

流出解析用ニューラルネットワーク におけるリカレント構造の考察

A Consideration on the Recurrent Structure of Neural Networks for Runoff Analysis

寺西 隆司 *

Takashi TERANISHI

四俵 正俊 **

Masatoshi SHIDAWARA

Abstract Recurrent type neural networks which are said to be good for time series are commonly used for runoff calculation. In usual recurrent neural networks with 3 layers, feedback from only the second layer (hidden layer) to the first layer (input layer) is set. In this paper, a recurrent structure that has feedback from the third layer (output layer) to the first layer in addition to the usual feedback is used. The neural network with this type of recurrent structure gives much better results in case of extrapolating calculation, that is, estimation of a big flood it has not experienced during the learning.

1. 序 論

降雨による河川などの流出を把握することは、洪水災害の防止、軽減といった治水の面で古くから重要視されていた。そのため流出解析法にはいくつかのモデルがあり、様々な手法が考えられている。これらの多くは、複雑な計算を必要としたり、対象流域の観測経験を必要としたりなどするもので、時間の経過によって得られる新しい情報に従って、それぞれの流出解析モデルの係数などを繰り返し修正しながら流出計算をしているため、かなりの手間と時間がかかるのが現状である。この原因として流域特性、流出過程が自然的要因により大きく左右され、複雑な現象として十分に解明する事ができないためであると言えよう。

一方、ニューラルネットワークは入出力関係が明確でない現象をブラック・ボックス的に表現することが可能という特徴が注目され、近年、研究が進められている。

本研究室でも、数年前より流出解析にニューラルネットワークを用いる研究を進めている。

その研究より、ニューラルネットワークを使用した流出解析の弱点として学習未経験のタイプの入力に対する予測結果が悪いことが挙げられている¹⁾。特に未経験ピーク流量の予測（以後、外挿予測と呼ぶ）は著しく不良であることが多い。

筆者等は流出解析に、時系列パターンを処理するのに優れているリカレント型ネットワークを使用しているが、本研究では、フィードバック部分のネットワーク構造を変えたモデルをいくつか検討することにより、外挿予測の精度の改善を試みた。

* 愛知工業大学大学院 院生 (豊田市)

** 愛知工業大学 土木工学科 (豊田市)

2. ニューラルネットワーク

2-1. ニューロン

生物の脳神経系の構成要素はニューロン(図 2-1)と呼ばれる神経細胞であることが明らかになっている。その仕組みを工学的に真似たものを、ニューロン・モデルあるいは単にユニットと呼んでいる。一つのユニットは、他のニューロンとシナプス結合部分でつながっており、他のニューロンからの入力信号を内部で増幅, 減衰, 合計などの処理をし、別のニューロンへ伝達する。このニューロンは学習によって機能や結合が変化する。

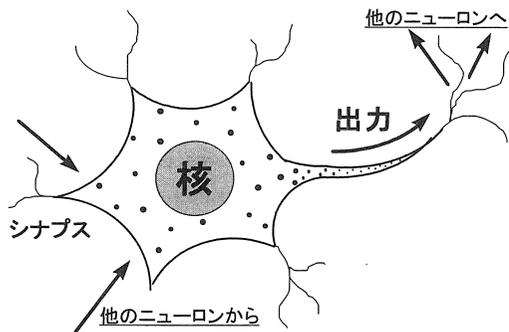


図 2-1. 生物のニューロンの模式図

2-2. ニューロンの工学的モデル化

入力信号が入力層のニューロンに送られ、中間層もしくは出力層へと非線形の変換を施される。ニューロンを工学的に表すとその処理(図 2-2)は、一段階前のニューロンからの入力信号 (I_j) を結合度に応じた重み (W_{jk}) を乗じて、それらの和 $X = (\sum I_j \times W_{jk})$ を次式で表される

シグモイド関数 $O'_k = \frac{1}{1 + \exp(-X + \theta)}$ で行われる。

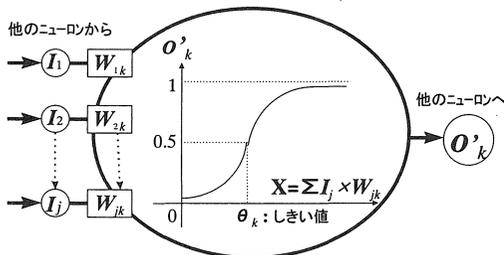


図 2-2. ニューロンの工学的モデル

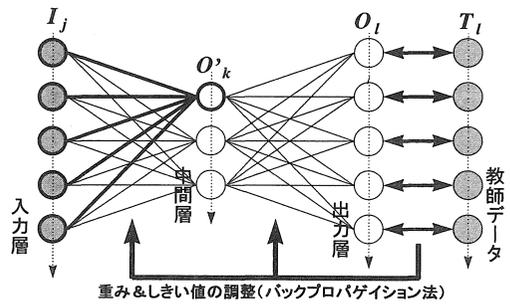


図 2-3. ニューラルネットワーク

2-3. ニューラルネットワークの構造と学習

このような内部処理を行って出力信号を次の層の全ニューロンに送り、最終的には最後の層である出力層からの出力信号を期待する値とする。このようにニューロンが複数結合したものをニューラルネットワーク(図 2-3)と呼ぶ。

ニューロンの学習法(バックプロパゲーション法)

このように出力された値 O を教師信号 T と全パターンにおいて比較し、その二乗誤差が減少していくように出力層から入力層へ逆のぼりながら重み (W) としきい値 (θ) を調整する。これをバックプロパゲーション法(逆伝播法)と呼ぶ。

$$\Delta W(n+1) = \alpha \times \Delta W(n) - \epsilon \times \frac{\partial E}{\partial W}$$

$$\Delta \theta(n+1) = \alpha \times \Delta \theta(n) - \epsilon \times \frac{\partial E}{\partial \theta}$$

- E : 二乗誤差 ($= \sum (O - T)^2 / 2$)
- W : 結合の重み
- θ : しきい値
- n : 学習回数
- α : 学習パラメータ(学習の安定化)
- ϵ : 学習パラメータ(学習速度)

2-4. リカレント型ネットワーク

ニューラルネットワークは、ユニット間すべての結合方向が、入力層から中間層、そして出力層へ移る方向のみで、階層を移るたびに非線形の変換を行い、中間層を飛ばした結合などが存在しない。これを一般に通常階層型ネットワークと呼ぶ。

リカレント型とは、この通常階層型を拡張して新たにコンテキスト層と呼ばれる層を入力層と同位

置に設定し、一つ前のパターン時の中間層の出力をコンテキスト層に移して、次の学習に使うというものである(図2-4)。これは、時系列パターン学習をする際、非常に有効である。

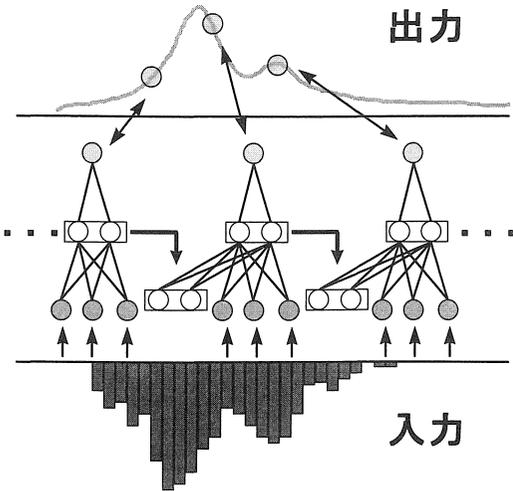


図 2-4. Elman 型リカレントモデルの時系列処理

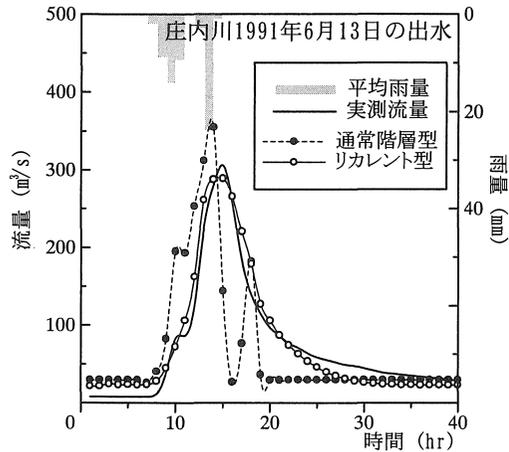


図 2-5. 通常階層型とリカレント型の結果比較

入力値に対する出力値を算出する際、前回算出した中間層の値を次の計算に使用することにより、時系列処理計算が生まれる。図2-5のグラフは、通常階層型とリカレント型のネットワークによる予測結果を比較したもののだが、雨量が途切れたことによって流量が一定値になる通常階層型に対して、時系列を処理するリカレント型は流量の軌跡をとることができる。

リカレント型モデルには、中間層をフィードバックさせる *Elman* 型のリカレントモデルと出力層をフィードバックさせる *Jordan* 型のリカレントモデルの2種類が挙げられる。

3. 流出解析用ニューラルネットワーク

ニューラルネットワークは、既知の入力-出力セットの学習によってネットワーク内部の定数(重み, しきい値)を調整し、入力から出力を算出するシステムを構築するというもの(図3-1)である。

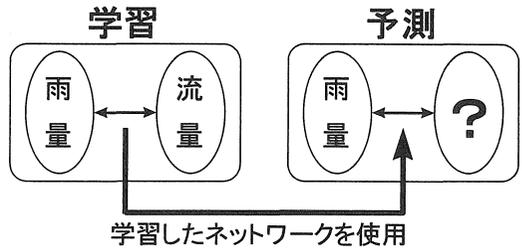


図 3-1. ニューラルネットワークシステム

3-1. 入力と出力

入力は流域内 5 地点の雨量データに 6 時間累加処理を施した計 30 個。最終的な出力は流量 1 個である。これにフィードバック用の出力として過去数時間分の流量の時間変化量を付け加えた(図3-2)。

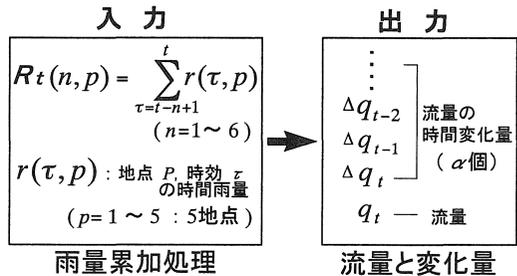


図 3-2. 入力値と出力値

以上、入力層 30 個×中間層 16 個×出力層 1+ α 個による 3 層の階層型ネットワークを基本にした。

3-2. 従来のニューラルネットワークモデル

本研究室では、従来中間層をフィードバックさせる *Elman* 型のリカレント型ネットワークを使用し、

入力層に累加処理雨量, 教師データに実測流量 1 個を用い学習 (図 3-3 上)。そして, それによって構築したネットワーク (重み, しきい値) を予測用ネットワーク (図 3-3 下) として, 予測結果を得ていた。

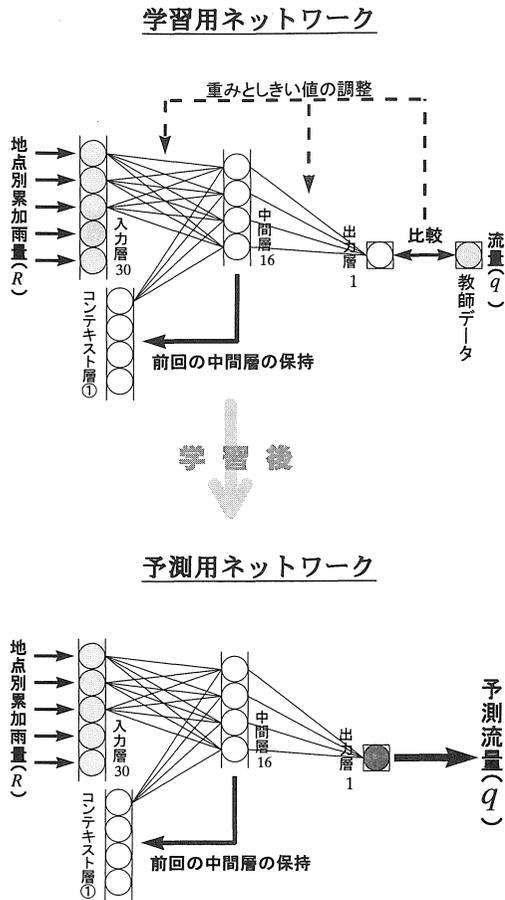


図 3-3. 従来の方式

3-3. 流出解析用ニューラルネットワークモデル

今回, 流出量計算用に考えたニューラルネットワークにおいては, 雨量だけでなく, 少し前の流量を入力に用いると学習が早く終了し精度も非常によくなくなる事から。これまで用いてきた中間層をフィードバックさせる *Elman* 型のネットワークに, 出力層をフィードバックさせる *Jordan* 型のリカレント型ネットワーク²⁾ を組み合わせた以下の方式 (以後, 組み合わせ方式と呼ぶ) を試みた。

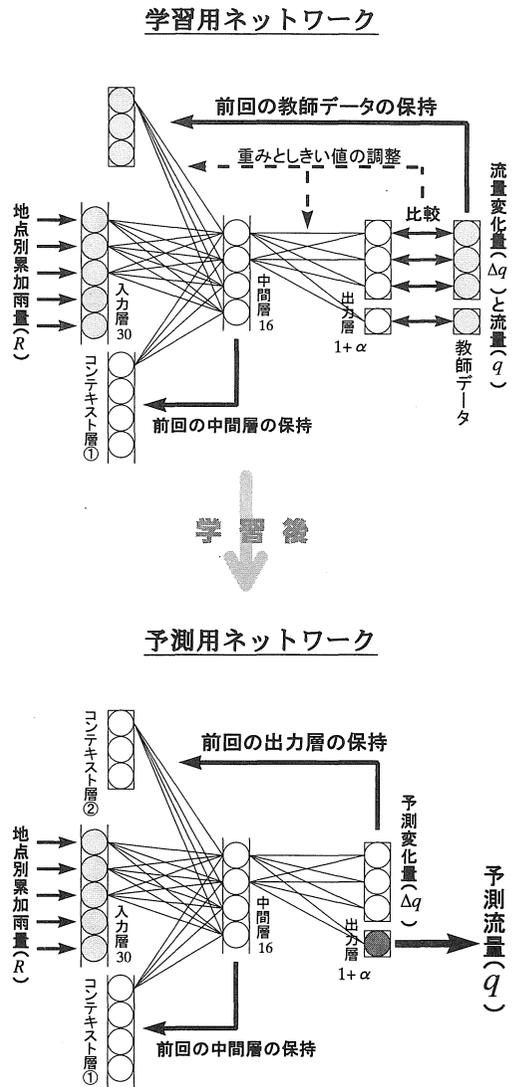


図 3-4. 今回の方式 (組み合わせ方式)

学習用ネットワーク (図 3-4 上) は, 中間層のフィードバックのみの *Elman* 型モデルで, 入力に前回の実測流量である教師データをフィードバックさせて学習をする。つまり実際には, 入力層 30 個に出力層 $1 + \alpha$ 個が加わる。

そして予測計算 (図 3-4 下) では, 実測流量の代わりに出力層の予測流量をフィードバックさせてコンテキスト層とする。通常, コンテキスト層の初期値は, 0 から始まるが, ここでは基底流量を使用することにした。流量の時間変化量は, 基底流量一定として 0 から始める。

この方式は、学習の段階では、入力に実測流量(教師データ)を用いるが、出来上がったネットワークを用いた予測計算においては、雨量のみの入力から結果を求めることができる。

また、この方式では、フィードバック部分を変化させることができる。今回、以下の変化(図 3-5)を試みた。

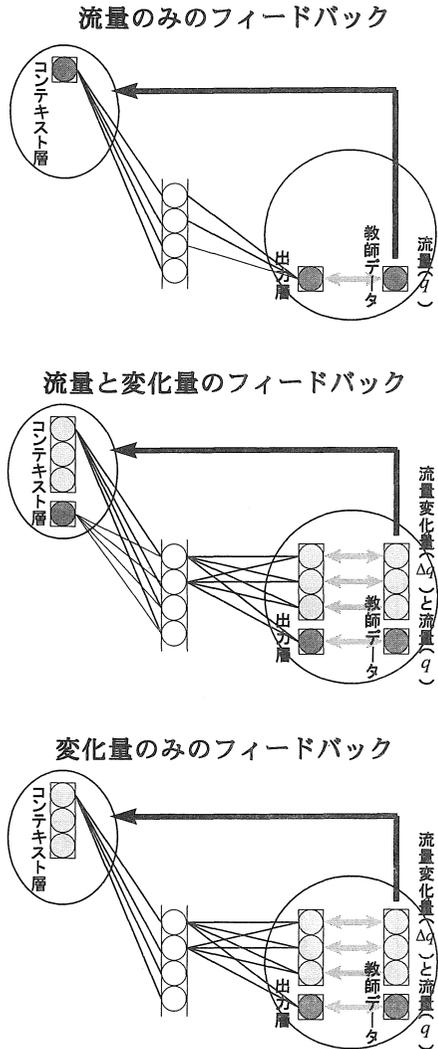


図 3-5. 組み合わせ方式のフィードバック部分

変化量を使わない、流量のみのもので、それをフィードバックさせる。つまり出力層、コンテキスト層、共に、1個の場合。そして、流量1個と変化量を3個を出力とし、それを全部フィードバックさせ

たもの。最後に、流量と変化量を出力としますが、この変化量3個のみのフィードバックで、流量は、フィードバックさせないもの、以上の3通りです。

4. 対象流域とその出水

4-1. 庄内川

対象流域として、愛知県中央を流れる庄内川上流部の多治見流域(流域面積 367km²)を選定(図 4-1)した。多治見地点の流量と流域内5地点の雨量データを使用し、過去の洪水出水の中から学習及び評価に使用する出水(表 4-1)を選択。多治見地点における通報水位レベル以下の流量の出水(最大 340m³/s)を学習用として使い、それ以上の出水を外挿予測評価用として使用した。

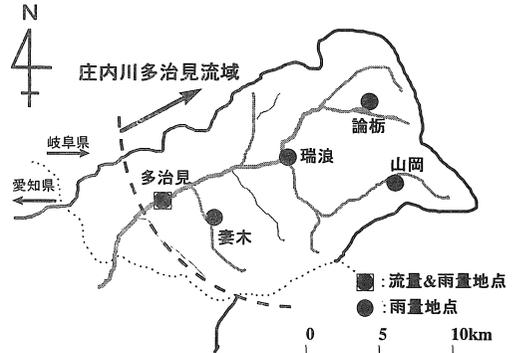


図 4-1. 庄内川上流多治見流域図

表 4-1. 庄内川の学習および評価用出水データ

水防レベル	学習用出水 (m ³ /s)	評価用出水 (m ³ /s)	外挿
出動(3.70m≒950m ³ /s)		1991/9/17 (1080)	
警戒(3.20m≒670m ³ /s)		1989/9/1 (840)	
通報(2.50m≒360m ³ /s)		1990/9/19 (510)	↑
		1996/7/7 (450)	
	1989/6/27 (340)	1991/6/13 (310)	↑
	1988/6/1 (220)	1990/6/14 (130)	
	1992/9/25 (100)		

多治見流域には、全体で9地点の雨量観測所があるが、ここで挙げた5地点は、その中でもテレメータ雨量計の設置場所である。テレメータ(遠隔観測装置)は、災害時においてもデータ通信が途絶えないように無線になっており、雨量データをオンラインで入手できる。このシステム(図 4-2)を利用すれば、流量の随時予測が可能である。

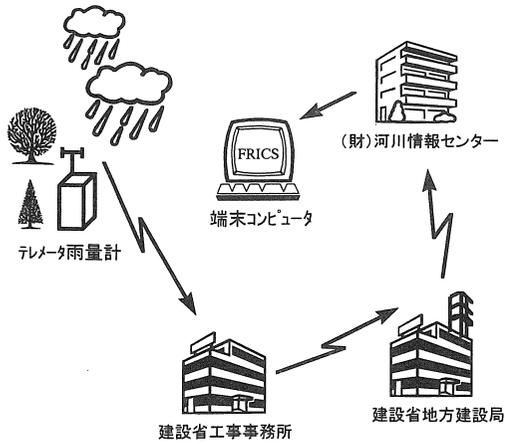


図 4-2. テレメータシステム

4-2. 豊川

また、同レベルの流域として、豊川の上流部である石田上流域（流域面積 450km²）も比較対象として選定（図 4-3）し、その出水（表 4-2）を使用した。

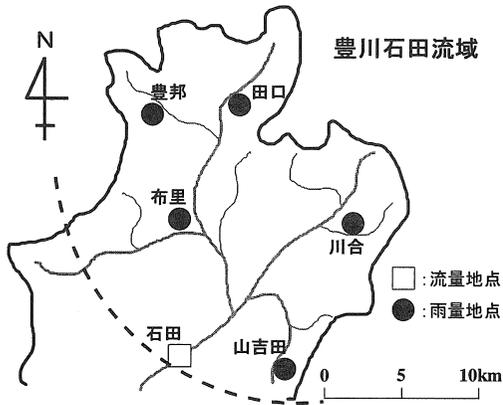


図 4-3. 豊川上流石田流域図

表 4-2. 豊川の学習および評価用出水データ

水防レベル	学習用出水 (m ³ /s)	評価用出水 (m ³ /s)	外挿
警戒(4.20m≒1590m ³ /s)		1990/9/17 (2450)	
		1988/9/24 (1610)	
		1989/9/18 (1470)	
通報(2.40m≒630m ³ /s)	1991/9/13 (880)	1993/7/4 (660)	
	1991/6/22 (820)		
	1993/7/2 (630)		

5. 計算結果

5-1. 予測結果

出力層をフィードバックさせない通常 (Elman) のリカレント型モデルによる従来方式と、今回の組み合わせ方式を比較する。組み合わせ方式については、フィードバックさせる出力層を、流量 (1 個) と流量の時間変化量 (3 個) の両方、流量のみ (1 個)、変化量のみ (3 個) と変え (庄内川, 豊川とともに同じ数で)、その影響を考察する。

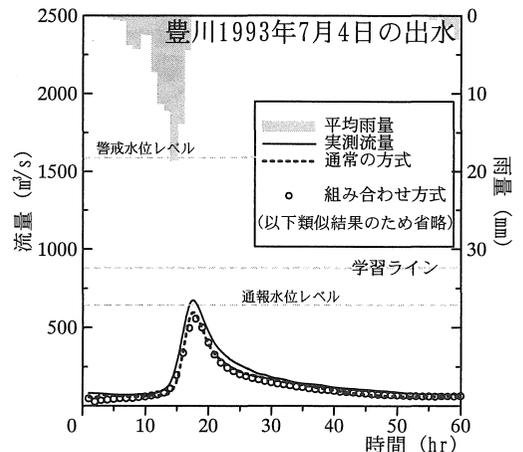
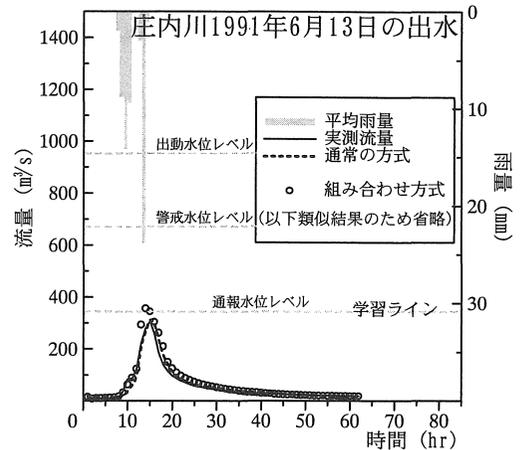


図 5-1. 学習最大流量以下の出水の予測

学習最大流量以下の出水の予測については、いずれの方式においても大きな誤差が生じることはなく、良好な結果が得られた（図 5-1 上下）。

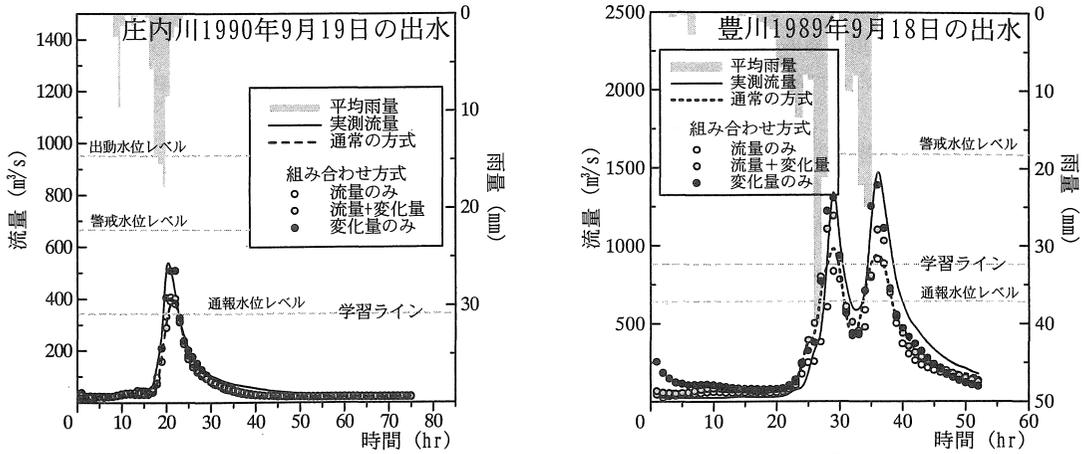


図 5-2. 外挿予測 (小)

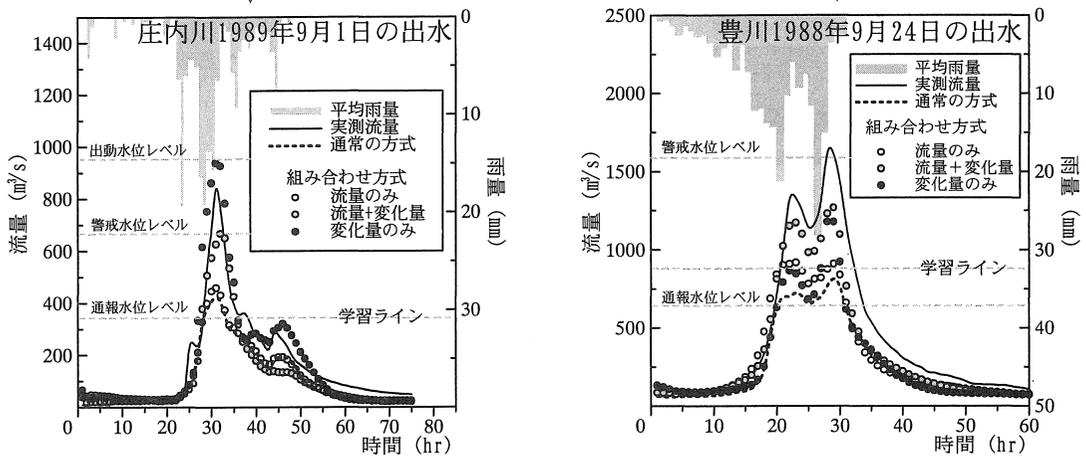


図 5-3. 外挿予測 (中)

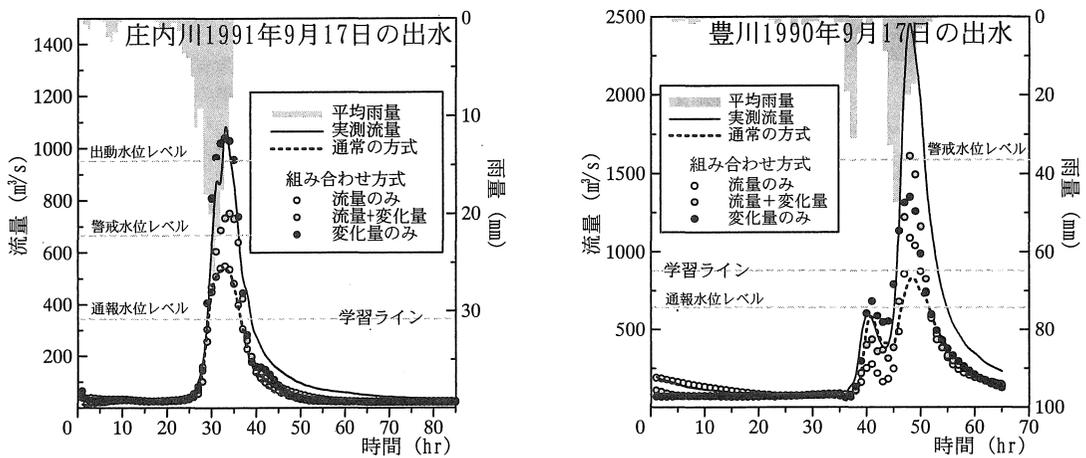
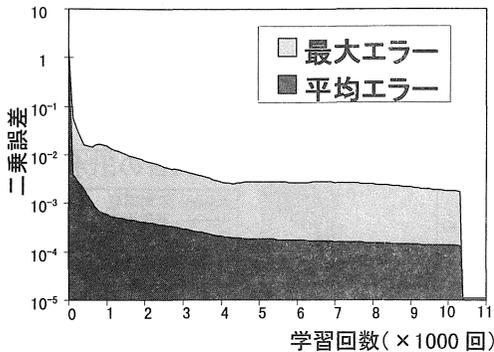


図 5-4. 外挿予測 (大)

外挿予測の結果を図 5-2・3・4 に示す。通常のリカレント型モデルを使用した方式では, 出水の規模が大きくなるにつれ, ピーク流量の誤差が大きくなる結果となった。これに対し組み合わせ方式を用いた計算では, 出水の規模に関係なく, 比較的良好な予測が実行できた。特に流量の時間変化量のみをフィードバックでは, ピーク流量にかなり近い結果が得られた。

5-2. 学習状況

通常の方式



組み合わせ方式

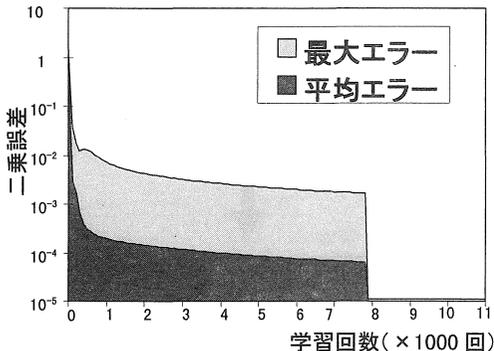


図 5-5. 学習の誤差収束過程

このグラフ (図 5-5) は, 学習の段階での出力値と教師データの二乗誤差の収束過程を表したものである。平均エラーは, 学習するすべてのパターンの平均誤差値で, 最大エラーは, すべてのパターンを通して最大の誤差が生じた値である。

同じ設定許容誤差値 (目標とする最大エラー) まで収束するのに通常の方式 (図 5-5 上) より, 組み合わせ方式 (図 5-5 下) の方が早く終わる結果となった。

6. 結語

ニューラルネットワークを用いた流出解析において, 時系列パターンを処理することに優れているリカレント型ネットワークを使用した。3 層の階層型ニューラルネットワークにおいて, 中間層および出力層を同時にフィードバックさせることにより, 精度の改善が見られた。

出力層から流量の時間変化量をフィードバックして入力層に戻すことによって, 特に外挿予測でのピーク流量の精度が著しく向上した。また, この方法によって学習時間が短くなる効果などが得られた。

参考文献

- 1) 四俣正俊・山田正: ニューラルネットワークによる流出解析-外挿の試み, 自然災害シンポジウム, 1993
- 2) 合原一幸: ニューロ・ファジィ・カオス, p.31, オーム社, 1992
- 3) 菅原正巳: 流出解析法, 共立出版, 1972
- 4) 中野馨・飯沼一元・他: 入門と実習ニューロコンピュータ, 技術評論社, 1989
- 5) 建設省庄内川工事事務所 編集: 庄内川洪水予測マニュアル, 1977
- 6) 安藤大介: ニューラルネットワークによる流出解析, 愛知工業大学修士論文, 1993
- 7) 打田卓実: 雨域移動を考慮したニューラルネットワークによる流出解析, 愛知工業大学修士論文, 1993
- 8) 落合慶広・戸田尚宏・臼井支朗: ニューラルネットワークにおける学習率の新しい更新率, 情報処理学会論文, p.1081, 1994
- 9) 落合慶広・戸田尚宏・臼井支朗: 重みの振動を抑制する階層型ニューラルネットワークの学習法-Kick Out 法-, 電学論, p.1154, 1993
- 10) 戸田尚宏・臼井支朗: ニューラルネットワークにおける逆伝搬学習アルゴリズムの初期値設定に関する一考察, 信学論, p.1179, 1993
- 11) 内山匡・下原勝憲: リカレントニューラルネットワークのための実時間学習アルゴリズム, 電学論, p.1158, 1990

(受理 平成 9 年 3 月 21 日)