

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
Forecasting for the occurrence of debris flow
using Neural Networks.

森山聰之*・平野宗夫**・上松泰介***・川原恵一郎***・白川朋道***

By Toshiyuki MORIYAMA,Muneo HIRANO,Taisuke JYOMATSU,

Keiichirou KAWAHARA and Tomomichi SHIRAKAWA

A model for the forecasting the occurrence of debris flow has been developed by Hirano et al. In this model, the concentration time and critical rainfall rate are necessary for the forecasting. In this paper, without giving the concentration time and critical rainfall rate, a forecasting model using neural networks is derived. To examine its practical applicability, the model proposed here is applied to Unzen Volcano. This model predicted the most of occurred debris flows in the rain on the volcano.

Keywords: neural networks, critical rainfall rate, debris flow

1 はじめに

土石流発生予測に関して、平野・疋田・森山^{1),2),3)}らは火山性土石流の発生機構及び流出過程についてモデル化を行い、土石流の発生と流出規模の予測手法の確立を目的として検討を行ったが、土石流発生予測を行うためには、限界降雨と到達時間を求める必要があり、これは多少の経験を必要とする。そこで今回はこれらを求めずに土石流発生予測を行うためにニューラルネットワークを導入した。ニューラルネットワークは人間の神経細胞のモデルを用いた情報処理システムのことであり、このニューラルネットワークには外部環境に合うように自分を変化させて調整する自己学習が可能であるため、従来の予測システムに比べ、より人間に近い判断を下すものとして期待できる。

2 ニューラルネットワーク理論

本研究では、図-1のような入力層*i*・中間層*j*・出力層*k*からなる階層型の構造をしたニューラルネットワークを使用し、教師付き学習法であるバックプロパゲーション（誤差逆伝播法）を利用した。バックプロパゲーションは出力層の各ユニットが実際に出力した値と教師信号との誤差を規則にしたがって入力層へ向かって伝播させるものである。ネットワークを構成する最小単位であるユニットは図-2のようになっており、応答関数には

$$f(x) = \frac{1}{1+e^{-(rx-\theta)}} \quad (1)$$

で表されるシグモイド関数を使用した。ここに、*r*はシグモイド関数の傾き、*x*は入力及び*θ*はしきい値である。各ユニットからの出力は[0,1]の値を取るようにしている。階層型のネットワークではユニットからの出力は1方向のみ

* 正会員 工修 九州大学助手 工学部水工土木学科 (〒812 福岡市東区箱崎6-10-1)

** 正会員 工博 九州大学教授 工学部水工土木学科 (同上)

*** 非会員 九州大学学生 工学部水工土木学科 (同上)

に伝わり、入力層の各ユニットに出力された値 x は応答関数 f により変換され全ての中間層に向かって出力される。これに各々のユニット間に付けられている重み w を乗じたものが中間層への入力値として入力される。中間層と出力層の間においても同様の処理が行われ、最終的に出力層から出力されたものに教師信号を与える。ネットワーク間の重みを変えていく。ネットワークはこれをいくつかのパターンについて繰り返し学習することにより重みを決定し、理想的なネットワークを形成する。出力層のユニット k のパターン p が入力された時の出力 O_{kp} と教師信号 T_{kp} のずれの程度を出力層での誤差とすると、パターン p に対する誤差関数及び全パターンでの誤差はそれぞれ次式で表される。

$$E_p = \frac{(T_{kp} - O_{kp})^2}{2} \quad (2) \quad E_T = \sum_p E_p \quad (3)$$

この E_T が最小となったものを最適なネットワークとしてこの E_T を極小化するように重みを変化させる。これを学習と呼ぶ。ここで E_T を極小化するためには、 E_p の極小化が必要であり、これは非線形最小化問題である。この問題の解法としてよく挙げられるのが前述のバックプロパゲーションである。バックプロパゲーションの計算手法としては最急降下法と修正モーメント法を採用することにする。前者は中間層のユニット j と出力層のユニット k との結合係数（重み）を V_{kj} 、入力層のユニット i と中間層ユニット j との結合係数を W_{ji} とすると、各々の結合係数の微小変化に対する E_p への影響 $\delta E_p / \delta V_{kj}$ 、 $\delta E_p / \delta W_{ji}$ を求め、 E_p が減少する方向に結合荷重が修正されるように次式をパターン p が入力された時の修正量として結合荷重を修正していく手法である。

$$\Delta V_{kj} = -\alpha \left(\frac{\delta E_p}{\delta V_{kj}} \right) \quad (4)$$

$$\Delta W_{ji} = -\alpha \left(\frac{\delta E_p}{\delta W_{ji}} \right) \quad (5)$$

後者は誤差の極小化を早く行うため、学習が進んでからは前回の修正方向に近い方向で修正を行う修正モーメント法と呼ばれる手法である。今回は、この二法で学習を行った。

3 土石流発生限界理論

図-1のような砂質斜面の表面流の発生条件は次式で表される。

$$\frac{1}{T} \int_0^T R(t - \tau) \cos \theta dt \geq D k \tan \theta \quad (6)$$

ここに D は堆積層の厚さ、 L は斜面長、 k は透水係数 θ は斜面の傾斜角、 R は降雨強度及び T は到達時間とする。

上式において右辺は斜面に関する項、左辺は到達時間内の平均降雨

強度を表している。従って、ある斜面において到達時間内の降雨強度がある値を超えると、表面流（土石流）が発生することになる。つまり土石流の発生を予測するためには、到達時間とその間の限界降雨強度を見い出す必要がある。

4 雲仙普賢岳の降雨データによる計算と結果

今回、雲仙普賢岳の噴火に起因して発生した水無川における土石流を平成3年5月1日から9月30日までの気象庁の雲仙普賢岳測候所及び島原測候所の地上雨量データから各降雨について T 時間の累加雨量を求め検討した。なお、土石流の発生時刻が判明している資料については、発生時刻以前の降雨波形を対象とした。使用したデータは時間

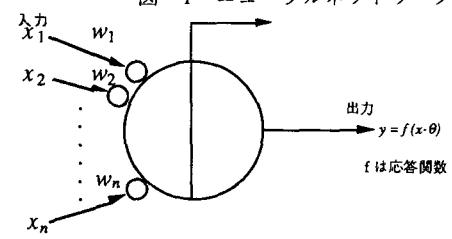
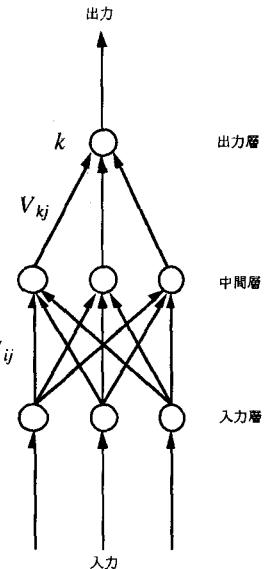


図-2 ユニットモデル

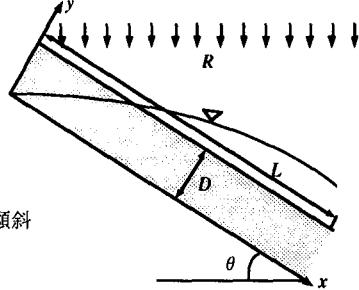


図-3 斜面の模式図



図-4 雲仙概要図

雨量であるため T を 1 時間から 5 時間まで変化させ累加雨量の最大値を計算した。

5 計算結果

5.1 単純パーセプトロンでの学習 まず、入力層ユニット 2、出力層ユニット 1 のネットワークに $(0.50, 0.05)$ ・ $(0.05, 0.50)$ の入力に対し 0.990 の教師信号を、 $(0.95, 0.50)$ ・ $(0.50, 0.95)$ という入力に対しては、0.010 の教師信号を与えて学習を行った。

学習の結果、図-5 に示すようにユニットからの出力に使われている r が、大きい程、誤差が収束する速度は速いが、学習後、データを入力して出力させた場合 $(0.50, 0.05)$ ・ $(0.05, 0.50)$ に近い点には 0.990 に近い出力を、 $(0.95, 0.50)$ ・ $(0.50, 0.95)$ に近い点に 0.010 に近い出力をするはずであるが、図-6・7・8 に示すように r が大きいと必ずしもネットワークが正しい学習をしているとは言えないことがわかった。

● $o > 0.9$

○ $0.1 < o < 0.9$

× $o < 0.1$

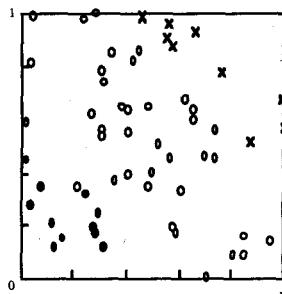


図-6 $r=1$

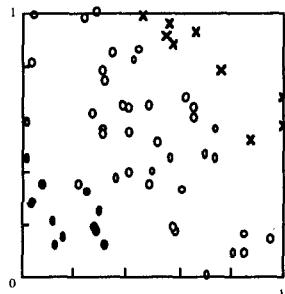


図-7 $r=5$

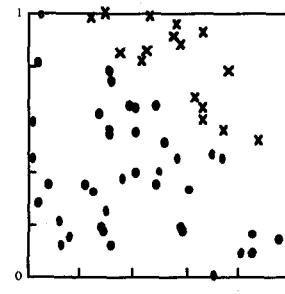


図-8 $r=1000$

5.2 3層ネットワークでの学習 次に、図-1 のような 3 層ニューラルネットワークを用い各入力層に 1 時間から 5 時間の各累加雨量を入力し、出力層に対して土石流の発生を 0.990、不発生を 0.010 の教師信号を与えた。但し入力は累加雨量の最大値が 1.0 となるように正規化されている。まず入力層、中間層のユニットの数の違いが、学習の結果にどのような影響を及ぼすか調べるために、適当に降雨を選び誤差が 0.01 以下になるまで学習を行った後、別の降雨を入力し、それに対する出力を求めた。図-9 に示すように、入力層、中間層のユニット数を変えた場合、入力層、中間層とも数の少ないもののはうが学習が早く収束する傾向がある。また、出力結果にそれほどの差は見られなかった。

5.3 5月の降雨を使っての予測 図-11 に示される雲仙における 5 月の降雨の時間毎の最大累加雨量を学習させた。ここで、入力層と中間層の数は 2 とする。つまり 1 時間と、2 時間の最大累加雨量のみを入力とし、 $r=2, 5, 8$ のそれぞれについて学習させてみた。学習後のネットワークに 6 月以降の累加雨量のデータを入力して、出力させたものを、図-12 及び、図-13、図-14 に示す。図-10 より、5 月の降雨を使って学習させた場合、 r の違いや、最急降下法と、修正モーメント法の両者を使った場合で出力結果に違いはなかったと判断できる。図-12

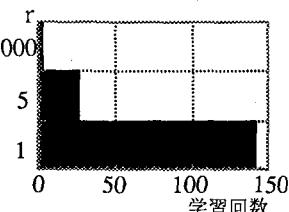


図-5 シグモイド関数の傾き r と学習回数の関係

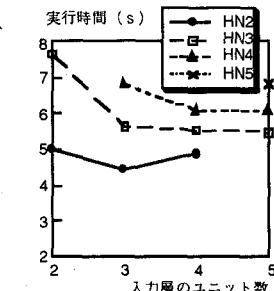


図-9 入力層及び中間層の数による比較

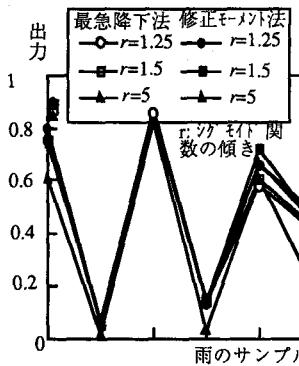


図-10 降雨による出力の比較

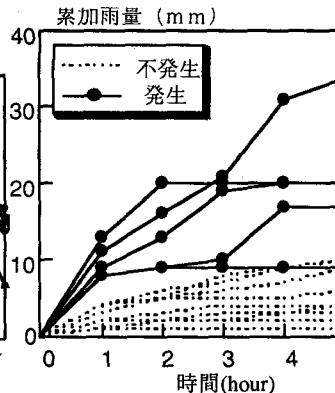


図-11 5月の累加雨量

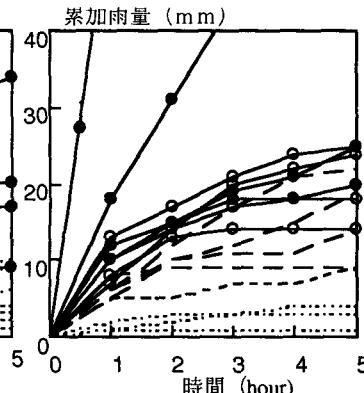


図-12 6月の累加雨量

13・14に示すように土石流の発生が確認されている5つの降雨に対しては、全て0.990と出力されているが、発生しなかった降雨または、発生が確認されていない降雨に対しても0.990と出力している降雨が13個ある。これらに対しては、土石流の発生の有無を再確認する必要があるが、一応安全側であるといえる。また7月3日以降は河床が火碎流で埋まり発生場の状況

が大幅に変わっている可能性が高い。

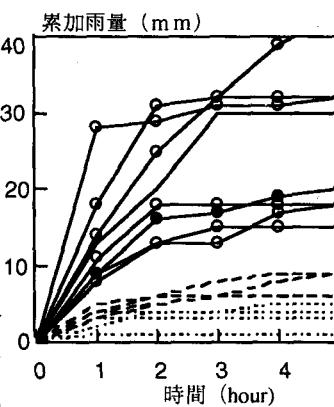


図-13 7月の累加雨量

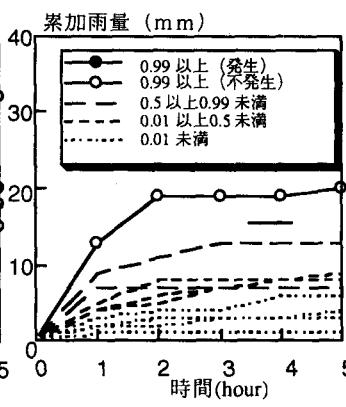


図-14 8月の累加雨量

従って5～7月あるいは5～8月の雨を学習させそれより後の期間の予測に用いる必要があると考えられる。また、出力の値は降雨が大きくなるほど大きな値を示しており、予測の信頼度として扱うことが可能であると考えられる。

6 結語

以上のことから（1）土石流の発生予測にニューラルネットワークを適用し、ある程度良好な結果を得た。（2）しかし、シグモイド関数の傾きの決定は、学習の速度と出力の信頼性のかねあいを考慮する必要があると結論づけられる。今後の予測としては、建設省のレーダによる雨量で細かい累加時間（5分間隔）の予測を行い、桜島のように土石流の発生がきちんと観測されている雨量データで再度検討を行うこと、学習速度を向上させるために、各種の非線型最適化手法を試みること、降雨域のパターン認識や火碎流の発生予測にも応用すること等が考えられる。

参考文献

- 1) M.Hirano, M.Hikida, T.Moriyama, Field Observation and Prediction of the Hydrograph of Volcanic Debris Flow, 4th Congress APP IAHR, 287-297, (1984)
- 2) 平野宗夫・疋田誠・森山聰之、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)
- 3) M.Hirano, T.Moriyama, M.Hikida, Modeling of Deposition of Volcanic Ash and Runoff of Debris Flow in Sakurajima Volcano, Journal of Hydroscience and Hydraulics Engineering Vol.5 No.2, (1988)
- 4) 中野聰他、入門と実習・ニューラルネットワーク、技術評論社、(1991)
- 5) 平野広美、Cでつくるニューラルネットワーク、パソコンメディア社、(1991)

謝辞 本論文を作成するにあたり、九大工学部水工土木学専攻の安道竜也・福富章尚院生に協力頂いた。記して感謝の意を表す。