

ニューラルネットワークによる土石流の発生限界降雨の評価

Estimation of Critical Rainfall for Occurrence of Debris Flow by Use of the Neural Networks

川原 恵一郎^{*} ・ 平野 宗夫^{**} ・ 森山 聡之^{***}

By Keiichiro KAWAHARA, Muneeo HIRANO and Toshiyuki MORIYAMA

In the previous study, the neural networks with back-propagation method (BP) were applied to predict the occurrence of debris flow. It was also found that this model is useful to estimate the critical rainfall. In this study, LVQ (Learning Vector Quantization) is introduced to improve the accuracy of the prediction. The LVQ and BP are applied to the debris flow at Unzen and Sakurajima Volcanoes. Comparison between the results by both methods confirms that LVQ has an advantage in prediction. The BP model is used to find the critical condition at Unzen Volcano. Validity of the method is demonstrated by the theory of the occurrence criteria of debris flow.

Keywords : Debris flow, Critical rainfall, Neural networks, Prediction

1. はじめに

土石流の発生に関して、その誘因である降雨量に基づいた予測手法¹⁾がこれまでにいくつか提案されている。例えば、平野ら²⁾は土石流の発生限界が雨水流の到達時間とその間の累加雨量によって規定されることを示し、システム解析的手法で土石流の予測を行った。最近、著者ら³⁾は一義的な限界値を推定することなく、降雨パターンから自動的に土石流の発生を予測するために、ニューラルネットワークを用いた手法を提案した。その手法の特徴は、実例から得られた知識により、与えられた問題を客観的に判断できるところにある。その中で採用されたニューラルネットワークは、バックプロパゲーション学習法による多層パーセプトロンとよばれるもので、種々のニューラルネットワークの中で最も代表的なモデルである。この学習法の目的は入力空間と出力空間の応答を関数近似的に実現することで、複雑なシステムの予測・制御などの問題に汎用的に用いられている。

本論文においては、土石流の発生予測は降雨パターンを土石流発生パターンと不発生パターンに判別することと考え、クラス分類を目的とした自己組織化学習を行うLVQ⁴⁾ (Learning Vector Quantization, 学習ベクトル量子化) というニューラルネットワークを利用し、土石流の発生予測精度の向上を試みる。また、バックプロパゲーション法による多層パーセプトロンについては、その関数近似の特性を利用した土石流の発生限界降雨の評価手法を提案し、考察する。

^{*} 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. 従来の手法とその問題点

土石流の発生限界降雨については、累加雨量と直前の雨量によって判断する手法¹⁾や到達時間とその間の累加雨量によって判断する手法²⁾などがある。これらはいずれも未だ予測精度は不十分であることのほかに、雨量データの誤差、発生場の非定常性などの影響で限界が不明瞭になり、判断しにくい場合が少なくない。このような限界値の不明瞭なデータの判定に、雨量パターン全体から発生／不発生雨量パターンの分類を行う手法として、ニューラルネットワークの利用が考えられる。

前報で提案したニューラルネットワークによる土石流の発生予測手法³⁾では、バックプロパゲーション (Back Propagation) による多層パーセプトロン (以下、BPとよぶ) を用いた。これは降雨資料からえられた累加雨量パターンを入力し、出力が土石流発生の場合には危険度1、不発生の場合には危険度0となるようにバックプロパゲーション学習則によりネットワークを同定するものである。学習後のモデルに新たな累加雨量パターンを入力することにより、土石流の発生危険度を予測する。このとき、BPの出力値は連続値をとるので、その出力結果を0.5で閾値処理して予測精度を検証する。BPの学習アルゴリズムの特徴は収束性があることであるが、学習に時間がかかるという欠点がある。さらに、ニューラルネットワークの利点のひとつには、入出力の関係をブラックボックス的にモデル化するため、ノンパラメトリック解析が可能なことである。しかし、土石流の発生予測への適用においては、学習事例の発生雨量パターンと不発生雨量パターンの分類に非線形性が大きい場合、両者のパターン数の差が出力結果に影響を及ぼす傾向がみられる。一般に降雨資料を発生時と不発生時のものに分類すると発生事例の方が少ないので、BPによる出力分布が不発生時の危険度0に偏る結果となる。BPのアルゴリズムはネットワークの出力値と実際に要求する出力との全パターンに対する累積誤差を最急降下法によって最小化することであるから、学習時に発生雨量パターンに対する累積誤差をその事例数の比率で調整することで、ネットワークの出力分布は矯正される。実際には、発生パターンを不発生パターンが同数になるように発生パターンを繰り返して入力するか、不必要な不発生パターンをあらかじめ削除して発生パターンと同数にする方法が用いられる。

3. LVQによる予測モデルの検証

3.1. LVQの学習理論

LVQはクラス分類を行うネットワークパラダイムで入力層、コホーネン層、出力層から構成される。出力層は各クラス毎に1つの出力ユニットを持ち、コホーネン層には各出力に結合するユニットがあり、全ての入力ユニットと結合している。LVQのアルゴリズムは、最初に、入力層のユニット i からコホーネン層のユニット j の結合荷重 w_{ij} を乱数で初期化し、ユニット j の近傍の初期範囲 N_j を大きく設定する。そして、ユニット j と全入力データ x_i との距離 d_i を次式により計算する。

$$d_i = \sqrt{\sum_{j=1}^N (x_i - w_{ij})^2} \quad (1)$$

そして、 d_i が最小となるコホーネン層のユニット j^* を選択する。ユニット j^* と N_{j^*} で定義される近傍への結合荷重 w_{ij} に対して、クラス分けが正しかったときは式(2)、誤ったときは式(3)で修正する。

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(x_i - w_{ij}) \quad (2)$$

$$w_{ij}(t+1) = w_{ij}(t) - \alpha(x_i - w_{ij}) \quad (3)$$

ここで、 t は時間ステップ、 j^* は N_{j^*} に含まれる全てのユニットで、学習係数 α と近傍 N_{j^*} は時間ステップ t の増加とともに減少させ、更新される領域を狭めていく。また、 w_{ij} 以外の結合荷重は変化させない。

LVQでは、ユニット j^* と N_{j^*} で定義される近傍への結合荷重 w_{ij} を参照ベクトルというが、入力に最も近い参照ベクトル以外は何も変化せず、ユニット間の結合が局所的で済むことから、学習時間はBPより短縮できる。

3.2. LVQ とBP の学習精度の比較

LVQとBPの両予測手法を雲仙、桜島の土石流によって検証する。雲仙の事例については、1991年5月から1995年7月までを対象とし雲仙岳測候所の10分雨量記録から求めた10, 20, ..., 180分累加雨量最大値を入力データとする。桜島の事例については、1983年8月から1986年7月の建設省のレーダー雨量計による5分雨量記録による、5, 10, 15, ..., 90分累加雨量を入力データとする。両手法とも学習回数は10000回を上限とし、最も正解率の良いモデルによって結果を調べる。ここで、正解率とは、全学習パターン数と分類正解パターン数の比率である。

表-1は全事例を学習した後の学習データの認識結果から学習結果を比較したものである。さらに、学習正解率を比較すると表-2のようになる。これによると、両手法とも高い精度で分類していることがわかる。雲仙、桜島の事例に対して、LVQの方がともに5%以上優れている。土石流予測において重要なポイントになる実際発生している事例の見逃しに関しても、表-1から正解率と同様にLVQがやや優勢である。ここで、BPではデータの入力時に、分類するカテゴリーの比率を考慮して、発生時の雨量パターンが不発生のパターン数とほぼ同数になるように繰り返して提示している。しかし、LVQはその必要がなく、学習時間は関数近似とカテゴリー分類のアルゴリズムでは、圧倒的にLVQの方が節約できる。

図-1に両手法ともに高い正解率であった桜島の学習に用いた全累加雨量パターンを示す。これからわかるように、発生時と不発生時の雨量パターンは混在している部分が多く、正解率95%を越える両手法は土石流を降雨パターンから判断する手法として、十分な精度であることが分かる。

表-1 BP とLVQによる学習結果

(a) 雲仙

学習事例数		LVQ		BP	
発生	不発生	発生	不発生	発生	不発生
84	0	69	15	47	37
0	202	15	187	14	188

(b) 桜島

学習事例数		LVQ		BP	
発生	不発生	発生	不発生	発生	不発生
34	0	28	6	22	12
0	155	6	149	10	145

表-2 BP とLVQによる学習正解率

	雲仙	桜島
LVQ	89.5	93.7
BP	82.2	88.4




図-1 桜島の土石流発生時の累加雨量（左）と不発生時の累加雨量（右）

3.3. LVQによる雲仙の土石流発生予測

LVQとBPの学習精度はLVQが優勢であったので、LVQにより雲仙の事例の予測を行う。ここでは、年別に学習データと予測データに分割して、モデルの予測精度を調べる。まず、91年の全ての発生時雨量パターンと不発生時雨量パターンを学習したモデルで、翌年の雨量パターンに対して、発生／不発生を予測する。

次に、92年のデータを学習したモデルで93年の雨量パターンで予測し、以降95年までを随時予測する。ここで、学習精度を調べた、10、20、...、180分累加雨量最大値を入力データとする。そして、60分雨量最大値が5mm未満の雨量パターンの際は土石流の発生は記録されていないので、60分雨量最大値が5mm以上のものについて予測結果を調べる。

表-3は各年の予測結果で、予測させる年の実際の発生／不発生の事例数とそれに対する予測内容、予測正解率、およびその年の予測モデルに用いた前年の学習データに対する学習正解率を示す。表-3から、予測モデルの年別の学習正解率は全体を通して、約80%と安定しているが、予測結果はかなりばらつきがみられた。特に94年の予測モデルでは、前年のデータをかなり良く学習しているが、予測正解率は最も低い。これは、93年と94年の土石流の発生状況が大きく変化したことによるものと推察される。

そこで、91年から95年まで、土石流発生と不発生を時間雨量によって時系列順に並べると図-2のようになる。93年は記録的な多雨の年で大規模な土石流が頻発した年であったが、6月中旬で発生限界の不連続な変化がみられる。データを91年5月から93年6月の前期とそれ以降の後期に分割して学習し、学習に使用しない期間のデータで予測したところ、学習・予測正解率は表-4のようになった。ここで、

() 内の数字は学習正解率を表す。期間別の予測正解率は、両者ともそのモデルの学習正解率とは大きく差がある。これは、ネットワークの汎化能力に関する問題というよりは、データの質の変化、つまり発生限界の変化によるものと考えられる。前・後期の発生限界の変化を調べるために、次にBPによる発生限界降雨の推定法を提案し、考察する。

表-3 雲仙の土石流の年別予測結果

	実際の事例数		予測事例数		予測正解率	前年の学習正解率
	発生	不発生	発生	不発生		
1992年	発生 21	不発生 0	7	14	56.3	77.4
1993年	発生 34	不発生 0	23	11	64.7	87.5
1994年	発生 8	不発生 0	3	5	50	80.4
1995年	発生 6	不発生 0	6	0	92.3	72.7




図-2 時間雨量による土石流の発生と不発生

表-4 1993年6月前後の学習・予測正解率

		学習データ	
		1991年-1993年6月	1993年6月-1995年
予測	1991年-1993年6月	(87.7)	66.7
データ	1993年6月-1995年	73.1	(91)

4. BPによる土石流発生限界雨量の推定

ここでは、BPを用いて、不明瞭な発生限界雨量を推定する手法を検証する。BPの学習法、そして学習データの内容は前述の発生予測の場合と同様で、BPの各入力要素と学習後の出力値との関係を調べることによって、土石流の発生限界雨量を推定する。累加雨量パターンとその時の発生／不発生を危険度0、または危険度1として学習するとき、一般に発生パターンの出現が雨量パターン包絡線の勾配の増加に伴い増加するので、学習する降雨パターン数が多く、発生時雨量パターンと不発生時雨量パターンの境界が明瞭でない場合、関数近似型のBPは降雨パターンに対して連続的に発生危険度を出力する。そして、BPに累加雨量パターン

を入力し学習した時、各入力ユニット別に累加雨量に対する発生危険度をプロットすると、各入力要素とも概ね雨量の増加に伴い、危険度は高くなる。そのなかで雨量と危険度の相関が最も高くなる入力降雨要素が危険度出力に最も有用な降雨要素で、その累加雨量によって発生限界雨量を推定することができる。さらに、BPの出力層のユニットはシグモイド関数により出力するので、雨量と危険度の関係はシグモイド曲線によって回帰分析でき、相関が最も高いときの回帰曲線が危険度0.5を示す雨量が土石流の発生限界雨量、その雨量の累加時間が到達時間と推定される。

雲仙のデータで、1991年-1993年6月までの期間（前期）と1993年6月-1995年までの期間（後期）により、それぞれの発生限界を推定する。18個の入力要素、10, 20, ..., 180分累加雨量最大値から危険度を求める。図-3は前期と後期のデータに対して、その学習結果から各入力要素と危険度の関係をシグモイド曲線で回帰して相関係数を調べた結果である。また、それぞれの入力パターンで最も相関が高い雨量要素との危険度を示すと図-4のようになる。前期で危険度と相関が最も高いのは60分累加雨量最大値、また後期で危険度と相関が最も高いのは40分累加雨量最大値であった。




図-3 各入力要素と出力結果の相関





図-4 BP 学習後の雲仙の前期（左）と後期（右）の限界雨量と危険度

このような発生限界雨量の推定法に関して、発生限界雨量図により考察を加える。土石流の発生限界が一義的に到達時間と累加雨量によって規定され则认为と、すべての発生時の累加雨量曲線の下限值と不発生時の累加雨量曲線の上限值は、データに誤差がなく、発生場が定常な場合、図-5のように到達時間 T とその間の累加雨量 $R_m(T)$ で与えられる限界点で分類できる。しかし、実際は雨量データの誤差、発生場の非定常性などの影響が大きくなるにつれて、限界点が不明瞭になる。

図-6は前期・後期の学習データの発生時累加雨量の下限と不発生時累加雨量の上限、そして、学習後にBPが危険度0.5以上を出力した発生時累加雨量の下限とBPが危険度0.5未満を出力した不発生累加雨量の下限をプロットしたものである。前期・




図-5 発生限界を示す理想的な累加雨量曲線

後期とも学習に使用した実際の累加雨量曲線の上・下限からは発生限界点を判断できないが、BPで学習後に発生／不発生が正しく認識されたものによる累加雨量曲線の上・下限によると、図-5のような雨量図となり、限界雨量を推定できる。このときの限界雨量と到達時間は、図-4による推定値と一致する。このことから、BPによる発生限界評価法の妥当性が示される。

そして、この手法によると、雲仙の土石流の発生に関して、前期は到達時間60分で限界雨量が8mmとなり、後期は到達時間40分で限界雨量が10.5mmとなり、両者の差が明らかになった。




図-6 雲仙の前期（左）と後期（右）の実際の限界雨量とBPの学習結果から得られた限界雨量

5. 結論

ニューラルネットワークによる土石流の発生予測について、新しいモデルの提案と検証を行った。発生予測に用いたLVQはBPに比べて、単純なアルゴリズムでありながら、高い精度で発生と不発生の判定が可能であった。また、BPは発生限界雨量の推定に用いる妥当性を示した。つまり、両モデルの特徴を活かした利用が、土石流の予測に有益であるといえる。

雲仙の土石流への適用の結果、学習期間を適切に与えることにより、その発生場の非定常な変化にも対応できる可能性があるが、発生場の非定常性を考慮した土石流の予測に関しては、さらに研究の余地があり、今後の課題である。

参考文献

- 1) 例えば、建設省河川局砂防部：総合土石流対策（II），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
- 2) 平野宗夫・疋田誠・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
- 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
- 4) T. Kohonen：The Self-organization Map, Proceedings of the IEEE, Vol 78, No. 9, 1990