流出予測におけるファジィ推論手法とニューラルネット手法の比較

A Comparison of Fuzzy Inference Method and Neural
Network Method for Runoff Prediction

朱木蘭* 藤田睦博**

By Mu-Lan ZHU and Mutuhiro FUJITA

In this paper, two different approaches to forecast runoff using the fuzzy inference method and neural network (NNs) are described. The actual applicability of this two methods is assessed and compared through making 1-hr, 2-hr, 3-hr lead time forecast of runoff in BUTTERNUT CREEK, NY. The good results indicate that both of these two approaches are very effective for runoff prediction.

Keywords: runoff prediction, fuzzy inference, neural networks, back-propagation, sigmoid function

1 はじめに

近年、ファジィ理論あるいはニューラルネットが工学に限らず種々の分野で利用されている。流出予測の分野もその例外ではない。両手法は、複雑で入出力間の因果関係を明確にできないようなシステムを記述することのできる点に共通点を持っているが、その理論構成は全く異なっている。ファジィ理論はメンバーシップ関数の概念の導入によって、システムに内在するあいまいな量を有効に取り扱うことができる。これに対して、ニューラルネットは神経の情報伝達を模擬したもので、教師信号を学習することにより、非常に複雑な現象でも入出力間の特性の記述が可能である。本研究は、両手法による流出予測法を述べるとともに、実流域におけるリードタイム1、2、3時間の流出量予測結果より両手法の適合性、予測精度について比較したものである。また、著者らは、通常どこでも利用できるパソコンを用いた流出量の予測を意図しており、予測計算のための時間、計算機容量などについても検討した。

* 学正員 北海道大学大学院 (〒060 札幌市北区北13条西8丁目)

** 正会員 工博 北海道大学教授 工学部土木工学科 (〒060 札幌市北区北13条西8丁目)

2 基礎理論

(1) ファジィ推論法¹⁾

降雨量を R 、流出変化量を ΔQ とすると流出系の一般的なシステム方程式は、式(1)で表される。実際の解析では、流域特性や予測のリードタイムを考慮して適宜 m, n を定めることになる。本研究で解析の対象とした米国NEWYORK州のBUTTERNUT CREEKにおける観測資料では、式(2)を用いている。

$$\Delta Q(t) = f \{R(t-1) \dots R(t-n), \Delta Q(t-1) \dots \Delta Q(t-m)\} \quad (1)$$

$$\Delta Q(t) = f \{R(t-3), \Delta Q(t-1), \Delta Q(t-2)\} \quad (2)$$

式(2)の降雨量、流出変化量のメンバーシップ関数をそれぞれ M_R 、 $M_{\Delta Q}$ とすると、式(2)を以下の様な条件付き命題 P_t (Proposition at time t) に書き直すことができる。

$$\begin{aligned} &\text{if } R(t-3) \text{ is } M_R(t-3) \text{ and } \Delta Q(t-1) \text{ is } M_{\Delta Q}(t-1) \text{ and } \Delta Q(t-2) \text{ is } M_{\Delta Q}(t-2) \\ &\text{then } \Delta Q \text{ is } M_{\Delta Q}(t). \rightarrow P_t \end{aligned} \quad (3)$$

本研究に採用した M_R 、 $M_{\Delta Q}$ は図-1に示されるような3角型の関数で、パラメーター DR 、 DQ によって降雨、流出変化量のあいまいさを表している。

ファジィ推論による流出予測手法を簡単に説明する。まず、命題 P_t によって示される t 時刻の「あいまい関係」を式(4)で求める。次に、現時刻 t までに得られる各時刻の「あいまい関係」 $P_1, P_2, \dots, P_t$ を式(5)で合成して、全体の「あいまい関係」 Π_t を求める。

図-1

降雨量と流出変化量のメンバーシップ関数

また、過去の水文資料がある場合、前回の洪水

水の終了時刻に得られた Π_t を Π_{t-1} と表し、これまでの出水経験として、式(6)に示すように予測計算の際の初期値とすることができる。最後に、合成した出水経験 Π'_t を用いて式(7)により1時刻だけ将来の $\hat{M}_{\Delta Q}(t+1)$ のメンバーシップ関数を推論する。リードタイムが2時間の場合には、式(7)で求めた $\hat{M}_{\Delta Q}(t+1)$ を用いると、式(8)のようになる。同様に、 $\hat{M}_{\Delta Q}(t+2)$ を用いて式(9)に示すようにリードタイムが3時間の $\hat{M}_{\Delta Q}(t+3)$ を求めことができる。

$$P_t = M_R(t-3) \wedge M_{\Delta Q}(t-1) \wedge M_{\Delta Q}(t-2) \wedge M_{\Delta Q}(t) \quad (4)$$

$$\Pi_t = P_1 \vee P_2 \vee \dots \vee P_t \quad (5)$$

$$\Pi'_t = \Pi_{t-1} \vee P_1 \vee P_2 \vee \dots \vee P_t \quad (6)$$

$$\hat{M}_{\Delta Q}(t+1) = \Pi'_t \odot M_R(t-2) \odot M_{\Delta Q}(t-1) \odot M_{\Delta Q}(t) \quad (7)$$

$$\hat{M}_{\Delta Q}(t+2) = \Pi'_t \odot M_R(t-1) \odot M_{\Delta Q}(t) \odot \hat{M}_{\Delta Q}(t+1) \quad (8)$$

$$\hat{M}_{\Delta Q}(t+3) = \Pi'_t \odot M_R(t) \odot \hat{M}_{\Delta Q}(t+1) \odot \hat{M}_{\Delta Q}(t+2) \quad (9)$$

ただし、 $\wedge, \vee, \odot$ はそれぞれmin演算、max演算、ファジィ合成max-min演算を意味している。流出量の具体的な予測値を求めるには、メンバーシップ関数 $\hat{M}_{\Delta Q}(t+1)$ 、 $\hat{M}_{\Delta Q}(t+2)$ 、 $\hat{M}_{\Delta Q}(t+3)$ の重心の座標値を求め、これらの値を $\hat{Q}(t+1)$ 、 $\hat{Q}(t+2)$ 、 $\hat{Q}(t+3)$ とおくと、 $(t+1)$ 、 $(t+2)$ 、 $(t+3)$ 時刻の予測流出量は式(10)、(11)、(12)で与えられる。

$$\hat{Q}(t+1) = Q(t) + \hat{\Delta Q}(t+1) \quad (10)$$

$$\hat{Q}(t+2) = \hat{Q}(t+1) + \hat{\Delta Q}(t+2) \quad (11)$$

$$\hat{Q}(t+3) = \hat{Q}(t+2) + \hat{\Delta Q}(t+3) \quad (12)$$

(2) ニューラルネット²⁾

ニューラルネットは既知の入力と出力値（教師信号）を学習することにより入出力間の特性を記述し、新しい入力に対する出力を推定する一種のブラックボックス的な手法である。学習アルゴリズムは、Rumelhart³⁾らのBack Propagationアルゴリズム（BPアルゴリズム）を用いた。

図-2は1個の出力ユニットを持つ完全結合な3層構造のニューラルネットを示している。入力層と中間層のユニット数はそれぞれ m 、 n である。入力ユニットへの P 番目の入力ベクトル $X_P = (X_{P1}, X_{P2}, \dots, X_{Pm})$ に対して、各層の各ユニットからの出力値は次のように計算される。

$$\text{入力層: } y_{Pi} = X_{Pi} \quad i=1, 2, \dots, m \quad (13)$$

$$\text{中間層: } y_{1Pj} = f(S_{1Pj}) \quad j=1, 2, \dots, n \quad (14)$$

$$\text{ただし: } S_{1Pj} = \sum_{i=1}^m y_{Pi} w_{1ji} + \theta_{1j} \quad (15)$$

$$\text{出力層: } y_{2P} = f(S_{2P}) \quad S_{2P} = \sum_{j=1}^n y_{1Pj} w_{2j} + \theta_2 \quad (16)$$

図-2

関数 f はシグモイド関数で、本計算で $f(S) = 2 / (1 + \exp(-S)) - 1$ と定義した。 w_{1ji} は中間層のユニット j と入力層のユニット i 間の結合強度であり、 w_{2j} は出力ユニットと中間層のユニット j の結合強度である。または θ_{1j} 、 θ_2 は中間層のユニット j と出力ユニットにおけるそれぞれの閾値である。

ここで、ベクトル X_P が入力された時、ニューラルネットからの望ましい出力値（教師信号）を t_P とすると、学習は次の評価関数 E_P が最小になるように行われる。

$$E_P = (t_P - y_{2P})^2 / 2 \quad (17)$$

結合強度 w_{2j} 、 w_{1ji} 及び閾値 θ_{1j} 、 θ_2 を次のように修正していく。

$$w_{2j}(\text{new}) = w_{2j}(\text{old}) + \eta (-\partial E_P / \partial w_{2j}) = w_{2j}(\text{old}) + \eta \delta_P y_{2P} \quad (18)$$

$$\delta_P = (t_P - y_{2P}) * f'(S_{2P}) \quad (19)$$

$$w_{1ji}(\text{new}) = w_{1ji}(\text{old}) + \eta (-\partial E_P / \partial w_{1ji}) = w_{1ji}(\text{old}) + \eta \delta_{Pj} y_{1Pj} \quad (20)$$

$$\delta_{Pj} = \delta_P * w_{2j} * f'(S_{1Pj}) \quad (21)$$

$$\theta_2(\text{new}) = \theta_2(\text{old}) + \eta (-\partial E_P / \partial \theta_2) = \theta_2(\text{old}) + \eta \delta_P \quad (22)$$

$$\theta_{1j}(\text{new}) = \theta_{1j}(\text{old}) + \eta (-\partial E_P / \partial \theta_{1j}) = \theta_{1j}(\text{old}) + \eta \delta_{Pj} \quad (23)$$

ただし η は学習率である。上述したBPアルゴリズムより、ニューラルネットからの出力値が望ましい教師信号に近づくように学習が行われる。十分に学習が行った後のニューラルネットは、層間結合強度と各ユニットにおける閾値によつて入出力間の特性が記述される。上述したニューラルネットを流出予測に利用しようと、以下に示すような2通りの手法が考えられる。

手法（1）：過去の出水資料のほかに、現在の出水に関して時々刻々入手できる $R(t)$ 、 $Q(t)$ の情報をも利用してニューラルネットの結合強度と閾値を新しい情報が入手される毎に求める。手法（1）は降雨量、流出量の情報の利用方法からみると、前節のファジィ推論手法と同一である。

手法（2）：過去の出水資料を教師信号とし、得られたニューラルネットの結合強度と閾値を現在の出水予測に直接利用する。すなわち、現在の出水に関して t 時刻までに既知である $R(t)$ 、 $Q(t)$ の情報が、ニューラルネットの結合強度と閾値の算定に直接利用していない。

3 実流域における適用

(1) ファジィ推論手法による流出予測

本研究では、NBUTTERNUT CREEK(ニューヨーク州、流域面積154.6km²)を計算の対象とした。この流域では、5例の出水資料があり、初めの2例の出水資料(1975.10.17日、1976.10.7日の洪水)を用いて Π_i とした。図-1でDR=2(mm/hr)、DQ=0.08(mm/hr)の計算条件の下で、3番目の1976.10.20日の出水をリードタイム1、2、3時間とした予測を行った。次に、3番目の出水の終了時における Π_i を Π_{i+1} として4番目の出水予測を行った。以下、順次トレーニングデータを増やしながらか予測計算を実施した。ここではスペースの関係で3番目の出水を予測した結果のみを図-3、4、5に示す。■印が予測値を示し、実測値(実線)と時刻を描えてプロットしている。他の出水に関しても予測精度は図-3とほぼ同じであった。

ここでの予測は過去の出水資料と現在の出水の現時刻までの降雨量、流出量の情報を利用したもので、降雨量の予測を行っていない。したがって、解析の対象としているBUTTERNUT CREEKの流域面積が150km²程度であることを考慮すると、予測のリードタイムは3時間が限度であり、リードタイムが4時間以上になると過大なピーク流量を予測することになる。

(2) ニューラルネットによる流出予測

計算手法(1): 前節と同一の資料を用いて予測計算をした。システム方程式はファジィ推論と同一である。まず、流出予測する時、前節に述べた手法(1)を用いた場合を示す。図-6は教師信号を用いた結合強度、閾値を同定する際のニューラルネットの構

図-6 教師信号を用いたニューラルネットの結合強度、閾値の同定

成を示している。この構成の特徴は各ユニット間が完全結合ではなく、降雨量Rと流量増分 ΔQ の2つのグループに分かれているのである。著者らの計算によると、完全結合にするよりこのような不完全結合方式が学習する際の収斂が良好であった。また、図-7は、それぞれリードタイムが1、2、3時間の場合の予測におけるニューラルネットの構成を示している。リードタイムが2、3時間のとき、ファジィ推論と同様に既に

予測されている $\Delta\hat{Q}(t+1)$, $\Delta\hat{Q}(t+2)$ を利用している。教師信号として初めの2例の出水と、3番目の出水に関し

図-7 ニューラルネットによる予測計算

て時々刻々入手できる時刻 t までの降雨量、流出量の資料を用いて、ニューラルネットの結合強度と閾値を求めた。すなわち、時々刻々得られる結合強度、閾値は、式(6)の Π_i に相当している。ニューラルネットでは、 $(t+1)$, $(t+2)$, $(t+3)$ 時刻の流量増分量が求められるので式(10)～(12)より流出量が得られる。図-8, 9, 10は、計算結果を示している。■印が予測値である。なお、ニューラルネットの結合強度、閾値を計算する際、式(18)～(23)に示すように繰り返し計算によりこれらの値を修正するが、計算時間の節約上繰り返し回数を100回で打ち切っている、ただし、学習する際、ニューラルネットの結合強度、閾値の初期値はランダムな値で与えられたのではなく、最初の2例の出水だけを教師信号として、1000回の繰り返し計算により得られた値で与えられたのである。

計算手法(2): 次に、予測する時、前節に述べた手法(2)を用いた場合を示す。最初の2例の出水だけを教師信号として10000回の繰り返し計算により同定したニューラルネットの結合強度、閾値を固定して3番目の出水を予測する。すなわち、3番目の出水に関して時々刻々入手できる時刻 t までの降雨量、流出量を使わずに、予測計算を行う。ニューラルネットの構成、予測方法は、図-6, 7と同様である。図-11, 12, 13は、計算結果を示している。

4 まとめ

図-8～10と図-11～13を比較すると、前者は現在の出水の情報までも取り込んでニューラルネットの結合強度、閾値を時々刻々計算しており、理論上は後者より高精度の予測値が得られるように思われる。しかし、図に示すように必ずしも前者は後者よりも良好な結果を与えていない。この原因の一つは、結合強度、閾値を計算する際の繰り返し回数によるものと思われる。ニューラルネットを用いた計算では、過去の出水資料のみを教師信号として十分な精度で結合強度、閾値を求める計算手法(2)が有利と思われる。また、計算手法(2)では、流出量を予測する際に既に計算されている結合強度、閾値をそのまま利用できるため、予測のための計算時間は極めて短く、かつ、計算機の容量も少ない。

一方、更にリードタイムの長い流出予測をしようとするれば降雨量の予測が不可欠になる。この場合、降雨量の予測値の与えられ方にもよるが、予測降雨量が弱、並、強、極強などの定性的な情報であればファジィ推論の応用が便利である。今後は、両者の特長を利用した流出予測手法の開発が考えられる。

参考文献

- 1 Fujita, M & Zhu, M.-L.; An Application of Fuzzy Theory to Runoff Prediction, Proc of the Sixth IAHR International Symposium on Stochastic Hydraulics, P727-P734, 1992.

2 Dayhoff, J. E.; Neural Network Architectures, Van Nostrand Reinhold, 1998.

3 Rumelhart, McClelland and the PDP Research Group; Parallel Distributed Processing, Vol.1, P318
-P362, MIT Press, Cambridge, 1986.