

ファジィ・ニューラルネットワークを用いた洪水流出実時間予測

Real-Time Flood Runoff Prediction by Fuzzified Neural Network

藤間 聡*・外山かおり**・大坂忠史***

By Satoshi TOHMA, Kaori TOYAMA, Tadashi OSAKA

A neural network is developed to forecast flood discharge. Network training is conducted using back-propagation with simulated annealing, where rainfall and discharge data as input and discharge data as output. These hydrologic observation data are generally included in various types of errors, so we applied fuzzy theory to these data including errors. After training is completed, the neural network is used to forecast for 3 and 6 hours ahead using only the current observation data as input. The authors have shown that fuzzified neural network is capable of learning the complex flood runoff process and can get reasonable estimations.

Keywords : Flood Runoff, Fuzzy Theory, Neural Network, Simulated Annealing

1. はじめに

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。現在広範に使用されている流出解析法では、流域特性を表わすパラメータを決定するために長期に渡る観測データと複雑な同定計算が必要である。しかし、我が国の雨量観測は長くても100年程度であり、洪水予測にとって重要である山地部の観測が量・質的に整備されたのはここ50年であるため、使用できるデータが限られる場合が多い。また、予測に使用される観測データに含まれている誤差は、確率的に処理することが困難である。そのため、この様な観測データを用いて得られた予測結果は誤差の影響を受けていると考えられる。

本研究はこれらの要因を踏まえて、降雨－流出過程をニューラルネットワークを用いてブラックボックス的に捉え、観測データの誤差や不確実性を考慮するためにファジィ理論を適用することとした。また、解析対象の各河川における流出特性を十分に反映できるようにネットワークモデルの構築及び改良を行い、観測洪水事例を用いて検証し、その予測能力について検討を加えるものである。

-
- * 正会員 工博 室蘭工業大学教授 工学部建設システム工学科
(〒050 室蘭市水元町 27-1)
- ** 学生員 室蘭工業大学大学院 工学研究科建設システム工学専攻
(〒050 室蘭市水元町 27-1)
- *** 学生員 室蘭工業大学大学院 工学研究科建設システム工学専攻
(〒050 室蘭市水元町 27-1)

2. 解析対象河川

本研究では図-1に示される北海道の代表的な一級河川である石狩川上流部、天塩川及び十勝川の3河川について解析を行った。各河川ともに、地域保全上また経済上重要な位置にあり、河川沿岸の人口集中度が高く、洪水が発生した場合には多大な被害を受けると考えられる。従って、被害の軽減を図るためには的確な洪水予測が必要である。解析に用いるデータとしては図中に示されている各河川1カ所の流量観測所におけるデータ、降雨量に関しては石狩川上流部及び天塩川では5カ所、十勝川では4カ所の降雨観測所のデータを用いる。

3. 観測データのファジィ数化

前述のように、洪水予測に用いられる水文データにはさまざまな誤差が含まれている。降雨量は観測点近くに障害物がある場合や風などの影響による観測誤差や機械誤差がある。その上時・空間分布の変化を考慮すると流域全体における降雨量の正確な値を把握することは困難である。一方、流量については、一般に各河川固有の水位-流量変換式を用いて水位から推定するが、洪水時には水位の正確な測定が困難であり、また河川の断面形状も変化するため、大きな観測誤差が予想される。これらの誤差はその特性値が解らないため、確率的に処理することもまた困難である。そこで、誤差などの不確定要素を考慮して予測に用いるために観測データにファジィ理論を適用する。

本研究で使用するファジィ理論は、観測値が真値である可能性を $[0, 1]$ の度数で表わしたものである。この可能性の程度を表わす関数をメンバーシップ関数とい

い、本研究では図-2に示すような観測値が真値である可能性を1とし、可能性をもつ範囲を L とした三角型のメンバーシップ関数を使用する¹⁾。ここで、降雨と流量の単位が異なるので、予測に用いる入力データの次元を等しくするために、流量を以下の式を用いた流出高さ q_t に変換を行った。

$$q_t = \frac{3.6}{A} Q_t \quad (1)$$

ここに、 Q_t は流量、 A は流域面積を示す。また、現時刻 t と予測先時間 h との流出高さの差を流出高さ変化量として用いる。

$$\Delta q_t = q_{t+h} - q_t \quad (2)$$

以上から、予測に用いる降雨量、流出高さ、流出高さ変化量に対するメンバーシップ関数は以下のように表示される。

$$Mr_t = 1 - |r_t - x_r| / (L_r / 2) \quad (3)$$

$$Mq_t = 1 - |q_t - x_q| / (L_q / 2) \quad (4)$$

$$M\Delta q_t = 1 - |\Delta q_t - x_{\Delta q}| / (L_{\Delta q} / 2) \quad (5)$$

ここに、 r_t 、 q_t 及び Δq_t はそれぞれ時刻 t における観測降雨量、流出高さ、流出高さ変化量を示し、 x_r 、 x_q 及び $x_{\Delta q}$ はそれぞれファジィ観測値としての雨量強度、流出高さ、流出高さ変化量を表わす。また、 L_r 、 L_q 及び $L_{\Delta q}$ はそれぞれの可能性を持つ範囲を表わす。この様に、ファジィ数化によってデータは観測値を中心に




図-1 解析対象河川図




図-2 三角型メンバーシップ関数

$[-L/2, L/2]$ の範囲に拡大されると解釈することができる。

4. ファジィ・ニューラルネットワークによる洪水流出予測

4. 1 ネットワーク構造

ニューラルネットワークは脳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、並列分散型の処理を行えること、学習能力及び汎化能力があることがその特徴である。この様な特性を踏まえた上で、複雑な降雨-流出過程をニューラルネットワークに学習させ、洪水予測を行うことが本研究の目的である。解析に使用したネットワークの構造は図-3に示すように入力層、中間層及び出力層から構成される3階層型で、ファジィ数を入・出力としたファジィ・ニューラルネットワークである。入力としては、現時刻 t と $t-1$ の流出高さ、各観測点における3時間分の降雨量データを用いることとする。降雨と流出高さの性質が異なるものと考え、中間層をそれぞれに分離した局所結合型を採用し、出力は現時刻と予測先時間の間の流出高さ変化量とする。ファジィ数を入・出力としているので、入力層では15個のユニットをもって1つのデータに対応し、出力層では29個のユニットを用いる。

信号伝達方法は、入力層のユニット i に入力された信号が荷重 V_{ij} を介して結合している中間層のユニット j へ送られる。中間層のユニット j が結合しているすべての入力層のユニットから受ける信号の総和は(6)式で示される。

$$X_j = \sum_{i=1}^n S_i V_{ij} \quad (6)$$

次にユニット j が出力層に伝達する信号 A_j は(7)式の応答関数を用いて表わされる。

$$A_j = \frac{1}{1 + \exp \left\{ - (X_j - \gamma_j) / \mu \right\}} \quad (7)$$

ここに、 γ_j はユニット j の閾値であり、 μ は応答関数の形状を決定するパラメータである。次に中間層から出力層のユニット k に送られる信号の総和は(8)式で与えられる。

$$X_k = \sum_{j=1}^m A_j W_{jk} \quad (8)$$

上式で求められた信号を受けて出力層ユニット k から得られるネットワーク出力は次式で示される。

$$R_k = \frac{1}{1 + \exp \left\{ - (X_k - \theta_k) / \mu \right\}} \quad (9)$$

ここに、 θ_k はユニット k の閾値である。ネットワーク出力 R_k はファジィ集合として得られるので、予測値を決定するため、本研究では、最大出力信号をとるユニットの値を採択することとする。

4. 2 ネットワーク学習

この様にして構築されたネットワークを予測に用いるために、各結合荷重及び閾値の最適値を同定するためのネットワーク学習を行う。学習法に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、(10)式で示す入力信号に対する実際のネットワーク出力と教師信号との誤差2乗和をもとに荷重及び閾値の修正を行うものである。

$$E = \sum_k \sum_k (T_k - R_k)^2 \quad (10)$$

ここに、 T_k は教師信号、 R_k はネットワーク出力、 p は学習パターン数である。上記の誤差を最小化するため




図-3 ネットワーク構造図

に最急降下法を利用して、荷重修正量を求める。すなわち、誤差を結合荷重の関数であると考え、修正量を次式で与える。

$$\Delta W_{jk} = \alpha (T_k - R_k) R_k (1 - R_k) A_j / \mu \quad (11)$$

ここに、 α は学習率で修正量を調節する係数である。 V_y , θ_k , γ_j についても同様に求められる。通常のバックプロパゲーション法においては応答関数の形状を決定するパラメータは $\mu = 1$ と固定して与えるが、本研究ではこの μ にシミュレーティッド・アニーリング法²⁾を用い、学習回数によって変化させる方法を採用した。 μ は次式で示される³⁾。

$$\mu = \frac{T_0}{1 + \ln(1 + \Delta t \cdot t)} \quad (12)$$

ここで、 T_0 は初期値で一定であり、 Δt は増加率、 t は学習の繰り返し回数を示す。学習の初期段階において μ は大きな値をとり、学習が進むに連れて減少していく。ここで、荷重修正量が出力信号に規定されると考えると修正量 ΔW_{jk} が最大となるのは、次式を満たす場合である。

$$\frac{\partial \Delta W_{jk}}{\partial R_k} = \alpha (T_k - R_k) A_j / \mu \cdot [R_k (1 - 2R_k)] = 0 \quad (13)$$

よって、修正量 ΔW_{jk} は $R_k = 0.5$ で最大値をとる。図-4に示されるように μ が大きな値のとき R_k の出力は0.5に近づくの

で学習の初期段階においては修正量が大きくなる。 μ が減少してくると R_k の値は0または1に漸近し、修正量は減少する。このようにシミュレーティッド・アニーリング法を用いることにより、学習の初期地点近くの極小値に陥ることを防ぎ、最小値に達する可能性を高めることができる。図-5は通常のバックプロパゲーション法とシミュレーティッド・アニーリング法を用いた場合の誤差収束状況の比較を示している。学習回数が40回以降の2乗誤差を比較すると、シミュレーティッド・アニーリング法を適用した場合の誤差はほぼ半減しており、大幅な計算処理時間の短縮を図ることができる。この手法は、初期値によっては極小値に陥る可能性があるバックプロパゲーションの改良法として、ニューラルネットワークを用いた広範多岐の事例についても適用することができ、また非常に有効であると思われる。

5. 解析結果

前述の方法で構築及び学習を行ったネットワークを用いての洪水流出実時間予測の結果を示す。本解析では対象河川の洪水が2事例と少ないため、比較して流量の大きい事例を用いて学習を行い、他方の事例の予測に用いることとした。また、現在までの研究結果をもとに降雨と流出の相関性が高い入・出力の組み合わせを決定するため、入力として与える降雨データを変えて予測を行った。解析対象とした3河川の各洪水事例において、流量ピークは降雨ピークよりも8時間以上の遅れが見られる。そこで、現時点を t として $t-4$, $t-5$, $t-6$ 時の降雨量を入力として用いた場合をパターンAと称し、 $t-3$, $t-4$, $t-5$ 時の降雨データを用いた場合をパターンBと呼称する。また、入力する流量データについては、両パターンともに現時刻 t 及び $t-1$ の観測データを用いた。

図-6, 7はそれぞれ石狩川上流部についてパターンA, パターンBを用いて予測を行った結果である。3時間先予測においては両パターンともに流出特性を良く捉えており、的確な予測を行っていることが認められる。6時間先予測では、ピークの出現に数時間の遅れがあるが、全体的なハイドログラフの特徴を再現している。ピーク出現の遅れは学習に用いた事例とは流出形状が異なることに起因すると考えられる。両図を比較すると、3時間先予測では大きな違いは見られないが、6時間先予測ではパターンBがよりの確な予測を行っていることが認められる。

図-8, 9は天塩川においてのそれぞれパターンAとパターンBの結果である。天塩川の場合、3時




図-4 応答関数の傾き




図-5 2乗誤差の比較




図 - 6 (a) 石狩川 3 時間先予測 A




図 - 6 (b) 石狩川 6 時間先予測 A




図 - 7 (a) 石狩川 3 時間先予測 B




図 - 7 (b) 石狩川 6 時間先予測 B




図 - 8 (a) 天塩川 3 時間先予測 A




図 - 8 (b) 天塩川 6 時間先予測 A




図 - 9 (a) 天塩川 3 時間先予測 B




図 - 9 (b) 天塩川 6 時間先予測 B




図 - 1 0 (a) 十勝川 3 時間先予測 A




図 - 1 0 (b) 十勝川 6 時間先予測 A




図 - 1 1 (a) 十勝川 3 時間先予測 B




図 - 1 1 (b) 十勝川 6 時間先予測 B

間先予測については両パターンともに観測値の形状特性を再現し、ピーク出現時刻・流量が一致している。6時間先予測では石狩川と同様にピーク出現の遅れがあるが、流出特性は良好に再現している。パターン A とパターン B を比較すると、3 時間先においては大きな差異は見られないが、6 時間先予測ではパターン B がより明確に特徴を捉えていると言える。天塩川の場合は、学習に用いた事例と予測を行った事例の降雨－流出パターンがほぼ一致しているため、高い精度の予測が行えたと思われる。

図 - 1 0, 1 1 は十勝川におけるパターン A とパターン B を用いた予測結果である。3 時間先予測については両パターンにおいて観測ハイドログラフの特性を十分に再現した結果を得た。しかし、6 時間先予測になると、流量の増加部において観測値との間に不一致があり、ピークの出現時刻も遅れている。これは、十勝川の降雨観測所が中流部以降にあり、流量観測所も大きな支川が合流した点にあり、学習した事例との洪水規模の差が著しかったため、流量の急激な変化に対応することができなかったためと推定される。

6. 結 び

ファジィ・ニューラルネットワークを用いて、洪水事例が少ない場合においても実用上支障のない精度で流出予測が行えることを示した。また、入力には観測データをそのまま使用し、シミュレーティッド・アニーリング法を用いた学習法でネットワークを構築することによって計算処理時間の大幅な短縮が図られ、洪水被害の軽減のための迅速な対応を講ずるのに有用であると思われる。

参考文献

- 1) Kaori TOYAMA et.al: Flood Forecasting Using a Fuzzified Neural Network, Proc. of 1st Korea-Japan Bilateral Seminar on Water Resources and Environment Research, pp57-64, 1996.
- 2) J.A.Freeman, D.M.Skapura: Neural Networks Algorithms, Applications, and Programming Techniques, pp169- 212, 1991.
- 3) 中野馨他: 入門と実習ニューロコンピュータ, 技術評論社, pp109-127, 1989.