

II-215

遺伝的アルゴリズムを用いた土石流流出土砂量の予測について

九州大学大学院 学生員 高畑 洋 九州大学工学部 正 員 平野 宗夫
九州大学工学部 正 員 森山 聡之 九州大学大学院 学生員 川原恵一郎

1. 目的 土石流による被害の規模は、流出土砂量の多寡によっている。土石流は、現象が複雑で、降雨から流出量を推定する信頼性のある手法は確立されていない。そこで、3層パーセプトロン型ニューラルネットワークを用い、雲仙・水無川における、土石流の流出土砂量の予測を試みる。この型のネットワークの学習には、従来バックプロパゲーション(Back-propagation; BP)法という局所探索の手法が用いられるが、この方法は局所解に陥りやすい。そこで、生物の進化に着想を得た、確率的な多点探索の手法で、大域的探索能力に優れている遺伝的アルゴリズム(Genetic Algorithm; GA)を用いた学習を行い、ネットワークの学習誤差の低減と予測精度の向上を試みる。

2. 内容

(1) ニューラルネットワークを用いた流出土砂量の予測 土石流に関して、平野ら^{*)}の計算式によると、その流出高は、直前の降雨強度と累積雨量の積に比例する。そこで降雨時系列から降雨群を区分し、土石流の発生した降雨群について、その総雨量 R_c と τ 時間雨量最大値 $R_m(\tau)$ という降雨要素を求める。ここでの降雨群とは、降雨の記録されていない時間が6時間以上になる場合に、時系列を分割してできる、一連の降雨時系列を表す。総雨量 R_c はその降雨の総量、 τ 時間雨量最大値 $R_m(\tau)$ とは下記の式で定義される種々の累加時間 τ (hour)に対応する降雨群の累加雨量 $R(t, \tau)$ のうちの最大値である。

$$R(t, \tau) = \int_{t-\tau}^t r \, dt \quad (1) \quad R_m(\tau) = \max_t \{R(t, \tau)\} \quad (2)$$

ニューラルネットワークにおいては、これら降雨要素の一部を組み合わせて入力降雨要素とし、それらの最大値で割って正規化して、入力信号とする。出力信号あるいは教師信号 T は、流出土砂量 $Q(m^3)$ に対応し、 $T = -1.95 + \log Q$ で Q を正規化したものである。なお、すべてのユニットのシグモイド関数の傾きは3.0とし、中間層ユニットの数は、入力層ユニットの数の約半分とする。

(2) GAを用いたニューラルネットワークの学習法 ニューラルネットワークのGAへのコーディングは、結合の重みとユニットのしきい値の組み合わせを、そのまま一続きの数字の列に置き換え、それを染色体とする、Real Value Encodingという簡単な方法で行う。また、GAは局所的な探索に弱いので、大域的探索に優れたGAと、局所探索の手法であるBPを組み合わせた学習も試みる。以下ではGAのみの学習と、GAとBPの組み合わせとして、GAを行ったのちBPを行う学習と、BPで学習しながら、GAの操作をする学習を行う。これら3つの学習法をそれぞれ、GA、GABP、BPGAと呼ぶ。これらの学習法におけるGAの操作条件を次のように定める。重みとしきい値の初期値の範囲は-4.0から4.0にする。個体数20とし、選択操作は、ルーレット選択戦略にエリート保存戦略(エリート数1)を併用する。交叉方法は2点交叉で、交叉率は0.50から0.70とする。突然変異の方法は、0.0から1.0までの一様乱数と、-1.0から1.0までの一様乱数の積を、遺伝子の値に加えることで行い、突然変異率は0.10から0.50とする。さらに、GAとBPを比較するため、BP法のみ学習を、重みとしきい値の初期値の範囲を、従来よく行われている0.00から0.20にする場合と、GAと同じ-4.0から4.0にする場合とで行う。これらを、それぞれBP、BP4.0と呼ぶ。

(3) ニューラルネットワーク学習結果の比較 精度のよい出力を得るネットワークを構築する入力降雨要素と学習法について、学習に用いた入力に対する出力信号と、教師信号との誤差の、学習1パターンあたりの平均値を比較して考える。学習データは、'91年から'93年に発生した、19回の土石流における降雨群

と流出土砂量である。結果を図.1に示す。入力降雨要素としては、 $R_c, R_m(1) \sim R_m(12)$ の13個の要素を用いた場合に誤差が小さい。学習法に関しては、GAのみの探索だけでもBP並みに誤差を小さくできる。しかし、BP4.0とGA、GABP、BPGAの間では、ほとんど差がない。つまり、結合荷重の初期値を広くとったほうが、誤差を小さくできるが、学習にGAを用いても、BPを用いても、誤差の低減効果は同じであるといえる。

(4)流出土砂量の予測 次に、'93年の6回の土石流について、そのそれぞれが発生した以前で、'91年以降の土石流の降雨と流出土砂量のデータをニューラルネットワークに学習させ、それぞれの流出土砂量を予測する。入力降雨要素としては、最も学習誤差の少ない、 $R_c, R_m(1) \sim R_m(12)$ を用いる。結果を図.2に示す。重みとしきい値の初期値の範囲を-4.0から4.0にした学習法で、予測が大きく外れる場合が目立つ。そこでGAを用いる学習法も、重みとしきい値の初期値の範囲を、0.00から0.20にして予測すると、図.3に示すように、大きく外れる例は少なくなる。予測値は、多くの場合、実測値とよく適合しているが、どの学習法も予測精度は同じ程度である。

3. 結論 ネットワークの重みとしきい値の初期値の範囲を拡大すると、学習誤差が従来よりも低減する。しかし、Real Value EncodingによるGAや、それとBPを組み合わせる学習法が、学習誤差を低減する効果はBPと同じ程度である。

一方で、予測に関しては、重みとしきい値の初期値の範囲が広いと、予測の精度がよくない。また、学習誤差と同様、学習法の間で予測の精度に差はない。

*)平野・疋田・森山：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，1986




図.1 学習誤差の比較




図.2 流出土砂量の予測




図.3 流出土砂量の予測
(重みとしきい値の初期値0.00から0.20の場合)