

ファジィ・ニューラルネットワークによる洪水流出予測

Flood Runoff Forecasting Using A Fuzzified Neural Network

今井 里美*, 藤間 聡**

By Satomi IMAI and Satoshi TOHMA

The hydrologic measurements are always affected by various types of errors. Fuzzy number may be used to express the uncertainties in rainfall and discharge data. In this paper, Fuzzified neural network model is capable of learning the complex runoff process ongoing in a basin, and presented for the calculation of the sequences of river discharge using the inaccurate data. This model is a kind of black box deterministic models that consist of a highly interconnected network between fuzzified input and output, and no physical meanings. This model is expected to yield more accurate results than other deterministic models with less available hydrologic data.

Keywords: Fuzzy Number, Membership Function,

Fuzzified Neural Network, Flood Runoff Forecasting

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は誤差を含む測定値からパラメータを迅速に求めるのは困難である。本研究では、観測降雨量、流量データをあいまいな値すなわちファジィ数とみなし、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. 観測降雨量および流量データのファジィ数化

降雨は流域内に一様に分布するものではなく、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することは難しい。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む。このように、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

* 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)

** 正会員 工博 室蘭工業大学助教授 工学部建設システム工学科
(〒050 室蘭市水元町27-1)

とし、真値である可能性を持つ範囲を L とする三角型関数を使用する。¹⁾ 流出予測には以下のメンバーシップ関数を用いる。

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

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

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

ここで、 Mr_t 、 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、 x_r 、 x_Q 、 $x_{\Delta Q}$ はそれぞれ雨量強度、流量、流量変化量を、 L_r 、 L_Q 、 $L_{\Delta Q}$ は可能性を持つ範囲を表す。このように、データをファジィ数とすると、各データは $[-L/2, +L/2]$ の範囲に拡大される。このファジィ数は、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。後述の流出予測計算では、 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、250、天塩川で 10、2000、200、²⁾胆振根別川で 15、150、50 としている。³⁾




図-1 メンバーシップ関数

3. ファジィ・ニューラルネットワークによる流出予測

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の信号を並列に伝達し合って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、信号の伝播に伴い変化する。この作用により、神経系は与えられた情報における信号の入力-出力パターンを満たすように「学習」される。⁴⁾ 従って、このシステムを応用し、入出力パターンとして降雨量、流量を与えるならば、通常の流出解析のように複雑な数学的解法を用いずに流出予測が行える。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、流量データの入出力、信号伝達と「学習」、流出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 、 ΔQ_t および6時間の降雨量情報 r_t 、 r_{t-1} 、 r_{t-2} 、 r_{t-3} 、 r_{t-4} 、 r_{t-5} を与えると、出力層に流量変化量 ΔQ_{t+1} を出力し、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。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)のニューロンを1組とし、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する。図-2の右に示すように、 Q_t を表す組のニューロンはそれぞれ流量 a 、 b 、 $\dots$ 、 g (m³/s)を表すと定められている。 $Q_t = c$ と観測された場合、この組のニューロンには c のニューロンで1となる MQ_t が信号 S_i として与えられる。

入力信号 S_i は、(4)および(5)式に従って出力層のニューロンまで伝達される。ニューロン i 、 j 間の荷重を V_{ij} とすると、 j が i から受ける入力 $S_i V_{ij}$ である。 j は連結されている入力層の全てのニューロンから信号を受けるため、 j が受ける入力




図-2 ファジィ・ニューラルネットワーク

の合計は $\sum_j S_i V_{ij}$ となる。この値とニューロン j 自身の閾値 h_j に応じて j は信号 A_j を発生する。

$$A_j = \frac{1}{1 + \exp\{-\sum_i S_i V_{ij} - h_j\} / \mu} \tag{4}$$

同様に、出力層のニューロンは中間層の全てのニューロンから信号を受けるから、 k の発生する信号 R_k は、

$$R_k = \frac{1}{1 + \exp\{-\sum_j A_j W_{jk} - \theta_k\} / \mu} \tag{5}$$

となる。ただし、 W_{jk} は $j-k$ 間の荷重、 θ_k は k の閾値、 μ はニューロンの信号変換感度を表す係数 ($\mu=1$) 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つに分割することにより、入力パターンを広意に解釈するようにした。⁵⁾

ネットワークの学習は、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、すべてのパターン p の入力信号 $\{S_i\}_p$ に対して、それぞれネットワークが出力すべき理想的な信号 $\{T_k\}_p$ と実際の出力信号 $\{R_k\}_p$ との誤差二乗和 E_p を減少させるように荷重と閾値の修正を繰り返し、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。

$$E_p = \sum_k (T_k - R_k)^2 \tag{6}$$

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下式のように定められる。

$$W_{jk} = W_{jk} + \alpha (T_k - R_k) R_k (1 - R_k) A_j / \mu \tag{7}$$

ここで、 α は修正量を調整する係数であり、 V_{ij} 、 θ_k 、 h_j の修正も同様に求められる。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の修正計算を繰り返すことにより、ネットワークは学習される。この学習データには過去の洪水事例を使用し、 T_k には $M \Delta Q_{t+1}$ を与える。このように、荷重、閾値は学習を行うことにより自動的に同定されるので、これらの初期値は任意数を与えてよい。本研究では、計算機で発生させた危険率5%の χ^2 検定をみたす10組10000個の乱数の中で、 χ^2 値が最小となる組の乱数を $[-1, +1]$ の範囲に変換して荷重および閾値の初期値として使用する。⁶⁾

ここで、中間層のニューロン数について考える。表-1に中間層のニューロン数と平均二乗誤差の関係を示す。初期乱数、修正量調節係数、学習データ、メンバーシップ関数等によって違いはあるが、全体的な傾向として中間層のニューロンが少なすぎると学習は進まず、一方、25個以上のニューロンを与えても誤差は減少しない。以下の計算例は、中間層ニューロン数を25個（流量情報用10個、降雨情報用15個）とする。

流出予測計算は、図-3の手順で行われる。始めに、時刻 t における入力データをファジィ数化して学習済みのネットワークに与え、 R_k を計算する。出力層の中で最大の信号を発生するニューロンが表す流量変化量を予測変化量 $\Delta Q'$ とし、流量予測値 $\Delta Q'_{t+1}$ は(8)式で求める。

$$\Delta Q'_{t+1} = Q_t + \Delta Q' \tag{8}$$

また、流出予測計算を行う段階において、各時刻毎に観測データによる学習を行うことによりネットワークを逐次改良させ、予測精度の向上をめざす。時刻の更新に伴い、この予測計算と学習を進めることにより洪水流量の逐次予測が行われる。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。

表-1 中間層のニューロン数と誤差

中間層のニューロン数	$\sqrt{\sum E_p / nm}$
5個	0.0453
15	0.0276
25	0.0258
40	0.0260
70	0.0258

石狩川上流部1975年8月22日
出力層のニューロン数; $n=15$
入出力パターン数; $m=93$
学習繰り返し100回目




図-3 流出予測計算の流れ

4. 洪水流出予測結果と考察

上述のシステムにより、北海道中央部に位置する石狩川上流部、北部に位置する天塩川および南西部の胆

振幌別川について洪水流出予測を行う。

石狩川上流部の流域面積は3087km²、流域内に16カ所の降雨観測所を有する。天塩川の流域面積は3698km²、降雨観測箇所は15地点で、両河川ともテューセン法により流域平均降雨量を求めた。図-4、図-5はそれぞれ石狩川上流部と天塩川の1981年8月3日の洪水流出予測を示す。この流出予測は、1975年8月22日の洪水データで100回の繰り返し学習を行ったネットワークから開始されている。1時間先の流量予測値は、観測値と一致することが認められる。3時間先の流出予測では、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、かつピーク流量を過大に予測する傾向がある。これは、3時間先に起きる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-6に、胆振幌別川の1981年8月21日の流出予測を示す。この河川は流域面積105km²の中小流域であり、降雨は流域中央部で観測されている。その地形および地質的特性から、洪水到達時間が短いため、1時間先の予測のみ行う。石狩川、天塩川と同様、予測値は観測値に精度良く一致する。過去のデータによる繰り返し学習は、1968年から1981年までの6つの洪水事例について行った。

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、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。本モデルは、一般的洪水解析法のようなパラメータ同定作業を必要とせず、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が、図-3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, 藤間聡, 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) 今井里美, 藤間聡, ファジィ・ニューロ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) 菊地豊彦, 入門ニューロコンピュータ, オーム社, pp.17-95, 1991.
- 5) 中野馨, 他, 入門と実習ニューロコンピュータ, 技術評論社, pp.38-84, pp.231-245, 1989.
- 6) Dayhoff, J.E., Neural Network Architectures An Introduction, Van Nostrand Reinhold, New York, pp.58-95, 1990.




図-4 観測値・予測値ハイドログラフ(石狩川上流部)




図-5 観測値・予測値ハイドログラフ(天塩川)




図-6 観測値・予測値ハイドログラフ(胆振幌別川)