

Ⅲ-18 カウンタープロパゲーションネットワークによる斜面崩壊予測

(有)シー・エー・イー 正会員 ○伊藤則夫
香川大学工学部 正会員 白木 渡
香川大学工学部 今井慈郎
香川大学工学部 正会員 井面仁志

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り、斜面崩壊予測問題には斜面がいつ（時期）、どこで（場所）、どれくらい（規模）の崩壊が発生するかを予測する3つの要素がある。

著者らは、これまでもニューラルネットワーク手法を用いて比較的簡単な調査だけで斜面崩壊を予測するシステムを開発してきた。当初の研究では誤差逆伝搬法（B P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¹⁾。しかし、データの特性にばらつきが大きくB P法のみでは精度高い予測を行うことができなかった。次に、コホーネンの自己組織化特徴マップ²⁾（Self Organizing Feature Map、以下 SOM と呼ぶ）を利用して、評価対象となる斜面に類似した過去の崩壊事例を9つ選択し、これをB P法の学習データとすることで、B P法による予測精度の向上を図る研究を行った³⁾。SOMを用いて学習データを選択することにより、B P法による予測精度はかなり向上したが、この方法の欠点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ことであった。

斜面崩壊予測問題に対してSOMを適用する有利性はこれまでの研究で判明したので、本研究ではさらに予測手順を簡素化することを目的とし、コホーネンの競合学習とグロスバグ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⁴⁾（Counter Propagation Network、以下C P N と呼ぶ）を用いた斜面崩壊予測システムの構築を行う。

2. 入力データ

この研究では、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³⁾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 ケ所）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 ケ所）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、これまでの研究では表 1 に示す 19 項目を使用していた。しかし、斜面の種類はその大半が自然斜面であるため、本研究ではこれを使用しないこととし、表 1 の 2～19 の 18 項目を使用した。

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。

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、平衡な山腹
	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

3. CPN を用いた斜面の崩壊予測

CPN は入力、競合、補間層の 3 層からなるネットワークであり、入力～競合層間ではコホーネンの競合学習が行われ、競合～補間層間ではグロスバグ学習が行われる。そして、CPN は学習パターンをいくつかのパターンに分類して記憶し、未知のデータに対しては記憶している中の類似した数種のパターンを参照した別のパターンを出力する。

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。入力層のニューロンは入力項目数と同じ 18 個、補間層のニューロンは連続雨量および崩土到達距離に対応する 2 個とした。CPN では学習時には競合層上で学習パターンに最も類似した勝者ニューロンを 1 つのみ選択するが、補間時（未知パターンに対する出力パターンを求めるとき）には勝者ニューロン数は 1 つ以上あってもよい。そして、この数が記憶しているパターンの中の類似パターンをいくつ参照するかを決定する。本研究では、補間時の勝者ニューロン数は 3 個とした

CPN による連続雨量および崩土到達距離の予測結果を図 2、図 3 に示す。そして、予測誤差の統計量をこれまでの研究である BP 法のみによる予測¹⁾、SOM と BP 法の併用による予測²⁾の結果と合わせて表 2、表 3 に示している。この数値だけを見ると BP 法のみによる予測が SOM と BP 法の併用による予測より優れているように見えるが、実際には BP 法の場合、大半の斜面を到達距離 1.0m 以下と予測しており、正しく予測できているとはいえない。CPN による予測は連続雨量、崩土到達距離のいずれにおいてもこれまでの方法と比べて誤差がかなり小さくなっていることがわかる。

4. まとめ

本研究で CPN を用いることにより、斜面の崩壊予測が簡単に、かつ精度高く行えることがわかった。しかし、現段階では崩壊事例のすべてをそのままに記憶しており、CPN の持つパターン分類の能力を生かしているとはいえない。将来にわたってさらに多くの崩壊事例が収集されたとき、この方法のままではメモリ量などの関係で十分にデータを活用できなくなる状況も考えられる。よって、予測精度を維持しながら多くのデータをコンパクトに記憶するという観点で、さらに改善の余地があるといえる。

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) 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, シュプリンガー・フェアーク東京, 1996, 5.
3) 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.
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) 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.




図 2 CPN による連続雨量の予測




図 3 CPN による崩土到達距離の予測

表 2 各方法での連続雨量の予測誤差

	最小誤差	最大誤差	平均誤差	標準偏差
BP のみ ¹⁾	—	—	—	—
BP+SOM ³⁾	1.5	258.2	74.9	63.9
CPN	2.3	163.1	74.9	43.2

表 3 各方法での崩土到達距離の予測誤差

	最小誤差	最大誤差	平均誤差	標準偏差
BP のみ ¹⁾	0.2	23.5	7.0	5.5
BP+SOM ³⁾	0.0	35.0	7.3	7.8
CPN	0.0	14.5	4.2	3.5