



오일 생산정에서 초크사이즈와 가스주입량에 따른 생산성 예측 인공신경망 모델 개발

한동권 · †권순일

동아대학교 에너지자원공학과

(2018년 6월 19일 접수, 2018년 12월 17일 수정, 2018년 12월 18일 채택)

Development of Productivity Prediction Model according to Choke Size and Gas Injection Rate by using ANN(Artificial Neural Network) at Oil Producer

Dong-kwon Han · †Sun-il Kwon

Dept. of Energy and Mineral Resources Engineering, Dong-A University,
Busan, 550-37, Korea

(Received June 19, 2018; Revised December 17, 2018; Accepted December 18, 2018)

요 약

본 연구에서는 초크크기와 가스주입량을 조절함으로써 일반 유정이나 가스리프트가 적용된 유정에서 최적 생산량을 산출할 수 있는 두 가지 인공신경망 모델을 개발하였다. 개발된 모델들의 입력자료는 용해가스-오일 비, 물 생산 비율, 저류층압력, 초크크기 또는 가스주입량이고 출력자료는 정두압력과 오일 생산량으로 구성하였다. 먼저 육상 유정 시스템에 대하여 입력자료의 민감도 분석을 통해 각 변수의 범위를 결정하였고, 노달분석을 수행하여 초크크기 선정 모델에 1,715개, 가스주입량 선정 모델에 1,225개의 훈련자료를 각각 생성하였다. 동일한 저류층 자료에 대해 노달분석과 인공신경망 모델 결과를 비교해보면 두 모델 모두 결정계수 값이 0.99 이상으로 상관관계가 매우 높은 것으로 확인되었다. 또한 초크크기 선정 모델의 정두압력과 오일 생산량의 평균절대백분율오차는 각각 0.55%, 1.05%이고, 가스주입량 선정 모델의 정두압력과 오일 생산량의 평균절대백분율오차는 각각 1.23%, 2.67%로 개발된 모델의 정확도가 높은 것으로 확인되었다.

Abstract - This paper presents the development of two ANN models which can predict an optimum production rate by controlling choke size in oil well, and gas injection rate in gas-lift well. The input data was solution gas-oil ratio, water cut, reservoir pressure, and choke size or gas injection rate. The output data was well-head pressure and production rate. Firstly, a range of each parameters was decided by conducting sensitive analysis of input data for onshore oil well. In addition, 1,715 sets training data for choke size decision model and 1,225 sets for gas injection rate decision model were generated by nodal analysis. From the results of comparing between the nodal analysis and the ANN on the same reservoir system showed that the correlation factors were very high(>0.99). Mean absolute error of wellhead pressure and oil production rate was 0.55%, 1.05% with the choke size model, respectively. And the gas injection rate model showed the errors of 1.23%, 2.67%. It was found that the developed models had been highly accurate.

Key words : choke size, gas lift, artificial neural network, nodal analysis, gas injection rate, oil production rate

†Corresponding author:sikwon@dau.ac.kr

Copyright © 2018 by The Korean Institute of Gas

I. 서론

2010년대 들어 주요 석유 메이저 기업들은 유가스전 생산현장에서 실시간 자료 모니터링, 빅데이터 및 인공지능(artificial intelligence ; AI)기법에 의한 해석을 수행하는 디지털오일필드라고 불리는 유전관리 통합 자동화 시스템을 운영하고자 기술 개발을 수행하고 있다[1]. 이 기술은 특히 탐사기간을 단축하고 생산성을 향상시키며 생산정을 효율적으로 관리하는데 활용되고 있다[2]. 쿠웨이트 국영 석유회사(kuwait oil company)는 kuwait digital oil field(KWiDF)라는 사업을 진행하고 있는데, 이 중에서 생산현장 관리 시스템인 스마트플로우(smart flow)는 인공지능망(artificial neural network ; ANN), 전문가시스템, 패턴인식을 이용하여 오일 유동 및 실시간 모니터링, 시각화 등을 자동으로 수행하는 것이 핵심이다. 이 회사는 이 기술을 이용하여 운영 비용을 감소시키고 의사결정에 이르는 시간을 단축시켜 경제성을 높이고 있다[3].

전통적으로 유전 현장에서 최적의 생산량을 도출하고 제어하는 방법으로 노달분석을 사용하는데, 이는 유입되는 지점과 유출되는 지점이 만나는 한 부분(노드)에서의 생산량과 압력을 분석하는 방법으로 주로 노드를 공저(bottomhole) 또는 정두(well-head)로 선정한다. 일반적으로 현장에서 생산량 조절을 위해 초크(choke)를 사용하기 때문에 초크크기에 따른 최적 생산량 분석은 정두를 노드로 노달 분석이 수행되어야 한다.

한편, 저류층압력이 낮아 자연적인 유동으로는 오일을 생산할 수 없거나 낮은 생산성으로 인해 경제성이 떨어지는 유전들이 많이 존재한다. 그런 연유로 육상 유전에는 대부분 생산 초기부터 인공채유(artificial lift)기법을 적용하는데, 이는 인공적으로 공저압력을 높여 생산을 가능하게 하거나 생산성을 향상시키는 방법이다. 인공채유에는 흡입대펌프(sucker rod pump), 가스리프트(gas lift), 전기펌프(electric submersible pump ; ESP), 수압피스톤펌프(hydraulic piston pump ; HPP) 등 여러 가지 방법들이 있는데 그 중 가스리프트는 생산관 하단부에 가스를 주입하는 방법이다. 가스리프트는 설치가 쉽고 유정심도에 제약이 없으며, 운영과 유지보수 비용이 저렴하고 생산량 제어가 비교적 간단하다는 장점이 있다[4].

유전 현장을 통합적으로 실시간 모니터링, 해석, 제어하는 디지털오일필드에서 각 생산정의 생산량을 조절하기 위해 매번 노달분석과 같은 공학적 분석을 수행할 수 없기 때문에 빠른 시간에 공학자의 판단을 대신할 수 있는 의사결정 모델의 적용이 필수

적이다. 전문가의 판단을 대신하는 인공지능 기법에는 학습에 기반한 인공지능망, 심층학습(deep learning), 기계학습(machine learning) 등과 최적화에 기반한 유전자알고리즘(genetic algorithm), 담금질모사법(simulated annealing) 등이 존재한다[5]. 이 중에서 인공지능망은 기본적인 정보를 처리하는 뉴런들이 모여 복잡한 일을 수행하는 인간의 두뇌에 기반을 두어 모델링 한 것으로 학습에 의하여 의사를 결정한다. 즉, 학습 자료들을 입력하고 알고리즘과 함수를 결정하여 훈련시키면 원하는 출력 값을 도출해주는 시스템이다[6].

가스리프트가 설치된 저류층의 생산성 향상을 위해 인공지능망 모델을 적용한 연구가 많이 수행되었다. 실제 40개 유정자료를 이용하여 새로운 생산정에 가스리프트를 적용 시 가장 최적화된 가스주입량과 주입심도를 예측하는 두 가지 인공지능망 모델 개발 연구[7], 가스리프트 설치 시 필요한 인자들을 고려하여 오일 생산량(production rate)이 최대가 되는 가스주입량을 예측할 수 있는 인공지능망 모델 개발 연구가 수행되었다[8]. 그러나 위 두 연구는 가스리프트 적용 시 최적 인자 산출을 통한 유정완결 설계에 중점을 둔 것으로서 생산이 진행 중인 유정에서 생산량 조절을 위해 가스주입량을 결정하는 방법은 제시되지 않았다.

이에 본 연구에서는 대상 유정의 유정완결 상태 및 저류층 특성을 고려한 후 입출력자료를 생성, 훈련하였으며 이를 기반으로 초크크기와 가스주입량 조절을 통해 적정 생산량을 산출할 수 있는 모델을 개발하였다. 본 연구에서 개발한 모델은 시뮬레이션에 의해 산출된 자료를 활용하였기 때문에 즉시 현장에 적용할 수는 없으나 이러한 방법이 디지털 오일필드 시대에 필요한 기술로 제안될 수 있음을 보여주는 것에 초점이 맞추어져 있다.

II. 이론적 고찰

2.1. 노달분석

일반적으로 오일 및 가스의 생산과정은 저류층에서 탄화수소가 유동하여 생산관을 따라 흐르며 지상에 위치한 정두장치를 통과하여 분리기로 보내져 오일, 가스, 물로 구분하여 저장된다(Fig. 1). 오일 및 가스 생산 시 유정제어는 정두에 위치한 초크의 크기 조절을 통해 생산 증가 및 감소가 이루어지는데 최적의 생산량을 결정하기 위해서는 노달분석이 필요하다. 노달분석 하에서 유정의 생산모델은 모든 요소에서의 에너지 손실 합으로부터 계산되는데, 이것은 압력으로 표현이 가능하며 시작 압력인

저류층압력과 마지막 압력인 분리기압력의 차이이다. 각 요소에서의 압력감소는 다음 식 (1)-(3)의 형태로 나타낼 수 있다. 노달분석은 생산시스템의 생산성을 평가하는 것으로 특정 노드에서 생산량과 압력감소의 관계를 계산하는 것이며 이를 그래프로

도시하여 표현가능하다(Fig. 2). 본 연구에서는 정두에서 측정된 자료를 인공신경망의 훈련자료로 활용하였는데 이때의 유입거동 곡선(inflow performance relationship ; IPR)은 정두거동 곡선(wellhead performance relationship ; WPR)이고, 유출거동 곡선




Fig. 1. Possible pressure losses in completed producing system.

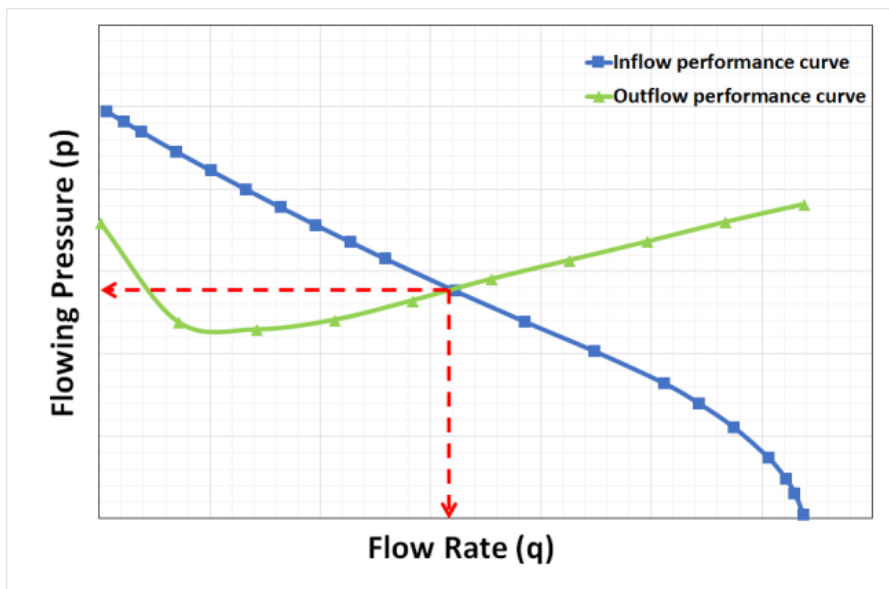


Fig. 2. Determination of system flow capacity using nodal analysis.

(outflow performance relationship ; OPR)은 초크 거동 곡선(choke performance relationship ; CPR)이다. 이때 두 곡선의 교차점을 통해 정두에서의 압력 및 생산량을 결정할 수 있다[9].

노달분석을 수행하는 이유는 크게 다음의 세 가지로 요약할 수 있다. 첫째, 주어진 생산정 유정완결 조건에서 생산량을 결정하며, 둘째, 어떠한 유동조건 하에서 생산정이 유지될 수 있는지 판단한다. 그리고 셋째, 인공채유시스템 설치의 최적시기와 적절한 방법을 선택한다.

$$\Delta P_1 = \overline{P}_r - P_{wf} \quad (1)$$

$$\Delta P_2 = P_{wf} - P_{wh} \quad (2)$$

$$\Delta P_3 = P_{wh} - P_{sep} \quad (3)$$

2.2. 가스리프트

가스리프트는 밸브를 통하여 가스를 주입해 저류층 유체와 혼합되어 밀도 감소와 주입가스 팽창에 의한 효과로 오일이 지상으로 쉽게 유동하도록 하는 인공채유기법 중 하나이다(Fig. 3). 가스리프트에는 가스를 환체(annulus)로 주입하여 생산관으로 생산하는 방법이 있고, 생산관으로 주입하여 환체로 생산하는 방법이 있다. 전자는 오일과 역청(Bitumen) 생산정에서 주로 사용되고, 후자는 석탄층 메탄가스(coal bed methane ; CBM) 생산정에서 주로 적용되는 방법이다.

가스리프트 운영에는 연속과 불연속이 있는데, 이 둘은 생산성으로 결정된다. 연속운영은 생산성지수(productivity index ; PI)가 0.5이상일 때 이루어지며, 0.5미만이 되면 불연속으로 변경된다. 연속운영은 자연유동과 유사한데 가스가 주입되면 오일이 연속적으로 생산되는 것이고, 불연속 운영은 가스가 계속 주입되어도 어느 정도 오일이 집적될 때까지 중단되어 있다 생산이 되는 것이다. 즉, 유동과 정지를 반복하는 운영이다.

가스리프트를 설계할 때는 케이싱, 생산관, 분리기, 밸브 등과 같은 운영장비의 선택과 유체유동 및 생산과 관련된 요소들이 다르기에 각 상황에 맞게 적절한 요소들을 고려하여 분석이 수행되어야 한다. 본 연구는 후자인 경우로 가스리프트가 적용되어 운영 중인 생산정을 대상으로 하였기 때문에 저류층압력, 정두압력, 물 생산 비율(water cut), 용해가스-오일비(solution gas-oil ratio ; solution GOR)를 고려해서 분석하였다. 가스리프트가 설치된 생산정의 성능은 노달분석을 이용해 판단할 수 있는데, 분석하고자 하는 변수에 따라 노드를 선택할 수

있다. 본 연구는 정두에서의 압력과 최적 생산량을 산출하였고, 또한 그 생산량에 대해 주입되어야 할 가스량을 계산하였다. 이 생산정의 최대 생산량과 그에 대응하는 가스주입량을 그래프로 알 수 있는데, 생산량이 최대일 때의 가스주입량이 최적화된 값은 아니다. 생산량이 최고점에 점차적으로 도달하면서 주입되는 가스량에 비해 생산량이 증가하는 비율이 감소한다. 즉, 이것은 적정 시점이 지나면 가스를 많이 주입하여도 기대했던 생산량보다 적게 산출된다는 의미이다. 또한 가스 압축 비용과 오일 가격 등 경제적인 요인에 따라 주입되어야 할 최적 가스량이 적어질 수 있다. 이런 요소들을 모두 고려하여 생산정 운영 시 적절한 가스주입량을 산출하여야 한다(Fig. 4)[10].

2.3. 인공신경망

인공신경망은 인간이 뇌를 통해 문제를 처리하는 방법을 모사한 것으로 판단이 필요한 문제들을 컴퓨터로 해결하기 위해 만든 수학적 모델이다. 인간의 뇌는 수천억 개 정도의 뉴런으로 구성되어 있으며 뉴런 상호 간 연결되어 있다. 인공신경망은 뉴런 간의 가중치할당을 통해 저장된 자료의 패턴과 특징을 발견해내는 훈련과정을 포함한다. 이는 지도학습 중 하나의 방법으로 기본적으로 입력 값




Fig. 3. Schematic of gas lift well system

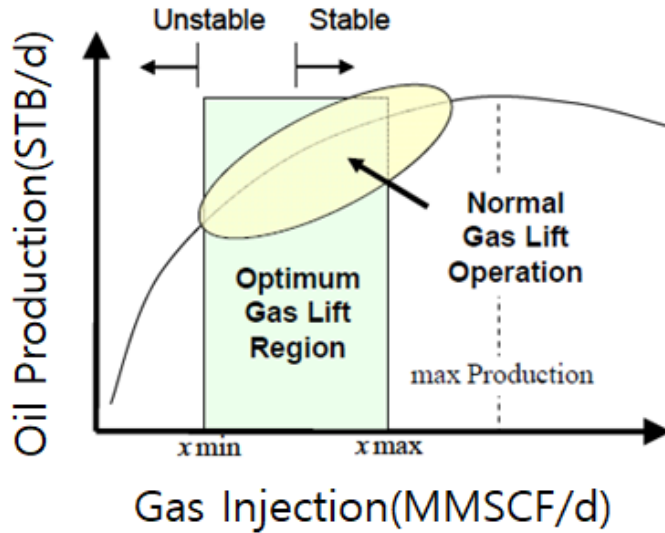


Fig. 4. Graph to determine the optimum gas rate in gas-lift well[10].




Fig. 5. Structure of basic neural network.

과 목표 값이 주어지는 형태이며 학습과정은 입력 값과 각 뉴런에 연결된 가중치(weight)를 곱하고 바이어스(bias)를 더한 값과 활성화 함수의 곱을 통해 산출한 출력값(Y)을 목표값과 비교하는 것이 기

본적인 신경망 구성법이다(Fig. 5)(식 4-5). 인공신경망 기법 중 널리 활용되는 역전파 알고리즘은 모델의 예측성능 향상을 위해 하위층에서 상위층으로 전파되면서 오차를 계산하고 이를 바탕으로 목표

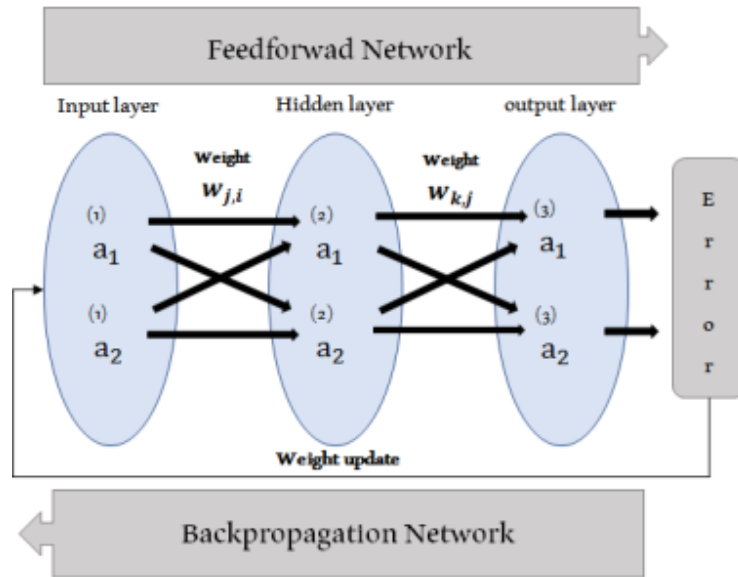


Fig. 6. Structure of an ANN using error back-propagation algorithm.

값에서 입력 값으로 역전파하면서 각 층에 연결된 가중치를 조정한다. 이를 통해 출력 값과 목표 값의 오차를 줄여가는 방향으로 진행된다(Fig. 6).

$$y = (input \times weight) + bias \quad (4)$$

$$Y = f(y) \quad (5)$$

III. 인공신경망 모델 및 실험결과

본 연구에서 개발한 초크크기 선정 모델과 가스 주입량 선정 모델에 활용된 역전파 알고리즘은 Levenberg-Marquardt로 훈련에 소요되는 시간이 짧으며 정확성이 높아 널리 활용되고 있는 알고리즘이다. 그리고 각 층을 연결하는 활성화 함수로는 log-sigmoid 함수를 이용하였으며, 은닉층 뉴런은 7개로 구성하였다. 인공신경망은 모델을 구성하는 입력 및 출력자료의 상관관계와 모델 정확도를 높이기 위해 입력력 변수와 그 범위를 결정하는 것이 중요하다. 두 가지 인공신경망 모델에 공통으로 적용되는 입력자료는 저류층압력, 용해가스-오일비, 물 생산 비율이다. 본 모델은 전 생산기간 동안의 저류층압력 강하에 따른 생산성 분석을 위해 저류층압력을 입력변수로 선정하였다. 저류층이 포화상태일 때 오일을 생산하면, 저류층압력이 강하하면서 오일에 용해되어 있던 가스가 빠져나와 용해가

스-오일비가 감소하기에 입력변수로 선정하였다. 물 생산 비율이란 총 유체 생산량에서 물이 차지하는 비율이다. 물이 생산되지 않는 유전은 거의 없고 물 생산 비율이 증가할수록 오일 생산량은 감소하기에 입력변수로 선정하였다. 생산량 제어 시 일반 유정에서는 초크크기를 조절하여 생산량을 제어하고 가스리프트가 적용된 유정에서는 가스주입량으로 생산량 제어가 이루어지기 때문에 초크크기와 가스주입량을 각각의 모델에서 입력변수로 설정하였다.

3.1. 초크크기 선정 모델 개발

이 모델의 입력자료는 저류층압력, 용해가스-오일비, 물 생산 비율, 초크크기이고 출력자료는 정두압력과 오일 생산량으로 구성되었다. 분석에 사용된 생산정은 서부 텍사스 육상 유정자료에 근거하여 물성들을 선정하였는데, 저류층 심도는 7,000 ft, 저류층 온도는 120 °F, 생산관 크기는 4 1/2 인치이고 초기 저류층압력은 4,050 psia 이다. 일반적으로 텍사스 지역의 오일은 황성분이 적고, 용해가스-오일비는 평균적으로 1,000 scf/STB 내외이다[11]. 생산기간 동안 변화가 큰 물 생산 비율과 초크크기의 범위는 노달분석을 수행하여 선정하였다. 물 생산 비율은 10%에서 90%까지의 범위에서 분석을 수행하였는데, 10%에서 70% 까지는 오일 생산량이 약 50 STB/D 씩 거의 일정하게 감소하는 경향을 보였




Fig. 7. Nodal analysis for selecting water cut range.

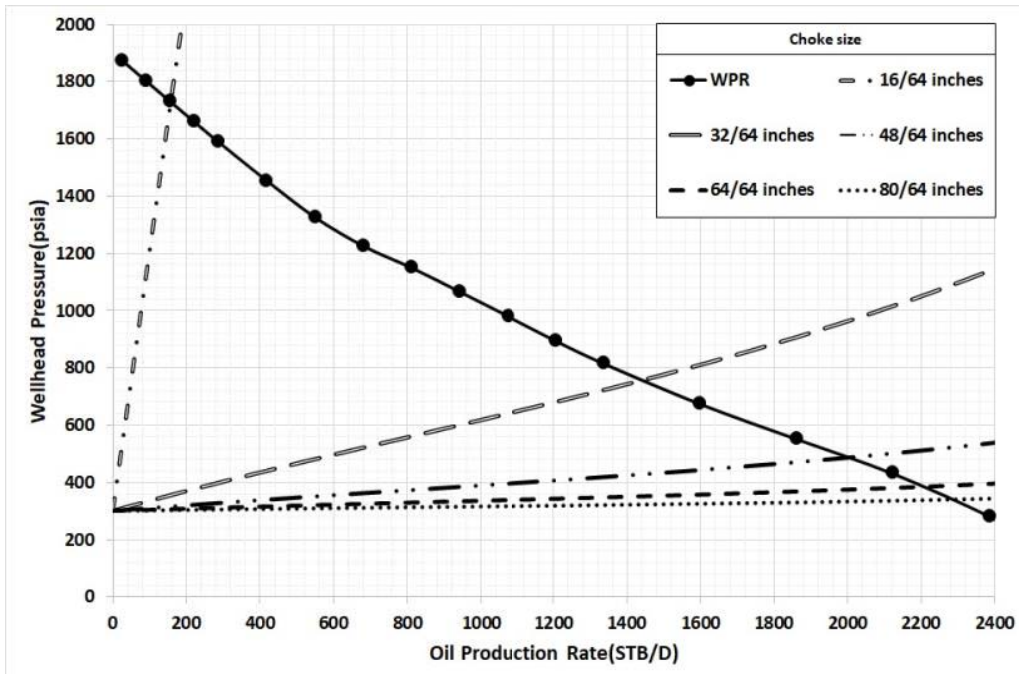


Fig. 8. Nodal analysis for selecting choke size range.

Table 1. Statistical range of parameter for input data(choke size ANN model).

Property	Solution GOR (scf/STB)	Choke size (1/64 in.)	Reservoir pressure (psia)	Water cut (%)
Min.	300	32	3,750	10
Max.	1,100	64	4,050	70
Mean	650	48	3,900	40

Table 2. Statistical range of parameter for output data(choke size ANN model).

Property	Oil production rate (STB/D)	Wellhead pressure (psia)
Min.	105	403
Max.	1,973	893
Mean	850	461

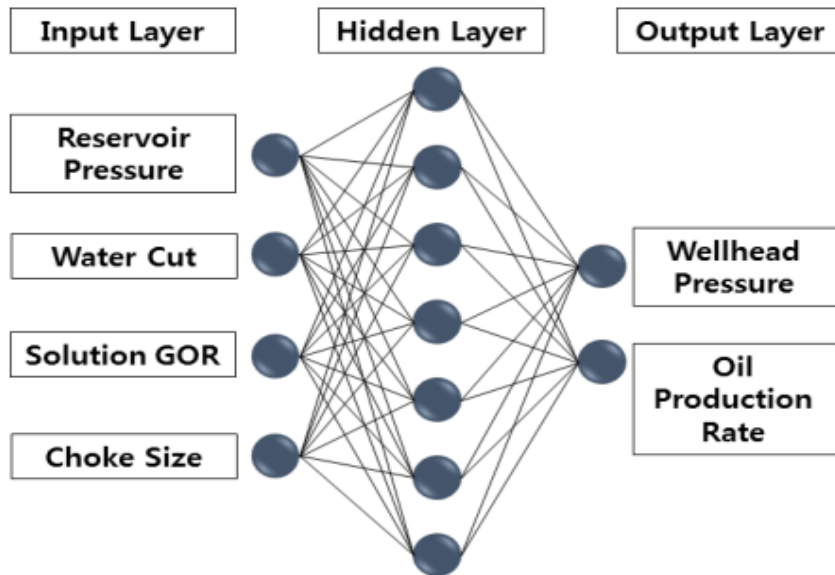


Fig. 9. Structure input-output data of ANN model in choke size selection.

다. 그 이후 물 생산 비율이 80% 되었을 때 약 70 STB/D 차이로 감소되었고, 90% 되었을 때는 약 80 STB/D 만큼이 감소되었다. 그 결과 물 생산 비율이 70%를 넘어가면 생산량이 크게 감소하므로 경제성이 없다고 판단하여 물 생산 비율의 범위를

10%에서 70%로 선정하였다(Fig. 7). 그러나 물처리 비용을 상쇄할 만큼 많은 오일생산이 이루어지는 저류층의 경우 높은 범위의 물 생산 비율의 학습자료 생성이 가능할 것으로 판단된다. 초크크기의 경우, 16/64 인치에서 32/64 인치로 증가할 때 오일

생산량이 약 150 STB/D에서 약 1,350 STB/D으로 상승하여 800% 증가율을 보였지만 32/64 인치에서 48/64 인치로 변화했을 시 1,350 STB/D에서 1,950 STB/D로 증가되어 44%가 향상되는 경향을 보였다. 48/64 인치에서 64/64 인치로 조절했을 때는 13% 증산되었고 64/64 인치에서 80/64 인치로 늘어날 때는 약 2,200 STB/D에서 약 2,280 STB/D 상승하였는데 증가율이 4%로 미미하였다. 이 결과를 바탕으로 16/64 인치는 실제적으로 현장에서 적용하기에는 너무 작은 사이즈이기 때문에 분석에서 제외하였고 80/64 인치 초크크기는 생산량 증가율이 4%로 영향이 미미하다고 생각하여 제외한 후 범위를 선정하였다(Fig. 8).

위의 과정을 거쳐 선정한 입력자료의 범위는 Table 1과 같으며 노달분석을 통해 계산된 출력자료의 범위는 Table 2와 같다. 노달분석을 통해 산출

된 1,715개의 훈련자료들을 이용해 개발한 인공지능 경망 모델의 구조도는 Fig. 9와 같다.

3.2. 초크크기 선정 모델 실험 결과

이 모델의 훈련자료는 총 1,715개로 구성되어 있으며 전체자료 중 80%는 훈련자료, 10%는 검증자료, 10%는 시험자료로 활용되었다. 본 연구에서 개발한 모델의 예측성능을 검증하기 위해 결정계수(coefficient of determination ; R^2)와 평균절대백분율오차(mean absolute percentage error ; MAPE) 지표를 활용하였다. 결정계수는 선형회귀 모델에서 독립변수 X로 설명되는 응답 변수 y의 비례적인 변동량이며 제곱 회귀의 합(regression sum of squares ; SSR)을 제곱 총계의 합(total sum of squares ; SSTO)으로 나눈 값으로 나타낸다. SSTO는 제곱 회귀의 합과 제곱 오차의 합(residual sum of squares

Table 3. Statistical accuracy of choke size ANN model.

	Value	
	Wellhead pressure (psia)	Oil production rate (STB/D)
R^2	0.999	0.998
MAPE(%)	0.55	1.05

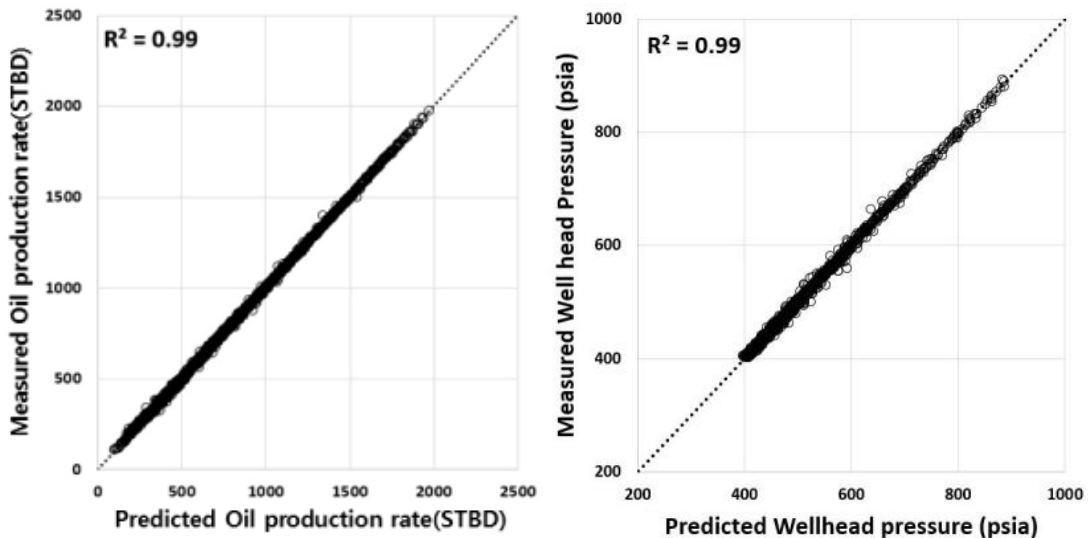


Fig. 10. Correlation of coefficient for choke size ANN model.

Table 4. Validity verification of choke size ANN model.

	Value	
	Wellhead pressure (psia)	Oil production rate (STB/D)
Theoretical data	472.7	767.6
Predicted data	471.4	769.4
Absolute error	1.3	1.8
Relative error(%)	0.28	0.23

; SSE)을 더한 값이다(식 6-10). 훈련 결과를 토대로 통계적 기법을 통해 인공신경망 모델의 정확성을 검증하였다. 훈련자료와 공학적 모델 출력자료의 비교결과 정두압력과 오일 생산량의 결정계수 값이 모두 0.99 이상으로 도출되었고, 평균절대백분율오차는 각각 0.55%, 1.05%로 개발된 모델의 정확도가 높은 것으로 확인되었다(Table 3, Fig. 10). 개발 모델의 타당성을 확인하기 위해 입출력자료의 범위 내 임의로 한 세트의 입력자료를 만들어 도출하고자 하는 정두압력 및 오일 생산량을 공학적 모델을 통해 산출하였다. 인공신경망 모델의 출력자료와 대조하여 절대오차 및 상대오차 값을 도출한 결과 정두압력과 오일 생산량의 절대오차는 각각 1.3, 1.8로, 상대오차는 각각 0.28%, 0.23%로 확인되었다(Table 4).

$$R^2 = \frac{SSR}{SSTO}, \quad SSTO = SSR + SSE \quad (6)$$

$$SSTO = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (7)$$

$$SSR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad (8)$$

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|X_{observed} - X_{predicted}|}{|X_{observed}|} \quad (10)$$

3.3. 가스주입량 선정 모델 개발

이 모델의 입력자료는 저류층압력, 용해가스-오일비, 물 생산 비율, 가스주입량으로 선정하였다. 또한 출력자료는 정두압력과 오일 생산량으로 구성하였다. 저류층의 특성과 물성 등을 고려하여 생산정 모델을 구성하였는데, 저류층심도는 7,500 ft, 저

류층압력은 2,000 psia, 저류층온도는 182 °F, 오일 비중은 35 °API, 가스비중은 0.65, 튜빙내경은 1.995 인치, 초크크기는 96(1/64 인치), 생산지수는 2.5 STB/D/psi, 기포점압 이상에서의 용해가스-오일비는 800 scf/STB, 기포점압은 저류층 모델과 조건이 유사한 Vasquez and Beggs 경험식을 적용하여 4,000 psia, 가스가 주입되는 운영 밸브의 심도는 4,025 ft 이다.

가스리프트를 적용한 생산정은 자연 유동으로 생산이 불가능한 유정으로 가정하였다. 저류층압력의 범위는 노달분석을 수행하여 인공채유기법을 사용해야만 생산할 수 있는 압력인 2,000 psia부터 시작하였다. 저류층압력이 2,000 psia 일 때는 오일 생산량이 약 210 STB/D가 되었고, 1,900 psia 에서는 약 140 STB/D, 1,800 psia 는 약 70 STB/D이고 1,700 psia 일 때는 약 40 STB/D 생산되었다. 1,600 psia 일 때는 약 20 STB/D로 오일이 생산되었지만 1,500 psia에서는 정두거동 곡선과 초크거동 곡선이 만나지 않는 것을 확인할 수 있었다. 그 결과 1,500 psia는 오일을 생산할 수 없는 저류층압력이라 판단하여 저류층압력의 범위를 1,600 psia에서 2,000 psia로 지정하였다(Fig. 11). Fig. 12를 보면 가스주입량이 300 Mscfd 일 때 오일 생산량이 가장 높았다. 그러나 경제적인 측면에서 주입가스 비용, 물 처리 비용 등을 고려하여 오일 생산량의 증가율이 미미한 지점을 최대 가스주입량으로 선정하였다. 그래프들을 살펴보면 가스주입량이 230 Mscfd를 기점으로 주입량이 늘어나도 오일 생산량이 거의 증가하지 않는다는 것을 확인할 수 있었다. 이 결과로부터 230 Mscfd를 최대 가스주입량으로 선정하였다. 그리고 최소 가스주입량은 가장 낮은 저류층압력인 1,600 psia에서 오일 생산량이 10 STB/D를 넘는 시점인 80 Mscfd로 선정하였다.

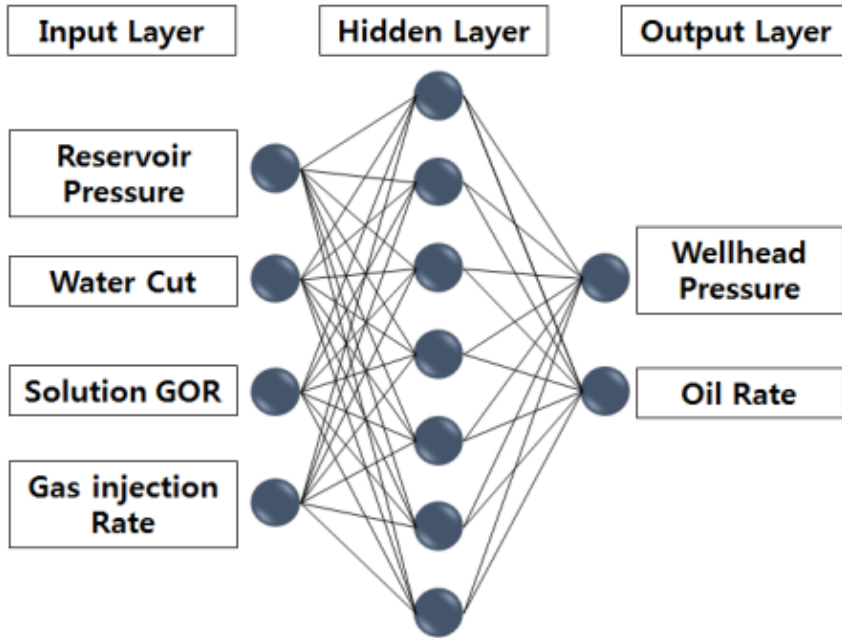


Fig. 11. Structure input-output data of ANN model in gas injection rate selection.

Table 5. Statistical range of parameter for input data(gas lift ANN model).

Property	Solution GOR (scf/STB)	Gas injection rate (Mscfd)	Reservoir pressure (psia)	Water cut (%)
Min.	250	80	1,600	0
Max.	350	230	2,000	60
Mean	300	155	1,800	30

Table 6. Statistical range of parameter for output data(gas lift ANN model).

Property	Oil production rate (STB/D)	Wellhead pressure (psia)
Min.	4	101
Max.	644	228
Mean	324	165

이를 통해 결정된 입력자료의 범위는 Table 5와 같으며, 출력자료의 범위는 Table 6과 같다. 본 연구에서는 노달분석을 통해 산출된 1,225개의 혼련

자료들을 이용하였는데, 개발된 인공지능망 모델의 구조는 Fig. 9의 입력자료에서 초크크기를 가스주입량으로 대체한 것과 같다(Fig. 11).

3.4. 가스주입량 선정 모델 실험 결과

본 모델에 사용된 훈련자료는 총 1,225개로 구성되어 있으며 전체자료 중 80%는 훈련자료, 10%는 검증자료, 10%는 시험자료로 활용되었다. 훈련 결과를 통계적으로 분석하여 인공신경망 모델의 적용성을 검증하였다. 훈련자료와 공학적 모델의 출력자료의 비교결과 정두압력과 오일 생산량의 결정계수 값은 0.99 이상으로 도출되었고, 평균절대백분율 오차는 각각 1.23%, 2.67%로 개발된 모델의 정확도가 높은 것으로 확인되었다(Table 7, Fig. 13). 개발

모델의 타당성을 확인하기 위해 학습자료 범위에 해당하는 임의의 한 세트의 입력자료(저류층압력 1750 psia, 물 생산 비율 35%, 용해가스-오일비 260 scf/STB, 가스주입량 200 Mscfd)를 개발모델에 입력하여 정두압력 및 오일 생산량을 산출하였다. 인공신경망 모델과 공학적 모델의 출력값의 절대오차 및 상대오차 값을 도출한 결과 정두압력과 오일 생산량의 절대오차는 각각 1.3, 2.1로, 상대오차는 각각 1.05%, 0.99%로 확인되었다(Table 8).

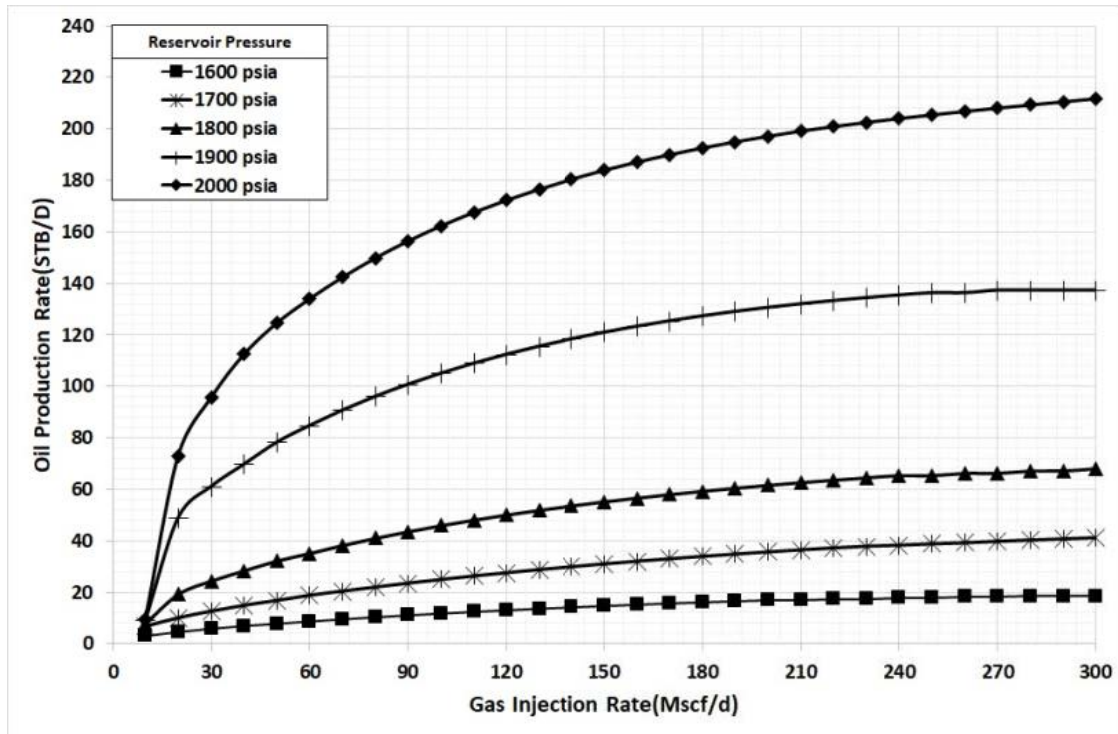


Fig. 12. Nodal analysis for selecting gas injection rate range.

Table 7. Statistical accuracy of gas lift ANN model.

	Value	
	Wellhead pressure (psia)	Oil production rate (STB/D)
R ²	0.993	0.999
MAPE(%)	1.23	2.67

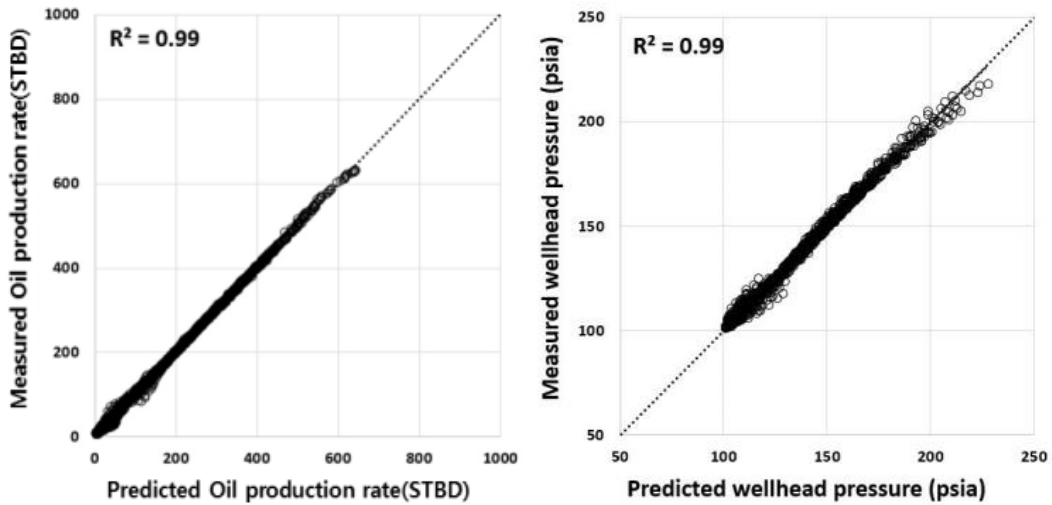


Fig. 13. Correlation of coefficient for gas lift ANN model.

Table 8. Validity verification of choke size ANN model.

	Value	
	Wellhead pressure (psia)	Oil production rate (STB/D)
Theoretical data	122	209
Predicted data	123.3	211.1
Absolute error	1.3	2.1
Relative error(%)	1.05	0.99

IV. 결론

본 연구에서는 초크크기와 가스주입량을 조절하여 생산량을 예측할 수 있는 두 가지 인공지능망 모델을 개발하였다. 이 모델은 매번 노달분석을 수행하지 않고 초크크기와 가스주입량에 따른 생산량을 산출할 수 있어 생산전문가를 활용할 수 없는 한계 유전이나 디지털오일필드 시스템이 적용된 현장에서 효과적으로 적용될 수 있을 것으로 판단된다. 개발된 모델은 생산에 영향을 미치는 인자를 도출하고 민감도 분석을 통해 입출력자료를 구성하였고, 일반적인 육상유전의 저류층 물성, 유정완결 특

성과 노달분석 결과를 토대로 입출력자료의 범위를 선정하여 자료를 훈련하였다. 뉴런 간의 가중치할당을 통해 저장된 자료의 패턴과 특징을 발견해내는 훈련 후 오차를 줄여나가는 과정을 거쳐 인공지능망 모델을 개발하였다. 그 후 동일한 저류층 자료를 입력자료로 하여 도출하고자 하는 정두압력 및 오일 생산량을 공학적 모델을 통해 산출하고, 통계적인 분석을 통해 적용성 및 적합성을 판단하였다. 공학적인 모델과 인공지능망 모델의 출력자료를 비교하여 분석한 결과 초크크기 선정 인공지능망 모델의 정두압력과 오일 생산량의 상대오차는 각각 0.28%, 0.23% 이고, 평균절대백분율오차는 각각 0.55%,

1.05%이다. 가스주입량 선정 인공신경망 모델의 정두압력과 오일 생산량의 상대오차는 각각 1.05%, 0.99%이고, 평균절대백분율오차는 각각 1.23%, 2.67%로 도출되었다. 모든 오차 범위가 3% 이내로 신뢰성을 있는 결과가 도출될 수 있음을 알 수 있었다. 본 모델은 디지털오일필드 시스템이 적용된 유전 중 생산전문가(production engineer) 활용이 용이하지 않은 소규모 유전에서 적용 가능한 기술로 판단된다. 또한 학습자료가 많을수록 인공신경망 모델의 정확도가 높아질 가능성이 있으므로, 향후 현장자료를 확보할 수 있다면 이 연구에서 개발한 인공신경망 모델을 재훈련시켜 신뢰성은 더 높아지고 그 유전에 최적화된 자료를 얻을 수 있을 것으로 사료된다.

감사의 글

본 연구는 2017년도 산업통상부의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다.(No. 20172510102090)

사용기호

\bar{P}_r	: Average reservoir pressure [psia]
P_{wf}	: Bottomhole pressure [psia]
P_{wh}	: Wellhead pressure [psia]
P_{sep}	: Separator pressure [psia]
R^2	: Coefficient of determination
MAPE	: Mean absolute percentage error [%]
SSR	: Regression sum of squares
SSE	: Residual sum of squares
SSTO	: Total sum of squares

REFERENCES

[1] Cramer, R., Gobel, D., Mueller, K., and Tullian, R., "A measure of the digital oil fields status - Is it the end of the beginning", SPE Intelligent Energy International, Utrecht, The Netherlands, March 27-29. SPE 149957, (2012).
 [2] Lim, J., Park, H. and Lim, J., "Classification

and application of digital oil field System", J. Korean Soc. Miner. Energy Resour. Eng, Vol. 51, No. 5, 750-756, (2014).
 [3] Al-Jasmi, A., Goel, H.K., Nasr, H., Carvajal, G.A., Johnson, D.W., Cullick, A.S., Rodriguez, J.A., Moricca, G., Velasquez, G., Villamizar, M. and Querales, M., "A surveillance 'Smart Flow' for intelligent digital production operations", SPE Digital Energy Conference and Exhibition, Woodlands, Texas, USA, March 5-7. SPE 163697, (2013).
 [4] Guo, B., Lyons, W.C., and Ghalambor, A., "Petroleum Production Engineering A Computer-Assisted Approach, Gulf Professional Publishing", Oxford, U.K., 182, (2007).
 [5] 김의중, 알고리즘으로 배우는 인공지능, 머신러닝, 딥러닝 입문, 위키북스, (2016).
 [6] Mohammed, A. Al-Khalifa. and Muhammad, A. and Al-Marhoun., "Application of neural network for two-phase flow through chokes", SPE Saudi Arabia section Annual Technical Symposium and Exhibition, Khobar, Saudi Arabia, May 19-22, SPE 169597, (2013).
 [7] Khamchchi, A., Rashidi, F. and Rasouli, H., "Prediction of Gas Lift Parameters Using Artificial Neural Networks", Enhanced Oil Recovery-Iranian Chemical Engineering Journal (Special Issue), Vol. 8, No. 43, (2009).
 [8] Ranjan, A., Verma, S. and Singh, Y., "Gas Lift Optimization using Artificial Neural Network", SPE Middle East Oil & Gas Show and Conference, Manama, Bahrain, March 8-11, SPE 172610, (2015).
 [9] Beggs, H.D., "Production Optimization Using Nodal Analysis", 2th Ed., Vol. 1, OGI and Petroskills Publications, Tulsa, USA, (2008).
 [10] Robert, N.H. and Potter, K., "Optimization of Gas-Injected Oil Wells", SAS Gloval Forum, (2011).
 [11] Sim, S.S.K., "Pressure-Volume-Temperature Correlations for Crud Oils from the Illinois Basin", Illinois State Geological Survey, 140, (1993).