



인공신경망과 SA 알고리즘을 이용한 지능형 생산정 위치 최적화 전산 모델 개발

곽태성 · 정지현 · 한동권 · [†]권순일

동아대학교 에너지자원공학과

(2014년 12월 9일 접수, 2015년 2월 11일 수정, 2015년 2월 12일 채택)

Development of Well Placement Optimization Model using Artificial Neural Network and Simulated Annealing

Tae-Sung Kwak · Ji-Hun Jung · Dong-Kwon Han · [†]Sun-Il Kwon

Dept. of Energy and Resource Engineering, Dong-A University, Busan 604-810, Korea

(Received December 9, 2014; Revised February 11, 2015; Accepted February 12, 2015)

요약

본 연구에서는 고속의 연산이 가능한 인공신경망 시뮬레이터와 SA 알고리즘을 결합하여 지능형 생산정 위치 최적화 전산 모델을 개발하였다. 기존의 사용하는 상용시뮬레이터의 경우 현장 규모의 저류 전산 시뮬레이션을 수행시 시간이 많이 소모되므로 이를 해결하기 위하여 이 모델에서는 인공신경망을 사용하여 짧은 시간 내에 시뮬레이션을 수행할 수 있도록 하였다. 이렇게 얻은 결과를 주관적인 경험에 의거하지 않고 자동으로 최적의 생산정 위치를 선정할 수 있도록 최적화기법인 SA 알고리즘을 적용하였다. 개발된 모델을 사용하여 얻은 결과를 기존 상용 시뮬레이터와 비교하여 예측성능이 양호함을 검증할 수 있었으며, 연산속도 또한 향상됨을 확인하였다. 특히 SA 최적화 알고리즘의 제어변수인 초기온도와 냉각률에 대한 민감도분석을 실시하여 각각에 대한 최적값을 산출하였으며, 이를 통해 개발한 모델의 연산성능을 향상시킬 수 있었다. 마지막으로 개발된 모델을 사용하여 생산정 위치 최적화를 수행한 결과, 생산성이 우수한 지역을 선정하여 최적의 생산정 위치를 도출하였다.

Abstract - This study presents the development of a well placement optimization model, combining an artificial neural network, which enables high-speed calculation, with a simulated annealing algorithm. The conventional FDM simulator takes excessive time when used to perform a field scale reservoir simulation. In order to solve this problem, an artificial neural network was applied to the model to allow the simulation to be executed within a short time. Also by using the given result, the optimization method, SA algorithm, was implemented to automatically select the optimal location without taking any subjective experiences into consideration. By comparing the result of the developed model with the eclipse simulator, it was found that the prediction performance of the developed model has become favorable, and the speed of calculation performance has also been improved. Especially, the optimum value was estimated by performing a sensitivity analysis for the cooling rate and the initial temperature, which is the control parameter of SA algorithm. From this result, it was verified that the calculation performance has been improved, as well. Lastly, an optimization for the well placement was performed using the model, and it concluded the optimized place for the well by selecting regions with great productivity.

Key words : ANN, simulated annealing, well placement

[†]Corresponding author: sikwon@dau.ac.kr

Copyright © 2015 by The Korean Institute of Gas

I. 서론

유·가스전 개발계획을 수립하는데 있어서 생산정의 위치를 선정하는 것은 매우 중요하다. 부적절한 위치에 생산정을 시추하는 경우 석유 개발의 특성상 막대한 손실이 발생될 수 있다. 이러한 손실을 피하기 위해서는 생산량에 영향을 미치는 생산정간 영향 반경, 저류층 물성, 운영비용, 유가등 다양한 인자들을 고려하여 생산 시나리오를 선정하고, 비교·분석하여 최적의 시나리오를 결정해야 한다. 하지만 현장 규모의 저류전산 시뮬레이션은 시간과 비용이 많이 소모되는 문제가 있다. 이러한 문제점을 해결하기 위해서는 고속의 연산이 가능한 시뮬레이터의 개발과 예측된 값을 바탕으로 다수의 시나리오를 자동으로 평가하여 최적의 생산정 위치를 선정할 수 있는 최적화 기법을 적용할 필요가 있다.

Doraisamy[1]와 Centilman[2]은 가스전을 대상으로 추가 생산정 위치 선정을 위한 인공신경망 시뮬레이터를 개발하였다. 인공신경망 모델에 대한 가이드 라인을 제시하고, 모델에 지질학적 특성을 적용하여 인공신경망의 예측성능을 향상시켰다. Min[3]은 불균질 가스전을 대상으로 추가 생산정의 개수에 따른 최적의 생산정 위치를 선정하는 연구를 수행하였다. 입력 자료에 생산성 잠재력 분포도를 사용하여 자료의 숫자를 최소화함으로 인공신경망 학습에 수행되는 시간을 단축하고 모델의 예측성능을 향상 시켰다. Han[4]은 생산중인 불균질 가스전을 대상으로 최대 공급계약량의 유지 기간을 증가시킬 수 있는 추가 생산정 위치 선정 연구를 수행하였다. 입력 자료에 압력 데이터를 추가하여 생산량뿐만 아니라 압력까지 정확하게 도출할 수 있는 모델을 개발하였다.

하지만 이전 연구들이 최적의 생산정 위치를 누적생산량이 가장 높은 곳으로 선정하였기 때문에 실제 현장처럼 경제성을 고려하여 개발계획을 수립하는 경우와는 상이하였고, 전체 시나리오 중 무작위로 선정한 일부 시나리오에서 최적의 값을 도출하였기 때문에 선정한 위치가 최적의 위치라고 보기에는 한계가 있다.

생산정 위치 선정은 경험이 많은 엔지니어의 판단이 필요하며, 이는 비용의 문제뿐만 아니라 결과가 주관적인 판단에 의해 좌우될 수 있는 단점이 있다. 따라서 다수의 생산시나리오에 대해서 최적의 생산정을 자동으로 선정할 수 있는 광역적 최적화 알고리즘이 필요하다.

Beckner[5]는 상용 시뮬레이터와 SA 알고리즘을 적용하여 대상 저류층 36개의 특정 위치에 대하여

최적의 수평정 위치를 선정하였다. 하지만 탐색시간이 크게 증가하는 한계가 있었다. Castineira[6]는 채널화된 심해퇴적물 저류층에 대하여 gradient method를 사용하여 자동으로 생산정 위치를 선정하는 연구를 진행하였다. 이 알고리즘을 사용하여 초기 추측 모델, 엔지니어의 판단, sequential optimization과 비교하여 타당성을 검증하였지만, 광역적 탐색을 하는 경우 지역해를 탈출할 수 없는 한계가 있었다. Jung[7]은 SA 알고리즘을 사용하여 생산자료 매칭을 통해 최적의 투과도와 공극률 분포를 규명할 수 있는 역산 모델을 개발함으로써, 석유공학 해석에서 SA 알고리즘의 적용성을 검증하였다.

생산정 위치 최적화를 위한 연구가 다방면에 걸쳐서 수행되고 있지만, 각각의 연구결과에 대해서는 한계점이 보였으며 이를 해결하기 위해 본 연구에서는 SA 알고리즘을 적용하였다. SA 알고리즘은 단일해를 사용하기 때문에 메모리 사용이 적고, 최적화하는 대상에 영향을 받지 않기 때문에 다양한 문제에 적용이 가능하다. 또한 전위 시뮬레이터로 고속의 연산이 가능한 인공신경망 시뮬레이터를 사용하기 때문에 일반 시뮬레이터 사용 시 가장 큰 단점인 연산시간이 증가하는 문제를 해결할 수 있다.

II. 생산정 위치 최적화 모델 개발

2.1. 모델 개발

인공신경망은 다른 알고리즘과는 다르게 학습과정이 필요하며, 이를 위해서 대상 저류층에 대한 정보를 습득하는 것이 중요하다. 따라서 전체 저류층을 모사할 수 있는 특정 위치를 다수 선정하여 시추 위치에 따른 생산량을 인공신경망 시뮬레이터에 학습 시켰다. 선택한 위치를 바탕으로 학습에 사용할 시나리오를 선정하여 저류 전산 시뮬레이션을 수행하고 그 결과로부터 출력 자료를 얻었다. 또한 출력 자료와 밀접한 관계가 있는 인자를 선정하여 입력 자료로 선정하였다. 입·출력 자료를 사용하여 인공신경망 시뮬레이터를 학습시키고, 훈련 시나리오에 포함되지 않은 위치의 결과를 저류 전산 시뮬레이터와 비교하였다.

Fig. 1은 인공신경망과 SA 알고리즘을 결합하여 개발한 생산정 위치 최적화 모델의 흐름도를 나타낸다. 이 모델은 추가 생산정을 시추하여 생산량 예측을 통한 순현재가치를 평가하는 인공신경망 전위 시뮬레이터와 예측한 값을 역산하여 최적 생산정의 위치를 탐색하는 SA 역산 모델로 구성된다.

개발된 모델을 이용하여 생산정 위치 최적화 탐

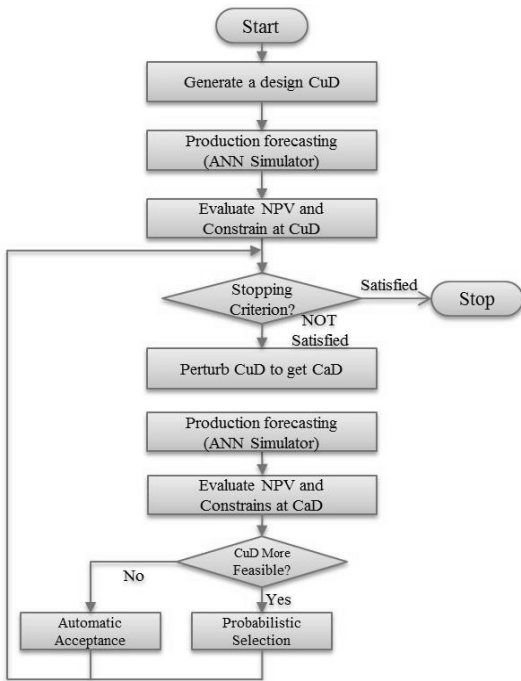


Fig. 1. Flow chart.

색은 다음과 같이 진행하였다. 먼저 무작위로 추가 생산정의 위치를 선정하거나, 또는 미리 정해진 좌표를 입력하여 current design을 생성한다. 생성된 design의 위치에 대한 생산량을 인공신경망 시뮬레이터가 예측하고, 목적함수인 순현재가치를 계산한다. 이후 design의 위치를 변경하여 candidate design을 생성하고, 마찬가지로 생산량 예측과 순현재가치를 평가한다. 두 개의 design을 상대평가하여 더 좋은 값을 차기의 current design으로 선택하고 종료조건에 도달할 때 까지 계속 반복한다. 이 때, metropolis algorithm에 의해서 덜 적합한 위치를 차기의 current design으로 선택하여 지역해 탈출을 가능하게 한다.

2.2. 저류층 시스템

저류층 시스템은 Fig. 2와 같다. 대상 저류층은 불균질 가스전이며, 크기는 가로 21,648 ft, 세로 20,336 ft, 두께는 1,000 ft이다. 현재 3개의 생산정을 통해서 생산이 진행되고 있으며, 생산된 가스는 파이프라인을 통하여 이송되고 있다. 또한 생산된 가스를 판매처로 보내기 위해서 정두압력을 1,900 psia가 되도록 유지시켜야 한다.

이 가스전의 경우 Eclipse를 이용한 시뮬레이션

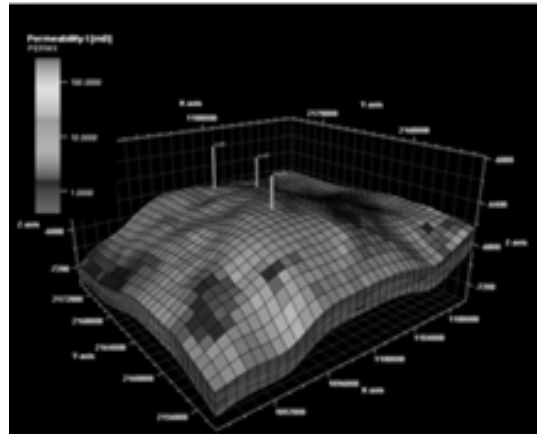


Fig. 2. Reservoir system.

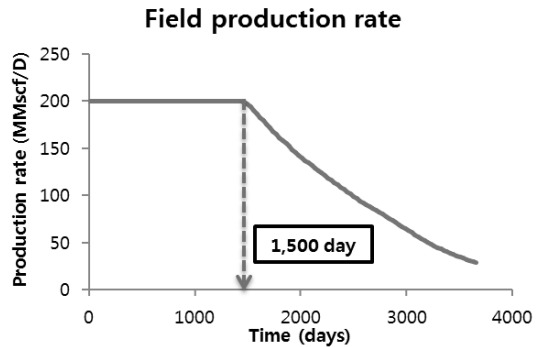


Fig. 3. Production rate of existing well.

결과, 1,500일이 지난 시점에서 생산량이 감퇴하여 판매처와의 최대공급계약량인 200 MMscf/d를 유지할 수 없는 것으로 나타났다(Fig. 3). 따라서 1,500일이 지난 시점에서 3개의 추가 생산정을 시추하여 최대공급계약량 유지 기간을 연장하였다.

이 저류층에 대한 학습자료를 얻기 위해서 격자를 33(656ft)x31(656ft)x12(20ft)로 구성하여 시뮬레이션을 수행하였고, 이를 위한 입력자료는 Table 1과 같다.

2.3. 훈련 생산정 선정

인공신경망은 훈련 생산정 범위내의 생산량을 바탕으로 보간법에 의해서 추가 생산정의 생산량을 예측한다. 훈련 범위 밖의 입력자료를 사용하여 생산량을 예측한 경우 예측성능이 크게 떨어질 수 있다. 따라서 훈련 생산정 선정 시 생산성이 높은 지역, 생산성이 낮은 지역을 모두 고려해야 한다.

Table 1. Simulation input data

Input data	
Maximum daily quantity (MMscf/d)	200
Maximum daily quantity per well (MMscf/d)	70
Average initial reservoir pressure(psia)	3,003
Wellhead pressure(psia)	1,900
Range of permeability(md)	20~300
Range of porosity(%)	24~27
k_v/k_h	0.1
Top depth of reservoir(ft)	6,200

유체투과도가 우수한 지역, 기존 생산정과 멀리 떨어져 간섭효과가 일어나지 않는 지역은 생산성이 우수할 것이라 기대된다. 하지만 저류층 경계지역, 단층, 기존 생산정과 인접한 지역등은 생산성이 떨어질 것이라 판단되며 이러한 위치에 훈련 생산정을 선정하여 인공신경망 시뮬레이터에 다양한 생산 패턴을 학습 시킬 필요가 있다[1].

Centilmen[2]은 저류층 경계지역, 기존 생산정과 인접한 지역에 훈련 생산정을 선정하였는데 이는 생산정의 위치가 생산량에 큰 영향을 준다고 가정하였기 때문이다. 하지만 실제 저류층의 경우 불확실성이 크기 때문에 기존 생산정과 영향반경 이상 떨어진 지역의 생산성이 우수할 것이라고 판단하기는 어렵다[3].

저류층의 생산성을 판단하기 위해서 생산정간 거리 외에 생산성 잠재력 분포도(PPM : Productivity Potential Maps)를 적용하였으며 이 인자는 저류층 위치에 따른 생산성을 간단한 방법으로 비교하기 위해서 개발되었다. 격자 크기, 유체 물성, 공저압력 등을 무시하고 오일 포화도가 오일의 상대투과도를 대체 가능하다고 가정하면 저류층 격자에서는 상대투과도가 가장 중요하다. 이 때 저류층 격자에 대한 단위 부피당 오일 함유량은 공극률과 오일 포화도의 곱으로 계산되고, 오일의 유동 능력은 유체 투과도와 오일 포화도의 곱으로 대체 하였다. 따라서 생산성 잠재력 분포도는 식 (1)에 의해 계산되고, n은 상관계수이다[8].

$$PPM = \sum k\phi S_o^n \quad (1)$$




Fig. 4. Well pattern for training well.

이 인자를 적용하면 생산정의 위치에 대한 생산성을 고려하여 인공신경망에 저류층의 지질학적 특성을 반영할 수 있다.

훈련 생산정의 수는 인공신경망 시뮬레이터의 예측성능에 영향을 주기 때문에 매우 중요하다. 훈련 생산정의 수가 증가하면 시뮬레이터의 예측성능은 향상되지만 학습에 소요되는 시간이 증가하므로 적절한 훈련 생산정의 수를 설정해야 한다.

이번 연구에서 선정한 불균질 가스전 저류층은 총 1032지역에 시추가 가능하며, 이 중 대수층 지역, 저류층 경계 지역, 기존 생산정과 인접한 지역을 제외한 시추 가능한 지역은 502곳이다. 이 지역에 총 3개의 추가 생산정을 시추해야 하므로 총 시나리오는 20,958,500개이다. 이러한 시나리오를 고려하여 생산성이 높다고 판단되는 지역 6곳, 낮다고 판단되는 지역 6곳 총 12개의 훈련 생산정을 선정하였다 (Fig. 4). 생산성이 높다고 판단되는 지역 6곳 중 3개를 선택하여 20개의 훈련 패턴 시나리오를 선정하였으며, 생산성이 높다고 판단되는 지역 6곳 중 1개와 생산성이 낮다고 판단되는 지역 6곳 중 2개를 선택하여 110개의 훈련 패턴 시나리오를 선정하였다. 이 130개의 시나리오에 대해서 14개의 특정 시간에 대하여 총 1820개의 훈련자료를 선정하였다. 이 훈련 패턴 시나리오를 이용하여 시뮬레이션을 수행하였으며 생산기간에 대한 총 분석기간은 1500일부터 3660일 까지 6년으로 설정하였다.

2.4. 인공신경망 시뮬레이터 구조 설계

생산정 위치 최적화를 위한 인공신경망은 역전파 신경망을 선택하였다. 역전파 신경망을 사용하여 생산량을 예측하면 생산량이 완만하게 감소하는 형태로 나타나게 되며, 회귀 신경망을 사용하는 경우 생산량이 급격한 변화를 나타내게 된다. 이번 연구에서 선정한 저류층은 생산량 감퇴 곡선이 특정 시간이 지남에 따라서 완만하게 감소하는 경향을 보이므로 역전파 신경망을 선정하는 것이 타당하다고 판단하였다.

인공신경망 훈련은 Matlab을 사용하여 실시하였으며, 신경망 학습을 위해 Levenberg-Marquardt 기반의 역전파 신경망을 사용하였다. 이를 통해서 얻은 가중치와 설계한 입출력 자료를 바탕으로 생산정 위치 최적화 모델은 마이크로소프트사 Visual Studio 2010 기반의 C++ 언어를 사용하여 개발하였으며 훈련 데이터를 얻기 위한 시뮬레이터는 Schlumberger사의 Eclipse를 사용하였다.

인공신경망 입출력 자료의 선정은 시뮬레이터의 예측성능에 영향을 주므로 매우 중요하다. 또한 불필요한 입출력 자료를 선정하면 생산량에 대한 패턴 인식을 정확하게 수행할 수 없기 때문에 예측성능이 크게 저하될 수 있다. 인공신경망의 입출력 자료는 이를 고려하여 Fig. 5와 같이 선정하였으며 입력 자료는 시간, 추가 생산정의 좌표, 저류층 경계(대수층 경계)와 추가 생산정간 거리, 기존 생산정과 추가 생산정간 거리, 추가 생산정간 거리, 생산성 잠재력 인자, 추가 생산정의 좌표 제곱으로 구성하였다. 또한 출력 자료는 추가 생산정간 동안 기존 생산정, 추가 생산정의 총 6개 생산정에 대한 생산량으로 나타냈다. 모든 입출력 자료는 -1과 1사이의 값으로 정규화시켰으며, 이는 인공신경망의 학습과정에서 수치적

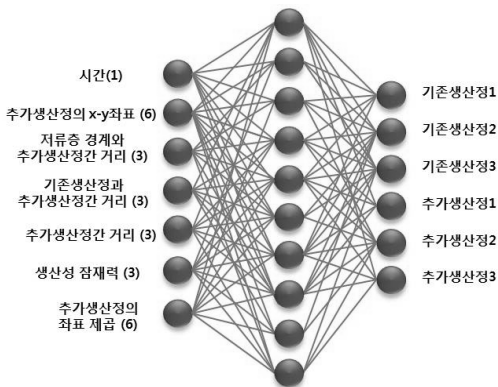


Fig. 5. The structure of input-output data.

안정성을 위한 방법이다.

2.5. 인공신경망 시뮬레이터 검증

인공신경망 시뮬레이터의 타당성을 검증하기 위하여 앞서 선정한 130개의 추가 생산 시나리오의 Eclipse 결과와 인공신경망 시뮬레이션의 예측 결과를 비교하였다(Fig. 6). 인공신경망의 예측성능을 평가하기 위하여 결정계수와 평균제곱오차를 사용하였다.

Table 2는 인공신경망 시뮬레이션의 예측성능을 평가한 통계인자 값이다. 결정계수는 0과 1사이의 값이 산출되며 1에 가까울수록 예측성능이 우수한 것을 나타낸다. 훈련 결과 결정계수는 0.99로서 매우 높은 선형성을 띠는 상관관계가 확인되었다. Fig. 7, Fig. 8은 경계지역 및 생산정간 간섭효과에 의해서 예측성능이 떨어질 것이라 판단되는 생산 시나리오를 선정하여 Eclipse와 비교한 그래프이다. 비교결과 예측결과가 양호한 것으로 나타났다. 이러한 10개의 생산시나리오에 대하여 동일한 방법으로 비

Table 2. Statistical parameter of ANN simulator

Statistical parameter	Value
Coefficient of determination	0.99
ARMS (Average Root Mean Square)	0.26
Performance	0.07

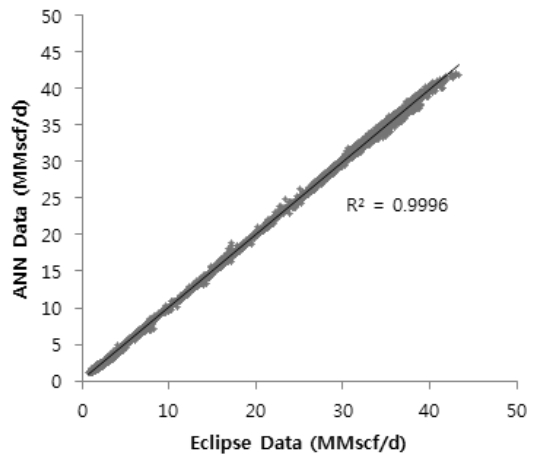


Fig. 6. Cross plot of output data for production rate.




Fig. 7. Well pattern for test well.




Fig. 8. Comparison of production rate for test well.

교·분석한 결과 결정계수는 0.97 오차율은 2.0으로 개발된 모델의 예측능력이 양호함을 검증하였다.

III. 생산정 위치 최적화 모델 민감도 분석

개발된 모델을 사용하여 최적의 생산정 위치 선정을 하기 위해서는 SA 알고리즘이 전위 시뮬레이터를 제어하여 얻어진 목적함수를 평가하여 최적의 값을 탐색해야 한다. 최적의 해 탐색은 목적함수에 의해서 영향을 받을 수 있으며, SA 알고리즘의 고유 파라미터인 초기온도와 냉각률에 의해서 영향을 받을 수 있다. 따라서 이러한 변수에 대한 민감도 분석을 실시하여 최적의 값을 도출하였다.

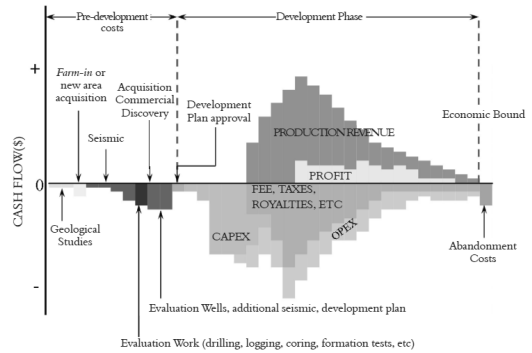


Fig. 9. A typical E&P cash-flow project based upon the Brazil Fiscal System[9].

3.1. 목적함수

생산정 위치 최적화 모델에 대한 목적함수는 순현재가치로 선정하였다. 순현재가치는 사업의 가치를 나타내며, 가스전 개발계획부터 생산기간이 끝날 때까지의 연도별 순편익의 흐름을 각각 현재가치로 계산하여 나타낼 수 있다. 순현재가치를 사용하여 사업의 투자가치를 분석할 수 있고, 이러한 분석을 통해서 사업에 대한 의사결정을 할 수 있다. 순현재가치는 식 (2)에 의해서 계산하였다.

$$NPV = \sum_{t=0}^n \left(\frac{CF_t}{(1+d)^t} \right) \quad (2)$$

여기서 CF_t 는 시간 t 동안의 현금흐름이며, d 는 시간 t 동안의 할인율이고, n 은 생산이 종료되는 시점이다. 이러한 현금흐름에 대한 인자들은 Fig. 9에서 확인할 수 있다. 순현재가치를 정확히 계산하기 위해서는 경제적인자를 적절하게 선정해야 하며 이 인자는 Table 3과 같이 선정하였다.

가스전 개발 계획에 있어서 가스가격의 변화에 따라서 기업이 얻을 수 있는 수익이 달라지기 때문에 가스 가격을 정확하게 예측하는 것이 중요하다. 가스가격은 식 (3)을 사용하여 예측하였다.

$$I = P_g (1 + R)^n \quad (3)$$

여기서 P_g 는 현재 가스 가격이며, R 은 가격 상승률, n 은 생산기간으로 정의한다. 위의 식을 바탕으로 가격 상승률을 10%라고 예측하여 가스가격을 Table 4와 같이 설정하였다[10].

순현재가치는 할인율에 따라서 달라진다. 먼저

Table 3. Economic paramter

Economic parameter	value
Capital expenditure	\$ 250,000,000
Operating expenditure per year	\$ 50,000,000
Cost of drilling new well	\$ 20,000,000
Tax	20%
Risk adjusted discount rate	15%
Gas price	4~7/MMbtu
Penalty factor for well distance	1500\$/ft

Table 4. Forecast of gas price

Year	Gas price at MMBtu
0	4.00
1	4.40
2	4.84
3	5.32
4	5.86
5	6.44
6	7.09

위험을 고려하지 않은 무위험수익률을 선정하고, 이후 미래 현금에 대한 불확실성이 적용된 위험조정할 인율을 적용하였다. 일반적으로 석유개발 사업에서 이자율은 15%에서 25% 사이에서 적용하며[11], 개발된 모델에 대해서는 추가 생산정을 시추하여 위험도가 낮다고 판단되므로 위험 적용이자율을 15%로 적용하였다. 개발한 모델은 가스전이 해상에 위치한다고 가정하였으며, 운영비용은 일정한 값으로 고정하여 적용하였다.

이렇게 선정한 경제적인자를 바탕으로 8개의 결과를 비교·분석 하였다. 그 결과는 Fig. 10과 같고 각각의 경우에 대해서 누적 생산량과 순현재가치의 관계에 대해서 분석하였다.

8개의 결과에 대해서 1번을 기준으로 4번과 5번의 경우는 순현재가치와 누적생산량의 관계가 비례하게 증가함을 확인할 수 있었다. 하지만 2번, 3번, 6번, 7번, 8번의 경우에는 누적생산량이 감소하였지만 순현재가치는 증가하는 것을 확인 하였다. 특히 7번과 8번의 결과는 누적생산량이 각각 190,827 MMscf, 191,669 MMscf로 1번의 202,289 MMscf보다




Fig. 10. Case of well placement for NPV vs cumulative production.

낮지만 순현재가치는 1번보다 약 4천만 달러 높은 것을 확인할 수 있었다. 이는 가스가격, 플랫폼과 시추위치에 따른 거리등 여러 변수에 따라서 누적생산량이 낮은 경우에도 순현재가치는 높을 수 있음을 나타낸다.

3.2. 초기온도 및 냉각률

생산정 위치 최적화 모델에 사용한 SA 알고리즘은 온도에 따라서 metropolis algorithm의 채택확률이 변경되어 광역탐색이 가능하다. 기존에 선정한 추가 생산정의 순현재가치와 좌표를 변경한 추가 생산정의 순현재가치를 상대평가하여 후자의 순현재가치가 더 높다면 그 위치를 선택한다. 그러나 전자의 경우가 더 높다면 metropolis algorithm에 의해서 선택하게 된다. 따라서 추가 생산정의 위치를 변경하였을 때 확률적으로 생산성이 낮은 위치도 선택하게 만든다. 이러한 확률을 제어하는 인자에 온도가 포함되어 있으며, 온도가 낮으면 지역해 탈출이 불리하고 온도가 높으면 수렴에 불필요한 시간이 소요된다. 따라서 초기 온도를 적절하게 설정해야 SA 알고리즘이 효율적인 연산을 실시 할 수 있다. 초기 온도는 초기채택확률인 P_0 를 변경하여 조절한다.

생산정 위치 최적화 모델에 대한 적절한 초기온도를 도출하기 위하여 초기채택확률을 0.5로 설정하고 목적함수인 순현재가치의 경향을 분석하였다. 탐색 초기에는 목적함수의 값이 급격한 변화를 나타냈으나 3,000 sweep(18,000 iteration)부근에서 순현재가치의 값이 개선되지 않고 수렴하는 것을 확인하여 종료조건을 3,000 sweep으로 설정하였다.

종료조건을 3,000 sweep으로 고정하고 초기채택확률을 0.5에서 0.9 사이의 값으로 설정하여 100회 반복 수행하였다. 그 결과는 Fig. 11에 도시하였다. 보다 정확한 분석을 위해 평균값과 상위 10% 평균을 사용하였다. 평균값만 사용하면 초기채택확률이

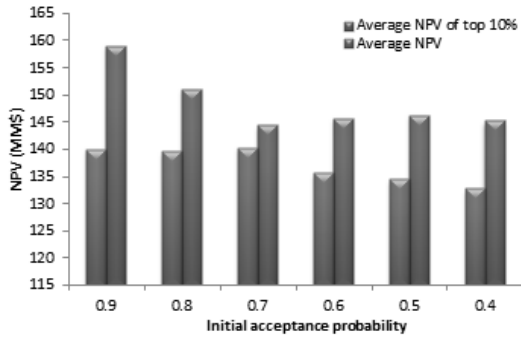


Fig. 11. NPV for initial acceptance probability.

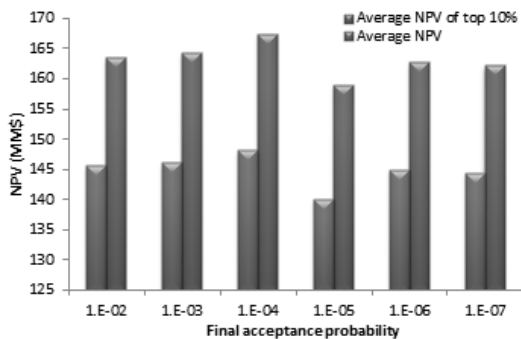


Fig. 12. NPV for final acceptance probability.

순현재가치에 미치는 영향을 확인할 수 있지만 최대값의 분포를 파악하기 어렵다. 따라서 상위 10%의 순현재가치 평균값을 함께 사용하여 초기채택확률을 선정하였다.

초기채택확률이 0.9일 때, 상위 10%의 순현재가치 평균이 가장 높았으며, 초기채택확률이 0.7로 감소함에 따라서 상위 10% 순현재가치 평균 또한 같이 감소하는 경향을 보인다. 순현재가치 평균값을 살펴보면 0.9, 0.8, 0.7일 때 차이가 거의 없음을 확인하였다. 초기채택확률이 높은 경우 광범위하게 탐색하므로 상위 10%의 순현재가치가 높지만 평균값은 0.8과 0.7인 경우와 차이를 보이지 않았다. 이 결과로부터 초기채택확률이 0.9 일 때, 탐색편차가 크다는 것을 알 수 있으며, 비효율적인 탐색이 증가하여 탐색횟수가 증가할 수 있다.

하지만 개발한 모델의 전위 시뮬레이터는 연산시간이 매우 짧기 때문에 탐색횟수의 증가가 연산시간에 크게 영향을 주지 않는다. 따라서 이번에 개발한 생산정 위치 최적화 모델은 초기채택확률을 0.9로 설정하는 것이 타당하다고 판단하였다.




Fig. 13. Best infill drilling well scenario.

냉각률은 온도를 감소시키는 변수로써 광역해를 도출하는데 중요한 요소이다. 냉각률을 낮게 설정하면 광역해 도달까지 탐색횟수가 증가하며 탐색횟수를 제한할 경우 광역해 탐색확률이 감소하게 된다. 반대로 냉각률을 너무 높게 설정하면 지역해에 빠질 가능성이 커지게 된다.

이러한 냉각률은 초기온도와 최종채택확률 (P_f)에 따라서 달라지며, 최종채택확률이 낮은 경우 냉각률은 높아진다. 앞선 민감도분석과 마찬가지로 종료조건을 3,000 sweep으로 설정하고 최종채택확률을 10^2 부터 10^7 사이의 값으로 변경하면서 100회 반복수행하였다. 그 결과는 Fig. 12에서 확인할 수 있다.

상위 10%의 평균과 평균 순현재가치 모두 최종채택확률이 10^4 일 때 가장 높게 나타났다. 이를 통해 최종채택확률을 10^4 으로 설정하는 것이 타당하다고 판단하였다. 또한 최적의 최종채택확률 10^4 를 기점으로 냉각률이 증가하거나 감소하면 순현재가치가 낮아짐을 알 수 있다. 특히 최종채택확률이 10^5 인 경우는 목적함수의 값이 크게 감소하였으며, 이는 확률론적 알고리즘에 대한 한계로써 특이점이 많이 나타나 다른 경우보다 값의 차이가 큰 것으로 판단된다.

따라서 이번에 개발한 생산정 위치 최적화 모델의 경우 초기채택확률은 0.9, 최종채택확률은 10^4 으로 설정하는 것이 타당하다. 또한 초기온도와 냉각률에 따른 민감도분석을 통하여 최대 순현재가치는 1.69억 달러로 민감도 분석을 실시하지 않은 초기모델보다 약 15% 증가하였다. 이 때, 추가 생산정의 좌표




Fig. 14. Change pattern of NPV.

는 (19,22), (23,25), (10,25) 이며(Fig. 13), 연산횟수는 16,225회, 연산시간은 6.73분으로 측정되었다.

최적의 추가 생산정의 위치를 살펴보면 기존 생산정과 추가 생산정간 거리가 생산정간 영향반경인 1,300ft 이상 떨어져 있음을 확인하였다. 이는 생산정과 추가 생산정이 영향반경 내에 있을 경우 생산성이 감소하므로 영향반경 이상 떨어진 위치를 선정해야 함을 알 수 있다. 일반적으로 배사구조의 중앙을 시추하는 것이 타당하지만, 개발된 모델의 경우 대수층 경계와 가까운 지역을 시추한 경우도 생산성이 우수한 것으로 나타났다. 이는 대수층 경계지역이라도 시추위치의 생산성 잠재력이 높은 경우 생산성이 우수한 것으로 판단된다. 특히 개발한 모델은 추가 생산정의 위치 중 한 곳을 (10,25)로 선정하였다. 이 위치는 저류층 경계와 가까워 생산성이 떨어질 것이라고 판단되지만 생산성 잠재력 지수가 양호하기 때문에 나타난 결과로 확인되었다. 마지막으로 Fig. 14는 최적화 진행 과정에서 NPV의 개선 양상을 도시한 그래프로 연산 초기 NPV가 증가 양상을 보이다가 후반부에서 수렴하는 것을 확인할 수 있다.

IV. 결론

본 연구에서는 고속의 연산이 가능한 인공신경망 시뮬레이터를 개발하고, SA 최적화 알고리즘과 결합하여 자동으로 최적의 생산정 위치 선정이 가능한 전산 모델을 개발하였다.

개발한 인공신경망 시뮬레이터는 불균질 가스저류층을 대상으로 추가 생산정에 대한 생산량을 도출하였으며, 연산성능을 크게 향상시켰다. 또한 개발한 모델을 기존 상용 시뮬레이터와 비교하여 예측성능이 양호함을 검증하였다.

최적화 알고리즘을 SA 알고리즘으로 선정하고 인공신경망 시뮬레이터를 제어하여 다수의 추가 생산정의 위치를 선정할 수 있었다. 또한 목적함수인 순현재가치가 최대인 위치를 자동으로 역산하여 최

적의 생산정의 위치를 선정하도록 하였다. 이를 통해 다수의 시나리오에 대해 분석하여 순현재가치와 누적생산량의 관계가 비례하지 않은 경우를 확인하였다.

SA 알고리즘은 확률론적 기법으로 이를 제어하는 변수인 초기온도와 냉각률을 적절하게 설정하는 것이 매우 중요하며, 그렇지 못한 경우 최적의 위치를 탐색하기가 어렵다. 따라서 민감도 분석을 통해 초기온도와 냉각률에 영향을 주는 초기채택확률과 최종채택확률을 각각 0.9, 10⁻⁴으로 설정하는 것이 타당하다고 검증하였다. 이를 통해 최대 순현재가치를 1.69억 달러로 산출하여 최적의 추가 생산정 위치를 선정하였다.

감사의 글

본 연구는 2013년도 산업통상자원부의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다.(2013251010005C)

REFERENCES

- [1] Doraisamy, H., "Methods of Neuro-Simulation for Field Development", Paper SPE 39962, presented at the Rocky Mountain Regional Low-permeability Reservoirs symposium held in Denver, Colorado, April 5-8, (1998)
- [2] Centilmen, A. Ertekin, T. and Grader, A.S., "Applications of Neural Networks in Multiwell Field Development", Paper SPE 56433, presented at the SPE Annual Technical Conference and Exhibition held in Houston, Texas, October 3-6, (1999)
- [3] Min, B.H., "Well Placement Optimization using Artificial Neural Network", MS Thesis, Seoul National - University, (2007)
- [4] Han, D.K., "A study on Production Well Placement in a Gas Field using Artificial Neural Network Simulator" MS Thesis, Dong A-University, (2012)
- [5] Beckner, B.L., "Field Development Planning Using Simulated Annealing - Optimal Economic Well Scheduling and Placement.", Paper, SPE 30650, presented at the SPE Annual Technical Conference & Exhibition held in Dallas U.S.A., 22-25 October, (1995)
- [6] Castineira, D. Alpak, F.O. and Hohl, D., "Automatic Well Placement Optimization in a Channelized Turbidite Reservoir Using Adjoint Based Sensitiv-

- ities", Paper, SPE 119156, presented at the Reservoir Simulation Symposium held in Texas, USA, 2-4 February, (2009)
- [7] Jung, J.H., "Development and Application of Inverse Model for Reservoir Characterization using SA Algorithm", MS Thesis, Dong A-University, (2011)
- [8] Guerra, N.Y., "Well Location Selection From Multiple Realization of a Geomodel Using Productivity Potential Maps - A Heristics Technique.", Paper, SPE 102903, presented at the First International Oil Conference and Exhibition in Mexico, (2006)
- [9] Suslick, S.B., "Quantifying the value of technological, environmental and financial gain in decision models for offshores oil exploration." Journal of Petroleum Science and Engineering London, v.32, n.2-4, pp. 115-125, (2001)
- [10] Akpan, S.E., "Well Placement for maximum production in the Norwegian Sea." - Case Study Norne Field C-Segment. Norwegian University of Science and Technology, MS Thesis, Norwegian University of Science and Technology, (2012)
- [11] Rodd, J.A., "Economic Analysis of Offshore Petroleum Prospects for SOPAC Member Countries", SOPAC Technical Reports 162, (1993)