

土石流の発生予測におけるニューラルネットワークの適用について

九州大学工学部 正員 森山 聰之
 ○九州大学工学部 学生員 上松 泰介
 九州大学工学部 学生員 白川 朋道
 九州大学工学部 学生員 川原恵一郎

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探る必要があり、これは多少の経験を必要とする。そこで今回はこれらを直接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、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期待される。

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方向のみに伝わり、入力層の各ユニットに入力された値*x*はそのまま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、入力値は応答関数により変換された後、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を採用することにする。バックプロパゲーション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

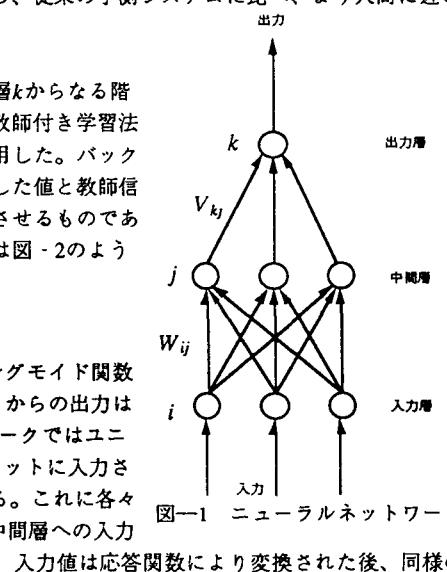


図-1 ニューラルネットワーク

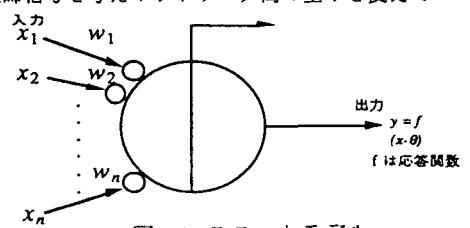


図-2 ユニットモデル

係数を W_j 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り、修正量は、次の式で表される。

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

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

3 ニューラルネットワークによる学習と結果

本研究では、乱数を用いて200個の降雨時系列を発生させ、そのうちの1~5単位時間の累加雨量最大値を計算した。その一例を図-3に示す。これらの降雨時系列の3単位時間の累加雨量最大値に対し、次の式により土石流の発生確率を求めた。

$$F(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-z^2/2} dz \quad Z = \frac{X - \mu}{\sigma} \quad (6)$$

ここで σ は標準偏差、 μ は期待値である。 X は3単位時間の累加雨量最大値である。

今回は $\mu = 50$ 、 $\sigma = 20$ として200個の降雨時系列に対する土石流の発生確率を求めた。学習用データとしては、その

うち100個の降雨時系列の累加雨量最

大値を入力値とし、

教師信号としては、

(6)式で求めた発

生確率に[-0.1, 0.1]

の乱数を加えたもの

を用いた。この学習

後のニューラルネッ

トワークに、残りの

100個の降雨時系

列の累加雨量最大値

を入力し、土石流の

学習後のネットワークによる出力

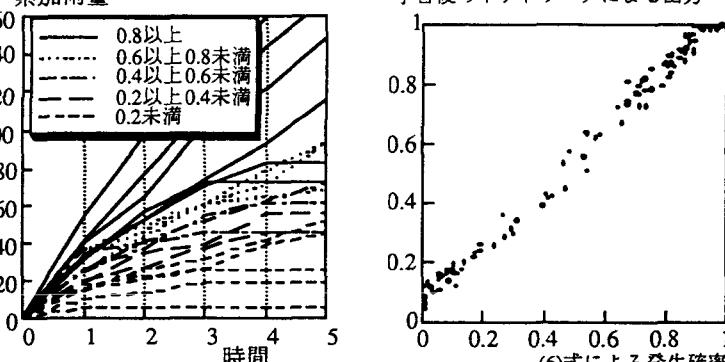


図-3 学習用モデル降雨

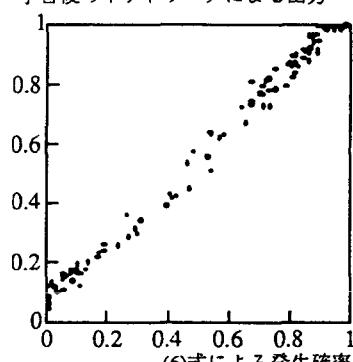


図-4 学習後の出力

発生確率を求め、(6)式により得られた発生確率と比較したものを図-4に示す。図-4よりネットワークはほぼ正解に近い出力をしていると考えられ、3単位時間の累加雨量最大値により土石流の発生確率が決められていることを判断できていると思われる。

4 あとがき

このシミュレーションの結果、ニューラルネットワークは土石流の発生が累加雨量に起因している場合、土石流の発生、不発生を予測することが可能であると思われる。

今後、学習の際のノイズの範囲を変え、結果にどのような影響があるかを調べたり、学習時においてシグモイド関数の傾きやユニットの数等を変え、学習の速度や誤差の収束状況の向上を試みることなどを行う必要がある。また、土石流の発生は、累加雨量だけに起因しているものではないと考えられるので、過去の土石流からの経過時間やその土石流の規模などの履歴も入力に加えてシミュレーションを行う必要があると思われる。

参考文献

- 1) M.Hirano, M.Hikida, T.Moriyama, Field Observation and Prediction of the Hydrograph of Volcanic Debris Flow, 4th Congress APD 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) 中野肇,他、入門と実習、ニューロコンピュータ、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)