

# ニューラルネットワークによる土石流流出量の予測 Prediction of Amount of Debris Flow by Using the Neural Networks

川原 恵一郎\* 平野 宗夫\*\* 森山 聡之\*\*

By Keiichiro Kawahara, Munee Hirano and Toshiyuki Moriyama

At Unzen Volcano, debris flows have frequently occurred in the Mizunashi River and caused severe damage in the downstream by depositing large amount of sands and stones. Therefore it is great important to estimate the amount of deposits for protecting the area from the disasters. In this study, the neural networks which can learn a general rule from given examples is used to estimate the amount of deposits due to rainfall. The results of the predictions lead to the conclusion that the neural networks is applicable to estimate the amount of debris flow.

*Keywords : Debris flow, Neural networks, Unzen Volcano*

## 1. はじめに

雨水の流出解析に関しては、単位図法、貯留関数法、特性曲線法など多くの手法が提案され実用に供されている。これに対して土石流に関しては、現象が複雑でかつ精度のよいデータが少ないことなどのため、降雨から流出量を推定する信頼性のある手法は未だ確立されていない。流出解析については平野ら<sup>1)</sup>の提案があり、桜島や雲仙の土石流に適用されているが、同定すべきパラメータが多く、実用上問題がある。最近、欧ら<sup>2)</sup>は土石流のピーク流量に関して経験式を提案しているが、左右辺の次元が一致していないなど物理性に乏しく一般性に欠ける。

著者ら<sup>3)</sup>は、土石流の発生についてニューラルネットワークを利用した予測手法を提案し、雲仙・水無川に適用して好結果を得た。近年、ニューラルネットワークは流出解析へも適用が試みられているが、カルマンフィルター導入の華々しい成功にくらべると成果は乏しく、流出解析に導入する利点は少ないように思われる。

雲仙・水無川においては91年以来土石流災害が頻発しており、大量の家屋が破壊されているが、災害は大量の堆積土砂によって生起している。したがって、発生予測より流出土砂量予測に対する要請が高いのが実情である。本研究においては、ニューラルネットワークを利用して流出土砂量の予測を試みる。

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

\*\* 正会員 工博 九州大学教授 工学部建設都市工学科 (同上)

\*\* 正会員 工博 九州大学助手 工学部建設都市工学科 (同上)

## 2. 降雨と流出量の関係

土石流の流出規模に関して、平野ら<sup>1)</sup>が土石流のハイドログラフに関する理論より導いた計算式は(1)式で近似される。これは土石流の流出規模を示し、土石流の流出高が直前の降雨強度と累積雨量の積に比例することを表している。

$$\frac{Q(t)}{A} \approx Mr(t) \int_0^t r(\tau) \cos \theta d\tau \quad (1)$$

$$\text{ここに, } M = \frac{fs}{(fs-1)\lambda} \int_{k \sin \theta / \lambda}^{\infty} \phi(\eta_0, l) dl, \quad \eta_0 = \int_0^t r(\tau) \cos \theta d\tau, \quad fs = (1-\lambda)/(1-\lambda-c)$$

であり、 $Q$ は土石流の流量、 $A$ は流域面積、 $r$ は降雨強度、 $t$ は時間、 $c$ は土石流の濃度、 $\lambda$ は堆積層の空隙率、 $k$ は堆積層の透水係数、 $\theta$ は堆積層の斜面勾配、 $l$ は堆積層の斜面長、 $D$ は堆積層の厚さ、 $\phi(\eta, l)$ は $\eta = \lambda D$ および $l$ の結合密度関数である。

次に、土石流の流量を規定する降雨要素の抽出のために、時間雨量の時系列データから降雨群を区分する。降雨群とは図-1に示すように、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時系列を表す。そして、得られた全降雨群の中から、土石流が発生したものを選出し、その時の流出土砂量との関係を調べる。




図-1 降雨群の定義

選択された降雨群から共通の降雨要素として次の2種類の降雨を算出する。ひとつは雨の降り始めから降り終わりまでの総雨量 $R_c$ であり、他のひとつは下記の(2)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 $R_m(\tau)$ である。

$$R(t, \tau) = \int_{t-\tau}^t r dt \quad (2)$$

$$R_m(\tau) = \max \{ R(t, \tau) \} \quad (3)$$

長崎県および建設省の資料によると、土石流の流出土砂量は図-2のようである。水無川における流出土砂の大部分は下流域に堆積しており、測量結果から堆積土砂量が求められている。91年、92年は例年より降雨量が少なかったため流出土砂量も少なかったが、93年は記録的な大雨の連続で、堆積土砂量100万 $m^3$ に近い土石流が数回発生し、水無川流域で大規模な災害が続発した。

雲仙岳測候所における時間雨量記録を用い、土石流の流出量 $Q$ を最大時間雨量 $R_m(1)$ 及び総雨量 $R_c$ と比較すると図-3及び4のようになる。ここで、降雨群は無降雨が6時間未満のものと定義している。図-3において、91、92年の流出土砂量は時間雨量と相関が高いが、93年は前2年と大きく異なっている。しかし、総雨量と

流出量の関係は図4のように91-93年を通じて同一傾向を示しており相関係数は0.92と高い。また，流出土砂量と各累加時間の降雨量との相関係数を求めてプロットすると図-5のようになり，相関係数は累加時間が長くなるに従って高くなり，30時間以上ではほぼ一定値0.92を示している。このことから，流出土砂量は30時間以上の長期の降雨量に規定されると考えられる。




図-2 水無川の土石流による流出土砂量




図-3 最大時間雨量と流出土砂量




図-4 総雨量と流出土砂量

### 3. ニューラルネットワーク理論

本研究に用いたニューラルネットワークの構造および学習理論について以下に述べる。ニューラルネットワークの構造は3層型で，各層には最小素子であるユニットがある。入力層の各ユニットはセットされた入力信号をそのまま中間層の全てのユニットへ伝達する。そして，中間層と出力層では図-6に示すように，前層から出力された信号 $x$ に重み $w$ を乗じた値の総和としきい値 $\theta$ の差 $\sum wx - \theta$ を(4)式のシグモイド関数で変換して出力する。

$$f(a) = \frac{1}{1 + \exp(-\gamma a)} \tag{4}$$

ここで， $\gamma$ はシグモイド関数の傾きで，図-7に示すように $\gamma$ を大きくするとステップ関数に近づく。

ニューラルネットワークの学習とは，提示された入・出力データに応じて重みとしきい値を調節することで，それにはバックプロパゲーション法とよばれる学習則を用いる。この学習則では，ネットワークの評価は(5)式で定義される誤差関数で行われる。




図-5 各累加時間の降雨量と流出量の相関係数

$$E_p = \frac{1}{2} \sum_k (d_{pk} - z_{pk})^2 \quad (5)$$

ここで、 $z_{pk}$ は入力パターン $p$ に対する出力層の $k$ 番目のユニットの出力、 $d_{pk}$ はそれに対する期待すべき出力で教師信号という。

(5) 式は重み $w$ の関数と考えられるので、その最小値探索に最急降下法を適用すれば、次式で表される量だけ重みを変化させればよいことになる。

$$\delta w = -\varepsilon \frac{\partial E_p}{\partial w} \quad (6)$$

ここで、 $\varepsilon$ は比例定数である。

これにより、中間層のユニット $j$ と出力層のユニット $k$ の重み $w_{jk}$ の更新は

$$w_{jk}(t+1) = w_{jk}(t) + \eta \delta_{pk} z_{pj} \quad (7)$$

で表される。ここで、 $t$ は学習回数、 $\eta$ は修正幅を決定する学習係数、 $\delta$ は誤差項で次式で表される。

$$\delta_{pk} = \gamma z_{pk} (1 - z_{pk}) (d_{pk} - z_{pk}) \quad (8)$$

また、出力層の誤差量を中間層の誤差量の計算に用いれば、入力層のユニット $i$ と中間層のユニット $j$ の重み $v_{ij}$ の更新は(9)式、その誤差項は(10)式で表される。

$$v_{ij}(t+1) = v_{ij}(t) + \eta \delta_{pj} y_{pj} \quad (9)$$

$$\delta_{pj} = \gamma y_{pj} (1 - y_{pj}) \sum_k \delta_{pk} w_{jk} \quad (10)$$

ここで、 $y$ は中間層のユニットの出力である。

実際の学習には、一回の重みの修正時に全パターンの誤差の総和 $\sum E_p$ により誤差項を計算する一括修正法を採用する。以上の学習理論により、図-8のようなフローチャートで降雨量と土石流流出量のルールを習得し予測を行う。




図-8 ニューラルネットワークによる降雨量－流出土砂量の学習過程




図-6 ユニットのモデル




図-7 シグモイド応答関数

なお、初期条件については、中間層のユニット数はほぼ入力層ユニット数の半分、シグモイド関数の傾きは3.0、学習係数は0.5、結合荷重は $0 < W < 0.2$ の乱数を与えた。これらの値は、経験的に得られた値であるが、それぞれ学習アルゴリズムや学習すべき問題の性質により変化するものである。また、各初期条件は相互に影響するので、一つの条件をわずかに変化させただけでは、学習時の誤差の収束性を大きく変えるには至らない。学習を終了するときの条件は学習時間、学習回数、及び全パターンの誤差の総和  $\sum E_p$  の収束状況を考慮して決定する。

4. 土石流の流出土砂量を規定する降雨パターンの選択

長時間の雨量と流出量に相関があることは前述したが、実際に流出量を規定する降雨要素を選択する場合、累加時間の取り方や種々の雨量要素の組み合わせが問題となる。ここでは、ニューラルネットワークの学習による認識状況から判断することにする。

まず、学習データセットとして入力信号と教師信号を用意する。教師信号としては流出量を与えるが、範囲が大きく、かつ分布が偏っていることを考慮して、図-8のように対数関数で正規化する。入力信号は長時間の累加雨量、あるいは総雨量と短時間の累加雨量とし、それぞれ最大値で割って正規化する。入力について累加時間を変化させて学習を行い、認識状況を調べる。




図-9 正規化した教師信号

次に、91年から93年の全ての流出データについて、入力する降雨要素の内容を変えて学習させたときの認識内容を表-1に示す。ここで、誤差は各流出量とネットワークが学習で認識した量の差の絶対値とし、それらの平均と標準偏差が示されている。それによると、ケース7が誤差の平均及び標準偏差ともに最小であることが分かる。よって、降雨群からの総雨量と1～12時間雨量最大値の13個の要素を用いて、流出土砂量を推定するのが最適であると思われる。また、ケース7について、実測流出土砂量と学習により認識した計算土砂量を示すと図-9のようになる。この結果から、実測土砂量と計算土砂量との相関係数を求めると0.97となり、図-5と比較しても精度よく学習していることが分かる。

表-1 入力要素と学習誤差

|      | 入力降雨要素                                | 認識誤差  |       |
|------|---------------------------------------|-------|-------|
|      |                                       | 平均    | 標準偏差  |
| ケース1 | $R_m(1), R_m(2), \dots, R_m(12)$      | 0.10  | 0.076 |
| ケース2 | $R_m(1), R_m(2), \dots, R_m(24)$      | 0.082 | 0.056 |
| ケース3 | $R_m(1), R_m(2), \dots, R_m(36)$      | 0.070 | 0.068 |
| ケース4 | $R_m(1), R_m(2), \dots, R_m(48)$      | 0.074 | 0.059 |
| ケース5 | $R_m(1), R_m(2), R_m(3), R_c$         | 0.071 | 0.057 |
| ケース6 | $R_m(1), R_m(2), \dots, R_m(6), R_c$  | 0.070 | 0.056 |
| ケース7 | $R_m(1), R_m(2), \dots, R_m(12), R_c$ | 0.061 | 0.056 |
| ケース8 | $R_m(1), R_m(2), \dots, R_m(24), R_c$ | 0.073 | 0.057 |




図-10 学習の結果

5. 流出量の予測モデルの検証

過去の全データから入・出力の関係を最も良く認識できるパターンとして、総雨量と1～12時間雨量最大値という指標が得られたので、それらの降雨指標で流出量の予測を行い検証する。水無川における土石流の記録は91年5月15日から始まるが、この月には連続して土石流が発生した。そこでまず、91年の5月の流出量を学習し6月30日の流出土砂量を予測させる。以下、災害が記録されるごとにそのデータを追加して学習させ、次の流出土砂量を予測させる。図-10は予測結果を示したもので、実測土砂量と予測土砂量を比較している。まず、91年6月30日土砂量は5月に記録されたものと比べてかなり大きい規模であったが、学習データが少なかったこともあり、少なく予測されている。92年は8月13日には実測よりも少なく予測されているが、このときは断続的に発生しているため、データの誤差が大きいことも考えられる。93年4月28日には、既往最大を大きく上回る流出量であったが、良好な予測結果となっている。予測結果は総じて実測値とよく一致しており、本モデルの有効性を示している。

6. おわりに

ニューラルネットワークにより土石流の流出土砂量の予測を試み、複数の降雨指標を用いることにより、かなり高い精度での認識及び予測が可能であることを示した。ニューラルネットワークは流出機構をブラックボックス的に取り扱うが、新たなデータの蓄積によりシステムを自己修正できるのが特徴である。雲仙・水無川においては、今後火山活動の推移とともに土石流の流出状況も変化していくので、本モデルのような自己学習機能を有する予測手法が有効であると考えられる。今後は、雨量や土砂量の時間分布を十分に考慮した入力信号の正規化、あるいは学習パターンの選択・判別の方法などの確立および予測精度の向上が課題である。

参考文献

1) 平野宗夫・正田誠・森山聡之：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，181-186，1986  
2) 欧国強・唐邦興・小橋澄治・水山高久：土石流ピーク流量の統計的予測に関する研究，新砂防，第44巻，第2号，14-21，1991  
3) 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，第36回水工学論文集，705-708，1992




図-11 流出土砂量の予測結果