

시추효율매개변수를 이용한 굴진율 예측 지도학습 모델 비교 연구

한동권¹ · 성유정² · 양윤정² · 권순일^{3*}

Comparative Study of the Supervised Learning Model for Rate of Penetration Prediction Using Drilling Efficiency Parameters

Dong-Kwon Han¹ · Yu-Jeong Sung² · Yun-Jeong Yang² · Sun-Il Kwon^{3*}

¹Post-doctoral Researcher, Department of Future Energy Engineering, Division of Environmental and Energy Engineering, Dong-A University, Busan, 49315 Korea

²Graduate student, Department of Future Energy Engineering, Division of Environmental and Energy Engineering, Dong-A University, Busan, 49315 Korea

^{3*}Professor, Department of Future Energy Engineering, Division of Environmental and Energy Engineering, Dong-A University, Busan, 49315 Korea

요 약

굴진율은 시추작업에서 효율성을 극대화하기 위한 중요한 변수 중 하나이다. 시추효율을 극대화하기 위해서는 시추속도를 향상시키는 것이 필요한데 시추 엔지니어에게 시추 중 문제를 확인할 수 있는 실시간 굴진율 예측이 중요하다. 굴진율은 시추스트링 회전속도, 비트하중, 시추이수 유량과 높은 상관성을 가지고 있다. 이 논문에서는 시추효율매개변수 자료를 통해 학습한 데이터기반 지도학습 모델을 이용하여 굴진율을 예측하였다. 회귀모델의 성능 평가 지표를 통해 비교한 결과 RF 모델의 RMSE가 4.20, MAPE는 9.08%로 예측성능이 가장 우수한 것으로 확인되었다. 제안한 방법은 실시간 시추운전가이드 시스템 구축 시 굴진율 예측 기반 모델로 활용될 수 있다.

ABSTRACT

Rate of penetration(ROP) is one of the important variables for maximizing the drilling performance. In order to maximize drilling efficiency, it is necessary to increase the drilling speed, and real-time ROP prediction is important so that the driller can identify problems during drilling. The ROP has a high correlation with the drillstring rotational speed, weight on bit, and flow rate. In this paper, the ROP was predicted using a data-driven supervised learning model trained from the drilling efficiency parameters. As a result of comparison through the performance evaluation metrics of the regression model, the root mean square error(RMSE) of the RF model was 4.20 and the mean absolute percentage error(MAPE) was 9.08%, confirming the best predictive performance. The proposed method can be used as a base model for ROP prediction when constructing a real-time drilling operation guide system.

키워드 : 굴진율, 시추스트링 회전속도, 비트하중, 시추효율매개변수, 지도학습

Keywords : ROP, Drillstring rotational speed, Weight on bit, Drilling efficiency parameters, Supervised learning

Received 15 July 2021, Revised 15 July 2021, Accepted 28 July 2021

* Corresponding Author Sun-Il Kwon(E-mail:sikwon@dau.ac.kr, Tel:+82-51-200-7766)

Professor, Department of Future Energy Engineering, Dong-A University, Busan, 49315 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.8.1032>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

석유 생산정의 시추는 석유산업에서 가장 중요한 작업 중 하나이고 비용소모가 큰 작업이다. 시추 효율성과 비용에 영향을 미치는 주요 요인 중 하나가 굴진율(rate of penetration; ROP)이다. 굴진율 개선에 따라 최대 30% 이상 비용을 감소시킬 수 있다고 제시된 바 있다 [1]. 굴진율에 영향을 미치는 요소로는 크게 6가지가 있는데 지층의 암종, 시추공 내 직경, 시추공 내 유압, 비트 하중(weight on bit; WOB), 시추스트링 회전속도(drillstring rotational speed; RPM)와 비트 종류이다[2]. 이 중 지층의 암종에는 암석 강도, 연마도, 불균질성, 투과도, 공극 압력(pore pressure) 등이 영향을 미친다. 궁극적으로 최소 비용을 통해 시추의 효율성을 높이기 위해서는 시추 매개변수와 굴진율 간 관계를 규명하고 최적화하는 작업이 필요하다[3][4]. 그러나 지층 요소는 지질학적 불확실성과 조정불가능한 운영변수들이기 때문에 시추작업의 최적화를 위한 굴진율 예측은 늘 어려운 문제이다. 굴진율을 예측하는 방법은 크게 두 가지로 나뉠 수 있는데 첫째, 물리적 기반의 수학적 토대로 만든 경험식 모델과 둘째, 데이터기반의 머신러닝 지도학습 모델을 사용하는 것이다. 경험식 모델은 굴진율에 영향을 주는 시추매개변수들의 상호작용을 고려하여 이를 관계식으로 도출한다. 그러나 실제 매개변수 간 비선형적인 요소를 하나의 관계식으로 모사하기에는 저류층 별 불확실성이 높고 유정 별 암종에 따른 지층특성이 상이하다. 이러한 단점을 보완하고자 새롭게 제시된 데이터기반의 굴진율 예측 모델 연구는 인근 유정에서 시추한 굴진율 데이터 이력을 학습자료로 활용하여 모델을 생성하고 이를 통해 생산 시추정의 굴진율을 예측하는 방식을 사용하는 연구가 수행되었다.

데이터기반 굴진율 예측 모델은 주로 신경망(neural network) 기반의 지도학습 기법을 통해 예측에 활용한 연구가 주로 수행되었다[5][6]. 최근에 석유 생산과 관련된 전반적인 분야에 걸쳐 디지털 오일필드(digital oil-field)라는 기존의 top down 방식의 모델링 기법을 대체보완하는 bottom up 방식의 데이터기반 머신러닝 알고리즘을 이용하는 연구들이 활발하게 진행되고 있다[7]. 그리하여 굴진율 예측도 ANN(artificial neural network), DT(decision tree), RF(random forest), SVM(support vector machine) 알고리즘 등 지도학습 모델을

이용하는 연구가 제시되었다[8][9]. 하지만 굴진율 예측을 통한 시추의 효율을 높이기 위해서는 실시간 예측이 가능한 모델이 요구되는데, 이것은 기존 암석의 물성이나, 물리검층 자료, 비트의 특성 등은 고정변수이거나 실시간으로 취득하기 어려운 변수이므로 굴진율 모델의 입력변수로 활용이 어렵다.

본 연구에서는 실시간으로 굴진율 예측 시 적합한 모델을 제안하고자 머신러닝 지도학습 알고리즘 중 회귀 분석이 가능한 SVM, GBM(gradient boosting machine), RF 모델과 경험적 기반의 MB&Y(modified Bourgoyne and Young) 모델을 실제 유정의 시추현장자료를 이용하여 비교분석하였다. 또한 시추효율매개변수 중 굴진율과 가장 상관성이 높은 중요변수를 도출하였다. 지도학습 모델의 최적 하이퍼파라미터를 찾기 위해 여러 연구에서 활용되고 있는 Grid Search 방법을 적용하였다 [10]. 또한 모델의 예측성능의 평가는 회귀모델의 대표적인 지표인 RMSE(root mean square error), MAPE(mean absolute percentage error)를 이용하였다.

본 논문의 2장에서는 연구에 사용한 학습데이터에 대한 구성에 대해서 설명하고, 3장에서는 지도학습 기반 굴진율 예측 모델 설계 방안에 대해 설명하고, 4장에서는 굴진율 예측 모델의 평가지표를 통해 성능을 평가하고 비교 분석한다. 마지막으로 5장에서는 결론으로 논문을 마무리한다.

II. 학습데이터 구성

2.1. 학습데이터 설명

본 연구에서 굴진율 예측 모델 개발에 활용한 자료는 호주 퀸즈랜드주(State of Queensland)의 육상 유전 중 생산시추가 완료된 A-생산정이다. 시추가 시작된 시점은 2012년 12월 29일이며 종료된 시점은 2013년 2월 15일로 총 시추 운영시간은 49일이다. 총 시추공 깊이는 2500m이고 오일이 생산되는 목표 저류층의 심도는 2100~2125m이다. 각 심도별 시추효율매개변수는 1m 당 취득하였으며 변수 별 총 취득데이터 개수는 2101개이다. 본 논문에 사용한 입력 및 출력 변수는 표 1과 같으며, 입력변수는 시추공 심도를 포함하여 총 6개, 출력변수는 굴진율이다. 본 연구에서 활용한 데이터 세트(data set)의 통계적 특성값을 표 2에 나타내었다.

Table. 1 Input and output data for ROP prediction model.

Data type	Data name
Input data	Depth (m)
	Weight on bit(WOB) (klb)
	Drillstring rotational speed(RPM) (rpm)
	Torque (kgf · m)
	Flow rate (gpm)
	Stand pipe pressure(SPP) (psi)
Output data	Rate of penetration(ROP) (m/hr)

Table. 2 Statistical analysis of drilling parameters dataset.

Data name	Min.	Max.	Avg.	Std.
WOB (klb)	0.70	45.02	14.74	7.48
RPM (rpm)	0.06	69.96	45.61	10.85
Torque (kgf · m)	502.38	10311.56	6693.01	2265.16
Flow rate (gpm)	129.00	461.58	321.21	66.49
SPP (psi)	211.11	2037.96	1054.59	368.18
ROP (m/hr)	4.90	72.76	34.34	11.99

2.2. 학습데이터 구성

지도학습 모델의 학습데이터는 크게 학습자료(training dataset)와 테스트자료(test dataset)로 구성되는데 학습자료의 샘플링에 따라서 과대적합 또는 과소적합이 우려되기 때문에 k-fold validation 같이 학습자료의 샘플링을 반복하여 모델의 안정적인 예측성능을 확보하기 위한 방법을 사용한다. 그러나 본 연구는 시추공 심도에 따른 학습자료를 구성하여 학습된 모델을 바탕으로 앞으로 시추가 될 심도의 굴진율을 예측하는 방법이기 때문에 k-fold validation 적용이 불가능하여 심도에 따른 학습자료의 양에 따라 모델의 예측력을 평가하고자 한다. 그림 1은 시추공 심도에 따른 굴진율 자료이며, 25m에서 1725m 범위(전체자료의 약 81%)를 학습자료(training

data)로 하였고 1726m에서 2125m(전체자료의 약 19%)는 비교검증 자료(test data)로 사용하였으며, 3개의 지도학습 모델과 1개의 경험적 모델의 회귀모델 평가지표 비교를 통해 예측모델의 적정성을 평가하였다.

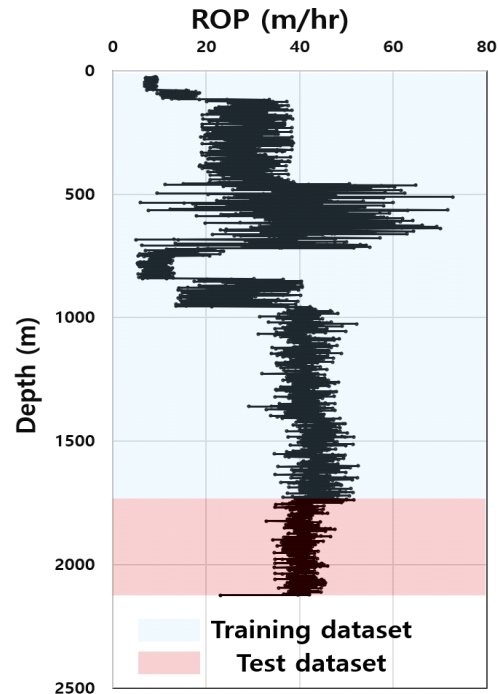


Fig. 1 Training and test data for field data

III. 굴진율 예측 모델 설계

3.1. 굴진율 예측 경험식

1950년대부터 굴진율과 WOB, RPM 사이의 상관성을 연구하고 경험식을 제시하였다. WOB, RPM과 더불어 비트의 직경과 연관된 경험적 지수를 추가한 식(1)과 같은 Bingham 모델[11], 지층강도와 공저압력차, 비트의 직경과 관련된 경험적 지수를 추가한 식(2)의 B&Y (Bourgoyne and Young) 모델이 대표적이다[12]. 8가지의 경험적 지수가 포함된 B&Y 모델의 경우 실시간 굴진율 예측 모델 적용 시 가용할 수 없는 시추매개변수들이 존재하기 때문에 이를 보완하기 위해 5가지의 중요 경험적 지수와 WOB, RPM, flow rate, 저류층 심도로 구성된 식 (3)의 MB&Y 모델이 제안되었다[13]. 1990년대

들어 PDC(polycrystalline diamond compact) 비트가 개발된 후 비트의 기하학적 형태와 지층의 압축강도 경험적 지수가 반영된 식 (4) Motahhari 모델도 대표적인 굴진을 예측 모델이다[14]. 국내에서는 상기 경험식의 단점을 보완한 새로운 회귀모델을 제안한 연구나[15] 석유생산현장이 아닌 건설 토목현장에서의 터널의 TBM 굴착 시 굴진율을 예측하는 연구들이 주를 이루고 있다 [16].

$$ROP = a \left(\frac{WOB}{d_b} \right)^b RPM \quad (1)$$

여기서 a와 b는 지층의 특성에 대한 무차원 상수값이고, d_b 는 비트의 직경이다.

$$ROP = \text{Exp} \left(a_1 + \sum_{j=2}^8 a_j x_j \right) \quad (2)$$

$$ROP = a_1 D^{a_2} WOB^{a_5} RPM^{a_6} q^{a_8} \quad (3)$$

여기서 D는 시추심도, q는 이수유량이고 a_1 - a_8 은 굴진율에 영향을 미치는 주요인자이며 표3에 정리하였다. 본 연구에서 분석에 활용한 MB&Y 모델은 Depth, WOB, RPM, Flow rate 4가지 입력변수를 필요하다.

$$ROP = W_f \left(\frac{GRPM^\gamma WOB^\alpha}{d_b S} \right) \quad (4)$$

여기서 W_f 는 시추비트 마모도이고 G는 비트와 암석 간 기하학적 연관성 지수, α 와 γ 는 굴진율 모델 관련 지수, S는 암석의 압축강도이다.

3.2. SVM model

SVM은 분류 및 회귀문제에 널리 활용되는 지도학습 모델로 데이터를 분류하는 Margin을 최대화시키는 결정경계(decision boundary)를 찾는 것을 기본 이론으로 하는 알고리즘이다. 기본 SVM은 분류 문제가 해결가능하기 때문에 회귀문제를 해결하기 위해서는 비선형 문제에서는 kernel 함수를 이용하여 고차원 공간에서는 선형문제로 변환하고 ϵ -무감도 손실함수를 추가로 적용한다. 본 연구에서는 Grid search 방법을 이용하여 최적의 하이퍼파라미터 값을 도출하였으며 분석 파라미터 범위와 이를 통해 도출된 최적값은 표 4와 같다.

3.3. GBM model

GBM은 Adaboost와 유사한 메커니즘을 가지고 있는 머신러닝 앙상블 기법을 사용하여 약한 학습기(weak learner)를 결합하고 틀린 것에 가중치를 부여하여 강한 학습기(strong learner)를 만드는 방식이다. 가중치는 gradient descent 알고리즘을 활용하여 계산한다. 이 최적화 알고리즘은 손실함수(loss function)를 정량화 해주는 역할을 하며 손실함수를 미분하여 기울기가 작아지는 방향으로 파라미터를 조정한다. GBM 모델의 하이퍼파라미터 분석 범위와 최적값은 표 5와 같다.

Table. 3 Exponent(a1-a8) description of Bouroyne and Young ROP model

Exponent	Description	Exponent	Description
a_1	formation strength	a_5	bit weight
a_2	normal compaction trend	a_6	rotational speed
a_3	under compaction	a_7	tooth wear
a_4	pressure differential	a_8	hydraulic

Table. 4 Hyperparameters of SVM model

Model	Search range	Optimum value
C	10~500	100
Epsilon	10^{-4} ~ 10^{-6}	10^{-5}
Gamma	10^{-3} ~ 10^{-5}	10^{-3}

Table. 5 Hyperparameters of GBM model

Model	Search range	Optimum value
Number of trees	10~500	300
Max depth	10~50	50
Min samples split	1~10	4
Min samples leaf	1~10	5

3.4. RF model

RF는 decision tree(DT) 기반의 앙상블 기법을 적용하여 DT 알고리즘의 과적합문제와 낮은 예측력을 해결하기 위해 만든 모델이다. 데이터 세트에서 무작위로 학습 자료를 추출하여 반복적으로 모델을 생성하고 이 중 다수결 투표를 통해 최적의 모델을 선정하여 예측을 수행하는 방식이다. RF 모델의 하이퍼파라미터 분석 결과는 표 6과 같다. RF 알고리즘은 출력변수와 입력변수 간의 상대적인 중요도를 나타내는 것도 가능한데, 이것은 학습 시 입력변수 중 가장 예측력 강한 변수가 무엇인지 도

출가능하다. RF 모델을 통해 산출된 굴진율 예측에 강한 영향도를 보이는 중요한 변수는 WOB이며, 다음으로 RPM, Depth, Flow rate, Torque, SPP 순서로 확인되었다 (그림 2). 분석결과를 통해 굴진율 예측 모델에 가장 낮은 영향력을 가진 SPP 변수를 제외한 5가지의 입력변수를 3 가지 지도학습 모델의 학습자료로 활용하였다.

Table. 6 Hyperparameters of RF model

Model	Search range	Optimum value
Number of trees	10~500	200
Max depth	10~50	30
Min samples split	1~10	5
Min samples leaf	1~10	3

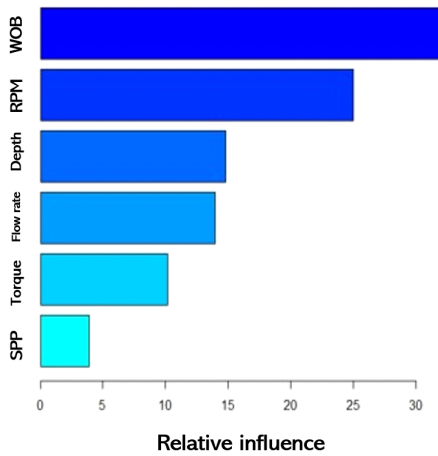


Fig. 2 importance variables obtained from Random Forest

IV. 성능평가 및 비교분석

3장에서 구성한 학습데이터 세트와 설계한 굴진율 지도학습 모델들과 경험적 모델인 MB&Y를 이용하여 예측성능을 비교분석하였다. 회귀모델의 예측 성능을 측정하는 일반적인 지표인 RMSE(식 (5))와 MAPE(식 (6))를 활용하였다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i - Y_i| \quad (6)$$

여기서 n은 데이터의 수, X_i 는 굴진율의 관측한 값, Y_i 는 모델을 통해 예측한 값이다.

표 7에 제시된 바와 같이 GBM 모델이 RMSE가 8.41, MAPE가 16.74%로 예측성능이 가장 낮은 것으로 확인되었고 MB&Y 모델은 RMSE가 7.14, MAPE가 11.99%였으며, RF, SVM은 RMSE와 MAPE가 유사하나 RF 모델이 RMSE가 4.20, MAPE가 9.08%로 가장 우수한 예측성능을 보이는 것으로 확인되었다.

그림 3은 테스트데이터 세트의 400개 관측값의 절대 백분율오차를 나타내는 박스플롯 그래프이다. 분석결과, MB&Y, RF, SVM의 MAPE값 차이가 약 7%로 오차가 크지 않는 것으로 볼 수 있다. 그러나 RMSE가 그림 3에서 보듯이 이상치로 분류되는 예측값이 많으며 RMSE 상대적 차이가 약 70% 이상으로 GBM에 더 가까운 예측력을 나타낸다. 이는 그림 4의 1725m에서 1775m 구간에서 볼 수 있듯이 실제값과 예측값의 오차가 크고, 오차변동성이 높은 것에 원인이 있는 것으로 확인되었다.

Table. 7 Accuracy of supervised learning models for ROP prediction.

Algorithm	RMSE	MAPE(%)
MB&Y	7.14	11.99
GBM	8.41	16.74
RF	4.20	9.08
SVM	4.58	9.74




Fig. 3 Absolute percentage error of ROP prediction models for test data sets

GBM 모델의 가장 낮은 예측력을 보인 원인은 1975m부터 2125m 구간의 오차값 때문인 것으로 확인되며 이 구간의 절대평균오차가 30% 이상 되는 것으로 나타났다.

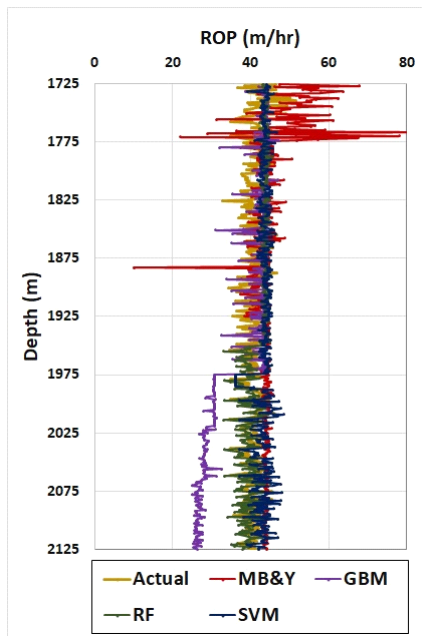


Fig. 4 Comparison of supervised learning models(GBM, RF, SVM) and empirical model(MB&Y) for ROP prediction.

V. 결 론

본 연구에서는 시추작업 시 실시간으로 취득될 수 있는 시추효율매개변수를 기반으로 다양한 머신러닝 지도학습 모델을 이용하여 굴진율을 예측하는 방안을 제시하였다. 지도학습 회귀모델은 GBM, RF, SVM을 이용하여 굴진율을 예측하는 방식을 사용하였고, 실시간 시추 굴진율 예측이 가능한 MB&Y 경험식과 비교분석하였다.

굴진율 예측 모델에 사용한 시추효율매개변수의 중요도를 파악하기 위해 랜덤포레스트 기반의 변수중요도 분석 결과 WOB가 가장 중요도가 높았으며 RPM, Depth, Flow rate 순서의 결과를 확인할 수 있었다. 테스트 세트 자료의 예측성능 분석을 통해 제안한 지도학습 모델의 높은 정확도를 나타내는 것으로 확인되었다. 제

시한 지도학습 모델 중 RF 알고리즘이 평가지표 결과 가장 우수한 것으로 확인되었다.

인근의 시추공 정보나 물리검층을 통한 심도별 지층 자료가 존재한다면 데이터 기반 모델의 예측력을 높일 수 있으며 향후 이에 대한 연구가 필요할 것으로 보인다. 본 연구를 통해 제안한 지도학습 모델과 연구결과는 실시간 시추운전가이드 시스템 구축 시 기반 모델로 활용될 수 있을 것으로 기대된다.

ACKNOWLEDGEMENT

This research was supported by Institute of Information & communications Technology Planning & Evaluation (IITP) grant funded by the Korea government (MSIT) (2019-0-01561-002, Development and Application of Artificial Intelligence Techniques for Geospatial Information Analysis)

REFERENCES

- [1] M. J. Kaiser, "Modeling the time and cost to drill an offshore well," *Energy*, vol. 34, no. 9, pp. 1097-1112, 2009.
- [2] C. Hedge and K. Gray, "Use of machine learning and data analytics to increase drilling efficiency for nearby wells," *Journal of Natural Gas Science and Engineering*, vol. 40, pp. 327-335, 2017.
- [3] C. Hedge, H. Daigle, and K. Gray, "Performance comparison of algorithms for real-time rate-of-penetration optimization in drilling using data-driven models," *SPE Journal*, vol. 23, no. 5, pp. 1706-1722, Oct. 2018.
- [4] J. H. Jung, D. K. Han, S. H. Kim, I. H. Yoo, and S. I. Kwon, "Analysis of Technical Trend for Drilling ROP Optimization with Artificial Intelligent," *Journal of the Korean Institute of Gas*, vol. 24, no. 1, pp. 66-75, Feb. 2020.
- [5] A. Esmaili, B. Elahifar, R. K. Fruhwirth, and G. Thonhauser, "ROP modeling using neural network and drill string vibration data," in *Proceeding of the SPE Kuwait International Petroleum Conference and Exhibition*, Kuwait City, Dec. 2012.
- [6] X. Shi, G. Liu, X. Gong, J. Zhang, J. Wang, and H. Zhang, "An efficient approach for real-time prediction of rate of penetration in offshore drilling," *Mathematical Problems in*

- Engineering*, vol. 2016, pp. 1-13, Nov. 2016.
- [7] D. Han and S. Kwon, "Development of Productivity Prediction Model according to Choke Size and Gas Injection Rate by using ANN(Artificial Neural Network) at Oil Producer," *Journal of the Korean Institute of Gas*, vol. 22, no. 6, pp. 90-103, Dec. 2018.
- [8] H. R. Ansari, M. J. Hosseini, and M. Amirpoir, "Drilling rate of penetration prediction through committee support vector regression based on imperialist competitive algorithm," *Carbonates Evaporites*, vol. 32, pp. 205-213, 2016.
- [9] C. Hedge, H. Daigle, H. Millwater, and K. Gray, "Analysis of rate of penetration(ROP) prediction in drilling using physic-based and data-driven models," *Journal of Petroleum Science and Engineering*, vol. 159, pp. 295-306, Nov. 2017.
- [10] J. Choi, H. Yang, and H. Oh "Store Sales Prediction Using Gradient Boosting Model," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 25, no. 2, pp. 171-177, 2021.
- [11] M. G. Bingham, "How rock properties are related to drilling," *Oil Gas Journal*, vol. 62, pp. 94-101, 1964.
- [12] A. T. Bourgoyne and F. S. Young, "A multiple regression approach to optimal drilling and abnormal pressure detection," *SPE Journal*, vol. 14, pp. 371-384, 1974.
- [13] C. Soares and K. Gray, "Real-time predictive capabilities of analytical and machine learning rate of penetration (ROP) models," *Journal of Petroleum Science and Engineering*, vol. 172, no. 5, pp. 934-959, Jan. 2019.
- [14] H. R. Motahhari, G. Hareland, and J. A. James, "Improved drilling efficiency technique using integrated PDM and PDC bit parameters," *Journal of Canadian Petroleum Technology*, vol. 49, no. 10, pp. 45-52, 2010.
- [15] Y. B. Seo, "A model for the Prediction of Penetration Rate Using Myanmar Field Data," M. S. dissertation, Seoul National University, Seoul, Republic of Korea, 2008.
- [16] T. H. Kang, S. W. Choi, C. Lee, and S. H. Chang, "A Study on Prediction of EPB shield TBM Advance Rate using Machine Learning Technique and TBM Construction Information," *Tunnel & Underground Space*, vol. 30, no. 6, pp. 540-550, Dec. 2020.



한동권(Dong-Kwon Han)

2011년 2월 동아대학교 에너지자원공학과 공학사
 2013년 2월 동아대학교 에너지자원공학과 공학석사
 2018년 8월 동아대학교 에너지자원공학과 공학박사
 2018년 9월~현재 동아대학교 환경에너지공학부 미래에너지공학전공 박사후연구원
 ※관심분야: 클린가스, 비전통에너지, 빅데이터 분석, 딥러닝, 머신러닝, 등



성유정(Yu-Jeong Sung)

2019년 2월 동아대학교 에너지자원공학과 공학사
 2021년 8월 동아대학교 에너지자원공학과 공학석사
 ※관심분야: 딥러닝, 머신러닝, 토양환경, 수질환경, 신재생에너지, 등



양윤정(Yun-Jeong Yang)

2019년 2월 동아대학교 에너지자원공학과 공학사
 2021년 8월 동아대학교 에너지자원공학과 공학석사
 ※관심분야: 딥러닝, 머신러닝, 토양환경, 수질환경, 신재생에너지, 등



권순일(Sun-Il Kwon)

1999년 2월 한양대학교 자원환경공학과 공학사
 2001년 2월 한양대학교 지구환경시스템공학과 공학석사
 2006년 8월 한양대학교 지구환경시스템공학과 공학박사
 2006년 8월~2008년 2월 한국석유공사
 2008년 3월~현재 동아대학교 환경에너지공학부 미래에너지공학전공 교수
 ※관심분야: 에너지천연가스 개발, 빅데이터 분석, 딥러닝, 머신러닝, 등