

II-35

A I に基づく流出予測

北海道大学大学院 学生員 朱 木 蘭
 北海道大学工学部 正 員 藤田睦博

1 はじめに

近年、ファジィ、ニューロなど最新の人工知能(AI)技術が様々な分野でその応用研究がなされている。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組織における情報処理をモデル化したもので、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。両理論の構成は全く異なっているが、明確な数学式により表しにくい複雑、あいまいな入出力関係をよく記述できることに共通点を持っている。一方、水文分野における降雨と流出の関係は多くのあいまいな影響要因が含まれており、非線形的で、非常に複雑である。本研究は、ファジィ推論手法とニューラルネット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実応用性について検討したものである。

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)のように考えられる。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。本研究は北海道にある青山ダムと当別川流域を解析対象として、式(2)のような簡略式を用いた。

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

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

式(2)の降雨量、流出変化量をファジィ化して、各自のメンバーシップ関数 M_R 、 $M_{\Delta Q}$ によって表せば、式(2)を以下のような条件付き命題(Proposition at time t)に書き直すことができる。

$$\text{if } R(t-3) \text{ is } M_{R(t-3)} \text{ and } \Delta Q(t-1) \text{ is } M_{\Delta Q(t-1)} \text{ then } \Delta Q \text{ is } M_{\Delta Q(t)}. \quad (3)$$

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の程度を表している。

ファジィ推論による流出予測手法を簡単に説明すると、まず、ファジィ理論のある”訳”規則によって上述したt時刻における条件付き命題を「ファジィ関係」 P_i に式(4)で変換する。次に、現時刻tまでに得られる各時刻の「ファジィ関係」 P_1, P_2, \dots, P_t を式(5)で合成して、全体の「ファジィ関係」 Π_t を求める。ここで、もし過去の水文資料がある場合、前回の洪水の終了時刻に得られた Π_t を Π_{t-1} と表し、これま

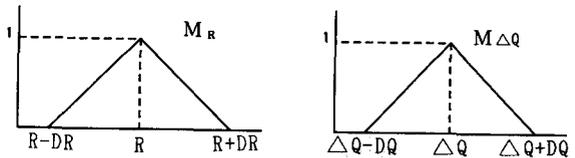


図-1

降雨量と流出変化量のメンバーシップ関数

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 $\Delta Q'(t+1)$ のメンバーシップ関数を推論する。更に、予測された $\Delta Q'(t+1)$ の値を用いて2時間先の $M_{\Delta Q'}(t+2)$ を式(7)で求めることが考えられ、予測値 $\Delta Q'(t+2)$ を用いて式(9)に示すように3時間先の $M_{\Delta Q'}(t+3)$ を求めることができる。

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

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

$$\Pi'_t = \Pi_t \vee P_1 \vee P_2 \vee \dots \vee P_t \quad (6)$$

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

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

$$M_{\Delta Q'}(t+3) = \Pi'_t \odot M_{R(t)} \odot M_{\Delta Q'}(t+2) \quad (9)$$

ただし、 \wedge 、 \vee 、 \odot はそれぞれmin演算、加算、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 $M_{\Delta Q'}(t+1)$ 、 $M_{\Delta Q'}(t+2)$ 、 $M_{\Delta Q'}(t+3)$ の重心の座標値を求め、これらの値を $\Delta Q'(t+1)$ 、 $\Delta Q'(t+2)$ 、 $\Delta Q'(t+3)$ 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。

$$Q'(t+1) = Q(t) + \Delta Q'(t+1) \quad (10)$$

$$Q'(t+2) = Q'(t+1) + \Delta Q'(t+2) \quad (11)$$

$$Q'(t+3) = Q'(t+2) + \Delta Q'(t+3) \quad (12)$$

著者らは、ファジィ推論手法による流出予測に関する論文を既に発表しているが¹⁾、本研究は Π_t 、 (Π'_t) の計算にあたって、式(5)或いは式(6)で本来のMAX演算の代わりに加算を採用した。

(2) ニューラルネット²⁾

ニューラルネットは神経の情報伝達を模擬したもので、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。このようなニューラルネットを流出予測に利用しようとするとき、まず、過去の出水経験を学習することによって、ネットを同定する必要がある。本研究ではRumelhartらのBack Propagation(BP)アルゴリズムに従って、学習を行ったのである。以下にこのBP学習アルゴリズムについて簡単に述べておく。

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。

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

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

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

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

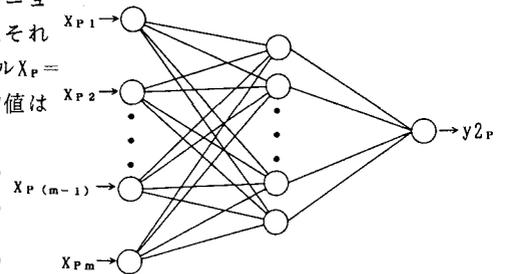


図-2

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_{1j} , 及び閾値 θ_{1j} , θ_{2j} を次のように修正していく。

$$W_{2j}(\text{new}) = W_{2j}(\text{old}) + \eta (-\partial E_p / \partial W_{2j}) = W_{2j}(\text{old}) + \eta \delta_p y_{2p} \quad (18)$$

$$\delta_p = (t_p - y_{2p}) * f'(S_{2p}) \quad (19)$$

$$W_{1ji}(\text{new}) = W_{1ji}(\text{old}) + \eta (-\partial E_p / \partial W_{1ji}) = W_{1ji}(\text{old}) + \eta \delta_{pj} y_{1pj} \quad (20)$$

$$\delta_{pj} = \delta_p * W_{2j} * f'(S_{1pj}) \quad (21)$$

$$\theta_{2j}(\text{new}) = \theta_{2j}(\text{old}) + \eta (-\partial E_p / \partial \theta_{2j}) = \theta_{2j}(\text{old}) + \eta \delta_p \quad (22)$$

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

ただし η は学習率である。

以上、図-2に示すような構造を持っているニューラルネットに対して、BP学習アルゴリズムを説明した。この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り、入出力間の特性が記述される。実際の流出予測問題を取り扱う時、ニューラルネットの構造は必ずしも図-2と同じように完全結合にする必要がなく、不完全結合にすることも考えられる。これに応じて、上述したBPアルゴリズムの各層からの出力値の計算式を少々書き直すことが必要となる。

ニューラルネットを流出予測に利用しようとする時、まず過去の出水資料を教師信号とし、BP学習アルゴリズムによって、入出力間の特性を記述しているニューラルネットの結合強度と閾値を同定する。次に同定したニューラルネットを用いて現在の出水について流出予測する。

3 実流域における計算例とその考察

(1) ファジィ推論手法による流出予測

本計算では、北海道にある2つの流域（青山流域と当別流域）を解析対象とし、前節に説明したファジィ推論手法を用い、それぞれリードタイム1、2、3時間の流出を予測した。

まず、青山流域（流域面積229.0 Km²）について、3つの洪水資料がある。図-1のDR=1.5、DQ=0.04の計算条件の下で、初めの2例の洪水資料（1975.8.22日と1979.10.9日の洪水）を過去の出水経験 Π_{1i} とし、次の1985.9.6日の洪水を予測する。過去の出水経験とした2つの洪水例はスペースの原因でここに載せなかった。図-3、4、5はリードタイムを1、2、3時間にした時の予測結果を示している。

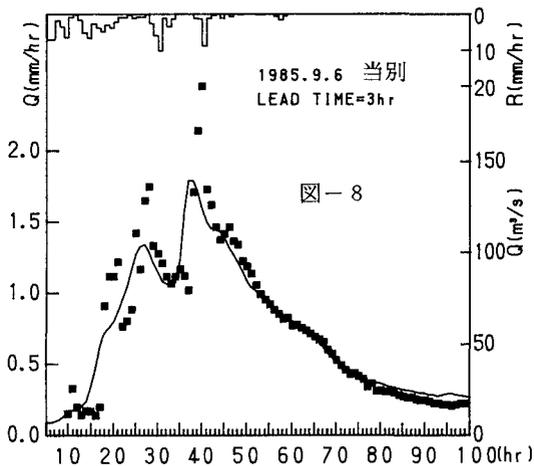
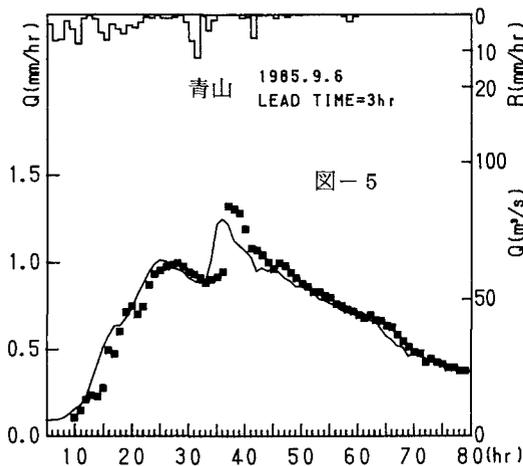
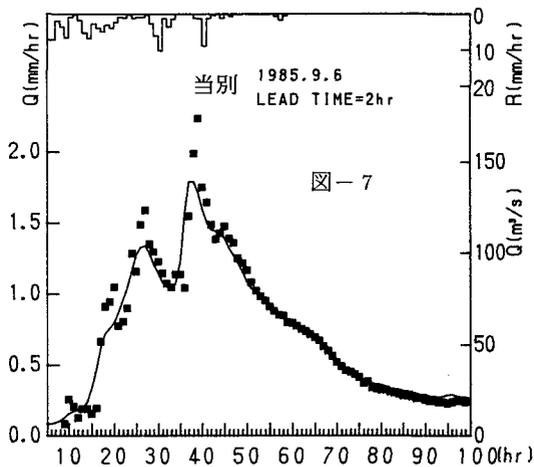
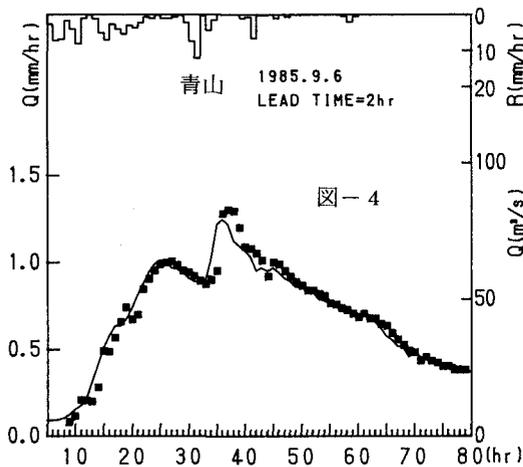
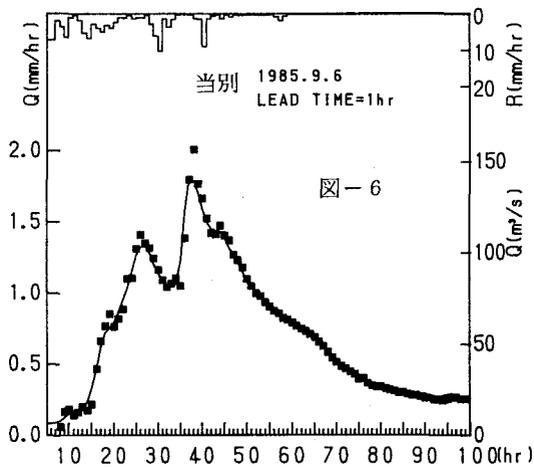
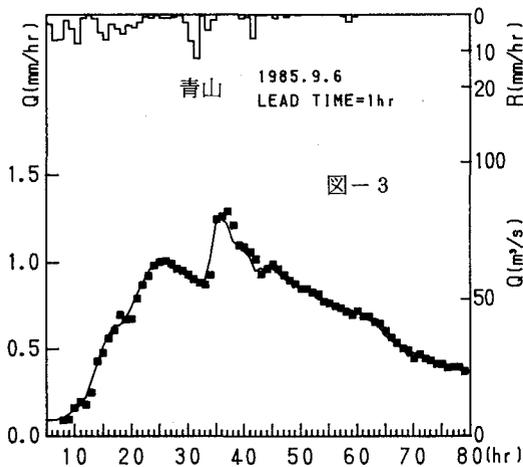
次は、当別流域（流域面積280.7 KM²）について、4つの洪水資料があるが、その中に1つの洪水資料は雨量観測地点が1つしかデータを記録していないので雨量精度が不十分だと判断され、本計算には用いられなかった。図-1のDR=2、DQ=0.04とした計算条件のもとで、初めの1981.7.4日と1981.8.3日の2つの洪水を過去の出水経験とし（スペースの原因で、ここに載せていない）、次の1985.9.6日の洪水について予測する。図-6、7、8はそれぞれリードタイムが1、2、3時間の予測結果である。ただし、図には■印が予測値を示し、実線が実測値を示している。

計算結果から分かるように、当然なことながらリードタイムが大きくなると伴い予測精度が低くなってくるとし、ピーク流量が過大に予測されている。また、青山流域の場合予測された洪水は流出変化が緩く、より良く予測されたが、当別流域の場合、流出変化が激しくて予測精度がより悪かった。

なお、式(5)、(6)の Π_i (Π'_i) の算出に関して加算とMax演算の計算結果を比較するため、図-8の結果に対して、本来のMax演算を採用した場合の結果は図-9に示している。図-5と図-9を比較した結果より、加算がMax演算より流出予測に適当であることが考えられる。

(2) ニューラルネットによる流出予測

ファジィ推論の場合と同一の洪水資料を用い、同一の流出系方程式で計算を行った。図-10は流出系方



ファジィ推論手法による予測結果

程式(2)に対応する本計算に用いられたニューラルネットの構造を示している。この構造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収斂できる。計算では、まず、青山流域について、初めの2例の洪水資料(1975.8.22日と1979.10.19日の洪水)によって、ニューラルネットを同定する。同定したニューラルネットを直接利用して、次の1985.9.6日の洪水について、それぞれリードタイム1、2、3時間の予測をする。予測アルゴリズムは式(24)~(26)に示している。

$$\Delta Q'(t+1) = f\{R(t-2), \Delta Q(t)\} \quad (24)$$

$$\Delta Q'(t+2) = f\{R(t-1), \Delta Q'(t+1)\} \quad (25)$$

$$\Delta Q'(t+3) = f\{R(t), \Delta Q'(t+2)\} \quad (26)$$

式(25)、(26)より分かるように、リードタイムが2、3時間の時、ファジィ推論と同様に既に予測された $\Delta Q'(t+1)$ 、 $\Delta Q'(t+2)$ を利用している。図-11、12、13はそれぞれリードタイム1、2、3時間の予測結果を示している。

次に、当別流域の場合、同様に初めの2ケースの洪水(1981.7.4日と1981.8.3日)を教師信号とし、ニューラルネットを同定して、次の1985.9.6日の洪水について予測する。図-14、15、16はそれぞれリードタイム1、2、3時間の予測結果を示している。

予測結果はリードタイムの増大に伴いピーク流量時に過大な予測をしているが、実用的には利用可能である。

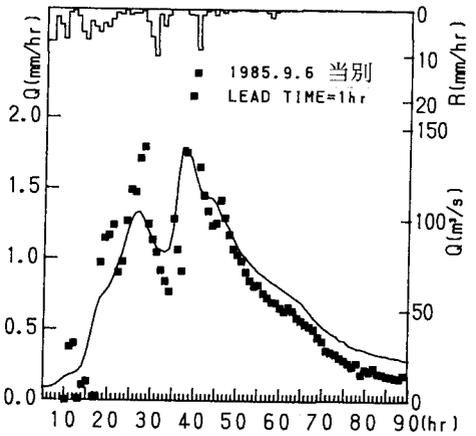


図-9

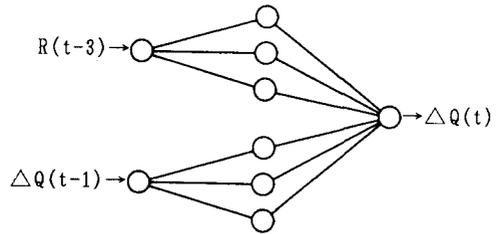


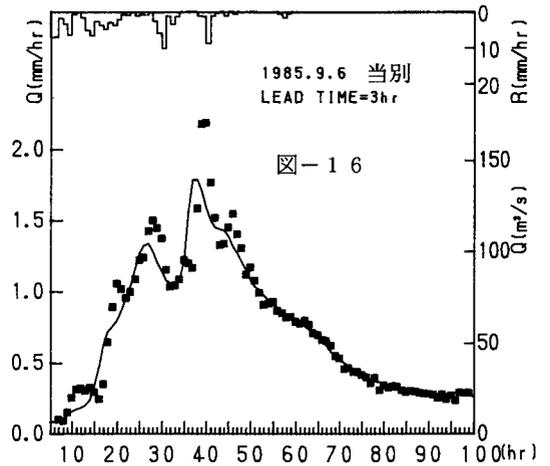
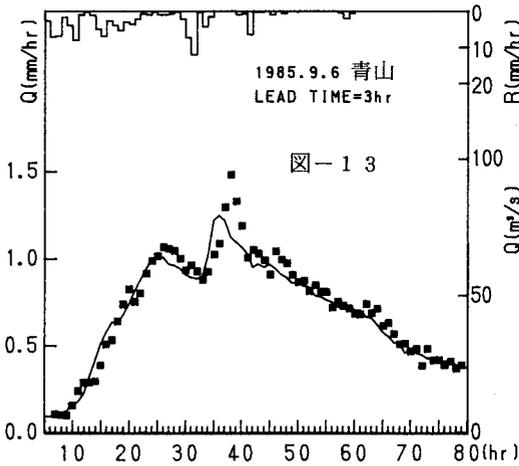
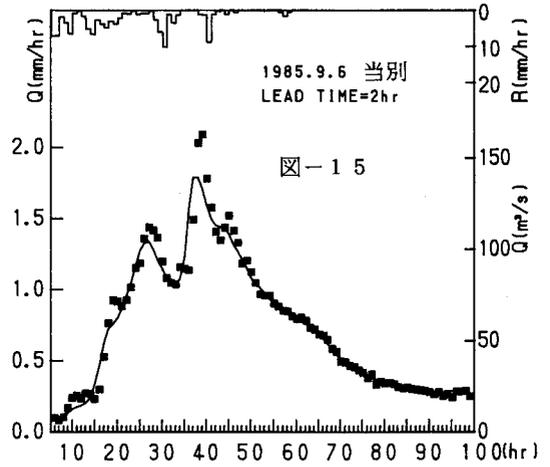
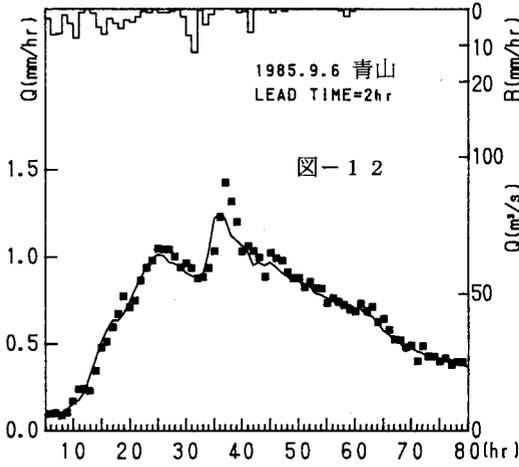
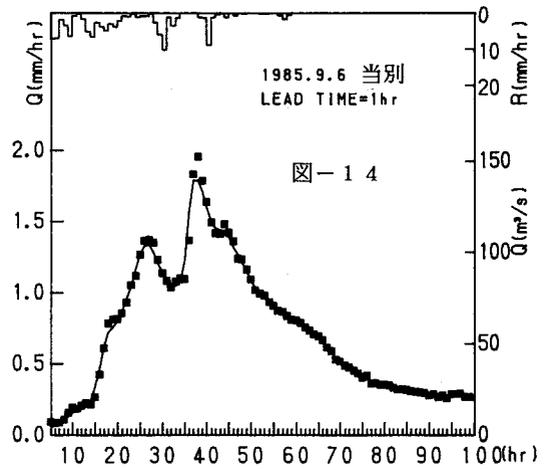
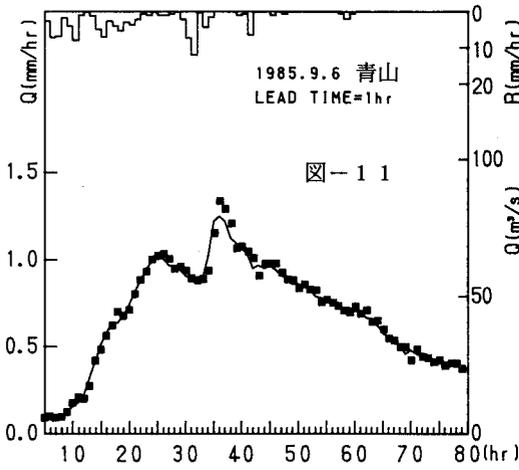
図-10

3 まとめ

以上、ファジィ推論手法とニューラルネットによる流出予測法について説明し、実流域への応用計算も行った。両手法を比較すると、ニューラルネット手法は流出予測する際に既に同定された結合強度、閾値を利用するので、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。予測精度について、両手法に簡単に優劣付けられないと思われる。流出変化が激しい洪水に対して、ファジィ推論手法はニューラルネット手法より劣るですが、流出変化が緩い洪水に対して、よく対処できる。それに、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、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、両者の特長を利用する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.
- 4 藤田・朱木蘭、ニューラルネットを用いた流出予測、水文・水資源研究のためのAI技術の利用に関するシンポジウム、P53-P60、1992.



ニューラルネット手法による予測結果