

# 自己組織化特徴マップを用いた地盤性状の空間分布推定法

A study on spatial estimation method for geotechnical characterization  
using self-organizing feature map

伊藤則夫\*、白木渡\*\*、安田登\*\*\*

Norio Itou, Wataru Shiraki and Noboru Yasuda

\*(有)シー・エー・イー (〒680-8064 鳥取県岩美郡国府町分上2-210)

\*\* 工博 香川大学教授、工学部安全システム建設工学科 (〒760-8526 香川県高松市幸町1-1)

\*\*\* 工博 東京電力(株)電力技術研究所 土木グループ (〒230-8510 横浜市鶴見区江ヶ崎4-1)

In design of large size structures such as dam, air port so on, one of most important works is to evaluate the geotechnical characterizations at the construction site. Field or laboratory data are often analyzed to measure geotechnical characterization parameter values such as ore grade, base rock, hydraulic conductivity, sediment thickness, porosity at known locations over an area of interest. When used in combination with these values at the measured locations to determine values for the unmeasured locations, geostatistics can provide a way of describing the spatial continuity necessary for increased understanding of the area of interest. The geostatistical tool kriging is a popular method of interpolation, however it requires that an estimate of the correlation structure be known or assumed. In practice it often become to be very difficult. In this study, an effective spatial estimation method without correlation structure is proposed using self-organizing feature map known as Kohonen neural network.

*Keywords : Self-organizing feature map, spatial estimation method,  
geotechnical characterization, Lugeon water test*

## 1. まえがき

構造物を建設しようとするとき、その構造物の基礎となる地盤性状を正しく知ることが重要な問題となる。ボーリング調査は地盤性状を知るために最も一般的に行われる調査法である。しかし、ボーリング調査によって得られる情報はいわば線としての情報であり、これから2次元あるいは3次元空間における地盤性状の分布を推定するのは容易ではない。また、地盤性状の評価精度を高めようとすると、より多くの情報を入手すること、すなわちより多くのボーリング調査を実施することが必要となるが、これは工期および費用の制約上自ずから限界がある。結局、地質専門家は限られた調査資料をもとに広域的な地形、地質の情報および歴史的経緯を考え合わせて地面の下の状態を推定することになる。

早く、安価に、かつ精度高く地盤の評価を行うためには、これまで得られているデータからすばやく地盤性状モデルを作成し、追加調査を必要とする地点があるならそれ

を示すことができるツールが不可欠である。

近年、新しい計測技術の開発と平行して、新しい情報処理手法を利用して地盤性状の推定精度を高めようとする研究が増えてきている<sup>1)</sup>。そのひとつに、地質・鉱山学で用いられているクリッギングがある。これは確率論的に未知空間の変数を求めるもので、著者らもこの手法により物性値の空間分布推定を行い、送電線鉄塔の支持力の推定に利用している<sup>2)</sup>。しかし、多くの場合この手法ではエルゴード性の仮定が成り立つことが必要であり、複雑に入り組んだ地盤へ適用することは困難である。

また、一方では空間的な物性値の分布推定問題へのニューラルネットワーク(以下、NNとする)の応用に関する研究が盛んに行われている<sup>3)</sup>。これらの研究の大半は誤差逆伝播法(BP法)を用いた教師ありネットワークであり、著者らも地熱資源探査問題<sup>4)</sup>、グラウト効果の評価問題<sup>5)</sup>などにBP法を応用する研究を行ってきた。BP法

を応用することの有効性は多くの論文で発表されているが、本研究で取り扱おうとする地盤性状の空間分布推定問題にはこの方法は適当ではないと考えられる。なぜなら、ボーリング調査の実施地点ではさまざまな地質情報が得られているものの、評価を行おうとする地点においてはこれらの情報はまったく得られておらず、NNシステムの入出力データが存在しないことになるからである。

最近、NNの1つである自己組織化特徴マップ(SOM: Self-Organizing feature Map)<sup>6)</sup>が注目され始めている。SOMは競合学習を行う教師なしNNで、学習により入力データパターンの特性をそのまま反映したマップを形成することができる。そして、そのマップを観察することによりパターン間の関係やパターングループを理解することが可能となる。このような特徴からSOMはパターン分類やパターン認識の分野で特に優れていると考えられ、データの前処理にSOMの特性を利用してBPの汎化能力の向上を図ろうとする研究<sup>7)8)</sup>が行われている。

SOMの学習アルゴリズムの特徴は、競合に勝ち残ったニューロンだけではなく、その近傍に位置するニューロンをも含めて集団で学習が行なわれることである。すなわち、学習の過程において近くに位置するニューロンはお互いに影響しあっているということである。地盤性状の分布も当然位置的に近ければ関連しあっているはずであり、SOMの学習アルゴリズムに通ずるものがある。

本研究においては、このSOMの学習アルゴリズムの特徴を生かし、ボーリング調査資料から2次元空間における地盤性状モデルを作成する方法について検討する。

## 2. SOMの基礎理論

ヒトの脳の大脳皮質には感覚情報の解析、運動の組織化などの様々な知的行動の複雑な作業が行えるように特殊化された部分がある。これらは感覚野と呼ばれており、各感覚野には対応する感覚器官の配置を表すマップがある。SOMは感覚運動現象の脳へのマッピングを模したNNモデルとして1988年にコホーネンによって提唱された教師なし学習アルゴリズムである<sup>6)</sup>。

SOMのネットワークはデータを入力する入力層と、入力したデータを元にマップが形成される競合層の2層か

らなっている。図-1にSOMの基本的な構造を示す。競合層はBP法で言えば出力層に当たるものであるが、多数のニューロンが競争し、競争に勝ち残ったものだけが出力されることからこのように名づけられたものである。また、学習法が競合学習と呼ばれるのも同じ理由である。SOMの各層にはニューロンが存在し、入力層と競合層のすべてのニューロンは結合している。そして、入力層と競合層の結合重みを介してデータが記憶される。同じ層同士のニューロン間には結合は存在しない。

SOMの学習則をまとめると次の通りである。

- ① 入力層と競合層を結ぶ結合重みに適當な値を設定する。結合重みは乱数で設定されることが多いが、意図して規則的な値を与えることもある。
- ② 入力層に入力ベクトル $E$ を設定する。
- ③ 入力ベクトル $E$ と競合層のニューロン $i$ への重みベクトル $U_i$ の一致値 $\|E - U_i\|$ を計算する。この値は各ニューロンの重みが入力パターンの対応する値と一致する度合いを計るものであり、式(1)で計算される。

$$\|E - U_i\| = \sqrt{\sum_{j=1}^n (e_j - u_{ij})^2} \quad (1)$$

ここで、 $e_j$ :入力ベクトルの各成分

$u_{ij}$ :入力層のニューロン $j$ と競合層のニューロン $i$ への結合重み

- ④ 一致値が最小となるニューロン、すなわち入力ベクトル $E$ と最も似通った重みベクトルを持つニューロンを勝者ニューロンとする。さらに、勝者ニューロンの回りに近傍領域 $N_c$ と呼ばれる領域を設定する(図-2参照)。
- ⑤ 組合重みベクトルの更新を行なう。

$$\Delta u_{ij} = \begin{cases} \alpha(e_j - u_{ij}) & i \in N_c \\ 0 & i \notin N_c \end{cases} \quad (2)$$

ここで、 $\Delta u_{ij}$ :組合重み $u_{ij}$ の更新量

$\alpha$ :学習率

- ⑥ 各入力ベクトルに対して①～⑤を繰り返す。

近傍領域 $N_c$ および学習率 $\alpha$ には最初は比較的大きな値を設定し、学習の進行に従って次第に小さくなるように

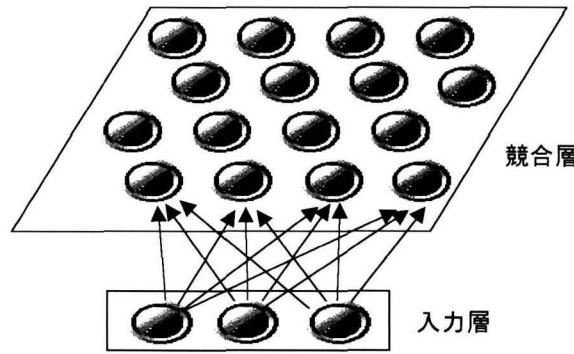


図-1 コホーネンの自己組織化特徴マップの基本構造

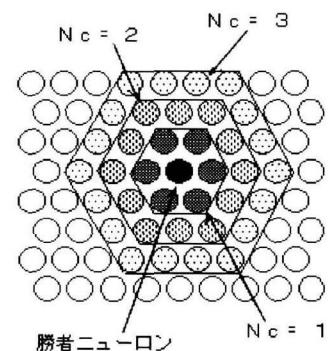


図2 近傍領域

設定する。近傍領域および学習率の減衰関数としては参考文献によりさまざまな関数が紹介されており、学習の進行とともに減少するものならどのような関数でも使用して差し支えないといえる。最も適切な減衰関数がどのようなものかは取り扱う問題により異なると思われるが、その都度プログラムを書き直すのは得策ではない。そこで、著者らはBP法で入出力関数として一般的に用いられているシグモイド関数を変形した式(3)、式(4)を使用している。シグモイド関数はパラメータによりさまざまな減衰状態を作り出せるので都合が良い。

$$N_c = \left[ (N_{c\max} - N_{c\min}) \frac{f(t/t_{all}) - f(1)}{1 - f(1)} + N_{c\min} \right] \quad (3)$$

$$\alpha = (\alpha_{\max} - \alpha_{\min}) \frac{f(t/t_{all}) - f(1)}{1 - f(1)} + \alpha_{\min} \quad (4)$$

$$f(x) = \frac{1}{\exp(x/T)} \quad (5)$$

ここで、 $t$ は現在の学習回数であり、 $t_{all}$ は行なわれるべき全学習回数、 $N_{c\max}$ 、 $\alpha_{\max}$ は近傍領域および学習率の初期値、 $N_{c\min}$ 、 $\alpha_{\min}$ は終値である。また  $T$ は温度である。式(5)は本来右上がりであるシグモイド曲線を右下がりになるように変更するとともに  $x=0$  のときに 1.0 となるようにしたものである。そして、式(5)では  $X$  がどれほど大きくなつたとしても  $f(x)$  は 0.0 とはならないので式(3)、式(4)でこれを補正している。

近傍領域の初期値には一般的には競合層の大きさの  $1/3 \sim 1/2$  が用いられ、学習率の初期値には普通  $0.2 \sim 0.5$  程度の値が用いられる<sup>9)</sup>。

### 3. 適用例の概要

本研究では、ダム立地地点の地質評価問題を適用例

表-1 ポーリング地質データ項目一覧

項目	説明
① 岩種	岩盤を4岩種に区分
② 岩盤等級	B,CH,CM,CL,D の5段階
③ 岩の硬さ	極硬～極軟の5段階
④ コア形状	棒状～スライム状の7段階
⑤ 割れ目の性状	4段階の風化・変質区分
⑥ 風化区分	4段階の風化区分
⑦ 変質区分	4段階の変質区分
⑧ 採取率	コア採取長
⑨ 最大コア長	コアの最大長
⑩ RQD(10cm)	10cm以上のコア長の累計
⑪ RQD(5cm)	5cm以上のコア長の累計
⑫ RCI	コア長の上位3つの累計
⑬ 粘土比率	粘土化部の比率
⑭ 分離面頻度	コア分離面の総数
⑮ X座標	ダム軸からの離れ
⑯ Y座標	区間中央の海拔標高
⑰ ルジョン値	1Lu は試験区間で $10 \text{ kg/cm}^2$ の圧力で 1m 当り $1 \text{ ml/min}$ の注水量をあらわす。

として扱う。ダム地質調査の目的は、安全かつ経済的なダムの設計・施工に必要な地質工学的特性をできるだけ正確に把握することである。ダムの安全性を確保するためにはダム基礎の状態をその耐荷力(強度)と遮水性(透水性)の両面から解析する必要がある。

適用例として選んだダムサイトにおいては 12 本のボーリング調査(掘進長: 100 ~ 300m)が実施されており、ボーリング調査については表-1 のようなデータがまとめられている。表-1 の項目のうち ① ~ ⑦ は定性的なデータであり、⑧ ~ ⑯ は定量的なデータである。

本研究では、表-1 の地盤性状のうち、遮水性の評価に直接的にかかわるルジョン値の分布状況の推定を行うものとする。推定を行う範囲は左岸側の水平方向に 210m、深さ方向に 200m とし、入出力データとしては 12 本のボーリングのうち 5 本分を使用した。使用したボーリングの位置、および地質専門家によるルジョン値の分布推定図を図-3 に、データの数量を表-2 に示す。標高 400 ~ 500m 付近のかなり深い位置に 30 ルジョン以上の高透水性ゾーンの存在が推定されているのがこの地点の特徴である。なお、ダム基礎岩盤として確保すべき遮水性の目標値は 2 ルジョン以下である。

ニューラルネットワークを利用したシステムの妥当性を

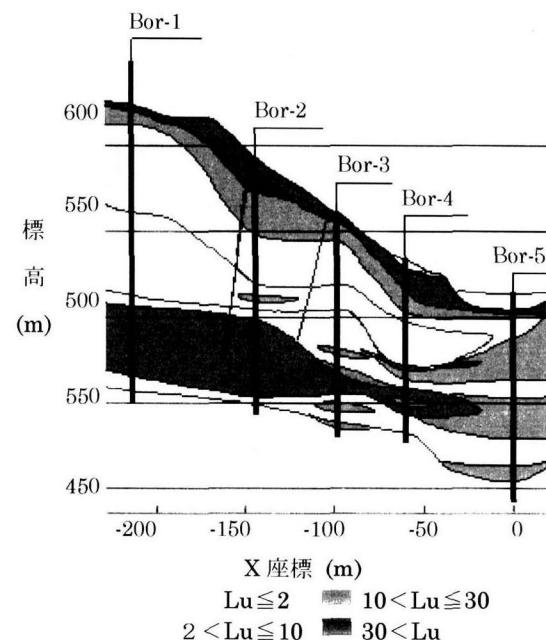


図-3 ボーリング位置およびルジョン値分布図

表-2 データ数量

記号	X座標(m)	坑口標高(m)	掘進長(m)	データ数
Bor-1	-210.00	646.62	195.00	38
Bor-2	-145.00	594.21	150.00	28
Bor-3	-100.00	561.53	130.00	25
Bor-4	-60.00	533.27	105.00	20
Bor-5	0.00	514.87	120.00	22
合計			700.00	133

注) ルジョン値の計測単位は 5m である。

示すためには、一般的には使用できるデータのうちいくらくを学習に関与させないで残しておき、出来上がったシステムによって残しておいたデータを評価し、その結果を正解値と比較する方法がとられている。しかし、本研究で取り扱う地点においては、ボーリング同士の離れが平均50mではほぼ等間隔に並んでおり、このうちの1本を除くと推定精度そのものを大きく損なうことが予測できる。また、鉛直方向に何点かのテストデータを取り出す方法によるとしてもデータ値のばらつきが大きいため正解・不正解を議論するのは無意味と考える。以上の理由から、本研究ではすべてのデータを学習データとして、推定結果の評価は地質専門家が推定した分布図と対比することによって行う。ただし、その分布図自体が推定によって作成されたものであり、本当の正解は誰にもわからないということを考慮する必要がある。

#### 4. BP法によるルジオン値分布の推定

まえがきにおいて、BP法はこの問題には適当ではないと述べたが、SOMとの比較のためにBP法によるルジオン値分布の推定も行った。

表-1に示したようにボーリング調査を行った地点においてはさまざまな情報が得られているが、これらはすべて掘削を行った結果判明したものであり、推定を要する未知の地点では得ることができないものである。結局、未知の地点において明確にわかっているのは空間的な位置関係のみである。

よって、BP法で入力に使用できるのはX座標およびY座標のみとなる。しかし、試算を行ったところ情報不足から座標値のみでは学習できなかった。そこで、情報を増やすため、座標値を百位の桁、十位の桁、および一位の桁(それぞれが0~9の値を持つ)に分解し合計6項目とした。システムの出力はルジオン値であるが、ルジオン値の分布が0~4,600程度と幅広いため、これの対数値を推定することとした。

入力層-中間層-出力層を6-5-1とし、10,000回(1組の学習データをすべて提示するのを1回とする)の学習を行った。中間層のニューロン数はコンパクト構造化<sup>10)</sup>を

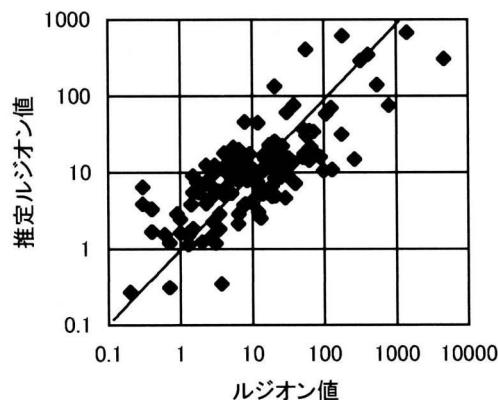


図-4 BP法による学習状況

用いた予備検討により最適と思われる数を採用したものである。

このシステムの学習の状態を調べるために横軸には実際のルジオン値、また、縦軸には学習後のBPシステムにより推定したルジオン値をプロットしたものを図-4に示している。縦横軸はともに対数目盛であり、学習状況は決して良好とは言えない。BP法で学習するにはやはり情報不足であるといえる。

また、未知の地点におけるルジオン値の推定の様子を調べるために、推定範囲を縦5m横10mのグリッドに分割し、各グリッド上のルジオン値を推定した。そして推定したルジオン値により専門家の推定図(図-3)と同様の階級化した等高線図を作成して図-5に示している。図-5を見るとボーリング位置の近傍においては図-3と同様な状況を示しているが、隣り合うボーリング間のつながりを捉えられず、推定範囲全体としては図-3とはかなり異なっている。

#### 5. SOMによるルジオン値分布の推定

SOMを用いて地盤性状の空間分布を推定するには2つの方法が考えられる。すなわち、推定すべき地盤性状を学習データに加えない方法と、その地盤性状をもいつしょに学習する方法である。

前者の場合ネットワークへの入力として使用できるのはBP法の場合と同様にX座標およびY座標の2項目となる。そして、後者の場合ではこれに推定すべき地盤性状、本研究ではルジオン値(対数値)を加えた3項目とする。

X、Y座標のみを使用したSOM学習により得られたマップからのルジオン値の推定は以下のように行う。

- ① 1つのニューロンとすべての学習データの式(1)に示す一致値を計算する。
- ② 一致値が最小である学習データを1つ選び出し、そのデータセットに対応するルジオン値をルジオン値の推定値とする。

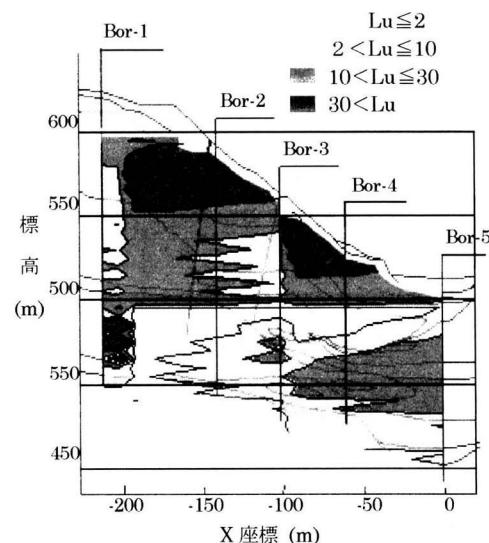


図-5 BP法による推定ルジオン値分布

③ 推定されたルジオン値に対する空間的な位置はマップのX、Y座標に対応する結合重みそのものとする。

一方、座標値およびルジオン値を使用して学習を行った場合には、推定ルジオン値、座標位置はすべて学習後のマップの結合重みそのものとする。

入力層には入力項目数に合わせて2つまたは3つのニューロンを設け、競合層には推定範囲を縦にルジオン値の計測範囲である5m、横には10mのグリッドで覆うように縦49、横22のニューロンを設けた。式(5)の温度Tは1.0とした。

SOMの学習を行うにあたって注意すべき重要な点がある。それは、この適用例について例えれば、マップの中央にあたるニューロンが推定範囲の端部

に割り当てられることである。そのような状態を著者らは「マップのねじれ」と呼んでいる。この適用例においては、マップのねじれは推定結果に悪影響を及ぼすことが予備研究によりわかっている。

マップのねじれを防ぐには重みの初期値のとり方や学習パラメータの選択が重要である。そこで、重みの初期値には、実際の座標値とニューロンの位置を対応付けるためX座標については左から右に向かって、また、Y座標については下から上に向かって0~1に変化するように設定した。ルジオン値に対する初期重みは0.5の一定値とした。なお、学習を行う際には学習データは0.0~1.0に基準化する。

さらに、急激な重みの変化を避けるために、学習率の初期値は通常よりかなり小さく0.1とし、近傍領域の初期値は競合層横のニューロン数の1/2程度として10とした。学習回数は300回とした。

図-6~8にSOMにより推定したルジオン値の分布を示している。図-6は座標値のみで学習を行ったものであり、図-7は座標値およびルジオン値を用いて学習を行ったものである。図-8も座標値およびルジオン値の3項目を使用して学習したものであるが図-7では座標値とルジオン値を同等に扱ったのに対し、図-8ではルジオン値の基準化を0.25~0.75の範囲で行っている。こうすることにより式(1)におけるルジオン値の寄与率を下げることができる。

なお、学習を終えたマップから図-6~8を作成するには次のような手順を踏んでいる。

- ① 先に述べた方法によりマップからルジオン値の推定値およびその座標位置を取り出す。
- ② SOMの性質から推定値は学習データとして与えた位置には密集して得られる。例えば図-7に対応する学習後のマップの座標値に対する

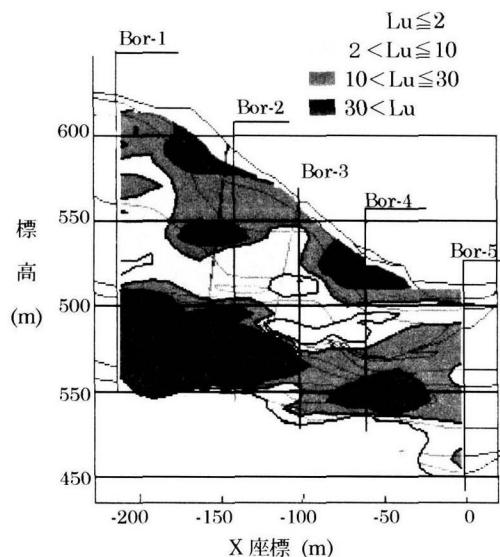


図-6 座標値のみを用いたSOMによる推定ルジオン値

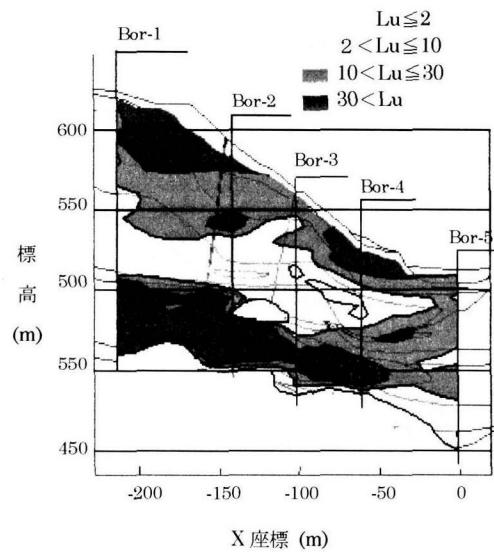


図-7 座標値とルジオン値を学習したSOMによる推定ルジオン値

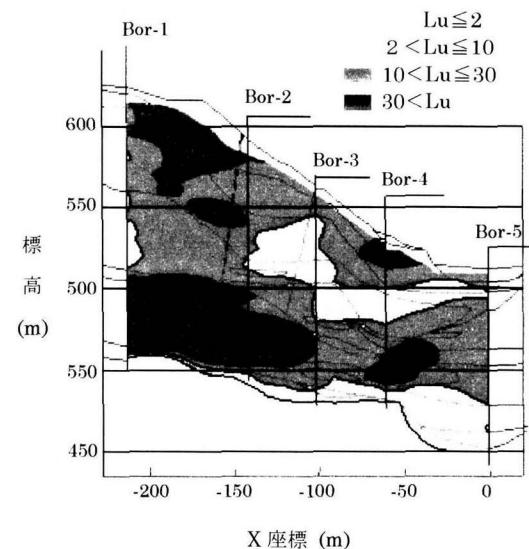


図-8 座標値とルジオン値を学習したSOMによる推定ルジオン値(ルジオン値の基準化幅:0.5)

重みをプロットすると図-9 のようになっている。この図で点は1つのニューロンを示し、点を結ぶ線は2つのニューロンが隣接していることを示している。この図で縦に太い線のように見えている部分がボーリングの位置であって、この付近には多くの推定値が存在する。これらの5m四方の範囲にあるものを平均し、その区間の代表値とする。

- ③ ②で得られた値に学習に用いた生のデータを加え、曲面を当てはめる方法<sup>11)</sup>により、49×22の格子点上の推定値を求める。
- ④ 格子点上の推定値を直線補間し、境界値となる位置を求めて結ぶ。

すなわち、②および③の段階でSOMで求めた推定値を平滑化していることになり、細かい変化は捉えにくくなる。

図-6～8 のいずれの図もBP法によって推定した図-5 と比べるとボーリング間のつながりをはるかに良く捉えていると思われる。

専門家による推定図（図-3）と比較すると、標高500～550mの低透水性ゾーンの推定はかなり異なっている。Bor-5 の標高600m付近およびBor-4 の標高550m付近には、データの数値としてはルジオン値が大きいものがある。しかし、専門家はこれを局部的なものと考えたのか無視する形で推定しているのに対し、SOMではこれをそのまま用いて推定したためこの相違が生じたものである。

標高450m以下の低透水性ゾーンおよび標高450～500mの高透水性ゾーンではSOMの推定と専門家の推定は良く一致している。中でも座標値とルジオン値を用いて学習した図-7 では標高450～500mの高透水性ゾーンの連続性を良く捉えており、推定すべき地盤性状を学習データに加えた効果が現れているものと考える。

図-8 では推定の状態が若干ラフであるように感じられる。これは、ルジオン値の基準化幅を狭めたことによりルジオン値に対する分解能が低下したものと思われる。

## 6.まとめ

本研究ではダム基礎岩盤のルジオン値分布の推定を例題としてニューラルネットワークにより地盤性状の分布を推定する方法について検討を行った。その結果、従来から用いられているBP法では情報不足のため満足できる推定が行えなかつたが、SOMを用いる方法ではかなり正確に推定できる可能性を見出した。

この種の問題では実際に掘削して正解を確かめることは工期および費用の制約から不可能であり、そのため、本研究で提案した方法がどの程度正しいのかを直接的に、かつ定量的に示すことはできない。よって、正解が明らか

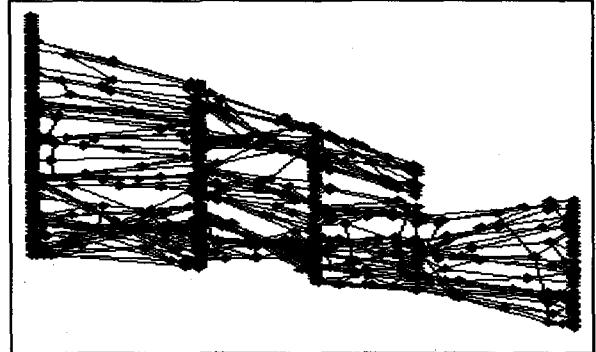


図-9 学習後の座標値の重み

である他の問題にこの方法を応用して推定誤差を定量的に把握することが本研究の今後の課題となる。

## 参考文献

- 1) 戸井田,升元,日比谷:比抵抗トモグラフィーによる水理地質構造の異方性評価について,鹿島技術研究所年報,Vol. 43,pp. 185 - 189,1995
- 2) 白木,恒国,松島,安田:地盤物性値間の回帰関係を利用したコクリッギングによる送電鉄塔基礎の支持力の推定,土木学会論文集,No. 582 / III - 41,pp. 47-58,1997,12
- 3) 水野,後藤,一柳,横水,松村,鬼頭:レーダデータを用いたニューラルネットワークによる大井川上流域の地上雨量分布推定,電気学会電力・エネルギー部門大会論文集,Vol6th, No. 2,pp. 119-120,1995
- 4) 伊藤,白木,安田,上田:重力異常の空間分布特性を考慮したニューラルネットワークによる地熱資源評価,構造工学論文集,Vol. 43A,pp. 571-576,1997,3
- 5) 安田登,松島,安田武,飯島:ニューラルネットワークを用いた岩盤グラウト注入効果の評価システムの構築,構造工学論文集,Vol. 42A,pp. 433-438,1996,3
- 6) T. Kohonen 著,徳高,岸田,藤村:自己組織化マップ,シェブリンガーフェアレーク東京,1996, 5.
- 7) 白木,松保,宮下,伊藤:自己組織化特徴マップ(SOM)による斜面崩壊予測システム,構造工学論文集,Vol. 44A,pp. 453-459,1998,3
- 8) 近田,広瀬,城戸:SOM/LVQ を援用した橋梁点検データの見直し,構造工学論文集,Vol. 44A,pp. 503-510,1998,3
- 9) J. Dayhoff 著,桂井浩:ニューラルネットワークアーキテクチャ入門,森北出版,1992,4
- 10) 伊藤,白木,安田:階層型ニューラルネットワークの構造最適化に関する研究,第5回システム最適化に関するシンポジウム講演論文集,pp. 135～140,1997,12
- 11) 塩野,升本,弘原海:BASICによるコンターマップ II 応用編,共立出版,1988,11

（1998年9月18日受付）