



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](#)

2018년 2월  
석사학위논문

# 인공지능기법을 이용한 다생산정 위치선정 연구

조선대학교 대학원

에너지자원공학과

강 현 정

# 인공지능기법을 이용한 다생산정 위치선정 연구

Optimization of Multi-well Placement using  
Artificial Intelligence

2018년 2월 23일

조선대학교 대학원

에너지자원공학과

강 현 정

# 인공지능기법을 이용한 다생산정 위치선정 연구

지도교수 장 일 식

이 논문을 공학 석사학위신청 논문으로 제출함

2017년 10월

조선대학교 대학원

에너지자원공학과

강 현 정



## 강현정의 석사학위논문을 인준함

위원장 조선대학교 부교수 강 성 승 (인)

위 원 조선대학교 조교수 장 일 식 (인)

위 원 조선대학교 조교수 최 태 진 (인)

2017년 11월

조선대학교 대학원

## 목 차

목차 .....	i
List of Tables .....	iii
List of Figures .....	iv
ABSTRACT .....	vii
제1장 서론 .....	1
제2장 이론적 배경 .....	4
제1절 인공지능기법 .....	4
제2절 역전파 신경망 .....	8
제3절 순차적 인공신경망 .....	10
제3장 다생산정 시추 위치 최적화 모델 개발 .....	13
제1절 다생산정 시추 위치 최적화 과정 .....	13
제2절 인공신경망의 학습 자료 선정 .....	17
제3절 인공신경망의 입출력 자료 .....	18

제4장 연구 결과 .....	20
제1절 저류층 시스템 .....	20
제2절 생산정 2개의 추가 시추 위치 선정 .....	22
1. 인공신경망의 학습 자료 선정 .....	22
2. 광역적 최적 추가 시추 위치 결정 .....	24
가. 1단계 격자시스템을 사용한 최적 위치 선정 .....	24
나. 2단계 격자시스템을 사용한 최적 위치 선정 .....	36
다. 3단계 격자시스템을 사용한 최적 위치 선정 .....	44
제3절 생산정 3개의 추가 시추 위치 선정 .....	54
1. 인공신경망의 학습 자료 선정 .....	54
2. 광역적 최적 추가 시추 위치 결정 .....	55
가. 1단계 격자시스템을 사용한 최적 위치 선정 .....	55
나. 2단계 격자시스템을 사용한 최적 위치 선정 .....	68
다. 2단계 격자시스템을 사용한 최적 위치 선정 .....	78
제5장 결론 .....	90
참고문헌 .....	92

## List of Tables

Table 3.1. Input data for the artificial neural network in the case of 2 infill wells with 6 existing wells .....	19
Table 3.2. Output neuron descriptions for the artificial neural network .....	19
Table 4.1 Properties of CBM reservoir .....	21
Table 4.2 Summary of applying the hierarchical ANN of 2 infill wells(Step 1) .....	31
Table 4.3 Results of repeated application of 2 infill wells ANN(Step 1) .....	34
Table 4.4 Ranking 1 to 5 of 2 infill wells(Step 1) .....	35
Table 4.5 Summary of applying the hierarchical ANN in 2 infill wells(Step 2) .....	40
Table 4.6 Results of repeated application of 2 infill wells ANN(Step 2) .....	42
Table 4.7 Ranking 1 to 3 of 2 infill wells(Step 2) .....	43
Table 4.8 Summary of applying the hierarchical ANN of 2 infill wells(Step 3) .....	49
Table 4.9 Results of repeated application of 2 infill wells ANN(Step 3) .....	52
Table 4.10 Result of 2 infill wells .....	53
Table 4.11 Summary of applying the hierarchical ANN of 3 infill wells(Step 1) · .....	64
Table 4.12 Results of repeated application of 3 infill wells ANN(Step 1) .....	66
Table 4.13 Ranking 1 to 5 of 3 infill wells(Step 1) .....	67
Table 4.14 Summary of applying the hierarchical ANN of 3 infill wells(Step 2) · .....	74
Table 4.15 Results of repeated application of 3 infill wells ANN(Step 2) .....	76
Table 4.16 Ranking 1 to 5 of 3 infill wells(Step 2) .....	77
Table 4.17 Summary of applying the hierarchical ANN of 3 infill wells(Step 3) .....	86
Table 4.18 Results of repeated application of 3 infill wells ANN(Step 3) .....	88
Table 4.19 Result of 3 infill wells .....	89

## List of Figures

Figure 2.1 Neural network general scheme(Oilvares et al., 2012). .....	6
Figure 2.2 General neural network flowchart(Oilvares et al., 2012). .....	7
Figure 2.3 Application of back propagation algorithm to ANN(Centilmen et al., 1999). .....	8
Figure 2.4 Flow chart of well placement optimization using sequential Artificial Neural Network(김유미, 2017). .....	12
Figure 3.1 Flow chart of multi-well placement optimization. ....	15
Figure 3.2 Optimization procedure for 2-well placement problem. ....	16
Figure 3.3 The structure of ANN model. ....	18
Figure 4.1 Description of coalbed methane reservoir system. ....	20
Figure 4.2 Grid system of 2 infill-well case. ....	23
Figure 4.3 Well location for 2 infill-well case. ....	24
Figure 4.4 Result of initial ANN model. ....	24
Figure 4.5 Result of 2nd ANN model. ....	25
Figure 4.6 Result of 3rd ANN model. ....	26
Figure 4.7 Result of 4th ANN model. ....	27
Figure 4.8 Cumulative gas production rate of 2 infill wells(Step 1). ....	31
Figure 4.9 Adsorption(CH <sub>4</sub> ) of 2 infill wells(Step 1). ....	32
Figure 4.10 Reduced search space of 2 infill wells(Step 1). ....	33
Figure 4.11 Ranking 1 to 5 of 2 infill wells(Step 1). ....	35
Figure 4.12 Training map of 2 infill wells(Step 2). ....	36
Figure 4.13 Result of initial ANN model. ....	38
Figure 4.14 Result of 2nd ANN model. ....	39
Figure 4.15 Cumulative gas production rate of 2 infill wells(Step 2). ....	40
Figure 4.16 Adsorption(CH <sub>4</sub> ) of 2 infill wells(Step 2). ....	41
Figure 4.17 Reduced search space of 2 infill wells(Step 2). ....	41
Figure 4.18 Ranking 1 to 3 of 2 infill wells(Step 2). ....	43

Figure 4.19 Training map of 2 infill wells(Step 3). ..... 44

Figure 4.20 Result of initial ANN model. .... 46

Figure 4.21 Result of 2<sup>nd</sup> ANN model. .... 47

Figure 4.22 Result of 3<sup>rd</sup> ANN model. .... 48

Figure 4.23 Cumulative gas production rate of 2 infill wells(Step 3). .... 49

Figure 4.24 Adsorption(CH<sub>4</sub>) of 2 infill wells(Step 3). .... 50

Figure 4.25 Reduced search space of 2 infill wells(Step 3) ..... 51

Figure 4.26 Well location for 3 infill well case. .... 54

Figure 4.27 Result of initial ANN model. .... 57

Figure 4.28 Result of 2<sup>nd</sup> ANN model. .... 58

Figure 4.29 Result of 3<sup>th</sup> ANN model. .... 59

Figure 4.30 Result of 4<sup>th</sup> ANN model. .... 60

Figure 4.31 Result of 5<sup>th</sup> ANN model. .... 61

Figure 4.32 Result of 6<sup>th</sup> ANN model. .... 62

Figure 4.33 Result of 7<sup>th</sup> ANN model. .... 63

Figure 4.34 Cumulative gas production rate of 3 infill wells(Step 1). .... 64

Figure 4.35 Adsorption(CH<sub>4</sub>) of 3 infill wells(Step 1). .... 65

Figure 4.36 Ranking 1 to 5 of 3 infill wells(Step 1). .... 67

Figure 4.37 Training map of 3 infill wells(Step 2). .... 68

Figure 4.38 Result of initial ANN model. .... 70

Figure 4.39 Result of 2<sup>nd</sup> ANN model. .... 71

Figure 4.40 Result of 3<sup>th</sup> ANN model. .... 72

Figure 4.41 Result of 4<sup>th</sup> ANN model. .... 73

Figure 4.42 Cumulative gas productions of 3 infill wells field(Step 2). .... 74

Figure 4.43 Adsorption(CH<sub>4</sub>) of 3 infill wells(Step 2). .... 75

Figure 4.44 Ranking 1 to 3 of 3 infill wells(Step 2). .... 77

Figure 4.45 Training map of 3 infill wells(Step 3). .... 78

Figure 4.46 Result of initial ANN model. .... 80

Figure 4.47 Result of 2<sup>nd</sup> ANN model. .... 81

Figure 4.48 Result of 3<sup>th</sup> ANN model. .... 82

Figure 4.49 Result of 4<sup>th</sup> ANN model. .... 83

Figure 4.50 Result of 5<sup>th</sup> ANN model. .... 84  
Figure 4.51 Result of 6<sup>th</sup> ANN model. .... 85  
Figure 4.52 Cumulative gas production rate of 3 infill wells(Step 3). .... 86  
Figure 4.53 Adsorption(CH<sub>4</sub>) of 3 infill wells(Step 3). .... 87

# ABSTRACT

## Optimization of Multi-well Placement using Artificial Intelligence

Kang, Hyeon Jeong

Advisor : Prof. Jang, Il Sik, Ph.D.

Department of Energy & Resource Engineering

Graduate School of Chosun University

Well placement is one of the most important steps in conventional or unconventional field development. Reservoir simulation has been frequently used to determine the optimal locations in well-placement problems. The ideal method is to conduct simulations for all possible drilling locations, called as the exhaustive run, to obtain a true global solution wherein the cumulative production or the economic value is a maximum. However, the exhaustive run takes too much computational time. Therefore, studies using artificial neural networks have been carried out to reduce the required time and cost.

In previous studies to investigate multi-wells placement problem, artificial neural network was applied to scenarios selected by expert's experience and intuition. However, this method does not take into account all cases in which the multi-wells can be located in the entire reservoir, and thus there is possibility of not obtaining the true global solution.

In this study, a new algorithm is proposed to find the optimal locations of multi-wells by using sequentially artificial neural networks in hierarchical grid systems. By applying the sequential artificial neural network (ANN) for each hierarchical grid system, a new search space is identified, where a more



detailed grid system is used for the next sequential ANN. In this methodology it is possible to identify the true global solution with relatively small number of reservoir simulations.

The proposed method was applied to optimize multi-well placement in a coalbed methane reservoir. The result proved that the proposed method provided a practical, cost-effective and robust tool for field production management in helping petroleum engineers determine locations for infill drilling wells.

## 제1장 서론

저류층의 생산량 최적화를 위해 저류층 물성, 운영 및 경제적 요건, 유정의 간섭 효과, 저류층의 불균질성, 유가 등이 고려되어야 하며, 이 중, 생산정의 위치 선정은 다른 무엇보다 더욱 중요한 작업으로 인식되고 있다. 석유 개발의 특성상 천문학적 금액이 투자되는 분야로 부적절한 생산정 위치는 막대한 손실을 발생시킬 수 있다. 이러한 손실을 방지하기 위해 최적의 위치에 생산정을 시추해야 한다. 시추 위치 최적화의 가장 이상적인 방법은 누적 생산량 또는 경제적 가치가 최대한 광역해를 얻기 위해 저류층 전체에 대해 저류층 전산 모사(exhaustive run)를 수행하는 것이다. 하지만 저류층 전산 모사를 수행하기 위해서는 많은 시간과 비용이 소요되기 때문에 최적화 및 확률적 탐색 알고리즘과 같은 다양한 최적화 기법 연구가 수행되어 왔다.

Bittencourt and Horne (1997)은 유전알고리즘을 사용하여 생산정과 주입정, 수직정, 수평정의 조합을 찾아 그 위치를 최적화하였고, Morales et al. (2010)은 Qatar's North field를 바탕으로 유전알고리즘을 적용하여 생산정 위치 최적화 연구를 진행하였다. 생산정 위치를 선정하기 위해서는 지질학적 요소, 저류층과 유체 물성, 경제성, 기술 능력 등이 고려되어야 하며 이 연구에서는 전체 저류층 전산 모사 결과와 비교하여 엔지니어가 판단한 최적 위치와 시뮬레이션을 통한 결과를 비교 분석하였다. Onwunali and Durlofsky (2010)은 입자 군집 최적화 알고리즘을 이용해 유정의 형태와 위치를 최적화하고, 대체적으로 유전알고리즘보다 우수한 결과를 보였다.

확률적 탐색 알고리즘은 저류층 전체에 전산 모사를 수행하는 방법보다 적은 시뮬레이션을 요구하지만, 계산의 반복 과정을 통해 해가 광역해임을 확인해야하기 때문에 상당히 많은 저류층 시뮬레이션이 요구된다. 또한, 충분히 많은 반복을 통해 도출된 최적해의 변화가 없을 때, 최적해로 인식할 수 있지만, 이는 광역해로 인정될 수 없다. 이러한 계산 시간과 비용을 감소시키기 위해 인공신경망 모델이 개발되었다. 인공신경망은 다양한 입력 데이터를 포함한 저류층 시뮬레이션의 출력 값을 예측하고, 입력 및 출력 데이터 간의 비선형성을 기반으로 한 학습을 통해 최적의 예측을 제공한다.

Doraisamy et al. (1998, 2000)은 일정기간 생산이 진행된 저류층에 1개의 추가 시추 시, 인공신경망을 이용하여 연구를 진행하였다. 신경망을 제어하는 중요한 매개변수로 학습 상수와 은닉층 개수를 제안하였다. 뉴런을 많이 사용할수록 인공신경망의 예측성이 좋아지지만 효과적인 훈련을 위해서는 10개가 적당하다고 제안하였다. 또한 인공신경망을 사용하여 다상유동, 가스 혹은 물 주입과 같은 시나리오에도 사용이 가능하다고 하였다.

곽태성(2013)은 인공신경망 시뮬레이터와 SA 최적화 알고리즘을 결합하여 지능형 생산정 위치 최적화 전산 모델을 개발하였다. 인공신경망의 입력 값은 시간, 추가 생산정의 좌표, 저류층 경계와 추가 생산정간 거리, 기존 생산정과 추가 생산정간 거리, 추가 생산정간 거리, 생산성 잠재력 인자, 추가 생산정의 좌표 제곱으로 구성하였고, 출력자료는 각 생산정에 대한 생산량으로 나타냈다. 불균질 가스 저류층을 대상으로 추가 생산정에 대한 생산량을 예측하였고, 기존 상용시뮬레이터의 연산시간을 크게 단축하여 다수의 시나리오에 대해서 짧은 시간에 연산시간이 가능하도록 하였다.

하지만 시뮬레이션의 횟수를 최소화하기 위해 인공신경망을 사용한 경우, 인공신경망을 통해 도출된 예측 값과 실제 값에 오차가 발생한다. 즉, 인공신경망을 사용하여 도출한 광역해가 실제 광역해가 아닐 수도 있음을 의미한다.

김유미(2017)는 일련의 인공신경망을 순차적으로 적용함으로써 광역해를 도출하였다. 훈련 데이터의 수는 이전 인공신경망 모델에 사용된 훈련 데이터와 선행 네트워크에 의해 결정된 새로운 탐색 공간 내에서 선택된 데이터로 결정하여 인공신경망을 훈련시켰다. 이러한 훈련데이터의 누적은 인공신경망을 반복적으로 구성함으로써 예측 성능을 향상시켰다. 또한 탐색 공간의 크기가 점차 광역해로 수렴해나감으로써 신뢰성 높은 결과를 도출하였다.

저류층 시추 위치 최적화는 단일 생산정뿐만 아니라, 다생산정 위치선정 연구도 수행되어 왔다. Centilmen et al. (1999)은 다생산정 위치 최적화를 위해 시추정이 위치 할 수 있는 몇 가지 시나리오를 무작위로 구성하여 인공신경망을 훈련시켰다. 훈련된 인공신경망을 활용하여 시추가 가능한 시나리오 중 가장 적절한 시추 위치를 도출하였다. 유정 위치 최적화에 적용할 수 있는 인공신경망 가이드라인을 제안하였는데 훈련 데이터는 저류층의 경계 근처, 기존 생산정 근처, 생산정과 생산정의 사이, 물성의 변화가 급격하게 변하는 곳을 고려하여 선택해야 한다고 하였다. 훈련 데이터는 많아질수록 정확성은 증가하나 시뮬레이션 횟수도 늘어나기 때문에

적절한 훈련 데이터 수를 결정해야 하며, 생산 시간이 가장 중요한 입력 변수인 것을 강조했다.

민배현(2007)은 인공신경망을 이용하여 다수의 추가 시추위치에서 생산량을 평가하고 누적생산량이 최대인 최적 시추위치 시나리오를 찾는 인공신경망 모델을 개발하였다. 입력 자료는 물리적 특성 인자, 유정의 공간적 위치 정보, 생산정간 상관관계, 저류층의 상대적 생산성을 반영하기 위해 생산성 잠재력 분포도로 구성하였고, 출력자료는 생산정별 누적생산량을 도출하였다. 개발한 모델을 단일 및 다수 생산정 추가시추문제에 적용하였다. 입력 자료로 사용한 생산성 잠재력이 유체투과율을 사용한 인공신경망 모델에 비해 신뢰성 있는 예측성능을 제시하는 것을 검증하였다. 하지만 이상의 다생산정 위치 최적화 연구는 전문가의 경험 및 직관으로 선정한 검증 시나리오에 대해 인공신경망을 적용하였기 때문에, 전체 저류층에 다생산정이 위치할 수 있는 모든 경우의 수를 고려하지 않아 도출된 해가 광역해라는 보장을 하기 어렵다.

본 연구에서는 다생산정 위치 최적화를 위해 저류층을 계층적 격자시스템으로 구성하고 각 계층별 격자에 대해 순차적 인공신경망 모델을 적용하여 광역해를 도출하는 기법을 개발하였다. 저류층 내 시추 가능 위치에 대한 대부분의 경우의 수를 고려함으로써 불확실성을 감소시켰다. 또한, 매 단계의 광역해 상위 순위를 고려하여 탐색 영역을 설정함으로써 광역해의 탈락 가능성을 축소시켰다. 개발한 방법을 석탄층 메탄가스 저류층에 대한 다생산정 최적 시추위치 선정문제에 적용하여 신뢰도를 분석하였다.

## 제2장 이론적 배경

### 제1절 인공지능기법(Artificial Intelligence, AI)

인공지능(Artificial Intelligence)이란 인간이 갖고 있는 추론, 인식, 판단, 학습 등의 사고기능을 컴퓨터에 의해 모델화하여 인간의 사고활동을 정보처리의 입장에서 규명함과 동시에 컴퓨터상에서 인간의 사고과정 일부를 실현하는 것이다. 즉, 보다, 듣다, 말하다, 이해하다 등과 같은 인간의 지적인 행동을 컴퓨터상에서 실현하고자 하는 것이 인공지능의 의미이다. 인공지능은 인간의 인지 즉, 지각, 판단, 기억, 학습, 이해와 같은 마음의 작용을 정보처리라는 관점에서 컴퓨터를 이용하여 시뮬레이션하기 위한 여러 가지 시도라고 볼 수 있다. 인간을 정보처리시스템 관점에서 바라보면 육체는 하드웨어이고 마음은 소프트웨어로서 하나의 인공지능이라고 간주할 수 있다(최규석과 박종진, 2009).

인공신경망(Artificial Neural Network, ANN)은 인간의 신경체계와 유사한 성능과 특성을 갖는 정보처리 시스템의 하나이다. 인공신경망 방식은 인간의 뇌가 대량의 데이터를 효율적, 병렬적으로 처리 및 학습할 수 있다는 사실에 근거하여, 인간의 생물학적 신경세포를 모델링하여 구현하는 방식으로서 네트워크 구조 내에 서로 연결된 처리항목을 가진 대량의 병렬 처리소프트웨어 시뮬레이션의 수행에 사용된다(Fausett, 1994).

인공신경망은 생물학적 신경시스템의 기본원리를 이용하여 문제를 효율적으로 해결할 수 있으며, 이러한 신경망 이론은 엄청난 계산 속도를 요구하는 문제에 있어 기존의 계산방법에 비해 훨씬 빠르고, 높은 예측 가능성을 가지고 있는데, 이는 신경망의 많은 처리단위(Processing Element, PE) 및 노드(node)로 이루어진 병렬 네트워크를 사용하기 때문이다. 뉴런은 신경망을 구성하는 가장 기본적인 단위로, 가중치(weight)를 이용해  $n$ 개의 입력 값들을 가중합산(weighted)하고 그 결과들을 전이함수(transfer function) 또는 활성화 함수(activation function)로 전환하여 결과를 도출한다.

신경망 모델에서 각 뉴런들은 다른 뉴런들로부터 입력을 받아 계산과정을 거쳐 하나의 출력을 생성한다. 이때 각 뉴런들의 출력 값은 뉴런들 간의 상호 연결강도

(weights)의 합, 임계치(threshold), 그리고 활성화 함수(activation function)의 값에 의해 결정된다. 이러한 처리과정은 원하는 출력 값이 도출될 때까지 반복되며, 원하는 출력 값이 활성화되도록 가중치가 조절된다.

인공신경망은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer) 방향으로 연결되어 있다. 뉴런을 연결하는 선은 수상 돌기(dendrites)이며, 가중치를 가지고 있다. 입력층은 계산을 위한 뉴런이 없으며, 외부에서 입력 신호를 받아 은닉층으로 분배하는 역할을 수행한다. 입력층과 출력층 사이에는 하나 이상의 층이 존재하며 이를 은닉층이라 한다. 은닉층은 입력층으로부터 입력 받은 자료를 처리하여 출력 패턴을 결정하고, 출력층으로 보내는 역할을 한다. 출력층은 은닉층에서 출력 신호를 받아들여 전체 인공신경망의 출력을 결정한다. 즉, 인공신경망은 외부 입력신호에 대해 가중치( $W_{kj}, W_{ji}$ )를 곱한 합을 내부 활성화함수를 거쳐 은닉층 뉴런의 값( $V_1, V_2, V_3$ )과 출력층 뉴런의 값( $S_1, S_2$ )을 출력한다(Figure 2.1, 2.2)(Olivares, 2012).

인공신경망의 학습과정은 신경망의 피드백을 통해 검증된다. 먼저, 인공신경망에 사용하는 첫 번째 학습 모델을 정규화 시키고, 역전파 신경망이나 최소 자승법을 이용하여 각 인공 신경망의 가중치에 대한 평가를 수행한다. 인공신경망을 적용하여 계산된 출력 값과 목표 값을 비교하여 평균 제곱 오차 또는 지정된 반복 횟수에 도달할 때까지 반복한다.

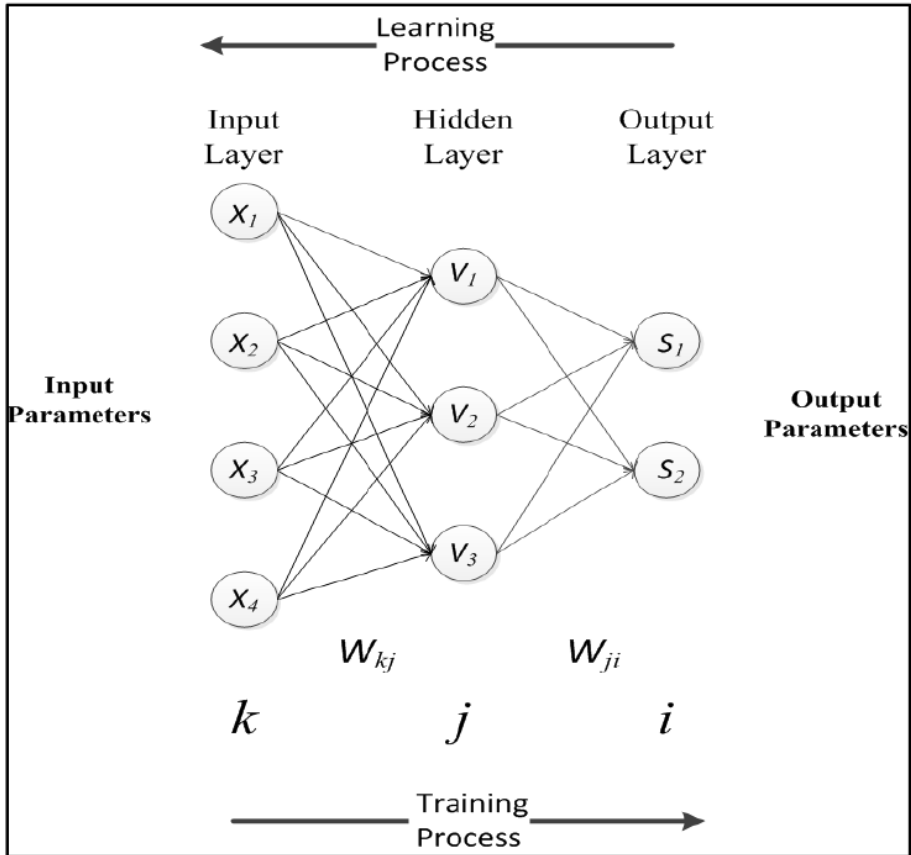


Figure 2.1 Neural network general scheme(Oilvares et al., 2012).

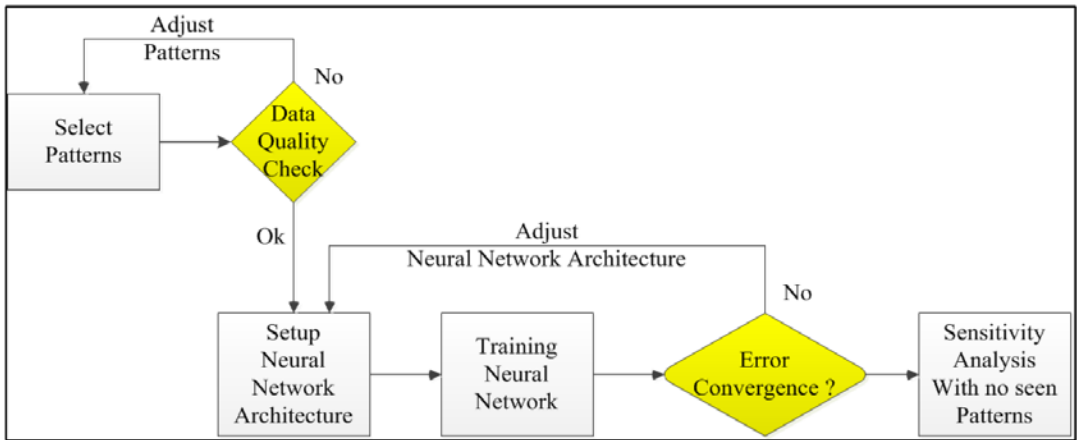


Figure 2.2 General neural network flowchart(Oilvares et al., 2012).



## 제2절 역전파 신경망(Back-Propagation Networks)

역전파 신경망의 ‘역전파’는 역방향의 오차 전파라는 뜻으로써, 인공지능의 한 분야인 인공신경망을 학습시키기 위한 가장 기본적이고 일반적인 알고리즘이라고 할 수 있다. 역전파 신경망은 인공신경망의 입력층에 입력 패턴을 입력하고 이후 은닉층을 거쳐 출력층으로 값을 출력하게 한다. 이후, 신경망을 통해 생성된 출력 값과 목적 값에서 오차가 발생한 경우 신경망을 통해 거꾸로 전파하면서 가중치를 수정하게 된다.

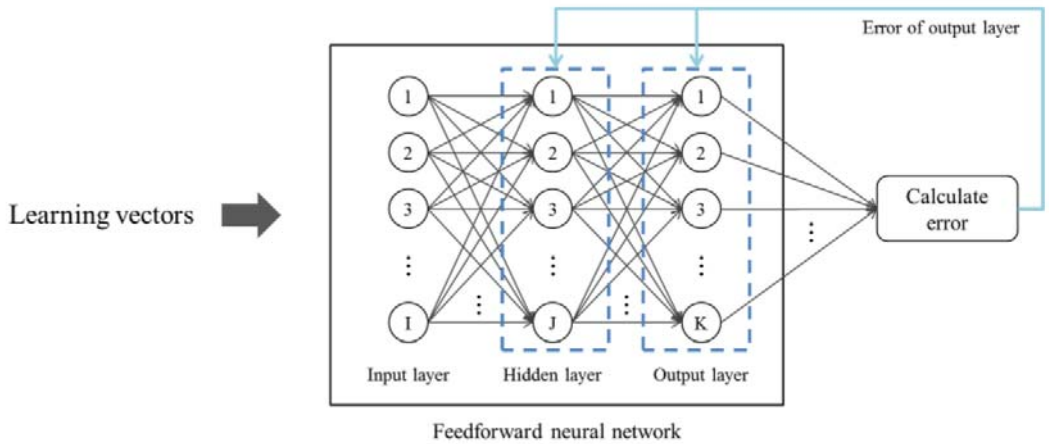


Figure 2.3 Application of back propagation algorithm to ANN(Centilmen et al., 1999).

역전파 신경망은 최소 3개 이상의 뉴런으로 구성되어 있으며, 각 뉴런은 층으로 연결되어 있다. 첫 번째 층은 입력층이며, 여러 개의 입력 뉴런으로 구성되어 있다. 세 번째 층은 출력층으로 출력 뉴런으로 구성되어 있으며, 각 출력 뉴런은 입력 뉴런으로부터의 결과가 산출된다. 입력층과 출력층 사이의 중간층을 은닉층이라 하며, 각 은닉층의 뉴런은 입력층의 뉴런에서 입력 값을 받고 출력층의 뉴런에 값을 출력한다. 각 뉴런들 간의 연결을 가중치라 하며 가중치는 입력 패턴의 특성을 나타낸다.

신경망의 훈련은 뉴런간의 가중치의 값을 결정하는 것으로 정의할 수 있다. 인공

신경망을 훈련시키기 위해서는 입력 자료와 출력 자료가 필수적이며, 각각의 입출력 자료 집합은 서로 매칭이 되어야 한다. 훈련된 신경망은 훈련된 가중치를 사용하여 주어진 입력 자료에 대해 정확한 결과를 제공할 수 있다.

역전파와 신경망의 훈련과정은 다음과 같다(Centilmen et al., 1999).

- 1) 뉴런간의 가중치를 [0-1] 사이의 값으로 초기화 시킨다.
- 2)  $V$ 는 입력층과 은닉층 사이의 가중치로 설정하고,  $W$ 를 은닉층과 출력층간의 가중치로 설정하여 입력 및 출력 자료의 정규화를 진행한다. 훈련에 사용되는 전달 함수에 따라 정규화 값이 달라진다. log-sigmoid 함수를 사용할 경우 [0,1] 사이의 값, tan-sigmoid 함수를 사용할 경우 [-1,1] 사이의 값으로 정규화 된다.
- 3) 정규화 된 입력 뉴런( $I$ )과 초기 가중치의 곱( $I_x V$ )을 은닉층으로 보낸다. 은닉층 뉴런의 값( $y$ )은 뉴런이 받는 모든  $I_x V$ 의 합이다. 출력층 뉴런( $\sigma$ )을 계산하기 전에 전달함수가 모든 ( $y$ )값에 적용된다. 일반적으로 S형 시그모이드 전달 함수가 많이 사용된다.

$$f(y) = \frac{1}{1 + e^{-y}} \dots\dots\dots (1)$$

- 4) 은닉층 뉴런의 값( $y$ )과 은닉층과 출력층( $W$ ) 간의 가중치를 곱한 다음 결과값을 전달 함수에 적용함으로써 출력 값을 구한다.
- 5) 계산된 출력 값과 목표 값을 비교하여 허용오차를 만족하는지 확인한다.
- 6) 만약 허용오차를 만족하지 못한다면 각 층 사이의 모든 가중치를 수정하게 된다. 가중치의 수정 과정은 출력층에서 입력층으로 거꾸로 전파하면서 진행된다. 이러한 훈련 과정은 계산된 출력 값과 목표 값 사이의 허용 오차를 만족할 때까지 반복하여 수행된다.

### 제3절 순차적 인공신경망

순차적 인공신경망은 일련의 인공 신경망을 순차적으로 적용하고 미리 정의된 기준을 만족하는 탐색 공간을 선택함으로써 점차적으로 탐색 공간을 줄이는 방법이다. 다음 단계의 인공 신경망에서 사용될 학습 데이터의 수는 이전 네트워크에서 사용된 훈련 데이터와 이전에서 결정된 탐색 공간에서 새롭게 선택된 데이터로 구성된다. 탐색 공간의 범위를 좁혀가면서 최종적으로 남은 공간에 대해 저류층 시물레이션을 수행하게 되면 정확한 광역해를 찾을 수 있다. 또한, 훈련 데이터를 누적하여 인공 신경망을 반복적으로 구축하기 때문에 인공 신경망의 예측 성능을 향상시킬 수 있다는 장점을 가진다(김유미, 2017).

Figure 2.4는 순차적 인공신경망의 과정을 나타낸 순서도이다.

- 1) 인공신경망의 학습에 사용될 훈련 데이터 수(a), 입출력 자료, 차기 인공신경망을 이용한 결과 예측에 사용될 상위 데이터의 비율(b)을 설정한다.
- 2) 저류층 시물레이션을 통해 훈련 데이터의 값을 확보하고 초기 ANN 모델 1을 학습하는데 사용한다.
- 3) 광역해를 찾을 탐색 공간을 정의한 후, ANN 모델 1을 사용하여 탐색 공간의 목적 함수를 예측한다. 목적함수는 누적 석유 또는 가스 생산량, NPV 또는 그 두 가지 등이 될 수 있다.
- 4) 목적 함수의 값을 오름차순 또는 내림차순으로 정렬한다.
- 5) 초기에 설정한 선택 비율(b)만큼 상위데이터를 선정하여 다음 모델의 새로운 탐색 공간으로 설정한다. 컷오프 비율(b)은 새로운 탐색 공간에서 광역해를 포함할 수 있을 정도로 충분히 커야하지만 너무 큰 값을 사용하는 경우 프로세스의 수렴 속도를 감소시킬 수 있다. 수렴속도를 고려하여 초기 ANN 모델에서는 컷오프 비율로 작은 값을 사용하였고, 반복적으로 모델을 구성하면서 점점 더 큰 값을 사용하였다.
- 6) 다음 ANN 모델을 만들기 위해 추가되는 훈련 데이터 개수(c)는 초기 훈련 데이터 수(a)보다 작게 설정하고, 3)의 탐색 공간에서 가장 상위 값을 포함하여 일정한 간격으로 추출하였다. ANN 예측값이 가장 상위에 위치한 값을 훈련 데이터에 추가하게 되면 광역해가 훈련 데이터에 포함될 확률이 커지게 된다.

- 7) 추가할 훈련 데이터를 저류층 시뮬레이션을 통해 목적 함수 값을 획득하고 기존 훈련 데이터와 결합하여 ANN 모델 2를 학습하는데 사용한다.
- 8) 컷오프 비율에 따라 남은 탐색공간과 추가하는 훈련 데이터 수를 비교한다. 탐색공간의 수가 추가되는 훈련 데이터 수보다 적으면 순차적 인공신경망을 종료하고, 남은 탐색공간을 저류층 시뮬레이션을 통해 목적함수 값을 획득한다.
- 9) ANN 모델을 훈련시키는데 사용한 훈련 데이터와 남은 탐색공간의 목적함수 값을 비교하여 광역해를 찾는다.

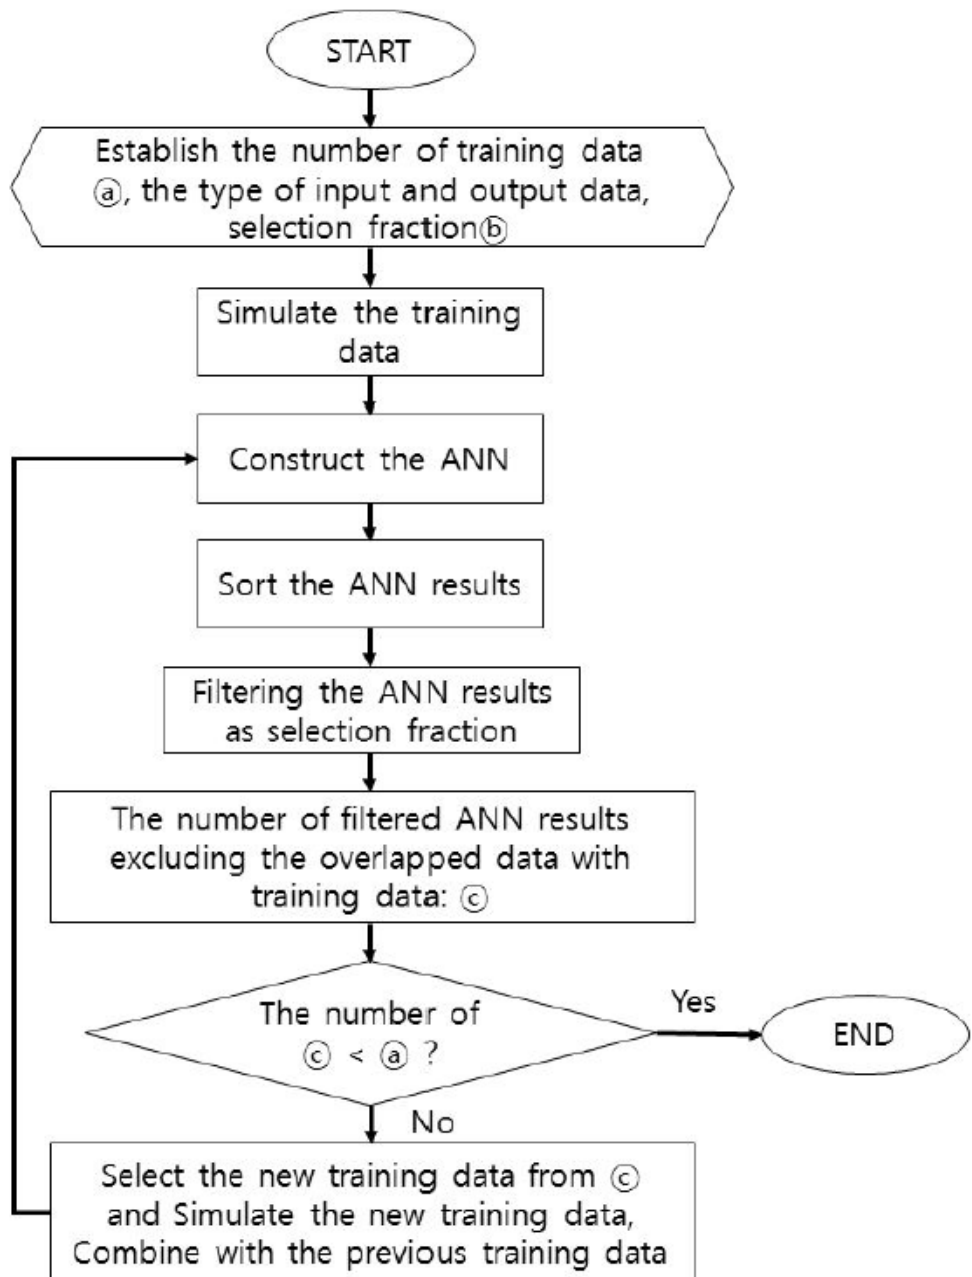


Figure 2.4 Flow chart of well placement optimization using sequential Artificial Neural Network(김유미, 2017).

## 제3장 다생산정 시추 위치 최적화 모델 개발

### 제1절 다생산정 시추 위치 최적화 과정

기존의 다생산정 시추 위치 최적화 연구는 전문가의 경험 및 직관으로 선정한 검증 시나리오에 대해 인공신경망을 적용하였다. 하지만, 이는 다생산정이 전체 저류층에 위치할 수 있는 모든 경우의 수를 고려하지 않아 정확한 광역해를 얻지 못하는 한계가 존재한다. 본 연구에서는 저류층 내에 다생산정이 위치할 수 있는 모든 경우의 수를 고려하여 최적화를 수행하기 위해 계층적 격자 시스템(hierarchical grid system)에 순차적 인공신경망을 적용하는 방법을 제안하였다. 먼저, 계층적 격자 시스템 중 1단계 격자시스템은 다음과 같은 가정을 바탕으로 구성한다. 즉, 저류층 모델의 기본 격자시스템에서  $n_1 \times n_1$  격자당 시추정 1개가 위치할 수 있도록 가상의 격자시스템을 구축한다.

Figure 3.1과 3.2은 2개 시추정의 최적위치를 선정하는 방법에 대한 절차를 나타낸다. Figure 3.2에서 1단계 격자시스템은  $5 \times 5$  격자 당 하나의 시추정이 위치할 수 있도록 구성하였다. 이렇게 하면 전체 격자시스템을 모두 사용하는 것에 비해 시추정 위치에 대한 경우의 수를 크게 감소시킬 수 있다. 이 격자시스템에 대해 순차적 인공신경망을 적용하여 최적의 위치를 찾을 수 있다. 이 때 불확실성을 고려하기 위해 순차적 인공신경망을 통해 도출된 상위  $r_1$  랭크까지의 영역을 모두 결합하여 다음 격자 시스템의 탐색 공간으로 선정한다. Figure 3.2에서는 상위 5랭크까지의 위치를 모두 결합하여 새로운 탐색 공간으로 선정하였다.

새롭게 정의된 탐색 공간에서 기본 격자시스템을 적용할 경우, 고려해야하는 경우의 수가 많을 경우 2단계 격자시스템을 도입한다. 즉, 새로운 탐색공간을  $n_2 \times n_2$  격자 당 하나의 시추정이 위치할 수 있도록 구성한다. 이때  $n_2 < n_1$ 가 되도록 하여 이전 계층 격자시스템보다 해상도가 더 높게 유지한다. Figure 3.2에서는 두 번째 격자시스템으로  $3 \times 3$  격자 당 하나의 시추정이 놓일 수 있도록 하였다. 이 격자 시스템에서 순차적 인공신경망을 적용하여 광역해를 구한다. 이때 상위  $r_2$  랭크까지의 값을 사용하여 다음 탐색 공간을 구축한다. Figure 3.2에서는 상위 3 랭크까지의 값을 사용하여 새로운 탐색 공간을 구성하였다. 이와 같은 과정을 반복하여 인공신

경망 기법의 적용성을 높임과 동시에 계층적 격자시스템의 사용에 따른 불확실성을 개선할 수 있다. 마지막으로 새롭게 구성된 탐색 공간에 대해 기본 격자시스템을 사용하여도 충분히 작아진 경우, 3단계 격자시스템 즉, 기본 격자시스템에 대해 순차적 인공신경망을 적용하여 광역해를 구한다.

결과적으로 Figure 3.2에서는 3단계의 계층적 격자시스템을 사용하여 순차적 인공신경망을 적용하였다.

- 1단계 격자시스템: 기본 격자시스템을  $5 \times 5$  크기의 영역으로 분할
- 2단계 격자시스템:  $5 \times 5$ 에서 도출된 상위 5위까지의 영역을 확장하여  $3 \times 3$  크기로 격자시스템을 분할
- 3단계 격자시스템:  $3 \times 3$ 에서 도출된 상위 3위까지의 영역을 확장하여 기본 격자시스템 사용

훈련정 선정 시, 훈련정이 다양한 생산 패턴을 학습할 수 있도록 선정한다. 또한, 각 단계에서 새롭게 도출된 탐색 공간 내에서 인공신경망이 패턴을 인식할 수 있도록 규칙성을 부여해 준다. 이러한 훈련정을 사용하여 인공신경망 모델을 구축하고 순차적 인공신경망을 이용하여 최적 시추 위치를 선정한다.

각 인공신경망 모델에서 사용한 순차적 인공 신경망 방법은 인공 신경망을 순차적으로 적용하고 미리 정의 된 기준을 만족하는 탐색 공간을 선택함으로써 점차적으로 탐색 공간을 줄여나갔다. 매 단계의 인공신경망에서 사용될 학습 데이터의 수는 이전 인공신경망에서 사용된 훈련 데이터와 이전에서 결정된 탐색 공간에서 새롭게 선택된 데이터로 구성된다. 탐색 공간의 범위를 좁혀가면서 최종적으로 남은 공간에 대해 저류층 시뮬레이션을 수행하게 되면 정확한 광역해를 찾을 수 있다. 또한, 훈련 데이터를 누적하여 인공신경망을 반복적으로 구축하기 때문에 인공신경망의 예측 성능을 향상시킬 수 있다는 장점을 가진다.

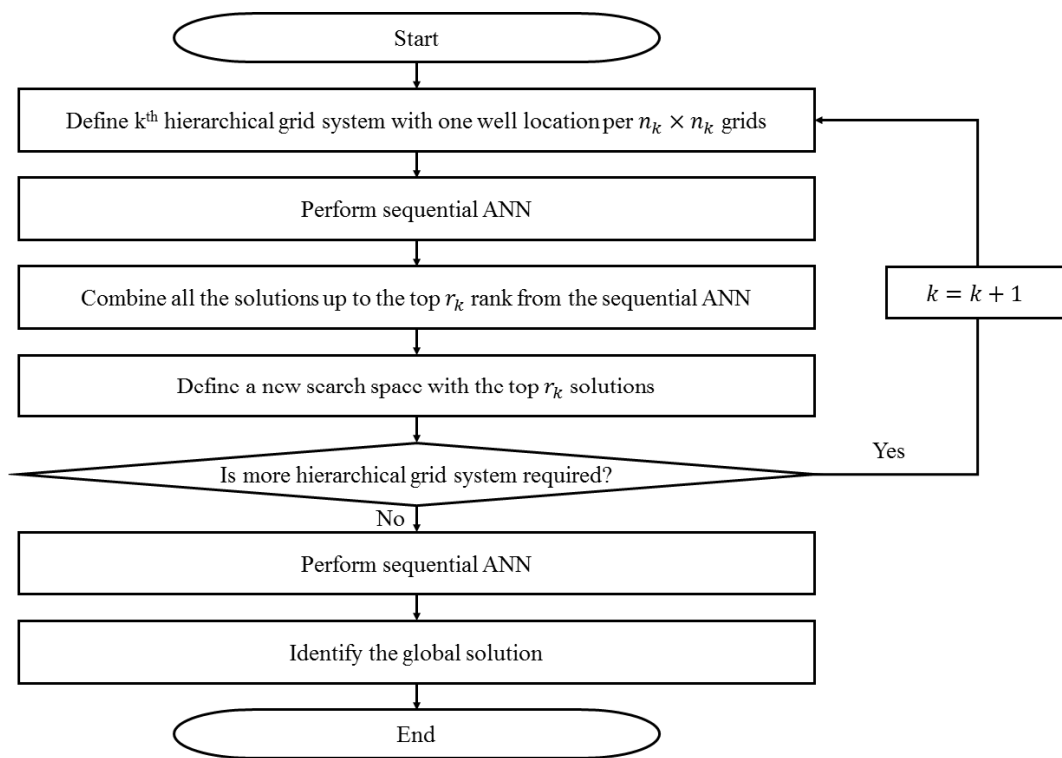


Figure 3.1 Flow chart of multi-well placement optimization.



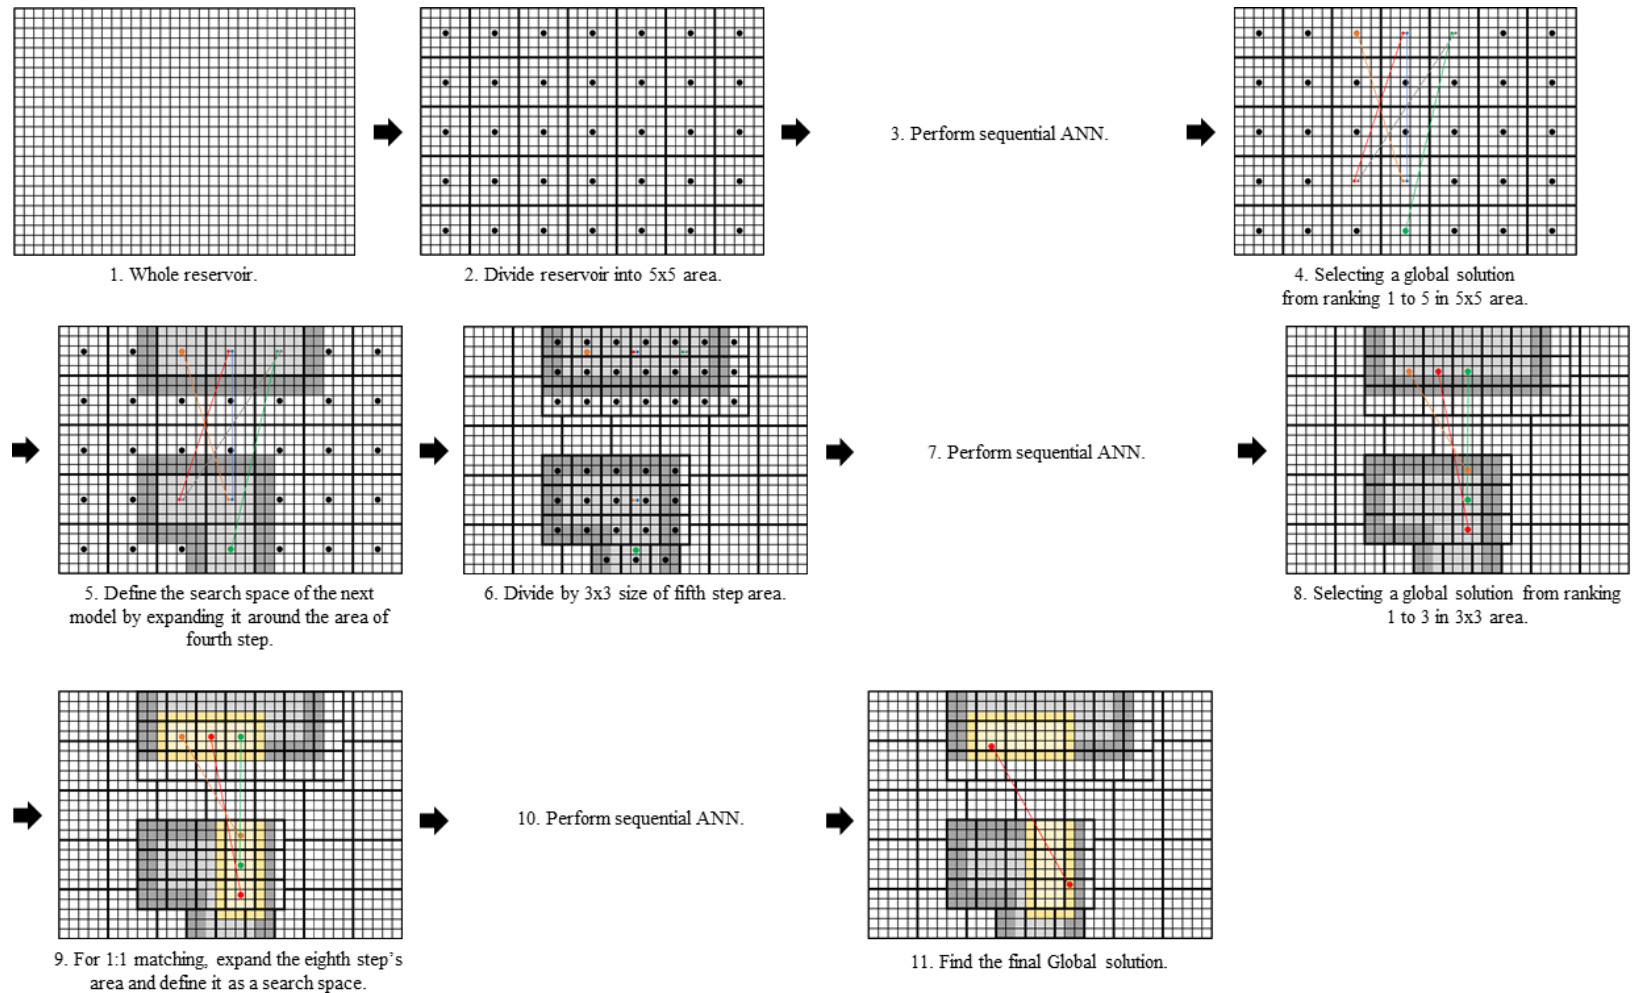


Figure 3.2 Optimization procedure for 2-well placement problem.

## 제2절 인공신경망 학습 자료 선정

인공신경망 설계 시 훈련정을 선정하는 것은 매우 중요하다. 훈련정의 수가 증가 증가할수록 예측성능은 향상되지만, 학습에 소요되는 시간 또한 증가한다. 그러므로 인공신경망 모델의 예측성능을 유지할 수 있도록 적절한 수의 훈련정을 선정해야 한다.

훈련정이 다양한 생산 패턴을 학습할 수 있도록 생산성이 우수한 유체투과도가 높은 지역, 생산성이 떨어질 것으로 예상되는 지역, 간섭효과를 고려하여 유정 간의 거리가 가까울 때와 멀리 있을 때 등의 경우를 모두 고려하여 훈련정을 선정해야 한다.

본 연구에서는 저류층 경계와의 근접성을 고려하여 외부 경계 100m를 제외하고 훈련정을 선정하였다. 또한, 각 단계에서 도출된 광역해의 관계와 탐색 공간의 수를 고려하여 훈련정을 선정하였다. 먼저, 1단계는 전체 저류층이 탐색 공간이므로, 저류층을 대상으로 고르게 훈련정을 선정해 주었다. 다음 2단계에서는 기존 1단계에서 사용했던 훈련정 중에, 광역해의 관계를 가진 훈련정을 유지하였고, 추가적으로 정의된 영역 내에서 훈련정을 선정하였다. 마지막 기본 격자시스템을 사용하는 단계에서는 전 단계에서 이미 훈련정의 위치가 고려되었기 때문에 기존 훈련정을 전부 사용하였다.

### 제3절 인공신경망 입출력 자료

인공신경망의 입력 자료는 결과 값 예측에 큰 영향을 미치므로 매우 중요한 자료이다. 불필요하거나 과도한 입력 자료는 인공신경망의 예측 성능을 저하시킬 뿐만 아니라, 학습 시간을 지연시키므로, 적절한 입력 자료를 선정해야 한다.

다양한 입력 자료의 민감도 분석을 수행한 결과, 사용한 입력 자료는 추가 생산정의 공간적 위치 정보, 생산정간 상관관계 등으로 구성하였다. 추가 생산정의 공간적 위치 정보로는 추가 생산정의 위치 좌표, 추가 생산정과 저류층 경계와의 거리(동, 서, 남, 북)를 사용함으로써 공간적인 정보에 대한 패턴을 인공신경망에 제공하였다. 유정 간 간섭효과를 고려하기 위한 생산정간 상관관계는 추가 생산정과 기존 생산정간의 거리와 추가 생산정 간의 거리를 사용하였다(Figure 3.3, Table 3.1). 출력 자료는 누적 가스 생산량을 사용하였다(Table 3.2).




Figure 3.3 The structure of ANN model.

Table 3.1. Input data for the artificial neural network in the case of 2 infill wells with 6 existing wells

Description of the input neuron	Number of neurons
Infill well x-y coordinates	4
Distance from infill well to the reservoir boundary	8
Inter-distance between existing wells and infill well	12
Inter-distance between 1 infill well and 2 infill well	1

Table 3.2. Output neuron descriptions for the artificial neural network

Description of the output neuron	Number of neurons
Cumulative production rates	1

## 제4장 연구 결과

### 제1절 저류층 시스템

본 연구에서는 Computer Modeling Group(CMG, 2016)에서 개발한 상용 시뮬레이터 『GEM』을 사용하여 석탄층 메탄가스 저류층의 다생산정 위치 선정 연구를 수행하였다. 이를 위해 3차원 저류층 모델을 구축하였고 Figure 4.1에 도시하였다. 저류층 및 저류층 유체 물성은 Table 4.1과 같다. 대상 저류층은 6.1 km × 3.7 km 직사각형의 형태로 6개의 수직 생산정이 위치하고 있다. 저류층은 61 × 37 × 3의 6,771개의 격자로 구성하였고, 격자 간격은 100m이다. 저류층의 두께는 3-10m이다. 기존 6개의 수직정은 (7, 13), (7, 26), (33, 3), (34, 20), (47, 20), (53, 5)에 각각 위치하고 있다.

추가 시추하는 생산정은 수직정으로, 생산조건은 기존 6개의 수직정이 3년을 생산한 후 추가 시추하며, 총 생산기간은 20년으로 하였다.




Figure 4.1 Description of coalbed methane reservoir system.

Table 4.1 Properties of CBM reservoir

Parameters	Values
Size	6.1 km × 3.7 km
Grid	61 × 37 × 3
Cleat spacing	0.1 m
Sorption time(CH <sub>4</sub> )	1 day
Reservoir pressure	791 psi at 300 m
Molar ratio of CH <sub>4</sub> and CO <sub>2</sub>	1(CH <sub>4</sub> ) : 0(CO <sub>2</sub> )
Langmuir volume; V <sub>L</sub> (CH <sub>4</sub> )	598 scf/ton
Langmuir pressure; P <sub>L</sub> (CH <sub>4</sub> )	419 psi
Max. water production rate	5,000 m <sup>3</sup> /day
Permeability Model	Palmer & Mansoori
Matrix Permeability	0.001 md
Permeability of face cleat	43.95 md-105md
Permeability of butt cleat	11 md-26.42md
Matrix porosity	0.08
Cleat porosity	0.02-0.03

## 제2절 생산정 2개의 추가 시추 위치 선정

### 1. 인공신경망의 학습 자료 선정

인공신경망 모델은 입력층 1개, 은닉층 1개, 출력층 1개로 구성되어 있으며, 노드 수는 각각 25, 10, 1개로 설정되었다. 입력변수는 추가 시추정의 위치 좌표, 추가 시추정과 저류층 경계와의 거리(동, 서, 남, 북), 기존 생산정과 추가 시추정간의 거리, 두 개의 추가 시추정간의 거리를 사용하였고, 출력변수는 20년 메탄가스 누적 생산량으로 하였다. 특히 입력변수로 사용한 추가 시추정간의 거리는 초기 ANN 모델의 신뢰성을 높이는데 아주 효과적인 것으로 나타났다.

인공신경망 모델 학습에 사용되는 추가 생산정은 생산정의 공간적 위치 정보, 저류층의 경계, 추가 생산정과 기존 생산정과와의 거리, 추가 생산정간의 거리 등 저류층 인자의 다양한 분포 특성을 적절히 고려할 수 있도록 분포시켰다. 초기 학습 자료는 두 개의 영역 및 유정을 짝을 지어 40쌍을 사용하였으며, 그 중 85%는 학습용, 15%는 시험용으로 사용되었다.

Figure 4.2는 유정 배치도를 나타낸 것으로 회색 격자는 저류층 경계, 흰색 격자는 추가 시추 가능 지역, 파란색 격자는 기존 생산정을 의미한다. 추가 생산정의 수가 2개 일 때, 시추가 가능한 경우는 기존 생산정(6개), 저류층 경계(192개)를 제외한 2,545,698개에 달한다.

순차적 인공신경망 기법에 사용되는 상위 랭킹에 대한 컷오프 비율 R은 각각 15, 20, 25, 30%로 설정하였으며, 인공신경망 모델은 MATLAB을 사용하여 개발하였다.




Figure 4.2 Grid system of 2 infill-well case.



## 2. 광역적 최적 추가 시추위치 결정

### 가. 1단계 격자시스템을 사용한 최적 위치 선정

기본 격자시스템을  $5 \times 5$  단위로 나누어 1단계 격자시스템을 구성하고 초기 ANN 모델을 학습하는 데 유정 40쌍을 사용하였다(Figure 4.3). 여기서 진한 검은 실선은 1단계 격자시스템을 의미하며, 녹색 격자는 선정된 훈련정 40 쌍의 위치를 의미한다. 1단계 격자시스템에서 2개의 생산정을 시추할 수 있는 총 경우의 수는 3,271개로 계산되었다. 제안된 방법의 신뢰도를 분석하기 위해 우선 모든 경우에 대해 저류층 전산 모사를 수행하여 최적 위치를 확인하였다. 그 결과, 누적 가스 생산량이 최대가 되는 생산정의 위치는 (29, 34)과 (34, 9) 격자로 나타났으며, 해당 위치는 Figure 4.3에 노란색으로 표시되어 있다.




Figure 4.3. Well location for 2 infill-well case.

Figure 4.4(a)는 40쌍의 훈련 데이터를 사용하여 학습된 ANN 모델 1과 ANN 모델 1을 사용하여 총 3,271개 탐색 공간에 대해 누적 가스 생산량을 예측한 결과이다. Figure 4.4(b)의 가로축은 시뮬레이션, 세로축은 인공신경망의 결과를 나타낸다. 컷오프는 상위 15%로 하였고, 핑크색 라인이 컷오프 라인, 빨간 점이 광역해, 파란 점이 탐색 공간, 연두색 점이 ANN 모델 1을 학습하는데 사용된 훈련 데이터 40개이다. 분홍색 선 위의 점들은 ANN 모델을 적용한 결과 상위 15%에 해당하는 값들이며, 이는 다음 인공신경망 모델의 524개 탐색 공간이 된다. Figure 4.4(c)는 새로운 탐색 공간의 지도를 보여준다. 녹색은 학습 데이터, 빨간색은 축소된 탐색 공간(524개), 파란색은 기존의 수직정 6개, 노란색은 광역해를 나타낸다. 광역해는 상위 1.96 %에 위치해있다.

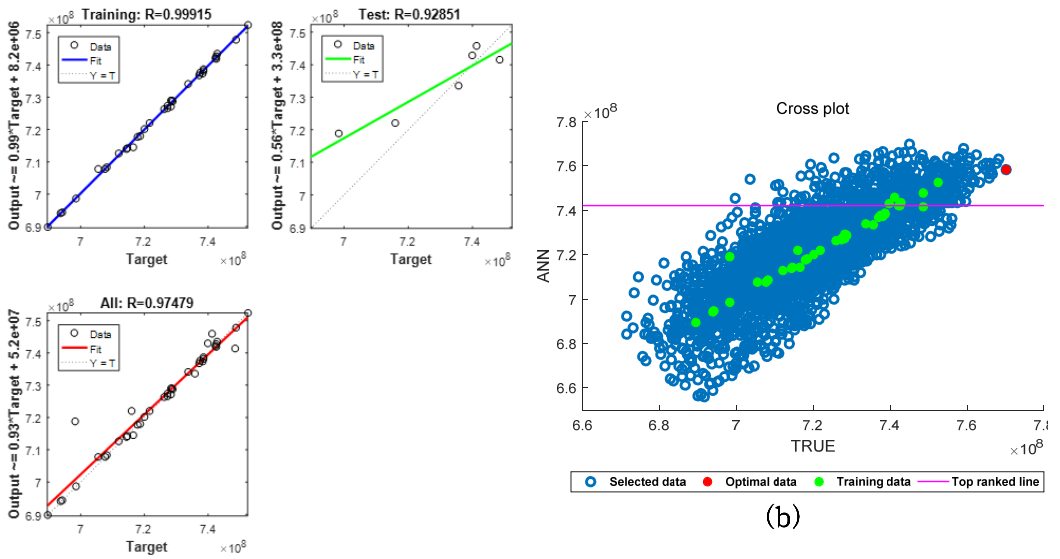
순차적 인공신경망의 두 번째 ANN 모델2를 훈련시키기 위해 모델 1에서 축소된 탐색공간인 524개를 등간격으로 나누어서 가장 인공신경망 예측 값이 높은 데이터를 포함한 10개를 훈련 데이터로 선정한다. 새롭게 정의된 10쌍의 훈련 데이터를 시뮬레이션을 통해 정확한 값을 획득하고, 기존 40쌍의 훈련 데이터와 결합하여 ANN 모델 2를 구축한다. Figure 4.5(a)는 학습된 ANN 모델 2로, 모델 1에 비해 신뢰도가 높음을 확인할 수 있다. Figure 4.5(b)는 ANN 모델 2를 사용하여 새로운 탐색 공간에 대해 누적 가스 생산량을 예측한 결과이다. 컷오프는 상위 20%로 하였으며, 새로운 탐색공간 153개가 정의되었다. 이때, 광역 해는 상위 0.95%에 위치한다. Figure 4.5(c)는 탐색 공간의 지도로, Figure 4.5(c)와 비교했을 때, 탐색공간이 광역 해에 가깝게 수렴되고 있음을 확인할 수 있다.

탐색공간이 153개로, 추가되는 훈련 데이터에 비해 여전히 많으므로 앞선 방법과 동일하게 훈련 데이터 10쌍을 추출하여 정확한 시뮬레이션 값을 획득한다. 기존 50쌍의 훈련데이터와 결합하여 총 60쌍을 구성하여 ANN 모델 3을 훈련시키는데 사용한다. ANN 모델 3을 사용하여 153개의 탐색공간에 대해 누적 가스 생산량을 예측하고, 컷오프는 상위 25%로 설정하였다. 탐색 공간이 줄어들고 훈련 데이터의 수가 증가함에 따라 ANN 모델 2에 비해 모델 3에서 예측된 값과 시뮬레이션 값과의 차이가 많이 줄어들음을 확인할 수 있다(Figure 4.6). ANN 모델 3을 적용한 결과 광역해는 상위 1.96%에 위치하며, 컷오프를 적용한 결과 탐색 공간은 96개가 정의되었다.

상위 25%를 컷하여 남은 탐색공간이 96개로 추가하는 훈련데이터의 2배인 20쌍


보다 많으므로 ANN 모델을 다시 훈련시킨다. 추가된 10쌍의 훈련 데이터와 기존 데이터가 결합되어 총 70쌍을 사용하여 ANN 모델 4를 구축한다. ANN 모델 4를 사용한 결과 광역해는 6.38%에 위치하는 것으로 나타났으며 30% 컷오프를 실행하여 남은 탐색 공간은 14개로 나타났다(Figure 4.7). 남은 14개의 탐색 공간에 대해 시뮬레이션을 수행하여 정확한 값을 얻어 기존에 사용한 70쌍의 훈련데이터 값과 비교하여 가장 큰 값을 갖는 데이터를 찾으면 본 알고리즘은 종료된다. 인공신경망을 활용하여 정확한 광역해를 찾기 위해 필요한 시뮬레이션 횟수는 총 84회로 확인되었다(Table 4.2). 시뮬레이션을 통해 도출된 광역해는 (29, 34)-(34, 9)이며, 누적가스 생산량은 770,267,520 m<sup>3</sup>이다(Figure 4.8). 석탄층 메탄가스 저류층에 시추한 결과 메탄의 흡착량은 Figure 4.9과 같이 확인할 수 있다. Figure 4.10에 나타난 탐색영역의 지도를 통해 탐색 공간이 광역해를 중심으로 점차 좁혀지고 있음을 확인할 수 있다. 또한, 추가되는 훈련 데이터가 광역해 부근에서 추가되므로, Figure 4.4(a)-4.7(a)와 같이 인공신경망 모델의 정확도를 향상시키는데 도움이 되는 것으로 판단된다.

본 연구의 신뢰성을 위해 10회 반복한 결과는 Table 4.3와 같다. 수 회 반복한 결과 광역해가 항상 남아있는 것을 확인하였고, 광역해를 찾기 위해 필요한 시뮬레이션 횟수는 초기 훈련 데이터를 40쌍으로 시작했을 때 최소 83회, 최대 86회로 나타났다.



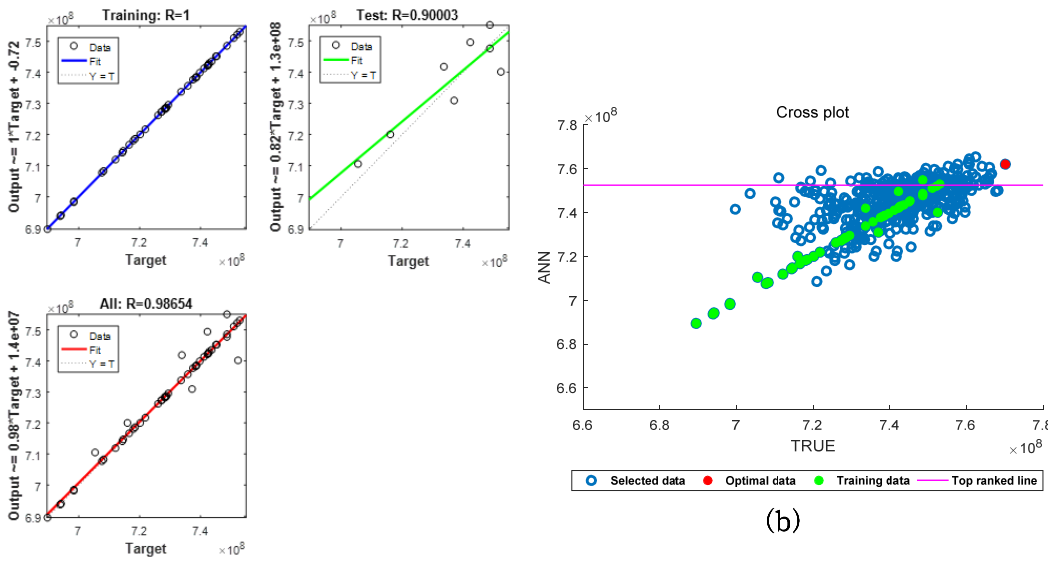
(a)

(b)




(c)

Figure 4.4 Result of initial ANN model.((a) Training result of initial ANN model, (b) Cross plot of ANN model and simulation results, (c) Top 15% of search space using initial ANN model)



(a)

(b)



(c)

Figure 4.5 Result of 2<sup>nd</sup> ANN model.((a) Training result of 2<sup>nd</sup> ANN model, (b) Cross plot of ANN model and simulation results, (c) Top 20% of search space using 2<sup>nd</sup> ANN model)

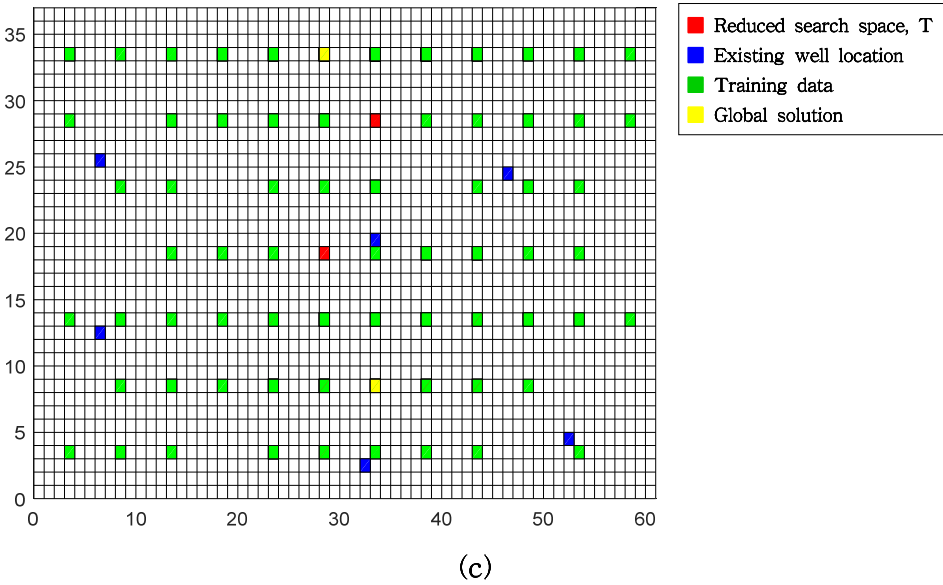
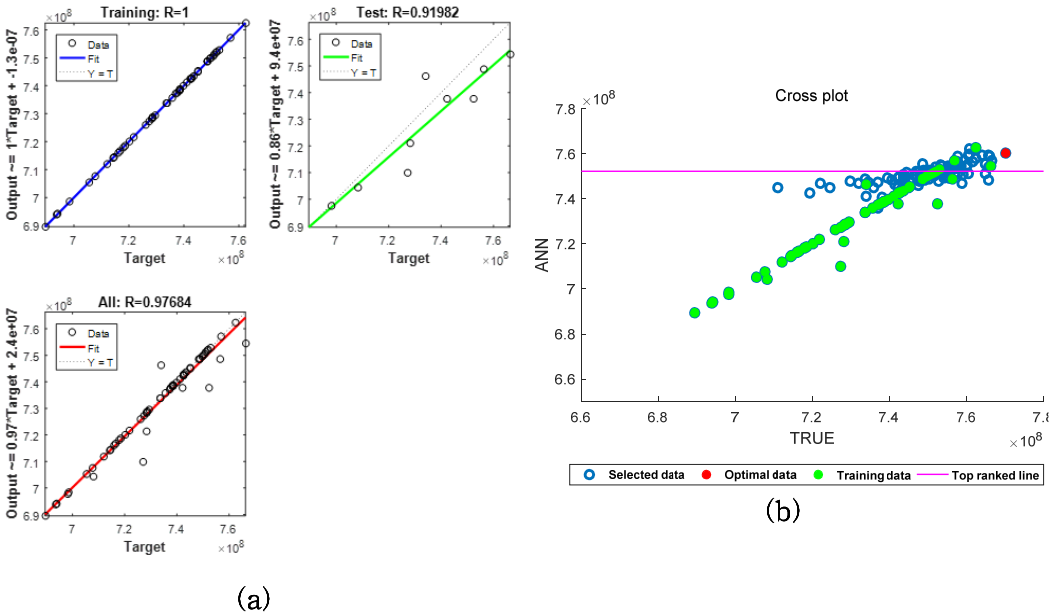
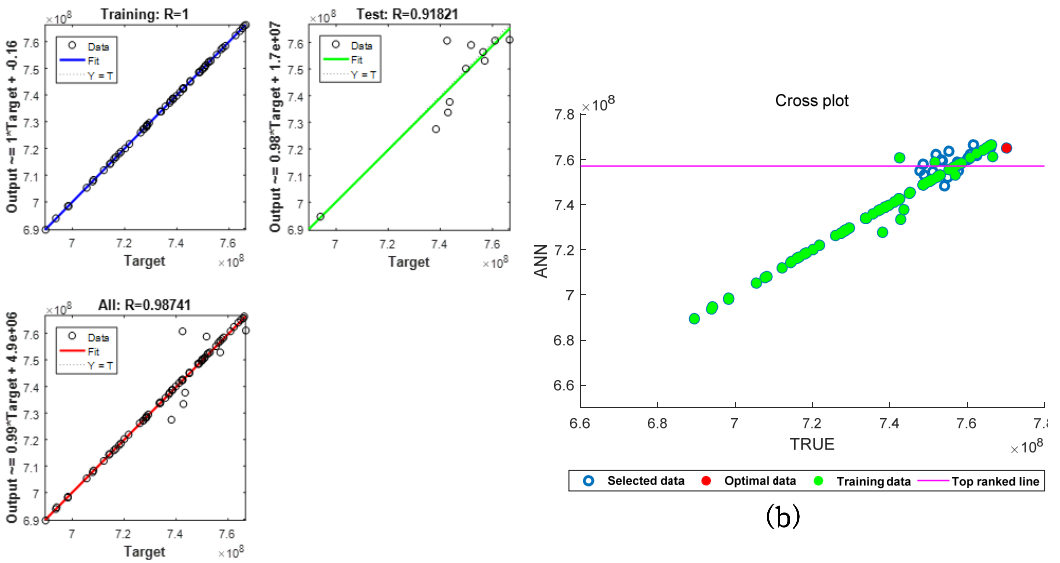



Figure 4.6 Result of 3<sup>rd</sup> ANN model.((a) Training result of 3<sup>rd</sup> ANN model, (b) Cross plot of ANN model and simulation results, (c) Top 25% of search space using 3<sup>rd</sup> ANN model)



(a)

(b)



(c)

Figure 4.7 Result of 4<sup>th</sup> ANN model.((a) Training result of 4<sup>th</sup> ANN model, (b) Cross plot of ANN model and simulation results, (c) Top 30% of search space using 4<sup>th</sup> ANN model)

Table 4.2 Summary of applying the hierarchical ANN of 2 infill wells(Step 1)

ANN model	Cutoff value(%)	Number of training data	New search space	Rank of global solution	Total number of simulation runs
1 <sup>st</sup>	15	40	524	1.96	40
2 <sup>nd</sup>	20	50	153	0.95	50
3 <sup>rd</sup>	25	60	96	1.96	60
4 <sup>th</sup>	30	70	14	6.38	70




Figure 4.8 Cumulative gas production rate of 2 infill wells(Step 1).



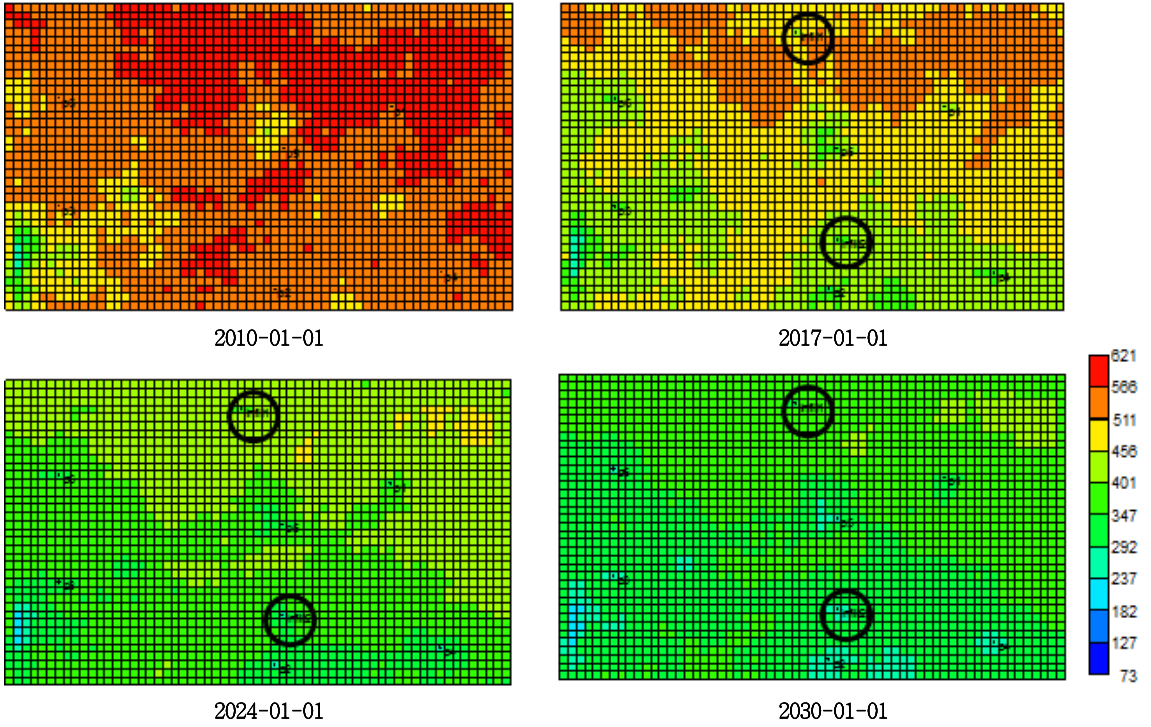


Figure 4.9 Adsorption(CH<sub>4</sub>) of 2 infill wells(Step 1).


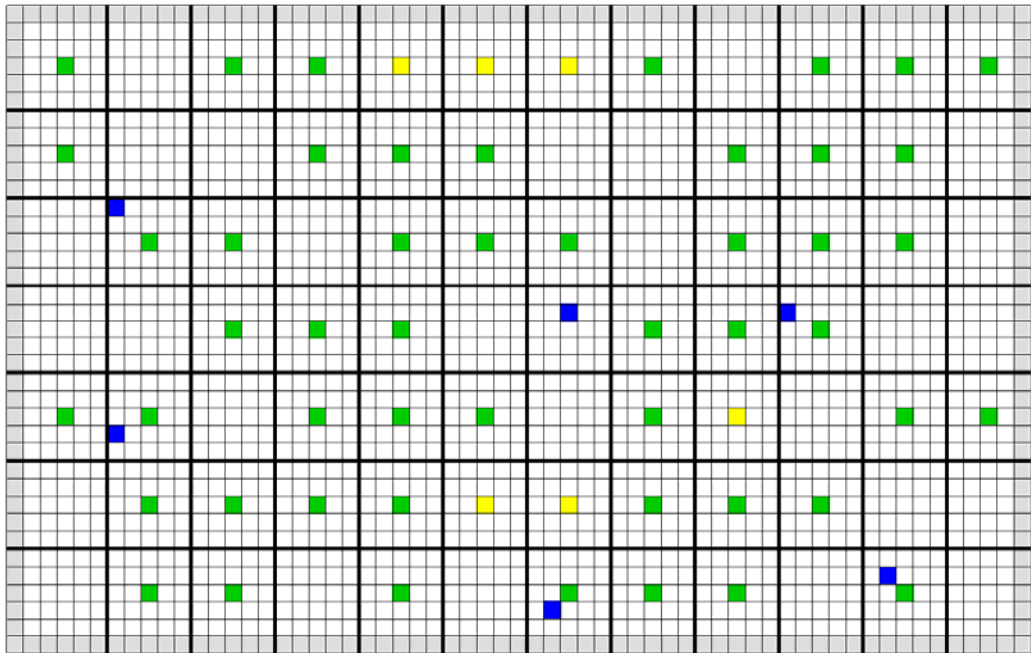


Figure 4.10 Reduced search space of 2 infill wells(Step 1)  
 ((a) initial ANN model, (b) 2<sup>nd</sup> ANN model, (c) 3<sup>rd</sup> ANN model,  
 (d) 4<sup>th</sup> ANN model)

Table 4.3 Results of repeated application of 2 infill wells ANN(Step 1)

Case	Rank of global solution for each ANN model				Total of number simulation runs
	1 <sup>st</sup> (%)	2 <sup>nd</sup> (%)	3 <sup>rd</sup> (%)	4 <sup>th</sup> (%)	
1	1.96	0.95	1.96	6.38	84
2	2.64	4.2	8.43	6.5	83
3	5.60	4.96	8.43	7.4	84
4	4.48	6.75	1.49	3.19	84
5	1.56	3.05	6.84	9.4	85
6	5.61	6.6	8.43	8.5	84
7	1.80	1.64	9.4	8.63	84
8	1.05	3.98	6.84	9.4	86
9	1.96	6.35	8.16	8.19	85
10	1.56	3.05	7.19	8.5	84

2단계 격자시스템을 구축하기 위해 1단계에서 도출된 출력값 상위 1-5위를 사용하여 탐색공간을 선정하였다. 선정된 영역을 확장하여 다음 단계의 새로운 탐색 공간으로 정의한다(Figure 4.11, Table 4.4).



Reservoir boundary  
  Training well  
  Existing well  
  Top 5 solution wells

Figure 4.11 Ranking 1 to 5 of 2 infill wells(Step 1).

Table 4.4 Ranking 1 to 5 of 2 infill wells(Step 1)

	ILoc1	JLoc1	ILoc2	JLoc2	FieldCum(m <sup>3</sup> )
No. 1	29	34	34	9	770,267,520
No. 2	34	9	34	34	768,324,860
No. 3	29	9	29	34	767,565,890
No. 4	24	34	29	9	766,720,130
No. 5	29	34	44	14	766,270,270

## 나. 2단계 격자시스템을 사용한 최적 위치 선정

1단계에서 선정된 상위 1-5위의 위치를 병합하여 2단계 격자시스템을 위한 새로운 탐색 공간을 만들고 3×3으로 영역으로 나뉜다(Figure 4.12). 새롭게 정의된 탐색 공간에서 2개의 시추위치에 대한 경우의 수는 총 528개로 계산되었다. 인공신경망 모델의 학습 성능을 평가하기 위해 대상 저류층에 추가 시추가 가능한 모든 위치에 대해 저류층 전산 모사를 수행한 결과 누적 가스 생산량이 최대가 되는 추가 시추 위치는 (27, 35)-(35, 9)다.

1단계에서 도출된 광역해가 저류층의 남, 북쪽에 각각 1개씩 위치하기 때문에, 1단계에서 사용한 훈련정 중 남쪽과 북쪽의 위치관계를 가진 훈련정을 선정하여 사용하였으며, 새롭게 정의된 영역 내에서 추가 훈련정을 선정하였다. 기존의 훈련정 24쌍과 새롭게 선정된 훈련정 13쌍, 총 37쌍의 훈련정을 사용하여 인공신경망 모델을 학습시켰다. 이후 후속 ANN 모델 구축시 새로운 10쌍의 훈련정을 추가하는 과정을 거쳤다.




Figure 4.12 Training map of 2 infill wells(Step 2).

초기 훈련정 37쌍을 사용하여 학습된 ANN 모델 1은 Figure 4.13과 같다. 전체 528개의 영역에 대해 ANN을 수행한 결과, Figure 4.13(a)를 통해 정확도를 확인할 수 있으며, Figure 4.13(b)를 통해 시물레이션과 인공신경망의 값을 확인할 수 있다. 컷오프는 상위 15%를 적용한 결과 113개의 새로운 탐색 영역을 정의하였다. 광역해는 상위 5.01%에 위치해있음을 확인할 수 있다.

새롭게 정의된 영역 내에서 추가 훈련정 10쌍을 선정하여 ANN 모델 2를 학습시킨 결과는 Figure 4.14(a)와 같다. 총 47쌍의 훈련정을 사용하였으며, 컷오프 20%를 적용한 결과 새로운 탐색 공간 18개가 정의되었다. 이는 훈련정의 수의 2배보다 적기 때문에 인공신경망을 종료하고 남은 영역에 대해 시물레이션을 수행함으로써 광역해를 도출하였다.

최종적으로 남은 탐색 공간 18개, 훈련정으로 선정하기 위해 수행한 시물레이션 23회, 총합 41회의 시물레이션으로 2단계의 최적 시추 위치를 도출하였다. 광역해는 (27, 35)-(35, 9)에 위치해있으며, 누적 가스 생산량은 770,427,650 m<sup>3</sup>이다(Table 4.5, Figure 4.15). 최적 시추 위치에 추가 시추를 수행하였을 때의 메탄의 흡착량을 확인할 수 있다(Figure 4.16).

2단계의 탐색 공간에 대한 지도를 보게 되면, 탐색 공간이 광역해를 향해 점차 수렴되는 것을 확인할 수 있으며, 훈련정이 광역해 주변에서 선정됨으로써 인공신경망 모델의 정확성을 향상시킴을 확인하였다(Figure 4.17).

위와 같은 과정을 10회 반복한 결과, 매 회 광역해가 포함되어 있었으며, 기존 훈련정에 사용된 시물레이션 포함 최소 64, 최대 66회의 시물레이션을 통해 광역해를 도출해 낼 수 있었다(Table 4.6).


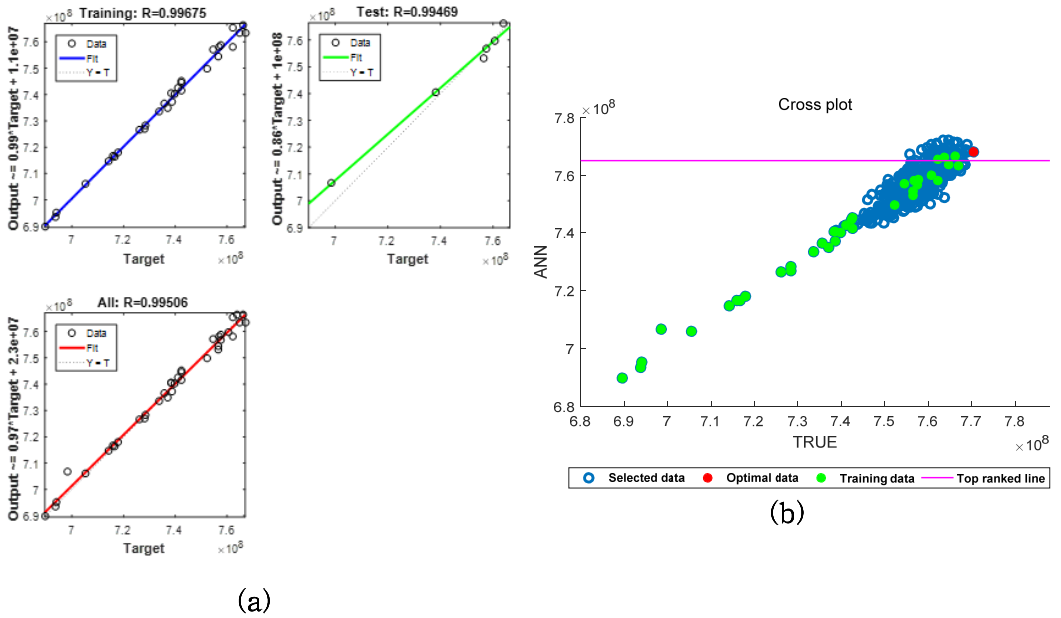
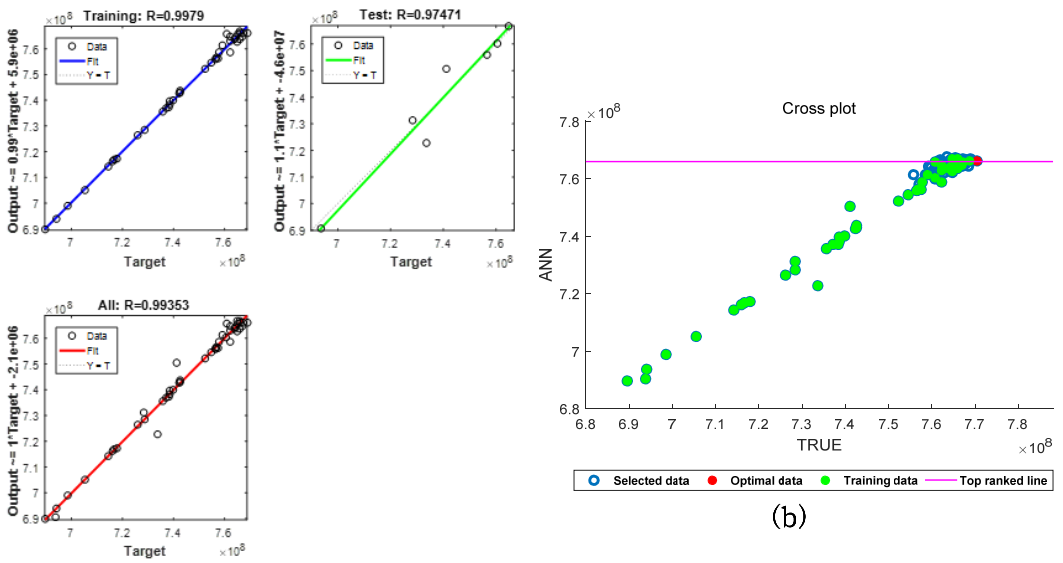



Figure 4.13 Result of initial ANN model.((a) Training result of initial ANN model, (b) Cross plot of ANN model and simulation results, (c) Top 15% of search space using initial ANN model)



(a)

(b)



(c)

Figure 4.14 Result of 2<sup>nd</sup> ANN model.((a) Training result of 2<sup>nd</sup> ANN model, (b) Cross plot of ANN model and simulation results, (c) Top 20% of search space using 2<sup>nd</sup> ANN model)



Table 4.5 Summary of applying the hierarchical ANN in 2 infill wells(Step 2)

ANN model	Cutoff value(%)	Number of training data	New search space	Rank of global solution	Total number of simulation runs
1 <sup>st</sup>	15	37	113	5.01	13
2 <sup>nd</sup>	20	47	18	0.95	23

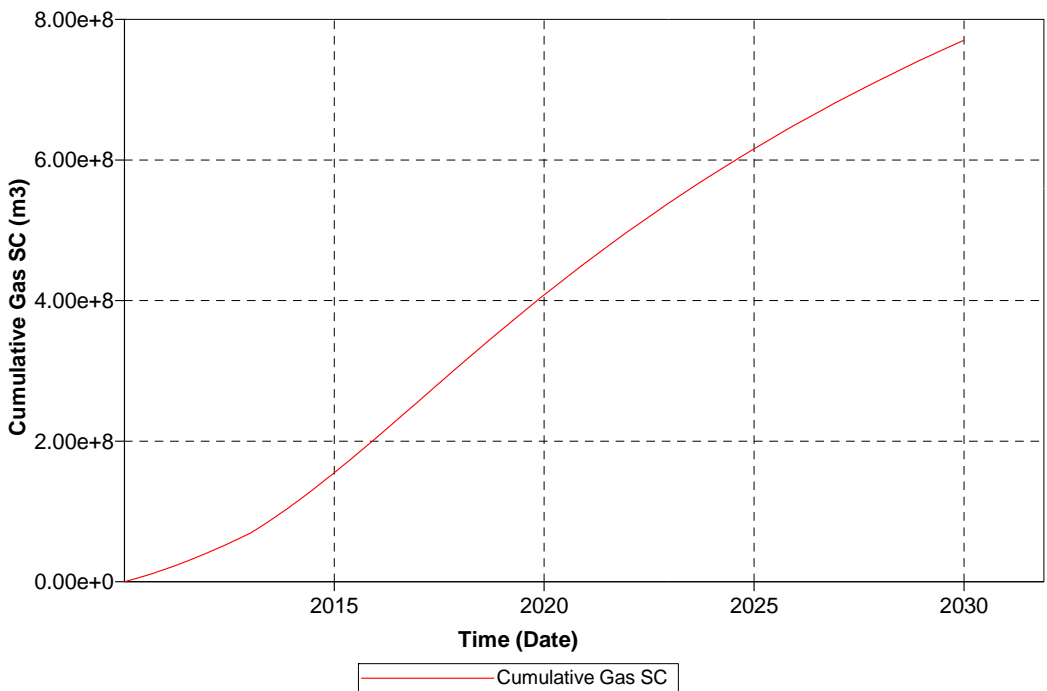


Figure 4.15 Cumulative gas production rate of 2 infill wells(Step 2).

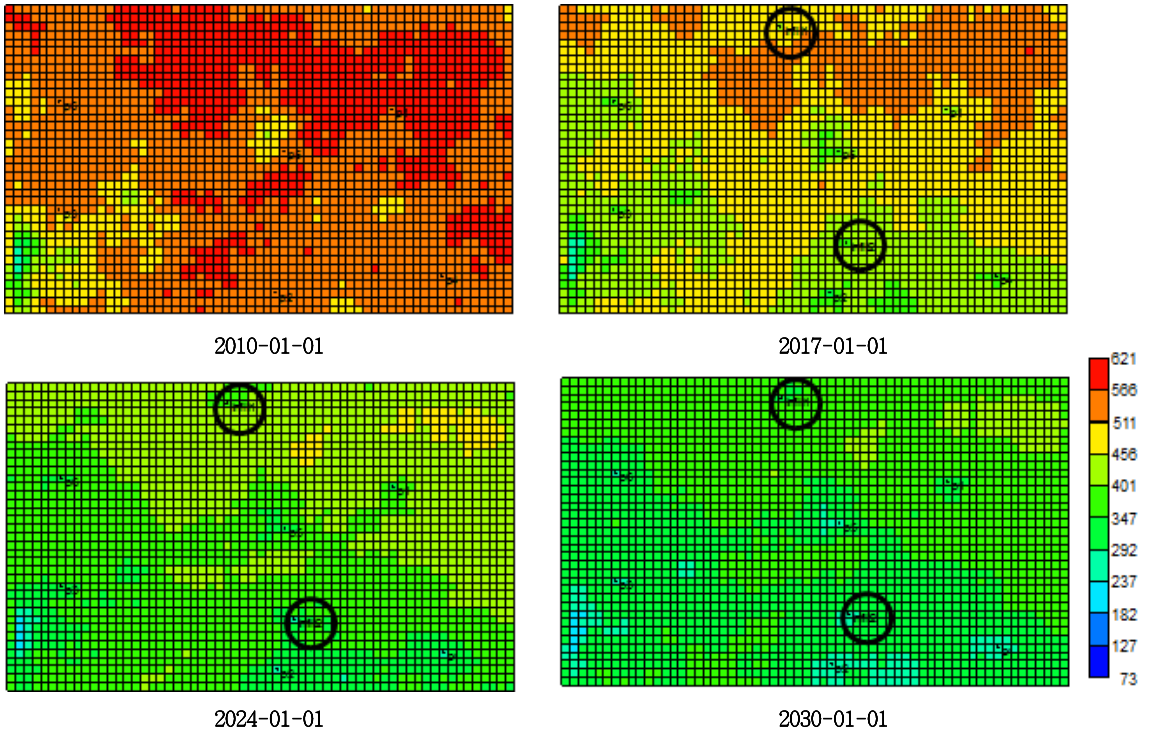


Figure 4.16 Adsorption(CH<sub>4</sub>) of 2 infill wells(Step 2).

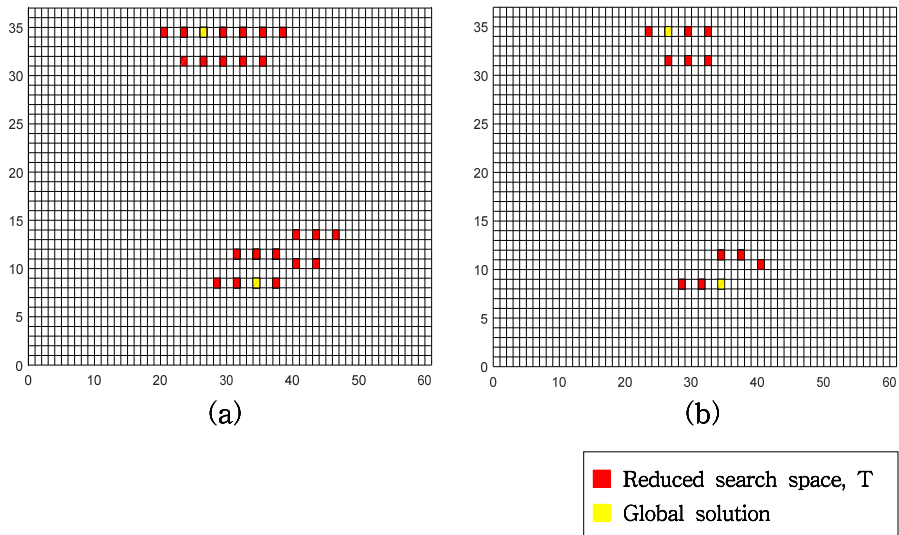


Figure 4,17 Reduced search space of 2 infill wells(Step 2).  
 ((a) 1st ANN model, (b) 2<sup>nd</sup> ANN model)

Table 4.6 Results of repeated application of 2 infill wells ANN(Step 2)

Case	Rank of global solution for each ANN model		Total of number simulation runs
	1 <sup>st</sup> (%)	2 <sup>nd</sup> (%)	
1	5.01	17.5	65
2	8.25	17.6	66
3	4.64	12.6	64
4	5.52	18.6	66
5	6.77	18.1	66
6	6.86	17.6	65
7	6.68	13.6	64
8	9.64	13.6	64
9	5.52	18.6	66
10	5.01	12.6	64

3단계 격자시스템을 구축하기 위해 2단계에서 도출된 출력값 상위 1-3위위를 사용하여 탐색공간을 선정하였다. 선정된 영역을 확장하여 다음 단계의 새로운 탐색공간으로 정의한다(Figure 4.18, Table 4.7).




Figure 4.18 Ranking 1 to 3 of 2 infill wells(Step 2).

Table 4.7 Ranking 1 to 3 of 2 infill wells(Step 2)

	ILoc1	JLoc1	ILoc2	JLoc2	FieldCum(m <sup>3</sup> )
<b>No. 1</b>	27	35	35	9	770,427,650
<b>No. 2</b>	27	35	32	9	768,903,810
<b>No. 3</b>	27	35	35	12	768,898,750

### 다. 3단계 격자시스템을 사용한 최적 위치 선정

2단계에서 선정된 상위 1-3위의 새로운 탐색 공간 1,156개에 대해 기본 격자시스템을 사용한다(Figure 4.19). 인공신경망 모델의 학습 성능을 평가하기 위해 대상 저류층에 추가 시추가 가능한 모든 위치에 대해 저류층 전산 모사를 수행한 결과 누적 가스 생산량이 최대가 되는 추가 시추 위치는 (29, 34)-(31, 11)이다.

2단계에서 사용된 모든 훈련정은 광역해와의 위치 관계가 성립되어 있기 때문에 기존의 훈련정 정보를 사용하여 인공신경망 모델을 학습시켰다. 이후 후속 ANN 모델을 구축할 때마다 10쌍의 훈련정을 추가하였다.




Figure 4.19 Training map of 2 infill wells(Step 3).

2단계에서 사용한 전체 훈련정 59쌍을 사용하여 1,156개의 영역에 대해 인공신경망을 수행한 결과는 Figure 4.20(a)와 같다. 컷오프 15%를 적용한 결과 231개의 새로운 탐색공간이 정의되었다(Figure 4.20(b)). 광역해는 상위 6.14%에 위치해 있으며 새롭게 정의된 영역 내에서 다음 모델의 훈련정 10쌍을 선정하였다.

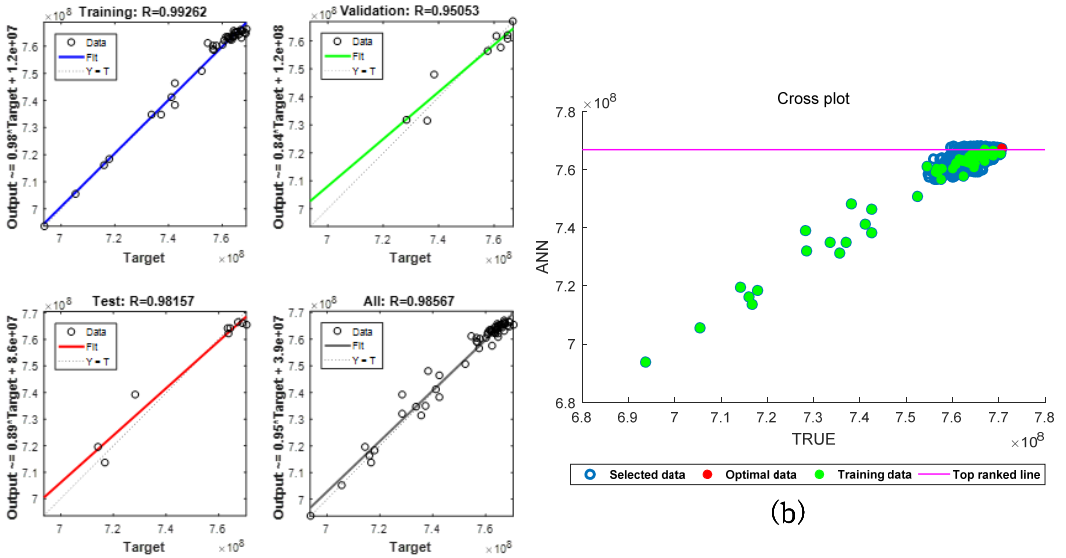
추가된 10쌍의 훈련정을 포함하여 총 69쌍의 훈련정으로 인공신경망을 수행한 결과는 Figure 4.21(a)와 같다. 20%를 컷하였으며 115개의 새로운 탐색공간이 정의되었다(Figure 4.21(b)). 광역해는 상위 2.6%에 위치해 있음을 확인하였다.

마지막으로 총 79쌍의 훈련정을 사용하여 인공신경망을 구축하였으며 25%의 컷오프를 통해 9개의 새로운 탐색공간이 정의되었다(Figure 4.22). 이는 종료 기준에 만족하므로, 인공신경망을 종료하고 시뮬레이션을 수행함으로써 최종 광역해를 도출한다.


최종적으로 남은 탐색공간 9개, 훈련정 구성을 위해 수행한 시뮬레이션 20회, 총 29회의 시뮬레이션을 통해 최종 광역해를 도출하였다. 광역해는 (29, 34)-(31, 11)에 위치해 있으며, 누적 가스 생산량은 770,698,050m<sup>3</sup>이다(Table 4.8, Figure 4.23, 4.24).

또한, 탐색 공간에 대한 지도를 보면, 탐색 공간이 광역해를 향해 수렴해나가는 것을 확인할 수 있다(Figure 4.25).

위와 같은 과정을 10회 반복한 결과, 매 회 광역해가 포함되어 있었으며, 기존 훈련정에 사용된 시뮬레이션 포함 최소 88, 최대 90회의 시뮬레이션을 통해 광역해를 도출해 낼 수 있었다(Table 4.9).

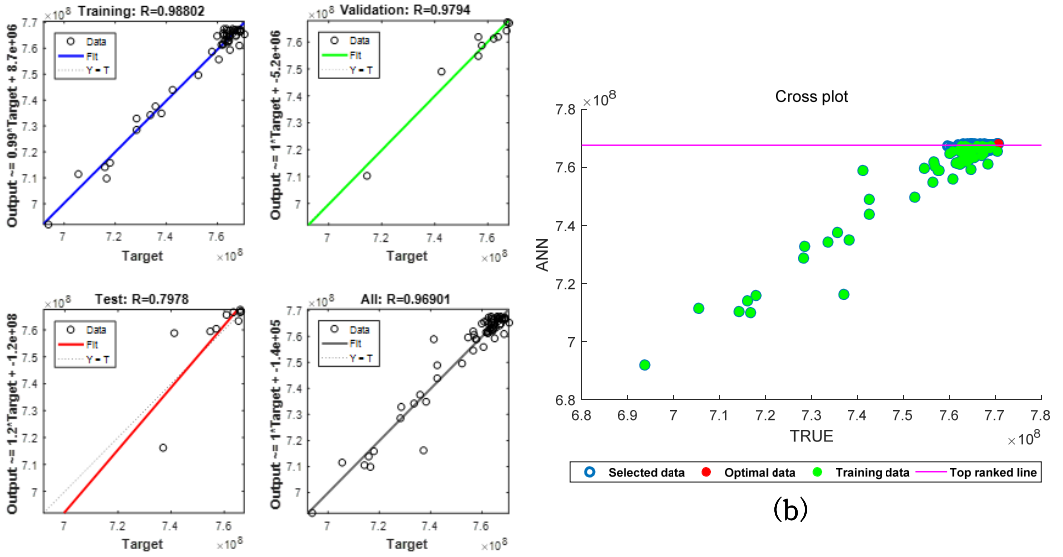


(a)




(c)

Figure 4.20 Result of initial ANN model.((a) Training result of initial ANN model, (b) Cross plot of ANN model and simulation results, (c) Top 15% of search space using initial ANN model)



(a)



(b)




(c)

Figure 4.21 Result of 2<sup>nd</sup> ANN model.((a) Training result of 2<sup>nd</sup> ANN model, (b) Cross plot of ANN model and simulation results, (c) Top 20% of search space using 2<sup>nd</sup> ANN model)





(a)



(c)

Figure 4.22 Result of 3<sup>rd</sup> ANN model.((a) Training result of 3<sup>rd</sup> ANN model, (b) Cross plot of ANN model and simulation results, (c) Top 25% of search space using 3<sup>rd</sup> ANN model)

Table 4.8 Summary of applying the hierarchical ANN of 2 infill wells(Step 3)

ANN model	Cutoff value(%)	Number of training data	New search space	Rank of global solution	Total number of simulation runs
1 <sup>st</sup>	15	59	231	6.14 %	0
2 <sup>nd</sup>	20	69	115	2.6 %	10
3 <sup>rd</sup>	25	79	9	18.26 %	20




Figure 4.23 Cumulative gas production rate of 2 infill wells(Step 3).




Figure 4.24 Adsorption(CH<sub>4</sub>) of 2 infill wells(Step 3).

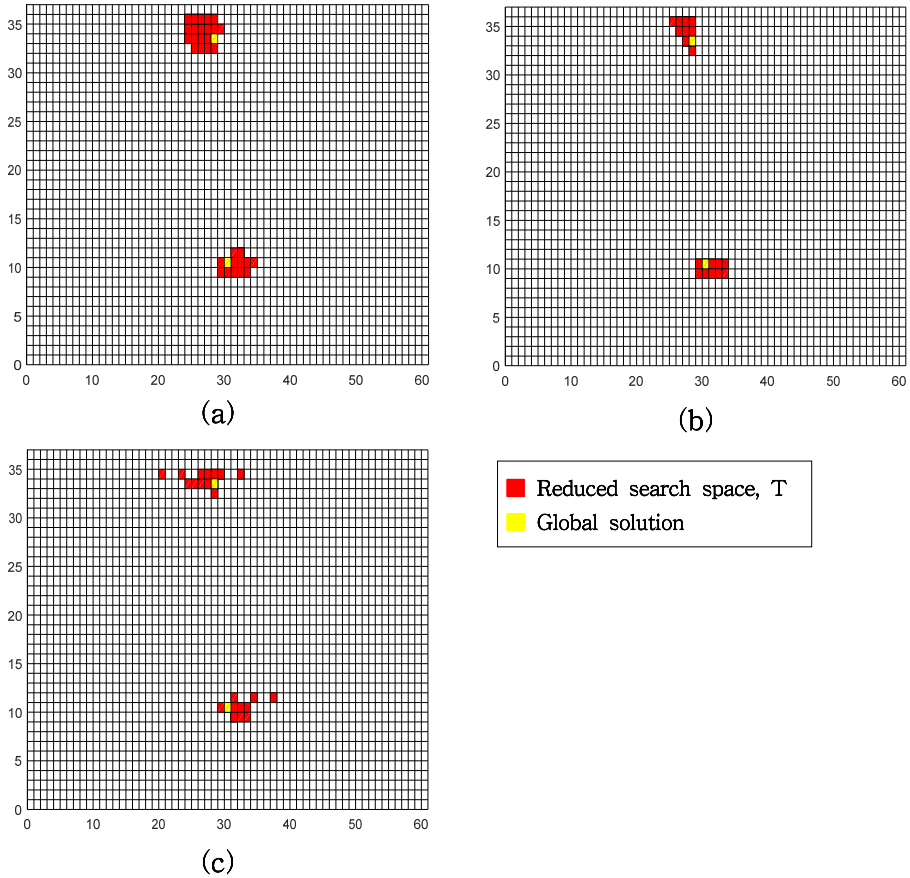


Figure 4.25 Reduced search space of 2 infill wells(Step 3).  
 ((a) Initial ANN model, (b) 2<sup>nd</sup> ANN model, (c) 3<sup>rd</sup> ANN model)

Table 4.9 Results of repeated application of 2 infill wells ANN(Step 3)

Case	Rank of global solution for each ANN model			Total of number simulation runs
	1 <sup>st</sup> (%)	2 <sup>nd</sup> (%)	3 <sup>rd</sup> (%)	
1	6.14	2.6	18.26	88
2	5.64	8.65	11.6	89
3	8.41	5.64	13.5	88
4	5.41	5.13	8.41	89
5	3.42	6.84	8.96	88
6	7.65	9.42	6.87	89
7	3.24	4.76	9.74	90
8	3.56	3.87	5.24	90
9	5.34	8.97	8.64	88
10	9.86	8.54	13.78	89

최종적으로, 생산정 2개의 시추 위치를 도출하기 위해 저류층을 5×5의 영역으로 나누었고, 1단계에서 도출된 광역해 1-5위까지 고려하여 이를 3×3으로 다시 나누었다. 2단계에서 도출된 광역해 1-3위를 고려하여 기본 격자 시스템의 탐색 영역으로 정의하여 인공지능망을 수행한 결과 최적 추가 시추 위치를 도출하였다.

본 저류층에서 2개의 추가 시추 위치를 도출하기 위해서 최대 2,545,896의 저류층 전산 모사를 수행해야 하지만, 제안한 방법을 사용함으로써 139회의 시뮬레이션으로 추가 시추 위치를 도출할 수 있다.

Table 4.10 Result of 2 infill wells

Step 1(itr 10 average)	
GP Coordinate	(29, 34)-(34, 9)
GP Cum rate(m')	770,267,520
GP Rank	4.70 %
Number of simulations	69
Step 2(itr 10 average)	
GP Coordinate	(27, 35)-(35, 9)
GP Cum rate(m')	770,427,650
GP Rank	6.02 %
Number of simulations	42
Step 3(itr 10 average)	
GP Coordinate	(29, 34)-(31, 11)
GP Cum rate(m')	770,698,050
GP Rank	9.89 %
Number of simulations	28

### 제3절 생산정 3개의 추가 시추 위치 선정

#### 1. 인공신경망의 학습 자료 선정

인공신경망 모델은 입력층 1개, 은닉층 1개, 출력층 1개로 구성되어 있다. 입력, 은닉 및 출력층의 노드 수는 각각 42, 10, 1개이다. 입력변수는 추가 시추정의 위치 좌표, 추가 시추정과 저류층 경계와의 거리(동, 서, 남, 북), 기존 생산정과 추가 시추정간의 거리, 두 개의 추가 시추정간의 거리를 사용하였고, 출력변수는 20년 메탄가스 누적 생산량으로 하였다. 특히 입력변수로 사용한 추가 시추정간의 거리는 초기 ANN 모델의 신뢰성을 높이는데 아주 효과적인 것으로 나타났다.

인공신경망 모델 학습에 사용되는 추가 생산정은 생산정의 공간적 위치 정보, 저류층의 경계, 추가 생산정과 기존 생산정과의 거리, 추가 생산정간의 거리 등 저류층 인자의 다양한 분포 특성을 적절히 고려할 수 있도록 분포 시켰다. 초기 학습 자료는 두 개의 영역 및 유정을 짝을 지어 50쌍을 사용하였으며, 그 중 85%는 학습용, 15%는 시험용으로 사용되었다.

Figure 4.27는 유정 배치도를 나타낸 것으로 회색 격자는 저류층 경계, 흰색 격자는 추가 시추 가능 지역, 녹색 격자는 훈련 생산정, 파란색 격자는 기존 생산정을 의미한다. 추가 생산정의 수가 3개 일 때, 시추가 가능한 격자는 기존 생산정(6개), 저류층 경계(192개)를 제외한 1,913,665,160개이다.

순차적 인공신경망 기법에 사용되는 상위 랭킹에 대한 컷오프 비율 R은 각각 15, 20, 25, 30%로 설정하였다.

## 2. 광역적 최적 추가 시추위치 결정

### 가. 1단계 격자시스템을 사용한 최적위치 선정

2개 유정 위치 최적화에 본 방법을 적용하여 검증하였으며, 신뢰성이 높음을 판단하였다. 따라서 3개 유정 시추 위치 결정을 수행하여 결과를 비교 분석하였다. 먼저, 기본 격자시스템을 5×5 단위로 나누어 1단계 격자시스템을 구성하고 초기 ANN 모델을 학습하는 데 유정 50쌍을 사용하였다. 각 모델 구축 시, 새롭게 정의된 탐색 영역 내에서 20개를 추가 선정하여 ANN을 학습시켰다(Figure 4.27).

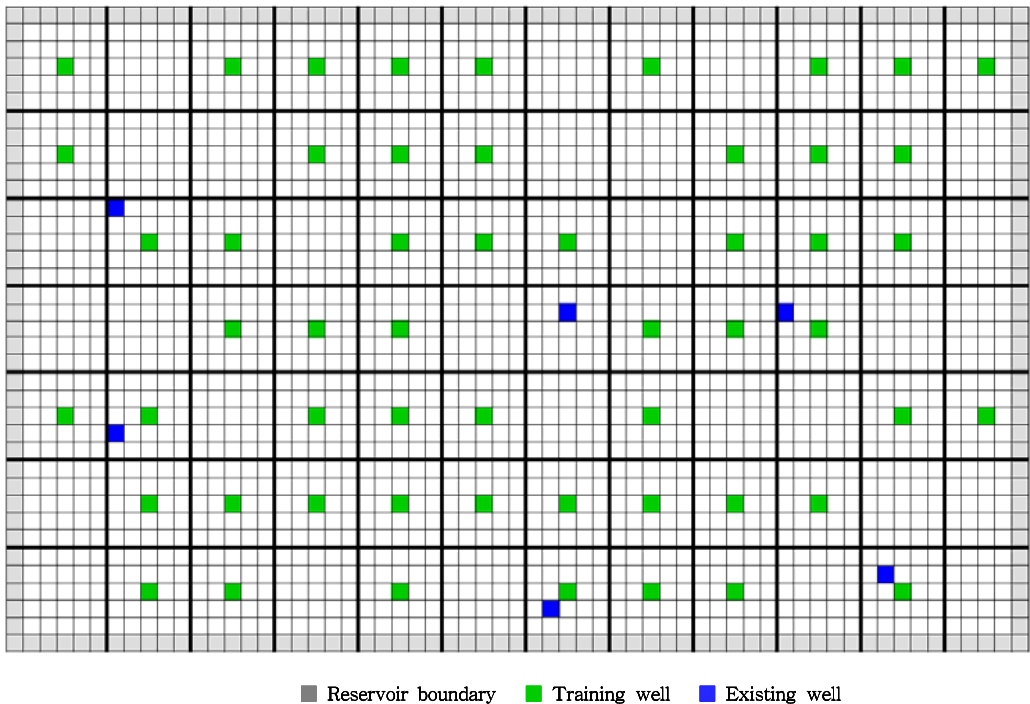


Figure 4.26 Well location for 3 infill well case.



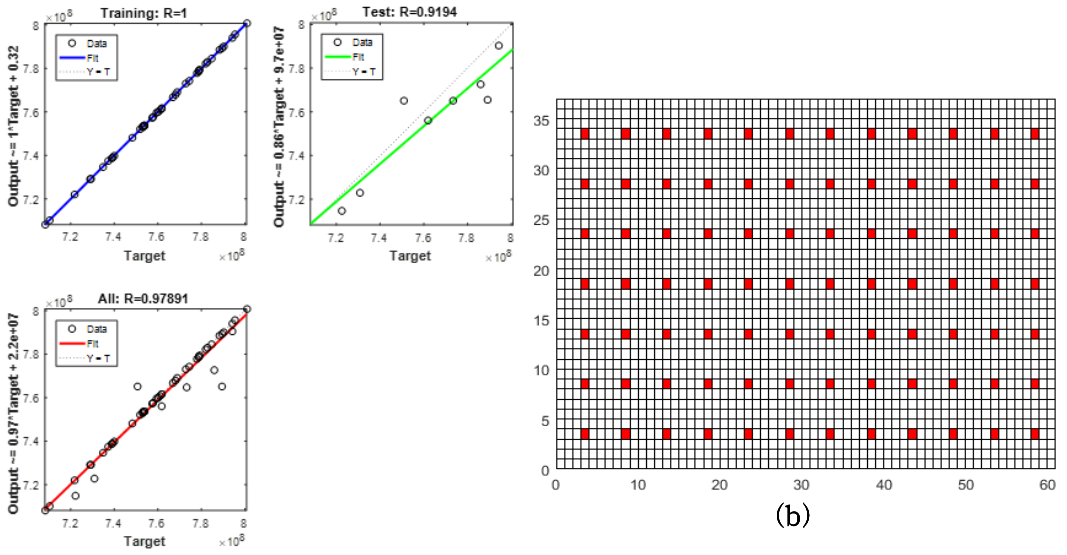
Figure 4.28(a)는 50쌍의 훈련정을 사용하여 학습된 ANN 모델 1과 ANN 모델 1을 사용하여 총 95,284개 탐색 공간에 대해 누적 가스 생산량을 예측한 결과이다. 컷오프 15%를 적용하여 새로운 탐색공간을 정의하였다. 새로운 탐색공간 14,335개를 등간격으로 나누어 인공신경망 예측 값이 가장 높은 데이터를 포함한 20쌍을 훈련데이터로 선정한다.

새롭게 정의된 20쌍의 훈련정은 시뮬레이션을 통해 정확한 값을 획득하고, 기존의 50쌍의 훈련정과 결합하여 ANN 모델 2를 구축한다. Figure 4.29(a)는 학습된 ANN 모델 2로, 모델 1에 비해 신뢰도가 높음을 확인할 수 있다. 컷오프 20%를 사용하여 새로운 탐색공간을 정의하였다. 2,925개의 탐색공간에 대해 90쌍의 훈련정을 사용하여 모델을 구축한 결과 Figure 4.30(a)와 같다. 컷오프 25%를 적용한 결과 ANN 모델 4의 813개의 탐색공간이 정의되었다. 110개의 훈련정을 사용하였으며 컷오프 30%를 적용하였다(Figure 4.31(a)).


ANN 모델 5는 130개의 훈련정을 사용하여 344개의 탐색공간에 ANN을 수행한 결과는 Figure 4.32(a)과 같다. 컷오프 30%를 적용하였으며, ANN 모델 6는 219개의 탐색공간에 대해 ANN을 수행하였다(Figure 4.33). 마지막으로 ANN 모델 6에 컷오프 30%를 적용하여 새롭게 정의된 191개의 탐색공간에 대해 170쌍의 훈련정을 사용하여 ANN을 수행하였다(Figure 4.34). 컷오프 30%를 적용한 결과 19개가 정의되었다. 이는 종료조건에 만족하여 남은 19개의 탐색 공간에 대해 시뮬레이션을 수행하여 정확한 값을 얻어 기존에 사용한 170쌍의 훈련데이터 값과 비교하여 가장 큰 값을 갖는 데이터를 찾으면 본 알고리즘은 종료된다(Table 4.11).

총 189회의 시뮬레이션을 통해 광역해 (24, 34)-(34, 9)-(44, 34)를 도출하였으며, 해당 좌표의 누적 가스 생산량은 820,813,060m<sup>3</sup>이다(Figure 4.35). 석탄층 메탄가스 저류층에 시추한 결과 메탄의 흡착량 변화는 Figure 4.36과 같이 확인할 수 있다. Figure 4.28(b)-Figure 4.34(b)에서 나타난 탐색영역의 지도를 통해 탐색 공간이 광역해 중심으로 감소하고 있음을 확인할 수 있다.

본 연구의 신뢰성을 위해 10회 반복한 결과는 Table 4.12와 같다. 수 회 반복한 결과 항상 동일한 값이 도출되는 것을 확인하였고, 이를 광역해로 판단하였다. 광역해를 도출하기 위해 필요한 시뮬레이션 횟수는 초기 훈련 데이터 50쌍으로 시작했을 때, 최소 189회, 최대 191회로 나타났다.



(a)



(c)

Figure 4.27 Result of initial ANN model.((a) Training result of initial ANN model, (b) Reduced search space of initial ANN model, (c) Top 15% of search space using initial ANN model)

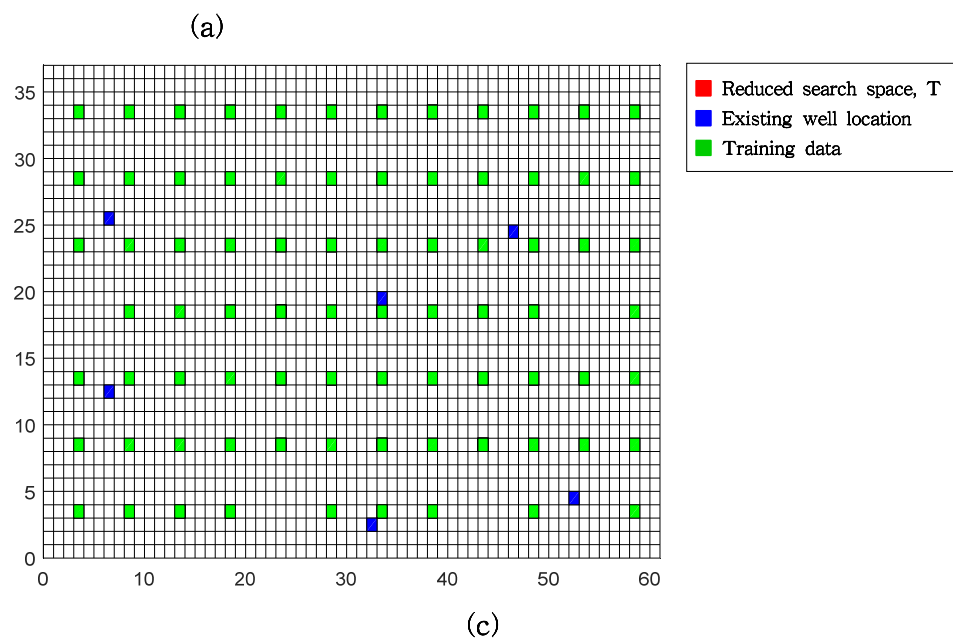
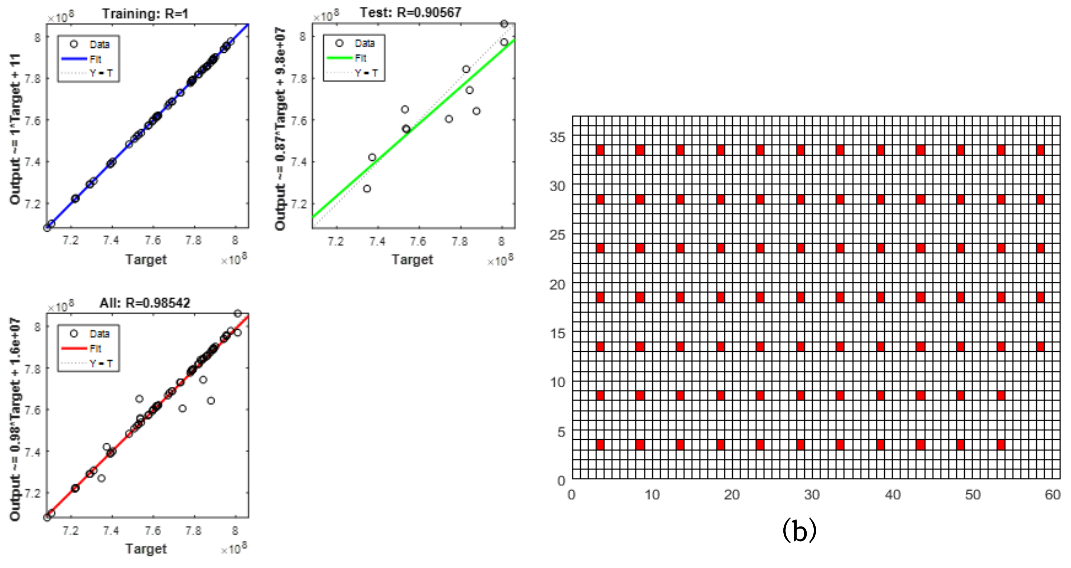
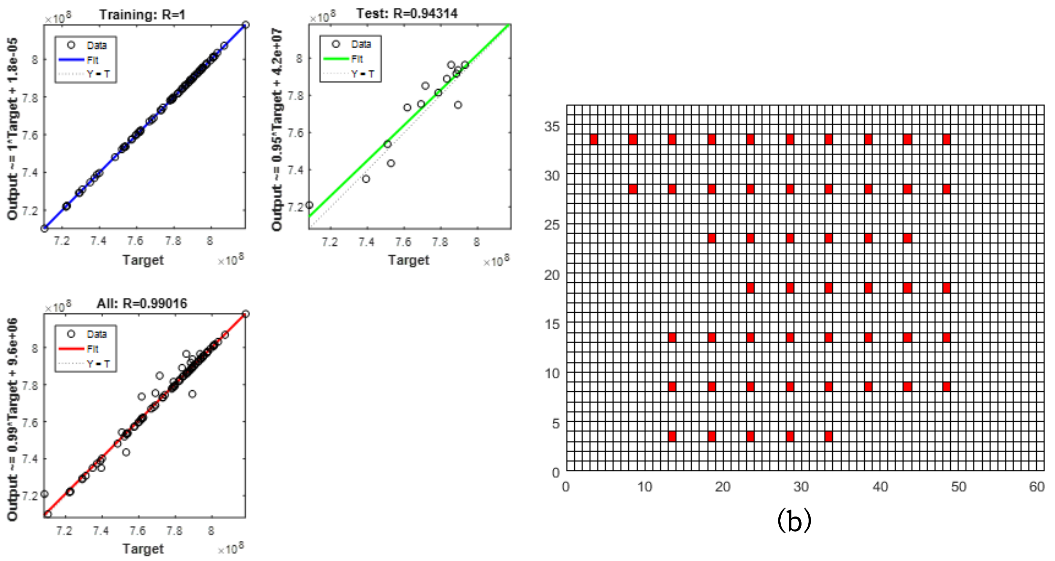



Figure 4.28 Result of 2<sup>nd</sup> ANN model. ((a) Training result of 2<sup>nd</sup> ANN model, (b) Reduced search space of 2<sup>nd</sup> ANN model, (c) Top 20% of search space using 2<sup>nd</sup> ANN model)

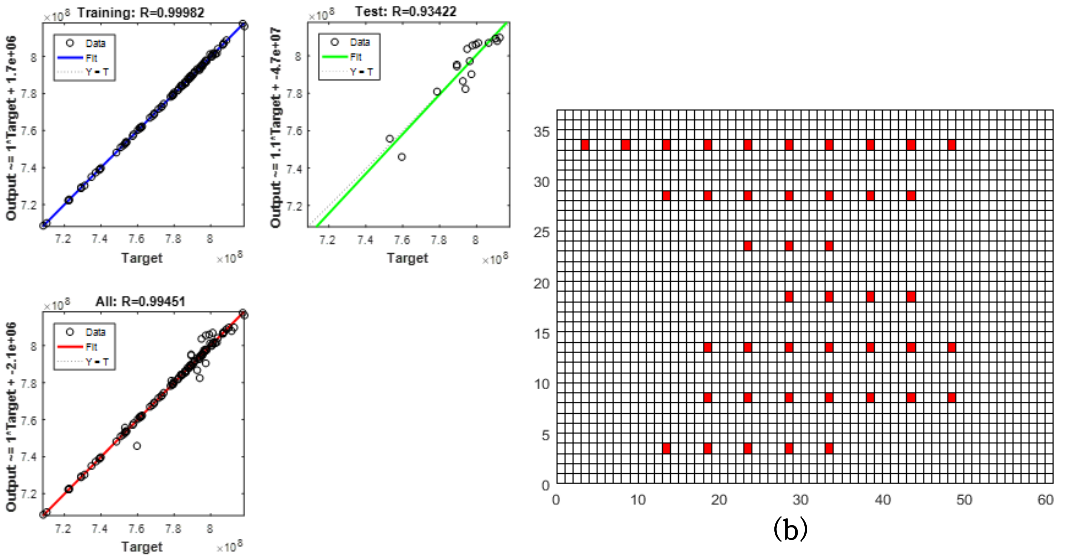


(a)




(c)

Figure 4.29 Result of 3<sup>rd</sup> ANN model.((a) Training result of 3<sup>rd</sup> ANN model, (b) Reduced search space of 3<sup>rd</sup> ANN model, (c) Top 25% of search space using 3<sup>rd</sup> ANN model)

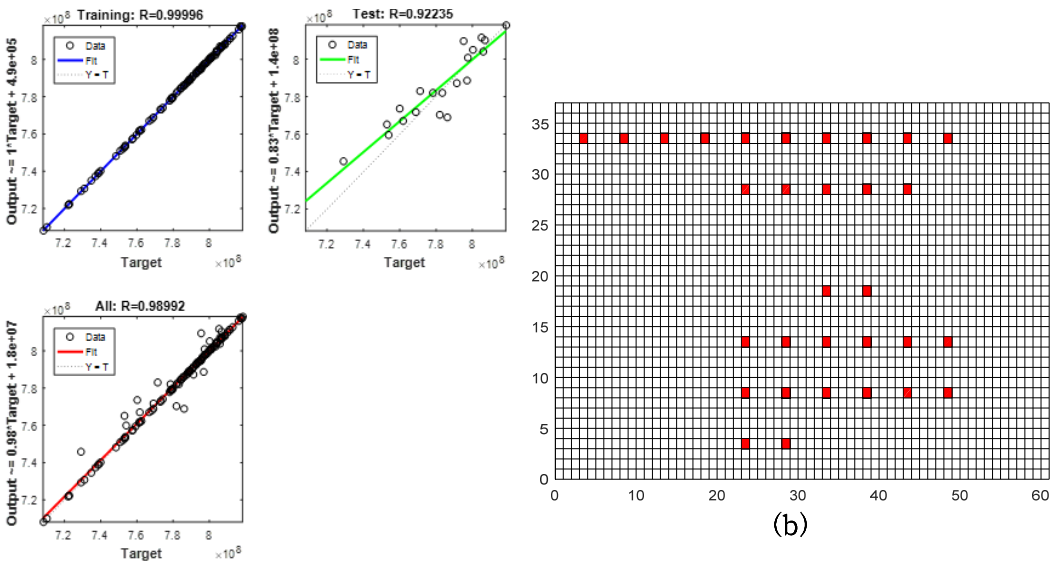


(a)




(c)

Figure 4.30 Result of 4<sup>th</sup> ANN model.((a) Training result of 4<sup>th</sup> ANN model, (b) Reduced search space of 4<sup>th</sup> ANN model, (c) Top 30% of search space using 4<sup>th</sup> ANN model)

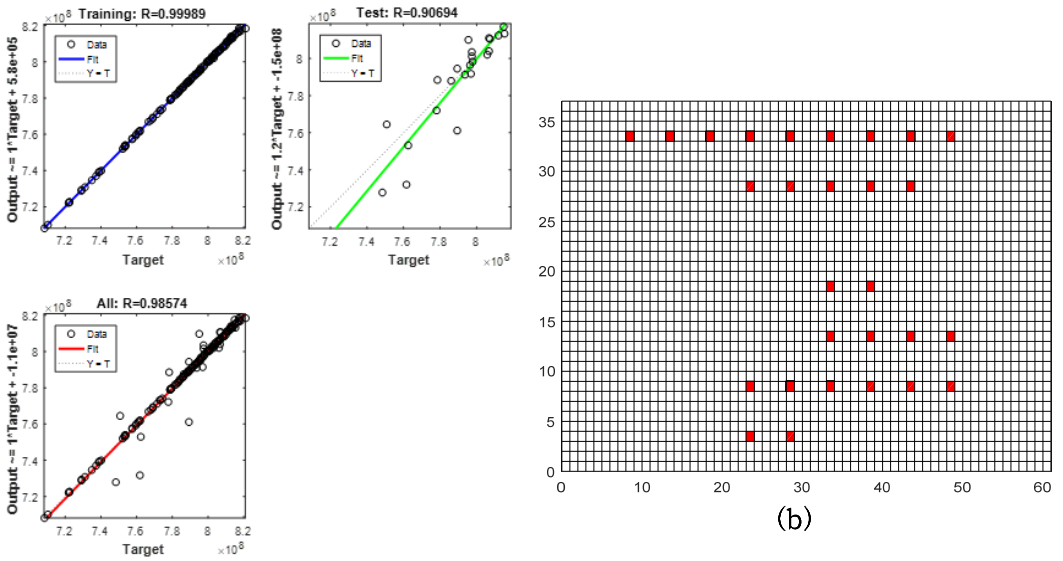


(a)




(c)

Figure 4.31 Result of 5<sup>th</sup> ANN model.((a) Training result of 5<sup>th</sup> ANN model, (b) Reduced search space of 5<sup>th</sup> ANN model, (c) Top 30% of search space using 5<sup>th</sup> ANN model)

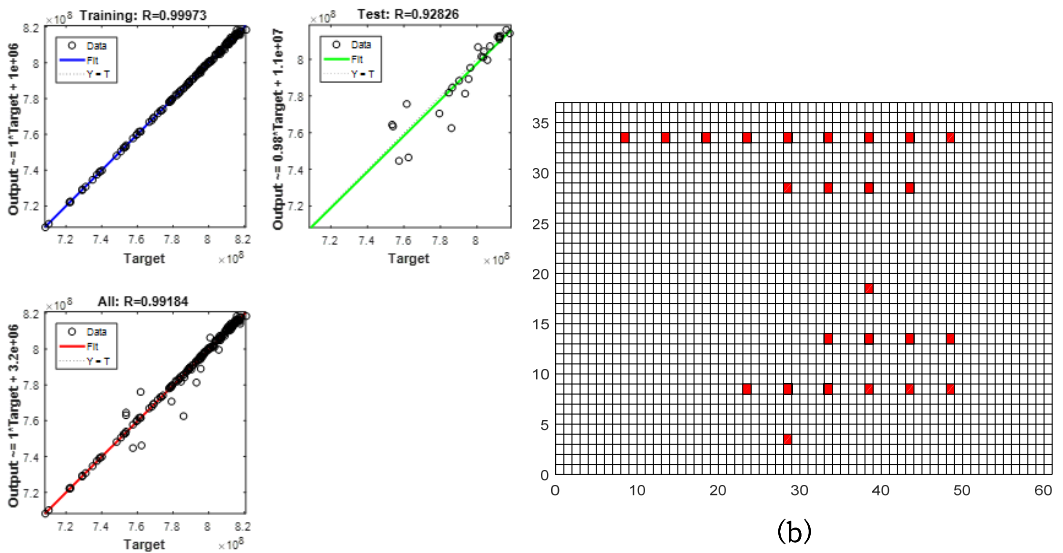


(a)




(c)

Figure 4.32 Result of 6<sup>th</sup> ANN model. ((a) Training result of 6<sup>th</sup> ANN model, (b) Reduced search space of 6<sup>th</sup> ANN model, (c) Top 30% of search space using 6<sup>th</sup> ANN model)



(a)



(c)

Figure 4.33 Result of 7<sup>th</sup> ANN model.((a) Training result of 7<sup>th</sup> ANN model, (b) Reduced search space of 7<sup>th</sup> ANN model, (c) Top 30% of search space using 7<sup>th</sup> ANN model)



Table 4.11 Summary of applying the hierarchical ANN of 3 infill wells(Step 1)

ANN model	Search space	Cutoff value(%)	Number of training data	Total number of simulation runs
1 <sup>st</sup>	95,284	15	50	50
2 <sup>nd</sup>	14,335	20	70	70
3 <sup>rd</sup>	2,925	25	90	90
4 <sup>th</sup>	813	30	110	110
5 <sup>th</sup>	344	30	130	130
6 <sup>th</sup>	219	30	150	150
7 <sup>th</sup>	191	30	170	170




Figure 4.34 Cumulative gas production rate of 3 infill wells(Step 1).

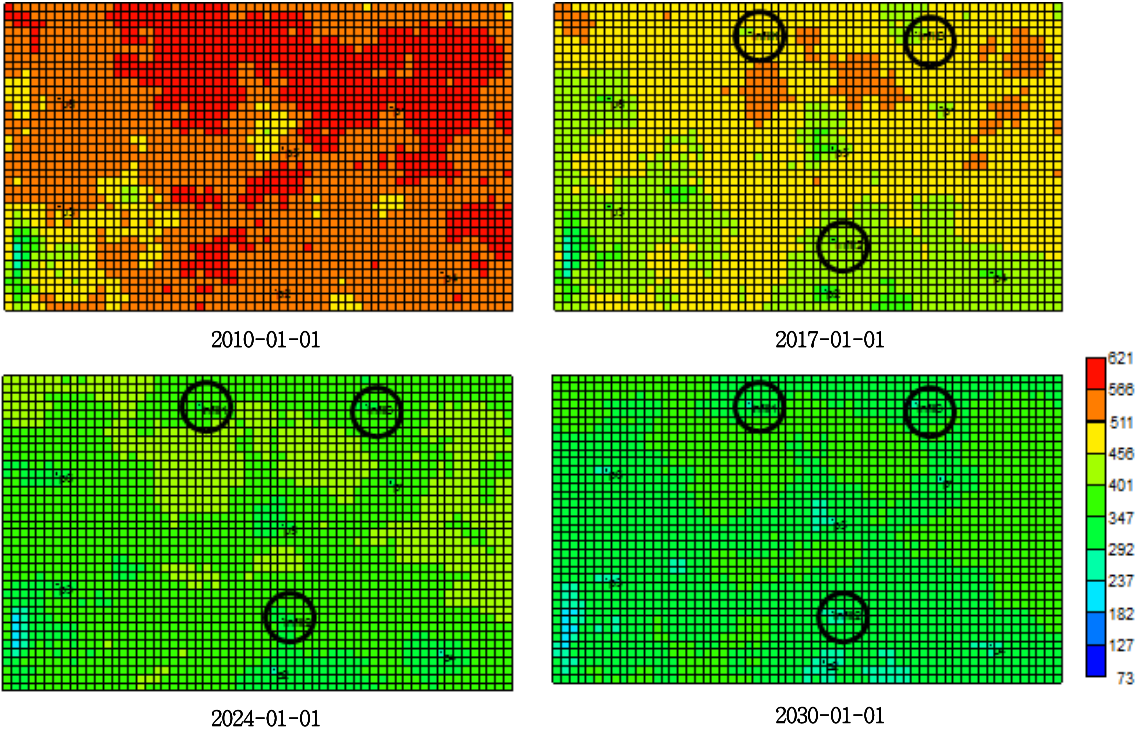


Figure 4.35 Adsorption(CH<sub>4</sub>) of 3 infill wells(Step 1).

Table 4.12 Results of repeated application of 3 infill wells ANN(Step 1)

	<b>Training</b>	<b>Remain</b>	<b>Total</b>	<b>GP Coord</b>	<b>GP Cum. (m<sup>3</sup>)</b>
<b>1</b>	170	19	189	(24, 34)-(34, 9)-(44, 34)	820,813,060
<b>2</b>	170	20	190	(24, 34)-(34, 9)-(44, 34)	820,813,060
<b>3</b>	170	21	191	(24, 34)-(34, 9)-(44, 34)	820,813,060
<b>4</b>	170	20	190	(24, 34)-(34, 9)-(44, 34)	820,813,060
<b>5</b>	170	21	191	(24, 34)-(34, 9)-(44, 34)	820,813,060
<b>6</b>	170	20	190	(24, 34)-(34, 9)-(44, 34)	820,813,060
<b>7</b>	170	19	189	(24, 34)-(34, 9)-(44, 34)	820,813,060
<b>8</b>	170	19	189	(24, 34)-(34, 9)-(44, 34)	820,813,060
<b>9</b>	170	19	189	(24, 34)-(34, 9)-(44, 34)	820,813,060
<b>10</b>	170	20	190	(24, 34)-(34, 9)-(44, 34)	820,813,060

2단계 격자시스템을 구축하기 위해 1단계에서 도출된 출력값 상위 1-5위를 사용하여 탐색공간을 선정하였다. 선정된 영역을 확장하여 다음 단계의 새로운 탐색 공간으로 정의한다(Figure 4.37, Table 4.13).




Figure 4.36 Ranking 1 to 5 of 3 infill wells(Step 1).

Table 4.13 Ranking 1 to 5 of 3 infill wells(Step 1)

	ILoc1	JLoc1	ILoc2	JLoc2	ILoc3	JLoc3	FieldCum(m <sup>3</sup> )
<b>No. 1</b>	24	34	34	9	44	34	820,813,060
<b>No. 2</b>	24	34	34	9	34	29	820,722,500
<b>No. 3</b>	24	34	34	9	39	29	819,734,780
<b>No. 4</b>	19	34	34	9	39	34	818,328,580
<b>No. 5</b>	24	34	29	9	44	34	818,216,450

## 나. 2단계 격자시스템을 사용한 최적 위치 선정

1단계에서 선정된 상위 1-5위의 위치를 병합하여 2단계 격자시스템을 위한 새로운 탐색 공간을 만들고 3×3의 영역으로 나뉜다. 새롭게 정의된 5,625개의 영역에 대해 ANN을 수행하였다. 1단계에서 도출된 광역해가 저류층의 남쪽 1개, 북쪽 2개에 위치하기 때문에, 1단계에서 사용한 훈련정 중 광역해와의 위치 관계를 가진 훈련정을 선정하여 사용하였으며, 새롭게 정의된 영역 내에서 추가 훈련정을 선정하였다. 기존의 훈련정 15쌍과 새롭게 선정된 훈련정 15쌍, 총 30쌍의 훈련정을 사용하여 인공신경망 모델을 학습시켰다. 후속 모델 구축시 20쌍씩 훈련정을 새롭게 추가하여 ANN 모델을 구축하였다(Figure 4.38).

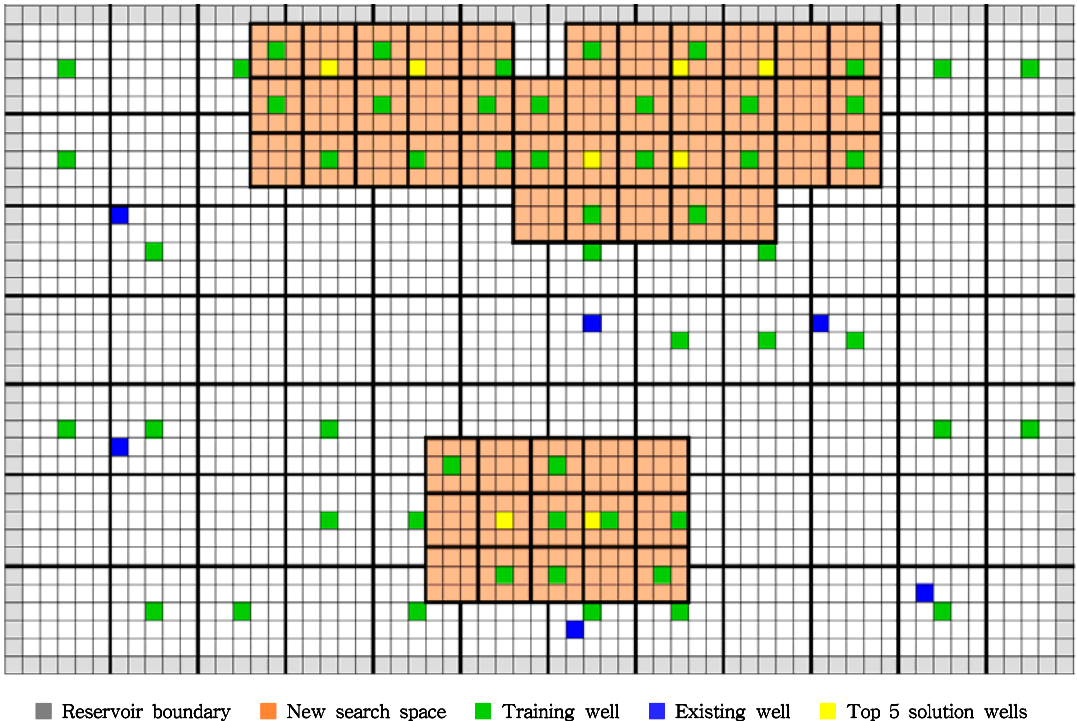


Figure 4.37 Training map of 3 infill wells(Step 2).

Figure 4.39(a)는 30쌍의 훈련정을 사용하여 학습된 ANN 모델 1과 ANN 모델 1을 사용하여 총 5,625개 탐색 공간에 대해 누적 가스 생산량을 예측한 결과이다. 컷오프 15%를 적용하여 새로운 탐색공간을 정의하였다. 새로운 탐색공간 874개를 등간격으로 나누어 인공신경망 예측 값이 가장 높은 데이터를 포함한 20쌍을 훈련 데이터로 선정한다.

새롭게 정의된 20쌍의 훈련정은 시뮬레이션을 통해 정확한 값을 획득하고, 기존의 30쌍의 훈련정과 결합하여 ANN 모델 2를 구축한다. Figure 4.40(a)는 학습된 ANN 모델 2로, 모델 1에 비해 신뢰도가 높음을 확인할 수 있다. 컷오프 20%를 사용하여 새로운 탐색공간을 정의하였다. 218개의 탐색공간에 대해 70쌍의 훈련정을 사용하여 모델을 구축한 결과 Figure 4.41(a)와 같다.

컷오프 25%를 적용한 결과 ANN 모델 4의 120개의 탐색공간이 정의되었다. 90쌍의 훈련정을 사용하였으며 컷오프 30%를 적용하였다(Figure 4.42(a)). 컷오프를 적용한 결과 15개가 정의되었다. 이는 종료조건에 만족하여 남은 15개의 탐색 공간에 대해 시뮬레이션을 수행하여 정확한 값을 얻어 기존에 사용한 90쌍의 훈련데이터 값과 비교하여 가장 큰 값을 갖는 데이터를 찾으면 본 알고리즘은 종료된다(Table 4.14). 총 90회의 시뮬레이션을 통해 광역해 (19, 35)-(40, 32)-(32, 9)를 도출하였으며, 해당 좌표의 누적 가스 생산량은 821,786,500m<sup>3</sup>이다(Figure 4.43). 석탄층 메탄가스 저류층에 시추한 결과 메탄의 흡착량 변화는 Figure 4.44과 같이 확인할 수 있다. Figure 4.39(b)-Figure 4.42(b)에서 나타난 탐색영역의 지도를 통해 탐색 공간이 광역해 중심으로 점차 좁혀지고 있음을 확인할 수 있다.

본 연구의 신뢰성을 위해 10회 반복한 결과는 Table 4.15과 같다. 수 회 반복한 결과 항상 동일한 값이 도출되는 것을 확인하였고, 이를 광역해로 판단하였다. 광역해를 도출하기 위해 필요한 시뮬레이션 횟수는 초기 훈련 데이터 30쌍으로 시작했을 때, 최소 104회, 최대 108회로 나타났다.


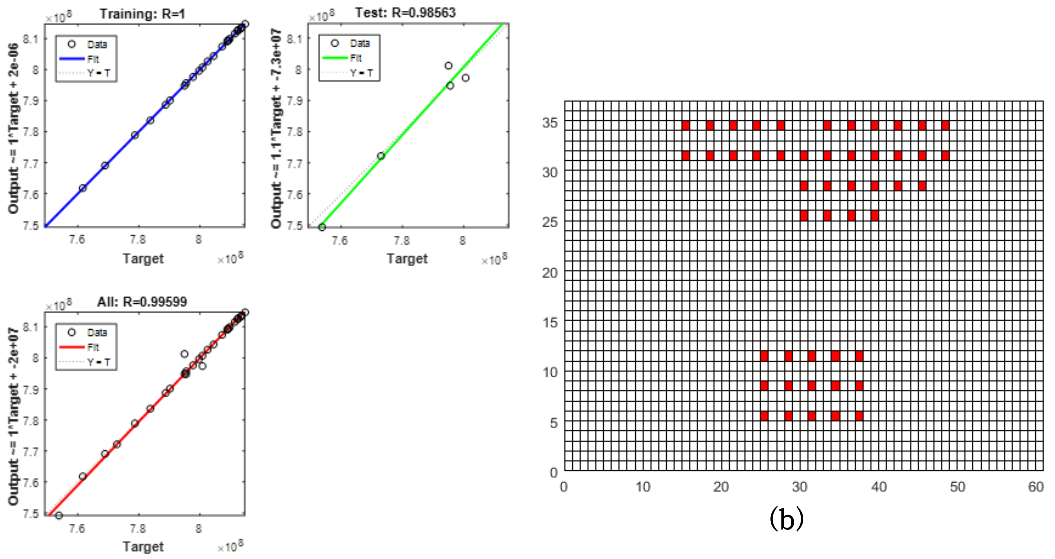
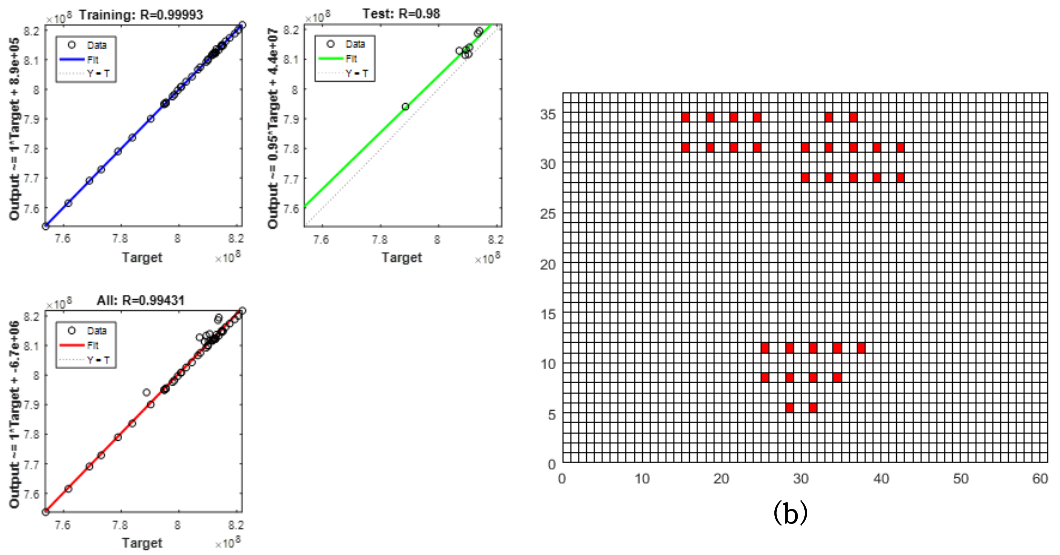



Figure 4.38 Result of initial ANN model.((a) Training result of initial ANN model, (b) Reduced search space of initial ANN model, (c) Top 15% of search space using initial ANN model)



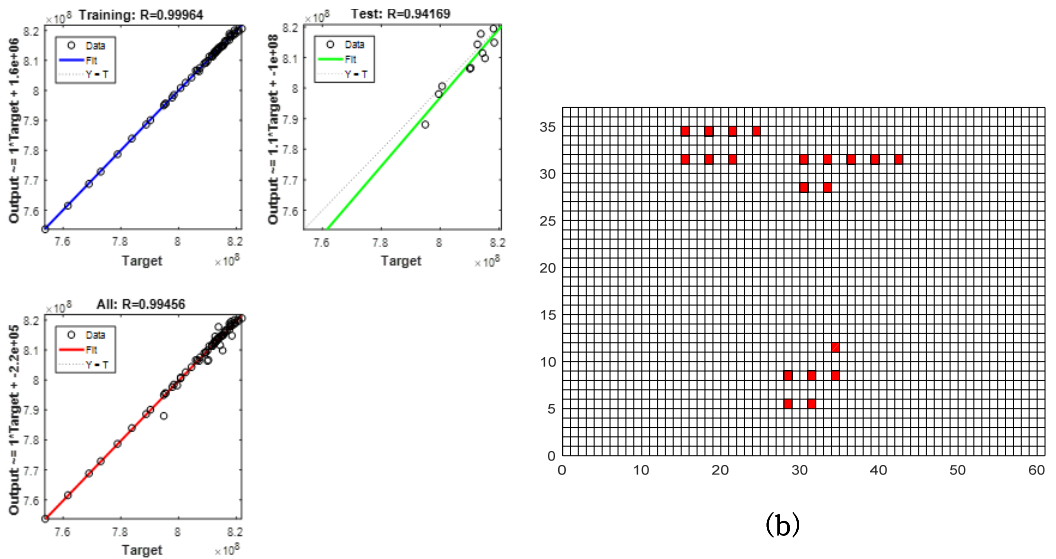
(a)



(c)


Figure 4.39 Result of 2<sup>nd</sup> ANN model.((a) Training result of 2<sup>nd</sup> ANN model, (b) Reduced search space of 2<sup>nd</sup> ANN model, (c) Top 20% of search space using 2<sup>nd</sup> ANN model)





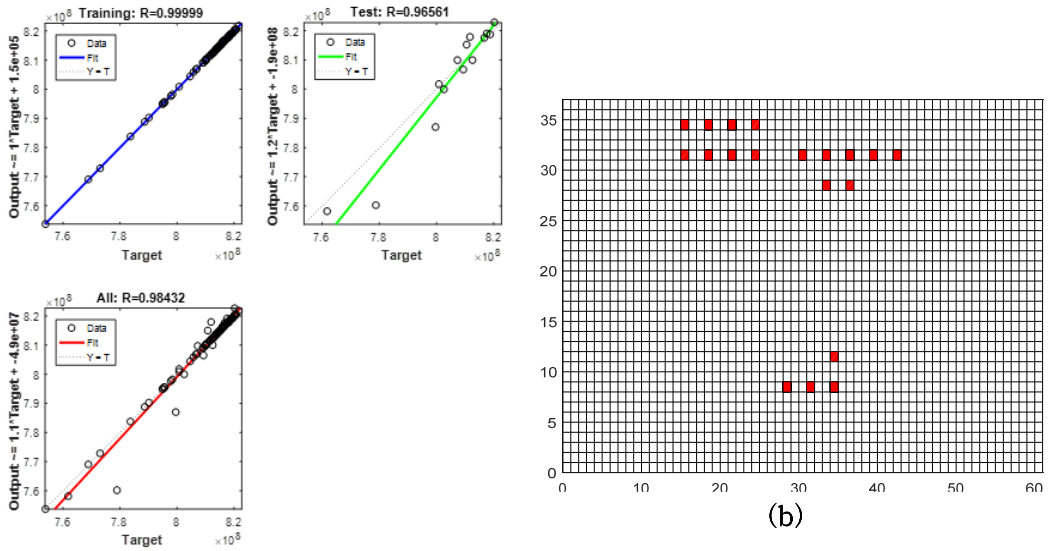
(a)

(b)




(c)

Figure 4.40 Result of 3<sup>rd</sup> ANN model. ((a) Training result of 3<sup>rd</sup> ANN model, (b) Reduced search space of 3<sup>rd</sup> ANN model, (c) Top 25% of search space using 3<sup>rd</sup> ANN model)



(a)



(c)

Figure 4.41 Result of 4<sup>th</sup> ANN model.((a) Training result of 4<sup>th</sup> ANN model, (b) Reduced search space of 4<sup>th</sup> ANN model, (c) Top 30% of search space using 4<sup>th</sup> ANN model)

Table 4.14 Summary of applying the hierarchical ANN of 3 infill wells(Step 2)

ANN model	Search space	Cutoff value(%)	Number of training data	Number of simulation runs
1 <sup>st</sup>	5,625	15	30	15
2 <sup>nd</sup>	874	20	50	35
3 <sup>rd</sup>	218	25	70	55
4 <sup>th</sup>	120	30	90	75




Figure 4.42 Cumulative gas productions of 3 infill wells field(Step 2).

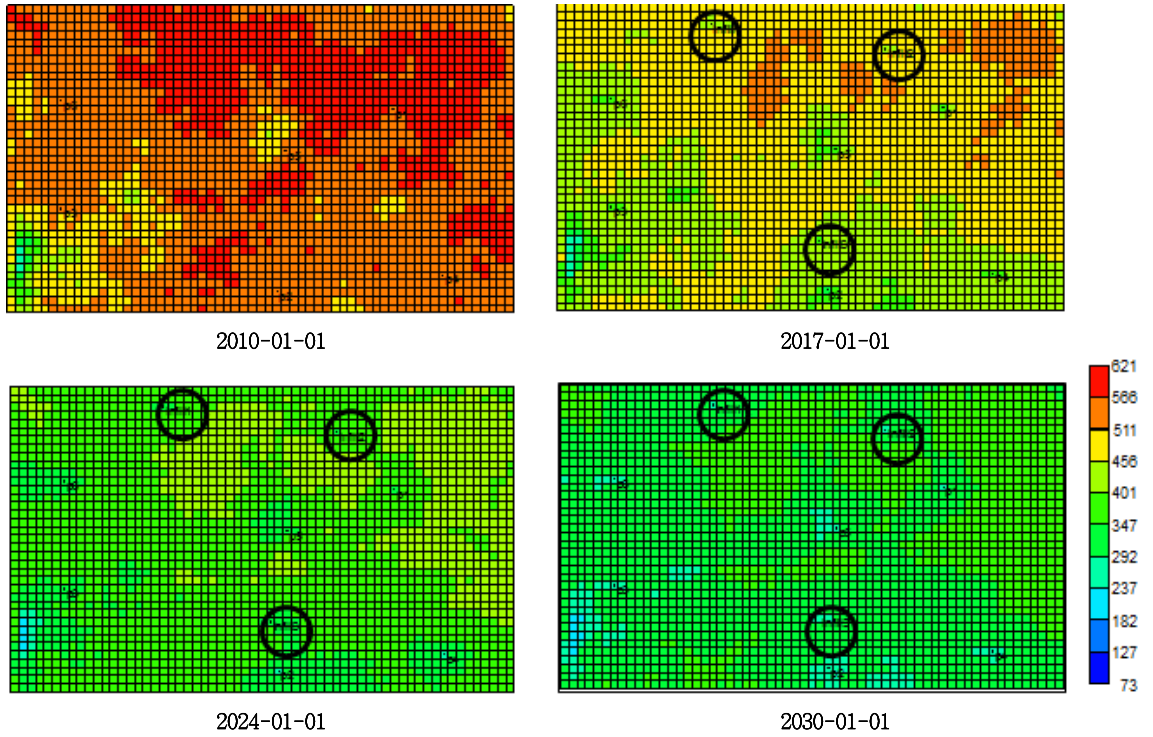


Figure 4.43 Adsorption(CH<sub>4</sub>) of 3 infill wells(Step 2).

Table 4.15 Results of repeated application of 3 infill wells ANN(Step 2)

	<b>Training</b>	<b>Remain</b>	<b>Total</b>	<b>GP Coord</b>	<b>GP Cum (m<sup>3</sup>)</b>
<b>1</b>	90	15	105	(19, 35)-(40, 32)-(32, 9)	821,786,500
<b>2</b>	90	16	106	(19, 35)-(40, 32)-(32, 9)	821,786,500
<b>3</b>	90	15	105	(19, 35)-(40, 32)-(32, 9)	821,786,500
<b>4</b>	90	14	104	(19, 35)-(40, 32)-(32, 9)	821,786,500
<b>5</b>	90	18	108	(19, 35)-(40, 32)-(32, 9)	821,786,500
<b>6</b>	90	15	105	(19, 35)-(40, 32)-(32, 9)	821,786,500
<b>7</b>	90	18	108	(19, 35)-(40, 32)-(32, 9)	821,786,500
<b>8</b>	90	15	105	(19, 35)-(40, 32)-(32, 9)	821,786,500
<b>9</b>	90	14	104	(19, 35)-(40, 32)-(32, 9)	821,786,500
<b>10</b>	90	15	105	(19, 35)-(40, 32)-(32, 9)	821,786,500

3단계 격자시스템을 구축하기 위해 2단계에서 도출된 출력값 상위 1-3위를 사용하여 탐색공간을 선정하였다. 선정된 영역을 확장하여 다음 단계의 새로운 탐색 공간으로 정의한다(Figure 4.45, Table 4.16).

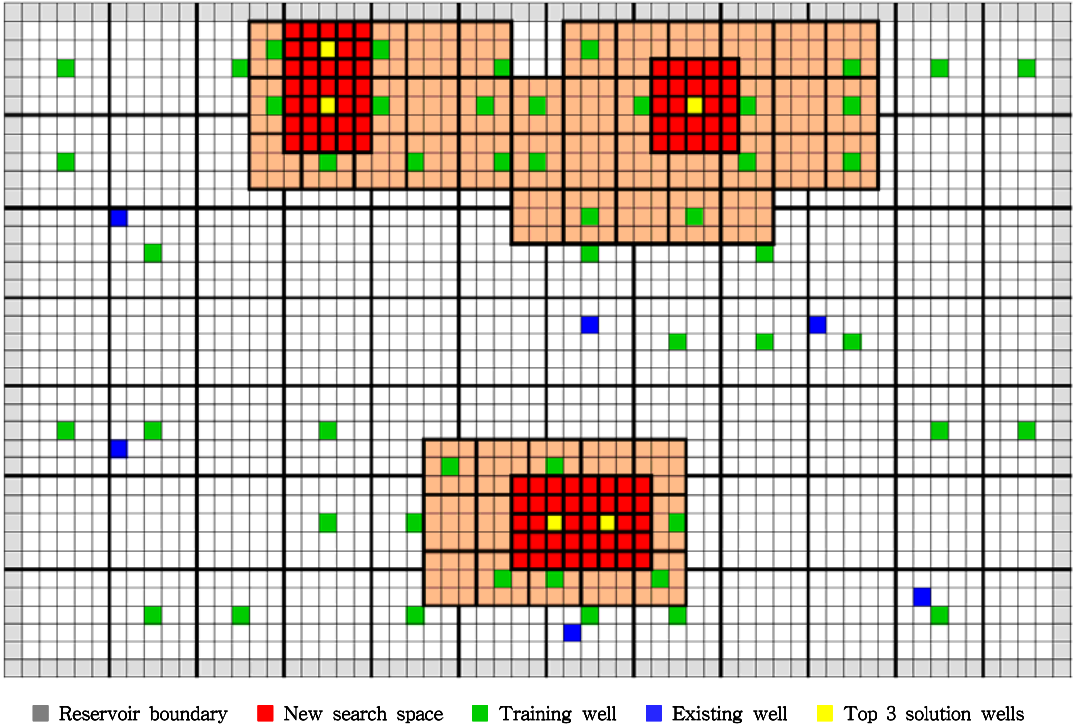


Figure 4.44 Ranking 1 to 3 of 3 infill wells(Step 2).

Table 4.16 Ranking 1 to 5 of 3 infill wells(Step 2)

	Iloc1	Jloc1	Iloc2	Jloc2	Iloc3	Jloc3	FieldCum(m <sup>3</sup> )
No. 1	19	35	40	32	32	9	821,786,500
No. 2	19	35	40	32	35	9	821,771,460
No. 3	19	32	40	32	35	9	820,794,880

### 다. 3단계 격자시스템을 사용한 최적 위치 선정

2단계에서 선정된 상위 1-3위의 위치를 병합하여 3단계 격자시스템을 사용한다. 탐색 공간 35,000개에 대해 기본 격자 시스템을 수행한다. 2단계에서 사용된 모든 훈련정은 광역해와의 위치 관계가 성립되어 있기 때문에 기존의 훈련정 정보를 사용하여 인공지능망을 모델을 학습시켰다. 후속 모델 구축시 20쌍의 훈련정을 새로 추가하였다.(Figure 4.46).




Figure 4.45 Training map of 3 infill wells(Step 3).

Figure 4.47(a)는 2단계에서 사용한 전체 훈련정 105쌍을 사용하여 학습된 ANN 모델 1과 ANN 모델 1을 사용하여 총 35,000개의 영역에 대해 인공신경망을 수행한 결과이다. 컷오프 15%를 적용하여 새로운 탐색공간을 정의하였다. 새로운 탐색공간 5,351개를 등간격으로 나누어 인공신경망 예측 값이 가장 높은 데이터를 포함한 20쌍을 훈련데이터로 선정한다.


새롭게 정의된 20쌍의 훈련정은 시뮬레이션을 통해 정확한 값을 획득하고, 기존의 105쌍의 훈련정과 결합하여 ANN 모델 2를 구축한다. Figure 4.48(a)는 학습된 ANN 모델 2로, 모델 1에 비해 신뢰도가 높음을 확인할 수 있다. 컷오프 20%를 사용하여 새로운 탐색공간을 정의하였다. 1,189개의 탐색공간에 대해 145쌍의 훈련정을 사용하여 모델을 구축한 결과 Figure 4.49(a)와 같다.

컷오프 25%를 적용한 결과 ANN 모델 4의 431개의 탐색공간이 정의되었다. 165쌍의 훈련정을 사용하였으며 컷오프 30%를 적용하였다(Figure 4.50(a)). ANN 모델 5는 279개의 새로운 탐색공간에 대해 185개의 훈련정을 사용하여 구축하였다. 30%의 컷오프를 적용하여 ANN 모델 6의 탐색공간을 정의하였다(Figure 4.51(a)).


마지막으로, 244개의 탐색공간에 대해 ANN 모델 6를 사용하여 누적 가스 생산량을 계산하였다(Figure 4.52). 컷오프비율 30%를 적용하여 27개의 탐색공간이 정의되었다. 종료기준에 만족하여 ANN을 중지하고, 남은 27개의 탐색 공간에 대해 시뮬레이션을 수행하여 기존의 205쌍의 훈련정과의 비교를 통해 광역해를 도출하면 본 알고리즘은 종료된다(Table 4.17). 기존에 사용한 훈련정의 시뮬레이션 횟수를 제외하고, 총 127회의 시뮬레이션을 통해 광역해 (19, 35)-(39, 32)-(33, 9)를 도출하였으며, 해당 좌표의 누적 가스 생산량은 823,057,280m<sup>3</sup>이다(Figure 4.53). 석탄층 메탄가스 저류층에 시추한 결과 메탄의 흡착량 변화는 Figure 4.54과 같이 확인할 수 있다. Figure 4.47(b)-Figure 4.52(b)에서 나타난 탐색영역의 지도를 통해 탐색 공간이 광역해 중심으로 점차 좁혀지고 있음을 확인할 수 있다.

본 연구의 신뢰성을 위해 10회 반복한 결과는 Table 4.18과 같다. 수 회 반복한 결과 항상 동일한 값이 도출되는 것을 확인하였고, 이를 광역해로 판단하였다. 광역해를 도출하기 위해 필요한 시뮬레이션 횟수는 초기 훈련 데이터 105쌍으로 시작했을 때, 최소 231회, 최대 236회로 나타났다.



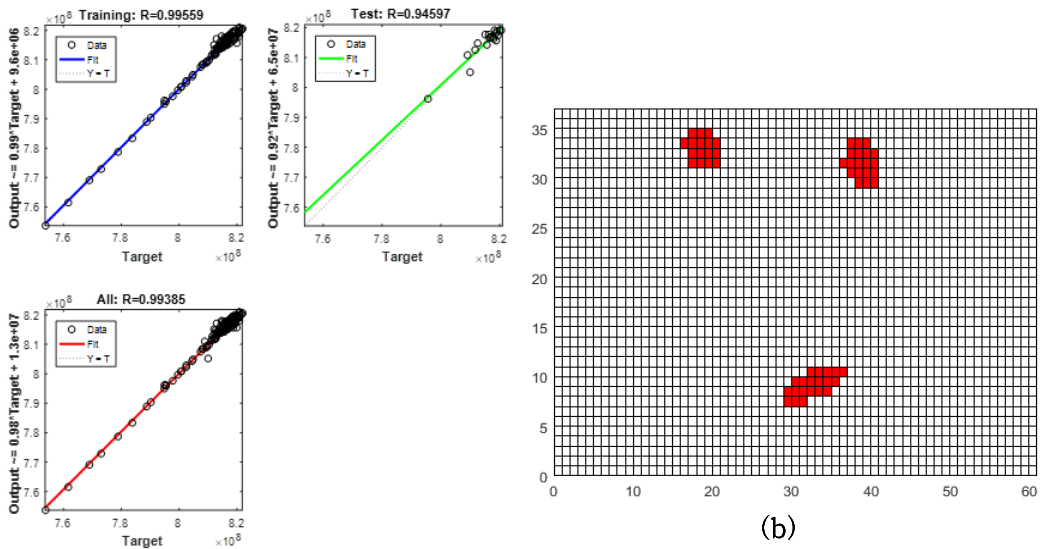


(a)




(c)

Figure 4.46 Result of initial ANN model.((a) Training result of initial ANN model, (b) Reduced search space of initial ANN model, (c) Top 15% of search space using initial ANN model)



(a)

(b)



(c)

Figure 4.47 Result of 2<sup>nd</sup> ANN model. ((a) Training result of 2<sup>nd</sup> ANN model, (b) Reduced search space of 2<sup>nd</sup> ANN model, (c) Top 20% of search space using 2<sup>nd</sup> ANN model)


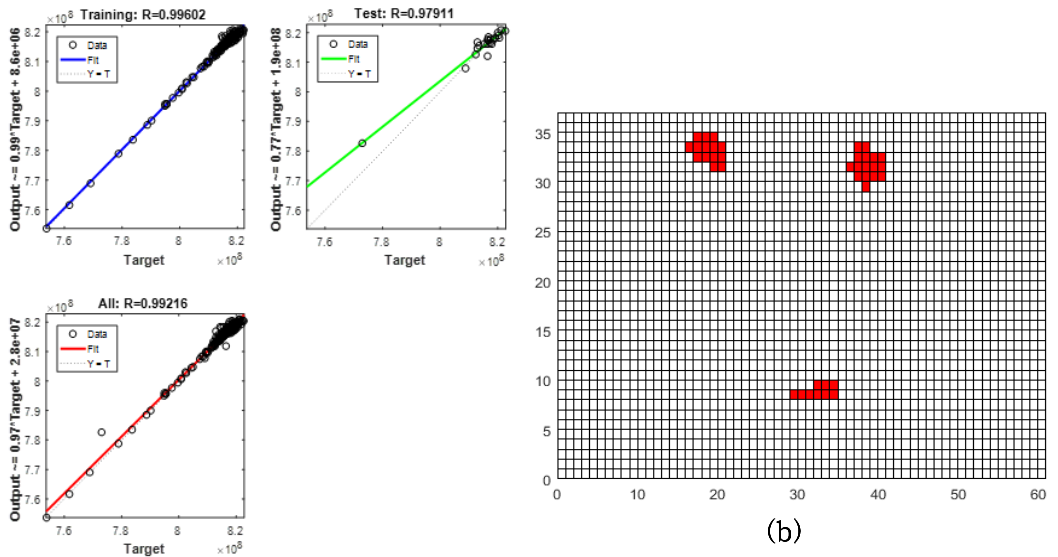
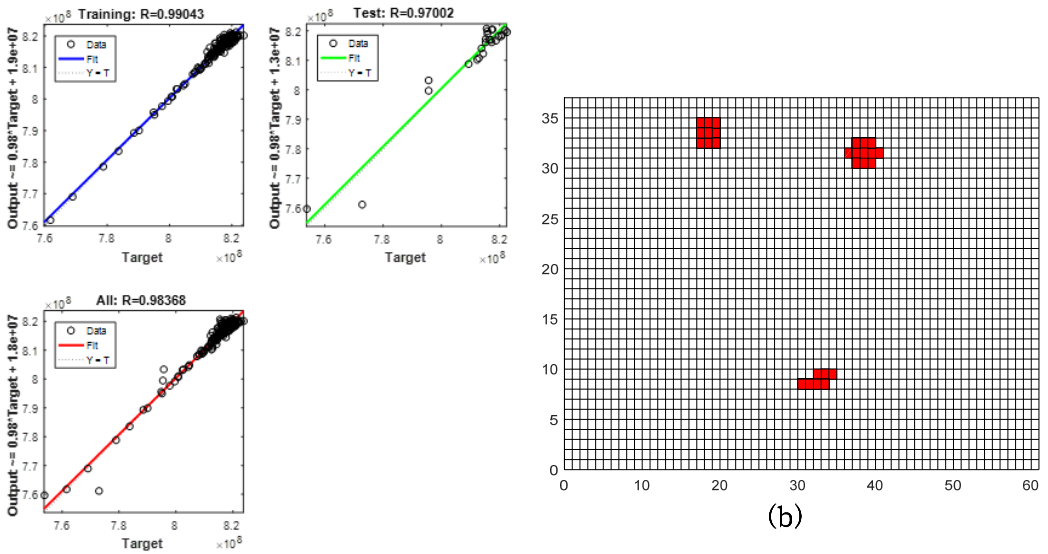



Figure 4.48 Result of 3<sup>th</sup> ANN model.((a) Training result of 3<sup>th</sup> ANN model, (b) Reduced search space of 3<sup>th</sup> ANN model, (c) Top 25% of search space using 3<sup>th</sup> ANN model)

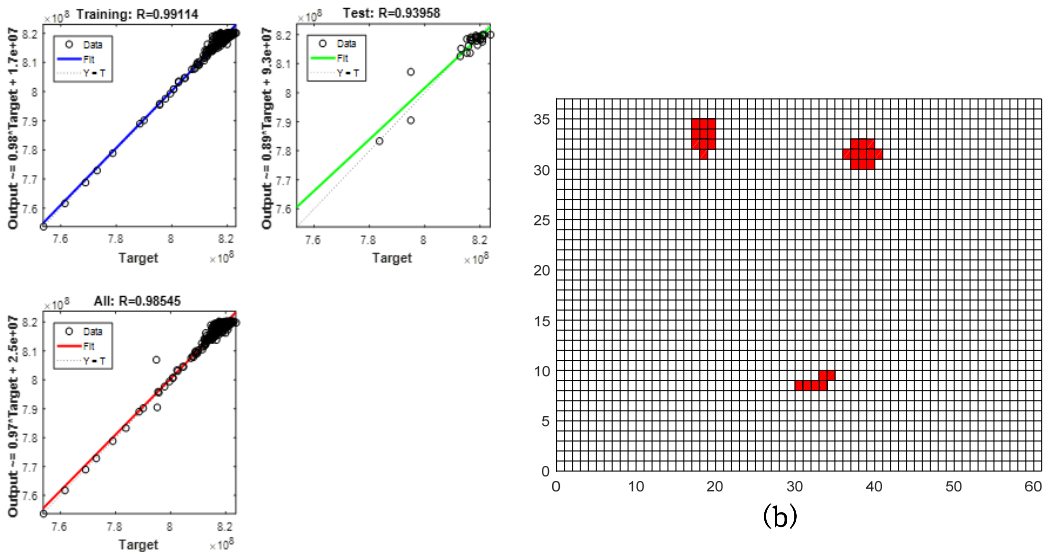


(a)




(c)

Figure 4.49 Result of 4<sup>th</sup> ANN model.((a) Training result of 4<sup>th</sup> ANN model, (b) Reduced search space of 4<sup>th</sup> ANN model, (c) Top 30% of search space using 4<sup>th</sup> ANN model)

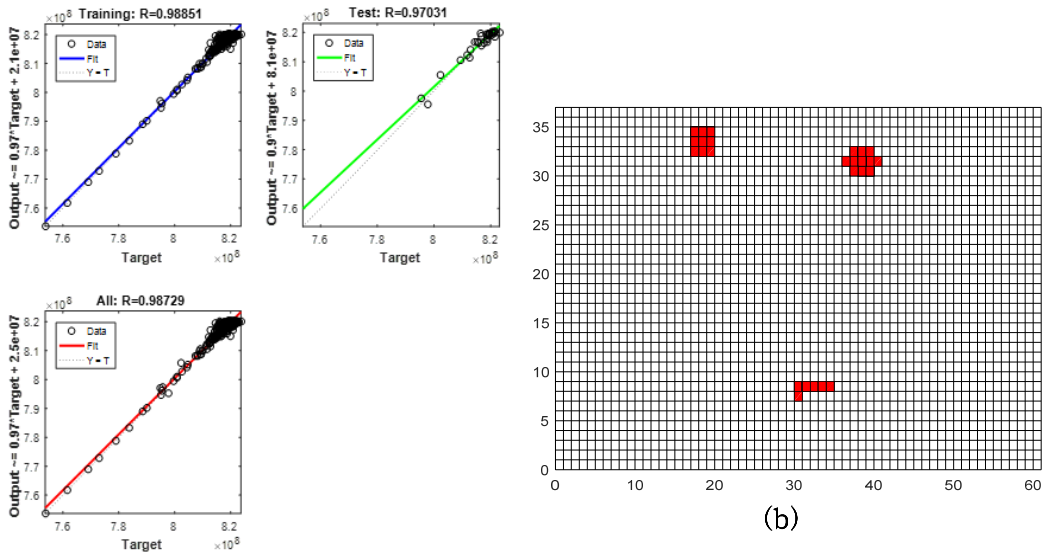


(a)




(c)

Figure 4.50 Result of 5<sup>th</sup> ANN model. (a) Training result of 5<sup>th</sup> ANN model, (b) Reduced search space of 5<sup>th</sup> ANN model, (c) Top 30% of search space using 5<sup>th</sup> ANN model)



(a)



(c)

Figure 4.51 Result of 6<sup>th</sup> ANN model.((a) Training result of 6<sup>th</sup> ANN model, (b) Reduced search space of 6<sup>th</sup> ANN model, (c) Top 30% of search space using 6<sup>th</sup> ANN model)

Table 4.17 Summary of applying the hierarchical ANN of 3 infill wells(Step 3)

ANN model	Search space	Cutoff value(%)	Number of training data	Number of simulation runs
1 <sup>st</sup>	35,000	15	105	0
2 <sup>nd</sup>	5,351	20	125	20
3 <sup>rd</sup>	1,189	25	145	40
4 <sup>th</sup>	431	30	165	60
5 <sup>th</sup>	279	30	185	80
6 <sup>th</sup>	244	30	205	100




Figure 4.52 Cumulative gas production rate of 3 infill wells(Step 3).




Figure 4.53 Adsorption(CH<sub>4</sub>) of 3 infill wells(Step 3).



Table 4.18 Results of repeated application of 3 infill wells ANN(Step 3)

	<b>Training</b>	<b>Remain</b>	<b>Total</b>	<b>GP Coord</b>	<b>GP Cum (m<sup>3</sup>)</b>
<b>1</b>	205	27	232	(19,35)-(39,32)-(33,9)	823,057,280
<b>2</b>	205	26	231	(19,35)-(39,32)-(33,9)	823,057,280
<b>3</b>	205	28	233	(19,35)-(39,32)-(33,9)	823,057,280
<b>4</b>	205	28	233	(19,35)-(39,32)-(33,9)	823,057,280
<b>5</b>	205	31	236	(19,35)-(39,32)-(33,9)	823,057,280
<b>6</b>	205	28	233	(19,35)-(39,32)-(33,9)	823,057,280
<b>7</b>	205	27	232	(19,35)-(39,32)-(33,9)	823,057,280
<b>8</b>	205	27	232	(19,35)-(39,32)-(33,9)	823,057,280
<b>9</b>	205	26	231	(19,35)-(39,32)-(33,9)	823,057,280
<b>10</b>	205	28	233	(19,35)-(39,32)-(33,9)	823,057,280

최종적으로, 생산정 3개의 시추 위치를 도출하기 위해 저류층을 5×5의 영역으로 나누었고, 1단계에서 도출된 광역해 1-5위까지 고려하여 이를 3×3으로 다시 나누었다. 2단계에서 도출된 광역해 1-3위를 고려하여 최종적으로 기본 격자 시스템의 탐색 영역으로 정의하여 인공지능망을 수행한 결과 최적 추가 시추 위치를 도출하였다.

본 저류층에서 3개의 추가 시추 위치를 도출하기 위해서 최대 1,913,665,160의 저류층 전산 모사를 수행해야 하지만, 제한한 방법을 사용함으로써 380회의 시뮬레이션으로 추가 시추 위치를 도출할 수 있다(Table 4.19).

Table 4.19 Result of 3 infill wells

<b>Step 1(itr 10 average)</b>	
<b>GP Coordinate</b>	(24, 34)-(34, 9)-(44, 34)
<b>GP Cum rate(m<sup>3</sup>)</b>	820,813,060
<b>Number of simulations</b>	190
<b>Step 2(itr 10 average)</b>	
<b>GP Coordinate</b>	(19, 35)-(40, 32)-(32, 9)
<b>GP Cum rate(m<sup>3</sup>)</b>	821,786,500
<b>Number of simulations</b>	90
<b>Step 3(itr 10 average)</b>	
<b>GP Coordinate</b>	(19, 35)-(39, 32)-(33, 9)
<b>GP Cum rate(m<sup>3</sup>)</b>	823,057,280
<b>Number of simulations</b>	127

## 제5장 결론

본 연구에서는 기존의 다생산정 시추 위치 최적화의 시나리오 기반 인공신경망의 한계를 극복하고자 계층적 격자시스템을 사용한 순차 인공신경망 기법을 제안하였다. 제안한 방법을 석탄층 메탄가스 다생산정 시추 위치에 적용하여 다음과 같은 결론을 도출하였다.

1. 개발한 계층적 격자시스템을 적용한 순차인공신경망 기법은 다생산정에 대한 위치 최적화시 시추위치에 대한 모든 경우를 고려하는 대신, 단계별 광역해를 찾아가는 과정에서 최종 광역해에 수렴하도록 한다. 도출된 광역해는 저류층 전산모사와 비교한 결과 정확히 일치함을 확인하였다.

2. 단계별 격자시스템 적용시 저류층의 지역적 불균질성에 의한 인공신경망 모델 결과의 불확실성을 고려하기 위해 각 단계의 광역해 상위 순위를 조합하여 다음 단계의 탐색 공간을 구축하고, 재탐색을 수행함으로써 광역해의 탈락 가능성을 축소시켰다.

3. 생산정 2개의 최적 위치 선정의 경우, 2개의 시추위치 조합은 2,545,896에 달하며, 계층적 격자시스템에 대한 순차인공신경망 기법을 적용한 결과 139회의 전산모사를 통해 광역해를 도출하였다. 또한 3개의 추가 시추에서 1,913,665,160의 시추위치 조합이 있으며, 본 방법의 380회로 광역해를 도출하여 소요되는 시간을 크게 단축하였다.

4. 이 논문에서 제시한 방법을 사용하면 숙련된 엔지니어의 경험과 직관이 요구되는 기존의 다생산적 시추 위치 시나리오의 방법에 비해 객관적이고 체계적인 접근법으로 추가 시추위치에 대한 최적화를 수행할 수 있다.

이와 같이 제안한 다생산정 시추 위치 최적화 방법은 기존의 시나리오 기반의 시추 위치 최적화 방법의 한계를 극복하고 신뢰성 있는 결과를 도출하였다. 계층적 격자시스템에 대한 순차인공신경망 기법은 광역해의 탈락 가능성을 최소화하고 계

산시간을 획기적으로 단축시킴으로써 생산성 시추위치 최적화 과정에서 신속하고 합리적인 의사결정의 도구로 활용될 수 있다.

## 참고문헌

곽태성, 정지현, 한동권, 권순일, 2015, “인공신경망과 SA 알고리즘을 이용한 지능형 생산정 위치 최적화 전산 모델 개발”, 한국가스공학회지, 19(1), 28-37.

김유미, 2017, 순차적 인공신경망 기법을 적용한 시추위치 최적화 연구, 석사학위논문.

민배현, 2007, 인공신경망을 이용한 추가 시추위치 최적화, 석사학위논문.

최규석, 박종진, 2009, “인공지능시스템”, 21세기사, pp. 19-24.

Ali S. Al-Mashhad, Sulaiman A. Al-Arifi, Mohammed S., Mohammed S. Al-Kadem, Al-Dabbous, and Ahmed Buhulaigah, 2016, “Multilateral Wells Evaluation Utilizing Artificial Intelligence”, SPE 183508, presented at Abu Dhabi International Petroleum Exhibition & Conference held in Abu Dhabi, UAE, 7-10 November 2016.

Beckner, B.L., and Song, X, 1995, “Field Development Planning Using Simulated Annealing-Optimal Economic Well Scheduling and Placement”, SPE 30650, presented at SPE Annual Technical Conference & Exhibition held in Dallas, U.S.A, 22-25 October, 1995.

Centilmen, A., Ertekin, T., and Grader, A.S., 1999, “Applications of Neural Networks in Multiwell Field Development”, SPE 56433, presented at the 1999 SPE Annual Technical Conference and Exhibition held in Houston, Texas, 3-6 October, 1999.

Doraisamy, H., 1998, “Method of Neuro-Simulation for Field Development, MS thesis in Petroleum and Natural Gas Engineering”, The Pennsylvania State

University, University Park, PA(1998).

Doraisamy, H., Ertekin, T., and Grader, A. S., 1998, “Method of Neuro-Simulation for Field Development”, SPE 39962, 1998 SPE Rocky Mountain Regional, Denver, CO.

Doraisamy, H., Ertekin, T., and Grader, A. S., 2000, “Field Development Studies by Neuro-Simulation: an Effective Coupling of Soft and Hard Computing Protocols”, Computers & Geosciences(2000) 26, 963-973.

Jang, I., Oh, S., Kim, Y., Park, C., & Kang, H., 2017, “Well-placement optimisation using sequential artificial neural network”, Energy Exploration & Exploitation, 14459871772949. <https://doi.org/10.1177/0144598717729490>

Olivares, G., Escalona, C. and Gimenez, E., 2012, “Production Monitoring Using Artificial Intelligence, APLT Asset”, SPE 149594, presented at SPE Intelligent Energy International held in Utrecht, The Netherlands, 27-29 March 2012.

Onwunalu, J.E. and Durlofsky, L.J., 2010, “Application of a particle swarm optimization algorithm for determining optimum well location and type”, Springer Science, Comput Geosci(2010) 14:183-198.

Salmachi, A., Bonyadi, M.R., Sayyafzadeh, M., and Haghghi, M., 2014, “Identification of potential locations for well placement in developed coalbed methane reservoirs”, International Journal of Coal Geology 131 (2014) 250-262.

Yeten, B., Durlofsky, L.J., and Aziz, K., 2003, “Optimization of Nonconventional Well Type, Location and Trajectory”, SPE 86880, presented at the 2002 SPE Annual Technical Conference and Exhibition, San Antonio, Texas, 29 September-2 October.