

複閾数分類学習ニューラルネットワークによる重力式ダムの漏水管理

長通伸幸¹・作田 健²・香月 智³

¹ 修(工) 防衛大学校 理工学研究科 元学生 (〒239-8686 神奈川県横須賀市走水 1-10-20)

² 学生会員 防衛大学校 理工学研究科 学生 (〒239-8686 神奈川県横須賀市走水 1-10-20)

³ 正会員 工博 防衛大学校 建設環境工学科 教授 (〒239-8686 神奈川県横須賀市走水 1-10-20)

本研究は、複閾数分類学習ニューラルネットワークシステムを用いた構造物のモニタリングシステムを重力式ダムの漏水データ管理に応用することを試みたものである。本研究で用いた実測データは、30年間にわたる実漏水観測データの一部であり、気温、水温、雨量、水位などの要因関連データも同時に計測されている。その変化曲線は極めて複雑で、データ内には複数のパターンの漏水要因データとの因果関係が混在している。このため、線形関数を前提とする重回帰分析では、データの正常と異状を分別することができない。しかし、提案システムは、構造物の正常さを明瞭に認識できると同時にノイズ混合による異状を認識できることを明らかにした。

Key Words: multi-pattern neural network, differentiation monitoring, structural characteristic

1. 緒言

ダムの用途は、上水、工業用水、農業用灌漑および電力用水と多岐にわたっており、平成13年4月現在で堤高15m以上のものが、約2700基ほど運用されている¹⁾。その堤体構造の種別としては主に重力式、アーチ式、中空重力式、ロックフィル式、アース式、コンパイン式、バットレス式などがあるが、国内で運用中の全基数のうち約850基が重力式ダムである¹⁾。ところで、ダム高が15m以上のものでは貯水量が大きくなるため、流水系における貯留または放流管理の影響が大きく、特に洪水時にはその管理を誤ると下流域に被害を及ぼすため、ダムごとに慎重な管理手法が定められている²⁾。

また、堤体の健全性管理についても慎重な管理体制がとられており、その一つとして、堤体に生じる漏水量の観測が義務付けられている³⁾。すなわち、図-1に示すような堤体内部の監査廊内に生じる漏水量を計測すると同時に、漏水に影響を及ぼすであろう関連事象データを日々観測している。そのうえで、これらのデータ間に閾数関係を導いておくことにより、漏水量が因果関係からはずれることをもって、堤体の異状を発見することを企図しているものである。

しかし、この閾数関係には、ダム堤体の固有の特性が反映されるため、閾数の標準化は困難であり、具体的な管理手法が明確に確立されているとは言い難い。

このような背景から、これまでにもいくつかの研究がな

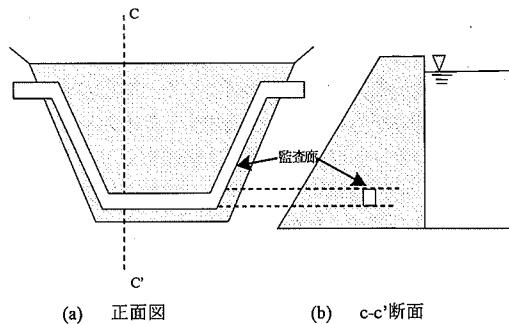


図-1 ダム監査廊

されている。例えば、塩崎ら⁴⁾は、降水量、貯水位、融雪量の3つの説明変数を用いた重回帰分析により漏水量の予測式を作成し、ダムの漏水量の異状検知を行っている。徳井ら⁵⁾は、カルマンフィルタ理論を用いて漏水量計測値の評価を行っている。後藤・坂本⁶⁾は、揚水発電用フィルダムの健全性を確認するため、降雨特性や貯水位変動を考慮した計測管理手法を確立し、パーソナルコンピュータによる管理システムを構築している。梅島ら⁷⁾は、フィルダムの安全管理のため、降雨の影響を考慮した浸透水量予測式を構築している。また、松岡ら⁸⁾は、コンクリートひび割れからの漏水メカニズムを明らかにするための漏水実験を行っている。その結果、ひび割れ幅が大きくなるにつれ浸透流速の特性が層流理論から逸脱するようになり、この現象を乱流浸透モデルにより良好に再現できることを示している。しかし、これらの研究成果

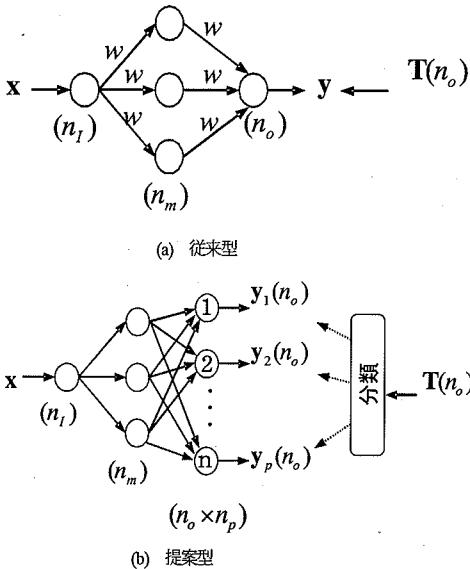


図-2 提案ネットワークと従来型ネットワーク

にかかわらず、現場ごとに異なる問題を包括的に解決するには、これからもいくつかの技術提案や研究が必要と思われる。

著者ら⁹⁾は、モニタリングデータから構造物の物理的異状箇所や状況を特定する前段階として、従来の状態から何らかの遷移が生じたことを検知するためのシステムをニューラルネットワークを用いて構成することを提案した。その際、正常な構造であっても、複数のパターンによりモニタリングデータの因果関係が混在する可能性があることを指摘して、複閾数分類学習ニューラルネットワークを開発し、提案した。そのうえで、実験レベルのデータにおいてその有効性を確認した。しかし、実構造の実観測データでの有効性は未確認であった。そこで本研究は、著者らの提案した複閾数分類学習ニューラルネットワークシステム⁹⁾を用いて、実在する重力式ダムで計測された漏水データに対する複数のパターンデータの分類学習を行い、適用性について検討したものである。

2. 複閾数分類学習ニューラルネットワーク

ここで用いる複閾数分類学習ニューラルネットワークは、文献⁹⁾で提案したものであるが、後述する実データ適用時の分析に必要な基礎部分を抜粋し、基本例題を用いてその特性について説明する。なお、文献⁹⁾では鋼板振動の基礎実験によって提案手法の適用性を検討しているが、人工的に行ったやや理想的な環境で得られたデータへの適用であり、実構造の実観測データへの適用検討

は行われていない。

(1) 計算アルゴリズム

図-2 に、提案する複閾数分類学習ニューラルネットワークシステムを、従来型の3階層ニューラルネットワークと比較して示す。従来型ニューラルネットワークシステムでは、入力ベクトル x (n_I 次元) と出力ベクトル y (n_o 次元) の間を図-2(a)のような中間層ニューロンを経由して関係付け、教師データ T (n_o 次元) との誤差が最小となるようにネットワークの結合強度 w およびニューロン特性を決定するシグモイド関数のしきい値を探索決定する。

一方、提案するシステムは図-2(b)に示すように第3層にパターン数 (n_p) 倍だけの出力層ニューロン (n_o 次元 $\times n_p$ 組) を準備する。そのうえで教師データ T (n_o 次元) と出力ベクトル y (n_o 次元) を比較し、どのパターン関数に属するかについて識別分類した後、学習するものである。つまり、選ばれた出力に関するネットワークのみを学習過程において更新する。ここで、識別分類の基準は各パターン出力と教師データが最も近いものを選択する。すなわち、

$$i_{\text{select}} = \min |T - y_i| \quad (1)$$

よって、学習におけるバックプロパゲーションは次式のように行われる。

$$|T - y_{i_{\text{select}}}| \rightarrow \min \quad (2)$$

この方法では、初期値としてランダムに決定される各パターン出力が教師信号の分類と相性良くできている必要がある。しかし、相性の悪い場合には学習が収束不能となるので、改めて初期のネットワーク構成をランダム値を用いて変更するものとした。すなわち、式(1)によるパターン分類はデータに対する近似の良さを求めており、物理的メカニズムを陽な形で反映したパターン分類ではない。

(2) 複閾数分類学習ニューラルネットワークと構造特性遷移検知システム

複閾数分類学習ニューラルネットワークの構成を決定するために、あらかじめデータ群に含まれる入出力パターン数を知ることができれば、それに応じた数だけのパターン数を設定すれば良い。しかし、実測データ群を取り扱う場合は含まれるパターン数を知ることは難しい。そこで、パターン数等の決定は以下のようを行う。

① パターン数は収束できるパターン数の中で最も小さいものを採用する。

② 関数の非線形性が小さいものを採用するために、中間層のニューロン数はできる限り少なくする。

以上の基準を考慮したネットワークシステムのパラメ

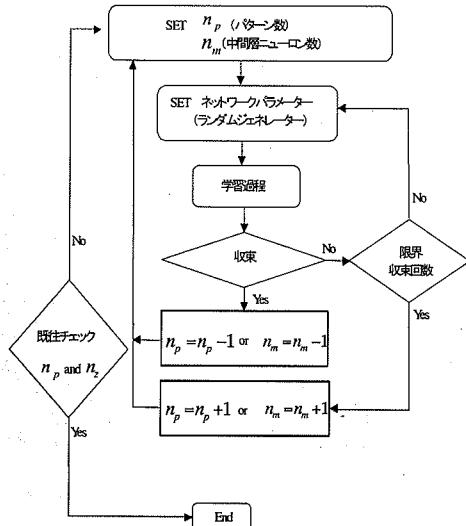


図-3 システムパラメータの決定要領

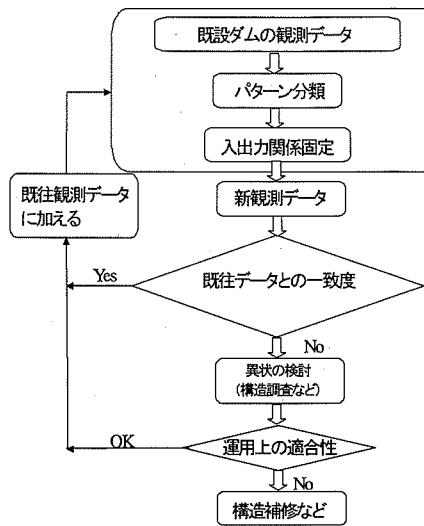


図-4 構造特性遷移判定システム

ータ決定要領を図-3に示す。また、この複閾数分類学習ニューラルネットワークを用いた構造物のモニタリングデータを用いた構造特性の遷移（変化）を検知するシステムの流れを図-4に示す。

(3) 簡易な数値例題

a) 完全矛盾型関数データ

まず、2つの線形関数を用いて提案ネットワークによる分類学習能力を検証する。図-5(a)に示すのは、次式によって作られた線形関数データである。

$$\begin{cases} y = 1 & (\text{pattern 1}) \\ y = -x + 11 & (\text{pattern 2}) \end{cases} \quad (3)$$

ここで、2つのデータ群が完全矛盾関係となるようにを両パターン共通にして $x = \{1, 2, 3, 4, 5, 6, 7, 8, 9\}$ として与える。これを従来のネットワークを用いて近似（学習）したもの図-5(b)に示す。従来のネットワークは、両データ群の中間に位置する関数が得られるため、教師データにさえ一致できないことがわかる。提案手法における学習収束過程は、図-5(c)に示すように初期値のネットワーク出力は教師データと一致していないが、各パターンの出力値が教師データと近い方のみが改良されて、学習回数を重ねるにつれて各パターンの教師データに近づいている。最終的に、図-5(d)に示すように2つのパターン教師データに一致する入出力を有するネットワークが構築されている。

b) 無矛盾型関数データ

図-6には次式による2つの非線形関数による教師データを示す。

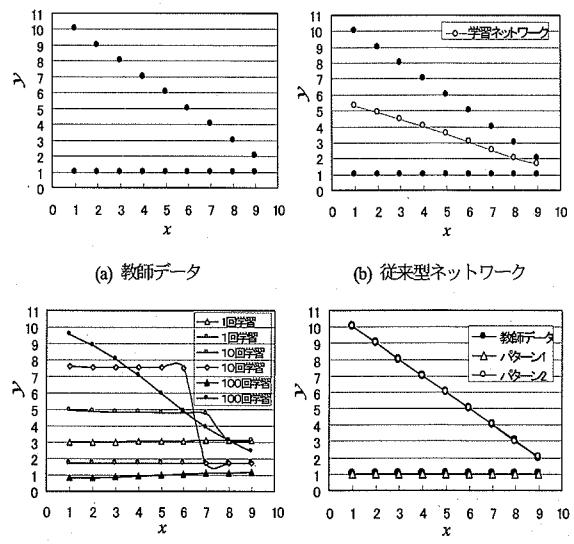
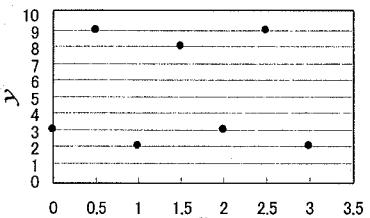


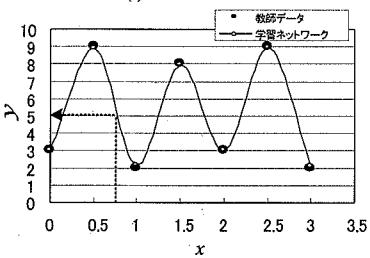
図-5 完全矛盾型関数データ

$$\begin{cases} y = 8.5x + 0.5 \sin \pi x & (\text{pattern 1}) \\ y = 2.5 + 0.5 \cos \pi x & (\text{pattern 2}) \end{cases} \quad (4)$$

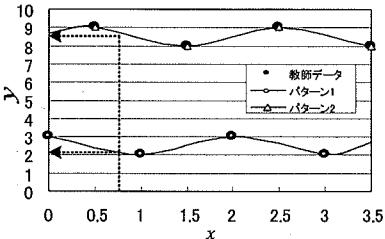
ただし、第1パターン関数と第2パターン関数では相互に異なる x の値を用いているので、前述のように同一の x 値に対して異なる出力 y の教師信号が存在する矛盾データにはなっていない。このため従来型ニューラルネットワークにおいて、中間層ニューロン数を多くして ($n_m = 12$)、非線形汎化能力を高めると、図-6(b)のようになんての教師信号を通過する関数を得られる。一方、提案手法 ($n_i = 1, n_m = 6, n_o = 1, n_p = 2$) で学習させ



(a) 教師データ



(b) 従来型ネットワーク

(c) 提案法学習結果
図-6 無矛盾関数データ

ると、図-6(c)に示すように2つのパターン関数を生成する。この例では、従来型でも提案手法でも近似を完了するが、教師データには存在しない中間的な x 値を与えると出力に違いが現れる。例えば、 $x = 0.7$ を入力すると、従来型では、 $y = 5.03$ となり過去に一度も生起しなかった値を得る。一方、提案法では、 $y = 8.44$ または $y = 2.08$ となり、概ね過去のデータと一致する。すなわち、従来型ニューラルネットワークは、教師データはほぼ完全に同定しているのにもかかわらず、推定値は適切でない過学習問題が生じているが、提案手法はこの問題点は生じていない。このように単純なニューラルネットワークシステムと提案手法では差異がある。この提案法の関数を分離したうえで非線形性を弱める能力が後述する実データの近似に影響を及ぼすものと考える。

3. ダム漏水データの特性遷移検知システム

(1) 使用データ

対象とする重力式ダムの計測されているデータは、表-1に示されている気温、水温、監査廊水温、水位、日雨量、漏水量である。監査漏水温は写真-1に示すように監

表-1 使用データ

項目	単位	内 容
気温	°C	気温計により計測（午前10時）
水温	°C	水温計により計測（午前10時）
監査漏水温	°C	監査廊内に発生する漏水の温度（午前10時）
水位	m	水位計により計測（午前10時）
水位変動量	m	前日水位と当日水位との差
日雨量	mm	ダム付近に設置された雨量計による日雨量（0-24h）
漏水量	ℓ/min	監査廊内において一箇所に集積し計測（午前10時）

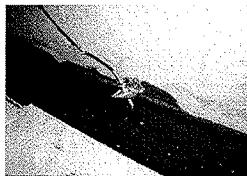


写真-1 漏水温計測器



写真-2 監査廊内の堤体縫目



写真-3 堤体縫目からの漏水

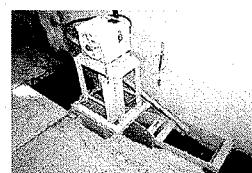


写真-4 漏水量計測器

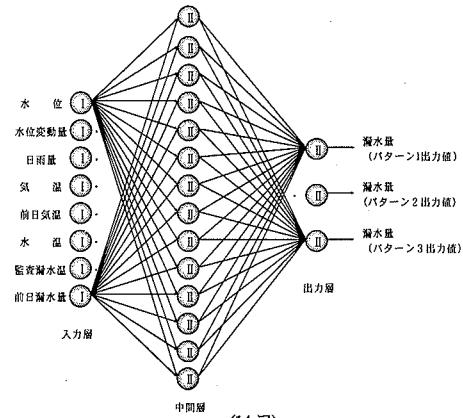


図-7 複閑関数分類学習ニューラルネットワーク

査廊内の側溝に温度計を設置し計測している。

計測される漏水量は監査廊内におけるものであり、大部分は写真-2、写真-3に示す堤体の縫目から発生していると考えられている。しかし、堤体と側壁の岩体との間から入るものなども含まれている可能性もあるなど不明な点も多い。その漏水を監査廊内で一箇所に集積し、写真-4に示すような三角堰により漏水量を計測している。なお、データは毎日の午前10時に定期計測されたものである。

(2) ダム漏水データの特性変化判定システム

構築するニューラルネットワークシステムは、図-7に

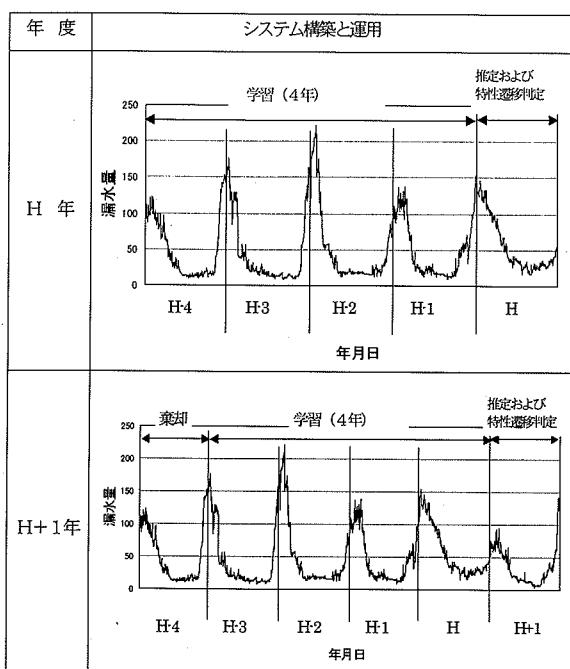


図-8 システムの構築と運用

示す 8 つのパラメータを入力層に持ち、漏水量を出力するモデルである。入力パラメータは表-1 に示したものに加えて、前日漏水量および前日気温を入力する。前日漏水量は、直前のダム堤体状況を表す代表的なデータと考えられる。また、前日気温は、堤体温度変化へのタイムラグ効果を考慮する必要があると考えたためである。ちなみに、2 日以上前のデータを採用してもニューラルネットワークの近似能力の明確な向上は見られなかった。

図-7 の複閾数分類学習ニューラルネットワークシステムを用いた漏水データ特性変化判定システムは、図-8 のように構築運用するものとする。すなわち、その管理運用する年の直近でのダムの漏水特性を取得するため、管理運用する年から逆のぼって 4 年間の観測データを用いて、ニューラルネットワークシステムによる学習処理を行う。その後、当該年度の入力値観測データを用いたニューラルネットワークによって、毎日の漏水量推定を行い、推定値と観測値との誤差がしきい値を超える場合に、「要調査シグナル」を与える。

なお、本研究では比較のために、重回帰分析モデルや従来型ニューラルネットワークによる比較を行なうが、既知データの取得期間と推定期間を基本的に同じ考え方で設定する。

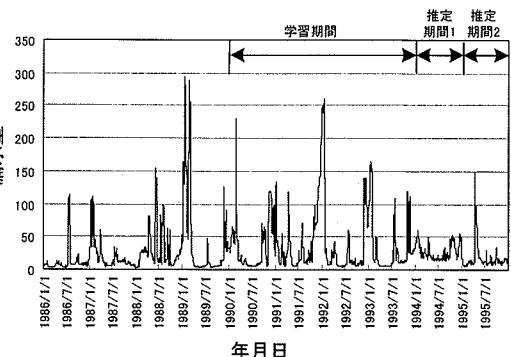


図-9 1986 年から 10 年間のダム漏水量の変化 (検討対象)

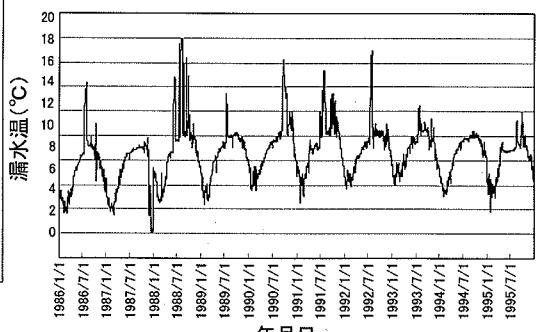


図-10 ダム漏水温の推移

4. 重力式ダムの漏水データモニタリング

(1) 設定問題の概要

本研究で取り扱うダムは、流域面積 83.3 km^2 、頂長 192m、高さ 74m の 50 年以上運用されている水力発電用重力式ダムであり、現在正常に運用されているものである。図-9 に 1986 年 1 月～1995 年 12 月の 10 年間におけるダム漏水量の推移を示す。年度によって相似性はあまり見当たらないが、大きな傾向として、夏季では漏水量は少なく、 $10 \text{ l}/\text{min}$ 未満の日が多い。一方、冬季の 1 月以降では、急激に漏水量が増加し約 $300 \text{ l}/\text{min}$ に達する場合もある。これは、冬季にコンクリート堤体の打継ぎ面が、温度収縮のため開くことによると考えられている。しかし、1988 年の 7 月頃や 1991 年の 7 月頃にも漏水量の多い日が続いている、この原則だけで漏水量変化を説明するのは困難である。

ところで、図-10 に観測された漏水温の推移を示すが、夏期において突然漏水温が上昇する日があることがわかる。注意深く観察すると、これは図-11 に示した水位が高くなった日と連動している。この 2 つの傾向から推定するに、ある水位を超えた場所に特別な水道（みずみち）が存在し、その水道に水位が達すると夏季で温められた

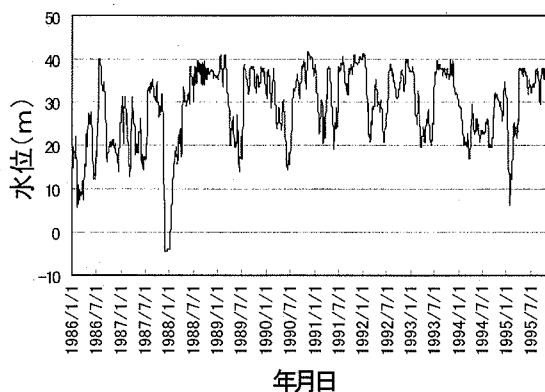


図-11 ダム水位の推移

貯水表面付近の水が流れ込み水温が増すのではないかと思われる。すなわち、この漏水と関連データとの間には、少なくとも水道を通る場合と通らない場合という複数の因果関係が混在する複数パターン混在型データであるものと推定される。

このように、複雑な変化を伴うデータであるので、まずその変化を他のデータと関連付けて説明できる関数を作ることは困難であると思われる。続いて、その中に異状なノイズを混入させた場合にノイズによる異状を発見することはさらに困難である。本研究では、提案手法との比較のために、重回帰分析および従来型ニューラルネットワークを用いて、いくつかの年度において検討を行った。ここでは、その特徴が最もよく現れた検討例を記述する。

ここで、1990年1月～1993年12月の4年間データを学習して、1994年1月～1995年12月の2年間のデータを予測させ、実測値との比較した場合の誤差がしきい値(10ℓ/min)以上となる場合に堤体の状態が過去と異なるものと認識するものとする。なお、このしきい値10ℓ/minは、他のいくつかのダムデータについて検討を行った際に、最も適当と考えられる丸め値である。

なお、1994年のデータは、一年を通じて、冬季の大きな漏水が見られず、夏季では、例年よりも漏水量が多いことがわかる。これは、図-11に示すようにダム水位の運用が例年と異なることが影響していると思われるが、このままでは、いずれの方法でも一年間を通じて正常と判定されることがわかっている。

そこで、1994年の実測データに次のようなランダムな加工を加えて、異状を発するように加工したデータについて検討する。

$$Z_c = Z_0 + RQ \quad (5)$$

ここで、 Z_c : 加工された漏水データ、 Z_0 : 実観測データ、 R : 0.0～1.0 の値をとるランダムデータ、 Q : 冬場には 10、夏場には 20 の定数。なお、これらの定数は、

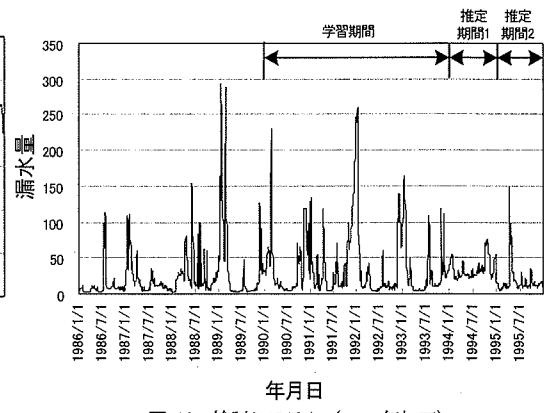


図-12 検討システム (1994年加工)

図-12 に示すように年間を通じて漏水量変化が小さくなるものを選定した。図-12 に加工されたデータを示す。なお、1995年のデータは、計測されたままであり、正常データである。

(2) 重回帰モデル

提案法と比較するため重回帰モデルを用いてデータの評価を行う。すなわち、システムが変更される以前の1990年1月～1993年12月の4年前のデータを重回帰分析し、構築した線形予測モデルを用いて、1994年1月～1994年12月および1995年1月～1995年12月の漏水量を推定し、実測との誤差を調べる。図-13には、4年間のデータに対する重回帰分析の結果を示している。4年分のデータに対する回帰モデルは、次式となった。

$$\begin{aligned} Z = & -0.03744x_1 + 0.06071x_2 - 0.15004x_3 \\ & + 0.16105x_4 + 0.12563x_5 + 4.42041x_6 \quad (6) \\ & + 0.16105x_7 + 0.973969x_8 - 3.17516 \end{aligned}$$

ここで、 z : 漏水量 (ℓ/min), x_1 : 気温 (℃), x_2 : 前日気温 (℃), x_3 : ダム水温 (℃), x_4 : 漏水温 (℃), x_5 : ダム水位 (m), x_6 : 水位変動量 (m), x_7 : 日雨量 (mm), x_8 : 前日漏水量 (ℓ/min)。

図-13(a)には、式(6)による推定値と実測値を比較図示している。式(6)による回帰推定値は実測値と一見すると良く一致しているように見える。しかし、図-13(b)に示した実測値と回帰推定値との相関を見ると、相関係数は 0.986 と高いが、後述する他の手法に比してややばらついている。また、図-13(c)には日々の実測値と推定値の誤差を、また、図-13(d)には誤差ヒストグラムを示す。これらより、重回帰モデルでは誤差が 30 ℓ/min を超える日がかなり頻繁に現れており、誤差が最大となる 1990 年 3 月 1 日の誤差は、-102 ℓ/min と最大漏水量の 40% を超えている。

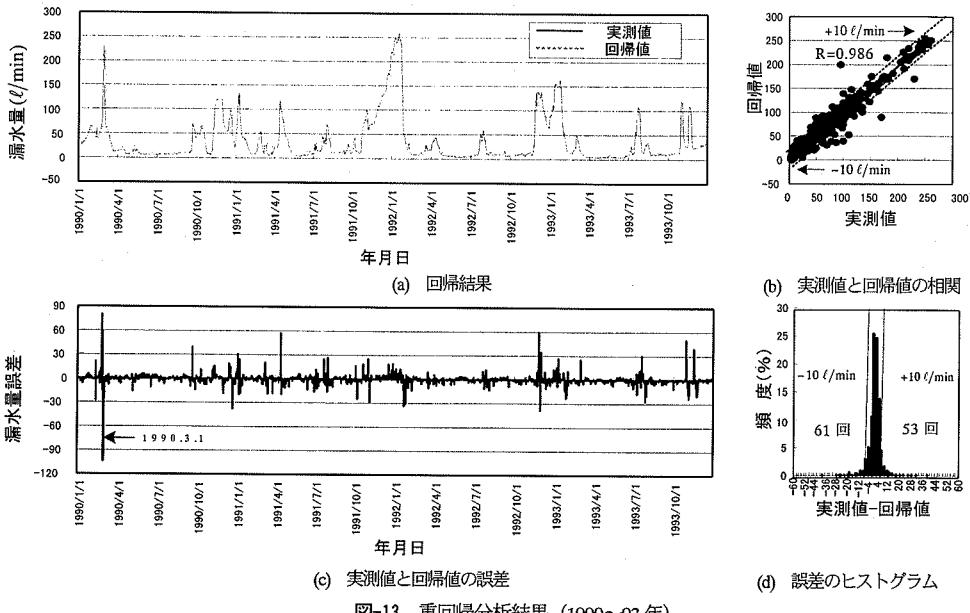


図-13 重回帰分析結果 (1990~93年)

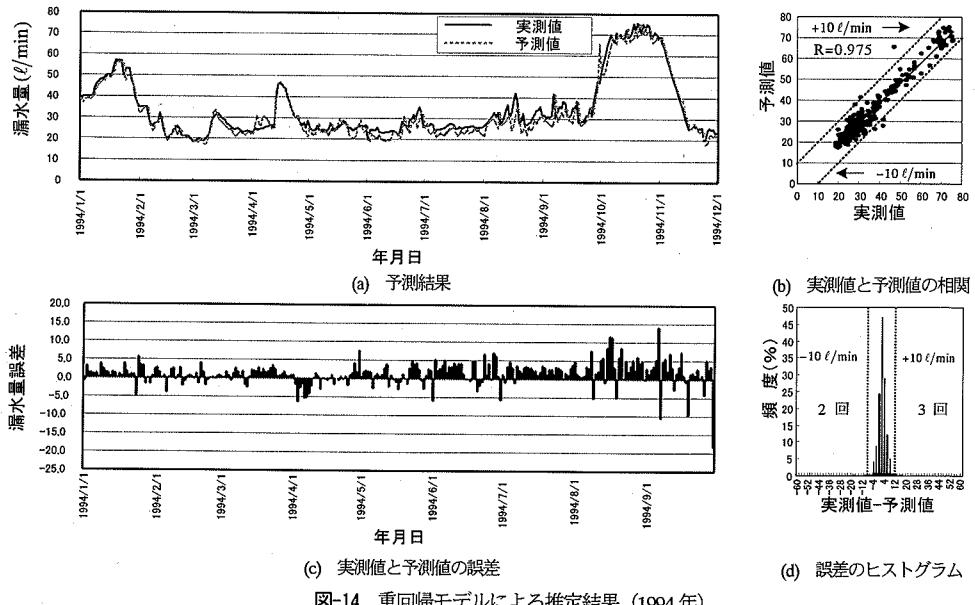


図-14 重回帰モデルによる推定結果 (1994年)

図-14 には、式(6)によって1994年1月～1994年12月の1年間の漏水量予測を行った場合の推定と調整された実測値の結果を比較図示する。この期間はデータにノイズを混入しているので誤差が大きく出ることが期待されるが、誤差（絶対値）が $10 l/min$ を超える日は総計5日ほどしか出現しない。

図-15 には、式(6)によって1995年1月～1995年12月の1年間の漏水量予測を行った場合の推定と実測値の結果を比較図示する。推定と実測の誤差が1995年4月16日において $90 l/min$ 以上となるものもあるが、全体的に

良く一致しており、「要調査シグナル」は年間で9日となる。このように重回帰分析では、異状データも正常データも同程度の検知頻度となる。これは、回帰モデルには前日漏水量(x_8)との相関性が強く現されているためである。具体的には、式(6)によると前日漏水量の97%が当日漏水量の推定値を反映する式となっている。すなわち水位や水温の変化にかかわらず、前日漏水量とほぼ等しい予測値となるため、1994年のようにデータの変化が小さい年では、作為されたデータであっても前日との相対差のないデータでは、ほとんど異状を検知できないこと

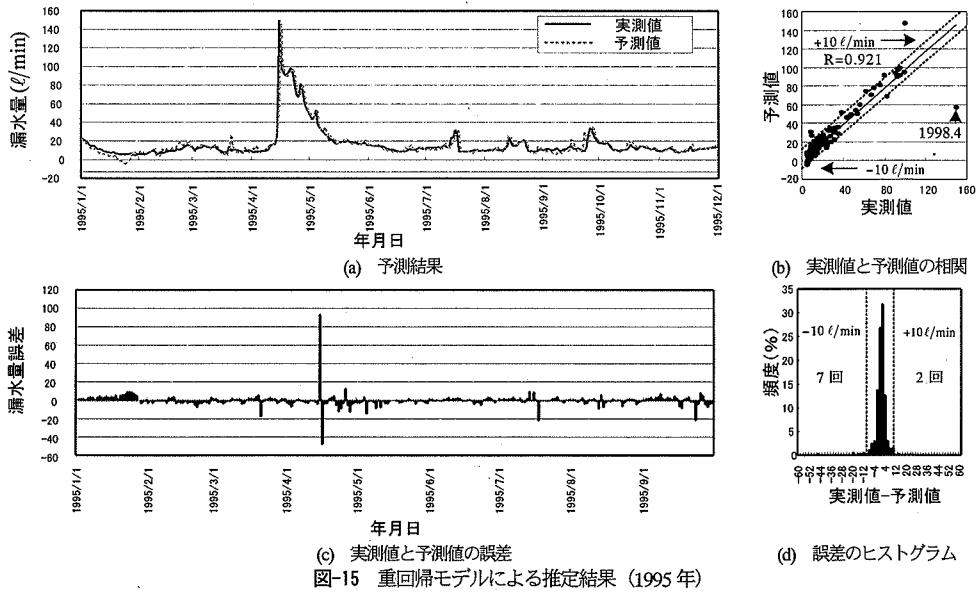


図-15 重回帰モデルによる推定結果（1995年）

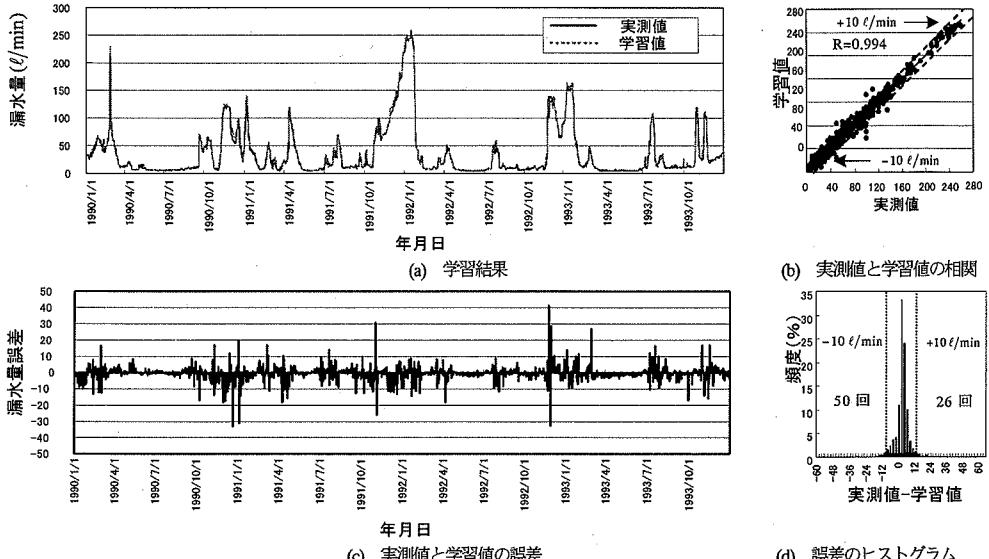


図-16 従来型ネットワークによる学習結果（1990～93年）

になる。

(3) 従来型ニューラルネットワーク

従来型ニューラルネットワークは、中間層ニューロン数を18個とし、学習回数10万回もしくは学習の最大誤差が $10\text{ l}/\text{min}$ 以下となったときに学習を終了させるものとしたが、10万回の打ち切り回数で終了した。ちなみに、中間層ニューロンを増やしても収束させることはできなかった。

図-16に、4年間のデータに対するネットワークの学習結果を示す。図-16(a)に、ネットワークによる学習結果

と実測値を比較図示している。ネットワークによる近似は、重回帰モデルよりも良好な近似となっている。図-16(b)には実測値と学習値との相関を示している。重回帰モデルの結果に比べ、ばらつきがやや減少しており、相関係数も0.994と若干高くなっている。また、図-16(c)に示す実測値と学習値の誤差および図-16(d)の誤差ヒストグラムを見ると、誤差が大きくなる日数が図-13(d)で示した重回帰モデルよりも減少しており、 $10\text{ l}/\text{min}$ を超える日も76日と少ない。さらに、最大誤差についても重回帰モデルでは $102\text{ l}/\text{min}$ であったものに対し、 $42\text{ l}/\text{min}$ と減少している。

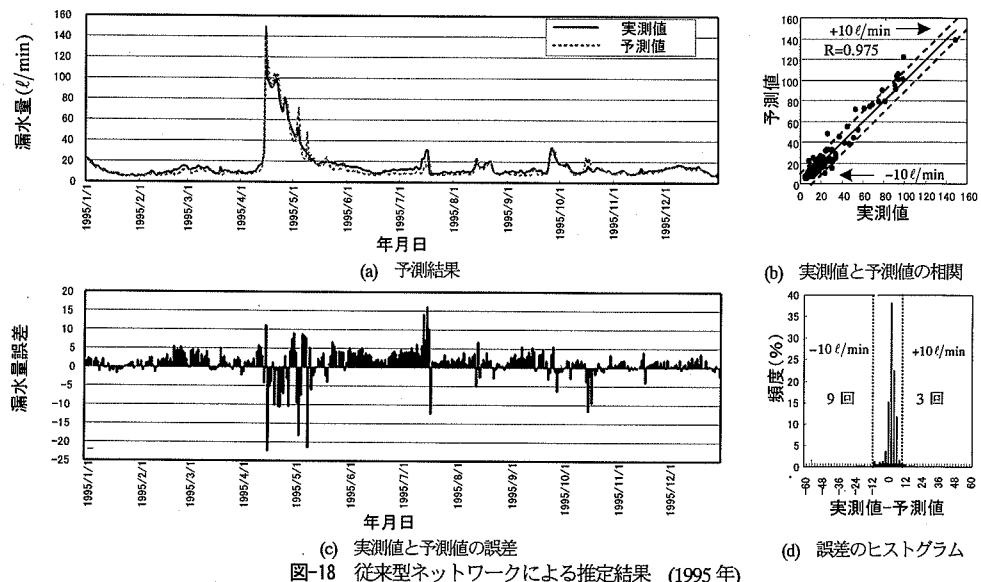
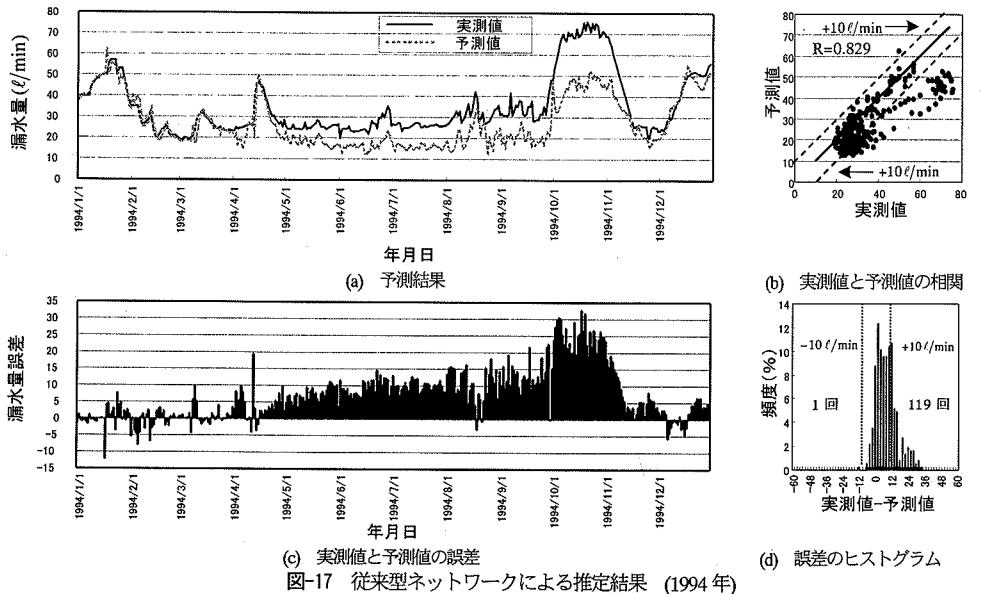
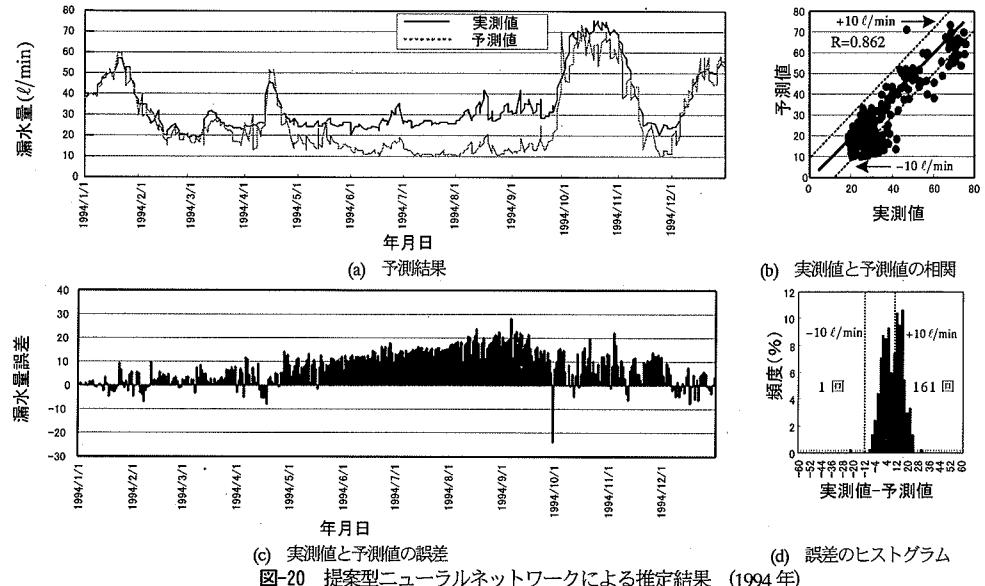
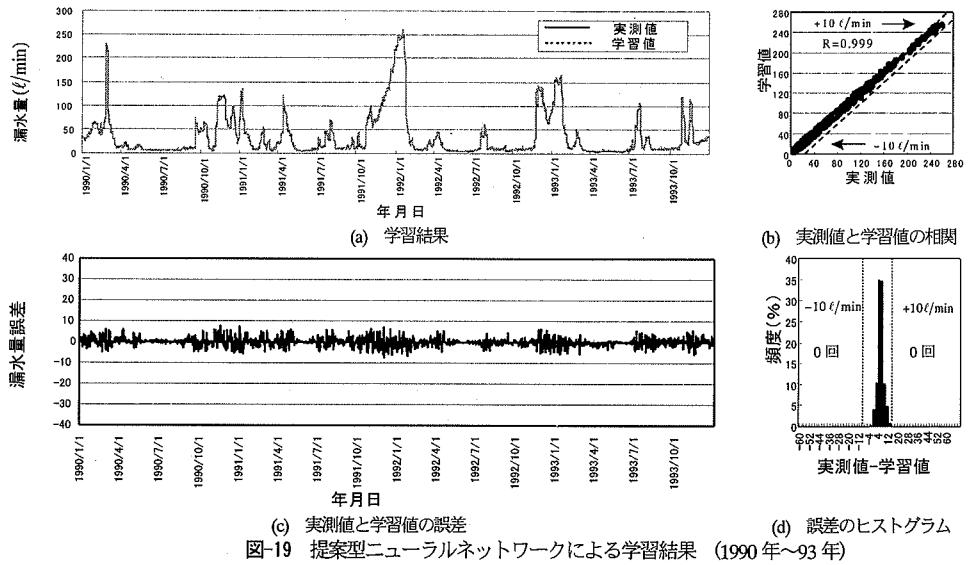


図-17には、この従来型ニューラルネットワークによって1994年1月～1994年12月の1年間の漏水量予測を行った場合の推定と調整された実測値の結果を比較図示する。重回帰モデルでは推定値と調整された実測値が一致していたが、図-17(a)のネットワークによる推定値は正常データにノイズを与えたため誤差が大きく、特に4月から急激に誤差が増加している。図-17(b)の相関図を見てても重回帰モデルに比べばらつきが大きく、相関係数も低い。また、図-17(c)には調整された実測値と推定値の誤差を示しているが、4月より誤差(絶対値)が $10\ell/\text{min}$ を超える日が連続して現れるようになる。すなわち、従来型ニューラルネットワークモデルは、正常データに乱れを与えた漏水データ特性の変化を検知し、「要調査シグ

ナル」を出し続けるので、計測データに何らかの異状があることを検知できる。

図-18には、正常データである1995年1月～1995年12月の漏水量の推定値と実測値の結果を比較図示する。図-18(a)の漏水量の推定値と実測値は概ね一致しており、図-18(b)の相関図を見ても重回帰モデルに比べばらつきが少なく、相関係数も高い。また、図-18(c)には実測値と推定値の誤差を示しているが、図-17(c)の結果に比べ $10\ell/\text{min}$ 以上の誤差が連続で現れるということではなく、1993年以前の漏水特性と1995年の漏水特性では大きな変化はない。このため、図-18(d)に示すように年間で12回の要調査シグナルを発生することになるが、過去の正常な年とあまり変わらない状態であることがわかる。



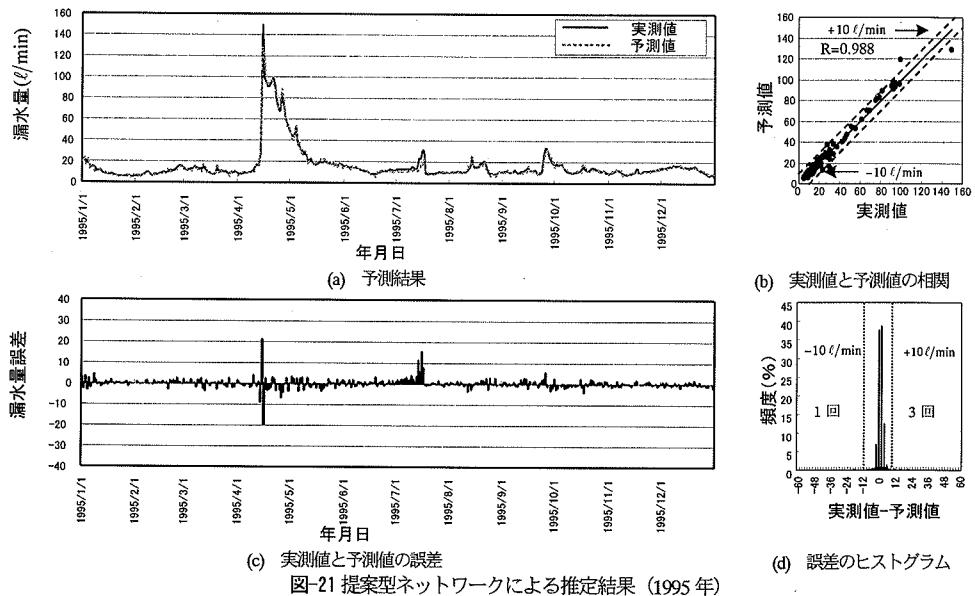
(4) 複閾数分類学習ニューラルネットワーク

統いて、提案する複閾数分類学習ニューラルネットワークを用いて同様の推定を行う。なお、このニューラルネットワークの中間層は14個とし、前述の従来型よりも4個少ない。すなわち、やや非線形性は弱まっている。また、パターン数を3とすると、最大誤差 $10 \ell/min$ 以下となる収束判定を約5万回程度の学習計算で達成する。なお、パターン数については、1, 2と増やしていく3で収束したので、収束できる最小値としてパターン数は3とした。

図-19は、4年間のデータに対する複閾数分類学習ニューラルネットワークの学習結果を示している。図-19(a)には、ネットワークによる学習値と実測値を比較図示し

ている。なお、ここで比較値は3つのパターンの中で実測値と最も小さいものを用いている。ネットワークによる近似は、重回帰モデルまたは従来型ニューラルネットワークと比較して極めて良好な近似である。図-19(b)には実測値と学習値との相関を示しているが、相関係数も0.999と極めて高い。また、図-19(c)に示す実測値と学習値の誤差および図-19(d)の誤差ヒストグラムによると、 $10 \ell/min$ を超える日が一度もなく、学習で得られた3パターンの近似閾数は、提体のこの4年間における漏水特性を良く近似できていることがわかる。このことにより、推定で $10 \ell/min$ の誤差をしきい値として使用することが有効となる。

図-20には、このネットワークによって1994年1月～



1994年12月の1年間の漏水量予測を行った場合の推定と調整された実測値の結果を比較図示する。図-20(a)より、従来型ニューラルネットワークと同じく4月頃より急に誤差が増加していることがわかる。図-20(b)の相関図では、重回帰モデルに比べばらつきが大きく、相関係数も低い。また、図-20(c)に示した推定値の誤差によると、4月より誤差（絶対値）が $10\ell/\text{min}$ を超える日が連続して現れるようになる。その「要調査シグナル」発生回数は162日と従来型ニューラルネットワークモデルの120日よりも多く、学習期間のモデル近似が極めて良好であることとの差異が明瞭である。すなわち、提案手法は1994年のデータの乱れを明瞭に検知できることがわかる。

図-21には、複数分類学習ネットワークを用いて正常データである1995年1月～1995年12月の漏水量予測を行った場合の推定と実測値の結果を比較図示する。図-21(a)の推定値は実測値と一致しており、図-21(b)の相関図を見ても相関係数は高い。また、図-21(c)には実測と推定値の誤差を示しているが、図-20の結果に比べ $10\ell/\text{min}$ 以上の誤差が連続で現れるということではなく、図-21(d)のヒストグラムでも $10\ell/\text{min}$ 以上の誤差が生じる日は4日と極めて少ない。すなわち、提案する複数分類学習ニューラルネットワークシステムは、この観測システムが1994年3月以前のものと同じ状態であることを明瞭に認知できる。

表-2に各手法ごとの要調査シグナル発生回数の比較を示す。システムの目的からすると、1990年～1993年の近似期間での発生回数と1995年のシステム復帰後の発生回数が少なく、逆に、1994年の発生回数が多いことが、構造または計測システムの異状を検知するうえで好ましい。表-2より、重回帰モデルは、近似の段階で既に年平均30

表-2 各手法ごとの要調査シグナル発生回数

手法	年間要調査シグナル回数（誤差 $\geq 10\ell/\text{min}$ ）		
	1990年1月～1993年12月 (学習開始)	1994年1月～1994年12月 (データ乱れ混付)	1995年1月～1995年12月 (正常データ)
重回帰	114回	5回	9回
従来型	76回	120回	12回
提案型	0回	162回	4回

回程度の警報発生となっており、またその誤差も前述のように大きい。よって、推定年において大きな誤差がある日が数日生じてもそのデータの異状を判別することが困難となる。さらに悪いことには、異状データの年に逆に警報発生回数が減少している。よって、重回帰モデルは好ましいシステムとは言い難い。一方、従来型ニューラルネットワークは、異状年に120回、正常年には12回の警報回数と明確に差異が現れており、重回帰モデルのような問題点はない。しかし、堤体が正常であることが判明しているはずの1990年～93年の学習結果でも年平均25回程度の誤差がしきい値 $10\ell/\text{min}$ を超える日が存在し、前述のようにその最大誤差は $42\ell/\text{min}$ となる。本研究では、比較する提案手法のしきい値を準用して、 $10\ell/\text{min}$ をしきい値と決定したが、1990～93年の誤判断数を減ずるにはしきい値を大きくする必要がある。その場合には、1994年の異状判定回数が減ることになり、表-2に示すほど明確な差異が得られなくなる。これは、実ダムの漏水データには複数のパターンの漏水因果関係が混在しており、図-5で説明したように同一入力に対して

複数の互いに矛盾する出力があつたり、図-6 で説明した近接した入力値に対して大きく異なる出力値が混在しているため、一関数によってデータ近似を行う従来型ニューラルネットワークでは充分な学習収束ができないためである。また、システムが正常である 1995 年においても、年 12 回の警報発生となり、これは毎月 1 回程度の誤情報となる。これに対して、提案手法では、1990~93 年のデータに対してしきい値 $10 \ell /min$ 以下の誤差になることが確定されているため、しきい値設定に矛盾が生ずることはない。さらに、異状年と正常年の警報発生回数は極めて明瞭に差異があり、正常年では年 4 回と誤判断発生回数も少ない、好ましい結果が得られている。

5. 結 言

本研究は、複関数分類学習ニューラルネットワークを、ダムの漏水量管理システムに適用することを試みたものである。本研究の成果を要約すると以下のようになる。

- (1) 漏水データの変化は極めて複雑であるが、線形の重回帰モデルでも一見すると良い近似が可能である。これは、前日漏水量との相関性が極めて高いためである。しかし、前日との変化が小さい場合には、そのデータが過去のものとは異なる傾向であってもデータの異状を検知できない傾向がある。
- (2) ニューラルネットワークは前日漏水量以外の水位変化など非線形性のあるデータの影響を反映した近似を行うので、重回帰モデルに見られる問題点が生じにくく、精度が良いモニタリングシステムを構築できる。しかし、実測データには、複数のパターンデータが混在しているため、従来型ニューラルネットワークでは完全に近似を収束させることができない。しかし、提案する複関数分類学習型ニューラルネットワークでは、データ群を内在する複数のパターンに分類して、それぞれに対する近時曲線を作成するため、より明瞭に異状を検知することができる。

(3) 提案する複関数分類学習ニューラルネットワークによる漏水データモニタリングシステムは、実ダムのデータに対しても、期待するように正常と「要点検」を区分することができる。ただし、実ダムの管理基準の要求レベルは、堤体が正常である限り要調査シグナルを発しないことが必要であり、さらに精度向上のための工夫が必要である。

参考文献

- 1) 財団法人 日本ダム協会：ダム年鑑 2001, 日本ダム協会, 2001.
- 2) 財団法人 ダム水源地環境整備センター：ダム管理条例規集, 山海堂, 1994.3.
- 3) 財団法人 國土開発技術研究センター：解説・河川管理施設等構造令, 山海堂, 1999.11.
- 4) 塩崎功, 向上拡美, 合田勝男, 齋田賢次郎：重回帰分析手法を用いたダム漏水量の予測・監視 降水量・貯水位・融雪量を説明変数として, 間組研究年報, pp.81-95,1991.
- 5) 徳井順, 西恭二, 美濃宏樹, 広川晶：農業用フィルダムの漏水量安全管理における Kalman フィルタ理論およびタンクモデル理論の応用について, 農業土木学会 北海道支部研究発表会講演要旨集, pp.100-105,1989.
- 6) 後藤勇司, 坂本邦隆：パーソナルコンピュータを活用した栗山ダム計測管理システムについて, 電力土木, No.236, pp.63-69,1992.
- 7) 梅島仙次郎, 角江俊昭, 三浦康史：フィルダムの浸透水量予測式について, 土木学会年次学術講演会講演概要集, Vol.40,pp.383-384,1985.
- 8) 松岡茂, 福原輝幸, 柳博文：コンクリートひび割れからの漏水メカニズムと漏水量予測, 土木学会論文集, No.523/III-32,pp.83-90,1995.9.
- 9) 長通伸幸, 香月智, 深和岳人：複関数分類・学習ニューラルネットワークと構造モニタリングへの応用, 土木学会論文集, No.710/I-60,pp.321-335,2002.7.
- 10) T.Kohonen：自己組織化マップ, シュプリンガー・フェアラーク東京株式会社, 1996.6.
- 11) 土木学会 岩盤力学委員会：ダム建設における水理地質構造の調査と止水設計, 2001.6.

(2003.8. 28 受付)

LEAKAGE MONITORING OF A GRAVITY DAM USING A MULTI-PATTERN DIFFERENTIATION NEURAL NETWORK SYSTEM

Nobuyuki NAGADORI, Takeshi SAKUDA and Satoshi KATSUKI

This paper proposes an irregularity detecting monitoring system of gravity dam related with a monitoring data of leakage by using the multi-patterns differentiating neural network system. The proposed system predicts the leakage amount with respect to the water level of dam, precipitation, temperature of water, air and leakage water every day. The difference between the prediction and the observation of leakage notices an irregularity of the dam. The real observation data used herein contains an irregularity induced by giving an artificial noise. The neural network system detects this irregularity much better than the multi-regression system. The proposed system detects it better than conventional neural network system, because the observed data includes multi-patterns relationship between input and output data.