

月間降雨量に基づくニューラルネットワークを用いたダム堆砂量予測

STUDY ON THE PREDICTION OF SEDIMENT VOLUME DEPOSITED IN A RESERVOIR BY NEURAL NETWORK BASED ON MONTHLY RAINFALL

森本 稔¹・坂田洋次郎²・門田章宏³・鈴木幸一⁴
Minoru MORIMOTO, Yojiro SAKATA, Akihiro KADOTA and Koichi SUZUKI

¹ 学生員 愛媛大学大学院 理工学研究科博士前期課程 環境建設工学専攻

² 非会員 工修 日本発条株式会社(神奈川県横浜市金沢区福浦3-10)

³ 正会員 博(工) 愛媛大学大学院講師 理工学研究科生産環境工学専攻

⁴ フェロー会員 工博 愛媛大学大学院教授 理工学研究科生産環境工学専攻
(〒790-8577 愛媛県松山市文京町3)

The prediction method for the sediment deposition in the Ishidegawa dam reservoir, using artificial neural network (ANN), is proposed. Monthly sediment deposition V_{SM} is calculated by the ANN trained with data of rainfall and sediment deposition in the past 20 years. Input elements of the ANN are monthly rainfall depth TR_M , monthly maximum inflow discharge Q_{mM} , monthly number of days with daily inflow discharge more than $10\text{m}^3/\text{s}$ (N_{10M}) and monthly number of days with daily inflow discharge between $1\text{m}^3/\text{s}$ and $10\text{m}^3/\text{s}$ (N_{1M}). In the first step, three input elements Q_{mM}, N_{10M}, N_{1M} are estimated by sub-ANN with monthly rainfall TR_M , and the input element of the ANN for V_{SM} is reduced to be only one element TR_M . Target monthly sediment deposition V_{SM} is given by distributing the observed yearly sediment deposition V_{SY} according to the ratio of monthly rainfall TR_M to yearly rainfall TR_Y . It is proved that yearly sediment deposition can be estimated well by the ANN based on the monthly rainfall depth as an input.

Key Words: neural network, sediment deposition, reservoir, prediction

1. はじめに

本研究は、ダムの年間堆砂量に関する過去のデータに基づくニューラルネットワークシステムを構築することによって、ダム堆砂量の将来予測を行う方法を検討したものである。ダムの堆砂量を求める際には、流域条件・ダム規模の類似した近傍のダムの実績堆砂量から類推する方法、流砂量に影響する因子と実績堆砂量との関係を統計的に処理して求める方法、および降雨による斜面侵食物理モデルによる方法が用いられてきた^{1),2),3)}。しかし、山地における土砂生産や土砂輸送の物理機構は複雑なので精度の高い予測は困難であり、実績堆砂量と計画堆砂量が大きく離れている場合が存在する。

ダム堆砂量は、大きく分けて流域特性と降雨特性によって決まるが、流域特性は地形の規模や形状、地質、植生の有無など多岐に亘る要素からなる^{4),5)}。ただ、特

定のダムの今後の堆砂量を過去のデータから推定する場合、将来とも流域の地形変化を伴うような開発や大規模な植生の伐採などの流域特性に大きな変化がなければ、斜面崩壊による土砂生産も不安定土砂の発生も降雨の結果であるので、降雨特性がダム堆砂の支配要素である。

本研究では、愛媛県松山市の石手川ダム貯水池における過去の年間ダム堆砂量と降雨特性の関係から、ニューラルネットワークを用いて将来のダム堆砂量を推定する。

ダム堆砂量の実測データは年単位であり、しかもデータの精度は一般に高くない。これは堆砂量が年一回の貯水池内の河床横断測量に基づいて計算されたものであり、流下方向測定間隔が大きければ小規模の三次元河床形状は把握できない等の原因に基づいている。本解析では年間ダム堆砂量が負であるようなあきらかに不合理なデータは除外して解析を行っている。降雨データは基本的には日雨量であるが、降雨あるいはそれに基づく流入流量等を、ダム堆砂量の測定精度との整合性を考慮してどの

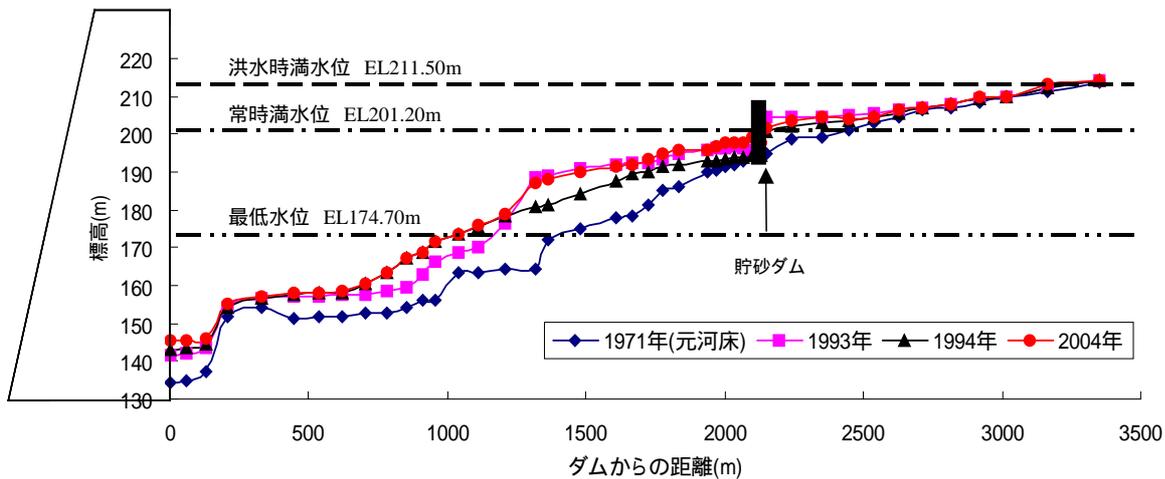


図 1 貯水池内の元河床と堆砂形状の推移

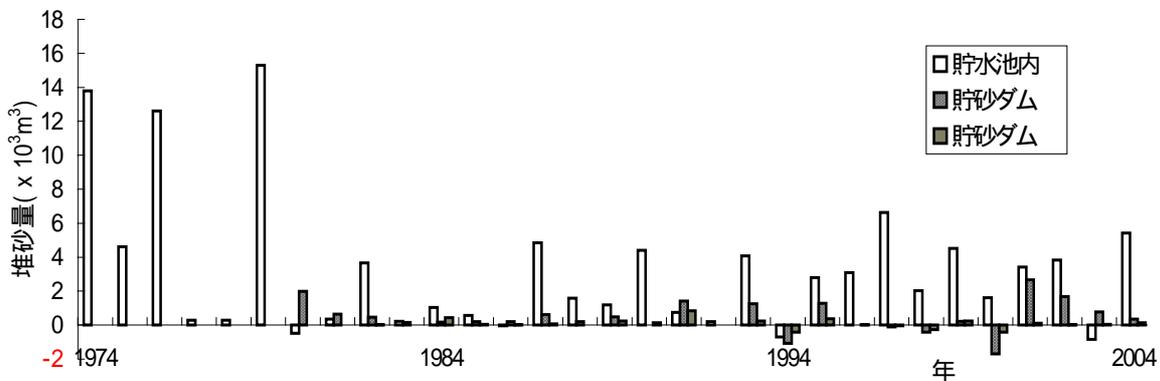


図-2 石手川ダムの堆砂量の経年変化

程度詳細に扱うかが問題となる．本研究では，月間降雨量を用いて，年間ダム堆砂量を推定する方法を提案した．

2. 石手川ダムの堆砂特性と降雨特性

本研究で対象とする石手川ダムは，松山市を流れる一級河川重信川の支川石手川上流に，1973年に完成した重力式コンクリートダムである．松山市の水道用水，灌漑用水および洪水調節用の多目的ダムで，総貯水量1,280万 m^3 ，集水面積72.6 km^2 ，堆砂容量220万 m^3 である．流域の最大標高差は，約750mで地形はあまり急峻ではなく，植生は豊かで裸地は少ない．加えて，年間総雨量が平均1,500mm程度と少なく，土砂生産は活発とはいえない．図-1は1971年における河床形状とダム完成の1973年以降のダム貯水池内の堆砂形状の一部を示した例である．貯水池には石手川本川と支川である五明川が直接流れ込んでおり，それぞれ貯水池の近くに貯砂ダムが設けられている．貯水池内では，掃流砂の堆積はデルタを形成しながら進んでいることがわかる．しかし，1994年夏季に

は，ダム貯水率が0となりダム底水までも使用する大濁水が発生し，デルタが一度崩れ大きく堆砂形状が変化している．その後，再びデルタが形成されているのが認められる⁶⁾．

ダム堆砂量は，石手川ダム貯水池内，石手川本川の貯砂ダム()，支川である五明川の貯砂ダム()，の3つの堆砂量の合計であり，貯砂ダムで砂利採取が行われている場合は，それらも本来はダムに流れ込んだものと考え堆砂量として加え，それぞれの年間堆砂量を，図-2に示している．建設から数年は貯水池内に年間10万 m^3 を超える大きな堆砂がみられるが，それ以降は貯砂ダムの堆砂量を含めても最大で年間6万 m^3 程度の堆砂量にとどまっている．また，三次元の堆砂形状が精度よく測量されていないことなどから，年堆砂量の実測精度は低い．全堆砂量が負になるなど明らかに不合理なデータは解析対象から除外した．

図-3は年間総雨量 TR_Y ，年間最大日平均流入量 Q_{mY} の経年変化を示している．年間総雨量 TR_Y は900mmから2,400mmの範囲であり，年間最大日平均流入量 Q_{mY} は年によって20 m^3/s から180 m^3/s と大きく異なっている．図-4は日平均流入量1 m^3/s ～10 m^3/s の生じた日数 N_{1Y} ，および

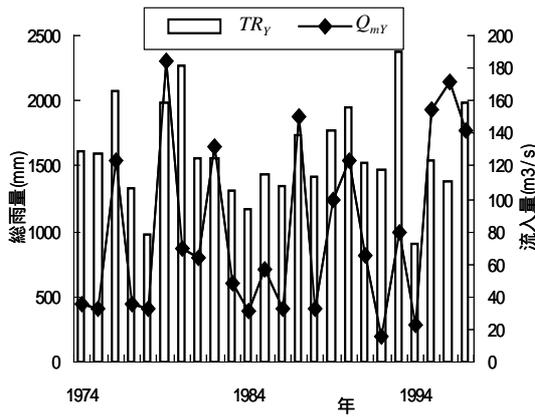


図-3 TR_Y と Q_{MY} の経年変化

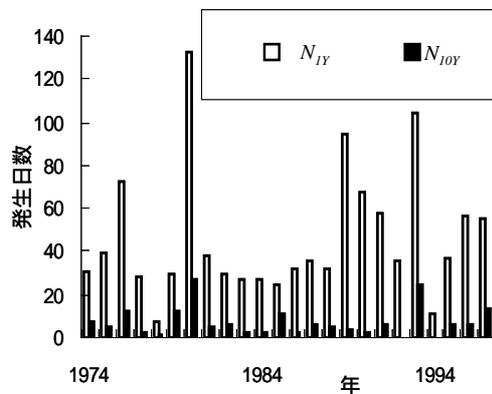


図-4 N_{IY} と N_{10Y} の経年変化

日平均流入量 $10\text{m}^3/\text{s}$ 以上が生じた日数 N_{10Y} の経年変化を示している。1980年のように N_{IY}, N_{10Y} が大きな年と、1994年のようにほとんど0に近い年がある。 N_{IY}, N_{10Y} に関しても N_{IY} が大きいときに N_{10Y} も大きくなるとは限らず、降雨の特性による違いがあると考えられる。

3. ダム堆砂量ニューラルネットワークの構築

ニューラルネットワークは、ニューロン、セル、ノードなどと呼ばれる多くの単純な過程単位（神経細胞）の作用に基本を置いている。入力（刺激）層と出力（反応）層との間に、中間ニューロン層が想定される。各層における各神経細胞は、全ての層の全ての要素に結びついており、それぞれの結びつきは重みを持っている。ニューラルネットワークの一般的な特性は、自然の複雑な現象を学習し、それを再現できることである^(7,8)。

降雨量のようにダム堆砂に関係すると考えられる要素 x の入力ベクトルとして $X = [x_1, x_2, \dots, x_n]$ 、各入力要素とダム堆砂量との関係を示すネットワークパラメータ（重み w ）のベクトルとして、 $W = [w_1, w_2, \dots, w_n]$ を考え、ダム堆砂量としての多変数関数 $f(x)$ を近似することを目的

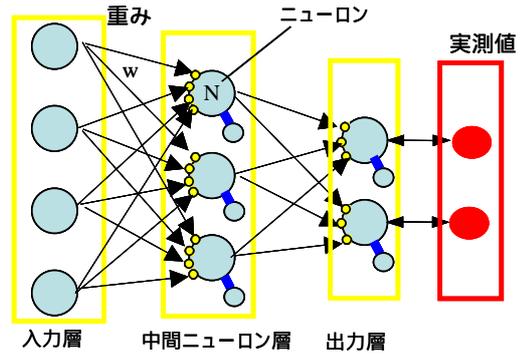


図-5 ニューラルネットワークの概要

にすると、学習過程によって $f(x)$ の実測値に近い最適近似を得るような最適な重みベクトル W を見つければ良いことになる。

ここでは図-5に示す multi-layer-perceptron (MLP) を用い、back-propagation (BP) 学習によって、ネットワークを決定する^(9,10)。

BP アルゴリズムにおいては、前進過程と後退過程がある。前進過程においては、入力パターンがネットワークに与えられると、その影響はネットワークを通して、層から層へと伝播する。各ニューロンに対しての入力は次式で計算される。

$$net_i^n = \sum_{j=1}^m w_{ji}^n O_j^{n-1} \quad (1)$$

ここに、 net_i^n は n 層の i 番目のニューロン入力値、 w_{ji}^n は $(n-1)$ 層の j ニューロンと n 層の i ニューロン間の重み、 O_j^{n-1} はニューロン $(n-1)$ 層の j ニューロンの出力、 m は $(n-1)$ 層のニューロンの数、である。各ニューロンにおいて、式(1)で計算された値は応答関数（ここではシグモイド関数⁽⁴⁾を使う）によって伝達される。

ネットワークの出力層からの出力 O_{pj} は計算によるダム堆砂量であり、実測の堆砂量であるターゲット（真値） T_{pj} と比較され、次式(2)で示されるような二乗誤差の合計 E を最小とすることを目的とする。

$$E = \sum_{p=1}^{n_p} \sum_{j=1}^{n_o} (T_{pj} - O_{pj})^2 \quad (2)$$

ここに、 T_{pj} は p 番目のパターンに対するターゲットの出力の j 番目の要素、 O_{pj} は p 番目のパターンに対する j 番目のニューロンの計算出力、 n_p はパターン数、 n_o は出力層のニューロン数である。

目的関数(式(2))を計算すると、BP アルゴリズムの次の段階、すなわち後退過程が前の層に対するネットワーク誤差の伝播として始められる。最急降下法⁽⁷⁾を用いて、次式(3)によってネットワーク誤差を減少させるように重みを調整する。

表-1 実測年堆砂量と年別ANNの計算値の比較

年	実測値(x 10 ³ m ³)	計算値(x 10 ³ m ³)	比
1996	31.20	45.57	1.5
1997	66.36	30.04	0.5

$$\Delta w_{ji}^n \Big|_{(m+1)} = \eta \frac{\partial E}{\partial w_{ji}^n} + \alpha \Delta w_{ji}^n \Big|_{(m)} \quad (3)$$

ここに、 $w_{ji}^n \Big|_{(m+1)}$ は(m+1)番目の反復後の重み差、(>0), (<1)は定数である。この過程をネットワーク誤差が許容範囲になるまで続ける。

4. 石出川ダム堆砂量予測への適用

(1) 年別ネットワーク

ニューラルネットワークをダム堆砂予測に適用するにあたって、考慮しなければならないのは堆砂と関係の深いパラメータの設定である。もっとも単純に考えられるものは、総雨量と総堆砂量との関係である。総雨量のみをパラメータとした場合、雨量が同じであるとしても短期間に集中的に雨が降るものと、長期にわたり弱い雨が降り続けるものとは土砂生産量に違いがある。これらをどのように考慮していくかが重要になる。

実測のダム堆砂データは、年一回の地形測量から計算されたもので、年間堆砂量しか実測値がない。年堆砂量としては、貯水池内、本川上流の貯砂ダム および支川上流の貯砂ダム での堆砂量があり、それら3つの合計を年堆砂量 V_{SY} とした。この年堆砂量を決める要素として、年間総雨量 TR_Y (mm)、貯水池への年最大日平均流入量 Q_{mY} 、 $1m^3/s$ 以上で $10m^3/s$ 未満の日平均流入量の流入日数 N_{1Y} 、 $10m^3/s$ 以上の日平均流入量の流入日数 N_{10Y} の4つを考慮した。ここで、上記のほかに $20m^3/s$ 以上あるいは $30m^3/s$ 以上日平均流入量の日数等をパラメータとして加えることも考えられるが、それらの日数のダム堆砂への影響を考えれば、極端に小さい値や大きい値は好ましくない。本研究対象の石手川ダムでは図-4を参考にして便宜的にパラメータを与えた。すなわち、入力として TR_Y, Q_{mY}, N_{1Y} および N_{10Y} を考え、出力として V_{SY} を推定することとする。

ネットワークの構築にあたり、1975年から1995年までのデータで堆砂量が負などの明らかに誤りであるデータを除いた20年分のデータを用いて、ニューロン数を10個、50個、その後は50個刻みで500個まででネットワークをそれぞれ訓練させた。確立したネットワークを用いて、1996年と1997年の年間堆砂量を推定した結果と実測値を比較すると表-1のように実測値と計算値とで大きな違いがあった。内容を見ると、入力の中で TR_Y が大きい V_{SY}

表-2 実測年堆砂量と月別ANNの計算値の比較

年	実測値(x 10 ³ m ³)	計算値(x 10 ³ m ³)	比
1996	31.20	38.94	1.2
1997	66.36	50.69	0.8

が小さく、逆に TR_Y が小さい V_{SY} が大きいというような一見矛盾するデータが存在している。また、集中豪雨期のみ大きな降雨量を記録した年でも TR_Y が平均以下のときは、集中豪雨期のみ大量の堆砂が発生したと考えられる。その場合、 V_{SY} が平均以上だったとき、 TR_Y と V_{SY} の関係に矛盾が生じる。しかし、年間でネットワークを構築している限りこの矛盾は解決できないことがわかった。また、年別ネットワークでは、 Q_{mY}, N_{1Y}, N_{10Y} の相互関係が小さくなり、各要素の影響があまり反映されず、年単位でネットワークを構築するには限界がある。

(2) 月別ネットワーク

月ごとの突出した降雨に基づく上記のような矛盾に対応するため、月別ネットワークモデルの構築を試みる。すなわち、入力として月間総雨量 TR_M (mm)、月間最大日平均流入量 Q_{mM} (m^3/s)、 $1m^3/s$ 以上で $10m^3/s$ 未満の日平均流入量の月間流入日数 N_{1M} 、 $10m^3/s$ 以上の日平均流入量の月間流入日数 N_{10M} を用いる。また、出力としての月間堆砂量 V_{SM} の実測がなく、年間堆砂量 V_{SY} しか実測されていない。ここでは、仮に堆砂量と最も相関の高い総雨量を考慮して、月間総雨量 TR_M と年間総雨量 TR_Y の比を用いて便宜的に月間堆砂量 V_{SM} を与えた

$$V_{SM} = V_{SY} \frac{TR_M}{TR_Y} \quad (4)$$

で、月間堆砂量 V_{SM} を実測(推定)堆砂量とする。月間堆砂量 V_{SM} については TR_M / TR_Y に対して1.5乗あるいは2乗など様々な方法が考えられるがここでは便宜的にもっとも単純な式(4)を使用することとした。この月別堆砂量ネットワークモデルにおける年間総堆砂量の計算結果は表-2 のようになり、表-1 と比較すると計算値が実測値に大きく近づいていることがわかる。年別ネットワークより月別ネットワークの有用性が認められた。さらに日別ネットワークを用いることが考えられるけれども、ダム堆砂量の実測精度が高くないこと等を考えると、これ以上計算精度を上げる意味がないと考えた。

月別ネットワークモデルによって、年別モデルでは認められなかった Q_{mM}, N_{1M}, N_{10M} の影響が大きく反映される結果が得られ、月別ネットワークモデルの有用性が認められた。しかし、入力要素として TR_M, Q_{mM}, N_{1M} 及び N_{10M} の4つがそろわなければ V_{SM} (その年合計としての V_{SY}) が導かれないという非実用的なネットワークモデルとなっている。

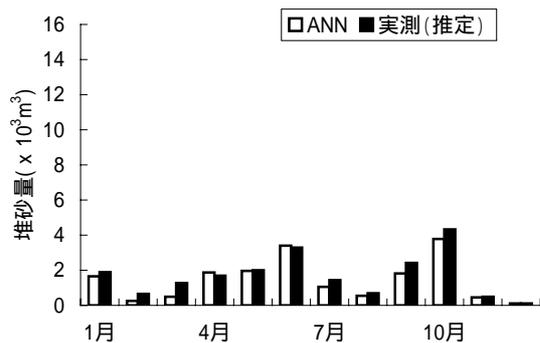


図-6(a) 1998年

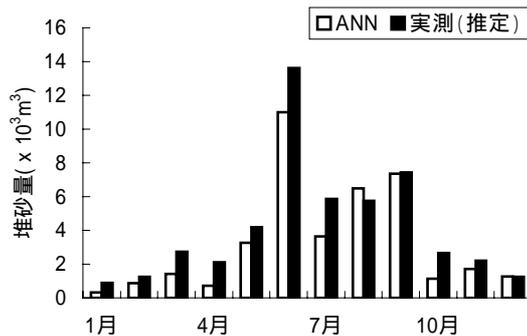


図-6(b) 1999年

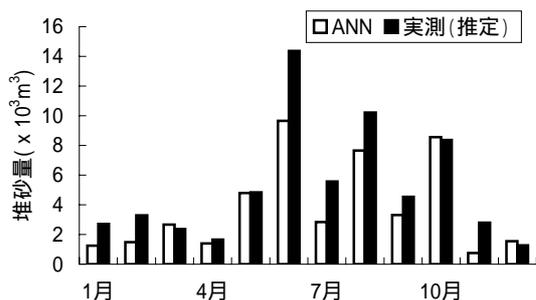


図-6(c) 2001年

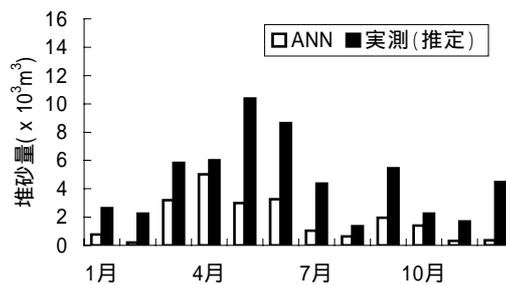


図-6(d) 2002年

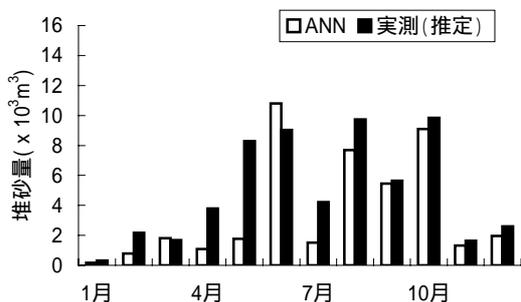


図-6(e) 2004年

図-6 月別堆砂量のANNによる予測値と実測値の比較

あったため、両期間において N_{IM} 、 N_{IOM} および V_{SY} との関連性の強化を図るためである。

過去20年分のデータでネットワークを訓練し、そのネットワークを用いてその後1998年から2004年までの堆砂量を計算した。図-6(a)～(e)は月別堆砂量の実測(推定)とネットワークによる計算値を比較したもので、それぞれ1998年、1999年、2001年、2002年および2004年のものについて示している。2002年を除いては実測(推定)値と計算値とは比較的よく一致している。2002年のように一致度の低いものが生じているが、実測(推定)値の持つ特性や精度を考えると、提案した修正月別ネットワークモデルは有用性があるものと考えられる。ニューラルネットワークによる計算値と実測値の不一致の原因は、訓練データにおいての入力に対して望ましくないターゲット(実測値)がある場合、そのターゲットに強く影響される出力となることである。これは、便宜的に与えた月間堆砂量 V_{SM} の設定方法、また、パラメータの選定方法にも原因の一端があることも考えられる。図-7は1998年から2004年までの実測の年間堆砂量の累計と月別ニューラルネットワークでの計算値を1年間合計した計算年間堆砂量の累計とを比較したものである。実測値とANNによる計算値が比較的よく一致していることが認められる。

(3) 修正月別ネットワークモデル

上記の月別ネットワークモデルをより実用的にするために、入力を月間総雨量 TR_M のみとすることを考える。そのために、二つのネットワークモデルを構築する。一つ目は入力を TR_M とし出力を Q_{mM} 、 N_{IM} および N_{IOM} とするものであり、もう一つは、この計算される Q_{mM} 、 N_{IM} および N_{IOM} と TR_M を入力として、出力 V_{SM} (その年間合計として V_{SY})を計算するネットワークモデルである。この連続した二つのネットワークモデルにより、月間総雨量のみを入力することによって堆砂量を求めることができる。その際、より精度を高めるためにネットワークの訓練を5月から10月の期間と、11月から4月までの期間とに分けて行うこととした。その理由は、11月から4月の期間においては N_{IOM} が過去20年分において皆無($N_{IOM} = 0$)で

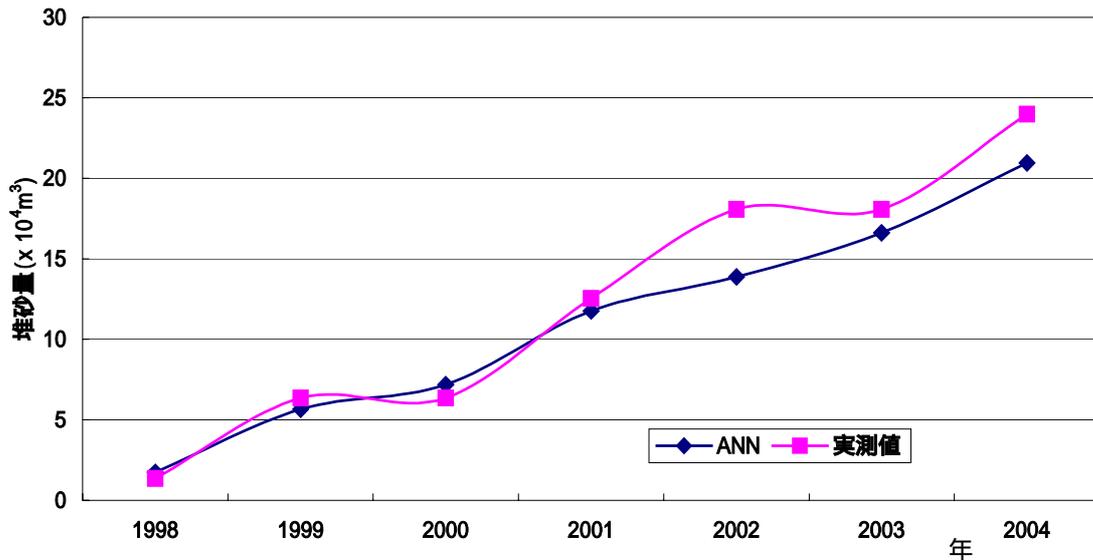


図-7 計算値と実測値の累積堆砂量の経年変化

5. おわりに

本研究はニューラルネットワークを用いたダム堆砂量予測の有用性を検討したものであり、本研究で示した月間降雨量に基づく堆砂量予測法は過去のデータの存在するダムに対し適用できると考える。まず、ネットワークを年間という大きな期間に対して構築し学習を行うこととしたが、年間総雨量やダムへの各種流入量の特徴を十分に反映させることができなかった。そこで、月別のネットワークを構築し、月間総雨量 TR_M 以外に雨量の特徴を反映させるため月間最大日平均流入量 Q_{mm} 、 $1m^3/s$ 以上で $10m^3/s$ 未満の日平均流入量の月間流入日数 N_{IM} 、 $10m^3/s$ 以上の日平均流入量の月間流入日数 N_{IOM} を入力として使用することにより、期限内での降雨の特性等をより反映させられるよう試みた。その結果年間を単位としたネットワークよりもより高い精度の予測結果を得た。さらに、より実用的になるように4つの入力を全てそろえる必要がないように総雨量のみを入力として与えるだけで堆砂量を求められるよう改良を加えた修正月別ネットワークを構築した。このように、月間総雨量のみを入力とした二重ネットワークと、4要素を入力とした結果を比較しても大きな精度の低下は見られなかった。しかし、もともと堆砂量の測定データの精度が低いことに加え、使用できるデータ量が不足のためこれ以上の精度を求めるのは難しい。ただ、ダム建設後の経年数が増しデータ数が蓄積されると予測精度の向上が期待できる。また、パラメータの選定方法や便宜的に与えた月間堆砂量の設定方法を検討する必要がある。

謝辞：石手川ダムに関する水文および堆砂資料は国土交通省四国地方整備局石手川ダム管理事務所より提供していただいた。記して謝意を表す。

参考文献

- 1) Lane, L.J. and Shirley, E.D. : Erosion and sediment yield equations: solutions for overland flow, West Lafayette. Presented at Workshop on USLE Replacement, Nat. Soil Erosion Lab. West Lafayette, Apud Lopes, 1985.
- 2) Lopes, V.L. : A numerical model of watershed erosion and sediment yield, Ph.D. dissertation, University of Arizona, Tucson, AZ, 1987.
- 3) Celso, A.G., Santos, M., Watanabe, K., Suzuki, K., and V.S. Srinivasan : Sediment yield due to heavy rainfall from a test field in Brazil and its analysis by a runoff-erosion models. Journal of Hydraulic, Coastal and Environmental Engineering, JSCE -40, No.586, pp.117-126, 1998
- 4) 吉良八郎：ダム堆砂とその防除，森北出版(株)，1982。
- 5) 芦田和男編著：ダム堆砂文献資料集成，河鍋書店(株)，1976。
- 6) 国土交通省四国地方整備局：石手川ダム定期報告書，2006。
- 7) Haykin, S.: *Neural networks : a comprehensive foundation*, Prentice Hall, Inc., 2ed, New Jersey, 1999.
- 8) 小林賢二，廣安知之，三木光範：ニューラルネットワークとは，ISLD Report No.20050909006, 2005.
- 9) 玄光男，井田憲一：ニューラルネットワークと最適化，共立出版株式会社，1998.
- 10) 熊沢逸夫：学習とニューラルネットワーク，森北出版(株)，1998.

(2006.9.30受付)