

II-2

ニューラルネットワークを用いた番匠川の流出解析

函館工業高等専門学校 正会員 番匠 勲
 室蘭工業大学工学部 正会員 藤間 聡
 室蘭工業大学大学院 学生員 外山かおり

1. 研究目的

洪水災害の防止・軽減には正確で迅速な流量の逐次予測とその予測に基づいた適切な対応が求められる。現在使用されている流出解析法では流域特性を表すために各種のパラメータを必要とするが、このパラメータの同定には長期にわたる観測データと複雑な同定計算が必要である。しかし流出解析は必ずしも容易ではなく、多数の流出解析モデルが提案されているが、どのような流出特性にも対応できる流出モデルを作成することは困難であるのが現状である。本研究は、これらの要因を踏まえて複雑なパラメータの同定を必要としないニューラルネットワークを用いて降雨一流出過程をブラックボックス的に捉え、1時間先の洪水流量を予測するモデルを構築し、また、実際の観測事例を用いてその実用性を検証するものである。

2. 解析対象河川の概要

番匠川は九州の大分県南部に位置する一級河川である。水源は大分県の三国峠であり、東流しながら大小あわせて51の支川と合流し、佐伯湾に注いでいる。その流域は東西30km、南北25km及び流域面積は464km²、幹川流路延長38.1kmである。流域内は山地面積が全流域の89%であり、平地面積は11%に過ぎない。また、山地面積の内の94%は森林である。流域は2市1町2村にまたがり総人口約60,000人に及び、大分県南部における社会・経済・文化の基盤をなし、番匠川水系の治水・利水及び環境の意義は極めて大きいものがある。降雨は台風によるものが多く、年平均降雨量は2,190mmで、既往最大日雨量は約460mmである。近年では平成5年に台風13号による戦後最大の出水を記録している。



図 - 1 番匠川流域図

本研究で対象とするのは、番匠川中流部の終点に位置する番匠橋までの流域面積278km²、流路延長29.15kmの流域である。

解析に用いるデータは、番匠橋流量観測所におけるデータを用いる。また、入力となる降雨量データは流域内に設置されている観測所の中から、上流部の因尾、番匠川の中流部で合流する支川上流の直川、宇藤木降雨観測所のデータを使用する。

3. ニューラルネットワークによる流出予測

3.1 ネットワーク構造

ニューラルネットワークは生物の神経系の情報処理システムを工学的にモデル化したものであり、近年では様々な分野で活用されている。ニューラルネットワークの特徴としては、並列分散型の処理を行なえること、学習能力及び汎化能力があることがあげられる。このような特性を利用し、過去の洪水事例を用いてネットワークに降雨-流出過程を学習させることによって洪水予測を行うモデルを構築する。

本解析に用いたネットワークの構造は図-2に示すような、入力層、中間層、出力層からなる3階層型である。信号伝達の方法の概略を以下に示す。

入力層のユニット*i*に入力された信号*S_i*は荷重*V_{ij}*を介して結合している中間層のユニット*j*へと送られる。このユニット*j*において全入力層から受ける入力信号の総和は*X_j*は(1)式で示される。

$$X_j = \sum S_i V_{ij} \quad (1)$$

中間層ユニット*j*は、受けた信号*X_j*及びユニット*j*自身の持つ閾値*γ_j*によって次に結合している出力層ユニットへの応答*A_j*を決定するが、この際に図-3に示されるシグモイド関数が使用される。*A_j*は(2)式で求められる。

$$A_j = \frac{1}{1 + \exp\left\{-\left(X_j - \gamma_j\right) / \mu\right\}} \quad (2)$$

ここでμはシグモイド関数の形状を決定するパラメータであり、信号変換率とも呼ばれている。

次に、中間層から出力層に向けて送られる信号の総和は(1)式と同様に与えられる。

$$X_k = \sum A_j W_{jk} \quad (3)$$

上式において*W_{jk}*は中間層ユニット*j*と出力層のユニット*k*間の荷重である。(3)式で求められた出力層への入力信号と出力層のユニット自身が持つ閾値*θ_k*によって最終的なネットワーク出力が決定される。

$$R_k = \frac{1}{1 + \exp\left\{-\left(X_k - \theta_k\right) / \mu\right\}} \quad (4)$$

以上がニューラルネットワークの信号伝達法の概要である。

ネットワークへの入出力に関しては、本研究ではネットワークの入力として、流量と降雨量を採用しているため、同じシステムに入力するために、流量を雨量強度に換算した流出高さに変換し、次元を等しくして使用する。ネットワークへ入力されるデータとして、これまでの番匠川における観測事例から、降雨のピークと流出量のピークを考慮した結果、現時刻*t*と*t-1*時における流出高さ、3ヶ所の降雨観測点における現時刻*t*から*t-2*時までの3時間分の降雨データを用いることとした。

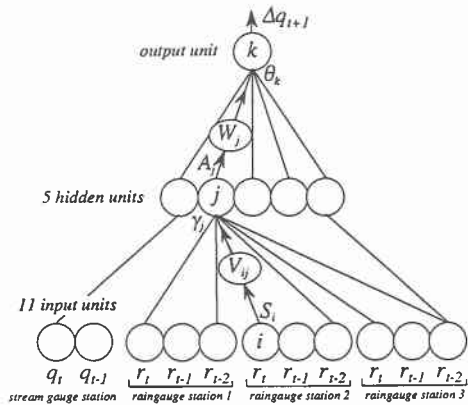


図-2 ネットワーク構造




図-3 シグモイド関数の形状

3. 2 ネットワーク学習

前述のように構築されたネットワークを予測に用いるためには、各結合荷重及び閾値の最適値を同定しなければならない。これをニューラルネットワークの学習といい、本研究ではバックプロパゲーション法を用いた。これは教師付き学習法であり、ネットワークに学習させたい事例をもとに入力信号とそれに対応する教師信号を組にした学習パターンを作成し、実際のネットワーク出力と教師信号との誤差を以下の式によって求め、この誤差を最小にするように荷重・閾値を調整するものである。

$$E = \sum_p \sum_k (T_k - R_k)^2 \quad (11)$$

ここに、 T_k は教師信号、 R_k は実際のネットワーク出力、 p は学習パターン数である。中間層－出力層間を例にあげると、荷重の更新式は次式で示される。

$$W_j^{new} = W_j + \Delta W_j \quad (12)$$

上式において、 W_j^{new} は更新後の荷重、 W_j は更新前の荷重、 ΔW_j は修正量である。この修正量を(1)式の誤差をもとに最急降下法を利用して求めると(13)式で示される。

$$\Delta W_j = \varepsilon (T_k - R_k) R_k (1 - R_k) A_j / \mu \quad (13)$$

ここに、 ε は修正量を調節する正の係数で学習率と呼ばれる。以上の修正を誤差が許容範囲内に収束するまで繰り返すことによって荷重・閾値が同定される。入力層－中間層間の荷重とそれぞれのユニットが持つ閾値も同様の方法を用いて更新される。学習を行う前の荷重・閾値の初期値は0としてもよいが、迅速な学習を行うためには小さな範囲の一樣乱数を与える方が良いことが知られているので、本研究においても $[-1, 1]$ の範囲の乱数を与えている。また学習の改良法として、モーメント法を使用している。これは現時点で計算された誤差による修正量の他に1回前の学習過程における修正量も考慮に入れる方法である。モーメント法を用いた場合の荷重更新式は以下の式で与えられる。

$$W_j^{(t+1)} = W_j^{(t)} + \Delta W_j^{(t)} + \beta \Delta W_j^{(t-1)} \quad (14)$$

ここで、添字 t は学習回数、 β はモーメント係数である。モーメント係数は通常 $[0, 1]$ の値をとる。モーメント法を用いた場合、厳密には最急降下法ではなくなるが、全体の修正量が抑えられることによってオーバーシュートが少なくなり、迅速な学習が可能となる。図-4はバックプロパゲーション法を用いたネットワーク学習中の二乗誤差のグラフである。ネットワークの大きさにもよるが、今回のネットワークでは学習回数が80回を超えると誤差の大きな減少が見られなくなることから、学習は100回で打ち切りとした。

次に、学習に用いた事例について述べる。番匠川においては、1989年から1993年まで4つの洪水事例が記録されている。そこで戦後最大の出水であった1993年の事例をネットワーク学習に用い、他の3事例を予測するものとする。図-5に示すハイエト・ハイドログラフは学習に使用された1993年台風13号による洪水事例である。




図-4 学習時の二乗誤差




図-5 学習用事例

4. 予測結果

前述の方法をもって学習を行ったネットワークによる流出予測の結果を示す。図-6に示されるのは1989年台風22号による洪水事例の予測結果である。今回得られた4つの事例の内最も規模の小さい出水である。流量の上昇部分において観測値との間に開きが見られるが、ピーク部分及び逓減部分においてはほぼ一致しており、流出形状の特徴をよく捉えた結果である。20時間目から50時間目までの洪水ピーク部分における観測値と予測値の相対誤差は11.9%となっており、良好な予測結果が得られている。




図-6 事例1 予測結果

図-7は1990年、台風21号による事例の予測結果である。降雨及び流量のピークが2回出現しており、予測が難しいと思われた。しかし、最初の流量の上昇部分において大きな予測値が出現している以外は全般にわたって観測値とほぼ一致した流量が得られており、2回目の流量ピークも正確に捉えられている。これにより、降雨と流出の関係をニューラルネットワークが正確に捉えていることが認められる。洪水生起後8時間から70時間までの相対誤差は8.3%であり、非常に良好な結果が得られた。




図-7 事例2 予測結果

図-8は1992年、台風10号による出水事例の予測結果である。流量の上昇部分、ピーク、逓減部分全てにおいて観測値とほぼ一致した予測値が得られており、非常に良好な結果が得られている。25時間から40時間までの相対誤差は3.6%である。これは予測に用いた他の事例に比較して、学習に用いた事例と類似した流出特性を有しているためであると思われる。




図-8 事例3 予測結果

5. 結び

ニューラルネットワークを用いて番匠川の洪水流出予測を行い、ネットワーク学習に1事例しか用いない場合においても、実用上支障のない精度で予測を行えることを示した。また降雨入力に流域平均雨量ではなく流域内の数カ所の観測点のデータをそのまま用いること、予測精度的に十分な規模のネットワークを用いることによって計算時間の短縮が図られる。以上より、洪水被害の軽減のために迅速な対応を講ずるのに有用であると思われる。