

II-17 ファジィ・ニューラルネットワークによる洪水流出解析

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

現在、洪水流出解析に多用されている方法は、流域特性を表すために降雨量と流量等の長期観測データを用いてパラメータを同定し、支配方程式を差分に変形して流出量を求めている。しかし、流出量の予測は非線形問題であるため、リードタイムが長時間の場合は予測精度が低下することが報告されている¹⁾。また、予測に用いられる観測降雨量の誤差は、各観測地点において時々刻々と変化する。さらに、流量は水位の観測値から水位-流量曲線を用いて流量に変換しているため、高水位時には大きな誤差が含まれると考えられる。このことから、従来の方法による予測流出量は誤差を含んだ状態で出力されるため、正確な洪水流出予測を行うことは困難であると思われる。

著者ら²⁾は観測誤差を考慮した方法としてファジィ・ニューラルネットワークで予測を行うことを提案した。この手法では観測データをファジィ数として取り扱い、降雨-流出過程をニューラルネットワークによりモデル化し、洪水流量の逐次予測を行った。入力に用いる降雨量は観測所が水系流域内に多く設置されているため、ティーセン法及び算術平均を行って流域平均雨量に変換している。

本研究は、流域内に設置されている数カ所の降雨観測所の降雨データを入力として使用し、それに基づいたニューラルネットワークのモデルを構築して、1時間先と3時間先の洪水流出量を逐次予測した結果を報告するものである。

2. 解析対象河川の概要

解析対象河川は、図-1に示す北海道内の代表的な一級河川である道中部に位置する石狩川上流部、道北部の天塩川上流部及び道東部の十勝川の計3水系について解析を行った。各水系の流域面積は石狩川上流部で3087 km²、天塩川上流部で3698 km²、十勝川で8087 km²である。本解析に使用する降雨量については流量観測所より上流部に位置している降雨観測所のデータを用いた。各水系の流量観測所の位置については、図-1に示すように石狩川上流部は伊納、天塩川上流部は蒼平、十勝川は茂岩とし、降雨観測所の位置については、石狩川上流部は中越、中愛別、旭川、瑞穂、白金の5カ所、天塩川上流部は士別東、下川サンル、小車岳、音威子府、岩尾内ダムの5カ所、十勝川は帯広、士幌、上札内、本別の4カ所とした。



図-1 解析対象河川と水文観測位置

3. 観測降雨量および流出量データのファジィ数化

降雨量は観測値点の近くに障害物がある場合、雨がそれらに遮られたり、また風の影響により観測誤差が生じる。一方、流量は、水位-流量曲線を用いて流量に変換しているため、洪水時には大きな誤差が予想される。これらの誤差を確率的に考慮する場合、正確な特性値がわからないため、統計的に取り扱うの

Flood Runoff Forecasting Using A Fuzzified Neural Network.

By Tadashi OSAKA and Satoshi TOHMA

が困難である。本研究では、このような誤差を含む観測値を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、観測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-2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もつ範囲を L とする三角形関数を使用する⁹⁾。観測データをその最大値で除し、 $[0, 1]$ に変換する。また、降雨量と流量の単位が異なるため、流量に関しては流出高さに単位の変換を行った。

流出予測には以下のメンバーシップ関数を使用する。

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

$$Mq_t = 1 - |q_t - x_q| / (L_q / 2) \quad Mq_t \geq 0 \quad (2)$$

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

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 、観測流出高さ q_t のメンバーシップ関数、 $M\Delta q_t$ は $t-1$ から t までの観測流出高さの変化量 $\Delta q_t = q_t - q_{t-1}$ のメンバーシップ関数である。 $x_r, x_q, x_{\Delta q}$ はそれぞれ雨量強度、流出高さ、流出高さの変化量を $L_r, L_q, L_{\Delta q}$ 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 $[-L/2, +L/2]$ の範囲に存在することになる。




図-2 三角形関数のファジィ数

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 入・出力値及びネットワーク構造

降雨と流出量の関係には多くの要因が含まれており、モデル化は一般に複雑かつ困難である。近年、報告されているニューラルネットワークを用いた洪水予測は、過去の洪水流出データを入力-出力パターンとして学習することにより、降雨-流出過程を表現することが可能となっている。更にネットワーク内の入力信号は $[1, 0]$ で処理されるため、上記のファジィ理論により誤差を考慮した降雨・流出量データを使用することが可能となる。本研究は図-3に示す3層の階層型ネットワークに降雨量、流出量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。降雨と流出の性質は異なることから中間層については2つに分け、入力層-中間層間の結合は不完全結合とした。ここで、ネットワークへの入・出力について説明する。入力層は現時間 t を基準にして1時間前までの流出量 q_t, q_{t-1} と2時間前までの降雨量 r_t, r_{t-1}, r_{t-2} とし、さらに降雨量については流域平均雨量を用いず観測点の値を使用する。出力層は1時間先および3時間先の流量の変化量 $\Delta q_{t+1}, \Delta q_{t+3}$ とする。降雨量、流出量等の観測データはファジィ数であるため、これを入出力するのにニューロンを複数個必要とする。ここでは、入力層での入力個数を15個、出力層での出力個数を29個とした。

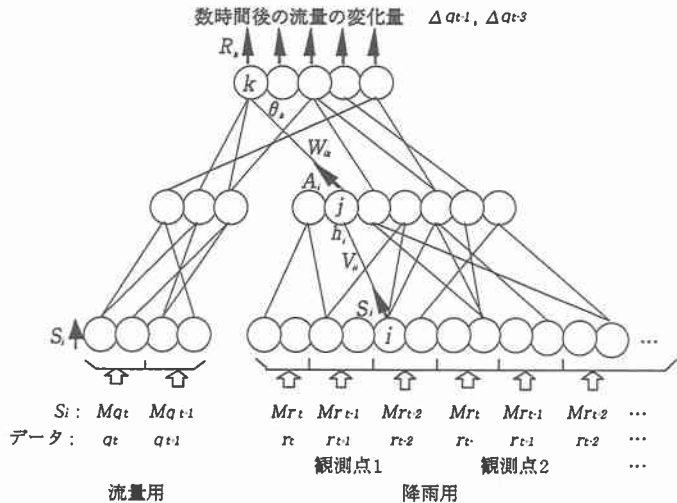


図-3 ファジィ・ニューラルネットワーク構造図

ここで、ネットワークへの入・出力について説明する。入力層は現時間 t を基準にして1時間前までの流出量 q_t, q_{t-1} と2時間前までの降雨量 r_t, r_{t-1}, r_{t-2} とし、さらに降雨量については流域平均雨量を用いず観測点の値を使用する。出力層は1時間先および3時間先の流量の変化量 $\Delta q_{t+1}, \Delta q_{t+3}$ とする。降雨量、流出量等の観測データはファジィ数であるため、これを入出力するのにニューロンを複数個必要とする。ここでは、入力層での入力個数を15個、出力層での出力個数を29個とした。

1つの観測データは入力層では15個のニューロンを用いて、メンバーシップ関数で表現した信号を入力する。

4.2 ニューラルネットワークの Forward と Backward

次に、信号の伝達について説明する。入力信号は中間層のニューロン j を介して出力層のニューロン k に伝達される。途中、中間層ニューロン j が入力層の1つのニューロン i から受ける入力 $S_i V_{ij}$ である。中間層のニューロンは結合されている側の入力の全てのニューロンから信号を受けるため、 j が受ける入力信号の合計は $\sum S_i V_{ij}$ となる。更に、 j 自身も閾値 h_j により出力値を決定する。この出力値 A_j の計算にはシグモイド関数を用いて(4)式で表される。

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

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 jk 間の結合荷重を 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、ニューロン k の発生する信号は R_k となる。

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

ここで、 W_{jk} はニューロン jk 間の結合荷重、 θ_k は k の閾値、 μ は温度であり、この値でシグモイド関数の形状を決定する。本研究では $\mu = 1$ としている。

ネットワークの学習にはバックプロパゲーション法を用いた。この方法はすべてのパターン p の入力信号 S に対して出力層で望むべき値が教師信号 T として与えられる教師付き学習法である。結合荷重があらかじめ与えられていない未学習の初期ネットワークは無意味な値を出力するため、出力 R と教師 T との誤差二乗和 E_p に基づき結合荷重を徐々に変更し、誤差が消えるまで繰り返す。そして、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。また、初期ネットワークには $[-1, +1]$ の範囲の一樣乱数を与えた。

$$E = \sum_p E_p = \sum_p \sum_k (T_k - R_k)^2 \quad (6)$$

結合荷重 W_{jk} の補正は、 $\partial E_k / \partial W_{jk}$ を計算することにより下式のように定められる：

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

ここで、 α は学習率と呼ばれる修正量を調整する係数である。その他の V_{ij} 、 θ_k 、 h_j についての修正も同様に求められる。しかし、上記の方法で学習を行うと学習回数を多く必要とするため、回数の短縮に効果があるモーメント法を用いて学習を行った。それを(8)式に示す。

$$\Delta W(t)_{jk} = \alpha (T_k - R_k) R_k (1 - R_k) A_j / \mu + m \cdot \Delta W(t-1)_{jk} \quad (8)$$

ここで、 $\Delta W_{jk}(t)$ は今回の修正量、 $\Delta W_{jk}(t-1)$ は前回の修正量、 m はモーメント係数と呼ばれ前回の修正量を調整するものである。

4.3 洪水流出予測

流出予測計算は、時刻 t における入力データをファジィ数化し、上記の方法で学習したネットワークに与え、 R_k を計算する。その中で出力信号が最大を示すものを予測流出変化量 $\Delta Q'_{t+1}$ と決定し、1時間先の流出予測値 Q'_{t+1} は(5)式で求める。

$$Q'_{t+1} = Q_t + \Delta Q'_{t+1} \quad (9)$$

また、洪水予測は学習に使用した洪水事例の降雨-流出パターンを基本にして行われるため、もし、学習パターンに該当しないパターンで洪水が進行すると流出予測が難しくなる。そこで、予測時にも時間の更新とともに観測データを使用して適宜ネットワークの荷重と閾値を修正することで、学習時の洪水では得られなかった洪水流出パターンに対応する逐次学習を含む洪水流出予測を行った。この学習方法は図-

2において t 時に得られた観測流出量の変化量 Δq_t を教師信号、 $t-1$ 時までの観測流出量 q_{t-1} 、 q_{t-2} 、観測降雨量 r_{t-1} 、 r_{t-2} 、 r_{t-3} を入力信号として与る。

5. 流出予測結果及び考察

5.1 解析諸元

今回解析に使用した洪水事例は2つと少ないため、双方を比較し大きな洪水の事例で学習にさせ、それよりも小さい洪水の事例を予測に使用した。学習に使用した事例は3水系とも図-4に示す1981年8月3日の洪水である。予測については石狩川上流部と天塩川上流部が1975年8月22日の洪水を使用し、十勝川は1979年10月19日の洪水を使用した。ファジィ・ニューラルネットワークの構造は入力層のニューロンが255個、中間層のニューロンは流量に対し10個、降雨に対し45個及び出力層のニューロンは29個である。但し、十勝川については降雨量観測地点が4点であるため、入力層のニューロンが210個である。学習パターンでの学習回数は100回行い、その際の学習率は0.6、モーメント係数は0.5とした。メンバーシップ関数については L_r 、 L_q 、 $L_{\Delta q}$ をそれぞれ石狩川上流部で12、3.5、0.4、天塩川上流部で10、2、0.3、十勝川で12、1.2、0.2とした。

5.2 解析結果

図-5(a)、(b)は本法での石狩川上流部、図-6(a)、(b)は天塩川上流部および図-7(a)、(b)は十勝川の予測結果を示す。各水系とも1時間先予測は観測値と一致することが認められる。3時間先予測では石狩川上流部は急増部からピーク時において遅れ予測値の出現時間が観測値に比べ遅れている。天塩川上流部では観測値と良好な一致を見ている。十勝川についてはピーク時にかけて過大に予測する傾向があるが、それ以降は観測値の特性を良好に再現している。3水系とも多少の時間遅れはあるものの予測時での流出の特徴をよく表している。






図-4 学習用洪水事例 (1981.8.3)




図-5 (a) 石狩川上流部の1時間先予測結果




図-5 (b) 石狩川上流部の3時間先予測結果

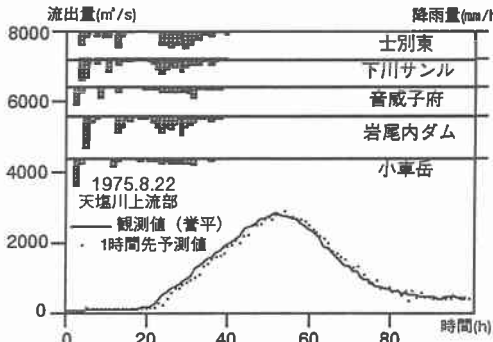


図-6 (a) 天塩川上流部の1時間先予測結果

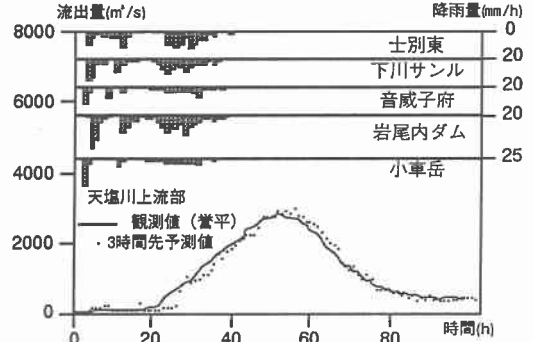


図-6 (b) 天塩川上流部の3時間先予測結果




図-7 (a) 十勝川の1時間先予測結果




図-7 (b) 十勝川の3時間先予測結果




図-8 (a) 石狩川上流部の1時間先予測結果




図-8 (b) 石狩川上流部の3時間先予測結果




図-9 (a) 天塩川上流部の1時間先予測結果




図-9 (b) 天塩川上流部の3時間先予測結果




図-10 (a) 十勝川の1時間先予測結果




図-10 (b) 十勝川の3時間先予測結果

図-8から図-10 (a), (b) は入力としてティーセン法で求めた流域平均雨量を使用した3水系の予測結果を示す。1時間先予測では前述の方法と同様に観測値とよく一致しているのが認められる。3時間予測では石狩川上流部はピーク時に関しては多少の時間遅れがあるが、全体的に見て流出特性を良好に再現していることが認められる。天塩川上流部については上昇期で予測値に不連続な個所が存在し、かつ過小に予測している。十勝川については増加時からピーク時にかけて3時間の時間遅れが出現している。3水系とも前法に比べ予測値のばらつきが顕著である。2つの方法において学習パターンから検討してみると、石狩川上流部の場合、図-4の学習時での流出は比較的なだらかな傾向を示しているのに対し、予測時では観測値は急激にピークに達している。従って、予測値は学習時でのなだらかなパターンに従って出力しようとしているため、急激な立ち上がりにはついていけず、しかも3時間先の流出量を予測してもその値に対して逐次学習がなされるのは3時間後にデータが入力された時であり、学習時のパターンに強く影響される。十勝川の場合も同様な傾向を示す。天塩川上流部の場合は学習時と予測時のパターンが類似しているため、予測値が観測値に対して時間的に遅れることなく予測している。

6. 結 び

ファジィ・ニューラルネットワークを用いた方法で洪水流出量の予測を行う場合、降雨量に関しては流量観測所より上流部に設置されている数ヶ所の降雨観測所のデータを使用することにより、観測値の特徴をつかんだ予測値が得られた。また、流域平均雨量を用いた方法は予測値にばらつきがあるが、ネットワークの構造が小さいため、計算時間が短時間で済む利点がある。今回は学習に使用した事例が1つであったにもかかわらず、精度良い予測ができるため、多数の洪水事例を学習することにより、さらに高い精度での予測が期待できると思われる。

参考文献

- 1) 藤田睦博ほか：ファジィ・ニューラルネットワークを用いたリードタイムの長い流出予測，土木学会北海道支部論文集第50号，pp.382-387，1994.
- 2) 今井里美，藤間聡：ファジィ・ニューラルネットワークによる洪水流出予測，水工学論文集 第38巻 pp.805-808，1994.
- 3) 本多中二ほか：ファジィ工学入門，海文堂，pp.15-77，1991.
- 4) 中野馨ほか：入門と実習ニューロコンピュータ，技術評論社，pp.15-84，1989.