

九州大学大学院 学生員○川原恵一郎

九州大学工学部 正員 平野 宗夫

九州大学工学部 正員 森山 聰之

1. はじめに

土石流の複雑な現象をモデリングするために、著者ら¹⁾はニューラルネットワークを利用し、その有効性を示している。しかし、ニューラルネットワークの適用には、その内部表現の不透明さや極値データなどによるモデルの外挿性の限界などの問題がある。非線形システムの同定や制御に関しては、ニューラルネットワークが利用される以前から、GMDH(Group Method of Data Handling)²⁾が用いられている。GMDHは、複雑なシステムの入出力データが与えられた場合、その入出力関係を2次多项式により自己組織的に求めるもので、その概念はニューラルネットワークと共通点がある。本報では、GMDHを土石流の流出解析に適用して、雲仙の土石流データにより検証を行う。モデルの外挿性についてはニューラルネットワークと比較する。

2. 土石流の基礎流出モデル

土石流の流出規模に関して、平野ら³⁾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、斜面に関するパラメータを統一し、簡略化すると(1)式のように表すことができる。

$$Q(t) = \sum_{\tau} K_{\tau} r(t) R(t, \tau), \quad R(t, \tau) = \int_{t-\tau}^t r(t) dt \quad (1)$$

ここに、 Q は土石流の流量、 t は時間、 r は降雨強度、 R は τ 時間の累加雨量、 K_{τ} は長さの次元を有する流出場に固有の値である。

(1)式において、累加時間 τ の決定とそれに伴い変化する流出場の係数 K_{τ} の同定は非常に困難であるので、土石流の流出モデルの同定、予測モデルの作成にGMDHやニューラルネットワークを用いる意義がある。

3. 雲仙・水無川における土石流の流出解析

雲仙・水無川において1993年6月12-13日に計測された土石流のハイドログラフ⁴⁾と雲仙岳測候所の10分雨量を図-1に示す。この事例の流出モデルの同定に用いる入力要素は、(1)式をもとに次のようにセットする。

$$x_i = r(t) R(t, \tau), \quad \tau = 10, 20, \dots, 60, 120, 180, 240, 300, 360, 420, \infty \quad (2)$$

ここで、 $R(t, \infty)$ は雨の降り始めからの総雨量を表す。

また、出力変数は図-1の実測ハイドログラフとハイエトグラフの遅れ時間を考慮して、土石流流量 $Q(t+20)$ とする。全入出力要素は観測最大値で割り正規化を行う。ここでは基本的なGMDHアルゴリズムを用いる。まず、入力変数の2個 x_i, x_j の組み合わせに対して中間変数 y_m^k を次式でつくる。

$$y_m^k = G[x_i, x_j] = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \quad (3)$$

ここで、 k は中間層の数、 m は組み合わせ数を表す。

(3)式の6個の係数を実測データに基づいて最急降下法で決定し、それに対する2乗平均誤差を求める。そして、この誤差を少なくするものから入力変数と同数の中間変数を次層の入力変数として採用する。このとき、 m は最小誤差の順位に置き換える。さらに得られた中間変数から、次層の中間変数を求め、モデルの誤差が収束するまで続ける。

以上のアルゴリズムによる計算フローチャートを図-2、そして各層での部分表現とモデル誤差を表-1に示す。ここで、図-2の各層のユニットの数字は表-1のRankに相当する。表-1に示すように、第4層までの最小誤差を比較すると本モデルの構造は第2層までの計算で十分であることがわかる。第1層の組み合わせをみると、各部分表現は短時間累加雨量と長時間累加雨量によって構成されていることがわかる。そこで、第2層の最小誤差を示した式 $y_1^2 = G[y_2^1, y_5^1]$ による計算流量を図-1の破線で示すが、計算結果は全体的に実測値と一致している。

現在のところ、本モデルの検証に十分な精度のハイドログラフはないが、GMDHモデルの外挿性を調べるために、モデルの同定に用いた事例の約2倍の堆積土砂が記録された1993年4月28日の土石流に対して、降雨データからその流出量を予測する。同様に、2層GMDHモデルと同じ入・出力で中間層2つの階層型ニューラルネットワークをバックプロパゲーション法により学習し予測する。ただし、ニューラルネットワークの学習データは予測データの入力値も含め正规化している。両手法の予測結果を図-3に比較する。予測時の入力値は最大で2倍ほど学習データより大きいが、ニューラルネットワークの予測ピーク流量は学習データのピーク流量とほぼ同じであるのに対し、GMDHは入力値の比率をピーク流量に反映しており、モデルの応答特性の違いがわかる。

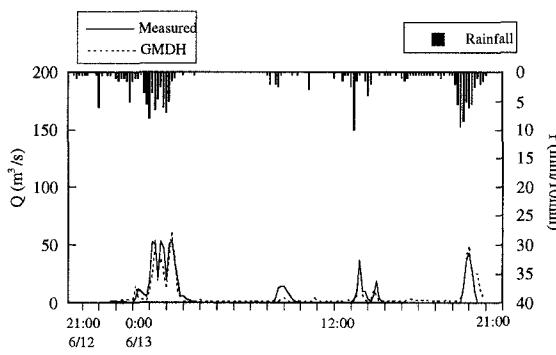


図-1 GMDHによる土石流の実測流量の同定

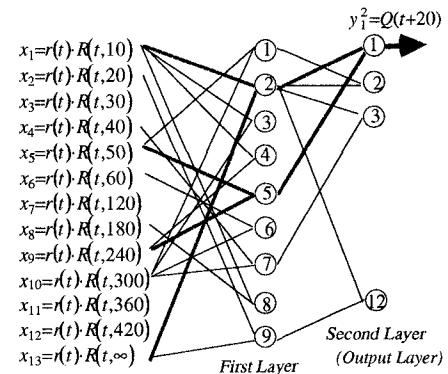


図-2 2層モデルの計算フローチャート

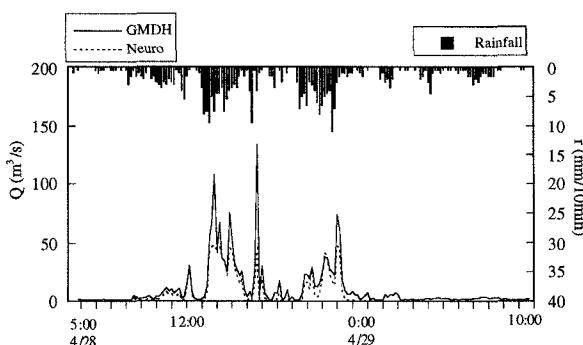


図-3 GMDHとニューラルネットワークによる予測流量

表-1 変数組み合わせと計算精度

Layer	Rank	Equation	RMS Error (m³/s)
1	1	$y_1^1 = G[x_5, x_{10}]$	6.13
2	2	$y_2^1 = G[x_1, x_{13}]$	6.16
3	3	$y_3^1 = G[x_1, x_{10}]$	6.19
4	4	$y_4^1 = G[x_1, x_9]$	6.21
5	5	$y_5^1 = G[x_5, x_9]$	6.21
2	1	$y_1^2 = G[y_2^1, y_5^1]$	5.67
2	2	$y_2^2 = G[y_1^1, y_2^1]$	5.67
3	1	$y_1^3 = G[y_2^2, y_{12}^2]$	5.66
4	1	$y_1^4 = G[y_5^1, y_3^1]$	5.66

4. おわりに

土石流の流出解析にGMDHを用いることにより、土石流ハイドログラフの計算に有効であることがわかった。また、GMDHの中間層から、モデルの入力要素の分析ができた。これによると短時間から長時間にわたる累加雨量が流出に影響していることが考えられる。モデルの外挿性はニューラルネットワークに比べ、GMDHの方が入力値の変化に応じた出力を示した。

参考文献

- 川原恵一郎・平野宗夫・森山聰之（1996）：水工学論文集、第40巻、145-150
- 池田三郎・堪木義一（1975）：計測と制御、Vol. 14, No. 2, 185-195
- 平野宗夫・疋田誠・森山聰之（1986）：第30回水理講演会論文集、181-186
- 平野宗夫・橋本晴之・河野道齊（1994）：文部省科学研究費(No.05302071)総合計画(A)研究成果報告書、13-23