

自己組織化特徴マップ (SOM) による斜面崩壊予測システム

ESTIMATION SYSTEM OF EARTH SLOPE FAILURE
USING SELF-ORGANIZING FEATURE MAP (SOM)

白木渡*・長瀬裕俊**・宮下英明***・伊藤則夫****

Wataru SHIRAKI, Yasutoshi NAGASE, Hideaki MIYASHITA and Norio ITO

*工博 鳥取大学助教授 工学部土木工学科 (〒680 鳥取市湖山町南4丁目101)

**松尾橋梁(株) (〒551 大阪市大正区鶴見町3丁目4番18)

***鳥取大学大学院生 工学研究科土木工学専攻 (〒680 鳥取市湖山町南4丁目101)

****(有)シー・エー・イー 代表取締役 (〒680 鳥取県岩美郡国府町分上2丁目210)

In this study, two layered neural network system which estimate the cumulative rain-fall until the time of failure of slope and the failure distance (from the top of slope) are developed in combination with the self-organizing feature map (SOM) proposed by Kohonen. In construction of these systems, a two-dimensional feature map is used to analyze the complex data sets with multiple data items such as slope angle, slope height, depth of cover-layer, soil classification, etc. which are obtained in 309 areas in Japan. In numerical examples, the effectiveness of systems developed in this study is demonstrated by estimating the cumulative rain-fall and failure distance for 33 failure slopes which are not trained by the neural network systems. Furthermore, the influence of the depth of cover-layer on the failure distance is investigated by using the method of sensitivity analysis of neural network.

Key Words: earth slope failure, self-organizing feature map (SOM), layered neural network, cumulative rain-fall, failure distance of slope, sensitivity analysis

1. まえがき

斜面崩壊を予測するとき、斜面崩壊がいつ(時期)、どこで(場所)、どれくらい(規模)で発生するか、という3つの問題が重要である。この中で、1番目および2番目の斜面崩壊の時期および場所の予測問題は、事故を防ぐための車両等の走行規制や危険箇所から避難する時期および場所の決定、また緊急避難警告を発令する時期および区域を決定する時に必要となってくる。3番目の斜面崩壊の規模予測は、ある斜面が崩壊する可能性が高いとわかった時に、今住んでいる住居や、交通機関、構造物等まで崩土がやってくるのかどうかを決定する時に必要となってくる。

著者らの研究グループでは、これまでも階層型ニューラルネットワーク(NN)の誤差逆伝搬法(Back Propagation (BP))¹⁾を用いて比較的簡単な調査だけで斜面崩壊の規模を推定するシステムを開発してきた²⁾。この研究では、全国358箇所のうち使用可能な342箇所の斜面崩壊データを利用し、過去の崩壊事例から将来の予測に活用するシステムの開発を目指した。しかし、この斜面崩壊データは、データの特性にばらつきが大きいため、単純にBPを用いるだけで学習を行うことは不可能であった。そこで、斜面データを地形や地質学的に分類し、そのグループごとにBPを利用して予測するシステムを開発した。このように分類して求めようとすると、比較的データが多いグループでは、精度のよい結果が得られたが、データの少ないグループでは十分な精度を有する結果が得られなかった。

本研究では、斜面データの分類する過程にコホーネンの自己組織化特徴マップ³⁾(Self-Organizing Feature Map (SOM))を用いることにより、専門的知識がなくても機械的操作だけで、斜面崩壊時の降雨量と、崩土到達距離を予測できるようにすることを考える。さらに、BPにSOMを併用することにより、精度の向上を考えたシステムの開発を行う。

2. コホーネンの自己組織化特徴マップ(SOM)

2.1 SOMの特徴

SOMは出力データを必要としない教師なし学習アルゴリズムである。これは、データの出力値がどの分類に属するかは与える必要がなく、データ中の隠れた特徴を抜き出して自動的に学習が行える点にある。また、何十次元ものデータの類似性を見つけだし、似たもの同士を2次元平面(マップ)上の近くに配置するという特徴がある。本来はこれらの特徴を利用してデータの分類に用いられる。

SOMは図-1のように入力層とマップ層がある2層構造ネットワークである。入力層のニューロンとマップ層のニューロンは、全てつながっているが、同じ層のニューロン間には結合はない。マップ層には、2次元平面(マップ)に配置され、入力されたデータはマップ層へ配置付けが行われる。学習時にどこに分類するかを入力する必要がないため、入力データの分類状態を素直に反映したマップ(入力データの元の空間における順序性、類似性などを保存した




図-1 コホーネンの自己組織化特徴マップ (SOM)

マップ)をつくることができる。

データの特徴をとらえてデータの分析を行う統計的手法として従来からよく利用されているとして主成分分析法等があるが、ここで取り上げている自己組織化ニューラルネットワークにPCA (Principal-Component Analyzer) 型学習則³⁾を適用すれば主成分分析を行う自己組織化ニューラルネットワークが構築できる。このネットワークを用いて色彩における感性構造分析を行っている例もある⁴⁾。

このように、自己組織化ニューラルネットワークは、目的に応じてデータの分析が可能で、データマイニングの方法としても注目されている。

SOMの特徴としては、以下に示すものがある。

- (1) 高次元入力ベクトルの任意次元表示(本研究では、2次元表示を使用)への非線形マッピングが可能である。
- (2) 未知(未学習)データへの分類が可能である。
- (3) 時間的、空間的に異なる特徴を有するデータの分類が可能である。

これらの特徴は、従来の統計的分類法にはないものである。

本研究では、階層型ニューラルネットワークで用いるデータの前処理としてSOMを用いることを提案する。つまり、このマップを利用することにより、予測の妨げとなるような悪いデータを取り除くことを考える。さらに予測データに特徴の似たデータと異なるデータを別々に分類して汎化能力を高めることを考える。

2.2 SOMのアルゴリズム

SOMの学習アルゴリズムでは、競合に勝ち残ったニューロンだけでなく、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われるのが特徴である。SOMの学習則を簡単にまとめると、次の通りである。

- ① 入力層と競合層とを関連づける重みを重みベクトルとして、その初期値を乱数で設定する。
- ② 入力層に入力ベクトル X を設定する。
- ③ 入力ベクトル X とニューロン j の重みベクトル W_j との距離 D_j を計算する。

表-1 斜面の番号と地域

斜面の番号	都道府県	検証データとする斜面	斜面の番号	都道府県	検証データとする斜面
1 ~ 11	北海道	6	103 ~ 129	静岡県	110, 128
12 ~ 15	青森県		130 ~ 135	愛知県	135
16 ~ 20	岩手県	18	136 ~ 143	京都府	137
21 ~ 27	宮城県	23	144 ~ 146	鳥取県	
28 ~ 32	秋田県	30	147 ~ 197	島根県	150, 160, 165, 180, 190
33 ~ 35	山形県		198 ~ 232	岡山県	200, 210, 220, 228
36 ~ 39	福島県		233 ~ 250	山口県	235
40 ~ 41	茨城県		251	徳島県	
42	栃木県		253 ~ 255	香川県	
43 ~ 44	群馬県		256 ~ 259	愛媛県	
45 ~ 53	千葉県	49	260 ~ 270	高知県	265
54	東京都		271 ~ 279	福岡県	275
55 ~ 58	神奈川県		280 ~ 298	長崎県	285, 290
59 ~ 65	長野県		299 ~ 326	熊本県	300, 314, 320
66 ~ 70	富山県	68	327 ~ 354	大分県	330, 340, 350
71 ~ 90	石川県	80, 90	357	鹿児島県	
91 ~ 102	岐阜県	97	358	沖縄県	

$$D_j = \sqrt{\sum_i (x_i - w_{ji})^2} \quad (1)$$

- ④ D_j が最小=入力ベクトル X にもっとも似かよった重みベクトルのニューロンを勝者ニューロンとする。さらに、勝者ニューロンの周りに近傍と呼ばれる領域を設定する。
- ⑤ 近傍内のニューロンに対して重みベクトルを更新する。

$$W_j(t+1) = W_j(t) + \alpha [X - W_j(t)] \quad (2)$$

t :学習回数, α :学習率

- ⑥ 各入力ベクトルに対して①～⑤の操作を繰り返して、重みベクトルを更新していく。近傍は最初、比較的大きな値(たとえば、マップサイズの半分)に設定し、学習の進行とともに1に近づくように設定する。また、学習率についても最初は比較的1に近い値に設定し、学習の進行とともに0に近づくように設定する。

3. 学習データ

今回の研究では、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)」⁵⁾の中から豪雨により崩壊した全国358地域のうち使用可能な342カ所のデータを用いた(表-1参照)。ここで、表の右側の番号は、システムの妥当性を検証するために使用した斜面データ(検証データ)の番号である。

システムの開発にあたっては、まず斜面崩壊予測の入力項目及び出力項目を選定する必要がある。斜面崩壊時降雨量の予測を行う場合、降り始めから崩壊時までの連続雨量(単位mm)を出力項目とした。ただし、この連続雨量は、6

表-2 斜面のデータを入力するときの項目

番号	入力項目	入力方法(該当する数値を入力)	番号	入力項目	入力方法(該当する数値を入力)
1	斜面の種類	1: 自然斜面 2: 人工斜面	11	表層の地質	1: 粘土 2: 砂 3: 黒土 4: れき 5: 岩塊 6: 腐植土 7: その他
2	斜面の型: 横断方向	1: 大きな尾根部 2: 大きな谷部 3: 山腹の小さな尾根部 4: 山腹の小さな谷部 5: 平行な山腹	12	表層厚	直接数値 (m) を入力
3	斜面の型: 縦断方向	1: 上昇型 (凸型) 2: 下降型 (凹型) 3: 直線型 4: 複合型 (S型) 5: 複合型 (逆S型)	13	基岩の地質	1: 噴出岩類 2: 深成岩類 3: 火山砕屑物 4: 水性堆積岩類 5: 変成岩類 6: シラス 7: ローム 8: その他
4	斜面の上端の状態	1: 尾根 2: 台地 3: 凹地 4: その他	14	地被物の種類	1: 裸地 2: 草地 3: 竹 4: 針葉樹 5: 広葉樹 6: 針広混合 7: その他
5	斜面の上端の利用状況	1: 水路または沢 2: 道路 3: 池、沼 4: 家 5: 田畑 6: 山林 7: その他	15	地被物の密度の状態	1: 疎 2: 中 3: 密
6	斜面の下端の状態	1: 上昇直線型 2: 下降直線型 3: 上昇凸型 4: 上昇曲線型 5: 上昇S線型 6: 上昇階段型	16	過去の崩壊の有無: 同一箇所	崩壊回数を数値で入力
7	斜面の下端の傾斜角	直接数値 (度) を入力	17	過去の崩壊の有無: 付近	崩壊回数を数値で入力
8	斜面の平均傾斜角	直接数値 (度) を入力	18	地表水の有無	0: 無し 1: 有り
9	頭部までの角度	直接数値 (度) を入力	19	湧水の有無	0: 無し 1: 有り
10	斜面高	直接数値 (m) を入力			

時間以上雨が降っていない時は、連続とはみなさないものとして得られたものである⁹⁾。この連続雨量は、これ以上降ると斜面が崩壊する可能性が高い限界降水量とを意味しているの、これ単独でも避難の注意や警戒を出す指標として用いることができる。降雨を指標とする時については、10分間単位の雨量を用いる方がよいという指摘もあるが、観測上の都合から時間雨量が利用されている⁹⁾。

斜面崩壊規模の予測を行う場合、一番理解しやすいのは崩壊土量である。しかし規模を予測する目的は崩土が到達する範囲を特定して、対策工を計画したり災害を回避する計画を検討したりするためである。このような目的から崩壊土量を予測するよりも具体的に崩土到達距離を求めた方が予測結果を利用しやすいと考え、本研究では、BPによる崩壊規模の予測に、崩土到達距離を出力値に選んだ。また、崩土到達距離と、連続雨量は、相関が低いと、個別にシステムを構築する必要がある。

システムの入力項目には、斜面の地形、地質、植生、土地の利用状況など、表-2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。

4. システムの構築

4.1 システムの学習方法

斜面崩壊はそれぞれの斜面ごとにたくさんの要因が複雑に入りこんでいる。崩壊メカニズムは少しずつ解明されつつあるが、現時点ではまだ十分には解明されておらず、予測を難しくしている。BPは理論的に未開発な分野でも、入力と出力のデータが十分にあれば問題を定式化するのに非常に有効とされる手段である。しかしBPの問題点としては、入力するデータの質でシステムの善し悪しが決まってしまう点である。

そこで、BPを用いて予測する前に、SOMを用いて予測データに極端に特徴が似ていない、すなわち予測の妨げとなるような悪いデータを取り除き、さらに予測データに特徴の似たデータと異なるデータを別々に分類して汎化能力を高めることを考える。SOMを用いると高い次元のデータを、似たもの同士が近くに配置されるような2次元の格子にマッピングすることができ、何十次元にもなる高度な次元のデータを比較的簡単に分類できるようになる。

今回の研究でのシステムの流れを図-2に示す。このシステムは、SOMを次のように利用した。

- ① 全国309箇所の斜面データを、SOMを用いてマップに配置する。
- ② 予測したい斜面のデータと、マップ上のニューロンの重みベクトルとの距離を求める。
- ③ 予測したい斜面のデータと、重みベクトルとの距離が、




図-2 斜面崩壊予測のフロー

- 最小となるニューロンを1つ選択する。
- ④ マップ上では、各々が近くにあるデータほど似ているデータということが言える。このことを利用して、予測する斜面データがプロットされた位置の（マップ上での）近くのデータを取りだして、それらの斜面群をひとつのグループと見なす。本研究では、図-3のように、予測する斜面データがプロットされた場所のデータと、その上、下、左、右に左上、右上、左下、右下を加えた合計9個のデータを1つのグループとみなした。
- ⑤ ④で選択した9個の斜面データをBPのネットワークに入力して学習させる。
- ⑥ 予測する斜面のデータを⑤のネットワークに入力し、崩壊時の連続雨量と、崩土到達距離を出力させる。
- 実際に予測する際は、②から⑥の作業を行えばよい。




図-3 マップ上でのユニットのグループ

4.2 システムの学習と検証結果

(1) マップの作成

全国342箇所のうち309箇所の斜面データを、SOMにより2次元のマップに配置した結果を、図-4に示す。格子内の番号は、そのニューロンに選択された斜面の番号を示す。灰色に囲った部分の番号は、検証するための斜面データ33個の斜面番号を表す。これら33個の検証データがプロットされた場所の斜面データは検証データに最も似たデータであることはもちろんのこと、その付近のデータについても検証データに似たデータであるということが出来る。

また、学習の競合層のサイズは、 18×18 、学習回数は、10万回、学習率0.5、初期の近傍領域を9とした。

(2) BPによる連続雨量予測

(1)で作成したマップを基に、検証する斜面データと特徴が似ているグループの斜面データを用いて、BPにより学習させる。入力層のニューロン数は、19、中間層のニュー





図-4 全国309箇所の斜面データをSOMにより配置した結果




図-5 発生時の連続雨量予測




図-6 連続雨量の実測値と推定値の散布図




図-7 連続雨量の推定値と実測値のヒストグラム

ロン数は、19、出力層のニューロン数は、1、学習回数を3000回とした。

実測値と推定値との値の差をグラフにしたものが図-5である。横軸には斜面番号、縦軸には発生時までの連続雨量(mm)をとった。また図-6には、横軸に連続雨量の実測値、縦軸に推定値をとって結果を散布図にした。

誤差の大きさが一番大きかった斜面は#210で、-205(mm)、一番小さかった斜面は#320で、-2(mm)であった。また、実際の傾向をみるために結果をヒストグラムにしたものが図-7である。横軸には、発生時までの連続雨量(mm)で階級幅を25(mm)とし、縦軸にはその頻度をとった。また、比較のために実測値に対するヒストグラムを折れ線で表示した。

これらの図からわかるように、250(mm)を超えた値のデータについては過小評価する傾向にある。また100(mm)に満たない値のデータについては過大評価されている。また、300(mm)を超えるような豪雨に、斜面が耐えうるか否かの判定は、ほとんどできていないことがわかる。しかし、少ない雨量で斜面が崩壊するか否かの判定は、概ねできていることが読みとれる。

(3) BPによる崩壊規模予測

斜面崩壊規模予測も、雨量予測と同じように(1)で作成したマップを基に、BPを用いて学習させる。学習回数についても3000回とした。

また、比較のため、SOMで前処理を行わずに、BPのみで学習したシステムも構築した。入力層のニューロン数は、19、中間層のニューロン数は、19、出力層のニューロン数は、1、学習回数を3000回とした。

実測値と推定値の差をグラフにしたものが図-8である。横軸には斜面番号、縦軸には崩土到達距離(m)をとった。また、実測値と推定値を散布図にしたものが、図-9である。また、SOMを用いずにBPのみで構築したシステムに対する結果と実測値を散布図にしたものが図-10である。誤差が一番大きかった斜面は#97で35(m)、一番小さかった斜面は#90で1(m)となった。また、雨量予測と同じように全体的な傾向をみるために結果をヒストグラムにしたものが図-11である。折れ線は、実測値のヒストグラムを表している。横軸は崩土到達距離(m)で階級幅を2.5(m)とし、縦軸はそ




図-8 崩土到達距離の推定結果




図-9 崩土到達距離の実測値と推定値(SOM+BP)の散布図




図-10 崩土到達距離の実測値と推定値(BPのみ)の散布図

の頻度をとった。SOMを用いずにBPのみで構築したシステムに対する結果と実測値に対するヒストグラムを図-12に示す。

これらの図からわかるように、BPのみで構築したシステムによる出力値はほとんど0(m)～2.5(m)の値を出力としている(図-12)。逆に図-11, 12により、SOMとBPを用いたシステムでは若干過大評価される傾向にあるが、BPのみで構築したシステムに比べて、かなり実測値と近い傾向を示している。また図-8、図-9より、推定値が実測値より小さい場合、誤差は極端に小さい値を示すが、実測値より推定値が大きい場合、若干過大評価してしまう傾向にある。実際に適用する場合は、評価がより安全側へ評価されているので、適用することは可能である。




図-11 崩土到達距離の実測値と推定値(SOM+BP)のヒストグラム




図-12 崩土到達距離の実測値と推定値(BPのみ)のヒストグラム

5. 崩土到達距離予測システムによる感度解析

さらに、本研究では、斜面の規模を連続雨量の大きさによって以下に示す4つのシステムを構築し、感度解析の手法⁶⁾を用いて各入力項目の影響を分析した。

- ①斜面規模が小さく、崩土到達距離が小さい。
- ②斜面規模が小さく、崩土到達距離が大きい。
- ③斜面規模が大きく、崩土到達距離が小さい。
- ④斜面規模が大きく、崩土到達距離が大きい。

これら4つについての感度解析のうち、影響の大きかった項目を表-3にまとめる。斜面規模が大きいものについては、崩土到達距離に及ぼす影響が最も大きかったものは表土厚である。斜面規模が小さいものについては、全体的に影響が小さかった。

また、特に影響が大きかった表土厚についての感度解析結果のグラフを、図-12にまとめる。

図-12において、①の表土厚が2mの時の出力値は20.0mであるが、表層厚6mになると、出力値は29.0mまで大きくなった。他の②、③、④についても同じような値となった。これは表土厚が大きいと土砂量も大きくなり、崩土の到達距離が大きくなることが考えられる。危険と考えられる斜面について、このような解析結果を事前情報として持つておけば、防災対策上非常に有効である。

表-3 規模予測システムの感度解析結果

●：影響あり

入力項目	斜面規模が小さい		斜面規模が大きい	
	① が崩 小土 さ 到 い 達 距 離	② が崩 大土 き 到 い 達 距 離	③ が崩 小土 さ 到 い 達 距 離	④ が崩 大土 き 到 い 達 距 離
斜面の種類				
斜面の型：横断方向				●
斜面の型：縦断方向	●			●
斜面の上端の状態				
斜面の上端の利用状況				
斜面の下端の状態				
斜面の下端の傾斜角				
斜面の平均傾斜角				
頭部までの角度			●	
斜面高				●
表層の地質			●	
表層厚			●	●
基岩の地質				
地被物の種類			●	
地被物の密度の状態				
過去の崩壊の有無：同一箇所				
過去の崩壊の有無：付近				
地表水の有無				
湧水の有無	●			

6. おわりに

斜面崩壊の予測システムは地域ごとに作成しているものが多い。しかし、この場合地域ごとの多少によって各システムによる予測精度が異なり、データが少ない地域では予測精度が低くなる。本研究では、地域ごとのシステムを作らずに、SOMにより近い特性の斜面データを自動的に選択し、そのデータを用いてシステムを構築することを提案した。これにより、いずれの地域においても予測精度を向上するための一つの方法を示す事ができた。

予測する斜面のデータと選択した9個が同じグループの中に収まっている場合は、予測した値の誤差は極端に小さくなる。しかし選択した9個が、真のグループとずれている場合、見当違いの出力値を出すことが考えられる。今後どのようにしてそのグループを見つけるかが課題となる。




図-12 表土厚に対する感度解析結果

参考文献

1) 市川 紘：階層型ニューラルネットワーク非線形問題解析への応用一，共立出版，1993。

2) 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，JCROSSAR'95 論文集，Vol. 3, 1995。

3) T. コホネン著，徳高 平蔵・岸田 悟・藤村 喜久朗：自己組織化マップ，シュプリンガーフェアラーク東京，1996, 5。

4) 石原 茂和・石原 恵子・長町 三生・松原 行宏：ニューラルネットワークを用いた感性エキスパートシステム一色彩における感性構造の分析への適用，人間工学，Vol. 31, No. 6, PP. 389-398, 1995。

5) 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。

6) 武長 寛：感度解析を用いたニューラルネットワークの入力層のその数学認識への応用，PP. 36～44，電気学会論文集D. 111 巻1号。

(1997年9月26日受付)