

大阪大学

学生員 ○北村将太郎

大阪大学大学院

学生員 工藤 俊祐, 神田真太郎

大阪大学大学院

正会員 小田 和広, 常田 賢一

## 1. はじめに

人工知能のうちニューラルネットワーク（以下 NN）の技術は、パターン認識等の計算機が従来苦手としていた分野を得意としている。この手法を用いれば、何らかの関係がありそうではあるが、理論的には説明しにくい関係を半ば強引に求めることができる。筆者らは、NN を用いて緯度、経度及び深度の位置情報から地盤情報を推定する試みを行ってきた。そして、大阪湾沿岸域の沖積粘土層における地盤情報の空間補間に対しては NN が有効であることを明らかにしている<sup>1)</sup>。

ところで、以前から大阪湾の沖積粘土には地域性があることが指摘されている<sup>2)</sup>。但し、その空間的な変化は激しいものではない。これは沖積粘土が堆積した大阪湾の環境の空間的な変化が緩やかであったことを反映している。一方、東大阪地域における沖積粘土の堆積環境は、海水→汽水→淡水と変化し、最終的に陸化している。それに加え、空間的な変化も激しい。

本研究では、形成過程が複雑な地盤の一例として東大阪地域を選び、そこにおける地盤情報の空間補間に対する NN の適用性を検討する。特に、最適な NN の構造と補間の精度について、地盤情報の持つ空間的なばらつきの点から考察する。

## 2. ニューラルネットワーク

NN とは人間の脳にある神経細胞（ニューロン）の情報伝達のしくみを数理的にモデル化した情報処理機構である。図-1 は本研究で用いた NN の構造を示している。NN は入力層、中間層及び出力層という階層状の構造をなしている。本研究の場合、地盤情報の空間補間、すなわち、地盤調査の行われていない地点の地盤情報を推定することを目的としているため、北緯・東経・深度の位置情報を入力項目とし、各種地盤情報を出力項目とした。モデルの構築においては入力値と出力値が既知である学習用データを NN に与え、推定値と学習値の誤差が小さくなるように層間の重みを変化させる。これを繰り返すことにより最適なモデルが構築される。また、NN の構築において、学習方法には拡張剪定法を採用している。これは大きなネットワークから開始し、学習が進行するにつれて中間層内の最も弱いユニットを削除（剪定）する方法で、NN 構築後の中間層内のニューロ数を見ることでネットワークの複雑さ、つまり、データのばらつき度合を評価する目安となる。




図-1 NNの構造




図-2 補間対象域とボーリング位置

## 3. 解析手順

本研究では、図-2 で示す東大阪対象地域内のボーリング試験結果（ボーリング試験本数 4767 本）を用いて解析を行った。推定項目は自然含水比と液性限界の2項目である。ボーリングデータベース（以下 DB）として KG-NET 関西圏地盤情報協議会『関西圏地盤情報データベース 2010』を、解析には SPSS『Clemen-

time Graduate Pack 10.0J』を使用した。以下に解析手順を説明する。

手順 1：地盤情報 DB から補間対象地域内のボーリング調査結果のみを選ぶ。また、今回の解析では沖積粘土層（Ma13 層）のみを解析対象とするため、そのデータのみを抽出する。

手順 2：使用するデータを 7 対 3 の割合で学習用と検証用にランダムに分ける。

手順 3：学習用データを用いて NN を作成、その NN に検証用データを通し地盤情報を推定する。

手順 4：推定値に対して精度評価を行うことで、NN 構造と精度について検討する。

#### 4. 精度評価方法

本研究にて推定精度の評価を行う上で用いる指標は、(1)相関係数、(2)精度  $G$ 、(3)平均誤差率  $MARE$  及び (4)Success Rates の 4 項目である。相関係数は対象となる全データの線形相関を表す指標である。 $G$  は誤差の二乗平均平方根  $RMSE$  及び真値の二乗平均平方根  $RMS$  より得られる指標で、誤差が大きいほど  $G$  は小さくなる。また、個々のデータのばらつきを表現するために、絶対誤差率  $r$  より得られる  $MARE$  及び  $r$  の頻度分布を示す Success Rates を用いる。真値を  $x_o$ 、NN による推定値を  $x_p$  として、各算出式を以下に説明する。

$$RMSE = \sqrt{\frac{1}{n} \sum (x_p - x_o)^2} \quad RMS = \sqrt{\frac{1}{n} \sum x_o^2} \quad G = \left(1 - \frac{RMSE}{RMS}\right) \times 100 \quad , \quad r = \frac{|x_p - x_o|}{x_o} \times 100 \quad MARE = \frac{1}{n} \sum r$$

#### 5. ニューラルネットワークの構造と精度について

表-1 及び表-2 は、それぞれ自然含水比及び液性限界における学習回数別精度分析結果を示している。自然含水比、液性限界ともに、学習回数 15000 回時に最も良い精度が得られた。この時の NN の構造は、自然含水比に対するものの方が液性限界に対するものよりも簡素である。また、多少精度も良いようである。物理特性である液性限界は堆積環境に依存しており、状態の変化によっても基本的に変化しない。一方、含水比は状態量であるので、乾燥や圧密によって変化する。したがって、含水比の空間分布の方が液性限界のそれよりも複雑であると考えられる。そうであるにも関わらず、含水比に対する NN の構造が簡素であり、かつ精度が良いのは、その空間変化を代表値からのばらつきと NN が判断した可能性がある。事実、表-1 及び表-2 に示す精度は海底粘土に対するものよりもかなり低い<sup>1)</sup>。したがって、予測精度向上のための何らかの工夫が必要である。

#### 6. まとめ

東大阪地域の沖積粘土を対象に、緯度・経度・深度の位置情報から地盤情報を推定するために、NN による空間補間を行い、NN の構造及び推定精度について検討した。その結果、今回適用した方法では、予測精度の高い NN を作成することは困難である。よって、予測精度向上のためには何らかの工夫が必要である。

#### 参考文献

- 1) 小田和広他：地盤情報の空間補間におけるニューラルネットワークの適用性，第 54 回地盤工学シンポジウム平成 21 年度論文集，pp185-188，2009
- 2) 土質工学会関西支部大阪湾海底の地盤研究委員会：大阪湾海底地盤，1990

表-1 学習回数別精度分析結果（自然含水比）

| 学習回数  | 分類  | 相関係数  | 精度 $G$ (%) | MARE (%) | Success Rates (%) |               |          | ニューロ数 |     |
|-------|-----|-------|------------|----------|-------------------|---------------|----------|-------|-----|
|       |     |       |            |          | $r < 10$          | $10 < r < 15$ | $15 < r$ | 1層目   | 2層目 |
| 5000  | 学習用 | 0.605 | 81.02      | 16.40    | 43.01             | 17.99         | 39.00    | 30    | 13  |
|       | 検証用 | 0.556 | 80.95      | 16.43    | 43.16             | 16.21         | 40.63    |       |     |
| 10000 | 学習用 | 0.655 | 82.22      | 15.33    | 48.37             | 17.91         | 33.72    | 27    | 6   |
|       | 検証用 | 0.617 | 82.25      | 15.24    | 49.02             | 17.97         | 33.01    |       |     |
| 15000 | 学習用 | 0.657 | 82.23      | 15.71    | 48.54             | 17.91         | 33.56    | 11    | 2   |
|       | 検証用 | 0.634 | 82.58      | 15.23    | 50.98             | 16.21         | 32.81    |       |     |
| 20000 | 学習用 | 0.667 | 82.38      | 15.39    | 51.21             | 18.08         | 30.71    | 10    | 5   |
|       | 検証用 | 0.626 | 82.40      | 15.42    | 48.24             | 19.73         | 32.03    |       |     |

表-2 学習回数別精度分析結果（液性限界）

| 学習回数  | 分類  | 相関係数  | 精度 $G$ (%) | MARE (%) | Success Rates (%) |               |          | ニューロ数 |     |
|-------|-----|-------|------------|----------|-------------------|---------------|----------|-------|-----|
|       |     |       |            |          | $r < 10$          | $10 < r < 15$ | $15 < r$ | 1層目   | 2層目 |
| 5000  | 学習用 | 0.550 | 82.23      | 14.96    | 44.75             | 19.66         | 35.59    | 30    | 11  |
|       | 検証用 | 0.523 | 82.05      | 15.59    | 45.66             | 17.37         | 36.97    |       |     |
| 10000 | 学習用 | 0.598 | 82.94      | 14.22    | 48.66             | 17.37         | 33.97    | 25    | 11  |
|       | 検証用 | 0.541 | 82.26      | 15.31    | 48.11             | 17.37         | 34.52    |       |     |
| 15000 | 学習用 | 0.604 | 83.05      | 13.78    | 47.42             | 21.95         | 30.63    | 24    | 13  |
|       | 検証用 | 0.546 | 82.29      | 15.13    | 46.77             | 19.38         | 33.85    |       |     |
| 20000 | 学習用 | 0.570 | 82.52      | 14.65    | 47.04             | 18.03         | 34.92    | 8     | 4   |
|       | 検証用 | 0.502 | 81.74      | 15.82    | 44.10             | 19.60         | 36.30    |       |     |