



## 인공지능을 적용한 시추 굴진율 최적화 기술 동향 분석

정지현 · 한동권\* · 김상호\*\* · 유인항 · †권순일\*\*\*

(주)아이에치케이, \*동아대학교 에너지자원공학과 박사후연구원,

\*\*동아대학교 에너지자원공학과 석사후연구원, \*\*\*동아대학교 에너지자원공학과 교수

(2019년 12월 12일 접수, 2020년 2월 18일 수정, 2020년 2월 19일 채택)

### Analysis of Technical Trend for Drilling ROP Optimization with Artificial Intelligent

Ji-hun Jung · Dong-kwon Han\* · Sang-ho Kim\* · In-hang Yoo · †Sun-il Kwon\*

IHK, Seoul 07556, Korea

\*Dept. of Energy and Mineral Resources Engineering, Dong-A University,  
Busan 49315, Korea

(Received December 12, 2019; Revised February 18, 2019; Accepted February 19, 2020)

#### 요약

시추는 석유자원 탐사와 개발에서 가장 중요하며 많은 비용이 소요되는 필수 작업이다. 그래서 시추의 효율 향상을 위한 굴진율 연구가 지속적으로 진행되어왔다. 근래에는 전통적인 수학적 모델의 단점을 극복하기 위하여 새로운 방식의 자료기반 모델이 다양한 연구자들에 의해 개발되고 있다. 자료기반 모델은 알고리즘과 매개변수의 선택이 매우 중요하다. 또한 개발된 모델의 성능향상을 위하여 실시간으로 모델을 재훈련하여 연속적인 시추작업을 실현해야한다. 이 논문에서는 최신 연구들을 조사하여 시추 최적화에서 사용된 알고리즘, 시추 매개변수, 모델 재훈련 간격에 대한 정보를 제공하고자 한다.

**Abstract** - Drilling operation is the most important and costly essential work in oil and gas exploration and development. Therefore, the studies about rate of penetration have been carried out continuously to improve drilling efficiency. In recent years, data-driven models have been developed by various researchers to overcome disadvantages of traditional mathematical models. For the data-driven models, selecting proper algorithms and parameters is very important. In addition, data-driven models should be retrained in real-time during continuous drilling operations in order to improve the model performance. In this paper, the latest studies are investigated to provide information about algorithms, drilling parameters and model re-training intervals that used in drilling optimization.

**Key words :** Drilling optimization, Drilling parameter, Rate of penetration, Real time drilling optimization

#### I. 서 론

시추는 석유가스자원 탐사와 개발에서 가장 중요한 작업 중 하나이며 많은 비용이 소요되는 필수

작업으로, 시추 비용은 전체 개발 비용의 25-35%를 차지한다고 알려져 있다. 시추작업의 궁극적인 목표는 시추공내 안정성이 확보된 상태에서 최소한의 비용으로 시추 효율을 극대화하는 것이다. 그러나 지층의 불확실성과 복잡하게 연결된 다양한 운영 요인 때문에, 시추 최적화는 석유 산업에서 중요한 도전과제이다[1,2].

†Corresponding author:sikwon@dau.ac.kr

Copyright © 2019 by The Korean Institute of Gas

지난 몇십년 동안, 석유자원의 경제적 가치를 감안하여 시추 비용에 영향을 미치는 변수들을 모델링함으로써 시추 최적화 수행을 위해 상당한 노력을 진행해 왔다[3,4]. 여기서 굴진율(Rate of Penetration; ROP)은 시추 최적화에 있어서 다양한 매개변수를 통합한 핵심적 지표이다. 굴진율을 개선하게 되면 시추 작업시간을 대폭 감소시킬 수가 있으므로[5], 목적함수(굴진율)는 최대화되어야 한다[6]. 이러한 굴진율의 개선으로 작업속도를 향상시켜 유정 비용의 최대 3분의 1까지 영향을 줄 수가 있다고 알려져 있다[7].

오늘날 석유산업 분야에서 시추 최적화를 위하여 수행되는 굴진율 모델링은 전통적이며 물리적 또는 경험적 기반의 분석 모델과 자료기반(Data-driven) 모델로 크게 나눌 수 있다[4]. 여기서 전통적 분석 모델은 반경험적 방법을 사용하여 굴진율을 예측하는 반면[8,9], 자료기반 모델은 굴진율 예측을 위해 기계학습(Machine learning) 알고리즘을 사용한다[10]. 전통적 분석 모델은 굴진율을 최적화하기 위하여 굴진율에 영향을 주는 다양한 변수들 각각의 상호작용에 기초하지만, 이 과정의 대부분은 인간의 경험과 실험실에서 도출한 경험적 관계에 의해 결정된다. 이런 이유로 발생하는 불확실성과 자료의 공백으로 인하여 모델의 생성이 어려울 뿐만 아니라 현장 적용에 한계가 있다고 알려져 있다[7,10-12]. 또한 이상 값에 영향을 크게 받는 매개변수가 많아서 정확하고 범용적인 모델을 제시하기 매우 어렵다는 한계가 있다[13].

굴진율 분석 모델의 단점으로 인하여 새로운 방식의 자료기반 모델이 다양한 연구자들에 의해 개발되고 있다. 자료기반 모델은 공학에서 복잡한 개념을 모델링하는 효율적인 대안으로 제시되고 있다. 자료기반 접근법은 운영의 효율성을 향상시키기 위해 모델에서 제어 가능한 일부 입력 매개변수를 최적화하는 것이 일반적인 방식이다[14]. 시추 최적화 분야에서는 시추를 통해 확보한 실제 자료를 바탕으로 다양한 기계학습 알고리즘을 사용하여 굴진율을 예측하고, 굴진율을 최적화하기 위해 매개변수들을 최적화하는 방식으로 연구들이 진행되고 있다. 이에 본 논문에서는 현재까지 시추 운영 최적화에 기계학습을 활용한 사례들을 조사하고 이를 분석, 정리하여 기계학습을 활용한 시추 운영 최적화 연구의 기본 정보를 제공하고자 한다.

## II. 전통적 굴진율 분석 모델

1950년대와 1960년대 초에는 굴진율, 비트의 하중

(Weight on Bit; WOB), 회전속도(Rotary speed, RPM)와 관련된 많은 기초적인 경험식들이 제안되었고 R-W-N(ROP-WOB-RPM) 관계로 그룹화 되었다. 다음은 굴진율을 예측하는 대표적인 경험식에 대해 알아보고자 한다.

Murray and Cunningham(1955)에 의해 굴진율 예측모델에 WOB 지수를 포함시키는 방식이 처음 제시되었다[15]. Maurer(1962)는 다른 연구들에 의해 제안된 9개의 R-W-N 관계를 도출하였다[16]. Rowley et al.(1961)은 WOB 항과 RPM 항을 조합하여 R-W-N 관계를 더욱 발전시켰다[17]. Bingham(1964)은 굴진율, WOB, RPM 및 비트 직경 사이의 단순한 관계에 WOB와 관련된 경험적 지수를 추가함으로써, 이전 연구들의 R-W-N 관계의 적용 범위를 더욱 넓혔다[18]. Bourgoyn and Young(1974)이 제안한 굴진율 예측모델(Bourgoyn and Young model; BYM)은 가장 성공적인 수학 모델 중 하나로써 널리 사용되었다[19,20]. BYM 모델은 굴진율에 영향을 미치는 인자를 지층 강도(formation strength), 공저의 압력차, 비트의 직경과 하중, 비트의 회전속도, 비트 마모도, 비트 분사압으로 나타내었다. BYM은 둘러운 비트를 사용하는 회전식 시추 조건에만 적합한 모델이다. 그러나 이후 PDC(Polycrystalline Diamond Compact) 비트가 널리 활용되면서, BYM을 수정하여 PDC 비트에서도 적용 가능한 경험식을 제안하는 연구가 많이 수행되었다[21-24]. Hareland and Rampersad(1994)는 PDC 비트 사용 시 활용되는 모델(Hareland and Rampersad; HRM)을 개발하였으며 커터의 형태에 대한 변수, 커터날의 개수, 커터 하나가 암석에 접촉하는 면적, 비트직경을 사용하였다[25]. Motahhari et al.(2010)은 PDC 비트 사용 시에 HRM과 추가변수들을 이용해 굴진율을 예측하는 모델을 제안하였는데 비트의 기하학과 상호작용, 관련된 모델 계수, 굴진율 모델 지수, 일축암축강도를 사용하였다[26]. 몇몇의 다른 연구에서는 굴진율을 암석의 강도 같은 암석 특성과 연관시키려고 했다[27]. 또한 기존의 수학적 모델에서 불확실한 지수 및 상수를 구하기 위하여 최적화 알고리즘을 이용한 연구를 수행하기도 하였다[28-30]. 그 밖에도 굴진율과 관련하여 수학적 모델, 비트의 성능진단, 시추 시뮬레이션, 피트당 비용분석, 비트 기록 분석 등의 다양한 변수들이 추가되어 연구가 진행되었다[7].

수학적 또는 결정론적 최적화 모델은 연산시간 제약 없이 실시간으로 매개변수를 최적화 할 수는 장점이 있다[31]. 그러나 60년 가까이 지속적인 연구에도 불구하고, 수학적으로 정립된 모델의 공동

적인 문제점은 하나의 식으로 전체 지층에 대한 굴진율을 예측하는 것이다. 실제로는 굴진율과 관계된 매개변수들의 복잡하고 비선형적 거동 때문에 정확하고 범용적인 추정을 할 수 없다[32]. 허나 기존의 연구들에서 굴진율과 관련 매개변수의 관계

**Table 1.** Drilling variables for four analytical ROP models divided into data types[33]

Analytical ROP Model	①	②	③	④	
<b>Operational Variables</b>					
Weight-on-Bit, <i>WOB</i>	○	○	○	○	
Rotary Speed, <i>RPM</i>	○	○	○	○	
Flow Rate, <i>q</i>	○				
Well Depth, <i>D</i>	○				
Equivalent Circulating Density, $\rho_e$	○				
Bit Wear, <i>h</i> or $W_f$	○	○	○		
<b>Rock Properties</b>					
Pore Pressure Gradient, $g_p$	○				
Unconfined Compressive Strength, $\alpha$		○			
Confined Compressive Strength, $S$			○		
<b>Bit Properties</b>					
Bit Diameter, $d_b$	○	○	○	○	
Bit Nozzle Diameter, $d_n$	○				
<b>PDC Cutters Design Properties</b>					
Number of Cutter, $N_c$		○	○		
Cutter Diameter, $d_c$		○			
Cutter Siderake Angle, $a$		○			
Cutter Backrake Angle, $\theta$		○			
<b>Drilling Fluid Properties</b>					
Mud Density, $\rho$		○			
Apparent Viscosity at 10,000 sec-1, $\mu$	○				
① Bingham(1964) ② Bourgoine and Young(1974) ③ Hareland and Rampersad(1994) ④ Motahhari et al.(2010)					
surface measurements available in real-time		uncertain data availability in real-time		constant during a bit run	

가 정립된 연구결과는 Table 1과 같이 기계학습을 활용한 굴진율 최적화의 매개변수를 선정함에 있어서 귀중한 기초자료가 되고 있다.

### III. 인공지능 기반 굴진율 예측

최근의 낮은 유가와 기존 경험적 분석 모델의 단점을 보완하기 위하여, 기계학습을 적용한 방법이 굴진율 향상을 위한 시추 최적화에서 크게 각광받고 있다. 컴퓨터 기술과 통신의 발전으로 수집한 현장 자료를 기계학습으로 적용한 방법은 광범위한 범위에서 엄청나게 기여하고 있다. 그러나 다양한 분야에서 널리 적용되고 인정받는데 비해 석유가스 산업에서는 보수적인 성향과 자료의 보안에 대한 우려로 충분히 적용되지 못하였다[34]. 그러나 현재는 석유가스 산업에서도 꾸준한 발전을 이루고 있다.

일반적으로 시추작업자는 과거 경험 또는 시추 프로그램에 따라 WOB, RPM, 이수의 유량(Mud flow rate)을 조절하며, 긴 시간 동안 일정하게 값을 유지한다. 그러나 일정한 시추 매개변수를 유지하면 시추의 진행효율이 감소하게 된다. 그 이유는 습동(Stick-slip) 진동으로 굴진율이 감소하고 시추 에너지(Drilling Specific Energy; DSE)가 높아지며 공저장비(Bottom-Hole Assembly; BHA)가 손상될 가능성이 높아지기 때문이다. 또한 시추작업자가 복잡하게 연관된 매개변수를 직관적으로 파악할 수 없으므로 예상보다 굴진율이 저하될 수 있다 [35]. 이런 제한요소 때문에 시추 매개변수를 활용한 기계학습 굴진율 개선 모델이 주목 받고 있다.

자료기반 모델에서는 기계학습을 활용하여 굴진율을 목적함수로 출력자료를 선정한다. 목적함수를 출력하기 위하여 다양한 입력 자료가 고려되는데, 다음의 자료들은 선행연구의 분류이다. AL-Rashidi (2011)은 굴진율에 영향을 미치는 4가지로 장비(비트), 공내 환경(이수, 조정불가(지층 등)와 운영(지

**Table 2.** Parameters controlling ROP[7]

Factors effecting ROP			
Hardware	Environmental	Uncontrollable	Operational
Bit type	Mud type	Formation type/lithology	Rotary speed
Bit design	Mud density	Formation properties	Mud flow rate
Bit wear state	Mud properties	Equivalent circulation density	Weight on bit
Bit hydraulic			Torque
Bit nozzle arrangement			

**Table 3.** ROP related drilling parameters classification[3]

Rig and bit related parameters	Formation parameters	Drilling fluid properties
Weight on bit(WOB)	Local stresses	Mud weight
Torque	Hardness	Viscosity
Rotary speed(RPM)	Mineralogy	Filtrate loss
Flow rates	Porosity and permeability	Solid content
Pump stroke speed(SPM)	Formation abrasiveness	Gel strength
Pump pressure	Drillability	Mud pH
Hook load	Depth	Yield point
Bit wear	Temperature	
Type of the bit	Unconfined compressive strength(UCS)	

**Table 4.** Some of the parameters known to affect the ROP[13].

ROP	Personal efficiency	<ul style="list-style-type: none"> <li>· Competence</li> <li>· Psychological factors</li> </ul>
	Formation characteristics	<ul style="list-style-type: none"> <li>· Compressive strength</li> <li>· Hardness and/or abrasiveness</li> <li>· In-situ stress</li> <li>· Permeability</li> <li>· Porosity</li> <li>· Mineral composition</li> <li>· Temperature</li> </ul>
	Operating condition	<ul style="list-style-type: none"> <li>· Weight on bit</li> <li>· Rotary speed</li> <li>· Bit type</li> <li>· Torque</li> </ul>
	Drilling fluid properties	<ul style="list-style-type: none"> <li>· Density</li> <li>· Rheological flow properties</li> <li>· Filtration characteristics</li> <li>· Solid content</li> <li>· Solid size distribution</li> <li>· Chemical composition</li> </ul>
	Bit hydraulics	<ul style="list-style-type: none"> <li>· Bottom hole cleaning</li> <li>· Bit teeth cleaning</li> </ul>
	Rig efficiency	<ul style="list-style-type: none"> <li>· Repair and maintenance</li> <li>· Proper size</li> <li>· Ease of operation</li> </ul>

상) 요소로 분류하고 매개변수를 구분하였다(Table 2)[7]. Shi et al.(2016)은 리그와 비트, 지층, 이수에 관련된 3가지로 분류하고 매개변수를 구분하였다(Table 3)[3]. Anemangely et al.(2018)은 분류는 Table 2과 매우 유사하나 개인과 리그의 효율(Personal & Rig efficiency)처럼 정량화하기 어려운 분류를 추가하였다(Table 4)[13].

이렇듯 굴진율에 영향을 미치는 인자는 다양하나 시추 작업 중에 굴진율을 개선하기 위하여 변경할 수 있는 매개변수는 그렇게 많지 않다. 다양한 매개변수 중에서도 연구자가 관심을 가지는 부분은 자료의 신뢰도, 획득의 용이성, 매개변수의 조정 가능 여부일 것이다. 오늘날에는 Logging While Drilling (LWD)를 이용하여 시추 작업 중에 지층의 매개변수를 측정하여 사용할 수 있다[36, 37].

Table 5는 매개변수 간의 복잡한 관계와 모델의 선정에 참고할 수 있도록 Shi et al.(2016)이 조사한 각 연구별 사용한 모델과 입력 자료에 최근의 연구를 조사하여 추가적으로 정리한 표이다[3].

Table 5의 분류에도 불과하고 다양한 모델과 매개변수가 복합적으로 적용되어 있어 각 연구의 장단점을 비교하기는 힘들다. 그리고 모든 상황에서 적용 가능한 단일한 굴진율 모델은 없다[33]. 그러나 연구의 추이를 살펴보면 전통적인 인공신경망 (Artificial Neural Network; ANN) 모델에서 다양한 방법의 모델로 적용성이 넓어지고 있다. 이유는 전통적인 ANN의 느린 훈련 속도와 과적합 현상 때문에 속도 및 정확도에서 성능이 우수한 모델을 다양하게 적용하고 있기 때문이다. 연산속도는 실시간 시추에서 재훈련에 소요되는 시간 때문에 중요한 제한 요소이다. 다양한 매개변수 수의 조합이 입력 자료로 사용될 수 있는데, Anemangely et al.(2018)의 연구에서는 입력 매개변수의 수가 증가하면 오류가 감소하는 경향이 나타나는데 5개 이상의 입력 매개변수를 사용은 큰 의미가 없는 것으로 나타났다[13]. 그러므로 시추 최적화를 위하여 모든 자료를 반드시 획득할 필요는 없으며 획득이 용이하며 신뢰성이 높고 노이즈가 적은 자료를 사용해야 할 것이다.

굴진율과 관련된 매개변수는 매우 다양하며 지역적인 특성에 따라서 관계성이 다르게 도출될 수 있다. Table 5에서 가장 많이 사용된 매개변수는 WOB, RPM, 이수 유량이다. 그리고 지표에서 지속적으로 조정할 수 있는 세 가지 중요한 매개변수도 WOB, RPM, 유량이다[33]. 즉, 굴진율 개선을 위하여 시추작업자에게 주어지고 변경할 수 있는 변수이므로 시추 최적화에서 가장 중요한 매개변수로 볼 수 있다. 일부 연구에서는 WOB와 이수 비중 (Mud weight)이 굴진율 예측에 가장 영향을 미치는 주요 요소로 조사되었다[45,52-54]. 그러나 이수 비중은 시추공의 설계과정에서 미리 정해지는 요소로써 주로 시추공의 안정성을 위하여 우선 조정되기

**Table 5.** Summary of ROP prediction models with artificial intelligence

Reference	Model	Input number	Input Parameter	Output Parameter
Bilgesu et al.(1997)[38]	ANN	9	Formation drillability, Formation abrasiveness, Bearing wear, Tooth wear, Pump rate, Rotating time, Rotary torque, WOB, and RPM	ROP
Bahari and Seyed(2007) [28]	Fuzzy	4	UCS, Rock quality designation, Bit Load, and Bit rotation	ROP
Moran et al. (2010)[39]	ANN	6	Rock strength, Rock type, Abrasion, WOB, RPM, and Mud weight	ROP and wear
Bataee and Mohseni (2011)[2]	ANN	4	Bit diameter, WOB, RPM, and Mud weight	ROP
AL-Rashidi (2011)[7]	ANN	4	Depth, WOB, RPM, and Flow rate	ROP
Zhang et al. (2012)[40]	AHP, BPANN	9	UCS, Bit size, Bit type, Drillability coefficient, Gross hours drilled, WOB, RPM, Drilling mud density, and Apparent viscosity	ROP
Jahanbakhshi et al.(2012) [41]	ANN	20	Differential pressure, Hydraulics, hole depth, Pump pressure, Density of the overlying rock, Equivalent circulating density, Hole size, Formation drillability, Permeability, Porosity, Drilling fluid type, Plastic viscosity of mud, Yield point of mud, Initial gel strength of mud, 10 min Gel strength of mud bit type and its properties, WOB, RPM, Bit wear, and Bit hydraulic power	ROP
Amar and Ibrahim (2012)[42]	RBF, ELM	7	Depth, Bit weight, RPM, tooth wear, Reynolds number function, Equivalent circulating density, and Pore gradient	ROP
Monazami et al.(2012)[43]	ANN	13	Drill collar outside diameter, Drill collar length, Kick of point, Azimuth, Inclination angle, WOB, Flow rate, RPM, Mud weight, Solid percent, Plastic viscosity, Yield point, and Measured depth	ROP
Bodaghi et al.(2015)[44]	BPANN, hybrid SVRs	11	Mud viscosity, Mud weight, Pump rate, Pump pressure, Angle of well deviation, RPM, WOB, Interval drilled, Formation lithology, Bit size, and Tooth wear	ROP
Shi et al.(2016)[3]	ELM, USA	10	Bit size, Bit type, UCS, Formation drillability, Formation abrasiveness, Pump pressure, Rotational per speed, WOB, Mud type, and Mud viscosity	ROP
Hegde and Gray(2017) [14]	RF	4	WOB, RPM, Flow rate, and UCS	ROP
Eskandarian et al.(2017) [45]	RF, MON-MLP	6	WOB, Mud weight, Incline, Azimuth, Pump pressure, and Plastic viscosity	ROP
Hegde et al. (2018)[6]	eyeball mothod, RSM	4	WOB, RPM, Flow rate, and UCS	ROP
Anemangely et al.(2018) [13]	hybrid MLPs	5	RPM, WOB, Hear wave slowness, Compressional wave slowness, and Flow rate	ROP
Ahmed et al.(2019)[46]	SVR, ELM, ANN, LSSVR	9	WOB, RPM, rotary torque, standpipe pressure, mud flow-in rate, Depth, Mud weight, and Bit Size	ROP
Zhao et al.(2018)[47]	ANN	7	Well depth, Rotation speed of bit, WOB, Shut-in pipe pressure, Fluid rate, Ratio of yield point to plastic viscosity, and Ratio of 10 min gel strength to 10 s gel strength	ROP
Okoli et al. (2019)[48]	MLR, LDA, KNN, DT, GNB	3	Torque, ROP, and WOB	Downhole Vibration
Soares and Gray(2019) [33]	RF, SVM, NN model	4	Depth, WOB, RPM, and Flow rate	ROP
Gan et al. (2019)[49]	hybrid SVR	6	Standpipe pressure, Flow rate, Torque, RPM, WOB, and Depth	ROP
Liao et al. (2019)[50]	ABC	4	Thrust, RPM, Flushing media, and Compressive strength	ROP
Ashrafi et al.(2019)[51]	hybrid RBF and MLP	8	WOB, Gamma ray, Bit flow rate, Pore pressure, Pump pressure, Shear wave velocity, Density, and Rotary speed	ROP

**Table 6.** Input variables in feature ranking[45]

Variable (unit)	Range
WOB (Klb)	6-30
RPM	4-100
Flow Rate (gpm)	350-1100
Pump Pressure (psi)	1200-3800
Incline (°)	5.1-56
Azimuth (°)	52.41-322
Measured Drilling Depth (m)	1020-5186
Mud weight (ppg)	8.85-17.25
Funnel Viscosity (sec)	28-179
Plastic Viscosity (cp)	3-97
Yield Point, lb/100sf	4-76
Gel strength after 10 sec, lb/100sf	1-73
Gel strength after 10 min, lb/100sf	2-143

때문에 굴진율 개선을 위하여 임의로 최적화 할 수 없는 매개변수이다.

지표에서 시추작업자가 변경할 수 있는 매개변수만 활용한 연구도 있는 반면에 지층의 자료와 같은 변경할 수 없는 매개변수를 함께 활용한 연구도 있다. 굴진율을 개선하기 위하여 모델을 생성할 시에는 지표에서 조정할 수 있는 WOB, RPM, 유량은 반드시 포함되어야 할 것이다. 기본적으로 WOB가 증가함에 따라 굴진율도 증가한다. 그러나 임계값을 초과하면 비트의 마모를 촉진시키며 시추공 하단의 암편이 효율적으로 제거되지 못하여 굴진율이 감소한다. RPM도 증가하면 굴진율이 증가하나 임계값을 초과하면 안정성이 감소하여 진동 발생 및 Balling 효과로 굴진율이 감소한다. 유량은 WOB와 RPM에 비하여 굴진율에 주는 영향이 복잡하며 증가하면 암편 제거에 기여하여 굴진율이 증가하나 과도한 유량은 시추공 압력을 증가시키기 위한 적절한 범위가 지정되어야 할 것이다. Table 6, 7는 Table 5의 논문에서 매개변수의 범위가 기록된 참고할 수 있는 연구 자료이다.

Eskandarian et al.(2017)의 논문에서는 Table 6의

**Table 7.** Statistical summary of input data[47]

Parameter (unit)	Range
Well depth (m)	1016-4235
Rotation speed of bit (rpm)	91.38-192.00
Weight on bit (Klb)	1.02-43.26
Shut-in pipe pressure (psi)	898.98-4085.82
Fluid rate (gpm/day)	726.92-1054.75
The ratio of yield point to plastic viscosity	0.96-2.09
The ratio of 10 min gel strength to 10 sec gel strength	1.13-1.50

변수에서 순위를 매겨서 시추 최적화 모델에서는 6개의 변수만을 사용하였다[45]. 취득한 자료가 다양하더라도 중요도 분석을 통하여 낮은 중요도의 변수를 제외하고 사용한 경우이다.

#### IV. 실시간 시추 최적화

훈련된 모델이 새로운 시추공에서 완벽하게 굴진율을 예측하고 개선하기는 불가능하다. 그 이유는 지층의 불균질성으로 인해 측정이 불가능한 매개변수들 때문이다. 그러므로 굴진율을 극대화시키기 위해서는 시추과정 중에 실시간으로 자료를 획득하고 모델을 재훈련할 필요성이 있다. 실시간 시추 최적화는 목적함수인 굴진율을 최대화하는 운용 매개변수를 선택하는 것으로 구성된다. 특히 지역의 이전 시추 정보를 이용할 수 없는 탐사정 시추에는 필수적이다[33]. 이전 절에서 언급되었던 운용 매개변수인 WOB, RPM, 유량은 실시간 시추에서 반드시 포함되어야 할 매개변수라고 할 수 있다.

Hegde and Gray(2017)는 시추 작업 후의 굴진율 최적화에서 연산시간 제약 없는 자료기반 모델 사용법을 연구했다[14]. 자료기반 모델은 함수 형태가 정확하지 않은 비선형 함수가 될 수 있으므로 실시간 최적화가 어렵다. 그러나 굴진율을 데이터를 사용하여 최적화하기 위해선 비선형은 필수적이다. 그러므로 실시간 시추에서는 연산의 효율성과 연속적인 시추작업을 고려하여 Simplex, Random-Search Method 기법을 추천하고 적용하였다. 즉, 굴진율 개선 성능과 연산 시간 사이의 적절한 절충을 통하여 실시간 시추 최적화가 가능하다. 적용된 기

법은 초단위로 연산 및 최적화를 진행하는 것은 아니라 분단위로 연산된다[6].

실시간 최적화 연구에서는 시추 간격에 따라 모델의 재훈련을 하는 것이 일반적이다. Hegde and Gray(2017)는 25, 50, 100 ft, Soares and Gray(2019)는 10, 20, 30 ft, Okoli et al.(2019)은 90 ft의 시추 간격에서 재훈련을 실시하였다[14,33,48]. 여기서 재훈련 간격은 운영자의 재량으로 결정되는데, 기본적으로 재훈련 주기가 짧아짐에 따라 모든 모델에서 굴진율 예측 정확도가 향상되어 시추에 소요되는 시간이 감소하게 된다[14, 33].

앞서 개발된 실시간 시추 최적화 모델들은 심층 학습(Deep learning)보다는 얕은 학습(Shallow learning)으로 구현되었다. 그 이유는 성능과 연산 시간의 절충안으로써 얕은 학습이 선택된 것이다. 어떠한 현장이든 바로 적용되는 범용적인 모델과 수치는 없으므로 실시간 시추 모델을 설계할 경우에는 모델의 연산시간과 성능을 고려하여 선정하고 현장의 제한요소들을 종합하여 재훈련 간격을 선택해야 할 것이다. 알고리즘의 정확도와 연산시간은 반비례하며 재훈련 간격이 짧아지면 굴진율 예측 정확도가 증가하기 때문에 두 가지 요소의 합리적인 선택이 필요하다. 즉 모델의 재훈련을 기다리기 위하여 시추작업이 멈춰지는 것은 비효율적이다. 이러한 기술적인 제약요소는 컴퓨터와 통신기술의 발전으로 시간이 지나면 해결될 가능성이 높다. 그러므로 실시간 시추 최적화는 기술의 발전과 더불어 더욱 중요한 기술로 발전될 것이 틀림없다.

## V. 결 론

석유개발에서 비중이 큰 시추에 대한 예측과 비용 절감에 대한 연구는 지속적으로 이루어져 왔다. 그리고 컴퓨터 기술과 통신의 발전으로 인하여 전통적인 수학적 모델에서 실시간으로 다양한 자료를 활용할 수 있는 인공지능을 이용한 모델로 패러다임이 전환되고 있다. 이 주제는 굴진율의 개선으로 상당한 비용 절감을 이를 것으로 주목받는 연구 분야이다.

그러나 기존의 방식과는 다르게 하나의 모델이 모든 현장에 범용적으로 사용될 수 없으므로 결과의 정확도와 연산시간이 적절한 알고리즘의 선택과 현장의 조건을 파악한 매개변수의 선택이 매우 중요하다. 또한 개발된 모델의 성능향상을 위하여 실시간으로 모델을 재훈련하기 위하여 모델의 연산시간과 시추 작업시간을 고려하고 효과를 극대화시키기 위한 연속적인 시추작업을 실현해야한다. 즉, 시추 최적화에서는 알고리즘, 시추 매개변수, 모델 재훈련 간격이 가장

중요한 설계요소라고 할 수 있다.

## 감사의 글

본 연구는 2019년도 산업통상부의 지원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(No. 20182510102500).

## 사용기호

ABC : Artificial Bee Colony

AHP : Analytic Hierarchy Process

ANN : Artificial Neural Network

BPANN : Back Propagation Artificial Neural Network

DT : Decision Tree

ELM : Extreme Learning Machine

GNB : Gaussian Naive Bayes

KNN : K-Nearest Neighbour

LDA : Linear Discriminant Analysis

LSSVR : Least Square Support Vector Regression

MLP : Multi-Layer Perceptron neural network

MLR : Multinomial Logistic Regression

MON-MLP : Monotone Multi-Layer Perceptron

NN : Neural Network

RBF : Radial Basis Function neural network

RF : Random Forest

RSM : Random Search Method

SVR : Support Vector Regression

USA : Upper layer Solution Aware

## REFERENCES

- [1] Perrin, V.P., Wilmot, M.G., and Alexander, W.L., “Drilling index—a new approach to bit performance evaluation”, *SPE/IADC Drilling Conference*, SPE, Amsterdam, Netherlands, 199–205, (1997)
- [2] Bataee, M. and Mohseni, S., “Application of artificial intelligent systems in ROP optimization: a case study in Shadegan oil field”, *SPE Middle East Unconventional Gas Conference and Exhibition*, Muscat, Oman, 13–22, (2011)
- [3] Shi, X., Liu, G., Gong, X., Zhang, J., Wang, J. and Zhang, H., “An efficient approach for real-time prediction of rate of penetration in offshore drilling”, *Mathematical Problems in Engineering*, (2016)

- [4] Hegde., C., Millwater, H., Pyrcz, M., Daigle, H. and Gray, K., "Rate of penetration (ROP) optimization in drilling with vibration control", *Journal of Natural Gas Science and Engineering*, **67**, 71–81, (2019)
- [5] Kaiser, M.J., "Modeling the time and cost to drill an offshore well", *Energy*, **34**(9), 1097-1112, (2009)
- [6] Hegde, C., Daigle, H. and Gray, K., "Performance comparison of algorithms for real-time rate-of-penetration optimization in drilling using data-driven models", *SPE Journal*, **23**(5), (2018)
- [7] AL-Rashidi, A.A., *Application of neural networks to evaluate factors affecting drilling performance*, Ph.D Thesis, Imperial College London, UK, (2011)
- [8] Eren, T. and Ozbayoglu, M.E., "Real-time drilling rate of penetration performance monitoring", *Offshore Mediterranean Conference and Exhibition*, OMC, Revanna, Italy, (2011)
- [9] Soares, C., Daigle, H. and Gray, K., "Evaluation of PDC bit ROP models and the effect of rock strength on model coefficients", *Journal of Natural Gas Science and Engineering*, **34**, 1225–1236, (2016)
- [10] Hegde, C., Daigle, H., Millwater, H. and Gray, K., "Analysis of rate of penetration (ROP) prediction in drilling using physics-based and data-driven models", *Journal of Petroleum Science and Engineering*, **159**, 295-306, (2017)
- [11] Mantha, B. and Samuel, R., "ROP optimization using artificial intelligence techniques with statistical regression coupling", *SPE Annual Technical Conference and Exhibition*, SPE, Dubai, UAE, (2016)
- [12] Moraveji, M.K. and Naderi, M., "Drilling rate of penetration prediction and optimization using response surface methodology and bat algorithm", *Journal of Natural Gas Science and Engineering*, **31**, 829-841, (2016)
- [13] Anemangely, M., Ramezan-zadeh, A., Tokhmechi, B., Molaghbab, A. and Mohammadian, A., "Drilling rate prediction from petrophysical logs and mud logging data using an optimized multi-layer perceptron neural network", *Journal of Geophysics and Engineering*, **15**(2018), 1146–1159, (2018)
- [14] Hegde, C. and Gray, K., "Use of machine learning and data analytics to increase drilling efficiency for nearby wells", *Journal of Natural Gas Science and Engineering*, **40**, 327–335, (2017)
- [15] Murray, A.S. and Cunningham, R.A., "Effect of mud column pressure on drilling rates", *Petroleum Transactions*, **204**, 196–204, (1955)
- [16] Maurer, W.C., "The "Perfect-Cleaning" theory of rotary drilling", *Journal of Petroleum Technology*, **14**(11), 1270–1274, (1962)
- [17] Rowley, D.S., Howe, R.J. and Deily, P.H., "Laboratory drilling performance of the full-scale rock bit", *Journal of Petroleum Technology*, **13**(1), 71–81, (1961)
- [18] Bingham, M.G., "How rock properties are related to drilling", *The Oil and Gas Journal*, 94-101, (1964)
- [19] Bourgoine Jr., A.T. and Young Jr., F.S., "A multiple regression approach to optimal drilling and abnormal pressure detection", *Society of Petroleum Engineers Journal*, **14**(4), 371–384, (1974)
- [20] Ansari, H.R., Hosseini, M.J.S. and Amirpour, M., "Drilling rate of penetration prediction through committee support vector regression based on imperialist competitive algorithm", *Carbonates and Evaporites*, **32**(2), 205–213, (2017)
- [21] Bourgoine Jr., A.T., Millheim, K.K., Chenevert, M.E. and Young Jr., F.S., *Applied Drilling Engineering*, Society of Petroleum Engineers, Richardson, Texas, (1986)
- [22] Rashidi, B., Hareland, G. and Nygaard, R., "Real-time drill bit wear prediction by combining rock energy and drilling strength concepts", *Abu Dhabi International Petroleum Exhibition and Conference*, SPE, Abu Dhabi, UAE, (2008)
- [23] Nascimento, A., Kutas, D.T., Elmgerbi, A., Thonhauser, G. and Mathias, M.H., "Mathematical modeling applied to drilling engineering: an application of bourgoine and young ROP model to a presalt case study", *Mathematical Problems in Engineering*, (2015)
- [24] Wiktorowski, E., Kuznetcov, A. and Sui, D., "ROP optimization and modeling in directional drilling process", *Proc. of the SPE Bergen One Day Seminar*, SPE, Bergen, Norway, (2017)
- [25] Hareland, G. and Rampersad, P.R., "Drag-bit

- model including wear”, *Latin American/Caribbean Petroleum Engineering Conference*, Buenos Aires, Argentina, (1994)
- [26] Motahhari, H.R., Hareland, G. and James, J.A., “Improved drilling efficiency technique using integrated PDM and PDC bit parameters”, *Petroleum Society of Canada*, **49**(10), 45–52, (2010)
- [27] Meng, C.U.I., Mengci, S.U.N., Jinwen, Z., Kai, K. and Yucai, L.U.O., “Maximizing drilling performance with real-time surveillance system based on parameters optimization algorithm”, *Advances in Petroleum Exploration and Development*, **8**(1), 15–24, (2014)
- [28] Bahari, A. and Seyed, A.B., “Trust region approach to find constants of Bourgoyne and Young penetration rate model in Khangiran Iranian gas field”, *SPE Latin American and Caribbean Petroleum Engineering Conference*, SPE, Buenos Aires, Argentina, (2007)
- [29] Yi, P., Kumar, A. and Samuel, R., “Realtime rate of penetration optimization using the shuffled frog leaping algorithm”, *Journal of Energy Resources Technology*, (2015)
- [30] Self, R.V., Atashnezhad, A. and Hareland, G., “Use of a swarm algorithm to reduce the drilling time through measurable improvement in rate of penetration”, *50th U.S. Rock Mechanics/Geomechanics Symposium*, American Rock Mechanics Association, Houston, Texas, (2016)
- [31] Cui, M., Wang, H., Zhao, J., Cui, L. and Chen, Z., “Optimizing drilling operating parameters with real-time surveillance and mitigation system of downhole vibration in deep wells”, *Advances in Petroleum Exploration and Development*, **10**(1), 22–26, (2015)
- [32] Ricardo, J., Mendes, P., Fonseca, T.C. and Sera-pao, A.B.S., “Applying a genetic neuro-model reference adaptive controller in drilling optimization”, *World Oil*, **228**(10), 29–36, (2007)
- [33] Soares, C. and Gray, K., “Real-time predictive capabilities of analytical and machine learning rate of penetration (ROP) models”. *Journal of Petroleum Science and Engineering*, **172**, 934–959, (2019)
- [34] Noshi, C.I. and Schubert, J.J., “The role of machine learning in drilling operations; a review”, *SPE Eastern Regional Meeting*, Pittsburgh, Pennsylvania, (2018)
- [35] Abughaban, M., Alshaarawi, A., Meng, C., Ji, G., and Guo, W., “Optimization of drilling performance based on an intelligent drilling advisory system”, *International Petroleum Technology Conference*, Beijing, China, (2019)
- [36] Tian-Shou, M. and Ping, C., “Development and use of a downhole system for measuring drilling engineering parameters”, *Chemistry and Technology of Fuels and Oils*, **51**(3), 294–307, (2015)
- [37] Ma, T., Chen, P. and Zhao, J., “Overview on vertical and directional drilling technologies for the exploration and exploitation of deep petroleum resources”, *Geomechanics and Geophysics for Geo-Energy and Geo-Resources*, **2**(4), 365–395, (2016)
- [38] Bilgesu, H.I., Tetrick, L.T., Altmis, U., Mohaghegh, S. and Ameri, S., “A new approach for the prediction of penetration (ROP) values”, *SPE Eastern Regional Meeting*, SPE, Loington, Kentucky, (1997)
- [39] Moran, D., Ibrahim, H., Purwanto, A. and Osmond, J., “Sophisticated ROP prediction technology based on neural network delivers accurate results”, *IADC/SPE Asia Pacific Drilling Technology Conference and Exhibition*, Ho Chi Minh City, Vietnam, 100–108, (2010)
- [40] Zhang, J., Li, J., Hu, Y. and Zhou, J., “The identification method of igneous rock lithology based on data mining technology”, *Mechanics and Materials*, 466–467, 65–69, (2012)
- [41] Jahanbakhshi, R., Keshavarzi, R. and Jafarnezhad, A., “Real-time prediction of rate of penetration during drilling operation in oil and gas wells”, *46th US Rock Mechanics/Geomechanics Symposium*, ARMA, Chicago, Illinois, 2390–2396, (2012)
- [42] Amar, K. and Ibrahim, A., “Rate of penetration prediction and optimization using advances in artificial neural networks, a comparative study”, *4th International Joint Conference on Computational Intelligence*, IJCCI, Barcelona, Spain, 647–652, (2012)
- [43] Monazami, M., Hashemi, A., and Shahbazian, M., “Drilling rate of penetration prediction using artificial neural network: a case study of one of Iranian southern oil fields”, *Journal of*

- Oil and Gas Business*, **6**, 21–31, (2012)
- [44] Bodaghi, A., Ansari, H.R. and Gholami, M., “Optimized support vector regression for drilling rate of penetration estimation”, *Open Geosciences*, **7**(1), 870–879, (2015)
- [45] Eskandarian, S., Bahrami, P. and Kazemi, P., “A comprehensive data mining approach to estimate the rate of penetration: Application of neural network, rule based models and feature ranking”, *Journal of Petroleum Science and Engineering*, **156**, 605–615, (2017)
- [46] Ahmed, O.S., Adeniran, A.A., and Samsuri, A., “Computational intelligence based prediction of drilling rate of penetration: A comparative study”, *Journal of Petroleum Science and Engineering*, **172**, 1–12, (2019)
- [47] Zhao, Y., Noorbakhsh, A., Koopialipoor, M., Azizi, A. and Tahir, M.M., “A new methodology for optimization and prediction of rate of penetration during drilling operations”, *Engineering with Computers*, (2018)
- [48] Okoli, P., Vega, J.C. and Shor, R., “Estimating Downhole Vibration via Machine Learning Techniques Using Only Surface Drilling Parameters”, *SPE Western Regional Meeting*, SPE, San Jose, California, (2019)
- [49] Gan, C., Cao, W.H., Wu, M., Chen, X., Hu, Y.L., Liuc, K.Z., Wang, F.W. and Zhang, S.B., “Prediction of drilling rate of penetration (ROP) using hybrid support vector regression: A case study on the Shennongjia area”, *Central China Journal of Petroleum Science and Engineering*, **181**, (2019)
- [50] Liao, X., Khandelwal, M., Yang, H., Koopialipoor, M. and Murlidhar B.R., “Effects of a proper feature selection on prediction and optimization of drilling rate using intelligent techniques”, *Engineering with Computers*, (2019)
- [51] Ashrafi, S.B., Anemangely, M., Sabah, M. and Ameri, M.J., “Application of hybrid artificial neural networks for predicting rate of penetration (ROP): A case study from Marun oil field”, *Journal of Petroleum Science and Engineering*, **175**, 604–623, (2019)
- [52] Cheatham, C.A. and Nahm, J.J., “Effects of selected mud properties on rate of penetration in full-scale shale drilling simulations”, *SPE/IADC Drilling Conference*, SPE, New Orleans, Louisiana, (1985)
- [53] Ernst, S., Pastusek, P.E. and Lutes, P.J., “Effects of RPM and ROP on PDC bit steerability”, *SPE/IADC Drilling Conference*, SPE, Amsterdam, Netherlands, (2007)
- [54] Akpabio, J.U., Inyang, P.N. and Iheaka, C.I., “The effect of drilling mud density on penetration rate”, *International Research Journal of Engineering and Technology*, **2**(9), 29–35, (2015)