

疲労損傷モニタリングへの 複関数分類学習ニューラルネットワークの適用

An application of multi-pattern differentiation neural network system for monitoring of fatigue damage

作田 健*, 坊原 尚記**, 香月 智***, 梶田 幸秀****, 園田 佳巨*****

Takeshi SAKUDA, Naoki BOUHARA, Satoshi KATSUKI, Yukihide KAJITA and Yoshimi SONODA

* 修(工) 防衛大学校 理工学研究科後期学生 (〒239-8686 横須賀市走水 1-10-20)

** 防衛大学校 理工学研究科前期学生 (〒239-8686 横須賀市走水 1-10-20)

*** 工博 防衛大学校教授 建設環境工学科 (〒239-8686 横須賀市走水 1-10-20)

**** 博(工) 防衛大学校助手 建設環境工学科 (〒239-8686 横須賀市走水 1-10-20)

***** 工博 九州大学大学院助教授 工学研究院建設デザイン部門

(〒812-8581 福岡市東区箱崎 6-10-1)

This paper presents an application of multi-pattern differentiation neural network for monitoring of fatigue damage in concrete material. Sometimes it has difficulty to detect the fatigue damage of concrete, because it is brought about various causes. So it is important to develop a monitoring system to detect the fatigue damage and keep good condition of structure. This system uses the relationship between input data and output data for monitoring signal to detect the change of structural characteristic. This proposed system can detect the progress of fatigue damage of concrete very well which has plural pattern between input data and output data.

Key words: multi-pattern neural network, monitoring, fatigue test

キーワード: 複関数分類学習ニューラルネットワーク, モニタリング, 繰り返し載荷実験

1. 緒 言

近年, コンクリート構造物の劣化損傷例が多数報告されている¹⁾。維持管理の基本は, 手遅れにならない時期に劣化現象や災害予兆を検知し, 適切な維持・補修を行うことにある。しかし, 土木構造物は単品設計, 単品生産システムであり, 時代ごとの技術と経済状況を反映して建設される。すなわち, それぞれに異なる環境と時代の影響を強く受けて供用されている。そのため, 劣化のメカニズムや損傷の程度を評価する方法は多種多様であり, 個々の構造物に対する慎重な解析と評価が必要とされている²⁾。

構造物の維持管理においては, 致命的でない損傷を許容し, 適切に損傷の経過をモニタリングすることが重要である。このため, 国際的な連携の下にモニタリングに関する調査研究活動が展開され始めているほどである³⁾。モニタリングの考え方や手法は, 医療分野において進んでおり, 一般市民にとっても周知されたものである。しかし, 土木工学分野におけるモニタリング技術は, 現在のところ, 医療分野ほど実用化できる段階にあるとは言えない^{3), 4)}。

モニタリング技術に関する研究としては, 次のようなものがある。まず, 長滝ら⁵⁾は, 鋼・コンクリート合成構造

の常時モニタリングを AE 法を用いることで, 構造物の欠陥評価を行っている。三木ら⁶⁾は, 光通信網を使用した鋼橋の健全度モニタリングシステムを構築し, ひずみゲージによる活荷重のモニタリング, ピーク記憶型ひずみセンサによる地震や車両衝突時の最大ひずみのモニタリング, 物体温度計とひずみゲージによる温度変化とひずみのモニタリングを行っている。中村⁷⁾は, GPS により長大吊橋補剛桁の変位を直接計測し, 長大吊橋補剛桁の準静的および極長周期の把握, さらに長期モニタリングについて検討している。また, 斉藤・星谷⁸⁾や, 安田ら⁹⁾はニューラルネットワークをモニタリング処理技術として活用することについて検討しており, ニューラルネットワークが構造特性の同定および健全度評価への適用可能であることを示している。

一方, 疲労損傷は長期間を要して徐々に進行する。疲労寿命を予測する場合, 疲労損傷が線形的に累積するものと仮定するマイナー則が用いられるが, 不確定要因が多く含まれるため, 実測と予測との差異にばらつきが大きいことが知られている¹⁰⁾。このため, 適切なモニタリングにより, 損傷が軽微なうちに発見できれば, 期間的に余裕をもって適切な対策が実施できると考えられる。これらのことから,




図-1 提案ネットワークと従来型ネットワーク

疲労損傷の進展を長期的に監視するモニタリングシステムの開発が行われている^{11),12)}。

ところで、長通ら¹³⁾は、最新モニタリングデータと既往データとを比較することで構造物の状態変化を判定するための複関数分類学習ニューラルネットワークシステムを提案した。そのうえで、鋼板構造を用いた実験を行い、その構造特性遷移を検知できることを示した。しかし、不確定要因がより多く含まれるコンクリート構造を対象とし、繰り返し载荷により徐々に進展する損傷検知問題については未検討であった。そこで本研究は、コンクリート構造の状態変化を提案システムで検知可能かどうかを確認するため、疲労試験に準じた要領でコンクリート供試体の損傷を進展させた。そのうえで、定期的に行う打撃荷重に対する加速度データをモニタリングデータとして測定し、このデータを用いて複関数分類学習ニューラルネットワークによる疲労損傷モニタリングシステムの適用性について検討したものである。

2. 複関数分類学習ニューラルネットワークによる構造特性遷移検知システム

2.1 複関数分類学習ニューラルネットワーク¹³⁾

図-1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と従来型の3階層ニューラルネットワークを比較して示す¹³⁾。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 $\mathbf{x}$ (n_i 次元) と出力ベクトル $\mathbf{y}$ (n_o 次元) との間を図-1(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 $\mathbf{T}$ (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閾値を探索決定する。

従来型では、1パターンである入出力関係の学習であるのに対し、提案するシステムは図-1(b)に示すように第3




図-2 システムパラメータの決定要領

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 $\mathbf{T}$ (n_o 次元) と出力ベクトル $\mathbf{y}$ (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、選ばれた出力に関連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、

$$i_{select} = \min |\mathbf{T} - \mathbf{y}_i| \quad (1)$$

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。

$$|\mathbf{T} - \mathbf{y}_{i_{select}}| \rightarrow \min \quad (2)$$

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により変更するものとした。ここで、収束条件として、誤差の最大値およびバックプロパゲーションにおける平均2乗誤差が一定以下となる2種類を設定した。

なお、複関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、計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のは難しい。そこで、パターン数等の決定は以下のように行う。

- 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ータ決定要領を図-2に示す。また、この複関数分類学習ニューラルネットワークを用いた疲労損傷による構造特性の遷移(変化)を検知する流れを図-3に示す。




図-3 構造特性同定・遷移判定システム

表-1 繰り返し載荷実験の設定値と結果

Case	設定荷重 (最大圧縮強度 に対する割合)	モニタリング 間隔 (回)	破壊に至った回数 (回)
1	90%	900 回ごと	2000 回
2	65%	5400 回ごと	71101 回

3. 実験要領とシステム

3.1 繰り返し載荷実験

コンクリート供試体に規則波形の荷重を繰り返し載荷し、定期的に供試体へ打撃荷重を与え、各所に伝播する加速度データをモニタリングした。これにより、疲労損傷の進展に伴う構造振動特性（加速度データ）の変化から提案システムが構造特性の同定および遷移を検知できるかどうかを確認する。

実験に用いたコンクリート供試体は、図-4 および写真-1 に示す直径 10cm および高さ 30cm の円柱供試体である。

実験は幾通りか実施したが、ここでは表-1 に示す 2 ケースについて述べる。載荷要領は、図-5 に示すように周波数 1.5Hz で最大荷重を一定に保ち、sin 波の半波を繰り返すものである。Case-1 については、最大圧縮強度の 90%を与えたが、写真-2 に示すように 2000 回載荷後に破壊した。Case-2 については、最大圧縮強度の 65%を載荷し、71101 回目の載荷で破壊した。

打撃によるモニタリングについては、図-4 に示すように、滑り台を設け、落差 8cm で 130g の鋼球を転がしコンクリ




図-4 コンクリート供試体と加速度計の位置




図-5 載荷要領




図-6 実験装置




写真-1 実験状況





写真-2 破壊状況




ート供試体に打撃を与えた。加速度計は、図-4 に示すように、鋼球により打撃される側のコンクリート供試体の上から 10cm および反対側の上下 10cm の位置に計 3 箇所設置した。モニタリング間隔は、Case-1 について 900 回ごと、Case-2 については 5400 回ごとに行い、各時点で 3 回加速度データを計測した。

また、図-4 に示すようにひずみゲージによりコンクリート供試体のひずみを、荷重および供試体の変形量については、図-6 に示すようにロードセル、レーザー式変位計によって計測した。



3.2 損傷モニタリングシステム

本研究において構成する損傷モニタリングシステムは、図-7 に示すものである。すなわち、図-7(a)に示すように打撃によって生じた振動波は、コンクリート内部を通過して、加速度計1, 2, 3に到達する。この際、内部に損傷が生ずると、健全な場合とは異なった波となって加速度計に到達すると考えられる。一方、加速度計に伝播する波は、もともと同一の波から発生したものであるため、相互に線形もしくは非線形の相関性があるものと考えられる。そこで、図-7(b)に示すように、構造物が健全時（もしくは軽微な損傷時）に、得られた加速度データについて、加速度計3の時刻 t におけるデータ ${}_3O_t$ を推定するための入力データを加速度計1と2のデータ ${}_iI_{t-\Delta t_j}$ （ここで i : 加速度番号, Δt_j : タイムラグ値）4種類を選ぶ。そのうえで、図-7(b)に示すように加速度データ間の非線形相関性をニューラルネットワークの学習機能を用いてフィッティングし、ある期間の繰り返し荷重載荷後の打撃モニタリングデータによって、入力データから推定される出力データの各時刻 t に対する加速度データを求める。これを計測値と比較し、予



測値と計測値の差が大きな場合は、損傷の進展を確認するシステムである。

4. 実験結果と考察

4.1 従来型ニューラルネットワークによるシステム

(1) Case-1の損傷進展

図-8に、Case-1における最大ひずみ～載荷回数の関係を示す。初期の最大ひずみは、1020(μ)であったものが徐々に増加し、破壊直前の1900回で1150(μ)にまで増加している。また、打撃試験を行った900回載荷時では1070(μ)、1800回載荷時では1130(μ)と最大ひずみに差がある。図-9には、初期と900回および1800回前後10サイクルの応力～ひずみ関係を示す。これより、900回目、1800回目と繰り返し載荷が進むにつれて、 $\sigma = 0$ で残留ひずみが生じている。弾性係数も小さくなっており、損傷が進展していることがわかる。ただし、写真-3に示すように外見上のひ





図-10 鋼球による打撃時の加速度 (900 回載荷時)

表-2 繰り返し載荷実験の設定値と結果

Case-1		Case-2	
入力	従来型 NN	従来型 NN	複関数分類学習 NN
①	$1 I_{t-0\mu s}$	$1 I_{t-300\mu s}$	
②	$1 I_{t-3200\mu s}$	$1 I_{t-2600\mu s}$	
③	$2 I_{t-2100\mu s}$	$2 I_{t-300\mu s}$	
④	$2 I_{t-2600\mu s}$	$2 I_{t-1600\mu s}$	

(NN : ニューラルネットワーク)



(a) 波形 (b) 相関分析

図-12 学習結果 (Case-1:従来型 NN)

び割れは見当たらず、損傷判定は難しい。また、実構造物では、応力～ひずみ関係は取得できないので、応力～ひずみ関係より損傷度を測ることはできない。


(2) 入力データの決定

図-10 に 900 回載荷時において、鋼球による 1 回目の打撃により得られた加速度を示す。このままでは、計測された 3 つの加速度波形には類似性が見られない。そこで、文献 13) を参考にタイムラグ相関を解析した。すなわち、


$$\rho_{\Delta t} = \frac{\sum I_t \cdot O_{t+\Delta t}}{\sqrt{\sum I_t^2 \cdot \sum O_{t+\Delta t}^2}} \quad (3)$$

ここで、 $\rho_{\Delta t}$: Δt 秒のタイムラグがある場合の相関係数、 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-11 に図-10 で示した加速度データの入力値～出力値のタイムラグ相関係数を示す。約 25 (μs) 間隔で相関係数の




(a) 加速度計 1 (入力) ～ 加速度計 3 (出力)



(b) 加速度計 2 (入力) ～ 加速度計 3 (出力)

図-11 タイムラグ相関係数 (900 回載荷時 1 回目)




(a) 波形 (b) 相関分析

図-13 予測結果 (Case-1:従来型 NN)

ピーク値が表れている。そこで、図-11 においてそれぞれの入出力関係の中から相関係数が高いタイムラグを各加速度計から 2 つずつ合計 4 個 (図-11 の①～④) を抽出した。すなわち、従来型ニューラルネットワークの入力層ニューロン数は、抽出した相関係数が高いタイムラグ数である 4 個とした。中間層ニューロン数は、1 から徐々に増加させ、最も中間層ニューロン数が少なく収束した 8 個とした。なお、同様な方法で決定した入力データのタイムラグ値を、表-2 にまとめて示す。ここで、図-11 中の①～④は、表-2 の入力①～④に対応させた。

(3) Case-1 における学習能力と損傷進展判定能力

まず、学習能力については、900 回載荷時の 1 回目と 2 回目の打撃データを使って学習した後、900 回載荷時の 3 回目の打撃データを推定させ、その能力を判定する。図-12 に示すように、学習値は教師値と良く一致しており、決定係数は 0.998 である。続いて、3 回目の打撃に対する計測値と予測値を図-13 に示す。図-13(a) に示すように、波形および値はよく一致している。また、図-13(b) に示す計測値～予測値の決定係数も 0.997 と非常に大きく、従来型ニューラルネットワークでも振動伝播特性の学習能力がある。



(a) 波形 (b) 相関分析

図-14 損傷判定 (Case-1: 従来型 NN)




図-16 応力～ひずみ関係 (Case-2)






図-15 最大ひずみと載荷回数 (Case-2)



(a) 波形 (b) 相関分析

図-17 学習結果 (Case-2: 従来型 NN)



(a) 波形 (b) 相関分析

図-18 隠しデータ検定 (Case-2: 従来型 NN)

次に、従来型ニューラルネットワークによる損傷判定能力を確かめる。Case-1における900回繰り返し載荷時の鋼球による打撃3回を教師データとし学習させた後、1800回載荷時の加速度を予測させる。

図-8または図-9の考察に基づけば、900回載荷時と1800回載荷時における供試体の構造特性は変化している。よって、ニューラルネットワークによる予測データと計測データは異なったものとなれば、損傷の進展を検知できることになる。計測値と予測値の関係について図-14に示す。図-14(a)の予測波形は、計測値と全く異なっている。また、図-14(b)に示す計測値～予測値の相関関係の決定係数は0.211と極めて小さく、従来型ニューラルネットワークが疲労損傷の進展に伴う構造特性遷移を検知できていないことがわかる。

(4) Case-2における損傷進展

Case-2はCase-1より設定荷重の最大圧縮強度比が小さいため、破壊までに多くの繰り返し載荷を要した。図-15に示す最大ひずみ～載荷回数の関係においては、破壊直前の70000回時に、ひずみが1500(μ)まで大きくなっている。図-16には、初期と32400回(6時間後)および64800回(12時間後)の前後10サイクルの応力～ひずみ関係を示す。ここでも、Case-1と同様に内部損傷の影響により残留ひずみが生じ、弾性係数が徐々に小さくなっていることがわかる。

(5) Case-2の学習能力および損傷推定能力

本研究では、図-15に示すように16200、21600回載荷時の入力データを学習させ、ニューラルネットワークを形成することにした。ただし、検定に用いる21600載荷時の3回目の打撃データは、教師データとして用いていない。図-17に学習結果を示す。学習値の波形は教師値と似ているものの、ピーク値に差があり決定係数も0.867と大きくない。

図-18には、隠しデータである、21600回載荷時の3回目打撃データに対する予測値と計測値の比較を図示する。この構造状態での2回分の加速度データは、学習データに含まれているので予測できるはずだが、予測波形は計測値と第1波が一致しているだけで、それ以降予測できていない。これは、図-15で明らかのように、学習期間として用いたデータに16200回載荷時および21600回載荷時の構造状態が混合して含まれるためである。




図-19 損傷判定 (Case-2: 従来型 NN)




図-21 学習結果 (Case-2: 複関数分類学習 NN)





図-22 隠しデータ検定 (複関数分類学習 NN)

図-19 には、32400 回載荷時の打撃データに対する予測を示す。予測波形および値は計測値と全く一致しない。一致しないことは、21600 回載荷時までの状態と異なる状態であることを示唆しているとも考えられるが、図-18 で見たように、21600 回載荷時の学習検定において既に一致していないため、異状判定は難しい。このように、従来型ニューラルネットワークでは、Case-1 のように学習データが 1 つのパターンの場合は構造特性遷移を検知できるが、Case-2 のように過去の計測データ履歴が多くなり、学習データが複数のパターンとなる場合は、構造特性が変化したことを判定できない。


4.2 複関数分類学習ニューラルネットワーク

ここでは、提案する複関数分類学習ニューラルネットワークの Case-2 に対する適用を試みる。その際、図-20 に示す 2 つのタイプの学習データ更新法について検討する。すなわち、第 1 の方法は、図-20 (a) に示すように構造物が健全である初期におけるデータを学習データとして固定し、その後の変化を見るもので、ここでは「初期学習型」と呼ぶものとする。第 2 の方法は、ある段階のデータを推定する



打撃検定順序


(a) 初期学習型



打撃検定順序

(b) 更新学習型

図-20 学習データ更新法



(a) 波形

(b) 相関分析

図-23 推定 (32400 回載荷時)

(複関数分類学習 NN, 初期学習型)

際に、その直前のデータを学習データとして用いるもので、「更新学習型」と呼ぶものとする。

(1) 初期学習型

学習データは、従来型ニューラルネットワークと同じ 16200、21600 回載荷時のデータを用いる。入力データ数は、従来のものと同じ 4 種類とし、出力パターンを 5 種類、中間層ニューロン数を 8 とした。その学習結果を図-21 に示す。学習回数および学習時間は従来型より少なく、波形および値は良く一致し、決定係数も 0.99 と良好な学習が行われている。続いて検定用に隠していた 21600 回載荷時の、3 回目の打撃に対する予測結果を図-22 に示す。予測波形は、計測値と一致しており、決定係数も 0.965 と大きい。図-23 には、この学習データによって作られた複関数分類学習ニューラルネットワークを用いて、32400 回載荷時の打撃デ




図-24 推定 (64800 回載荷時)
(複関数分類学習 NN, 初期学習型)




図-26 推定 (32400 回載荷時)
(複関数分類学習 NN, 更新学習型)

ータの入出力関係を推定した結果を示す。波形は計測値と概ね一致しているが、第1波のピーク値付近で予測値と計測値の差が大きくなっており、その決定係数が0.922とやや低下している。図-24には、さらに繰り返し載荷が進み、載荷回数が64800回に達した際の予測値と計測値を比較して示す。波形は第1波と2波は一致するものの、それ以降の3~7波では、ほとんど一致していない。よって、その決定係数は0.704とかなり小さくなる。すなわち、複関数分類学習ニューラルネットワークシステムは、繰り返し載荷回数の増加に伴いコンクリート供試体の内部損傷が進展し、その特性が初期のものから変化していることを明瞭に検知している。

図-25に決定係数の変化を示す。ここで比較のため、従来型ニューラルネットワークによる結果も示す。従来型ニューラルネットワークでは、21600回載荷時の学習検定用データでさえも、決定係数が0.475と小さい。また、その次の27000回載荷時で決定係数が0.0008になり、それ以降も決定係数が0.001~0.17とばらつきが大きく、載荷回数の増加に伴う決定係数の低下や増加の傾向も無いことから構造特性を明瞭に判定できているとは言い難い。一方、複関数分類学習ニューラルネットワークでは21600回載荷時で決定係数は0.965と大きく、43200回載荷時までは0.88以上の決定係数が続く。48600回載荷時に0.73と決定係数が低下し、それ以降0.64~0.74の範囲で推移する。仮に、ここで決定係数0.75を閾値としたならば、複関数分類学習ニューラルネットワークにより48000回載荷時に、疲労損傷が進展し始めたことを検知することが可能である。




図-25 決定係数の変化 (初期学習型)




図-27 推定 (64800 回載荷時)
(複関数分類学習 NN, 更新学習型)

(2) 更新学習型

次に、図-20(b)に示す更新学習型について述べる。

まず、学習データとして21600回載荷時および27000回載荷時のものを使用して、32400回載荷時の加速度データを予測した結果を図-26に示す。波形は計測値と概ね一致しているが、第2波のピーク値付近で予測値と計測値の差がやや大きくなっており、その決定係数は0.869である。図-27には、学習データとして54000回載荷時および59400回載荷時のデータを使用して、64800回載荷時の加速度を予測した結果を示す。波形および値は全く一致しておらず、相関分析による決定係数は0.406と小さい。

図-28に更新学習型により予測を行ったときの決定係数の変化を示す。予測値と計測値の決定係数は、48600回載荷時まで0.85以上を継続しており、構造の健全性を妥当に評価していると考えられる。この結果を図-25と比較すると、図-25の初期学習型では、48600回載荷時で決定係数が低下していたにも関わらず、図-28の更新学習型では、48600回載荷時には0.99と高い相関性がある。これは、健全といっても、徐々に損傷が進展していることを初期学習型は検知するのに対し、更新学習型は、最近の構造特性に学習データを更新するため、緩やかな損傷進展に対する検知能力が弱まることを示している。しかし、更新学習型では、図-15において最大ひずみが落ち込む5500回直前の54000回載荷時以降の決定係数は0.5を下回る。提案システ




図-28 決定係数の変化 (更新学習型)

ムは、構造状態の変化の判定を目的としたもので、仮に決定係数を異状検知の指標と定義し、図-25 の時と同じ決定係数 0.75 を閾値とするならば、図-28 より明らかに更新学習型では損傷が進展しているとみなせるため、初期学習型より更新学習型が異状検知能力が高いとも考えられる。

5. 結 言

本研究は、コンクリートの疲労損傷モニタリングに対する、複関数分類学習ニューラルネットワークの適用について検討したものである。本研究の成果を要約すると以下のようになる。

- ① コンクリート供試体の繰返し載荷実験を行い、定期的に打撃実験を行った。打撃実験により得られた加速度データの中で、相関性の高いタイムラグデータを用いると、単パターンの構造特性であれば、従来型ニューラルネットワークによる構造特性の同定および遷移の検知が行えることを示した。
- ② 疲労損傷の進展に伴い、複数パターンが存在すると思われるコンクリート供試体の打撃データを教師データとして用いると、従来型ニューラルネットワークでは構造特性の同定すらできない。一方、提案システムは、複数パターンに分類・学習を行えることから、構造特性の同定および疲労損傷の進展に伴う構造特性の遷移を検知できることを示した。
- ③ モニタリングにおける学習期間の設定方法として、学

習期間を初期に固定する場合と、逐次更新する場合について検討した。その結果、提案システムでは、学習期間を逐次更新する方が、疲労損傷の進展をより明瞭に検知できることを示した。

- ④ 提案システムを実構造物に適用する場合、異状検知を判定する指標およびその閾値の設定や、ニューラルネットワークは外挿領域の適合性に対する問題があるため、外挿領域の扱いについて別途検討する必要がある。

参考文献

- 1) 中谷昌一：国土交通省における道路アセットマネジメントの考えかた，土木学会誌，pp.24-26, 2004.8.
- 2) 西川和廣：「橋梁マネジメント」分野における技術展望，土木構造・材料論文集，第 19 号，pp.9-14, 2003.12.
- 3) 国際連携活動：International Society for Structural Health Monitoring of Infrastructures (ISHMII)，会長 Aftab Mufti 教授 <http://www.shm-international.org>.
- 4) (社) 土木学会：橋梁振動モニタリングのガイドライン，構造工学シリーズ 10, 2000.9.
- 5) 長瀧重義，鎌田敏郎，矢崎剛吉，黒坂 基，岩坂光保：非破壊試験による鋼・コンクリート合成構造の欠陥評価法に関する研究，土木学会論文集，No.564/V-35，pp.133-143, 1997.5.
- 6) 三木千尋，水ノ上俊雄，小林祐介：光通信網を使用した鋼橋梁の健全度評価モニタリングシステムの開発，土木学会論文集，No.686/VI-52，pp.31-40, 2001.9.
- 7) 中村俊一：GPS を用いた吊橋剛桁の風圧変形計測に関する研究，土木学会論文集，No.658/VI-48，pp.231-243, 2000.9.
- 8) 齊藤芳人，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, 1994.9.
- 9) 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.
- 10) 吉川弘道，中林秀和，山内洋志：変動疲労荷重を受けるコンクリートのマイナー数の評価と破壊確率に関する基礎的考察，土木学会論文集，No.520/V-28，pp.259-268, 1995.8.
- 11) 建設省：既設構造物の点検・補修システムの開発（橋梁の長期監視システムの開発）概要報告集，1990.10.
- 12) 森 猛，公門和樹，小高弘行，成本朝雄，阿部 充：疲労損傷度モニタリングセンサーの高感度化，土木学会論文集，No.765/V-64，pp.357-362, 2004.7.
- 13) 長通信幸，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.

(2004 年 9 月 17 日受付)