



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](#)

2017년 2월

석사학위논문

순차적 인공신경망 기법을 적용한 시추위치 최적화 연구

조선대학교 대학원

에너지자원공학과

김 유 미

순차적 인공신경망 기법을 적용한 시추위치 최적화 연구

A Study on Well Placement Optimization Using a
Sequential Method of Artificial Neural Networks

2017년 2월 24일

조선대학교 대학원

에너지자원공학과

김 유 미

순차적 인공신경망 기법을 적용한 시추위치 최적화 연구

지도교수 장 일 식

이 논문을 공학 석사학위신청 논문으로 제출함


2016년 10월


조선대학교 대학원


에너지자원공학과

김 유 미

김유미의 석사학위논문을 인준함

위원장 조선대학교 교수 강성승 

위원 조선대학교 교수 장일식 

위원 조선대학교 교수 최태진 

2016년 11월

조선대학교 대학원

목 차

목차	i
List of tables	iii
List of figures	v
Abstract	vi
제1장 서론	1
제2장 이론적 배경	4
제1절 소프트 컴퓨팅	4
제2절 인공신경망	6
1. 인공신경망의 구성	6
2. 시추위치 최적화를 위한 인공신경망의 학습 자료 설정	9
제3장 인공신경망을 이용한 추가 시추위치 최적화	12
제1절 기존 방법의 과정 및 한계	12
제2절 순차적 인공신경망 기법을 적용한 광역적 최적 추가 시추위치 선정 방법	14
제4장 연구 결과	17
제1절 Black-Oil Model	17

1. 저류층 시스템	17
2. 인공신경망의 학습 자료 설정	20
3. 광역적 최적 추가 시추위치 선정	23
제2절 석탄층 메탄가스 저류층	40
1. 저류층 시스템	40
2. 인공신경망의 학습 자료 설정	42
3. 광역적 최적 추가 시추위치 선정	45
제3절 광역적 최적 시추위치 선정 결과	70
제5장 결론	74
참고문헌	76

List of tables

Table 1. Difference between soft and hard computing(Ahmad, 2014).	5
Table 2. The similarities between the biological neural network and artificial neural networks(Han, 2014).	6
Table 3. Input neuron for artificial neural network.	11
Table 4. Output neuron for artificial neural network.	11
Table 5. Black-Oil reservoir properties.	18
Table 6. Layer porosity and thickness values(Killough, 1995).	18
Table 7. Input neuron for Black-Oil Model artificial neural network.	21
Table 8. Output neuron for Black-Oil Model artificial neural network.	21
Table 9. The results of Black-Oil Model sequential artificial neural network constructed using 40 initial training data.	25
Table 10. The results of Black-Oil Model sequential artificial neural network constructed using 20 initial training data.	28
Table 11. The results of Black-Oil Model sequential artificial neural network constructed using 10 initial training data.	32
Table 12. The results of Black-Oil Model sequential artificial neural network constructed using 5 initial training data.	36
Table 13. Simulation condition for Coalbed Methane Model.	41
Table 14. Input neuron for artificial neural network of Coalbed Methane Model.	43
Table 15. Output neuron for artificial neural network of Coalbed Methane Model.	43
Table 16. The results of Coalbed Methane Model sequential artificial neural network constructed using 40 initial training data.	47
Table 17. The results of Coalbed Methane Model sequential artificial neural network constructed using 20 initial training data.	51
Table 18. The results of Coalbed Methane Model sequential artificial neural network constructed using 10 initial training data.	57

Table 19. The results of Coalbed Methane Model sequential artificial neural network constructed using 5 initial training data. 64

Table 20. Total results of the Black-Oil and Coalbed Methane models. 70

Table 21. PSO Parameters used for the well placement optimization run. 71

List of figures

Figure 1. Comparison of (a)the Biological Neural Network(Raschka, 2015) and (b)Artificial Neural Networks(Wikibooks, 2013).	7
Figure 2. Activation functions(Kim, 2013).	8
Figure 3. Back-propagation algorithm(Pusan National Univ. NR Lab.).	9
Figure 4. Cross plot of output data using ANN method.	13
Figure 5. Magnified cross plot of output data using ANN method.	13
Figure 6. Flow chart of well placement optimization using sequential Artificial Neural Network.	16
Figure 7. Permeability distribution for Black-Oil Model.	19
Figure 8. Oil saturation for Black-Oil Model.	19
Figure 9. Well location map of Black-Oil Model.	22
Figure 10. Oil production rate of Black-Oil Model.	22
Figure 11. Permeability distribution for Coalbed Methane Model.	41
Figure 12. Well location map of Coalbed Methane Model.	44
Figure 13. Oil production rate of Coalbed Methane Model.	44
Figure 14. Cost as a function of 15 and 20 iteration for PSO.	72
Figure 15. Cost and number of simulations as a function of 79 iteration for PSO. ·	72
Figure 16. The correct example of the coefficient of determination.	73
Figure 17. The wrong example of the coefficient of determination.	73

ABSTRACT

A Study on Well Placement Optimization Using a Sequential Method of Artificial Neural Networks

Kim Yu Mi

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

Department of Energy & Resources Engineering

Graduate School of Chosun University

Well placement is an important task to minimize the risk of unproductive drilling and to maximize the production. When dealing with heterogeneities, the intuitive engineering judgment may not be sufficient, and the use of global optimization methods becomes necessary in finding a favorable production plan.

The behavior of scenario combining thousands of production locations are predicted through reservoir simulations. Depending on the size of the reservoir, the computation time and cost of the reservoir simulation may be excessive. Soft computing techniques can reduce the time and cost of solving problems. Among the soft computing techniques, artificial neural network is capable of high-speed computation while ensuring reliability of prediction results.

In conventional drilling location optimization studies, artificial neural network is frequently used due to fast operation speed, but the prediction result is sensitive to the learning data and input/output data used for the learning. While it is possible to identify values close to the global optimum using the optimization algorithm, there is a limit that it is not easy to obtain the global optimum itself.

In this paper, a new method is proposed by applying sequential neural networks to obtain true global optimization for well placement. By repeatedly generating artificial neural networks for the high ranked data among the results from a sequence of artificial neural networks, the range of the search space is gradually narrowed down. As a result, the global optimum point can be found

through execution of minimum number of reservoir simulation. In order to evaluate the reliability of the developed method, the new method was applied for two different reservoir cases.

It was confirmed that the proposed method of well location optimization can reduce the computation time by at least 70% according to the number of grids and the number of data used in learning. The proposed method was compared with particle swarm optimization (PSO) algorithm, which proved that the proposed method was more efficient than PSO.

If the drilling location optimization of the on-site reservoir is performed by the method proposed in this paper, it is possible to save the time and cost by high-speed operation and obtain the global optimum infill drilling location with the maximum accumulated production.

제1장 서론

시추 위치의 결정은 생산성이 없는 유정 시추의 위험성을 최소화 시키고 오일, 가스의 생산량을 최대화 시키는 중요한 작업이다. 생산량에 영향을 미치는 운영비용, 유가, 생산정간 영향 반경, 저류층의 물성 등 다양한 인자들을 고려하여 많게는 수천가지 이상의 생산정 위치 조합에 대해 저류층 전산 시뮬레이션을 수행하여 예측할 수 있다. 그러나 불균질한 저류층에서의 시추정 위치 선정 시 엔지니어의 직관에 의한 시나리오 선정은 정확성이 떨어질 수 있다. 따라서 최소 제곱법과 같은 국소적 최적화 방법과 보간법 등으로 시추 위치 선정 문제를 다루기 시작하였으며 국소적 최솟값 또는 최댓값들 중에서 광역적 최소 또는 최대가 되는 매개변수를 찾는 방법인 광역적 최적화 방법을 적용하는 연구가 수행되어 왔다.

자연적 선택 구조에 기반을 둔 유전 알고리즘(Genetic algorithm)은 광역적 최적화 기법 중 석유 기술에서 다양한 분야의 문제를 해결하는데 사용되어 왔다. Morales 등(2010)은 도함수와 기울기 변화에 기반을 둔 알고리즘은 지역적 최적 값에 고립될 수 있으나 유전 알고리즘은 이러한 수렴 문제를 피하는 유연함이 장점이라고 평가하였다. 또한 시뮬레이션 구동 시간을 줄이고 정확한 결과를 얻기 위해 알고리즘 내에서 한 세대의 개체수와 교배 방법, 돌연변이율, 멈춤 기준과 같은 변수들에 대해 적절한 기준을 제시하였다. Montes 등(2001)에 의해 유전 알고리즘의 변수들의 변화에 따른 효과가 연구되었다. 랜덤 시드, 개체군의 크기, Elitism의 사용과 미사용, 돌연변이율이 수렴 속도와 알고리즘의 절대 수렴에 미치는 효과를 파악하였다. 복잡한 구조의 저류층의 시추 위치를 최적화하는데 적용될 수 있는 강력한 검색 방법이라는 것을 증명하였으며 다른 평가 방법(Streamlines, Conference mapping, Neural networks, Nested gridding)을 결합한다면 연산 시간을 단축시킬 수 있을 것이라 예측하였다.

Kennedy와 Eberhart(1995)에 의해 제안된 입자 군집 최적화 알고리즘(Particle swarm optimization)은 새, 물고기와 같이 집단행동을 하는 생물들의 집단행동 특성에서 광역 최적화의 아이디어를 얻어 개발된 진화 연산 기법으로 최적화 기법 중에서 일반적인 발견적 해결 방법이다. Feng 등(2012)은 저류층 시뮬레이션과 입자 군집 최적화 알고리즘을 통합하여 석탄층 메탄가스(CBM) 저류층에서 유정의 위치를 최적화 하고 목적함수는 가상의 저류층에서 순현재가치를 최대화 시키는

것에 대해 연구 하였다.

Gargari와 Lucas(2007)에 의해 개발된 제국주의 경쟁 알고리즘(Imperialist competitive algorithm)은 제국이 식민지의 정치 및 문화적 지배를 통해 국가의 영향력을 확대하는 사상에서 영감을 받은 알고리즘으로 광역해의 탐색에 대한 높은 수행능력으로 다양한 문제에 제안되어 왔다. Dossary와 Nasrabadi(2015)에 의해 제국주의 경쟁 알고리즘이 처음으로 오일, 가스 산업에서 유정의 생산성 최대화를 위한 최적의 유정 위치를 찾기 위해 적용되었다. 불균질한 저류층에서의 수직정 및 수평정에 대해 제국주의 경쟁 알고리즘과 유전 알고리즘의 결과 값을 비교하였다. 최대 누적 생산량을 목적함수로 두었을 때 정해진 시물레이션 실행 횟수에 대해 제국주의 알고리즘이 전역적 최댓값에 가깝게 수렴하였다.

대상 저류층의 규모에 따라 저류층 전산 모델을 이용할 경우 과도한 계산 시간과 비용이 소요될 수 있다. 기존(하드) 컴퓨팅 기법과 달리 특정 문제에 대한 부정확하고 불완전한 정보의 지정된 허용 오차를 이용하여 추론과 학습을 통해 계산하는 혁신적인 접근 방법인 소프트 컴퓨팅 기법을 이용하여 문제를 해결하는데 드는 시간과 비용을 줄일 수 있다. 소프트 컴퓨팅 기법 중 예측 결과의 신뢰성을 확보하면서 고속의 연산이 가능한 인공지능망은 인간의 신경 조직을 수학적으로 모델링하여 인간처럼 학습, 기억, 판단 할 수 있도록 구현한 것이다. 신경망의 구조를 선택한 후에 어떤 학습 알고리즘을 사용할 것인지 선택하고 신경망 훈련을 통해 가중치를 갱신하여 구축할 수 있다. 인공지능망은 저류층 전산 모델을 대체하는 기법으로 신속성과 정확성의 문제를 해결하고 최적의 시추위치를 결정하는 연구에 적용되어 왔다.

Centilmen 등(1999)은 정확성을 유지하면서 빠르고 효과적으로 유정의 위치를 최적화 하는데 신경망시물레이션(Neuro-simulation)을 사용하는 가이드라인을 제안하였다. 역전파 알고리즘을 사용하여 입력 자료로는 저류층의 특성을 반영한 변수, 입력 자료가 출력 자료에 끼치는 영향을 확대하기 위한 함수적 연관관계, 회수율에 따라 저류층의 격자를 분류한 Expectancy factor 등을 도입하여 다수의 생산정을 시추 할 경우의 최적의 시추 위치를 예측하였다. Guyaguler와 Horne(2004)은 유전알고리즘, polytope 방법, kriging, 인공지능망을 활용한 하이브리드 최적화 알고리즘을 저류층 시물레이터와 함께 적용하였다. Yeten 등(2003)은 유전알고리즘에 기반하고 힐클라임, 인공지능망 또는 유정 주변을 격자 세밀화하는 방법으로 시물레이션을 가속화하여 다중 수평정의 종류, 위치, 궤도를 최적화 하는 방법을 제안하였다.

그러나 이상의 시추위치 선정 연구는 인공지능망을 이용하여 신속한 연산속도는

얻을 수 있지만 그 예측 결과는 학습에 사용되는 학습 자료와 입출력 자료에 민감하다. 또한 최적화 알고리즘을 사용하여 최적 값에 가깝게 도달하여 정확도를 향상시킬 수는 있지만 정확하게 일치하는 결과는 얻지 못하는 한계가 존재한다.

이 연구에서는 추가 시추위치를 최적화하기 위해 인공신경망의 순차적인 구축을 통해 저류층 전산 시뮬레이터를 최소한으로 실행하여 시추위치의 광역해(Global optimum point)를 찾는 방법을 제안하고자 한다. 인공신경망은 시행하기에 간단하고 정확해 가장 많이 쓰이는 학습규칙인 역전파 알고리즘을 사용하였다. 또한 입력 자료에 포함된 불필요한 인자들로 인해 패턴 인식을 방해 받아 예측 성능이 저하될 수 있기 때문에 학습과정에서 주어진 정보의 패턴을 파악하여 입력 자료를 선택하였다. 개발한 방법의 신뢰성을 평가하기 위해 대상 저류층의 시추 가능한 전체 위치에 대한 저류층 전산 모사의 결과와 비교하였다. 또한 기존의 광역적 최적화 알고리즘 중에서 입자 군집 최적화 알고리즘을 사용하여 최적 추가 시추위치 결과의 정확성과 성능을 비교하여 효용성을 입증하였다.

제2장 이론적 배경

제1절 소프트 컴퓨팅(Soft computing)

소프트 컴퓨팅 기법은 정확성과 완전한 정보를 추구하는 기존(하드) 컴퓨팅 기법과 달리 특정 문제에 대한 부정확하고 불완전한 정보의 지정된 허용 오차를 이용하여 추론과 학습을 통해 계산하는 혁신적인 접근 방법이다. 인간의 지적 활동에 대한 규명과 그것을 응용하여 기계적으로 실현한 것으로 지능 시스템이라고도 한다. 지능 시스템이 갖추어야 할 요소는 불확실성 대처기능, 학습기능, 최적화 지향성 기능이 있다(정환목, 2008). 현재까지 알려진 지능형 기법을 총칭하는 용어로 사용되고 있으며 대표적으로 인공지능망, 퍼지이론, 근사 추론과 미분에 근거한 최적화 방법 등으로 구성된다. 최근의 추세는 진화론 및 군집 지능 기반의 알고리즘 및 생체 인식 계산을 포함하는 경향이 있다.

Table 1은 기존 컴퓨팅 기법과 소프트 컴퓨팅 기법의 차이를 비교해 놓은 표이다. 기존의 컴퓨팅 기법은 정확하게 기술된 분석 모델을 필요로 하고 때때로 많은 계산 시간이 요구되며 계산을 위해 정확한 정보를 요한다. 그렇기 때문에 정확한 결과를 얻는 반면 높은 비용이 소요된다. 소프트 컴퓨팅 기법은 완전히 정확하지 않은 정보로 작업이 가능하기 때문에 그 결과 또한 통계적이며 부정확하다. 그러나 적은 계산 시간과 비용이 소요된다. 석유공학에서는 이러한 소프트 컴퓨팅 기법이 저류층 특성화, 히스토리매칭, 시추위치 최적화 등에 활용되어 왔다.

Table 1. Difference between soft and hard computing(Ahmad, 2014).

Hard Computing	Soft Computing
requires a precisely stated analytical model.	is tolerant of imprecision.
often requires a lot of computation time.	can solve some real world problems in reasonably less time.
requires full truth.	can work with partial truth.
precise and accurate.	imprecise.
high cost for solution.	low cost for solution.
deterministic.	stochastic.
requires exact input.	can deal with ambiguous and noisy data.
produce precise answer.	produce approximate answers.

제2절 인공신경망(Artificial Neural Network)

인공신경망은 인간의 신경 조직을 수학적으로 모델링하여 인간처럼 학습, 기억, 판단할 수 있도록 구현한 것이다. 신경 조직의 기본 단위인 뉴런을 수학적으로 모델링한 ‘퍼셉트론’을 기본 단위로 사용한다. 여기서 퍼셉트론은 신경세포와 유사한 계산 기능을 갖는 요소로 구성된 입력층과 출력층을 갖는 신경 시스템의 모델명이다. 인공신경망은 신경망의 구조를 선택한 후에 어떤 학습 알고리즘을 사용할 것인지 선택하고 신경망 훈련을 통해 가중치를 갱신하여 만들어진다. 이러한 인공신경망이 석유공학에서 시스템 제어, 예측 및 상관관계분석, 패턴/클러스터 분석, 신호/이미지 처리, 최적화의 목적으로 활용되고 있다(Ali, 1994).

1. 인공신경망의 구성

다음 Table 2와 Figure 1은 생물학적인 신경망과 인공 신경망 사이의 유사점을 비교한 것이다. 생물학적인 신경세포체는 수상돌기(Dendrite), 축삭돌기(Axon) 그리고 세포체(Cell body)로 이루어졌다. 수상돌기는 인접 뉴런에서 신경흥분이 세포체로 입력되는 통로이며, 축삭돌기는 가늘고 긴 신경섬유로 신경흥분으로 전달하는 역할을 한다(한학용, 2014). 세포체는 일정 시간 동안 입력된 자극이 세포체에서 가중되고 그 값이 임계값 이상이 되면 뉴런이 활성화하여 축삭돌기로 자극이 전달되는 메커니즘이다(한학용, 2014).

Table 2. The similarities between the biological neural network and artificial neural networks(Han, 2014).

Biological neural network	Artificial neural network
Cell body	Neuron
Dendrite	Input
Axon	Output
Synapse	Weight




Figure 1. Comparison of (a)the Biological Neural Network(Raschka, 2015) and (b)Artificial Neural Networks(Wikibooks, 2013).

Figure 1과 같이 생물학적인 신경세포에서 수상돌기를 입력 유닛(Input, x_n)으로 설정하고, 세포체의 가중합(v)은 각 유닛과 연결된 연결 가중치(Weight, ω_n)를 곱한 합으로 계산한다. 이것은 활성화 함수에 의해 출력값을 얻도록 모델링할 수 있다. 입력 신호의 가중치 합을 계산하여 임계값과 비교하여 활성화 함수로 출력값을 얻는다.

$$v = \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n = \sum_{k=1}^n \omega_k x_k$$

활성화 함수(Figure 2)들 중에 계단(Step)과 부호(Sign) 활성화 함수는 하드리밋 함수(Hard limit function)로서 분류와 패턴인식 작업과 같이 결정을 내리는 뉴런에 주로 사용된다. 시그모이드(Sigmoid) 활성화 함수는 양과 음의 무한대 사이에 있는 값을 0과 1의 사

이의 적당한 값으로 바꾸어 주며 역전파 신경망(BPN, Back-propagation network)에 쓰인다. 선형(Linear) 활성화 함수는 뉴런의 입력에 가중치가 적용된 것과 같은 값을 출력으로 내 놓고 선형 근사에 주로 쓰인다.




Figure 2. Activation functions(Kim, 2013).

연결 구조는 전방향신경망(Feedforward)과 회귀신경망(Recurrent)으로 나눌 수 있다. 전방향 신경망은 주어진 입출력 패턴에 대응하는 결과를 출력하게끔 학습하며 역전파 알고리즘이 개발된 이후 널리 사용되고 있다. 회귀신경망은 입력층과 출력층 사이에 은닉층의 일종인 인지층이 존재하여 피드백 작용이 존재하며 시간에 따라 특성이 동적으로 변하는 구조에 사용된다. 인공신경망의 출력값이 부드럽고 단조롭게 감소하며 급격한 변화가 없을 것으로 예측된다면 전방향 신경망, 출력값의 급격한 변화가 예측된다면 회귀 신경망을 추천한다(Doraisamy, 1998, Doraisamy et al, 1998).

인공신경망의 학습은 총 오차가 일정 수렴 기준에 도달할 때까지 가중치를 수정하여 이루어지며 지도 학습(Supervised learning)과 자율 학습(Unsupervised learning)으로 나뉜다. 지도 학습은 입력 패턴과 그에 대응하는 목적 패턴을 함께 신경망에 입력하여 학습하는 것으로 홉필드(Hopfield), 델타 규칙(Delta rules), 역전파 알고리즘(Back-propagation algorithm)이 있다. 자율 학습은 목적 패턴을 사용하지 않고 학습 자료를 신경망의 입력 자료로만 사용하고 스스로 연결 가중치를 조정하는 학습 방법으로 경쟁 학습 알고리즘과 ART(Adaptive resonance theory) 모델이 있다.

역전파 알고리즘은 시행하기에 간단하고 정확해 가장 많이 쓰이는 학습규칙이다. 전향 단계와 후향 단계로 이루어져 있으며 학습에서 중요한 연결 강도 갱신이 후향 단계에서 이루어진다. 전향 단계를 통해 발생한 출력값과 목표값의 큰 오차를 역전파하여 출력층에서

입력층으로 층과 층 사이의 연결 강도를 갱신한다. 연결 강도를 조절한 후 다시 입력을 넣어 출력을 얻고 총 오차의 합이 정해진 오차의 기준치에 도달할 때까지 반복 실행해 원하는 값에 수렴시킨다(Figure 3).




Figure 3. Back-propagation algorithm(Pusan National Univ. NR Lab.).

2. 시추 위치 최적화를 위한 인공지능망의 학습 자료 설정

인공지능망의 학습을 위해 선정되는 입·출력값은 문제를 묘사하는 변수들로 이루어져 있으며 시뮬레이터의 예측성능에 영향을 주므로 매우 중요하다. 학습에 사용되는 자료의 수는 일반적으로 그 수가 증가할수록 신경망의 예측성능이 향상되나 이에 비례하여 전산모사 횟수가 늘어나 학습에 소요되는 시간이 증가하여 비용의 제약이 따를 수 있다. 그러므로 인공지능망의 예측성능을 유지할 수 있는 최소의 학습 자료의 수를 선정해야 한다.

이와 같이 시추 위치 최적화를 위한 정확한 생산량 예측 모델을 얻기 위해서는 인공지능망 학습과정에서 입력값과 출력값에 따른 예측결과의 패턴을 파악하여 입력 자료를 선택해야 한다. 입력 자료에 불필요한 인자들이 포함되면 인공지능망의 패턴인식을 방해하여 예측성능이 저하되기 때문이다. 따라서 예측 모델의 생산량과

밀접한 관련이 있는 주요한 특징을 가능한 최소한의 입력 자료로 효과적으로 표현해야 한다(Doraisamy et al., 1998). 인공신경망에 사용한 입력 자료는 생산 시간, 생산정의 물리적 특성, 유정의 공간적 위치 정보, 생산정간 상관관계, 신경망의 민감도를 향상시키는 함수적 연관관계(Functional links) 등으로 구성한다(Table 3). 유정의 공간적 위치 정보는 추가 생산정의 위치 좌표, 추가 생산정과 저류층 경계간 거리, 추가 생산정과 대수층까지의 거리를 포함하며 유정 간 간섭효과를 파악하기 위한 생산정간 상관관계는 기존 생산정과 추가 생산정간 거리, 추가 생산정간 거리를 포함한다(민배현, 2007). 저류층 물성을 모두 입력 자료로 사용하여 입력 변수의 수가 크게 증가하는 것을 오일 부존량과 저류층 연결성의 함수인 생산성 잠재력(Productivity potential)을 사용하여 효율적인 신경망 구조를 갖출 수 있다. 함수적 연관관계는 입력 패턴의 작은 변화로 인한 출력 패턴의 민감도를 높여 인공신경망의 정확성을 향상시키며 제곱함수(Square function)는 입력 자료의 미세한 변화를 증폭시키고, 분수함수(Reciprocal function)는 작은 입력값이 신경망 예측 성능에 끼치는 영향을 확대한다(민배현, 2007). 출력 자료는 생산정의 생산 가치를 의미하도록 생산 기간 동안의 누적 생산량 또는 순현재가치(Net present value)등을 사용할 수 있다(Table 4).

최적의 시추 위치를 선정하기 위한 인공신경망의 학습에 사용되는 훈련 생산정은 다양한 생산패턴을 학습하기 위해 생산성이 높은 지역과 낮은 지역을 모두 고려하여 선정해야 한다. 학습 자료의 수가 증가하면 인공신경망의 예측 정확성은 증가하지만 학습에 소요되는 시간 또한 증가하기 때문에 비용의 제약이 따를 수 있다. 따라서 훈련정의 위치는 생산성이 우수할 것으로 예상되는 유제투과도가 우수한 지역, 기존 생산정과 멀리 떨어져서 간섭효과가 일어나지 않는 지역과 생산성이 낮을 것으로 예상되는 단층, 저류층의 경계지역, 기존의 생산정과 인접한 지역 등을 고려하여 선정하도록 한다.

Table 3. Input neuron for artificial neural network.

Input neuron	Data type
Time	Time series data
Infill well x-y coordinates	Spatial information of well
Distance from infill well to the reservoir boundary	Spatial information of well
Distance from infill well to the aquifer	Spatial information of well
Productivity potential of each grid blocks	Individual well property
Inter-distance between existing wells and infill well	Well interaction data
Inter-distance between infill wells	Well interaction data
Square time	Functional links
Reciprocal time	Functional links
Square of infill well x-y coordinates	Functional links
Reciprocal of infill well x-y coordinates	Functional links

Table 4. Output neuron for artificial neural network.

Output neuron	Data type
Cumulative oil production rates	Time series data
Net present value	Time series data

제3장 인공신경망을 이용한 추가 시추위치 최적화

제1절 기존 방법의 과정 및 한계

인공신경망을 이용한 추가 시추위치 최적화 과정의 핵심은 대상 저류층에 추가 생산정을 설치한 일부 시나리오를 저류층 전산 시뮬레이터로 실행한 결과를 사용하여 인공신경망을 학습시켜 구축하는 것이다. 시나리오는 인공신경망을 학습시키기 위해 대상 저류층에 시추할 추가 생산정의 위치와 수를 정해 학습에 사용되는 생산정 위치를 조합하여 생성한다. 이 시나리오를 저류층 전산모사를 수행하여 인공신경망의 출력자료로 선정한다. 저류층 전산 시뮬레이터로 검증된 시나리오의 예측 결과와 비교하여 인공신경망의 예측성능을 평가한다.

기존에 연구되어온 인공신경망을 사용한 시추위치 최적화 방법은 연산속도는 개선하였지만 최적의 정확한 시추위치를 얻지 못하는 한계가 있다. 그리하여 인공신경망의 학습에 사용되는 입력 자료에 변화를 주어 저류층 전산 모사 결과와 인공신경망을 통해 얻은 결과 값의 결정계수 값을 높여 오차를 줄여왔다. Figure 4는 0.98의 결정계수를 갖는 인공신경망을 사용하여 300개의 추가 생산 시나리오의 가스 생산량 예측결과와 저류층 시뮬레이션 결과를 비교한 그래프이다. Figure 4의 빨간색 사각형 범위를 확대하면 인공신경망을 사용한 예측값의 최댓값이 저류층 시뮬레이션의 결과에서 최댓값과 일치하지 않음을 확인할 수 있다(Figure 5). 0.98로 높은 결정계수 값을 갖는 인공신경망을 사용하여 생산시나리오의 결과를 예측하였지만 저류층 시뮬레이션 결과에 근접할 뿐 정확히 일치하는 광역해를 얻지 못하는 것이 인공신경망의 한계이다.

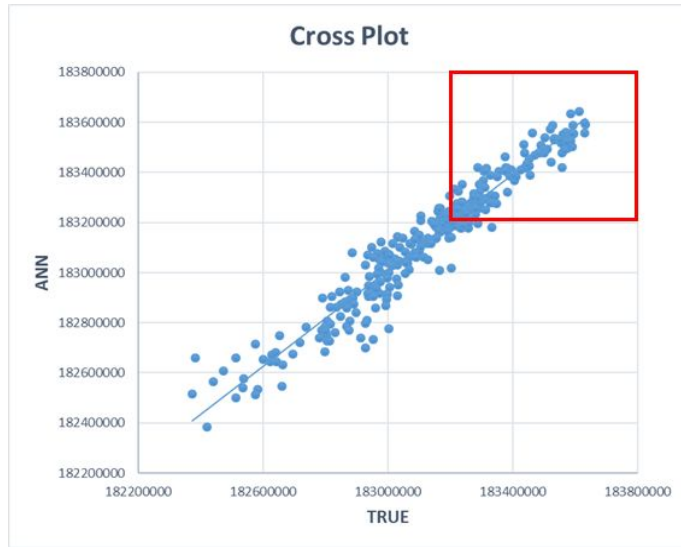


Figure 4. Cross plot of output data using ANN method.

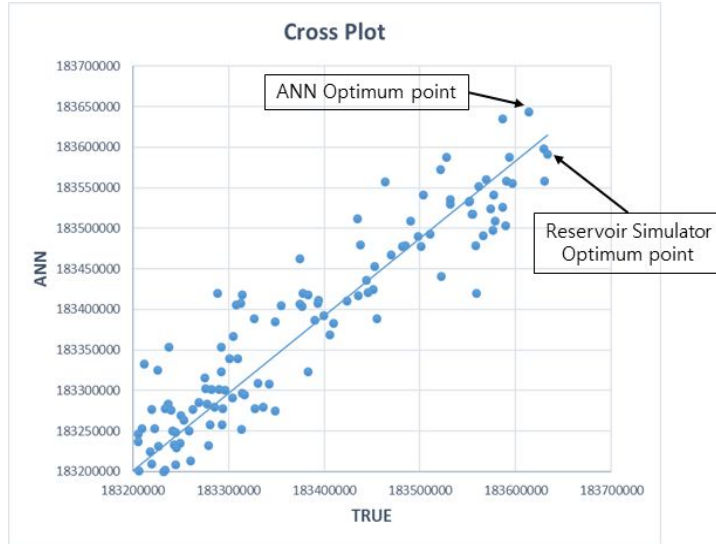


Figure 5. Magnified cross plot of output data using ANN method.

제2절 순차적 인공신경망 기법을 적용한 광역적 최적 추가 시추위치 선정 방법

인공신경망의 예측 성능은 학습 자료의 개수와 입출력자료의 선정에 민감하다. 또한 신속성과 정확성의 문제를 해결하고 최적의 시추위치를 결정하기 위해 인공신경망과 최적화 알고리즘을 사용한 다양한 연구가 수행되어 왔지만 정확한 최적의 시추위치는 얻지 못하는 한계가 있다. 기존의 인공신경망을 이용한 시추위치 최적화는 1개의 인공신경망만을 구축하여 결과를 예측한다. 인공신경망을 사용하여 도출한 최적해는 실제 광역해라기 보다는 인공신경망에서 계산된 결과 중 최댓값을 지정하는 것으로서 그 값이 광역해가 되는 것을 보장하지 못하는 단점이 있다.

본 논문에서는 불균질한 저류층에서의 추가 시추위치를 최적화하기 위해 인공신경망의 순차적인 구축을 통해 저류층 전산 시뮬레이션을 최소한으로 실행하여 광역해를 찾는 방법을 제안하였다. 즉, 인공신경망을 통해 얻은 결과의 상위 데이터를 이용해 반복적으로 인공신경망을 만들어 탐색 공간의 범위를 점차 좁혀감으로써 최소한의 저류층 시뮬레이터의 실행을 통해 광역해를 찾아낼 수 있다. 인공신경망을 반복적으로 구축할 때 기존 학습 자료를 누적하여 입력 자료로 사용하여 예측성능을 높일 수 있는 장점이 있다.

Figure 6은 광역적 최적 추가 시추위치를 선정하기 위해 인공신경망을 구축하는 과정을 나타낸 순서도이다. 먼저 인공신경망의 학습에 사용될 자료의 수(㉠), 입·출력 자료, 차기 인공신경망을 이용한 결과 예측에 사용될 상위 데이터의 선택 비율(㉡)을 설정한다. 첫 인공신경망의 구축을 위해 학습에 사용될 학습 자료는 초기에 설정해 놓은 수에 맞게 선정하여 입력 자료로 사용한다. 학습 자료로 선정된 시추 위치의 누적오일생산량을 저류층 전산 시뮬레이터로 계산하고 학습 자료의 출력 자료로 사용하여 인공신경망을 구축한다. 이후 구축된 인공신경망을 사용하여 대상 저류층의 시추 가능한 모든 위치의 누적생산량 예측값을 구한 후 내림차순으로 정렬한다. 초기에 설정해 놓은 선택 비율만큼 상위데이터를 선정하여 다음 단계의 탐색 공간으로 설정한다. 기존의 학습 자료에 중복되지 않은 새로운 학습 자료를 선정하고 시뮬레이션을 수행한다. 이 자료는 기존의 학습 자료와 합쳐 다음 단계의 인공신경망 구축에 사용된다. 두 번째로 구축한 인공신경망을 이용하여 탐색 공간에 대해 누적 오일 생산량의 예측값을 얻어 정렬한다. 이러한 과정을 탐색 공

간 내 시뮬레이션이 되어 있지 않은 자료의 수(㉔)가 ㉓의 수보다 적어질 때까지 반복한다. 시뮬레이션의 실행 횟수는 최종 학습 자료의 수와 최종 ㉔의 데이터 수의 합과 같으며 이 자료들의 저류층 시뮬레이션 결과 중 가장 높은 값을 갖는 위치가 광역해가 된다.

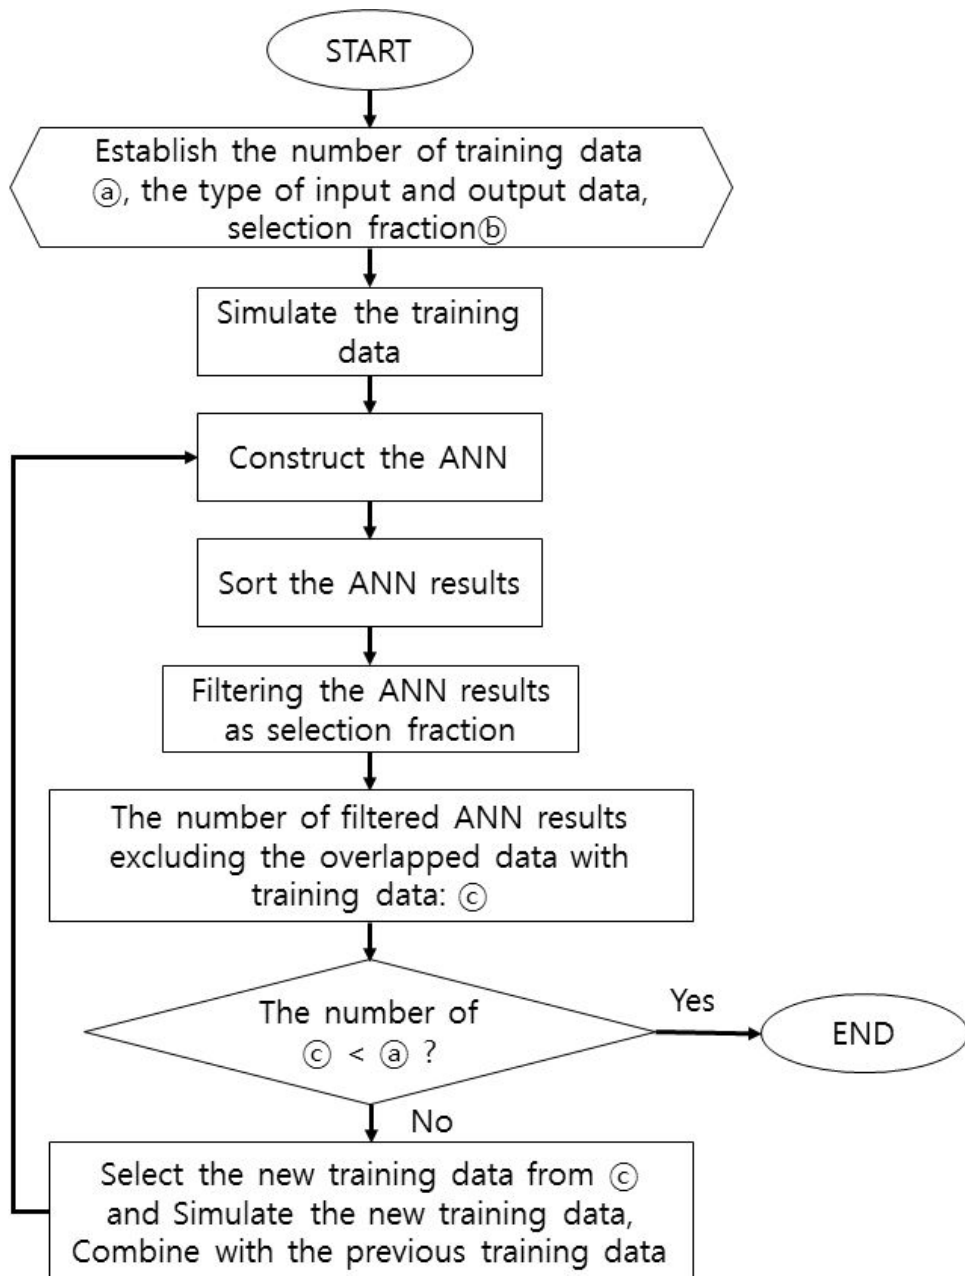


Figure 6. Flow chart of well placement optimization using sequential Artificial Neural Network.

제4장 연구 결과

제1절 Black-Oil Model

1. 저류층 시스템

광역적 최적 추가시추 위치를 선정하는 방법의 효용성을 검증하기 위해 두 개의 저류층에 적용하였다. Black-Oil Model의 물성(Table 5)은 Killough(1995)의 “Ninth SPE Comparative Solution Project”를 사용하였다. 부족한 자료는 Black-Oil의 일반적인 물성을 입력하였다. 저류층은 7,200 x 7,500 ft 규모로 i 방향으로 10° 기울어져 있다. 격자수는 24 x 25 x 15 으로 총 9,000개로 이루어져 있다. 저류층의 깊이는 9,000에서 10,552 ft 이며, 공극률은 층 별로 0.08에서 0.17 사이의 값을 가진다(Table 6). 유체투과율은 등방성이며 5에서 100 md 까지 불균질하게 분포한다(Figure 7). 초기 오일 포화율은 Figure 8과 같으며 해수면 9,950 ft 아래 대수층이 존재한다. 기존의 3개 생산정의 최대 오일 생산량은 4,000 bbl/day 로 고정하고, 공저압력은 1,000 psi로 일정하게 유지 하였다. 모든 생산정은 저류층 상부의 4개 층을 천공하였다.

Table 5. Black-Oil reservoir properties.

Reservoir properties	Data
Reservoir grid(XxYxZ)	24x25x15
$\Delta x = \Delta y$ (ft)	300
Total thickness (ft)	359
Permeability(isotropic) (md)	5-100
Depth of cell(1, 1, 1) (ft)	9,000
Initial reservoir temperature (°F)	100
Initial oil phase pressure(psia) at 9035 ft	3,600
Saturation pressure of oil (psia)	3,600
Oil-water contact(ft) subsea	9,950

Table 6. Layer porosity and thickness values(Killough, 1995).

Layer	Porosity	Thickness (ft)
1	0.087	20
2	0.097	15
3	0.111	26
4	0.16	15
5	0.13	16
6	0.17	14
7	0.17	8
8	0.08	8
9	0.14	18
10	0.13	12
11	0.12	19
12	0.105	18
13	0.12	20
14	0.116	50
15	0.157	100




Figure 7. Permeability distribution for Black-Oil Model.




Figure 8. Oil saturation for Black-Oil Model.

2. 인공신경망의 학습 자료 설정

본 연구에서 인공신경망의 학습은 MATLAB을 사용하여 실시하였으며, 신경망 학습을 위해 Scaled conjugate gradient 기반의 역전파 신경망을 사용하였다. Black-Oil 모델을 대상으로 인공신경망의 학습에 사용되는 입·출력 자료는 Table 7, Table 8과 같이 구성하였다. 인공신경망의 학습에 사용되는 추가 생산정은 생산정의 공간적 위치 정보, 저류층의 경계, 생산정간 상관관계를 고려할 수 있도록 분포 시켰다. 예측 정확성을 유지하는 최소 훈련정의 수를 선정하기 위해 훈련정이 5개, 10개, 20개, 40개 일 때의 인공신경망의 결과를 비교 분석하였다.

Figure 9는 유정 배치도이다. 기존 생산정의 위치의 x, y 좌표는 (10, 4), (16, 17), (6, 13)이다. 남색 격자는 기존 생산정, 주황색, 초록색, 노란색, 보라색 격자는 학습에 사용한 훈련 생산정, 회색 격자는 저류층 경계와 기존 생산정에 인접한 격자, 연한 파란색 격자는 대수층을 의미한다. 회색 격자는 생산량이 낮을 것으로 예측되거나 기존의 생산정과 매우 근접하여 추가 시추 가능한 위치에서 제외 시켰다. 추가 시추가 가능한 격자는 기존 생산정(3개), 기존 생산정에 인접한 격자(24개), 저류층 경계(82개), 대수층(150개)을 제외한 341개이다.

기존 3개 생산정은 2015년부터 5년간 생산하며 오일 생산량은 Figure 10과 같다. 3개의 기존 생산정이 생산을 시작하고 3년이 지나 생산량이 점차 감소할 때 1개의 추가 생산정의 위치를 선정하기 위해 추가 시추위치 최적화를 진행하였다. 즉, 기존의 생산정 3개와 훈련정 1개, 총 4개로 생산하는 학습 시나리오를 생성하여 학습에 사용하였다. 검증의 효율을 위해 한 개의 추가 시추정에 국한하여 수행하였으며 대상 저류층에 추가 시추가 가능한 모든 위치에 대해 저류층 전산 시뮬레이션을 수행한 결과 누적 오일 생산량이 최대가 되는 추가 시추위치는 (12, 4)이다.

Table 7. Input neuron for Black-Oil Model artificial neural network.

Input neuron	Data type	Number of neurons
Infill well x-y coordinates	Spacial information of well	2
Nearest distance from infill well to the reservoir boundary	Spacial information of well	1
Second nearest distance from infill well to the reservoir boundary	Spacial information of well	1
Distance from infill well to the aquifer	Spacial information of well	1
Inter-distance between existing wells and infill well	Well interaction data	3
Square of infill well x-y coordinates	Functional links	2
Reciprocal of infill well x-y coordinates	Functional links	2

Table 8. Output neuron for Black-Oil Model artificial neural network.

Output neuron	Data type	Number of neurons
Cumulative oil production rates	Time series data	1

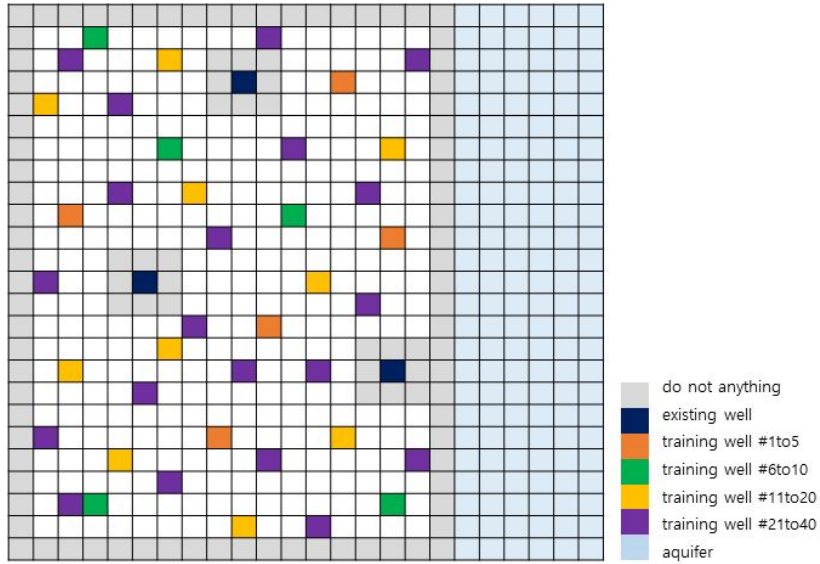


Figure 9. Well location map of Black-Oil Model.




Figure 10. Oil production rate of Black-Oil Model.

3. 광역적 최적 추가 시추위치 선정

인공신경망의 예측 결과는 학습 자료의 수에 민감하다. 따라서 광역적 최적 추가 시추위치 선정을 위한 인공신경망을 이용할 때 대상 저류층에 적절한 학습 자료의 수를 제안하기 위해 상위 데이터의 선택 비율을 30%로 설정하고 학습 자료의 수가 40개, 20개, 10개, 5개일 때 Black-Oil 모델의 최적 위치인 (12, 4)의 순위를 확인하였다. 학습 자료의 수가 적을수록 저류층 전산 시뮬레이션의 실행 횟수가 감소하나 저류층 전체를 대표할 수 있는 적절한 학습 자료의 선택이 중요하다. 따라서 학습 자료의 수를 40개에서 점차적으로 줄여가며 저류층 전산 시뮬레이션을 최소한으로 실행하여 광역해를 찾아낼 수 있는 자료의 수에 대한 분석을 실시하였다.

가. 학습 자료 40개

대상 저류층을 대표하는 학습 자료의 수를 40개로 설정하여 인공신경망을 구축하였을 때 광역해가 모두 30% 내에 속하는 것으로 나타났다(Table 9). 첫 번째 인공신경망 ANNt40-1은 40개의 시나리오를 학습 자료로 사용하여 구축하였으며 결정계수는 0.97로 나타났다. 그 결과 추가 시추 가능한 모든 위치 중에서 광역해는 상위 7%에 위치하였다. 두 번째 인공신경망 ANNt40-2의 구축을 위한 학습 자료는 ANNt40-1의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(91개) 중에서 새로운 학습 자료 40개를 선정하고 ANNt40-1에서 사용했던 40개의 학습 자료를 합하여 총 80개를 사용하였다. ANNt40-2를 사용한 결과 광역해는 상위 8%에 위치하였다.

세 번째 인공신경망은 ANNt40-2의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터를 제외한 자료(22개)가 새롭게 학습에 사용될 자료의 수(40개) 보다 적어 구축하지 않고 종료되었다. 위의 순차적인 인공신경망 구축 과정을 통해 저류층 시뮬레이션이 실행된 횟수는 학습 자료의 출력 자료로 사용된 80개의 위치와 마지막 인공신경망의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외

한 자료 22개를 합하여 총 102회이다. 1개 시추위치를 시뮬레이션 하는데 소요되는 시간은 약 25초로 102개 위치를 시뮬레이션 하는데 소요되는 시간은 총 42분 30초이다. 추가 시추 가능한 모든 위치를 시뮬레이션 했을 때 소요되는 시간이 2시간 22분이 소요되는 것에 비해 약 70% 감소시켜 광역해를 찾아낼 수 있다.

Table 9. The results of Black-Oil Model sequential artificial neural network constructed using 40 initial training data(Continued).

	ANNt40-1
Coefficient of determination	
Cross plot	
Global Point Ranking	0.07
Number of training data	40
©	91

Table 9. The results of Black-Oil Model sequential artificial neural network constructed using 40 initial training data.

	ANNt40-2
Coefficient of determination	
Cross plot	
Global Point Ranking	0.08
Number of training data	80
©	22

나. 학습 자료 20개

대상 저류층을 대표하는 학습 자료의 수를 20개로 설정하여 인공지능망을 구축하였을 때 광역해가 모두 30% 내에 속하는 것으로 나타났다(Table 10). 첫 번째 인공지능망 ANNt20-1은 20개의 시나리오를 학습 자료로 사용하여 결정계수 0.95의 값을 갖는 인공지능망을 구축하였다. 그 결과 추가 시추 가능한 모든 위치 중에서 광역해는 상위 6%에 위치하였다. 두 번째 인공지능망 ANNt20-2의 구축을 위한 학습 자료는 ANNt20-1의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(97개) 중에서 새로운 학습 자료 20개를 선정하고 ANNt20-1에서 사용했던 20개의 학습 자료를 합하여 총 40개를 사용하였다. ANNt20-2를 사용한 결과 광역해는 상위 6%에 위치하였다.

세 번째 인공지능망 ANNt20-3의 구축을 위한 학습 자료는 ANNt20-2의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(24개) 중에서 새로운 학습 자료 20개를 선정하고 ANNt20-2에서 사용했던 40개의 학습 자료를 합하여 총 60개를 사용하였다. ANNt20-3을 사용한 결과 광역해는 상위 5%에 위치하였다.

네 번째 인공지능망은 ANNt20-3의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(1개)가 새롭게 학습에 사용될 자료의 수(20개) 보다 적어 구축하지 않고 종료되었다. 위의 순차적인 인공지능망 구축 과정을 통해 저류층 시뮬레이션이 실행된 횟수는 학습 자료의 출력 자료로 사용된 60개의 위치와 마지막 인공지능망의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료 1개를 합하여 총 61회이다. 1개 시추위치를 시뮬레이션 하는데 소요되는 시간은 약 25초로 61개 위치를 시뮬레이션 하는데 소요되는 시간은 총 25분 25초이다. 추가 시추 가능한 모든 위치를 시뮬레이션 했을 때 소요되는 시간에 비해 약 82% 감소시켜 광역해를 찾아낼 수 있다.

Table 10. The results of Black-Oil Model sequential artificial neural network constructed using 20 initial training data(Continued).

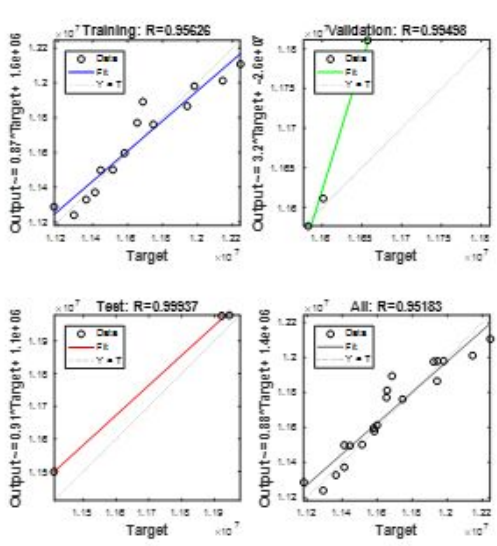
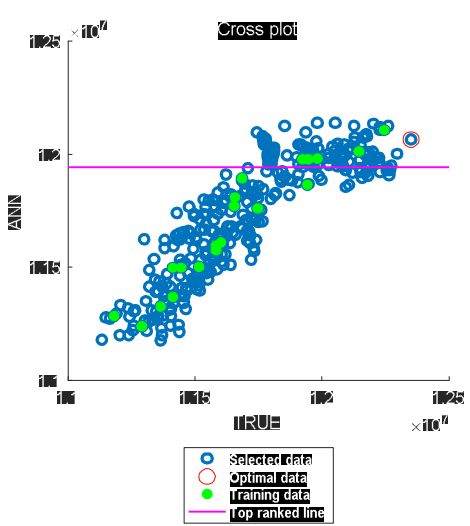
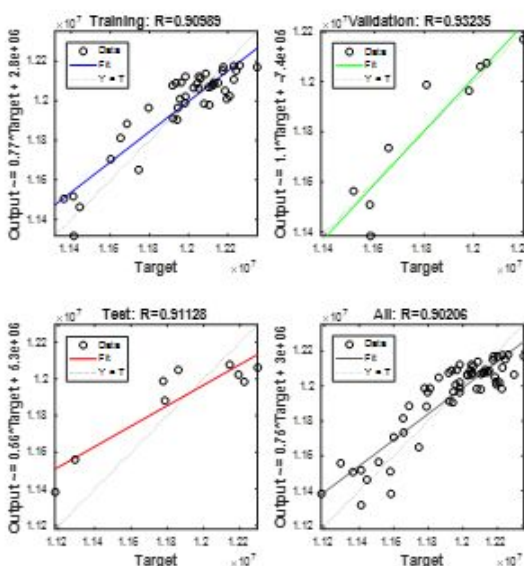
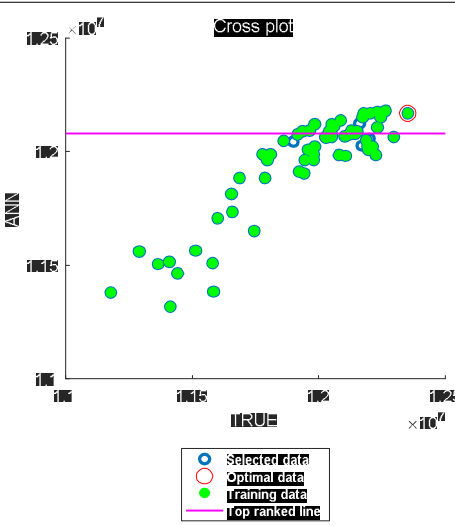
	ANNt20-1
Coefficient of determination	
Cross plot	
Global Point Ranking	0.06
Number of training data	20
©	97

Table 10. The results of Black-Oil Model sequential artificial neural network constructed using 20 initial training data(Continued).

	ANNt20-2
Coefficient of determination	
Cross plot	
Global Point Ranking	0.06
Number of training data	40
©	24

Table 10. The results of Black-Oil Model sequential artificial neural network constructed using 20 initial training data.

	ANNt20-3
Coefficient of determination	
Cross plot	
Global Point Ranking	0.05
Number of training data	60
©	1

다. 학습 자료 10개

대상 저류층을 대표하는 학습 자료의 수를 10개로 설정하여 인공신경망을 구축하였을 때 광역해가 모두 30% 내에 속하는 것으로 나타났다(Table 11). 첫 번째 인공신경망 ANNt10-1은 10개의 시나리오를 학습 자료로 사용하여 결정계수 0.94의 값을 갖는 인공신경망을 구축한 결과 추가 시추 가능한 모든 위치 중에서 광역해는 상위 3%에 위치하였다. 두 번째 인공신경망 ANNt10-2의 구축을 위한 학습 자료는 ANNt10-1의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(99개) 중에서 새로운 학습 자료 10개를 선정하고 ANNt10-1에서 사용했던 10개의 학습 자료를 합하여 총 20개로 학습 시켜 구축하였다. ANNt10-2를 사용한 결과 광역해는 상위 11%에 위치하였다.

세 번째 인공신경망 ANNt10-3의 구축을 위한 학습 자료는 ANNt10-2의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(29개) 중에서 새로운 학습 자료 10개를 선정하고 ANNt10-2에서 사용했던 20개의 학습 자료를 합하여 총 30개로 학습 시켜 구축하였다. ANNt10-3을 사용한 결과 광역해는 상위 8%에 위치하였다.

네 번째 인공신경망은 ANNt10-3의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(7개)가 새롭게 학습에 사용될 자료의 수(10개) 보다 적어 구축하지 않고 종료되었다. 위의 순차적인 인공신경망 구축 과정을 통해 저류층 시뮬레이션이 실행된 횟수는 학습 자료의 출력 자료로 사용된 30개의 위치와 마지막 인공신경망의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료 7개를 합하여 총 37회이다. 1개 시추위치를 시뮬레이션 하는데 소요되는 시간은 약 25초로 37개 위치를 시뮬레이션 하는데 소요되는 시간은 총 15분 25초이다. 추가 시추 가능한 모든 위치를 시뮬레이션 했을 때 소요되는 시간에 비해 약 89% 감소시켜 광역해를 찾아낼 수 있다.

Table 11. The results of Black-Oil Model sequential artificial neural network constructed using 10 initial training data(Continued).

	ANNt10-1
Coefficient of determination	
Cross plot	
Global Point Ranking	0.03
Number of training data	10
©	99

Table 11. The results of Black-Oil Model sequential artificial neural network constructed using 10 initial training data(Continued).

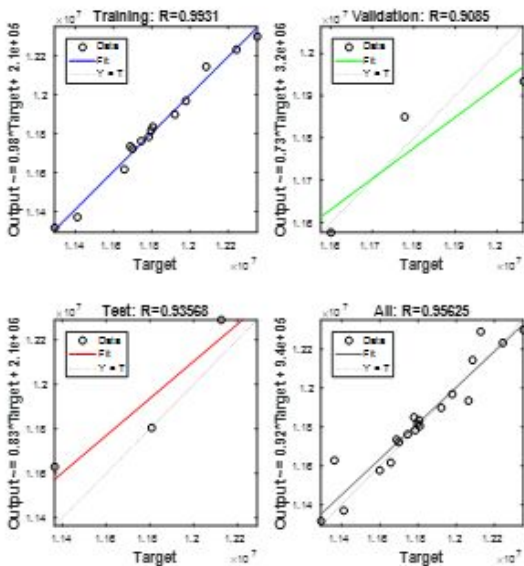
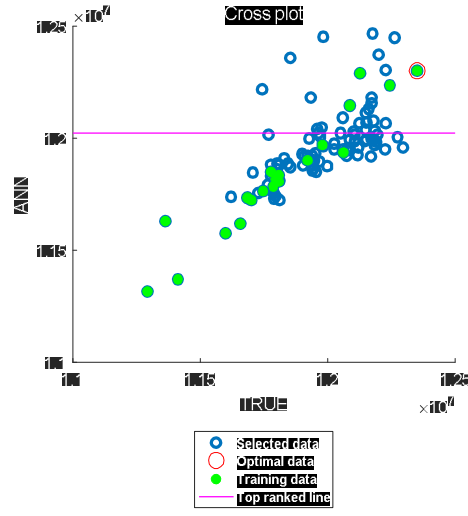
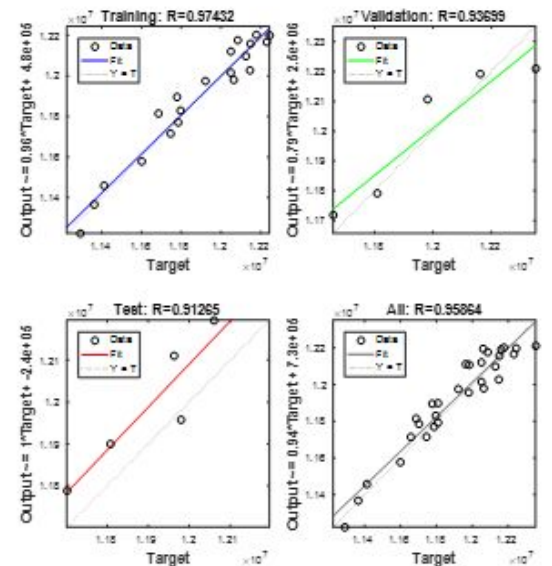
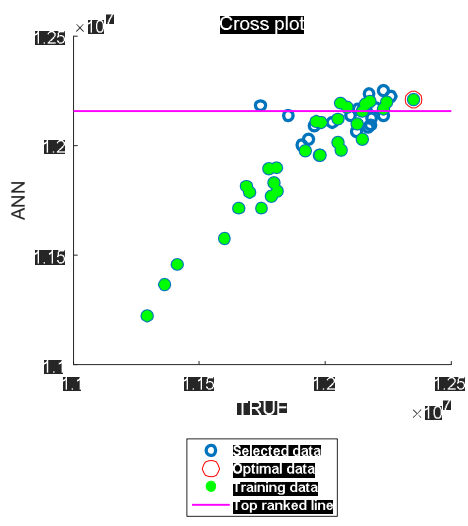
<p>Coefficient of determination</p>	<p style="text-align: center;">ANNt10-2</p> 
<p>Cross plot</p>	
<p>Global Point Ranking</p>	<p style="text-align: center;">0.11</p>
<p>Number of training data</p>	<p style="text-align: center;">20</p>
<p style="text-align: center;">©</p>	<p style="text-align: center;">29</p>

Table 11. The results of Black-Oil Model sequential artificial neural network constructed using 10 initial training data.

ANNt10-3	
Coefficient of determination	
Cross plot	
Global Point Ranking	0.08
Number of training data	30
©	7

라. 학습 자료 5개

대상 저류층을 대표하는 학습 자료의 수를 5개로 설정하여 인공신경망을 구축하였을 때 광역해가 모두 30% 내에 속하는 것으로 나타났다(Table 12). 첫 번째 인공신경망 ANNt5-1은 5개의 시나리오를 학습 자료로 사용하여 결정계수 0.93의 값을 갖는 인공신경망을 구축한 결과 추가 시추 가능한 모든 위치 중에서 광역해는 상위 12%에 위치하였다. 두 번째 인공신경망 ANNt5-2의 구축을 위한 학습 자료는 ANNt5-1의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(101개) 중에서 새로운 학습 자료 5개를 선정하고 ANNt5-1에서 사용했던 5개의 학습 자료를 합하여 총 10개로 학습 시켜 구축하였다. ANNt5-2를 사용한 결과 광역해는 상위 0.9%에 위치하였다.

세 번째 인공신경망 ANNt5-3의 구축을 위한 학습 자료는 ANNt5-2의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(29개) 중에서 새로운 학습 자료 5개를 선정하고 ANNt5-2에서 사용했던 10개의 학습 자료를 합하여 총 15개로 학습 시켜 구축하였다. ANNt5-3을 사용한 결과 광역해는 상위 12%에 위치하였다. 네 번째 인공신경망 ANNt5-4의 구축을 위한 학습 자료는 ANNt5-3의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(9개) 중에서 새로운 학습 자료 5개를 선정하고 ANNt5-3에서 사용했던 15개의 학습 자료를 합하여 총 20개로 학습 시켜 구축하였다. ANNt5-4를 사용한 결과 광역해는 상위 20%에 위치하였다.

다섯 번째 인공신경망은 ANNt5-4의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(2개)가 새롭게 학습에 사용될 자료의 수(5개)보다 적어 구축하지 않고 종료되었다. 위의 순차적인 인공신경망 구축 과정을 통해 저류층 시뮬레이션이 실행된 횟수는 학습 자료의 출력 자료로 사용된 20개의 위치와 마지막 인공신경망의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료 2개를 합하여 총 22회이다. 22개 위치를 시뮬레이션 하는데 소요되는 시간은 총 9분 10초이다. 추가 시추 가능한 모든 위치를 시뮬레이션 했을 때 소요되는 시간에 비해 약 94% 감소시켜 광역해를 찾아낼 수 있다.

Table 12. The results of Black-Oil Model sequential artificial neural network constructed using 5 initial training data(Continued).

	ANNt5-1
Coefficient of determination	
Cross plot	
Global Point Ranking	0.12
Number of training data	5
©	101

Table 12. The results of Black-Oil Model sequential artificial neural network constructed using 5 initial training data(Continued).

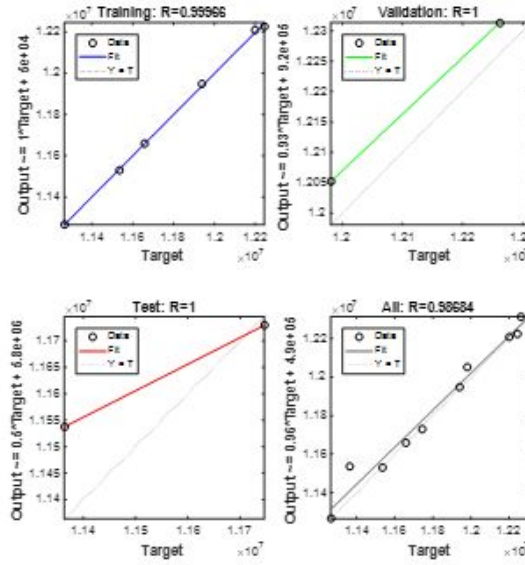
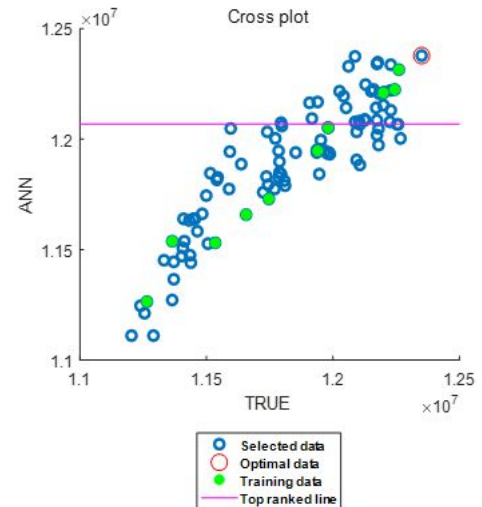
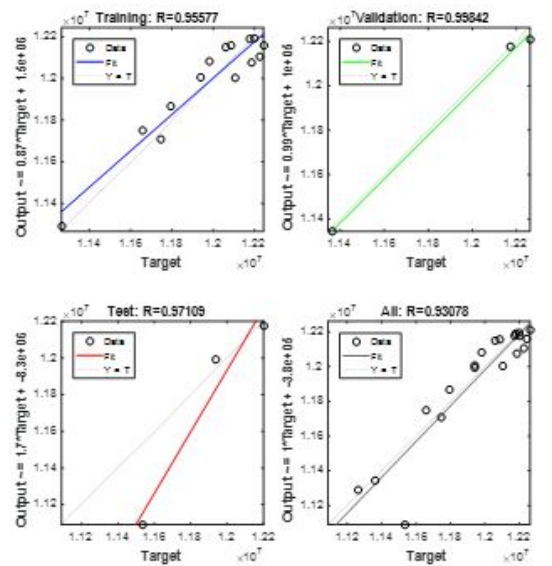
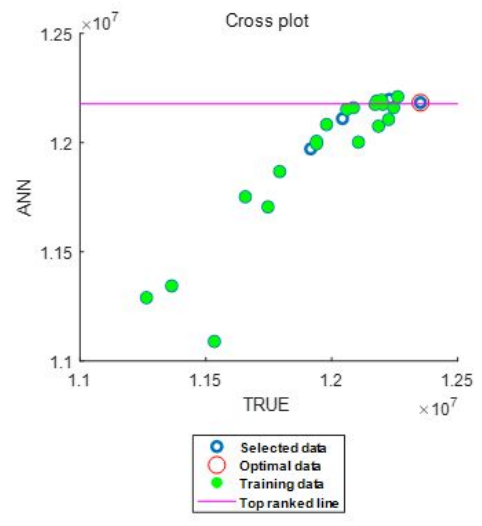
	ANNt5-2
Coefficient of determination	
Cross plot	
Global Point Ranking	0.009
Number of training data	10
©	29

Table 12. The results of Black-Oil Model sequential artificial neural network constructed using 5 initial training data(Continued).

ANNt5-3	
Coefficient of determination	
Cross plot	
Global Point Ranking	0.12
Number of training data	15
©	9

Table 12. The results of Black-Oil Model sequential artificial neural network constructed using 5 initial training data.

	ANNt5-4
Coefficient of determination	
Cross plot	
Global Point Ranking	0.20
Number of training data	20
©	2

제2절 석탄층 메탄가스(Coalbed Methane) 저류층

1. 저류층 시스템

석탄층 메탄가스(Coalbed Methane) 저류층은 아주 넓은 표면에 많은 양의 메탄을 함유하고 있으며, 같은 크기 저류층보다 6~7배 많은 가스를 저장할 수 있다 (USGS, 1997). 석탄층에 발달된 두개의 직교하는 탄리 중 주탄리(Face cleat)는 연속적으로 측면으로 넓게 분포한 균열이며, 부탄리(Butt cleat)는 주탄리와 주탄리를 서로 이어주는 탄리이다. 탄리는 석탄의 방향성 투과도를 조절하며, 석탄층 가스가 생산되는 주요 유동통로의 역할을 한다. 석탄층 메탄가스는 생산 초기 생산정에서 균열에 있는 물이 먼저 생산되고 저류층의 압력이 감소하여 유효응력이 증가함에 따라 균열이 압축된다. 매질 미세공극 내에 흡착되어 있는 메탄가스는 압력 감소로 탈착이 발생하면서 생산이 된다. 대상 저류층의 규모는 1,320 x 1,320 m 이다. 격자수는 40 x 40 x 3 으로 총 4,800개로 이루어져 있다. 물성 값은 다음의 식과 같이 설정하였다. 층리의 유체투과도는 저류층 깊이에 대한 관계식을 사용하여 분포시켰다(Figure 11).

$$\text{cleat } k_{avg} = e^{(6.9792 + 0.007188173 * \text{depth})}$$

$$\text{cleat } k_{face} = \text{cleat } k_{avg} * 2$$

$$\text{cleat } k_{butt} = \text{cleat } k_{face} / 4$$

$$\text{matrix permeability} = 0.001 \text{md}$$

$$\phi_{fracture} = 0.0124 * \left(\frac{\text{cleat } k_{avg}}{5.87} \right)^{1/3}$$

$$\text{matrix porosity} = 0.08$$

시뮬레이션 조건은 Table 13과 같다. 기존의 3개 생산정의 최대 물 생산량은 5,000 m³/day 로 고정하고, 공저압력은 250 kPa 로 일정하게 유지 하였다. 모든 생산정은 저류층 전체 3개 층을 천공하였다.




Figure 11. Permeability distribution for Coalbed Methane Model.

Table 13. Simulation condition for Coalbed Methane Model.

Cleat spacing	1 in
Sorption time (CH ₄)	0.1~1 day
Sorption time (CO ₂)	0.1~1 day
Reference pressure	5,911 kPa @300m
Molar ratio of CH ₄ and CO ₂	8(CH ₄) : 2(CO ₂)
Langmuir volume; V _L (CH ₄)	358 scf/ton
Langmuir volume; V _L (CO ₂)	929 scf/ton
Langmuir pressure; P _L (CH ₄)	549 psia
Langmuir pressure; P _L (CO ₂)	339 psia
Max. water production rate	5,000 m ³ /day
Permeability Model	PM Model
Production period	15 years

2. 인공신경망의 학습 자료 설정

석탄층 메탄가스 저류층을 대상으로 인공신경망의 학습에 사용되는 입·출력 자료는 Table 14, Table 15와 같이 구성하였다. 인공신경망의 학습에 사용되는 추가 생산정은 생산정의 공간적 위치 정보, 저류층의 경계, 생산정간 상관관계를 고려할 수 있도록 분포 시켰다. 예측 정확성을 유지하는 최소 훈련정의 수를 선정하기 위해 훈련정이 5개, 10개, 20개, 40개 일 때의 인공신경망의 결과를 비교 분석하였다.

Figure 12는 유정 배치도이다. 기존 생산정의 위치의 x, y 좌표는 (32, 32), (16, 18), (45, 35)이다. 남색 격자는 기존 생산정, 주황색, 초록색, 노란색, 보라색 격자는 학습에 사용한 훈련 생산정, 회색 격자는 기존 생산정에 인접한 격자를 의미한다. 회색 격자는 기존의 생산정과 매우 근접하여 추가 시추 가능한 위치에서 제외 시켰다. 추가 시추가 가능한 격자는 기존 생산정(3개), 기존 생산정에서 인접한 격자(24개)를 제외한 1,573개이다.

기존 3개 생산정은 2010년부터 15년간 생산하며 가스 생산량은 Figure 13과 같다. 기존 생산정이 생산을 시작하고 2년이 지나 생산량이 점차 감소할 때 1개의 추가 생산정의 위치를 선정하기 위해 추가 시추위치 최적화를 진행하였다. 즉, 기존의 생산정 3개와 훈련정 1개, 총 4개로 생산하는 학습 시나리오를 생성하여 학습에 사용하였다. 검증의 효율을 위해 한 개의 추가 시추정에 국한하여 수행하였으며 대상 저류층에 추가 시추가 가능한 모든 위치에 대해 저류층 전산 시뮬레이션을 수행한 결과 누적 가스 생산량이 최대가 되는 추가 시추위치는 (26, 44)이다.

Table 14. Input neuron for artificial neural network of Coalbed Methane Model.

Input neuron	Data type	Number of neurons
Infill well x-y coordinates	Spacial information of well	2
Nearest distance from infill well to the reservoir boundary	Spacial information of well	1
Second nearest distance from infill well to the reservoir boundary	Spacial information of well	1
Inter-distance between existing wells and infill well	Well interaction data	3
Square of infill well x-y coordinates	Functional links	2
Reciprocal of infill well x-y coordinates	Functional links	2

Table 15. Output neuron for artificial neural network of Coalbed Methane Model.

Output neuron	Data type	Number of neurons
Cumulative oil production rates	Time series data	1

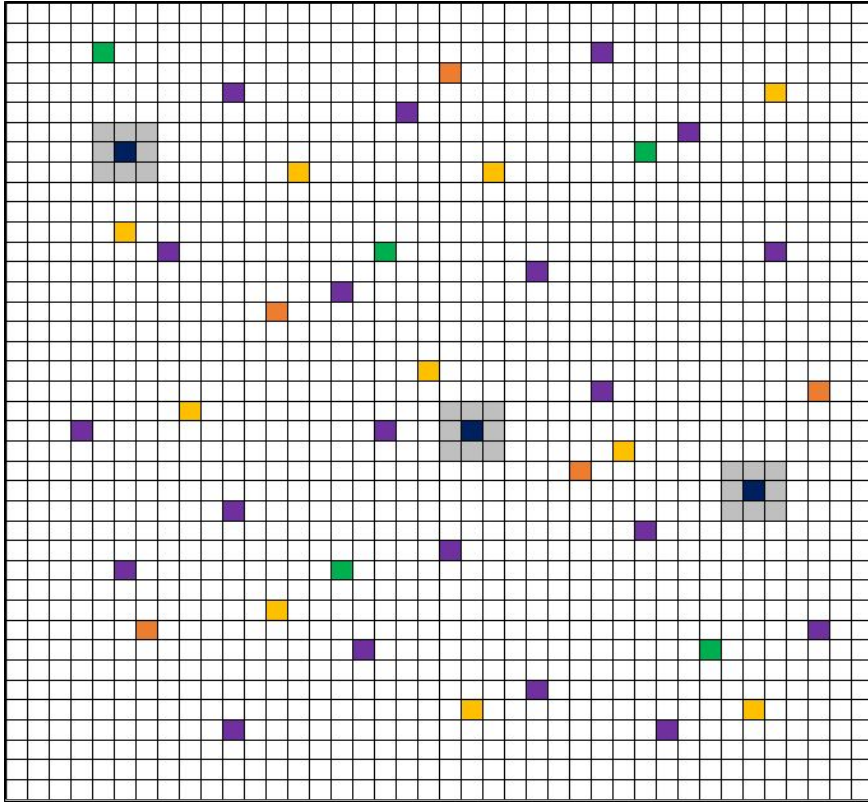


Figure 12. Well location map of Coalbed Methane Model.

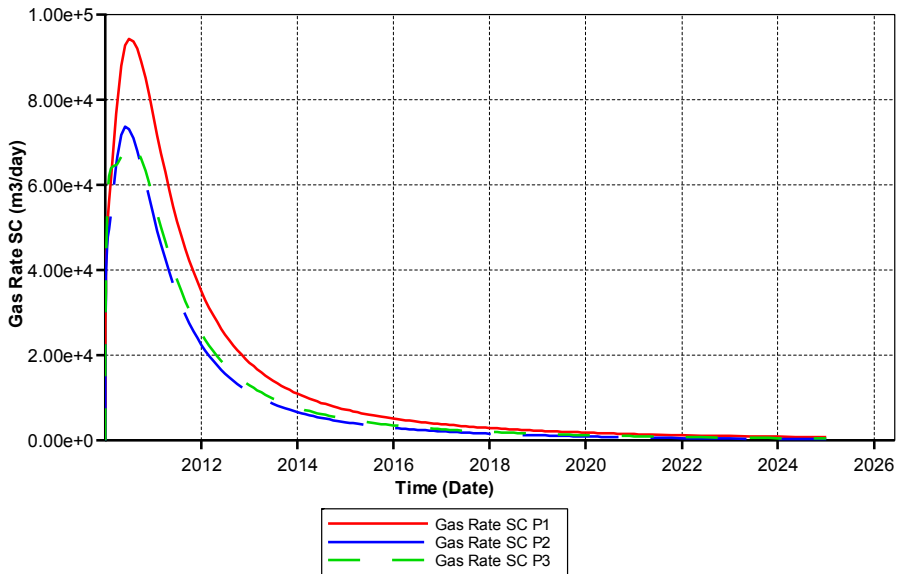


Figure 13. Oil production rate of Coalbed Methane Model.

3. 광역적 최적 추가 시추위치 선정

광역적 최적 추가 시추위치 선정을 위한 인공신경망을 이용할 때 대상 저류층에 적절한 학습 자료의 수를 제안하기 위해 상위 데이터의 선택 비율을 30%로 설정하고 학습 자료의 수가 40개, 20개, 10개, 5개일 때 석탄층 메탄가스 저류층 모델의 최적 위치인 (26, 44)의 순위를 확인하였다. 학습 자료의 수를 40개에서 점차적으로 줄여가며 저류층 전산 시뮬레이터를 최소한으로 실행하여 광역해를 찾아낼 수 있는 자료의 수에 대한 분석을 실시하였다.

가. 학습 자료 40개

대상 저류층을 대표하는 학습 자료의 수를 40개로 설정하여 인공신경망을 구축하였을 때 광역해가 모두 30% 내에 속하는 것으로 나타났다(Table 16). 첫 번째 인공신경망 ANNt40-1은 40개의 시나리오를 학습 자료로 사용하여 결정계수 0.98의 값을 갖는 인공신경망을 구축한 결과 추가 시추 가능한 모든 위치 중에서 광역해는 상위 2%에 위치하였다. 두 번째 인공신경망 ANNt40-2의 구축을 위한 학습 자료는 ANNt40-1의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료(458개) 중에서 새로운 학습 자료 40개를 선정하고 ANNt40-1에서 사용했던 40개의 학습 자료를 합하여 총 80개를 사용하였다. ANNt40-2를 사용한 결과 광역해는 상위 7%에 위치하였다.

세 번째 인공신경망 ANNt40-3의 구축을 위한 학습 자료는 ANNt40-2의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(129개) 중에서 새로운 학습 자료 40개를 선정하고 ANNt40-2에서 사용했던 80개의 학습 자료를 합하여 총 120개를 사용하였다. ANNt40-3을 사용한 결과 광역해는 상위 2%에 위치하였다.

네 번째 인공신경망은 ANNt40-3의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(37개)가 새롭게 학습에 사용될 자료의 수(40개) 보다 적어 구축하지 않고 종료되었다. 위의 순차적인 인공신경망 구축 과정을

통해 저류층 시뮬레이션이 실행된 횟수는 학습 자료의 출력 자료로 사용된 120개의 위치와 마지막 인공신경망의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료 37개를 합하여 총 157회이다. 1개 시추위치를 시뮬레이션 하는데 소요되는 시간은 약 2분 30초로 157개 위치를 시뮬레이션 하는데 소요되는 시간은 총 6시간 32분 30초이다. 추가 시추 가능한 모든 위치를 시뮬레이션 했을 때 소요되는 시간이 65시간 32분 30초가 소요되는 것에 비해 약 90% 감소시켜 광역해를 찾아낼 수 있다.

Table 16. The results of Coalbed Methane Model sequential artificial neural network constructed using 40 initial training data(Continued).

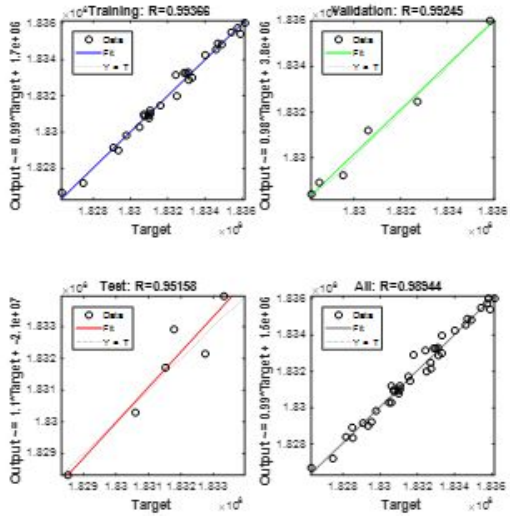
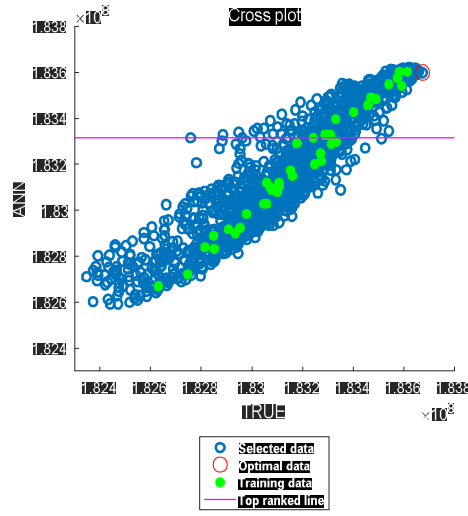
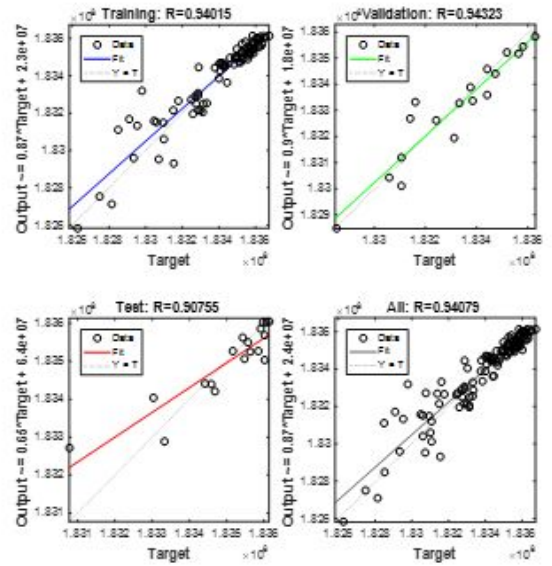
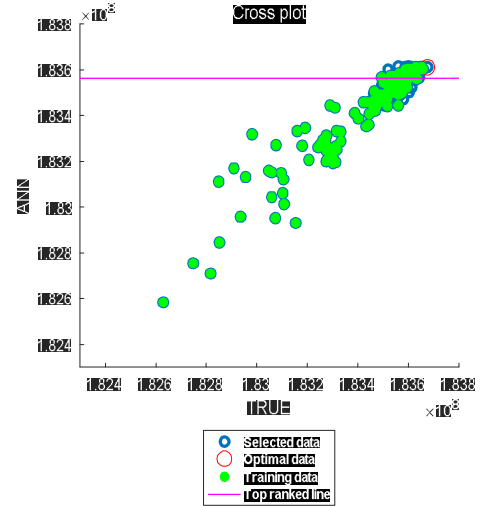
	ANNt40-1
Coefficient of determination	
Cross plot	
Global Point Ranking	0.02
Number of training data	40
©	458

Table 16. The results of Coalbed Methane Model sequential artificial neural network constructed using 40 initial training data(Continued).

<p>Coefficient of determination</p>	<p style="text-align: center;">ANNt40-2</p>
<p>Cross plot</p>	
<p>Global Point Ranking</p>	<p>0.07</p>
<p>Number of training data</p>	<p>80</p>
<p>©</p>	<p>129</p>

Table 16. The results of Coalbed Methane Model sequential artificial neural network constructed using 40 initial training data.

	ANNt40-3
Coefficient of determination	
Cross plot	
Global Point Ranking	0.02
Number of training data	120
©	37

나. 학습 자료 20개

대상 저류층을 대표하는 학습 자료의 수를 20개로 설정하여 인공신경망을 구축하였을 때 광역해가 모두 30% 내에 속하는 것으로 나타났다(Table 17). 첫 번째 인공신경망 ANNt20-1은 20개의 시나리오를 학습 자료로 사용하여 결정계수 0.97의 값을 갖는 인공신경망을 구축한 결과 추가 시추 가능한 모든 위치 중에서 광역해는 상위 4%에 위치하였다. 두 번째 인공신경망 ANNt20-2의 구축을 위한 학습 자료는 ANNt20-1의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(465개) 중에서 새로운 학습 자료 20개를 선정하고 ANNt20-1에서 사용했던 20개의 학습 자료를 합하여 총 40개로 학습 시켜 구축하였다. ANNt20-2를 사용한 결과 광역해는 상위 0.2%에 위치하였다.

세 번째 인공신경망 ANNt20-3의 구축을 위한 학습 자료는 ANNt20-2의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(138개) 중에서 새로운 학습 자료 20개를 선정하고 ANNt20-2에서 사용했던 40개의 학습 자료를 합하여 총 60개로 학습 시켜 구축하였다. ANNt20-3을 사용한 결과 광역해는 상위 21%에 위치하였다. 네 번째 인공신경망 ANNt20-4의 구축을 위한 학습 자료는 ANNt20-3의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(44개) 중에서 새로운 학습 자료 20개를 선정하고 ANNt20-3에서 사용했던 60개의 학습 자료를 합하여 총 80개로 학습 시켜 구축하였다. ANNt20-4를 사용한 결과 광역해는 상위 12%에 위치하였다.

다섯 번째 인공신경망은 ANNt20-4의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(11개)가 새롭게 학습에 사용될 자료의 수(20개) 보다 적어 구축하지 않고 종료되었다. 위의 순차적인 인공신경망 구축 과정을 통해 저류층 시뮬레이션이 실행된 횟수는 학습 자료의 출력 자료로 사용된 80개의 위치와 마지막 인공신경망의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료 11개를 합하여 총 91회이다. 1개 시추위치를 시뮬레이션 하는데 소요되는 시간은 약 2분 30초로 91개 위치를 시뮬레이션 하는데 소요되는 시간은 총 3시간 47분 30초이다. 추가 시추 가능한 모든 위치를 시뮬레이션 했을 때 소요되는 시간에 비해 약 94% 감소시켜 광역해를 찾아낼 수 있다.

Table 17. The results of Coalbed Methane Model sequential artificial neural network constructed using 20 initial training data(Continued).

	ANNt20-1
Coefficient of determination	
Cross plot	
Global Point Ranking	0.04
Number of training data	20
©	465

Table 17. The results of Coalbed Methane Model sequential artificial neural network constructed using 20 initial training data(Continued).

	ANNt20-2
Coefficient of determination	
Cross plot	
Global Point Ranking	0.002
Number of training data	40
©	138

Table 17. The results of Coalbed Methane Model sequential artificial neural network constructed using 20 initial training data(Continued).

	ANNt20-3
Coefficient of determination	
Cross plot	
Global Point Ranking	0.21
Number of training data	60
©	44

Table 17. The results of Coalbed Methane Model sequential artificial neural network constructed using 20 initial training data.

	ANNt20-4
Coefficient of determination	
Cross plot	
Global Point Ranking	0.12
Number of training data	80
©	11

다. 학습 자료 10개

대상 저류층을 대표하는 학습 자료의 수를 10개로 설정하여 인공신경망을 구축하였을 때 광역해가 모두 30% 내에 속하는 것으로 나타났다(Table 18). 첫 번째 인공신경망 ANNt10-1은 10개의 시나리오를 학습 자료로 사용하여 결정계수 0.92의 값을 갖는 인공신경망을 구축한 결과 추가 시추 가능한 모든 위치 중에서 광역해는 상위 5%에 위치하였다. 두 번째 인공신경망 ANNt10-2의 구축을 위한 학습 자료는 ANNt10-1의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료(469개) 중에서 새로운 학습 자료 10개를 선정하고 ANNt10-1에서 사용했던 10개의 학습 자료를 합하여 총 20개를 사용하였다. ANNt10-2를 사용한 결과 광역해는 상위 17%에 위치하였다.

세 번째 인공신경망 ANNt10-3의 구축을 위한 학습 자료는 ANNt10-2의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터는 제외한 자료(142개) 중에서 새로운 학습 자료 10개를 선정하고 ANNt10-2에서 사용했던 20개의 학습 자료를 합하여 총 30개를 사용하였다. ANNt10-3을 사용한 결과 광역해는 상위 2%에 위치하였다. 네 번째 인공신경망 ANNt10-4의 구축을 위한 학습 자료는 ANNt10-3의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료(48개) 중에서 새로운 학습 자료 10개를 선정하고 ANNt10-3에서 사용했던 30개의 학습 자료를 합하여 총 40개를 사용하였다. ANNt10-4를 사용한 결과 광역해는 상위 3%에 위치하였다. 다섯 번째 인공신경망 ANNt10-5의 구축을 위한 학습 자료는 ANNt10-4의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료(17개) 중에서 새로운 학습 자료 10개를 선정하고 ANNt10-4에서 사용했던 40개의 학습 자료를 합하여 총 50개를 사용하였다. ANNt10-5를 사용한 결과 광역해는 상위 11%에 위치하였다.

여섯 번째 인공신경망은 ANNt10-5의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(3개)가 학습에 사용되는 자료의 수(10개)보다 적어 구축하지 않고 종료되었다. 위의 순차적인 인공신경망 구축 과정을 통해 저류층 시뮬레이션이 실행된 횟수는 학습 자료의 출력 자료로 사용된 50개의 위치와 마지막 인공신경망의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료 3개를 합하여 총 53회이다. 1개 시추위치를 시뮬레이션 하는데 소요되는

시간은 약 2분 30초로 53개 위치를 시뮬레이션 하는데 소요되는 시간은 총 2시간 23분 30초이다. 추가 시추 가능한 모든 위치를 시뮬레이션 했을 때 소요되는 시간에 비해 약 96% 감소시켜 광역해를 찾아낼 수 있다.

Table 18. The results of Coalbed Methane Model sequential artificial neural network constructed using 10 initial training data(Continued).

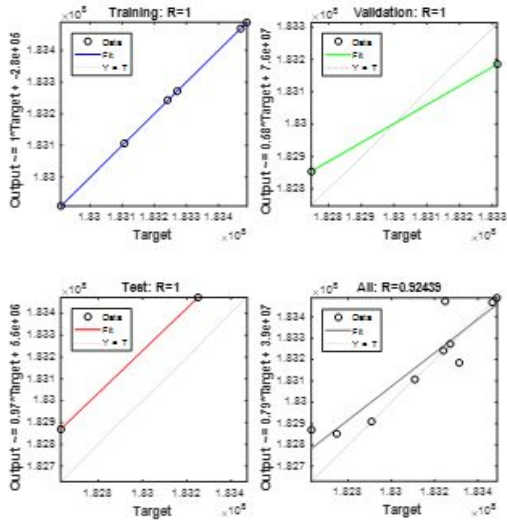
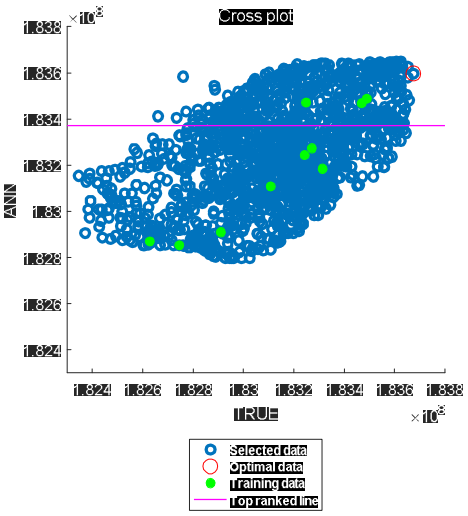
	ANNt10-1
Coefficient of determination	
Cross plot	
Global Point Ranking	0.05
Number of training data	10
©	469

Table 18. The results of Coalbed Methane Model sequential artificial neural network constructed using 10 initial training data(Continued).

	ANNt10-2
Coefficient of determination	<p>ANNt10-2</p> <p>Training: R=0.57816 Validation: R=0.57685 Test: R=0.79618 All: R=0.55067</p>
Cross plot	<p>Cross plot</p> <p>ANN</p> <p>IRU</p> <p>Legend: ○ selected data ○ optimal data ● training data — top ranked line</p>
Global Point Ranking	0.17
Number of training data	20
©	142

Table 18. The results of Coalbed Methane Model sequential artificial neural network constructed using 10 initial training data(Continued).

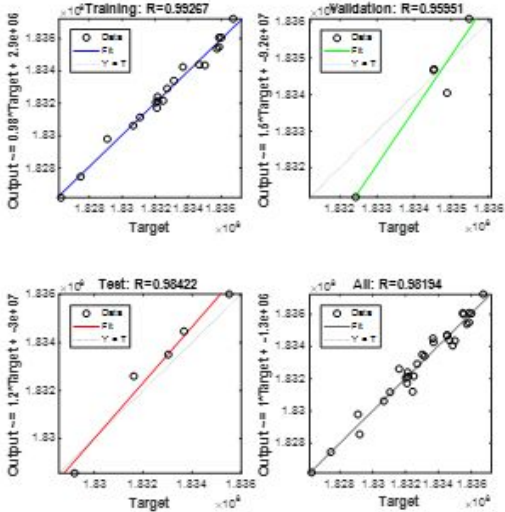
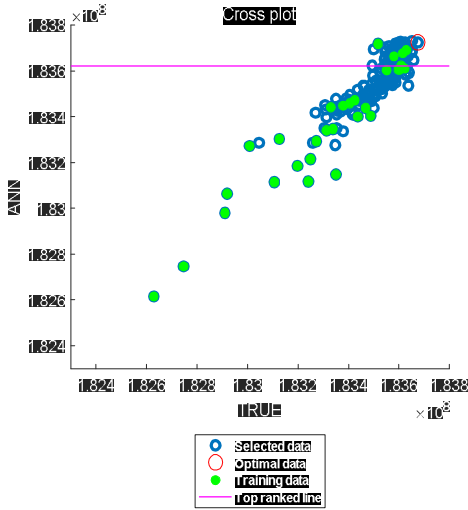
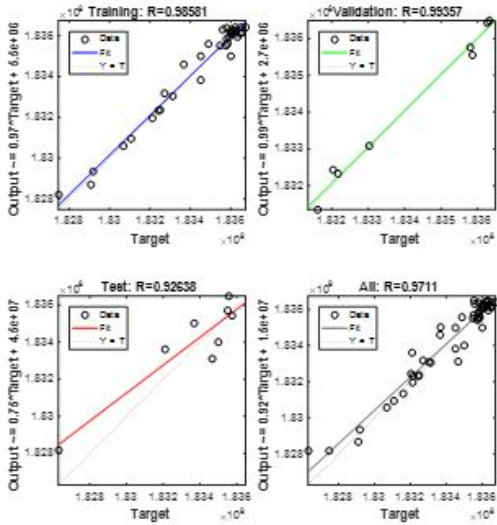
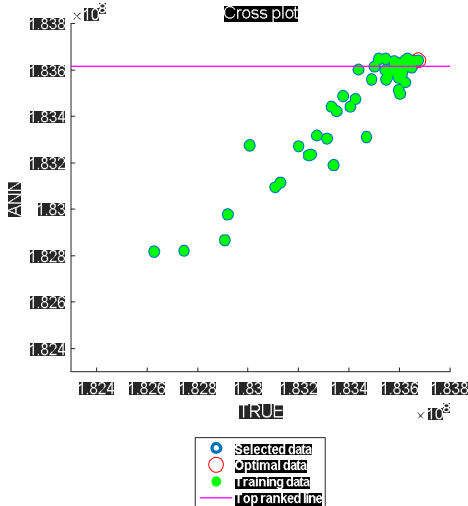
	ANNt10-3
Coefficient of determination	
Cross plot	
Global Point Ranking	0.02
Number of training data	30
©	48

Table 18. The results of Coalbed Methane Model sequential artificial neural network constructed using 10 initial training data(Continued).

	ANNt10-4
Coefficient of determination	
Cross plot	
Global Point Ranking	0.03
Number of training data	40
©	17

Table 18. The results of Coalbed Methane Model sequential artificial neural network constructed using 10 initial training data.

	ANNt10-5
Coefficient of determination	
Cross plot	
Global Point Ranking	0.11
Number of training data	50
©	3

라. 학습 자료 5개

대상 저류층을 대표하는 학습 자료의 수를 5개로 설정하여 인공신경망을 구축하였을 때 광역해가 모두 30% 내에 속하는 것으로 나타났다(Table 19). 첫 번째 인공신경망 ANNt5-1은 5개의 시나리오를 학습 자료로 사용하여 결정계수 0.92의 값을 갖는 인공신경망을 구축한 결과 추가 시추 가능한 모든 위치 중에서 광역해는 상위 19%에 위치하였다. 두 번째 인공신경망 ANNt5-2의 구축을 위한 학습 자료는 ANNt5-1의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(471개) 중에서 새로운 학습 자료 5개를 선정하고 ANNt5-1에서 사용했던 5개의 학습 자료를 합하여 총 10개를 사용하였다. ANNt5-2를 사용한 결과 광역해는 상위 23%에 위치하였다.

세 번째 인공신경망 ANNt5-3의 구축을 위한 학습 자료는 ANNt5-2의 예측 결과의 상위 30%에서 학습 자료와 중복되는 데이터를 제외한 자료(140개) 중에서 새로운 학습 자료 5개를 선정하고 ANNt5-2에서 사용했던 10개의 학습 자료를 합하여 총 15개를 사용하였다. ANNt5-3을 사용한 결과 광역해는 상위 2%에 위치하였다. 네 번째 인공신경망 ANNt5-4의 구축을 위한 학습 자료는 ANNt5-3의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료(43개) 중에서 새로운 학습 자료 5개를 선정하고 ANNt5-3에서 사용했던 15개의 학습 자료를 합하여 총 20개를 사용하였다. ANNt5-4를 사용한 결과 광역해는 상위 6%에 위치하였다.

다섯 번째 인공신경망 ANNt5-5의 구축을 위한 학습 자료는 ANNt5-4의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(14개) 중에서 새로운 학습 자료 5개를 선정하고 ANNt5-4에서 사용했던 20개의 학습 자료를 합하여 총 25개를 사용하였다. ANNt5-5를 사용한 결과 광역해는 상위 11%에 위치하였다. 여섯 번째 인공신경망 ANNt5-6의 구축을 위한 학습 자료는 ANNt5-5의 예측 결과의 상위 30%에서 기존 학습 자료와 중복되는 데이터를 제외한 자료(5개) 중에서 새로운 학습 자료 5개를 선정하고 ANNt5-5에서 사용했던 25개의 학습 자료를 합하여 총 30개를 사용하였다. ANNt5-6을 사용한 결과 광역해는 상위 10%에 위치하였다.

일곱 번째 인공신경망은 ANNt5-6의 예측 결과의 상위 30%에서 기존 학습 자

료와 중복되는 데이터를 제외한 자료(0개)가 새롭게 학습에 사용될 자료의 수(5개)보다 적어 구축하지 않고 종료되었다. 위의 순차적인 인공신경망 구축 과정을 통해 저류층 시뮬레이션이 실행된 횟수는 학습 자료의 출력 자료로 사용된 30개의 위치와 마지막 인공신경망의 상위 30%에서 기존 학습 자료와 중복되는 데이터는 제외한 자료 0개를 합하여 총 30회이다. 30개 위치를 시뮬레이션 하는데 소요되는 시간은 총 1시간 15분이다. 추가 시추 가능한 모든 위치를 시뮬레이션 했을 때 소요되는 시간에 비해 약 98% 감소시켜 광역해를 찾아낼 수 있다.

Table 19. The results of Coalbed Methane Model sequential artificial neural network constructed using 5 initial training data(Continued).

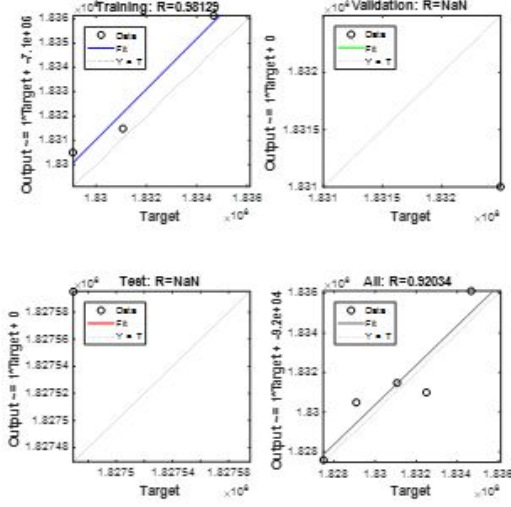
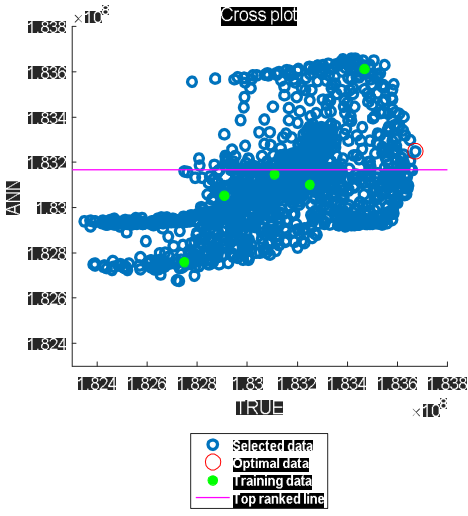
	ANNt5-1
Coefficient of determination	
Cross plot	
Global Point Ranking	0.19
Number of training data	5
©	471

Table 19. The results of Coalbed Methane Model sequential artificial neural network constructed using 5 initial training data(Continued).

	ANNt5-2
Coefficient of determination	
Cross plot	
Global Point Ranking	0.23
Number of training data	10
©	140

Table 19. The results of Coalbed Methane Model sequential artificial neural network constructed using 5 initial training data(Continued).

	ANNt5-3
Coefficient of determination	
Cross plot	
Global Point Ranking	0.02
Number of training data	15
©	43

Table 19. The results of Coalbed Methane Model sequential artificial neural network constructed using 5 initial training data(Continued).

	ANNt5-4
Coefficient of determination	
Cross plot	
Global Point Ranking	0.06
Number of training data	20
©	14

Table 19. The results of Coalbed Methane Model sequential artificial neural network constructed using 5 initial training data(Continued).

	ANNt5-5
Coefficient of determination	
Cross plot	
Global Point Ranking	0.11
Number of training data	25
©	5

Table 19. The results of Coalbed Methane Model sequential artificial neural network constructed using 5 initial training data.

	ANNt5-6
Coefficient of determination	
Cross plot	
Global Point Ranking	0.10
Number of training data	30
©	0

제3절 광역적 최적 추가 시추위치 선정 결과

학습 자료의 수가 적어질수록 인공신경망의 예측 결과 값과 참값의 오차가 커지나 최적의 위치는 순차적으로 구축한 인공신경망의 예측 결과 모두에서 30% 내에 위치하는 것을 확인하였다. 또한 대상 저류층에서 추가 시추 가능한 모든 위치를 시뮬레이션 할 때보다 적은 수의 시뮬레이션 실행 횟수로 시간을 절약하여 정확한 추가 시추 위치를 선정할 수 있다는 것을 확인하였다(Table 20). Black-Oil 모델과 석탄층 메탄가스 저류층 모델 모두 학습 자료를 20개로 설정 하였을 때 최소한의 저류층 전산 시뮬레이터의 실행을 통해 추가 시추 가능한 모든 위치를 시뮬레이션 했을 때 보다 각각 약 82%와 94%의 시간을 감소시켜 광역해를 찾을 수 있는 적합한 수의 학습 자료라고 판단된다. 학습 자료를 5개와 10개로 설정 하였을 때에도 광역해가 순차적으로 구축한 인공신경망의 예측 결과 모두에서 30% 내에 위치하였지만 인공신경망 학습 과정에서 결정계수를 달리하여 여러 case를 분석한 결과 결정계수를 얻기에 어려움이 있고 광역해가 30%를 벗어나는 경우가 많아 전체 저류층을 대표하기에는 적은 수의 학습 자료라고 판단하였다. 학습 자료를 40개로 설정하였을 때에도 광역해가 순차적으로 구축한 인공신경망의 예측 결과 모두에서 30% 내에 위치하였지만 저류층 전산 시뮬레이터를 최소한으로 실행하고자 하는 목적에 부합하지 않는다고 판단된다.

Table 20. Total results of the Black-Oil and Coalbed Methane models.

	The number of training data	The Number of simulations	Run time reduction ratio(%)
Black-Oil Model	40	102	70
	20	61	82
	10	37	89
	5	22	94
Coalbed Methane Model	40	157	90
	20	91	94
	10	53	96
	5	30	98

광역적 최적화 알고리즘 중 Kennedy와 Eberhart(1995)에 의해 제안된 입자 군집 최적화 알고리즘(PSO)을 사용하여 최적 추가 시추위치 결과의 정확성과 성능을 비교하였다. 검증을 위해 대상 저류층에 추가 시추가 가능한 모든 위치에 대해 저류층 전산 시뮬레이션을 수행하여 구한 최적의 추가 시추위치는 (26, 44)이다. 이 위치를 찾기 위해 입자 군집 최적화 알고리즘은 몇 회의 시뮬레이션 실행이 요구되고 제한된 시뮬레이션 실행 횟수 내에서 광역해를 찾을 수 있는지에 대해 분석하였다. 대상 저류층은 앞서 연구한 석탄층 메탄가스 모델을 사용하였으며 입자 군집 최적화에 사용된 변수는 Table 21과 같다.

Table 21. PSO Parameters used for the well placement optimization run.

PSO Parameter	Value
Particle size	20
Inertia Weight	0.3
Cognition Component	1.5
Social Component	2.5
Number of iterations	79

입자 군집 최적화 알고리즘을 50회 실행하여 (26, 44)의 위치를 찾아내는 시뮬레이션 실행횟수를 분석한 결과 평균적으로 190회 실행하여 광역해를 찾아내었다. 이는 알고리즘의 특성 상 위치가 중복되는 것을 포함한 수치이며 위치의 중복을 제외하면 112회 실행하여 광역해를 찾아내었다. 그러나 간혹 국소적 최적값(Local optimum point)을 찾아내어 알고리즘의 반복 횟수인 79회 내에 광역해를 찾지 못하는 경우도 발생하였다.

Figure 14는 입자 군집 최적화 알고리즘의 반복 횟수를 15회와 20회로 설정한 경우 최적의 추가 시추위치를 찾아가는 과정이다. Cost는 누적 가스 생산량을 음수화한 것으로 값이 적을수록 누적 가스 생산량이 많은 것을 의미해 추가 시추 위치가 될 가능성이 높아진다. 15회로 설정했을 때의 최적의 위치와 20회로 설정했을 때의 예측된 최적의 위치가 다르게 나타난다. 입자 군집 최적화 알고리즘을 사용할 경우 반복 횟수의 설정에 따라 최적의 시추 위치에 도달하지 못할 수 있다. Figure 15는 Table 21의 변수를 사용하여 알고리즘의 반복 횟수를 79회로 설정했을 때 최적의 추가 시추위치를 찾아가는

과정이다. 22회 반복에서 최적의 위치를 찾아내었으며 시추 위치의 중복을 제외하면 저류층 시뮬레이션을 181회 실행하여 광역해를 찾아내었다. 그러나 실제로 알고리즘을 시추 위치 최적화에 적용할 때에는 광역해를 모른 채 수행하게 됨으로 22회에서 찾은 시추 위치가 광역해인지는 확신할 수 없다. 따라서 기존의 광역적 최적화 알고리즘을 이용한 시추 위치 최적화는 반복 횟수에 따라 최적의 시추위치의 결과가 달라질 수 있으며 선정된 위치가 광역해라고 확신하기 어려워 확인을 위해서 여러 차례 반복을 수행해야 한다.




Figure 14. Cost as a function of 15 and 20 iteration for PSO.




Figure 15. Cost and number of simulations as a function of 79 iteration for PSO.

인공신경망 구축 시 주의해야 할 점은 Figure 16과 같이 목표값(x축)의 상위 끝 데이터가 인공신경망의 예측값(y축)도 상위에 위치하도록 구축해야 한다. 그렇지 않고 Figure 17과 같이 결정계수가 1에 가깝다 하더라도 목표값(x축)의 상위 끝 데이터가 인공신경망의 예측값(y축)의 상위에 위치하지 않는다면 광역해가 상위 데이터의 선택 비율에 내에 존재하지 않을 수 있다.

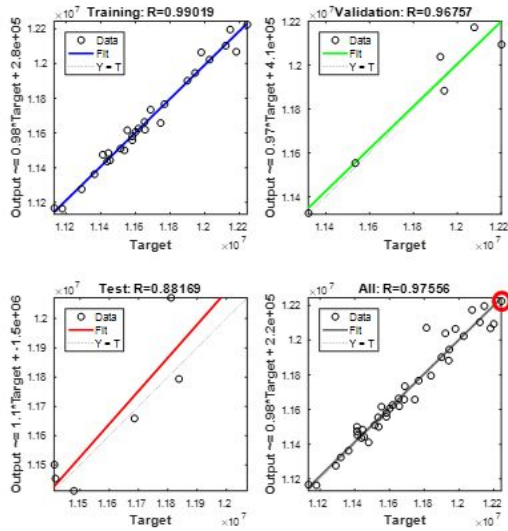


Figure 16. The correct example of the coefficient of determination.

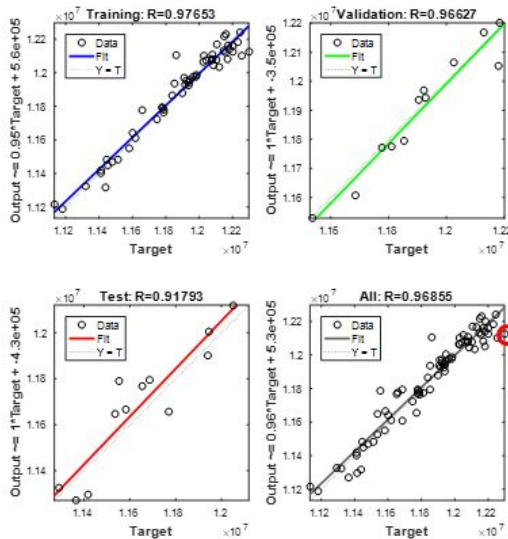


Figure 17. The wrong example of the Coefficient of determination.

제5장 결론

이 연구에서는 기존의 인공신경망을 이용하여 추가 시추위치를 최적화하는 방법의 정확성의 한계를 보완하여 광역적 최적 추가 시추위치를 선정하는 방법을 제안하였다. 제안한 방법을 격자수가 다른 오일 저류층과 가스 저류층에 적용하여 다음과 같은 결론을 얻었다.

(1) 추가 시추 가능한 모든 위치를 저류층 전산 모사를 수행 하였을 때에 비해 제안한 방법을 수행할 경우 연산 시간을 70% 이상 감소시킬 수 있음을 확인하였다. 인공신경망을 구축하기 위해 학습에 사용되는 자료의 수는 대상 저류층의 격자수에 관계없이 20개 내외가 적절하다고 판단된다.

(2) 저류층 모델에 대한 연구결과 광역해는 대체적으로 탐색공간의 상위 20%에 내에 존재하는 것을 확인하였으나 안전율을 고려하여 상위 데이터의 선택 비율을 30%로 설정하는 것이 적절한 것으로 판단하였다. 그러나 저류층의 복잡성과 인공신경망 구축 과정의 정확성이 떨어지면 상위자료 선택의 비율 조정이 필요하다.

(3) 기존의 광역적 최적화 알고리즘 중 입자 군집 최적화 알고리즘을 사용하여 선정한 최적 시추위치가 광역해라는 것을 판단하기 위해서는 충분히 많은 수의 반복이 필요하였다. 따라서, 이 연구에서 제안한 순차적 인공신경망 기법이 더 효율적으로 광역해를 찾아내는 것을 확인하였다.

(4) 인공신경망 구축 시 목표값(x축)의 상위 끝 데이터가 인공신경망으로 예측된 값(y축)의 상위에 위치하도록 구축한다면 순차적 인공신경망을 통한 광역해 도출의 성공 가능성을 높일 수 있다.

이와 같이 제안한 광역적 추가 시추위치 최적화 방법은 기존의 인공신경망을 이용한 추가 시추위치 최적화 방법의 한계를 극복하고 신뢰성 있는 결과를 산출하였다. 이 연구에서는 검증의 효율을 위해 한 개의 추가 시추 위치를 선정하였지만

다수의 시추위치, 수평정 등 다양한 시추정에도 적용이 가능하다. 순차적 인공신경망 기법으로 현장 규모 저류층의 시추 위치 최적화를 수행 한다면 고속의 연산을 통해 시간과 비용을 절약하고 최대 누적 생산량을 갖는 추가 시추위치의 광역해를 선정할 수 있을 것이다.

참 고 문 헌

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

마이클 네그네빗스키 저, 김용혁 역, 2013, 인공지능 개론, 한빛아카데미.

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

박기현, 한석영, 2016, 제국주의 경쟁 알고리즘을 이용한 위상최적화, 한국생산제조 시스템학회 학술발표회 논문집, 60-60.

박평재, 2016, 수학적 모델링과 입자 군집 최적화 기법을 이용한 플랜트 최적화 배치에 관한 연구, 석사학위논문, 17-20.

정환목, 2008, 소프트웨어컴퓨팅, 내하출판사, 3-57.

한학용, 2014, 패턴인식 개론, 한빛아카데미, 318-354, 374-401.

Ahmad, T., 2014, Introduction to Soft Computing, Department of Computer Engineering, ZHCET, Zakir husain College of Engineering & Technology, Aligarh Muslim University.

Ali, J.K., 1994, Neural Networks: A New Tool for the Petroleum Industry?, paper SPE 27561 presented at the 1994 European Petroleum Computer Conference held in Aberdeen, U. K., 15-17 March.

Bratton, D. and Kennedy, J., 2007, Defining a standard for particle swarm optimization, Proceedings of the 2007 IEEE Swarm Intelligence Symposium (SIS 2007).

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.

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, Methods of Neuro-Simulation for Field Development, SPE Paper 39962, 1998 SPE Rocky Mountain Regional, Denver, CO.

Doraisamy, H., Ertekin, T., and Grader, A. S., 1998, Key Parameters Controlling the Performance of Neuro-Simulation Applications in Field Development, SPE Paper 51079, 1998 SPE Eastern Regional Meeting, Pittsburgh, PA.

Dossary, M.A.A. and Nasrabadi, H., 2015, Well Placement Optimization Using Imperialist Competition Algorithm, SPE 175646 presented at the 2015 SPE Reservoir Characterisation and Simulation Conference and Exhibition held in Abu Dhabi, UAE, 14 - 16 September.

Emerick, A.A, Silva, E., Messer, B., Almeida, L.F., Szwarcman, D., Pacheco, M.A.C., and Vellasco, M.M.B.R., 2009, Well Placement Optimization Using a Genetic Algorithm with Nonlinear Constraints, SPE 118808 presented at the 2009 SPE Reservoir Simulation Symposium held in The Woodlands, Texas, USA, 2 - 4 February.

Feng, Q., Zhang, J., Zhang, X., and Hu, A., 2012, Optimizing well placement in a coalbed methane reservoir using the particle swarm optimization algorithm,

- International Journal of Coal Geology 104 (2012) 34-45.
- Gargari, E.A. and Lucas, C., 2007, Imperialist Competitive Algorithm: An Algorithm for Optimization Inspired by Imperialistic Competition, 2007 IEEE Congress on Evolutionary Computation (CEC 2007).
- Guyaguler, B., Horne, R.N., Roger, L.L., and Rosenzweig, J.J., 2002, Optimization of Well Placement in a Gulf of Mexico Waterflooding Project, SPE Reservoir Evaluation & Engineering (June 2002) 5, 229-236.
- Guyaguler, B. and Horne, R.N., 2004, Uncertainty Assessment of Well-Placement Optimization, SPE 87663 presented at the 2001 SPE Annual Technical Conference and Exhibition held in New Orleans, 30 September-3 October.
- Jesmani, M., Bellout, M.C., Hanea, R., and Foss, B., 2015, Particle Swarm Optimization Algorithm for Optimum Well Placement Subject to Realistic Field Development Constraints, SPE 175590 presented at the 2015 SPE Reservoir Characterisation and Simulation Conference and Exhibition held in Abu Dhabi, UAE, 14 - 16 September.
- Kennedy, J. and Eberhart, R., 1995, Particle Swarm Optimization, Proceedings of the 1995 IEEE International Conference on Neural Networks, 1942-1948.
- Minton, J.J., 2014, A Comparison of Common Methods for Optimal Well Placement, SIAM.
- Montes, G., Bartolome, P., and Udias, A.L., 2001, The Use of Genetic Algorithms in Well Placement Optimization, Paper SPE 69439 presented at the 2001 SPE Latin American and Caribbean Petroleum Engineering Conference held in Buenos Aires, Argentina, 25-28 March.

Morales, A.N., Gibbs, T.H., Nasrabadi, H., and Zhu, D., 2010, Using Genetic Algorithm to Optimize Well Placement in Gas Condensate Reservoirs, Paper SPE 130999 presented at the 2010 SPE EUROPEC/EAGE Annual Conference and Exhibition held in Barcelona, Spain, 14-17 June.

Morales, A.N., Nasrabadi, H., and Zhu, D., 2010, A Modified Genetic Algorithm for Horizontal Well Placement Optimization in Gas Condensate Reservoirs, Paper SPE 135182 presented at the 2010 SPE Annual Technical Conference and Exhibition held in Florence, Italy, 19 - 22 September.

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.

Pusan National Univ. NR Lab., 2015, Back-propagation algorithm.

Raschka, R., 2015, Single-Layer Neural Networks and Gradient Descent,

Schwaab, M., Biscaia, E.C., Jr., Monteiro, J.L., and Pinto, J.C., 2008, Nonlinear parameter estimation through particle swarm optimization, Chemical Engineering Science 63 (2008) 1542 - 1552.

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, Paper SPE 86880 presented at the 2002 SPE Annual Technical Conference and Exhibition, San Antonio, Texas, 29 September-2 October.

감사의 글

석유가스공학 연구실에서 학부연구생으로 시작해 대학원에 진학하고 벌써 석사 과정을 졸업하게 되었습니다. 대학원 생활을 마치며 그동안 저에게 관심과 도움을 주신 모든 분들에게 진심으로 감사드립니다.

먼저 많이 부족한 저를 앞에서 이끌어 주신 장일식 교수님께 감사드립니다. 항상 모범적인 모습으로 본보기가 되어주시고 저의 원활한 연구 수행을 위해 관심과 조언을 아끼지 않으셨습니다. 스승의 참됨을 누구보다 여실히 보여주시어 많은 배움을 얻을 수 있었습니다. 이에 다시 한 번 진심으로 감사드립니다. 그리고 학부 과정 때부터 저에게 지속적인 관심과 독려를 해주신 강성승 교수님, 조언과 칭찬을 아끼지 않으신 최태진 교수님, 항상 먼저 안부를 물어 주시는 고진석 교수님, 학부 과정 때부터 많은 가르침을 주신 한오형 교수님, 박천영 교수님, 박철현 교수님께 감사의 말씀을 드립니다. 교차 강의를 통해 전공 지식을 넓혀 주신 전남대학교 이정환 교수님께도 감사의 말씀을 드립니다.

에너지자원공학과를 다니며 맺은 소중한 인연, 선후배들과 동기들에게도 감사의 말을 전합니다. 고민을 함께 나누며 늘 든든한 버팀목이 되어준 영진이 오빠, 아무것도 모르는 학부 과정 때부터 많은 도움을 주시며 대학원생이 되어서도 끊임 없이 관심을 가져주셨던 영경이 오빠, 연구실은 다르지만 대학원 생활의 활력소가 되어준 정두오빠, 주호오빠, 건주오빠, 연구실에서 함께 생활한 주환이 오빠, 현정이, 현택이 오빠, 연일이 오빠, 영두, 남희에게 고맙다는 말을 전합니다.

마지막으로 가족이 있었기에 이 논문을 완성하고 석사과정을 마칠 수 있었습니다. 많은 것을 경험할 수 있도록 헌신해 주시는 부모님과 하나뿐인 언니에게 진심으로 감사합니다. 지금껏 주신 무한한 사랑과 아낌없는 지원에 보답하겠습니다. 사랑합니다. 감사합니다.