

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 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く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、パラメータを決定するために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、我が国の雨量観測の歴史は浅く、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の誤差は、確率統計的に処理することが困難であるため、この様にし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、3時間先および6時間先の洪水流量の予測を行うものである。

2. 解析対象河川

本研究では北海道の代表的な一般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。解析に用いるデータとしては、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。

3. 観測データのファジィ数化

洪水予測のために用いられるデータには様々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、時・空間分布の変化があり流域全体における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理論を適用する。

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。また、降雨と流量の次元を等しくするために、流量を流域面積で除した流出高さ q_t に変換を行った。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。

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

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

$$M\Delta q_t = 1 - |\Delta q_t - x_{\Delta q}| / (L_{\Delta q} / 2) \quad (3)$$

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。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。




図-1 ネットワーク構造図

4. ファジィ・ニューラルネットワークによる流出予測

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、

洪水流量予測 ニューラルネットワーク シミュレーテッド・アニーリング 赤池情報量規準(AIC)

〒050 室蘭市水元町27-1

TEL 0143-47-3176

FAX 0143-47-3406

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。解析に用いたネットワークの構造は図－1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 $\Delta q_{t,t+\Delta t}$ とする。また、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にはバックプロパゲーション法を用いた。修正量は次式で与えられる。

$$\Delta W_{jk} = \alpha (T_k - R_k) R_k (I - R_k) A_j / \mu \quad (4)$$

ここに、 α は学習率で修正量を調節する係数である。本研究では係数 μ にシミュレーティッド・アニーリング法を用い、次式に従って学習回数により変化させる。

$$\mu = \frac{T_0}{1 + \ln(1 + \Delta t \cdot t)} \quad (5)$$

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。また本研究では、ネットワークモデルの最適化を行うために、赤池情報量規準（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。AICの値は（6）式を用いて計算される。

$$AIC = N \log(E) + 2K \quad (6)$$


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。図－2に示すように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AICの値が小さく得られたので、このモデルを用いて予測を行った。

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の一例を示す。図－3は石狩川上流部についての3時間先、図－4は6時間先の予測を行った結果である。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。一方、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。

6. 結 び


ファジィ・ニューラルネットワークを用いて、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。シミュレーティッド・アニーリングを用いた学習法によって計算処理時間の大幅な短縮が図られ、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。



図－2 ネットワーク構造図



図－3 石狩川3時間先予測結果



図－4 石狩川6時間先予測結果