

연구논문

## 이산화탄소 회수증진-저장 최적화를 위한 머신러닝 기법 적용연구

이원석<sup>1\*</sup> · 홍용준<sup>2</sup>

<sup>1</sup>한국지질자원연구원 석유해저연구본부 책임연구원, <sup>2</sup>주식회사에너지이 기업부설연구소 연구소장

### Application of Machine Learning Technologies for optimizing CO<sub>2</sub> EOR-Storage Processes

Won Suk Lee<sup>1\*</sup> and Youngjun Hong<sup>2</sup>

<sup>1</sup>Principal Research Engineer, Petroleum & Marine Research Div., Korea Institute of Geoscience & Mineral Resources (KIGAM)

<sup>2</sup>Chief Technology Officer, R&D Center, ENERZAI

Received 14 October 2020 Final version Received 4 December 2020 Accepted 22 December 2020

**Abstract :** This paper investigates an applicability and efficiency of machine learning algorithm in CCS-EOR(Carbon Capture & Storage-Enhanced Oil Recovery) optimization processes. By using simulation results of 105 cases according to variation of selected 8 influencing factors in the reference, all cases reaching to 2,916 were predicted by developed proxy model. For improved training and testing accuracy, the hyperopt algorithm was adopted and in case of objective function NPV, the testing accuracy is achieved above 92%. However, in cases of other objective functions such as recovery factor, CO<sub>2</sub> stored, it is required to re-select influencing factors more sensitive to respective objective functions. Machine learning optimization process suggested in this paper, can be utilized as conventional optimization methods, especially, it can be more efficient procedure in complex optimization processes with additional influencing factors.

**Key words :** CCS-EOR, Machine learning, Proxy model, Optimization

**요 약 :** 이 연구에서는 CCS-EOR 저류층 최적화 분석을 위한 머신러닝 기법 적용성 및 효율성을 검토하였다. 기존 문헌에서 수행된 8개 인자 변화에 따른 105개의 경우의 수에 대한 시뮬레이션 결과를 활용하여, 개발된 프록시 모델을 적용하여 2,916개에 달하는 모든 시뮬레이션 경우의 수를 예측하였다. 머신러닝 모델 개발에 있어 초매개변수(hyper-parameter) 선정 최적화 과정을 도입하여 학습 및 예측 과정을 향상시켰으며, 목적함수 NPV의 경우 평균 적합도 92% 이상의 정확도를 확보하였다. 그러나 회수율 및 저장량 등의 목적함수에 대한 최적화 수행 결과, 보다 목적함수에 민감한 영향인자 재선정이 필요함을 알 수 있었다. 목적함수에 대한 적절한 영향인자 선정 및 학습자료가 확보될 경우, 머신러닝 최적화 기법은 기존의 최적화 과정을 대체할 수준의 매우 효과적인 방법임을 확인하였으며, 영향인자가 추가되어 경우의 수가 증가할 경우 보다 효과적으로 최적화 분석에 이용될 수 있을 것으로 판단된다.

**주요어 :** CCS-EOR, 머신러닝, 프록시 모델, 최적화

## 서 론

다양한 회수증진기법(EOR, enhanced oil recovery) 중 CO<sub>2</sub> 주입기법은 새로운 관점에서 다시 주목을 받고 있다. 주입된 CO<sub>2</sub>는 오일에 용해되어 오일을 팽창시켜 점성도를 낮추며, 고압 주입에 따른 혼화 상태(miscible state)가 만족 되면 단상유동(single phase flow)이 가능하여 추가적인 회수율 증진 효과를 볼 수 있다(Perera *et al.*, 2016). 또한 주입된 CO<sub>2</sub>와 저류층 오일과의 밀도차에 의한 낮은 점축효율

(sweep efficiency)를 증가시키기 위한 WAG(water alternating gas) 공법 등이 고안되어 세계적으로 상업적인 개발에 적용되고 있는 실정이다(Godec *et al.*, 2011).

현재까지 대다수의 CO<sub>2</sub>-EOR 프로젝트는 고가의 CO<sub>2</sub> 소비를 최소화하면서 최대의 오일 생산 효과를 보기 위한 공법 설계가 수행되었다. 그러나 최근들어 온실가스 저감에 대한 필요성이 증가하면서, CO<sub>2</sub> 처분에 따른 수익창출이 가능할 수 있게 되어 CO<sub>2</sub> 저장량 및 오일 회수율을 동시에 고려하는 광구운영 설계(CCS-EOR operation optimization)

\*Corresponding Author, Won Suk Lee, wslee@kigam.re.kr, Petroleum & Marine Research Div., Korea Institute of Geoscience and Mineral Resources, Daejeon, Korea

가 제안되고 있다(Kovscek and Cakici, 2005).

성공적인 CCS-EOR 공법 적용을 위해서는 저류층 특성을 고려한 다양한 형태의 운영조건을 고려하여야 한다. 특히 저류층 특성에 대한 불확실성이 클 경우, 고려해야 할 인자의 수는 기하급수적으로 증가한다. CCS-EOR 최적화 과정은 크게 운영 인자(오일 생산량 거동, CO<sub>2</sub> 활용도: 단위 오일 생산량에 대한 CO<sub>2</sub> 저장량, CO<sub>2</sub> 재활용도: CO<sub>2</sub> 주입량에 대한 CO<sub>2</sub> 생산량 등)과 경제성 인자(유가, CO<sub>2</sub> 가격, 세제혜택 등) 등을 고려해 수행된다(Ettehadavakkol *et al.*, 2014). 경제성 인자는 외부환경에 좌우되므로 인위적인 조절이 어렵지만, 광구 운영 인자는 운영 목적에 따라 적절한 범위의 값을 선정하게 된다.

CCS-EOR 광구 운영 최적화를 위해 우선 민감도 분석을 통해 각 인자에 대한 영향 정도를 결정한다. 대표적인 설계 인자로는 CO<sub>2</sub> 주입량, WAG비, 주입패턴(flooding pattern), 유정완결형태(completion) 등이 있으며, 치밀 또는 비전통 저류층을 대상으로 할 경우 수압파쇄 형태(파쇄균열 거리, 간극 등) 및 자연균열과의 연결성 등이 추가로 고려되어야 한다(Ghaderi *et al.*, 2012).

인자에 대한 민감도 분석을 위해 우선적으로 대상 저류층에 대한 정적모델(지질모델) 및 동적 모델을 구축하고 인자의 범위에 따른 경우의 수를 선정하여 시뮬레이션을 수행한다. 각 인자들의 민감도는 목적함수에 따라 그 영향 정도가 다를 수 있기 때문에 최적화 목적함수(최대 오일 회수율, 최대 CO<sub>2</sub> 저장량 또는 최대 NPV 등)에 따른 분석이 각각 수행되어야 한다. 이 과정에서 현실적인 문제에 직면하게 된다. CO<sub>2</sub>-EOR 뿐 아니라 CCS-EOR 분석을 위해서는 조성시뮬레이터를 활용하게 되는데, 일반적으로 5에서 10개 정도의 유사 조성(pseudo-component)으로 구성된 유체, 현장 규모 격자 체계 및 다수 정호에 대한 설정 등으로 인해 상당한 계산량이 요구된다. 일반적인 개인용 워크스테이션 기준으로 1회 시뮬레이션 수행을 위해 최소수 시간이 소요되며, 여러 인자들의 민감도 분석 및 최적화 경우를 선정하기 위해서는 적게는 수백 회, 많게는 수천 회 시뮬레이션 수행이 필요하므로 모든 경우에 대한 시뮬레이션 수행은 현실적으로 불가능하다. 예를 들어, 8개 인자에 대한 경우의 수(2개 인자는 2개 파라미터, 6개 인자는 3개 파라미터)는 2,916(=2<sup>2</sup>×3<sup>6</sup>)에 이르며, 인자의 범위가 연속적일 경우 그 경우의 수는 무한대로 증가하게 된다. 이러한 문제를 해결하기 위해 계산의 효율을 위해 대표성을 갖는 경우를 찾기 위한 DOE(design of experiment; Montgomery, 2013) 방법 등이 적용되고 있다.

최근 들어 석유개발 분야에도 머신러닝(또는 인공지능) 기술 접목이 활발히 이루어지고 있다. 프록시 모델 구성, 히스토리 매칭, 프로젝트 디자인, 그리고 최적화 분야에 활발

한 적용사례가 발표되고 있다(Min *et al.*, 2020; Kim *et al.*, 2017). 머신러닝 기술 접목을 통해 저류층 특성과 및 유체 거동 파악을 위한 원시자료 처리, 가공 시간 감축 및 시뮬레이션 연산에 소요되는 시간 감축 등이 가능할 것으로 판단되나, 아직까지 전통적인 분석 절차를 대체할 수준은 아니고 분석의 효율을 높이기 위한 보조적인 수단으로 활용되고 있다(Ertekin and Sun, 2019).

이 연구에서는 CCS-EOR 최적 해를 도출하기 위한 머신러닝 기법 적용 가능성을 검토하고자 하였다. 대상 저류층은 캐나다 알버타주에 위치하는 Pembina Cardium 필드이며, 기 발표된 시뮬레이션 결과를 활용하였다. 전체 경우의 수를 대표할 수 있는 방법(design of experiment)을 통해 도출된 105개 경우에 대한 시뮬레이션 결과를 활용하여 프록시 모델링을 수행한 결과, 총 경우의 수(2,916)에 대한 예측 값을 도출하였으며, 이를 발표된 결과와 비교하여 최적화 분야에서의 머신러닝 기법의 적용성 및 활용가능성을 검토하였다.

## 본 론

### 대상 광구 개요

문헌 검토를 통해 CCS-EOR 최적화 분석이 수행된 저류층을 선정하였다. 대상 저류층은 캐나다 알버타주에 위치한 Pembina Cardium 필드로써, 낮은 투과도로 인해 회수율이 낮아 수압파쇄를 계획 중에 있다(Clarkson and Pedersen, 2011). Ghaderi *et al.*(2012)은 대상 저류층에 대한 유체 및 저류층 모델을 구축하여 상업모델(CMG GEM)을 활용한 시뮬레이션을 수행하였으며, 8개의 인자를 선정하여 이에 대한 민감도 및 최적화 분석을 수행하였다. 이를 개략적으로 요약하면 다음과 같다.


### 저류층 특성

저류층 유체 비중은 38 °API의 경질유이며, 초기 압력은 5,279 ft 기준으로 2,520 psi, 기포점 압력은 127°F에서 약 1,620 psi이다. 저류 유체 및 암석, 그리고 시뮬레이션 구동 관련한 주요 특성은 Table 1과 같다. CO<sub>2</sub>를 포함한 7개의 유사조성으로 유체성분을 구성한 후 PVT 실험자료(swelling test 및 MMP 측정실험)와 매칭하여 PVT 입력자료를 구성하였으며, Peng-Robinson 상태방정식을 사용하였다.

당초 코어 및 로깅자료를 활용한 3차원 지질모델이 구축되었으나, 다양한 인자들의 영향을 관측하기 위해 저류층의 일부분(640 acre)을 대상으로 분석하였다(Fig. 1). 특히 균열 특성(fracture spacing 및 fracture half length 등)은 저류층 지질특성에 영향을 받을 수 있으므로 고도차를 배제 한 모델을 사용하였다.

**Table 1.** Reservoir fluids and rock properties

Reservoir fluids properties		Reservoir rock properties	
P <sub>b</sub> , psia	1,620	Initial reservoir pressure, psi	2,520
R <sub>s</sub> at P <sub>b</sub> , scf/stb	730	Initial water saturation, %	25
Oil viscosity at P <sub>b</sub> , cp	0.63	Initial oil saturation, %	75
B <sub>o</sub> at P <sub>b</sub> , res. bbl/stb	1.37	Avg. porosity, %	9.1
Oil density at STP, lbm/ft <sup>3</sup>	52.1	Avg. permeability, md	1.44
Avg. gas viscosity, cp	0.01	Rock compressibility, 1/psi	5.0×10 <sup>-6</sup>
Water viscosity, cp	0.57		
Water salinity, ppm	50,000		

**Fig. 1.** (a) One section of Pembina Cardium reservoir considered as the study area, (b) the flattened version of reservoir model used in reservoir simulation (Ghaderi *et al.*, 2012).

시물레이션을 위해 대상 지역은 외곽이 단절된 것으로 가정하였으며, 하부 대수층의 영향은 고려하지 않았다.

생산정 및 CO<sub>2</sub> 주입정은 모두 수평정으로 설계되었으며, 모두 4,650 ft의 길이를 갖는다. 수압파쇄에 의한 균열 전도도(fracture conductivity= $K_f \times W_f$ )는 균열 간극( $W_f$ )을 0.1ft로 가정하여, 약 200 md-ft 내외인 것으로 가정하였다.

#### 시물레이션 수행 결과

Ghaderi *et al.*(2012)은 시물레이션 수행을 통해 CCS-EOR 최적화에 영향을 미치는 인자를 선정하였다. 최대 오일 회수율과 최대 CO<sub>2</sub> 저장량을 목적함수로 할 경우 영향을 미치는 인자 8개가 선정되었으며, 이에 대한 설명은 Table 2와 같다. 동시에 경제적 효과에 대한 최적화를 동시에 고려하기 위해 NPV(net present value)를 목적함수로 분석을 수행하였다. NPV 계산을 위해 사용된 가정은 Table 3과 같다. OPEX 뿐 아니라 CAPEX 비용 또한 고려하여 분석되었으며, cemented 정호 비용을 open-hole에 비해 1.5배로 가정하였다. 그러나 그 이상의 자세한 내용은 문헌에 수록되지 않았다.

8개 인자 중 A와 B는 2개의 파라미터를, C에서 H는 3개의 파라미터를 고려하였으며, 이에 대한 모든 경우의 수는 2,916(=2<sup>2</sup>×3<sup>6</sup>)에 이른다. 이에 대한 각각의 시물레이션은 현실적으로 불가능하기 때문에 Ghaderi *et al.*(2012)은 DOE(design of experiment) 방법(Montgomery, 2013)을 도입하여 대표성을 가지는 105가지 경우를 선정하여 결과를 도출하였다. DOE 방법은 1개 이상의 인자에 대한 상관성을 파악하는데 활용되며, 목적함수에 대한 인자의 영향을 반응표면(response surfaces) 형태로 표현할 수 있다는 장점을 가지고 있다.

105개 경우에 대한 시물레이션 수행 결과는 Table 4와 같다. 목적함수에 따른 결과를 살펴보면, 회수율은 37.0%에서 60.6% 사이의 값을 보이며, 오일 생산량 증가비율은 OOIP 기준 0.4~17.1%이다. 또한 CO<sub>2</sub> 저장량은 0.2~3.6 bcf, 그리고 NPV는 8.6~38.1 mm\$의 범위를 갖는다. 위에서 산출된 목적함수별 최소, 최대 범위는 105개 경우에 대한 범위이며, 전체 조합의 수가 2,916이므로 보다 다양한 조합을 통해 이 범위 이상의 목적함수 최소, 최대값들이 산출될 수 있다.

**Table 2.** Different factors and the associated parameters for sensitivity runs

Factor Name	Parameters			Comments
	L1	L2	L3	
A. Well Pattern	D1	D2	-	<ul style="list-style-type: none"> <li>The number of wells and the well spacing</li> <li>- D1: 5 wells with spacing 1,000 ft</li> <li>- D2: 7 wells with spacing 650 ft</li> </ul>
B. Well Completion	Cemented	Open-Hole	-	<ul style="list-style-type: none"> <li>Cemented well: restricted to the interaction point of the hydraulic fracture plan</li> <li>Open-hole: whole length of the lateral is contributing to the fluid flow</li> </ul>
C. Frac. Spacing, ft	200	300	400	<ul style="list-style-type: none"> <li>Decreasing the fracture spacing will increase the well contact area with the reservoir and improve the productivity/injectivity of the wells</li> </ul>
D. Frac. Half-length, ft	100	200	300	<ul style="list-style-type: none"> <li>Long traverse fractures leave a short gap between the fracture tips and shortens the breakthrough time of the injected fluid and undermines the sweep efficiency</li> </ul>
E. $P_{avg}$ while WF, psi	1,000	1,300	1,600	<ul style="list-style-type: none"> <li>Higher in-situ gas saturation leads to multi-phase flow of the liquid and gas phases, lowers the mobility of the oil phase</li> </ul>
F. WCUT while switch WAG, fraction	0.5	0.7	0.9	<ul style="list-style-type: none"> <li>The transition from water-flood scheme to CO<sub>2</sub> injection scheme can occur at varying water cuts</li> </ul>
G. CO <sub>2</sub> slug size	0.25	0.50	0.75	<ul style="list-style-type: none"> <li>The cumulative volume of injected gas / the initial hydrocarbon pore volume</li> </ul>
H. WAG ratio	0	1	2	<ul style="list-style-type: none"> <li>The ratio of the volume of injected water to that of gas at reservoir conditions</li> <li>WAG=0 implies continuous CO<sub>2</sub> injection until the designated slug size is fulfilled</li> </ul>

**Table 3.** Input parameters for NPV calculations

Oil price, \$/bbl	80
*Royalty, %	variable
CO <sub>2</sub> price, \$/mscf	1.0
CO <sub>2</sub> recycle cost, \$/mscf	0.52
Oil lifting cost, \$/well/year	15
Operating cost of producers, \$/well/year	24,000
Operating cost of injectors, \$/well/year	30,000
Operating cost cut-off, \$/boe	60

\*Royalty: 캐나다 알버타 주정부 규정을 따르며, 일반적으로 오일 생산량 및 유가에 따라 연동

이를 위해 Ghaderi *et al.* (2012)은 “half-normal probability” 도식법을 통해 목적함수에 따라 영향이 큰 인자들을 선정한 후, 반응표면 도식법을 통해 상호 연관성이 있는 인자들에 대한 영향 정도를 파악하였다. 즉, 불연속적인 값을 가지는 인자(D1/D2, cemented/open-hole 등)들은 영향 정도를 고려해 미리 고정한 후, 연속적인 값을 가지는 나머지 인자들은 반응표면의 값을 활용하여 추가적인 시뮬레이션 수행 없이 내삽법을 활용해 Table 5와 같은 조합의 최적해를 산

출하였다.

제시된 방법 및 결과는 과도한 시뮬레이션 횟수를 줄이기 위해 일반적으로 시도되는 타당한 방법이나, 저류층 특성 및 유동(주입) 거동에 영향을 미치는 인자들에 대한 고려가 추가적으로 필요할 경우, 이러한 과정도 매우 복잡하고 과도한 계산량을 요구하기 때문에 한계를 가질 것으로 판단된다.

**Table 4.** Sensitivity factors and response values for the selected runs

Run	Factors								Responses			
	A	B	C	D	E	F	G	H	Oil Rec. Factor (%OOIP)	Inc. Oil Rec. Factor (%OOIP)	Stored CO <sub>2</sub> Volume (bcf)	NPV (MM\$)
1	D1	Open-Hole	200	200	1300	0.9	0.5	1	53.5	10.1	2.5	29.2
2	D1	Open-Hole	400	100	1600	0.5	0.25	2	58.6	14.8	1.9	31.7
3	D1	Cemented	400	200	1300	0.7	0.5	1	58.2	14.7	1.9	19.4
4	D1	Open-Hole	200	100	1600	0.9	0.75	0	48.2	4.7	0.2	29.8
5	D1	Cemented	200	300	1300	0.5	0.25	2	49.8	8.2	1.3	22.2
6	D1	Cemented	300	300	1300	0.7	0.5	2	54.0	11.1	2.5	19.4
7	D1	Open-Hole	200	200	1000	0.5	0.25	2	51.8	8.9	1.6	29.9
8	D1	Cemented	200	100	1600	0.9	0.25	1	55.4	12.1	1.6	23.0
9	D2	Open-Hole	400	200	1600	0.5	0.25	2	53.5	12.2	1.6	32.9
10	D1	Cemented	400	200	1600	0.9	0.25	0	50.6	7.6	1.1	16.7
11	D2	Open-Hole	200	200	1000	0.7	0.25	0	42.8	2.1	0.5	25.9
12	D2	Open-Hole	400	300	1300	0.7	0.25	2	51.6	10.4	1.5	30.5
13	D2	Cemented	200	100	1000	0.9	0.5	0	43.1	3.3	0.4	19.9
14	D1	Open-Hole	300	100	1000	0.7	0.5	2	57.1	15.2	3.1	29.1
15	D2	Open-Hole	300	200	1600	0.9	0.25	1	50.7	9.5	1.4	26.8
16	D1	Open-Hole	300	300	1300	0.5	0.5	0	45.1	2.3	0.4	28.7
17	D1	Open-Hole	200	100	1300	0.7	0.25	2	56.0	12.5	1.7	33.2
18	D2	Cemented	400	300	1600	0.9	0.25	2	49.7	10.1	1.4	10.7
19	D1	Open-Hole	400	300	1300	0.5	0.5	1	57.6	13.6	1.9	31.1
20	D1	Open-Hole	400	300	1000	0.9	0.75	2	56.8	13.3	2.8	23.4
21	D1	Open-Hole	400	300	1600	0.5	0.75	0	44.5	2.8	0.5	27.6
22	D2	Open-Hole	300	100	1000	0.9	0.25	0	46.5	6.4	0.9	30.1
23	D1	Open-Hole	200	300	1000	0.7	0.75	1	47.7	7.8	2.2	27.1
24	D2	Open-Hole	200	100	1300	0.5	0.25	0	45.9	4.6	0.7	36.0
25	D2	Cemented	300	300	1300	0.7	0.75	2	49.5	8.7	2.0	19.1
26	D2	Open-Hole	300	200	1300	0.5	0.5	2	52.8	11.1	2.3	36.4
27	D1	Open-Hole	300	100	1600	0.7	0.75	1	58.0	15	3.2	32.4
28	D2	Open-Hole	200	100	1600	0.5	0.5	1	54.0	11.5	1.7	38.1
29	D2	Cemented	300	200	1600	0.7	0.75	1	52.5	11.4	2.5	21.5
30	D1	Cemented	300	200	1300	0.9	0.5	0	48.1	4.2	0.6	21.0
31	D1	Open-Hole	400	300	1000	0.9	0.25	0	49.2	7.0	1.0	23.4
32	D1	Open-Hole	200	200	1000	0.9	0.5	2	52.8	11.0	2.5	27.0
33	D1	Cemented	400	100	1000	0.5	0.75	1	58.3	17.1	3.5	17.7
34	D1	Cemented	300	100	1000	0.9	0.75	2	57.6	15.0	3.0	20.1
35	D1	Open-Hole	300	100	1600	0.5	0.25	0	49.2	7.0	0.9	32.2
36	D2	Open-Hole	300	100	1600	0.9	0.5	2	54.4	13.2	2.7	29.6
37	D2	Cemented	400	200	1600	0.7	0.5	2	54.4	13.3	2.7	20.2
38	D2	Cemented	200	100	1300	0.5	0.5	2	52.8	11.3	2.4	28.8
39	D2	Open-Hole	300	200	1000	0.9	0.75	2	52.2	10.8	2.3	27.8
40	D2	Cemented	400	300	1600	0.5	0.5	1	50.5	11.6	1.6	22.6
41	D2	Open-Hole	200	300	1600	0.9	0.75	1	42.2	2.8	1.2	17.6
42	D2	Cemented	200	200	1600	0.9	0.5	1	48.0	7.2	2.1	14.4
43	D2	Open-Hole	300	200	1300	0.7	0.5	0	44.1	2.4	0.5	31.0
44	D2	Cemented	400	300	1000	0.9	0.75	1	49.9	11.3	2.4	12.0
45	D1	Open-Hole	300	200	1000	0.5	0.75	1	54.6	13.0	3.0	29.8
46	D1	Open-Hole	300	200	1600	0.5	0.5	1	56.9	13.5	1.9	32.0

**Table 4.** Sensitivity factors and response values for the selected runs (Continued)

Run	Factors								Responses			
	A	B	C	D	E	F	G	H	Oil Rec. Factor (%OOIP)	Inc. Oil Rec. Factor (%OOIP)	Stored CO <sub>2</sub> Volume (bcf)	NPV (MM\$)
47	D1	Cemented	300	300	1000	0.7	0.25	0	45.3	4.9	0.7	18.2
48	D2	Open-Hole	300	100	1300	0.7	0.75	1	55.3	13.2	2.9	38.1
49	D2	Cemented	400	100	1600	0.9	0.75	0	43.2	4.8	2.6	15.4
50	D2	Cemented	300	200	1000	0.5	0.25	0	44.1	5.0	0.7	20.3
51	D1	Open-Hole	200	300	1300	0.7	0.5	0	41.7	2.2	0.2	27.0
52	D2	Cemented	200	100	1600	0.7	0.5	0	43.4	3.2	0.3	21.2
53	D2	Open-Hole	400	100	1000	0.7	0.75	0	39.9	4.0	2.2	28.4
54	D2	Cemented	200	100	1300	0.9	0.75	1	52.6	10.5	2.5	23.9
55	D1	Cemented	200	300	1600	0.7	0.75	2	50.4	8.6	2.1	18.8
56	D1	Cemented	200	100	1000	0.5	0.25	0	47.0	6.0	0.9	23.4
57	D1	Cemented	200	200	1000	0.7	0.25	2	51.6	10.8	1.6	21.8
58	D1	Cemented	400	100	1000	0.9	0.5	2	58.4	16.0	3.3	15.3
59	D2	Open-Hole	200	200	1600	0.5	0.75	0	39.9	0.4	0.2	27.6
60	D2	Cemented	200	100	1000	0.5	0.75	2	52.0	11.6	2.4	25.7
61	D2	Open-Hole	400	200	1300	0.9	0.75	0	42.3	3.5	2.2	27.1
62	D1	Open-Hole	200	200	1600	0.7	0.25	1	52.3	10.2	1.4	30.5
63	D2	Open-Hole	400	200	1000	0.9	0.5	2	55.4	13.7	2.8	26.6
64	D2	Open-Hole	200	300	1600	0.5	0.5	2	43.6	4.2	1.4	24.0
65	D1	Cemented	400	200	1300	0.5	0.25	0	49.9	7.6	1.0	20.0
66	D1	Open-Hole	300	100	1000	0.9	0.5	1	58.2	15.5	2.0	28.1
67	D2	Open-Hole	400	100	1000	0.7	0.25	1	53.5	13.6	1.6	31.4
68	D2	Open-Hole	400	300	1000	0.7	0.5	0	44.6	4.1	0.7	25.5
69	D2	Open-Hole	300	300	1600	0.5	0.25	1	47.1	7.3	1.0	30.8
70	D2	Cemented	300	300	1300	0.9	0.5	1	48.9	7.7	1.9	15.0
71	D2	Cemented	200	200	1300	0.5	0.5	1	47.7	7.9	2.2	27.3
72	D1	Cemented	300	300	1000	0.5	0.75	2	52.9	12.1	2.5	20.0
73	D2	Open-Hole	200	200	1300	0.9	0.25	2	49.4	8.3	1.3	28.4
74	D1	Open-Hole	400	300	1600	0.9	0.5	1	58.8	13.5	2.0	24.1
75	D1	Cemented	300	100	1300	0.5	0.25	1	55.6	13.4	1.7	27.0
76	D2	Cemented	200	300	1600	0.5	0.25	0	40.0	0.5	0.3	8.6
77	D2	Cemented	300	300	1300	0.7	0.25	0	43.8	3.2	0.6	16.2
78	D1	Cemented	400	200	1000	0.9	0.25	1	54.1	12.8	1.6	14.9
79	D1	Open-Hole	400	200	1600	0.7	0.5	0	49.4	5.7	0.7	27.9
80	D2	Cemented	300	100	1600	0.7	0.25	2	54.3	12.9	1.7	24.1
81	D2	Cemented	400	200	1000	0.7	0.75	0	37.0	3.9	2.2	14.3
82	D1	Open-Hole	400	100	1300	0.7	0.5	0	49.7	5.8	0.7	29.4
83	D2	Cemented	300	100	1300	0.5	0.75	0	45.3	2.9	0.4	25.3
84	D2	Open-Hole	300	300	1600	0.7	0.25	1	46.8	6.9	1.1	26.4
85	D1	Cemented	400	300	1300	0.9	0.5	0	43.7	4.4	2.3	15.0
86	D2	Open-Hole	200	300	1000	0.5	0.75	0	38.6	1.4	0.2	22.7
87	D1	Open-Hole	200	200	1300	0.7	0.75	2	54.3	10.5	2.4	28.9
88	D1	Cemented	200	200	1000	0.9	0.75	0	45.1	3.5	0.2	19.5
89	D1	Cemented	300	300	1600	0.9	0.5	0	46.5	3.3	0.5	15.8
90	D2	Open-Hole	200	200	1000	0.7	0.5	1	46.9	7.9	2.2	31.1
91	D2	Cemented	400	100	1300	0.9	0.25	1	52.3	12.4	1.6	17.2
92	D2	Open-Hole	200	100	1000	0.7	0.25	2	51.6	11.3	1.5	34.6

**Table 4.** Sensitivity factors and response values for the selected runs (Continued)

Run	Factors								Responses			
	A	B	C	D	E	F	G	H	Oil Rec. Factor (%OOIP)	Inc. Oil Rec. Factor (%OOIP)	Stored CO <sub>2</sub> Volume (bcf)	NPV (MM\$)
93	D1	Open-Hole	300	300	1300	0.9	0.75	0	46.4	3.0	0.3	26.3
94	D2	Cemented	300	300	1000	0.9	0.5	2	48.8	8.6	1.9	14.4
95	D2	Open-Hole	200	300	1000	0.9	0.25	1	42.3	3.4	0.8	22.2
96	D2	Cemented	400	200	1300	0.9	0.75	2	53.4	12.4	2.6	15.1
97	D1	Open-Hole	300	200	1000	0.9	0.25	2	54.2	12.0	1.8	26.9
98	D1	Cemented	200	300	1000	0.5	0.5	1	49.4	8.8	1.4	21.0
99	D1	Open-Hole	200	100	1300	0.5	0.75	2	56.4	13.1	2.9	34.5
100	D2	Cemented	300	100	1000	0.7	0.5	1	55.9	14.7	1.9	25.1
101	D2	Cemented	200	300	1300	0.7	0.25	1	42.6	3.5	0.7	15.6
<b>102</b>	<b>D1</b>	<b>Open-Hole</b>	<b>400</b>	<b>100</b>	<b>1300</b>	<b>0.9</b>	<b>0.75</b>	<b>1</b>	<b>60.6</b>	16.0	<b>3.6</b>	28.2
103	D1	Cemented	400	300	1300	0.7	0.75	1	55.6	12.9	2.9	17.9
104	D1	Cemented	300	200	1600	0.5	0.5	2	56.3	13.5	2.8	23.6
105	D2	Cemented	400	100	1000	0.5	0.5	0	38.4	4.4	2.7	16.0
		average							50.1	8.8	1.7	24.4
		maximum							60.6	17.1	3.6	38.1
		minimum							37.0	0.4	0.2	8.6

**Table 5.** The proposed optimal values of factors

Factor Name	Max. Recovery Factor	Max. Stored CO <sub>2</sub> Vol., bcf	Max. NPV, mm\$
A. Well Pattern	D1	D1	D2
B. Well Completion	Open-Hole	Cemented	Open-Hole
C. Frac. Spacing, ft	400	400	290
D. Frac. Half-length, ft	100	110	100
E. P <sub>avg</sub> while WF, psi	1,530	1,590	1,360
F. WCUT while switch WAG	0.9	0.9	0.5
G. CO <sub>2</sub> slug size	0.75	0.75	0.45
H. WAG ratio	1.87	1.93	1.38
Response Value	Recovery Factor, %	60.8	56.1
	Stored CO <sub>2</sub> Vol., bcf	<b>4.2</b>	3.3
	NPV, mm\$	16.2	<b>38.9</b>

### 머신러닝 기법 적용

CCS-EOR 최적화 분석에서 머신러닝 기법의 적용성을 검토해 보기 위해 먼저, 최적화 모델을 개발하였으며, 다음으로 위에서 설명된 저류층 분석 자료를 활용하여 최적화 과정 및 결과를 비교하였다. 각각의 과정 및 결과는 다음과 같다.

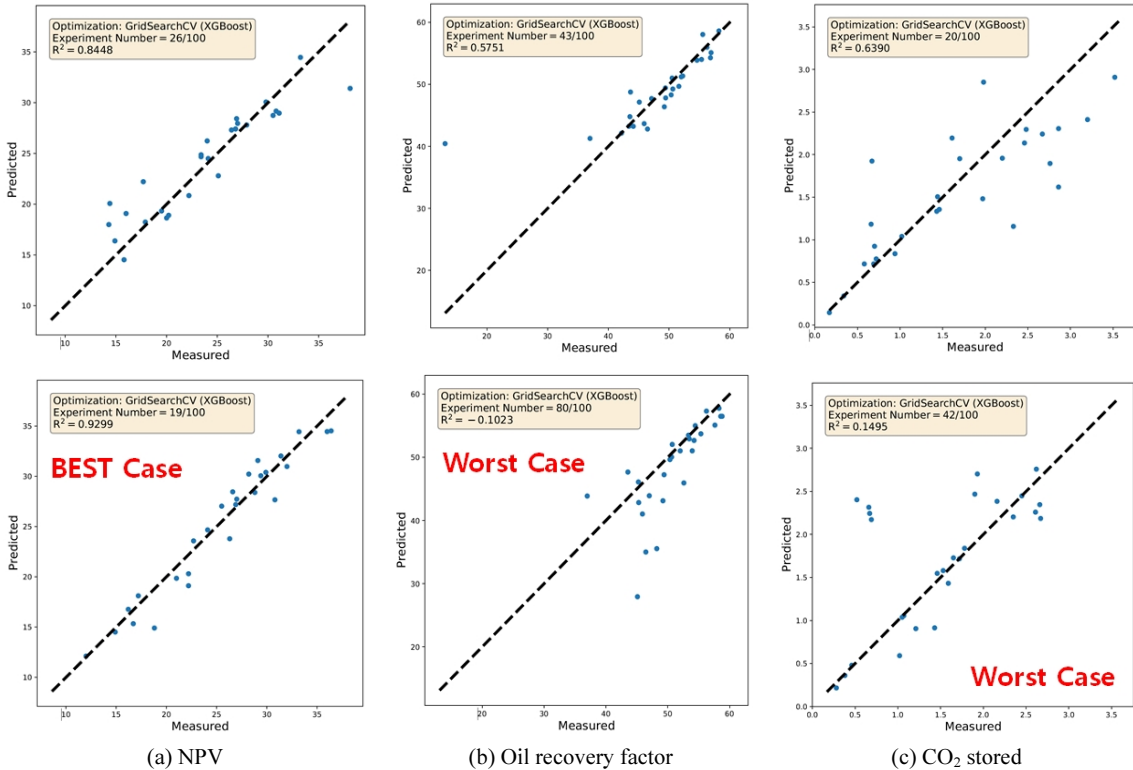
### 프록시 모델 개발 및 적용

위와 같은 형태의 최적화 문제는 머신러닝 기법에서 지도학습(supervised learning)의 분류(classification)에 해당된다. 즉, 학습 데이터로 주어진 데이터의 피쳐(feature)와

레이블(label) 값을 머신러닝 알고리즘으로 학습해 모델을 생성하고, 이렇게 생성된 모델에 새로운 데이터 값이 주어졌을 때 미지의 레이블 값을 예측하는 과정이다(Géron, 2019). 관련된 분석을 위해 다양한 패키지 활용이 가능한 파이썬 언어를 이용하였으며, 기본적으로 활용된 패키지는 pandas, numpy 및 scikit-learn이다. 최적화 모델로는 트리기반(decision tree) 앙상블 학습에서 가장 각광받고 있는 XGBoost 알고리즘을 사용하였다. 또한 결과 도시 및 엑셀 파일, PDF 형식 출력을 위한 matplotlib, openpyxl 등의 패키지가 활용되었다.

**Table 6.** The averaged accuracy in test procedure by GridSearchCV method

	Accuracy			Standard Deviation
	Mean	Min.	Max	
NPV	0.8485	0.6864	0.9299	0.0505
Oil Recovery Factor	0.5860	-0.1177	0.8881	0.2048
CO <sub>2</sub> Stored	0.6227	0.1495	0.8448	0.1317



**Fig. 2.** Example cases and the best/worst cases for (a) NPV, (b) Oil recovery factor, and (c) CO<sub>2</sub> stored.

**프록시 모델 적용결과 및 분석**

먼저 Table 4의 105개 자료를 범주형(categorical) 자료로 변환하였다. 즉, Table 2와 같은 8개의 변수 중 A(well pattern)와 같이 2개의 파라미터를 갖는 변수들은 0과 1의 자료형으로, C(fracture spacing)와 같이 3개의 파라미터를 갖는 변수들은 0, 1, 2의 자료형으로 변환하였다. 변환된 105개의 세트 자료를 scikit-learn 패키지의 train\_test\_split 함수를 활용하여 학습 및 테스트 자료를 분리하였다. 이때 활용된 최적화 모델은 XGBoost 패키지의 XGBRegressor 함수이며, 파라미터를 순차적으로 입력하여 최적의 파라미터를 선정하는 GridSearchCV 방법을 적용하였다. 여기서 테스트 사이즈는 0.25이며(학습에 활용된 자료 비율은 0.75), 학습자료에 대한 무작위 선택에 따른 오류를 최소화

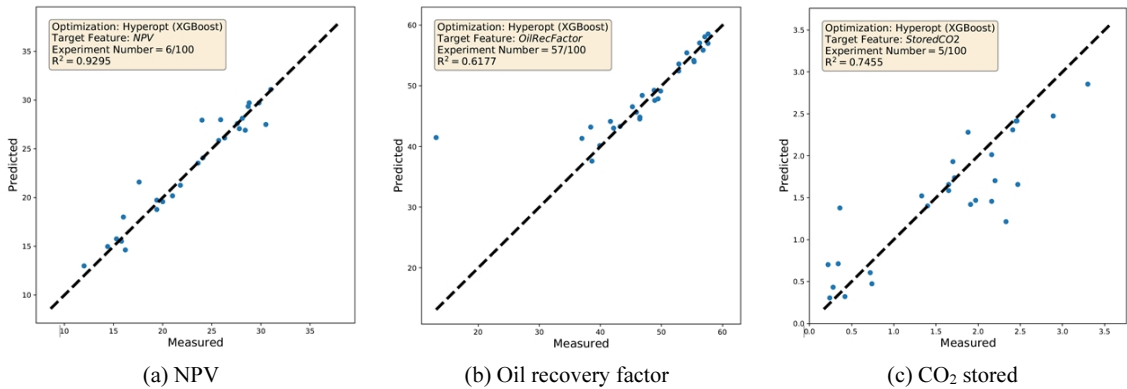
하기 위해 100회의 실험을 수행하여 이를 평균한 값을 대표값으로 선정하였다. 50회 이상의 실험 수행 시 평균값이 수렴되는 현상을 발견할 수 있었으나, 평균 및 표준편차 값의 대표성을 확보하기 위해 실험 횟수를 충분히 크게 설정하였다.

위의 방법으로 수행된 학습 및 테스트 결과는 Table 6과 같다. 목적함수가 NPV일 경우 100회 실험의 평균 정확도는 0.8485이며, 최소 0.6865, 최대 0.9299의 수치를 나타내었다. 이에 반해 오일 회수율과 CO<sub>2</sub> 저장량 항목은 평균 0.5860 및 0.6227을 보였으며, 특히 음의 값을 갖는 적합도(R-square)를 보이기도 하였다. Fig. 2는 각 100번의 실험 중 적합 특성을 나타내는 예를 보여주는 것으로, 그림의 상부는 평균치에 가장 가까운 경우를 예로 보여주고 있으며, 하부는 적합도가 가장 높은 경우와 가장 낮은 경우를 나타



**Table 7.** The averaged accuracy in test procedure by Hyperopt method

	Accuracy			Standard Deviation
	Mean	Min.	Max	
NPV	0.9279	0.8256	0.9779	0.0314
Oil Recovery Factor	0.7651	0.4431	0.9470	0.1496
CO <sub>2</sub> Stored	0.7396	0.3492	0.8942	0.1084

**Fig. 3.** Example cases of averaged test accuracy for (a) NPV, (b) Oil recovery factor, and (c) CO<sub>2</sub> stored.

내었다. 여기서, 평균값이 대표값을 갖지 못할 경우 적합도는 음의 값을 보이기도 하며, 특히 사용된 자료 중 이상치(outlier)의 영향이 클 경우 이와 같은 현상이 발생할 수 있다(Scikit-learn, 2020). NPV의 경우 어느정도 만족스러운 수준이나, 오일 회수율과 CO<sub>2</sub> 저장량의 경우 적합도가 떨어짐을 알 수 있으며, 이를 활용한 적절한 예측이 어려울 것으로 판단되어 학습 및 테스트 수행을 위한 초매개변수(hyper-parameter) 선정 방식을 다음과 같이 수정하였다.

앞서 수행한 GridSearchCV 함수의 초매개변수는 4개를 선정하였으며, 일정 범위 내에서 최적의 값을 탐색하는 방식이었기 때문에 최적값 도출에 한계가 있는 것으로 판단되었다. 이를 개선하기 위해 Hyperopt 함수를 활용하여 초매개변수의 범위를 확장하고 보다 많은 수의 초매개변수를 고려하였다. Hyperopt 함수의 튜닝(tuning) 알고리즘 중 Bayesian 방법을 사용하였으며, 이 방법은 격자탐색(grid search)이나 무작위탐색(random search) 방법에 비해, 사전 지식을 충분히 반영하면서 동시에 전체적인 탐색 과정을 체계적으로 수행할 수 있다는 장점을 가진다(Brochu *et al.*, 2010). Hyperopt 함수를 활용한 테스트 자료 정확도는 Table 7과 같다. 마찬가지로 100회의 실험을 통한 평균값은 NPV, 오일 회수율, CO<sub>2</sub> 저장량의 경우 각각 0.9279, 0.7651, 0.7396으로 산출되었다. 앞서 수행한 GridSearchCV 방법에 비해 정확도가 모두 증가한 것을 확인할 수 있으며, 각 목적함수에 대한 대표적인 자료 적합 특성을 Fig. 3에 도

시하였다. 각 그림은 평균에 가장 근사한 경우를 도시한 것으로, 그림에서와 같이 NPV의 경우 테스트 자료에 대한 적합이 매우 고르게 분포하고 있음을 알 수 있다. 그러나 오일 회수율의 경우 대부분의 테스트 자료가 고르게 적합되나 간헐적으로 이상치가 관측되는 특징을 보이기도 하였다. CO<sub>2</sub> 저장량의 경우 앞선 두가지 목적함수의 적합 분포에 비해 전체적으로 자료가 분산되어 있는 특징을 보인다.

위에서 관측된 특성을 토대로 추가적인 분석을 수행하였다. 즉, 각 목적함수에 대한 최적화는 동일한 8개의 인자가 활용되었으나, 인자의 특성을 살펴보면 각 목적함수에 미치는 영향정도가 상이한 것으로 판단된다. 목적함수를 최적화하기 위해 민감도가 큰 인자를 선별하는 과정이 필수적이므로, 우선 각 목적함수에 대한 인자들의 영향 정도를 파악하였다. NPV의 경우 학습/테스트 결과가 만족스럽기 때문에 오일 회수율 및 CO<sub>2</sub> 저장량 목적함수에 대한 인자들의 영향만을 파악하였다. 먼저 오일 회수율 학습에 기여한 인자들의 정도를 알아보았으며, 이를 위해 내장 함수인 “feature importance”를 활용한 결과는 Table 8과 같다. 상대적으로 영향 정도가 낮은 B, E, F, 및 G 인자 중에서 E와 F를 제외하였는데, 이는 Ghaderi *et al.*(2012)이 제시한 반응표면(response surface) 분석 결과를 동시에 참고하여 결정하였다. 반응표면 분석에 의하면 오일 회수율 목적함수에 대한 인자들의 영향 정도는 H, A, D, C, G 순으로 낮아진다. 두 개의 인자를 제외한 학습 및 테스트 결과, 적합도는

**Table 8.** The averaged feature importance values in Oil Recocery Factor calculation

	A	B	C	D	E	F	G	H
mean	0.21	0.05	0.11	0.11	0.06	0.06	0.06	0.34
standard deviation	0.05	0.03	0.03	0.04	0.03	0.03	0.02	0.08
minimum value	0.13	0.01	0.06	0.06	0.01	0.01	0.02	0.19
maximum value	0.34	0.14	0.19	0.24	0.15	0.16	0.11	0.51

**Table 9.** Maximum NPV cases and parameter combination

Cases	A	B	C	D	E	F	G	H	NPV
1961	D2	Open-Hole	<b>300</b>	100	1300	0.5	<b>0.50</b>	1	39.91
1493	D2	Open-Hole	<b>200</b>	100	1300	0.5	<b>0.50</b>	1	39.88
1496	D2	Open-Hole	<b>200</b>	100	1300	0.5	<b>0.25</b>	1	39.47

**Table 10.** Maximum Recovery Factor cases and parameter combination

Cases	A	B	C	D	G	H	Recovery Factor
320	D2	Cemented	300	300	0.50	1	60.62
29	D1	Open-Hole	400	100	0.75	2	59.61
26	D1	Open-Hole	400	100	0.50	2	59.49

0.9251, 표준편차는 0.0246으로 계산되었으며, NPV와 유사한 수준으로 적합도가 산출되었으며 약 20%의 적합도 향상이 가능하였다. 위의 과정과 동일하게 CO<sub>2</sub> 저장량 목적함수에 대한 분석을 수행하였으나, 유의미한 적합도 향상 결과를 획득하지 못하였다. 이는 CO<sub>2</sub> 저장량 목적함수 최적화를 위해 선정된 인자들의 개선 및 민감도 분석과정이 추가적으로 필요함을 보여준다.

#### 최적 목적함수 예측

먼저 입력자료로 활용된 105개의 시뮬레이션 결과를 살펴보면, Table 4에서와 같이 NPV의 경우 28번의 38.1 MM\$, 오일 회수율 및 CO<sub>2</sub> 저장량의 경우 각각 102번인 60.6%, 3.6 bcf를 보이고 있다. 앞선 과정을 통해 선정된 초매개변수를 기준으로 각 파라미터에 대한 목적함수를 예측하였다. 먼저 NPV의 경우, 8개 파라미터에 대한 2,916가지 경우의 NPV를 산출하여, 최대 NPV를 보이는 3가지 파라미터 조합을 Table 9에 정리하였다. 입력자료로 활용한 38.1 MM\$ 대비 약 5% 증가한 39.9 MM\$의 최대 NPV 산출이 가능함을 알 수 있으며, 파라미터 C, G를 제외한 나머지 파라미터는 최대 목적함수를 나타내는 3가지 경우에서 모두 고정된 양상을 보이기 때문에 영향인자에 대한 보다 명확한 분석 방향을 제시하고 있다.

다음으로 오일 회수율의 경우 E, F 파라미터를 제외한 6개 파라미터에 대한 최대값은 Table 10과 같다. 최대값은 60.62%로써 입력자료에 비해 향상된 값을 보이지 못하고 있으며, 이러한 현상은 CO<sub>2</sub> 저장량 경우에서도 유사한 양

상을 나타낸다. 목적함수 오일 회수율의 경우 6개 인자를 활용한 최적화가 만족할 만한 수준이나, CO<sub>2</sub> 저장량 목적함수 최적화는 상대적으로 신뢰성이 떨어짐을 알 수 있다. 이는 목적함수에 따른 영향 인자 선정이 개별적으로 이루어지거나, 보다 추가적인 영향인자 선정이 필요함을 보여준다.

기존 문헌 결과를 활용한 머신러닝 최적화 분석의 한계로 인해, 예측된 목적함수 최대값이 실제 시뮬레이션 결과와 어느정도 일치하는지에 대한 비교분석을 수행하지 못하였으나, 이 연구에서 제시된 값들은 기존 문헌의 최적화 방법을 통해 제시된 결과와 유사한 수준의 값을 보이고 있으므로, 신뢰성은 확보된 것으로 판단할 수 있다.

## 결론

이 연구에서는 CCS-EOR 최적화 분석에서 머신러닝 기법의 적용성을 검토해 보기 위해, 문헌 검토를 통한 기존 최적화 분석 필드 검토, 머신러닝 기반 저류층 최적화 모델 개발 및 적용성 검토 분석을 수행하였으며, 이를 통해 도출된 결론은 다음과 같다.

최근들어 다양하고 복잡한 형태의 저류층 운영방식이 고안되어 적용되는 시점에서 저류층 특성, 현장 운영 조건, 외부 환경 등을 동시에 고려한 효과적인 최적화 방안이 요구되고 있는 실정이며, 수반되는 과도한 계산량 문제를 해결하기 위해 시뮬레이션 수행 횟수를 최소화하고자 하는 노력들이 다양하게 진행되고 있다.

이 연구에서 제안한 머신러닝 최적화 과정은 학습에 필요한 최소한의 시뮬레이션 결과를 활용하여, 모든 경우의 시뮬레이션 결과를 예측할 수 있는 프록시 모델 개발 및 적용 과정을 제안하였다. 학습에 필요한 시뮬레이션 경우 수 및 영향인자 선정 등에 따라 머신러닝 학습 적합도는 차이를 보였으나, 목적함수에 대한 적절한 영향인자 선정 및 학습자료가 확보될 경우, 머신러닝 최적화 기법은 기존 기존의 최적화 과정을 대체할 수준의 매우 효과적인 방법임을 보여주고 있다.

목적함수 NPV에서와 같이 학습 및 테스트 과정은 매우 높은 적합도를 보여주었으며, 추가적인 시뮬레이션 수행 없이 가능한 모든 경우에 대한 결과 예측이 가능함을 알 수 있다. 또한 영향인자가 추가되어 경우의 수가 증가하더라도 비교적 쉽게 이에 대한 고려가 가능하므로, 다양하고 복잡한 저류층 운영조건에 대한 최적화 과정에 효과적으로 이용될 수 있을 것으로 판단된다.

## 사 사

본 연구는 한국지질자원연구원의 주요사업(20-3311, 국내 대륙붕 3차원 석유시스템 평가 및 세일가스전 EGR+ 원천기술 개발)의 일환으로 수행되었습니다.

## References

- Brochu, E., Cora, V.M., and de Freitas, N., 2010. A tutorial on bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. *arXiv: 1012.2599v1*.
- Clarkson, C.R. and Pedersen, P.K., 2011. Production analysis of western canadian unconventional light oil plays. *Presented at the Canadian Unconventional Resources Conference*, Calgary, Alberta, Canada, 15-17 November, SPE-149005.
- Ertekin, T. and Sun, Q., S.L., 2019. Artificial intelligence applications in reservoir engineering: a status check. *Energies*, 12, p.1-22.
- Ettehadtavakkol, A., Lake, L.W., and Bryant, S.L., 2014. CO<sub>2</sub>-EOR and Storage Design Optimization. *International Journal of Greenhouse Gas Control*, 25, p.79-92.
- Géron, A., 2019. *Hands-on Machine Learning with Scikit-Learn, Keras, and Tensorflow*, 2<sup>nd</sup> Edition, O`reilly Media, Inc.
- Ghaderi, S.M., Clarkson, C.R., and Chen, S., 2012. Optimization of WAG process for coupled CO<sub>2</sub> EOR-Storage in tight oil formation: an experimental design approach. *Presented at the SPE Canadian Unconventional Resources Conference*, Calgary, Alberta, Canada, 30 October -1 November, SPE-161884.
- Godec, M., Kuuskraa, V., Leeuwen, T., Melzer, L.S., and Wildgust, N., 2011. CO<sub>2</sub> Storage in depleted oil fields: the worldwide potential for carbon dioxide enhance oil recovery. *Energy Procedia*, 4, p.2162-2169.
- Kim, J, Kang, J., Park, C., Ahn, S., and Min, B., 2017. History matching of gas production rates integrated an artificial neural network with distance-based candidate selection. *Journal of The Korean Society of Mineral and Energy Resources Engineers*, 54(4), p.416-428.
- Kovscek, A.R. and Cakici, M.D., 2005. Geologic storage of carbon dioxide and enhanced oil recovery II: Co-optimization of storage and recovery. *Energy Conversion and Management*, 46, p.1941-1956.
- Min, B, Kwon, S., Park, G., Jeong, D., and Lee, H., 2020. Current status and prospects of artificial intelligence in the oil and gas exploration and production business. *Journal of The Korean Society of Mineral and Energy Resources Engineers*, 57(3), p.295-308.
- Montgomery, D.C., 2013. *Design and Analysis of Experiments*, 8th Edition, John Wiley & Sons, Inc.
- Perera, M.S.A., Gamage, R.P.G., Rathnaweera, T.D., Ranathunga, A.S., Koay, A., and Choi, X., 2016. A Review of CO<sub>2</sub>-Enhanced Oil Recovery with a Simulated Sensitivity Analysis. *Energies*, 9, p.481.
- Scikit-learn Machine Learning in Python, 2020.10.02., <https://scikit-learn.org>.



**이 원 석**

1993년 한양대학교 공과대학 자원공학과 공학사  
1995년 한양대학교 대학원 자원공학과 공학석사  
2000년 한양대학교 대학원 자원공학과 공학박사

현재 한국지질자원연구원 석유해저연구본부 책임연구원  
(E-mail; wslee@kigam.re.kr)



**홍 용 준**

2014년 서울대학교 공과대학 전기정보공학과 공학사  
2018년 서울대학교 대학원 전기정보공학과 공학석사

현재 주식회사에너지 기업부설연구소 연구소장  
(E-mail; youngjun.hong@enerzai.com)