

レーダ雨量を考慮したニューラルネットワークによる流出計算

Runoff Calculation by Neural Networks Using Radar Rainfall Data

岡田 晋作[†], 四俵 正俊^{††}
Shinsaku OKADA, Masatoshi SHIDAWARA

Abstract Neural networks are used to calculate runoff from weather radar data and ground rain gauge data. Compared to usual runoff models, it is easier to use radar data in neural network runoff calculation. Basically you can use the radar data directly, or without transforming them into rainfall, as the input of the neural network. A situation with the difficulty of ground measurement is supposed. To cover the area lacking ground rain gauge, radar data are used. In case that the distribution of ground rain gauges is non-uniform, filling up the vacancy with radar data is very efficient to get good runoff estimation.

1. はじめに

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が、流域内部の表面・中間・基底流出など、複雑な現象とそれらの相互関係については十分に解明されていない。また、これらは多くの場合、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のが現状である。

一方、ニューラルネットワークは、動物の神経細胞（ニューロン）を単純な数理モデルで表し、それを多数結合したものである。これは従来のように数式化した処理手順をプログラムとしてコンピュータに与えて解を得るのではなく、単純に入力と出力の関係のみを学習させて解を得ようとするものである。

それによって出来るニューラルネットワークは入出力関係をブラックボックス的に表現するので、物理的に明確でない現象でも容易に適用できる特徴を持っている。つまり、入力に対する正しい出力を学習さ

せることである種の経験を積み、何らかの関係があると思われるデータを用いて、解析を試みる事が可能であるということである。

これまで我々の研究室では、現在までの地上雨量もしくは流量を入力として与えることにより、ニューラルネットワークによる洪水時の短期流量予測に関しては良好な結果が得られている。そこで今回は、さらにレーダ雨量を入力として与えることで流出予測の精度の向上を目指すものである。

本来なら流出計算をする上で、流域内には地上雨量計が均等に、そして数多く設置されていることが望ましい。しかし、何らかの理由で流域内の地上雨量計の数が少ない場合や、設置場所が偏っている場合が考えられる。このような場合を想定し、地上雨量計では計測できない部分をレーダ雨量で補うことによって流出計算の精度向上を図ることが出来るか検討する。

2. ニューラルネットワーク

2.1 ニューロンとは

モデルとしたニューロン（神経細胞）を表したものが図2.1である。脳や神経は、このニューロンが結合してきた大規模なシステムであり、機能的にみれば、ニューロンは情報処理素子の役割をしている。1つの

[†] 愛知工業大学 建設システム工学専攻（豊田市）

^{††} 愛知工業大学 土木工学科（豊田市）

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信号を内部で増幅、減衰、合計など処理し、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

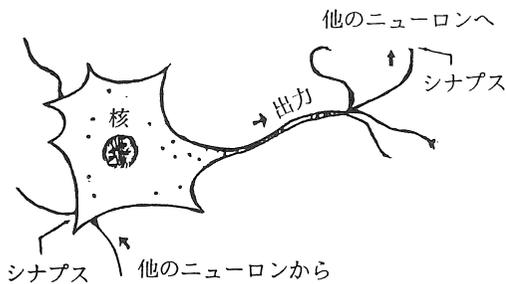


図 2.1 ニューロン

2.2 ニューロンのモデル化

図 2.1 の神経細胞をモデル化したものを図 2.2 に示す。増幅または減衰されて、入ってくる複数の入力信号の和をこの式でしきい値処理を行い、結果を出力信号として他のニューロンに送る。

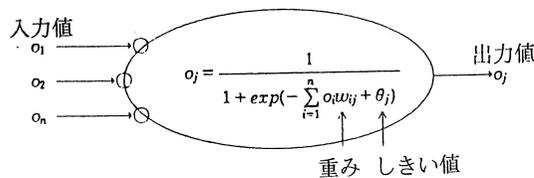


図 2.2 ニューロンのモデル化

2.3 ニューラルネットワークの構造

図 2.2 で示した 1 つのニューロンを 1 ユニットとして、これを階層的に結合したものが図 2.3 に示す階層型ニューラルネットワークと呼ばれるものである。入力層と出力層およびいくつかの中間層（隠れ層）から構成されている。ネットワークの入力層に入力信号が与えられると、内部で処理し、それに応じた出力信号が出力され、次の層に入力信号として送られる。以上のようなことが繰り返され、最後に出力層からでた出力信号が出力データとなる。

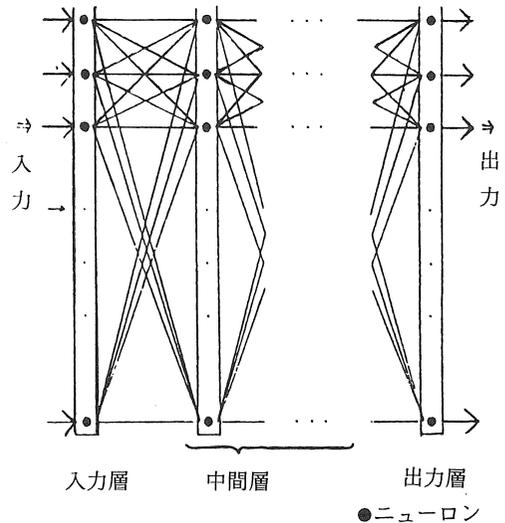


図 2.3 ネットワークの構造

2.4 ニューラルネットワークの学習と評価

入力するデータに対して手本となる教師データを与え、ニューラルネットワークで計算された出力データを教師データと比較し、許容誤差より大きければ、誤差の大きさによって結合の重みとしきい値を調整する。この過程を許容誤差内に達するまで繰り返す。これをニューラルネットワークの学習といい、図 2.4 にその過程を示す。そして、できあがったネットワークに、学習には用いていないデータを入力し、ネットワークを通して出力された値が予測となる。

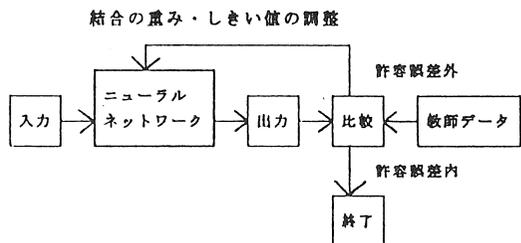


図 2.4 ネットワークの学習と予測

3. 解析方法

3.1 対象流域

図 3.1 に対象流域を示す。本研究では豊川石田地点流域 (流域面積 721km²) を対象とし、流域内の 8 地点の地上時間雨量データ、流域内の 50 メッシュのレーダ雨量データおよび布里・石田地点の流量データを使用した。

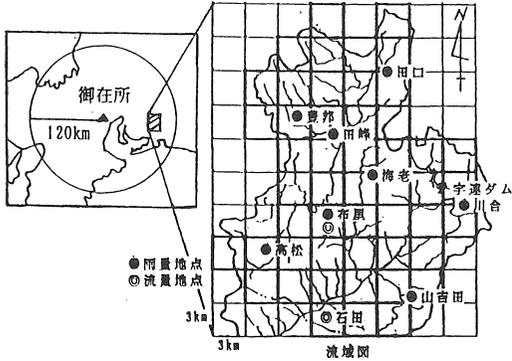


図 3.1 対象流域

3.2 使用する出水

本研究に使用する出水を表 1 に示す。計算には 1983 年から 1993 年までの 8 出水を用い、その内の 3 出水を学習、残りの 5 出水を評価に用いた。

表 1 豊川出水データ

年	月	日	時	～	月	日	時	時間	最大流量(m ³ /s)
①	1983	8	15	12	8	18	23	84	533
②	1988	9	24	0	9	26	23	72	778
③	1989	9	1	12	9	4	17	78	878
④	9	18	12	9	20	20	57	906	1 489
⑤	1990	9	17	0	9	20	19	92	1 424
⑥	1991	6	22	1	6	26	24	120	196
⑦	9	13	14	9	16	24	83	769	879
⑧	1993	7	2	1	7	7	12	132	359
									657

3.3 レーダ雨量データ

本研究で使用するレーダ雨量データは御在所レーダで観測されたものである。磁気テープから取り出した 5 分間強度の反射電力値からレーダ方程式により雨量強度を求め、これの 1 時間平均値をレーダ雨量とする。また、すべての計算で $B=200$, $\beta=1.6$ を用いた。レーダ雨量値は 3 km × 3 km の直交メッシュの平均値を用いた。式 1 に使用したレーダ方程式、図 3.2 に 8 地点単純平均の地上雨量と流域内 50 メッシュで平均したレーダ雨量の例を示す。

$$Pr = \frac{C \times F \times B \times R^\beta \times \alpha}{r^2} \dots\dots\dots (式 1)$$

Pr: 反射電力値 C: レーダ定数 B × R^β: 反射強度因子
F: 補正係数 α: 減衰項 r: 御在所から目標までの距離

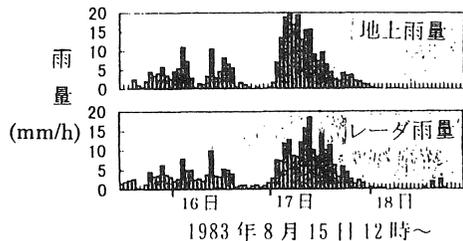


図 3.2 地上雨量・レーダ雨量の例

3.4 入力データの前処理

入力データは、過去数時間の雨量データをそのまま入力値とするよりも、累加処理を施すことにより計算時間の短縮や予測結果が向上することが解っている。本研究で用いる累加方法は図 3.3 に示す 6 時間累加で行った。

時間	雨量	累加処理(6時間)
1時	r(1)	r(6)
2時	r(2)	r(6)+r(5)
3時	r(3)	r(6)+r(5)+r(4)
4時	r(4)	r(6)+r(5)+r(4)+r(3)
5時	r(5)	r(6)+r(5)+r(4)+r(3)+r(2)
6時	r(6)	r(6)+r(5)+r(4)+r(3)+r(2)+r(1)
⋮	⋮	⋮
⋮	⋮	r(7)
⋮	⋮	r(7)+r(6)
⋮	⋮	r(7)+r(6)+r(5)
⋮	⋮	r(7)+r(6)+r(5)+r(4)
⋮	⋮	r(7)+r(6)+r(5)+r(4)+r(3)
⋮	⋮	r(7)+r(6)+r(5)+r(4)+r(3)+r(2)

図 3.3 6 時間累加

3.5 ネットワーク

本研究に用いたネットワークは図 3.4 に示したリカレント型である。入力層のユニット数は、計算する地点数などによって異なるが、1つの雨量観測地点について過去 6 時間分までの累加雨量データ (6 個) を入力とするので、2カ所の雨量観測所のデータを用いた場合には 12 個、4カ所の雨量観測所を用いた場合には 24 個が入力層ユニットの個数となる。中間層のユニット数は入力層のユニット数の半分とし、出力層のユニット数は石田流量地点 1つとした。

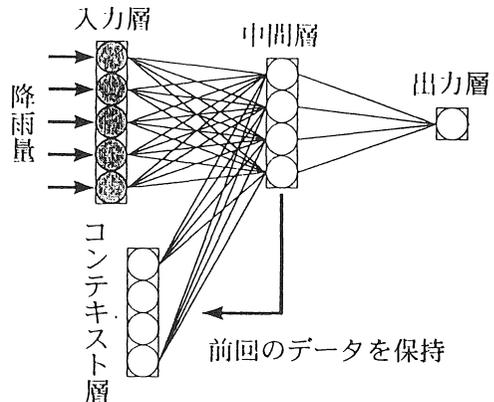


図 3.4 ネットワーク

4. 解析結果

4.1 地上雨量のみ、レーダ雨量のみを

用いた場合
 まず、流域内 8 地点の地上雨量データすべてを入力としたネットワークを作った。8 出水のデータを学習用の 3 出水と評価用の 5 出水に分けた。この分け方は 336 通りあるが、ランダムに 25 通り選んで計算を行った結果、どの出水を選んでも良好であった。次に、レーダ雨量のみを用いた流出計算を試みた。流域内 50 メッシュのレーダ雨量を 8 ブロックに分け、ブロックの平均値をそれぞれ累加処理して入力とした。8 地点の雨量を用いた場合と比較すると、8 ブロックのレーダ雨量を用いた場合は、学習時間が長いものが多く、また予測精度も良くなかった。評価例を図 4.1 に示す。学習に用いた出水は表 1 の③、④、⑤、評価には表 1 の②の出水を用いた。

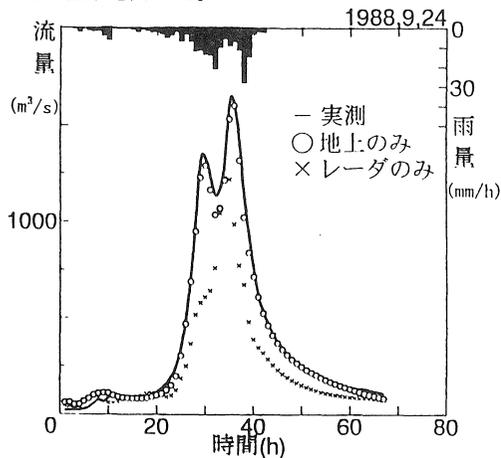


図 4.1 地上雨量のみ、レーダ雨量のみの場合

4.2 地上雨量(4地点)をレーダ雨量で

補った場合
 この流域内の地上雨量計の設置場所が偏っていた場合を仮定する。4 個の地上雨量計を考え①上流に 4 地点(田口・豊邦・田峰・高松)設置した場合、②下流に 4 地点(海老・布里・川合・山吉田)設置した場合、③流域周辺部に 4 地点(田口・豊邦・川合・山吉田)設置した場合、④流域中央部に 4 地点(海老・布里・田峰・高松)設置した場合を仮定し、地上雨量のみを用いたものと地上雨量にレーダ雨量を補ったものとを比較した。①~④いずれの場合も地上雨量をレーダ雨量で補うことにより精度が向上した。評価例を図 4.2.1~図 4.2.4 に示す。学習に用いた出水は表 1 の①、④、

⑧、評価には表 1 の⑥の出水を用いた。

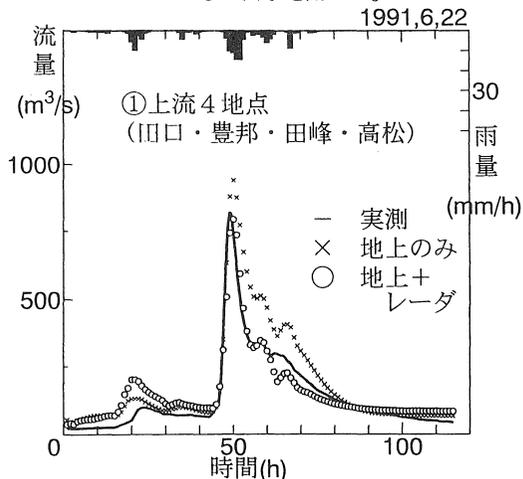


図 4.2.1 上流 4 地点を考えた場合

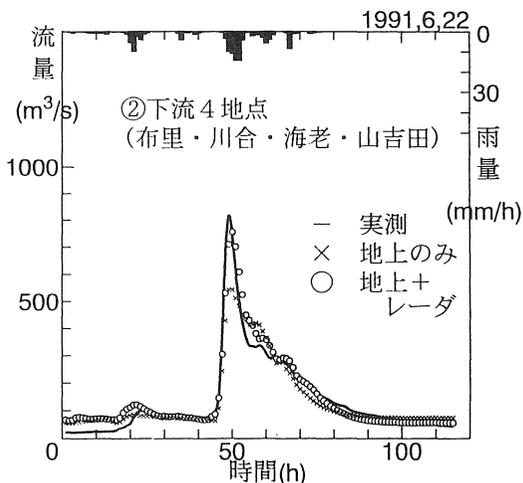


図 4.2.2 下流 4 地点を考えた場合

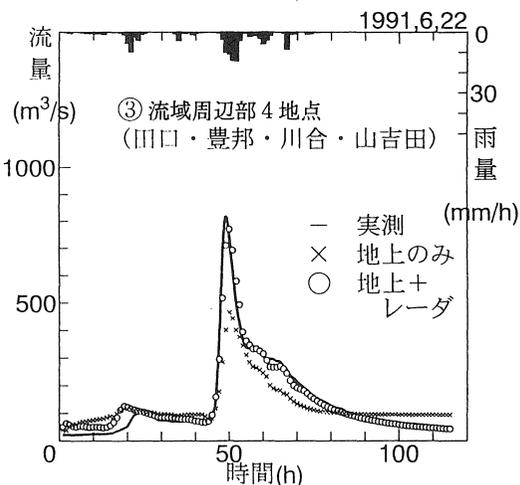


図 4.2.3 流域周辺部 4 地点を考えた場合

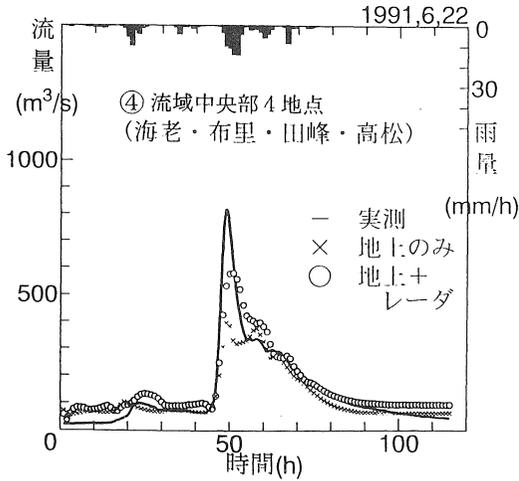


図 4.2.4 流域中央部 4 地点を考えた場合

4・3 地上雨量(2 地点)をレーダ雨量で

補った場合

次に、この流域内の地上雨量計の数が少なかった場合を仮定する。2 個の地上雨量計を考え、近くにある 2 地点を選んだものを 3 組、離れたところにある 2 地点を選んだものを 3 組使用し、それぞれ地上雨量のみを用いたものと地上雨量にレーダ雨量を補ったものとを試みた。結果は、地上雨量のみを用いたものは学習時間が長いものが多く、許容誤差内に収まらないものもあり、予測精度も良くなかった。一方、地上雨量にレーダ雨量を補ったものは学習時間はそれほど長くないが、予測精度はあまり良くなかった。過去の研究から流量をネットワークの入力に用いることで学習時間が短縮し、予測精度も向上することが解っている。布里から石田までの流達時間は 1 時間であるので、1 時間前の布里地点の流量を入力として用い、地上雨量と流量を用いたものと地上雨量にレーダ雨量を補い、さらに流量を用いたものとを比較した。近くにある 2 地点を選んだ場合(①～③)も、離れたところにある 2 地点を選んだ場合(④～⑥)も、それぞれ地上雨量をレーダ雨量で補ったものの方が精度も良く、好結果が得られた。評価例を図 4.3.1～図 4.3.6 に示す。学習に用いた出水は表 1 の①、④、⑧、評価には表 1 の③の出水を用いた。

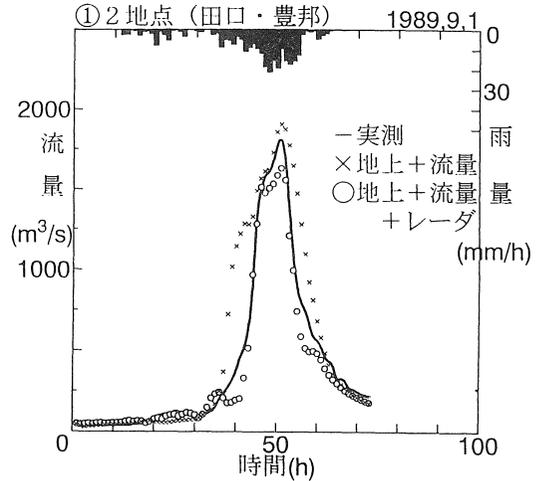


図 4.3.1 田口・豊邦を考えた場合

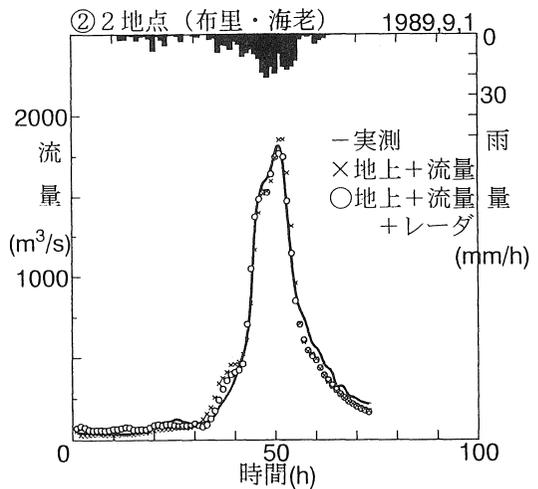


図 4.3.2 布里・海老を考えた場合

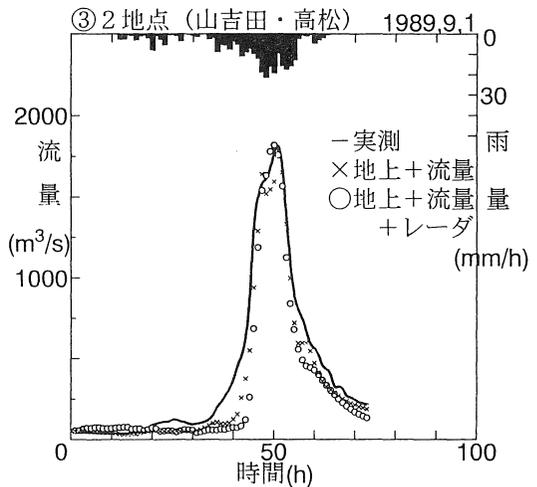


図 4.3.3 山吉田・高松を考えた場合

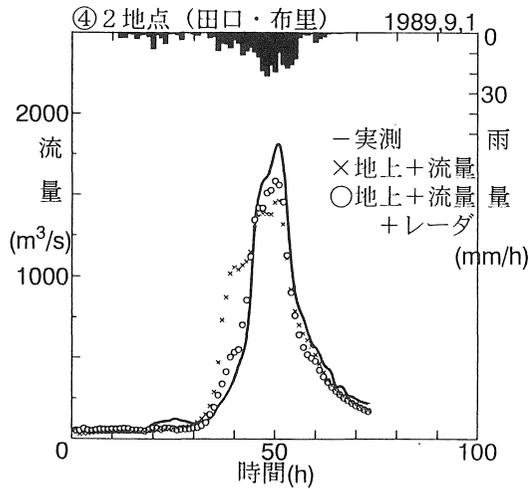


図 4.3.4 田口・布里を考えた場合

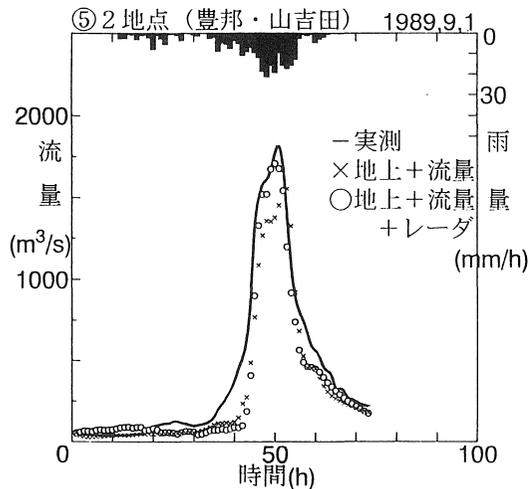


図 4.3.5 豊邦・山吉田を考えた場合

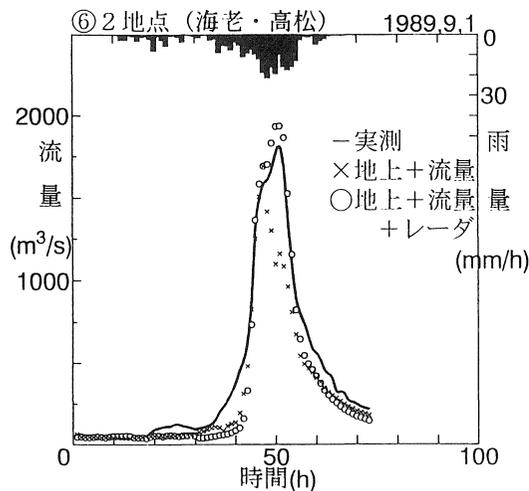


図 4.3.6 海老・高松を考えた場合

5. まとめ

流域内の地上雨量計の数が少ない場合や設置場所に偏りがある場合、雨量が観測できないところをレーダ雨量で補うことによりニューラルネットワークの流出予測の精度を向上させることが出来た。地上雨量計の数が少ない場合はネットワークの入力値のユニット数が少なくなり、学習機能がうまく働かなかったことから、ネットワークに入力する前処理の段階で工夫する必要がある。今回は、上流の流量を入力することにより好結果を得ることが出来た。今後の課題の一つとして、上流の流量を入力に使用せず、雨量と流量の関係のみで流出計算の精度向上を図ることが挙げられる。

参考文献

- 1) 富士通：ニューロシステムガイド, pp135~143, 富士通 東京 1991
- 2) 菊池豊彦：入門 ニューロコンピュータ, pp19~34, オーム社 東京 1990
- 3) 甘利俊一：ニューロコンピュータ読本 14, サイエンス社 東京 1989
- 4) 菅原正巳：流出解析法 pp1~24, 共立出版株式会社 東京 1972
- 5) 安藤大介：ニューラルネットワークによる流出計算, 1-10, 1993
- 6) 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計算, 1-8, 1994
- 7) 村井基浩：流出計算用ニューラルネットワークの学習用データの選択コスト, 1-10, 1995
- 8) 卒業研究：レーダ雨量換算定数 β 、 β の最適値の変動に関する研究 1-15, 1985
- 9) 卒業研究：レーダ雨量計による降雨観測結果の解析, 1-9, 1987
- 10) 卒業研究：レーダ雨量計を使った小流域の短時間洪水予測 1-9, 1995

(受理 平成 9 年 3 月 21 日)