論 説
 Original Article

実油田シミュレーションモデル上でのニューラルネットワークを用いた 原油生産計画の最適設計

藤井 光*・白井 寛人*・土井 学**・須貝圭一郎**

(Received October 27, 2008 : accepted February 26, 2009)

Optimization of oil production schemes in actual oil fields with application of artificial neural networks on reservoir simulation

Hikari Fujii, Hiroto Shirai, Manabu Doi and Keiichiro Sugai

Abstract : This paper investigates the applicability of Artificial Neural Networks (ANN) in the optimization process of lifting rate allocation for ESP wells. In the optimization, oil recovery is maximized according to the production performance predicted using a reservoir simulation of a real oil field.

Lufeng 13-1 Oil Field in the South China Sea has strong natural bottom-water drive and its development has reached a mature production stage. All production wells are currently operated with Electric Submersible Pumps (ESP) and the averaged water cut has exceeded 90%. The limited handling capacity of the surface processing facilities cannot allow all the wells to lift liquid at their ESPs' maximum rate. The lifting rate allocation to the wells, therefore, needs to be optimized for maximizing the oil recovery in a certain production period.

Generally, a large number of reservoir simulation runs are required for solving this type of optimization problems since all possible cases of lifting rate allocations need to be examined. In this study, oil recovery volume was estimated with a trained ANN on the basis of allocated liquid rates at the wells as the initial screening. The ANN was constructed with back-propagation method treating the results of 100 simulation results as the training data sets. Two patterns of training data sets were examined; one with random rate allocation and the other with systematic rate allocation. Blind tests for the estimation accuracy presented that the ANN trained with the systematic data sets showed better results than that with the random ones. Oil recovery factors under all the possible cases with different liquid rate combinations were estimated using the trained ANN. The top fifty cases were selected for the final examination by numerical simulation. The best case yielded 5.5% increase of produced oil volume from the base case, in which lifting rates were equally reduced to 89% of the maximum lifting capacities to meet the facility capacity. The investigation results demonstrated that the efficiency of the optimization was remarkably improved with the use of ANN on the determination of optimum liquid lifting rates in terms of oil recovery.

Keywords : Optimization, artificial neural network, reservoir simulation

1. はじめに

南シナ海海上に位置する陸豊 (Lufeng, 以下 LF と略す) 13-1 油田は 1993 年に生産を開始し, 2007 年 5 月末における原油生産レートは約 11,000 STB/d, 累計生産量は約 64.0 MMSTB である (吉田ほか, 2007)。本油田は 2,500 m 層および 2,370 m 層と呼ばれる 2 枚の砂岩層よりなるが, 主力油層である 2,500 m 層は典型的な底水押し排油機構を有し, 近年では既存生産井の平均含水率は 90% を超えているため, 全坑井で電動水中ポンプ (Electrical Submersible

Pump, 以下 ESP と略す) による採油を行なっている。本油田の海上施設における原油処理能力は, 各坑井の ESP の最適稼働条件における流体汲み上げ能力の総和より少ないため, 各坑井の流体生産レートの合計が海上施設の原油処理能力以下となるように各坑井の流体生産レートを設定している。坑井ごとに含水率の値やその上昇率が異なることに加えて, 同一油層に仕上げられている坑井間では生産干渉が存在するため, 適正な各坑井の流体生産レートの割り当ては油田全体の原油生産量を目的関数として最大化する非線形性の最適化問題ととらえることができる。

本研究では, 最適化の対象を 20 本の生産井が仕上げられている主力油層の 2,500 m 層とした。しかしながら, 各生産井における流体生産レートを複数のケースについて設

*九州大学大学院工学研究院 Graduate School of Engineering, Kyushu University

**アラビア石油㈱ Arabian Oil Co., Ltd.

定する場合、可能な生産レートの組み合わせ数はきわめて多くなるため、これらすべてのケースについて油層シミュレーションモデルを用いて生産挙動予測を行うことは現実的ではない。したがって、オペレーションズリサーチにおける各種最適化手法を用いて、油層シミュレーションの回数を抑えつつ、生産システムの最適化を行う手法を確立することは、プロジェクトの効率的な操業計画立案にきわめて有意義であると考えられる。

フィールド規模での油層シミュレーションを用いた原油生産システムの最適化に関する研究は、これまでさまざまな手法を用いて行なわれている。Fujii and Horne (1995) はプロジェクト現在価値を目的関数として、石油生産システムのネットワーク設計を遺伝的アルゴリズムにより最適化した。Pan and Horne (1998) は、最小二乗法とクリギングを用いることにより、少ない油層シミュレーション回数で単一坑井の原油生産レートのスケジューリングを最適化できることを示した。Güyagüler and Horne (2004) は確率的数値シミュレーションモデルとハイブリッド型遺伝的アルゴリズムを組み合わせることにより、生産井配置の最適化において数値シミュレーションの回数を削減できることを示した。Ishihara *et al.* (2005) は密閉坑口圧・チョーク径・含水比などを入力層とし、ニューラルネットワーク (Artificial Neural Network, 以下 ANN と略す) を用いて原油生産レートを高精度で推定できるとことを坑井試験データとの比較により示した。牧嶋ほか (2007) は実験計画法を用いた、原油生産レートおよびプラトー期間の推定を行い、同手法の適用により油層シミュレーションの回数を効果的に減らすことが可能であることを示した。しかしながら、本研究が対象とする実油田の操業計画上で重要となるような、フィールド全体の生産流体処理能力を制約条件として適正な各生産井の流体生産レートを決定し、原油生産レートを最大化するための検討が行われた例はこれまでのところ見当たらないようである。

そこで、本研究ではヒストリーマッチ後の 2,500 m 層の油層シミュレーションモデルを用いて、最小限の油層シミュレーション回数により、累計原油生産量を目的関数として最大化することを目指す種々の検討を行う。まず、各生産井における流体生産レートを変化させた 100 ケースについて、油層シミュレーションモデルを用いて累計原油生産量を計算し、ANN における教師データとなるデータベースを準備する。そして、誤差逆伝播法 (Back Propagation 法: BP 法) を用いて、各坑井の流体生産レートと累計原油生産量を相関づける ANN を構築し、さらに *v*-fold Cross Validation (CV) 法 (矢川ほか, 1999) により、構築した ANN の汎化能力を検証する。この結果、さまざまな組み合わせの流体生産レートに対応する累計原油生産量の信頼性を持った推定が可能となる。次に ANN を用いて、各生産井が累計原油生産量に与える影響に関する感度計算を行い、生産レートの増加が累計原油生産量に与える影響を各生産井について検討し、特に負の影響が大きい (すなわち減産の対象となる) 生産井を抽出する。そして、これらの

生産井における生産レート割り当てを複数ケース設定し、これらの組み合わせにおける累計原油生産量を ANN により推定する。最後に、ANN の推定において累計原油生産量が最も多い 50 ケースについて油層シミュレーション計算を行い、累計原油生産量の増加量について検討する。

ANN の適用により、少ないシミュレーション回数にて累計原油生産量の増加が実現すれば、計算時間の制約のために十分な回数の試行が困難であった大規模な油層シミュレーションモデルを用いての原油生産スケジュールの最適化が可能となるため、本研究が油層マネージメントの高精度、高効率化に与える貢献は大きいと考えられる。

2. LF13-1 における油層シミュレーションモデル

2.1 モデルの概要

LF13-1 油田の 2,500 m 砂岩層は、頁岩層を帽岩とする典型的なドーム構造をなしており、強力な底水押しの排油機構を有している。Fig. 1 に地質構造図および同構造に掘削された生産井 (20 坑井) の坑跡を示す。油水界面上の集油エリアは東西約 6 km、南北約 4.5 km に及ぶ。約 50 m の層厚は 26 枚のレイヤーに分割され、比較的泥質分が高く浸透性と連続性に劣る上部 (レイヤー 6 以浅) と、より均質で厚い砂岩が発達する下部 (レイヤー 7 以深) に大別されている。

1993 年の生産開始以来、数度にわたってシミュレーションスタディが行なわれたが、2003 年に実施された三次元地震探査の解釈によって地質モデルが更新され、それを基に新たなブラックオイル型の油層シミュレーションモデルが再構築された。Fig. 2 にシミュレーションモデルと開発井の坑跡を示す。このシミュレーションモデルは生産予測と追加開発の検討に供されるとともに、開発作業を通じて油層に関する新たな知見が得られた際には、それを反映する

Fig. 1 Top structure map of Zone 2,500 m (Contours are labeled every 5 m. Long-dashed short-dashed contour line shows OWC).

Fig. 2 3D grid map of reservoir simulation model of Zone 2,500 m with well paths (Contours are labeled every 5 m. Dashed contour line shows OWC).

べく更新が行なわれている。グリッドシステムは115（東西）×78（南北）×26（垂直）で、開発対象となる構造中心部は水平方向50 m四方のメッシュでカバーされ、総実効セル数は22万弱である。貯留岩性状は、坑井位置における検層解析結果を基にローカルな堆積学的考察を加えて、決定論的に分布させている。

当該油層の原油の特徴は、API 比重 30.5 度の中質油ながらパラフィン系炭化水素に富み高流動点（約 39℃）を示すことと、溶解ガス油比が 8～11 SCF/STB と極めて低いことである。現実的な圧力温度条件下では油層内に気相が生じないため、数値モデルでは単純な油・水 2 相のいわゆるデッドオイルシステムとして取り扱っている。飽和率関数については、Reservoir Quality Index (RQI) の帯域に拠るロックタイプを設定し、コア試験結果を基にタイプ別に標準化させた相対浸透率と毛細管圧力曲線を適用させている。油・水システムの限界飽和率 (S_{wir}, S_{or}) や相対浸透率の極値 (K_{rw}, K_{ro}) は、コア試験の結果を基に、水平方向の絶対浸透率を用いた RQI との関連性を検討し、その従属変数として個々のグリッドセルで変化させた。強力な自然の底水押しの排油機構が確認されていることから、モデルの周囲には無限の広がりを持つ Carter-Tracy 型水層を配置した。また、すべての坑井が ESP による人工採油を適用しているため、坑内垂直流動モデルは作成せず、予測計算時の制御条件には生産レートと坑底圧力を用いた。

2.2 ヒストリーマッチング

当該油層では 1993 年に生産井 6 坑で生産を開始して以来、数次にわたる開発キャンペーンを実施して原油生産を維持してきた。それぞれの開発キャンペーンは複数井の新掘あるいはサイドトラック改修作業からなり、2005 年初頭までに 20 坑井が当該油層に仕上げられた。第二次キャンペーン以降では水平仕上げを適用し、生産性の向上を図っている。

良好な砂岩が発達する下部層においては縦方向の貯留岩性状の連続性が良いため、油層構造頂部に配置された生産井によってすでに高い原油回収率が達成されているが、上

部層では、横方向、縦方向とも連続性が低く不規則的であり、原油回収率は井戸の配置と仕上げ区間、流体生産レートの割り振りに影響され、今後さらに最適化の余地がある。その議論を行うために、シミュレーションモデルには高い精度での貯留層内流動の再現能力が求められた。

そもそも、坑井の生産挙動をヒストリーマッチすることで、油層内の流体流動もモデル上で再現されていると保証するためには、個々の坑井の位置関係と坑跡、仕上げ区間の産出性能の特徴などの坑井状況が的確に表現されている必要がある。坑跡だけを忠実になぞると、仕上げ区間が複数のグリッドに（垂直方向だけでなく水平方向にも）単純に分配され、モデル上でセルから井戸へのフローキャパシティの分布が拡散し、現実の生産に伴って生じる油層内のポテンシャル分布を反映しない事態が生じる恐れがある。その場合、局所的な地層水のコーニングやカスピング現象の程度に影響を及ぼし、井戸ごとのヒストリーマッチングをミスリードさせることから、個々のグリッドセル上での井戸の仕上げ区間長を確認しながら、現実に沿った坑井のモデル化を図った。また、追加掘削が行われた際には、その時点での坑井位置での油水飽和率分布が得られる。シミュレーションモデルでこの飽和率分布を再現させる場合、均質な砂岩層が発達する油層下部では限界飽和率と毛細管圧力の設定に修正を加える必要はなかったものの、シェールとカルサイトの挟みが見られる油層上部では評価誤差が顕著であった。この誤差の解消のため、上部サブレイヤーに対しては RQI と限界飽和率との相関関数をレイヤーごとの検層結果から評価し直し、油層内の飽和率分布の四次元的な再現を図った。観測された飽和率や生産挙動のマッチングのために、さらなる調整として局所的な貯留岩性状（水平/垂直浸透率）の改変が必要であった坑井は全体の 3 割程度であった。ここで水平浸透率を変化させた場合でも、RQI との相関関数によって限界飽和率が決定されるというモデル上のルールは維持されている。したがって、ヒストリーマッチングが終了した段階で、最終的なモデルによる原始埋蔵量評価が確定した。

本研究においては、2005 年 5 月の時点までの開発・生産状況についてマッチングを終了したモデルを使用し、本油田の操業計画の最適化を立案する上で ANN を効果的に適用する手法を考察する。

3. ANN を用いた累計原油生産量の推定

本章では 2,500 m 層の油層シミュレーションモデルに対して、誤差逆伝播法を用いて ANN を構築する。その際、入力層には最適化の対象とする生産期間における各生産井における流体生産レートを与え、出力層では同期間における累計原油生産量を得るものとする。なお、最適化対象期間はヒストリーマッチング終了時の 2005 年 5 月から、その後に水処理施設能力が増強された 2007 年 5 月までとする。構築した ANN は教師データを用いた v-fold CV 法により推定精度を確認し、任意の流体生産レートに対応する累計原油生産量の高精度な推定を目指す。

3.1 ANNの理論と評価法

ANNとは、人間の脳の仕組みをモデル化した情報処理機構である。生物の神経系は、多数のニューロンが複雑に結合され、それぞれが並列処理を行っている。ANNはニューロンの結合の仕方により、BP法を代表とする階層型と自己組織化マップ (Self Organizing Maps: SOM) などの相互結合型に大別される。本研究では、未知パラメータの推定に適したBP法を用いて原油生産レートを推定する。

BP法はFig. 3に示すように入力層 (Input Layer)、中間層 (Intermediate Layer)、出力層 (Output Layer) の3層からなる階層型ネットワークを用いる。入力層に提示された学習パターンは中間層へ、そして出力層へと伝播され、出力値が得られる。なお、ANNでは中間層を多層に設定することも可能であるが、本研究では最も一般的に用いられる単層の中間層を用いた。入力データに対して出力すべき状態を教師データとすると、入力データと教師データのセットを学習データと呼ぶ。

階層型ANNの入力変数の数を n 個、中間層の変数を m 個、出力変数の数を p 個、学習データを t 組とすると、ANNの学習データセットは以下の通り表せる。

$$\text{入力データ: } I^{(s)} = (I_1^{(s)}, \dots, I_i^{(s)}, \dots, I_n^{(s)})$$

$$\text{出力データ: } T^{(s)} = (T_1^{(s)}, \dots, T_k^{(s)}, \dots, T_p^{(s)})$$

ここで、 s は s 番目の学習データを意味する (ただし、 $s = 1, \dots, t$)。入力層ニューロン i の入力信号を I_i 、中間層ニューロン j からの出力を H_j 、出力層ニューロン k からの出力を O_k 、入力層ニューロン $i \sim$ 中間層ニューロン、および中間層ニューロン $j \sim$ 出力層ニューロン k の結合係数をそれぞれ W_{ji} 、 V_{kj} とすると、 H_j および O_k は式 (1)、式 (2) で表される。

$$H_j = f \left(\sum_{i=1}^n W_{ji} \cdot I_i + \theta_j \right) \quad (1)$$

$$O_k = f \left(\sum_{j=1}^m V_{kj} \cdot H_j + \theta_k \right) \quad (2)$$

ここで、 θ_j 、 θ_k はしきい値 (上層に信号を送るかを判断する際の基準値) である。ただし、本研究では、常に1.0を出力する特別なバイアスニューロンユニットを入力・中間層に1個ずつ設け、しきい値をゼロとした。ニューロンの応答関数である $f(x)$ にはシグモイド関数を用いる (矢

Fig. 3 Structure of ANN used in this study

川ほか, 1999)。

T_k を出力層ニューロン k への教師値とすると、出力層での誤差 E は式 (3) で表される。式 (3) の誤差 E を最小にするように、結合係数を更新することで学習が行われる。

$$E = \frac{1}{2} \sum_{k=1}^p (T_k - O_k)^2 \quad (3)$$

ANNを用いた最適化においては、学習データの学習精度に加えて、未学習のデータに対する推定精度を向上させることが重要である。このため、学習データの一部を学習に用いず認識データとし、これに対する推定能力を汎化能力として観察しながら学習を行うことが有効である。学習精度を評価する学習誤差 $E^{(training)}$ は次式 (4) で表される。

$$E^{(training)} = \frac{1}{t \cdot p} \sum_{s=1}^t \sum_{k=1}^p |T_k^{(s)} - O_k^{(s)}| \quad (4)$$

ここで $T_k^{(s)}$ は s 番目の学習パターンにおける出力層 k ユニットの教師データ、 $O_k^{(s)}$ は s 番目の学習パターンにおける出力層 k ユニットの出力信号、 p は出力ユニット数、 t は学習データの組である。汎化能力の検証に用いる未学習の検証データセットに対する認識誤差 $E^{(checking)}$ は式 (4) における学習データ数 t を認識データの数としたものである。

v-fold CV法では学習を行うため、全学習データ n 組をほぼ同じ大きさの部分集合に分割する。このうち最初の v 組を認識用のデータとして、残りを学習データとして扱う。この操作を n/v ケース行い、どのケースにおいても認識誤差ができるだけ小さくなるようにネットワークの自由度を決定する。 $n = 100$ 、 $v = 20$ の場合におけるv-fold CV法の概念図をFig. 4に示す。

3.2 ネットワークの構築

本研究で構築したANNでは、Fig. 3に示すように入力層を最適化期間 (2005年5月～2007年5月) における全生産井 (20坑井) の流体生産レートとし、出力層を同期

Fig. 4 Concept of V-fold cross validation method.

Table 1 Liquid production rates of each well in maximum base and optimum cases.

Well Name	Liquid Production Rate (STB/d)		
	Maximum	Base Case	Optimum
Well-A	1,600	1,430	1,600
Well-B	3,600	3,218	3,600
Well-C	3,600	3,218	3,600
Well-D	5,000	4,469	5,000
Well-E	5,600	5,006	5,600
Well-F	5,600	5,006	5,600
Well-G	8,500	7,598	8,500
Well-H	8,500	7,598	8,500
Well-I	8,500	7,598	0
Well-J	8,500	7,598	8,500
Well-K	8,500	7,598	8,500
Well-L	8,500	7,598	8,500
Well-M	8,500	7,598	0
Well-N	13,500	12,067	13,500
Well-O	13,500	12,067	11,500
Well-P	13,500	12,067	13,500
Well-Q	13,500	12,067	13,500
Well-R	13,500	12,067	13,500
Well-S	13,500	12,067	13,500
Well-T	13,500	12,067	13,500
Total	179,000	160,000	160,000

間における 2,500 m 層全体の累計原油生産量とした。最適化期間において、2,500 m 層における最大流体生産レートはハイドロサイクロンセパレータの処理能力である 160 MSTB/d を上限とした。各生産井には生産井指数に基づく ESP が設置されており、ESP 能力によって流体生産レートが制限されるので、それぞれ 0 から最大生産レートの範囲で最適な値を決定した。Table 1 に各生産井の最大流体生産レート (Maximum と表記) を示す。

まず、ANN を構築するための教師データとして、100 通りの流体生産レートの組み合わせにおける原油生産挙動を油層シミュレーションモデルにより予測し、累計原油生産量を得た。本研究では、生産パラメータの抽出方法として、各パラメータをランダムに抽出するパターン A と、規則的に抽出するパターン B の 2 通りを設定した。パターン A では各生産井の生産レートの組み合わせを偏らず広く分布させることによる推定精度の向上を目指し、パターン B では 1 坑井の生産レートを広い範囲で変化させることによって各坑井の生産レートが総生産レートに及ぼす影響を重点的に調べた。各パターンを用いた学習はそれぞれ独立して行い、それぞれの学習効率について評価した。各パターンにおける各坑井の生産レートの設定方法を以下に説明する。

パターン A

それぞれの流体生産レートについて、0 と最大生産レートの間でランダムに値を設定した。この時、全 20 坑井の総流体生産レートが 160 MSTB/d (ハイドロサイクロンセパレータの処理能力) となるように、19 坑井の流体生産レートはランダムに抽出し、残る 1 坑井の生産レートは 160 MSTB/d から 19 坑井の生産レートの合計を引いた値と

した。ただし、19 坑井の流体生産レートをランダムに選ぶと、残る 1 坑井の生産レートが負になる場合や最大流体生産レートを超える場合が多いため、19 坑井の生産レートは各生産井の最大流体生産レートの 89% (= 流体処理能力 (160 MSTB/d) / 全生産井の最大流体生産レートの合計 (189 MSTB/d)) を平均値、標準偏差を平均値の約 35% とする正規分布と乱数を用いて決定した。

パターン B

パターン B では 20 坑井のうち 1 坑井の流体生産レート (R とする) を 0 から最大流体生産レートの範囲で等間隔に 5 つ選び出した。残り 19 本の生産井の流体生産レートは、残りの生産可能なレートを 19 本の ESP の汲み上げ能力で割り、平均した値とした。例えば、最大流体生産レートが 1,600 STB/d である Well-A を対象とした場合、増分を 400 STB/d として、同坑井の流体生産レートを 0, 400, 800, 1,200, 1,600 STB/d と等間隔に 5 つ選び出す。その際、残りの 19 生産井の流体生産レートは以下のように決定した。

例: RWell-A = 400 STB/d の場合 (添え字は坑井名をあらわす),

最大流体生産レートが 3,600 STB/d の Well-B について

$$R_{\text{Well-B}} = R_{\text{Well-B}_{\text{max}}} \times \frac{160,000 - R_{\text{Well-A}}}{179,000 - R_{\text{Well-A}_{\text{max}}}}$$

$$= 3,600 \times \frac{160,000 - 400}{179,000 - 1,600} = 3,239 \text{ STB/d}$$

最大流体生産レートが 13,500 STB/d の Well-T について

$$R_{\text{Well-T}} = R_{\text{Well-T}_{\text{max}}} \times \frac{160,000 - R_{\text{Well-A}}}{1,790,000 - R_{\text{Well-A}_{\text{max}}}}$$

$$= 13,500 \times \frac{160,000 - 400}{1,790,000 - 1600} = 12,145 \text{ STB/d}$$

同様の計算を全 20 坑井について行い、パターン B でも合計 100 通りの流体生産レートの組み合わせを作成した。

3.3 汎化能力の評価

前節に示したパターン A, パターン B により作成した 100 通りずつの流体生産レートの割り当てと数値計算結果を用いて、数値シミュレーション結果を推定する ANN を構築した。まず、高い再現性を得るために、v-fold CV 法を使い、最適な学習パラメータ (学習回数と中間層の数) の選定および汎化能力の検証を行った。本研究における v-fold CV 法では、Fig. 4 に示すように学習データ 100 組あるうち 20 組を認識データ、残り 80 組を学習データとして扱い、認識データを 5 回変えて (Case No.1 ~ No.5) 汎化能力を評価した。

まず、パターン A, B において最適な学習回数を選定した。ANN では学習回数が増えるに伴い、(4) 式に示す学習誤差は単調に減少するものの、認識誤差はある学習回数を境に増加することが一般的である。これは過剰学習として知られている現象であり、過剰な学習回数により応用力が低下する。そこで、学習回数を 10,000 回と設定し認識誤差が最小となる学習回数について検討した。パターン A, B における学習回数と認識誤差の関係を Case No.1 ~ No. 5 の 5 ケースについて Fig. 5 (a), (b), (c), (d) にそれ

Fig. 5 Training cycle vs. error (a) Pattern A and $N = 10$, (b) Pattern B and $N = 10$, (c) Pattern A and $N = 20$, (d) Pattern B and $N = 20$ (N : Number of nodes in intermediate layer).

ぞれ示す。ただし、Fig. 5 (a), (b) は中間層のニューロン（ノード）数を 10 個、Fig. 5 (c), (d) は 20 個とした場合である。Fig. 5 (a), (c) に示すパターン A では学習回数 2,000 回より以前で認識誤差が増加に転じる傾向が見られるため、パターン A の最適な学習回数は 2,000 回とした。Fig. 5 (b), (d) に示すパターン B では学習回数の増加に伴う過学習は観察されず、学習回数 10,000 回程度で認識誤差がほぼ一定となるため、パターン B の最適な学習回数は 10,000 回とした。パターン A, B で最適学習回数に差が見られる理由は、パラメータの抽出方法の違いによると考えられる。パターン A では、教師データにおける流体生産レートは最大生産レートの 89% を中心に正規分布しているため、各パラメータの分布が抽出範囲の中心に偏在している。したがって、比較的少ない回数で認識誤差が最小を示したと考えられる。一方、パターン B ではパラメータの値を抽出範囲の最小値から最大値まで広範囲に選んでいるため、多くの学習回数を必要としたと考えられる。最適な学習回数における認識誤差はパターン A、パターン B においてそれぞれ 0.00178 および 0.00146 となり、パターン B がより高い汎化能力を示した。

次に、以上で求めた各パターンの最適な学習回数に基づき、中間層のニューロン数を 1 ～ 20 個に変えた場合の認識誤差を評価し、各パターンにおける最適なニューロン数を検討した。学習は認識データを変えた Case No. 1 ～ No. 5

Fig. 6 Determination of number of nodes in intermediate layer.

において行なった。Fig. 6 にパターン A, B における中間層ニューロンの数と認識誤差（各ケースにおける 20 組の認識誤差の平均値をケース間で平均した値、つまり 100 組の認識誤差の平均値）の関係を示す。中間層ニューロン数によって認識誤差の大きな違いは見られないものの、パターン A では中間層ニューロンの数が 9 個のとき、パターン B では 7 個のときに認識誤差が最も小さくなるため、中間層ニューロンの数はこれらを採用した。中間層ニューロンが 20 個以上のケースについては結合係数の計算量が

過剰となるため、効率的でないと見なして排除した。

最後に、以上で得られた最適な学習パラメータを用いて各パターンの汎化能力を検証した。検証では、ニューラルネットワークによって推定された累計原油生産量(推定値)と、数値シミュレーションにより計算された累計原油生産量(教師値)の比較を行なった。パターン A, B それぞれにおける推定値と教師値を Fig. 7 に比較する。図中の教師値=推定値となる太線に近いほど、正確な推定が可能であることを表し、破線は教師値と推定値の誤差が1%の範囲を示す。Fig. 7 (a), Fig. 7 (b) に示されるように、100 回の推定における誤差の平均値はパターン A, パターン B においてそれぞれ 0.15%, 0.20% ときわめて小さく、高い汎化能力が示された。パターン A においてパターン B よりわずかに高い推定精度が得られた理由としては、本研究では v-fold CV 法において教師データを用いた検討を行っており、各坑井の流体生産量の変化範囲の大きいパター

ン B における v-fold CV 法では流体生産量の最大値・最小値となるケースを含む外挿計算が必要であるためと考えられる。

以上の結果に基づき、パターン A では入力層ニューロン 20 個(各生産井の流体生産レート)、中間層ニューロン 9 個、出力層ニューロン 1 個(2005 年 5 月～2007 年 5 月の累計原油生産量)の階層型 ANN を構築し、学習回数を 2000 回として学習を行うこととした。また、パターン B では入力層ニューロン 20 個、中間層ニューロン 7 個、出力層ニューロン 1 個として学習回数を 10,000 回とした学習を行うこととした。

4. 流体生産レートの最適化による累計原油生産量の最大化

本章では構築した ANN を用いて、各生産井における流体生産レートが累計原油生産量に与える影響について感度計算を行い、特に負の影響が大きい(すなわち流体生産レートを減少させる)生産井を抽出する。続いて、減産対象と見なされた坑井における生産レートを複数ケース設定し、これらの組み合わせにおける累計原油生産量を ANN により推定する。そして、ANN による推定において上位 50 番までの累計原油生産量を示すケースについて油層シミュレーション計算を行い、累計原油生産量の増進可能性について評価する。減産対象とする坑井数については 2 ケース設定し、最適化結果を比較する。

4.1 感度解析

研究対象油層である 2,500 m 層の生産井数は 20 坑井であり、このうち 19 坑井における流体生産レートをそれぞれ n 通り設定した場合、残る 1 坑井の生産レートは総流体生産レートにより自動的に決まるため、流体生産レートの全組み合わせ数は n^{19} となる。したがって、たとえば $n = 5$ とすると総組み合わせ数は $5^{19} \approx 1.9 \times 10^{13}$ ときわめて大きくなり、全坑井の流体生産レートを小さい増分で複数ケース設定する場合、ANN を用いた累計原油生産量の推定に多大な時間を要する。そこで、本研究では各生産パラメータが目的関数(累計原油生産量)に及ぼす影響に関する感度解析を行い、減産の対象となる坑井を抽出した。まず、パターン A, B おのおのについて、前章にて構築した ANN 上での各生産井の流体生産レートに対する目的関数の増減を Fig. 8 に示すよう得た。同図より、各生産井は流体生産レートが増加により累計原油生産量が増加する生産井、すなわち目的関数に正の影響を及ぼす生産井と、目的関数に負の影響を及ぼす生産井に大別できる。全 20 坑井における目的関数に対する影響度を Table 2 に示す。Table 2 では、特に負の影響が強い生産井を“Negative (Strong)”として弱い負の影響を持つ生産井“Negative (Weak)”と区別している。なお、“Negative (Strong)”と“Negative (Weak)”の分類については、Fig. 8 における各生産井の(累計原油生産量の増減量)/(当該坑井の最大生産レート)がパターン A においては -5 以下の坑井、パターン B においては -10 以下の坑井とした。

Fig. 7 Comparison between supervised and estimated values in V-fold cross validation method in Patterns A and B.

Fig. 8 Results of sensitivity studies in Patterns A and B.

Table 2 Classification of production wells through sensitivity studies.

Pattern A			Pattern B		
Positive	Negative (Weak)	Negative (Strong)	Positive	Negative (Weak)	Negative (Strong)
Well-A	Well-F	Well-D	Well-A	Well-D	Well-I
Well-B	Well-K	Well-O	Well-B	Well-H	Well-M
Well-C	Well-M	Well-P	Well-C	Well-K	Well-O
Well-E	Well-N		Well-E	Well-N	Well-P
Well-G	Well-Q		Well-F	Well-Q	
Well-H	Well-S		Well-G	Well-R	
Well-I	Well-T		Well-J	Well-S	
Well-L			Well-L	Well-T	
Well-R					

感度解析結果より、正の影響が強い Well-A と負の影響が強い Well-M について、2007 年 5 月における水飽和率断面図をそれぞれ Fig. 9, Fig. 10 に示す。両生産井の断面図の比較より、Well-M は Well-A と比べて坑井周辺の水飽和率が高く、生産流体の含水率が高いため、本生産井における生産レートの増加が油層全体の原油生産レートを低下させることがわかった。また、Well-A では下方の頁岩層の存在により下部帯水層からの水の浸入が阻止されているた

Fig. 9 Cross-section of water saturation distribution at Well-A.

Fig. 10 Cross-section of water saturation distribution at Well-M.

め、流体生産レートの増加により生産流体の含水率が上昇せず、減産の対象とならないことが推測された。

4.2 最適流体生産レートの決定

ここでは、正の影響を及ぼす生産井の汲み上げレートを ESP の最大汲み上げレートに固定し、目的関数に負の影響を及ぼす生産井の流体生産レート割り当てを最適化し、累計原油生産量の最大化を目指す。なお、本研究では負の影響を及ぼす全生産井 (Table 2 にて “Negative (Weak)” および “Negative (Strong)” に該当する生産井) を最適化対象とするケース 1、および強い負の影響を持つ生産井 (“Negative (Strong)” に該当) のみを対象とするケース 2 について検討を行なう。なお、目的関数値改善の度合いの評価基準として、最大流体生産レートの約 89% (流体処理能力 / 全生産井の最大流体生産レート) を一律に各生産井の流体生産レートとするケースをベースケースと定め (Table 1 における “Base Case” に相当)、油層シミュレーションによって得られた目的関数値を Table 3 に示す。また、同表に ANN 構築のための教師データとした、100 回のシミュレーションにおける目的関数値 (“Before ANN” と表示) の上位 5 位をあわせて示す。

ケース 1 では負の影響を及ぼす全生産井 (パターン A :

Table 3 Enhancement of cumulative oil productions through optimization calculations using ANN in Patterns A and B.

Rank	Cumulative Oil Production from May 2005 to May 2007 (MSTB)						
	Pattern A			Pattern B			Base Case
	Before ANN	Case 1	Case 2	Before ANN	Case 1	Case 2	
1	5,261.1 (+2.4%)	5,378.3 (+4.6%)	5,392.2 (+4.9%)	5,326.2 (+3.6%)	5,353.4 (+4.1%)	5,424.9 (+5.5%)	5,140.2
2	5,255.7	5,375.5	5,386.6	5,315.4	5,353.1	5,424.2	
3	5,249.1	5,372.9	5,382.7	5,270	5,349	5,423.5	
4	5,246.3	5,370.9	5,382	5,269.1	5,346.5	5,422.8	
5	5,246.1	5,369.5	5,381.6	5,259.8	5,345.8	5,422.1	
Average	5,154.2	5,355.3	5,356.2	5,144.6	5,334.1	5,393.9	

10 坑井, パターン B: 12 坑井) について, 流体生産レートを最大流体生産レートから 1,000 STB/d (最大流体生産レートが 10,000 STB/d 以下の生産井), または 2,000 STB/d (最大流体生産レートが 10,000 STB/d 以上の生産井) の増分で減少させて最適化を図る。それぞれの井戸につき 4 通りずつ生産レートを設定し, 全 20 生産井の流体生産レートが流体処理能力 160,000 STB/d になる組み合わせ (パターン A: 49,720 通り, パターン B: 360,986 通り) を用意し, 目的関数値を ANN により計算した。そして, ANN により目的関数値が高くなると推定された上位 50 組について油層シミュレーションを行なった。Table 3 に上位 50 組のシミュレーションによって得られた目的関数の上位 5 位までと, 再計算した上位 50 組の目的関数の平均値を “Case 1” の列に示す。パターン A, B ともに最大目的関数値はベースケースより 4% 以上増加し, ANN 適用前と比べて目的関数値は 2.4 ~ 3.6% 増加した。

ケース 2 では, さらなる累計原油生産量の増加を目指して, 目的関数に対する負の影響が特に大きい生産井に着目する。Fig. 8 に示した感度解析に基づき, 特に負の影響が大きいと判断されたのは, Table 2 に示すようにパターン A で Well-D, Well-O, Well-P の 3 坑井, パターン B で Well-I, Well-M, Well-O, Well-P の 4 坑井であった。そこで, これらの生産井について 0 STB/d から最大流体生産レートの間で増分 500 STB/d として生産レートを設定し, 他の生産井は最大汲み上げレートに固定して全生産井の流体生産レートが 160,000 STB/d となるケースについて, ANN を用いて目的関数値を推定した。そして, 目的関数が上位となる 50 組について油層シミュレーションで再計算を行い, Table 3 の “Case2” の列に示すシミュレーションによって得られた目的関数値の上位 5 組までと上位 50 組の目的関数の平均値を得た。また, Table 1 に最適となったケースにおける各生産井の流体生産レートを “Optimum” と示す。ケース 2 において, 累計原油生産量の最大値はパターン B の 5,424.9 MSTB であり, ベースケースと比べて約 5.5% と大幅な累計原油生産量の増加となった。パターン A の増加率は約 4.9% となり, パターン B と比べて劣るが, これは流体生産レートの平均付近を中心にランダムな教師データを作成するパターン A で学習を行なった ANN は, Well-I および Well-M の 2 坑井で生産レート 0 STB/d のケー

スが最適となる (Table 1 の “Optimum” 参照) 本最適化問題のように, 広い推定範囲を要求されるケースには適さないためと考えられる。累計原油生産量が最大となったケースにおいて, 流体生産レートが 0 STB/d となった Well-I と Well-M は坑井の下方に頁岩層が存在せず, 下方からの水コーニングが起りやすいという共通の特徴を持つ。

4.3 数値計算時間の評価

ここでは ANN を用いて行う最適化計算と, 油層シミュレーションのみを用いる場合について, 必要な数値計算時間を比較する。本研究における油層シミュレーションでは ECLPSE100 を使用し, 数値計算時間はケースにより異なるが平均値は 1 ランにつき約 10 分である。なお, 数値計算には Intel (R) Core (TM) 2 CPU 2.4 GHz および 2.4 GB RAM を搭載したウィンドウズ PC を使用した。

数値計算のみを用いて, 前節のケース 1 と同じ回数の数値計算を行なう場合, パターン A ではケース数が 49,720, 数値計算時間が 8,287 時間, パターン B ではケース数が 360,986, 数値計算時間が 60,164 時間といずれも実用範囲外となった。一方, ANN を用いる最適化計算に要した油層シミュレーション計算は, ニューラルネットワークを構築するための 100 回と上位 50 ケースの再計算の 50 回で合計 150 回, したがって必要な数値計算時間は約 25 時間であり, いずれのパターンにおいても数値計算時間は数値計算のみによる最適化の 1% 未満である。以上より, ANN の使用が最適化に要する数値計算時間を大幅に削減し, 効率的な生産計画の最適化が可能となったと考えられる。

5. ま と め

本研究では中国南シナ海海上に位置する陸豊 13-1 油田において, ヒストリーマッチ後の主力油層の油層シミュレーションモデルとニューラルネットワーク (ANN) の組み合わせによる, 流体生産レートの最適化計算を行なった。ANN では, 誤差逆伝播法を用いて各坑井の流体生産レートと累計原油生産量を線形化した結果, 任意の流体生産レート割り当てに対して, 累計原油生産量が高い精度で推定可能であった。次に, ANN を用いた感度計算により, 総生産レートに対して負の相関を持つ生産井を抽出し, これらの生産井の流体生産レートを様々な割合で減少させて, ANN により累計原油生産量を推定した。そして,

累計原油生産量が多い 50 ケースについて再度油層シミュレーション計算を行ったところ、全坑井に一律に（生産施設の処理能力 / 各坑井の汲み上げ能力の総和）を割り当てるベースケースと比べて約 5.5% の原油回収量の増加が見られ、本最適化手法の有効性が示された。また、ANN の適用による最適化計算に要する計算時間は、全ケースの数値計算を行なう場合の 1% 未満であり、本最適化手法の高い効率性が示された。

謝 辞

本稿の公表を許可いただいた新南海石油株式会社、日鉱珠江口石油開発株式会社、新華南石油株式会社、CCLS (CNOOC China Limited-Shenzhen)、およびシミュレーションソフトの使用にご協力いただいたシュルンベルジェ株式会社に深く感謝の意を表します、

SI 単位換算係数

$$\text{feet} \times 3.048^* \quad \text{E} - 01 = \text{m}$$

$$\text{bbl} \times 1.589874 \quad \text{E} - 01 = \text{m}^3$$

* は正確な値

引 用 文 献

Fujii, H. and Horne, R.N., 1995 : Multivariate Optimization of

Networked Production Systems. *SPE Production & Facilities*, August, 165–171.

Güygülar, B. and Horne, R.N., 2004 : Uncertainty assessment of well-placement optimization. *SPE Reservoir Evaluation and Engineering*, February, 24–32.

Ishihara, N., Sugai, K. and Nishikiori, N., 2005 : Integrated reservoir monitoring and production analysis. *Jour. Japan Assoc. Petrol Technol.*, **70** (6), 545–552.

牧嶋 憲・川井健史・高山邦明, 2007 : 実験計画法を用いた貯留層の不確実性評価. 石技誌, **72** (6), 570–576.

Pan, Y. and Horne, R.N., 1998 : Improved methods for multivariate optimization of field development scheduling and well placement design. SPE49055, presented at *SPE Annual Technical Conference and Exhibition*, New Orleans, Louisiana, 27–30 September 1998.

矢川元基・吉村 忍・松田聡浩, 1999 : 感性と設計, 163p, 培風館.

吉田宏生・茂木慎吾・中川和則・山足友浩, 2007 : 地質・生産データを用いた JHN 陸豊 13-1 油田第 6 次・7 次掘削キャンペーン成果と知見—生産後期油田における油増産の取り組み例として—. 石技誌, **72** (6), 531–540.