

II-19

ファジィ・ニューラルモデルを用いた洪水流量の逐次予測

室蘭工業大学大学院 学生員 今井里美
室蘭工業大学工学部 正員 藤間聰

1. はじめに

洪水災害の防止および軽減には、正確で速やか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。一般に使用されている流出解析法は、降雨量、流量等の長期にわたる観測データから流域特性を表すパラメータを同定する作業が必要とされるため、これらを逐次予測法として用いる場合に誤差を含む測定値から迅速にパラメータを求めて定式化を行うことは困難である。本研究では、観測降雨量、流量データを誤差や不確実さを含むあいまいな値すなわちファジィ数とみなすとともに、降雨と流出との関係は神経系の情報処理システムをモデルにした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、洪水流量の逐次予測を行うことを目的とする。

2. ファジィ数としての降雨量、流量データ

降雨は流域内に一様に分布するものではなく、その観測地点数が限られるために流域全体の真の降雨量を知ることは難しい。また、流量は観測水位から水位-流量関係式を用いて決定される場合が多く、ある程度の誤差を含んでいる。つまり、観測降雨量および流量データは必ずしも真値ではないため、本研究ではファジィ数として取り扱う。ここで使用するファジィ数は、各値が真値である可能性を $[0, 1]$ の度数で表現した実数の組である。この度数はメンバーシップ関数と呼ばれ、図-1に示すように観測値が真値である可能性を1とし、真値である可能性を持つ範囲を L とする三角型の関数を使用することが多い。¹⁾

流出予測に用いたのは(1), (2), (3)式のメンバーシップ関数である。

$$Mr_t = 1 - |r_t - x_r| / (L_r / 2) \quad Mr_t \geq 0 \quad (1)$$

$$MQ_t = 1 - |Q_t - x_Q| / (L_Q / 2) \quad MQ_t \geq 0 \quad (2)$$

$$M\Delta Q_t = 1 - |\Delta Q_t - x_{\Delta Q}| / (L_{\Delta Q} / 2) \quad M\Delta Q_t \geq 0 \quad (3)$$

ここで、 Mr_t および MQ_t はそれぞれ時刻 t における観測降雨量 r_t 、観測流量 Q_t のメンバーシップ関数、 $M\Delta Q_t$ は $t-1$ から t までの観測流量の変化量 $\Delta Q_t = Q_t - Q_{t-1}$ のメンバーシップ関数であり、ファジィ数 x_r 、 x_Q 、 $x_{\Delta Q}$ はそれぞれ雨量強度、流量、流量変化量を、係数 L_r 、 L_Q 、 $L_{\Delta Q}$ は可能性を持つ範囲を表している。このようにデータをファジィ数にすると、各観測データは $[-L/2, +L/2]$ の範囲にそれぞれの可能性を持ちつつ拡大される。これらのファジィ数は、次に述べるファジィ・ニューラルネットワークの入出力データとして使用される。以下の計算ではメンバーシップ関数の範囲を表す3つの係数 L_r (mm/h)、 L_Q (m³/s)、 $L_{\Delta Q}$ (m³/s)をそれぞれ石狩川上流部で5, 1700, 260、天塩川で10, 1540, 200、留萌川で10, 270, 35とし、鶴川で15, 1760, 350、胆振幌別川で15, 170, 65、敷生川で15, 190, 75、とする。²⁾

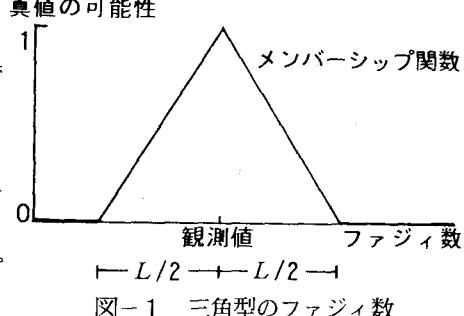


図-1 三角型のファジィ数

3. ファジィ・ニューロンを用いた洪水流量の逐次予測

生物の神経系は、多数のニューロン（神経細胞）が結合して複雑なニューラルネットワークを構成し、ニューロン間で電気パルス的な信号を並列に伝達し合うことで情報を処理している。一般に、ニューロン間の信号伝達効率は荷重と呼ばれ、信号の伝播に伴い荷重が変化することにより、神経系は与えられた情報における信号の入力一出力パターンを満たすように「学習」すると考えられている。したがって、このシステムを応用し、入出力パターンとして降雨量－流量のパターンを与えるならば、通常の流出解析のように複雑なアルゴリズムを定義することなく流量予測が可能になる。

本研究では、図-2のようにニューロンを3層構造に組み合わせたネットワークに、降雨量、流量情報をファジィ数として与えるファジィ・ニューラルネットワークを使用する。このモデルにおいて、入力層のニューロン*i*に与えられた信号 S_i は、中間層のニューロン*j*を通して出力層のニューロン*k*に伝達され、同一層内のニューロン同士の信号伝達ではなく、信号の最大値は1、最小値は0とされる。以下、1時間先の流量を予測する場合を例に、降雨量および流量情報の与え方、信号の伝達と学習、流量予測方法について述べる。

まず、このネットワークの入力層に流量情報 $Q_t, \Delta Q_t$ と6時間分の降雨量情報 $r_t, r_{t-1}, r_{t-2}, r_{t-3}, r_{t-4}, r_{t-5}$ を与えると、出力層では流量変化量 ΔQ_{t+1} を出力し、1時間先の時刻 $t+1$ の流量は $Q_{t+1} = Q_t + \Delta Q_{t+1}$ として得られると仮定する。降雨量、流量などの入出力データはファジィ数であるから、入出力層は複数個（本論文では15個）で1組を成すニューロンのグループで1つの情報を表すとし、各組のニューロンはそれぞれのデータのメンバーシップ関数を信号として与えられる。例として、 Q_t の入力方法について説明

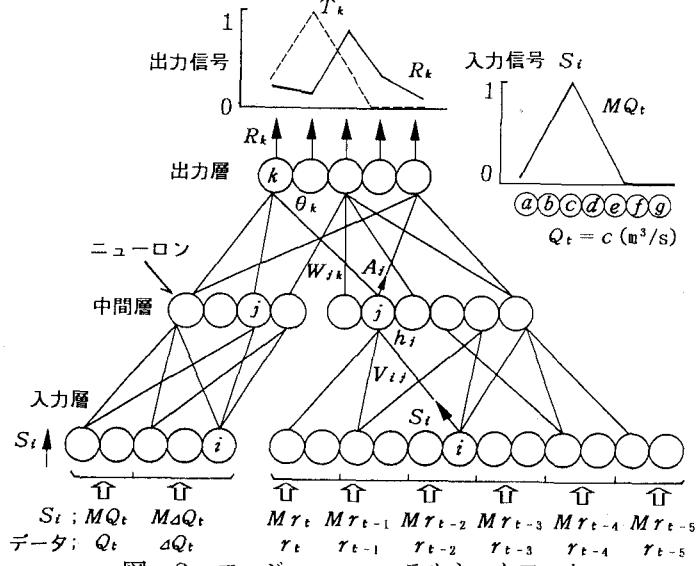


図-2 ファジィ・ニューラルネットワーク

する。図-2の右上に示すように、 Q_t を表す組のニューロンはそれぞれ流量 $a, b, \dots, g (\text{m}^3/\text{s})$ を表すと定められている。同図は $Q_t = c (\text{m}^3/\text{s})$ と観測された場合であり、ニューロン c において 1 となり、 b において 0.5、 f において 0 となるメンバーシップ関数 $MQ_t (Q_t = c)$ が、流量 Q_t を表す組のニューロン a, b, \dots, g に入力信号 S_i として与えられる。³⁾

入力信号 S_i は中間層のニューロンを介して出力層のニューロンに伝達される。入力層と中間層のニューロン i, j 間の荷重を V_{ij} とすると、中間層のニューロン j が入力層の1つのニューロン i から受ける入力は $S_i V_{ij}$ である。中間層のニューロンは連結されている側の入力層の全てのニューロンから信号を受けるから、 j が受ける入力の合計は $\sum S_i V_{ij}$ となる。ニューロン j は入力の合計と j 自身の閾値 h_j に応じて(4)式のように信号 A_j を発生する。

$$A_j = f(\sum S_i V_{ij}, h_j) \quad (4)$$

同様に、出力層のニューロン k は中間層の全てのニューロンから信号を受けるから、ニューロン j, k 間の荷重を W_{jk} とすると、 k が中間層のニューロンから受ける入力の合計は $\sum A_j W_{jk}$ となり、(5)式に従つ

て信号 R_k が発生される。

$$R_k = f(\sum A_j W_{jk}, \theta_k) \quad (5)$$

ここで、 θ_k は出力層ニューロン k の閾値であり、(4)式と(5)式で使用されている関数 $f(X, \alpha)$ は(6)式および図-3 のシグモイド関数で与えられる。

$$f(X, \alpha) = \frac{1}{1 + \exp\{-(X - \alpha)/\mu\}} \quad (6)$$

ただし、 X および α はそれぞれ(4)式では中間層のニューロンが受ける入力の合計 $\sum S_i V_{ij}$ と閾値 h_j 、(5)式では出力層のニューロンが受ける入力の合計 $\sum A_j W_{jk}$ と閾値 θ_k の意味であり、 $\mu = 1$ はニューロンの信号変換感度を表す係数である。また、

図-2 に示すように中間層ニューロンを、流量情報の信号を変換するグループと降雨量情報の信号を変換するグループの 2 つに分割したのは、入力パターンを広意に解釈させるためである。

ネットワークの荷重と閾値の学習は、バックプロパゲーションといわれる最急降下法に類する方法で実施される。この方法は、幾つかのパターン p の入力信号 $\{S_i\}_p$ に対して、それぞれネットワークが output すべき理想的信号 $\{T_k\}_p$ と

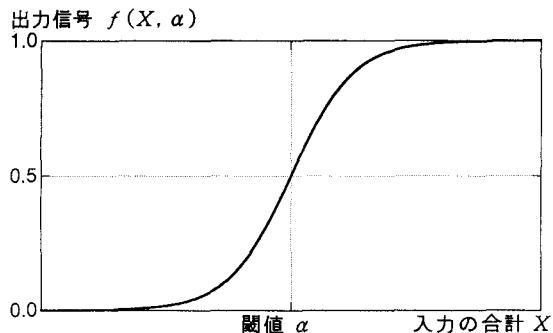


図-3 ニューロンの信号発生

実際の出力信号 $\{R_k\}_p$ との誤差二乗和 E_p を減少させる方向に荷重、閾値の修正を何度も繰り返し、与えられた入出力パターンを完全に満たすネットワークを導くものである。理想的な信号は一般に教師信号と呼ばれる、本ネットワークの入出力の仮定として入力層に $Q_t, \Delta Q_t, r_t, \dots, r_{t-5}$ が与えられた場合には流量変化量 ΔQ_{t+1} が出力されるべきであるから、 T_k には入力層と同じ要領でメンバーシップ関数 $M_{\Delta Q_{t+1}}$ を与える。ただし、学習の基準となる誤差二乗和 E_p の計算は(7)式による。

$$E_p = \sum \{T_k - R_k\}^2 \quad (7)$$

E_p を減少させるための W_{jk} の修正は、 $\partial E_p / \partial W_{jk}$ を計算することにより(8)式のように求められる。

$$\begin{aligned} W_{jk} &= W_{jk} - \varepsilon \frac{\partial E_p}{\partial W_{jk}} \\ &= W_{jk} - \varepsilon \frac{\partial E_p}{\partial R_k} \frac{\partial R_k}{\partial X_R} \frac{\partial X_R}{\partial W_{jk}} \\ &= W_{jk} + \varepsilon (T_k - R_k) R_k (1 - R_k) A_j / \mu \end{aligned} \quad (8)$$

ここで、 ε は修正量を調整する正の係数（以下の計算では $\varepsilon = 0.7$ ）、 X_R は出力層のニューロンが受ける入力の合計 $\sum A_j W_{jk}$ である。閾値 θ_k の修正も同様にして(9)式で定められる。

$$\theta_k = \theta_k - \varepsilon (T_k - R_k) R_k (1 - R_k) / \mu \quad (9)$$

さらに、中間層と入力層のニューロン間の荷重 V_{ij} 、中間層のニューロンの閾値 h_j の修正は、

$$\sigma_j = \sum W_{jk} (T_k - R_k) R_k (1 - R_k) / \mu \quad (10)$$

として(11)式と(12)式でそれぞれ定められる。

$$V_{ij} = V_{ij} + \varepsilon \sigma_j A_j (1 - A_j) S_i / \mu \quad (11)$$

$$h_j = h_j - \varepsilon \sigma_j A_j (1 - A_j) / \mu \quad (12)$$

全ての入力パターンに対して正しい出力がなされるまでこの修正計算を繰り返すことにより、ネットワークの学習は完成される。学習の繰り返し回数は、すべてのパターンについて(8)式から(12)式の修正計算を 1 度ずつ行って 1 回と数える。実際の計算では、他のパターンでの修正量を考慮しながら荷重と閾値を

が行われる。3時間先流量の予測では、 T_k に3時間の流量変化量のメンバーシップ関数を使用する。

4. 洪水流量予測結果と考察

本論文では、上述のシステムを用いて道北の一級河川である石狩川上流部、天塩川および留萌川と、道南の鶴川、登別・白老地方に位置する胆振幌別川、敷生川の6水系における洪水流量の逐次予測を行う。ファジィ・ニューラルネットワークは入力層のニューロンが120個、流量情報と降雨量情報を変換する中間層のニューロンがそれぞれ10個、30個、出力層のニューロンが15個であり、過去の洪水事例による学習の繰り返し回数は100回、メンバーシップ関数は2節に記述した通りである。

石狩川上流部および天塩川はそれぞれ流域面積3087km²、3698km²の一級河川であり、石狩川上流部では流域内に16箇所、天塩川では15箇所の降雨観測所を有しているので、ティーセン法を用いて流域平均降雨量を求めており、図-5および図-6に、両河川の1981年8月3日の洪水について1時間先と3時間先の流量予測を示す。流量データは石狩川上流部は伊納、天塩川は誉平で観測されたものであり、1975年8月22日の洪水事例により学習を行ったネットワークから予測を開始した。1時間先の流量予測値は観測値と良く一致することが認められるが、3時間先の流量予測では、流量の急増時および主ピーク時において予測値の出現時刻が観測値に比べて遅れる傾向とピーク流量を過大に予測する傾向が見られる。これは、3時間前に起きたであろう現象に対して、ネットワークの学習が追いつかないためと考えられる。

図-7に留萌川の1981年8月3日の洪水流量予測を示す。留萌川の流量は大和田観測所におけるデータであり、降雨量データは大和田上流域234km²内の幌糠、チバベリ、峠下、タルマップの4観測地点の算術平均を用いている。ネットワークの学習は、3節で記した表-1および表-2の計算と同様に1975年と1979年に得られた2つの洪水事例で行った。石狩川上流部および天塩川と同様に1時間先の流量予測値は観測値と一致するが、3時間先の予測値は観測値に遅れる傾向がある。

次に、北海道南部に位置する流域面積1270km²の鶴川における洪水流量予測を示す。図-8は鶴川において観測された1992年8月9日の洪水事例である。この水系での洪水事例のデータがこれより他に得られなかったので、過去の洪水

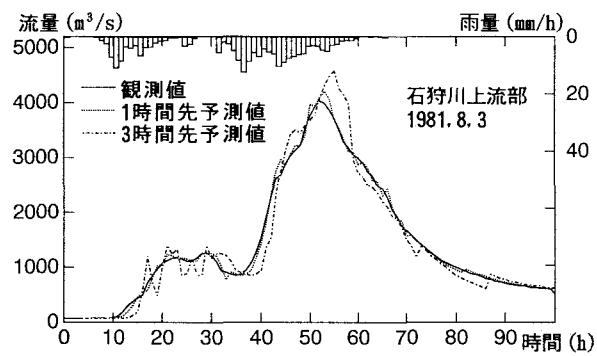


図-5 観測値・予測値ハイドログラフ(石狩川上流部)

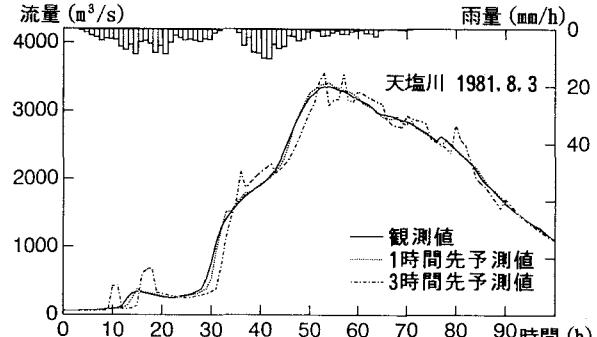


図-6 観測値・予測値ハイドログラフ(天塩川)

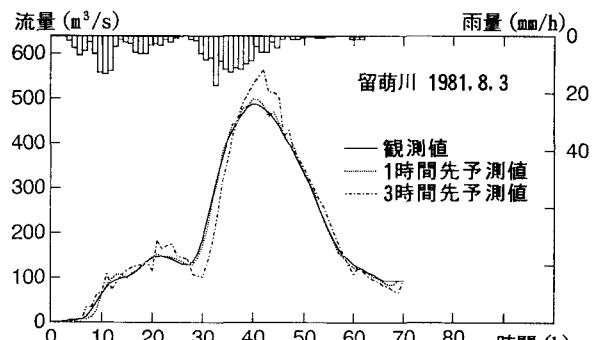


図-7 観測値・予測値ハイドログラフ(留萌川)

による学習は行わず、予測時の学習だけで洪水流量の1時間先の予測を試みた。

図-9は1981年8月21日の胆振幌別川の洪水流量予測であり、図-10は同日敷生川の洪水流量予測である。これらの河川はオロフレ山系の南東斜面域に位置しており、流域面積（胆振幌別川 105km^2 、敷生川 136km^2 ）の80%前後を山地部が占める。また、この地域は道内有数の豪雨地帯で、地質的には溶結凝灰岩が比較的浅いところで不透水層をなしているため、洪水到達時間が短い。本論文では、胆振幌別川の幌別ダム観測所と敷生川の竹浦における流量データについて1時間先流量の予測を行った。ネットワークの学習は、胆振幌別川における1970年9月17日、1980年8月28日および1981年8月3日の3つの洪水データで行い、敷生川の洪水流量予測にもこのネットワークを用いた。両図とも予測値は、観測値に精度良く一致する。

5. 結 語

以上のように、誤差、不確実さを含む降雨量および流量観測値とファジィ・ニューラルネットワークを用いて、洪水流出を精度良く予測することができる。過去の洪水の繰り返し学習には長時間の計算が必要であるが、本法は予測計算と予測時の学習は短時間で行うことができるため、流出時間の短い中小流域でも逐次予測法として使用可能である。このモデルでは、一般的洪水解析のパラメータ同定作業より単純なバックプロパゲーションを行うことにより、非常に多くの降雨-流量関係を学習でき、特に流域の複雑な流出過程をブラックボックスとして扱える長所を有する。また、一般的なニューラルネットワークの応用例では、予測前の学習のみを行い本論文でいう予測時の学習はなされない。図-4に示したように予測時にも学習を重ねることにより、ネットワークは過去のパターンの他に最新の降雨と流量の関係を取り入れ、それを予測計算に活かすことができる。

参考文献

- 1) 本多中二、他、ファジィ工学入門、海文堂、pp. 15-77, 1991.
- 2) 今井里美、藤間聰、ファジィ・ニューラルネットワークを用いた洪水流量逐次予測、土木学会第48回年次学術講演会講演概要集第2部、pp. 222-223, 1993.
- 3) 同、ファジィ・ニューラルネットワークを用いた道南中小河川の洪水解析、土木学会北海道支部論文集第49号、pp. 455-460, 1993.
- 4) 中野馨、他、入門と実習ニューラルコンピュータ、技術評論社、pp. 38-84, pp. 231-245, 1989.

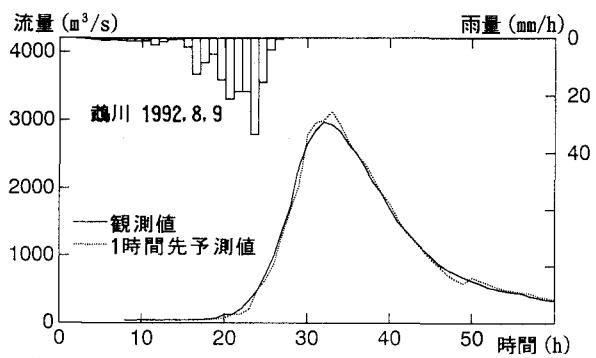


図-8 観測値・予測値ハイドログラフ(鶴川)

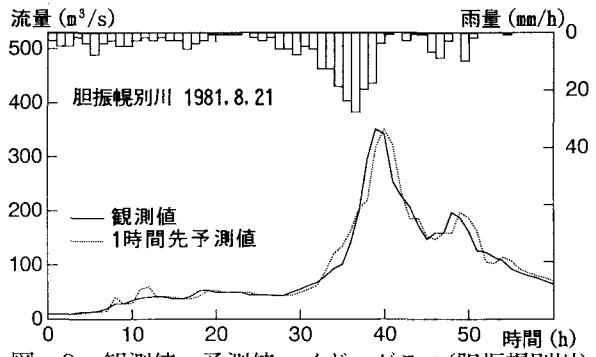


図-9 観測値・予測値ハイドログラフ(胆振幌別川)

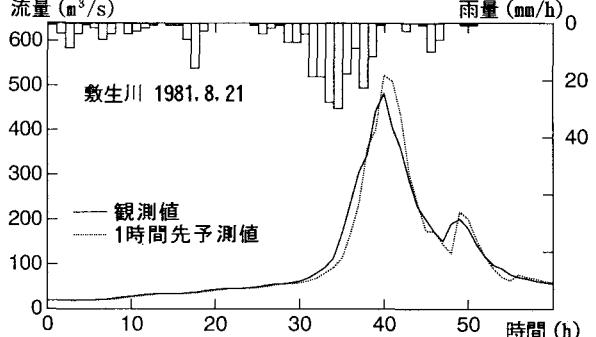


図-10 観測値・予測値ハイドログラフ(敷生川)

- 381 -