

(4) 斜面崩壊予測システムへのSOM・CPNの応用

AN APPLICATION OF SOM AND CPN TO SLOPE FAILURE ESTIMATION SYSTEM

伊藤則夫*・白木渡**

Norio ITOU and Wataru SHIRAKI

*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)

**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)

In this paper, two estimation systems of earth slope failure using SOM (Self-Organizing Feature Map) are proposed. One is a system combining a two-dimensional SOM with a three-layered neural network, another one is a system using CPN (Counter Propagation Network). For 342 earth slope failure data the rainfall cumulated until slope failure and the failure distance from the top of slope are estimated, and then the effectiveness of proposed systems is demonstrated.

*Key Words : Self-organizing feature map, Counter propagation network
Slope failure estimation system*

1. まえがき

斜面崩壊の予測は、危険範囲や避難時期の決定、および対策工の計画を行うにあたって重要である。斜面崩壊予測問題では、時期、場所、規模の3つの要素を考える必要がある。

著者らは、これまでニューラルネットワーク手法を用いてこのような3つの斜面崩壊要素のうち、規模の予測を行うシステムを開発した¹⁾²⁾。当初の研究では誤差逆伝搬法(BP法)のみに頼って崩壊規模の尺度である崩土到達距離の予測を試みたが¹⁾、この方法では満足できる予測精度を得ることができなかった。続いて、自己組織化特徴マップ³⁾(Self Organizing Feature Map, 以下SOMと呼ぶ)を用いて、評価対象となる斜面に類似した過去の崩壊事例を抽出し、これらの斜面データのみを学習することにより、BP法による予測精度の向上を図る研究を行った²⁾。SOMを用いて学習データを選択することにより、BP法による予測精度はかなり向上したが、この方法にはある斜面の崩壊を予測しようとしたとき、非常に煩雑な手順を要するという欠点が残されていた。

そこで、本研究では予測手順を簡素化することを目的として、SOMを用いた別法を提案する。また、本研究ではCPNを用いた斜面崩壊予測システムについても合わせて検討を行う。

CPNとは、コホーネンの競合学習とグロスバーク学習を組み合わせたカウンタープロパゲーションネットワーク(Counter Propagation Network)⁴⁾と呼ばれるもので、関数近似、パターン分類問題に適していると言われるアルゴリズムであり、過去の類似した崩壊事例を用いて未知の斜面の崩壊を予測しようとする本研究のような

問題には有効な手法ではないかと考えられる。

CPN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⁵⁾、また構造物の最適設計への応用⁶⁾などが報告されている。

2. ニューラルネットワークの基礎理論

2.1 SOMの基礎理論

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り、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-1参照)。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、パターン分類・パターン認識が得意とされているアルゴリズムである。

SOMの学習の特徴として、競合に勝利したニューロンが学習する競合学習、および勝者ニューロン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。

SOMの学習アルゴリズムをまとめると次の通りである。




図-1 SOMの基本構造

- ① 入力層と競合層を結ぶ結合重みを適当な値で初期化する。
- ② 入力層に入力ベクトル $\mathbf{X}$ を設定する。
- ③ 入力ベクトル $\mathbf{X}$ と競合層のニューロン i への重みベクトル $\mathbf{U}_i$ の一致値 $|\mathbf{X}-\mathbf{U}_i|$ を式(1)で計算する。

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

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 の結合重みである。

- 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 $\mathbf{X}$ 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。
- ⑤ 勝者ニューロンの回りに近傍領域と呼ばれる領域を設定する。そして、近傍領域に含まれるニューロンに対して式(2)で重みベクトルの更新を行う。

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

ここで、 Δu_{ij} は結合重み u_{ij} の更新量、 $\alpha_{(t)}$ 、 $N_{c(t)}$ は学習回数 t における学習率、および勝者ニューロンの回りに設定された近傍領域である。近傍領域の初期値および学習率の初期値に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り、最終的には0に近づくように設定する。

- ⑥ 各入力ベクトルに対して②～⑤を繰り返す。

学習手順の④に示した処理が競合学習であり、⑤が近傍学習と呼ばれるものである。

2.2 CPNの基礎理論

(1) CPNの概要

CPNは1986年にヘクト・ニールセンにより提唱された教師付き学習法である⁴⁾。CPNは図-2に示すように入力層、競合層、および補間層の3層からなるネットワークである。CPNでは、あるパターンが入力されると、記憶しているパターンの中から入力パターンに類似したものをいくつかを選び出し、これらを合成した新しいパターンを作り出すことができる。




図-2 CPNの基本構造

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した出力ベクトルを得るステップで異なっており、前者を学習モード、後者を補間モードと呼んでいる。

(2) 学習モード

学習は2つのステップによって行われ、最初のステップでは入力層～競合層の結合重みベクトルが、そして2番目のステップで補間層～競合層の結合重みベクトルが学習される。学習モードにおけるCPNの学習アルゴリズムをまとめると次のようである。

- ① すべての結合重みを初期化する。
- ② 入力ベクトル $\mathbf{X}$ を入力層に提示する。
- ③ 競合層ニューロンとの一致値を式(1)で計算し、一致値が最も低いニューロンを1つだけ選択し、これを勝者ニューロンとする。
- ④ 式(3)により入力層と競合層の間の結合重みを更新する。なお、記号は式(2)と同様である。

$$\Delta u_{ij} = \begin{cases} \alpha_{(t)} \{x_j - u_{ij}\} & \text{勝者ニューロン} \\ 0 & \text{その他} \end{cases} \quad (3)$$

- ⑤ ②～④を繰り返す。
- ⑥ 入力ベクトルを入力層に提示し、勝者ニューロンを選択する。
- ⑦ 教師ベクトル $\mathbf{Y}$ を補間層に提示し、式(4)により補間層と競合層の間の結合重みを更新する。

$$\Delta v_{ij} = \begin{cases} \alpha_{(t)} \{y_j - v_{ij}\} & \text{勝者ニューロン} \\ 0 & \text{その他} \end{cases} \quad (4)$$

ここで、 Δv_{ij} は補間層と競合層の結合重み v_{ij} の更新量、 $\alpha_{(t)}$ は学習回数 t における学習率である。

- ⑧ ⑥、⑦を繰り返す。

ここで、①～⑤の手順は近傍学習を行わない場合は、SOMと全く同じである。

(3) 補間モード

補間モードにおいても、学習モードと同様に入力ベクトルを入力層に提示し、式(1)で競合層のすべてのニューロンとの一致値を計算する。そして、一致値の小さいものを勝者ニューロンとするが、補間モードでは学習モードと異なり、一致値が小さい順に1つ以上の勝者ニューロンを選択することができる。勝者ニューロンをいくつ選択するのかは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 $\mathbf{Y}' = \{y'_1, y'_2, \dots, y'_m\}$ は式(5)で求める。

$$y'_j = \sum_{i=1}^{N_{win}} v_{ij} \cdot Z_i \quad (5)$$

表-1 入力データ

斜面の種類	1	自然斜面, 人工斜面
斜面型	横断方向	2 大きな尾根部, 大きな谷部, 山腹の小さな尾根部, 山腹の小さな谷部, 平行な山腹
	縦断方向	3 上昇型(凸型), 下降型(凹型), 直線型, 複合型(S型), 複合型(逆S型)
斜面の上端	状態	4 尾根, 台地, 凹地, その他
	利用状況	5 水路又は沢, 道路, 池, 沼, 家, 田畑, 山林, その他
斜面の下端	状態	6 平地, 上昇直線型, 下降直線型, 上昇凸型, 上昇曲線型, 上昇S線型, 上昇階段型
	傾斜角	7 傾斜角(度)
斜面の角度	8	平均傾斜角(度)
	9	崩壊頭部までの角度(度)
斜面高	10	斜面高(m)
地質の情報	表層	11 粘土, 砂, 黒土, 礫, 岩塊, 腐植土, その他
	表層厚	12 表層厚(m)
	基岩	13 噴出岩類, 深成岩類, 火山砕屑物, 水性堆積岩類, 変成岩類, シラス, ローム, その他
地被物の状態	種類	14 裸地, 草地, 竹, 針葉樹, 広葉樹, 針広混合, その他
	密度	14 疎, 中, 密
過去の崩壊の有無	同一箇所	16 回数を数値入力
	付近	17 回数を数値入力
水の存否	地表水	18 有, 無
	湧水	19 有, 無

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(1)の一致値 d_i の大きさに応じて決められる. 出力応答は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. 出力応答式には S_w を勝者ニューロンの集合として式(6)のようなものがある.

$$z_i = \begin{cases} 1.0 & i \in S_w (N_{win} = 1 \text{ or } d_{i \min} = 0) \\ \frac{1/d_i}{\sum_{j=1}^{N_{win}} 1/d_j} & i \in S_w (N_{win} > 1) \\ 0.0 & i \notin S_w \end{cases} \quad (6)$$

① SOM を用いて全国の斜面崩壊データを 18×18 の2次元のマップ上に配列する

② 予測したい斜面のデータをマップに提示し, 反応したセルおよびその周囲の9つのセルを占める斜面を類似斜面として選択する

③ 9つの斜面データを学習してBPシステムを構築する

④ BPシステムを用いて崩壊時の連続雨量, 崩土到達距離を予測する

図-3 手法Iにおける斜面崩壊予測のフロー

3. 入力データ

本研究では, 建設省土木研究所砂防部傾斜地崩壊研究室資料「がけ崩れの災害実態について(昭和50年~52年)」⁷⁾の中から全国358地域の豪雨により崩壊した事例を用いている. これまでの研究²⁾では, これらの事例のうちデータが欠落なく整っているものを抽出し, 342カ所(学習用309カ所, 検証用33ヶ所)のデータを用いている. 本研究でも同じデータを使用するが, 一部のデータが失われており, 使用できるデータは332カ所(学習用301カ所, 検証用31ヶ所)であった.

システムの入力項目は, 斜面の地形, 地質, 植生, 土地の利用状況などで, 表-1に示す19項目を考える. 斜面崩壊の誘因として降雨の影響は, 無視する事ができない. しかし実際に予測する場合には, 降雨のように短時間で変化するような項目を入力することは, 難しい作業になるので, 入力項目から省いた.

また, システムの出力には崩壊の場所・時期の予測にあたる斜面崩壊時までの連続雨量(mm), および規模の予測にあたる崩土到達距離(m)を選んだ.

4. これまでの研究におけるSOMの利用方法

これまでの研究²⁾における斜面崩壊予測のフローを図-3に示す. この手法を, 以後手法Iと呼ぶ. 複数の斜面について予測を行う際には, ②~④の作業を繰り返すことになる.

図-4はBP法のみを用いて崩土到達距離の予測を行ったものである. また, 図-5, 図-6, は手法Iにより崩壊時までの連続雨量および崩土到達距離の予測を行ったものである. BP法のみでは正しい予測がなされていないの




図-4 BP法のみを用いた崩土到達距離の予測

に対して、手法ⅠではSOMを用いて学習データを選択したことにより予測精度がかなり向上していることがわかる。

連続雨量の予測誤差は最大誤差が 258.2mm、最小誤差が 1.5mm、そして平均誤差は 74.9mm であった。また、崩土到達距離については最大誤差が 35.0 m、最小誤差が 0.04 m、そして平均誤差は 7.3 m であった。

手法Ⅰの煩雑さは、手順③で予測対象斜面1つずつについてBPシステムを構築しなおさねばならない点にある。あらかじめ必要なBPシステムを構築しておけばよいのだが、そのためには $(18 \times 18) = 324$ ものBPシステムを構築する必要がある。そして、新しいデータが追加されるたびにこの作業が必要となる。

5. SOMを用いる別法

過去の崩壊事例をあらかじめいくつかのグループに分けておくことができれば、手法Ⅰの問題点を解消することができる。本来、SOMは類似したパターン同士を近くに配置し、これを観察することによってグループに分類可能であるといわれているが、著者らがこれまでにやってきた研究の中では、2次元のマップを観察してグループの境界線を見出すことは困難であった。

そこで、クラスタリングの手段としてSOMの競合学習を利用して学習データを分類し、それぞれのクラスタごとにBPシステムを構築しておき、これを用いて斜面崩壊を予測することを考えた。この方法を、以後手法Ⅱ




図-5 手法Ⅰによる連続雨量の予測




図-6 手法Ⅰによる崩土到達距離の予測

と呼ぶ。この方法による斜面崩壊予測のフローを図-7に示す。複数の斜面について予測を行う際には、図-7の③、④を繰り返せばよい。

入力項目を表-1の19項目から斜面の種類を除いた18項目として競合学習を行った。入力項目から斜面の種類を除いたのは崩壊事例の大半が自然斜面におけるものであったためである。学習を行う際には近傍領域は設けず、学習時の結合重みの更新は勝者ニューロンに対してのみ

表-2 各クラスタ中のデータ数

	学習 データ	検証 データ		学習 データ	検証 データ		学習 データ	検証 データ
1	22	2	14	10	1	27	4	1
2	21	5	15	10	3	28	3	0
3	19	1	16	9	0	29	2	0
4	19	2	17	8	1	30	3	0
5	15	1	18	7	0	31	2	0
6	14	1	19	7	0	32	2	0
7	13	2	20	6	0	33	2	0
8	12	3	21	6	1	34	1	0
9	12	1	22	5	1	35	1	0
10	12	0	23	5	1	36	1	0
11	11	1	24	5	1	37	1	0
12	11	1	25	5	0			
13	11	1	26	4	0	計	301	31

図-7 手法Ⅱにおける斜面崩壊予測のフロー

表-3 崩土到達距離と各入力項目の相関係数（一部）

		全 体	SOMによるクラスタ			
			①	②	③	④
斜面型	横方向	-0.07	-0.33	-0.03	0.46	0.03
	縦方向	-0.05	-0.20	-0.27	0.32	0.00
斜面上端	状態	-0.11	0.09	-0.03	-0.34	-0.06
	利用状況	0.02	-0.03	-0.02	0.22	-0.18
斜面下端	状態	-0.02	---	---	---	0.09
	傾斜角	0.07	-0.06	---	---	0.56
斜面角度	平均傾斜角	-0.03	-0.18	0.30	-0.32	-0.16
	崩壊頭部との角度	-0.09	-0.35	0.23	-0.22	-0.41
斜面高		0.05	-0.28	-0.17	-0.02	0.17
地質	表層の種類	0.05	0.06	-0.09	0.28	-0.11
	表層厚	0.21	0.43	0.26	0.43	0.50
	基岩	0.09	-0.07	-0.40	0.03	0.20
地被物	種類	-0.04	-0.45	-0.27	0.32	0.07
	密度	0.04	-0.30	-0.16	-0.67	0.17
過去の崩壊	同一箇所	-0.07	-0.13	---	0.11	-0.34
	付近	0.05	-0.10	0.14	0.17	0.33
水	地表水(崩壊前のみ)	0.01	---	---	---	---
	湧水(崩壊前のみ)	0.05	---	---	---	---

行った。

競合層に 100 個のニューロンを配して学習を行った結果、301 の崩壊事例を 37 のクラスタに分類することができた。分類された各クラスタ中のデータ数は表-2のようになっている。

また、それぞれのクラスタ内で入力項目と崩壊時までの連続雨量の相関関係を調べると表-3のようになっている。表-3で横線が引いてある項目はクラスタ内の全データがすべて同じ値となったものであり、塗りつぶしているのは相関係数が 0.4 以上のものである。

301 件のすべてのデータを用いた場合には、相関係数が最も大きいものでも表層厚の 0.21 で完全な無相関といえる状態であったが、SOMで分類したことによりいくらか相関関係が見える状態になっている。

学習データのうち水に関するデータは有無を表す 2 値であり、無しが 70%~75%を占めている。データの分布は均等とはいえないが、すべてのクラスタで完全に同じ値になっており、このような 2 値データが分類を決定する大きな要素となっているのではないかと考えられる。

それぞれのクラスタごとにBPシステムを構築するが、このときクラスタ内のデータセットのすべてで同じ値となっているデータ項目は入力から除外した。従って、表-3のクラスタ①では入力層のニューロンは 15 個、クラスタ②では 13 個となる。中間層のニューロンはいずれも 2 個とした。また、雨量の予測と崩土到達距離の予測はそれぞれ別のシステムを用いることとして、出力層のニューロンは 1 個である。学習回数はいずれも 5,000 回である。

このBPシステムを用いて連続雨量および崩土到達距離を予測すると図-8、図-9のようになった。




図-8 手法Ⅱによる連続雨量の予測




図-9 手法Ⅱによる崩土到達距離の予測

連続雨量予測の最大誤差は 250.0mm, 最小誤差は 2.5mm, そして、平均誤差は 98.3mmであった。また、崩土到達距離の予測では最大誤差が 14.7 m, 最小誤差が 0.6 m, そして平均誤差は 4.9 mであった。連続雨量の予測では手法Ⅰにやや劣るものの、ほぼ同程度の精度を維持できており、崩土到達距離の予測では手法Ⅰよりも精度は向上している。

6. CPNを用いた斜面の崩壊予測

手法Ⅱの手順①で行った操作は、実は、CPNの入力～競合層間の学習とまったく同じものである。従って、もし競合～補間層間の働きがBP法と同等の能力を持つならば、CPNを用いることにより斜面崩壊の予測手順は手法Ⅰ、Ⅱよりさらに単純になる。CPNを用いる方法を手法Ⅲとする。

多くの学習パターンを、より少ないパターンに整理・統合して記憶できることはCPNの優れた能力の1つである。しかし、本研究では競合層には学習パターンと同数である 301 個のニューロンを設け、学習ベクトルと重みベクトルを等しくすることにより、得られている事例をすべて記憶することとした。入力項目は手法Ⅱと同じく 18 項目であり、補間層には連続雨量および崩土到達距離に対応する 2 つのニューロンを設けた。また、検証データにより崩壊予測を行う際の勝者ニューロン数は 3 個とした。




図-10 手法Ⅲによる連続雨量の予測




図-11 手法Ⅲによる崩土到達距離の予測

手法Ⅲによる連続雨量および崩土到達距離の予測を図-10、図-11に示す。連続雨量予測の最大誤差は163.1mm、最小誤差は2.3mm、そして、平均誤差は74.9mmであった。また、崩土到達距離の予測では最大誤差が14.5m、最小誤差が0.0m、そして平均誤差は4.1mであった。最大雨量予測では3つの手法のうちで最も優れており、崩土到達距離では手法Ⅱと同程度の性能を有している。

7. まとめ

手法Ⅰ～Ⅲによる予測誤差を表-4にまとめている。崩壊時までの連続雨量の予測では、最小誤差は手法Ⅰが最も小さいが、その他の指標では手法Ⅲによる予測精度が最も高い。手法Ⅱは手法Ⅰと同程度か、むしろやや劣っている。崩土到達距離の予測でも最も精度が低いのは手法Ⅰであり、精度が高いのは手法Ⅲであった。手法Ⅱは手法Ⅲと同程度といえることができる。

結局、手法Ⅰ～Ⅲで最も簡素な手順で、かつ精度高い予測ができたのはCPNを用いる手法Ⅲであった。しかし、この方法では崩壊事例のすべてをそのままに記憶しており、崩壊事例が増加する将来を考えると、さらに改善の余地があるといえる。

また、表-3でわかるようにSOMを用いてデータを分類したことで無相関と思われた入出力間の関係が明らかになった。著者らはこれまで、SOMの応用に関する研究を行うとき安易に多次元のSOMを用いて、結果としてグループの境界線を見出すことに難しさを感じてきた。本研究で使用したのは、いわば無次元のSOMであるが、これによって簡単にデータを分類することができた。

いきなり多次元のSOMを用いるのではなく、まず、無次元のSOMによってグループを明確に把握し、その上でデータを多次元のSOMに投影してグループ同士の関係を調べることで、SOMからさらに多くの情報を引き出せる可能性がある。そして、このことは、項目間の関係が不明瞭なデータの分析全般に対して、SOMが強力なツールとなり得ることを示している。

表-4 各手法による予測誤差

		手法Ⅰ	手法Ⅱ	手法Ⅲ
崩壊時までの連続雨量 (mm)	最大誤差	258.2	250.0	163.1
	最小誤差	1.53	2.54	2.25
	平均誤差	74.9	98.3	74.9
	標準偏差	62.9	66.5	42.5
崩土到達距離 (m)	最大誤差	35.0	14.7	14.5
	最小誤差	0.04	0.56	0.00
	平均誤差	7.3	4.9	4.1
	標準偏差	7.7	4.3	3.5

参考文献

- 1) 白木 渡・松保 重之：ニューラルネットワークによる斜面崩壊予測システムの開発,JCOSSAR'95 論文集,Vol.3,1995.
- 2) 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,1998,3.
- 3) T.コホーネン著,徳高平蔵・岸田悟・藤村喜久朗：自己組織化マップ,シュプリング-フェアラーク東京,1996,5.
- 4) 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,トッパン,1992,8.
- 5) Leung A, Payandeh S; Application of adaptive neural network to localization of objects using pressure array transducer, Robotica, Vol.14, No.4 pp.407-414 1996.
- 6) Hojjat Adeli, Hyo Seon Park: Neurocomputing for Design Automation, CRC Press 1998.
- 7) 建設省河川局砂防部傾斜地保全課, 建設省土木研究所砂防部急傾斜地崩壊研究室：がけ崩れ災害実態について(昭和50年～52年), 1978.