

標準化されたデータベースと降雨要因を用いた 豪雨時における切土のり面のリアルタイム 崩壊予測について

菊池英明¹・古川浩平²・小山保郎³・奥園誠之⁴・西岡勲⁵

¹正会員 工博 八千代エンジニアリング株式会社 東京事業部 水工部
(〒153-8639 東京都目黒区中目黒1-10-23; 元山口大学助手 工学部社会建設工学科)

²正会員 工博 山口大学教授 工学部社会建設工学科 (〒755-8611 山口県宇部市常盤台2-16-1)

³正会員 工博 第一復建株式会社 (〒812-0016 福岡市博多区駅南3丁目5-28; 元山口大学大学院)

⁴正会員 工博 九州産業大学教授 工学部土木工学科 (〒813 福岡市東区松香台2丁目3番5号)

⁵日本道路公団中国支社 保全部保全第一課 (〒730-0017 広島市中区鉄砲町7-18 東芝770生命ビル)

現在、日本道路公団中国支社管内では、高速道路の調査・設計、施工時の資料に基づき標準化された切り土のり面データの整備が行われ、降雨データは気象庁アメダスや道路公団管理の路線沿いの観測所からリアルタイムで入手が可能となっている。切り土のり面の崩壊は崩壊の素因となる斜面要因と誘因である降雨要因により発生することから、標準化されたデータベースと降雨データを有効に活用した崩壊予測システムの構築が望まれている。そこで本研究では、これらのデータを用いた豪雨時の崩壊発生予測システムの構築を行い、リアルタイム予測への適用を試みた。そして、標準化されたデータを用いたシステムを構築する上での留意点について述べる。

Key Words : cut-slope ,prediction ,standard data base ,simple rainfall factors ,neural network

1. はじめに

全国的高速道路網の骨格が整い、これらの高規格道路の整備に伴い建設された切土のり面の日常の維持管理及び防災管理が今後ますます重要となってきた。切土のり面の管理では、崩壊による自動車等への被害を最小限にする必要がある。しかし、現実には多くののり面について管理密度を同じくすることは不可能に近い。よって、のり面の崩壊危険度に応じた優先度による適切かつ効率的な管理が望まれている。供用後ののり面崩壊の多くは豪雨時に発生しており、豪雨時の防災管理が特に重要となる。

豪雨時ののり面崩壊は、素因としての斜面評価要因に加え、誘因としての降雨要因の組み合わせにより発生することから、筆者らは最適化手法としてニューラルネットワーク(以下NN)を用いた降雨継続中でのリアルタイムの崩壊・未崩壊の予測システムの構築を行った^{1),2)}。そして、NNを用いた予測システムは降雨開始直後から個々ののり面に対してリアルタイムで崩壊・未崩壊の判別が可能であることを示した。

しかし、この予測システムは、切土のり面データ

として、「のり面評価要因」³⁾により十分に吟味、照査され、加えて崩壊発生日時が比較的明確なデータにより構築されたものであり、非常に特殊なデータを用いて構築されたシステムであると言える。したがって、実際の防災管理への適用に際しては、より一般的に得やすいデータでのシステムの構築が必要である。

日本道路公団中国支社管内では、日常の維持管理及び防災管理を効率的に行うため高速道路の調査・設計、施工時の資料により、後述する様々な斜面評価項目に基づき標準化されたのり面データが作成されている。また、降雨データは気象庁のアメダスや道路公団管理の路線沿いの観測所よりリアルタイムでデジタルデータの入手が可能であり、標準化されたのり面データとこれらの降雨データとを有効に活用した豪雨時の崩壊予測システムの構築が望まれている。加えて、累積雨量、時間雨量などの降雨量を基準とした路線単位の防災管理では、一路線内ののり面の管理密度は同じとせざるを得ないため、個々ののり面の危険度に応じた効果的な管理が行われているとは言い難い。そのため、のり面ごとに崩壊危険度評価が可能な崩壊発生予測システムの構築が必要である。

表-1 切土のり面データ標準化基準

管理事務所	30	津山	31	新見	32	三次	33	千代田	34	六日市	35	小郡		
のり面No.	のり面No.													
K.P	キロポストを数値入力													
車線	1	上下線共有	2	上り線	3	下り線	4	上下無関係						
段数	のり面段数を数値で入力													
崩壊履歴	0	1~3以外	1	建設時崩壊	2	供用後崩壊	3	1+2						
大地形	1	山岳地形	2	丘陵地形	3	台地形	4	扇状地形	5	段丘地形	9	その他		
のり面の形	1	円錐形	2	円形	3	複合形	4	扁平型	5	その他				
上土地利用	1	樹木	2	草地	3	緑地	4	竹林	5	畑地	6	水田	7	果樹園
	8	住宅・沼地	9	その他										
上方の地形	1	順傾斜	2	水平	3	傾斜地								
のり面延長(m)	1	100未満	2	100~200	3	200~300	4	300~400	5	400~500	6	500以上		
全直高(m)	1	7以下	2	7.1~14	3	14.1~21	4	21.1~28	5	28.1~35	6	35.1~42	7	42.1以上
のり勾配	1	0.5以下	3	0.8	5	1.0	7	1.2	10	1.5	11	1.8未満	12	1.8以上
小段幅(m)	1	1以下	2	1.1~1.5	3	1.6~2.0	4	2.1~2.5	5	2.6~3.0	6	3.1以上		
地質区分	1	土砂	2	軟岩(上丹)	3	硬岩	8	公団の積算区分						
岩質区分	1	流紋岩	2	石英安山岩	3	安山岩	4	玄武岩	5	その他火成岩	6	花崗岩	7	花崗閃緑岩
	8	閃緑岩	9	はんれい岩	10	その他深成岩	11	石英班岩	54	その他風化土	55	その他		
風化	1	新鮮	2	亀裂面風化	3	弱風化	4	強風化	5	風化土	6	不明		
亀裂	1	開口	2	密着	3	粘土存在	4	不明						
断層とのり面	1	切土のり面に平行	2	斜交	3	直交	8	なし						
湧水	1	流出	2	常時しみ出し	3	降雨時しみ出し	4	なし						
割れ目角度	1	0°~30°	2	31°~60°	3	61°~90°	4	不明						
保護工	1	筋芝工	2	張芝工	3	種撒布工	4	種吹付工	5	植生穴工	6	植生袋工	7	植生マット工
	8	植生筋工	9	その他植生工	10	コンクリート張工	11	コンクリートロック張工	45	無処理	99	その他		
貫入岩	1	有り	2	なし										

表-2 のり面要因とカテゴリー区分

要因	カテゴリー区分							
	1	2	3	4	5	6	7	8
A 大地形	山岳地形	丘陵地形						
B のり面の形	円錐形	円形	複合形	扁平型	その他			
C 上土地利用	樹木	草地	緑地	竹林	畑地	水田	果樹園	その他
D 上方の地形	順傾斜	水平	逆傾斜					
E 湧水	流水	常時しみ出し	降雨時しみ出し	なし				
F 地質区分	土砂	軟岩	硬岩	その他				
G のり面延長 (m)	100未満	100~200	200~300	300~400	400~500	500以上		
H 全直高 (m)	7以下	7.1~14	14.1~21	21.1~28	28.1~35	35.1~42	42.1以上	
I のり勾配	0.5以下	0.8	1.0	1.2	1.5	1.8未満	1.8以上	
J 小段幅 (m)	1以下	1.1~1.5	1.6~2.0	2.1~2.5	2.6~3.0	3.1以上		
K 保護工	密閉型	開放型	無処理型					

したがって、本研究では、実際に日本道路公団中国支社で管理されている標準化された切土のり面データと降雨要因によるNNを用いたのり面ごとに崩壊発生予測が可能な豪雨時の崩壊・未崩壊の判別システムの構築を行い、降雨継続中のリアルタイム崩壊発生予測へ適用する。その際、崩壊発生に関するデータについても道路公団中国支社管内の防災報告書より入手し、特に詳細な調査は行っていない。そして、これらの容易に得られるデータを用いた崩壊・未崩壊の判別システムの構築手法及び精度向上の方法について検討する。

2. 使用データ

(1) のり面データ

本研究で取り扱う切土のり面データは、日本道路公団中国支社管内において、高速道路の調査・設計、

施工時の資料により表-1に示す様々な評価項目に基づき標準化されたデータである。

対象とした切土のり面データは、日本道路公団中国支社管内の4管理事務所内の893個のり面である。そのうち、供用中降雨時に何らかの崩壊が発生したのり面は129個である。これらの崩壊のり面のうち雨量が非常に小さいにも関わらず崩壊したのり面については、崩壊と降雨との関係が明確でないと考えられるため、既研究成果における降雨選別基準⁴⁾を参考に累積雨量50mm以下で、一時間最大雨量が10mm/h以下で崩壊したのり面データは削除した。その結果、崩壊のり面数は変成岩:13個、堆積岩:85個、火成岩:64個となった。ここで、切土のり面の崩壊予測では岩種毎に取り扱うことが有効である^{4),5)}ことから、岩種毎にある程度の崩壊データ数を確保するため本研究では堆積岩、火成岩のデータを用いることとした。

(2)降雨データとエリア区分

「崩壊」に対応する降雨データはのり面崩壊発生時の降雨資料より作成した。「未崩壊」に対応する降雨データの抽出法は4.にて検討する。なお、基本となる降雨データは、気象庁アメダスの時間雨量データを用い、日本道路公団中国支社の降雨基準に基づき無降雨時間が8時間以内の降雨を一連続降雨とした。

降雨観測所のエリア区分は対象路線全てののり面をカバーするように半径10kmとした。なお、エリアが重なる場合は、距離の近い観測所エリアに属するものとした。

3. NNによる崩壊・未崩壊判別システムの概要

(1)のり面評価要因

表-1に示した評価基準のうち、標準化されたデータが1つのカテゴリー区分にしか属していない評価基準を削除し、A:大地形,B:のり面の形,C:上土地利用,D:上方の地形,E:湧水,F:地質区分,G:のり面延長,H:全直高,I:のり勾配,J:小段幅,K:保護工,L:のり面段数をのり面評価要因として採用した。また、のり面の供用開始からの時間経過を表す指標として、M:供用年数も評価要因とした。表-2にA~Kの評価要因のカテゴリー区分を示す。なお、K:保護工は表-1のカテゴリー区分をそのまま使うと、カテゴリー区分が多く煩雑となるため、表-1の要因区分の大分類を参考に、密閉型、開放型、無処理型の3分類とした。また、数値データとして入手できた、L:のり面段数、M:供用年数はカテゴリー区分は行っていない。

(2)降雨要因

降雨要因及び降雨要因の抽出時刻は、筆者らの研究結果^{1),2)}から次の通りとした。

a)降雨要因

N:時間雨量(mm/h), O:累積雨量(mm), P:降雨継続時間(hr)

b)降雨要因の抽出時刻

- ・崩壊降雨:崩壊発生時刻(又は推定時刻)において抽出し「崩壊降雨データ」とした。
- ・未崩壊降雨:時間雨量が最大値を示す時刻と累積雨量が最大値を示す降雨終了時刻において抽出し「未崩壊降雨データ」とした。




図-1 ニューラルネットワークモデル

タ」とした。

また、無降雨時の未崩壊を示すデータとして、N:時間雨量=0(mm/h), O:累積雨量=0(mm), P:降雨継続時間=0(hr)を用いる¹⁾。

(3)NNモデルの構成

NNモデルのモデル化に際してNNモデルの基本構造は、モデルの学習において比較的単純な構造とするほうがよく、むやみに複雑にするとかえって逆効果になることが示されている⁶⁾。加えて、中間層が複数となると煩雑となりNNの判断過程を工学的に評価することが難しい。したがって、筆者らのNNモデルの切土のり面の崩壊予測への適用結果^{1),2)}を参考に、入力層、中間層、出力層の3階層からなる階層型ネットワークとした。本モデルは切土のり面の崩壊・未崩壊の判別を斜面要因・降雨要因を入力データとし、崩壊・未崩壊を出力する一つの入力パターンとして取り扱う。

NNモデルを構成するニューロンは、その出力が[0]~[1]である。そのため、入力層ではカテゴリー化されたデータについては、入力要因のカテゴリー数だけニューロンを設定し該当するランクに[1]を入力する。また、数値データは、データの最大値が[1]となるように基準化して入力する。本研究ではA~Kの斜面要因をカテゴリーデータとして入力し、L,Mの斜面要因及びN~Pの降雨要因を数値データとして入力した。中間層のユニット数は6個¹⁾

表-3 崩壊・未崩壊のり面数とデータ数

岩種	ケース	のり面数			データ数		
		崩壊	未崩壊	総数	崩壊	未崩壊	総数
堆積岩	Case A	81	768	849	81	1536	1617
	Case B	81	310	391	81	620	701
	Case C	81	100	181	81	200	281
	Case D	81	410	491	81	820	901
火成岩	Case A	56	635	691	56	1270	1326
	Case B	56	342	398	56	684	740
	Case C	56	69	125	56	138	194
	Case D	56	411	467	56	822	878

とし、出力層は「崩壊」のニューロンを設定した。このニューロンには、0.0～1.0までの確信度(以下、崩壊確信度とする)が出力される。すなわち崩壊確信度0.5以上であれば「崩壊」となり0.5未満であれば「未崩壊」となる。また、この崩壊確信度が1.0に近いほど「崩壊」の判別の信頼性が高いことを示し、0.0に近いほど「未崩壊」判別の信頼性が高いことを示す。本研究で用いたNNモデルを図-1に示す。

ニューロンの応答特性を示す入出力関数にはシグモイド関数を用い、学習方法にはバックプロパゲーションを適用した。また、学習の収束条件は学習回数10,000回の制約下で平均2乗誤差： $E < 0.001$ とした。

(4)判別システムの構築手順

本研究では、全データの2/3をランダムに抽出し「教師データ」として学習し判別システムを構築した後、残りの1/3のデータを未学習の「テストデータ」としシステムの信頼性の検証に用いる。また、5.で用いる未崩壊1/3モデルでは、未崩壊データを1/3に削減した後に、教師・テストデータに区分して用いる。ただし、3.(2)で示したように、降雨継続中の全ての降雨データを抽出対象としないため、教師データに対してもリアルタイム予測を行いシステムの検証を行う。

以下に判別システムの構築手順を示す。

手順1：未崩壊降雨の設定方法の検討

手順2：リアルタイム予測への適用

手順3：判別システムの精度向上

(5)評価指標

筆者らの研究^{1),2)}を参考に次の評価指標を用いる。

a)学習及びテスト結果の評価

収束状況、崩壊・未崩壊データの判別率

b)リアルタイム予測結果の評価

・崩壊予測率

崩壊発生時の1～3時間前から連続的に崩壊判別し

たのり面数を全のり面数で除したもの

・降雨継続時間内での未崩壊予測率

降雨継続時間内の未崩壊判別時間を降雨継続時間で除したもの

・崩壊確信度の経時変化

4. 崩壊・未崩壊判別システムの構築

(1)未崩壊データの設定方法

崩壊データは、崩壊のり面と崩壊時の降雨(崩壊降雨)との組み合わせであることは明らかである。しかし、未崩壊データの設定に関しては、未崩壊のり面の確定は容易であるが、そののり面に組み合わせる降雨(以下未崩壊降雨)は、様々な選定が可能である。例えば、過去未崩壊であったのり面においては供用期間中の全降雨を未崩壊降雨とすることが可能である。崩壊のり面においても崩壊発生以前の経験降雨は未崩壊降雨として取り扱うことが可能である。また、崩壊降雨は、その降雨で崩壊が発生していないのり面に対しては未崩壊降雨として組み合わせることが可能である。本研究では、これらを考慮し、下記の未崩壊降雨とのり面との組み合わせを設定した。なお、崩壊データは、既述のように崩壊のり面データと崩壊発生時の降雨要因とを組み合わせたものである。

Case A: 全崩壊のり面の±2.5kmの範囲のその崩壊降雨では未崩壊であったのり面に対して未崩壊降雨として設定

Case B: 全未崩壊のり面に対して累積雨量を基準に過去の最大経験降雨を未崩壊降雨として設定。

Case C: 崩壊のり面に対して、崩壊発生以前にはそののり面では未崩壊であった降雨を累積雨量を基準に、第一番目に多かった降雨から第三番目に多かった降雨を未崩壊降雨として設定。

Case D: Case B + Case C

このようにして組み合わされた崩壊・未崩壊のり面数を表-3に示す。

(2)学習結果及び崩壊・未崩壊判別結果

表-3に4.(1)に示した降雨要因の抽出方法に基づき抽出された降雨要因とのり面要因とを組み合わせた時の崩壊・未崩壊データ数を示す。

学習に用いる教師データとして3.(4)に記述の通り、崩壊・未崩壊データごとに全データよりランダムに2/3を抽出し、残りの1/3をテストデータとした。

表-4 学習状況及び教師データに対する判別結果

岩種	ケース	Case A	Case B	Case C	Case D
堆積岩	判別結果	崩壊 48/54	53/54	54/54	43/54
	(%)	88.89	98.1	100	79.63
	未崩壊	1024/1024	413/413	127/133	546/547
	(%)	100	100	95.49	99.82
	学習回数	10000	776	10000	10000
平均2乗誤差	0.0043	0.0008	0.01525	0.01360	
火成岩	判別結果	崩壊 36/37	36/37	33/37	36/37
	(%)	97.3	97.3	89.19	97.3
	未崩壊	847/847	456/456	92/92	548/548
	(%)	100	100	100	100
	学習回数	275	10000	10000	10000
平均2乗誤差	0.001	0.019	0.01895	0.00123	

表-5 未学習のテストデータに対する判別結果

岩種	ケース	Case A	Case B	Case C	Case D
堆積岩	崩壊	16/27	19/27	19/27	12/27
	(%)	59.26	70.37	70.37	44.44
	未崩壊	508/512	198/207	54/67	261/273
	(%)	99.22	95.65	80.6	95.6
火成岩	崩壊	14/19	16/19	11/19	13/19
	(%)	73.68	84.21	57.89	68.42
	未崩壊	420/423	223/228	31/46	262/274
	(%)	99.29	97.81	67.39	95.62

表-6 Case Bの崩壊予測結果

岩種	データ	3時間前	2時間前	1時間前	崩壊判別
堆積岩	教師	2/54	8/54	16/54	53/54
	(%)	3.7	14.8	29.6	98.1
	テスト	0/27	3/27	11/27	19/27
	(%)	0.0	11.1	40.7	70.4
火成岩	教師	6/37	14/37	22/37	36/37
	(%)	16.2	37.8	59.5	97.3
	テスト	3/19	7/19	12/19	16/19
	(%)	15.8	36.8	63.2	84.2

学習状況および教師データに対する崩壊・未崩壊判別結果を表-4に示す。

表-4より、学習の収束状況は堆積岩ではCase B、火成岩ではCase Aを除くケースで収束条件を満足せず10,000回の学習回数で学習が終了している。教師データに対する崩壊・未崩壊の判別結果は堆積岩では、Case Bが崩壊・未崩壊判別を通じて最も良い結果が得られており、次いでCase Cが若干未崩壊判別率が悪いものの全ての崩壊データに対して正解を与えている。火成岩では何れのケースにおいても全ての未崩壊データに対して正解を与えており、崩壊データにおいてもCase A,B,Dでは1データのみでしか誤判別しておらず非常に高い精度で学習が行われている。

次に、テストデータに対する崩壊・未崩壊の判別結果を表-5に示す。表-5より崩壊判別では堆積岩

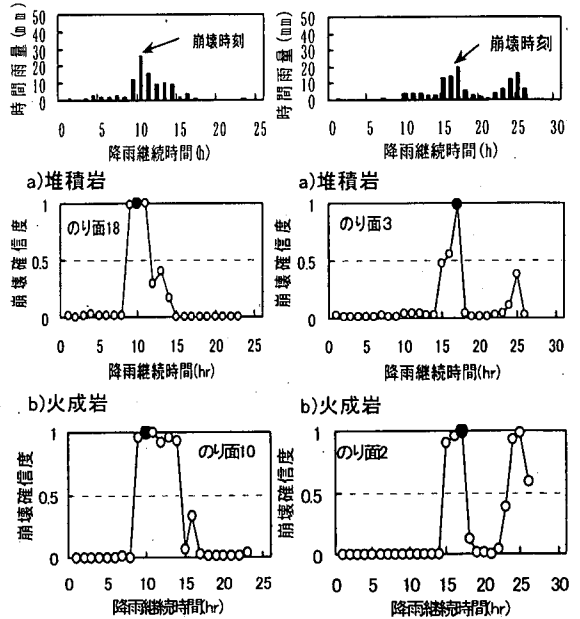


図-2 リアルタイム予測結果の一例 (降雨継続時間が短く降雨規模が小さい例)

でCase B,Cが約70%、火成岩でCase Bで80%以上の高い判別率が得られている。未崩壊判別では堆積岩、火成岩ともにCase Cを除き95%以上の高い判別率が得られている。

以上の学習状況およびテストデータに対する判別結果を考慮すると未崩壊降雨の設定方法として、Case Bが最も有効であると考えられる。

(3)リアルタイム予測への適用と評価

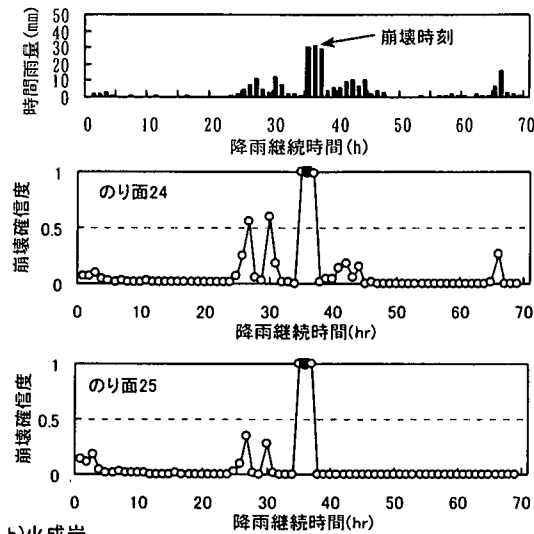
降雨継続中のリアルタイム予測は、学習が終了した堆積岩、火成岩の判別システムに斜面要因と降雨開始時からの降雨要因を入力して得られる崩壊確信度により行う。また、3.(2),(4)で記述したように、降雨継続中の全ての降雨データを抽出対象としないため、本節では教師データに対してもリアルタイム予測を行いシステムの検証を行う。以下にCase Bの判別システムを用いたリアルタイム予測結果を示す。

a)崩壊のり面のリアルタイム予測結果

表-6に教師・テストデータにおいて崩壊3時間前、2時間前、1時間前から連続的に崩壊判別(予測)したのり面数及び崩壊時刻での崩壊判別結果を示す。ただし、これらの判別には崩壊時刻の4時間前以前の崩壊確信度の変化は考慮していない。

崩壊時刻での判別は前節の表-5で示したように、システムの構築に用いた教師データに対しては、堆積岩、変成岩ともに95%以上の高い判別率が得られている。未学習のテストデータにおいては、表-5で

a) 堆積岩



b) 火成岩




図-3 リアルタイム予測結果の一例（長期降雨）

示したように火成岩では80%以上の高い判別率が得られているが、堆積岩では約70%と火成岩に比べ若干劣る結果となっている。

表-6より崩壊予測では火成岩においては、教師・テストデータの崩壊予測率はほぼ等しく、1時間前予測では約60%の高い判別率が得られており、2時間前予測においても40%に近い判別率が得られている。これに対して堆積岩においては火成岩に比べ判別率が低いものの1時間前予測では、テストデータで約40%、教師データで、約30%の判別率が得られている。しかし、2時間前予測では、教師・テストデータともに20%以下と判別率が低くなっている。

次にテストデータのうち崩壊時刻で正しく崩壊と

判別されたのり面に対するリアルタイムの崩壊確信度の経時変化の例を示す。

図-2に降雨開始後10時間～20時間前後で比較的降雨規模の小さな崩壊例を示し、図-3には降雨継続時間が長く降雨規模も大きい崩壊例を示す。図-2、図-3では崩壊発生時刻を●で示している。

図-2よりテストデータにも関わらず崩壊時刻付近で大きく確信度が上昇し崩壊を予測し崩壊発生時刻には的確に崩壊と判別し降雨全般で良好な判別傾向を示している。図-2の堆積岩と火成岩の確信度の変化を比較すると火成岩の方が堆積岩に比べ確信度が高くなっている区間が長く、火成岩の方が崩壊予測率が高くなったことを裏付ける結果である。

図-3の降雨規模が大きな場合においても図-2と同様に崩壊時刻付近では的確に崩壊と判別している。しかし、図-3の火成岩ののり面4に示すように累積雨量の上昇に過敏に反応する例も見られた。

しかしながら、崩壊のり面の多くは図-2、図-3の崩壊確信度の経時変化に見られるように降雨の降り始めには未崩壊と判別し、崩壊発生時刻付近では崩壊と判別した後、累積雨量が増加するにも関わらず、崩壊確信度が下降し未崩壊と判別しており、良好なリアルタイムでの判別結果が得られた。さらに、これら図-2、図-3の崩壊確信度の変化が示すように同じ崩壊降雨に対しても岩種、のり面の違いにより異なった経時変化を示しており、個々ののり面ごとに崩壊可能性評価が十分可能であると思われる。

ここで、図-3ののり面4に見られる崩壊確信度の振動は、降雨の降り始め25時間前後までは、わずかな時間雨量の変化に敏感に反応し、その後、30時間を過ぎると累積雨量の増加に敏感に反応していると推察される。これは、教師データの中のにのり面4と非常に類似したのり面要因を持ち、さらに崩壊発生時刻の時間雨量、累積雨量がともに小さいデータが存在していると推測される。

実際に、のり面4は一度崩壊した翌年に再び崩壊が発生しており、システム構築の際に教師、テストデータに分割されている。この時ののり面4の降雨データとのり面4と同様に同一のり面での崩壊例の降雨データを表-7に示す。表-7よりのり面4では、テストデータに対して時間雨量、累積雨量ともに小さなデータが学習されていることが分かる。さらにこの教師データは、火成岩のり面で最も小さな時間雨量で崩壊した例である。これらのことから、のり面4での確信度の震動が生

表-7 同一のり面崩壊での教師・テストデーへの分割例

対象のり面	教師・テストデータの別	時間雨量 (mm/h)	累積雨量 (mm)	降雨継続時間 (hr)
のり面4	教師	10	23	12
	テスト	24	244	65
のり面2	教師	26	76	17
	テスト	20	67	17
のり面3	教師	24	65	18
	テスト	24	244	65

じたものと考えられる。

これに対して、表-7に示した他ののり面でのリアルタイムのテスト結果では、震動は見られなかった。これは、表-7が示すようにのり面2では教師・テストデータの時間、累積雨量がほぼ等しく、のり面6では時間雨量がほぼ等しいためであると推察される。

このような同一のり面での崩壊発生例の場合、確信度の変化特性を降雨要因の特徴より推測可能であるが、実際には数多くの教師データの組み合わせパターンとテストデータのパターンとを照合し、確信度の変化特性を原因を追求することは難しい。

b)未崩壊のり面のリアルタイム予測結果

表-8に降雨継続時間内の未崩壊予測率別ののり面数を示す。

表-8より、システムの構築に用いた教師データでは、堆積岩、火成岩の全てののり面において、降雨継続中常に未崩壊と判別がなされている。未学習のテストデータに対しては、降雨継続中に崩壊と誤判別が生じたのり面は、堆積岩では、114個中わずか4個と非常に少なく、降雨継続時間中に80%以上の未崩壊判別率が得られなかったのり面はわずか3個である。火成岩においても降雨継続時間中誤判別が生じたのり面は103個中7個であり、降雨継続時間中に90%以上の未崩壊判別率が得られなかったのり面はわずか2個である。このように未崩壊降雨においても、非常に高い確率で降雨継続中常に未崩壊と判別が可能である。

5. 判別システムの信頼性の向上

前章では、標準化されたのり面データベースと災害報告書の災害記録情報を基に抽出した降雨データとを組み合わせた、一般的に得やすい情報のみを用いた場合においても崩壊・未崩壊判別システムの構築が可能であることを示した。さらに本章では、前章で構築したCase Bを基本システムと位置づけ、この基本システムの精度向上手法について検討する。

表-8 Case Bの未崩壊予測率別のり面数

岩種	データ	降雨継続時間内の未崩壊予測率			
		100%	90%以上	80%以上	70%以上
堆積岩	教師	207/207	207/207	207/207	207/207
	(%)	100.0	100.0	100.0	100.0
	テスト	96/103	99/103	101/103	101/103
	(%)	93.2	95.2	98.1	98.1
火成岩	教師	228/228	228/228	228/228	228/228
	(%)	100.0	100.0	100.0	100.0
	テスト	110/114	112/114	112/114	112/114
	(%)	96.5	98.2	98.2	98.2

(1)精度向上手法と検討ケース

堆積岩のデータを例にとると、表-3に示したようにCase Bでは崩壊データ数81に対して未崩壊データ数は620あり、崩壊データの7倍以上となっている。このように、崩壊データに対して未崩壊データが多くなる場合、荒木ら⁷⁾の研究により崩壊データをn倍して学習させる集中学習により、崩壊データに対する正解率をさらに向上させることが可能であることが示されている。本研究では、このn倍学習(集中学習)に加え、未崩壊データを減らすことにより、全データ中で相対的に崩壊データの割合を増やし正解率の向上を試みる。そこで、本研究では、単純に未崩壊のり面をランダムに1/3ずつにし、それぞれの1/3の未崩壊のり面データをさらに教師・テストデータにランダムに分類しシステムの構築、検証を行う。さらに残りの2/3の未崩壊のり面についてもリアルタイム予測を行い検証を行った。なお、本章では全体的な学習精度の向上を考慮し平均2乗誤差を0.0001以下とし、学習回数の上限を20,000回とした。検討ケースを以下に示す。

・ Case B1

平均2乗誤差 ≤ 0.0001, 学習回数 20,000回

・ Case Nn(n=2~5) : n倍学習モデル

崩壊データを2倍~5倍し集中学習を行う。

(平均2乗誤差 ≤ 0.0001, 学習回数 20,000回)

・ Case Ti(i=1~3) : 未崩壊1/3モデル

未崩壊データを1/3ずつ用いて判別システムを構築する。

(平均2乗誤差 ≤ 0.0001, 学習回数 20,000回)

(2)学習結果及び崩壊・未崩壊判別結果

表-9に各精度向上モデルの学習状況及び教師データに対する判別結果を示す。表-9には参考のため基本モデルCase Bの結果も示している。

表-9より、各精度向上モデルの収束状況は、堆積

表-9 各精度向上手法の学習状況及び教師データに対する判別結果

岩種	評価項目	基本モデル		n倍学習(集中学習)モデル				未崩壊1/3モデル			
		Case B	Case B1	Case N2	Case N3	Case N4	Case N5	Case T1	Case T2	Case T3	
堆積岩	判別結果	崩壊	53/54	54/54	54/54	54/54	54/54	54/54	54/54	52/54	54/54
	(%)	98.1	100	100	100	100	100	100	96.3	100	
	未崩壊	413/413	413/413	413/413	412/413	413/413	413/413	111/111	111/111	111/111	
	(%)	100	100	100	99.76	100	100	100	100	100	
	学習回数	776	877	797	20000	703	628	1020	20000	405	
	平均2乗誤差	0.00077	0.00010	0.0001	0.0012	0.0001	0.0001	0.0001	0.0064	0.0001	
火成岩	判別結果	崩壊	36/37	36/37	37/37	37/37	37/37	37/37	37/37	37/37	37/37
	(%)	97.3	97.3	100	100	100	100	100	100	100	
	未崩壊	456/456	456/456	456/456	456/456	456/456	456/456	152/152	152/152	152/152	
	(%)	100	100	100	100	100	100	100	100	100	
	学習回数	10000	20000	220	233	236	205	323	328	422	
	平均2乗誤差	0.018952	0.00132	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	

表-10 各精度向上手法によるテストデータに対する判別結果

岩種	評価項目	基本モデル		n倍学習(集中学習)モデル				未崩壊1/3モデル			
		Case B	Case B1	Case N2	Case N3	Case N4	Case N5	Case T1	Case T2	Case T3	
堆積岩	判別結果	崩壊	19/27	21/27	21/27	18/27	20/27	20/27	20/27	23/27	21/27
	(%)	70.37	77.78	77.78	66.67	74.07	74.07	74.07	85.19	77.78	
	未崩壊	198/207	196/207	194/207	196/207	201/207	198/207	68/70	64/68	64/68	
	(%)	95.65	94.69	93.72	94.69	97.1	95.65	97.14	94.12	94.12	
	未崩壊(2/3)	-	-	-	-	-	-	385/412	386/412	385/412	
	(%)	-	-	-	-	-	93.45	93.69	93.45		
火成岩	判別結果	崩壊	16/19	16/19	17/19	16/19	16/19	16/19	18/19	16/19	18/19
	(%)	84.21	84.21	89.47	84.21	84.21	84.21	94.74	84.21	94.74	
	未崩壊	223/228	223/228	359/361	358/361	357/361	358/361	74/76	75/76	72/76	
	(%)	97.81	97.81	99.45	99.17	98.89	99.17	97.37	98.68	94.74	
	未崩壊(2/3)	-	-	-	-	-	-	438/456	439/456	433/456	
	(%)	-	-	-	-	-	96.05	96.27	94.96		

岩の Case N3, Case T2, 火成岩の Case B1 を除き収束条件を厳しくしたにも関わらず平均2乗誤差を満足し学習が終了している。教師データに対する判別結果では、堆積岩の崩壊データではCase T2のみで2個ののり面で誤判別しているほかいずれのケースも100%の判別率が得られ、未崩壊データについてはCase N3で1個ののり面について誤判別しているだけである。火成岩ではCase B1の崩壊データで1個ののり面で誤判別しているほか、全ケースで崩壊・未崩壊データに対して100%の判別率が得られている。このように精度向上モデルでは、全ケースで基本モデル(Case B)と同等以上の高い精度で学習が行われている。

精度向上モデルの未学習のテストデータに対する判別結果を表-10に示す。表-10の未崩壊(2/3)はシステム構築の教師・テストデータとしなかった残り2/3の未崩壊データに対する判別結果である。

表-10より、基本モデルにおいて収束条件のみを厳しくしたCase B1では、堆積岩の未崩壊データで若干判別精度が下がるものの崩壊データでは

判別精度の向上が見られ78%と高い判別率が得られている。しかし、火成岩では判別精度の向上は見られない。

次にn倍学習モデルでは堆積岩、火成岩ともに2倍学習が最も良い判別結果が得られており、火成岩では崩壊・未崩壊ともに基本モデルに比べ判別精度が向上し、崩壊データで約90%、未崩壊データでほぼ100%の判別率が得られている。堆積岩ではCase B1とほぼ同程度の結果である。

また、未崩壊データを削減した未崩壊1/3モデルにおいては堆積岩ではCase T2で崩壊データで85%、未崩壊データで94%と最も良い判別結果が得られ、Case B1, Case N2に比べても良い結果が得られている。火成岩ではCase T1で崩壊データで95%、未崩壊データで100%近い判別率が得られ、Case B, Case N2に比べ良い判別結果が得られている。なお、表-10に示すように、残りの2/3の未崩壊データに対しても堆積岩で93%、火成岩で96%と高い未崩壊判別率が得られている。

このように、本判別モデルにおいては、崩壊デー

表-11 崩壊・未崩壊降雨数とのり面数

岩種	降雨数		のり面数		一降雨当たりののり面数	
	崩壊	未崩壊	崩壊	未崩壊	崩壊	未崩壊
堆積岩	48	27	81	310	1.7	11.5
変成岩	35	16	56	342	1.6	21.4




図-4 学習に用いた崩壊・未崩壊降雨データの分布図

データをn倍した集中学習モデルに比べ、未崩壊データを減らした方が、判別精度向上に有効であることが分かる。

これは、荒木らの判別モデル⁷⁾においては、土石流発生降雨数が少なく、非発生降雨に対しても発生降雨数の割合が少なかったため、発生データを集中学習することで発生降雨の認識が高まり判別精度の向上が見られたものと推察される。しかし、本モデルでは表-11に示すように崩壊降雨数が未崩壊降雨数に対して多く、加えて、図-4に示す学習に用いた崩壊・未崩壊降雨の累積雨量・時間雨量の分布図に見られるように、未崩壊データの分布に対して、崩壊データの分布域が広いことn倍学習の効果があまりシステムに反映されなかったと推察される。また、表-11の一降雨当たりののり面数が示すように、一降雨当たりの崩壊のり面数に対して、堆積岩、火成岩いずれも未崩壊のり面数が非常に多く、降雨データのみを考えた場合、未崩壊降雨を集中的に学習させたと同様な影響をシステムに与えていると推察される。したがって、未崩壊データを減らすことによっても精度の向上が見られたものと思われる。

(3)リアルタイム予測への適用と評価

4.(3)でのリアルタイム予測への適用例が示すように、1時間前～3時間前の崩壊予測に関しては教師・テストデータともに同程度の結果が得られ、降雨継続時間内の未崩壊予測においては、学習に用いた教師データでは、全てののり面について降雨継続時間に常に未崩壊と判別が可能であった。これらのことから本節では、テストデータのみによりリアルタイ

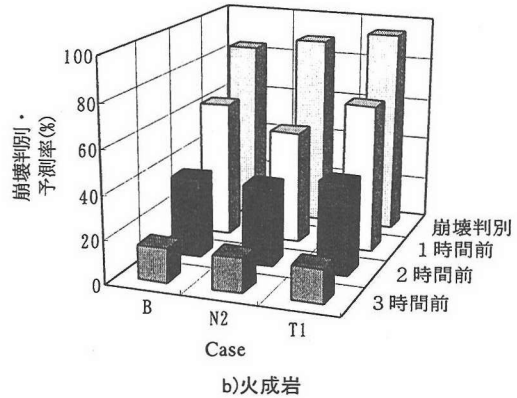



図-5 基本モデルと精度向上モデルの崩壊予測結果の比較

表-12 精度向上モデルでの全未崩壊のり面に対する降雨継続時間内の未崩壊予測率別のり面数(%)

岩種	ケース	降雨継続時間内の未崩壊予測率			
		100%	90%以上	80%以上	70%以上
堆積岩	Case B	93.2	95.2	98.1	98.1
	Case B1	91.3	96.1	97.1	97.1
	Case N2	88.4	98.1	98.1	98.1
	Case T2	90.0	95.9	96.3	97.5
火成岩	Case B	96.5	98.2	98.2	98.2
	Case N2	98.3	99.1	99.1	99.1
	Case T1	94.4	98.5	98.5	99.2

ム予測への適用性の評価を行う。

なお、本節では各精度向上モデルで崩壊・未崩壊判別精度の向上が見られた、堆積岩ではCase B1, Case N2, Case T2, 火成岩ではCase N2, Case T1の結果について基本モデルCase Bとの比較を行う。

a)崩壊のり面のリアルタイム予測結果

図-5に精度向上モデルによる崩壊のり面における崩壊予測結果を示す。

崩壊発生時刻の判別は図-5より、堆積岩では未崩壊1/3モデルCase T2がもっとも判別率が高く約85%




図-6 堆積岩の未崩壊1/3モデルにおける感度解析結果




図-7 火成岩の未崩壊1/3モデルにおける感度解析結果

の判別率が得られ、基本モデル Case B に比べ約 15% の判別率の向上が見られる (表-10 参照)。火成岩においても未崩壊 1/3 モデルである Case T1 が最も判別率が高く約 95% の判別率が得られ、基本モデルに比べ約 10% の精度向上が見られる (表-10 参照)。

図-5 より、堆積岩では各精度向上モデルとも基本モデル Case B 以上の崩壊予測結果が得られており、1 時間前予測では Case N2 の 2 倍学習モデルで、50% 以上の予測結果が得られ、未崩壊 1/3 モデルである Case T2 で約 60% と高い予測率が得られている。火成岩においても、1 時間前予測で Case T1 では約 70% の高い予測率が得られている。このように未崩壊 1/3 モデルは崩壊予測の面でも基本モデルに比べ精度向上が見られる。

b)未崩壊のり面のリアルタイム予測結果

表-12 に基本モデルと精度向上モデルの未崩壊降雨における降雨継続時間内の未崩壊予測率別のでの

り面数 (全未崩壊のり面数に対する割合 (%)) を示す。ここで、堆積岩 Case T2、火成岩 Case T1 の未崩壊のり面数はシステムの構築の際に残した 2/3 の未崩壊のり面も全て含む結果である。

表-12 より降雨継続時間内で 100% の未崩壊予測率が得られたのり面数では、堆積岩、火成岩ともに基本ケース (Case B) が最も良い結果が得られている。しかし、90% 以上の予測率が得られたのり面数は、何れの岩種においても各精度向上モデルが上回っており、その中で堆積岩、火成岩ともに Case N2 が最も良い結果が得られている。

(4)精度向上モデル(未崩壊1/3モデル)の特徴に関する考察

以上のことから未崩壊 1/3 モデルでは、何れのケースも基本モデル (Case B) に比べ表-9 に示したよ

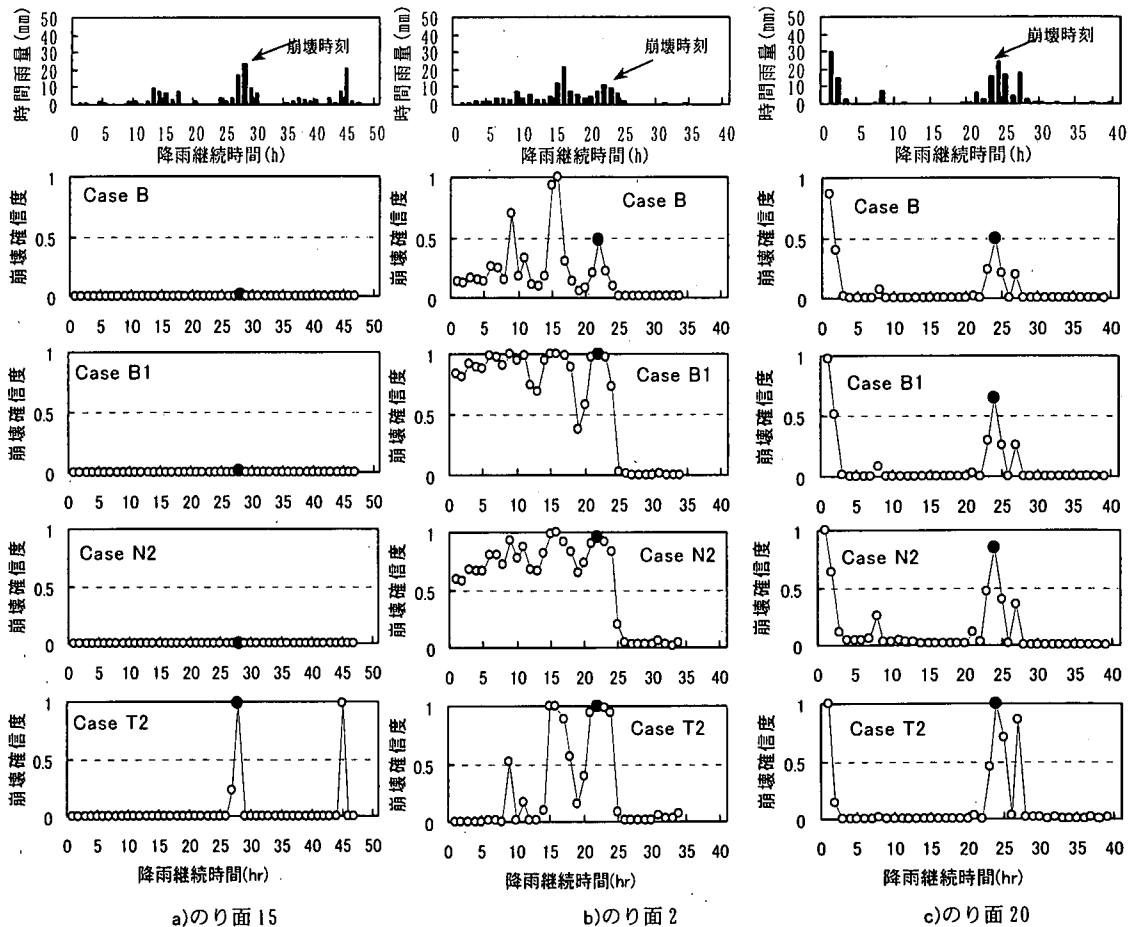


図-8 精度向上モデルによるリアルタイム予測結果の一例（堆積岩，テストデータ）

うに学習効率に優れ，基本モデル以上の判別結果が得られるものの組み合わせる未崩壊データにより判別精度に差が生じることが分かる．本節では，未崩壊データを削減した場合においても安定した結果が得られるよう未崩壊1/3モデルの特性について評価を行う．

a) 感度解析による精度向上モデルの特徴

堆積岩の未崩壊1/3モデルにおける時間雨量，累積雨量に対する感度解析結果を図-6に示す．図-6は，任意の時間雨量，累積雨量の組み合わせに対して判別を行い，崩壊確信度が0.5以上を示す領域を示したものである．このときの時間雨量，累積雨量以外の降雨要因，斜面要因は全データの平均値を用いた．なお，図-6の●はシステムの構築に用いた崩壊データ，○は未崩壊データ（1時間最大雨量時刻）である．図-6を見ると，堆積岩の未崩壊1/3モデルで最も良い判別率を示したCase T2が最も崩壊領域が広く，境界線の傾きも大きく累積雨量が小さな場合には，大きな時間雨量で崩壊し，累積雨量が大きくなると小さな時間雨量で崩壊と判別する傾向がCase

T1, Case T3に比べて強く，一般的な常識に最も近い結果を示している．次いで，Case T3, Case T1と崩壊領域が小さくなり，表-10に示すように崩壊の判別精度もこの順で悪くなる．それに対して未崩壊の判別精度はCase T1が最も高い．

次に，図-7に火成岩の未崩壊1/3モデルにおける同様な感度解析結果を示す．図-7より火成岩の未崩壊1/3モデルにおいても精度向上が見られたCase T1, Case T3が良好な感度解析結果を示していることが分かる．

b) リアルタイム予測結果から見た精度向上モデルの特徴

次に，堆積岩の崩壊降雨における基本モデルと精度向上モデルのリアルタイム予測の一例を示し，精度向上モデルの特徴について示す．

図-8に基本モデルと精度向上モデルのリアルタイム予測の一例を示す．図中の確信度変化の●印は崩壊発生時刻を示している．

図-8a)のり面15の例を見ると全体の収束精度

表-13 のり面要因間のコンテンジェンシー係数(火成岩)

	A	B	C	D	E	F	G	H	I	J	K	L	M
A	1												
B	0.0245	1											
C	0.0132	0.0253	1										
D	0.0376	0.0339	0.1469	1									
E	0.0809	0.0544	0.0030	0.0151	1								
F	0.1223	0.0326	0.0175	0.0194	0.0269	1							
G	0.0251	0.0512	0.0246	0.0438	0.0727	0.0580	1						
H	0.0327	0.0762	0.1645	0.1281	0.0682	0.0406	0.0319	1					
I	0.1839	0.0245	0.1246	0.0709	0.0426	0.0555	0.0303	0.0562	1				
J	0.0469	0.0415	0.1336	0.0767	0.0171	0.0461	0.0178	0.1177	0.0899	1			
K	0.0527	0.0021	0.0288	0.0036	0.0174	0.0378	0.0162	0.0706	0.1866	0.0697	1		
L	0.0286	0.0967	0.0126	0.0958	0.1301	0.0344	0.0442	0.3561	0.0417	0.0692	0.0265	1	
M	0.3201	0.1016	0.0241	0.0144	0.0870	0.2294	0.1087	0.0401	0.0614	0.0451	0.0548	0.0383	1

を向上させた Case B1 及び崩壊データの学習精度を向上させた Case N2 では基本ケースと同じく崩壊時刻での崩壊判別はなされていない。しかし未崩壊データを削除した Case T2 では崩壊時刻に的確に崩壊と判別している。これは、未崩壊データを減らすことにより、のり面 15 に類似した未崩壊のり面が減少したためであると推測される。

図-8b)を見るとのり面 2 に対して基本モデル Case B では崩壊時刻以前の一時間最大雨量付近で崩壊と高く判別し、崩壊発生時刻には 0.5 を若干下回り、未崩壊と判別している。これに対して、Case B1, Case N2 では降雨開始後から一般的に崩壊確信度が上昇し、崩壊時刻においても崩壊と判別している。これは、収束条件の向上および 2 倍学習により崩壊データの学習精度が向上し、のり面自体の崩壊可能性を高く認識したものと考えられる。しかし、Case N2 では崩壊データを 2 倍学習しているため崩壊発生時刻も強調される結果となり Case B1 に比べ降雨開始直後の確信度が低くなったものと思われる。また、Case T2 では未崩壊データを減らした結果、のり面 2 の崩壊時刻の降雨要因と類似した降雨要因を持つ未崩壊データが減少したため、崩壊時刻における未崩壊の認識度が低下し、その結果崩壊発生時刻に正しく崩壊と判別したのものと思われる。

図-8c)では、それぞれの精度向上モデルにおいて崩壊時刻付近のみが強調され特に未崩壊降雨を削減した Case T2 においても崩壊時刻付近が強調されうまく崩壊判別しており、理想的な精度向上の状況であると言える。

c) 数量化Ⅲ類による精度向上モデルの崩壊・未崩壊データの分布特性

数量化Ⅲ類で分類するにあたり、統計解析上、各要因の独立性の検討が必要であることから、のり面要因相互の独立性の検討を行う。ここで、取り扱う斜面要因は、表-2 に示した A~K のカテゴリー化さ

れた斜面要因および L: のり面段数, M: 供用年数である。ここで、L: のり面段数, M: 供用年数のカテゴリー区分は、それぞれ、のり面段数 1 段づつ、供用年数 1 年づつを 1 カテゴリーに対応させた。

このように、本研究で用いるデータは、カテゴリーデータを基本としているため、以下の手順に従い独立性の検討を行った。この手順の詳細については参考文献 4) を参照されたい。

手順 1: クロス集計表を作成しカテゴリー相互の度数を求める。

手順 2: χ^2 検定を行い独立性の検定を行う。


手順 3: クラマーのコンテンジェンシー係数 (C_c) で各要因間の関連を求める。

コンテンジェンシー係数 (C_c) は属性間が完全に独立の時 0, 独立でないとき 1 となり、属性間の程度を示す係数である。


χ^2 検定により有意水準 5% 及び 1% で検定を行った。その結果、いくつかの要因においては有意水準 5% で独立性の仮説が棄却され、従属関係にあることが分かった。なお、検定結果の具体的な数値に関しては説明を省略する。そこで、コンテンジェンシー係数 (C_c) を求め係数値により従属度を判断することとした。

表-13 に火成岩の各要因間のコンテンジェンシー係数 (C_c) を示す。表-13 から各要因の係数値は最大でも要因 H, 要因 L 間で 0.3561 と小さく各要因間の従属度は小さいと判断し、全てののり面要因を解析に用いるものとした。堆積岩についても同様の理由から全てののり面要因を解析に用いるものとした。


図-9 に堆積岩の数量化Ⅲ類による崩壊・未崩壊データの分類結果を示し、図-10 に火成岩の結果を示す。図-9, 図-10 の分類結果は、Case T1 ~ Case T3 の未崩壊の教師データと崩壊の教師・テストデータを同時に分類した未崩壊データを Case T1 ~ Case T3 別に表示したものである。ここで、図中の▲は各ケースにおける



a)Csae T1



b)Csae T2

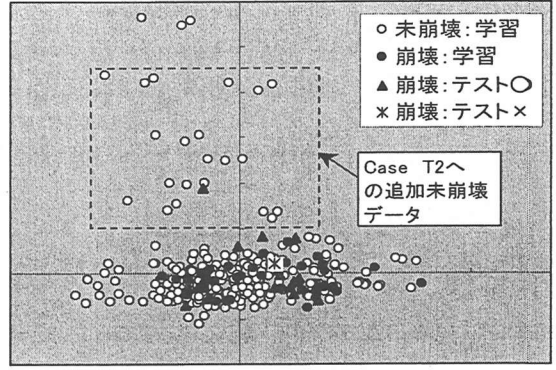


c)Csae T3

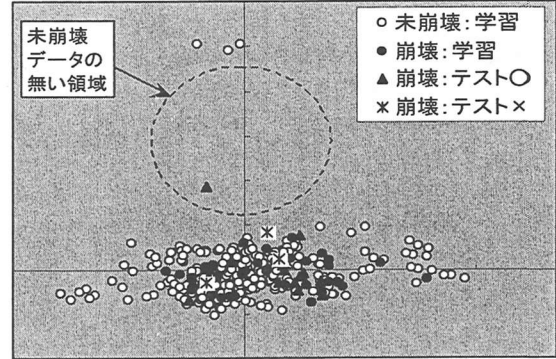
図-9 数量化Ⅲ類による崩壊・未崩壊データの分布 (堆積岩)

崩壊のテストデータのうち正判別したデータを、×は誤判別したデータを示している。なお、本研究では、数量化Ⅲ類による崩壊・未崩壊データの分布状況を相対的に評価することを目的としているため、図の縦、横軸の数値は示していない。

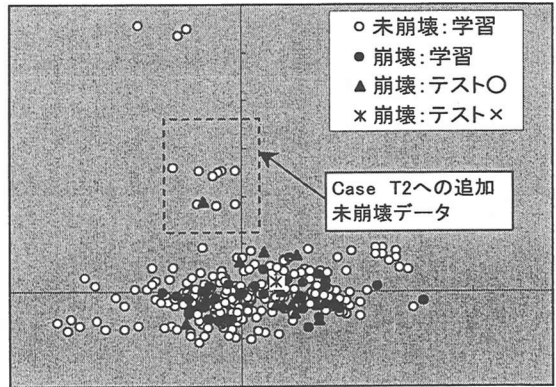
図-9の堆積岩における分類結果を見ると、Case T1,T2,T3の未崩壊データの分布状況には大差はなく、未崩壊データはほぼ均等に入力されていることが分かる。このことから、各ケースにおける崩壊のテストデータの正解、不正解は、非常にローカルな分布に左



a)Csae T1



b)Csae T2



c)Csae T3

図-10 数量化Ⅲ類による崩壊・未崩壊データの分布 (火成岩)

右されていると推察される。

次に、図-10の火成岩の分布図を見ると各ケースとも χ 軸近傍に比較的集中しているが、崩壊の判別結果が悪いCase T2はCase T1,Case T3に比べ図中○で囲った部分に未崩壊データが分布していないことが分かる。このことが崩壊データの判別結果に影響している可能性が高いと推察される。よって、Case T2の○で囲った部分に対応するデータをCase T1,Case T3のデータより追加し(図中□で囲った部分)システムの再構築を行った。その学習結果及び

表-14 堆積岩 CaseT2の再構築結果

評価項目		Case T2		Case T2 (再構築)	
		学習	テスト	学習	テスト
判別結果	崩壊 (%)	37/37 100	16/19 84.21	37/37 100	16/19 84.21
	未崩壊 (%)	721/721 100	132/133 99.25	721/721 100	132/133 99.25
学習回数		328		356	
平均2乗誤差		0.00010		0.00010	

崩壊・未崩壊データに対する判別結果を表-14に示す。表-14から明らかのようにデータを追加したことによる判別精度の向上は見られなかった。これらのことから、火成岩においては x 軸近傍に分布するデータが支配的で、図中○印で囲った領域の影響はないことが分かる。また、 x 軸近傍の未崩壊データはいずれのケースとも同じ様な分布をしており、崩壊のテストデータの正解、不正解は、非常にローカルな分布に左右されていると推察される。

以上のことから、火成岩、堆積岩における崩壊のテストデータの判別は、非常にローカルなデータの分布に左右されている可能性が高く、図-6、図-7の感度解析結果に見られたような明瞭な特性は見られない。しかし、図-9、図-10の分布が示すように、未崩壊データを削減したモデルでは未崩壊データが均等に抽出されたことで、基本モデルと同等以上の安定した結果が得られたものと推察される。

6. おわりに

本研究では、実際に道路公団中国支社で管理されている標準化されたのり面データベースと降雨要因を用い、最適化手法としてニューラルネットワークを用いた豪雨時ののり面崩壊発生予測システムの構築を試みた。その際、未崩壊のり面に対する未崩壊降雨の設定方法を検討するとともに、学習方法及び教師データを工夫することで予測システムの精度向上をはかった。以下にその結論を列記する。

(1) 本研究で用いた標準化されたのり面データベースと降雨要因を用いた切土のり面の崩壊・未崩壊判別システムでは、未学習の崩壊データに対して、堆積岩で70%、火成岩で84%もの崩壊時刻での高い判別率が得られ、1時間前では堆積岩で40%、火成岩で63%の判別(予測)率が得られた。未崩壊降雨では、堆積岩で93%、火成岩で96.5%ののり面で降雨継続中常に未崩壊と判別することが可能であった。

(2) リアルタイムの崩壊判別予測では、降雨の降り始めでは、未崩壊と判別し、崩壊発生時刻付近では崩壊

確信度が上昇し崩壊と判別し、その後確信度の下降が見られる。さらに、崩壊確信度の変化は、個々ののり面で異なるため、のり面ごとに崩壊可能性の評価が可能である。

(3) このように、本予測システムは高い精度で、いつ、どこかののり面の崩壊可能性が高いか予測することが可能である。

(4) 未崩壊降雨の設定方法として、未崩壊のり面の過去の経験降雨や、崩壊発生のり面での崩壊発生以前の経験降雨など数多くの降雨の抽出が可能となるが、本研究で構築した判別システムにおいては未崩壊降雨として、未崩壊のり面の累積雨量を基準とした過去最大経験降雨を用いることが最も有効であることが明らかとなった。

(5) 本研究で対象としたような崩壊・未崩壊データのデータ数に格差がある場合の判別システムの精度向上手法として、荒木らが提案した n 倍学習法に加え、未崩壊データを削減する(未崩壊データ削減モデル)ことも有効であることが分った。

(6) 未崩壊データ削減モデルでは、組み合わせる未崩壊データに判別精度が影響されるが、未崩壊データを均等に抽出することで、十分な判別精度が得られ、加えて学習状況の改善が見られた。

(7) その結果、未崩壊データ削減モデルでは、未崩壊降雨における降雨継続中の未崩壊判別率は若干低下するものの、未学習の崩壊のり面に対して、堆積岩で85.2%、火成岩で94.8%と降雨継続中における崩壊時刻での非常に高い判別率が得られた。

このように、最適化手法としてニューラルネットワークを用いることで実際に道路公団で管理されている標準化されたのり面データと降雨要因を用い降雨時に個々ののり面ごとに高精度でリアルタイム崩壊発生予測が行えるシステムの構築が可能である。

実際の防災管理では、現在の降雨基準による路線全域での防災管理に加え、本判別システムを用いることで、降雨継続中にリアルタイムで路線内のどののり面で崩壊発生の可能性が高いか判断が可能であり、防災管理を効率的かつ効果的に行うことが可能である。

精度の向上手法として有効性が示された未崩壊データ削減モデルでは、未崩壊データを適宜削減し適切な未崩壊データを用いることで、判別精度が向上する可能性が高いことが明らかとなった。しかし、その反面未崩壊データの削減、選定方法によっては逆に判別精度の低下が懸念される。

現在、非線形性の強いデータから類似性の高いデータを抽出する方法として自己組織化特徴マップ⁹⁾が注

目され斜面崩壊にも適用された事例⁹⁾も見られる。さらにデータ探索法としてデータマイニング手法¹⁰⁾も注目をあびている。今後これらの手法を参考に、未崩壊データの有効な抽出方法を検討することで安定した判別精度の向上が可能であると思われる。

参考文献

- 1) 菊池英明, 古川浩平, 大前伸司, 奥園誠之, 神谷誠: ニューラルネットワークを用いた降雨継続中の変成岩地山の切り土のり面におけるリアルタイムの崩壊・未崩壊の予測システムに関する研究, 土木学会論文集, 第574号/VI-36, pp. 57-72, 1997. 9.
- 2) 菊池英明, 古川浩平, 大前伸司, 奥園誠之, 西岡勲: ニューラルネットワークによる切土のり面の豪雨時のリアルタイム崩壊予測と予測に用いる降雨要因に関する一考察, 第616号/VI-42, pp. 63-76, 1999. 3.
- 3) 西邦正, 古川浩平, 中川浩二: ファジ理論を用いたのり面の崩壊要因および崩壊可能性の評価について, 土木学会論文集, 第445号/III-18, pp. 129-118, 1993. 12.
- 4) 西邦正, 古川浩平, 小川健, 中川浩二: 豪雨時における切土のり面の崩壊誘因評価と崩壊・未崩壊の判別につ

- いて, 土木学会論文集, 第480号/VI-21, pp. 127-136, 1993. 12.
- 5) 奥園誠之: 切土のり面の設計から維持管理まで, 鹿島出版会, 1983.
- 6) 荒木義則, 鈴木昌治, 宮崎智司, 日永田雅司, 古川浩平, 中川浩二: ニューラルネットワークを用いたNATM施工時の支保パターン選定構造のモデル化に関する研究, 土木学会論文集, 第522号/VI-28, pp. 143-153, 1995. 9.
- 7) 荒木義則, 古川浩平, 松井範明, 大木戸孝也, 石川芳治, 水山高久: ニューラルネットワークを用いた土石流危険渓流における土砂崩壊のリアルタイム発生予測に関する研究, 土木学会論文集, 第581号/VI-37, pp. 107-121, 1997. 12.
- 8) 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.
- 9) 白木渡, 長瀬裕俊, 宮下英明, 伊藤利夫: 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.
- 10) 例えば, 河野浩之: 知識発見とデータマイニング, 日本ファジイ学会誌 Vol19, No6, pp. 851-867, 1997. 12.

(1998. 9. 2. 受付)

A SYSTEM FOR FORECASTING CUT-OFF SLOPE COLLAPSE DURING HEAVY RAIN USING STANDARD DATA BASE AND RAINFALL FACTORS

Hideaki KIKUCHI, Kohei FURUKAWA, Yasuo OYAMA,
Seishi OKUZONO and Isao NISHIOKA

Recently, the standard data base of cut-off slope has been tidied up by the Japan Highway Public Corporation Branch of Chugoku base on the data form each stage of the investigation, design, and construction. And the rainfall data can be recorded at the observatory of the Meteorological Agency or the Japan Highway Public Corporation. The collapse of cut-off slopes in heavy rain is caused by slope evaluation factors as well as rainfall factors. Therefore, we expect the system to forecast the collapse of cut-off slope using the standard data base and the rainfall data effectively.

In this research, we have constructed a system using the given data for application to real time forecasting in actual heavy rain. We present the considered points to construct a forecasting system using standard data base of cut-off slope.