

## ソフトコンピューティングによる土石流のデータ解析

### Data Analysis of Debris Flow with Soft Computing

川原 恵一郎<sup>\*</sup>・平野 宗夫<sup>\*\*</sup>・森山 聡之<sup>\*\*\*</sup>・高畑 洋<sup>\*\*\*\*</sup>

By Keiichiro KAWAHARA, Muneo HIRANO, Toshiyuki MORIYAMA and Hiroshi TAKABATAKE

The purpose of this study is to develop the analysis method for debris flow with soft computing. The soft computing methods which embrace neural networks and/or genetic algorithms (GA) are expected to solve problems which are defined imprecisely from a complex phenomena.

The neural network combined with the GA was introduced into the analysis for the occurrence condition of debris flow. Training data sets to the LVQ network are optimized by the GA. The procedure was used to examine a characteristic change in occurrence condition of debris flow. Runoff analysis of debris flow by the use of GMDH was proposed. These methods were applied to the data for the Mizunashi River in the Unzen Volcano. The results led that the soft computing methods are useful for data analysis of the debris flow.

Keywords : Debris flow, Soft Computing, Neural networks, Genetic Algorithms, GMDH

#### 1. はじめに

土石流の発生・流出規模の予測手法には、システム解析的なアプローチ<sup>1)</sup>が有効であると考え、著者ら<sup>2), 3)</sup>はニューラルネットを土石流の予測手法に適用している。ニューラルネットの利用は土石流の発生や流出の予測モデルの作成だけでなく、発生限界を規定する因子の評価<sup>4)</sup>にも有用である。この手法の特徴は、土石流の素因である斜面のパラメータをブラックボックスとして処理し、実際のデータにより自己組織化されたモデルで、問題を客観的に評価できるところにある。本論文では、遺伝的アルゴリズム<sup>5)</sup> (Genetic Algorithms: GA) とLVQ法<sup>6)</sup>によるニューラルネット (LVQネット) を組み合わせた土石流の発生条件の解析、および、GMDH<sup>7)</sup> (Group Method of Data Handling) による流出解析を行う。このようなニューラルネット、遺伝的アルゴリズムなどの計算理論を利用して、低精度なコンピューティングで不精確に定式化された問題を解決する様式をソフトコンピューティング<sup>8)</sup>といい、ソフトコンピューティングを用いたデータ解析はソフトデータ解析と呼ばれている。「取り扱いやすさ、頑健性、低コストを達成するために、不精確性、不確実性をどこまで許容できるかを探り、高度の精確性や確実性を要求しない」というソフトコンピューティングの概念<sup>8)</sup>は土石流のデータ解析には有効であると考えられる。

#### 2. 土石流の発生条件の解析

##### 2.1. LVQネットによる発生予測モデル

LVQネットにより降雨パターンを発生／不発生に判別する手法は前報<sup>4)</sup>で示されている。すなわち、一連の降雨から任意の累加時間 $\tau$ の最大雨量 $R_{\max}(\tau)$ を求め、それらを累加雨量パターン $[R_{\max}(\tau_1), R_{\max}(\tau_2), \dots, R_{\max}(\tau_n)]$ としてLVQネットの入力要素とした。LVQネットにより降雨パターンを土石流の発生と不発生の2つのカテゴリーに判別するモデルを提案した。LVQネットを予測モデルとする場合、学習データの蓄積によって予測モデルが修練されるのが理想的であるが、土石流の発生場の変化に対応するためには、それに応じて学習データの選定が必要になる。

<sup>\*</sup> 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)

<sup>\*\*</sup> 正会員 工博 九州大学教授 工学部建設都市工学科 (同上)

<sup>\*\*\*</sup> 正会員 工博 九州大学助手 工学部建設都市工学科 (同上)

<sup>\*\*\*\*</sup> 学生員 九州大学大学院修士課程 工学研究科水工土木学専攻 (同上)

## 2.2. GA-LVQネットによる解析モデル

LVQネットに与える学習データ群から、検証データを最もよく判別できる学習データを選択し、選別された学習データの時期や集団の違いを検討することにより、土石流の発生条件の変化を調べる。学習データの最適化にはGAを用い、図-1のような解析モデルを作成する。GAにおける遺伝的オペレータはルーレット選択、一点交叉、突然変異による単純GAを利用する。学習データの使用と不使用をビット列でコーディングするために、選択する事例には1、選択しない事例には0を与え、図-2のように表現する。LVQネットとGAの評価は全学習パターン数と正解パターン数の比を正解率として用いる。GAの適応度は個体 $s_i$ による学習時の正解率 $C_L$ と検証時の正解率 $C_C$ の積  $f(s_i) = (C_L \cdot C_C)^2$  で定義する。これにより、学習と検証の正解率がともに高いほど適応度が大きくなる。GAにおけるパラメータとしては、個体数が20個、最大世代数が50世代とする。また、交叉確率は0.6、突然変異確率は0.01の一般的によく使われる確率を使用する。LVQネットのパラメータとしては、学習パターン数の約10%を各コホーネン層に置き、学習係数は0.1、学習事例数の10倍を学習回数の上限とする。そして、LVQネットによる学習終了時の学習正解率と検証データの正解率をGAの適応関数に代入する。




図-1 GA-LVQネットによる解析モデル




図-2 学習するデータを判別するための遺伝子表現

## 2.2. 現地への適用と結果の考察

雲仙・水無川の土石流に関する資料として、1991年5月から1996年9月までの雲仙岳測候所における10分雨量記録、および土石流発生時刻の記録を用いた。これにより、連続雨量が5mm以上の降雨について10分から120分までの累加を計算し、土石流発生／不発生の累加雨量パターンとした。

GA-LVQネットにより、年別に学習データと検証データを区分し解析した結果を図-3に示す。まず、図-3(a)は1991年から1995年までの全データのコードを示したものである。このコードは時間順に配置されており、データの無い時間は空白となっている。また、コードの実線は発生時、破線は不発生時のデータを表す。図-3(b)は1996年のデータを判定するのに最適な学習データとして選別されたコードで、1993年の後半と1994年は他の期間に比べてかなりのデータが削除されている。次に、図-3(c)は1995年を検証データに使用したもので、1991年の後半から93年の前半にかけて、および1994年の後半のデータがかなり削除されている。図-3(d)に示す1994年を検証した場合も、1991年の後半から93年の前半にかけては削除されているデータが多い。1993年に関しては、これまでの土石流の発生限界と流出量の調査から、同年の6-7月を境に発生状況の変化が指摘されている<sup>9)</sup>ので、1993年は1-6月と7-12月に分けて調べてみる。図-3(e)の1993年の後半を検証した場合、採用された学習データはその直前の期間に集中している。図-3(f)の1993年の前半を検証した場合もやはり直前のデータが多く残っている。

以上のような学習データの選別状況から、1993年1-6月の検証時には1992年後半のデータが多く採用されているのに対し、その後の1993年7-12月の検証時には1992年後半のデータは採用されず、その直前である同年前半のデータが採用されているが、それ以降の年の検証には1992年後半から1993年前半のデータはあまり採用されていない。このことは、1993年前半に発生条件が大きく変化していることに対応している。




図-3 全学習データコードと各期間の最適学習データコード

### 3. 土石流の流出解析

#### 3.1. GMDHによる流出モデル

土石流の流出過程をブラックボックスとしてGMDHでモデリングする。これまでに、洪水流出解析に関しては、バックプロパゲーション法によるニューラルネット（BPネット）を利用した研究があり、BPネットでは学習データを大きく越える流量の計算ができない<sup>10)</sup>ことが指摘されている。GMDHネットはBPネットと異なり、ユニットに発散形の関数をもつことから、そのような問題は生じない。また、GMDHネットの各ユニットの出力は独立しているため、入力要素の解析が行えると考えられる。

GMDHの基本アルゴリズムは、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。

$$y_m^k = G[x_i, x_j] = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \quad (1)$$

ここで、 $k$ は中間層の数、 $m$ は組み合わせ数を表す。

(1) 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RMS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。

土石流の流出に関して、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<sup>1)</sup>は、斜面に関するパラメータを簡略化して、式(2)のように表すことができる。

$$q(t+t_l) = \sum_{\tau} K_t r(t) R(t, \tau), \quad R(t, \tau) = \int_{t-\tau}^t r(u) du \quad (2)$$

ここに、 $q$ は土石流の流量、 $t$ は時間、 $r$ は降雨強度、 $R$ は $\tau$ 時間の累加雨量、 $t_l$ は観測の遅れ時間、 $K_t$ は時刻 $t$ における長さの次元を有する流出場の特性を表す係数である。

(2) 式の流出場の係数 $K_t$ は不明確であるので、種々の時間 $\tau$ の降雨要素 $x_n = r(t)R(t, \tau)$ をGMDHの入力値とする。

#### 3.2. 現地への適用と結果の考察

雲仙・水無川において大規模な土石流として唯一得られている1993年6月12-13日の土石流ハイドログラフ<sup>9)</sup>について解析する。GMDHで土石流ハイドログラフを計算するための入力要素は次のようにセットする。

$$x_n = r(t)R(t, \tau), \quad \tau = 10, 20, \dots, 60, 120, 180, 240, 300, 360, 420, \infty \quad (3)$$

ここで、 $R(t, \infty)$ は雨の降り始めからの累加雨量を表す。

また出力は、実測ハイドログラフとハイレー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。さらに、全入出力要素は観測最大値で割り正規化を行う。

上記の学習データによる第3層までのGMDHネットを図-4に示す。ここで、各層のユニット内の数字はそのユニットで表される組み合わせによる誤差のランキングを示す。第1層の組み合わせをみると、全78の組み合わせのうち上位9のユニットを示すが、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。本計算では第2層で誤

差がほぼ収束しており、それによると、 $r(t)R(t,10)$ 、 $r(t)R(t,50)$ 、 $r(t)R(t,300)$ 、 $r(t)R(t,\infty)$ の4要素で計算されることになる。図-5に実測と計算によるハイドログラフを比較するが、両者はほぼ一致している。

次に、GMDHネットの出力特性をバックプロパゲーション法によるニューラルネット（B P ネット）と比較する。モデルの検証のためのハイドログラフはないが、学習事例の約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ハイドログラフを推定する。まず、上記の2層GMDHネットと同じ学習データで、中間層2つのB P ネットを学習すると同程度の学習された。そこで、学習後のGMDHネットとB P ネットにより、1993年4月28日の推定値を比較すると図-6のようになる。予測時の入力値は最大で2倍ほど学習時より大きい、B P ネットの推定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ネット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を示している。




図-4 学習後のGMDHネットワーク




図-5 1993年6月12-13日の流量の学習結果




図-6 1993年4月28-29日の推定流量

#### 4. 結論

土石流のデータ解析手法にソフトコンピューティングの概念を導入し、雲仙・水無川の土石流に適用した。まず、L V Q ネットの学習／検証の過程において、検証データを判別するために最適な学習データをGAで選択することで、発生条件の変化を解析した。その結果、1991から1996年の期間では、1993年前半に土石流の発生条件が大きく変化していることがわかった。次に、GMDHを用いて土石流の流出解析を行った。1993年6月12-13日の土石流では、流出モデルの入力降雨要素としては、10分雨量、50分雨量、300分雨量、および雨の降り始めからの総雨量が寄与していることが示された。また、GMDHは出力レンジが学習時に限定されるB P ネットに比べ、ダイナミックに変化する土石流の流出モデルに適していると考えられる。

#### 参考文献

- 1) 平野宗夫 (1992): 土石流の発生予測と流出解析, 土砂移動現象に関するシンポジウム—芦田和男先生退官記念—, 23-38.
- 2) 森山, 平野, 上松, 川原, 白川 (1992): 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, 水工学論文集, 第36巻, 705-708.
- 3) 川原, 平野, 森山 (1995): ニューラルネットワークによる土石流流出量の予測, 水工学論文集, 第39巻, 43-48.
- 4) 川原, 平野, 森山 (1996): ニューラルネットワークを用いた土石流の発生限界雨量の推定, 水工学論文集, 第40巻, 145-150.
- 5) 阿江忠 (1992): もうひとつのニューラルネットワーク学習法—自己組織化1.コホーネンネット (L V Q), bit, Vol. 24, No. 11, 956-964.
- 6) 石淵久夫, 野崎賢, 山本直久, 田中英夫 (1993): 遺伝的手法によるファジィIf-Thenルールの選択, 電子情報通信学会誌, Vol. J76-A, No. 10, 1465-1472.
- 7) 市川新, 池田三郎 (1976): 発見的自己組織化法による水質予測, 土木学会論文報告集, 第246号, 47-56.
- 8) L. A. Zadeh (1995): Forward to Soft Computing Series, ファジィ学会編「ソフトデータ解析」, 朝倉書店.
- 9) 平野, 橋本, 川原 (1996): 雲仙・水無川における土石流の流出特性の変化, 水工学論文集, 第40巻, 1027-1032.
- 10) 四俣正俊, 安藤大介 (1993): ニューラルネットワークによる長期流出計算について, 土木学会第48回年次学術講演会概要集, 第2部, 214-215.