

(103) ニューラルネットの地盤物性評価への適用

○ 備間組技術研究所 京極孝子

備間組技術研究所 平井光之

Evaluation of Geological Properties by Neural Network

Takako KYOUGOKU, HAZAMA CORPORATION

Mitsuyuki HIRAI, HAZAMA CORPORATION

Abstract

The relations between many kinds of physical and mechanical properties have wide variety according to the kinds of rocks, the degree of weathering, water-saturation, and so on. Neural Network could construct the specific rules of expert's judgement by learning given input-output relations.

This report describes it's ability is applied to evaluation for geological properties. As a result, it was proved that hopfield network associated the whole patterns of lerarned properties from input data.

1. はじめに

地下構造物の設計・施工時には、ボーリング調査、物理検層、各種室内試験、原位置試験など様々な調査が行われているが広域に渡る地盤の三次元的な構造を直接計測することは実際には不可能であり、弾性波・電磁波などの地盤透過波を用いて間接的に推定することが試みられている。通常このように得られた地盤の探査・計測データを用いて地下構造物の設計・施工に必要な種々の地盤物性値を推定することになる。しかし、探査・計測データと地盤物性値の間、あるいは地盤物性値相互間の相関関係は地盤の風化の状況、含水状態等様々な要因によって変化するため、その把握には、熟練技術者による工学的判断が不可欠である。

近年人間の脳をモデルにした新しい情報処理システムとしてニューラルネットワークが注目を集め、既報のP波到達点の認識¹⁾のような時系列データに対する応用例、その他土木分野でも適用されるようになりつつある。

ニューラルネットワークは出力値を得るための途中経過を考慮せず、入力値と出力値のデータの組のみで、特定の判断基準や知識を獲得できるため、不明確な相互関係の評価に適している。筆者らはこの学習能力を、地盤の探査・計測データから必要とされる施工データへの変換、推定に活用する方向で検討を進めている。ここでは、その一例として、固結度の異なる数種の泥岩について得られた複数の物性値データを用いて、その相互関係の推定、あるいは限られたデータの組から不足しているデータを推定する方法等へのニューラルネットの適用性について検討した結果を報告する。

2. ニューラルネットの基本概念

人間の脳は、ニューロンとシナプスという2つの基本素子からなる神経回路網で構成されている。これをモデル化したのが、ニューラルネットワークで、ニューロンは多入力ー出力の応答関数(1)式で定義される演算ユニットとして表現される。シナプスはこの演算ユニット間の結合で、データの入出力に対し重みづけを行う。ニューラルネットワークにおいて特定問題の入出力関係は、各シナプスの重みと演算ユニットのしき

い値の組み合わせによって決定される。²⁾

$$S_{out} = \frac{1}{1 + \exp(-(\sin - \theta))} \quad \sin = \sum W_i X_i \quad (1)$$

ここで、 S_{out} : ユニットの出力、 $\sin$: 上位ユニットへの入力、 X_i : 下位ユニットからの出力、 θ : しきい値、 T : 温度、 W_i : シナプス荷重を示す。ネットワーク内のデータは $[0, 1]$ のアナログ値をとり、入力される物性値も各最大値によって $[0, 1]$ に規格化されて取り扱われる。以後、ネットワークの出力値の誤差は、規格化された値に対して行う。


3. 一軸圧縮強度の推定

3. 1 物性値データの概要

データは、千葉県をはじめとする東京湾岸沿いの5地点で採取された固結度の異なる上総層泥岩試料より得られた物性値を使用する。同一試料から、①湿潤密度、②乾燥密度、③土粒子密度、④含水比、⑤間隙比、⑥飽和度、⑦一軸圧縮強度、⑧静弾性係数、⑨静ポアソン比、⑩P波速度、⑪S波速度、⑫動弾性係数、⑬動ポアソン比の13物性値が1セットとして得られている。本報告では37試料分のデータセットを使用し、そのうちニューラルネットワークの学習に採取地4カ所22試料のデータセットを用いる。残り15試料のデータは、ネットワークの汎化能力を評価するため未学習とする。

3. 2 ネットワークの構造及び学習

初めに一軸圧縮強度を他の12物性値から推定する問題にニューラルネットワークを適用し、その認識能力を評価する。ネットワークは図-1に示すように、入力層12細胞、出力層1細胞の3層の階層型構造を採用した。中間層は、6, 9, 12, 15細胞の4ケースを設定し、出力誤差の小さい最適な数を決定する。前述のように学習時は12物性値を入力データとし、一軸圧縮強度を出力教師データとして与える。



①湿潤密度	②乾燥密度	③土粒子密度
④含水比	⑤間隙比	⑥飽和度
⑦P波速度	⑧静弾性係数	⑨静ポアソン比
⑩S波速度	⑪動弾性係数	⑫動ポアソン比

図-1: 一軸圧縮強度推定ネットワーク

図-2は、各ケースの出力値の学習中における二乗平均誤差の変化を示す。初期状態においてネットワークは、いずれも二乗平均誤差で0.071~0.075の値をとる。中間層の細胞が少ないケースでは1回の学習による個々のシナプス荷重の変化量が大きいため、学習開始直後は一時的に誤差が増加するが、すぐに減少し学習1000回程度でほぼ一定値に誤差が収束する。中間層の細胞数が多い場合、誤差は緩やかに減少し、急激な変動は見られない。最終的に各ケース、二乗誤差が0.003~0.005に収束するが、中間層の細胞数が少ないと

若干誤差が少なくなる。以上のように多入力1出力のニューラルネットでは、ネットワークの複雑さの減少に伴って、学習の進行が速くすすみ、同時に最




図-2: 学習進行過程における二乗平均誤差の変動




図-3：学習データにおける推定値と実測値




図-4：未学習データにおける推定値と実測値

終的な出力精度が向上するといえる。本節では、以後誤差の少なかった中間層6細胞のネットワークを使用する。また、ネットワークの作成にはCRC社製のRHINEを使用した。

3. 3 学習後の一軸圧縮強度の推定

学習後のネットワークに、学習に使用した22セット、未学習の15セットの計37セットの物性値データを入力し、一軸圧縮強度の推定を行った。図-3, 4に推定結果と実測値(正解値)を棒グラフで示す。学習に用いたデータ(図-3)はもちろん、未学習の(図-4)においても、推定値の誤差は少なく、ネットワークの一般化能力があることが確認される。図-5は、この出力値と実測値の関係を散布図上に表現したものであり、20~130kgf/cm²の範囲でバラツキをもつ一軸圧縮強度を精度良く推定している。




図-5：推定値と実測値の相関

4. 物性値が欠損したデータセットに対する認識

前節で述べたネットワークに対し、一供試体で12物性値を計測している例はほぼなく、他の測定例に活用することは不可能である。このように一部地盤情報が不足していても同一のネットワークで処理を行うことができれば、新たにネットワークを構築する手間が省略される。このような多様な状況に対応し、欠落した地盤情報を推定できるネットワークの構築が望ましい。

ニューラルネットワークには、大きく分けて前述のような階層型ネットワークと相互結合型ネットワークがある。相互結合型ネットワークは、単位ユニットの機能は階層型と変わらないが、その構造はランダムな結合によって構成されている。自己想起的な連想記憶によるパターン認識、図形の特徴抽出などに有効な手法として用いられている。³⁾ この相互結合型のネット




図-6：帰還型ネットワーク

ワークに13個のデータセットを学習させ、物性値のパターンを連想させることにより、欠損データを推定することができないか検討を行った。

4. 1 帰還型ネットワーク

RHINEでは相互結合型の一つとして、帰還型ネットワークがサポートされている。帰還型ネットワークは、図-6のように階層型ネットワークの出力を入力層にフィードバックできるように機能拡張したもので、相互結合型ネットワークとほぼ同じ機能をもつ。⁴⁾ 前節のデータセットを学習に利用するため、入力層13細胞、出力層13細胞、中間層6細胞の3層構造帰還型ネットワークを用いた。

4. 2 物性値ブランク入力

13物性値の組み合わせのうち欠落した物性値データがあると仮定して0を入力し、データセットの一部分からデータセット全体を推定する能力を評価する。データの欠落部分は、以下に示す4パターンを設定した。

①B0：一軸圧縮強度のみ0を入力する

②B1：湿潤密度、乾燥密度、土粒子の密度、一軸圧縮強度に0を入力する。

③B2：一軸圧縮強度、静弾性係数、静ポアソン比に0を入力する。

④B3：湿潤密度、乾燥密度、土粒子の密度、含水比、間隙比、飽和度、一軸圧縮強度、静弾性係数、静ポアソン比に0を入力する。

図-7に上述の入力パターンに対する出力例としてB3パターンにおける出力誤差を示す。縦軸に[0, 1]で規格化された物性値における誤差をとり、横軸にデータの番号を示す。B3パターンでは13物性値のうち半分以上の9物性値が不明であるケースを想定したものであるが、静弾性係数で約50%程度の誤差を生じた以外は、妥当な値を出力しているといえる。

欠落したデータのネットワークへの入力時の取扱いとして、0を入力する方法を採用したが、未知のデータに対しその岩種を代表する平均値や、熟練者による地質学的な判断を入力データとして与える方法が考えられる。ここでは代表値として学習に使用した物性値の平均値を入力してみる。この平均値の入力に際して、0入力と同様、以下に示す4パターンを用いる。

①B4：一軸圧縮強度のみ平均値を入力する

②B5：湿潤密度、乾燥密度、土粒子の密度、一軸圧縮強度に平均値を入力する。

③B6：一軸圧縮強度、静弾性係数、静ポアソン比に平均値を入力する。

④B7：湿潤密度、乾燥密度、土粒子の密度、含水比、間隙比、飽和度、一軸圧縮強度、静弾性係数、静ポアソン比に平均値を入力する。

図-8に出力例として一軸圧縮強度の推定値と実測値の関係を示す。ケースB3(0入力)に比較して、ケースB7(平均値入力)の方が全体的に精度の向上が認められる。図-9は各入力パターンにおける一軸圧縮強度の平均誤差を示したもので、13物性値のどの部分が欠落してもほぼ同程度の誤差に治まっている。また、各パターンとも平均値を入力したケ




図-7：B3パターンにおける出力結果例




図-8：一軸圧縮強度の推定結果

ースで精度の向上が見られる。このことから、未知の物性値に対し、何らかの代表値の入力が有効であると考えられる。




図-9：各ケースにおける出力誤差

5. 結論

本報告では、上総層群泥岩の地盤物性のデータセットを用いて、各物性値の相関関係の抽出および地盤物性の推定へのニューラルネットワークの適用性について兼用した。

まず多入力1出力型の階層型ネットワークにより高い精度で一軸圧縮強度の推定が行えることを示した。このことは、一軸圧縮強度以外の他の物性値の組み合わせの中にすでに一軸圧縮強度に関する情報が含まれていることを示唆するとともに、その推定方法としてニューラルネットワークを用いることの有用性を示していると考えられる。回帰型ネットワークによる物性値間の相関関係学習結果からは、欠損データがいくつかあっても、他の物性値からそれらの値が推定できる可能性が示された。通常、ここで用いたようなデータセットが全て既知である場合は非常に少なく、そのような欠損データがあるような場合でも、物性値の推定が行えることは、今後の地盤データベースの整備において大きな意味をもつものと考えられる。

6. 今後の課題

今回は上総層泥岩に限ったネットワークを作成したが、この学習結果を他の岩種にそのまま適用することは、ニューラルネットワークの性質上無理がある。また、全ての岩種をひとつのネットワークに押し込むようなことも、同様に不適と考えている。

比較的似通った性質の岩盤、地盤についてそれぞれ、今回作成したようなネットワークを作成し、その上にそれらのサブネットワークを統合するエキスパートシステムに整備するなどのアプローチが今後必要になると思われる。また、地盤物性値データは、その計測・評価方法により、同じ岩盤に対しても、値が異なっていることがあるため、入力データとして用いる際には、そういった点にも十分注意が必要である。一つの方策としては、計測状況（室内、現場等）、計測方法といった項目もニューラルネットワークに与える情報として加えることが考えられる。

参考文献：

- 1) 京極、平井、蓮井：弾性波探査におけるニューラルネットワークを用いた波形処理について、第23回岩盤力学に関するシンポジウム講演論文集、pp. 36-39、1991。
- 2) 合原一幸：ニューラルコンピュータ、東京電機大学出版局
- 3) 麻生英樹：ニューラルネットワーク情報処理、産業図書