

地盤物性値の空間分布推定問題への 自己組織化特徴マップの応用

伊藤則夫¹・白木渡²・安田登³

¹正会員 有限会社シー・エー・イー 代表取締役 (〒680-8064 鳥取県岩美郡国府町分上2-210)

²正会員 工博 香川大学工学部教授 安全システム建設工学科 (〒760-8526 香川県高松市幸町1-1)

³正会員 工博 東京電力㈱電力技術研究所 主管研究員 (〒230-8510 横浜市鶴見区江ヶ崎4-1)

土木構造物を設計し、建設するにあたって、まず地盤の状態を正しく推定することが必要となる。そのためにボーリングなどの調査が行われ、調査地点における地盤物性値が求められる。しかし、経済的理由等から調査地点の数は限定され、広い建設用地全体から見るとわずかな点の情報が得られるに過ぎない。結局、専門家の経験に基づいて点の情報を相互に関連付け、二次元・三次元空間における地盤物性値の分布を推定することになる。

本論文では、地盤物性値の分布推定を空間上の曲面補間問題としてとらえ、多次元空間に分布する情報の相互関係を明確にする自己組織化特徴マップに曲面補間に適するような改良を加えた新しいアルゴリズムを提案している。そして、これを用いて地盤物性値の空間分布推定を行い、その有効性を示している。

Key Words : *geotechnical characterization, spatial estimation method, self-organizing feature map, counter propagation network*

1. まえがき

土木構造物を設計し、建設するにあたって、まずその構造物の基礎となる地盤の状態を正しく推定することが必要となる。そのために、一般的にはボーリング調査が実施され、必要とする地盤物性値の情報が収集される。ボーリング調査を行うことで、調査地点においてはさまざまな情報が得られるが、これは広い建設用地全体から見るといくつかの点における情報が得られたに過ぎず、これをもとに建設用地全体に対する地盤物性値の分布を推定することは容易ではない。物性値分布の推定精度を高めようとする、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と限界がある。結局、建設用地全体にわたる地盤物性値の分布を推定するためには、地質専門家の経験に頼ることになる。専門家は広域的な地形、地質の情報および歴史的経緯を考え合わせて、限られた情報を相互に関連付けることでこの推定を行っている。

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物性値の分布を推定しようとする研究が増えてきている¹⁾。確率論的に未知空間の変数を求めようとするクリッキングもそのひとつである。

この方法は地質・鉱山学でよく利用される方法であり、著者らもこの手法により送電線鉄塔の支持力の分布推定を行っている²⁾。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。

最近、種々の物性値の空間分布推定問題にニューラルネットワーク(以下、NNとする)を応用しようとする研究が盛んに行われている^{3,4)}。これらの研究の大半は教師ありネットワークである誤差逆伝播法(BP法)を用いている。BP法がさまざまな問題に対して有効な手法であることは多くの論文^{5,6)}に示されており明らかであるが、本研究で対象としている地盤物性値の空間分布推定問題に対してこの方法を適用するのは困難であると考えられる。なぜなら、ボーリング調査を行った位置では多くの情報が得られているものの、評価を行おうとする未調査地点においてはこれらの情報は全く得ることができず、BP法による学習において必要な入力データを準備することができないからである。この場合、BP法の学習データとして使用できるのは、物性値が既知である地点と評価を行いたい地点の位置関係、すなわち座標値のみと言うことになる。しかし、座標値のみの情報だけではBP法の学習は充分に行えない。

自己組織化特徴マップ⁷⁾(Self-Organizing feature Map:以下




図-1 SOMの基本構造

SOMと呼ぶ) はパターン分類・パターン認識を得意とする手法である。SOMは多次元空間に分布するさまざまな情報の相互関係を可視化する能力に優れており、これまでこの特徴を利用した研究⁹⁾が数多く報告されている。筆者らも、BP法による斜面崩壊予測システムの学習データをSOMを用いて選択することで予測精度の向上を図る研究を行っている¹⁰⁾。その一方で、近年になってSOMが高い関数近似能力を持っていることが発見され、この能力を利用するための研究が行われている^{11),12)}。

また、コホーネンの競合学習とグロスバーク学習を結合したカウンタープロパゲーションネットワーク¹³⁾ (以下、CPNと呼ぶ) もまた高い関数近似能力を持つと考えられているアルゴリズムである。この手法の適用事例はまだ多くは見られないが、ロボット工学における物体の位置検出¹⁴⁾、また構造物の最適設計への応用¹⁵⁾などが報告されている。

本論文では、SOMおよびCPNを曲面の補間問題に応用し、それぞれのアルゴリズムの長所および短所を検証する。また、二つのアルゴリズムの長所を結合し、関数近似問題に適するように著者らが考案した拡張SOMを紹介し、これを用いた地盤物性値の空間分布推定法を提案する。

2. ニューラルネットワークの基礎理論

(1) SOMの基礎理論

a) SOMの概要

SOMは、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。SOM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。SOMの基本的な構造を図-1に示す。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。

SOMの学習の特徴には競合に勝利したニューロンが学習する競合学習、およびその近傍のニューロンもまた学習する近傍学習の2つがある。

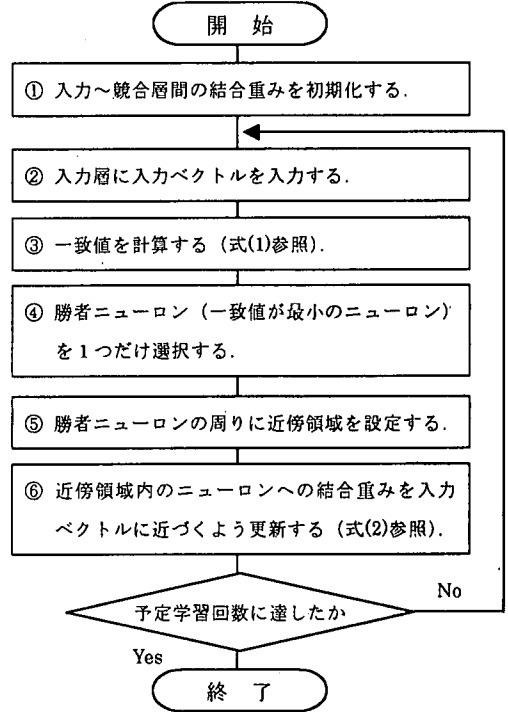


図-2 SOMの学習手順

b) SOMの学習アルゴリズム

SOMの学習手順をまとめると図-2の通りである。

図-2の③の一致値は競合層の各ニューロンへの結合重みと入力パターンの類似度を計るものであり、式(1)で計算される。

$$d_i = \| \mathbf{X} - \mathbf{U}_i \| = \sqrt{\sum_{j=1}^n (x_j - u_{ij})^2} \quad (1)$$

ここで、 x_j は入力ベクトルの各成分、 u_{ij} は入力層のニューロン j と競合層のニューロン i への結合重みである。

また、⑥の結合重みの更新は式(2)により行う。

$$\Delta u_{ij} = \begin{cases} \alpha_{(i)} \{ x_j - u_{ij} \} & i \in N_{c(i)} \\ 0 & i \notin N_{c(i)} \end{cases} \quad (2)$$

ここで、 Δu_{ij} は結合重み u_{ij} の更新量、 $\alpha_{(i)}$ 、 $N_{c(i)}$ は学習回数 i における学習率、および勝者ニューロンの周りに設定された近傍領域である。近傍領域の大きさおよび学習率は学習の初期値には比較的大きな値とし、学習の進行に従って次第に小さくなり、最終的には0に近づくように設定する。

図-2④が先に述べたSOM学習の特徴の1つである競合学習であり、⑥が近傍学習と呼ばれるものである。

c) 関数近似問題におけるSOMの利用方法

関数 $y=f(x_1, x_2, \dots, x_n)$ の補間を行う場合、BP法や次節で説明するCPNを用いるなら $\mathbf{X}=\{x_1, x_2, \dots, x_n\}$ を入

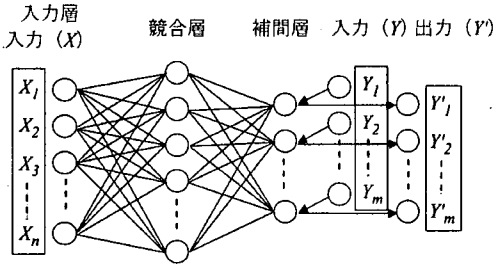


図-3 CPNの基本構造

カベクトルとして入力層に提示し、 y を教師ベクトルとして出力層に提示する。

SOMは出力層を持たないので、求めたい y をも含め、各要素ごとに0.0~1.0に正規化した $X' = \{x'_1, x'_2, \dots, x'_n, y'_1, y'_2, \dots, y'_m\}$ を入力ベクトルとする。そして、学習を行った後の結合重みの状態から補間点の位置および補間値を求めることになる。

具体的には、入力層には $n+1$ 個のニューロンを設け、入力ベクトル X' を用いてSOM学習を行う。そして、入力層 i 番目のニューロンと j 番目の競合層ニューロンの学習後の結合重みを u_{ij} として、 j 番目の競合層ニューロンが示す補間点の位置 $\{x_{1j}, x_{2j}, \dots, x_{nj}\}$ 、およびその位置における補間値 y_j を式(3)で求める。

$$\begin{cases} x_{ij} = u_{i,j} \cdot (x_{i,\max} - x_{i,\min}) + x_{i,\min} \\ y_j = u_{n+1,j} \cdot (y_{\max} - y_{\min}) + y_{\min} \end{cases} \quad (3)$$

ここで、 $x_{i,\min}, x_{i,\max}$ は学習ベクトルの i 番目の要素の最大値および最小値、 y_{\min}, y_{\max} は関数の最大値および最小値である。

関数補間問題にSOMを用いる場合、BP法やCPNと異なり、任意点における補間値を自由に求めることができないという問題点がある。SOMで得られるのは、学習が終わったとき、あるニューロンがたまたま示している位置での補間値のみであり、特定の位置における補間値を求めるためには、なにか別の補間手法を併用する必要がある。著者らのこれまでの研究¹⁶⁾では、任意位置での補間値を求めるために、等高線図の作成に一般的に用いられている曲面の当てはめ手法¹⁷⁾を併用している。

(2) CPNの基礎理論

a) CPNの概要

CPNは1986年にヘクト・ニールセン¹³⁾により提唱された教師付き学習法である。CPNは入力層、競合層、および補間層の3層からなっている(図-3参照)。

CPNにおける信号の流れは入力ベクトルを学習し、ネットワークを構築するステップと、学習済みのネットワークを利用して入力ベクトルに適合した出力ベクトル

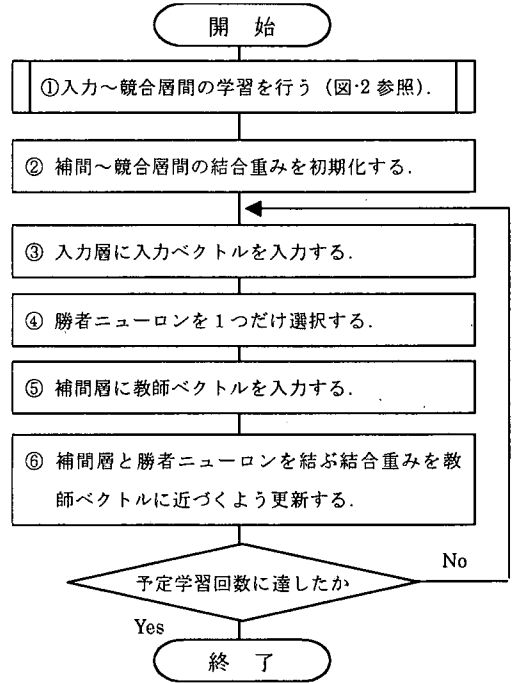


図-4 CPNの学習手順

を得るステップで異なっている。そして、それぞれのステップの前者を学習モード、後者を補間モードと呼んでいる。

CPNは、学習モードにおいて多くの学習ベクトルをいくつかのクラスタに分類し、それぞれのクラスタについて平均的な出力パターンを記憶する。そして、補間モードにおいては、評価対象となるベクトルに類似したいくつかのクラスタを選択し、それらが持つ出力パターンを補間した新しいパターンを出力する。

b) CPNの学習アルゴリズム(学習モード)

CPNの学習手順を図-4に示す。CPNの学習は2つのステップによって行われ、その最初のステップでは学習は入力層と競合層の間で行われる。

このステップの学習手順は近傍学習を行わないこと以外はSOMと同様である。CPNでは図-2の⑤、⑥の近傍領域は設けず、結合重みの更新は勝者ニューロンに対してのみ行われる。このステップにおいて学習ベクトルのクラスタリングが行われている。

入力層～競合層間の学習が終わった後、2番目のステップにおいて補間層と競合層の間での学習が行われる。このステップで各クラスタに対する平均的な出力パターンを記憶している。

c) 補間モード

補間モードにおいては、入力層に提示された1組の評価用ベクトルに対して、式(1)で計算される一致値が




図-5 初期結合重みの設定

小さい順に競合層上で勝者ニューロンを1つ以上決定する。勝者ニューロンをいくつ選択するかは問題によって異なり、ネットワークの性能にかかわる大きな要素である。

勝者ニューロンの数を N_{win} としたとき、出力ベクトル $Y = \{y'_1, y'_2, \dots, y'_m\}$ は式(4)で求めることができる。

$$y'_j = \sum_{i=1}^{N_{win}} v_{ij} \cdot Z_i \quad (4)$$

ここで、 Z_i は i 番目の勝者ニューロンの出力応答であり、一致値の大きさに応じて決められる。また、 v_{ij} は j 番目の補間層ニューロンと i 番目の勝者ニューロンを結合重みである。出力応答式は文献によりさまざまなものが示されているが¹³⁾¹⁴⁾、一致値が小さいほど大きく、またすべての勝者ニューロンからの出力応答の総和が1.0となるように決められる。

(3) 拡張SOMの提案

a) 提案の意義

後に例題で示すように、SOMの関数近似能力はきわめて高い。そして、これはSOMの近傍学習に負うところが大きいと思われる。しかし、前述のように、SOMには任意位置における補間値を直ちに求められないという重大な欠点がある。

一方、CPNでは類似したいくつかのパターンを明快なルールに基づいて結合し、容易に任意点の補間値を求めることができるが、入力パターンを相互に関連付ける近傍学習は行えない。また、これも後に例題で示すが、ボリングデータのように鉛直方向と水平方向のデータ密度が大きく異なる場合、CPNの補間精度は非常に低下する。

そこで、著者らはSOMの近傍学習の利点を生かしながら、CPNの補間アルゴリズムを取り入れ、両者の利点を組み合わせた拡張SOMを考案した。

また、神酒らの研究¹²⁾で提案されている自己組織化マ




図-6 評価関数

ップの内挿機能を利用した新しい補間アルゴリズムも近似精度を向上させるために、非常に有効な手法であると考えられるので、本論文で紹介する拡張SOMにはこれも取り入れることとした。

b) SOMの内挿機能を利用した補間アルゴリズム

拡張SOMについて説明する前に、神酒ら¹²⁾が提案している補間アルゴリズムを簡単に紹介する。

神酒らの工夫は3つの点からなっている。すなわち、①固定ニューロンと称する不動点を設けたこと、②本来入力ベクトル間を線形に補間することしかできないSOMを重みベクトルの更新に方向性を与える補正ベクトルを導入し、滑らかな補間を可能としたこと、そして③滑らかさを定義する評価関数を設定し、適正な学習回数を定めたこと、の3点である。

これらの工夫のうち、②の点については、正解が明確でない問題に対してどの程度の補正ベクトルを考慮すればよいのかその評価が難しく、扱い方によってはかえって補間精度を損なう可能性があるため、本論文ではこれは考えないこととした。

このアルゴリズムでは学習パターンと同数の固定ニューロン(図-5の●印)を設け、固定ニューロンの間に適当な数の中間ニューロンを挿入する。そして、固定ニューロンの初期重みベクトルは学習パターンの1つと同じとし、近傍領域の初期値は図-5に示すように隣接する固定ニューロンの一つ内側の範囲とする。こうすることで、固定ニューロンの重みベクトルは学習の過程において学習パターンの1つを保持したまま一度も更新されることがない。このことは、何らかの調査なり観測によって得られた情報である学習パターンを完全に信頼のおけるものと考えられることになる。

また、このアルゴリズムでは式(5)によって補間の滑らかさを定義している、

$$E = \sum_{j=2}^{m-1} \|d_j\|^2 = \sum_{j=2}^{m-1} \|u_{j-1} + u_{j+1} - 2u_j\|^2 \quad (5)$$

ここで、 E は評価関数、 m は競合層のニューロンの総数、 u_j はニューロン j の重みベクトル、 u_{j-1}, u_{j+1} はニューロン j の左右のニューロンの重みベクトルである。

式(5)の意味は図-6の d_j のようなベクトルの大きさの

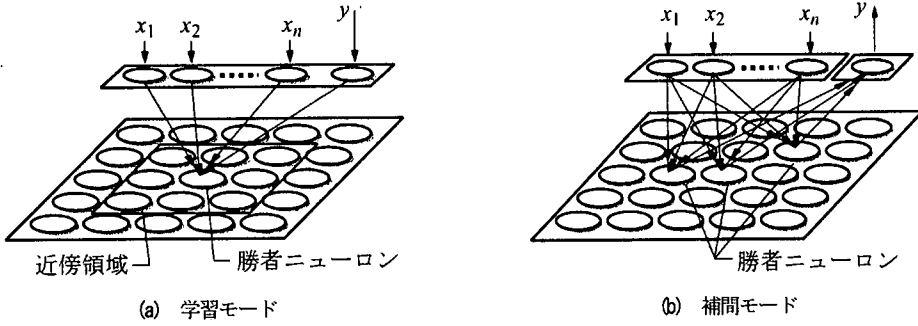


図-7 拡張SOMの信号の流れ

総和を計算することであり、これが最小になったとき、最も滑らかに補間されたことになる。

SOMで学習を長く繰り返すと、図-2 ⑥の操作により多くの重みベクトルが学習ベクトルと同じ値をとるようになる。SOMをパターン分類などの目的で用いるならば、これは問題にはならないが、本論文のように関数補間の目的で使用するときには、わずかな点でしか補間値が得られないことになり不都合な問題になる。従って、SOMの適正な学習回数を知ることは重要な問題となる。

なお、このアルゴリズムでは結合重みの更新を式(2)に代えて式(6)により行っている。

$$\Delta u_{ij} = \alpha_{(i)} \cdot \exp\left(-\frac{r_i^2}{G_{(i)}^2}\right) \cdot (x_j - u_{ij}) \quad (6)$$

ここで、 r_i はニューロン i と勝者ニューロンの距離、また、 $G_{(i)}$ は初期値が比較的大きく、学習の進行につれて次第に0に近づく値である。式(2)、式(6)はいずれもSOMで一般的に用いられているものである。

c) 拡張SOMの学習アルゴリズム

ここで提案する拡張SOMは入力層と競合層からなる2層構造であり、CPNと同様に学習モードと補間モードで異なった動作をするものとする。

入力ベクトルの次元を n とすれば、入力層には $n+1$ 個のニューロンを設ける。

学習モード(図-7(a))では入力ベクトル \mathbf{X} を入力層の1~ n 番目のニューロンに入力し、 $n+1$ 番目のニューロンには期待出力 y を入力する。そして、これらを一緒に学習する。

補間モード(図-7(b))においては、学習モードでは期待出力 y を入力していた $n+1$ 番目のニューロンが出力層に変化する。補間位置におけるベクトル \mathbf{X} を入力層の1~ n 番目のニューロンに入力し、式(1)の一致値が小さい順に N_{win} 個の勝者ニューロンを選択する。そして、式(7)を用いて入力ベクトルに対応した補間値 y' を得る。

$$y' = \sum_{i=1}^{N_{win}} u_{i,n+1} \cdot Z_i \quad (7)$$

ここで、 Z_i は i 番目の勝者ニューロンの出力応答であり、式(4)で用いたものと同じである。また、 $u_{i,n+1}$ は $n+1$ 番目の入力層ニューロンと i 番目の勝者ニューロンを結ぶ重みである。

3. 曲面補間問題による補間性能の検証

(1) 例題の概要

この章では、あらかじめ形がわかっている多項式の補間を行うことで、前章で説明したSOM、CPNおよび拡張SOMの補間性能の検証を行う。また、これらのアルゴリズムとの比較のため、NNとしては最も一般的に使用されているBP法による補間も行う。

例題とするのは式(8)に示す多項式である。

$$z = \frac{30000}{2(x-70)^2 + (y-70)^2 + 1000} + \frac{50000}{(x-20)^2 + 2(y-30)^2 + 2000} - 5 \quad (8)$$

この関数では、 $(x,y) = (25,30)$ および $(70,70)$ 付近にピークがあり、その間は鞍部になっている。図-8(a)は横軸を x 、縦軸を y とし、式(8)の z を等高線としてプロットしたものである。

検証のために2つのモデルを使用することとした。モデル①では補間領域内に均等に計測点が分布した状態を考え、 x および y 方向に10刻みに121(11×11)点のサンプル点を用意した(図-8(b)参照)。また、モデル②ではボーリング調査で得られるデータ分布を考慮し、 $x = 0, 30, 50, 70, 100$ の位置で y 方向に2刻みに255(5×51)点のサンプル点を用意した(図-8(c)参照)。


いずれのモデルでも x, y のそれぞれ5刻みに441(21×21)点を補間により求める。図-8(b)、(c)で○印はサン

表-1 学習パラメータ


アルゴリズム	パラメータ	行 ¹ ①	行 ¹ ②
B P 法	各層のニューロン数 ¹	2-10-1	2-10-1
	学習回数 ¹	5,000回	1,500回
SOM	各層のニューロン数 ²	入力層	3
		競合層	50×50
	初期 N_c^2	20	20
	初期 α^2	0.15	0.15
学習回数 ¹	500回	50回	
C P N	各層のニューロン数 ²	2-200-1	2-300-1
	初期 α^2	1.0	1.0
	学習回数 ¹	50回	50回
	補間モードにおける勝者ニューロン数 ¹	3個	3個
拡張 SOM	各層のニューロン数	入力層	2+1
		固定ニューロン	11×11
	中間ニューロン	¹ 3	
	初期 G	¹ 5	² 10
	初期 α	¹ 0.15	² 0.15
	予定学習回数	¹ 100回	² 500回
学習打ち切り回数	60回	270回	
補間モードにおける勝者ニューロン数 ¹	3個	3個	

*1 数種類の値で試算した上で決定したもの。


*2 経験的に定めたもの



(a) 例題の多項式



(b) モデル①のサンプル点



(c) モデル②のサンプル点

図-8 補間モデル

ル点を、そして×印は補間点を表している。

モデル①、およびモデル②の補間において各アルゴリズムで採用したパラメータを表-1に示している。拡張SOMにおける予定学習回数および打ち切り学習回数は、 i_{all} 回の学習を行うものとして学習しながら、式(5)の評価関数が最小となった1回で学習を打ち切ったことを意味している。式(6)の G および α の初期値については様々な組み合わせで試算を行った結果、 α の初期値は比較的小さい値(0.1~0.2程度)、 G の初期値は中間ニューロン数より大きくすれば良好な補間性能が得られることがわかっており、これらを配慮して決定したものである。また、補間モードにおける勝者ニューロン数も試算により2個では良好な補間性能が得られず、4個以上としても性能が3個の場合と比べて向上しないこともわかっていてる。

(2) モデル①の補間

各アルゴリズムにより補間を行った結果を図-9に示している。図-9(a), (c), (e), (g)は補間値の等高線図であり、図-9(b), (d), (f), (h)は補間誤差を示している。

2章でも述べたように、SOMだけでは任意点の補間値を求めることはできない。SOMによる補間結果を示した図-9(c), (d)は、SOMで得られたランダムな点の補間値に等高線図の作成に一般的に用いられている曲図-9(e)ではCPNの補間性能が他のアルゴリズムに比べて非常に劣っているように見えるが、図-9(f)の補間

誤差の分布を見ると、誤差は領域全体に分布しているものの大きな誤差はなく、案外正確に補間を行っていることがわかる。面の当てはめ手法¹⁷⁾を適用して格子点の補間値を求め、これを元に作成したものである。

曲面の当てはめ手法を適用する際に、曲面の柔軟さにかかわるいくつかのパラメータを決定する必要があり、パラメータによりかなり様相の異なる等高線図が出来上がることがある。そのような場合、補間精度に対するSOMと曲面当てはめ手法の関与の程度が分離できず、SOMの効果を明確に評価できない。しかし、この例題においては、曲面の当てはめ手法のパラメータをかなり変化させても出来上がった等高線図にはあまり差がなく、補間精度の良否はそのままSOMの補間性能の良否と考えることができる。

図-9(a), (c), (e), (g)の補間値の分布を見ると、CPNの場合に直線的で滑らかではない等高線となっているほかには際立った相違は見られない。CPNの学習アルゴリズムから、この例題のような場合、最も良く学習できたときには1つのニューロンがひとつの学習ベクトルを記憶することになる。その過程においてSOMの近傍学習の考え方がないので、他の学習ベクトルとの相互関係といった要素が入ってこないことになる。そのために、

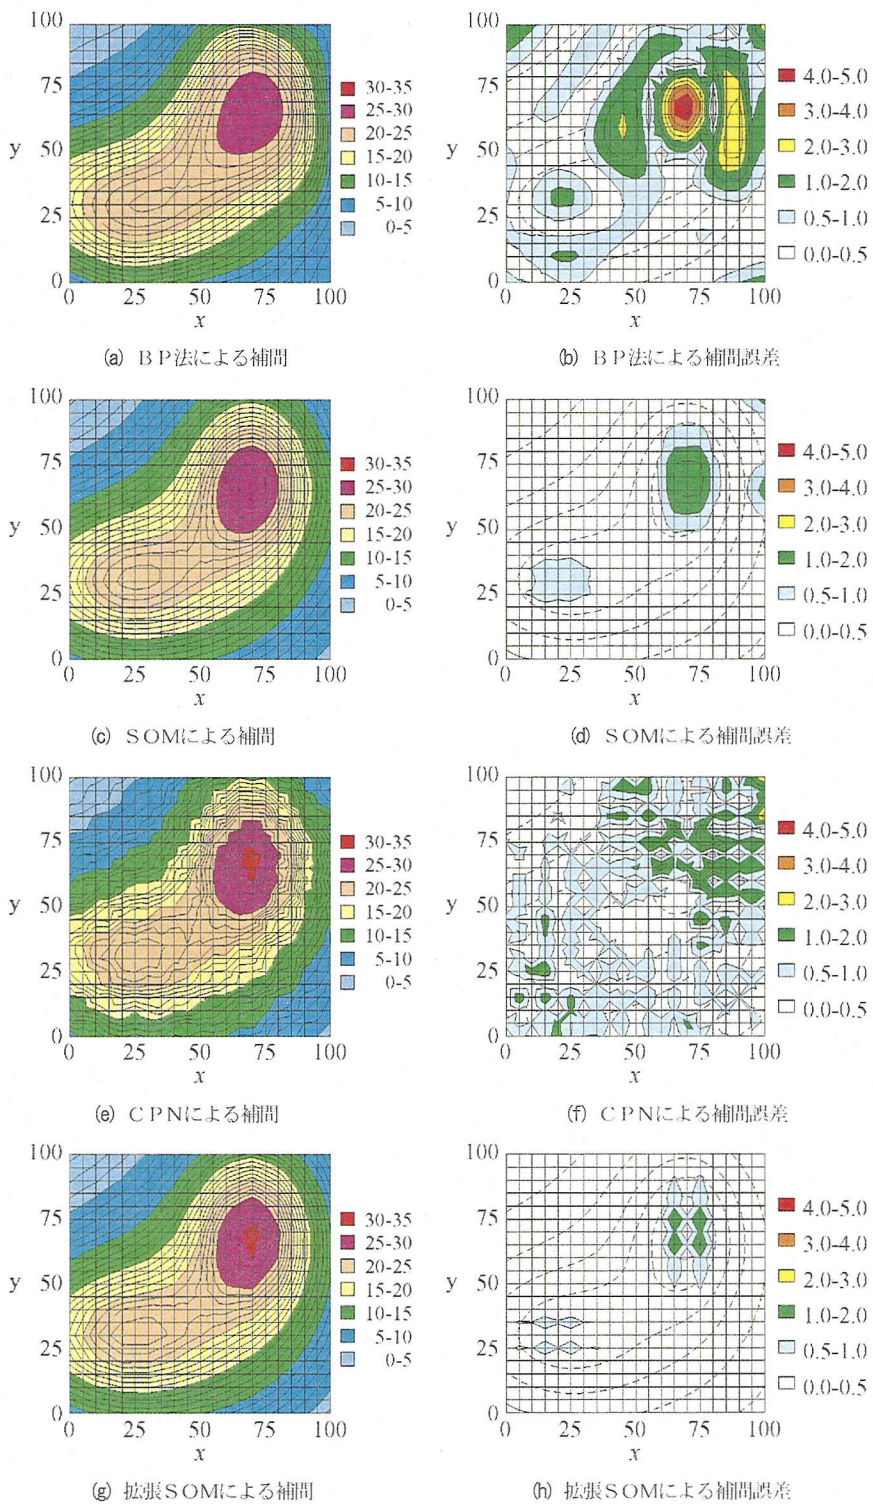





図-9 モデル①の補間



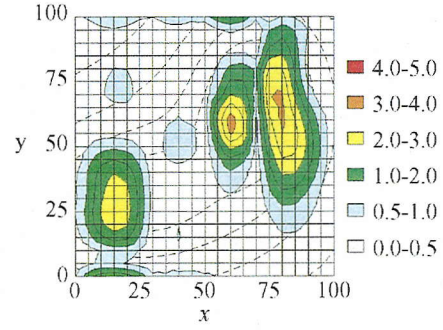
(a) BP法による補間



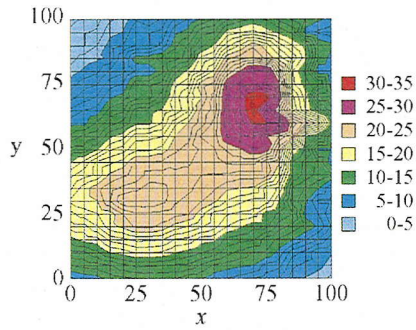
(b) BP法による補間誤差



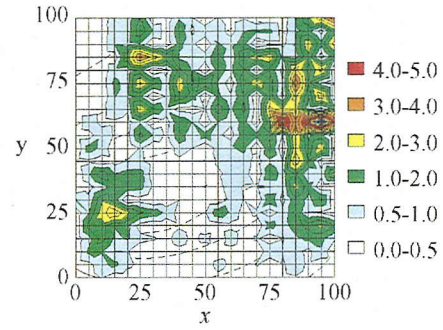
(c) SOMによる補間




(d) SOMによる補間誤差



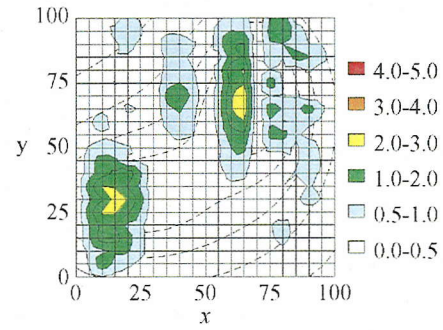
(e) CPNによる補間



(f) CPNによる補間誤差



(g) 拡張SOMによる補間



(h) 拡張SOMによる補間誤差

図-10 モデル②の補間

CPNでは図-9(e)のような滑らかでない等高線図が出来上がったものと考えられる。

その一方で、BP法の場合、図-9(a)ではきれいに補間できているように見えても、図-9(b)では右側のピーク周辺の誤差がかなり大きく、これで判断すると補間性能は4つのアルゴリズムのうちで最も劣っているといえる。

SOM、および拡張SOMでは補間誤差が0.5を超える領域が非常に小さく、正確な補間ができています。そして、この例題から拡張SOMの補間性能が最も優れていることは明らかである。

(3) モデル②の補間

モデル②では、モデル①と異なりサンプル点の分布に極端な偏りがある。そして、このような分布形態の問題にCPNを適用する際には2つの理由から工夫が必要となる。

まず、一番目は重みの初期設定の問題である。サンプル点は $x=0, 30, 50, 70, 100$ の位置にしかなく、 y 方向のデータ点の間隔は2である。従って、重みをランダムに領域全体に分布するように設定すると、近傍学習は行われないうので、競合層に多くのニューロンを配したとしても、その大半は使用されず、たまたま $x=0\sim 2, 28\sim 32, \dots, 98\sim 100$ にあるわずかなニューロンを奪い合って学習が行われることになる。

二番目は補間モードでの問題である。例えば、 $x=55$ の位置を補間しようとしたとき、勝者ニューロンの数をいくつにしたとしても、最も近い $x=50$ の位置にあるものばかりが選択されることになり、結局は y 方向にのみ補間したことにしかならない。

この問題は、学習ベクトルに適切なスケールを施すことである程度解決できる。サンプル点の間隔が x 方向には20または30であり、 y 方向には2であるから、 x を $0.067(=2/30)\sim 0.10(=2/20)$ 倍に圧縮して学習を行う。こうすることで、 x, y 両方向のサンプル点間隔を近づけることができる。

モデル②の補間結果を図-10に示す。図-10(e), (f)のCPNによる補間は中央部の補間精度の向上を優先して $x:y=0.1:1.0$ のスケールを行ったものである。

サンプル点の偏りが大きいため、モデル①のときより補間誤差が大きくなったものの、アルゴリズムによる補間の様子の特徴はモデル①の場合と同様である。すなわち、BP法での誤差は最も大きく、CPNでの補間図は滑らかではない。いずれもモデル①の場合に比べて誤差の増加が著しく、ことにCPNでの補間範囲の両端部の誤差の増大が著しい。

しかし、SOMおよび拡張SOMでは、モデル①に比べて極端な補間性能の低下は見られない。

(4) 例題によるアルゴリズムの比較

これまでに述べた3次元曲面の補間の例題から、補間性能に優れたアルゴリズムを順にあげると、拡張SOM、SOM、CPNおよびBP法の順位になると考えられる。

CPNとBP法のどちらが優れているかは単純には比較できない。BP法はこれまでに様々な問題に応用され、すでに多くの実績を持っている。実際、図-9および図-10でBP法だけを単独で見ると十分良好な補間ということもできる。しかし、学習に要する時間が長く、しかも誤差は4つのアルゴリズムのうちで最も大きい。

また、CPNの学習は短時間で行われ、誤差も小さい。さらに、類似したいいくつかのパターンを補間し、新たなパターンを見つけ出す過程は理論的に説明しやすい利点がある。一方で、結果を等高線図として示したとき、例題のような単純な問題でも、滑らかさに欠ける不自然な図が出来上がっていること、そして、サンプル点の分布が偏っている場合に、スケールだけでは対応しきれない場合が多く発生すると考えられることなどの欠点も持っている。

SOMは補間性能においては非常に優れていると思われるが、適切な学習回数が明確にわからないこと、そして、任意点の補間値が求まらないことに問題がある。適切な学習回数問題は神酒らの評価関数を導入することにより改善することができるが、任意点の補間値を求めるためには何か他の手法を併用するしか方法がない。

拡張SOMは関数補間問題にSOMを用いる場合の欠点を解決すべく考案したものであり、簡単で扱いやすく、精度高い補間を可能としたアルゴリズムであると確信している。

4. 拡張SOMによる地盤物性値分布の推定

(1) 例題の概要

実際の地盤物性値の分布推定を行う例題として、ダム立地地点の地質評価問題を扱うことにする。

例題として選んだダムサイトにおいては、ダム軸を中心として幅100m、長さ500mの範囲にわたって多くのボーリング調査(掘進長:100~300m)が実施されている。そして、これらから得た情報を元に地質、岩級区分、およびルジオン値の分布の推定が行われている。

本研究では、これらの物性値のうち遮水性の評価に直接的にかかわるルジオン値の分布状況の推定を行うものとする。入力データには X, Y 座標のみを使用する。また、出力はルジオン値であるが、ルジオン値の分布が0~4,600程度と幅広いいため、これの常用対数値を推定することとした。

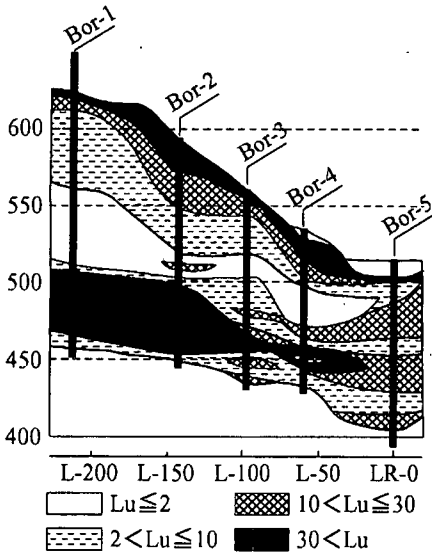


図-11 専門家によるルジオン値の推定分布図

表-2 データ数

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) ルジオン値の計測間隔は5mである。

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、5本分のボーリングデータを使用した。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オン値の分布推定図を図-11に、データの数量を表-2に示す。

標高450~500m付近のかなり深い位置に30ルジオ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ルジオン以下である。

(2) BP法を用いたルジオン値の分布推定

まえがきにおいて、BP法はこの種の問題には適さないと述べたが、拡張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。

図-12は学習の状況を見るために、横軸に実際のルジオン値を、縦軸には学習を終わったBPシステムを用いて推定したルジオン値をプロットしたものである。縦横軸はいずれも対数目盛となっている。

図-12の△は、X、Y座標だけを入力して学習したも




図-12 BP法の学習状態

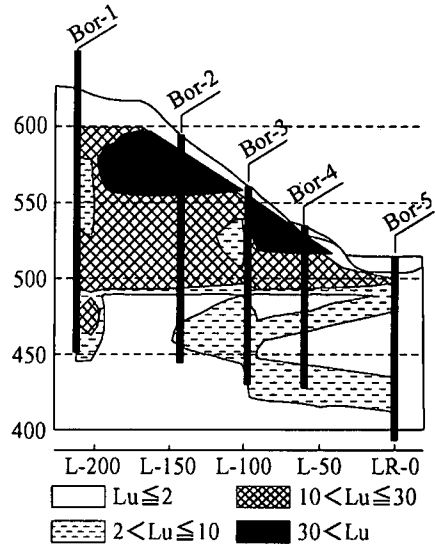


図-13 BP法によるルジオン値の分布推定図

のであるが、実際のルジオン値がいくらであろうと推定値はすべて10前後であり、全く学習ができていない。このときの入力、中間、出力の各層のニューロン数は2,2,1で、学習回数は10,000回である。中間層のニューロンをさらに増やしても全く改善されなかった。

情報を増やすために、座標値を百位、十位、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項目として学習したのが図-12の◆である。ネットワーク各層のニューロン数は6,5,1、そして、学習回数は10,000回である。学習の状況はいくらか改善されているが、まだ目標値である2ルジオン以下であるかどうかを判定できるような状態ではない。また、桁ごとに分解して入力データとした数値に工学的な意味があるのかという問題もある。

図-13は、縦横それぞれ10mのグリッド上のルジオン値を推定し、これをもとに作成した対象範囲のルジオン値の分布推定図である。専門家が推定した図-11とはかなり異なっていることがわかる。




図-14 評価関数の変化

(3) 拡張SOMを用いたルジオン値の分布推定

ルジオン値の推定に用いる拡張SOMでは 5×38 の固定ニューロンを設けた。X方向の固定ニューロン数はボーリングの数と同じとし、固定ニューロンの1列を1本のボーリングに割り付けた。

Y方向の固定ニューロン数はデータ数が最も多いBor-1にあわせたものである。前述したように拡張SOMでは1つの固定ニューロンの重みベクトルは1件の学習ベクトルと一致させる。しかし、学習データ数はボーリングごとに異なっているため、冗長なニューロンが発生することになるが、複数の固定ニューロンに1件の学習データを割り当てることでこの問題を解消した。各固定ニューロン間にはそれぞれ5個の中間ニューロンを挿入した。式(3)の学習率 α_0 および G_0 の初期値はそれぞれ0.15および8とした。これらのパラメータは3章における試算の結果を考慮して決定したものである。

予定学習回数を500回とし、X座標、Y座標およびルジオン値の常用対数値を入力して、学習を行いながら評価関数の変化を調べると図-14のようであった。評価関数の値が最小となる学習回数は280回である。

学習を280回で打ち切り、そのときのネットワークを用いてルジオン値の推定を行ったのが図-15である。補間を行う際の勝者ニューロンの数は3個とした。

深い位置に推定されている高ルジオン値の領域、地表面近くの様子などが良くとらえられている。

Bor-2付近の地表部では、専門家の推定に比べて高ルジオン値領域が深く推定されている。これは、この位置における計測データでは実際に高いルジオン値が観測されており、拡張SOMによる推定ではこの値を反映しているが、専門家は別にボアホールカメラによる観測を行い、その結果を踏まえて、観測値の一部を無視して分布推定を行っているために生じた相違である。




図-15 拡張SOMによるルジオン値の分布推定図

5. 結論

本論文において、著者らはSOMとCPNを組み合わせた新しいアルゴリズムである拡張SOMを提案した。そして、多項式の補間問題を通してその補間性能を客観的に評価した上で、このアルゴリズムをボーリングデータを用いたルジオン値の分布推定問題に応用し、良好な結果を得た。

本論文で提案したアルゴリズムは、地質区分や地盤の強度定数など他の地盤物性値の分布推定にも応用できる。また、このアルゴリズムは地盤問題に限らず、騒音や汚染の分布など曲面の補間問題としてとらえることができるさまざまな問題へも同様に応用が可能である。

このアルゴリズムを用いることで、現在までに得られている物性値から簡単に分布推定図を作成できるので、これを観察することにより追加調査を必要とする地点を抽出するなど、技術者の判断を支援するシステムとしても有効に活用できるものと考えられる。

著者らは現在、このアルゴリズムをGISに組み込み、既存のボーリングデータを有効に活用することを検討している。ただ、地質区分などの非数値データは、ルジオン値のような数値データと異なり、あらかじめ連続性を考慮して適正に数値化しておくことが必要である。このアルゴリズムをシステム化するに当たっては、この数値化の作業を自動化するアルゴリズムの考案、あるいは、ユーザーがパソコンの前で簡単に数値化できるユーザーインターフェースの設計が必要となる。

謝辞：鳥取大学工学部電気電子工学科の徳高教授，岸田助教ならびに藤村助手にはSOMに関してご指導をいただき，また，九州工業大学情報工学部制御システム工学科の山川教授および神酒助手の論文に接し，著者らの研究の方向に誤りがないことを確信するとともに，たいへん有意義なアイデアを多数いただいた。諸先生方に深く感謝の意を表します。

参考文献

- 1) 戸井田克, 升元一彦, 日比谷啓介: 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) 白木渡, 恒国光義, 松島学, 安田登: 地盤物性値間の回帰関係を利用したコクリッキ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) 水野勝教, 後藤泰之, 一柳勝広, 横水康伸, 松村年郎, 鬼頭幸生: 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, Vol.6th, No.2, pp.119-120, 1995.
- 4) 山本広祐, J. H. GARRET, JR, 斎藤潔: ニューラルネットワークを用いた座屈波形の可視化, 構造工学論文集, Vol.43A, pp.55-64, 1997.3.
- 5) 伊藤則夫, 白木渡, 安田登, 上田茂: 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.
- 6) 安田登, 松島学, 安田武, 飯島健: 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.
- 7) T.Kohonen著, 徳高平蔵, 岸田悟, 藤村喜久郎: 自己組織化マップ, シュプリンガーフェアラーク東京, 1996.5.
- 8) 近田康夫, 広瀬智士, 城戸隆良: 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) 窪野哲光: 自己組織マップ型情報検索インターフェースの検討, 第15回ファジーシステムシンポジウム講演論文集, 327-339, 1999.6.
- 10) 白木渡, 長瀬裕俊, 宮下英明, 伊藤則夫: 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.
- 11) 佐川泰広, 倉田耕治: 改良型コホネンマップの関数近似への応用, 電子情報通信学会技術報告書, NC95-45, p.127, 1995.
- 12) 神酒勤, 大迫洋平, 山川烈: 自己組織化マップの内挿機能を利用した新しい補間アルゴリズムの提案, 第15回ファジーシステムシンポジウム講演論文集, 311-314, 1999.6.
- 13) R.ヘクト・ニールセン著, 袋谷賢吉: ニューロコンピューティング, トップラン, 1992.8.
- 14) Leung, A. and Payandeh, S.: Application of adaptive neural network to localization of objects using pressure array transducer, Robotica, Vol.14, No.4, pp.407-414, 1996.
- 15) Hojjat Adeli and Hyo Seon Park: Neurocomputing for Design Automation, CRC Press, 1998.
- 16) 伊藤則夫, 白木渡, 安田登: 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, 構造工学論文集, Vol.45A, pp.487-492, 1999.3.
- 17) 塩野清治, 升本眞二, 弘原海清: BASICによるコンターマップII応用編, 共立出版, 1988.11.

(1999.11. 8 受付)

AN APPLICATION OF SELF-ORGANIZING FEATURE MAP TO SPATIAL ESTIMATION PROBLEM FOR GEOTECHNICAL CHARACTERIZATION

Norio ITOU, Wataru SHIRAKI and Noboru YASUDA

For design and construction of structures, it is required to get various geotechnical data on foundation. Generally, investigations using boring are done, and geotechnical characterizations of foundation are obtained at boring spots. As the number of boring is restricted for reasons cost and time, it is very hard to estimate the spatial distribution of geotechnical characterizations using such a few of boring data. Various spatial estimation techniques have been developed and examined. However, no efficient and convenient one has been developed. In this study, an efficient and convenient spatial estimation method is proposed using a new algorithm improved the SOM. The efficiency is shown by an example such that this proposed method is applied to a spatial estimation of permeability of bedrock.