

ニューラルネットワークを用いた土石流危険 溪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

荒木義則¹・古川浩平²・松井範明³・大木戸孝也⁴・石川芳治⁵・水山高久⁶

¹正会員 工修 中電技術コンサルタント(株) 水工部 (〒734 広島市南区出汐2-3-30)

²正会員 工博 山口大学教授 工学部社会建設工学科 (〒755 宇部市常盤台2557)

³広島県土木建築部砂防課 (〒730 広島市中区基町10-52)

⁴正会員 山口大学助手 工学部社会建設工学科 (〒755 宇部市常盤台2557)

⁵正会員 農博 京都府立大学助教授 農学部林学科 (〒606 京都市左京区下鴨半木町1-5)

⁶正会員 農博 京都大学教授 農学研究科 (〒606-01 京都市左京区北白川)

豪雨による土砂崩壊の発生に対して、パターン認識に優れるニューラルネットワークを用いて、素因である地形要因に誘因となる降雨要因を考慮することにより土砂崩壊の「発生」「非発生」を判断するモデルを構築した。また、このモデルを用いてリアルタイムでの発生予測を行い、ニューラルネットワークの適用可能性について検討した。さらに、ニューラルネットワークの汎化能力を向上させるための検討と降雨要因による感度解析を行い、本手法の有効性を示した。

KeyWords : debris-flow, collapse, heavy rain, neural network, real-time

1. はじめに

自然災害の中でも土砂災害は、梅雨時期や台風の子節になると毎年全国各地で発生している。一般に土砂災害には、土石流、地すべり、がけ崩れ、河川への土砂流出等が考えられる。中でも、土石流は、谷や斜面に貯まった土・石・砂礫などが梅雨や台風などの集中豪雨による水といっしょになって、一気に流れ出してくるので、破壊力が大きく、また速度も速いため、大きな被害をもたらすことがある。このような土石流発生の危険性があり、それにより人家5戸以上に被害が発生する危険性のある溪流は、土石流危険溪流に指定され、砂防ダムや流路工による土石流対策施設の整備が進められている。

このような土石流対策施設を必要とする土石流危険溪流は、平成2年度～4年度の調査によると全国に約7万9千もあり、しかも土石流危険溪流に指定される溪流が増加傾向にあることが示されている。また、これらの土石流危険溪流に対する全国の整備率は、約20%¹⁾と低い。このため、ハード対策とソフト対策からなる総合土砂災害対策が推進されている。

現在、ソフト対策の一つとして全国的に警戒・避

難基準雨量の設定²⁾が試みられている。警戒・避難基準雨量の設定では、過去の土石流の発生降雨と非発生降雨を用いて土石流の発生が予想される限界降雨量を設定することが行われている。しかしながら、降雨要因のみの基準では、雨量観測区域内のどの溪流から土石流が発生するかまでは特定することができない。また、警戒・避難体制を整備するためには、「ある地域にどれだけの雨が降ったらどの溪流がどのくらい危険となるか」を知る必要がある。つまり、土石流の発生を溪流単位で個別管理する必要があると考えられる。

土石流の発生とその予測に関する既往の研究は、累積雨量³⁾や実効雨量⁴⁾を用いた土石流の発生限界降雨に関しては、従来から種々の方法が提案されており、前述の建設省方式の警戒・避難基準雨量の設定²⁾は、一部で実用に供されている。しかしながら、非常に安全側の基準となり、空振り率が大きくなることもあり、避難勧告の発令や解除等の実用面で課題が残されている。最近では、警報の発令や避難指示に対する的確性向上の研究⁵⁾も行われている。

土石流の流出解析には、単位図法、タンクモデル法⁶⁾をはじめ多くの手法が提案されているが、土石

表-1 観測エリア毎の溪流数

観測 エリア	対象降雨数			発生降雨における 対象溪流数		
	発生	非発生	合計	発生	非発生	合計
1	1	4	5	1	13	14
2	1	2	3	2	0	2
3	1	2	3	9	32	41
4	2	3	5	2	70	72
				22	50	72
合計	5	11	16	36	165	201

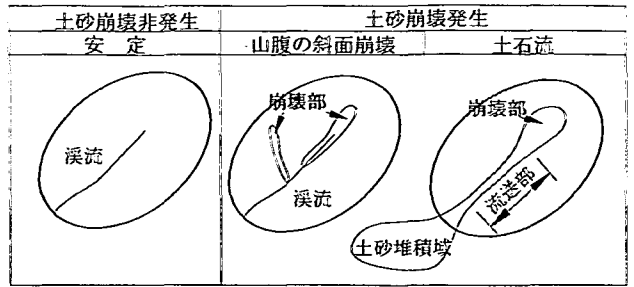


図-1 土砂崩壊発生状況の模式図

流は現象が複雑でかつ精度のよいデータが少ないため流出解析による信頼性の高い手法はいまだに確立されていない。

ニューラルネットワークを用いた土石流の発生予測では、森山ら⁷⁾、平野⁸⁾により火山性土石流の発生予測が行われており、ある程度良好な結果が得られている。しかしながら、雲仙普賢岳の火山性土石流を対象としているため、地形・地質条件としては比較的均一とみなされる条件下で行われている。また、降雨データのみを用いた検討となっており、複雑な地形条件からなる自然溪流に対する検討は行われていない。

そこで本研究は、過去に幾度も土石流災害に見舞われている広島県北西部地域（山県郡加計町及びその周辺）を対象として、パターン認識に優れたニューラルネットワーク⁹⁾を用いて、素因となる地形要因と誘因となる降雨要因を用いて、溪流毎に土砂崩壊の発生をリアルタイムで判断する評価システムを構築した。また、誘因となる降雨要因の組み合わせにより最適な評価モデルの検討を行った。さらに、ニューラルネットワークモデル（以下、NNモデル）の汎化能力を向上させるための学習データの取り扱い方および学習方法について検討した。

2. 土砂崩壊の発生予測モデルの構築

広島県北西部地域では、過去に幾度も土石流災害に見舞われており、特に昭和63年7月の土石流災害により大きな被害¹⁰⁾を被った。溪流の崩壊状況は、図-1の土砂崩壊発生状況の模式図に示すように、まったく変化のない安定した溪流、小規模な山腹斜面崩壊や溪岸崩壊は発生したが土石流にならなかった溪流、また土石流の発生した溪流があり、溪流の形態変化としては、安定・山腹斜面崩壊・土石流の3つのタイプに分類することができる。しかしながら、山腹斜面崩壊や土石流の発生した溪流には、その中間的な被害形態を示す溪流が存在していること

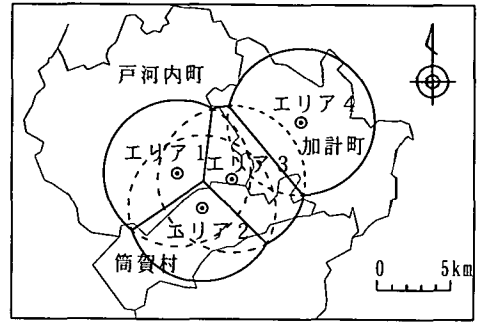


図-2 降雨観測所位置とエリア区分

を考慮すると土石流と山腹斜面崩壊を明確に分離することは困難であるため、本研究では、土石流または山腹斜面崩壊の発生した溪流を土砂崩壊の発生溪流として扱う。また、土石流の発生形態は、溪流の谷次数によって変化する。2次谷以上の溪流では、土石流の発生が本流や支流から発生することがあり、土石流の発生現象が複雑になるため、ここでは、1次谷を対象とする。また、2次谷以上の溪流は、1次谷に再分割して取り扱うものとする。

図-2に本研究で対象とした地域の降雨観測所の位置とエリア区分を示す。降雨の影響範囲は、雨量観測所を中心として半径5km¹¹⁾のエリアを設定し、エリア内において降雨は一定であると考えた。また、雨量観測所間の距離が5km以内でエリアの重複する溪流は最も近い雨量観測所に含まれるものとして取り扱った。表-1に、観測エリア毎の1次谷の溪流数と対象降雨数を示す。表-1より対象降雨数は、発生降雨5個、非発生降雨11個の計16個の一連続降雨で、対象溪流数は、129溪流の内36溪流から土砂崩壊の発生が確認されている。ここで、一連続降雨は前後に24時間以上の無降雨期間があるひとまとまりの降雨として定義²⁾する。

ニューラルネットワークでは、素因となる地形要因と誘因となる降雨要因を入力データとして土砂崩壊の発生予測モデルを構築する。

(1) 地形・地質要因の設定

土砂崩壊発生の素因となる地形・地質要因のうち地形要因には、「地形要因一覧表¹²⁾」を用いる。

a) 溪流要因

- A : 水系模様, B : 流域平均勾配,
- C : 最急渓床勾配, D : 主溪流長,
- E : 流域面積, F : 溪流幅,
- G : 渓床堆積厚さ

b) 斜面要因

- L : 〇次谷の数, M : 流域最大傾斜

c) 流域評価要因

- : 渓床危険度評価, P : 渓床堆積厚評価,
- Q : 降雨集中度評価

ここで、溪流要因に流域の形状を表す要因として、H : 流域長, I : 流域幅, J : 流域形状比 (流域幅 / 流域長), K : 谷深比 (主溪流長 / 流域長), 斜面要因としてN : 源頭部面積の5つの要因を新しく加える。これらは、いずれも地図より読み取ることが出来る要因である。

また、地質要因は、表土層の土質特性 (砂質土, 粘性土等) により、特に粘土含有率が多いと誘因となる降雨量が多くなると土石流化しにくい傾向を示すことなど、土砂崩壊の発生や流出形態等に影響¹³⁾ を与えると考えられる。このため、本研究では広島県北西部に広く分布している風化花崗岩からなる溪流を対象とした。

(2) 降雨要因の設定

降雨要因には、降雨の特徴を表すために、それぞれ降雨の短期, 長期, 時間, 変動の4つの指標を考えた。以下にその内容について記す。

a) 短期指標

- R : 時間雨量 (mm/h)

b) 長期指標

- S : 積算雨量 (mm)
一連続降雨における積算雨量
- T : 有効雨量 (mm)
一連続降雨において時間雨量4mm/h以上の降り始めから4mm/h未満が3時間以上経過するまでの積算雨量
- U_{i=1~3} : 実効雨量 (半減期 t' (h)) (mm)
前期降雨の影響を考慮した積算雨量で式(1)に示すように、半減期 t' 時間での t 時間前の減少係数と時間雨量の積和

$$R_w = \sum_{i=1}^n (0.5)^{t'/t} r(t) \quad (1)$$




図-3 降雨模式図

ここで、 R_w : 実効雨量 (mm), $(0.5)^{t'/t}$: 減少係数, t' : 半減期 (12, 24, 48hr), $r(t)$: 時間雨量 (mm/h)

c) 時間指標

- V : 降雨継続時間 (h)
一連続降雨において雨の降り始めから降り終わりまでの時間
- W : 有効時間 (h)
有効雨量に対する雨の降り始めから降り終わりまでの時間

d) 変動指標


- X : 有効雨量強度
有効雨量を有効時間で除した値
- Y : 降雨重心
基準化した一連続降雨の重心で式(2)で表される。

$$e = \frac{\sum_{i=1}^T r(t) \cdot t}{T \cdot \sum_{i=1}^T r(t)} \quad (2)$$

ここで、 e : 基準重心, $r(t)$: 時間雨量 (mm/h), t : 降雨時間 (t), T : 一連続降雨継続時間 (t)

- Z : 有効降雨重心
基準化した有効降雨の重心で式(2)において $T=W$: 有効時間 (t) としたもの

降雨要因の抽出において、一連続降雨から降雨要因を抽出する方法は、図-3 の降雨模式図に示すように、発生降雨については、土砂崩壊の発生時刻において要因を抽出し、発生データとして用いる。ここで、土石流の発生推定時刻¹⁰⁾ は、地元住民による土石流の前兆現象や発生状況の目撃証言等から推定された土石流の発生時刻と降雨の時間雨量のピーク値がほぼ一致しているため、時間雨量のピーク値



入力層 中間層 出力層
図-4 階層型ネットワーク

を土砂崩壊の発生時刻として取り扱った。また、非発生降雨については、1時間毎の全ての降雨データを学習させると、非発生データの数が多くなり、ニューラルネットワークの学習効率も悪くなる。そのため、建設省方式の警戒避難基準雨量の設定において対象となる非発生降雨量²⁾を参考にして、ここでは、時間雨量のピーク以降の変化点において積算雨量80mm以上で時間雨量20mm/h以上となる要因を抽出し、非発生データとして用いる。さらに、無降雨状態では、非発生であるため降雨要因=0を非発生データとして加える。

(3) ニューラルネットワークのモデル化

ニューラルネットワークのモデル化において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のが良く、むやみに複雑にするとかえって逆効果となることが著者らの研究¹⁴⁾において示されているため、ここでも、図-4に示すように、入力層、中間層、出力層の3層からなる階層型ネットワークモデルを用いる。一般に階層型ネットワークモデルは、パターン認識¹⁵⁾に優れているとされており、現象の複雑な土砂崩壊の発生・非発生の予測において、地形要因や降雨要因を入力データとし土砂崩壊の発生・非発生を出力する入出力関係を一つのパターンとして扱うのに適した問題と考えられる。

本研究で用いるNNモデルは、図-5に示すように地形要因と降雨要因の組み合わせを考えたモデルとする。図-5のモデルでは、入力層は、地形要因と降雨要因から構成され、要因の種類によって数値ニューロンとカテゴリーニューロンの2種類からなっている。

NNモデルを構成する1つのニューロンは、その出力が【0】～【1】までの値であるため、数値ニューロンでは、データの最大値が【1】になるように基準化して用いる。また、カテゴリーニューロンは、該当するランクのニューロンを【1】とする。

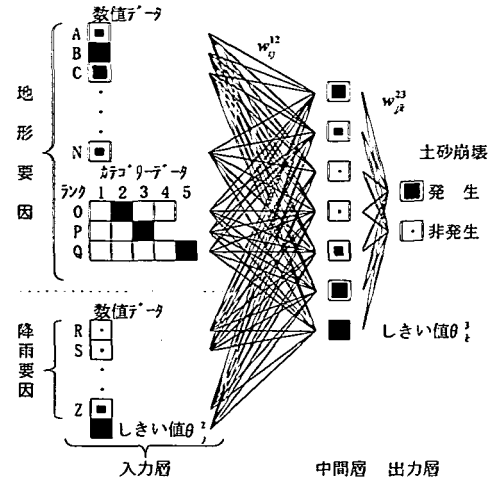


図-5 3層階層型ニューラルネットワークモデル

また、中間層のニューロンは6個とし、出力層のニューロンは、土砂崩壊の発生、非発生の2個のニューロンを設定している。

学習のアルゴリズムは、誤差逆伝播学習則（以下、BPと言う）を用い、入力層の地形・降雨要因を入力データとし、出力層の土砂崩壊の発生・非発生の関係を学習させる。このとき、発生データであれば発生ニューロンの出力【1】、非発生ニューロンの出力【0】を理想出力値として与える。逆に、非発生データであれば発生ニューロンの出力【0】、非発生ニューロンの出力【1】として与える。

また、入力層と中間層には、各層全てのニューロンに出力【1】を送るしきい値のためのニューロンを設けることにより、BPの過程で各層間の重み (w_{ij}^{12}, w_{jk}^{23}) としきい値 (θ_j^2, θ_k^3) を同時に修正していく手法¹⁴⁾を用いている。

学習の収束条件は式(3)において最小二乗誤差 $E \leq 0.001$ または、最大10,000回の反復学習を行った。

$$E = \frac{1}{2} \sum_i (v_i^N - \hat{v}_i)^2 \quad (3)$$

ここで、 E ：最小二乗誤差、 v_i^N ：実際の出力値（出力信号）、 \hat{v}_i ：理想出力値（教師信号）
また、ニューロンの入出力関数は式(4)に示すシグモイド関数（パラメータ $u_0=1.0$ ）とした。

$$f(x) = \frac{1}{1 + \exp(-x/u_0)} \quad (4)$$

ここで、 $f(x)$ ：ニューロンの出力値、 x ：入力値、 u_0 ：パラメータ

表-2 NNモデルの解析手順

検討項目	評価方法
a) 入力データの組合せ	NNモデルの発生確信度0.5以上の正解率 収束状況(最大学習回数, 最小二乗誤差)
b) リアルタイム発生予測	NNモデルの発生確信度の変化
c) 精度向上の検討	a)と同じ
d) 降雨要因に関する感度解析	降雨要因によるNNモデルの感度変化(曲線, 曲面)

ニューラルネットワークのモデル化では、入力データを教師データと試験データに分けて、教師データにより学習したモデルを用いて、未学習の試験データに適用するという方法¹⁴⁾がよく用いられている。しかし、本研究においては、NNモデルを用いて溪流の地形要因と降雨要因を組み合わせ、リアルタイムでの発生予測を試みるものであり、リアルタイムでの学習は行っていない。学習に用いたのは、図-3の降雨模式図に示した降雨要因抽出点のデータのみであり、その他の点におけるデータは未学習データとなっている。そのため、教師データと試験データの分離が難しい上、表-1に示したように、土砂崩壊の発生降雨は、非発生降雨に比べて少ないこと、また、発生降雨の観測エリア内の全ての溪流から土砂崩壊が発生するわけではないこと、さらに前述の地形要因と降雨要因の組み合わせを考えると、土砂崩壊の発生データ数は、非発生データ数と比べて非常に少なくなる。このため、構築したNNモデルの試験には、学習データを含む全てのデータに対してリアルタイムで土砂崩壊の発生予測を行う。

NNモデルの判断は、出力層における土砂崩壊の発生・非発生を判断するニューロンの出力値において、出力値が【0.5】以上を示す大きい方のニューロンをニューラルネットワークの判断とする。また、出力【1】に近いほどニューラルネットワークの判断の確信度が高いことを表しており、発生ニューロンと非発生ニューロンの出力値の関係は、それぞれの出力値の合計が【1】となっている。図-5では、入力データに対してニューラルネットワークは、土砂崩壊が発生すると判断している。

(4)解析手順

NNモデルの解析手順は、表-2に示すようにa)~d)の項目について検討する。

a)入力データの組合せ

溪流+斜面要因と流域評価要因、降雨要因として短期、長期、時間、変動のそれぞれの要因に対して最良の組合せを検討する。

b)リアルタイム発生予測

観測降雨に対するNNモデルの発生確信度の変化より、リアルタイム発生予測の適用性について検討する。

c)精度向上

NNモデルに用いる学習データの選別や学習データの集中的な学習方法により、NNモデルの判別精度の向上について検討する。

d)降雨要因に関する感度解析

土砂崩壊の発生した代表的な溪流について、降雨要因を変化させた場合のNNモデルの感度解析について検討する。

3. 入力データの組合せに対する検討

土砂崩壊の発生は、地形要因と降雨要因の組合せによって決まってくる。地形要因には、地形図や現地調査により求まる数値データとこれらの数値データから流域の状況を評価したカテゴリーデータがある。また、降雨要因には、短期、長期、時間、変動の4つの指標がある。これらの要因の中で、どの要因が土砂崩壊の発生に影響を与えるかについて、入力データの組合せを考えた検討を行う。

入力データの組合せは、地形要因を中心に土砂崩壊の引き金となる降雨要因を変化させて、表-3に示すような13通りの検討ケースを考えた。従って、13通りの入力データに対してそれぞれNNモデルを再構築した。

また、入力データがニューラルネットワークに与える影響は、土砂崩壊の発生・非発生の正解率と学習回数や最小二乗誤差による収束状況により評価する。表-4に学習データに対するNNモデルの正解率と収束状況を示す。

検討ケース1~6は、地形要因には数値データ、降雨要因には6つの降雨指標による組合せを行い、それぞれ図-5のネットワーク構造によりモデル化を行った。表-4より、検討ケース1~6の中で、検討ケース5の正解率が最も高くなり、発生データ

表-3 検討ケース (地形・降雨要因) の組合せ

要因		因子	検討ケース													
			1	2	3	4	5	6	7	8	9	10	11	12	13	
地形	流域	A 水系模様	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		B 流域平均勾配(°)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		C 最急流域勾配(°)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		D 主流域長(km)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		E 流域面積(km ²)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		F 流域幅(km)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		G 溪床堆積厚さ(m)	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	流	H 流域長(km)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		I 流域幅(km)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		J 流域形状比	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		K 谷深比	○	○	○	○	○	○	○	○	○	○	○	○	○	○
	斜	L 0次谷の数	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		M 流域最大傾斜(°)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		N 源頭部面積(km ²)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
面	O 溪床危険度評価											○	○	○	○	
	P 溪床堆積厚評価											○	○	○	○	
	Q 降雨集中度評価											○	○	○	○	
降雨	短期	R 時間雨量(mm/h)	○	○	○	○	○	○	○	○	○	○	○	○	○	○
		S 積算雨量(mm)	○													
		T 有効雨量(mm)		○	○											
	長期	U1 実効雨量(半減期12hr)					○									
		U2 実効雨量(半減期24hr)						○				○	○	○	○	○
		U3 実効雨量(半減期48hr)							○							
	時間	V 降雨継続時間(hr)	○			○	○	○	○	○				○		
		W 有効時間(hr)		○	○											
	変動	X 有効雨量強度(mm/h)		○												
		Y 降雨重心				○	○	○				○		○		○
Z 有効降雨重心					○											

表-4 学習データに対するNNモデルの正解率と収束状況

検討ケース		1	2	3	4	5	6	7	8	9	10	11	12	13	
確信度 0.5以上の 正解率	発生	20/36	20/36	21/36	21/36	22/36	20/36	24/36	25/36	22/36	22/36	26/36	33/36	30/36	
	(%)	55.6	55.6	58.3	58.3	61.1	55.6	66.7	69.4	61.1	61.1	72.2	91.7	83.3	
	非発生	736/736	736/736	736/736	736/736	736/736	736/736	736/736	736/736	734/736	735/736	736/736	736/736	736/736	736/736
	(%)	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	99.7	99.9	100.0	100.0	100.0	100.0
	全体	756/772	756/772	757/772	757/772	758/772	756/772	760/772	759/772	757/772	758/772	762/772	769/772	766/772	
	(%)	97.9	97.9	98.1	98.1	98.2	97.9	98.5	98.3	98.1	98.2	98.7	99.6	99.2	
収束 状況	最大学習回数	10,000	10,000	10,000	10,000	10,000	10,000	10,000	10,000	10,000	10,000	10,000	10,000	10,000	10,000
	最小二乗誤差	0.445	0.369	0.417	0.416	0.389	0.444	0.334	0.306	0.389	0.389	0.278	0.084	0.127	
	誤差	0.021	0.018	0.019	0.019	0.018	0.021	0.016	0.017	0.019	0.018	0.013	0.004	0.006	

61.1%, 非発生データ100%, 全体で98.2%となった。この時の降雨要因は、時間雨量(要因R), 実効雨量(半減期24h)(要因U2), 降雨継続時間(要因V), 降雨重心(要因Y)の4要因である。また、モデルの収束状況は、最大学習回数10,000回で最小二乗誤差0.018となった。

検討ケース7~9は、前述の検討で正解率が最も高くなった検討ケース5の降雨要因に着目し、降雨要因の数を減少させた場合の検討を行った。検討ケース5,7,8,9より、検討ケース8の発生データに対する正解率が最も高くなり、発生データ69.4%, 非発生データ99.7%, 全体で98.3%となり、発生データに対する正解率がやや向上した。この時の降雨要因は、時間雨量(要因R), 実効雨量(半減期24h)(要因U2), 降雨重心(要因Y)の3要因であり、時間指標として用いた降雨継続時間(要因V)を除いた

方が正解率が高くなった。また、モデルの収束状況は、最大学習回数10,000回で最小二乗誤差0.017となった。

検討ケース10~13は、前述の検討ケース5,7,8,9に対して、地形要因に数値データだけでなく流域評価要因としてのカテゴリーデータも加えた場合の検討を行った。検討ケース10は、検討ケース5と比べて正解率や最小二乗誤差が同じになり、地形要因に流域評価のカテゴリーデータを加えたことによる影響は表れていない。検討ケース11~13は、検討ケース7~9と比べて、全てのケースにおいて正解率が高くなり、最小二乗誤差も減少している。特に、検討ケース12の正解率が最も高くなり、発生データ91.7%, 非発生データ100%, 全体で99.6%となり、地形要因にカテゴリーデータを加えることにより発生データに対する正解率が大幅に改善された。この




図-6 対象降雨における降雨ピーク時刻および土石流発生推定時刻前後の降雨特性

表-5 溪流毎のリアルタイムでの土砂崩壊の発生予測の結果

観測エリア		1					2			3			4					合計
降雨	降雨番号	1-1	1-2	1-3	1-4	1-5	2-1	2-2	2-3	3-1	3-2	3-3	4-1	4-2	4-3	4-4	4-5	
発生	発生・非発生	非発生	非発生	非発生	非発生	発生	非発生	非発生	発生	発生	非発生	非発生	発生	非発生	発生	非発生	非発生	
発生	NN判断/実測	0/0	0/0	0/0	0/0	0/1	0/0	0/0	2/2	8/9	0/0	0/0	2/2	0/0	21/22	0/0	0/0	33/36
	正解率(%)	-	-	-	-	0.0	-	-	100.0	88.9	-	-	100.0	-	95.5	-	-	91.7
非発生	NN判断/実測	14/14	14/14	14/14	14/14	13/13	2/2	1/2	0/0	30/32	41/41	41/41	54/70	72/72	37/50	72/72	72/72	491/523
	正解率(%)	100.0	100.0	100.0	100.0	100.0	100.0	50.0	-	93.8	100.0	100.0	77.1	100.0	74.0	100.0	100.0	93.9
全体	NN判断/実測	14/14	14/14	14/14	14/14	13/14	2/2	1/2	2/2	38/41	41/41	41/41	72/72	72/72	72/72	72/72	72/72	524/559
	正解率(%)	100.0	100.0	100.0	100.0	92.9	100.0	50.0	100.0	92.7	100.0	100.0	77.8	100.0	80.6	100.0	100.0	93.7

時の地形要因は、数値データとカテゴリデータを含む全要因、降雨要因は、時間雨量(要因R)、実効雨量(半減期24h)(要因U2)、降雨重心(要因Y)の3要因である。また、モデルの収束状況は、最大学習回数10,000回で最小二乗誤差0.004となった。

4. 降雨継続時間毎の土砂崩壊のリアルタイム発生予測への適用



前章で構築した最良のNNモデルを用いて、図-3の降雨模式図に示した降雨要因抽出点における学習データとそれ以外の未学習データを含む全てのデータに対して、各溪流の降雨継続時間毎のリアルタイムにおいて土砂崩壊の発生予測を行い、NNモデルの適用性について検討する。

土砂崩壊の発生は、誘因となる降雨の影響を強く受けており、降雨量が小さければ全ての溪流で土砂崩壊は発生しないが、降雨量が大きくなると発生溪流と非発生溪流に分かれる。そこで、本研究で扱った降雨の特性を図-6に示す。図-6は、土砂崩壊の発生降雨については、発生推定時刻を含む前後3時間(▲:発生1時間前, ●:発生推定時刻, ■:発生1時間後)の時間雨量と実効雨量(半減期24hr)





を示し、非発生降雨については、時間雨量のピーク時刻を含む前後3時間(△:ピーク1時間前, ○:ピーク時間, □:ピーク1時間後)の時間雨量と実効雨量(半減期24hr)を示している。また、観測エリア毎の降雨を降雨番号で示した。図-6より、発生降雨は右側に非発生降雨は左側に分布しているものの、その境界は不明瞭である。また、発生降雨の中にも発生溪流と非発生溪流が存在していることを考慮すると土砂崩壊の発生は、降雨要因だけでなく地形要因の影響も受けていると考えられる。

溪流毎のリアルタイム発生予測の結果を表-5に示す。表-5は、本研究で対象とした全ての溪流と全ての降雨を用いて降雨継続時間毎に各溪流での土砂崩壊の発生予測をNNモデルで行い、発生溪流については、発生推定時刻に正しく認識できたもの、非発生溪流については、一連続降雨中の全ての期間で非発生を正しく認識できたものを分子に、実測値を分母にして正解率で示している。ここで、降雨番号1-5, 2-3, 3-1, 4-1, 4-3は、土砂崩壊の発生降雨であり、その他は、非発生降雨である。






表-5より、発生降雨におけるNNモデルによる予測は、発生予測溪流数と実測された溪流数の比(33/36)より、91.7%の高い正解率となった。また、各発生降雨について発生溪流別に見ると、誤判断を示したのは、どれも1溪流程度であった。それ








(a) 短期降雨波形の一例



(b) 中間的な降雨波形 (台形) の一例



(c) 中間的な降雨波形 (三角形) の一例



(d) 長期降雨波形の一例

図-7 降雨継続時間中のNNモデルの発生確信度の変化の一例

に対して各発生降雨で崩壊が発生しなかった非発生溪流での予測は、降雨番号4-1、4-3においてそれぞれ77.1%、74.0%とやや正解率は低くなったものの、降雨番号1-5、3-1では、それぞれ100%、93.8%と

高い正解率となった。

一方、非発生降雨については、ニューラルネットワークの判断は、降雨番号2-2の非発生降雨で1溪流で誤判断しているものの、その他の非発生降雨では、

全ての溪流に対して100%の高い精度で正しい判断が行われている。

このように、ニューラルネットワークは、土砂崩壊の発生予測において、どの溪流からいつ発生するかを精度良く判断することができる。

次に、降雨の連続的な変化に伴うNNモデルの発生確信度の変化の一例を図-7に示す。図-7では、代表的な降雨波形として、短期降雨、中間的な降雨（台形、三角形）、長期降雨を用いて代表的な発生溪流または非発生溪流のNNモデルの発生確信度のリアルタイム判断結果を例示する。

図-7より、(a)短期降雨として、降雨番号4-4の非発生降雨の例を示す。NNモデルは、時間雨量80mm/hの時点においても発生確信度は0.0となり、全ての降雨継続時間において正しい判断をしている。

(b)中間的な降雨（台形）では、降雨番号3-1の発生降雨を一例として示す。発生溪流No.16では、降雨継続11時間から発生確信度が高くなり始め、発生推定時刻（●印）である降雨継続14時間において発生確信度1.0となっている。また、発生溪流No.10では、降雨継続13時間以降に発生確信度が高くなり、発生推定時刻（●印）においては、発生確信度1.0を示し、その後の降雨量の低下に伴い発生確信度も低下する傾向を示した。また、非発生溪流の代表例として非発生溪流No.1を示すが、他の非発生溪流も溪流No.1と同様に全てのリアルタイムの判断において発生確信度が0.0を示した。

(c)中間的な降雨（三角形）では、降雨番号4-3の発生降雨を例として示す。発生溪流No.14は、降雨継続12時間から発生確信度が高くなり始め、降雨継続13時間に発生確信度1.0を示し、発生推定時刻（●印）の1時間前に土砂崩壊の発生の危険性を示している。また、発生溪流No.43では、降雨継続13時間から発生確信度が高くなり、発生推定時刻（●印）において発生確信度1.0となっている。非発生溪流No.31では、降雨継続14時間から発生確信度が上昇し降雨継続15時間で発生確信度が0.5以上となり、発生と誤判断を示した。非発生降雨No.6では、全ての降雨継続時間において発生確信度が0.0となった。

(d)長期降雨では、降雨番号4-1の発生降雨の例を示す。発生溪流No.34では、降雨継続52時間の発生推定時刻（●印）において発生確信度が1.0となっている。また、降雨量が減少するにつれて、降雨継続56時間から発生確信度が低下し、降雨継続59時間で発生確信度が0.0となり、また、降雨継続67時間でやや発生確信度が上昇した。発生溪流No.54は、発生推定時刻（●印）までは前述の発生溪流No.34

と同じ傾向を示したものの、それ以降の発生確信度は降雨継続64時間まで1.0となり、降雨継続66時間でやや低下するが、また上昇しそれ以降は、0.0となった。非発生溪流No.16は、降雨継続55～57時間に発生と誤判断している。非発生溪流No.2は、全ての降雨継続時間において非発生と正しく判断している。

このようにNNモデルは、降雨要因の特徴と溪流の地形特性をうまく捕らえて予測しており、土砂崩壊のリアルタイム発生予測に対して有効であることが示された。

5. NNモデルの精度向上に対する検討

前章で示したNNモデルを基本モデルと位置づけ、NNモデルの精度向上に対する検討を行う。豪雨による土石流の発生は、豪雨の襲来する期間にもよるが、数年～数十年に1回程度発生する地域や200～300年に1回しか発生しない地域もある。また、土石流が発生するといっても全ての溪流から発生するわけではなく、豪雨の規模にもよるが発生溪流の数は、非発生溪流に比べて少ない場合が多い。本研究で取り扱ったデータに関しても、同様に土砂崩壊の発生データ数が非発生データに比べて1/20程度と少なかった。

出力データとなる土砂崩壊の発生に関する被害状況の調査精度は、土石流の発生溪流については、十分な現地調査等が行われているためデータの信頼性は高いと考えられる。一方、土石流の発生を免れた溪流は、十分な調査が行われているとは考えにくく、データの精度が土石流発生溪流に比べて劣ると考えられる。そこで、表-6に示す検討ケースに対してNNモデルの精度向上のための検討を行う。

表-6より、検討ケース1は、前章で示した基本モデルとし、検討ケース2～4は、モデル構築においてデータ選別を行った場合であり、検討ケース2（全溪流＋降雨選別）は、全溪流に対して土石流発生降雨の降雨要因のみを用いている。検討ケース3（溪流選別＋全降雨）は、本研究の対象期間中で土砂崩壊の発生が確認されている溪流に対して図-3の降雨模式図で抽出した全ての降雨要因を用いている。検討ケース4（溪流選別＋降雨選別）は、対象期間中で土砂崩壊の発生が確認されている溪流に対して土石流発生降雨の降雨要因のみを用いている。

一方、検討ケース5～8は、基本モデルと同様に全溪流＋全降雨のデータを用いて、学習方法を工夫することにより精度の向上を検討する。検討ケース5

表-6 NNモデルの精度向上のための検討ケース

検討ケース	内 容	最大学習回数	システム構築用データ			
			発生	非発生	合計	
基本モデル	1 全溪流 +全降雨	全溪流に全ての降雨要因を用いる。 (第3章で構築した最良のNNモデル)	10,000	36	736	772
データ選別	2 全溪流 +降雨選別	全溪流に土砂崩壊の発生降雨要因のみを用いる。	10,000	36	418	454
	3 溪流選別 +全降雨	対象期間中に土砂崩壊を経験した溪流に全ての降雨要因を用いる。	10,000	36	158	194
	4 溪流選別 +降雨選別	対象期間中に土砂崩壊を経験した溪流に降雨選別要因を用いる。	10,000	36	74	110
集中学習	5 全溪流 +全降雨	全溪流に全ての降雨要因を用いる。 発生データを2倍にする。	10,000	36×2 =72	736	808
	6 全溪流 +全降雨	全溪流に全ての降雨要因を用いる。 発生データを3倍にする。	10,000	36×3 =108	736	844
	7 全溪流 +全降雨	全溪流に全ての降雨要因を用いる。 発生データを4倍にする。	6,634	36×4 =144	736	880
	8 全溪流 +全降雨	全溪流に全ての降雨要因を用いる。 最大学習回数を3万回にする。	30,000	36	736	772

表-7 学習データに対するNNモデルの検討結果と誤差

検討ケース		基本モデル	データ選別モデル				集中学習モデル			
		1	2	3	4	5	6	7	8	
確信度 0.5以上の 正解率	発生	33/36	25/36	35/36	35/36	35/36	35/36	36/36	34/36	
	(%)	91.7	69.4	97.2	97.2	97.2	97.2	100.0	94.4	
	非発生	736/736	165/165	158/158	21/22	735/736	735/736	730/736	736/736	
	(%)	100.0	100.0	100.0	95.5	99.9	99.9	99.2	100.0	
	全体	769/772	190/201	193/194	56/58	770/772	770/772	766/772	770/772	
	(%)	99.6	94.5	99.5	96.6	99.7	99.7	99.2	99.7	
収束 状況	最大学習回数	10,000	10,000	10,000	10,000	10,000	10,000	10,000	30,000	
	最小発生	0.084	0.306	0.028	0.028	0.028	0.027	0.000	0.056	
	非発生	0.000	0.000	0.000	0.045	0.001	0.001	0.005	0.000	
	全体	0.004	0.055	0.005	0.034	0.003	0.003	0.005	0.003	

~7は、発生データ数が非発生データ数に比べて少ないことから、発生データの数を2倍、3倍、4倍に増やし、学習回数は1万回としている。また、検討ケース8は、発生データ数と非発生データ数の数の比率はそのまま、単純に全体の学習回数を1万回から3万回に増やしている。

表-7に各検討ケースの学習データに対する正解率と誤差を示す。データ選別モデルでは、検討ケース2の全溪流+降雨選別は、基本モデルに比べて発生データの正解率が低下している。このことから、非発生データの降雨要因を少なくすることは、ニューラルネットワークのパターン認識としての判断を鈍らせる原因になると考えられる。また、検討ケース3(溪流選別+全降雨)は、発生データに対する正解率が97.2%と高くなり、非発生データの正解率も100%と高くなった。このことから、過去に土砂崩壊の発生が確認されている溪流のみを用いることにより、発生データの正解率が向上した。検討ケース4(溪流選別+降雨選別)は、発生データに対して検討ケース3と同様に精度の改善が見られるものの、非発生データに対する正解率がやや低下した。これは、検討ケース2と同様に非発生データの

降雨要因を少なくしたことが原因と考えられる。

集中学習モデルでは、検討ケース5, 6, 7により発生データの学習回数を増やすことにより、発生データに対する正解率が向上し、発生データの最小二乗誤差も少なくなってくる。しかしながら、非発生データに対する正解率は、わずかであるが低下し、非発生データの最小二乗誤差が大きくなる傾向を示した。検討ケース7は、発生データの正解率が100%、非発生データの正解率が99.2%となり、発生データを集中的に学習させたNNモデルは、基本モデルに比べて、より安全側の判断を示した。また、検討ケース8は、発生と非発生データ数の比率を変えずに学習回数を3万回まで増やしており、発生データの正解率が94.4%、非発生の正解率が100%となり、基本モデルに比べて、発生の正解率がやや改善されているが、検討ケース7と比べると発生溪流に対する正解率が低くなった。このことから、集中学習モデルにおいて、発生データを集中的に学習させる場合の学習回数は1万回で十分であり、ニューラルネットワークの学習効率面からは、全データを3万回学習させる場合に比べて、発生データを集中的に学習させる方がより効率的で、かつ安全側の判断が





図-8 全データに対するリアルタイム発生予測の結果

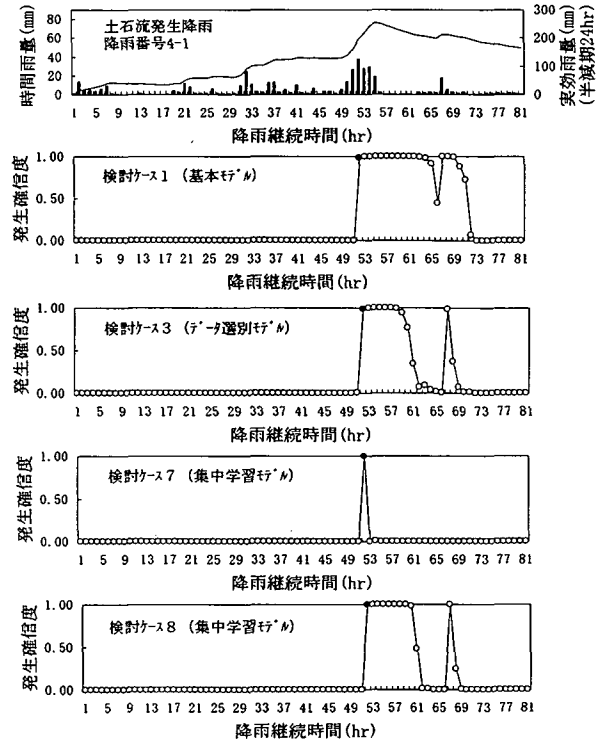
行えると考えられる。

次に、各検討モデルを用いて全溪流に対してリアルタイムで土砂崩壊の発生予測を行った結果を図-8に示す。図-8では、各溪流に対してリアルタイムで発生を予測し、一連続降雨において正しい判断が行われた溪流数を示している。図中の●、△印は、それぞれ発生・非発生の正解溪流数を示しており、検討ケース1の基本モデルに比べて発生・非発生とも精度の向上が見られたのは、検討ケース5～8の集中学習であり、中でも発生溪流に対して最も正解率が高いのは、検討ケース7の発生データを4倍にした場合であった。また、これらの改良NNモデルを用いて、降雨継続中の土砂崩壊の発生確信度の変化の一例を図-9に示す。図-9は、図-7の基本モデルと対比するため、土砂崩壊の発生溪流数が最も多い降雨番号4-3の代表的な溪流番号43と、長期降雨である降雨番号4-1の代表的な溪流番号54について、検討ケース1, 3, 7, 8におけるNNモデルの発生確信度の変化を示している。検討ケース3は、データ選別モデルにおいて最も正解率が高くなったケースであり、リアルタイムの発生確信度の変化は、検討ケース1の基本モデルに比べて、発生確信度【1】を示す時間が短くなり、降雨の変化をより鋭敏に捕らえていると考えられる。また、検討ケース7は、発生データを4倍にした集中学習モデルであり、発生確信度の変化は、土砂崩壊の発生時刻(●印)周辺に対してのみ反応するようになっている。検討ケース8は、基本モデルのデータで学習回数3万回行ったケースで、検討ケース3のデータ選別モデルと同じような傾向を示した。

この様に、本研究で提案しているNNモデルを用いた土砂崩壊のリアルタイム発生予測手法は、実際の土砂崩壊の発生現象をより良く反映することができる。また、学習方法を工夫することによりNNモ




(a) 代表的な発生溪流(No. 43)における発生確信度の変化




(b) 代表的な発生溪流(No. 54)における発生確信度の変化

図-9 検討ケース毎の土砂崩壊の発生確信度の変化の一例



(a) 検討ケース 1 (基本モデル)



(b) 検討ケース 2 (集中学習モデル)

図-10 降雨重心とNNモデルの発生確信度の関係の一例
(降雨番号 4-3, 溪流番号 No. 43)

デルの精度向上が図れる。従って、溪流の個別防災管理への適用可能性が高いことが示された。

6. NNモデルの降雨要因に関する感度解析

NNモデルのリアルタイム発生予測への適用性が前章において確認されたので、ここでは、さらにNNモデルの降雨要因に関する特性を感度解析により検討する。NNモデルは、地形要因と降雨要因を組み合わせた構造となっているため、モデルの特性に地形要因と降雨要因が反映されている。ここでは、土砂崩壊の発生した代表的な溪流として、図-9(a)に示した溪流 (No. 43) の地形要因を用いて、この代表的な溪流において降雨要因を変化させた感度解析を行う。

降雨要因には、時間雨量、実効雨量 (半減期 24hr)、降雨重心の3要因があるため、まず、溪流 (No. 43) の土砂崩壊の発生降雨 (降雨番号4-3) における発生推定時刻の時間雨量61mmと実効雨量 (半減期24hr) 250mmにおいて、降雨重心を変化させることによる発生確信度の変化を図-10に示す。図-10(a)は、検討ケース1 (基本モデル) における降雨重心と発生確信度の変化を示したもので、降雨重心が大きくなるほど、発生確信度は高くなっており、同じ降雨量でも後方集中型の降雨の方が崩壊の発生につながりやすいという一般的な特徴¹⁶⁾と一致している。また、図-10(b)は、検討ケース7 (集中学習モデル) を用いた場合であり、図-10(a)の基本モデルに比べて、降雨重心がより小さくないと土砂崩壊の発生確信度が変化しないことが示されている。これは、降雨重心の学習領域において、非発生データの学習は、降雨重心0~0.91と広い範囲を学習しているのに対して、発生データの範囲は、0.64~0.83と狭くなっており、図-10(b)の集中学習モデルでは、発生データとして用いた降雨重心の学習範囲において発生確信度が大きく変化しており、発生


データに対する感度が良くなっていることが分かる。

次に、前述と同様の地形要因を用いて、降雨重心については、図-10の各検討ケースにおいて、記号●印で示した発生確信度が1.0, 0.5, 0.0となるそれぞれの降雨重心の着目点1, 2, 3において、時間雨量と実効雨量 (半減期24hr) を変化させた場合の発生確信度の変化を図-11に示す。図-11(a)~(c)は、基本モデルにおける降雨重心の着目点1, 2, 3の感度解析結果を示している。各図とも土砂崩壊の発生確信度の変化を等高線による曲面で表している。図-11(a)~(c)において着目点が1, 2, 3と変化し、降雨重心が小さくなると、時間雨量と実効雨量 (半減期24hr) がより大きくなると発生確信度の曲面は、変化しないようになる。しかしながら、図-11(b), (c)の曲面の変化は、同じ実効雨量でも時間雨量の大きいものより、小さいものの方が発生確信度が高くなっており、一般的な常識と異なっている。

同様に、図-11(d)~(f)は、集中学習モデルにおける降雨重心の着目点1, 2, 3の感度解析結果を示している。降雨重心の変化と発生確信度曲面の関係は、ほぼ前述と同じ傾向を示している。また、図-11(d), (e)の曲面は、同じ実効雨量でも時間雨量が大きくなるにつれ発生確信度が一旦上昇し、時間雨量40~60mmを越えると下降しており、一般的な常識と異なっている。


図-6に示した降雨特性より、学習を行った発生降雨データは、時間雨量38~61mm、実効雨量 (半減期24hr) 174~250mmの範囲に分布している。したがって、これらの現象は、学習した発生降雨データを越える降雨データに対して表れており、NNモデルの判断に関しては、外挿領域にあることがわかる。また、集中学習を行った図-11(d), (e)では、学習した発生降雨データの分布領域とほぼ同じ領域において、NNモデルの発生確信度が強調されている。これは、既往の発生データに対する正解率を向上させるには有効であるが、逆に、将来、異なった降雨データが生じた場合には、危険側を予測する可能性

□ 0.00-0.25 □ 0.25-0.50 ■ 0.50-0.75 ■ 0.75-1.00




(a) 基本モデル (降雨重心=0.83)

□ 0.00-0.25 □ 0.25-0.50 ■ 0.50-0.75 ■ 0.75-1.00




(d) 集中学習モデル (降雨重心=0.83)

□ 0.00-0.25 □ 0.25-0.50 ■ 0.50-0.75 ■ 0.75-1.00




(b) 基本モデル (降雨重心=0.3)

□ 0.00-0.25 □ 0.25-0.50 ■ 0.50-0.75 ■ 0.75-1.00




(e) 集中学習モデル (降雨重心=0.72)

□ 0.00-0.25 □ 0.25-0.50 ■ 0.50-0.75 ■ 0.75-1.00



(c) 基本モデル (降雨重心=0.2)

□ 0.00-0.25 □ 0.25-0.50 ■ 0.50-0.75 ■ 0.75-1.00



(f) 集中学習モデル (降雨重心=0.4)

図-11 検討ケース1 (基本モデル) と検討ケース7 (集中学習モデル) の時間雨量と実効雨量 (半減期24hr) を変化させた感度解析の一例 (渓流番号 No. 43)

があることを示している。

一般的にニューラルネットワークの学習アルゴリズムであるBP法では、外挿は困難とされており、NNモデルの利用においては、本研究で示したようにモデルの特性を明らかにした上で、内挿の範囲内で適用¹⁷⁾ する必要がある。また、今後、土砂崩壊の発生データが増えれば、その都度、ニューラルネットワークの学習機能を用いて追加学習を行えば、

より精度の高いモデル構築が可能になると考えられる。

7. おわりに

本研究では、ニューラルネットワークを用いて豪雨に伴う土石流または山腹斜面崩壊のいわゆる土砂

崩壊の発生予測をリアルタイムで行い、ニューラルネットワークの特性について検討した。また、ニューラルネットワークの特性を踏まえて学習方法を工夫することにより、NNモデルの精度向上のための検討を行い、溪流の個別防災管理への適用可能性について検討した。さらに、降雨要因の感度解析を行いNNモデルの特性を示した。以下に結論を列挙する。

1) ニューラルネットワークを用いた土砂崩壊の発生予測は、学習データに対して発生データ91.7%、非発生データ100%と高い正解率が得られた。また、ニューラルネットワークのモデル構築に用いた要因は、本研究で提案している全地形要因と時間雨量、実効雨量(半減期24hr)、降雨重心の3つの降雨要因が重要であることが示された。

2) 構築したNNモデルを用いて土砂崩壊の発生をリアルタイムで予測した結果、NNモデルは、降雨特性と溪流の地形特性をうまく捕らえて予測できることが確認された。

3) 土砂崩壊の発生は、豪雨の規模や襲来する期間にもよるが、一般に発生データに比べて非発生データが多くなる場合がある。このような場合には、発生データを集中的に学習することにより、発生データに対する正解率をさらに向上させることが可能となる。本研究で試みた中では、発生データを4倍にして学習させた場合、発生データ100%、非発生データ99.2%と非常に高いリアルタイム予測結果が得られた。

4) 降雨要因による感度解析から、土砂崩壊の発生データを集中学習させたNNモデルは、基本モデルに比べて発生降雨データの分布範囲をよりの確に捕らえていることが確認された。

なお本研究の結果は、ある限られた地域に対してモデル化を行っているため、地形データや降雨データには、その地域の特徴が表れている。また、地質要因も風化花崗岩に限定して取り扱っているため、他の地域や他の地質に適用するには、再度システムを構築する必要がある。また、ニューラルネットワークは、学習機能を備えているため、今後さらに土砂崩壊の発生や非発生のデータを追加することによりモデルの性能は、改善されていくと考えられる。

本研究のデータの収集に際し、広島県土木建築部、広島県加計土木事務所の方々から多くの支援を頂いた。記して謝意を表します。

参考文献

- 1) 森山裕二, 星野和彦: 土石流危険渓流および地すべり危険箇所の調査結果まとまる。砂防と治水, Vol. 26, No. 2, 1993. 6.
- 2) 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.
- 3) 芦田和男, 高橋保, 沢井健二: 土石流の危険度の評価方法に関する研究, 京都大学防災研究所年報, 第21号, B-2, pp. 423-440, 1978.
- 4) 鈴木雅一, 小橋澄治: がけ崩れ発生と降雨の関係について, 新砂防, Vol. 34, No. 2(121), pp. 16-26, 1981.
- 5) 藤井恒一郎, 久保田哲也, 奥村武信: 土石流発生警報の発令及び避難指示の的確性向上に関する研究, 新砂防, Vol. 47, No. 2(193), pp. 35-42, 1994. 7.
- 6) 鈴木雅一, 福義宏, 武居有恒, 小橋澄治: 土砂災害発生の危険雨量, 新砂防, 110, pp. 1-7, 1979.
- 7) 森山聡之, 平野宗夫, 上松泰介, 川原恵一郎, 白川朋道: ニューラルネットワークを用いた土石流発生予測について, 水工学論文集, 第36巻, pp. 705-708, 1992. 2.
- 8) 平野宗夫: 土石流の発生とその予測, 土木学会論文集, No. 486/VI-22, pp. 1-7, 1994. 3.
- 9) 中野馨: ニューロコンピュータの基礎, pp. 52-60, コロナ社, 1990. 6.
- 10) 広島県土木建築部砂防課: 県北西部の災害メカニズム調査報告書, 1989. 3.
- 11) 建設省土木研究所砂防部砂防研究室: 土石流の警戒・避難基準雨量の設定に関する研究, 土木研究所資料, pp. 9-11, 1985. 3.
- 12) 荒木義則, 鈴木真次, 石川芳治, 水山高久, 古川浩平: 土石流危険渓流における崩壊規模の評価に関する研究, 土木学会論文集, No. 522/VI-28, pp. 133-142, 1995. 9.
- 13) 山下祐一, 石川芳治, 草野慎一: 土石流発生源の崩壊地の土質特性, 新砂防, Vol. 44, No. 5(178), pp. 19-25, 1992. 1.
- 14) 荒木義則, 鈴木昌次, 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, No. 522/VI-28, pp. 143-153, 1995. 9.
- 15) 矢川元基: ニューラルネットワーク, pp. 191-196, 培風館, 1992. 5.
- 16) 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, No. 480/VI-21, pp. 127-136, 1993. 12.
- 17) 土木学会構造工学委員会: 新しい構造システム最適化手法—人工生命技術の応用—, 土木学会構造工学委員会, pp. 3-14, 1996. 9.

(1996. 12. 3 受付)

A STUDY ON THE REAL-TIME JUDGEMENT MODEL OF SEDIMENT STABILITY
OF NEURAL NETWORK FOR COLLAPSE AND
DEBRIS -FLOW IN HAZARD TORRENT

Yoshinori ARAKI, Kohei FURUKAWA, Noriaki MATUI, Takaya OOKIDO,
Yoshiharu ISHIKAWA and Takahisa MIZUYAMA

We have constructed an evolution model for the collapsible and noncollapsible sediments of disasters, due to rainfall and natural torrential factors. The model was constructed as a neural network for pattern recognition. The model examines the actual statue of the sediment stability in a disaster. We present the usefulness of it , investigate ways to improve the general purpose capacity and perform a sensitivity analysis on rainfall factors.