

SVM を用いた鋼・コンクリート合成床版の剥離種別の分類

Recognition of filling conditions inside the steel-concrete composite slabs using support vector machine

広兼道幸*, 宮脇悠輔**, 菅隆之***, 野村泰稔****

Michiyuki Hirokane, Yusuke Miyawaki, Takayuki Suga, Yasutoshi Nomura

* 関西大学教授, 総合情報学科 (〒569-1095 大阪府高槻市霊仙寺町 2-1-1)

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

*** NTT コムウェア (〒108-8019 東京都港区港南 1-9-1)

**** 立命館大学助教授, 理工学部機械工学科 (〒525-8577 滋賀県草津市野路東 1-1-1)

According to the information of Ministry of Land, Infrastructure, Transport and Tourism, from 1950 to 1970, about 2,500 bridges per one year are newly established, and now about 136,000 bridges have been existed in Japan. So, it is important to diagnose efficiently the damage conditions of steel-concrete composite slabs. In this research, we implemented to detect the difference between intact and damage conditions inside the composite slabs by using the wave figure of impact acoustic that were recorded in hitting on the face of concrete. The SVM based recognition method of damage conditions inside was discussed.

Key Words: Damage analysis and assessment, Pattern recognition, SVM, Impact Acoustic, Nondestructive testing

キーワード：損傷度評価, パターン認識, SVM, 打音情報, 非破壊検査

1. はじめに

国土交通省の資料によれば, 戦後の 1950 年から 1970 年にかけて年平均約 2500 の橋梁が新設され, 現在, 約 13.6 万橋ものストックが存在する¹⁾. 施設の材料として主に使用されてきたコンクリートの寿命は一般的に約 50 年と言われており, ピーク時に建設された橋梁の老朽化が進むことが予測される. また, 近年の構造物が寿命化する観点により, 診断対象の数が急増していることなどから, 橋梁の維持管理は極めて重要である. 特に, ライフサイクルコスト最小化を目指し, 長期的かつ経済的にこれら社会基盤施設の維持管理を実施するためには, ただちに修復しなければならない大きな損傷を把握しておくことは非常に重要である.

現在までに開発されている非破壊検査法として, X 線²⁾, 赤外線³⁾, 電磁波法⁴⁾, 超音波法^{2), 5)} などを用いた様々な高度な検査法が開発されている. しかしながら, それぞれの技術に長所・短所があることも事実であり, X 線に関しては取り扱いが難しく, 有資格者しか使用できず, かつ被爆のリスクが伴う. 赤外線ではクラックとその周りとの温度差により診断を行うため, トンネル内部では日照がなく, そのためクラックの検出が困難である. ま

た, 電磁波レーダでは, 受信波の時系列信号のピークパターンに関する膨大なデータベースの作成が必要となる. 超音波に関しては, 現場での診断に時間がかかり, 効率面で劣る. 加えて, 上記の診断技術は相対的にコストが割高である. 一方古くから日常点検など多くの場面で使用される非破壊検査法に打音法がある. 打音法は低コストでかつ危険を伴わず, さらに簡便に作業が行える利点を持ち, 非常に信頼性の高い診断法であると言われている. その理由として打音そのものに, 診断対象の内部の状態に関する有益な情報が含まれていること, また打音法は従来, 熟練者の手によるもので, 診断結果は熟練者の長年の経験により裏付けられていることが挙げられる. しかし, 今後, 想定される熟練者の急減と診断対象の増大を勘案すると, 診断結果に対して高い信頼性を維持しつつ, 非熟練者でも診断可能な打音の定量的評価法の確立は極めて重要であると考えられる⁶⁾.

このような背景を踏まえ, 本研究では, 熟練の専門家が従来から行ってきた打音法による鋼・コンクリート合成床版に存在する不良箇所の有無を発見する点検の結果⁷⁾を学習し, 実際に, 鋼・コンクリート合成床版を対象として, 内部に剥離モデルを含んだ箇所を叩いたときに得られる周波数データとレスポンスデータから, パター

ン認識手法を用いて剥離種別の識別を実施した．本研究では，様々な分野で識別性能が優れているとされているサポートベクトルマシン(Support Vector Machine : SVM)を打音情報の適応可能性について，線形 SVM と非線形 SVM による識別性能の比較実験を行った．

2. サポートベクトルマシン(SVM)

SVM は 1960 年代に Vapnik 等が考案した Optimal Separating Hyper-plane を起源とするパターン認識手法である．SVM はクラスの帰属が既知の訓練用のサンプル集合から特徴ベクトルとクラスとの確率的な対応関係を知識として学習する教師あり学習モデルの一つであるが，現在知られている多くの手法の中でも最もパターン認識性能の優れた学習モデルの一つである⁸⁾．本研究では，線形ソフトマージン SVM (線形 SVM) を用いることとし，以下では，訓練サンプルからマージン最大化という基準で線形しきい素子のパラメータを学習する仕組みについて述べる．

2.1 学習の定式化

SVM は，ニューロンのモデルとして最も単純な線形しきい素子を用いて 2 クラスのパターン識別器を構成する手法である．訓練サンプル集合から，マージン最大化という基準で線形しきい素子のパラメータを学習する．線形しきい素子はニューロンを単純化したモデルで，入力特徴ベクトルに対し，識別関数（線形識別関数）

$$y = \text{sign}(w^t x + b) \quad (1)$$

により 2 値の出力値を計算する．ここで， w はシナプス荷重に対応するパラメータであり， b はしきい値である．また，関数 $\text{sign}(u)$ は， $u > 0$ のとき 1 をとり， $u \leq 0$ のとき -1 をとる符号関数である．このモデルは入力ベクトルとシナプス荷重の内積がしきい値を超えれば 1 を出力し，超えなければ -1 を出力する．これは幾何学的には識別平面により，入力特徴空間を 2 つに分けることに相当する．今，訓練サンプル集合として n 個の特徴ベクトル $x_i (i=1, \dots, n)$ と，それぞれのサンプルに対する正解のクラスラベル $t_i (i=1, \dots, n)$ が与えられているとする．また，この訓練サンプル集合は線形分離可能であるとする．すなわち，線形しきい素子のパラメータをうまく調整することで，訓練サンプル集合を誤りなく分けることができると仮定する．SVM では，最も近い訓練サンプルとの余裕をマージンと呼ばれる量で測り，マージンが最大となるような識別平面を求める．

もし，訓練サンプル集合が線形分離可能なら

$$t_i (w^t x_i + b) \geq 1, (i=1, \dots, n) \quad (2)$$

を満たすようなパラメータが存在する．これは H1: $w^t x + b = 1$ と H2: $w^t x + b = -1$ の 2 枚の超平面で訓練サ

ンプルが完全に分離されており 2 枚の超平面の間にはサンプルがひとつも存在しないことを示している．このとき，識別平面とこれらの超平面との距離（マージンの大きさ）は $1/\|w\|$ となる．したがって，マージンを最大とする w と b を求める問題は，

$$\text{Minimize}_{w,b} L(w) = \frac{1}{2} \|w\|^2 \quad (3)$$

$$\text{subject to } t_i (w^t x_i + b) \geq 1, (i=1, \dots, n)$$

の解 w^* ， b^* を求める問題と等価になる．この最適化問題は，数理計画法の分野で 2 次計画問題として知られている．ここで，Lagrange 乗数 $\lambda_i (\geq 0)$ ， $i=1, \dots, n$ を導入した後， w ， b で微分して得られる式を代入すると式(4)に示される Wolfe-dual と呼ばれる双対問題が得られる．

$$\begin{aligned} \text{Maximize}_{\lambda} L_D(\lambda) &= \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i,j=1}^n \lambda_i \lambda_j t_i t_j x_i^t x_j \\ \text{subject to } \sum_{i=1}^n \lambda_i t_i &= 0 \quad (0 \leq \lambda_i, i=1, \dots, n) \end{aligned} \quad (4)$$

これは，Lagrange 乗数 $\lambda_i (\geq 0)$ ， $i=1, \dots, n$ に関する最適化問題となる．その解で λ_i^* が 0 でない，すなわち， $\lambda_i^* > 0$ となる訓練サンプル x_i は，先の 2 つの超平面 H1: $w^t x + b = 1$ か H2: $w^t x + b = -1$ のどちらかにのっている．一般にはサポートベクトルは，もとの訓練サンプル数に比べてかなり少ない．つまり，沢山の訓練サンプルの中から少数のサポートベクトルを選び出し，それらのみを用いて線形しきい素子のパラメータが決定されることになる．実際，双対問題の最適解 $\lambda_i^* (i \geq 0)$ ，および停留点での条件式から，最適なパラメータ w^* は，

$$w^* = \sum_{i \in S} \lambda_i^* t_i x_i \quad (5)$$

となる．ここで， S はサポートベクトルに対応する添え字の集合である．また，最適なしきい値 b^* は，2 つの超平面 $w^t x + b = 1$ か $w^t x + b = -1$ のどちらかにのっているという関係を利用して求めることができる．すなわち，任意のサポートベクトル x_s ， $s \in S$ から

$$b^* = t_s - w^{*t} x_s \quad (6)$$

により求め，最終的に，線形 SVM による最適な識別関数 $f(x)$ を双対問題の最適解 $\lambda_i^* (i \geq 0)$ を用いて表現すると，

$$\begin{aligned} f(x) &= \text{sign}(w^{*t} x + b^*) \\ &= \text{sign} \left(\sum_{i \in S} \lambda_i^* t_i x_i^t x + b^* \right) \end{aligned} \quad (7)$$

となる．すなわち， $\lambda_i^* = 0$ となる多くの訓練サンプルを無視し， $\lambda_i^* > 0$ となる識別平面に近い少数の訓練サンプルのみを用いて識別関数が構成される．ここで，重要な点はマージン最大化という基準から自動的に識別平面付

近の少数の訓練サンプルのみが選択されたことであり、その結果として、未学習データに対してもある程度良い識別性能が維持できていると解釈できる。すなわち、サポートベクトルマシンは、マージン最大化という基準を用いて、訓練サンプルを選択することで、モデルの自由度を抑制するようなモデル選択が行われていると解釈できる。

2.2 線形 SVM

上述の SVM は訓練サンプルが線形分離可能な場合についてのみ有効である。したがって、本研究で取り扱うような実問題で線形分離可能となることは極めて稀である。よって、本研究では線形分離不可能な場合に対しても線形しきい素子のパラメータを求めることができるソフトマージン法を用いる。具体的には、線形分離不可能な問題に対応するため、多少の識別誤りを許すように制約を緩める方法をとる。ソフトマージン SVM はマージン $1/\|w\|$ を最大としながら、幾つかのサンプルが超平面 H_1 あるいは H_2 を越えて反対側に入ってしまうことを許すというものである。反対側にどれくらい入り込んだかの距離を、パラメータ $\xi_i (\geq 0)$ を用いて、 $\xi_i/\|w\|$ と表すと、その和は以下のようになる。

$$\sum_{i=1}^n \frac{\xi_i}{\|w\|} \quad (8)$$

式(9)はなるべく小さいことが望ましい。

$$w - \sum_{i=1}^n \lambda_i t_i x_i = 0 \quad (9)$$

2.3 非線形 SVM

ソフトマージン法を用いることで、線形分離可能でない場合に対しても線形しきい素子のパラメータを求めることができるようになる。しかし、ソフトマージン法を用いたとしても、本質的に非線形で複雑な識別課題に対しては、必ずしも良い性能の識別器を構成できるとは限らない。本質的に非線形な問題に対応するための方法として、特徴ベクトルを非線形変換して、その空間で線形の識別を行うカーネルトリックと呼ばれている方法が知られている。

今、元の特徴ベクトル x を非線形の写像 $\phi(x)$ によって変換し、その空間で線形識別を行うことを考える。写像 ϕ として、入力特徴を2次の多項式に変換する写像を用いるとすると、写像した先で線形識別を行うことは、もとの空間で2次の識別関数を構成することに対応する。一般には、こうした非線形の写像によって変換した特徴空間の次元は非常に大きくなりがちである。しかし、サポートベクターマシンの場合には、目的関数 L_D や識別関数が入力パターンの内積のみに依存した形になっており、内積が計算できれば最適な識別関数を構成すること

が可能である。つまり、非線形に写像した空間での2つの要素 $\phi(x_1)$ と $\phi(x_2)$ の内積が

$$\phi(x_1)^t \phi(x_2) = K(x_1, x_2) \quad (4.32)$$

のように、入力特徴 x_1 と x_2 のみから計算できるなら、非線形写像によって変換された特徴空間での特徴 $\phi(x_1)$ や $\phi(x_2)$ を計算する代わりに、 $K(x_1, x_2)$ から最適な非線形写像を構成できる。ここで、このような K のことをカーネルと呼んでいる。このように高次元に写像しながら、実際には写像された空間での特徴の計算を避けて、カーネルの計算のみで最適な識別関数を構成するテクニックのことをカーネルトリックと呼んでいる。

実用的には、 K は計算が容易なものが望ましい。例えば、

多項式カーネル

$$K(x_1, x_2) = (1 + x_1^t x_2)^p \quad (4.34)$$

Gaussianカーネル

$$K(x_1, x_2) = \exp\left(\frac{-\|x_1 - x_2\|^2}{2\sigma^2}\right) \quad (4.35)$$

などが使われている。

3. 入力データ

本研究で使用する打音データは鋼橋の実物大規模の鋼コンクリート床版の施工性確認実験および非破壊検査手法に関する実験において得られたものである⁷⁾。供試体として、孔あき鋼板などの鋼板をずれ止めとした鋼板リブ形式およびトラス型鉄筋をずれ止めとした2種類のトラス型鉄筋形式、幅30m長さ15mの鋼コンクリート床版を用いる。

剥離モデルとしては、コンクリート合成床版内部に剥離を再現するために大きさ、厚さの異なる発泡スチロールおよびゴムを挿入する。発泡スチロールおよびゴムはコンクリート内部に空気、水が介在している場合を想定している。剥離モデルはすべて同じ深さに設置する。打設方法としては、まず底鋼板を設置し、その上面に剥離モデルを取り付ける。その後、床版内部にコンクリートを注入する。コンクリート打設後に診断者が底鋼板下面からタッピングハンマーで打撃し、その発音をエレクトレットコンデンサーマイクロフォンにより、25kHzのサンプリング周波数で収録する。

表-1 に剥離モデルの材質と大きさ、およびサンプルのラベルについてまとめた。実験を行った剥離モデルの

厚さは 5mm と 1mm の二種類、材質は発泡スチロールとゴムの二種類、サイズは、300mm×300mm、200mm×200mm、100mm×100mm、50mm×50mm の四種類で、それぞれの剥離モデルが鋼板リブ形式、トラス型鉄筋形式の内部に設置されている。サンプルの総数は 49 点である。本研究ではこれらのサンプルを用いて正規化したうえで、パターン認識に基づいた波形データの識別を行う。

表 - 1 剥離モデルのサンプル一覧

厚さ	材質	サイズ(mm)	鋼板リブ形式	トラス型鉄筋形式
5mm	発泡スチロール	200×200	P1-7	T1-7
		100×100	P1-8	T1-8
		50×50	P1-9	T1-9
1mm	発泡スチロール	300×300	P2-6, P4-6	T3-6, T7-6
		200×200	P2-1, P2-2, P2-3, P2-7, P4-4, P4-7	T3-1, T3-2, T3-7, T7-4, T7-7
		100×100	P2-4, P2-8, P4-8	T3-4, T3-8, T7-8
	ゴム	50×50	P2-9, P4-9	T3-9, T7-9
		300×300	P6-6	T11-6
		200×200	P6-1, P6-2, P6-3, P6-7	T11-1, T11-2, T11-3, T11-7
	100×100	P6-4, P6-8	T11-4, T11-8	
		50×50	P6-9	T11-9
	健全部			P2-13




図 - 1 振幅データ(健全部)




図 - 2 振幅データ(発泡スチロール内在)




図 - 3 振幅データ(ゴム内在)

3.1 振幅データ

実験で得られた打音波形データの一部を図 - 1、図 - 2、図 - 3に示す。図 - 1は健全部、図 - 2は剥離モデル(発泡スチロール、200mm×200mm×5mm)が内部に存在する部位から得られた打音波形データ、図 - 3は剥離モデル(ゴム、300mm×300mm×1mm)が内部に存在する部位から得られた打音波形データである。図 - 1、図 - 2、図 - 3におけるX軸は時間(単位はミリセカンド)、Y軸は振幅となっている。振幅データにおける収録時間は、全て40msecとなっている。

3.2 周波数データ

収録した波形データに対して、高速フーリエ変換処理(以下FFT)を行い、各打音データの周波数を取得し、データとして用いる。図 - 1、図 - 2、図 - 3の波形データにFFTを適用して、出力されたデータが図 - 4、図 - 5、図 - 6である。周波数データについては、X軸は周波数、Y軸についてはレスポンスとなっている。




図 - 4 周波数データ(健全部)




図 - 5 周波数データ(発泡スチロール内在)




図 - 6 周波数データ(ゴム内在)

3.3 前処理

パターン認識手法に基づき得られた周波数データから特徴量をより抽出しやすくするようにノイズ除去を行う。本研究では、FFT処理によって得られたデータにウェーブレット変換を行ってノイズの除去を行った。図-7、図-8、図-9は、図-4、図-5、図-6の周波数データをそれぞれウェーブレット変換によりノイズ除去を行った後の図である。

3.4 特徴量抽出

本研究では、周波数データのピーク時の周波数とレスポンスに注目し、実験により得られた周波数データのピーク時の周波数とレスポンスを上位から特徴量とした。特徴量としてピーク時の周波数とレスポンスをそれぞれ上位から4つ取得し、4次元とした。また周波数データとレスポンスをそれぞれ均等に特徴量データとし、4次元(周波数上位2つ、レスポンス上位2つ)、6次元(周波数上位3つ、レスポンス上位3つ)、8次元(周波数データ上位4つ、レスポンス上位4つ)を特徴ベクトルとして識別を行った。図-10はグラフ上での特徴量取得方法の例であり、丸の部分を選択された特徴量の部分である。

4. 剥離種別の分類結果

4.1 実験概要

本研究では、鋼橋の鋼コンクリート合成床版を用いた施工実験により得られた49点の打音データを対象として、前章で述べた手順により抽出した特徴量を用いて周波数データの分類・識別を行う。




図-7 ノイズ除去後(健全部)




図-8 ノイズ除去後(発泡スチロール内在)

今回の実験では、多次元データを作成し、有効次元数の検証と認識率の向上を主な目的として行った。今回は、4次元、6次元、8次元データによる認識を行った。

また、次元数の変化による線形カーネルと非線形SVMで用いる多項式カーネル、Gaussianカーネルの場合での認識率の検証を行った。

学習においては、大きさと材質を分類した9段階をクラスとして教師信号に用いたもので学習を行う。テストにおける識別精度の評価はLeave-One-Outで行う。今回の実験で用いたクラステーブルを表-2に示す。

なおSVMにて使用したカーネルのパラメータについては、多項式カーネルは3、Gaussianカーネルは1とした。多項式カーネルに関しては、パラメータをあげた場合、認識結果は上昇したが、計算時間が長いので、適度な処理時間と感じられた数値をパラメータとしている。Gaussianカーネルでは、できるだけ高い認識率が得られ、かつ1~10の間にてパラメータを決定した。

表-2 クラステーブル

大きさ・材質	
N	健全部
S300	発泡スチロール300mm×300mm
S200	発泡スチロール200mm×200mm
S100	発泡スチロール100mm×100mm
S50	発泡スチロール50mm×50mm
R300	ゴム300mm×300mm
R200	ゴム200mm×200mm
R100	ゴム100mm×100mm
R50	ゴム50mm×50mm

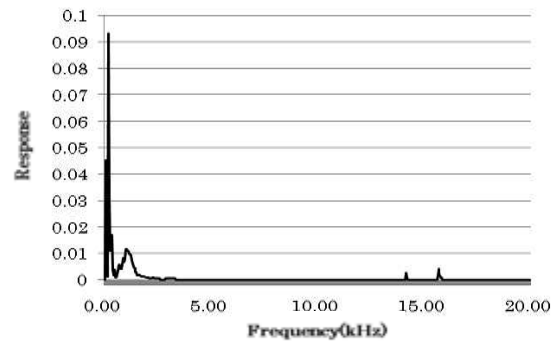


図-9 ノイズ除去後(ゴム内在)




図-10 特徴量選択例

4.2 結果と考察

表 - 3 に大きさと材質を考慮した各次元によるカーネルごとの認識結果を示す。それぞれの次元ごとによる、カーネルの識別結果からみてみると、4次元の場合、線形カーネルの場合は 28.57%，多項式カーネルの場合は 51.02%，Gaussian カーネルの場合は 57.14% となった。次に 6次元に着目しデータをみてみると、線形カーネルの場合は 28.57%，多項式カーネルの場合は 59.18%，Gaussian カーネルの場合は 71.43% となった。最後に 8次元に着目してみると線形カーネルの場合は 34.69%，多項式カーネルの場合は 71.43%，Gaussian カーネルの場合は 85.71% となった。各カーネルの平均認識率は、線形カーネルでは 30.61%，多項式カーネルでは 60.54%，Gaussian カーネルでは 71.43% となった。また、最大認識率は全てのカーネルにおいて 8次元であり、次元数を高めるほど、認識率が向上した。また各次元において Gaussian カーネルが最も高い認識率が得られた。このことより、本研究で取り扱った問題は非線形問題であることが分かる。

表 - 3 各次元による認識結果

	線形カーネル	多項式カーネル	Gaussianカーネル
4次元	28.57%	51.02%	57.14%
6次元	28.57%	59.18%	71.43%
8次元	34.69%	71.43%	85.71%

今回の実験では線形カーネルの認識率が著しく低かった。線形カーネル自体は複雑な計算式を必要せず、計算処理時間は短いですが、周波数データ分析に関しては有意なカーネルとはいえない。そのため、ある程度処理時間がかかったとしても、非線形 SVM である多項式カーネルや Gaussian カーネルを適応する必要がある。

本実験より、次元数を多くすることによって認識率が高くなる傾向が得られた。このことより、経験豊富な熟練技術者は打音情報の 1 点を見ているのではなく、一連の振動の傾向を把握した上で、剥離等の損傷を同定していることが分かる。また全てのカーネルにおいて 8次元の場合が最大認識率を得ることができたが、49 個のデータでは、これ以上の次元数による認識を行ってしまうと、次元の呪いに掛かってしまう可能性が高く、8次元以上の高次元による認識をおこなうならば、学習データ数の増加が必須となってくると思われる。そのため 8次元以上の高次元による認識に関して、今回は行わなかった。

5. おわりに

本研究では、サポートベクトルマシン(Support Vector Machine: SVM)を用いて、熟練の専門家が従来から行ってきた打音法による不良箇所の有無を発見する点検の結果を学習し、非熟練者でも、打音試験によって得られた波形データから得られる周波数データを抽出した特徴量を用いて類似性を検索できるシステムの開発を目指し、

線形SVMと非線形SVMによる識別性能の比較実験を行った。周波数データに対しては、線形SVMを用いるよりも非線形SVMを用いた方が高い結果が得られ、中でも Gaussianカーネルが最も高い認識率が得られた。

今回は周波数から得られる、周波数とレスポンスを特徴量として行ったが、取得できる特徴量が極端に少ない場合も存在したため、前処理の手法や特徴量の取得方法も少し改善する必要がある。また、実験で用いた打音データは剥離部分を想定して作られた発泡スチロールやゴムが埋め込まれた箇所を叩いたときに得られた打音試験データであるため、実際の橋梁の内部に存在する空気や水などの剥離箇所を叩いて得られたデータを用いたときに、どのような識別結果になるのかという問題点がある。

また SVM に関して、多項式カーネルや Gaussian カーネルは、学習する際のパラメータの設定も重要となってくる。今回の実験では、多項式カーネルのパラメータを 3、Gaussian カーネルのパラメータを 1 としたが、多項式カーネルについてはパラメータ数を 5 とした場合が、もっとも認識率が良かったが、計算時間が 3 と比べると数十倍にもなってしまい、実際にシステム化を行った際に学習に掛かる時間が膨大なものになってしまう可能性が高い。今回のデータ数は 49 個であったが、実際の認識を行うにはデータ数が少ないと思われる。今後、実験を行っていく際にはデータ数が膨大なものとなってきてしまうため、学習用のデータ数が増加すると、それに伴い学習計算時間も増加する傾向がある。しかし、学習用のデータ数が増加すると計算量を減らしたとしても、認識結果が向上する可能性もある。そのため、今後は学習データ数とパラメータの精度も向上していく必要がある。

参考文献

- 1) 魚本健人, 加藤潔, 広野進: コンクリート構造物の非破壊検査, 森北出版, pp.426, 1990.
- 2) 社団法人日本コンクリート工学協会: コンクリート診断技術 02 - 基礎編 -, 2002.
- 3) 阪上隆英: 赤外線サーモグラフィによる非破壊評価に関する最近の話題, 非破壊検査, 第 51 巻 6 号, pp.320-327, 2002.
- 4) 田中正吾, 山田実: 信号伝搬モデルに基づく電磁波レーダによるコンクリート構造物の非破壊検査, 計測自動制御学会論文集, Vol.39, No.5, pp.432-440, 2003.
- 5) 土木学会関西支部: コンクリート構造の設計・施工; 維持管理の基本, pp.363-415, 2003.
- 6) 魚本健人: コンクリート診断学入門, 2004.
- 7) 齋藤憲彦・鶴巻正行・川岡靖司・原田康弘・吉永文英: 鋼コンクリート合成床版の品質管理に関する確認実験, 橋梁と基礎, Vol.39, No.10, 2005.
- 8) 前田英作: 痛快! サポートベクトルマシン - 古くて新しいパターン認識手法 -, 情報処理, 情報処理学会, pp.676-683, 2001.

(2009 年 8 月 7 日受付)