

II-346

ファジィ・ニューラルネットワークを用いた洪水実時間予測

室蘭工業大学大学院 学生員 外山かおり

室蘭工業大学大学院 学生員 大坂 忠史

室蘭工業大学工学部 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。現在使用されている流出解析法では流域特性を表すパラメータの決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。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できないため、これによって得られた結果にも誤差が含まれているものと思われる。本報では、一地点の流量と多数の地点の降雨量を誤差や空間的变化を含む曖昧な値、すなわちファジィ数とみなし、降雨と流出の関係をニューラルネットワークによりブラックボックス的に扱い、1時間及び3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

本報では北海道内の1級河川を対象に、石狩川上流部、天塩川上流部及び十勝川の計3河川について解析を行う。流量については各河川1カ所の流量観測所のデータを用い、降雨量については各流量観測所よりも上流に位置している4または5カ所の代表的な降雨観測所のデータを使用する。

3. 観測データのファジィ数化

降雨量は観測点近くの障害物や風などの影響による観測誤差や時空間的分布の変化があり、流域全体における正確な値を把握することは不可能である。また流量は、一般に水位-流量変換式を使用して水位から推定するが、洪水時には水位の正確な測定が難しいためかなりの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、観測値を誤差を含んだまま空間分布を考慮したファジィ数として適用する。ここ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-1に示すように観測値が真値である可能性を1とし、可能性の値が0以上である範囲を L とした下記の三角型メンバーシップ関数を使用する。ここで、降雨と流量の単位が異なるため、流量を流域面積で除した流出高さに変換して予測に用いることとする。




図-1 三角型メンバーシップ関数

$$\text{降雨: } Mr_t = 1 - |r_t - x_r| / (L_r / 2) \quad (1)$$

$$\text{流出高さ: } Mq_t = 1 - |q_t - x_q| / (L_q / 2) \quad (2)$$

$$\text{流出高さ変化量: } M\Delta q_t = 1 - |\Delta q_t - x_{\Delta q}| / (L_{\Delta q} / 2) \quad (3)$$

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、流出高さ及び流出高さ変化量を、 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、流出高さ及び流出高さ変化量を、 L_r 、 L_q 及び $L_{\Delta q}$ はそれぞれの範囲を表わす。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。

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、その最小の単位である多数のユニットの結合によって信号の伝達を行う。本報では、図-2に示すようなファ




図-2 ネットワーク構造図

ジ数を入力・出力信号としたファジィ・ニューラルネットワークにより予測を行う。入力データとして、現時刻 t 及び $t-1$ 時の流出高さ q_t, q_{t-1} , t から $t-2$ 時の各時間降雨量 r_t, r_{t-1}, r_{t-2} を用い、1 時間または 3 時間後の流出高さ変化量を出力することとする。ファジィ数を入出力するため、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こととする。また降雨と流出高さの性質は異なるものと考え、中間層を分離した局所結合型とした。次に信号伝達方法について説明する。入力層のあるユニット i に入力された信号 S_i は荷重 V を介して結合している中間層の各ユニットへと送られる。中間層のあるユニット j が結合している全ての入力層のユニットから受け取る信号の総和は $\sum S_i V_{ij}$ となる。ユニット j が発する信号 A_j は j 自身の閾値 γ_j とこの総和 $\sum S_i V_{ij}$ により、シグモイド関数を用い (4) 式のように決定される。

$$A_j = \frac{1}{1 + \exp \left(\left(\sum S_i V_{ij} + \gamma_j \right) / \mu \right)} \quad (4)$$

次に、中間層と出力層の間において、中間層の各ユニットから出力層のあるユニット k に送られた信号の総和は荷重 W として $\sum A_j W_{jk}$ となり、ユニット k が発する信号 R_k は上式と同様に (5) 式のように表わされる。

$$R_k = \frac{1}{1 + \exp \left(\left(\sum A_j W_{jk} + \theta_k \right) / \mu \right)} \quad (5)$$

本報ではバックプロパゲーション法によってネットワークの学習を行う。これは教師付学習法であり、学習用事例から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、繰り返し学習させ教師信号と実際の出力信号との誤差を最小に達するまで荷重、閾値の同定を行うものである。この誤差の収束を早めるために学習を行う前に荷重、閾値に $[-1, 1]$ の乱数を与える。この様な学習済のネットワークで予測を行う。しかし、学習において与えられなかったパターンで洪水事象が発生すると予測が困難となる。そこで、予測時に得られるデータを使用して先程と同様に学習パターンを作成し、荷重と閾値の修正を行う逐次学習を行うこととする。

5. 解析結果

解析の一部として、石狩川上流部、天塩川上流部の予測結果を図-3, 4, 5 及び 6 に示す。ネットワーク学習は 100 回、逐次学習は 3 回行った。石狩川上流部については 1 時間先予測においては全体の流出形状がほぼ一致しており、的確な予測を行っていると思われる。3 時間先予測では、ピーク流量に関して予測値の出現が遅れているが、全体的な特徴は捉えている。天塩川上流部では、1・3 時間先予測共に予測値が観測値の特性を高い精度で再現しており、良好な結果が得られた。

6. 結 び

以上の予測結果から、ファジィ・ニューラルネットワークを用いた場合、降雨-流出機構の複雑な過程を短時間で学習し、観測データを空間分布や誤差を含んだまま使用することによって精度の高い予測が行えるという結果を得た。今後更に改良を加えることによって、リードタイムの長い予測を行うことができると考えられる。




図-3 石狩川上流部 1 時間先予測




図-4 石狩川上流部 3 時間先予測




図-5 天塩川上流部 1 時間先予測




図-6 天塩川上流部 3 時間先予測