

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

長通伸幸¹・香月智²・深和岳人³

¹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)

²正会員 工博 防衛大学校助教授 システム工学群建設環境工学科 (〒239-8686 神奈川県横須賀市走水 1-10-20)

³正会員 修(工) 防衛大学校助手 システム工学群建設環境工学科 (〒239-8686 神奈川県横須賀市走水 1-10-20)

本研究は、入出力関係を形成する関数が複数混在するデータ群をそれぞれのパターンに分類・学習するニューラルネットワークを提案し、構造物のモニタリングデータを用いた構造状態の変化を検知するシステムへの適用を試みたものである。既存構造物は時間経過に伴って既に幾分か劣化や損傷が含まれていることや、モニタリング点数に制約があるために、モニタリングデータ間に複数の入出力関係が混在する場合がある。提案するニューラルネットワークは、このような問題を自動的に複パターンに分類・学習するものである。提案システムの適用性を検討するために実構造物に模した鋼板構造加振実験を行い、加速度入出力関係の同定手法を検討し良好に同定できることを示した。また、提案手法により構造状態の変化を検知できることを示した。

Key Words: neural network, monitoring, structural characteristics, differentiation, damage detection

1. 緒言

近年、構造物の維持補修における意思決定に資するため、各種センサーによるモニタリングデータを活用する方法が着目されている¹⁾。例えば山口ら²⁾は、鶴見つばさ橋の常時微動実験および定常加振実験結果から動的特性の同定を試みている。その他にも多くのモニタリングデータを利用して既設構造物の動的特性を同定する研究³⁾⁴⁾や、土岐ら⁵⁾の、同定された特性値と観測値を用いて地震波の推定に応用している例等もある。また、岡林ら⁷⁾⁸⁾は、近年の通信情報処理技術の高度化に着目し、遠隔処理技術を利用したモニタリングシステムについて提案している。これらの正常な構造の特性把握だけでなく、大島ら¹⁰⁾や、西村ら¹¹⁾のように損傷推定への応用について検討している例もある。加えて、モード解析法によって診断を行う研究も行われている¹²⁾。また、斎藤・星谷¹³⁾や、安田ら¹⁴⁾は、モニタリングデータの処理技術の一方法としてニューラルネットワークの活用について検討しており、ニューラルネットワーク技術が構造同定および健全度評価へ応用可能であることを示している。さらに中村ら¹⁵⁾は、同定と診断に人工生命技術を応用した総合的橋梁診断システムの開発を行っている。

モニタリングを用いて構造の劣化を診断するには、2通りの方法が考えられる。すなわち、①第一法：構造物の正常時におけるモニタリングデータと劣化後のモニタリングデータの相違が明確に判明しており、モニタリングデータが劣化範囲に陥った場合に対策を講ずるシステム、②第二法：構造物の劣化に伴うモニタリングデータの変化からフィードバック的に劣化判定基準を作成、または適宜に作成し対策を講ずるものである。

意思決定の明瞭性から見ると、第一法が望ましい。しかし、①土木構造物の多くは新設時にはモニタリングシステムが設置されておらず、新設時の正常状態での基準値を得ることが難しく、②FEMなどの理論応答値と実構造物のモニタリングデータとを一致させることは困難な場合が多く、③既設構造物にモニタリングシステムを付け加えた場合には既に幾分か劣化・損傷には進展しているものと考えられる。よって、モニタリングデータに与える既存劣化の影響を絶対的定量値によって与えることが難しい。

このため、モニタリングシステムの判定基準は、第二法となることが多々あるものと考えられる。しかし、第二法においてはモニタリングデータ間の物理的關係付けが理論的に難しいことを前提としており、データに含ま




図-1 構造システムの変化とモニタリングデータ変化




図-2 構造特性変化と時間経過の関係

れるノイズや不確実性が混在することを前提とした判定システムを構築する必要がある。

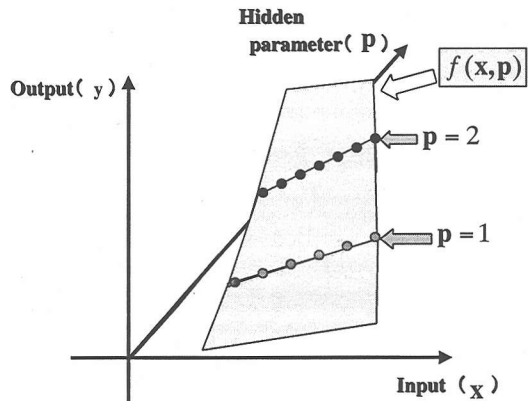
本研究は、多点モニタリングを行うシステムにおいて、モニタリングデータ間の関係付けをニューラルネットワークシステムのフィッティング機能を利用することを前提とし、その際に構造物の特性が隠された支配パラメータによってあたかも複数存在するかのように見えることを前提としたシステムを提案したうえで、その適用性について基礎的に検討したものである。

2. 構造特性遷移判定システムおよび複関数分類学習ニューラルネットワーク


(1) 構造特性遷移判定システムの考え方

図-1に模式的に示すように、既設構造物に複数(種類)のモニタリングセンサーを取り付け、時間経過に伴って構造物に生ずる劣化や損傷を検知判定するシステムを想定する。この場合、複数のデータ間に物理的因果関係が存在するならば、図中に示すように一部を入力信号とし、一部を出力信号とするデータ間には特定の関数補間が可能である。また、時間経過に伴って構造物に損傷や劣化が生ずると入出力データの関係に変化が生ずるものと考えられる。


時間経過と特性変化をイメージ的に見ると、図-2に示すように、①時間経過に伴って徐々に変化するタイプ I



(a) 出力変数の支配曲面



(b) 観測値



(c) 複パターンの入出力関係

図-3 構造特性遷移判定システム

と、②時間経過のある時期に特性が変化するタイプⅡがあると考えられる。タイプⅠでは徐々に変化が進むため、変化の態様のみで対策を判断することは困難であり、観測データの絶対的変化量と構造の物理的特性との対応を明らかにして、対策を講ずる基準値を設定する必要がある。一方、タイプⅡでは明らかに構造特性が変化したことが判断できるので、変化が生じた場合に構造異常の有無について診断を促すトリガー情報を得ることができる。本研究では、タイプⅡを対象としたシステム構築を考えている。

さて、タイプⅡのモニタリングシステムを構築する場合には正常（計測開始時）な構造状態における観測データの入出力関係を関数化しておく必要がある。しかし、構造システムの出力値に及ぼすパラメータは観測されている入力パラメータ以外にも存在することが考えられる。図-3(a)に、このような隠されたパラメータを含む入出力データの関係を示す。これは、出力 y を決定するパラメータの中に観測値 \mathbf{x} 以外にも、観測されていないパターン決定変数 p が存在することを現している。すなわち、

$$y = f(\mathbf{x}, p) \quad (1)$$

ここで、 y ：出力観測値、 \mathbf{x} ：入力観測値、 p ：観測されていないパターン決定変数。

観測されていないパターン決定変数とは、例えば図-1において構造物は間隙を有するように描かれているが、間隙に物が挟まったり、温度膨張で接触したりすると、あたかもスイッチのオン・オフ機能のように特性を変えることを表しており、観測し難い、または観測されていない変数をいう。

このようにパターン決定変数が離散的な値をとる場合には、観測されている空間内で、図-3(b)に示すようにあたかも入出力関係に複数の関数が存在するのようになる。この状況では、モニタリングデータからパターン変数を得ることができないので、図-3(c)に示すように一組の入力 \mathbf{x} に対して複数のパターンに対する関数出力を推定するシステムが必要である。

ここで、図-1と図-2で示したタイプⅡとをリンクさせて考える。すなわち、段階的に構造特性が変化することは、損傷や劣化によって既往状態での構造パターンにはなかった新しい入出力関係が生じることになる。以上の前提に基づいて、構造物が既往状態（正常）から何らかの新しい状態へ遷移したことの判定システムは、図-4のようにして構築することができる。すなわち、

- ① 既往観測データの一部を入力とし、残りを出力側と指定する。
- ② 観測された入出力データをパターン分類し、それぞれのパターンごとに入出力関係を同定する。
- ③ 新観測データの入力データを、同定された既往パターンの関数に入力し、パターンごとの出力値を得る。

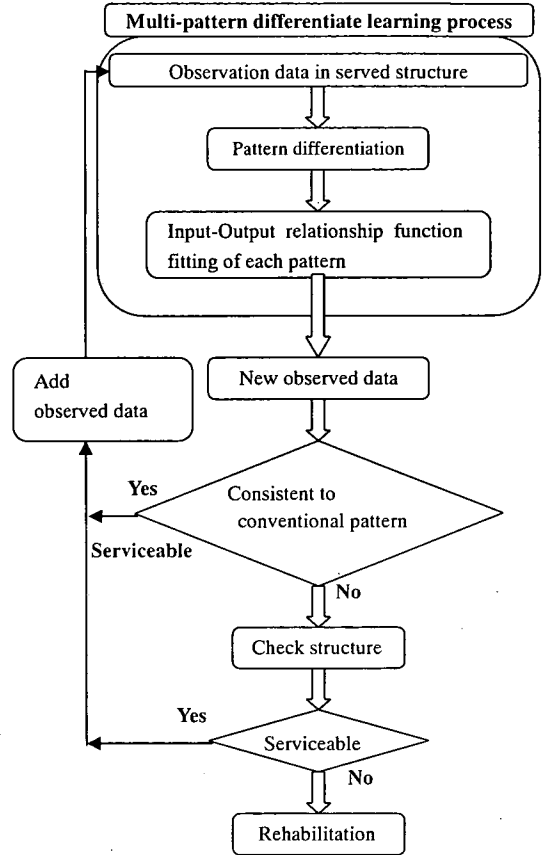



図-4 構造特性遷移判定システム

- ④ 新観測データの出力側データと各既往パターン推定出力値とを比較し、一致するものがあれば構造物は過去の正常状態にあるものと判断する。
- ⑤ いずれにも一致しない場合には、構造物に変化が生じているので、危険性や対策の必要性がないか点検する。
- ⑥ 点検結果で正常と判断された場合には、同定関数の修正を行うため既往観測データに加えてステップ①～②を行う。
- ⑦ 構造物に異常があれば補修等の処置を施す。


以下に、このモニタリングシステムに用いる複関数分類学習ニューラルネットワークについて述べる。

(2) 複関数分類学習ニューラルネットワーク

図-5に、提案する複関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階層型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^{10,17,18)}では、入力ベクトル \mathbf{x} (n_1 次元)と出力ベクトル \mathbf{y} (n_2 次元)との間を図-5(a)のような中間層ニューロンと関係付けて構成したうえで、学習データ \mathbf{T} (n_2 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 \mathbf{w} およびニューロン特性を決定するシグモイ



(a) 従来型



(b) 提案型

図-5 提案ネットワークと従来型ネットワーク

ド関数のしきい値 θ を探索決定する。

一方、提案するシステムは第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。そのうえで学習データ \mathbf{T} (n_o 次元) をどのパターン関数に属するかについて識別分類した後に、学習するものである。ここで、識別分類の基準は各パターン出力と教師信号が最も近いものを選択するものとした。すなわち、

$$i_{select} = \min |T - y_i| \quad (2)$$

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。

$$|T - y_{i_{select}}| \rightarrow \min \quad (3)$$

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しないことで判断できるので、改めて初期のネットワーク構成をランダムな値を用いて構成しなおすものとした。なお、本研究では基本的に3層型で、シグモイド関数を用いたネットワークであり、学習はバックプロパゲーション法¹⁷⁾を用いる。

また、パターン分類数等の決定については以下のような基準を用いた。

- 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小さくする。

以上を考慮したネットワークのシステムパラメータ決定要領を図-6に示す。

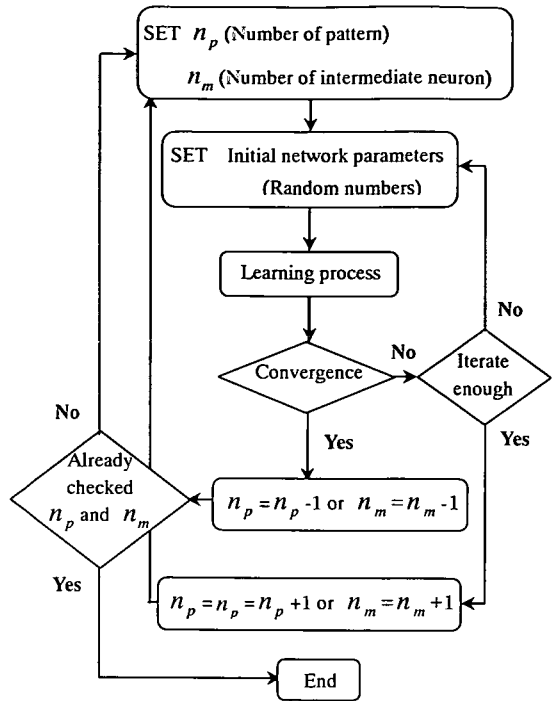


図-6 システムパラメータの決定要領

3. 数値問題による検証


ここでは、提案するニューラルネットワークを具体例によって補足説明し、また、その能力を検証するために、基本的な数値問題を用いて説明する。

(1) 完全矛盾線形関数データ


まず、線形の2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-7(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。

$$\begin{cases} y = 2 & (\text{pattern 1}) \\ y = x + 3 & (\text{pattern 2}) \end{cases} \quad (4)$$


ここで、2つのデータ群が完全矛盾関係となるように x 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 (入力層 $n_i = 1$, 中間層 $n_m = 6$, 出力層 $n_o = 1$) を用いてフィッティング (学習) したものを図-7(b)に示す。従来のネットワークでは1つの関数で最小誤差になるようにフィッティングするため、両データ群の中間に位置する関数が得られる。この場合の収束誤差は最小ではあるが大きなものとなる。一方、提案手法 (入力層 $n_i = 1$, 中間層 $n_m = 6$, 出力層 $n_o = 1$, $n_p = 2$) における学習プロセスを図-7(c)に示す。初期値のネットワーク出力は教師データと一致しないが、各パターンの出力値は教師データと近い方の出力




(a) 教師データ



(b) 従来型ネットワーク



(c) 提案法学習プロセス



(d) 提案法学習結果

図-7 完全矛盾線形関数データ


値のみが近い方のデータに近づくように学習するので、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く様子がわかる。最終的には図-7(d)に示すように3万回の学習で各教師データに一致する2つのパターン出力が得られるネットワークが構築される。

(2) 非矛盾線形関数データ


図-8には次式による2つの線形関数による教師データを示す。

$$\begin{cases} y = 2 & (\text{pattern 1}) \\ y = 4 & (\text{pattern 2}) \end{cases} \quad (5)$$


ただし、pattern1 関数では $x = \{1,2,3,4,5,6,7,8,9\}$, pattern2 関数では $x = \{0.5,1.5,2.5,3.5,4.5,5.5,6.5,7.5,8.5,9.5\}$ と相互に異なる入力値を用いているので、同一の x 値に対して



(a) 教師データ




(b) 従来型ネットワークによる学習結果




(c) 提案法による学習結果

図-8 非矛盾線形関数データ



(a) 教師データ



(b) 提案法学習結果

図-9 非線形データ

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。そこで、従来の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




図-10 鉄板寸法および加速度計配置図




写真-1 実験装置

ラバー：100mm×100mm×20mm




写真-2 載荷物

を高めると、図-8(b)のように全ての教師信号を通過する関数を求める。一方、提案手法($n_i = 1, n_m = 6, n_o = 1, n_p = 2$)で学習させると、図-8(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フィッティングを完了するが、教師データの中間的 x 値を与えると出力値に違いが現れる。従来法では、教師信号はほぼ完全に同定しているにもかかわらず、内層未知学習領域で工学的におかしな値が得られる場合を過学習として処理されることが多い。提案手法はこの過学習の問題点も回避処理することがわかる。

(3) 非線形関数

前述の例題においては、適切な線形変換を施すとパターンごとのデータ群が分離でき、SOM¹⁹⁾などの手法を用いて事前処理においてパターン分類が可能である。しかし、各パターンのデータが非線形関数で与えられる場合には事前処理によってパターン分類することができない。そこで提案手法の非線形関数への分類学習能力を見るため、次の関数による教師データを用いた。

$$\begin{cases} y = \sin x & (\text{pattern1}) \\ y = \cos x - 2 & (\text{pattern2}) \end{cases} \quad (6)$$

これを提案手法($n_i = 1, n_m = 4, n_o = 1, n_p = 2$)を用いて分類学習させると、図-9(b)のようになり、各パターンを良く分類認識してそれぞれのデータに対するフィッティングを完了している。ちなみに、フィッティング関数と教師データとの相関性を表す決定係数²⁰⁾は $\rho^2 = 0.999$ である。




写真-3 加振装置

4. 鋼板構造加振実験への応用

(1) 実験要領

提案手法の適用性を検討するために、鋼板構造を使った実験を行い、その振動特性の変化を検知するシステムの構築を試みた。

実験に用いた鋼板は、写真-1および図-10に示すようにSS400の1.35m×1.10mの長方形板で厚さ6mmのものである。この鋼板は別の用途に作られたものであるため、周辺には不規則に直径22mmの穴が開けられており、構造の振動特性は複雑な因子を多く含んでいる。これは既設建造物の複雑さを模したものである。

この構造の振動特性が離散的に変化する因子として、写真-2に示す300gのラバーの上に5kgおよび10kgの鋼製の重錘を載せたものを出力加速度計から25cm、50cm、75cm離れた位置に載せて作為した。すなわち、何も置かない状態を新設状態に、重錘を[1]と[2]の位置に置く状態をその後の構造状態の変化によって生じた2種類の追加パターン状態に模擬しており、重錘位置が[3]とは、新し

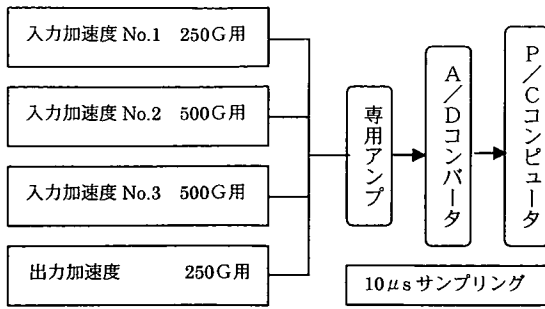




図-11 計測システム図

表-1 実験ケース


番号	ケース名	加振位置	載荷物位置	載荷重量	加振回数	備考
1	A-Non	A	なし	なし	5	既往構造状態
2	B-Non	B	なし	なし	5	
3	C-Non	C	なし	なし	5	
4	A-{1}-0.5	A	出力計から25cm	0.5kN	5	
5	B-{1}-0.5	B	出力計から25cm	0.5kN	5	
6	C-{1}-0.5	C	出力計から25cm	0.5kN	5	
7	A-{2}-0.5	A	出力計から75cm	0.5kN	5	
8	B-{2}-0.5	B	出力計から75cm	0.5kN	5	
9	C-{2}-0.5	C	出力計から75cm	0.5kN	5	
10	A-{3}-1.0	A	出力計から50cm	1.0kN	5	新状態
11	B-{3}-1.0	B	出力計から50cm	1.0kN	5	
12	C-{3}-1.0	C	出力計から50cm	1.0kN	5	




(a) 入力加速度計 No.1



(b) 入力加速度計 No.2



(c) 入力加速度計 No.3



(d) 出力加速度計

図-12 計測生データ (A-Non)

く構造に生じたパターンを模したものである。加振入力としては、写真-3 に示すように垂直に支持された長さ16.5cm、質量100gの鋼棒を高さ5cmの位置から落下衝突させた。

なお、実験に対応する具体的な実構造物を設定していないので、穴の大きさや載荷物および入力打撃等の設定に対応する実構造物との整合性は考慮されていない。しかし、鋼製構造物の一部材として、または、全体構造として定性的にこのような状況があることを想定したものである。

落下衝突の位置は、図-10 に示すように入力加速度計設置側短辺の両端と中央の3点である。なお、加速度計の応答周波数は50kHzであり、最大容量は図-11 に示したものである。以上のパラメータを組み合わせた実験ケースは、表-1 に示すように12ケースとなり、各ケース5回ずつ加振し、データサンプリングした。構造状態のモニタリングデータとしては、図-10 に示すように加振装置の近傍に30cm間隔で設置された入力加速度データ3個と反対側に設置された1個の出力加速度データを用い、

図-11 に示すように10μsecのサンプリング間隔でデジタルデータ保存した。

(2) 従来型ニューラルネットワークによる構造同定

提案する複関数分類学習システムを適用する前に、従来型ニューラルネットワークによってモニタリングデータの入出力関係を同定できることを検証しておく必要がある。

図-12 に、実験ケース A-Non において計測された入出力加速度データの例を示す。計測開始0.0022秒後に加振棒から最も近い入力加速度計 No.1 に191Gの加速度が現れた。続いて入力加速度計 No.2 は0.00258秒後に260G、入力加速度計 No.3 では0.00262秒後に176Gの加速度がやや遅れて現れた。出力加速度計は離れているので0.0035秒後に150Gが現れた。ところで、入力加速度計 No.1 で、0.075秒以降において再度卓越した加速度70Gが現れるが、これは加振棒が跳ね上がった後に再打撃したものである。入出力関係が不要に多様化することを避けるため、以下のデータ処理は再打撃前までのデータを用いて処理を行




図-13 打撃振動伝播経路の多様性

う。また、以後のデータ処理においては、加振位置に最も近い入力加速度計の加速度が現れる時間を処理開始時間とする。

さて、加振点で発生した振動は全方向に向かって傳播するが、図-13に示すように加振点近傍にある観測点①を通過した後、観測点②に至る経路は多数存在する。その経路ごとに観測点①を通過後に②に至る経路長さが異なるため、各々のタイムラグに差が生じる。ちなみに、鋼材の縦波傳播速度(5000m/s)による鋼板長辺の傳播時間は、250 μ sであり、データサンプリング間隔10 μ sは十分にタイムラグを検知できる範囲にある。

まず、タイムラグの影響を調べるために、次式によるタイムラグ相関係数を求めた。

$$\rho_{\Delta t} = \frac{\sum I_t \cdot O_{t+\Delta t}}{\sqrt{\sum I_t^2 \cdot \sum O_{t+\Delta t}^2}} \quad (7)$$

ここで、 $\rho_{\Delta t}$: タイムラグ Δt 秒データ間の相関係数、 I_t : 時刻 t における入力加速度データ、 $O_{t+\Delta t}$: 時刻 $t + \Delta t$ における出力加速度データ。

図-14(a)に、図-12で示した生データに対するタイムラグ相関係数を示す。タイムラグが0.0185sにおいて最大相関係数0.185が得られるほか、多数の点で相対的に大きな相関係数が現れるが、十分に大きな相関係数は得られない。このため、後述するようなニューラルネットワークによる出力データの予測システムは構築できない。図-14(b)には1000Hzでローパスフィルタ処理²⁾(ブラックマン窓関数)したデータに対するタイムラグ相関係数を示している。最大相関係数 $\rho = 0.372$ とやや大きくなるがこの場合も入出力関係をあまりうまくフィッティングできない。

そこで、計測データを100Hzのローパスフィルタ処理をすると、図-15のように高周波成分が取り除かれ、入力と出力の波形に相似性が認識できるようになる。このローパスフィルタ処理後のタイムラグ相関係数を求めると、図-16のようになり、概ね0.0025s周期で相関係数のピーク値が明瞭に現れ、タイムラグ0.0075sでは相関係数が0.81と、大きな相関係数が現れる。

a) 1加振点1入力測点システム

まず、加振点をA点に固定して、入力データは加速度







図-14 入力データとの時間差による相関性 (A-Non: 入力加速度計 No.1)




(a) 入力加速度 No.1 (ローパス後)



(b) 出力加速度 (ローパス)

図-15 100Hz フィルタ処理後の入出力データ (A-Non)

計No.1のデータのみを用いた場合の従来型ニューラルネットワークのフィッティング能力を検証してみる。そこで、図-17のように図-16(a)において相関係数の高いタイムラグを3個、5個または9個選択した従来型のニューラルネットワークシステムを用いて同定能力を調べた。学習データには4回分の加振データを用い、残りの1回分の加振データを予測検定に用いる。図-18に各システムによる①学習結果における予測値~教師データ相関図、②予測応答値、③未知データに対する予測値~観測値相関図を示す。図-18(a)の3つのタイムラグを用いるシステムでは、教師データに対する良好な学習収束が得られず、教師データと学習終了後による出力加速度推定値の決定係数 $\rho^2 = 0.516$ とあまり大きくない。このシステムを用いて未学習データ(第5回目の加振)を予測させると、図-18(a)の中央のようになり、初期の2波までは概ね傾向は一致するものの0.008~0.020sec間での予測値は全く



(a) 入力加速度 No.1~出力加速度 (b) 入力加速度 No.2~出力加速度 (c) 入力加速度 No.3~出力加速度
 図-16 ローパスフィルタ処理後タイムラグ相関係数 (A-Non)

一致していない。よって、この予測値と観測値の相関図を描くと右側の図のようになり、決定係数は $\rho^2=0.501$ となり観測値と予測値があまり一致しないことがわかる。図-18(b)の5つのタイムラグを用いた場合には、学習結果の決定係数が $\rho^2=0.921$ と向上し、未学習データに対する予測応答図も0.010~0.016secの部分を除きほぼ一致するようになる。さらに、図-18(c)の9つのタイムラグを用いると、学習および未知データの予測とも決定係数は0.9854と大きく、その応答値も0.012~0.015secでわずかな不一致があるが良く一致している。これらのことより、1加振点1入力測点を用いたシステムでは9点以上の高い相関性のタイムラグデータを入力層に用いると構造入出力特性を同定できることがわかる。

b) 1加振3入力測点システム


図-13で示した伝播経路の多様性を効率よく反映するには、入力測点数を多くする方法が有効と思われる。そこで、図-19に示すような従来型ニューラルネットワーク ($n_i = 6, n_m = 14, n_o = 1$) の入力層に、No.1~3の各入力加速度データの中で、図-16に示す2番目までの高い相関性を示すタイムラグデータを合計6つ抽出し入力データとして用いた。

図-20に、このシステムによる同定結果と未学習データに対する予測結果を示す。まず、図-20(a)の学習結果では教師データに対するフィッティングがほぼ完全であり、決定係数は0.998となっている。図-20(b)の未知データに対する時間応答の予測値も、図-18(c)の1加振1入力測点システムで9つのタイムラグを用いた場合よりも良く一致している。よって、図-20(c)の予測値と計測値の相関性はほぼ完全な直線となり、決定係数も0.993と高い。このように、入力測点数を増す方が入力層の数を少なくでき、より同定能力の高いシステムを構築できることがわかる。


(3) 従来型システムによる構造特性遷移検知能力

a) 構造特性遷移検知

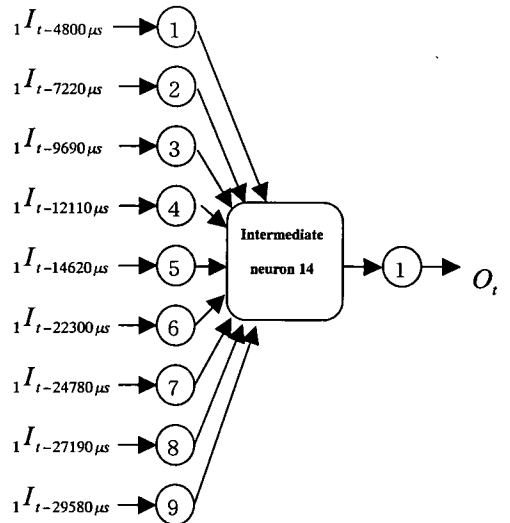
図-19で示したシステムは、実験ケース A-Non の特性を同定している。そこで、このシステムによって構造の振動特性が遷移したことの検知能力を確認するため、



(a) 3タイムラグ入力



(b) 5タイムラグ入力



(c) 9タイムラグ入力

図-17 1加振1入力測点システム

A-[1]-0.5の入力データを用いて出力値を予測させた。図-21(a)にその予測結果を計測値と比較して示す。予測値は初期の波でやや誤差があり、その後時間経過に伴って




図-18 1加振1入力測点システムの同定能力比較




図-19 1加振3入力測点システム

誤差が大きくなる。よって、予測値と計測値の相関性は著しく低下し、決定係数は0.792と小さくなる。すなわち、構造特性が変化したことを検知できる。

b) 加振点変化の感度

同システムを用いて、構造状態は何も载荷しない同一状態に保ったうえで、加振点が異なる B-Non に対する予測結果を図-22 に示す。この結果は著しく計測値と異なった予測値となっており、決定係数は0.128と極めて小さく、図-21(c)よりも相関性が低下している。すなわち、加振点の変化の方が構造特性変化よりも予測値と計測値間の相関性に与える影響が高く、このままでは構造特性






図-20 1加振3入力測点システムの同定能力




(a) 予測結果 (A-[1]-0.5)




(b) 予測値と計測値の相関 (A-[1]-0.5)

図-21 構造条件が変化したデータに対する予測検定




(a) 予測結果 (B-Non)




(b) 予測値と計測値の相関 (B-Non)


図-22 加振位置が変化したデータに対する予測検定



(a) 学習結果



(b) 未知データ予測結果 (A-Non)



(c) 未知データ予測の相関

図-24 従来型ネットワークの複パターン学習能力 (ケース1~9使用)

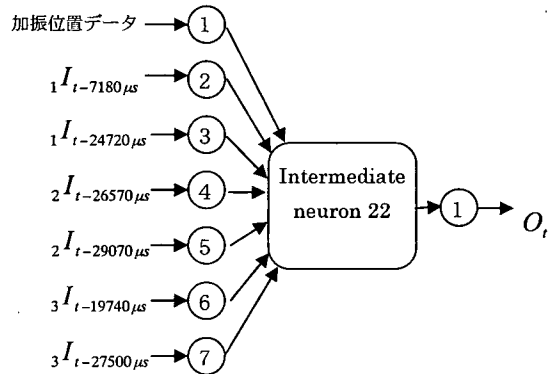


図-23 3入力加速度3加振点を用いるモデル

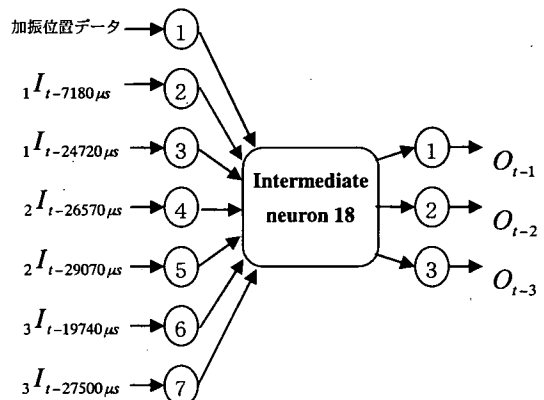


図-25 提案システム

が変化したのか加振点が変わったのか識別できない。

c) 複パターン混在データへの適用

そこで、加振点位置を入力情報として与える図-23に示すシステムを構築し、教師データとして表-1における

ケース番号1~9の加振4回分の実験データ、すなわち、複数の構造特性が混在するデータを与えて学習させた結果を図-24に示す。図-24(a)の学習結果をみると教師信号に対してうまくフィッティングできていないことがわ




図-26 提案システムの学習(1加振点システム)

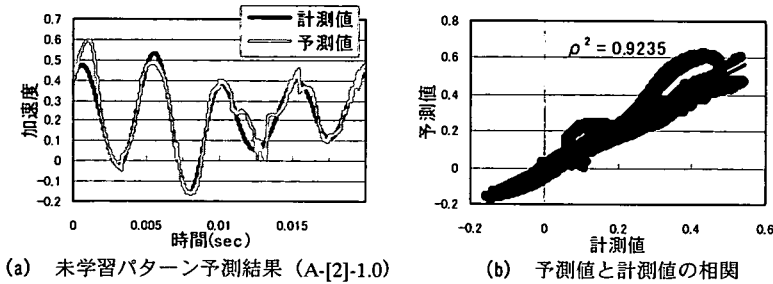


図-27 提案システムによる構造特性遷移探知 (1加振点システム)

かる。また、図-24 (b) の予測結果をみても全く一致しておらず、図-24 (c) の予測値と計測値との決定係数も 0.3064 と低くなっている。すなわち、従来型のニューラルネットワークでは複パターン混在データに対するフィッティングは難しいことがわかる。よって、後述するように新しい構造特性へ遷移したことに対する識別が明確にできない。

(4) 提案システムの適用

以上の従来型ニューラルネットワークの基本検討結果を反映して、提案する複関数分類学習ネットワークシステムを図-25 のように構築した。なお、ここで中間層の数が従来型では 22 であった (図-23) のものが 18 に減っているのは、図-4 に示したようになるべく中間層の数を減じる努力をしたためである。すなわち、同定システムの非線形が弱い方がより良いシステムと考えたのであるが、従来システムでは 22 個の中間層まで増やしても前述のように学習が収束しなかったのに対し、提案システムでは後述するように学習が収束した。図-23 と同様に加振点位置情報を入力値として用い、各入力加速度データから 100Hz ローパスフィルタ処理後に相関性の高い 2 つのタイムラグを使用する $n_i = 7, n_m = 18, n_o = 1, n_p = 3$ のモデルである。ただし、構造特性に対する入力データは与えずに複数の特性データが混在している。提案システムの適用性検討を、①加振点を A 点に限定する場合、②加振点は A, B, C の 3 点全部用いる場合の 2 種類で行う。

a) 1加振点データを用いる場合

加振点のデータを A 点に限定することにより、データ特性の多様性が減り、フィッティングが容易になることが期待できるシステムである。図-26 に 1加振点システムによる学習能力を示している。図-26 (a) には構造パターン Non, [1]-0.5, [2]-0.5 のデータのうち、最初の 4 回の加振データに対する学習結果の相関図を示している。データ量が多く 3 パターンのデータが混在しているので、やや膨らみが生じるが、決定係数は 0.9930 と高い相関性でフィッティングできている。図-26 (b) には、学習されたはずの構造パターン [1]-0.5 の未知データ (第 5 回目の加振) に対する予測値と計測値の比較を示している。システムが予測値が良く一致していることがわかる。図-26 (c) には、構造パターン Non, [1]-0.5, [2]-0.5 の未知データ (第 5 回目の加振) に対する予測値と計測値の相関図を示す。これより、本システムは既往の構造パターン Non, [1], [2] に対して極めて良く同定できていることがわかる。

そこで、構造特性を [3]-1.0 としたケース A-[3]-1.0 の入力加速度データを用いて、出力値を予測すると、図-27 (a) のようになる。概ね予測は計測値と一致しているように見えるが、最初の第 1 波、第 2 波のピーク値に明瞭なずれがあり、さらに、加振後 0.011~0.014 秒では、計測値にはない乱れた波形予測が生じ、全体的に一致していないことがわかる。図-27 (b) に相関図を示すが、相関線からはずれる一連の点が生じ、決定係数は 0.9235 と図-26 (c) のものよりも明らかに低下している。すなわち、既存構造状態と異なることを検知できる。




図-28 提案システムの学習(3加振点システム)




図-29 提案システムによる構造特性遷移探知(1加振点システム)

b) 3加振点システム

加振点の数を増やすと、データ特性の多様性が大きくなり、学習過程の同定難度は増すが、推定時のノイズに対する強靭性が増すことが考えられる。図-28には表-1のケース番号1~9までの4回分の加振データを用いた学習結果を示す。図-28(a)の学習結果は決定係数0.9737と、図-26(a)に示した1加振点モデルに比べやや劣るが良い同定が得られている。図-28(b)には、ケース Non, [1]-0.5, [2]-0.5の未学習データに対する応答予測と計測値の比較を示す。本構造パターンは学習値に含まれており、図-26(b)ほどではないが良い一致を示している。ちなみに、Non, [1]-0.5, [2]-0.5の全ての未知データに対する予測値の決定係数は図-28(c)に示すように0.9750と高い相関を示す。

図-29には、学習データに含まれていない構造パターンである[3]-1.0のケースを入力データとして用いて出力値と計測値を比較したものを示す。図-29(a)の応答予測では、まず第1波が一致しておらず、 $t = 0.010$ 以降の第3波、第4波では全く異なっている。図-29(c)の相関図では決定係数も0.806と著しく小さくなり、既往の構造特性とは異なった構造パターンに遷移したことを判断できる。

c) 構造特性遷移の検知

図-30には、提案手法での1加振システムによる決定係数の比較を示す。まず、左端の学習結果とは教師データに対するフィッティングの程度を示している。この場合、決定係数0.9930と高い相関性があり、学習結果が良い収束値を得たことがわかる。比較のためにパターン分

類を行わない従来型システムの決定係数は0.7423と小さく、あまり良い収束値が得られていない。これらの右にあるA-Non, A-[1]-0.5, A-[2]-0.5は学習に用いた構造パターンであるが、未知データへの推定を行いその観測値との相関性をチェックしたものである。相関性が一番低いA-[2]-0.5で決定係数は0.9780と、やはり高い相関性を維持しており、この学習結果の複関数分類学習ニューラルネットワークシステムが既往構造特性を良く同定できていることがわかる。

一方、パターン分類を行わない従来型ニューラルネットワークは、A-[1]-0.5およびA-[2]-0.5において決定係数が0.6510と学習結果に比べて相対的に0.1ほど小さくなる。

図中の一番右側のA-[3]-1.0は、学習に含まれない構造パターンである。提案システムの決定係数は0.9230と既往の最低値よりも0.05以上も小さくなっているため、構造特性が変化したことを認知できる。一方、従来型のニューラルネットでは、決定係数が0.5403と確かに低くなるが、既往構造状態であるA-[2]-0.5でも学習値から約0.1も小さくなる例があるので、新しい構造状態に遷移したのか判断基準が不明瞭である。

図-31には3加振点データを用いた場合の決定係数の比較を示す。まず、学習結果の決定係数は0.9742と1加振点よりもやや小さい。続いて既往構造パターンに対する未知データ予測値は概ね学習値と同等の決定係数を維持しており、最も小さいC-Nonでも0.9620である。一方、従来型ニューラルネットワークで同様のことを行くと、学習データの決定係数が0.4123と小さいことに加え、既

往構造特性の未知データ予測値の決定係数が 0.09~0.72 の範囲で大きくばらつき、既往構造特性状態であることの判定さえ難しい。新構造特性状態である A-[3]-1.0, B-[3]-1.0, C-[3]-1.0 に対する提案システムの決定係数は 0.8920, 0.7014, 0.8534 と既往構造状態よりも明らかに低下しており、構造特性が変化したことを明瞭に判定できる。一方、従来型ニューラルネットワークでは、新しい構造状態での決定係数はいずれの場合も約 0.1 程度で小さいが、既往構造でも B-[2]-0.5 では 0.0901 とこれより小さい決定係数となる場合があるため、構造特性が遷移したことの判定はできない。

図-30 と図-31 を比較してみると、仮に決定係数が 0.95 より小さいことによって構造特性が変化したものと判定する場合に、1 加振点システムでも提案法によって構造特性の遷移判定は可能であるが、新構造への遷移したことによる決定係数の低下は、3 加振点システムの方が大きい。よって、データ特性の多様性は大きくしたうえで、提案する複関数分類学習法を適用する方が、より明瞭に構造特性の遷移を判定できることがわかる。

なお、新しい特性へ変化したことの判断基準となる決定係数の臨界値については、構造物の特性、モニタリングデータやセンサーの特性に応じて決定されるものであり、今回の事例では 0.95 で識別できることがわかる。

5. 結 言

本研究は、構造モニタリングシステムへの新しいニューラルネットワークシステムの応用を提案したものである。本研究の成果を要約すると以下ようになる。

- ① 構造特性量の絶対的評価ではなく、相対的遷移を基準とするモニタリングシステムの考え方を提案し、その際、複数の関数データをパターン分類し、同時にフィッティングを行う同定法が必要であることを示した。
- ② 前述モニタリングシステムに用いるために、新しく複関数分類学習型ニューラルネットワークを提案した。
- ③ 数学的基本例題を用いて提案した複関数分類学習型ニューラルネットワークの動作および性能を示した。これより、提案システムは明確に非線形関数を含む複パターンデータを分類学習できることを示した。また、過学習の問題も解決できる可能性があることも示した。
- ④ 鋼板構造の加振実験を行い、ニューラルネットワークシステムで複数の加速度データに対する汎化能力を確かめた。その結果、適切なローパスフィルタ処理を行ったうえで相関性の高いタイムラグデータを用いると、単一の構造特性であれば従来型ネットワークを用いて十分に入出力関係を同定できることが認められた。
- ⑤ 鋼板構造の加振実験において、構造特性を変化させた複数のパターンデータを用いて提案システムの同定能




図-30 決定係数変化(1加振点システム)




図-31 決定係数変化(3加振点システム)

力を検定した。その結果、複数の加振位置と複数の重錘載荷位置を組み合わせた多様性の大きい複雑なデータ処理ほど、提案システムと従来型ネットワークの同定能力の差が大きくなり、分類学習の重要性が認められた。

⑥ 前述実験において、既往構造特性と異なる構造特性のデータに対する構造特性遷移判定を行った結果、提案するシステムの検知能力が高いことが認められた。特に、3加振点データを用いてデータの多様性を高めた場合には学習過程の同定難度が増すものの、新構造の検知能力は逆に高いことが示された。

なお、以上の結果は鋼材構造を用いた実験に限定されたものであり、実構造ではモニタリングデータにより大きなノイズが入ることや、より複雑な要因が混在することが考えられ、別途検討が必要である。また、提案システムの識別能力についても多様な案が考えられ、それらの効率性についても検討が必要である。また、本システムでは、図-2のtype I のように徐々に劣化が進む問題には適用できない点や、ニューラルネットワークが外挿領域への適合性に問題があることなどについて、実用化を図るうえで注意し、また別途検討する必要がある。

謝辞：本研究における鋼板加振実験を行うにあたり、本校研究科学生下山一貴氏のご協力を得たことを付記し、謝意を表します

参考文献

- 1) 土木学会構造工学委員会橋梁振動モニタリングとその標準化研究小委員会: Intelligent Bridge/ Structural and Smart Monitoring に関する公開講演会資料, 構造工学技術シリーズ No.12, 1999.11.
- 2) 山口宏樹, 高野晴夫, 小笠原政文, 下里哲弘, 加藤真志, 岡田淳: 鶴見つばさ橋の振動実験による動的特性の同定, 土木学会論文集, No.543/I-36, pp.247-258, 1996.7.
- 3) 安藤幸治, 岩楯敏広: 時間領域のモード解析による振動系の動的特性の同定とその適用, 土木学会論文集, No.450/I-20, pp.151-160, 1992.7.
- 4) 丸山收, 相沢旬, 星谷勝: ARMA モデルによる既存構造物の動特性の同定, 土木学会論文集, No.416/I-13, pp.439-447, 1990.4.
- 5) 佐藤忠信, 梶啓介: モンテカルロフィルタを用いた構造同定, 土木学会論文集, No.675/I-55, pp.161-170, 2001.4.
- 6) Toki, K., Sato, T. and Kiyono, J.: Identification of Structural Parameters and Input Ground Motion from Response Time Histories, *Proc. of JSCE*, No.410/I-12, pp.243-251, 1989.10.
- 7) 岡林隆敏, 山森和博, 讃岐康博, 田村太一郎: 近接固有値を有する構造物の振動特性推定, 土木学会論文集, No.633/I-49, pp.93-102, 1999.10.
- 8) 岡林隆敏, 山森和博, 田丸康広, 吉村徹: 可搬型振動計測システムによる構造物の振動特性推定, 土木学会論文集, No.591/I-43, pp.327-337, 1998.4.
- 9) 岡林隆敏, 吉村徹, 河村進一, 細川雅史: 無線LANおよびインターネット技術を活用した橋梁施工管理のための遠隔計測システム, 構造工学論文集, Vol.47A, pp.285-292, 2001.3.
- 10) 大島俊之, 三上修一, 山崎智之, 丹波郁恵: 橋梁健全度評価に用いる評価方法の検討と影響要因の解析, 土木学会論文集, No.675/I-55, pp.201-217, 2001.4.
- 11) 西村昭, 藤井学, 宮本文穂, 富田隆弘: 橋梁診断のシステム化に関する基礎的研究, 土木学会論文集, No.378/V-6, pp.175-184, 1987.2.
- 12) 例えば, Yuan, Hong Ying, Hirao, K., Sawada, T. and Nariyuki, Y.: Modal analysis method for stiffness degradation identification of non-proportionally damped structures, *Proc. of JSCE*, No.495/I-28, 1994.7.
- 13) 斎藤芳人, 星谷勝: 構造物の同定・予測に関する基礎的考察, 土木学会論文集, No.489/I-27, pp.91-100, 1994.4.
- 14) 安田登, 白木渡, 松島学, 堤知明: ニューラルネットワークに基づいたコンクリート構造点検技術者の思考過程の評価, 土木学会論文集, No.496/V-24, pp.41-49, 1994.8.
- 15) 中村秀明, 河村圭, 鬼丸浩幸, 宮本文穂: 遺伝的アルゴリズムおよび免疫アルゴリズムによる橋梁維持管理計画最適化の検証, 構造工学論文集, Vol.47A, pp.201-210, 2001.3.
- 16) 市川紘: 階層型ニューラルネットワーク 非線形問題解析への応用, 共立出版株式会社, 1993.6.
- 17) 白井支朗: 基礎と実践 ニューラルネットワーク, コロナ社, 1995.10.
- 18) 長通伸幸, 香月智: ニューラルネットワークを用いた砂防施設効果を考慮した河床変動推定に関する研究, 計算工学講演会論文集, Vol.6, pp.141-144, 2001.5.
- 19) Kohonen T.: 自動組織化マップ, シュプリンガー・フェアラーク東京株式会社, 1996.6.
- 20) 東京大学教養学部統計学教室: 統計学入門, 財団法人東京大学出版会, 2000.9.
- 21) 三谷政昭: デジタルフィルタデザイン, 昭晃堂, 1997.10.

(2001. 10. 29受付)

MULTIPLE FUNCTIONS DIFFERENTIATE FITTING NEURAL NETWORK SYSTEM AND ITS APPLICATION FOR STRUCTURAL MONITORING

Nobuyuki NAGADORI, Satoshi KATSUKI and Gakuto FUKAWA

This paper proposes a new neural network system that differentiates the multi-pattern mixed data into multiple pattern fitting functions, and its application for structural monitoring system to detect the change of structural characteristics. All parameters dominating cause of output monitoring signals are not necessarily monitored in real monitoring system. In such case, the relationship between input and output monitoring data are seemed to be relating to multiple functions controlled by hidden parameter. The proposed neural network systems can differentiate those data into multiple pattern-fitting functions. This network system can detect the appearance of new pattern of input-output relationship of structural monitoring data caused by a damage or deterioration.