

## (6) 遺伝的アルゴリズムとニューラルネットワークによる 土石流の予測

### PREDICTIONS OF DEBRIS FLOWS BY THE NEURAL NETWORK USING THE GENETIC ALGORITHM

高畠 洋\* 平野 宗夫\*\*

Hiroshi TAKABATAKE Muneo HIRANO

森山 聰之\*\*\* 川原 恵一郎\*\*\*

Toshiyuki MORIYAMA Keiichirou KAWAHARA

*The Neural network which learns with the Genetic Algorithm (GA), the Back-propagation (BP) Algorithm, or the method using both of them is applied to compute the amount of deposits of the debris flow from rainfall data and to judge whether the debris flow occurs or not by rainfall. The narrow or wide range where weights and biases are given before the learning is selected to watch GA's ability of global search. The learning with both GA and BP reduces the error when the network is large. But whichever learning method is used, the network has accuracy of the predictions equally. There are some cases that wide range causes the inaccurate predictions.*

*Key Words : Neural network, Genetic algorithm (GA), Debris flow*

#### 1. はじめに

長崎県の雲仙・水無川において、'91年以降土石流災害が頻発した。森山ら<sup>1)</sup>は、鹿児島県桜島の河川における土石流の発生についてニューラルネットワーク（Neural network, 以下単にネットワークと呼ぶ）に降雨のデータを入力して予測する手法を提案し、これを雲仙・水無川にも適用したが、精度の面で問題を残した。

ネットワークの学習には、局所探索の手法であるバックプロパゲーション（Back-Propagation; BP）法が用いられ、上記の予測においても同法が用いられた。しかし、BP法はいわゆる局所解（Local minimum）に陥る可能性が指摘されている。そこで本研究ではネットワークの学習に、確率的な探索の一手法で大域的探索に優れた遺伝的アルゴリズム（Genetic Algorithm; GA）を用いた予測を試みた。

以下では雲仙・水無川の土石流に関して、GAを用いて学習したネットワークを用いた、降雨データからの土石流発生後の堆積土砂量の予測と、降雨データによる土石流の発生予測について論じる。

#### 2. GAによるネットワークの学習

GAを用いてネットワークの学習をするには、ネットワークを何らかの形で染色体とよばれる一次元の記号列にマッピングする必要がある。本研究では、学習が局所解に陥るのを防いで予測精度を高めるのが目的であるから、GAを専らネットワークの結合のウェイトとユニットのバイアスのチューニングに用いることとし、そのためのマッピングの方法として、図-1に示した実値表現（Real value encoding）<sup>2)</sup>とよばれる

\* 九州大学大学院 工学研究科水工土木学専攻 修士課程 (〒812 福岡市東区箱崎6丁目10-1)

\*\* 工博 九州大学教授 工学部建設都市工学科 (〒812 福岡市東区箱崎6丁目10-1)

\*\*\* 工博 九州大学助手 工学部建設都市工学科 (〒812 福岡市東区箱崎6丁目10-1)

\*\*\*\* 九州大学大学院 工学研究科水工土木学専攻 博士課程 (〒812 福岡市東区箱崎6丁目10-1)

方法を用いることにした。これは、ウェイトとバイアスの値を、そのまま染色体上の遺伝子の値とするものである。

ここで、GAにおける遺伝的操作は次のようにした。選択操作における適応度の評価は、ネットワークに学習パターンを提示し、自乗和誤差の逆数を適応度として用いた。選択操作自体は適応度比例戦略にエリート保存戦略を併用して行った。また、交叉は2点交叉とし、突然変異は、突然変異させる遺伝子の値に-1.0から1.0までの乱数を加えることで行った。

さらに、GAは局所的探索に弱いといわれているので、GAと局所的探索の手法であるBPを組み合わせた2種類の学習法も試みた。一つは、図-2のように、BPによる学習の前に、ウェイトとバイアスの初期値をGAにより決定するものである。これを、以下GABPとよぶ。もう一つは、図-3のようにBPによる学習のち、GAの遺伝的操作を行う手順で世代交代を進めるものである。これを以下BPGAとよぶ。

さらに、GAが大域的探索能力に優れていることを考慮して、ネットワークのウェイトとバイアスの初期値を与える乱数の発生範囲を、従来BP法では、0近くの範囲(-0.2から0.2)としていたものを拡大して、-4.0から4.0にした。

GAを用いた学習と、GAとBPを組み合わせた学習によるネットワークの性能を評価するため、土石流の堆積土砂量予測及び発生予測に関して、表-1に示す5種類の学習を試み、これらの間で学習データに関するネットワークの誤差と、学習させたネットワークによる予測の精度を比較することにした。BP法のみを用いる方法は、ウェイトとバイアスの初期値を0近くの範囲(-0.2から0.2)にした従来のもとのと、GAとの比較のため、この範囲をGAと同じにしたもの試みた。これらの

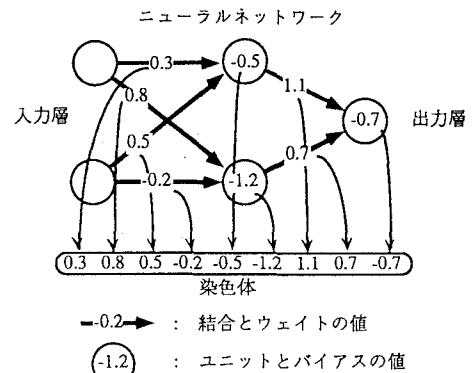


図-1 Real value encoding

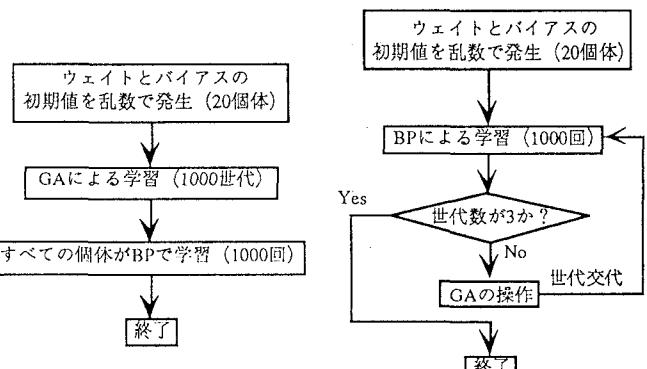


図-2 GABPの学習手順

図-3 BPGAの学習手順

表-1 各学習法における諸条件の設定

学習法	BP	BP4.0	GA	GABP	BPGA
ネットワーク	中間層ユニット数	入力層ユニット数の半分			
	ユニットの傾き	3.0			
	初期値の範囲	-0.2~0.2	-4.0~4.0		
BP	学習係数	0.02		0.02	
	学習回数	3000		1000	1世代当たり 1000
GA	集団サイズ			20	
	最終世代			2500	1000
	交叉率			0.7	0.5
	突然変異率			0.5	0.5

学習法を、以下それぞれBP, BP4.0とよぶ。GAとBPを組み合わせた2つの学習法における、ウェイトとバイアスの初期値はGAと同じ範囲とした。

### 3. 土石流堆積土砂量の予測

#### (1) ネットワークを用いた予測法

はじめに、土石流堆積土砂量の予測を行った。これは、ネットワークを用いて降雨量と堆積土砂量の間の回帰分析を試みるというものである。土石流の流出に関して、平野ら<sup>3)</sup>の計算式によると、ある時刻の土石流の流出高は、その直前の降雨強度とそれまでの累積雨量の積に比例する。そこで、まず降雨の時系列データから降雨群を区分した。降雨群とは図4のような、降雨の記録されていない時間がある時間以上になる場合に、時系列を分割してできる一連の降雨を表わす。土石流の発生した降雨群から予測に用いる降雨要素として、降雨群の総雨量  $R_c$  と、下記の式で定義される種々の累加時間  $\tau$  に対応する累加雨量  $R(t, \tau)$  のうちの最大値  $R_m(\tau)$  を求めた。後者は  $\tau$  時間（または分）雨量最大値とよぶ。

$$R(t, \tau) = \int_{t-\tau}^t r dt \quad R_m(\tau) = \max\{R(t, \tau)\}$$

'91年から'93年の長崎県および建設省の堆積土砂量の資料と、雲仙岳測候所の雨量の記録を用いて予測を行った。土石流を引き起こした降雨群の1時間雨量最大値  $R_m(1)$ , 3時間雨量最大値  $R_m(3)$ , 6時間雨量最大値  $R_m(6)$ , 12時間雨量最大値  $R_m(12)$ , 総雨量  $R_c$  と堆積土砂量  $Q(m^3)$  との関係を求めると図5のようになる。ここで、降雨群は無降雨が6時間以上のとき分割されたとした。

上記の降雨要素  $R_c, R_m(\tau)$  のなかから予測に用いるものを選び、図6のようにネットワークの入力層に、用いる降雨要素の数だけユニットをつくる。そして、用いられる降雨要素は、その中の最大値で除されて正規化され、それが入力層ユニットの入力信号となる。

堆積土砂量は、1個だけつくった出力層ユニットの出力信号から求めることにした。堆積土砂量が  $10^4 \sim 10^6 (m^3)$  と幅広い値をとることを考慮し、出力・教師信号  $S$  と堆積土砂量  $Q(m^3)$  の間を、 $S = -1.95 + \log Q$  により変換することにした。

#### (2) 学習誤差にみる学習法の比較

'91年から'93年までの19回の土石流のデータをネットワークに学習させ、その誤差（出力信号と教師信号の差）の学習1パターンあたりの平均値を調べた。用いる入力降雨要素は、 $R_m(1) \sim R_m(12)$  の12個の場合、 $R_c, R_m(1) \sim R_m(12)$  の13個の場合、 $R_c, R_m(1) \sim R_m(6)$  の7個の場合、 $R_c, R_m(1) \sim R_m(3)$  の4個の場合の4通りを試み、図7に示す結果を得た。

入力降雨要素は、学習法の違いに関わらず  $R_c, R_m(1) \sim R_m(12)$  の場合が、学習誤差が最も小さくなかった。これは、堆積土砂量が長時間の累加雨量に依存するためと考えられる。

学習法に関しては、学習法GAが、どの入力降雨要素においてもBPと同じ程度の誤差が残り、BP4.0よりも誤差の大きい場合もみられた。これは、GAの局所的探索能力の低さによると考えられる。GAとBPを組

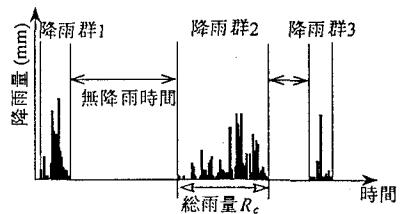


図4 降雨群の切り出し

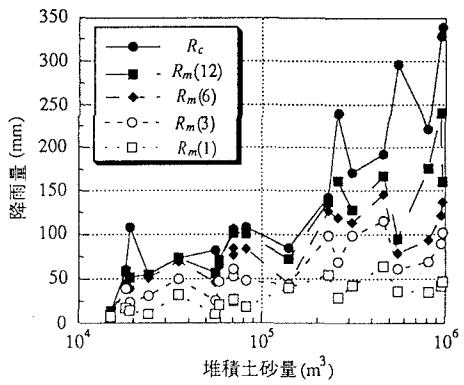


図5 学習データ

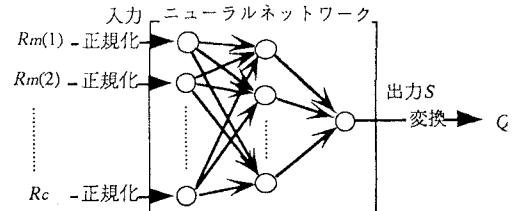


図6 ネットワークによる堆積土砂量の予測

み合わせた学習については、 $R_c, R_m(1) \sim R_m(12)$  と  $R_m(1) \sim R_m(12)$  の BPGA の場合以外は、BP, GA, BP4.0 と誤差は同程度だった。入力する降雨要素の数が少ない場合、ネットワークが小さくなり、計算するパラメータの数が少なくなるため、BP による学習で、十分にネットワーク自体の性能の限界まで誤差を低減できるためであると考えられる。逆にネットワークが大きく、計算するパラメータの数が多い  $R_c, R_m(1) \sim R_m(12)$  の場合、GA による大域的探索と BP による局所的探索の組み合わせによる効果が生じたといえる。

### (3) 堆積土砂量の予測

最も学習誤差が低かった入力降雨要素  $R_c, R_m(1) \sim R_m(12)$  を用い、堆積土砂量の予測を試みた。図-8 は'93年の6回の土石流の堆積

土砂量を、それぞれ以前の土石流のデータを学習させたネットワークによって予測したものである。

6月12日、7月4日に、BP 以外の学習法において実測値と大きく外れた、極端に小さいか、または極端に大きい予測値が出た。これらは、いずれもウェイトとバイアスの初期値の範囲を -4.0 から 4.0 に拡げた学習法であり、学習誤差が BP よりも小さかった学習法が、予測では逆に精度が悪くなるということになった。これは、ウェイトとバイアスの初期値の範囲が広い場合、狭い場合よりも学習によって得られたネットワークのウェイトとバイアスの絶対値が大きくなり、その結果としてユニットの入力・出力の値が、極端に大きいか、極端に小さいものが多くなったためであると考えられる。

そこで、学習に GA を用いる場合においても、ウェイトとバイアスの初期値の範囲を従来と同じく -0.2 から 0.2 にすれば極端な予測はなくなるのではないかと考え、そのようにした学習による予測を試みた。図-9 にその結果を示す。極端な予測はなくなり、ウェイトとバイアスの初期値の範囲が予測の精度に影響することが明らかになった。

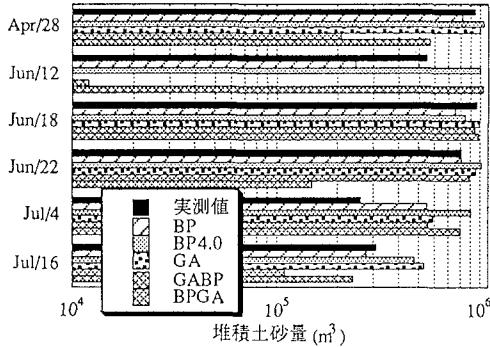


図-8 堆積土砂量の予測

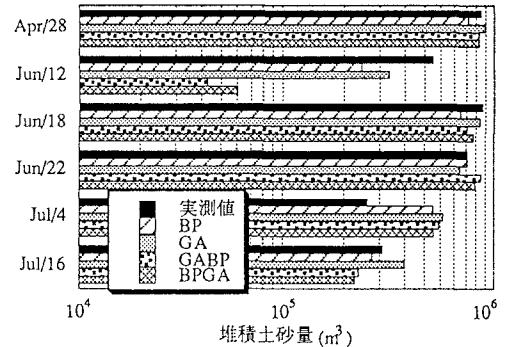


図-9 堆積土砂量の予測  
(ウェイトとバイアスの初期値-0.2から0.2の場合)

## 4. 土石流の発生予測

### (1) 方法

次に、土石流の発生予測を行った。これは、ある降雨群が土石流を引き起こす降雨群か否かをネットワークに判断・分類させるという問題である。土石流の発生条件は、平野ら<sup>3)</sup>の理論によると、降雨の到達時間とその間の雨量に規定される。雲仙の土石流の場合、到達時間は1時間以下であり、土石流の発生は短時間の降雨量に規定される。そこで土石流の発生予測においては、降雨時系列から無降雨期間が2時間以上のと

き降雨群を切り出し、土石流発生・不発生の降雨群とともに10分から60分まで、10分ごとの累加雨量最大値  $R_m(10)$ ,  $R_m(20)$ , ...,  $R_m(60)$  を求め、これらすべてを入力データとして用いた。そして、すべての降雨要素の値をその中の最大値で割って正規化し、ネットワークの6個の入力層ユニットの入力値とした。出力層については2個のユニットをおき、教師信号としてそれぞれのユニットに、土石流の発生した学習パターンには1.0と0.0を与え、不発生のパターンには0.0と1.0を与えた。

学習については、堆積土砂量の予測と同様のBP, GA, GABP, BPGA, BP4.0の学習に加え、堆積土砂量の予測での結果を考慮し、ネットワークのウェイトとバイアスの初期値の範囲の及ぼす影響をみるために、GA, GABP, BPGAの学習法において、初期値の範囲を-0.2から0.2にした学習も試みた。これらをそれぞれGA0.2, GABP0.2, BPGA0.2とよぶ。

'91年5月の降雨群の場合、土石流の発生・不発生の関係は図-10に示すとおりである。

## (2) 結果

'91年5月の11個の降雨群（うち土石流発生は5個）のデータをネットワークに学習させ、「91年の6月から12月までの82個（うち発生10個）の降雨群について予測し、さらに'92年の107個（うち発生20個）を学習させ、「93年の51個（うち発生17個）について予測した。後者の学習データに関しては、不発生に比べ、発生のデータ数が少ないため、学習データセットの作成に際しては、土石流の発生したひとつの降雨群の学習パターンは4個に増やすことにした。

図-11は、「92年の学習において、学習を終了させた時点における、学習1パターンあたりの自乗和誤差を示したものである。これをみると、GA, GABP, GA0.2, GABP0.2の誤差がやや大きい。土石流は、雨が多く降れば発生することが明らかなものであるから、降雨から土石流の発生・不発生の判断をする

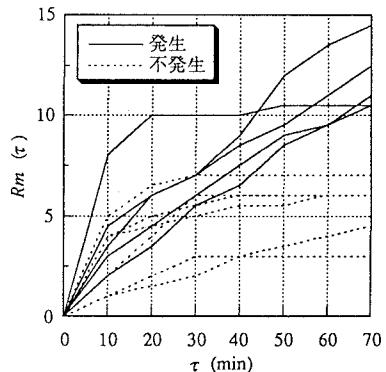


図-10 '91年5月の降雨群データ

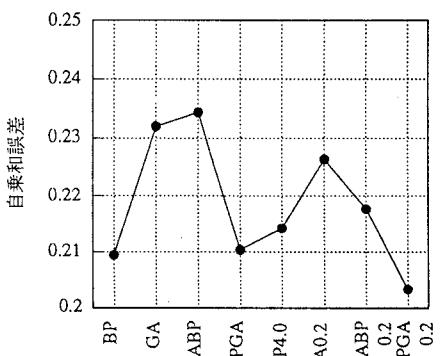


図-11 誤差の比較 ('92年のデータの学習)

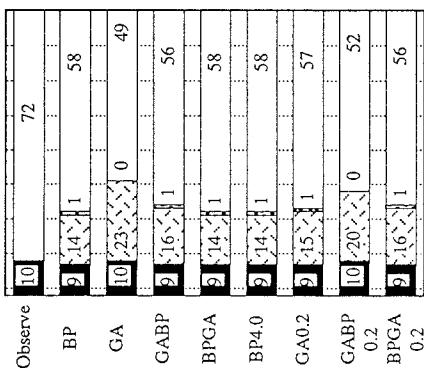


図-12 予測の正誤 ('91年6月～12月)

数字は降雨群の数

- : 発生と予測、実際に発生（発生）
- : 不発生と予測、実際に不発生（不発生）

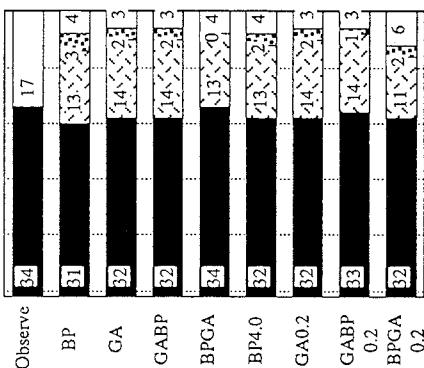


図-13 予測の正誤 ('93年)

数字は降雨群の数

- : 発生と予測、実際は不発生（空振り）
- : 不発生と予測、実際は発生（見逃し）

ネットワークの学習における誤差関数は、極値を複数持つような複雑な形状ではなく、単純なものであると考えられ、それゆえ局所的探索の手法であるBPが、GAよりも誤差を小さくできたと考えられる。なお、'91年5月のデータの学習では、学習パターン数が少なかったため、学習1パターンあたりの自乗和誤差はどの学習法においても  $1.0 \times 10^{-4}$  程度でほとんど差はなかった。

図-12 は'91年の6月から12月までの降雨群の予測について、図-13 は'93年の予測について、その正誤をまとめたものである。予測に際し、発生した学習パターンにおいて 1.0 の教師信号を与えた出力層ユニットが一定値以上の値を出力した場合に、ネットワークが発生と判断したものとみなした。どちらの場合も、どの学習法をもちいても予測の精度は同程度となった。

堆積土砂量の予測において問題となったウェイトとバイアスの初期値の範囲の問題については、学習の誤差、予測の精度とも、範囲を変えても大きな差はなかった。これは誤差関数の形状が単純で、また、発生・不発生の予測の場合、ネットワークの出力層ユニットに 0.0 か 1.0 という出力値の範囲の両端を要求する問題なので、大きなウェイトとバイアスの値によって、ユニットの入出力の値が極端に大きく、または小さくなることが問題にはならなかったようである。

#### 4. 結論

1. ネットワークの学習に関する誤差について、GAのみを用いた学習法は、GAの局所的探索能力の低さのため、BP法を用いた学習と同じ程度かそれより大きな誤差が生じる。GAとBPを組み合わせた学習は、ネットワークの規模が大きい場合に誤差を小さくする効果が表れる。
2. ネットワークの予測の精度に関しては、GA, BP, およびこれらを組み合わせた学習を行ったネットワークの間で、予測の精度に大きな差はみられない。
3. ネットワークのウェイトとバイアスの初期値の範囲を広くして学習する場合、堆積土砂量の予測のようなネットワークによる回帰分析の作業の場合、学習したネットワークの予測の精度が悪化する場合がある。

#### 参考文献

- 1) 森山 聰之ほか：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卷、pp705～708、1992年
- 2) 北野 宏明：遺伝的アルゴリズム、産業図書、pp237、1993年
- 3) 平野 宗夫ほか：活火山流域における土石流の発生限界と流出規模の予測、第30回水理講演会論文集、pp181～186、1986年