

ニューラルネットワークによる 流出解析手法（日流量）に関する研究

阿部清明¹・菊池英明²・古川浩平³・塩月善晴⁴

¹学生会員 工修 山口大学大学院 システム工学専攻 (〒755-8611 山口県宇部市常盤台 2-16-1)

²正会員 工博 八千代エンジニアリング株式会社 東京事業部 水工部
(〒153-8639 東京都目黒区中目黒 1-10-23; 元山口大学助手 工学部社会建設工学科)

³正会員 工博 山口大学教授 工学部社会建設工学科 (〒755-8611 山口県宇部市常盤台 2-16-1)

⁴正会員 理博 山口大学教授 工学部社会建設工学科 (〒755-8611 山口県宇部市常盤台 2-16-1)

降った雨の一部は地下に浸透し、やがて地表に現れて河川の流量となる。どの程度浸透するのか、地下にどれだけ貯えられるのか、どのくらい時間が経過し地下から出てくるのか、いずれも、現状では正確なところを把握することは難しい。このように、自然環境において、地面に雨水がしみ込み流量に変わる過程をモデル化し流量を予測することは困難を極める。これらの解決策の一つとしてタンクモデル等の流出解析が挙げられる。本研究では明らかにが行った河川流域におけるタンクモデルと同一のデータを用いて、非線形な連続関数の近似に適したニューラルネットワークを使用し流出解析モデルを構築し比較する。そして、流出解析におけるニューラルネットワークの有用性を検討する。

Key Words : neural network, runoff analysis, daily stream flow, variance.

1. はじめに

日本は、アジアの東に位置し周囲を海に囲まれた島国であるため、梅雨や台風等の集中的な降雨に対して影響を受けやすい。1998年の8月から9月にかけて北陸、関東、四国地方等で記録的な豪雨が降り近年に見られないほどの河川の氾濫や浸水害等の甚大な被害が起こった。一方雨のあまり降らなかった地域では渇水のため水不足になった地方もある。国土利用においても、農地、森林、原野が減少し、宅地と道路が増加する等都市の土地利用が増加し都市部へ人口が集中している。その結果、洪水時の河川水位より低い沖積平野を中心として高度な土地利用が行われており、国土面積の約1割にすぎない河川の氾濫区域に人口の約50%、資産の約70%が集中している。このため、上流ではダムを設置、下流では堰、水門の設置等の治水事業が行われてきた。これにより、浸水面積は減少傾向にあるものの洪水等の危険地域における資産が増大しているため、災害による被害額はかえって増加する傾向にある。今日このように河川において様々な問題があり、河川利用や洪水氾濫防止のため、河川の固有の流出量を把握しておくことは重要なことである。

降った雨の一部は地下に浸透し、やがて地表に現

れて河川の流量となる。どの程度浸透するのか、地下にどれだけ貯えられているのか、どれくらい時間が経過し地下から流出してくるのか、いずれも、現状では正確なところを把握することは難しい。このように、自然環境において、地面に雨水が浸透し流出に至るまでの過程をモデル化することは困難を極める。

この日流量解析には一般にタンクモデル²⁾を基本とした流出解析モデルが構築されることが多いが、未だ経験的な試行錯誤によるパラメータの決定が主流であるため、多大な時間と熟練を要する。そのため、Visual Basicによるタンクモデルのエキスパートシステムの開発^{3), 4)}が行われているがタンクモデルのパラメータの設定にはある程度の熟練を必要としているのが現状である。タンクパラメータの同定法では小林、丸山⁵⁾によるPowellの共役方向法の適用、永井、角屋^{6), 7)}のSP法、SDFP法などの非線形計画法によるものやGA^{8), 9)}等を用いたタンクパラメータの自動決定方法等も提案されている。しかしながら非線形計画法では局所的な準最適解に陥りやすいことや、GA局所探索が十分行えないなどの問題があり、未だ実用化に至っていない。そこで、前述のように降雨から流出へ至る複雑で非線形性の強い現象を表現する解決策として、本研究ではニュー

ーラルネットワーク¹⁰⁾を用い流出解析を試みた。ニューラルネットワークは非線形性の強い連続関数の近似に適しているとともに、繰り返し計算による学習を行うことで機械的に最適モデルの決定が可能であり、タンクモデルのような熟練を必要としない。流出解析への階層型ニューラルネットワークの適用例をみると洪水時¹¹⁾、渇水時¹²⁾等に限定されたものが多く年間を通した長期流出解析を行った例は少ない。したがって、本研究では、大小2つのモデル流域を対象としニューラルネットワークを用いた流出解析モデルを構築し、タンクモデル法と同様のアプローチにより10年に及ぶ日流量データの流出解析を行う。そして、既存のタンクモデルによる解析結果と比較して流出解析におけるニューラルネットワークの適用性について述べる。

ニューラルネットワークでは教師データの良否が学習結果に大きく影響を与えることから、効率よく教師データを抽出する方法を提案し、対象流域の最適モデルを構築する。また、ニューラルネットワークは一般にブラックボックスとして取り扱われることが多いが、本研究では、ニューラルネットワークのシステム評価指標の1つである入力層と中間層間とのシナプスウェイト差¹³⁾によりシステム特性の評価を行いニューラルネットワークのシステム特性にある程度その流域の流出特性が反映されていることを示す。

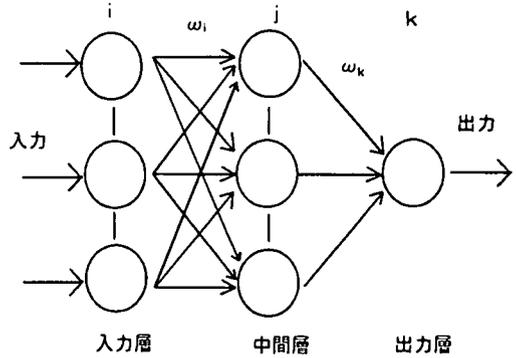


図-1 ニューラルネットワークの構造

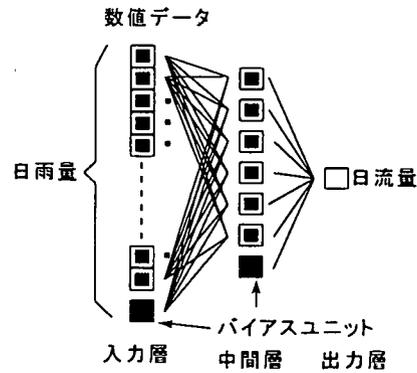


図-2 階層型ニューラルネットワークモデル

2. ニューラルネットワークを用いた流出解析システム

(1) ニューラルネットワークの概要

生物の脳の中には、数多くの神経細胞(ニューロン)が集まっており、個々のニューロンはシナプス結合と呼ばれるつながりによって回路を構成している。各ニューロンは数多くの他のニューロンからシナプスを通し正負両方の刺激を受け、その刺激があるしきい値をこえると、今度はそのニューロン自身が他のニューロンへと刺激を与えていき、情報を次々と伝達していく。一般に本研究等で用いるニューラルネットワークは、この脳の中で行われている情報処理作業を模擬したものであり、工学的に応用しようとして研究・開発されたシステムである¹⁴⁾。

ニューラルネットワークでは、従来のコンピュータアルゴリズムでは論理的な情報処理しかできなかったのに対し学習・記憶・判断といった直感的な処理作業が可能となっている。その最大の特徴は、非線形的な連続関数を近似することが可能であり、自らのパターン認識能力を高めることができることである。本研究では、パターン認識能力に優れ、定式化の困難な非線

形性の強い問題の評価や予測等に適している階層型ニューラルネットワークを用いる。ネットワークの構造は図-1に示すように入力層-中間層-出力層で構成され、各層にニューロンが複数存在している。また、中間層も複数層の存在が許される。本研究では、ニューロンの応答特性を表す入出力関数として、式(1)に示す代表的な関数であるシグモイド関数を用いる。

$$f(u_j) = \frac{1}{1 + \exp(-u_j)} \quad (1)$$

$$u_j = \sum_{i=1}^n \omega_{ij} x_i - \theta_j \quad (2)$$

ここに、 $f(u_j)$: ニューロンの出力値、 x_i : 入力値、 ω_{ij} : 重み付け係数、 θ_j : しきい値、 n : ひとつ前のユニット数 である。

一般にしきい値の取り扱いは、式(2)に示したとおりとなるが、本研究ではバイアス¹⁵⁾を用いる方法をとった。その方法は、しきい値(θ_j)を式(2)から除き、新たに常に1を値として持つ入力を加える。すなわち、入力の重み付き和($\sum_{i=1}^n \omega_{ij} x_i$)より、しきい値(θ_j)を引く代わりに新たに常に1を値として持つ入力

(x_0) に重み($\omega_0 (= -\theta)$)を掛けて、他の入力と同様に総和をとる方法であり、式(2)と同等の効果が得られる。この $\omega_0 x_0 (= -\theta)$ がバイアスと呼ばれている。このバイアスは、図-2示すように出力側へのユニットに刺激を伝達するのみとなる。以上示したように、バイアスユニットを用いることで式(2)は、次式(3)のように簡略化される。

$$u_j = \sum_{i=0}^n \omega_{ij} x_i \quad (3)$$

したがって、式(2)が示す一般的なしきい値の取り扱い方では学習は結合重みとしきい値の更新を別に考慮する必要があるのに対して、バイアスを用いることで式(3)が示すように結合重みの更新のみとなるためプログラムが簡単になり計算効率が良くなる。

また、学習法には誤差逆伝搬法(バックプロパゲーション法、以下BP法と略す)を使用し、誤差関数は式(4)に示す平均2乗誤差を使用した。

$$\text{誤差関数 } E = \frac{1}{2} \sum_{k=1}^{nc} (f(u_{k,c}) - y_{k,c})^2 \quad (4)$$

ここに $f(u_{k,c})$: ある入力パターン c を与えたときの実際出力値, $y_{k,c}$: 教師データ, nc : 出力ユニット数(本研究では $nc = 1$) である。

(2) モデル化と本研究への適応

ニューラルネットワークのモデル化において荒木ら¹³⁾の階層型ネットワークモデルの構造についての検討ではその構造は比較的単純なものが良く、むやみに複雑にすることはかえって逆効果になることが示されている。本研究においても中間層数を増やすことによる予測精度の向上が見られなかったこと、加えて、5章でのニューロン間のウェイト差の検討では、中間層が2層以上となるとウェイト差の評価が難しいことから本研究では図-2に示す入力層・中間層・出力層の3層からなる階層型ネットワークモデルを用いる。入力層には数日間の日雨量を、出力層には推定日の日流量を対応させ、これらの関係を学習させていく。このように本研究では、数日間の日雨量を入力データとし日流量を出力する入出力関係を一つのパターンとして扱うモデルとする。

ニューラルネットワークモデルを構成する中間層のニューロン数はシステム構築の過程で個数を数種変化させ計算した結果式(2)で示しているしきい値を含めた7個とした。以下様々な検討を行うにあたり中間層のニューロン数は7個として解析を行った。1つのニューロンの出力は、 $[0] \sim [1]$ の値であるため、入力データは全て、データの最大値が $[1]$ になるように標準化して用いる。また、3.(1)(b)で示すように理想

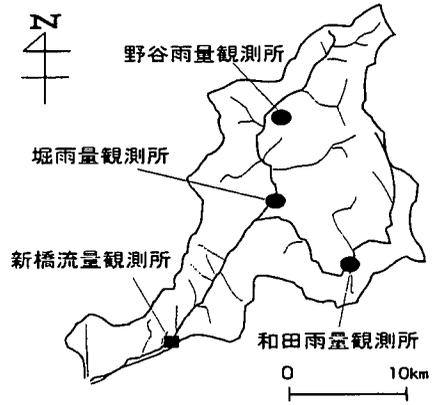


図-3 佐波川の流域図

出力値としての流量データはデータの性質上、常用対数化して用いる。学習過程における収束条件は、学習回数 10,000 の制約の下で平均2乗誤差: $E < 0.001$ とした。

解析においては雨量年表¹⁶⁾、流量年表¹⁷⁾のデータを使用し、日雨量データは mm/day 、日流量データは計算を行うためには標準化するので単位はあまり関係なく流量年表には m^3/s と載っている値のまま使用する。これは本計算が単純で機械的に行うことができるようにすることが本論文の目的のために、単純にできることを優先して計算を行うこととした。なお、解析結果は流出解析で一般的に使用されることが多い貯留高 (mm/day) で示し解析結果の検討を行う。

本研究では解析結果の評価指標は、実測日流量と計算日流量との相関係数(r)と式(5)に示す2乗平均平方根誤差(RMSE: 以下の論文において単純に誤差とする)を使用する。

$$\text{誤差(RMSE)} = \sqrt{\frac{1}{n} \sum_{i=1}^n (QO_i - QN_i)^2} \quad (\text{mm/day}) \quad (5)$$

QO_i : 実測日流量 (mm/day)

QN_i : 計算日流量 (mm/day)

3. モデル流域(小流域: 佐波川)での流出解析モデルの構築

(1) 佐波川の概況と使用データ

a) 佐波川の概況

佐波川は山口県のほぼ中央に位置しており、水源は島根県境の仏峠荷物湖で、佐波郡徳地町の中央部を南南西に走り、防府市の市街地西部を通り、瀬戸内海に注いでいる。流域面積は 446 km^2 、河川の流路延長 56 km 、河床勾配 $1/200 \sim 1/600$ の急流河川である。図-3に佐波川における雨量及び流量観測所を示す。

表-1 佐波川のデータの状況 (雨量 (堀), 流量 (新橋))

年	実測年間雨量 (mm/year)	実測年間流量 (mm/year)	流出係数	最大日流量 (m ³ /s)	日流量 の分散
1985	2747.9	2,090.8	0.7609	638.52	3,555.4
1986	2242.7	1,794.9	0.8003	446.59	1,821.2
1987	2063.0	1,709.4	0.8286	300.89	863.4
1988	1526.4	921.2	0.6035	130.07	255.3
1989	1972.4	1,304.5	0.6614	378.62	981.3
1990	2265.2	1,435.8	0.6338	325.43	745.9
1991	2339.8	1,738.4	0.7430	331.76	896.4
1992	1615.2	1,017.4	0.6299	173.27	267.1
1993	2765.8	2,312.4	0.8361	287.87	2,510.5
1994	1308.3	808.4	0.6179	168.01	278.8
85-94	20,846.7	15,133.2	0.7259	638.52	1,257.1

b) 解析で使用するデータとデータの基準化

解析期間は、1985年～1994年までの10年間とし、解析単位は日単位とする。表-1に佐波川の日流量データの状況を示す。表-1の右端には実測日流量の1年ごとの分散を示す。

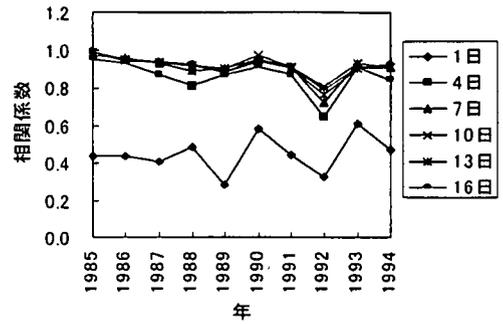
ニューラルネットワークの入力日雨量データは、10年間の雨量データの最大値である208.70 (mm/day) で基準化した値を用いる。出力データは、10年間の流量データを全て常用対数化し、それらの中での最大流量値である638.52 (m³/s) の常用対数で全データを基準化する。これは日流量データのほとんどが200 (m³/s) 以下であるため最大値638.52 (m³/s) のままで基準化を行うと、学習データの分布に偏りが生じてしまうためである。

(2) 基本モデルの構築 (10年間予測)

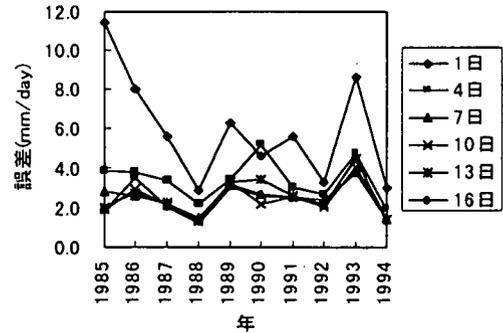
一般にタンクモデル法等を用いて、本研究で対象とするような10年間の流出解析を行う場合、1年間分から数年間分のデータによりタンクモデルのパラメータを設定し、10年間の計算流量と実測流量との適合度により最終的な流出モデルの決定が行われる。このことから、本研究では、まず1年間分の教師データによりニューラルネットワークモデルを構築し、この教師データを含む10年間の計算流量と実測流量との適合性により流出解析モデルを構築する。

a) 仮入力日数の検討

一般に当日の流量には何日か前からの雨量が影響していると考えられる。そのためシステムの構築には当日の雨量を含め何日か前 (n日前) までの雨量を入力することが有効であると考えられる。しかし、実際にどれだけ前からの雨量を入力することが妥当であるか明らかではないため1日、4日、7日、10日、13日、16日分の入力日雨量の幅で解析を行い、これ以降のシステム構築の過程での目安となる仮の入力日数を決定



(a) 相関係数



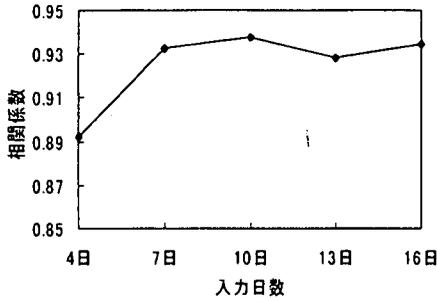
(b) 誤差

図-4 仮入力日数の設定のための解析結果

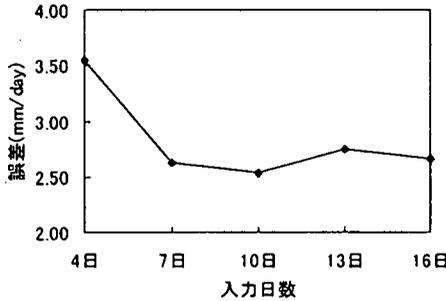
する。その際、学習期間を85年のみとし1985年～1994年の10年間の計算流量と実測流量との比較により、仮入力日数を定めることとした。各入力日数による実測日流量と計算日流量の(a)相関係数、(b)誤差の経年変化を図-4に示す。相関係数、誤差ともに1日(当日)の雨を入力したものでは他の5例より非常に悪い結果となっている。入力日数4日では表-1の年間流量が大きい1985年、1993年ではそれほど違いが見られないが年間流量が少ない1988年、1992年、1994年等で相関係数が悪くなっている。図-4(b)より7日以上を入力日数が全体的に良い結果を示している。図-4では入力日数が7, 10, 13, 16の違いが明確でないので図-5に入力日数4～16日の10年間の(a)相関係数、(b)誤差の平均値を示す。図-5(a), (b)より、相関係数、誤差の値が平均的によい入力日数10日を仮入力日数とする。

b) 各年学習における基本モデルの構築と特徴

前節で決定した入力日数10日を使用し、1985年～1994年の各1年分を教師データとして用い10年間に適応し教師データの違いによる流出解析結果の特徴を分析した。各学習年全ての相関係数、誤差を図-4のように表示すると非常に煩雑になり分かりにくいので、10年間の(a)相関係数、(b)誤差の平均値のみを図-6に示す。

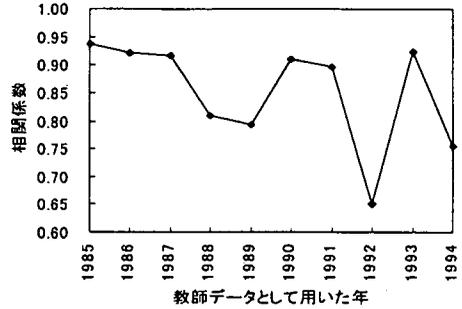


(a)相関係数

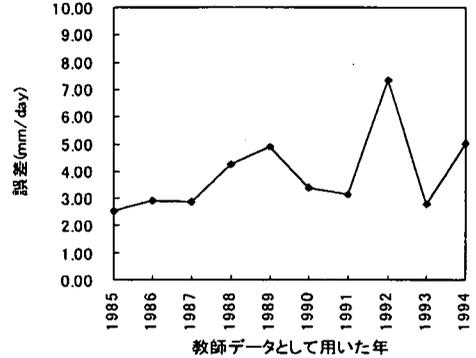


(b)誤差

図-5 仮入力日数設定のための解析結果 (10年間の平均)



(a)相関係数



(b)誤差

図-6 各年学習の解析結果 (10年間の平均)

図-6(a)より相関係数は、1985年、1986年、1987年、1990年、1991年、1993年のデータを学習して解析した場合の結果は0.9以上と良好な値を示しているが、1988年、1989年、1992年、1994年を学習した場合は相関係数が低く、特に1992年のデータによる結果は0.65を下回り非常に低い。図-6(b)より誤差も相関係数の状況と同じ傾向を示しており、1992年が最も悪いことを示している。しかし、後に(3)d)で示すが佐波川でのタンクモデルによる流出解析¹⁾では、相関係数が0.814であり、本モデルでは、1989、1992、1994年以外の学習年では0.8以上の相関係数が得られており適切な学習年を選ぶことで非常に高い精度の日流量解析が可能であることを示している。

ここで予測精度と佐波川のデータの状況を比較すると、相関係数が高く予測精度の良い3カ年では相関係数の高い順(1985、1993、1986年)に表-1 実測年間雨量、実測年間流量、最大日流量、分散ともに大きな値を示している。また、相関係数が最も低い1992年では10年間で2番目に分散が小さく、実測年間雨量、実測年間流量、最大日流量はそれぞれ3番目に小さい。以上のことから、実測年間雨量、実測年間流量、最大日流量、分散の各指標の大きな年を教師データとする方が、流出解析の精度が高くなることが分かる。

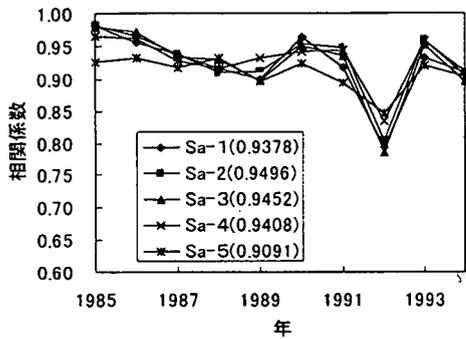
(3) 基本モデルの精度向上手法の検討

a) 教師データ抽出方法の検討

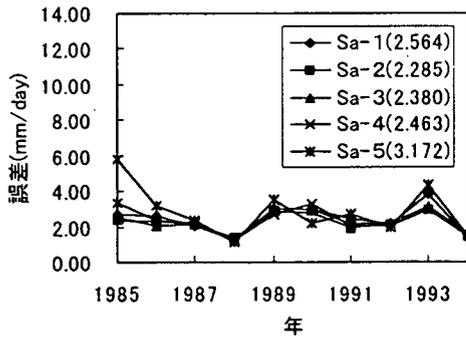
ニューラルネットワークによりシステムを構築する際、上述のように教師データの良否が、予測結果に大きく影響する。また、同じようなデータを集中的に学習してしまえば偏ったシステムとなる可能性が大きい。このことから本研究では、(2)(b)の結果を参考に分散の大きい年を基準にデータの抽出方法の検討を行う。表-1に示した流量データの年間の分散が大きい年から数年間分を教師データとして抽出することとし、以下の5ケースについて検討を行った。

- Sa-1: 教師データ1年分 (1985年)
- Sa-2: 教師データ2年分 (1985、1993年)
- Sa-3: 教師データ3年分 (1985、1986、1993年)
- Sa-4: 教師データ4年分 (1985、1986、1989、1993年)
- Sa-5: 教師データ10年分 (1985~1994年)

図-7にSa-1~Sa-5の1985~1994年全ての(a)相関係数、(b)誤差を示す。図中凡例のかっこ内の数字は10年間の平均値である。図-7(a)によるとSa-1~Sa-5のいずれのケースも1992年を除き相関係数は0.9以上と高い値を示している。Sa-1~Sa-4では、ほと

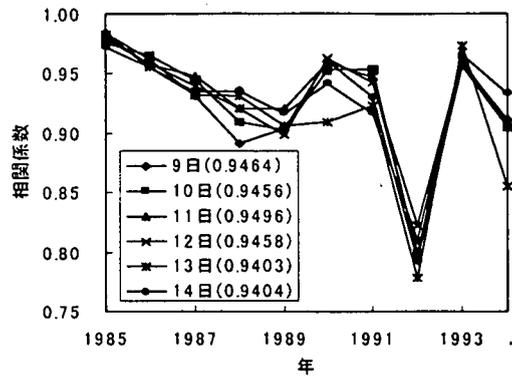


(a)相関係数

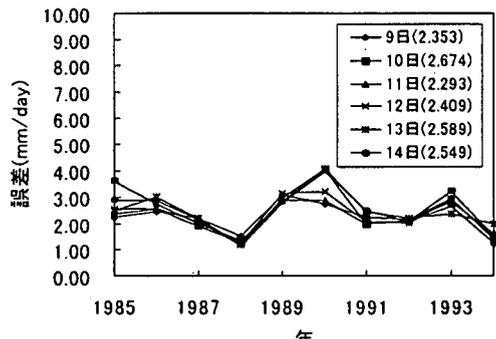


(b)誤差

図-7 教師データのケース別解析結果 (Sa-1~Sa-5)



(a)相関係数



(b)誤差

図-8 佐波川の最適入力日数の決定

んど相関係数の変化に違いが見られないことが分かる。また、Sa-5は10年間全てを教師データに用いたにも関わらず他のケースに比べ相関係数が若干低くなっている。図-7(b)を見るとSa-5の1985年で他のケースと比べ誤差が大きいものの、全般的にはほとんど差が見られないことが分かる。そこで10年間の平均値を見るとSa-2の相関係数が0.9496、誤差が2.285と最もよい結果を示している。またSa-3~Sa-5と教師データの年数が増えるにつれ10年間の相関係数の平均値が悪くなっている。これらのことから、佐波川においての最適学習年数は2年が妥当であると考えられる。

b) 最適な入力日数の決定

前節の結果により、佐波川では教師データとして分散の大きい2年分を使用することが有効であると考えられる。本システムをより最適なシステムにするために入力日数の詳細な検討を行った。前節までに目安として用いた10日を含め9, 10, 11, 12, 13, 14日の7ケースについて検討を行う。

図-8に入力日数を変えた時の相関係数、誤差の変化を示す。図中のかつこ内の数字は図-7同様に10年間の平均値である。年度毎に見ていくと相関係数では1988, 1990年、誤差は1990年を除きほとんど違いが見られないが、10年間の平均を見ると11日が相関係数と誤差ともにより結果を示している。よって佐波川に

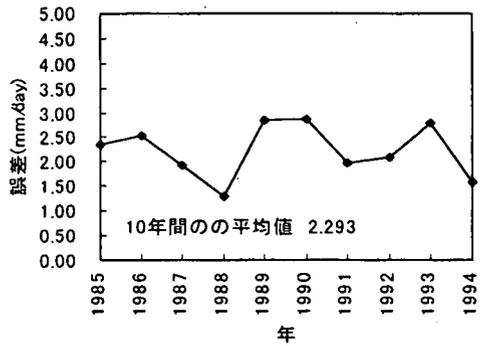
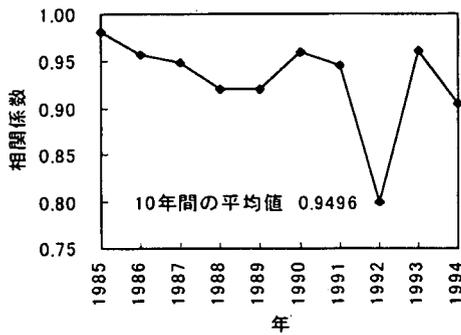
おいては日雨量の入力日数を11日と決定する。

c) 最適モデルでの特性評価

図-9に最適モデルでの(a)相関係数、(b)誤差の変化状況を示す。図-9(a)より相関係数は、1992年で約0.80と低い値を示しているが、その他の年では、0.9以上と高い相関係数が得られており、10年間の平均値も0.9496と非常に高い値である。図-9(b)より、誤差も極端な年変動はなく良好であると考えられる。

また表-1の年間流量の変動と図-9の相関係数、誤差の状況を比較すると、相関係数が悪い年は、年間流量、分散が小さい傾向がみられ、誤差が大きくなる年は年間流量、分散が大きい傾向がみられた。

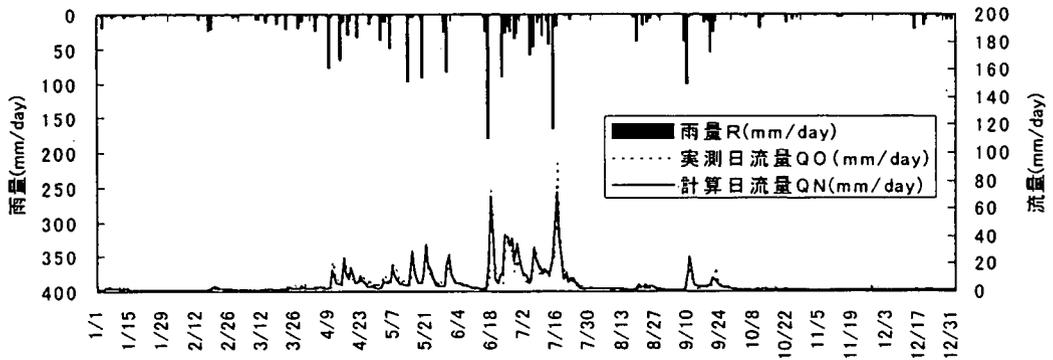
図-10に最適モデルでの流出予測結果のハイドログラフを示す。図-10は横軸に日付け、縦軸左に雨量、右に流量の軸を示す。図の上側にハイドログラフ、下側に点線で実測日流量、実線で計算日流量を示す。図-10(a)は未学習の年では分散が最も大きく最大日流量も大きい1986年の解析図、図-10(b)は分散が最も小さく最大日流量も最も小さい1988年のものである。図-10(a)の分散が大きく流出量も大きい年と図-10(b)の分散が小さく流出量も小さな両極端な流出特性を示している年にも関わらず、計算流量のハイドログラフは実測流量とほぼ同じであり非常に良好な結果を示して



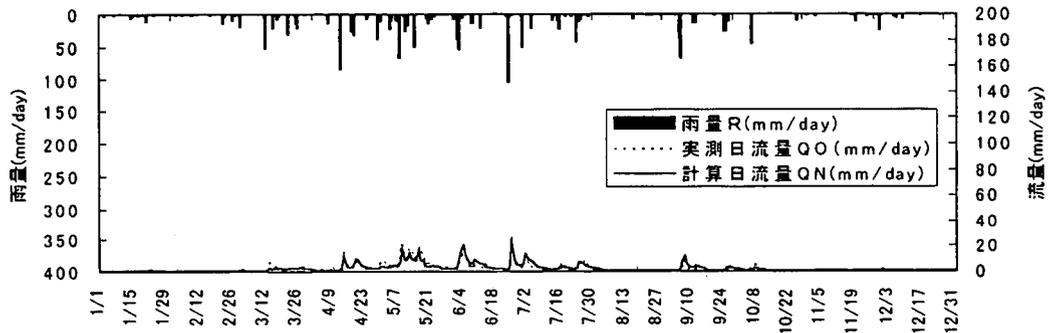
(a)相関係数

(b)誤差

図-9 佐波川の最適モデルによる解析結果



(a) 1986年



(b) 1988年

図-10 最適モデルによる流出解析解析図

いることが分かる。図-10(a), (b)をみると年間で多雨期、少雨期と雨の降り方は違うが両図とも計算流量は実測流量をうまくとらえている。

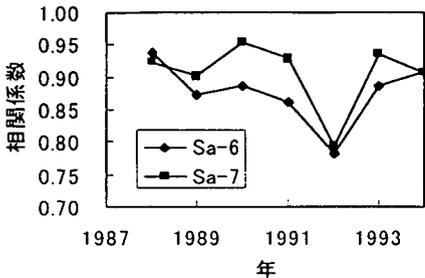
d) タンクモデルとの比較

梢ら¹⁾におけるタンクモデル法による佐波川の同期間の流出解析結果では相関係数は0.814である。また同参考文献¹⁾におけるタンクモデル法による他の一級河川(8流域)の解析結果による相関係数は0.817から0.666を示している。

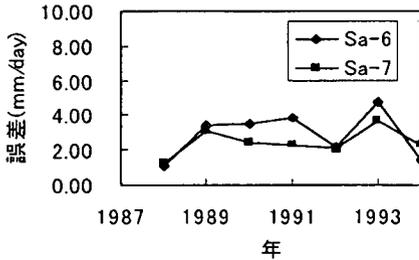
今回行ったニューラルネットワークによる流出解析では10年間の相関係数の平均値は0.9496と非常に高い値を示しており、相関係数のみの比較ではあるがタンクモデル法に比べ非常に良好な流出解析結果であることが分かる。

(4) 年度更新型モデルの検討

実際の流域の形態は流域内の生活形態の変化、河川工事、森林伐採等により年々姿を変えており、また流量



(a)相関係数



(b)誤差

図-11 年度更新型モデルの検討 (Sa-6, Sa-7)

データは年々蓄積されている。このことから、流出予測を実際に行う場合、流出モデルの固定は行わず前年までのデータより最適な教師データを抽出しモデルを構築し、翌年の流量を予測することが望ましいと考えられる。すなわち、年度毎に教師データを更新するモデル（以下年度更新モデル）を構築する必要がある。前節の結果を考慮すると最適な教師データとして、前年までのデータの中から、年間の観測流量の分散の大きい、2年間のデータを用いることが有効であると考えられる。また、最も簡単な教師データの抽出方法として、前年までの最近の2カ年のデータを用いることが上げられる。以上のことから、次の2ケースについて年度更新モデルについての検討を行った。

Sa-6: 教師データを直前の2年分とする

Sa-7: 教師データを過去の分散最大2年分とする

図-11にSa-6, Sa-7の(a)相関係数, (b)誤差を示す。図-11には教師データが3年以上得られる1988年より示している。図-11(a)より、相関係数ではSa-7のほうが全般的により高い値を示しており、Sa-6がSa-7より上回っているのは1988年のみである。図-11(b)より、誤差も全般でSa-7のほうが小さい値を示しており、Sa-6がSa-7より下まわっていて良い値を示しているのは1993年のみである。このように年度更新モデルにおいても直前の2年を教師データとするより、過去のデータより分散が大きいものから2年分を選んで教師データとして学習させた方が有効である。

表-2 川内川のデータの状況 (雨量 (入来), 流量 (釜淵))

年	実測年間雨量 (mm/year)	実測年間流量 (mm/year)	流出係数	最大日流量 (m ³ /s)	日流量 の分散
1985	2512.9	1,963.2	0.7813	917.14	7,247.7
1986	1809.9	1,465.5	0.8097	524.14	4,613.1
1987	2836.2	1,964.2	0.6926	1,797.65	20,776.1
1988	2015.3	1,569.2	0.7787	673.81	7,432.2
1989	2109.3	1,876.2	0.8895	1,797.65	12,567.0
1990	2541.6	1,644.4	0.6470	2,757.47	38,107.6
1991	2512.9	1,880.4	0.7483	1,032.13	12,501.0
1992	2135.8	1,103.8	0.5168	1,231.59	6,515.3
1993	4661.0	3,359.6	0.7208	2,013.27	55,929.1
1994	1830.0	687.7	0.3758	409.44	1,378.9
85-94	24964.9	17,514.3	0.7016	2,757.47	17,318.6

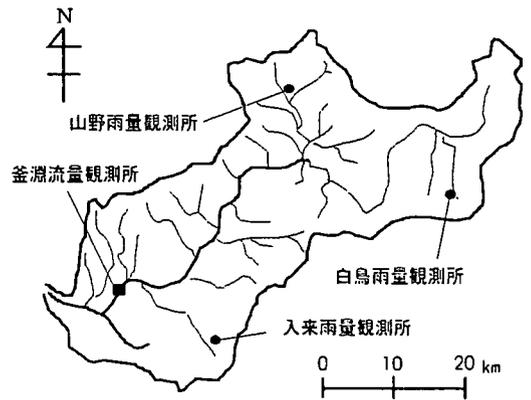


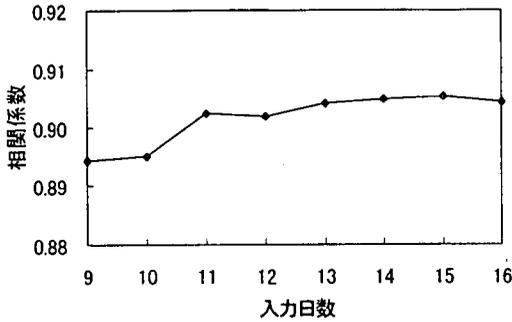
図-12 川内川流域図

4. 大流域 (川内川) における流出解析システムの構築

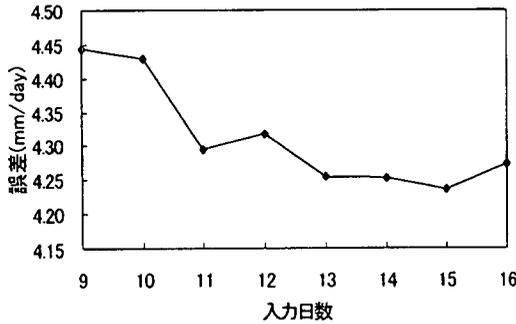
(1) 川内川の概況と使用データ

川内川は九州南西部に位置し、鹿児島、宮崎、熊本の3県にまたがる。水源は熊本県の白髪岳に発し、宮崎県西諸県盆地 (加久藤平野) を西流し、鹿児島県入り吉松狭榨部、湯之尾滝を経て、伊佐盆地で支川羽月川を合流し、景勝曾木の滝から鶴田ダムへ流入しその後宮乃城狭榨部、川内平野を貫流し、東シナ海へ注いでいる。流域面積は 1,600km²、河川の流路延長は 137 kmで、年間降水量 2,700 mmに達する多雨地域となっている。図-12 に川内川における雨量及び流量観測所を示す。

解析期間は1985年から1994年の10年間である。解析対象となる川内川の流量データの状況を表-2に示す。基準化に用いる最大日雨量は 430.5 (mm/day)、最大日流量 2148.16 (m³/s) である。

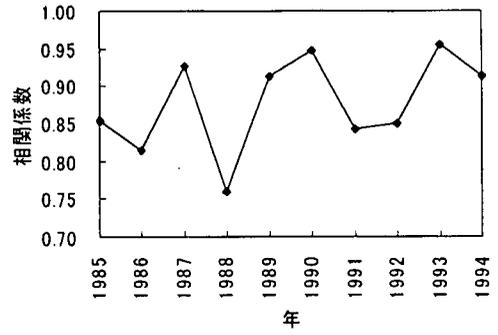


(a) 相関係数

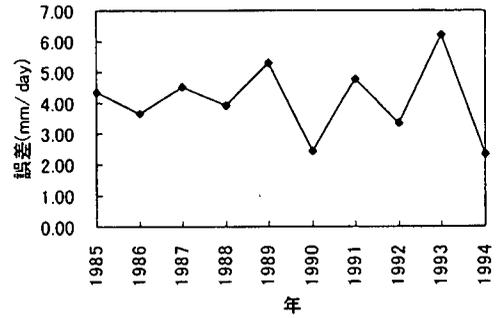


(b) 誤差

図-13 川内川の入力日数決定のための解析結果



(a) 相関係数



(b) 誤差

図-14 川内川を最適モデルで解析を行ったときの解析結果

(2) 川内川の基本モデルの構築

a) 最適な入力日数の決定

教師データには佐波川で決定した基本モデルと同様に表-2より分散の大きい1990, 1993年の2年分を使用し, 10年間の流出解析を行い最適な入力日数の決定を行う。川内川は佐波川より流域面積が大きいことから佐波川での解析結果を参考に9, 10, 11, 12, 13, 14, 15, 16日としてシステムの検討を行う。各入力日数の結果を佐波川と同様(図-8参照)に全て示すと明確な差が認められず非常にわかりにくいので, 10年間の平均のみを図-13に示す。図-13より入力日数15日が相関係数と誤差ともにより結果となっている。よって川内川においては日雨量の入力日数15日が妥当であると考えられる。

b) 基本モデルによる流出解析

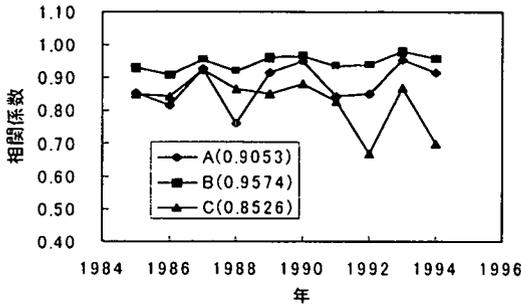
図-14に入力日数15日としたときの(a)相関係数, (b)誤差を示す。図-14(a)より, 相関係数では1993, 1990年は0.95と非常に高い値を示しているが, 図-9(a)に示した佐波川の例に比べ変動が激しいことが分かる。図-14(b)より誤差についても変動が激しいことが分かる。

ここで10年間の年間流量の変動と相関係数, 誤差の状況を見ると佐波川同様, 流量の分散の大きい年は相関係数が高く, 分散が小さい年では誤差が小さくなる

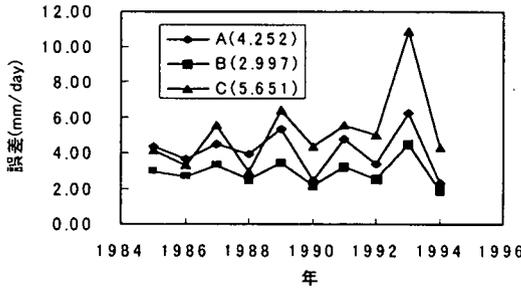
傾向がみられた。10年間の平均値は相関係数では0.9053, 誤差は4.252となった。佐波川の基本モデルの10年間平均値は相関係数0.9496, 誤差2.293であり, これと比較すると川内川の方がかなり精度は劣っている。しかし, 流域面積を比較すると佐波川における新橋流量観測所での流域面積は432.1km², 川内川における斧淵流量観測所での流域面積は1,348km²と川内川が約3倍大きく, 日最大流量についても佐波川は638.52m³/s, 川内川は2,757.47m³/sと川内川の方が非常に大きくなっている。これらのことを考慮すると同じ1雨量観測所における結果としては非常に満足のいくものであると考えられる。現実には流域が大きくなると一つの雨量観測所では流域全体の雨を代表することは難しく, 精度が低下したと考えられる。したがって, 次節では雨量観測所が複数存在する場合の精度向上手法について検討する。

(3) 複数の雨量観測所を用いた精度向上手法の検討

これまでに述べたニューラルネットワークによる流出解析システムの構築では各河川の雨量観測所を1カ所に限定して解析を行った。しかし実際の流域には複数個の観測所が存在し, これらのデータを有効に利用することが望ましい。また, 前章の結果より1ヶ所の雨量観測所では流域が大きくなると流出解析精度に限

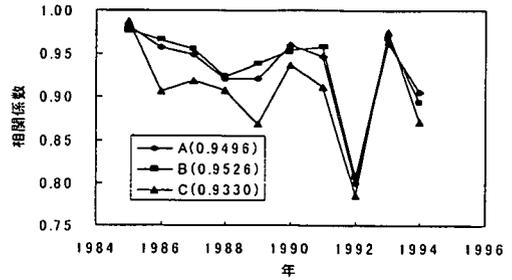


(a)相関係数

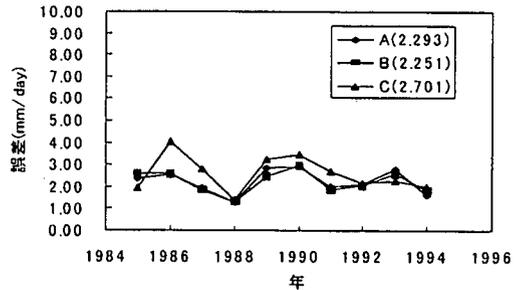


(b)誤差

図-15 川内川で雨量を3カ所入力したときの解析結果



(a) 相関係数



(b) 誤差

図-16 佐波川で雨量を3カ所入力したときの解析結果

界があると思われる。

本節では複数の雨量観測所のデータが存在する時の解析方法について述べる。ネットワークモデルの基本構造は、システムの簡素化のため前節までと同様とする。教師データは分散の大きい年2ヶ年とし、10年間の流量予測により最適モデルの検討を行う。なお対象雨量観測所数は3観測所とする。

複数の雨量観測所がある場合、実際には様々な平均化が行われるが、本研究では単純平均による方法およびニューラルネットワークの入力層のニューロン数には基本的に制約がないことから3カ所のデータを単独に並列に並べ入力する方法とを用いる。したがって本研究のように3雨量観測所のデータを用いる場合、しきい値ニューロンを除く入力層のニューロン数は、1観測所の3倍となる。以下に検討ケースを示す。

Case-A : 1 観測所 (前節までの基本モデル)

Case-B : 3 観測所 (単純平均)

Case-C : 3 観測所 (並列入力)

a) 川内川の場合

図-15 に川内川での Case-A~Case-C の (a)相関係数, (b)誤差を示す。凡例のカッコ内の数字は10年間の平均値である。学習データは1990年, 1993年である。図-15より Case-A, Case-B に比べ Case-C が相関係数, 誤差ともに全体的に悪い値を示している。1観測所の

みを使用した Case-A に比べ3観測所の単純平均を用いた Case-B が相関係数, 誤差ともに全般的に良好な結果を示している。10年間の平均値で比較すると相関係数, 誤差ともに Case-B が良い値を示しており, 相関係数 0.9574, 誤差 2.997 と小流域の佐波川で得られた結果と同等の非常に高い精度での流出解析結果が得られている。このように大流域では, 複数の雨量観測所のデータを用いることで, 解析精度の向上がみられた。

b) 佐波川の場合

川内川では, 複数の雨量観測所のデータを用いることにより解析精度の向上がみられたことから, 佐波川についても同様の手法により精度向上を試みる。図-16 に佐波川での Case-A~Case-C の (a)相関係数, (b)誤差を示す。凡例のカッコ内の数字は10年間の平均値である。なお学習データは, 1985年, 1993年である。図-16を見ると Case-A, Case-B に比べ Case-C が相関係数, 誤差ともに全体的に悪い値を示している。Case-A, Case-B では相関係数, 誤差ともにほぼ同じ値で推移しているが, 10年間の平均値を見ると相関係数, 誤差ともに若干であるが Case-B の方が良い値を示している。このように佐波川では, 3観測所のデータを単純平均して用いることで若干の精度向上が見られるものの, 精度的には1観測所で十分な結果が得られた。

ここで, 単純に流域面積と観測所数の関係と比較すると, 佐波川では 432.1km²の流域面積に対して1観測所で十分な結果が得られたのに対して, 川内川の流域

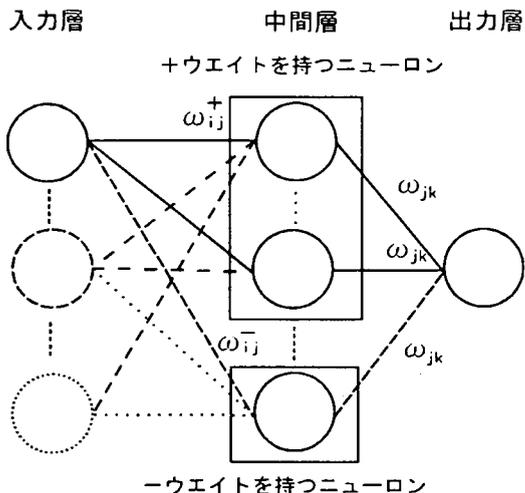


図-17 ニューロンのシナプスウエイト差の概念図

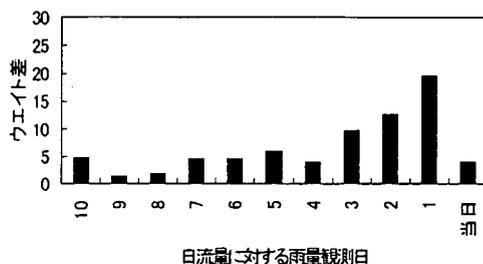
面積は 1348km² と佐波川の約 3 倍程度有るため、1 雨量観測所で流域全体の雨量を代表させることは難しく 3 観測所の日雨量データが必要であると考えられる。このことは、今回対象とした流域では、400km² に一箇所程度の雨量観測所で十分な予測精度が得られることを示している。

5. システム特性からみた流域特性の把握

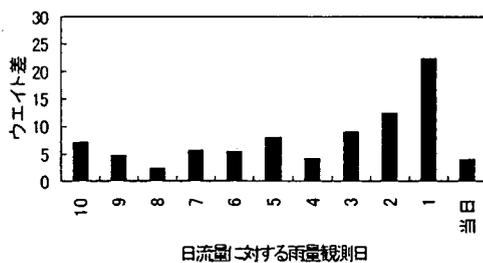
(1) ニューロンのシナプスウエイト差

本研究により構築したニューラルネットワークによる流出解析システムのシステム特性と流域特性を知る指標としてニューロンのシナプスウエイト差¹³⁾を用いる。ニューロンのシナプスウエイトとは、入力層と中間層または中間層と出力層のニューロンとを連結しているシナプスの結合の強さである。

ここで、図-17 に示すネットワークモデルにおいて、出力層のニューロンに着目すると、そのニューロンと中間層ニューロンとのウエイトは正または負の値を持つ。ここで、正值の中間層のニューロンは、出力値が大きければ大きいほど、負値の中間層のニューロンは出力値が小さければ小さいほど出力層のニューロンの値は大きくなる。そこで、式(6)に示す正值を持つ中間層ニューロン ($\omega_{jk} > 0$) に連結している入力層とのウエイト (ω_{ij}^+) の総和と負値を持つ中間層ニューロン ($\omega_{jk} < 0$) に連結している入力層とのウエイト (ω_{ij}^-) の総和の差を出力 (流量) ニューロンに影響を与えるシナプスウエイト差 (以下ウエイト差) とする。



(a) 堀雨量観測所



(b) 3 雨量観測所平均

図-18 佐波川でのウエイト差の検討

$$\Delta\omega_i = \sum_{j=1}^n (\omega_{ij}^+) - \sum_{j=1}^n (-\omega_{ij}^-) \quad (6)$$

i : 日流量に対する入力日雨量観測日

j : 中間層ニューロンの番号

k : 出力層

したがって、このウエイト差 $\Delta\omega_i$ が大きい n 日前の雨量が日流量に対する影響度が大きい可能性が高いと考えられる。

(2) 流出解析モデル特性の評価

a) 佐波川の場合

日雨量の入力日数 11 日の基本モデルにおけるシナプスウエイト差の算定を行い、システム特性及び流出特性の評価を行う。

図-18 に 1 観測所の雨量を用いた場合と、3 観測所の平均雨量を用いた場合の予測当日から、10 日前までの入力雨量に対するウエイト差を示す。図-18 (a), (b) を比較すると 1 観測所の雨量を用いた場合と、3 観測所の平均雨量を用いた場合のウエイト差は非常に似通っていることが分かる。したがって佐波川の場合 1 観測所のデータにより、十分な流出解析精度が得られたと考えられる。図-18 (a) の 1 観測所でのウエイト差をみると、当日の日雨量より 1 日前～3 日前の日雨量に対するウエイト差が非常に大きく、7 日前までのウエイト差は当日のものとは比べ大きいことが分かる。これは、

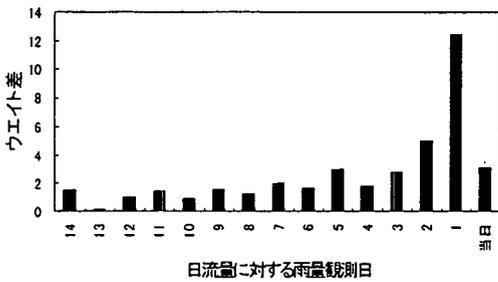


図-19 川内川での3観測所平均によるウエイト差の検討

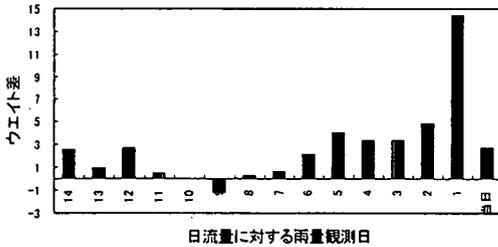


図-20 川内川での入来雨量観測所によるウエイト差の検討

予測日の日流量には前日の日雨量が大きく影響し、それ以前になると徐々に影響度が小さくなることを示しており、一般的な認識と良く一致した傾向を示していると考えられる。

b) 川内川の場合

日雨量の入力日数 15 日の基本モデルにおけるウエイト差の算定を行い、システム特性の評価及び流出特性の評価を行う。図-19 に 3 観測所の平均雨量を用いた Case-B のウエイト差を示す。図-19 より川内川においても前日の日雨量が日流量に最も影響し、ついで 2 日前の日雨量が影響していることを示している。全般的には前日より過去にさかのぼるに伴い影響度が小さくなっていることを示している。また佐波川に比べ入力日数が長くウエイト差も 8 日前～14 日前までほぼ同等の影響度を示しており、佐波川のウエイトの差が大きかったのが 1 日前から 3 日前であったのに対して影響範囲が長いことを示している。

次に、図-20 に Case-A の 1 観測所 (入来観測所) の雨量のみを用いた場合のウエイト差を示す。図-20 をみると予測日の 7 日から 11 日のウエイト差が極端に小さくなっており、図-19 と異なっていることが分かる。

6. おわりに

本研究では、日雨量、日流量を用いてニューラルネ

ットワークを適用し流出解析を行い、日単位流出解析システムの構築を試みた。その際、教師データの抽出方法、最適学習年数、複数の雨量観測所があるときの雨量データの入力方法について検討することにより予測システムの精度向上をはかった。以下にその結論を列記する。

- 1) 流出解析システムを構築する上で、年間の日流量の分散を指標として用い、分散が大きい 2 ヶ年を教師データとして用いることにより高い精度で流出解析システムの構築が可能である。
- 2) 日流量に対する日雨量入力日数は佐波川で 11 日、川内川で 15 日が最適であることが分かった。
- 3) 本研究により構築された流出解析システムでは対象とした 2 流域においては、降雨の大小に影響されることなく高精度の日流量予測結果が得られた。
- 4) 実際の運用を考慮した年度更新モデルにおいても予測対象年より過去の流量データの分散が大きくな 2 ヶ年のデータを用いることで高精度な流量予測が可能である。
- 5) 本研究で対象とした佐波川、川内川においては、400 km²に 1 ヶ箇所程度の雨量観測所を用いれば精度の良い予測が可能となった。
- 6) 複数の雨量観測所のデータを用いる際には、複数の観測所データを入力層に単純に並列で並べ入力するより、複数の観測所雨量を平均した雨量を入力する方が有効である。
- 7) ネットワークのウエイト差により入力日数内の日雨量の影響度を評価した結果、佐波川、川内川の両河川において予測日当日より 1 日前の雨が最も大きく影響し、それから日数がさかのぼるにつれて影響が弱くなっていることが示された。

一般にニューラルネットワークによる解析ではそのシステムはブラックボックスとして取り扱われることが多い。しかし、シナプスウエイト差によるシステムの評価では、それぞれの流域において、入力雨量の影響が一般的な常識に近い形でシステムに反映されていることが明らかになった。このことはニューラルネットワークを用いて、流出解析を行うことの妥当性を示唆しているものと考えられる。

また、本流出解析システムは教師データを 2 年とし入力日数を変化させるだけで機械的に流出予測が行えるので特殊な熟練が不要で、非常に簡便で有効なシステムであると考えられる。

このように、ニューラルネットワークを用いることにより、高精度で日流量解析が可能であることが分かった。

しかし、本研究では大・小 2 流域での適用結果であ

るため、今後多くの流域に適用し、流域の特性に応じたモデルの構築手順の確立を行う予定である。特に地質、地下構造等の異なる流域では流域の大小に関係なく流下時間が異なることが予想されることから特に注意が必要であると思われる。また、本研究では、複数の観測データを用いる場合の降雨データの入力形式の検討を行ったものであり、降雨データの平均化の手法についても別途検討が必要である。

謝辞：本論文の作成にあたり、データ収集の際に建設省佐佐川工事事務所の方々の協力を頂きました。深く感謝の意を表します。

参考文献

- 1) 梢満夫, 酒井純子, 塩月善晴: 西日本地域一級河川のタンクモデル解析, 土木学会中国支部研究発表会発表概要集, 第49回/II-52, pp. 221-222, 1997. 6.
- 2) 菅原正巳: 流出解析法, 共立出版, pp. 257, 1972.
- 3) 本釜耕一, Merabtene, T., 神野健二: Visual Basicを用いたタンクモデルのエキスパートシステムの開発, 土木学会西部支部研究発表会講演概要集, II-23, pp. 188-189, 1997. 3.
- 4) Merabtene, T. and Jinno, K.: Development of an Expert system for Tank model by using visual basic, 土木学会西部支部研究発表会講演概要集, II-24, pp. 190-191, 1997. 3.
- 5) 小林慎太郎, 丸山俊輔: Powellの共役方向法によるタンクモデル定数の探索, 農業土木学会論文集, 第65号, pp. 42-47, 1976.
- 6) 永井明博, 角屋睦: 流出モデル定数の最適化手法, 京都大学防災研究所年報, 第22号B-2, pp. 209-224, 1976. 4.
- 7) 永井明博, 角屋睦: タンクモデルの最適同定法に関する基礎的研究, 京都大学防災研究所年報, 第23号B-2, pp. 239-247, 1980. 4.
- 8) 田中丸治哉: 遺伝的アルゴリズムによるタンクモデル定数の同定, 京都大学防災研究所年報, 第36号B-2, pp. 231-239, 1993. 4.
- 9) 鈴木誠, 百田博宣, 神野健二, 河村明: GAを用いたタンクモデル同定に関する統計的検討, 水工学論文集, 第42巻, pp. 115-119, 1998. 2.
- 10) 矢川元基: ニューラルネットワーク, pp. 191-196, 培風館, 1992. 5.
- 11) 藤間総, 外山かおり, 大坂忠史: ファジィ・ニューラルネットワークを用いた洪水流出実時間予測, 水工学論文集, 第42巻, pp. 173-178, 1997. 2.
- 12) 長尾正志, 田沢孝和, 佐野正嗣, 鈴木正人: ニューラルネットワークと情報量基準による渇水期日流量予測の研究, 水工学論文集, 第40巻, pp. 359-364, 1996. 2.
- 13) 荒木義則, 鈴木昌次, 宮崎智司, 日永田雅司, 古川浩平, 中川浩二: ニューラルネットワークを用いた NATM 施工時の志保パターン選定構造のモデル化に関する研究, 土木学会論文集 No. 522/VI-28, pp. 143-153, 1995. 9.
- 14) 土木学会構造工学委員会: 新しい構造システム最適化手法—人工生命技術の応用—, 土木学会構造工学委員会, pp. 3-14, 1996. 9.
- 15) R. ビール, T. ジャクソン著 八名和夫訳: ニューラルコンピューティング入門, 海文堂, 1993. 2.
- 16) 建設省河川局編日本河川協会: 雨量年表, 1985年-1994年.
- 17) 建設省河川局編日本河川協会: 流量年表, 1985年-1994年.

(1999. 3. 16 受付)

STUDY ON A SYSTEM OF RUNOFF(DAILY)ANALYSIS USING NEURAL NETWORK

Kiyoaki ABE, Hideaki KIKUCHI, Kouhei FURUKAWA and Yoshiharu SHIOTSUKI

As the rain infiltrates the ground, the runoff of the rain flows into the river. It is difficult to know accurately the amount of rain that infiltrated the ground and the saturated amount of rain under ground as well as a period of conversion from infiltrated rain into a runoff. Thus it is very difficult to forecast stream flow by modeling a runoff process. The runoff analysis (e.g. tank model) is useful to forecast stream flow. In this study, we construct a system of runoff analysis by using neural network, which can be effective to solve non-linear and pattern classification problems, using the same data used in the tank model by KOZUE, and then compare to the results of the tank model. We evaluated the efficiency of the system using neural network on runoff analysis.