

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

菊池英明¹・古川浩平²・大前伸司³・奥園誠之⁴・神谷誠⁵

¹正会員 工修 山口大学助手 工学部社会建設工学科 (〒755 山口県宇部市常盤台2557)

²正会員 工博 山口大学教授 工学部社会建設工学科

³学生会員 山口大学大学院 工学部社会建設工学科

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1号)

⁵正会員 日本道路公団 中国支社 鳥取調査事務所(〒680 鳥取市東町1丁目308県庁東町分庁舎)

豪雨時における切り土のり面の崩壊は、素因としての地形・地質・土工の斜面要因にある限界以上の誘因(降雨要因)が作用することにより発生する。従来、切り土のり面の崩壊危険度評価には降雨量を指標とするものが多く、素因、降雨要因を考慮したものは少ない。本研究では変成岩(黒色片岩)地山の切り土のり面(斜面)に対して、素因と降雨要因とを加味したニューラルネットワークを用いたリアルタイムの斜面崩壊予測システムを構築した。その際、一連の降雨の中で、学習データの効率的な作成方法及び最適な降雨要因の組み合わせを検討し、予測システムの信頼性向上を計った。

Key Words : cut-off slope failure ,heavy rain forecasting collapse ,neural network

1. はじめに

近年、高速道路網の整備に伴う高規格道路が数多く建設されている。山地部が国土の8割を占める我が国の国土事情を考えると、これらの高速道路網の整備に伴い切り土のり面数は今後さらに増加するものと考えられる。このような現状の中、各地で豪雨によるのり面崩壊が発生し、交通障害を引き起こすなどの災害が発生している。したがって、これら多くののり面の日常の維持・管理に加え防災管理を効率的かつ適切に行うことがますます重要となると考えられる。

現在、降雨継続中の切り土のり面の防災管理は主に降雨量に基づき実施され、管理基準として、一時間最大雨量や累積雨量が一般的に用いられている。西、古川らによる降雨により崩壊した切り土のり面を対象とした研究^{1)・2)}によれば、切り土のり面の崩壊は、「のり面評価表」³⁾により示された切り土のり面の斜面評価要因(素因)に加え、降雨に関する要因(誘因)により発生することが示され、素因と誘因の組み合わせによる切り土のり面の個別評価の方向性が示された。降雨要因に関しては、降雨の量に関する指標に加え、降雨の降り方が重要であることが示された。また、重判別分析を用いた降雨継続

中の崩壊・未崩壊の判別システムを用い、様々な降雨に対して崩壊を引き起こす降雨であるか否かを判別できることが示された。しかし、このシステムでは、崩壊降雨に対して降雨の降り始めから高い確率で崩壊と判別するため、のり面崩壊が「いつ」発生するのかの判別が難しい。実際の降雨継続中の防災管理では、崩壊危険度に応じた適切な防災管理、対策を行うことが必要である。そのためには、のり面崩壊が「いつ」「どこで」発生するのかを的確に予測できるシステムの構築が必要である。

本研究では、切り土のり面の崩壊が斜面要因と降雨要因の組み合わせにより発生することから、最適化手法としてパターン認識に優れているニューラルネットワークを用いて崩壊・未崩壊の判別システムの構築を行い、切り土のり面の崩壊可能性評価への適用性について検討を行う。その際一連の降雨データの中から効率的な学習データの抽出方法及び最適な降雨要因の組み合わせを提案し、リアルタイムでの崩壊・未崩壊予測システムの信頼性向上手法について検討する。

2. 崩壊予測に関する既往の研究

現在、斜面崩壊に関する研究の多くは、自然斜面について行われている。特に崩壊発生誘因である

降雨に関しては、時間雨量、一時間最大雨量、有効雨量⁹⁾や降雨強度勾配比⁹⁾等の短期雨量指標および前期雨量、累積雨量や実効雨量⁹⁾等の長期雨量指標の両者の関係を用い、実際に崩壊を引き起こした降雨データに基づき崩壊予測や警戒・避難基準雨量設定が行われている。また、鉄道防災においても降雨を基準とした危険度評価⁷⁾及び規制雨量⁹⁾の検討が行われている。しかし、これらは降雨観測域に準じた流域単位、地域単位の基準である。そのため一単位内のどの斜面で崩壊が発生するかまでは特定することができない上、空振り率が高い等の多くの問題が残されており、いまだ実用化には至っていない。このように、誘因(降雨)のみにより崩壊予測及び管理基準を設定するには、限界があると考えられる。

次に、斜面要因(素因)に関して建設省では地形、地質要因による溪流の危険度評価⁹⁾が実用化され、土石流危険溪流調査が全国的に行われているが、データの蓄積にとどまっているのが現状である。一方、多変量解析を用いた土石流発生危険度の判別解析¹⁰⁾やファジィ理論等の最適化手法を用いた崩壊規模の予測^{11)・12)}も研究され、斜面崩壊の可能性と素因との関係が評価されている。しかしながら、素因のみの分析では斜面崩壊の可能性を十分評価できていないのが現状である。

これらの、素因、誘因のみの評価に対して、タンクモデル法等により降雨に地形・地質要因を考慮した流出過程を導入し、個々の溪流(自然斜面)の流出特性を考慮に入れた基準設定を行う研究が行われている¹²⁾。しかし、個々の溪流(斜面)の実績流量のデータが非常に少ないこと、流量変換過程に多くの誤差が含まれることなどから実用性に問題があると考えられる。また、物理モデルを適用し解析的に崩壊予測および危険度評価を行う試みも行われている¹³⁾が適切な解析モデルの評価が難しく、加えて全国的にこのモデルを適用するには大変な労力を必要とし実用的とは言えない。

本研究では素因と誘因の両者を用い現状で入手できるデータを用いて斜面の崩壊予測を行いうる手法を示す。

3. 使用データと評価要因

(1) 切り土のり面データ

次節に示すのり面評価要因により評価された変成岩(黒色片岩)地山で構成される12個のデータを用いる。ここで評価に使用された資料は、高速道路の調査、設計、施工および管理に携わる専門技術者




図-1 のり面ごとの崩壊・崩壊前降雨の累積雨量(崩壊・崩壊前降雨ともに降雨終了時までの累積)




図-2 のり面ごとの崩壊・崩壊前降雨の一時間最大雨量




図-3 のり面ごとの崩壊・崩壊前降雨の累積雨量(崩壊降雨では崩壊発生時までの累積、崩壊前降雨では一時間最大雨量発生時刻までの累積)

が供用中降雨時に崩壊した際の現地調査結果に基づいて記述した定性的・主観的表現による資料と、工事報告書である。

(2) 降雨データ

「崩壊」に対応する降雨データはのり面崩壊発生日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は崩壊発生以前にそののり面では未崩壊であった降雨資料より、累積雨量を基準に以下の3種類作成し、「崩壊前降雨1」～「崩壊前降雨3」とした。

降雨1:のり面崩壊以前に第一番目に多かった雨量
降雨2:のり面崩壊以前に第二番目に多かった雨量
降雨3:のり面崩壊以前に第三番目に多かった雨量

ここで、基本となる雨量データは気象庁観測の時間雨量データを用い無降雨期間が8時間以内の降雨（日本道路公団中国支社管内の一連続降雨の基準）を連続降雨とした。また、崩壊降雨の対象とした連続降雨は崩壊前降雨の対象から除いた。図-1にのり面1～12の崩壊降雨、崩壊前降雨1～3の降雨終了時の累積雨量の比較を示し、図-2に一時間最大雨量の比較を示す。図-1、図-2から分かるようにのり面1,6及びのり面8～10は同じ崩壊降雨により崩壊しており崩壊前降雨の組み合わせも同じである。

図-1の累積雨量ではのり面4,5以外ののり面では崩壊前降雨の累積雨量の方が崩壊降雨より大きいことを示している。また、図-2の一時間最大雨量ではのり面3～5は崩壊降雨の方が大きく、のり面7～10,12は同じくらいであることを示している。ここで、一般にのり面の崩壊は一時間最大雨量付近で発生していることから、崩壊降雨については崩壊発生時刻又は推定時刻（一時間最大雨量発生時刻）まで、崩壊前降雨については一時間最大雨量発生時までの累積雨量の比較を図-3に示す。

図-3の累積雨量の比較ではのり面5,8～10で崩壊降雨の方が大きく、のり面12では同じくらいであることを示している。

これらのことから、のり面3～5,7～10,12では累積雨量、一時間最大雨量、一時間最大雨量発生時刻までの累積雨量の何れかが崩壊前降雨に比べ崩壊降雨の方が大きいかまたは、同じくらいであり、降雨から見た場合崩壊発生は妥当であると考えられる。一方、残りの4のり面では崩壊発生以前に崩壊降雨より大きな規模の降雨を経験しているにも関わらず崩壊を免れていることもわかる。

(3) のり面評価要因

切り土のり面の評価要因は「のり面評価表」³⁾で用いられた地質・地形要因（A～G）、土工要因（H～J）に地山やのり面保護工の風化・劣化との関連性からK:供用年数を加えた11要因を用いた。「のり面評価表」³⁾で用いられた地形・地質要因、土工要因を以下に示す。

・地質・地形要因

A:地山地質, B:土質分類, C:節理等の状態,
D:節理等の傾斜, E:被覆層・風化層の厚さ,
F:地下水・湧水の状態, G:降雨水の集中度

・土工要因

H:のり高さ, I:のり勾配, J:のり面保護工

これらのA～Jの各要因は工学上 Very Low（非常に良好な状態で崩壊可能性は非常に低




図-4 降雨模式図

い）から Very High（非常に不良な状態で崩壊可能性は非常に高い）までを、1, ..., 5の評価ランクとしてカテゴリ区分したものである。供用年数は供用開始後から崩壊降雨・崩壊前降雨発生時までの供用年数である。また同一のり面については、崩壊と未崩壊時の地形要因の差はない。

(4) 降雨要因

降雨要因として、参考文献¹⁾及び降雨継続中のリアルタイム予測を考慮して、L:一時間雨量、M:累積雨量、N:降雨継続時間、O:降雨パターンを採用した。以下にその内容について記す。

L:一時間雨量

崩壊降雨では崩壊時刻の明確なものも崩壊発生時の一時間雨量、不明なもの及び崩壊前降雨では一時間最大雨量とする。

M:累積雨量

一時間雨量採用時刻までの雨量の累積値

N:降雨継続時間

累積雨量に対応した継続時間

O:降雨パターン¹⁾

対象とする降雨の降り方により、前半集中型（パターン1）、中盤集中型（パターン2）、後半集中型（パターン3）に分類したものである。目視による降雨パターンの分類は非常に曖昧性が高い。よって本研究では、図-4の降雨模式図に示すように降雨期間を前半、中盤、後半に3等分し、各区分の累積雨量を算出した。その結果、累積雨量の最も多い区分が前半であれば、パターン1、中盤であればパターン2、後半であればパターン3とした。

4. ニューラルネットワークを用いた崩壊・未崩壊の判別システムの概要

(1) ニューラルネットワークの概要

生物の脳にはニューロン（神経細胞）が非常に多く集まっており、個々のニューロンはシナプス結合




図-5 ニューロンのモデル化

と呼ばれる結合でつながって回路を作っている。そのため、各ニューロンは多数の他のニューロンからシナプスを通して正負両方の刺激を受け、その刺激がある値（しきい値）を越えると、今度は自らが他のニューロンへと刺激を与えていき、情報を次々と伝達して行く。

ニューラルネットワークとはこの脳の中で行われている情報処理を模擬したものであり、工学的に応用しようとして研究・開発されたシステムである。

従来のノイマン型のコンピュータアルゴリズムでは論理的な情報処理しか出来なかったのに対し、ニューラルネットワークは学習・記憶・判断といった直感的な処理が可能となっている。また、ニューラルネットワークの最大の特徴は学習によって自らのパターン認識能力を高めることが出来ること、非線形な連続関数を近似することが可能であることである。

図-5はニューロンを数学的にモデル化したものである。このニューロンモデルを多数結合し、ネットワークを構成した数理モデルが実際に使われるニューラルネットワークである。本研究では、図-6に示すような入力層、中間層、出力層からなる階層型ネットワークを用いる。これら入力層、中間層、出力層の各ニューロンはシナプス結合で結ばれており、ニューロンの刺激を入力層から出力層へと順次伝わるようになっていく。刺激の強さはニューロンやシナプスを伝わる間にしきい値や重み付けにより変化する。すなわち、このしきい値や重み付けを適当に変化させることによって、さまざまな入出力関係を実現することができる。

本研究では、しきい値や重み付けに関わるニューロンの応答特性を表す入出力関数として、代表的なモデルである式(1)に示すシグモイド関数を用いる。

$$f(u_i) = \frac{1}{1 + \exp(-u_i)} \quad (1)$$




図-6 ニューラルネットワークの構造

$$u_i = \sum_{i=1}^n \omega_i \cdot x_i - \theta \quad (2)$$

ここで、 $f(u_i)$ はニューロンの出力値（刺激）、 x_i は入力値、 ω_i は重み付け係数、 θ はしきい値、 n は入力層のユニット数である。このとき、ある入力パターン c を与えたときの実際の出力値 $f(u_{k,c})$ と理想出力値（教師信号） $d_{k,c}$ との2乗誤差の総和は、次式のように表される。ここで、 nc は出力ユニット数である。

$$E = \frac{1}{2} \sum_{k=1}^{nc} (f(u_{k,c}) - d_{k,c})^2 \quad (3)$$

また、学習方法としてバックプロパゲーションを適用しネットワークの最適化を行った。この学習方法は、この誤差 E を修正するために、最急降下法で重み付けやしきい値の調整を出力層から入力層へ逆に伝搬させる方法である¹⁴⁾。通常、入出力が1組となった複数の学習データを、順番に入力してバックプロパゲーションを行う操作を1回の学習と呼び、連続して学習を続けることにより、重み付けやしきい値を徐々に変化させて教師信号との誤差を減らしていく手法である。

(2) 基本システムの構築

ネットワークモデルの基本構造は既述したように図-6に示すような入力層、中間層、出力層の3階層からなる階層型ネットワークである。図-7に本研究で用いたニューラルネットワークの基本構造を示す。入力層は、カテゴリーニューロンと数値ニューロンで構成されている。カテゴリーニューロンとは[0]または[1]の値を与えるニューロンであり、要因のカテゴリー区分1つ1つに対応させている（図中■で示す）。そして数値ニューロンとは実数値を与えるニューロンであり、データの最大値が[1]となるように基準化し[0]～[1]の数値を入力する（図中□で示す）。これら、各ニューロンに対して入力デー




図-7 ニューラルネットワークモデル

タは図-7に示すように斜面要因(A ~ J)及び降雨パターン(O)をカテゴリーデータとし、供用年数(K)及びリアルタイムの判別に際し降雨の経時変化を的確にシステムに反映できるように、降雨量に関する要因(L ~ N)を数値データとした。

出力層は、「崩壊」を示す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。

中間層のニューロン数は、学習方法としてバックプロパゲーションを用いる場合、現在のところ適切な数を決定する確立された方法がないとされている^{15)・16)}。本研究では、中間層の個数を数種変化させて計算を行い、それらの学習の収束状況から中間層のユニット数を6個とした。収束条件は学習回数 10,000 の制約の下で平均2乗誤差:E < 0.001 とした。

5. 降雨要因の抽出方法と崩壊・未崩壊の判別特性について

(1) 降雨要因(学習データ)の抽出方法

ニューラルネットワークの特性から学習データの良否が判別結果に大きく影響することから、一連の崩壊・崩壊前降雨の中から崩壊・未崩壊の判別に有効なデータの抽出方法について検討を行う。

崩壊・崩壊前降雨の参考例として図-8にのり面1




図-8 崩壊降雨での学習データの採用例(のり面1)




図-9 崩壊前降雨での学習データの採用例(のり面3)

表-1 学習データ個数

種別 ケース	崩壊データ			未崩壊データ			無降雨 データ	データ 総数
	H1	M1	M2	M3				
Case A	12	36	—	—	—	—	12	60
Case B	12	36	36	—	—	—	12	96
Case C	12	36	36	6	—	—	12	102

注)M3に対応するのり面は1,5,6,8,9,10である。

の崩壊降雨、図-9にのり面3の崩壊前降雨1を示す。図-8、図-9には時間雨量の経時変化を棒グラフで示し、累積雨量の経時変化を折れ線グラフで示している。

崩壊データは、降雨継続中の崩壊時刻の判定を考慮し、一連の崩壊降雨のうち図-8のH1に示す崩壊発生時刻または崩壊発生推定時刻(一時間最大雨量発生時刻)の降雨要因を用いる。

これに対して、未崩壊データは、崩壊降雨の崩壊発生時刻以前の全てのデータと崩壊前降雨の降雨開始から終了までの全てのデータを用いることが可能である。従って、未崩壊データは一連の未崩壊領域全域と考えられデータ数が膨大となる。よって、未崩壊領域の特性を適切に捕捉した効率的な学習データの選定が必要となる。

一般に時間雨量、累積雨量が大きくなるにつれ崩壊可能性が大きくなるとされている。過去の例からすると一時間最大雨量発生時刻付近で崩壊が多く発生している。これらのことから一連の崩壊前降雨の中から、図-9のM1に示す一時間最大雨量発生時刻とM2に示す累積雨量が最大となる降雨終了時を未崩壊データ抽出の対象時刻とするのが妥当であろう。一方崩壊降雨でも、崩壊発生時刻以前に一時間最大

表-2 学習データ (Case A:崩壊データ)

のり面 番号	地質・地形要因						土工要因				時間要因	崩壊降雨			
	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
	地山 地質	土質 分類	節理 等 状態	節理 等 傾斜	被覆 風化 層厚	地下水 湧水	降雨 の 集中度	のり の高さ	のり 勾配	のり 保護	経過年数 (年)	時間 雨量 (mm/h)	累積 雨量 (mm)	継続 時間 (h)	降雨 パターン
1	4	4	5	5	4	2	3	1	2	2	11	16	149	50	3
2	4	3	4	3	4	5	2	3	4	4	5	21	93	14	3
3	4	4	3	4	4	5	2	5	4	3	6	37	79	5	3
4	3	3	3	3	3	5	2	4	3	2	10	25	56	9	3
5	5	5	5	2	3	5	4	4	5	2	0	24	134	5	2
6	2	2	2	5	4	3	3	2	3	3	11	16	149	50	3
7	3	3	3	5	4	2	2	2	2	4	2	25	81	5	3
8	3	3	3	5	4	2	2	1	2	4	11	11	100	18	3
9	3	3	3	4	3	5	2	4	3	2	11	11	100	18	3
10	3	3	3	3	3	5	1	3	2	3	11	11	100	18	3
11	4	4	4	4	4	4	1	2	2	1	3	17	111	14	3
12	3	3	3	4	2	4	4	2	3	2	12	23	53	16	3

表-3 学習データ (Case A:未崩壊データ)

のり面 番号	崩壊前降雨1					崩壊前降雨2					崩壊前降雨3				
	降雨要因					降雨要因					降雨要因				
	K	L	M	N	O	K	L	M	N	O	K	L	M	N	O
経過年数 (年)	時間 雨量 (mm/h)	累積 雨量 (mm)	継続 時間 (h)	降雨 パターン	経過年数 (年)	時間 雨量 (mm/h)	累積 雨量 (mm)	継続 時間 (h)	降雨 パターン	経過年数 (年)	時間 雨量 (mm/h)	累積 雨量 (mm)	継続 時間 (h)	降雨 パターン	
1	4	21	60	21	3	8	26	54	17	3	7	39	166	17	3
2	1	21	43	4	3	4	22	55	19	3	0	45	118	5	3
3	1	21	43	4	3	4	22	55	19	3	5	12	136	65	3
4	1	21	43	4	3	4	22	55	19	3	5	12	136	65	3
5	0	17	34	5	3	0	16	38	10	3	0	15	41	12	3
6	4	21	60	21	3	8	26	54	17	3	7	39	166	17	3
7	0	29	135	33	3	2	17	35	4	3	0	30	68	25	3
8	10	25	56	9	3	1	21	43	4	3	4	22	55	19	3
9	10	25	56	9	3	1	21	43	4	3	4	22	55	19	3
10	10	25	56	9	3	1	21	43	4	3	4	22	55	19	3
11	2	56	341	45	3	1	35	229	39	3	2	25	195	21	2
12	10	25	56	9	3	1	21	43	4	3	4	22	55	19	3

雨量が発生したような場合等、崩壊の危険性が高いにも関わらず実際の崩壊発生時刻まで崩壊を免れているのり面もある。このことから崩壊降雨で図-8のM3に示すような崩壊発生時刻以前の一時間最大雨量など明確な時間雨量のピークがある場合、その時刻も未崩壊データの抽出対象時刻とする。

以上の未崩壊データ採用対象時刻 (M1 ~ M3) から、データの選定の容易性を考慮し未崩壊データの抽出ケースとして次の3ケースを設定した。崩壊データの採用時刻は全ケースともH1である。

- Case A:未崩壊データ採用時刻 =M1
- Case B: " =M1+M2
- Case C: " =M1+M2+M3

また、無降雨状態では明らかに未崩壊であるため、無降雨を示す降雨要因として一時間雨量=0(mm/h)、累積雨量=0(mm)、降雨継続時間=0(h)、降雨パターン3を未崩壊データとして各ケースに追加すること

とした。

従って、Case A~Case Cの学習データ個数は表-1の通りとなる。ここで、M3の未崩壊データに対応するのり面はのり面1,5,6,8,9,10の6個である。

(2)学習データ及び学習結果

学習データは、既述の変成岩地山の12個の切り土のり面ののり面評価要因と降雨要因とを組み合わせ作成する。

参考例としてCase Aの「崩壊」の学習データを表-2に示す。「未崩壊」の学習データではのり面評価要因は崩壊データと同じであるため供用年数と降雨要因のデータのみを表-3に示す。ニューラルネットワークを用いたシステムの良否を示すには、のり面データを学習データとテストデータに分け、学習データを学習させた上で、未学習のテストデータの判別結果により判別システムの信頼性の検討を行う必要がある。しかし本研究では、のり面データ数が

表-4 学習結果

項目		Case A	Case B	Case C
判別結果	崩壊降雨	12/12	12/12	6/12
	未崩壊降雨	36/36	72/72	78/78
学習回数	無降雨データ	12/12	12/12	12/12
	全体	60/60	96/96	96/102
学習回数		849	860	10000
2乗誤差(E)		0.00100	0.00093	0.03136




図-10 崩壊学習データに対する崩壊確信度




図-11 未崩壊学習データに対する崩壊確信度(Case A)




図-12 未崩壊学習データに対する崩壊確信度(Case B)

12個と少ないことと、学習データは降雨継続中の全てのデータではなく、一時間最大雨量発生時刻及び降雨終了時のデータのみであり、それらの学習結果を未学習の降雨継続中の全データに対して適用することによりシステムの信頼性の検討を行うことから、各ケースとも全てののり面を学習データとした。

表-4に学習結果を示す。表-4に示すように Case A, Case B では収束条件 $E=0.001$ を満足し学習が終了し、全ての「崩壊」、「未崩壊」の学習データに対し正解を与えている。しかし、Case C では学習回数 10000 回では収束条件を満足せず、「崩壊」に対する判別結果も半数ののり面で誤判別している。図-10にこの時の Case A ~ Case C の崩壊確信度を

示す。図-10より Case C の誤判別はのり面 1, 5, 6, 8, 9, 10 であることが分かる。この誤判別のり面は未崩壊追加データ M3 を学習させたのり面であり、M3 データが崩壊データ HI に類似しているために誤判別が生じたものと考えられる。

このように Case C では学習が十分に行われず、M3 の影響で崩壊発生時刻の判別が難しい。従って、Case C の降雨要因の抽出方法は Case A, B に比べ不適切であると考えられる。

次に図-10により Case A, B の崩壊確信度を比較すると、両ケースの崩壊確信度はのり面 8 を除いて差は少なく、かつ確信度は 0.8 以上と高い。また Case A, B とも崩壊の学習データに対しては明確に崩壊の判別がなされている。

未崩壊データの Case A の崩壊確信度を図-11に示し、Case B の崩壊確信度を図-12に示す。ここで、図-11、図-12の崩壊確信度は一時間最大雨量時(M1)に対応した結果である。

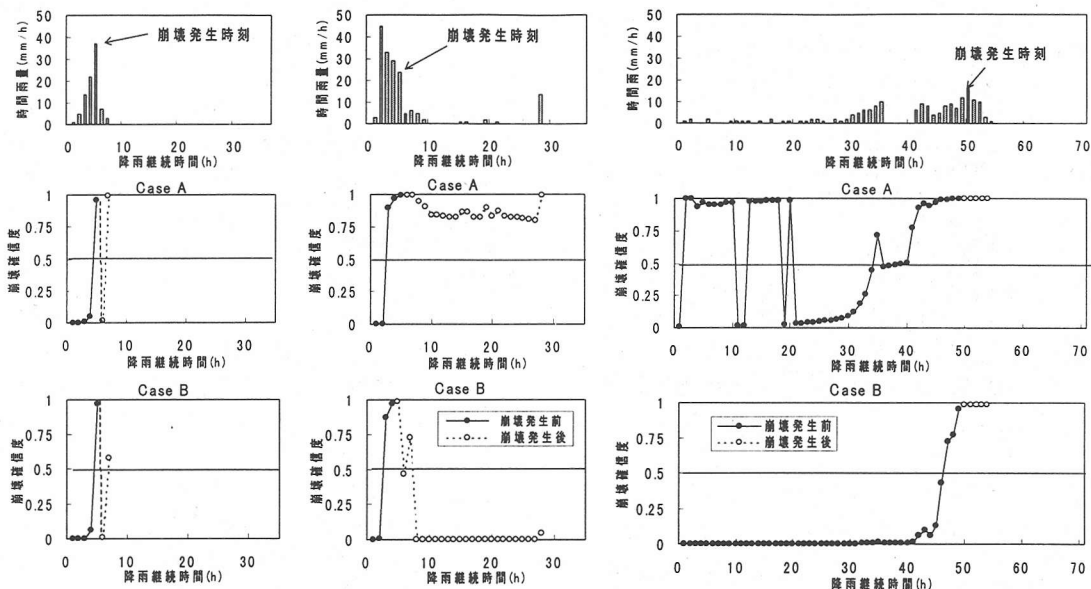
図-11、図-12に示した崩壊確信度の上限値は 0.0467 と非常に小さく、未崩壊の学習データに対して明確に未崩壊と判別している。また、図-11、図-12から分かるように、全般的には Case A に比べ Case B の方が崩壊確信度が低く、より明確に未崩壊と判別していることが分かる。

(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の判別は、雨の降り始めからの 1 時間ごとの降雨要因とのり面評価要因のデータを、学習が終了した判別システムに入力し得られる崩壊確信度の経時変化により行う。このとき、ニューラルネットワークの学習が十分に行われ、のり面評価要因、降雨要因の組み合わせによりのり面の崩壊・未崩壊パターンをうまく認識していれば、崩壊降雨に対しては降雨の降り始めは「未崩壊」と判別されるが、崩壊推定時刻には崩壊確信度が上昇し「崩壊」と判別される。崩壊前降雨においては、雨の降り始めから降り終わりまで崩壊確信度は上昇せず常に「未崩壊」と判別されると考えられる。また、崩壊を予測するという観点から考えると、崩壊発生時刻 2~3 時間前より崩壊確信度が上昇し、崩壊可能性が高いと判別できることが重要である。

しかし、のり面評価要因のみにより崩壊・未崩壊パターンを認識した場合、降雨量によらず雨の降り始めから崩壊降雨では崩壊と判別し、崩壊前降雨では未崩壊と判別する可能性が考えられる。

従って、本研究では、学習が十分に行われた Case A, Case B について「崩壊」、「未崩壊」の判別状況と崩壊予測の状況からニューラルネットワー



a)のり面3 b)のり面5
 図-13 崩壊降雨における崩壊確信度の経時変化
 (短時間降雨での崩壊例)

図-14 崩壊降雨における崩壊確信度の経時変化
 (長時間降雨での崩壊例 (のり面1))

クを用いた判別システムの崩壊予測への適用可能性について評価を行う。

a) 崩壊降雨における判別傾向と評価

図-13に短時間集中型の降雨での崩壊例 (のり面3,5), 図-14に長時間連続降雨での崩壊例 (のり面1), 図-15に両者の中間的な連続降雨での崩壊例 (のり面8,11)における雨の降り始めからの崩壊確信度の経時変化とそれに対応する降雨の一時間雨量の経時変化を示す。図中の崩壊確信度の●は崩壊発生時刻までの崩壊確信度を, ○は崩壊発生後の崩壊確信度を示している。

図-13の短時間集中型の降雨で崩壊したのり面3は崩壊発生時刻が不明確であったため一時間最大雨量の時刻を崩壊時刻と設定した例, のり面5は崩壊発生時刻が明確であった例である。

図-13から明らかなように, いずれののり面においても崩壊発生時刻には確信度がほとんど1.0になる的確に崩壊と判別している。また, のり面5ではCase A, Case Bともに崩壊発生時刻3時間前から崩壊確信度が急激に上昇し, 0.8以上と非常に高い確信度で崩壊発生時刻まで崩壊と判別している。このように, 崩壊発生の数時間前から崩壊と判別することが可能であることから, 崩壊発生を事前に予測する事が可能であると考えられる。そして崩壊発生後にはCase Bは崩壊確信度が下がっており, Case Aに比べ崩壊時刻を的確に示している。

次に図-14の長時間連続型の降雨における判別傾向を見ると, Case Aでは雨の降り始めの雨量の少ない期間に崩壊確信度が上昇し崩壊と誤判別している。その後雨量の変化に追従して崩壊確信度が変化し, 崩壊時刻の7時間前より再び崩壊確信度が上昇し, 崩壊直前では0.9以上と非常に高い確信度で崩壊と判別している。Case BはCase Aのような雨の降り始めに崩壊と誤判別することはなく, 崩壊時刻2時間前から崩壊確信度が上昇し崩壊と判別している。

図-15の中間的な連続降雨で崩壊したのり面8は崩壊時刻が明確であった例, のり面11は崩壊時刻が不明確であったため一時間最大雨量の時刻を崩壊時刻と設定した例である。

図-15ではのり面8のCase Bで崩壊時刻での崩壊確信度の若干の低下は見られるがCase A,Bのいずれのケースも崩壊発生時刻までは図-14の長時間連続降雨と同様の傾向を示している。崩壊発生後Case Bでは崩壊確信度が下降する傾向がみられる。そのほかの長時間連続降雨及び中間的な連続降雨(7個)においても図-14, 図-15と同様の判別傾向を示している。

ここで, Case Aでの誤判別発生の特徴を降雨要因から見ると, 雨の降り始めの降雨パターンが1,2の場合に誤判別が生じる傾向が見られる。これは5.(1)で述べたように, 未崩壊データとして, 降雨パターン3のみを追加したことと関係しているも

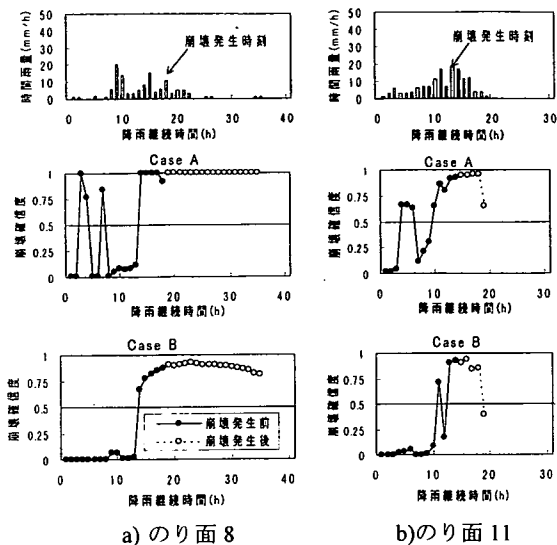


図-15 崩壊降雨における崩壊確信度の経時変化 (中間的な降雨継続時間での崩壊例)

のと思われる。また、図-13ののり面5のCase Aの崩壊発生後、時間雨量が非常に小さいにもかかわらず崩壊確信度が非常に高い部分も降雨パターンは1であった。

次に、図-16に崩壊発生時刻3時間前,2時間前,1時間前から崩壊時刻まで連続的に崩壊判別したのり面数と崩壊時刻に崩壊判別したのり面数を示す。崩壊時刻判別では表-4の学習結果に示したように全てののり面で崩壊と判別している。崩壊予測についての図-16を見ると、Case Aでは1時間前では12のり面中8個で崩壊予測し、3時間前では6個と半数ののり面で崩壊予測している。一方Case Bでは、Case Aより一つづつではあるが崩壊予測したのり面が少なく、崩壊予測の面からではCase Aがより有効な判別システムであると考えられる。

以上の崩壊降雨における判別傾向では、Case Aでの雨の降り始めの誤判別を事前に考慮していれば、降雨の経時変化に対する崩壊確信度の変化及び崩壊予測の面からではCase Aの方が有効な判別システムであると考えられる。しかし、雨の降り始めの誤判別がなく崩壊時刻を的確に捕らえ判別するという点ではCase Bが有効な判別システムであるとも考えられる。

このように本判別システムは、Case Aの雨の降り始めの誤判別を除けば崩壊降雨においては崩壊時刻付近から崩壊可能性を高い確信度をもって判別している。このことからニューラルネットワークを用い判別システムを構築することは非常に有効であると考えられる。




図-16 崩壊予測降雨数の比較




図-17 崩壊前降雨の累積雨量の経時変化の代表例 (のり面5,8,11)

b) 崩壊前降雨における判別傾向と評価







図-1～図-3の崩壊・崩壊前降雨の降雨規模の比較結果より、崩壊前降雨の代表例として次の3個ののり面の結果を示す。

- ・のり面5：崩壊降雨の降雨規模が崩壊前降雨より大きいのり面
- ・のり面8：崩壊、崩壊前降雨の降雨規模の差が少ないのり面
- ・のり面11：崩壊降雨に比べ崩壊前降雨の降雨規模が最も大きいのり面

図-17にのり面5,8,11の崩壊前降雨の累積雨量の経時変化を示す。図-17からのり面5,8,11の崩壊前降雨は降雨継続時間、累積雨量から見ても様々の降雨を含んでいることが分かる。

図-18に上段からのり面5,8,11のa)崩壊前降雨1, b)崩壊前降雨2, c)崩壊前降雨3の崩壊確信度の経時変化を示す。図の左がCase A, 右がCase Bに対応し、図中ののり面5,8,11の崩壊確信度をそれぞれ●, ▲, ◆で示している。

図-18a)～c)から明らかなように降雨継続期間の判別状況は、Case Aでは崩壊確信度が0.5以上の誤判別が見られる。一方Case Bではのり面11, 崩壊前降雨3の一時点を除き、全てののり面で雨の降り



Case A

Case B

図-18 崩壊前降雨の崩壊確信度の経時変化の代表例 (のり面 5,8,11)




図-19 崩壊前降雨の降雨継続期間内の判別率の比較 (Case A)




図-20 崩壊前降雨の降雨継続期間内の判別率の比較 (Case B)

壊前降雨 2,3 に見られるように、降雨終了時付近の累積雨量の最大付近で誤判別が発生している。しかし Case B ではこのような誤判別は発生していない。これは降雨終了時の降雨要因を未崩壊として学習させた効果によるものと考えられる。

全崩壊前降雨の降雨継続期間中の判別状況の比較のため図-19、図-20に Case A, Case B の崩壊前降雨の降雨継続時間内の判別率を示す。ここで判別率とは降雨継続時間内に未崩壊と判別した時間数の割合である。すなわち、雨の降り始めから終わりまで常に未崩壊と判別すれば判別率は 100%となる。

図-19、図-20から明らかなように、Case B では 2 降雨で判別率 100%を若干下回っているものの、残り全ての崩壊前降雨で 100%の判別率が得られている。これに対し Case A では 100%の判別率が得られた崩壊前降雨数は Case B に比べ少なく、判別率が 10%~20%の崩壊前降雨も多い。

このように崩壊前降雨の降雨継続期間内での判別状況では Case B が誤判別が発生する割合が非常に少なく有効なシステムであることが分かる。

c) 感度解析による判別傾向の評価

以上の崩壊・崩壊前降雨の判別傾向の評価から、Case A では降雨の変化状況に追従した確信度の変化傾向を示しているものの、崩壊降雨での雨の降り始めの誤判別が多いことが明らかになった。その原因として降雨パターンが考えられるのに加え、雨の降り始めに誤判別が多いことから降雨継続時間の影響も考えられる。よって、判別システムの感度解析

始めから終わりまで未崩壊と判別している。このように Case B は様々な降雨に対して的確に未崩壊の判別を行っていることが分かる。

Case A の誤判別の特徴を見ると、のり面 11 の崩

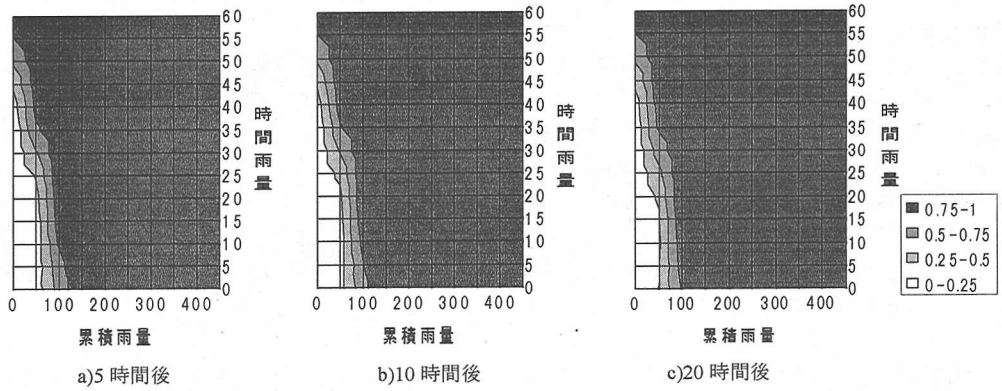


図-21 降雨継続時間別の感度解析結果(Case A)

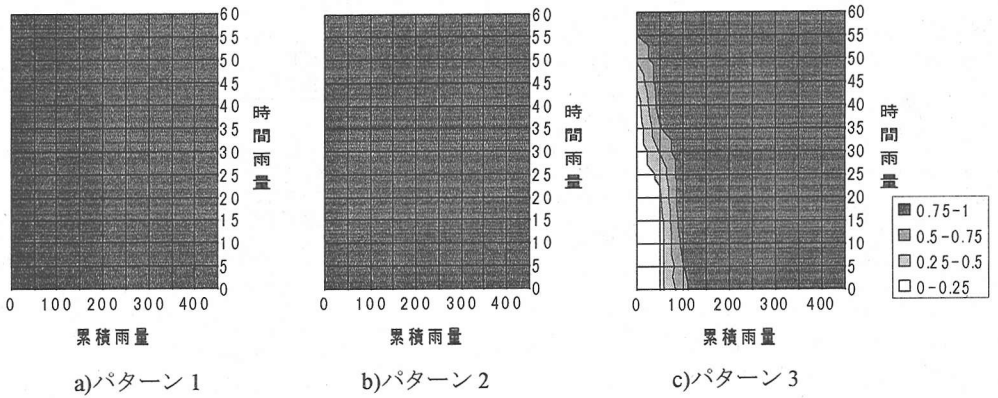


図-22 降雨パターン別の感度解析結果(Case A)

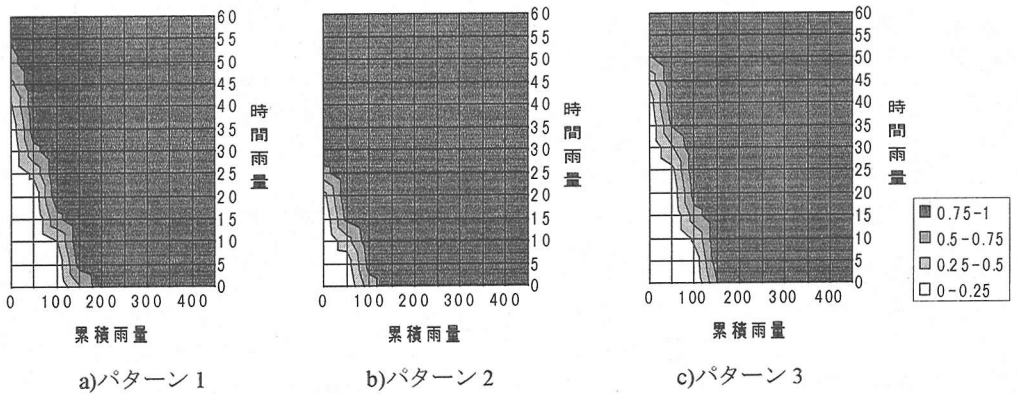


図-23 降雨パターン別の感度解析結果(Case B)

を行い、誤判別が生じる原因の究明と Case A、Case B の評価を行う。感度解析には崩壊・崩壊前降雨の降雨規模の差が少なく崩壊・崩壊前降雨の判別傾向の評価に用いたのり面 8 を代表例として用いることとする。

図-21に Case A の降雨開始後 5 時間後、10 時間後、20 時間後の感度解析結果を示す。図-21の感度

解析結果は横軸に示す累積雨量と縦軸に示す時間雨量の任意の組み合わせに対する崩壊確信度の分布を示したものである。そして、崩壊確信度の分布が 0.5 以上を示す領域が崩壊発生領域であることを示している。なお、降雨パターンとして 3 を用い確信度の算定を行っている。

図-21 を見ると降雨開始後からの継続時間の違い

による崩壊領域の差は非常に小さく、降雨継続時間の影響は非常に小さいと考えられる。ここには図示しないが Case B も同様に降雨開始後からの時間の变化による崩壊領域の変化は少ない。

図-22に Case A の降雨パターン別の感度解析結果を、図-23に Case B の降雨パターン別の感度解析結果を示す。なお、降雨継続時間は 10 時間としている。

図-22,図-23から明らかなように、Case B は降雨パターンの違いにより領域の多少の変動が見られるだけであるが、Case A は降雨パターンが 1,2 ではすべての領域で崩壊確信度が 0.75 以上を示している。すなわち Case A では一時間雨量、累積雨量の大きさに関わらず降雨パターンが 1 または 2 となることで崩壊確信度が極端に大きくなり崩壊と判別することを示している。これは、前章での誤判別の傾向を裏付ける結果である。

その他ののり面の感度解析結果についても同様の結果が見られ、Case A の 8 個ののり面について降雨パターンが 1,2 の場合、降雨パターン 3 に比べ崩壊確信度の危険領域が極端に大きくなる傾向が見られた。

以上の感度解析の結果、Case A, Case B のいずれのケースにおいても降雨継続時間の变化は崩壊確信度にほとんど影響しないが、降雨パターンの变化は、Case A, Case B のいずれのケースの感度解析結果にも影響が見られた。特に Case A については降雨量にかかわらず降雨パターンのみにより崩壊・未崩壊の判別がなされる可能性があることが明らかになった。

6. 降雨要因の組み合わせと崩壊・未崩壊の判別特性について

(1) 降雨要因の組み合わせ

前章では、ニューラルネットワークを用いたリアルタイムの判別システムが切り土のり面の崩壊・未崩壊判別に有効であることが分かった。

しかし、感度解析による判別システムの特性から降雨パターンの变化が崩壊・未崩壊判別システムの判別特性に大きく影響し、特に Case A では、のり面によっては雨量の変化に無関係に降雨パターンの变化により崩壊と判別される可能性があることが示された。

降雨パターンは、降雨終了時ではある程度明確にパターンの判別は可能と考えられる。しかし、降雨継続中では雨の降り始めの殆ど無降雨の状態や、長

表-5 降雨要因の組み合わせケース

要因 ケース	一時間 雨量	累積 雨量	降雨 継続時間	降雨 パターン
Case 1	○	○	○	○
Case 2	○	○	○	-
Case 3	○	○	-	-

表-6 Case1～Case3の学習結果

項目		Case 1	Case 2	Case 3
Case A	判別結果	崩壊降雨 12/12	12/12	12/12
		未崩壊降雨 48/48	48/48	48/48
		無降雨データ 12/12	12/12	12/12
		全体 60/60	60/60	60/60
		学習回数 849	742	744
2乗誤差(E)		0.00100	0.000997	0.000998
Case B	判別結果	崩壊降雨 12/12	12/12	12/12
		未崩壊降雨 72/72	72/72	72/72
		無降雨データ 12/12	12/12	12/12
		全体 96/96	96/96	96/96
		学習回数 860	728	880
2乗誤差(E)		0.000935	0.00100	0.000996

時間ほぼ一定の雨量を示す場合等は降雨パターンの設定が非常に曖昧である。

一方、降雨継続時間の变化は感度解析の結果から判別システムへの影響は非常に小さいと考えられるが、要因そのものが有効であるかについては不明確である。

従って、これらの降雨要因を除くことによりシステム全体の信頼性の評価を行い最適な降雨要因の組み合わせの評価が必要である。







以上のことから、前章での降雨要因の抽出ケース Case A, Case B に対して降雨要因の組み合わせケースとして表-5に示す3ケースを設定した。ここで、前章までの Case A, Case B の検討結果は Case 1 に対応する。

(2) 学習データ及び学習結果

学習データは、5.(3)に示した Case A, Case B の学習データを基に、Case 2 では降雨パターンを、Case 3 では降雨パターン、降雨継続時間を除き作成した。学習方法、収束条件等は前章と同様である。

表-6に学習結果を示す。表-6に示すように Case 1, 2, 3 ともに収束条件 $E=0.001$ を満足して学習が終了し、全ての「崩壊」、「未崩壊」の学習データに対して正解を与えている。

また、平均2乗誤差(E)は Case 1～3ともほぼ等しく、学習回数も同程度であることから Case 2、Case 3は Case 1と同様に十分に学習が行われたと考えられる。



a) Case A

b) Case B

図-24 Case 1～Case 3の崩壊降雨の崩壊確信度の経時変化の比較 (のり面 1)

(3) リアルタイム予測結果と評価


a) 崩壊降雨における判別傾向と評価

前章の崩壊降雨のリアルタイム予測において、雨の降り始めの誤判別が顕著であったのり面 1 の Case 1～Case 3 の崩壊確信度の経時変化を図-24 に示す。図中の崩壊確信度の表示方法は図-13～図-15 と同様である。

図-24 の Case A から明らかなように、降雨要因の降雨パターンを除いた Case 2, Case 3 では、全降雨要因を用いた Case 1 に見られた雨の降り始めの崩壊確信度の極端な変動による誤判別が見られないことが分かる。また、Case 3 は Case 2 に比べ崩壊確信度の変化が若干シャープであり、降雨継続時間を除いた影響であると推定される。

一方 Case B では本来、前章の既検討結果で示した様に、全降雨要因を用いた Case 1 においても Case A に見られた誤判別は見られず全般的に良好な判別傾向を示している。図-24 の降雨要因を除いた Case 2, Case 3 においても同様に誤判別はなく崩壊時刻には的確に崩壊判別を行っている。それに加え崩壊発生後には Case 1 に見られなかった崩壊確信度の低下が見られ、崩壊時刻をよりの確に予測している。また、Case A の場合と同様に Case 3 は Case 2 に比べ崩壊確信度の変化が若干シャープであり、降雨継続時間を除いた影響であると推定される。

次に、図-25 に Case 1～Case 3 の降雨要因の組み合わせケース毎の崩壊発生時刻 3 時間前、2 時間前、



a) Case A

b) Case B

図-25 Case 1～Case 3の崩壊予測降雨数の比較

1 時間前、崩壊時刻まで連続的に崩壊判別したのり面数を Case A, Case B 毎に示す。崩壊時刻判別では表-6 の学習結果に示したように全のり面で崩壊と別している。

図-25 から明らかなように Case A, Case B ともに 3 時間前、2 時間前予測では Case 1 の全降雨要因を用いた場合に比べ、Case 2, Case 3 の降雨要因を除いた方が予測できた降雨数が少なく、Case 2, Case 3 では同じであることが分かる。また、1 時間前予測では Case 1～Case 3 はほぼ同じであることを示している。このように、2, 3 時間前からの崩壊予測を考慮した場合には Case 1 の全降雨要因を用いた方がよいことが分かる。

以上の崩壊降雨の判別状況から判断すると、降雨要因として Case 1 の一時間雨量、累積雨量、降雨継続時間、降雨パターンの 4 要因を用いるのではな

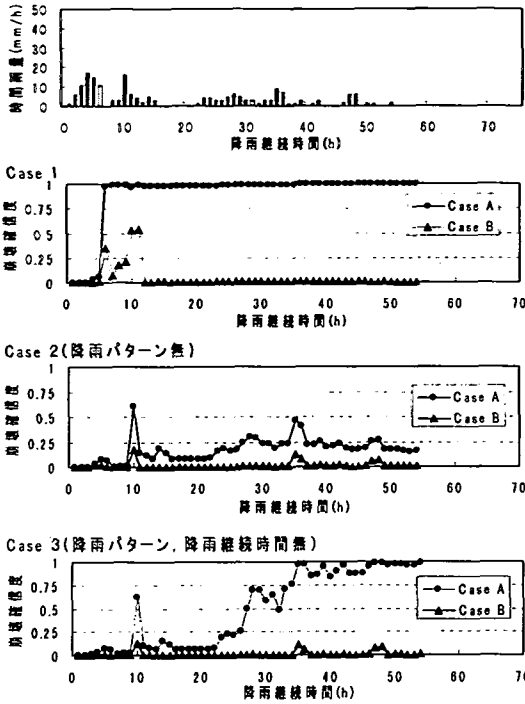


図-26 Case 1～Case 3の崩壊前降雨の崩壊確信度の経時変化の比較（のり面7，崩壊前降雨2）

く、Case 2の 一時間雨量，累積雨量，降雨継続時間の3要因またはCase 3の一時間雨量，累積雨量の2要因のみを用いた方が有効な判別システムの構築が可能である。

また，切り土のり面を防災管理する上で，崩壊可能性の高い期間に適切な管理体制を行った後，管理体制をいつ解除または緩和するか判断も重要である。従って，未崩壊データの抽出方法としては崩壊発生後に崩壊確信度の低下傾向が見られ，崩壊発生の可能性の高い期間を的確に把握することが可能であることからCase Bの 一時間最大雨量発生時刻と降雨終了時の降雨要因を抽出した方が有効であると言える。

b) 崩壊前降雨における判別傾向と評価

Case 1～Case 3の崩壊前降雨における崩壊確信度の判別特性を示すため，図-26にのり面7の崩壊前降雨2の崩壊確信度の経時変化とそれに対応した時間雨量の経時変化を代表例として示す。図中Case Aの確信度を●で示しCase Bの確信度を▲で示している。

図-26のCase Aの確信度の経時変化を見るとCase 1では降雨開始後5時間を経過した時点より崩壊確信度が1.0付近に極端に変動し，実際は崩壊し

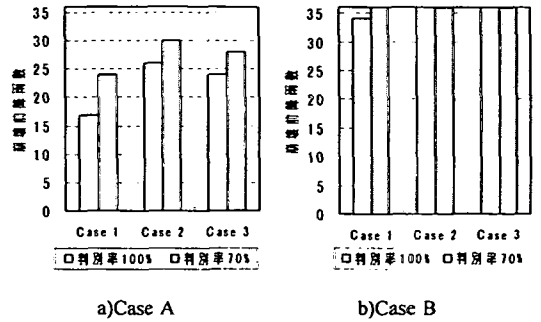


図-27 崩壊前降雨の降雨継続時間内の判別率別の降雨数の比較

なかつたにもかかわらず降雨終了時まで崩壊と誤判別している。これは，図-26の時間雨量の変化から分かるようにこの崩壊前降雨2は前方集中型降雨である。そのため降雨開始後5時間を経過した時点から降雨パターンが1を示し，感度解析で示した様に降雨パターンの変化により誤判別をしていると見られる。しかし，Case 2,Case 3の降雨パターンを除いたケースではCase 1の様に極端な変動はないことが分かる。またCase 2,Case 3の崩壊確信度の経時変化を比較すると，両ケースとも累積雨量の増加に伴い確信度が上昇している。特に，Case 3では累積雨量の増加に顕著に反応し，この降雨では崩壊しなつたにも関わらず最終的に崩壊と判別している。このことから累積雨量の増加に追従した顕著な崩壊確信度の増加を抑えるには降雨要因として降雨継続時間は必要であることが分かる。

次に，図-26のCase Bの崩壊確信度の変化傾向を見るとCase 1では一部で崩壊と誤判別をしているが，Case 2,Case 3では全ての区間において未崩壊と判別している。また，Case AのCase 2,Case 3に見られる降雨中盤から後半にかけての崩壊確信度の上昇は見られず，降雨全般を通して明確に未崩壊判別を行っている。これは，未崩壊データとしてCase BではCase Aの 一時間最大雨量時刻に加え累積雨量が最大となる降雨終了時の降雨要因を加えているため，各崩壊前降雨の累積雨量の最大値も未崩壊データとして学習されていることによると考えられる。

崩壊前降雨全体の降雨継続期間中の判別状況の比較を5.(3).b)で用いた降雨継続期間内の判別率により行う。ここで，全ケースの崩壊前降雨について判別率を図示することは，非常に煩雑となる。従って本節では，各ケースの降雨継続時間内に100%の判別率が得られた崩壊前降雨数と70%以上の判別率が得られた崩壊前降雨数について比較を行った。そ

の結果を図-27に示す。

図-27から明らかのように Case B では全降雨要因を用いた Case 1 においても図-20で示したように 36 降雨中 34 降雨で 100 % の判別率が得られている。さらに、降雨パターンを除いた Case 2、及び降雨パターン、降雨継続時間を除いた Case 3 では全ての崩壊前降雨で 100% の判別率が得られている。このように Case B は、Case A に比べ降雨継続期間内の未崩壊判別が非常に良いことが分かる。

次に、Case B の結果では Case 2、Case 3 の良否が判断できないため、Case A から判断すると降雨要因として一時間雨量、累積雨量、降雨継続時間の 3 要因を用いた Case 2 が最も良い結果が得られていることが分かる。これは、図-26ののり面 7 の崩壊確信度の比較で既述したように、Case 2 では降雨継続時間の効果により、降雨後半の累積雨量の増加による崩壊確信度の顕著な上昇が抑えられていることによると考えられる。

以上の崩壊前降雨の判別状況から、未崩壊データの抽出方法として、Case A の一時間最大雨量発生時刻に加え、Case B の降雨終了時の降雨要因を抽出する方法が判別システム構築に非常に有効であると言える。

また、降雨要因の組み合わせについては Case 2 の一時間雨量、累積雨量、降雨継続時間を用いた方が最も有効であると考えられる。

このように本研究で構築したニューラルネットワークを用いた判別システムでは適切な未崩壊データを抽出し、適切な降雨要因とのり面評価要因とを組み合わせることで、崩壊前降雨においては降雨の降り始めから終了時まで非常に高い確率で未崩壊と判別することが可能である。

7. まとめ

本研究では、供用中の降雨継続中に崩壊した変成岩地山の 12 個の切り土のり面に対してのり面評価要因と降雨要因とを組み合わせ、最適化手法としてニューラルネットワークを用いた降雨継続中の崩壊・未崩壊の判別システムの構築を行った。そしてニューラルネットワークを用いた判別システムの切り土のり面の崩壊可能性評価への適用可能性について示した。以下に要点を列記する。

(1)ニューラルネットワークを用いることにより、降雨開始直後からリアルタイムで個々ののり面の崩壊・未崩壊を判別することが可能なシステムの構築が可能である。

(2)判別システムを構築する上で崩壊降雨では崩壊発生時刻（推定時刻）、崩壊前降雨では一時間最大雨量と降雨終了時の降雨要因を抽出することがシステムを構築する上で有効である。

(3)また、降雨要因として、既研究結果¹²⁾で有効とされた降雨パターンは用いず、一時間雨量、累積雨量、降雨継続時間の 3 要因を用いた方がシステムの信頼性向上に有効である。

(4)この判別システムでは雨の降り始めでは未崩壊と正しく判別し崩壊発生 1～2 時間前から崩壊と判別できる。従って、崩壊可能性を事前に予測することが可能であると考えられる。

(5)また、本研究で提案したシステムによれば時々刻々変化する崩壊確信度の大きさにより崩壊可能性の評価が可能である。さらに崩壊発生後には崩壊確信度が低下する事から、崩壊可能性の高い期間を的確に把握する事が可能である。

以上示したように、ニューラルネットワークは切り土のり面の崩壊・未崩壊のパターン認識に非常に適しており、更に学習データを吟味することで切り土のり面の崩壊可能性をより精度良く評価することが可能であると考えられる。

本研究では変成岩地山ののり面に限定してシステムの構築を行ったが、他の岩種についても同様の手法、過程を用いることで判別システムの構築が可能であると考えられる。

ただし、本研究では連続降雨として無降雨期間が 8 時間以内の降雨を対象として崩壊・崩壊前降雨の抽出を行っている。しかし無降雨期間の取り方によっては降雨継続時間が非常に長く、累積雨量規模も非常に大きくなり、同じ時期の降雨でも本研究で抽出した降雨要因とかなり異なってくる事が予想される（特に降雨継続時間、累積雨量）。また、崩壊発生時刻への前期降雨の影響範囲も曖昧である。

従って、今後この無降雨期間の設定時間を変化させシステムの判別特性の比較評価を行い、無降雨期間の影響を考慮した判別システムの構築が必要であると考えられる。一方、無降雨期間の設定を必要としない降雨指標として、現在土石流の分野で多く用いられている実効雨量があげられる。この実効雨量は半減期の設定により時間雨量の変化を自動的に含んだ雨量の累積値であり、降雨継続時間、降雨パターンもある程度含んだ雨量指標とされている。従って、のり面の崩壊・未崩壊を評価する上でも有効な指標になると考えられる。しかし、半減期の設定方法および半減期によりどの程度降雨継続時間、降雨パターン等が反映され

るのか不明な点が多いため、今後、無降雨期間の設定方法と合わせて検討を進めていく必要があると考えられる。

参考文献

- 1) 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.
- 2) 西邦正, 古川浩平, 小川健, 中川浩二: 降雨継続中の切土のり面における崩壊・未崩壊の時間ごとの予測手法について, 土木学会論文集, 第 498 号/VI-24, pp.95-104, 1994.9.
- 3) 西邦正, 古川浩平, 中川浩二: ファジィ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.109-118, 1992.3.
- 4) 瀬尾克美, 船崎昌継: 土砂害 (主に土石流的被害) と降雨量について, 新砂防, Vol.26, No.2, pp.22-28, 1973.11.
- 5) 池谷浩: 降雨強度比による土砂災害からの避難基準に関する一私案, 新砂防, Vol.27, No.3, pp.7-12, 1974.12.
- 6) 建設省河川局砂防部砂防課: 土石流災害に関する警報の発令と避難の指示のための降雨量設定指針(案), 1984.
- 7) 村石尚: 鉄道沿線の斜面災害の危険度評価—鉄道の降雨災害に対する取組みと鉄道総研における技術開発—, 新砂防, Vol.49, No15, pp.3-8, 1996.5.7
- 8) 神野嘉希, 石井勝美: JR 西日本における鉄道防災対策, 新砂防, Vol.49, No15, pp.9-11, 1996.5.
- 9) 建設省河川局砂防部砂防課: 土石流危険区域調査要領 (案), 1976.
- 10) 足立勝治, 徳山久仁夫, 中筋章人, 中山政一, 二宮寿男, 大木俊治: 土石流発生危険度の判定について, 新砂防, Vol.30, No.3, pp.7-16, 1977.12.
- 11) 西邦正, 古川浩平, 小川健, 中川浩二: ファジィ理論に基づく供用中切土のり面の崩壊要因評価と岩種特性土木学会論文集, 第 457 号/III-21, pp.151-154, 1992.12.
- 12) 鈴木雅一, 福島義宏, 武居有恒, 小林澄治: 土砂害発生の危険雨量, 新砂防, Vol.31, No.3, pp.1-7, 1979.2.
- 13) 平松晋也, 水山高久, 奥山清一: 崩壊モデルを用いた各種崩壊要因の影響度評価, 新砂防, Vol.43, No.5, pp.11-18, 1991.1.
- 14) 高木英行: ニューラルネット Part II 基礎入門編, 日本ファジィ学会誌, Vol.4, No.4, pp.664-675, 1992.8.
- 15) 那野比古: ニューロコンピューター革命, 講談社, 1991.1.
- 16) 平野広美: C でつくるニューラルネットワーク, パーソナルメディア, 1991.3.

(1996. 10. 23 受付)

A STUDY OF A SYSTEM FOR FORECASTING METAMORPHIC-ROCK CUTT-OFF SLOPE COLLAPSE DURING HEAVY RAIN USING NEURAL NETWORK

Hideaki KIKUCHI, Kohei FURUKAWA, Shinji OHMAE, Seishi OKUZONO
and Makoto KAMIYA

The collapses of cut-off slope during heavy rain had been caused by slope evaluation factors that are topographical, geological and earth-work related factors as well as rain-fall factors over a certain limit of value. Until now, there are many studies related to an evaluation of slope-collapse possibility based on only rain-fall factors. But, there are few studies based on the combinatoin of slope evaluation and rain-fall factors. In this research, we have constructed a system that can forecast the collapse or non-collapse of metamorphic rock-slope in real time during heavy rain using neural network based on slope evaluation together with rain-fall factors. Then, we present a rule for selecting efficient study data and the best combination of rain-fall factors to improve the reliability of the system.