



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](#)

공학석사 학위논문

기계학습을 이용한
가스정 액체 서지 예측

Prediction of Liquid Surge for Gas Wells
Using Machine Learning

2022 년 2 월

서울대학교 대학원

에너지시스템공학부

윤 영 우

기계학습을 이용한
가스정 액체 서지 예측

Prediction of Liquid Surge for Gas Wells

Using Machine Learning

지도 교수 정 훈 영

이 논문을 공학석사 학위논문으로 제출함

2022 년 2 월

서울대학교 대학원

에너지시스템공학부

윤 영 우

윤영우의 공학석사 학위논문을 인준함

2022 년 2 월

위 원 장 _____ (인)

부위원장 _____ (인)

위 원 _____ (인)

초 록

액체 서지(Liquid Surge)는 관 내에서 특정 시간 간격 동안 유입되는 액체 부피를 의미한다. 과도한 액체 서지 문제 분석을 수행하기 위하여 일반적으로 다상 관 유동 시뮬레이터를 사용하지만 라이선스의 수와 비용에 대한 제약이 있기 때문에 동시에 여러 유정에 대하여 액체 서지 문제 분석을 수행하기 어렵다. 따라서 기계학습 모델을 사용하여 액체 서지 부피를 예측하면 시뮬레이터 라이선스의 제약 없이 액체 서지 문제를 예측할 수 있다. 본 연구에서는 순방향신경망 학습 모델을 사용하여 현장 지상에서 모니터링 할 수 있는 인자인 변경 전과 후의 정두 압력, 가스 부피유량, 물-가스비율, 총 수압 파쇄 단계 수를 입력 인자로 하여 최대 서지 부피와 정두 압력 조절 후 gas와 물의 부피유량을 예측하는 학습 모델을 구축하였다. 예측 정확도는 결정 계수 0.9 이상으로 매우 높지만 물-가스비율이 높은 경우 예측 성능이 감소하는 현상을 확인하였다. 또한, 같은 구조의 순방향신경망 학습 모델은 전체 관 유동 길이가 길어져도 안정된 예측 성능을 보이는 것을 확인하였으며, 단계적 압력 조절을 통한 액체 서지 문제 해결을 적용하였을 때에도 매우 높은 예측 성능을 보였다.

주요어 : 액체 서지, 순방향신경망, 최대 액체 서지 부피 예측, 정두 압력의 단계적 조절

학 번 : 2020-22122

목 차

제 1 장 서론	1
1.1 연구 목적	1
1.2 연구 배경	2
제 2 장 방법론	5
2.1 액체 서지 부피의 계산	5
2.2 순방향신경망	6
제 3 장 최대 액체 서지 부피 예측 모델	8
3.1 분석 모델 개요	8
3.2 모델 시뮬레이션 예시	10
3.3 훈련 데이터 및 모델 구성	12
3.4 학습 및 예측 결과	14
3.5 영향 인자 분석	20
제 4 장 유동 길이가 긴 경우의 적용	24
4.1 분석 필요성 및 모델 개요	24
4.2 훈련 데이터 및 모델 구성	27
4.3 학습 및 예측 결과	28
제 5 장 정두압력의 단계적 조절 적용	34
5.1 분석 필요성 및 모델 개요	34
5.2 훈련 데이터 및 모델 구성	34
5.3 학습 및 예측 결과	36
제 6 장 결론	44
참고문헌	46
Abstract	48

표 목차

표 1. Horn River Basin 필드 모델의 유체 구성	8
표 2. Horn River Basin 필드 모델의 저류층 특성 인자	8
표 3. Horn River Basin 필드 예시 모델의 구성 인자와 값	10
표 4. Horn River Basin 필드 예시 모델의 정두 압력 변경 전 과 후의 유량	11
표 5. Horn River Basin 필드 대상 학습모델 훈련을 위한 데 이터셋 인자 및 값 범위.....	12
표 6. Horn River Basin 필드 예시 데이터의 입력 자료	19
표 7. Rakhine Basin 필드 대상 학습모델 훈련을 위한 데이터 셋 인자 및 값 범위	27
표 8. 단계적 압력 조절을 적용한 학습모델 구축을 위한 데이 터셋 인자 및 값 범위	34
표 9. 단계적 압력 조절 예시 데이터의 입력 자료	41

그림 목차

그림 1. 관 유동 및 액체 서지 부피의 예시	5
그림 2. 순방향신경망의 구조	6
그림 3. Horn River Basin 필드 모델의 유정 기하 모식도	9
그림 4. Horn River Basin 필드 모델의 OLGA 모델 모식도 ...	10
그림 5. Horn River Basin 필드 예시 모델의 유량 그래프	11
그림 6. Horn River Basin 필드 모델을 활용한 순방향신경망 학습모델의 구조	13
그림 7. Horn River Basin 필드 학습모델의 예측 결과 그래 프	14
그림 8. Horn River Basin 필드 학습모델의 예측 예시 그래 프	19
그림 9. Horn River Basin 필드 학습모델 예측 결과의 일부 추세선과 거리가 먼 데이터 예시	20
그림 10. 물-가스비율을 범례로 나타낸 Horn River Basin 필드 학습모델의 예측 그래프	21
그림 11. 물-가스비율이 2500STB/MMscf 이상인 데이터 만 모은 예측 그래프	22
그림 12. Rakhine Basin 필드 모델의 유정 기하 모식도	25
그림 13. Rakhine Basin 필드 모델의 OLGA 모델 모식도	26
그림 14. Rakhine Basin 필드 모델을 활용한 순방향신경망 학습모델의 구조	27
그림 15. Rakhine Basin 필드 학습모델의 예측 그래프	29
그림 16. 단계적 압력 조절을 적용한 순방향신경망 학습 모델의 구조	35
그림 17. 단계적 압력 조절을 적용한 학습모델의 예측 결과 ...	37
그림 18. 단계적 압력 조절을 적용한 모델의 예측 예시 그래프	42

제 1 장 서 론

1.1 연구 목적

유가스 생산 파이프라인은 지하 저류층의 유체를 지상으로 운반하는 중요한 장비이다. 파이프라인 내에서의 유동은 다상 유동이기 때문에 주변 조건이나 유동 정도에 따라 내부 유동 특성이 다양하게 나타난다. 또한, 왁스, 하이드레이트 등의 고체가 생성되거나 물리, 화학적 반응을 통한 침식이나 부식 등의 현상이 발생하기도 한다. 이와 같은 파이프라인 유동 문제를 제어하고 생산 유체의 안전한 운반을 다루는 분야를 유동 견실성(Flow Assurance)이라 한다.

유동 견실성이 다루는 문제는 여러 가지가 있는데, 유전 종류에 관계없이 발생할 수 있는 문제로 액체 서지(Liquid Surge)가 존재한다. 액체 서지 부피는 파이프라인 내에서 특정 시간 간격 동안 유입되는 액체 부피로 정의되며, 액체 서지는 액체 서지 부피가 크게 발생하는 문제를 지칭한다. 본 논문에서는 이 문제의 의미를 액체 서지의 개념으로 사용한다. 유정을 운영하면서 액체 서지는 생산 경과에 따른 생산량 감소를 완화하기 위해 정두에서 압력을 낮추는 경우에 특히 많이 발생한다. 상분리기의 용량을 초과하는 액체 서지 부피가 상분리기로 유입되면 기체상과 액체상의 분리가 제대로 이루어지지 못하여 운영을 중단하는 문제가 발생한다. 이를 방지하기 위해 상분리기 앞에 슬러그 방지 장치를 두어 일차적으로 액체 서지 문제를 방지할 수 있다.

위와 같은 액체 서지 문제 분석을 위해 다상 유동 시뮬레이터가 사용된다. 그러나 상용 다상 관 유동 시뮬레이터는 높은 라이선스 비용 때문에 사용이 쉽지 않고 한정된 수의 대여 라이선스로 인해 다수 유정에 동시 적용이 어렵다는 문제가 있다.

본 논문에서는 이러한 문제점을 해결하기 위하여 기계학습모델을 적용하여 최대 액체 서지 부피를 신속하게 예측한다. 이러한 기계학습모델

을 활용하여 다상 유동 시뮬레이터 라이선스 제약 없이 동시에 다수 유동에 대해 최대 액체 서지 부피를 예측하는 것이 가능하다.

본 논문은 총 6장으로 구성된다. 제1장은 서론으로써 본 논문의 연구 목적과 액체 서지, 기계학습을 이용한 유동 건실성 문제 예측에 대한 기존연구 사례에 대해 언급한다. 제2장에서는 본 논문의 주제인 액체 서지의 개념과 기계학습 모델의 구성에 대하여 설명한다. 제3장에서는 제2장에서 언급된 방법론을 토대로 Horn River Basin 가스정 자료를 통하여 모델링한 분석 모델과 훈련 구성을 설명하고 학습 및 예측 결과를 제시하며, 각 인자의 결과에 대한 영향력을 분석한다. 제4장에서는 제3장의 모델보다 전체 유동 길이가 긴 경우인 Rakhine Basin 가스정 자료에 같은 구조의 모델을 적용한 분석 및 결과를 제시한다. 제5장에서는 정두 압력을 다단계로 나누어 조절할 경우 얻을 수 있는 효과 및 이를 반영한 학습모델의 구성과 결과를 제시한다. 제6장에서는 본 연구의 결론을 제시한다.

1.2 연구 배경

유동 건실성 문제는 전체 생산 시스템 상에서의 정상적인 운영에 악영향을 준다. 따라서 유동 건실성 문제를 기계학습을 통하여 예측하고 분석하는 것에 대하여 다양한 연구들이 수행되었으며, 상용 프로그램을 이용한 액체 서지 문제 시뮬레이션 분석도 수행되었다.

Omrani 등(2019)은 주성분 분석을 통해 여러 인자로부터 슬러그 발생 빈도수를 분류할 수 있는 두 가지 주성분을 추출하여 분류를 수행하고, 이 주성분을 이용하여 인공신경망과 순환신경망을 통해 유량을 예측하는 모델을 구축하였다. Al-Hajri 등(2019)은 생산 유체의 이온 구성, 수소 이온 농도, 스케일 형성 지수 등의 화학적 데이터를 활용하여 스케일링 지수를 계산하여 스케일 문제 발생을 예측할 수 있는 분류 알고리즘을 적용하였다. 적용한 분류 알고리즘은 SVM, KNN, DT 등이 있으며, 결과에 따른 보수 조치를 수행하였을 때의 경제적 이점도 제시하

였다. Alhashem(2019)은 수평 파이프라인에서의 유동 특성을 생산 액체 중 물 비율, 기체 걸보기 속도, 액체 걸보기 속도를 사용하여 분류하였고, 여러 분류 알고리즘(SVM, RF, Logistic Regression)을 비교하였다. Cheng 등(2019)은 유량과 수두 손실을 이용하여 파이프라인 거칠기 변화, 내경 변화를 계산하고 누수 위치를 구하는 학습 모델을 구축하였다. Bangert(2020)는 Gas Lift Well에서 슬러그로 인한 생산량 감소 및 설비 문제를 완화하기 위해 슬러그 발생을 예측하는 LSTM 모델을 구축하였다.

또한, 액체 서지에 대하여 Torpe 등(2009)은 생산량 감소에 따른 Severe Slugging으로 인한 액체 서지 문제를 모델 예측 제어를 사용하여 예측하고 자동으로 초크를 닫아 문제를 방지하는 연구를 수행하여 Åsgard B 필드에 적용하였다. Holmås 등(2013)은 Orman Lange 필드에 적용된 유동 견실성 시스템에 다상 유동 시뮬레이터인 FlowManager™ Dynamic을 기반으로 한 향상된 파이프라인 모니터링 시스템을 적용하여 액체 서지를 예측할 수 있음을 확인하였다.

액체 서지의 분석에 대한 연구와 다양한 유동 견실성 문제를 기계학습으로 예측하는 연구는 존재하지만, 액체 서지 문제를 기계학습을 이용하여 발생 여부 및 정도를 예측하는 연구가 없었다. 다른 유동 견실성 문제를 기계학습 모델을 활용하여 예측하는 대부분의 연구는 특정 상황에서의 인자를 추출하여 문제가 발생하는지를 예측한다. 이와 달리 현장 상황에서 운영 조건을 변경하였을 때 발생하는 액체 서지를 예측하는 것은 현재 조건과 변경 조건을 동시에 고려해야 한다. 따라서 기계학습모델에 현장 전문가가 모니터링하는 운영 조건을 적용하여 운영 조건을 변경하였을 때 발생하는 최대 액체 서지 부피를 예측하면 액체 서지 문제가 발생하는지에 대한 현장 적용성이 높은 예측 모델을 구축할 수 있다. 또한 학습모델을 구축해두면 빠르게 관 유동 시뮬레이터를 대체하여 예측이 가능하므로 비용 절감 및 신속한 운영 조건 변경에 대한 의사결정이 가능하다. 기계학습모델은 관 유동 시뮬레이터와 달리 라이선스에 대한 제약도 없으므로 동시에 다수 유정에 대한 예측 및 분석을 수행할 수

있다.

제 2 장 방 법 론

2.1 액체 서지 부피의 계산

액체 서지 부피의 정의는 파이프라인 특정 위치에서 특정 시간 간격 동안 유입되는 액체의 부피이다. 그림 1에서 파란색으로 색칠된 부피만큼의 액체가 A 위치에서 Δt 시간 동안 유입되었다면, Δt 시간 동안의 액체 서지 부피는 파란색으로 색칠된 부피에 해당된다.




그림 1. 관 유동 및 액체 서지 부피의 예시(출처: Shoham, O. (2005). Mechanistic Modeling of Gas-Liquid Two-Phase Flow in Pipes)

액체 서지 부피는 분석하고자 하는 지점에서의 누적 액체 부피 유량을 이용하여 구할 수 있다. 특정 시간 t 에서의 누적 액체 부피 유량을 *Cumulative Volume of Inflow Liquid_t*, 시간 간격을 Δt 라 하면 액체 서지 부피 V_{surge} 는 다음과 같은 식으로 구할 수 있다.

$$V_{surge} = \text{Cumulative Volume of Inflow Liquid}_t - \text{Cumulative Volume of Inflow Liquid}_{t-\Delta t} \quad \text{식 1}$$

계산된 V_{surge} 가 상분리기의 액체 분리도를 초과하면 상분리가 제대로 이루어지지 않아 운영을 중단하고 문제를 해결해야 한다. 따라서 현장 상분리기의 액체 분리도와 V_{surge} 를 비교하여 문제 발생 여부를 확인할 수 있다. V_{surge} 분석에 사용될 시간 간격 Δt 는 통상적인 2상 상분리기의 분리 잔류시간인 30~180초이다.

2.2 순방향신경망(Feedforward Network)

순방향신경망은 인공신경망의 한 종류로, 입력 인자로부터 출력 인자를 도출하는 학습모델이다. 모델의 구조는 그림 2와 같이 입력 인자들을 하나 이상의 은닉층에 통과시켜 출력 인자로 변환시키는 신경의 형태를 가진 구조이다.




그림 2. 순방향신경망의 구조(출처: S. Kotsiantis et al.(2006). A review of Classification and Combining Techniques)

은닉층은 선형 연산을 수행하며, 각 입력 인자 별 계수와 편향을 조절하여 출력 인자를 맞춘다. 또한, 변수의 비선형 관계를 묘사하기 위한 장치인 활성화함수가 마지막 단계에 존재하므로 입력 인자와 출력 인자의 선형성과 비선형성을 동시에 고려할 수 있는 학습모델이다. 순방향신경망은 은닉층 내에서 이전 층의 뉴런이 다음 층으로 연결되어 결과가 그대로 다음 층으로 전달되며, 순환 과정이 없으므로 시계열 자료의 처리에는 적합하지 않다는 특징이 있다.

순방향신경망은 계수와 편향을 통하여 묘사 관계식을 찾기 때문에 인자의 규모에 영향을 받는다. 입력 인자 각각의 규모가 차이가 많이 나면 계수와 편향의 조절이 규모가 큰 인자에만 맞춰지는 경향이 존재한다. 따라서, 입력 인자들의 규모를 맞춰주는 스케일링이 필요하며 본 연구에서는 각각의 인자의 최댓값과 최솟값을 활용하여 0부터 1사이의 값을

가지도록 변환하는 최소-최대 스케일링 방법을 사용하였다.

예측하고자 하는 최종 인자가 운영 조건을 변경하였을 때의 최대 액체 서지 부피이므로 회귀예측모델 중에서 가장 간단한 구조를 가지는 순방향신경망으로 학습모델을 구성하였다. 추후 모델 개선을 수행하며 입력 인자나 출력 인자가 복잡해지거나 예측이 잘 수행되지 않을 경우 더 복잡한 구조나 기법을 가진 모델을 활용하여 예측 성능을 개선할 수 있다.

제 3 장 최대 액체 서지 부피 예측 모델

3.1 분석 모델 개요

최대 액체 서지 부피 예측 학습모델 구축을 위해 캐나다의 Horn River Basin 필드의 셰일가스전 데이터를 활용하여 기본 시뮬레이션 모델을 구성하였다. 해당 유전은 육상 유전으로 다단계 수압 파쇄를 적용한 수평 셰일가스전으로 gas와 물의 2상유동이 특징이다. 시뮬레이션 모델 작성에 사용된 유체 구성과 저류층 특성은 표 1, 표 2와 같다.

표 1. Horn River Basin 필드 모델의 유체 구성

유체 구성 성분	몰 분율(%)
Nitrogen	0.96
Methane	98.86
Ethane	0.1
Propane	0.02
Isobutane	0.01
N-Butane	0.01
N-Pentane	0.01
C6	0.01
C7+	0.02

표 2. Horn River Basin 필드 모델의 저류층 특성 인자

저류층 특성 인자	값(단위)
Reservoir Thickness	450(ft)
Horizontal Permeability	0.3(md)
Vertical Permeability	0.03(md)

Reservoir Temperature	155(°C)
Sandface Radius	5.5(in.)
Mechanical Skin Factor	5
Perforation Interval	10(m)
Damaged Zone Permeability	450(md)
External Boundary Radius of Drainage Area	50(m)

유정 기하 자료를 토대로 Schlumberger사의 다상 관 유동 시뮬레이터인 OLGA를 활용하여 시뮬레이션 하였다. 유정 기하를 도시한 것은 그림 3과 같다. 정두부터 저류층까지의 깊이는 약 2,500m이고 전체 유동 길이는 3,500m 내외이다.




그림 3 Horn River Basin 웰드 모델의 유정 기하 모식도

그림 3에서 우상단 지점에 정두가 위치하며, 좌하단 지점에 저류층 접촉부가 위치한다. 저류층 접촉부의 수는 총 수압 파쇄 단계 수에 따라 조정된다. 이를 모델링한 OLGA의 모식도는 그림 4와 같다.




그림 4. Horn River Basin 필드 모델의 OLGA 모델 모식도

그림에서 INLET 부분이 저류층 부분에 해당하는 폐쇄 노드이며, 노드 바로 앞에 저류층 접촉부가 위치한다. 위의 유정기하를 적용한 파이프라인을 통해 압력 노드로 설정한 정두에 해당하는 OUTLET까지 이어지도록 모델링하였다.

3.2 모델 시뮬레이션 예시

위의 기초 자료를 토대로 하여 정두 압력을 감소시키는 예시 모델을 작성하였으며, 모델 구성에 필요한 인자 및 값은 표 3과 같다.

표 3. Horn River Basin 필드 예시 모델의 구성 인자와 값

예시 모델 구성 인자	값(단위)
저류층 압력	5500(psia)
물-가스비율	1000(STB/MMscf)
기존 정두압력	800(psia)
변경 후 정두압력	500(psia)


먼저 입력된 인자에 대하여 정상 상태 조건으로 초기 상태를 구하며,

이후 30분 지점에서 정두압력을 감소시킨다. 그에 따라 가스와 물 유량이 급격히 증가하였다가 90분 이내에 최종적으로 변화된 안정 유량을 가진다. 정두 압력을 조절하기 전과 후의 가스와 물 부피유량을 정리하면 표 4와 같으며, 이를 그래프로 표현하면 그림 5의 A, B와 같다.

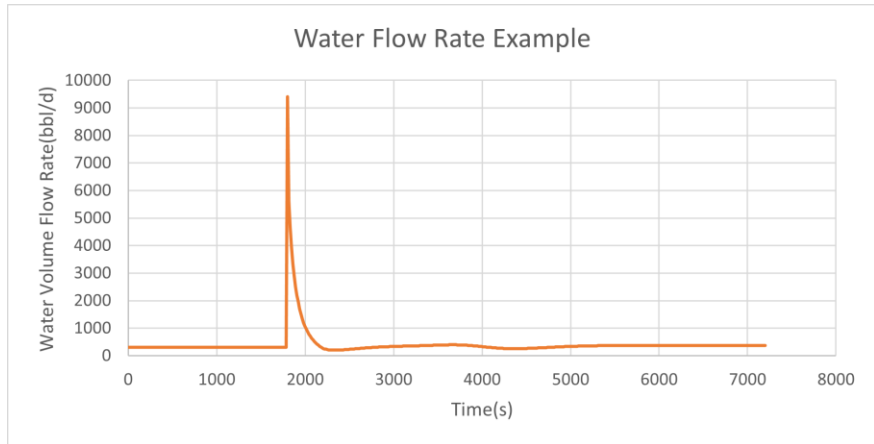
표 4. Horn River Basin 필드 예시 모델의 정두 압력 변경 전과 후의 유량

예시 모델 구성 인자	값(단위)
기존 가스 부피유량	4792.127 (cf/d)
기존 물 부피유량	311.560 (bbl/d)
변경 후 가스 부피유량	9313.445 (cf/d)
변경 후 물 부피유량	373.8967 (bbl/d)

그림 5. Horn River Basin 필드 예시 모델의 유량 그래프



A. 가스 부피유량 그래프



B. 물 부피유량 그래프

3.3 훈련 데이터 및 모델 구성

시뮬레이션 모델을 구성할 때 필요한 인자들의 값을 바꿔가며 모델을 생성하면 훈련을 위한 데이터셋을 구축할 수 있다. 해당되는 인자들과 값 범위에 대한 설정은 표 5와 같다.

표 5. Horn River Basin 필드 대상 학습모델 훈련을 위한 데이터셋 인자 및 값 범위

데이터셋 인자	값 범위(단위)
기존 정두압력	700~1000(psia)
변경 후 정두압력	300~600(psia)
물-가스비율(WGR)	300~3000(STB/MMscf)
저류층 압력	5500~7250(psia)
총 수압 파쇄 단계 수	1~4(정수형)

이때, 총 수압 파쇄 단계는 약 100m 간격을 가진 3개의 수압 파쇄 부로 구성되어 있다고 설정하였다. 위의 범위를 설정한 후, Latin Hypercube Sampling 방법을 사용하여 각 인자에서의 인자 추출을 균일

하게 수행한 1000개의 데이터를 생성하였다.

예측에 사용할 순방향신경망 학습모델의 구조는 그림 6과 같다.

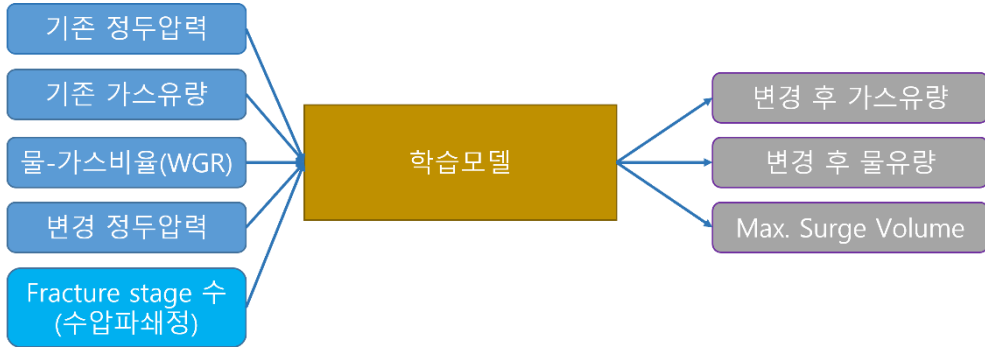


그림 6. Horn River Basin 필드 모델을 활용한 순방향신경망 학습모델의 구조

입력 인자로 유전 상부에서 바로 확인이 가능한 인자 중 설비 특성을 반영한 인자로 기존 정두압력, 변경할 정두압력을 선정하였다. 저류층 특성을 반영한 인자로 저류층 압력과 물-가스비율(WGR)을 선택할 수 있으나, 현장 지상에서 확인이 용이한 물-가스비율을 선정하였다. 물-가스비율에 맞추어 유량을 예측하기 위해 정두에서의 운영 조건 변경 전의 가스 부피유량을 선정하였고, 수압 파쇄정 파쇄 단계 수도 입력 인자로 넣어 다양한 파쇄 단계 수에 대응할 수 있도록 구성하였다.

출력 인자로 본 연구에서 예측하고자 하는 최대 액체 서지 부피가 있으며, 최대 액체 서지 부피는 유량으로 예측하므로 운영 조건 변경 후의 정두에서의 가스 부피유량과 물 부피유량도 함께 예측하도록 구성하였다. 시뮬레이션 상에서 시간 데이터를 기록하는 주기는 15초로 설정하였다.

위의 순방향신경망은 크기가 15인 은닉층을 하나만 가지는 간단한 구조로 설정하였으며, 예측 성능이 좋지 않거나 문제가 발생할 시에 더 복잡한 구조를 가지는 순방향신경망이나 다른 기계학습 기법을 활용할 수 있다. 훈련 알고리즘은 Levenberg-Marquardt 방법을 사용하였다.

생성한 1000개의 데이터 중 시뮬레이션 오류가 나거나 마지막에 유량이 안정되지 않는 불안정한 모델의 경우를 제외한 984개의 데이터셋을 추려 훈련:검증:평가 데이터의 개수를 각각 6:1:3의 비율로 임의로

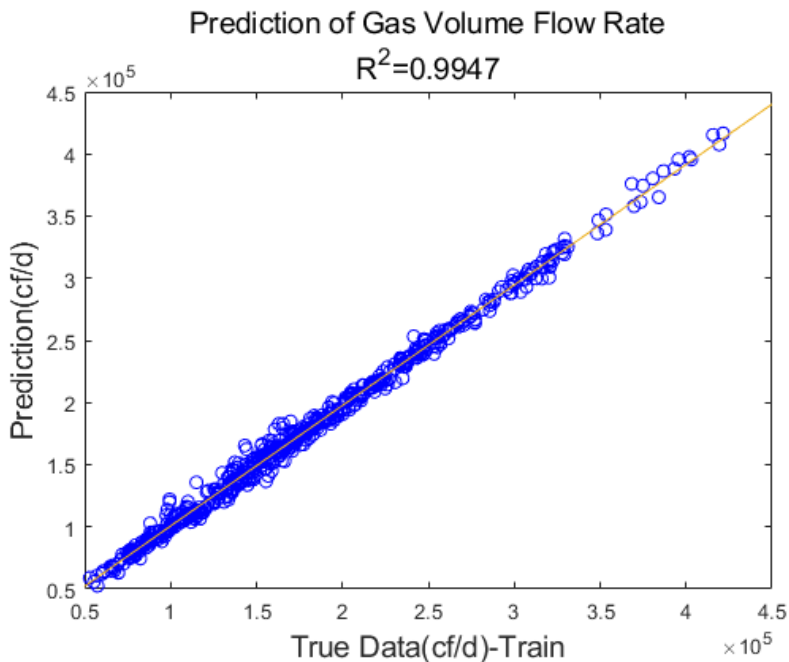
분배하여 훈련 데이터셋을 생성하였다.

3.4 학습 및 예측 결과


시뮬레이션 결과 나타난 가스 유량의 범위는 수 만~수 십만(cf/d)의 범위를 가지지만 총 수압 파쇄 단계 수는 1~4의 범위를 가진다. 입력 인자 내에서 각 범위의 차이가 크기 때문에 범위가 큰 유량 인자에 맞추어 학습이 이루어지는 경향이 있으므로 다른 인자의 영향력이 상대적으로 무시되어 예측 결과가 좋지 않게 출력된다. 따라서 각 인자의 최대값과 최소값을 이용한 최소-최대 스케일링을 모든 입력 인자와 출력 인자에 적용하였다.

위의 내용으로 학습을 진행하여 운영 조건 변경 후의 가스 부피유량, 물 부피유량, 최대 액체 서지 부피에 대한 예측 결과는 그림 7의 A~I와 같다.


그림 7. Horn River Basin 필드 학습모델의 예측 결과 그래프




A. 가스 부피유량 예측 그래프(훈련 데이터)




B. 물 부피유량 예측 그래프(훈련 데이터)



C. 최대 액체 서지 부피 예측 그래프(훈련 데이터)



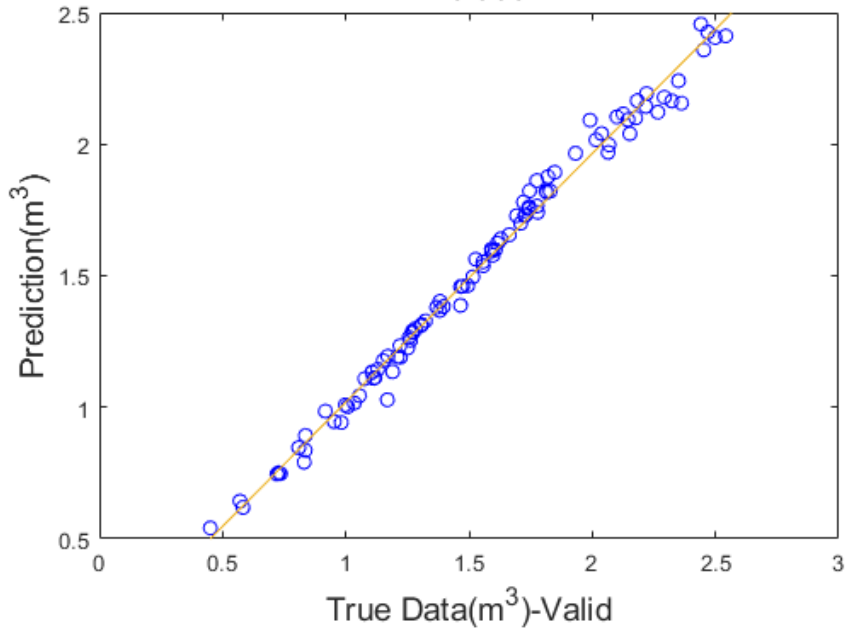
D. 가스 부피유량 예측 그래프(검증 데이터)



E. 물 부피유량 예측 그래프(검증 데이터)

Prediction of Maximum Liquid Surge Volume(dt=90s)


$R^2=0.9904$




F. 최대 액체 서지 부피 예측 그래프(검증 데이터)

Prediction of Gas Volume Flow Rate


$R^2=0.9948$



G. 가스 부피유량 예측 그래프(시험 데이터)



H. 물 부피유량 예측 그래프(시험 데이터)



I. 최대 액체 서지 부피 예측 그래프(시험 데이터)

분석 결과, 가스 부피유량과 물 부피유량, 최대 서지 부피에 대하여 훈련 데이터, 검증 데이터, 시험 데이터 모두 결정 계수 0.97 이상의 높은 예측 성능을 보였다. 특히 사항으로 전체적인 결정 계수는 높지만 물 부피유량과 최대 서지 부피 예측 결과에서 일부 데이터가 추세선에서 벗어난 경향을 확인할 수 있다.


예측 결과를 구체적으로 확인하기 위하여 하나의 예시 데이터를 선정하였으며, 해당 예시 데이터의 입력 구성은 표 6과 같다.

표 6. Horn River Basin 필드 예시 데이터의 입력 자료

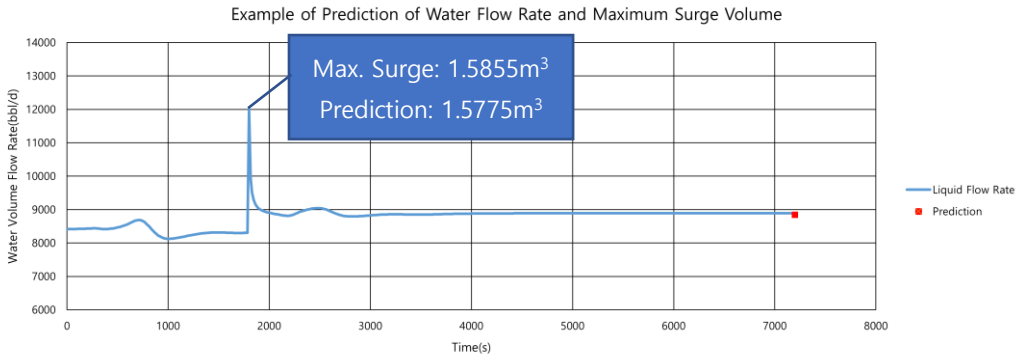
데이터셋 인자	값(단위)
기존 정두압력	734.9298 (psia)
변경 후 정두압력	496.9488 (psia)
물-가스비율(WGR)	1848.3966 (STB/MMscf)
저류층 압력	5854.1736 (psia)
총 수압 파쇄 단계 수	2(정수형)

위의 시험 데이터 예시로부터 가스 부피유량, 물 부피유량, 최대 액체 서지 부피를 구하고 모델을 통해 예측한 값을 표시한 그래프는 그림 8의 A, B와 같다.

그림 8. Horn River Basin 학습모델의 예측 예시 그래프



A. 가스 부피유량 예측 예시 그래프




B. 물 부피유량 및 최대 액체 서지 부피 예측 예시 그래프

그래프로부터 학습 모델이 운영 조건 변경 후 유량과 최대 액체 서지 부피를 잘 예측하는 것을 확인할 수 있다.

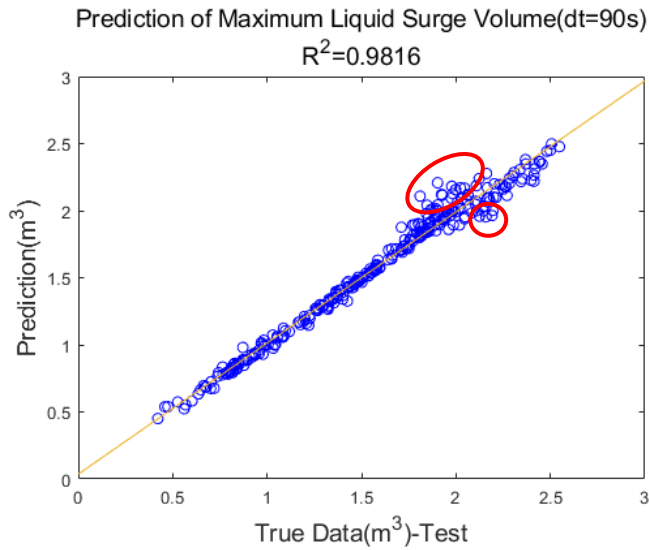
3.5 영향 인자 분석

추세선 분석 결과에서 전체적으로 잘 맞지만 물 부피유량 예측과 최대 액체 서지 부피 예측 결과 그래프에서 일부 데이터가 추세선과의 거리가 먼 경향이 있으며, 이를 그림으로 나타내면 그림 9의 A, B와 같다.

그림 9. Horn River Basin 필드 학습모델 예측 결과의 일부 추세선과 거리가 먼 데이터 예시



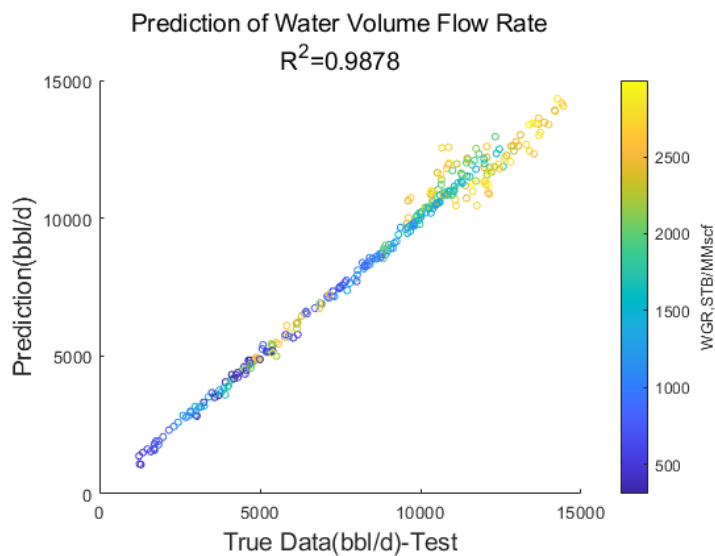
A. 물 부피유량 예측 그래프




B. 최대 액체 서지 부피 예측 그래프

원인 분석을 위하여 물 부피유량 예측 결과 그래프에 각각의 인자를 범례로 나타내어 그린 결과, 다른 인자에 비해 물-가스비율이 높은 경우의 예측 정확도가 떨어지는 것을 확인하였다. 최대 액체 서지 부피의 경우도 같은 경향이 나타나는데, 이는 최대 액체 서지 부피 계산을 물 부피유량을 토대로 수행하기 때문이다. 그래프로 나타낸 결과는 그림 10의 A, B와 같다.

그림 10. 물-가스비율을 범례로 나타낸 Horn River Basin 필드의 예측 그래프



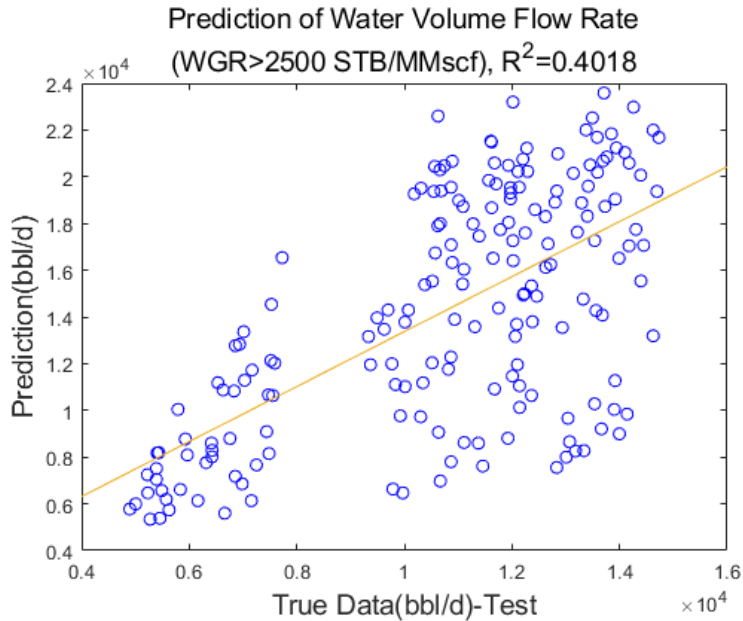
A. 물 부피유량 예측 그래프



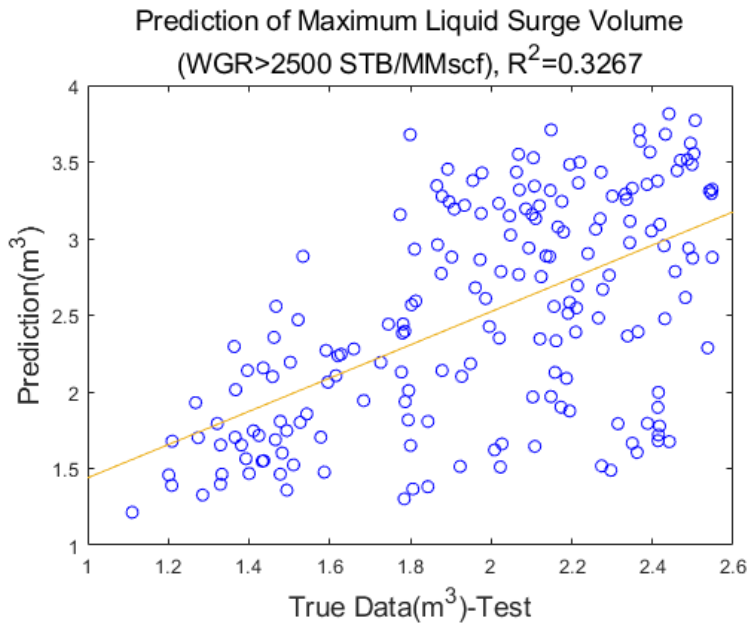
B. 최대 액체 서지 부피 예측 그래프

추세선과의 거리가 먼 점들에서 물-가스비율이 높은 경향이 관찰되는 것을 확인할 수 있으며, 물-가스비율이 2500STB/MMscf 이상인 경우들을 모아 같은 학습 모델에 대한 예측 결과를 그래프로 나타내면 그림 11의 A, B와 같다.

그림 11. 물-가스비율이 2500STB/MMscf 이상인 데이터만 모은 예측 그래프



A. 물 부피유량 예측 그래프



B. 최대 액체 서지 부피 예측 그래프

해당 경우들의 수는 전체 데이터의 18.8%에 해당되는 185개이다. 분석 결과, 물-가스비율이 2500STB/MMscf이상으로 높은 경우 예측 결정 계수가 0.3~0.4 내외로 정확도가 높지 않은 것을 확인할 수 있다.


제 4 장 유동 길이가 긴 경우의 적용

4.1 분석 필요성 및 모델 개요


Horn River Basin 필드의 경우 전체 유동 길이가 3,500m 내외이므로 보다 긴 유동 길이에 대해서도 본 연구에서 제안한 방법을 적용하였다. 이를 위해 미얀마의 Rakhine Basin 필드의 미고결 사암 저류층 데이터를 활용하여 분석 모델을 구성하였다. 해당 유전은 해상 플랫폼을 이용한 해상 유전으로서 저류층부터 해저면 정두까지의 생산구간과 해저면 정두부터 해상 플랫폼까지의 이송구간으로 나뉘어 있다. 유체 유동은 가스과 물의 2상유동이다. 비공개 현장데이터로써 구체적인 수치를 제시할 수는 없으나, 시뮬레이션 모델 작성에 사용된 유체는 대부분 메탄으로 이루어진 유체이며, 높은 투수율을 가지는 저류층 특성이 있다.

유정 기하 자료를 토대로 OLGA를 활용하여 시뮬레이션 모델을 작성하였다. 유정 기하를 도시한 것은 그림 12의 A, B와 같다.

그림 12. Rakhine Basin 필드 모델의 유정 기하 모식도



A. 저류층부터 해저면 정두까지의 유정 기하 모식도



B. 해저면 정두부터 해상 플랫폼까지의 유정 기하 모식도

그림12-A는 저류층부터 해저면 정두까지의 생산구간을 나타낸 것으로, 우상단 지점에 정두와 초크가 위치하여 압력을 조절하고, 좌하단 지점에 저류층 접촉부가 위치한다. 정두부터 저류층까지의 깊이는 약 1,100m이고 유동 길이는 2,000m 내외이다.

그림12-B는 해저면 정두부터 해상 플랫폼까지의 이송구간을 나타낸 것으로, 우상단 지점에 해상 플랫폼과 상분리기가 위치하며, 좌하단 지점에 정두가 위치한다. 깊이는 약 1,100m이고 총 수평 유동 길이가 30,000m이다.

이를 모델링한 OLGA의 모식도는 그림 13과 같다.




그림 13. Rakhine Basin 필드 모델의 OLGA 모델 모식도

그림에서 Hz-Toe_01 부분이 저류층 부분에 해당하는 폐쇄 노드이며, 노드 바로 앞에 저류층 접촉부가 위치한다. 그림12-A의 유정기하를 적용한 Well_01 파이프라인을 통해 내부 노드로 설정한 해저면 정두까지 연결하였고, 내부 노드 바로 앞에 초크를 설치하여 이를 이용하여 압력을 조절하도록 구성하였다. 이후 그림12-B의 유정기하를 적용한 FlowLine을 통해 압력 노드로 설정한 해상 플랫폼 상분리기 위치에 해당하는 FinalNode까지 이어지도록 모델링하였다. OLGA 시뮬레이션을 수행할 때, 두 유정 기하를 연결하기 위한 내부 노드를 활용할 경우, 접합부인 정두부분의 압력을 직접 지정할 수 없어 초크 개방도를 이용하여 압력을 조절하는 것으로 모델링하였다. 초크 개방도를 높이면 압력을 낮

추는 효과가 있다.

4.2 훈련 데이터 및 모델 구성

훈련 데이터셋 구축을 위한 시뮬레이션 인자들과 그 값 범위에 대한 설정은 표 7과 같다.

표 7. Rakhine Basin 필드 대상 학습모델 훈련을 위한 데이터셋 인자 및 값 범위

데이터셋 인자	값 범위(단위)
기존 초크 개방도	40~70(%)
변경 후 초크 개방도	70~100(%)
물-가스비율(WGR)	비공개 데이터
저류층 압력	비공개 데이터
플랫폼 설비 운영압력	비공개 데이터

훈련을 위한 데이터셋 인자는 비공개 데이터이지만 물-가스비율과 저류층 압력은 Horn River Basin 모델에 비해 낮고 플랫폼 설비 운영압력은 고정되어 운영된다.

위의 범위를 설정한 후, Latin Hypercube Sampling 방법을 사용하여 각 인자에서의 인자 추출을 균일하게 수행한 1000개의 데이터를 생성하였다.

예측에 사용할 순방향신경망 학습모델의 구조는 그림 14과 같다.



그림 14. Rakhine Basin 필드 모델을 활용한 순방향신경망 학습모델의 구조

입력 인자로 기존 초크 개방도와 해상 플랫폼에서의 가스 부피유량, 물-가스비율, 운영 조건 변경 후 초크 개방도를 선정하였으며, 출력 인

자로 최대 액체 서지 부피와 운영 조건 변경 후 해상 플랫폼에서의 가스 부피유량과 물 부피유량을 선정하였다.


순방향신경망은 제3장의 경우와 같이 크기가 15인 은닉층을 하나만 가지는 간단한 구조로 설정하였으며, 예측 성능이 좋지 않거나 문제가 발생할 시에 더 복잡한 구조를 가지는 순방향신경망이나 다른 기계학습 기법을 활용할 수 있다. 훈련 알고리즘은 Levenberg-Marquardt 방법을 사용하였다.

생성한 1000개의 데이터 중 시뮬레이션이 정상적으로 수행되지 않아 오류가 발생한 하나의 데이터를 제외한 999개의 결과 데이터를 추출하였다. 이를 훈련:검증:평가 데이터의 개수를 각각 6:1:3의 비율로 임의로 분배하여 훈련 데이터셋을 생성하였다.


4.3 학습 및 예측 결과

모든 입력 인자와 출력 인자에 대해 최소-최대 스케일링을 적용하였으며, 위의 내용으로 학습을 진행하여 운영 조건 변경 후의 가스 부피유량, 물 부피유량, 최대 액체 서지 부피에 대한 예측 결과는 그림 15의 A~I와 같다.


그림 15. Rakhine Basin 필드 학습모델의 예측 그래프



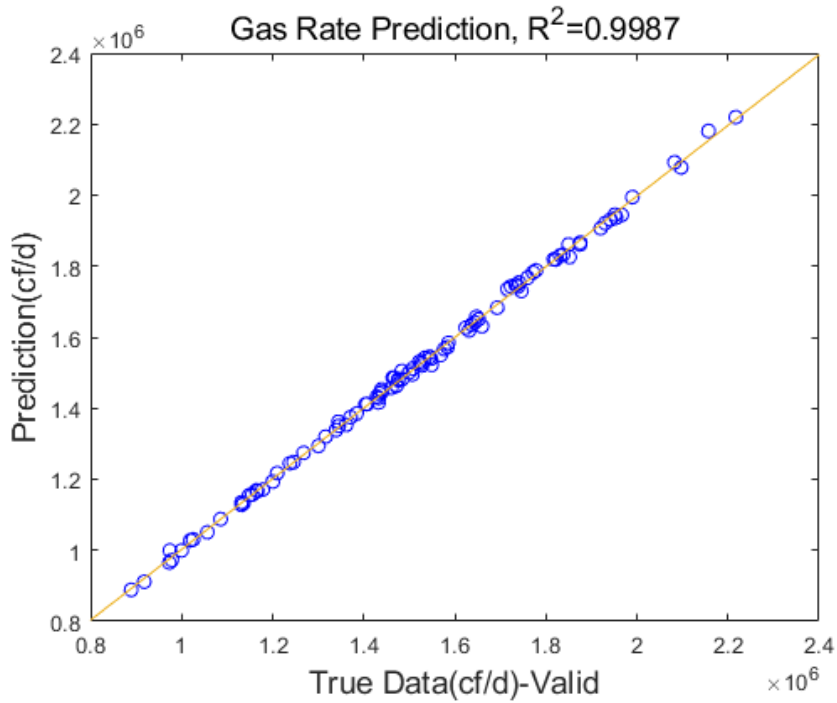
A. 가스 부피유량 예측(훈련 데이터)




B. 물 부피유량 예측(훈련 데이터)




C. 최대 액체 서지 부피 예측(훈련 데이터)




D. 가스 부피유량 예측(검증 데이터)




E. 물 부피유량 예측(검증 데이터)




F. 최대 액체 서지 부피 예측(검증 데이터)



G. 가스 부피유량 예측(시험 데이터)



H. 물 부피유량 예측(시험 데이터)



I. 최대 액체 서지 부피 예측(시험 데이터)

Horn River Basin 모델과 비교하였을 때, 물 부피유량과 최대 액체 서지 부피 예측에 대한 결정 계수가 높음을 알 수 있다. 이는 Rakhine Basin 모델의 물-가스비율이 Horn River Basin 모델의 물-가스비율에 비해 낮기 때문에 Horn River Basin 모델 분석 결과에서 도출된 물-가스비율이 높은 경우 물 부피유량과 최대 액체 서지 부피에 대한 예측 정확도가 감소하는 현상이 없기 때문이다.

학습 모델의 정두 압력 변경 후 부피유량과 최대 액체 서지 부피 예측 결정 계수가 유동 길이가 짧은 Horn River Basin 모델에 비교하여도 뚜렷한 결정 계수의 감소 없이 0.99 이상의 높은 예측 정확도를 보이는 것을 확인하였다. 이 경향은 훈련 데이터, 검증 데이터, 시험 데이터에 대하여 모두 동일하게 나타나며, 이로부터 유동 길이가 길어져도 학습 모델의 성능이 안정적인 것을 확인할 수 있다.

제 5 장 정두압력의 단계적 조절 적용

5.1 분석 필요성 및 모델 개요

앞에 제시된 기계학습 모델을 이용하여 운영 조건 변경 시에 발생하는 최대 액체 서지 부피 예측을 수행한 후 문제가 발생할 것으로 예상되는 경우, 해당 운영 조건을 피하거나 여러 단계에 걸쳐 정두압력 조건을 변경하는 조치가 가능하다. 반드시 변경하고자 하는 운영 조건을 맞추어야 할 경우, 필드에서 정두압력을 한 번에 낮추지 않고 여러 단계에 나누어 낮추면 목표 운영 조건을 맞추는 시간은 더 오래 걸리지만 최대 액체 서지 부피가 줄어드는 효과가 있다. 따라서 정두압력을 단계적으로 조절하는 경우에 대한 최대 액체 서지 부피 예측 모델을 구축하여 한 번에 조절하는 기존 모델과 함께 현장에서 전문가의 의사결정에 대한 지침으로 제공할 수 있다.

Horn River Basin 모델을 활용하여 단계적 조절 예측 학습모델 구축을 수행하였으며, 저류층 인자 및 유정 기하는 동일하다.

5.2 훈련 데이터 및 모델 구성

훈련 데이터셋 구축을 위한 시뮬레이션 인자들과 그 값 범위에 대한 설정은 표 8과 같다.

표 8. 단계적 압력 조절을 적용한 학습모델 구축을 위한 데이터셋 인자 및 값 범위

데이터셋 인자	값 범위(단위)
기존 정두압력	700~1000(psia)
물-가스비율(WGR)	300~3000(STB/MMscf)

저류층 압력	5500~7250(psia)
총 수압 파쇄 단계 수	1~4(정수형)
압력감소 단계 수	1~4(정수형)
단계별 압력 감소량	10~80(psia, 10단위 이산값)
마지막 압력 보정	0~단계별 압력 감소량(psia)

위의 범위를 설정한 후, Latin Hypercube Sampling 방법을 사용하여 각 인자에서의 인자 추출을 균일하게 수행한 2000개의 데이터를 생성하였다.

예측에 사용할 순방향신경망 학습모델의 구조는 그림 16과 같다.




그림 16. 단계적 압력 조절을 적용한 순방향신경망 학습모델의 구조

입력 인자로 기존 정두압력과 가스 부피유량, 물-가스비율, 총 수압 파쇄 단계 수를 선정하였으며, 기존 모델에서의 운영 조건 변경 후 정두 압력을 총 압력 조절 단계 수, 단계별 압력 감소 정도와 마지막 압력 보정으로 나누어 구성하였다. 마지막 압력 보정은 총 압력 감소량이 압력 감소 단계 수로 정확히 나누어 떨어지지 않는 경우를 위해 마지막 조절 압력을 0과 설정된 단계별 압력 감소 정도의 사잇값으로 두어 임의의 총 압력 감소량을 구현하기 위한 것이다. 출력 인자로 최대 액체 서지 부피와 운영 조건 변경 후 가스 부피유량과 물 부피유량을 선정하였다.


순방향신경망은 제3장의 경우와 같이 크기가 15인 은닉층을 하나만 가지는 간단한 구조로 설정하였으며, 예측 성능이 좋지 않거나 문제가 발생할 시에 더 복잡한 구조를 가지는 순방향신경망이나 다른 기계학습 기법을 활용할 수 있다. 훈련 알고리즘은 Levenberg-Marquardt 방법을 사용하였다.

생성한 2000개의 데이터 중 시뮬레이션 오류가 나거나 마지막에 유량이 안정되지 않는 불안정한 모델이 없었으므로 2000개의 데이터셋을 훈련:검증:평가 데이터 비율을 6:1:3로 임의로 분배하여 훈련 데이터셋을 생성하였다.


5.3 학습 및 예측 결과

모든 입력 인자와 출력 인자에 대해 최소-최대 스케일링을 적용하였으며, 위의 내용으로 학습을 진행하여 운영 조건 변경 후의 최종 가스 부피유량, 물 부피유량, 최대 액체 서지 부피에 대한 예측 결과는 그림 17의 A~I와 같다.

그림 17. 단계적 압력 조절을 적용한 학습모델의 예측 결과




A. 가스 부피유량 예측(훈련 데이터)



B. 물 부피유량 예측(훈련 데이터)

Prediction of Maximum Liquid Surge Volume(dt=90s)

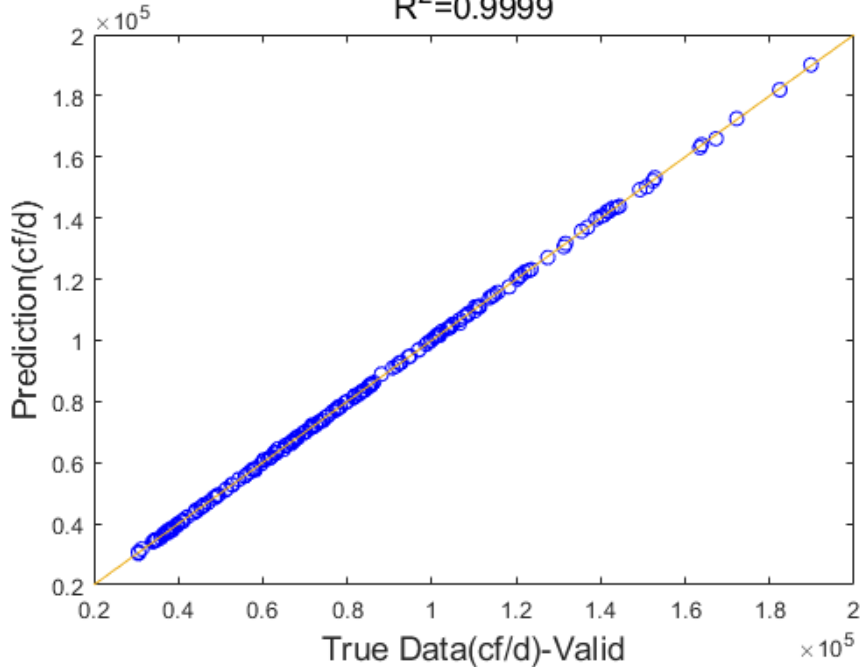
$R^2=0.9999$




C. 최대 액체 서지 부피 예측(훈련 데이터)

Prediction of Gas Volume Flow Rate


$R^2=0.9999$




D. 가스 부피유량 예측(검증 데이터)




E. 물 부피유량 예측(검증 데이터)



F. 최대 액체 서지 부피예측(검증 데이터)




G. 가스 부피유량 예측(시험 데이터)



H. 물 부피유량 예측(시험 데이터)

Prediction of Maximum Liquid Surge Volume(dt=90s)

$R^2=0.9998$



I. 최대 액체 서지 부피 예측(시험 데이터)

그래프로부터 학습 모델의 운영 조건 변경 후 유량과 최대 액체 서지 부피 예측 결정 계수가 기존 모델보다 더 높아 1에 가까운 정확도를 보이는 것을 확인할 수 있다. 이는 기존 예측 모델보다 조절되는 압력 감소 단위가 작아 예측 성능이 좋아진 것으로 해석된다.

예측 결과를 구체적으로 확인하기 위하여 하나의 예시 데이터를 임의로 선정하였으며, 해당 예시 데이터의 입력 자료는 표 9와 같다.


표 9. 단계적 압력 조절 적용 예시 데이터의 입력 자료

데이터셋 인자	값(단위)
기존 정두압력	956.9405(psia)
물-가스비율(WGR)	1288.1174(STB/MMscf)
저류층 압력	6323.9904(psia)
총 수압 파쇄 단계 수	4
압력 감소 단계 수	4
압력 감소 단계 정도	50(psia)


임의 압력 보정	30.2830 (psia)
전체 압력 감소량	169.7170 (psia)

위의 데이터로부터 가스 부피유량, 물 부피유량, 최대 액체 서지 부피를 구하고 모델을 통해 예측한 값을 표시한 그래프는 그림 18의 A, B와 같다.

그림 18. 단계적 압력 조절을 적용한 모델의 예측 예시 그래프



A. 가스 부피유량 예측 예시 그래프



B. 물 부피유량 및 최대 액체 서지 부피 예측 예시 그래프

그래프로부터 학습 모델이 운영 조건 변경 후 최종 가스 부피유량, 물 부피유량과 최대 액체 서지 부피를 잘 예측하는 것을 확인할 수 있다. 또한, 압력 조절 단계 수를 증가시키면 최대 액체 서지 부피가 감소하는 경향을 파악할 수 있으며, 학습모델이 이를 잘 예측하는 것을 결과값으

로 확인할 수 있다.

제 6 장 결 론

본 연구에서는 가스정에서 운영 조건을 변경하였을 때 변화되는 유량과 최대 액체 서지 부피를 예측하는 순방향신경망 학습모델을 구축하였다. 유동 모델 분석 및 학습모델 구축 과정에서 아래와 같은 결론을 도출하였다.

1. 본 연구에서는 Horn River Basin의 세일가스전 자료를 토대로 운영 조건을 변경하였을 때의 최대 액체 서지 부피와 가스 유량, 물 유량을 예측하는 순방향신경망 기계학습 모델을 구축하였다. 현장에서 모니터링 할 수 있는 운영 조건인 변경 전과 후의 정두 압력, 물-가스비율, 가스 부피유량, 총 수압 파쇄 단계 수를 입력 인자로 하고 정두 압력을 변경하였을 때의 가스 부피유량, 물 부피유량과 최대 액체 서지 부피를 출력 인자로 하였다. 예측 결과, 가스 부피유량, 물 부피유량, 최대 액체 서지 부피의 예측 결정 계수가 0.97이상으로 예측 정확도가 높음을 확인할 수 있었다.
2. 본 연구에서 구축한 순방향신경망 학습 모델은 전체적으로 예측 결정 계수가 높은 편이지만 물 부피유량과 최대 액체 서지 부피 예측에서 예측 경향에 벗어나는 경우가 일부 발생하였다. 이에 대한 영향 인자를 파악하기 위하여 저류층 압력, 물-가스비율, 정두 압력에 대하여 각 수치가 높을 때와 낮을 때 예측 추세선 상에 어떻게 나타나는지를 분석하였다. 분석 결과, 물-가스비율이 높은 경우에 추세선에서 벗어나는 경향이 있음을 확인하였다.
3. 본 연구의 대상인 Horn River Basin 모델은 전체 유동 길이가 3.5km 내외로 유동 길이가 짧아서 예측 성능이 매우 높게 나온 것으로 해석될 수 있다. 이를 확인하기 위해 해저면 정두와 해상 플랫폼을 이용하여 긴 유동 길이를 생산, 운송하는 Rakhine Basin 모델의 데이터를 활용하여 같은 구조의 순방향신경망 학

습 모델을 적용하였다. Rakhine Basin의 경우 해저면 정두부터 해상 플랫폼까지의 운송 구간의 수평 길이가 30km로 유동 길이가 보다 긴 특징이 있다. 예측 결과, 결정 계수는 0.99 이상으로 Horn River Basin 모델에 비해 뚜렷한 성능 감소 없이 높은 예측 성능을 보인다. 따라서 유동 길이가 길어도 순방향신경망 학습모델을 이용한 예측이 잘 수행되는 것을 확인하였다.

4. 학습 모델을 활용하여 정두압력을 변경하였을 때의 최대 액체 서지 부피를 예측하고 이 때 문제가 발생할 것으로 판단될 경우, 정두압력을 단계적으로 나누어 낮추는 방법으로 최대 액체 서지 부피를 줄여 문제를 해결할 수 있다. 이를 예측하기 위해 정두압력을 단계적으로 낮추는 경우에 대하여도 순방향신경망을 적용하여 최대 액체 서지 부피를 예측하는 학습 모델을 구축하였다. 해당 학습 모델은 입력 인자 중 변경할 정두압력을 감소시킬 단위 압력, 감소시킬 총 단계 수와 임의 압력 보정으로 바뀌어 구성하였으며, 예측 결과 매우 높은 예측 성능을 보임을 확인하였다.

참고 문헌

Bangert, P. (2020). Preventing Slugging by Tuning Choke through Machine Learning. *International Petroleum Technology Conference, Dhahran, Kingdom of Saudi Arabia, January 2020*. <https://doi.org/10.2523/IPTC-19931-Abstract>

Al-Hajri, Nasser M., & Abdullah A. (2019). Scale Prediction and Inhibition Design Using Machine Learning Techniques. *SPE Gas & Oil Technology Showcase and Conference, Dubai, UAE, October 2019*. <https://doi.org/10.2118/198646-ms>

Omrani P. Shoeibi, Dobrovolschi I., Loh K., & S. P. C. Belfroid. (2019). Slugging Monitoring and Classification with Machine Learning. *BHR-2019-007. BHR 19th International Conference on Multiphase Production Technology, Cannes, France, June 2019*.

Cheng D., & Daniel S. Zeosky. (2019). Pipeline Performance Data Analysis through Machine Learning with Hydraulics Model Assisted Training. *PSIG-1930. PSIG Annual Meeting, London, UK, May 2019*.

Alhashem, M. (2019). Supervised Machine Learning in Predicting Multiphase Flow Regimes in Horizontal Pipes. *Abu Dhabi International Petroleum Exhibition & Conference, Abu Dhabi, UAE, November 2019*. <https://doi.org/10.2118/197545-ms>

Shoham, O. (2005). Mechanistic Modeling of Gas-Liquid Two-Phase Flow in Pipes

Torpe, H., Godhavn, J.-M., Strand, S. T., Løvik, M., Tengesdal, J. Ø., & B. H. Pettersen. (2009). Liquid Surge Handling at ÅSgard by Model Predictive Control. *BHR-2009-A1. 14th International Conference on Multiphase Production Technology, Cannes, France, June 2009*.

Holmås, K., Gahr Lunde, G., Setyadi, G., Angelo, P., & G. Rudrum.

(2013). Prediction of Liquid Surge Waves at Ormen Lange. *BHR–2013–A4. 16th International Conference on Multiphase Production Technology, Cannes, France, June 2013.*

J. C. Helton, & F. J. Davis. (2003). Latin Hypercube Sampling and the Propagation of Uncertainty in Analyses of Complex Systems. *Reliability Engineering & System Safety*(Vol. 81, Issue 1, pp.23–69). [https://doi.org/10.1016/S0951-8320\(03\)00058-9](https://doi.org/10.1016/S0951-8320(03)00058-9).

V. Mulyandasari, & K. Kolmetz. (2011). Separator Vessels Selection and Sizing (Engineering Design Guideline), *KLM Technology Group, Practical Engineering Guidelines for Processing Plant Solutions, January 2011.*

S. Kotsiantis, I. D. Zaharakis, & P. E. Pintelas. (2006). Machine Learning: A review of Classification and Combining Techniques. *Artificial Intelligence Review* 26(3):159–190. <https://doi.org/10.1007/s10462-007-9052-3>

Reynolds, M. M., & D. L. Munn. (2010). Development Update for an Emerging Shale Gas Giant Field–Horn River Basin, British Columbia, Canada. *SPE–130103–MS. SPE Unconventional Gas Conference, Pittsburgh, Pennsylvania, USA, February 2010.* <https://doi.org/10.2118/1301031-ms>

Smith, H. V. (1987). Oil and Gas Separators, *Petroleum Engineering Handbook, Society of Petroleum Engineers*

Abstract

Prediction of Liquid Surge for Gas Wells Using Machine Learning

Youngwoo Yun

Department of Energy Systems Engineering

The Graduate School

Seoul National University

Liquid surge is the inflow liquid volume during a time interval in the pipeline flow. To analyze the liquid surge problem, the multiphase flow simulator is used. On the other hand, the license cost of the flow simulator is high, and the number of licenses is limited to apply to several wells. The machine learning model for predicting maximum liquid surge volume can resolve the problem of licenses. In this research, the feedforward network is used. The input variables are previous wellhead pressure, target wellhead pressure, gas volume flow rate, water–gas ratio, and the number of fracture stages for hydraulic fractured shale gas well. The output variables are gas and water volume flow rate after adjusting pressure, and maximum liquid surge volume. Although the prediction accuracy is high with a coefficient of determination of 0.9 or more, the prediction ability decreases when the water–gas ratio is high. Furthermore, the feedforward network model has no significant prediction ability decrease when the pipeline length becomes longer. In addition, sequential adjusting, one of the solutions for liquid surge problem, is applied to feedforward network model, which has high prediction

accuracy.

Keywords : Liquid Surge, Feedforward Network, Prediction of Maximum Liquid Surge Volume, Sequential Dropping Wellhead Pressure

Student Number : 2020-22122