

ノイズ環境下における多自由度構造物のヘルスマonitoringに関する研究

Structural health monitoring system of multi-degree-of-freedom structures for environment with noise

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 大阪府高槻市霊仙寺町 2-1-1)

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

In this paper, an attempt is made to develop a structural health monitoring system that can adapt to the structural systems and environments with noise, by introducing the learning ability. At the previous research, a health monitoring system that can adapt to the structural systems and environments through the learning ability was developed with the recognition rate of over 80%. By introducing the learning ability, it is unnecessary to prepare any previous knowledge and examination for the underlying structures and environment. However, the previous research could not account for the effects of noise involved in data obtained from the sensors. In this paper, through the numerical examples, it is concluded that the proposed system can recognize the change of structural characteristics and condition states even under the noisy environment.

Key Words: Structural health monitoring, Noise, Fuzzy Reasoning, Time series prediction

キーワード: ヘルスマonitoring, ノイズ, ファジィ推論, 時系列予測

1. はじめに

近年, わが国において, 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が保証されない, 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マonitoringシステムの研究が注目されている。

ヘルスマonitoring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 年ノースリッジ地震, 1995 年兵庫県南部地震の被害を受け, 設計基準の重要性とともに, 構造物の状態を常時把握する必要性が謳われるようになった。このことにより, 構造物へのヘルスマonitoringの適用が考えられるようになった。

構造物のヘルスマonitoringシステムでは, 対象となる構造物にセンサを配置し, 応答解析をすることにより, 遠隔からの健全性の判断を可能とする。また, 点検等の従来の手法に比べ, 対象構造物の現状把握の効率化, 省力化が期待できる。

従来, 土木構造物の故障診断では, 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マonitoring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, 実際に運用するためには, 対象構造物のモデル化や数値解析, 模型実験などの事前知識が必要であるものが多い。したがって, 実際に供用する場合, コストや労力などに問題がある。

以上のことから, 筆者らは多くの事前知識を必要としない, ロバスト性を有したヘルスマonitoringシステムの構築を試みた。提案システムでは, 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目指した。数値実験を通して, 実時間での解析を行うことにより, 常時監視を可能とし, 理想環境下で 80%以上の故障認識率を得られることを確認できた⁸⁾。

しかし, 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, その対応は重要な課題の一つであるといえる。

以上より, 本研究では, 前研究で提案したシステムを改良し, ノイズ環境下での精度向上を試みる。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。数値シミュレーションでは, ノイズ環境下を想定し, 本手法が誤差や雑音に強いロバスト性を有していることを示す。

2. 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、比較することにより、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。

2.1 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。

$$M \cdot \{u''(t)\} + C \cdot \{u'(t)\} + K \cdot \{u(t)\} = 0 \quad (1)$$

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(1)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。

$$M \cdot \{u''(t)\} + C \cdot \{u'(t)\} + K \cdot \{u(t)\} = p(t) \quad (2)$$

ここで、 $p(t)$ は外力を表す。

2.2 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を想定する。しかし、実際に構造物に作用するのは、風荷重であるため、風速を風荷重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荷重 F は、以下のように定式化される。

$$F = \frac{1}{2} C \rho A V^2 \sin^2 \alpha \quad (3)$$

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

Wind-force coefficient	2
Air density	0.125 (kgf·sec ² /m ⁴)
Effective area	200 (m ²)
Effective angle	90 (°)

2.3 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(3)をRunge-Kutta 法⁹⁾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。

$$\begin{cases} P = u'(t) \\ P' = -(C \cdot P + K \cdot u(t) - p(t)) / M \end{cases} \quad (4)$$

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

2.4 構造物モデル

本研究では、対象構造物として3自由度構造物を用いる。式(4)に示した運動方程式は、スカラー式であるため、次式に示すベクトル式に拡張する必要がある¹⁰⁾。

$$[M] \cdot \{u''(t)\} + [C] \cdot \{u'(t)\} + [K] \cdot \{u(t)\} = \{p(t)\} \quad (5)$$

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。

$$M = \begin{bmatrix} m_1 & 0 & 0 \\ 0 & m_2 & 0 \\ 0 & 0 & m_3 \end{bmatrix} \quad (6)$$

$$C = \begin{bmatrix} c_1 + c_2 & -c_2 & 0 \\ -c_2 & c_2 + c_3 & -c_3 \\ 0 & -c_3 & c_3 \end{bmatrix} \quad (7)$$

$$K = \begin{bmatrix} k_1 + k_2 & -k_2 & 0 \\ -k_2 & k_2 + k_3 & -k_3 \\ 0 & -k_3 & k_3 \end{bmatrix} \quad (8)$$

ただし、 m_i 、 c_i 、 k_i は i 層における質量、減衰係数、剛性である。本研究では、 m_i 、 c_i 、 k_i が各層で同じ3自由度の構造物を対象モデルとする。

2.5 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自由度に一つの変位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、2種類の実測の風速データを用い、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。検証に利用した実測の風速データを図-1および図-2に示す。検証では、対象構造物の第1層の剛性を1%、3%、5%、10%低下させ、正常時の振動応答との比較を行う。正常時と損傷時の変位の差異の絶対値の平均値を表-2に示す。




図-1 Wind velocity 1




図-2 Wind velocity 2

表-2 Average values of displacement differences due to variation of stiffness

deterioration	1%	3%	5%	10%
Wind1	0.105	0.244	0.278	0.329
Wind2	0.539	1.362	1.774	1.846

表-2より、剛性が低下することにより、正常状態に比べて、構造物の挙動が変化していることが確認できる。このことより、誤差を比較することにより、損傷の可能性の検知が可能であると考えられる。また、剛性の低下の割合により、その差異が増加することが確認できる。しかしながら、その差異は2つの風速により大きく異なっている。これは、2つの風速の絶対値が大きく異なることに起因しており、誤差のみでの損傷の大きさの特定は困難である。このため、本研究では、次式に示す誤差率の導入を試みる。表-3に誤差率の平均値を示す。

$$\text{誤差率} = \frac{|\text{真値} - \text{予測値}|}{\text{真値}} \quad (9)$$

表-3 Average values of displacement difference ratio

deterioration	1%	3%	5%	10%
Wind1	0.352	1.090	1.135	1.538
Wind2	0.340	0.979	1.162	1.143

表-3より、誤差率の推移は、多少のずれはあるが、損傷に応じて増加していることが確認できる。また、大きさが異なる二つの外力を用いた場合でも、誤差率の変動はほぼ等しくなる。このことから、損傷の判定に誤差率を導入することにより、損傷の有無の検知が可能であるといえる。また、その大きさにより、損傷の大きさの推定の可能性を見出すこともできた。本研究では、正常時との誤差および誤差率を用いることにより、損傷の検知を試みる。

次に、振動応答解析による損傷位置の特定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。ここでは、剛性を3%低減させた構造物を損傷状態とし、外力にはWind1を用い、解析を行っている。正常時と損傷時の差異の総和を表-4に示す。各層に損傷を与えた状態で、各層の正常状態との差異を検証する。

表-4では1列目は損傷位置、2列目以降は損傷が発生した場合の正常時との差異の総和を示している。

表-4 Summation values of displacement differences among stories

Location of degradation	1 st story	2 nd story	3 rd story
1 st story	2.64×10^{-3}	2.65×10^{-3}	2.66×10^{-3}
2 nd story	-4.00×10^{-5}	6.25×10^{-4}	6.10×10^{-4}
3 rd story	1.71×10^{-4}	3.43×10^{-4}	1.16×10^{-3}

表-4より、損傷をうけた層を含めた上層の誤差が増大していることが確認できる。

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確認できた。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考えられる。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。

3. AdaBoost

精度が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、AdaBoost¹⁰⁻¹⁴⁾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-3に示す。




図-3 Concept of AdaBoost

図-3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て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。

本研究では、時系列予測のシステムとして、学習器にAdaBoostを用いる。

4. 提案システム

時系列予測システムを用いた多自由度構造物のヘルスマ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。

システムへの入力、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。システムからの出力は、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、応答速度をもとに、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、弱学習器に階層型のニューラルネットワークを用いたAdaBoostにより予測を行う。AdaBoostでは、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。また、弱学習アルゴリズムにニューラルネットワークを用いるため、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

-5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2.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-5 Fuzzy rules

Input value		Output value
Error	Error ratio	Possibility of deterioration
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 ノイズへの対応

本研究では、提案システムでの精度の向上を目指すために、以下の点で改良を行っている。

4.1 で述べたように、時系列予測にはAdaBoostを用いている。これにより、学習データに含まれる特異点に対応できるため、学習精度は向上するが、過学習を引き起こし、予測精度の低下につながる恐れがある。また、弱学習器であるニューラルネットワークのニューロン数が多い場合にも同様の問題点がある。表-6に弱学習器の数を変更した場合、表-7に中間層のニューロン数を変更した場合の予測誤差の平均値の比較を示す。検証データには前述のWind1を用いる。

表-6 Compare the accuracy of the AdaBoost

Number of weak learning machine	1	3	5
Identification	0.1279	0.1220	0.1179
Prediction error	0.1355	0.1247	0.1323

表-7 Compare the accuracy of the Neural network

Number of neuron	2	3	4	5
Identification	0.1320	0.1279	0.1255	0.1001
Prediction error	0.1436	0.1355	0.1404	0.1437

表-6および、表-7より、弱学習器数、ニューロン数が増えるとともに同定精度は向上している。一方で予測精度は、数が増えるにつれて精度が上昇するが、ある点を境に低下している。以上より、本研究では、弱学習器には、中間層のニューロン数を3つにしたニューラルネットワークをしようする。

しかし、この場合でもノイズに起因する誤差は残るため、各ステップの誤差、誤差率を用いた場合に、誤認識を招く恐れがある。このため、推論は直近の数ステップの平均値を用いる。このことにより、計算時間の増加を抑えることが可能となり、リアルタイム性を残しながらの検知が可能となると考えられる。本研究では、直近 1000 ステップの平均値を用いている。

4.3 多自由度モデルへのヘルスマニタリング

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-8に、1層の構造特性を示す。また、ここでは、センサからの入力に対して正規分布に従うノイズを与えている。

表-8 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

提案システムの検証として、外力として正弦波を与えた数値シミュレーションを行う。正弦波は、風データと同じ25分の間に数回の周期が現れるように0.004(Hz)のものを使用している。対象物の損傷は、15,000ステップ目に剛性が低下することを想定する。また、時系列予測システムは、対象構造物に正弦波を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。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。剛性の低下は1%, 3%, 5%, 10%の4種類を想定している。図-5に、剛性の低下率を10%とした場合の第2層の予測誤差を示す。




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場合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、剛性を10%低下させた場合の、各層の提案システムの出力結果を示す。




図-6 Results of proposed system

図-6より、15,000ステップ過ぎまでは、出力値は小さく、損傷なしの推論結果が提示されているといえる。これに対し15,000ステップ以降では、損傷の発生があるため、システムの出力値が大きくなっていることが確認できる。

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、短時間での検知ができていと考えられる。数千ステップでの検知が可能であり、これは、1ステップを0.05秒として解析を行っているため、数分での検知となり、有用であるといえる。

また、第2層の出力が大きくなっており、第2層が損傷していると判断することが可能である。10%の損傷を与えた場合の正常状態および損傷状態の認識率を表-9に示す。

表-9 Recognition rate

	Intact situation	Deterioration situation
Recognition rate	100.0%	81.8%
False recognition rate	0.0%	18.2%

表-9より、10%の損傷に対して、提案システムが損傷を認識できているといえる。ここで、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。

$$\text{認識率} = \begin{cases} \frac{\text{非損傷判定ステップ数}}{\text{非損傷ステップ数}} & \text{(正常状態)} \\ \frac{\text{位置特定ステップ数}}{\text{損傷ステップ数}} & \text{(損傷状態)} \end{cases} \quad (10)$$

ここで、ファジィ推論により求められた損傷可能性が閾値を上回った場合に、損傷判定されたものとする。本論文では、経験則により0.4を閾値として用いている。

本適用例では、正常状態は始めの15,000ステップであるため、損傷層の前半および損傷の起こっていない層が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、15,001ステップ以降の計15,000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。損傷率を1%、3%、5%、10%とした場合の認識率の比較を表-10に示す。表-10の正常状態の認識率とは、健全時である前半15,000ステップの間に損傷なしと判定した割合、および、後半15,000ステップに第1層ならびに第3層に損傷なしと判定した割合の平均値である。

表-10 Recognition rate

Deterioration rate	Recognition rate	
	Intact situation	deterioration
1%	92.0%	79.5%
3%	91.3%	81.1%
5%	91.3%	81.0%
10%	90.5%	81.8%

表-8より、剛性の低下率が低くなるにつれて、認識率が低くなっていることが確認できる。これは、損傷による挙動の変化が小さくノイズによる影響に相殺されていることが原因として考えられる。逆に、正常状態の認識率は損傷の大きくなるにつれて大きくなっている。これは、損傷により第3層の誤差も大きくなるため、第3層に損傷ありという出力がされることが原因である。しかしながら、提案システムにおいて、健全時には約90%以上、損傷時でも約80%以上の認識率が得られている。

(2) 風速データを用いた数値シミュレーション

ここでは、提案システムの実用性を検証するため、実測の風速データを与えたシミュレーションを行う。シミュレーションでは、15,000ステップ目に剛性を低下させることにより、損傷を実現している。また、時系列予測システムは、図-1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に剛性を10%低下させた場合の予測誤差の推移を示す。




図-7 Prediction error of displacement

図-7より、非学習データにおいても誤差は小さく、学習によりルールを獲得しているといえる。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-8 Results of proposed system

図-8より、15,000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。15,000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2層の出力が大きくなっており、第2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3層と誤認識することがあるのも事実である。

損傷の検知までの時間は、正弦波に比べて長くなっているが、実用に耐えうる短い時間により検知できているといえる。

認識率の値を表-11に示す。

表-11 Recognition rate

	Intact situation	Deterioration situation
Recognition rate	82.2%	90.5%
False recognition rate	17.8%	9.5%

表-11より、正弦波の場合と比較して、認識率が低下していることがわかる。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。しかし、全体を通して80%以上の認識率があり、本手法は有効であるといえる。損傷率を1%, 3%, 5%, 10%とした場合の認識率の比較を表-12に示す。

表-12 Recognition rate

Deterioration rate	Recognition rate	
	Intact situation	deterioration
1%	89.3%	82.0%
3%	85.2%	88.3%
5%	84.4%	90.2%
10%	82.2%	90.5%

表-12より、正弦波を用いた場合と同様に、剛性の低下率が低くなるにつれて、損傷時の認識率が低くなっていることが確認できる。しかしながら、提案システムにおいて、1%の剛性の低下時においても80%以上という高い認識率を得ることができている。

次に、学習に用いたデータと異なる風速データを与えた場合の、提案システムの有効性の検証を行う。具体的には、図-1で示した風速データを与えた応答を学習した提案システムを用い、図-2に示した風速データを与えて、損傷の検知を行う。

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-9に剛性を10%低下させた場合の予測誤差の推移を示す。




図-9 Prediction error of displacement

図-9より、健全時において一部誤差が大きくなっている箇所が見受けられるが、学習に用いていない風速データに対しても、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場合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-10に提案システムの出力結果を示す。




図-10 Results of proposed system

図-10より、15,000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、これは、前半部に誤差が大きい箇所があったためであり、途中より、推論結果として損傷の可能性が低下している。一方で、15,000ステップ以降では、損傷可能性が増加している。これは、損傷により誤差が大きくなったためであり、システムが損傷を認識できているものと判断できる。剛性が10%低下した場合の認識率の値を表-13に示す。

表-13 Recognition rate

	Intact situation	Deterioration situation
Recognition rate	75.5%	75.2%
False recognition rate	24.5%	24.8%

表-13より、正弦波の場合と比較して、認識率が低下していることがわかる。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。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。

次に、損傷率を1%, 3%, 5%, 10%とした場合の認識率の比較を表-14に示す。

表-14 Recognition rate

Deterioration rate	Recognition rate	
	Intact	deterioration
1%	72.2%	71.5%
3%	73.2%	73.4%
5%	74.3%	74.0%
10%	75.5%	75.2%

表-14より、学習に用いていない風力データを与えた場合にお

ける認識率は、約70%と学習データに対する認識率と比較して低下している。これは、時系列予測の学習が完全でないことに起因していると考えられ、二つの風速データの最大値が大きく異なることが影響している。このことより、データの正規化等今後の課題であるといえる。しかし、損傷状態では、正常時に比べて誤差が増大していることから、認識は可能であると考えられる。

5. おわりに

本研究では、ノイズ環境下での損傷検知を目的として、学習機能を有したヘルスモニタリングシステムを構築した。多自由度構造物を対象とした数値シミュレーションにより、ノイズ環境下での提案システムの損傷の有無の認識能力、ならびに損傷位置の特定能力を検証し、その有用性を示した。

提案システムを用いることによりノイズ環境下においても、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。これは、前研究の理想環境下での精度と同じ水準である。

一方で、学習時と異なる風パターンに対しては認識率が低下している。70%以上の認識率を示しているものの、今後さらなる改善が必要であると考えられる。

以上のように、多少の精度の低下は認められるが、学習データとは大きく異なる外力を与えた場合や、大きなノイズが含まれる場合においても、実用に耐えうる精度を示すことができしており、ロバスト性を有していることが確認できた。

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。正弦波、実測はともに、約数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、誤認識が10%以上残されており、損傷判定ルールの見直しなど、改善の余地が残されているといえる。また、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。特に、本研究では、単層の損傷のみを対象としているため、複数層の損傷に対してはさらなる検討が必要である。

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—，共立出版，1999
- 2) 瀬川柳太郎，山本鎮男，曾根彰，増田新，畑宏明：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，pp.41-46，1999
- 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，pp.921-927，2001
- 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，pp.819-824，2002
- 7) 轟章：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，pp.227-235，2004
- 8) 古田均，服部洋：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，構造工学論文集，Vol52A，pp.651-658，2006
- 9) 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.
- 10) 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，pp.742-748，1992
- 11) Yoav Freund，Robert Schapire：A Short Introduction to Boosting，人工知能学会誌，第14巻第5号，pp.771-779，1999
- 12) 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，pp.763-770，1999
- 13) 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)，pp.119-1391，1997
- 14) Robert Schapire，Yoram Singer：Improved boosting algorithms using confidence-rated predictions，*Proceedings of the Eleventh Annual Conference on Computational Learning Theory*，pp.80-91，1998

(2007年9月18日受付)