

ニューラルネットワークを用いた石油地層の性質把握

2M-5

島田伸介[†] 谷亞輝紅^{††} 西川宜孝^{††}

石油探鉱分野において、石油地層の性質把握にニューラルネットワークを応用している。本研究では、ニューラルネットワークを用いて、坑井検層データおよび孔隙率の予測を行い、手法の有効性を確認した。

Reservoir Characterization using Neural Network

NOBUSUKE SHIMADA,[†] AKIKO TANI^{††} and NOBUTAKA NISHIKAWA^{††}

1. はじめに

石油探鉱技術において、データの高密度化に伴い、大量データの処理および解釈の高精度化、高速化が求められている。著者らは、ニューラルネットワークを石油地層の性質把握に応用している¹⁾。本研究では、ニューラルネットワークを用いて音波検層データおよび孔隙率の予測を行い、手法の有効性を確認するとともに、ニューラルネットワークの構造に関する検討を行った。

2. 坑井検層データの予測

検層データの1つである音波検層データは石油地層の性質把握に不可欠であり、同データが未知または欠落している場合には、それを予測することが重要となる。ここでは、ニューラルネットワークを用いて、複数の検層データから未知の音波検層データの予測を行い、従来の予測手法の1つであるGardnerの手法との比較を行った。Gardnerの手法は、次の一次式で一般化される²⁾。

$$\Delta t \approx A\rho^{-4} + B \quad (1)$$

ここで、 Δt は音波検層値 ($\mu\text{sec}/\text{ft}$)、 ρ は密度検層値 (g/cc)、 A, B は定数を表す。

2.1 予測手法

2.1.1 ニューラルネットワークの構造

ニューラルネットワークの構造は、入力層、中間層、出力層のニューロン数がそれぞれ6、3、1の、3層の階層構造型であり、学習方法には、バックプロパゲーション法を用いている(図1)。

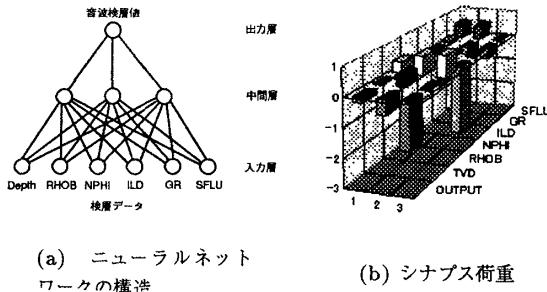


図1 音波検層データ予測に用いたニューラルネットワークの構造

2.1.2 入力データおよび教師データ

音波検層以外の検層データを入力データ、音波検層データを教師データとする学習データを用いて学習を行った。入力データは、深度(Depth)、密度検層(RHOB)、中性子検層(NPHI)、比抵抗検層(ILD、SFLU)、 γ 線検層(GR)である。学習データ数は10,000データ、学習回数は50,000回とし、6,000データに対して予測を行った。Sun SparcStation 20(メモリ256MB)を用いた場合、学習および予測に要した時間はそれぞれ約270秒、約15秒であった。

2.2 予測結果

2坑井を対象とし、一方の坑井における検層データを学習データとして学習を行い、学習後のニューラルネットワークを用いて、他方の坑井における未学習の音波検層データを予測した。

図2より、ニューラルネットワークによる予測値は、実測値との相違が小さく、Gardnerの手法と比較して、良い結果が得られていることが確認できる。また、図1に示すように、学習後のニューラルネットワークでは中性子検層と密度検層にかかるシナップス荷重が大きく、これらの検層データと音波検層データに関連性があると

[†] 石油公団 石油開発技術センター
Japan National Oil Corporation
^{††} 富士総合研究所 計算科学・小池クラスター
Fuji Research Institute Corporation

いう経験的知見が、ニューラルネットワークの構造に反映されている。

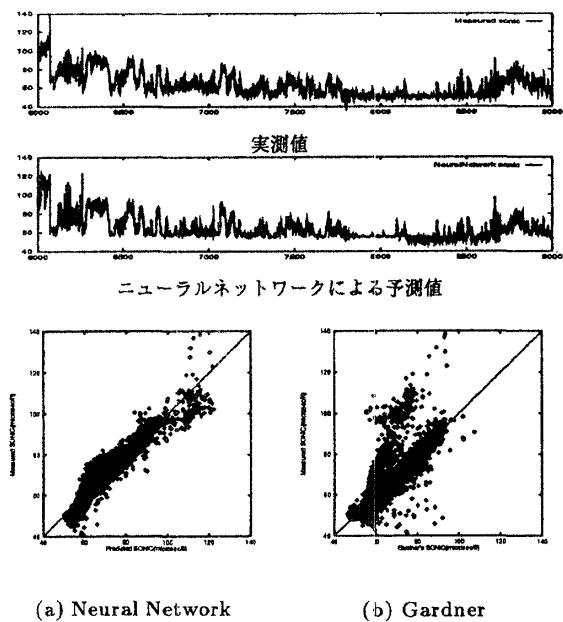


図2 音波検層データの予測結果

一方、図2に示すように、Gardnerの手法で用いた一次近似式では予測できていないグループが存在し、正確な推定を行うためには、地層区分ごとに関係式を求めるなどの煩雑な作業が必要である。これに対し、ニューラルネットワークを用いた手法では、このような煩雑な手順を踏むことなく、高精度な音波検層データの予測が可能である。

3. 孔隙率の予測

孔隙率は、油層における石油の含有量を知るために重要な指標の1つである。ここでは、坑井における検層データと、その坑井で採取されたコアサンプルにより測定された離散的なコア孔隙率を用いて、ニューラルネットワークによる連続的な孔隙率の予測を行い、予測結果を統計的手法を用いた検層解析ソフトウェアELANにより得られた孔隙率と比較した。

3.1 予測手法

3.1.1 ニューラルネットワークの構造

ニューラルネットワークの構造は、入力層、中間層、出力層のニューロン数がそれぞれ12、3、1の、3層の階層構造であり、学習方法には、バックプロパゲーション法を用いた(図3)。

3.1.2 入力データおよび教師データ

コア孔隙率が得られている深度における検層データを入力データ、コア孔隙率を教師データとする学習データを作成した。学習後のニューラルネットワークに検層データを入力し、坑井の解析対象区間における連

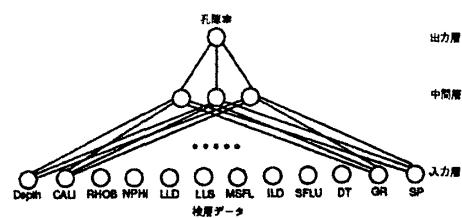


図3 孔隙率予測に用いたニューラルネットワーク

続的な孔隙率を予測した。入力に用いたデータは、深度(Depth)、坑径(CALI)、密度検層(RHOB)、中性子検層(NPHI)、比抵抗検層(LLD、LLS、MSFL、SFLU)、音波検層(DT)、 γ 線検層(GR)、自然電位(SP)である。離散的に分布する学習データ約40データに対し、30,000回の学習を行い、連続的に分布する約1300データの予測を行った。Sun SparcStation 20(メモリ256MB)を用いた場合、学習および予測に要した時間はそれぞれ約150秒、約3秒であった。

3.2 予測結果

図4において、ニューラルネットワークによる予測値は、ELANによる予測値と全体的に一致しており、信頼性は高い。また、コア孔隙率とニューラルネットワークによる予測値はよく一致しており、学習データに対する予測精度は十分に高い。しかし、未学習区間においては、ニューラルネットワークによる予測値とELANによる予測値の相違は大きく、予測区間の地質特性を反映した適切な学習データの選択が必要である。

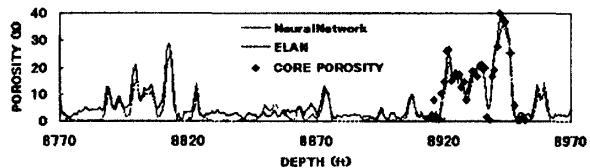


図4 孔隙率の予測値カーブ

4. おわりに

ニューラルネットワークを用いて、坑井検層データおよび孔隙率の予測を行った。ニューラルネットワークを用いた手法は、従来の手法と比較し単純な手順で高精度な予測が可能であり、その予測手法の有効性が確認された。

参考文献

- 1) 島田、小澤、吉岡、西川、谷: ニューラルネットワークを用いた坑井検層データの予測、物理探査学会 第93回 学術講演会 (1995).
- 2) G.H.F.Gardner, L.W.Gardner and A.R.Gregory: Formation velocity and density - the diagnostic basics of stratigraphic traps, *Geophysics*, Vol. 39, pp. 770-780 (1995).