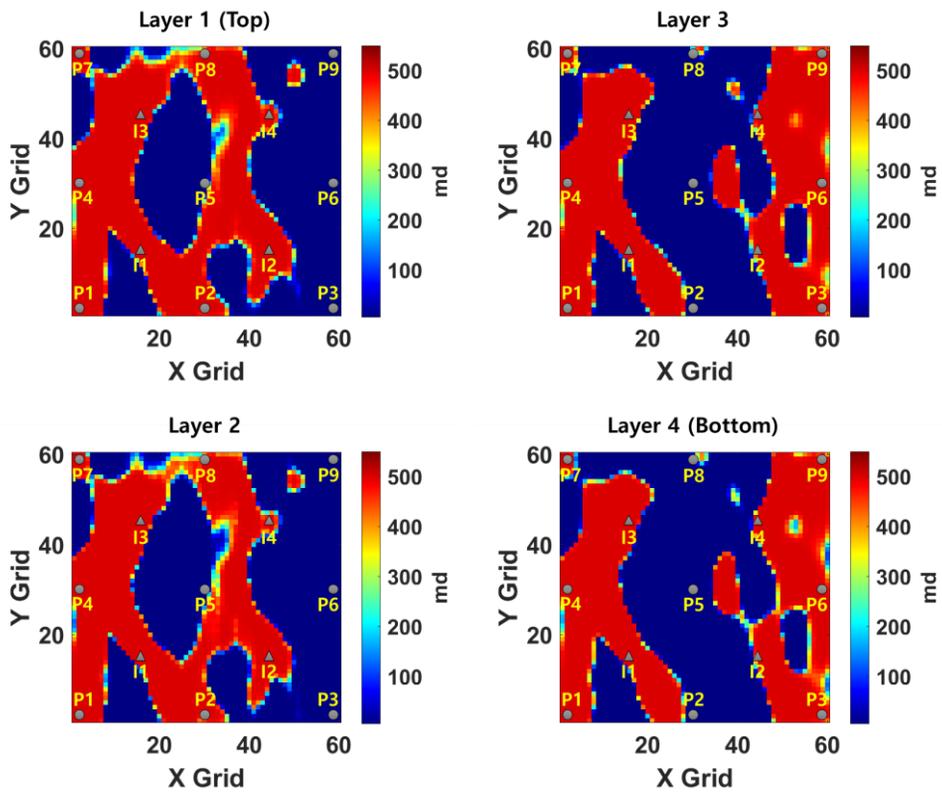
▲: Injector, ●: Producer

Fig. 3.82. Mean permeability distribution of case 4, updated using CVAE instead of beta-CVAE.



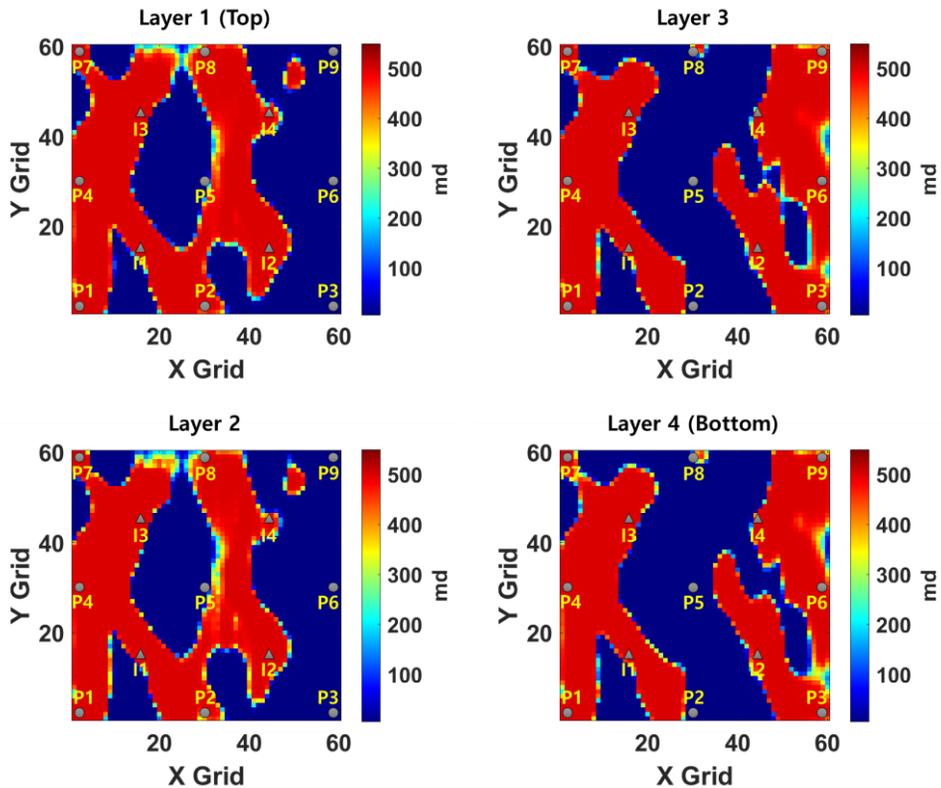
▲: Injector, ●: Producer

Fig. 3.83. Permeability distribution of the model in Fig. 3.66, updated using CVAE instead of beta-CVAE.



▲: Injector, ●: Producer

Fig. 3.84. Permeability distribution of the model in Fig. 3.67, updated using CVAE instead of beta-CVAE.



▲: Injector, ●: Producer

Fig. 3.85. Permeability distribution of the model in Fig. 3.68, updated using CVAE instead of beta-CVAE.

히스토리매칭 하기 전 초기 앙상블의 생산량 예측 그래프는 Fig. 3.86과 같으며, 거의 대부분의 유정에서 오일 생산량과 워터컷을 신뢰할 수 있게 예측하지 못하였다. 이 초기 앙상블을 제안하는 기법과 두 가지 비교군을 사용해 히스토리매칭 하여 업데이트하였고, 업데이트된 저류층 모델을 전위 시뮬레이션을 통해 1000일까지의 오일 생산량과 워터컷 예측값을 계산하여 Fig. 3.87-89로 나타내었다.

제안하는 기법을 사용하여 업데이트한 모델의 생산량 그래프는 초기 앙상블과는 달리 모든 유정에서 참조 모델의 생산 경향과 앙상블의 생산 경향이 유사하게 나타나며 불확실성 폭도 크게 감소하였다. 이는 앙상블 기법을 사용했을 때의 추계학적 결과도 제시하는 동시에 평균적으로

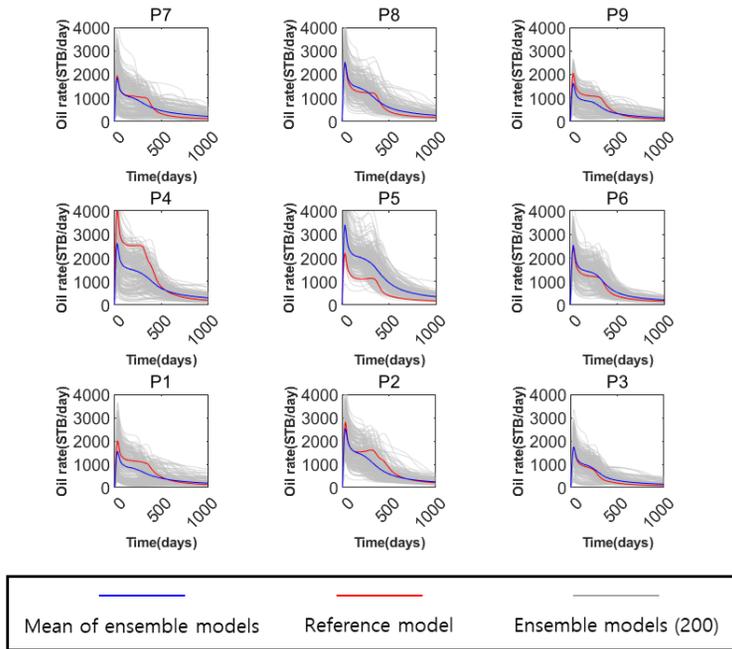
참조 모델의 생산 경향을 잘 따라갔기 때문에 신뢰할 수 있는 히스토리매칭 결과를 제시했다고 할 수 있다.

첫 번째 비교군인 CAE를 사용한 히스토리매칭 후 오일 생산량과 워터컷을 예측한 그래프는 업데이트된 모델이 참조 모델의 경향성을 어느 정도 따라가는 편이다. 그러나 히스토리매칭 후 평균 유체투과율 분포를 그린 Fig. 3.78-81에서 볼 수 있었듯이 채널의 연결성을 약하게 예측한 부분이 있었기 때문에 앙상블 멤버 간 불확실성 폭이 크게 나타난다.

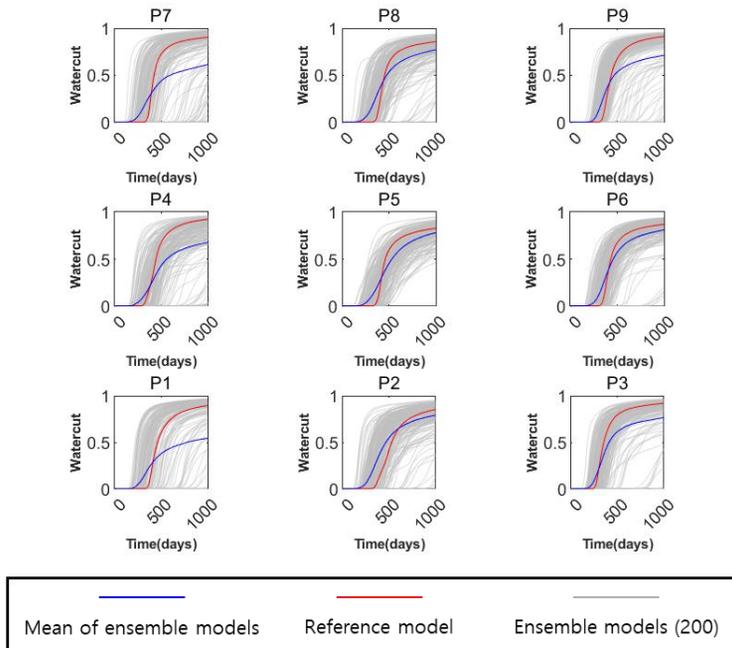
특히 생산정 P2, P5, P8 근처의 연결을 잘 파악하지 못하여 이 유정들의 생산량 예측 그래프는 불확실성이 크게 나타나며, P2의 오일 생산량이나 P8의 워터컷은 앙상블의 평균값이 참조 모델에서 다소 벗어나게 예측되었다.

두 번째 비교군인 CVAE를 사용한 히스토리매칭 후 예측한 생산량 그래프를 보면 몇몇 유정의 생산 경향이 참조 모델과는 완전히 다르게 나타난다. 무엇보다도 Fig. 3.82-85에서 유체투과율 분포를 그렸을 때도 채널의 연결성을 잘못 예측한 생산정 P1과 P5의 경우 앙상블의 평균 생산 그래프는 참조 모델과는 완전히 다른 경향성을 보이고 있기 때문에, 이 비교군 또한 제안하는 기법과 비교했을 때 신뢰할 수 있는 히스토리매칭 결과를 제시했다고 보기 어렵다.

Table 3.14에 제시한 오일 생산량 및 워터컷의 MAE 계산 결과에서도 제안하는 기법이 두 비교군에 비해 더 낮은 값을 가져서, 위의 주장을 뒷받침하는 근거가 된다.

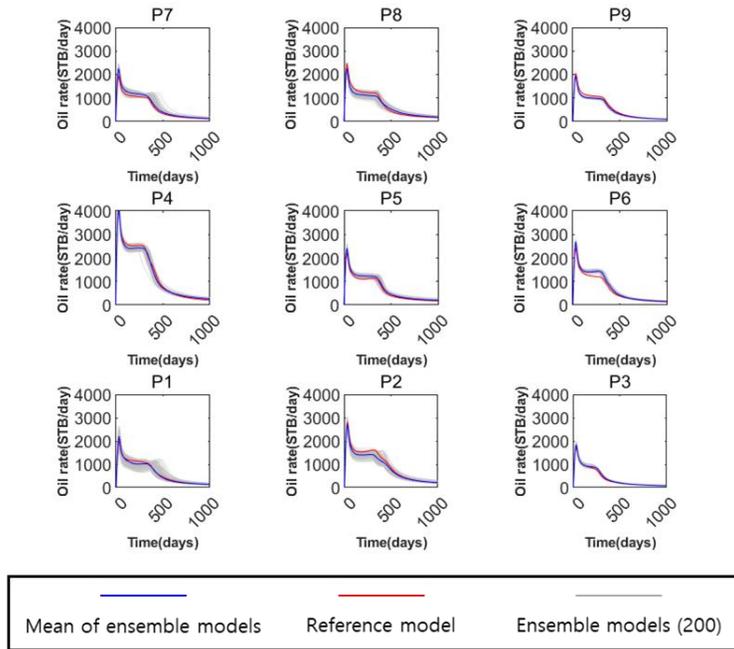


(a)

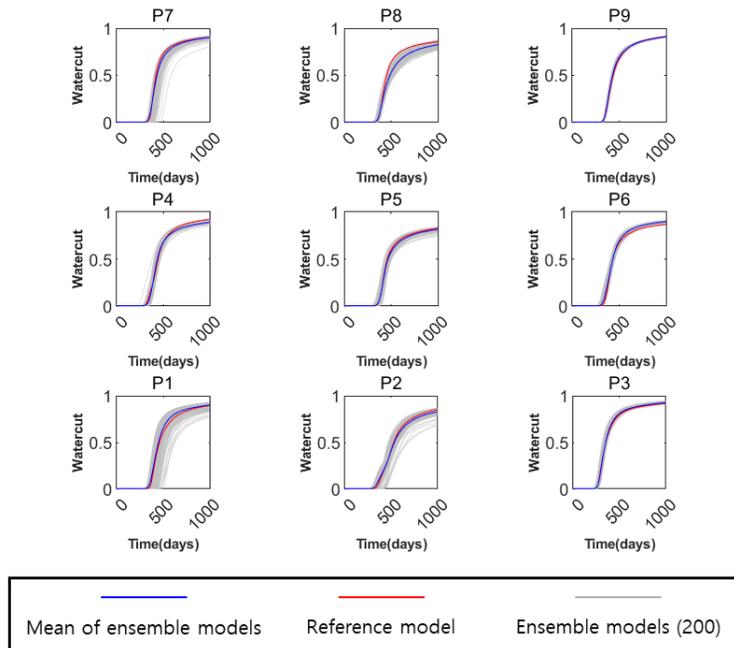


(b)

**Fig. 3.86.** Performance prediction of the initial ensemble models in case 4: (a) oil production, (b) watercut.

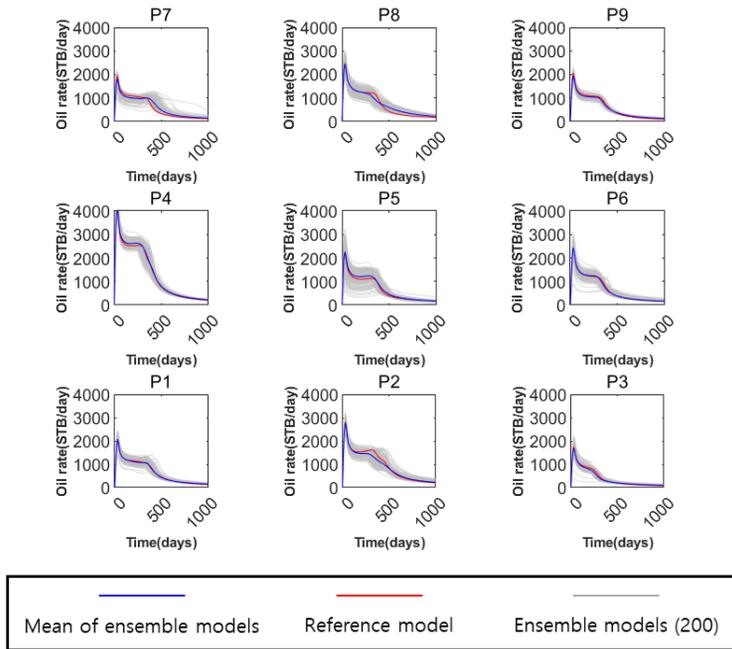


(a)

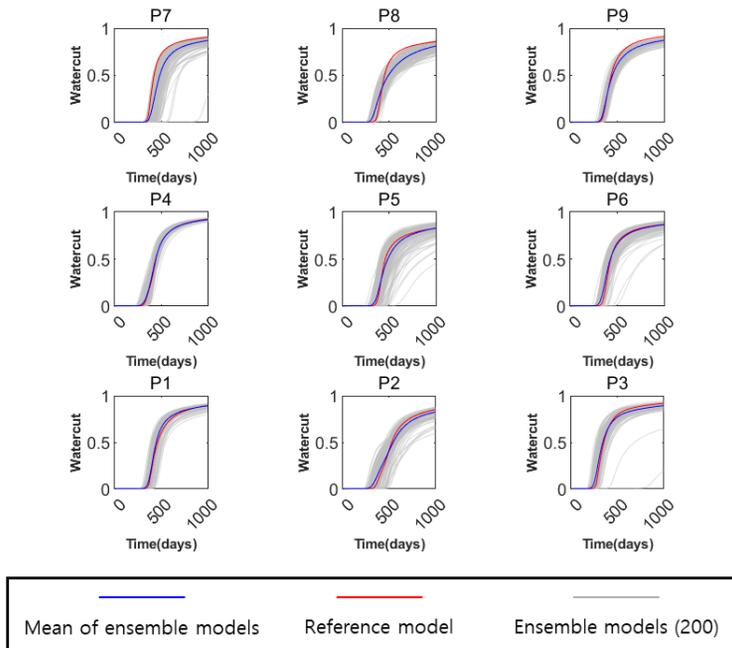


(b)

**Fig. 3.87.** Performance prediction of the updated models using the proposed method in case 4: (a) oil production, (b) watercut.

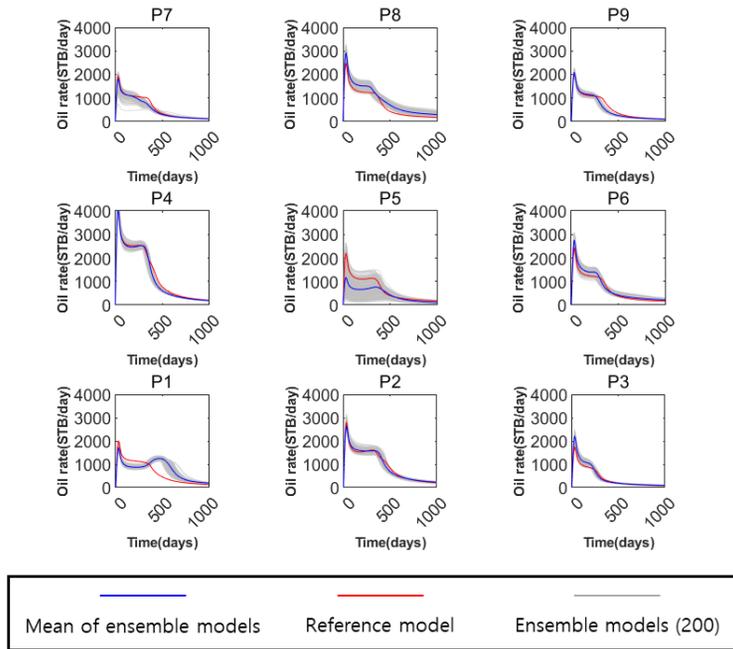


(a)

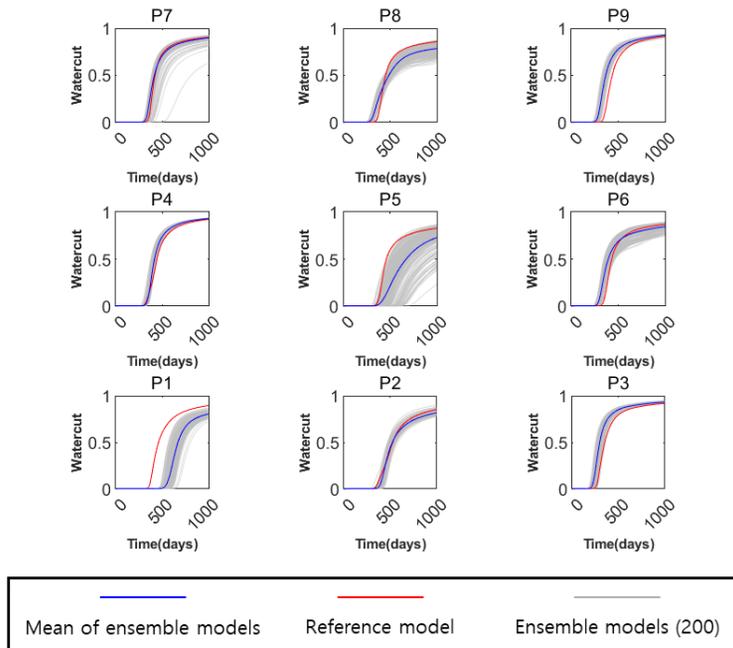


(b)

Fig. 3.88. Performance prediction of the updated models using CAE in case 4: (a) oil production, (b) watercut.



(a)



(b)

**Fig. 3.89.** Performance prediction of the updated models using CVAE in case 4: (a) oil production, (b) watercut.

**Table 3.14** MAE of oil rate and watercut prediction, case 4.

Reservoir models	MAE of oil rate	MAE of watercut
Initial models	314.86	$16.267 \times 10^{-2}$
Updated models using the suggested method	70.48	$2.357 \times 10^{-2}$
Updated models using CAE instead of beta-CVAE	82.16	$4.132 \times 10^{-2}$
Updated models using CVAE instead of beta-CVAE	134.82	$7.152 \times 10^{-2}$

## 4. 결론

본 연구에서는 beta-CVAE를 사용해 채널저류층의 유체투과율 분포로부터 다변량 정규분포를 따르는 잠재벡터를 학습한 다음, ES-MDA를 사용해 잠재벡터를 업데이트하고 그로부터 유체투과율 분포를 복원하여 3D 채널저류층을 히스토리매칭 하는 기법을 제안하였다.

제안하는 기법을 사용하여 먼저 두 가지 2D 채널저류층 모델을 히스토리매칭 하여 해당 기법이 히스토리매칭에 적합한지를 확인하였다. 이후 두 가지 3D 채널저류층 모델을 히스토리매칭 하여 3D 채널저류층에 대해서도 신뢰할 수 있는 결과를 제시한다는 것을 보였다. 이 연구를 통해 얻은 주요한 결론은 다음과 같다:

1. VAE는 채널저류층의 유체투과율 분포를 학습하여 저차원의 잠재벡터로 나타낼 수 있다. 학습과정에서 채널의 방향이나 연결성과 같은 자료의 중요한 특징을 파악하여, 잠재벡터를 다시 원래 유체투과율 분포로 복원했을 때 중요한 특징을 유지한다. 또한 VAE 네트워크는 잠재벡터가 다변량 정규분포를 따르는 생성 모델이 되도록 학습하는데, 이런 특징은 교정할 자료의 정규분포성을 가정하는 ES-MDA와 잘 맞다. 채널저류층의 유체투과율 대신 잠재벡터를 ES-MDA로 업데이트했을 때 더욱 신뢰할 수 있는 교정결과를 얻었고, 생성 모델로 교정된 잠재벡터를 새로운 유체투과율 분포로 복원했을 때 채널저류층 형태가 유지되는 것을 확인하였다.
2. 합성곱 신경망은 이미지 형태의 자료를 학습하는 데 특화되어 있고 네트워크가 학습해야 할 인자 수를 감소시켜 학습에 소요되는 시간을 줄일 수 있다. 본 연구 중 case 4에서 사용한  $60 \times 60 \times 4$  크기의 3D 채널저류층을 합성곱 신경망을 사용하지

않고 학습할 경우, 신경망의 각 층마다 차원을 절반으로 감소시킨다는 가정 하에 학습해야 할 인자 수는 약 27억개로, 소요 시간은 37일 정도로 추정된다. 본 연구에서는 이 케이스에 합성곱 신경망을 사용하여 학습해야 할 인자 수를 약 900만개까지 감소시키고 소요 시간도 3시간으로 단축시켰다. 합성곱 신경망은 네트워크 학습에 소요되는 시간을 감소시키는 동시에 이미지 자료를 학습하는 성능도 일반 인공신경망에 비해 뒤떨어지지 않는 것을 확인하였다.

3. Beta-VAE는 잠재벡터가 서로 독립된 특성을 학습하도록 유도하여 ES-MDA로 업데이트한 잠재벡터를 다시 유체투과율 분포로 복원하는 생성 모델이 잘 동작하게 했다. 일반 VAE는 잠재벡터의 값 중 하나만을 바꿨을 때 그로부터 생성되는 모델이 복합적으로 변화하도록 학습되는 경우가 있다. 이런 문제가 나타나는 VAE 모델은 생성 모델로 잘 동작하지 않기 때문에 ES-MDA로 업데이트한 채널저류층의 유체투과율 분포가 실제 채널저류층의 특징을 잘 나타내지 않을 수 있다. Beta-VAE는 이런 경향을 줄이기 위한 알고리즘으로, 잠재벡터가 서로 얽히지 않는 방향으로 학습을 유도한다. 이는 본 연구의 case 3과 case 4에서 beta-CVAE와 CVAE를 사용한 히스토리매칭 결과를 비교함으로써 확인할 수 있었고, CVAE보다 beta-CVAE를 사용했을 때 채널의 연결성을 더 신뢰할 수 있게 예측하는 것을 보였다.
4. ES-MDA는 적절한 타 알고리즘들과 같이 사용하면 여전히 히스토리매칭에 유용하게 사용할 수 있다. 앙상블 기반 방법은 그 멤버의 물성 분포가 정규분포를 따른다고 가정하기 때문에 채널저류층 히스토리매칭에 단독으로 사용하기에는 부적합하다. 그럼에도 불구하고 여러 알고리즘을 함께 써서 2D 채널저류층

히스토리매칭에는 앙상블 기반 방법을 사용할 수 있다는 것을 보인 연구들이 많았다. 본 연구는 거기에 더해 beta-CVAE를 사용하여 3D 채널저류층도 앙상블 기반 방법으로 히스토리매칭 할 수 있다는 것을 보였다.

마지막으로, 본 연구에서 더욱 발전할 수 있는 연구를 두 가지 제안할 수 있다. 첫 번째로, 초매개변수를 정할 수 있는 방법들을 정리하여 최적의 초매개변수 값을 빠르게 선정하는 연구를 제안한다. 본문에서 사용한 기법은 다양한 알고리즘이 많이 사용되었기에 그와 연관된 초매개변수도 많다. 이 연구에서 초매개변수는 이전 연구를 참고하거나 다수의 케이스를 만들어 가장 결과가 좋은 케이스의 초매개변수를 사용하는 방법을 택하였다. 하지만 비슷한 연구가 존재하지 않는 경우 이전 연구를 참고하기 어려우며 여러 케이스를 만드는 방식은 그에 따라 시뮬레이션 시간이 늘어난다는 단점이 있다. 따라서 초매개변수의 값을 빠르게 선정할 수 있다면 제안하는 히스토리매칭 기법을 새로운 모델에 더 쉽게 적용할 수 있을 것이다.

두 번째로, 제안하는 히스토리매칭 기법을 실제 필드 기반 채널저류층 자료에 적용하는 연구가 있다. 이 연구에서 해당 기법을 실제 필드에 적용하여 결과를 보여주는 것이 가장 좋았지만, 기계학습에 사용할 수천 개 이상의 등가확률을 갖는 모델을 포함하는 실제 저류층 모델을 찾을 수 없었다. 거기에 더해 실제 필드 자료는 채널의 규모도 훨씬 크고 유체투과율도 암상에 따라 명확하게 구분되지 않는 등 가상 저류층 모델에 비해 어려운 점이 많다. 따라서 실제 3D 채널저류층 필드 기반의 모델을 획득하고 그것을 앙상블 기반 방법과 기계학습 알고리즘으로 히스토리매칭 하는 것은 도전적인 연구과제가 될 것이다.

## 참고 문헌

최종근, 2013. 지구통계학. 2nd ed. 시그마프레스, 서울, pp. 253–262.

최종근, 2018. 해양시추공학. 2nd ed. 씨아이알, 서울, pp. 7–11.

Alemi, A.A., Fischer, I., Dillon, J.V., Murphy, K., 2017. Deep variational information bottleneck. In: 5th International Conference on Learning Representations, Toulon, France, April 24–26.

Bianco, A., Cominelli, A., Dovera, L., Nævdal, G., Vallès, B., 2007. History matching and production forecast uncertainty by means of the ensemble Kalman filter: a real field application. In: 69th EUROPEC/EAGE Conference and Exhibition, London, U.K., June 11–14.

BP p.l.c., 2023. BP energy outlook 2022 [WWW Document]. URL <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/energy-outlook/bp-energy-outlook-2022.pdf> (accessed 5.19.2023).

Burgess, C.P., Higgins, I., Pal, A., Matthey, L., Watters, N., Desjardins, G., Lerchner, A., 2017. Understanding disentangling in  $\beta$ -VAE. In: 31st International Conference on Neural Information Processing Systems, Long Beach, California, U.S.A., December 4–9.

Canchumuni, S.W.A., Emerick, A.A., Pacheco, M.A.C., 2018. History matching channelized facies models using ensemble smoother with a deep learning parameterization. In: 16th European Conference on the Mathematics of Oil Recovery, Barcelona, Spain, September 3–6.

Deutsch, C.V., Tran, T.T., 2002. Fluvsim: a program for object-based stochastic modeling of fluvial depositional systems. *Comput. Geosci.* 28 (4), 525–535.

EIA, 2023. U.S. field production of crude oil [WWW Document]. URL <https://www.eia.gov/dnav/pet/hist/LeafHandler.ashx?n=PET&s=MC RFPUS2&f=A> (accessed 5.19.2023).

Emerick, A.A., Reynolds, A.C., 2013. Ensemble smoother with multiple data assimilation. *Comput. Geosci.* 55 (3), 3–15.

Evensen, G., 1994. Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics. *J. Geophys. Res.* 99 (C5), 10143–10162.

Evensen, G., 2003. The ensemble kalman filter: theoretical formulation and practical implementation. *Ocean Dyn.* 53 (4), 343–367.

Fukushima, K., 1980. Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol. Cybern.* 36, 193–202.

Jung, H., Jo, H., Lee, K., Choe, J., 2017. Characterization of various channel fields using an initial ensemble selection scheme and covariance localization. *J. Energy Resour. Technol.* 139 (6), 062906.

Jung, H., Jo, H., Kim, S., Lee, K., Choe, J., 2018. Geological model sampling using PCA-assisted support vector machine for reliable channel reservoir characterization. *J. Pet. Sci. Eng.* 167, 396–405.

Kang, B., Choe, J., 2017. Initial model selection for efficient history matching of channel reservoirs using ensemble smoother. *J. Pet. Sci. Eng.* 152, 294–308.

Kim, S., Lee, K., 2019. Application of spectral clustering algorithm to ES-MDA with DCT for history matching of gas channel reservoirs. *Energies.* 12 (22), 4394.

Kim, J., Kim, S., Park, C., Lee, K., 2020. Construction of prior models for ES-MDA by a deep neural network with a stacked autoencoder. *J. Pet. Sci. Eng.* 187, 106800.

Kingma, D.P., Welling, M., 2014. Auto-encoding variational bayes. In: 2nd International Conference on Learning Representations, Banff, Alberta, Canada, April 14–16.

Kullback, S., Leibler, R.A., 1951. On information and sufficiency. *Ann. Math. Statist.* 22 (1), 79–86.

Le, D.H., Younis, R., Reynolds, A.C., 2015. A history matching procedure for non-Gaussian facies based on ES-MDA. In: SPE Reservoir Simulation Symposium, Houston, Texas, U.S.A., February 23–25.

LeCun, Y., Bottou, L., Bengio, Y., Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proc. IEEE*. 86 (11), 2278–2324.

LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. *Nature*. 521 (7553), 436–444.

Lee, K., Lim, J., Choe, J., Lee, H., 2017. Regeneration of channelized reservoirs using history-matched facies-probability map without inverse scheme. *J. Pet. Sci. Eng.* 149, 340–350.

Lorentzen, R.J., Flornes, K.M., Nævdal, G., 2012. History matching channelized reservoirs using the ensemble Kalman filter. *SPE J.* 17 (1), 137–151.

Maharaja, A., 2008. TiGenerator: object-based training image generator. *Comput. Geosci.* 34 (12), 1753–1761.

Mandal, J., 2007. A brief tutorial on the ensemble Kalman filter (No. 242). Center for Computational Mathematics, Denver, Colorado, U.S.A.

Mitchell, T.M., 1997. *Machine Learning*, 1st ed. McGraw Hill, New York.

Nævdal, G., Mannseth, T., Vefring E.H., 2002. Near-well reservoir monitoring through ensemble Kalman filter. In: SPE/DOE Improved Oil Recovery Symposium, Tulsa, Oklahoma, U.S.A., April 13–17.

Ng, A.Y., Jordan, M.I., 2002. On discriminative vs. generative classifiers: A comparison of logistic regression and naive bayes. *NeurIPS*. 14, 841–848.

Pyrzcz, M.J., Boisvert, J.B., Deutsch, C.V., 2008. A library of training images for fluvial and deepwater reservoirs and associated code. *Comput. Geosci.* 34 (5), 542–560.

Srisutthiyakorn, N., 2016. Deep Learning Methods for Predicting Permeability from 2-D/3-D Binary Segmented Images. In: SEG International Exposition and 86th Annual Meeting, Dallas, Texas, U.S.A., October 16–21.

Strebelle, S.B., 2000. Sequential simulation drawing structures from training images (Doctoral dissertation). Stanford University, California.

Van Leeuwen, P.J., Evensen, G., 1996. Data assimilation and inverse methods in terms of a probabilistic formulation. *Mon. Weather Rev.* 124 (12), 2898–2913.

Wen, X.H., Chen, W.H., 2007. Some practical issues on real-time reservoir model updating using ensemble Kalman filter. *SPE J.* 12 (2), 156–166.

## 부록 A. 채널저류층 학습을 위한 VAE 손실함수

이 장에서는 식 (2.11)로 표현되는 VAE의 손실함수를 채널저류층 학습과정에서 사용하기 위해 식을 전개하는 과정에 대해 설명한다:

$$\mathcal{L}(\theta, \phi; x^i) = -\mathbb{E}_{q_\phi(z|x^i)} \left[ \log(p_\theta(x^i|z)) \right] + D_{KL}(q_\phi(z|x^i) \parallel p(z)) \quad (2.11)$$

$$D_{KL}(q \parallel p) = \sum_{x \in \mathcal{X}} q(x) \log \left( \frac{q(x)}{p(x)} \right) \quad (2.12)$$

입력 자료와 잠재벡터의 확률분포를 각각  $p(x)$ 와  $p(z)$ 라고 했을 때, 조건부확률분포  $p(z|x)$ 는 알 수 없는 값이기 때문에 잠재벡터를 학습할 수 없다. 이 때,  $p(z|x)$ 를 잘 알려진 분포  $q_\phi(z|x)$ 로 근사하여 학습하는 기법을 변분추론(variational inference)이라고 하며, 변분추론을 사용하면 원래  $p(z|x)$ 를 추정하기 위한 VAE의 목표는 대신  $p(z|x)$ 와  $q_\phi(z|x)$  사이의 오차를 최소화하는 것이 된다.

본 연구의 목표는 채널저류층의 물성을 VAE로 학습하는 것인데, 이분포를 따르고 낮은 값과 높은 값이 크게 차이 나는 채널저류층 물성의 특징에 따라 이를 2진 데이터로 가정한다.

Kingma와 Welling(2014)에 따르면, 입력 자료가 2진 데이터일 때 다음 3가지 가정을 사용할 수 있다. 첫째,  $q_\phi(z|x)$ 는 다변량 정규분포  $\mathcal{N}(\mu_\phi(x), \Sigma_\phi(x))$ 로 가정한다. 둘째,  $p(z)$ 는  $\mathcal{N}(0, 1)$ 를 따른다. 셋째,  $p_\theta(x^i|z)$ 는 다변량 베르누이 다중 퍼셉트론이다.

위 가정들을 이용하면 식 (2.11)을 더 간단한 형태로 나타낼 수 있다. 다변량 정규분포를 따르는 임의의 변수  $X \sim \mathcal{N}(\mu_X(x), \Sigma_X(x))$ 에 대해, 확률분포  $f(x)$ 는 다음과 같다:

$$f(x) = \frac{1}{\sqrt{(2\pi)^k \det(\Sigma_X)}} \exp \left( -\frac{1}{2} (x - \mu_X)^T \Sigma_X^{-1} (x - \mu_X) \right) \quad (A.1)$$

여기서  $k$ 는 공분산행렬  $\Sigma$ 의 차원이며,  $\det(\Sigma_x)$ 는 행렬식이다. 이 식의 양변에 자연로그를 취하면,

$$\log f(x) = -\frac{k}{2}\log(2\pi) - \frac{1}{2}\log\{\det(\Sigma_x)\} - \frac{1}{2}(x - \mu_x)^T \Sigma_x^{-1}(x - \mu_x) \quad (\text{A.2})$$

가 되며, 다시 이 식을 KL 분산 식인 (2.12)에 대입하면,

$$D_{KL}(f \parallel g) = \sum f(x) \left\{ \frac{1}{2} \log \frac{\det(\Sigma_Y)}{\det(\Sigma_X)} + \frac{1}{2} (x - \mu_Y)^T \Sigma_Y^{-1} (x - \mu_Y) - \frac{1}{2} (x - \mu_X)^T \Sigma_X^{-1} (x - \mu_X) \right\} \quad (\text{A.3})$$

이 때  $g(x)$ 는 다변량 정규분포를 따르는 또다른 임의의 변수  $Y \sim \mathcal{N}(\mu_Y(x), \Sigma_Y(x))$ 다.

식 (A.3)의  $\sum f(x) \cdot \frac{1}{2} (x - \mu_X)^T \Sigma_X^{-1} (x - \mu_X)$  항은 대각합(trace)의 성질을 써서 다음과 같이 정리할 수 있다:

$$\begin{aligned} \sum f(x) \cdot \frac{1}{2} (x - \mu_X)^T \Sigma_X^{-1} (x - \mu_X) &= \frac{1}{2} E_{f(x)} [(x - \mu_X)^T \Sigma_X^{-1} (x - \mu_X)] \\ &= \frac{1}{2} E_{f(x)} [\text{tr}\{(x - \mu_X)^T \Sigma_X^{-1} (x - \mu_X)\}] \\ &= \frac{1}{2} E_{f(x)} [\text{tr}\{(x - \mu_X)^T (x - \mu_X) \Sigma_X^{-1}\}] \\ &= \frac{1}{2} \text{tr}[E_{f(x)}\{(x - \mu_X)^T (x - \mu_X) \Sigma_X^{-1}\}] \\ &= \frac{1}{2} \text{tr}[\Sigma_X \Sigma_X^{-1}] \\ &= \frac{k}{2} \end{aligned} \quad (\text{A.4})$$

또한 식 (A.3)의  $\sum f(x) \cdot \frac{1}{2} (x - \mu_Y)^T \Sigma_Y^{-1} (x - \mu_Y)$  항을 정리하면,

$$\begin{aligned}
& \sum f(x) \cdot \frac{1}{2} (x - \mu_Y)^T \Sigma_Y^{-1} (x - \mu_Y) \\
&= \frac{1}{2} \sum f(x) [\{(x - \mu_X) + (\mu_X - \mu_Y)\}^T \Sigma_Y^{-1} \{(x - \mu_X) + (\mu_X - \mu_Y)\}] \\
&= \frac{1}{2} \sum f(x) [(x - \mu_X)^T \Sigma_Y^{-1} (x - \mu_X) + (x - \mu_X)^T \Sigma_Y^{-1} (\mu_X - \mu_Y) \\
&\quad + (\mu_X - \mu_Y)^T \Sigma_Y^{-1} (x - \mu_X) + (\mu_X - \mu_Y)^T \Sigma_Y^{-1} (\mu_X - \mu_Y)] \tag{A.5}
\end{aligned}$$

이 때 우변의 각 항은 대각합의 성질을 사용해 식 (A.6), (A.7), (A.8)과 같이 정리할 수 있다:

$$\begin{aligned}
& \sum f(x) [(x - \mu_X)^T \Sigma_Y^{-1} (x - \mu_X)] \\
&= E_{f(x)} [(x - \mu_X)^T \Sigma_Y^{-1} (x - \mu_X)] \\
&= \text{tr} [\Sigma_X \Sigma_Y^{-1}] \tag{A.6}
\end{aligned}$$

$$\begin{aligned}
& \sum f(x) [(x - \mu_X)^T \Sigma_Y^{-1} (\mu_X - \mu_Y) + (\mu_X - \mu_Y)^T \Sigma_Y^{-1} (x - \mu_X)] \\
&= \left[ \{E_{f(x)}(x) - \mu_X\}^T \Sigma_Y^{-1} (\mu_X - \mu_Y) + (\mu_X - \mu_Y)^T \Sigma_Y^{-1} \{E_{f(x)}(x) - \mu_X\} \right] \\
&= 0 \tag{A.7}
\end{aligned}$$

$$\begin{aligned}
& \sum f(x) [(\mu_X - \mu_Y)^T \Sigma_Y^{-1} (\mu_X - \mu_Y)] \\
&= E_{f(x)} [(\mu_X - \mu_Y)^T \Sigma_Y^{-1} (\mu_X - \mu_Y)] \\
&= (\mu_X - \mu_Y)^T \Sigma_Y^{-1} (\mu_X - \mu_Y) \tag{A.8}
\end{aligned}$$

마지막으로 식 (A.4), (A.5), (A.6), (A.7), (A.8)을 식 (A.3)에 대입하여 계산하면 식 (A.9)와 같이 표현할 수 있다:

$$\begin{aligned}
D_{KL}(f \parallel g) &= \frac{1}{2} \left[ \log \frac{\det(\Sigma_Y)}{\det(\Sigma_X)} - k + \text{tr}(\Sigma_X \Sigma_Y^{-1}) \right. \\
&\quad \left. + (\mu_X - \mu_Y)^T \Sigma_Y^{-1} (\mu_X - \mu_Y) \right] \tag{A.9}
\end{aligned}$$

여기서 입력 자료가 2진 데이터일 때의 가정을 적용하여  $f$  를  $q_\phi(z|x) \sim \mathcal{N}(\mu_\phi(x), \Sigma_\phi(x))$ 로,  $g$ 를  $p(z) \sim \mathcal{N}(0, I)$ 로 보면,

$$D_{KL}(q \parallel p) = \frac{1}{2} \sum_{j=1}^k \left[ \sigma_{\phi,j}(x^i) + \mu_{\phi,j}^2(x^i) - 1 - \log(\sigma_{\phi,j}(x^i)) \right] \quad (\text{A.10})$$

으로 계산되며, 여기서 입력 데이터가  $x^i$ 일 때  $\sigma_{\phi,j}(x^i)$ 는  $\Sigma_\phi(x^i)$ 의  $j$ 번째 주대각 성분,  $\mu_{\phi,j}(x^i)$ 는  $\mu_\phi(x^i)$ 의  $j$ 번째 성분이며,  $\sigma_\phi(x^i)$ 와  $\mu_\phi(x^i)$ 는 VAE 네트워크 훈련 과정에서 학습된다.

한편,  $p_\theta(x^i|z)$ 를 다변량 베르누이 다층 퍼셉트론으로 가정했기 때문에 식 (2.11)에서  $\log(p_\theta(x^i|z))$ 는 다음과 같이 나타낼 수 있다:

$$\log(p_\theta(x^i|z)) = x^i \log y^i + (1 - x^i) \log(1 - y^i) \quad (\text{A.11})$$

여기서  $y^i$ 는  $z^i$ 를 디코딩한 결과이며,  $z^i$ 는 식 (A.12)로 쓸 수 있는  $L$ 개의 샘플링 과정을 통해 얻어진다:

$$z_l^i = \mu_\phi(x^i) + \sigma_\phi(x^i) \odot \epsilon_l \quad (\text{A.12})$$

이 때  $\epsilon_l$ 는  $\mathcal{N}(0, I)$ 에서 무작위로 샘플링한  $L$ 개의 변수이며  $\odot$ 는 성분별 곱셈이다.

$L$ 이 충분히 큰 경우,  $\mathbb{E}_{q_\phi(z|x^i)}[\log(p_\theta(x^i|z))]$ 는 (A.13)과 같이 샘플링한 값들의 평균값으로 계산할 수 있다:

$$\begin{aligned}
& \mathbb{E}_{q_\phi(z|x^i)} \left[ \log(p_\theta(x^i|z)) \right] \\
&= \mathbb{E}_{q_\phi(z|x^i)} [x^i \log y^i + (1 - x^i) \log(1 - y^i)] \\
&= \frac{1}{L} \sum_{l=1}^L [x^l \log y_l^i + (1 - x^l) \log(1 - y_l^i)] \tag{A.13}
\end{aligned}$$

마지막으로 식 (A.10), (A.13)을 식 (2.11)에 대입하면 채널저류층 학습에 사용하는 VAE의 손실함수는 (A.14)가 된다:

$$\begin{aligned}
\mathcal{L}(\theta, \phi; x^i) &= -\frac{1}{L} \sum_{l=1}^L [x^l \log y_l^i + (1 - x^l) \log(1 - y_l^i)] \\
&\quad + \frac{1}{2} \sum_{j=1}^k [\sigma_{\phi,j}(x^i) + \mu_{\phi,j}^2(x^i) - 1 - \log(\sigma_{\phi,j}(x^i))] \tag{A.14}
\end{aligned}$$

## Abstract

# 3D Channel Reservoir History Matching Using Ensemble-Based Method and Beta-Convolutional Variational Autoencoder

YoungBin Ahn

Department of Energy Systems Engineering

The Graduate School

Seoul National University

Building reservoir models for an oilfield is an important task for predicting future productions and decision making. However, reservoir models that built using only limited data from the initial phases of production lack reliability due to their high level of uncertainty. Therefore, history matching process is utilized to update the model to assimilate with the observed data obtained during the production phase, such as oil production rates.

Ensemble-based methods are applicable for history matching as they handle an ensemble, which is a collection of equi-probable models, to effectively address large non-linear datasets and generate stochastic results. For ensemble-based methods, each ensemble member is assumed to follow a normal distribution. This assumption makes channel reservoir history matching challenging due to the characteristics of channel reservoirs, which are bimodally distributed properties and channel connectivity.

In this study, a novel channel reservoir history matching method

is proposed that uses beta-CVAE(beta-convolutional variational autoencoder) and ES-MDA(ensemble smoother with multiple data assimilation). Beta-CVAE, which is one of the machine learning algorithms, is used to generate latent vectors learned from permeability distributions of channel reservoir models. ES-MDA, which is one of the ensemble-based methods, is used to update the latent vectors. Beta-CVAE network is trained to be generative models of which latent vectors follow a multivariate normal distribution. Thus, beta-CVAE not only satisfies the assumption of ES-MDA but also generates new channel reservoir models from updated latent vectors.

For four different cases, history matching results are presented in two ways which are updated permeability distributions and predictions of oil production and watercut. The four cases include 2D reservoir models with good initial ensemble, 2D reservoir models with poor initial ensemble, 3D reservoir models with varying channel positions across layers, and 3D reservoir models with varying channel shapes across layers.

The proposed method presented more reliable history matching results in prediction of permeability distributions, such as channel direction, connectivity, and interlayer connectivity compared to the results of benchmark history matching algorithms. The proposed method also presented reliable predictions of oil production and watercut. The ensemble mean follows the trends of actual oil production and watercut, and the range of uncertainty is effectively reduced.

**Keywords** : history matching, channel reservoir, 3D reservoir, ensemble-based method, machine learning, beta-convolutional

variational autoencoder

**Student Number** : 2017-25078