

AdaBoostによる多自由度構造物のヘルスモニタリングに関する研究

Structural health monitoring system to multi-degree of freedom structures using AdaBoost technique

古田 均*, 服部 洋**
Hitoshi Furuta, Hiroshi Hattori

*工博, 関西大学教授, 総合情報学部 (〒569-1095 大阪府高槻市靈仙寺町 2-1-1)

** 情修, 関西大学大学院, 総合情報学研究科 (〒569-1095 大阪府高槻市靈仙寺町 2-1-1)

In this paper, an attempt is made to develop a structural health monitoring system that can adapt to the structural system and environment, by introducing the learning ability. By adapting to the environment, it becomes unnecessary to prepare any previous knowledge and examination for the underlying structures and environment. In other words, it is not necessary to use the precise modeling and analysis method before conducting the health monitoring. The proposed system learns the vibration response by AdaBoost that uses fuzzy-neuro as a subsystem of learning process. By using AdaBoost, it is possible to deal with various external forces, and predict them with good accuracy. Through the numerical examples, it is concluded that the proposed system can recognize the change of structural characteristics and condition states.

Key Words: Structure health monitoring, AdaBoost, Fuzzy Reasoning, Steepest descent method

キーワード: ヘルスモニタリング, AdaBoost, ファジィ推論, 最急降下法

1. はじめに

近年, わが国においては, 既存構造物の安全性, 信頼性の確保が重要となっている。これは, 既存構造物の多くが建設から長い年月が経っており, 劣化が進行しているからである。しかしながら, 定期点検などによる保守, 管理では, 点検と点検の間の安全性は保証されない, 人員やコストがかかる, 点検中は使用できないなどの問題点がある。また, 日本は, 地震や台風などの自然災害が多い地域であるため, 特に構造物の安全性を常に確保しておくことは重要である。こういった背景から, 近年構造物に対するヘルスモニタリングシステムの研究が注目されている。

ヘルスモニタリングとは, 元来医療分野で使われていた用語で, 患者の健康状態を常に把握していることをさす。1988年4月に発生した米国のアロハJETの事故, 1994年ノーリッジ地震, 1995年兵庫県南部地震をきっかけに構造物へのヘルスモニタリングの適用が考えられるようになった。

構造物のヘルスモニタリングシステムでは, 対象となる構造物にセンサを配置し, 応答を解析することにより, 遠隔からの健全性の判断を可能とし, またその効率化, 省力化が期待できる。従来, ウェーブレット変換などによる応答解析によりシステムを同定し, 健全性の評価を行っていた¹⁾⁻⁵⁾。

近年, スマート材料⁶⁾や光ファイバを用いたヘルスモニタリングやニューラルネットワーク^{1), 7)}などのシステム同定を行わない診断など, 様々な手法

が提案されている。しかしながら, 適用する前のモデル化や解析, 実験などの事前知識の必要を前提としているものが多い。したがって, 実際に供用する場合, コストや手間などの問題がある。また, システムの実用化においては, 外乱やデータ転送中に発生する雑音, センサ測定時に存在する誤差の発生などは不可避であり, 重要な課題の一つであるといえる。

以上のことから, 本研究では, 事前知識を多く必要としない, ロバスト性を有したヘルスモニタリングシステムの構築を試みる。多自由度構造物を対象とし, 損傷の有無の検知および損傷位置の特定を試みる。また, 実時間での解析を行うことにより, 常時監視を可能にするとともに, 誤差や雑音に強いロバスト性を有していることを示すことを目的とする。本研究では, 提案システムの有効性を数値シミュレーションにより評価する。

2. AdaBoost

2.1 AdaBoost とは

精度は必ずしも高くない異なる学習アルゴリズム(弱学習アルゴリズム)を組合せ, より精度の高い学習アルゴリズム(強学習アルゴリズム)を構成する手法をBoostingと呼ぶ。このBoostingの手法の一つが, AdaBoost⁸⁾である。AdaBoostはパターン認識に利用されることが多い。AdaBoostでは, 与えられた学習アルゴリズムを用いて, 1回の学習ラウンドで1個の学習仮説を生成する。この学習アル

ゴリズムが弱学習アルゴリズムである。各ラウンドでは、与えられた確率分布に従い、訓練事例がリサンプリングされ、学習が行われる。次回のラウンドでは、誤分類された訓練事例が選ばれやすくなるように、確率分布が更新される。このラウンドを繰り返すことにより、異なる性質の複数の仮説を得ることができる。強学習アルゴリズムは、この弱学習アルゴリズムの仮説を取りまとめ、統合するものである。この際、弱仮説の出力を、弱仮説の精度により、重みを付け統合することにより、一つの仮説を得る。

AdaBoostの概念図を図-1に示す。

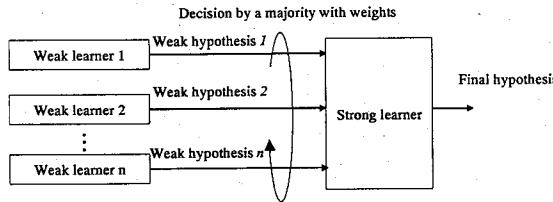


図-1 Concept of Adaboost

図-1に示すように、AdaBoostでは、複数の弱学習アルゴリズムを組み合わせることにより識別を行うが、一つ一つの弱学習アルゴリズムに制限はない。入出力数が同一であれば、すべて異なるアルゴリズムであってもよい。弱学習アルゴリズムにニューラルネットワークなどのソフトコンピューティング手法を用いることにより、ソフトコンピューティング手法の特徴を得ることができる。AdaBoostを用いることにより、数少ない教師信号で、汎用性の高い仮説を得ることが可能となる。また、アルゴリズムが簡単であること、ラウンド数を除き調整を有するパラメータがない、といったメリットがある。しかしながら、誤認識しやすい訓練データ(hard example)に重みをおいた学習を行うため、hard exampleに特化した仮説になる恐れがある。

2.2 AdaBoostによる学習

AdaBoostの学習手順^{9)~11)}を図-2に示す。多値のパターン認識にも拡張が可能であるが、ここでは出力を{-1, 1}の2値として取り扱う。

AdaBoostでは、与えられた弱学習アルゴリズムをそれぞれ1回呼び出すラウンドをT回($t=1, 2, 3, \dots, T$)繰り返す。

1. 訓練データの獲得

訓練データとして $(x_1, y_1), \dots, (x_m, y_m)$ をシステムに与える。ここで、 x_i はシステムへの入力ベクトル、 y_i はシステムからの理想出力である。

2. 訓練データの確率分布の初期化

訓練データの選択確率を次式により初期化する。

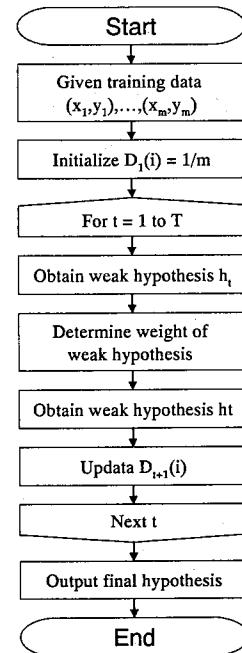


図-2 Procedure of Adaboost

$$D_t(i) = \frac{1}{m} \quad (1)$$

ここで、ラウンド t における訓練データ*i*の選択確率を $D_t(i)$ と表記し、 m は訓練データ数である。したがって、初期状態では、各訓練データの選択確率は同一となる。

3. 以下4から6を1ラウンドとし、 T 回繰り返す。

4. 弱仮説 h_t を得る。

弱学習アルゴリズムが、設定回数の学習を行うことにより弱仮説を得る。このとき、学習する訓練データは確率分布 $D_t(i)$ を基に、確率により選定される。

また、弱仮説の良否を示す誤り確率 ε_t の定義を次式に示す。誤分類された訓練データのそのラウンドでの選択確率の総和で表される。

$$\varepsilon_t = \sum_{i:h_t(x_i) \neq y_i} D_t(i) \quad (2)$$

5. 弱仮説の重要度の決定

弱仮説の重要度 α_t は、誤り確率を用いた次式により定義される。

$$\alpha_t = \frac{1}{2} \ln\left(\frac{1-\varepsilon_t}{\varepsilon_t}\right) \quad (3)$$

重要度 α_t は、強学習アルゴリズムが重み付き多数決により、最終仮説を得る際の重みとなる。

6. 確率分布の更新

弱仮説 h_t の予測結果を基に、訓練事例の確率分布

を更新する。弱仮説 h_t によって誤認識された訓練データの確率が増加、正しく認識されたデータの確率を減少させることにより、難しい事例に学習が集中するようになる。確率分布の更新式は次式のようになる。

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \times \begin{cases} e^{-\alpha_t} (h_t(x_i) = y_i) \\ e^{\alpha_t} (h_t(x_i) \neq y_i) \end{cases} = \frac{D_t(i) e^{-\alpha_t y_i h_t(x_i)}}{Z_t} \quad (4)$$

ただし、 Z_t は確率分布を正規化するための係数である。

7. 最終仮説の獲得

最終仮説 h_T を T 個の弱仮説を統合することにより得る。最終仮説を獲得するための式を以下に示す。

$$H(x) = \operatorname{sgn}\left(\sum_{t=1}^T \alpha_t h_t(x)\right) \quad (5)$$

弱仮説に、重要度を乗じたものを総和することにより、最終仮説を得る。すなわち、総和が正ならば 1、負ならば -1 となる。

2.3 時系列問題への拡張

前節で示したように、AdaBoost は判別が困難な訓練事例を集中して学習することにより、パターン識別問題において良好な結果を得ることが可能となる。しかし、時系列の予測問題では正誤をもとに訓練事例の確率分布を更新することは困難である。2 値パターン問題では、訓練データを正誤により分類することが可能であるが、時系列予測では、明確に正誤を与えることができないからである。そこで、本研究では、訓練データの正誤の取り扱い方法に正規化された予測誤差を用いる手法を提案する。正規化された予測誤差を用いた、学習方法を以下に示す。誤り確率を、正誤の 2 値で求めるのではなく、予測誤差を用いて求める手法である。前節に示した、AdaBoost の手順 4 および手順 6 を以下のように変更する。

4'. 弱仮説 h_t を得る。

誤り確率を表す式(2)を次式のように更新する。

$$\varepsilon_t = P_{ri-Di}[h_t(x_i) \neq y_i] = \sum D_t(i)(h_t(x_i) - y_i) \quad (6)$$

式(6)を用いると、正誤の 2 パターンのみではなく、誤差の大きさに応じた誤り確率を算出することが可能となる。

6'. 確率分布の更新

式(4)に示した、確率分布の更新式を以下のよう

に更新する。

$$D_{t+1}(i) = \frac{D_t(i) e^{-\alpha_t(h_t'(x_i))}}{Z_t} \quad (7)$$

ただし、 $h_t'(x_i)$ は仮説の良否を示す値であり、

$$h_t'(x_i) = -2 * h_t(x_i) + 1 \quad (8)$$

により、定義される。式(8)を用いることにより、式(4)の持つ性質を保持したまま拡張することが可能となる。式(4)では、確率分布の更新は、増加、減少の 2 パターンしかないが、式(7)を利用することにより、誤差の大きさに応じた連続値を扱うことが可能となる。しかし、式(8)では、誤差に差がない場合において、仮説の良否に差が生じないため、確率分布の更新が滞ることが予想される。仮説の良否を -1 から 1 に正規化することにより、各訓練データの仮説のよさにばらつきが生じ、確率分布の更新が機能すると考えられる。

3. 振動解析

ここでは、数値シミュレーションにより振動解析を行う。数値シミュレーションでは、対象構造物の劣化を想定し、振動特性を変化させる。

多自由度構造物の正常時と損傷時の振動を解析、比較し、振動応答解析による損傷診断を行うことの有用性を検討する。

3.1 振動方程式

構造物の振動は、次式により定式化することができる。

$$M \cdot \{u''(t)\} + C\{u'(t)\} + K\{u(t)\} = 0 \quad (9)$$

ただし、 $\{u(t)\}$ は時間 t における構造物の変位、 M 、 C 、 K はそれぞれ質量、減衰、剛性を表す。式(6)は外力が作用しない場合の方程式であり、自由振動と呼ぶ。

自由振動では、外力が働いていないために、時間とともに振動は減衰し、やがて静止することとなる。しかし、通常は外力が発生しているため、次式を用いる。

$$M \cdot u''(t) + C \cdot u'(t) + K \cdot u(t) = p(t) \quad (10)$$

ここで、 $p(t)$ は外力を表す。

3.2 風荷重

本研究では、数値シミュレーションにおける外力として風荷重を想定する。しかし、実際に構造物に作用するのは、風力エネルギーであるため、風速を風力エネルギーへと変換する必要がある。風速 v が構造物に作用した場合の風力エネルギー F は、以下のように定式化される。

$$F = \frac{1}{2} C \rho A V^2 \sin^2 \alpha \quad (11)$$

ただし、 C は風力係数、 ρ は空気密度、 A は作用面積、 α は作用角度を表す。本研究で変換に用いたパラメータを表-1 に示す。

表-1 Parameters

air density	0.125 (kgf·sec ² /m ⁴)
Coefficient	2
effect angle	90 (°)
effect area	200 (m ²)

3.3 振動解析手法

数値シミュレーションでは、微分方程式である式(10)を Runge-Kutta 法¹²⁾を用いて解くことにより、振動解析を行う。Runge-Kutta 法は、微分方程式の近似解を求めるための手法である。しかし、Runge-Kutta 法では、二階微分方程式を解くことができないため、次式に示す連立方程式に展開する必要がある。

$$\begin{cases} P = u'(t) \\ P' = -(C \cdot P + K \cdot u(t) - p(t))/M \end{cases} \quad (12)$$

本研究では、式(12)を Runge-Kutta の 4 次公式を用いることにより、振動解析を行う。

3.4 構造物モデル

本研究では、対象構造物に3自由度構造物を用いる。式(12)に示した運動方程式は、スカラ式であるため、ベクトル式に拡張する必要がある¹³⁾。

$$[M] \cdot \{u''(t)\} + [C] \cdot \{u'(t)\} + [K] \cdot \{u(t)\} = \{p(t)\} \quad (13)$$

ここで、 $[M]$ 、 $[C]$ 、 $[K]$ はそれぞれ質量、減衰、剛性行列である。3自由度構造物における各行列は、以下のようになる。

$$M = \begin{bmatrix} m_1 & 0 & 0 \\ 0 & m_2 & 0 \\ 0 & 0 & m_3 \end{bmatrix} \quad (14)$$

$$C = \begin{bmatrix} c_1 + c_2 & -c_2 & 0 \\ -c_2 & c_2 + c_3 & -c_3 \\ 0 & -c_3 & c_3 \end{bmatrix} \quad (15)$$

$$K = \begin{bmatrix} k_1 + k_2 & -k_2 & 0 \\ -k_2 & k_2 + k_3 & -k_3 \\ 0 & -k_3 & k_3 \end{bmatrix} \quad (16)$$

ただし、 m_i 、 k_i 、 c_i はそれぞれ*i*層における質量、減衰係数、剛性である。

3.5 予備実験

ここでは、多自由度構造物において、振動応答による、損傷の有無の検知および特定箇所の特定の可能性について検証を行う。多自由度構造物モデルに対して、正常時および損傷時の振動解析を行い、両者の振動応答を比較することにより、その有用性を示す。本研究では、3自由度モデルを用い、1自由度に付き一つのセンサを有しているものとする。また、各層は、下から順に第1層、第2層、第3層とする。

振動応答解析により損傷診断を行うことの有用性を検討するため、実測データを用い、対象構造物の正常時および損傷時の振動応答の変化について検討する。損傷状態は、剛性を 10% 低減させることにより実現している。検証に利用した実測データを図-3 に示す。正常時と損傷時の差異の平均値を表-2 に、1 層目の平均値を 1 とした場合の誤差を表-3 に示す。

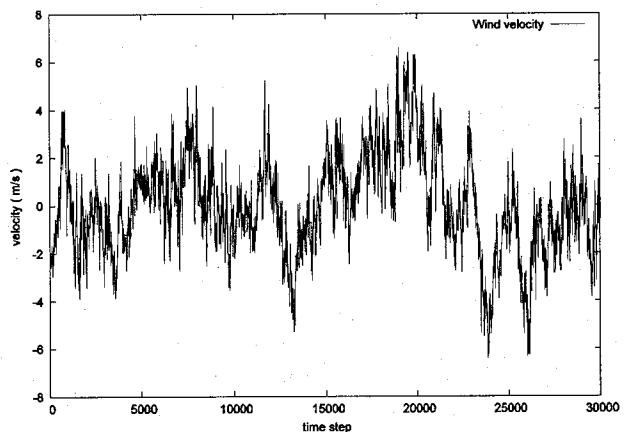


図-3 Wind velocity

表-2 Average values of displacement differences

Location of degradation	1 st story	2 nd story	3 rd story
1 st story	0.002642	0.002653	0.002658
2 nd story	-0.000040	0.000625	0.000610
3 rd story	0.000171	0.000343	0.001161

表-3 Ratios of average values of displacement differences

Location of degradation	1 st story	2 nd story	3 rd story
1 st story	1	1.003952	1.006080
2 nd story	1	-15.779748	-15.408367
3 rd story	1	2.000931	6.783205

表-2 および表-3 より、損傷をうけた層を含めた上の層の誤差が増大していることがわかる。

以上から、剛性の低下という振動特性の変化を与えることにより、振幅が増大することがわかった。

したがって、学習などにより振動特性を同定し、振動応答を予測することができれば、その予測誤差の推移を見ることにより、損傷の有無の検知を行うことができると言えられる。また、損傷位置により振幅の変化に大きな違いが現われることも確認できた。損傷位置を含む上層では、振幅の変化が大きいのに対し、損傷位置より低層では、振幅の変化は小さい。すなわち、各層の振幅の変化の大きさを比較することにより、損傷位置が特定できる。

4. 提案システム

AdaBoostを用いた多自由度構造物のヘルスモニタリングシステムについて述べる。また、数値シミュレーションを行い、提案システムの有効性を検証する。

4.1 システム構成

提案システムの構成図を図-4に示す。

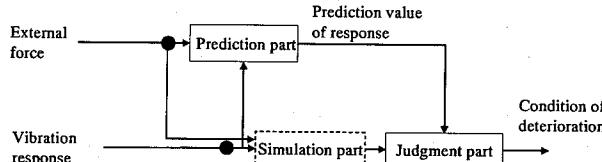


図-4 Structure of proposed system

提案システムは、次ステップの応答予測を行う予測部、実測値と予測値の誤差を基に損傷の有無、損傷位置の特定を行う判定部により構成される。また、本研究では数値シミュレーションを行うために、振動解析を行う振動解析部も内包している。システムへの入力は、外力および振動応答として、構造物の応答変位、応答速度である。出力は、損傷の有無、ならびに損傷箇所である。

予測部では、外力、応答変位、応答速度とともに、次ステップの応答変位および応答速度を予測する。提案システムでは、弱学習アルゴリズムにファジィ的ニューロンを用いた AdaBoost により予測を行う。ファジィ的ニューロンとは、ニューラルネットワークの一種であり、ネットワーク内の結合を工夫し、ファジィ推論の構造を持たせた階層型ニューラルネットワークである。すなわち、中間層においてメンバシップ関数とファジィルールを表現したネットワークである。

AdaBoost は、実測による訓練データを設置前にあらかじめ学習しているものとする。AdaBoost を用いることにより、学習時間の短縮が期待されるとともに、過学習が避けられるため、汎用性の高いルールの獲得が可能である。また、弱学習アルゴリズムにファジィ的ニューロンを用いるため、実行時の計

算時間は非常に短くなるという利点もある。

判定部では、予測部で求めた応答と、実測値との誤差および誤差率をもとに損傷の有無、損傷位置の特定を行う。損傷の有無は、ファジィ制御を用い確率という形で表現する。ファジィ制御では、各層の誤差率を入力とし、層ごとに損傷可能性を出力する。損傷確率を求めるために作成したファジィルールを表-4に示す。損傷診断に、ファジィ制御を用いるため、高速に計算することが可能となる。

損傷位置は第3章で示した通り、各層の誤差を比較することによる特定が可能である。提案システムでは、層間の誤差の最も大きい位置を特定し、その位置を損傷位置とし、その層が持つ損傷可能性を構造物全体の損傷可能性とする。

表-4 Fuzzy rules

Input value		Output value
Error	Error ratio	Possibility of degradation
Zero	Zero	Zero
	Small	Zero
	Medium	Zero
	Big	Small
Small	Zero	Small
	Small	Small
	Medium	Medium
	Big	Medium
Medium	Zero	Medium
	Small	Medium
	Medium	Medium
	Big	Big
Big	Zero	Medium
	Small	Medium
	Medium	Big
	Big	Big

4.2 多自由度モデルでのヘルスモニタリング

ここでは、多自由度構造物を対象にモニタリングを行う。損傷の有無と損傷位置の特定を行うことにより、提案システムの有効性を検証する。本研究では、正弦波データおよび風速データを与えた際の振動応答をあらかじめ学習した提案システムによりモニタリングを行った。本研究では、全層で同じ振動特性を持つ構造物を対象モデルとして扱う。表-5に、1層の構造特性を示す。

表-5 Structural characteristics

Mass	6.12×10^3 (kg)
Stiffness	4.74×10^6 (N/m)
Damping coefficient	7.68×10^{-1}
Natural Frequency	1.41 (Hz)

(1) 正弦波を用いた数値シミュレーション

第2層に損傷を与えた場合の誤差の推移を図-5に示す。シミュレーションでは、10,000ステップごとに剛性を10%低下させている。また、時系列予測システムは、0.004(Hz)の正弦波を対象構造物に与えた場合の振動応答5,000件を訓練データとして与え、あらかじめ学習を行っている。すなわち、現在の振動応答および外力を入力、次ステップの振動応答を理想出力とし、学習を行っている。

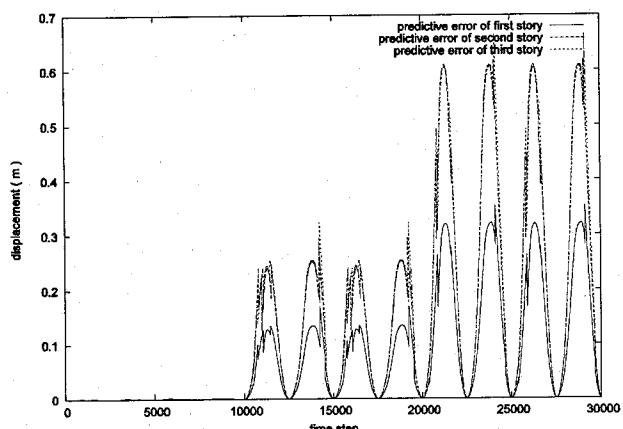


図-5 Prediction error of displacement

図-5より、非学習データにおいても誤差が非常に小さく、学習によりルールを獲得していることが確認できる。しかし、損傷が発生することにより、予測誤差が大きくなっている。構造物の振動特性が変化した際に生じる振幅の増大に対して、時系列予測システムは、その変化には追従しないためである。図-6に提案システムの出力結果を示す。

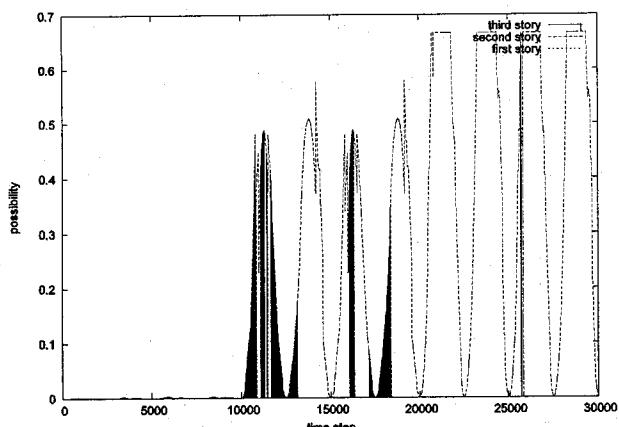


図-6 Results of proposed system

図-6より、10,000ステップ過ぎまでは、損傷なしの推論結果が提示されている。これに対し10,000ステップ以降では、損傷の発生があるため、システムの出力も、損傷ありの可能性が大きくなっていることが確認できる。また、第2層の出力が大きくなっていることから、第2層が損傷していることが認識できる。正常状態および損傷状態の認識率を表-6に示す。

表-6 Recognition rate

	正常状態	損傷状態
認識率	96.9%	91.2%
誤認識率	3.1%	8.8%

認識率の算出方法であるが、正常時の認識率は次式に示すように、損傷なしと判断した割合、損傷状態の認識率は、損傷位置を特定できた場合の割合とする。また、すべての層における損傷可能性がない場合、損傷なしと判定するものとする。

$$\text{認識率} = \begin{cases} \frac{\text{非損傷判定ステップ数}}{\text{非損傷ステップ数}} & (\text{正常状態}) \\ \frac{\text{位置特定ステップ数}}{\text{損傷ステップ数}} & (\text{損傷状態}) \end{cases} \quad (17)$$

本適用例では、正常状態は始めの10,000ステップであるため、その期間に損傷なしと判定された割合が、正常状態の認識率となる。また、損傷状態は、10,001ステップ以降の計20,000ステップであるが、その期間に第2層に損傷ありと判定した割合が認識率となる。

(2) 風速データを用いた数値シミュレーション

第3層に損傷を与えた場合の誤差の推移を図-7に示す。シミュレーションでは、10,000ステップごとに剛性を10%低下させている。また、時系列予測システムは、図-3に示す風速データのはじめの5,000件を対象構造物に与えた場合の振動応答を訓練データとして与えている。すなわち、現在の振動応答および外力を入力、次ステップの振動応答を理想出力とし、学習を行っている。

図-7より、非学習データにおいても誤差が小さく、学習によりルールを獲得していると言える。しかし、損傷が発生することにより、予測誤差が大きくなっている。構造物の振動特性が変化した際に生じる振幅の増大に対して、時系列予測システムは、その変化には追従しないためである。図-8に提案システムの出力結果を示す。

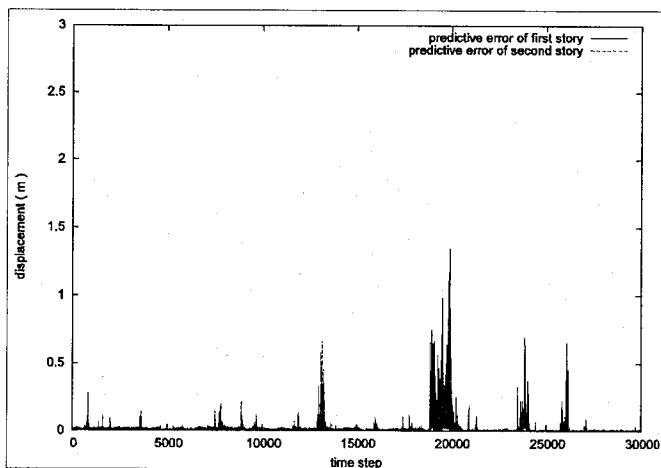


図-7 Prediction error of displacement

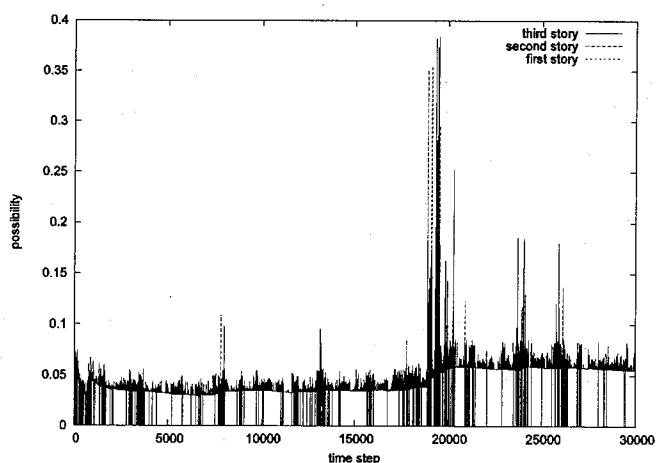


図-8 Results of proposed system

図-8より、10,000ステップ過ぎまでは、損傷ありの推論結果が提示されているが、その値が微少であるため、損傷なしという推論結果が得られているといえる。10,000ステップ以降では、損傷の発生があるにも関わらずシステムの出力は大きく変化していない。これはこの間の振幅が小さいことに起因していると考えられる。これは、約20,000ステップあたりの誤差が増大しているところでは、出力が大きくなっていることから確認できる。後半では、第3層の出力が大きくなってしまっており、第3層が損傷していることを認識できたといえる。しかし、損傷位置を第1層、第2層と誤認識することがあるのも事実である。認識率の値を表-7に示す。

表-7 Recognition rate

	正常状態	損傷状態
認識率	70.2%	83.5%
誤認識率	29.8%	16.5%

表-7より、正弦波の場合と比較して、認識率が低

下している。正常状態においても、誤差があるため、誤認識につながっていると考えられる。一方で、損傷状態では、外力が小さい環境では、損傷を検知することが困難である。しかし、80%以上の認識率があり、本手法が有効であるといえる。

5. おわりに

多自由度構造物を対象とし、数値シミュレーションにより提案システムの損傷位置の特定能力を検討した。数値シミュレーションでは、実測の風速データを外力波形として用いモニタリングを行った。

提案システムを用いることにより、構造物の損傷発生の検知、損傷位置の特定が可能となっており、外力として実測の風速データを用いた場合も、80%以上の認識率を示した。

提案システムには、構造物のモデルに関する知識を与えておらず、5,000ステップの振動応答のみ訓練データとして与えている。この学習のみで、提案システムは環境に適応し、振動特性を獲得している。

また、損傷発生から、損傷検知までの時間であるが、振幅により異なるが、短時間により検知できていると考えられる。本研究では1ステップを0.05秒として解析を行っており、100ステップで5秒であり、10,000ステップであっても500秒となり、約10分で検知することが可能となり、有用であるといえる。

しかし、精度の点から見た場合、20%近い誤認識が発生しており、これは、実測データが不規則であることが原因であるが、不規則なことにより、

1)事前学習後にも微少ではあるが誤差が残る

2)損傷位置による応答の変化の差が明確には現れない

という問題が発生しているためであると考えられる。したがって、実測データにおける精度を上昇させるためには、学習精度の改善と損傷位置の特定の判断基準を考慮する必要がある。

一方で、風速、構造物、劣化のモデルが単純であるため、実際に応用するには未だ問題が残る。今後実用化に向けたモデル化の検討が必要である。

参考文献

- 1) 山本鎮男編著：ヘルスモニタリング—機械・プラント・建築・土木構造物・医療の健全性監視一，共立出版，1999
- 2) 濑川柳太郎、山本鎮男、曾根彰、増田新、畠宏明：常時微動加速度観測波形のウェーブレット変換によるシステムパラメータの同定，日本建築学会構造系論文集第519号，pp41-46，1999
- 3) 中野宏毅、山本鎮男、吉田靖夫：ウェーブレットによる信号処理と画像処理，共立出版，1999

- 4) 斎藤兆古：ウェーブレット変換の基礎と応用
Mathematicaで学ぶ，朝倉書店，1998
- 5) 曾根彰：耐震設計におけるヘルスモニタリング
技術の応用，機械の研究第53巻第9号，pp921-927，
2001
- 6) 中村充：建築構造物のヘルスモニタリング，計
測と制御第41巻第11号，pp819-824，2002
- 7) 藤章：実用化を目指す構造ヘルスモニタリング，
機械の研究第56巻第2号，pp227-235，2004
- 8) Yoav Freund, Robert Schapire : A Short Introduction
to Boosting, 人工知能学会誌第14巻第5号，
pp771-779, 1999
- 9) 丸岡章, 瀧本英二：オンライン予測, 人工知能
学会誌第14巻第5号, pp763-770, 1999
- 10) Yoav Freund, Robert Schapire : A decision-theoretic
generalization of on-line learning and an application
to boosting, Journal of Computer and system Science,
55(1), pp119-1391, 1997
- 11) Robert Schapire, Yoram Singer : Improved boosting
algorithms using confidence-rated predictions,
Proceedings of the Eleventh Annual Conference on
Computational Learning Theory, pp80-91, 1998
- 12) 堀之内總一, 酒井幸吉：数値計算法入門—パソ
コン利用による—，森北出版，1993.
- 13) 新宮清志, 船本大蔵：多自由度系構造物のファ
ジィ制御，日本ファジィ学会誌第4巻4号
pp742-748, 1992

(2005年9月10日受付)