

## II-20

## ファジィ・ニューラルネットを用いたリードタイムの長い流出予測

北海道大学工学部	正 員	藤田睦博
北海道大学大学院	学生員	朱 木蘭
北海道開発局	正 員	橋本織秀

## 1はじめに

降雨と流出の関係には多くの要因が含まれており、非線形である。一方、近年発展してきたニューラルネット理論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。すなわち、ニューラルネットは過去の洪水資料を教師信号として学習して、流域における降雨と流出の関係を記述し、将来の洪水を流出予測可能である。100~200Km<sup>2</sup>程度の面積の流域を対象とした著者らの研究によると、降雨量の予測情報を全て用いない場合、流出量予測の最大リードタイムは3時間が限界である。さらに、リードタイムの長い流出予測をしようとすれば、予測降雨情報が不可欠であると思われる。近年、気象レーダー情報を用いた降雨予測が精力的に研究されているが、予測のリードタイムが長くなるにともない、降雨の予測は「弱い雨、やや強い雨、強い雨、激しい雨」などの定性的な情報になるざるを得ない。従って、リードタイムの長い流出を予測しようとすれば、定量的な予測降雨量に加えてこのようないまいな情報をも取り扱えるニューラルネットの構成が必要である。本研究は、石渕ら<sup>1)</sup>が提案したいまいさを含むデータを用いたニューラルネットの学習手法に基づいて、実流域における予測降雨情報を用いたリードタイムの長い流出予測について検討した。

## 2基礎理論

Rumelhartら<sup>2)</sup>により提案されたBack Propagation (BP)学習アルゴリズムでは、ニューラルネットへの入力値や教師信号は実数値として与えられる。一方、実際には、システムの入出力関係に関する情報にはいまいさを含む場合が多い。この問題を解決するため、これまでファジィデータを用いたニューラルネットの学習に関する種々の手法が提案されている。これらの手法は、Cohen & Husaon<sup>3)</sup>より次のような2つのクラスに分類される。

(1) ファジィ集合を実数ベクトルに変換するという前処理を行うことにより、通常の階層型ニューラルネットの構造とそのBP学習アルゴリズムをそのまま用いる手法。前処理手法としては、個々のファジィ変数のメンバーシップ関数値をそれぞれ複数のユニット（N個）を割り当て、N次元の実数ベクトルにより表すことが多い。

(2) ファジィ集合を取り扱うために、階層型ニューラルネットの構造と学習アルゴリズムに変更を加える手法。石渕らの提案した手法はこのクラスに含まれている。

ニューラルネットの入力あるいは出力をファジィ集合に拡張する場合では、つぎのような3通りの組み合せが考えられる。

(a) 入力のみがファジィ集合；(b) 出力のみがファジィ集合；(c) 入出力ともにファジィ集合。ここでは、(c)の場合に焦点を絞って石渕らの提案した手法の概略を述べる。(a)と(b)は(c)の特例と考えればよい。

入力層にn個、中間層にm個、また出力層に1個のユニットを持つ3層階層型ニューラルネットへn次元のファジィ数ベクトル $\mathbf{A}_p = (A_{p1}, \dots, A_{pn})$ が入力されたとき、各ユニットのファジィ入出力関係は、レベル集合に対する演算を行って求めることができる。更に、ファジィ数のhレベル集合が区間になっているので、区間演算<sup>4)</sup>に基づいて、各層のユニットからの出力はhレベルに対して、次のように定義することができる。

$$\text{入力層: } [O_{pi}]_h^L = [A_{pi}]_h^L \quad i=1,2,\dots,n \quad (1)$$

$$[O_{pi}]_h^U = [A_{pi}]_h^U \quad (2)$$

$$\text{中間層 : } [O_{pj}]_h^L = f([Net_{pj}]_h^L) \quad j=1,2,\dots,m \quad (3) \quad \text{出力層 : } [O_p]_h^L = f([Net_p]_h^L) \quad (7)$$

$$[O_{pj}]_h^U = f([Net_{pj}]_h^U) \quad (4) \quad [O_p]_h^U = f([Net_p]_h^U) \quad (8)$$

$$[Net_{pj}]_h^L = \sum_{\substack{i=1 \\ w_{ji} \geq 0}}^n w_{ji} [O_{pi}]_h^L + \sum_{\substack{i=1 \\ w_{ji} < 0}}^n w_{ji} [O_{pi}]_h^U + \theta_j \quad (5) \quad [Net_p]_h^L = \sum_{\substack{j=1 \\ w_j \geq 0}}^m w_j [O_{pj}]_h^L + \sum_{\substack{j=1 \\ w_j < 0}}^m w_j [O_{pj}]_h^U + \theta \quad (9)$$

$$[Net_{pj}]_h^U = \sum_{\substack{i=1 \\ w_{ji} \geq 0}}^n w_{ji} [O_{pi}]_h^U + \sum_{\substack{i=1 \\ w_{ji} < 0}}^n w_{ji} [O_{pi}]_h^L + \theta_j \quad (6) \quad [Net_p]_h^U = \sum_{\substack{j=1 \\ w_j \geq 0}}^m w_j [O_{pj}]_h^U + \sum_{\substack{j=1 \\ w_j < 0}}^m w_j [O_{pj}]_h^L + \theta \quad (10)$$

ここに、 $A_{pi}$ ,  $O_{pi}$ ,  $O_{pj}$ ,  $O_p$ ,  $Net_{pj}$ ,  $Net_p$  は全てファジィ数で、それぞれの h レベル集合は  $[[A_{pi}]_h^L, [A_{pi}]_h^U]$ ,  $[[O_{pi}]_h^L, [O_{pi}]_h^U]$ ,  $[[O_{pj}]_h^L, [O_{pj}]_h^U]$ ,  $[[O_p]_h^L, [O_p]_h^U]$ ,  $[[Net_{pj}]_h^L, [Net_{pj}]_h^U]$ ,  $[[Net_p]_h^L, [Net_p]_h^U]$  というような区間である。 $\omega_{ji}$ ,  $\omega_j$  は実数の結合強度で、 $\theta_j$ ,  $\theta$  は実数の閾値である。また、 $f$  はシグモイド関数で、本計算では、区間 (-1, 1) の値を取る関数である。

$$f(x) = \frac{2}{1+e^{-x}} - 1 \quad (11)$$

式 (1) ~ (10) を用いて、ユニットからの出力値を計算する具体的な計算手順を説明すると、まず、ファジィ数入力ベクトル  $A_p$  を h レベル集合に分解する；次に、 $A_p$  の各 h レベル集合に対する区間出力値  $[[O_p]_h^L, [O_p]_h^U]$  を計算する；最後に、 $[[O_p]_h^L, [O_p]_h^U]$  を積み重ねることにより、ファジィ数出力値  $O_p$  を構成する。この出力値  $O_p$  を望ましい出力値  $T_p$  (教師信号) にするため、ニューラルネットは学習を行う。学習手法はコスト関数を次のように定義して、これを最小化することを考える。

$$E_p = \sum_p E_p = \sum_p (\sum_h h E_{ph}) \quad \text{where } E_{ph} = ([T_p]_h^L - [O_p]_h^L)^2 / 2 + ([T_p]_h^U - [O_p]_h^U)^2 / 2 \quad (12)$$

ニューラルネットの学習は、Rumelhartらと同様に、結合強度  $\omega_{ji}$ ,  $\omega_j$  の修正量を次のように定義する。

$$\Delta \omega_{ji} = -\eta \sum_p \sum_h h (\partial E_{ph} / \partial \omega_{ji}), \quad \Delta \omega_j = -\eta \sum_p \sum_h h (\partial E_{ph} / \partial \omega_j) \quad (13)$$

ここで、 $\eta$  は学習率である。 $\partial E_{ph} / \partial \omega_{ji}$ ,  $\partial E_{ph} / \partial \omega_j$  の微分計算は BP アルゴリズムと同様にして導出することができる。本計算で定義したシグモイド関数のもとで、これらの微分計算結果は次のようにになる。ただし、表記を簡単にするため、大文字で表したそれぞれのファジィ数の h レベル区間値を対応する小文字で表す。

$$(1) \quad \partial E_{ph} / \partial \omega_j$$

$$(1) \quad w_j \geq 0 \text{ のとき : } \frac{\partial E_{ph}}{\partial \omega_j} = -\delta_p^L o_{pj}^L - \delta_p^U o_{pj}^U \quad (14)$$

$$\text{where } \delta_p^L = \frac{1}{2} (t_p^L - o_p^L) (1 + o_p^L) (1 - o_p^L), \quad \delta_p^U = \frac{1}{2} (t_p^U - o_p^U) (1 + o_p^U) (1 - o_p^U) \quad (15)$$

$$(2) \quad w_j < 0 \text{ のとき : } \frac{\partial E_{ph}}{\partial \omega_j} = -\delta_p^L o_{pj}^U - \delta_p^U o_{pj}^L \quad (16)$$

(II)  $\partial E_{ph} / \partial w_{ji}$

$$(1) w_j \geq 0 \text{ and } w_{ji} \geq 0 \text{ のとき : } \frac{\partial E_{ph}}{\partial w_{ji}} = -\delta_p^L w_j \frac{1}{2} (1+o_{pj}^L)(1-o_{pj}^L)o_{pi}^L - \delta_p^U w_j \frac{1}{2} (1+o_{pj}^U)(1-o_{pj}^U)o_{pi}^U \quad (17)$$

$$(2) w_j \geq 0 \text{ and } w_{ji} < 0 \text{ のとき : } \frac{\partial E_{ph}}{\partial w_{ji}} = -\delta_p^L w_j \frac{1}{2} (1+o_{pj}^L)(1-o_{pj}^L)o_{pi}^U - \delta_p^U w_j \frac{1}{2} (1+o_{pj}^U)(1-o_{pj}^U)o_{pi}^L \quad (18)$$

$$(3) w_j < 0 \text{ and } w_{ji} \geq 0 \text{ のとき : } \frac{\partial E_{ph}}{\partial w_{ji}} = -\delta_p^L w_j \frac{1}{2} (1+o_{pj}^U)(1-o_{pj}^U)o_{pi}^U - \delta_p^U w_j \frac{1}{2} (1+o_{pj}^L)(1-o_{pj}^L)o_{pi}^L \quad (19)$$

$$(4) w_j < 0 \text{ and } w_{ji} < 0 \text{ のとき : } \frac{\partial E_{ph}}{\partial w_{ji}} = -\delta_p^L w_j \frac{1}{2} (1+o_{pj}^U)(1-o_{pj}^U)o_{pi}^L - \delta_p^U w_j \frac{1}{2} (1+o_{pj}^L)(1-o_{pj}^L)o_{pi}^U \quad (20)$$

なお、閾値  $\theta_j$  と  $\theta$  の学習は、結合強度  $w_{ji}$  及び  $\omega_j$  の学習と全く同様に行うことができる。

具体的な学習ステップを説明すると、レベル  $h$  として  $L$  個の値  $\{h_1, h_2, \dots, h_L\}$  を用い、 $k$  個の学習用データ ( $A_p$ ,  $T_p$ )、 $p = 1, 2, \dots, k$  を用いた場合、学習は次のように行われる。

Step 1: レベル  $h$  を  $h = h_1$  とする。

Step 2: 学習用データの指標  $p$  を  $p = 1$  とする。

Step 3:  $p$  番目の学習用データの  $h$  レベルに対する学習を行う、すなわち、結合強度と閾値を修正する。

Step 4:  $p < k$  であれば、 $p = p + 1$  として Step 3 へ戻る。そうでなければ、Step 5 へ進む。

Step 5:  $h = h_L$  であれば、学習回数を更新し、Step 1 へ戻る。そうでなければ、Step 2 へ戻る。

以上、学習用データは全てファジィデータの場合でのニューラルネットの学習アルゴリズムを説明したが、実数値をファジイ数の特別な場合と見なせば、この手法により、ファジイ数データと実数値データを同時にニューラルネットに学習させることができる。すなわち、実数  $a$  を次のようなメンバーシップ関数で表すことによって、実数とファジイ数を全く同じように取り扱うことができる。

$$\mu_a(x) = \begin{cases} 1 & \text{if } x=a \\ 0 & \text{if } x \neq a \end{cases} \quad (21)$$

ニューラルネットを流出予測に利用しようとすると、まず過去の出水資料を教師信号とし、学習を通して、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。つぎに、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結果とその考察

降雨量を  $R$ 、流出変化量を  $\Delta Q$  とすると流出系の一般的なシステム方程式は、式 (22) のように考えられる。実際の解析では、流域特性などを考慮して適当な  $m$ ,  $n$  を決めればよい。本計算では、北海道にある流域面積  $229 \text{ Km}^2$  の青山流域を解析対象とした。流出系のシステム方程式を式 (23) のようにした。このシステム方程式に対応する構成したニューラルネットは図-1 に示されている。図-1 から分かるように、本計算に用いられたニューラルネットの特徴は降雨量と流出量に関連するユニット間が結合していない。降雨量  $R$  には流出変化量  $\Delta Q$  に比較して、高周波成分を含んでおり、著者らの研究によって、図-1 のような不完全結合ニューラルネットが優れていることが示されている。

青山流域では、3 例の洪水資料入手できた (1975.8.22 日、1979.10.9 と 1985.9.6 日)。計算には、初めの 2 例の洪水資料より時間系列データセット [ $R_{t-3}, R_{t-4}, \Delta Q_{t-1}; \Delta Q_t$ ] を構成して、学習用データにする。次に、3 番目の洪水についてリードタイムが 1 時間～6 時間までの流出予測をする。予測アルゴリズムは式 (24) ～(29) に示されている。

式 (24) ～(29) から分かるように、リードタイムが 4 時間から 6 時間までの流出予測では、将来の降雨予測情報が必要

$$\Delta Q(t) = f\{R(t-1), \dots, R(t-n), \Delta Q(t-1), \dots, \Delta Q(t-m)\} \quad (22)$$

$$\Delta Q(t) = f\{R(t-3), R(t-4), \Delta Q(t-1)\} \quad (23)$$

要となっている。気象庁予報部の「予測作業指針」その14の「予報用語及び文章」によると、予報用語における雨の強さに関する規定は以下のようである。

弱い雨： 1時間雨量が3mm未満の強さの雨。

やや強い雨： 1時間雨量がおよそ10mm以上で、大雨注意報の基準に達しないぐらいの強さの雨。

強い雨： 1時間または3時間の大気警報の基準を超えるぐらいの強さの雨（およそ15～30mm/hr以上）。

激しい雨： 1時間または3時間の大気警報の基準を超えるぐらいの強さの雨（およそ40～50mm/hr以上）

上述のように、予測降雨量が定量的な情報ではなく、定性的な4ランクからなる情報である。このような情報を利用するため、ファジイ理論におけるメンバーシップ関数の概念を導入すれば便利である。ここでは、規定した各ランクの境界が不連続などころで中間値を取って境界にし、図-2に示すような予測降雨量のメンバーシップ関数を考えた。

$$\Delta Q'(t+1) = f\{R(t-2), R(t-3), \Delta Q(t)\} \quad (24)$$

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

$$\Delta Q'(t+3) = f\{R(t), R(t-1), \Delta Q'(t+2)\} \quad (26)$$

$$\Delta Q'(t+4) = f\{R(t+1), R(t), \Delta Q'(t+3)\} \quad (27)$$

$$\Delta Q'(t+5) = f\{R(t+2), R(t+1), \Delta Q'(t+4)\} \quad (28)$$

$$\Delta Q'(t+6) = f\{R(t+3), R(t+2), \Delta Q'(t+5)\} \quad (29)$$

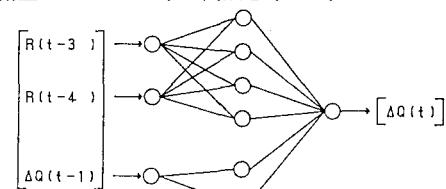


図-1：ニューラルネットの構造

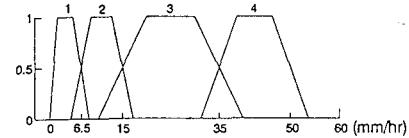


図-2：降雨予測のメンバーシップ関数

なお、提案した流出予測手法の妥当性を調べるために、本計算はリードタイムが3時間から6時間までの流出予測を行う時、手元にある実測降雨量のデータを表-1に示すような4ランクに分類し、各ランクの降雨量を図-2のメンバーシップ関数より表す。図-2に付けられている数字は表-1のランクと対応している。

上述から分かるように、ニューラルネットに利用させるデータが2種類もある。すなわち、ファジイ数データ（予測降雨情報）と実数値データ（降雨と流出の観測データ）。これらのデータを利用するにあたって、次のような2通りの方法が考えられる。

方法（1）：ファジイ数データと実数値データを混じて取り扱う。すなわち、予測降雨情報を図-2のメンバーシップ関数により表し、実測データは式（21）に定義した実数aのメンバーシップ関数により表して処理する。

方法（2）：実測値と言って観測誤差が含んでいるので、実数値の実測値をある程度のあいまいさが含んでいるファジイ数によって表すと、より合理であると考えられる。すなわち、予測降雨情報を方法（1）と同様に取り扱うが、t時刻における実測降雨量R(t)と実測流出変化量△Q(t)を図-3、図-4のようなそれぞれの三角形のメンバーシップ関数より表して計算する。ただし、図中のDR, DQはそれぞれのあいまいさを示している。

ランク	降雨強度 (mm/hr)	ランク	降雨強度 (mm/hr)
1	0~6.5	3	15~35
2	6.5~15	4	35~50

表-1：予測降雨のランク別化

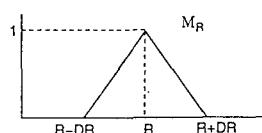


図-3：降雨量のメンバーシップ関数

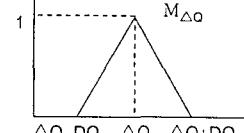


図-4：流出変化量のメンバーシップ関数

まず、方法（1）による計算：図-1のニューラルネットを用いて、通常のBP学習アルゴリズムにより、初めの2例の洪水資料をそのまま実数値データとして学習する。計算には、学習率 $\eta = 0.05$ にし、学習回数=2500にした。次に同定したニューラルネットを用いて、三番目の洪水についてリードタイムが1時間から6時間までの流出予測を行う。なお、予測する際に実数値の実測値とファジィ数の予測降雨データをそれぞれ式(21)と図-2に定義したメンバーシップ関数の導入により同時に取り扱う。ニューラルネットの入出力関係の計算は式(1)～(10)に基づく、レベル $h$ の値は0, 0.2, 0.4, 0.6, 0.8, 1.0にした。また、予測アルゴリズムは式(24)～(29)に示されている。この予測アルゴリズムから分かるように、本計算での予測は1時間単位で行われている。予測結果は図-5に示している。

次に、方法（2）による計算：同じく図-1のニューラルネットを用いて初めの2例の洪水を学習し、三番目の洪水について流出を予測するが、ニューラルネットの学習を行う時または予測を行う時も、実測降雨量と実測流出変化量は図-3、4のそれぞれのメンバーシップ関数より表し、ファジィ数データとして取り扱う。用いられた学習アルゴリズムは式(13)～(21)に示されている。ただし、計算では、図-3、4のDR=1.5 mm/h r, DQ=0.04 mm/h rとし、学習率、学習回数、またはレベル $h$ を方法（1）と同様な値にした。予測結果は図-6に示している。

なお、ニューラルネットより予測されたのは流出変化量のメンバーシップ関数であるが、ここでは、メンバーシップ関数の重心値を取ることにより流出変化量の具体的な値を求める。図-7は一例として、方法（2）によるリードタイムが6時間の予測された一部分のメンバーシップ関数を示している。図中の数字と矢印はそれぞれ時系列の順序とメンバーシップ関数の重心位置を示している。

#### 4 まとめ

本研究はファジィ入出力をもつニューラルネットを用い、あいまいな予測降雨情報を利用するリードタイムが6時間までの流出予測手法を説明した。そのうえで、実流域（青山流域）における実際の予測計算を2つの方法により行った。実測値をそのまま実数値として取り扱う方法（1）と実測値をある範囲の誤差をもつファジィデータとして取り扱う方法（2）との計算結果には優劣をつけがたいことが分かった。これは、ニューラルネットの学習が教師信号を総体的に擬合するように行っているので、ニューラルネットそのものが誤差があるデータに対して既に柔軟性を持っているからと考えられる。

ニューラルネットは流出予測する際に同定された結合強度、閾値を利用して予測する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。それに、ファジィ理論はメンバーシップ概念の導入により定性的な予測降雨情報が取り扱える。本研究はこの両者の特長を利用する流出予測手法を開発したものである。

#### 参考文献：

- 1)石淵久生：ファジィ入力とファジィ出力をもつニューラルネットワーク、日本ファジィ学会誌、Vol.5 No.2, pp.218-232 (1993)
- 2)Rumelhart, McClelland and the PDP Research Group (1986) Parallel Distributed Processing, MIT Press, Cambridge, Vol.1, pp.318-362
- 3)M.E.Cohen and D.L.Hudson: Approaches to the Handling of Fuzzy Input Data in Neural Networks, Proc. of IEEE International Conference on Fuzzy Systems (March 8-12, 1992, San Diego), pp.93-100
- 4)R.E.More: Methods and Applications of Interval Analysis, SIAM(1979)
- 5)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（論文集），1992.11月, pp.53-60

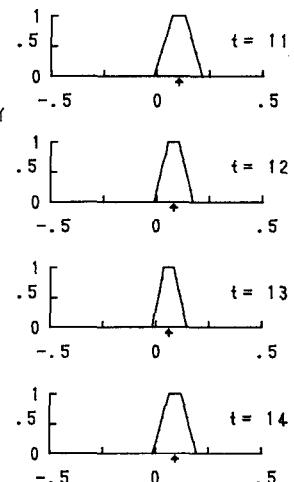


図-7：予測された流出変化量のメンバーシップ関数

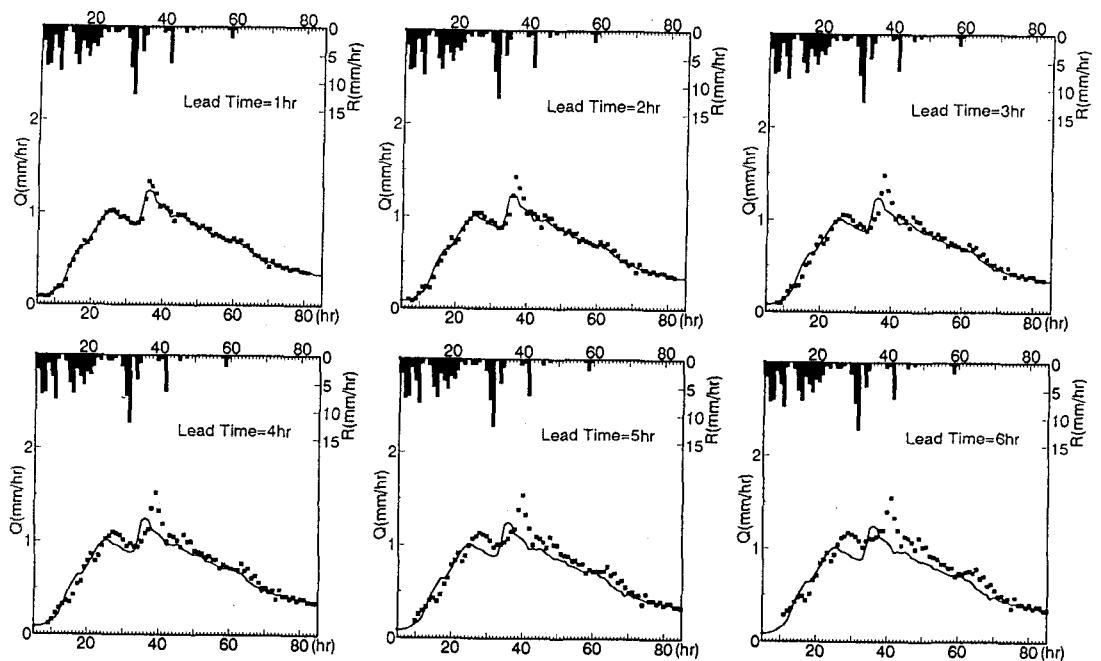


図-5：方法(1)によるリードタイムが  
1 hr ~ 6 hr の予測結果

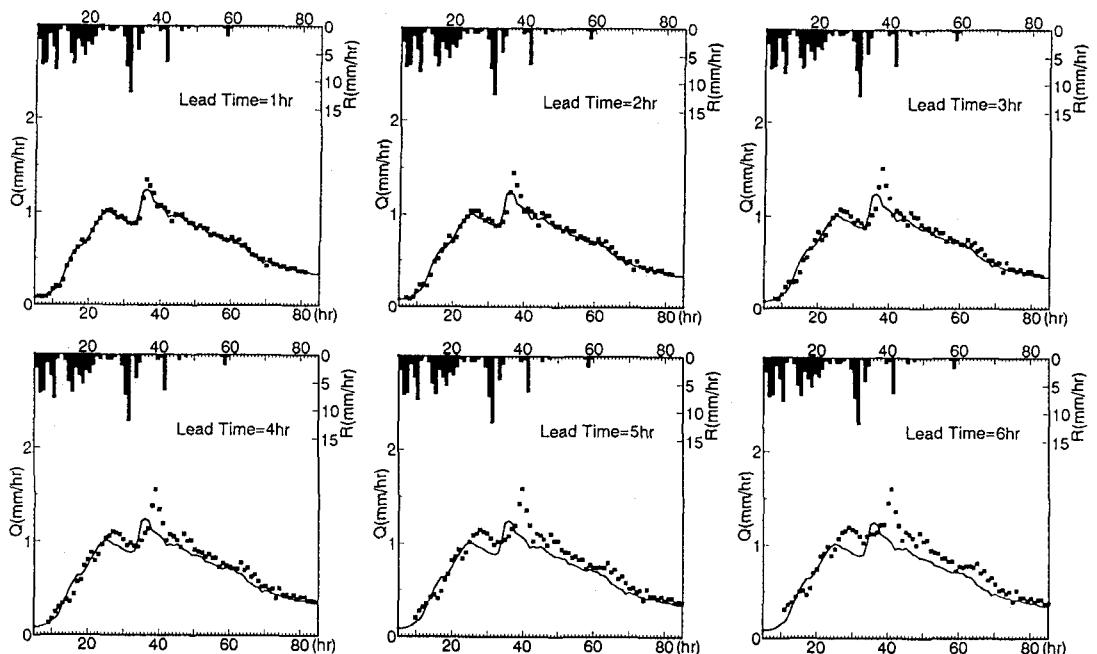


図-6：方法(2)によるリードタイムが  
1 hr ~ 6 hr の予測結果