

II-11 ニューラルネットワークを用いた洪水予測について

室蘭工業大学建設システム工学科 学生員 外山かおり
 室蘭工業大学建設システム工学科 学生員 大坂 忠史
 室蘭工業大学建設システム工学科 正会員 藤間 聡

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、確率統計的に処理することが不可能である。そのため、このよう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、降雨一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推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を行ない、その予測能力について検討を加えるものである。

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、天塩川の2河川について解析を行った。各河川ともに、地域保全・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思われる。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流域内に設置されている観測所から5カ所の降雨観測所のデータを選び用いることとする。

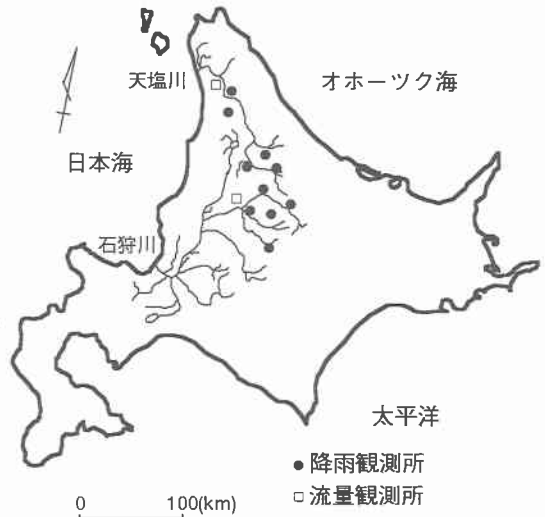


図-1 解析対象河川

3. 観測データのファジィ数化

前述のように、洪水予測のため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不可能である。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、確率統計的に処理すること

もまた不可能である．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推論を適用する．

本研究で使用するファジィ数は，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．

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

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 t 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に示される．

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

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

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

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数としての雨量強度，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 $[-L/2, L/2]$ 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．解析に用い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 t から $t+2$ まで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 Δq_{t+k} 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




図 - 2 三角型メンバーシップ関数

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。

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

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。

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

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 はファジィ数として得られるので、予測値を決定するために非ファジィ化を行い、出力をクリスプ値に戻す。

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差をもとに荷重及び閾値の修正を行うものである。

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

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_{ij} 、 θ_k 、 γ_j についても同様にして求められる。通常バックプロパゲーションにおいては応答関数の形状を決定するパラメータは $\mu = 1$ と固定して与えられるが、本研究ではこの μ にシミュレティッド・アニーリング法²⁾を用い、学習回数によって変化させる。 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、(11) 式で示される修正量が出力信号に規定されると考える。修正量 ΔW_{jk} が最大となるのは、次式を満たす場合である。

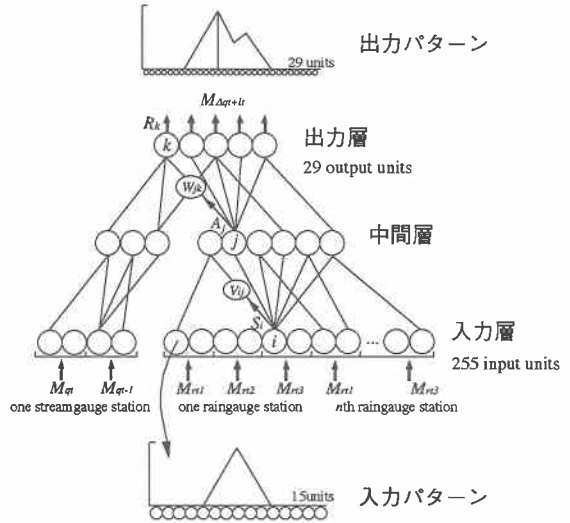


図 - 3 ネットワーク構造図

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

よって、 $R_k=0.5$ で修正量 ΔW_{jk} は最大値をとる。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ティッド・アニーリング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とシミュレティッド・アニーリング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100回の時点における2乗誤差を比較すると、シミュレティッド・アニーリング法を適用した場合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な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。

4. 3 中間層ユニット数の決定方法

本研究においては、得られた観測洪水例が各河川において2事例と少ないため、1つの事例を用いて学習を行い、もう一方の事例を予測する方法を採っている。そのため、ニューラルネットワークの汎化能力を考えた場合学習誤差が最小であるネットワーク、つまり学習パターンに完全に対応したネットワークが必ずしも最適なネットワークであるとは限らない。また、ネットワークの結合数を増やせばより複雑なパターンに対応することができるが、それに伴って計算時間も増大するので、迅速な対応が必要な洪水予測にとっては不利になるといえる。

そこで、ネットワークモデルの最適化を行うために、赤池情報量基準 (AIC) を利用してネットワークの中間層のユニット数を決定する方法を用いた⁴⁾。

AICの値は(14)式を用いて計算される。

$$AIC = N \log (E) + 2K \quad (14)$$

ここに、 K はニューラルネットワークモデルの中間層ユニットの数、 N は独立な学習データの個数、 E は教師信号と実際のネットワーク出力との間の二乗誤差である。中間層ユニット数が異なるネットワークを用いてネットワーク学習を行い、それぞれについてAICを求め正の値の範囲で最も小さいAICを与えるネットワーク構造を最良のものと判断する。それぞれ中間層ユニット数を変えて学習を行った結果を図-6に示す。それぞれ流量用のユニット数の3パターンを基本とし、降雨用のユニット数を4パターンに変化させてAICの比較を行った。その結果、流量用のユニット数が15個、降雨用ユニット数が50個の総中間層ユニット数が65個のネットワークが最も




図-4 応答関数の傾き




図-5 2乗誤差の比較




図-6 AICの比較

AICの値が小さく得られた。そこで、比較検討を行うために流量用ユニット15個・降雨用ユニット50個のモデルをパターンA、流量用ユニット10個・降雨用ユニット55個のモデルをパターンBとし、各ネットワークを用いて予測を行いその能力の比較を行う。

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モデルを用いての洪水流出予測結果を示す。得られている2つの洪水事例のうち、比較して規模の大きい事例を用いて150回の学習を行った。学習率及びシミュレーテッド・アニーリングにおけるパラメータは2つのモデルにおいてすべて等しい。

図-7は石狩川上流部についてパターンAのネットワークを用いてそれぞれ3時間先、6時間先の予測を行った結果である。(a)の3時間先予測においては流出特性をよく捉えており、的確な予測を行っているといえる。(b)の6時間先予測では、流量のピークの出現において若干の遅れが見られるが全体的な流出形状を把握した予測結果となっている。図-8は同じく石狩川上流部についてのパターンBのネットワークを用いた場合の3時間先、6時間先の予測結果である。パターンAの結果と比較すると、(a)の3時間先予測結果については大きな差異は見られないが、(b)の6時間先予測結果においては観測値との開きが大きくなっている。以上のことから、パターンAのネットワークを用いた場合の方が予測精度が高いといえるであろう。

図-9は天塩川についてパターンAを用いた場合のそれぞれ3時間先、6時間先の予測結果である。(a)の3時間先予測では増水部分、減水部分ともに観測値とほぼ一致した予測結果が得られており、精度の高い予測を行っているといえる。(b)の6時間先予測結果においては石狩川における6時間先予測結果と同様にピークの出現時刻が遅れているが、ハイドログラフの立ち上がり部分はほぼ一致しており、十分な精度の予測を行っている。図-10は天塩川についてパターンBのネットワークを用いた場合のそれぞれ3時間先、6時間先の予測結果である。(a)の3時間先予測ではパターンAの結果に比べて大きな違いは見られないが、(b)の6時間先予測結果においてはパターンAの結果よりも観測値と予測値の間の差が大きくなって出ている。天塩川の事例についてもパターンBのネットワークよりもパターンAのネットワークを用いた予測結果の方が精度が高いといえるであろう。

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。入力には観測データをそのまま使用し、シミュレーテッド・アニーリング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。また、中間層のユニット数の決定にAICを用いることによって、学習事例が少ない場合においても精度的・コスト的に適切なネットワーク構造を求めることができることを示した。

参考文献

- 1) 本多中二他：ファジィ工学入門，海文堂，pp15-77，1991.
- 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.
- 4) 馬場則夫他：ニューラルネットの基礎と応用，共立出版株式会社，pp9-27, 1994.

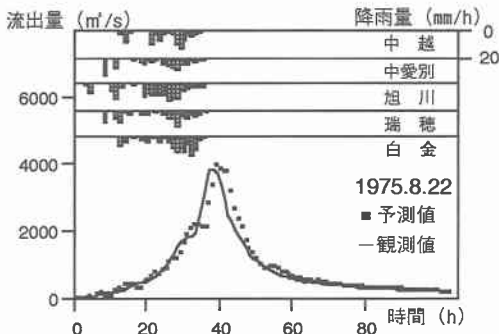


図 - 7 (a) 石狩川 3 時間先予測 A




図 - 7 (b) 石狩川 6 時間先予測 A




図 - 8 (a) 石狩川 3 時間先予測 B




図 - 8 (b) 石狩川 6 時間先予測 B




図 - 9 (a) 天塩川 3 時間先予測 A




図 - 9 (b) 天塩川 6 時間先予測 A

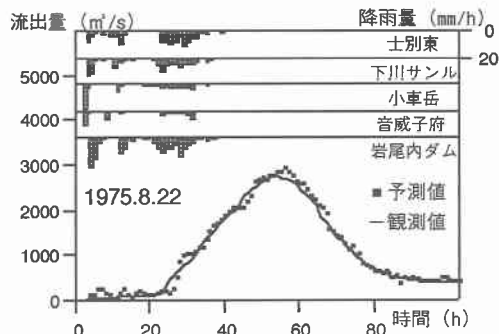


図 - 10 (a) 天塩川 3 時間先予測 B




図 - 10 (b) 天塩川 6 時間先予測 B