

AdaBoost を用いた RC 床版のひびわれ損傷度判定システムの構築

Damage Assessment System for RC bridge deck cracks using AdaBoost technique

服部洋*・中津功一朗*・古田均**

Hiroshi HATTORI, Koichiro NAKATSU and Hitoshi FURUTA

*正会員 博士 (情報学) 関西大学 総合情報学部 (〒 569-1095 大阪府高槻市霊仙寺町 2-1-1)

**正会員 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)

In order to establish a rational maintenance program for bridge structures, it is necessary to evaluate the structural damage of existing bridges in a quantitative manner. However, it is difficult to avoid the subjectivity of inspectors when visual data are used for the evaluation of damage or deterioration. In this paper, an attempt is made to develop a new assessment system of bridge conditions by using a health monitoring technique. The damage of Reinforced Concrete (RC) bridge decks is evaluated with the aid of digital photos and pattern recognition. So far, neural network has been applied to judge the damage state of RC bridge decks. However, there are still some problems that learning data are not enough and recognition accuracy is not satisfactory. In order to solve these problems, AdaBoost is applied here, which is a classifier system with combined strong and weak learning systems. Through the numerical examples using actual data, it is shown that the recognition rate can be improved by using AdaBoost.

Key Words : Adaboost , damage assessment, RC slab, pattern recognition

1. はじめに

わが国では、高度経済成長期において多くのコンクリート構造物が建設され、橋梁や道路等に代表される社会資本の整備が急速かつ大量に行われてきた¹⁾。しかし土木構造物は絶えず重い荷重を負担し、厳しい気候作用を受けるという悪条件にさらされている。

そのため、経年により劣化することは不可避であるが、橋梁構造物に亀裂や傷が発見されるなど、これまでの構造物に対する信頼性が揺らいでおり、維持管理に対する関心も高まっている²⁾。橋梁は、その規模が大きく、その多くは現在すでに供用されているため、社会的・経済的影響を考えると老朽化が進んでいても取り壊して作り変えることが容易にはできないことや、国や地方公共団体の財政が逼迫していることを考慮すると、橋梁の余寿命をできるだけ延ばし、永く供用していくことが望まれる。そして土木構造物という貴重な資産を保全し、安全かつ長期的に利用するために、時期を失することなく限られた予算の中で適切な維持管理を行い、常に良好な状態に保たなければならない。そこで、どの程度劣化しているかを効率的に、しかも正確に調査し、信頼性の高い判定をすることが重要となってくる³⁾。

現在は、専門家が点検項目に沿って損傷箇所・状態を記入し、橋梁点検要領に基づいて損傷度の判定を行っている。診断・補修を専門とする技術者は非常に少なく、専門家の直感や工学的判断に頼らざるを得ないという状況であるため、人的コストの増大化、専門家に

よる診断の差異や見過ごしによる誤診という問題点が指摘されている。その一方で診断・補修を必要とする構造物は増加しており、こうしたことから、目視点検による常時の的確な健全度把握は困難であり、コストや時間の観点において効率的かつ信頼度の高いシステムの構築が求められる。

こういった背景から、コンクリート構造物の健全性を的確に評価するヘルスマonitoringシステムの開発は重要であり、床版のひびわれデジタル画像を基に、損傷度を判定するシステムの提案が行われてきた^{4) - 8)}が、認識率の点でまだ課題が残されているといえる。これは、ひびわれの損傷度判定が複雑であること、識別の学習データとなるひびわれ画像が多くないこと等が挙げられる。このことにより、損傷度を判定するためのルールを作成することが困難となっており、より精度の高い識別システムの構築が必要である。

このような状況を踏まえ、本研究では橋梁の床版におけるひびわれを対象に、デジタル画像を用いた新たなひびわれ損傷度判定システムの構築を試みる。本研究では、近年注目を集める Boosting 手法の一つである AdaBoost を適用し、床版の損傷判定の改良を試みる。AdaBoost では、少数の教師データより、汎用的な識別規則を構築できるため、本研究で取り扱うひびわれの損傷度判定に効果的であるといえる。本研究では、実在の橋梁のひびわれ画像を用いることにより、提案システムの検証を行う。提案システムによりデジタル画像のみを用いたひび割れの損傷判断を実現することにより、安価かつ簡易に床版の損傷度判定が可能となる

ことから、維持管理において非常に効果的であるといえる。

2. 床版の損傷診断

2.1 損傷診断の現状

橋梁の維持管理において、長期的な視野のもと経済面、安全面で最適な維持管理を実現するためには、常に橋梁の健全度を把握していることが望ましい。こういったことから、現状では、日常点検や定期点検により現状把握を行っている。目視点検が主であり、橋梁のコンクリート床版を対象にした場合、コンクリートの表面に顕在化したひびわれなどの損傷要因に関する視覚的な情報から、専門技術者が床版内部の健全性を評価する。

しかしながら、損傷度診断は専門技術者の長年の経験に基づく評価であるため、経験豊富な経験技術者不足といった問題への対応が急務であり、客観的な判断基準が必要となる。

また、現状の点検方法では、専門技術員が現地に赴く必要があるため、効率的であるとはいいがたく、維持管理対象となる橋梁の増加が見込まれる現状では、目視点検による常時的確な健全度把握は困難になると考えられる。こういったことから、簡易かつ低コストでの損傷度把握が望まれている。

そのため、コンクリート構造物の健全性を的確に評価するヘルスマニタリングシステムの開発は重要であり、床版のひびわれデジタル画像を基に、損傷度を判定するシステムの提案が行われているが、前述のように認識率の点でまだ課題が残されているといえるため、改良が望まれている。

2.2 損傷度判定対象

本研究ではデジタルカメラにより撮影された画像を用いて、ニューラルネットワークによる識別器を構築し、これら識別器により構成された AdaBoost を用いて判定を行う。

前処理として、デジタル画像に対して図-1 に示す流れによる処理を施す。本研究ではデータとして阪神高速道路株式会社から提供された、市販のデジタルカメラによる橋梁の床版部分の写真を用いた、床版部分にひびわれによる損傷のみを含む画像 48 枚を使用した。ただし、床版観測時においてホワイトチョークによりひびわれ領域のトレースが行われている。図-2 に本研究で用いた床版画像の例を示す。

デジタル画像は照明むらにより輝度にばらつきがあるため、ホワイトチョークと照明が重なる部分が多く、グレースケールに変換するだけではひびわれだけを認識させることは難しい。そのため、専用の検出ソフト⁹⁾などを使用し、ひびわれの抽出を行うことが必要と




図-1 ひびわれ画像の前処理




図-2 ひびわれ画像

なる。また、画像からのひびわれ抽出に関しては、種々の研究が行われており¹⁰⁾、今後さらに容易にひびわれを抽出することが可能になると考えられる。本研究で用いた画像では、ひびのトレースのみではなく、床版の位置などの付加情報もチョーキングされているため、ひびの抽出処理には手作業が必要となった。次に、ひびわれが抽出された画像をグレースケールに変換し、2値化処理を施す。

(1) 2 値化処理

本研究で扱う画像の中には、照明条件が一様ではないため、背景領域の濃度値や対象領域の濃度値が画像全体で一定していないものが含まれている。

そこで本研究では、しきい値を決定する方法として、固定しきい値処理におけるモード法を用いて 2 値化を行う。固定しきい値処理モード法とは、ある濃度をしきい値とし、2 値化結果を見ながら試行錯誤的にしきい値 t を決定する手法である。

この方法を用いた場合、2 値化結果を見ながら、より損傷箇所を正確に抽出できるしきい値を決定することができる。また、2 値化処理によって画像の特徴を少しのデータ量により表すことが可能となり、学習時間を短縮することができる。本研究では 2 値化処理には Adobe Photoshop を使用して変換を行った。図-3 に閾値を決定するためのひびわれ画像とヒストグラムを、図-4 にしきい値の変化による画像の差異を示す。また、図-5 に処理を施した画像の例を示す。




図-3 ひびわれ抽出後の画像とその 2 値化ヒストグラム




図-4 しきい値別ひびわれ画像




図-5 2 値化処理後のひびわれ画像

2.3 判定基準

本研究で用いた損傷ランクは、以下のように定められている点検項目と判定基準に基づくものである。また画像に対しては、予め専門家により判定が行われたものを使用する。

(1) 点検項目

点検項目は以下によるものとする。

1. 亀甲状ひびわれ、または線状ひびわれ
2. ひびわれの方向（一方向性、二方向性の種別）
3. ひびわれの連続性
4. ひびわれの集中性

(2) 判定基準

ひびわれの判定は、一方向性および二方向性のひびわれそれぞれについて、阪神高速道路公団により提示された床版ひびわれ判定基準¹¹⁾に従い、ひびわれの種類や幅、間隔を基に行うものとする。なお、ここでいうひびわれ幅、間隔は平均的な値を示す。

表-1 床版ひびわれ判定基準¹¹⁾

ひびわれの種類		判定要素		判定
		平均ひびわれの幅	平均ひびわれの間隔	
二方向性のひびわれ	平均的ひびわれ発生密度による判定	0.1mm 程度以上	40cm 以下	A
			40-60cm	B
			60cm 以上	C
	局所的に集中したひびわれ、または局所的に発生した亀甲状ひびわれに対する判定	0.2mm 程度以上 0.1-0.2 mm 程度	-	A B
			-	A
一方向性のひびわれ	平均的ひびわれ発生密度による判定	0.2mm 程度以上 0.1-0.2 mm 程度	50cm 以下	A
			50cm-1m	B
			1m 以上	C
			1m 未満	B
	局所的に集中したひびわれ、または局所的に発生した亀甲状ひびわれに対する判定	0.2mm 程度以上 0.1-0.2 mm 程度	1m 以上	C
			-	A B

注：局所的に集中したひびわれとは、主桁近傍で橋軸方向に連続した線状ひびわれや部分的にひびわれの発生密度が高くなっている箇所を示す

3. AdaBoost

パターン認識とは、ある対象の中から観測されたパターンをあらかじめ定められた複数のクラスのうちの一つに対応させる処理である¹²⁾。従来は、ひとつの識別器により判定を行っているが、複雑な対象問題であっ

た場合に、認識が困難になったり、教師データが少数であった場合に、過学習を引き起こしたりと、精度のうえで問題が起こることが考えられる。

その対策として Boosting 手法の適用が試みられている。Boosting 手法とは、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) を構成する手法である。この Boosting 手法の一つが、AdaBoost^{13) - 19)} 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重み付き多数決により一つの仮説に統合する。AdaBoost の概念図を図-6 に示す。




図-6 AdaBoost の概念²⁰⁾

図-6 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、すべて異なる学習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出来る。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こと、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。

AdaBoost の学習手順¹³⁾を図-7 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。




図-7 AdaBoost の流れ²⁰⁾

1. 訓練データの獲得

訓練データとして $(x_1, y_1), \dots, (x_m, y_m)$ を与える。

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。ここで、ラウンド t における訓練データ i の選択確率を $D_t(i)$ と表記する。

$$D_1(i) = \frac{1}{m} \quad (1)$$

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 $D_t(i)$ を基に、確率により選別される。また、弱仮説の精度は、 D_t による誤り確率により、次式で定義される。

$$\epsilon_t = P_{ri-Di}[h_t(x_i) \neq y_i] = \sum_{i: h_t(x_i) \neq y_i} D_t(i) \quad (2)$$

5. 弱仮説の重要度の決定

重み付き多数決に用いる弱仮説の重要度を次式で定義する。

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

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され、難しい事例に学習が集中することになる。確率分布の更新式は次式のようになる。

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

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 H_t の獲得

最終仮説 H_t を T 個の弱仮説の重み付き多数決として得る。最終仮説を獲得するための式を以下に示す。

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

4. AdaBoost を用いた損傷診断

4.1 入力値

元の画像データは 1782×1220 ピクセルとサイズが大きく、元画像をそのまま学習に用いることは効率的ではなく、非常に多くの時間がかかる。そのため、少ない情報量で効果的に識別が可能である特徴を用いる必要がある。

前述のようにひびわれの幅や長さなどの判断基準があるが、画像内にひびわれは多数あり、すべての情報を抽出することは容易ではない。さらに、画像内には複数のひびわれが存在していること、チョーキングを行っていることや解像等の問題から画像からの正確な幅や長さの抽出は困難であり、場合によってはシステムに応じた性能で新たに画像を取り直す必要が生じるため現実的ではないと考えられる。また、出力となる損傷度が3段階であるため、厳密な入力情報は必ずしも必要ではないと考えられる。

こういったことから、本研究では2値化画像を圧縮した入力の使用による識別を試みる。具体的には、2値化された画像を 256×256 のメッシュに区切り、各メッシュ内のひびわれ密度を求めることとする。各メッシュ内のひびわれ部分の面積を計算し、縦横各方向にひびわれ面積の総和をとる。すなわち、一つ目の入力をメッシュの1行目の総和、二つ目の入力をメッシュの2行目の総和、256個目の入力をメッシュの最終行の総和とし、同様に257個目の入力をメッシュの1列目の総和、512個目の入力をメッシュの最終列の総和とする。これにより、縦256、横256の合計512個のデータでひびわれを表現することができ、ニューラルネットワークにおける学習データ数を抑えることが可能となり、学習時間の短縮につながる。また、現在使用しているひ

びわれ画像を用いることも可能である。この操作により、位置、密度などの情報を保持したまま、情報の圧縮が可能である。入力データの作成方法を図-8に示す。




図-8 入力データ

なお本研究では、損傷度を A, B, C の3段階で判定するため、階層型ニューラルネットワークは3出力とし、教師データは A ランク (1, 0, 0), B ランク (0, 1, 0), C ランク (0, 0, 1) の3パターンとし、最も大きな値を出力するものを識別結果とする。

4.2 数値実験

ここでは、AdaBoost を用いた提案システムの有効性を示すため、実際の床版のひびわれ画像を用いた数値実験を行い、ニューラルネットワークによるシステムとの比較を行う。本実験では、48枚の画像データのうち、20枚を教師データとして用い、提案システムの精度の検証を行う。この際、学習データに用いる画像の各損傷度画像の枚数は、均一となるようにする。また、比較対象であるニューラルネットワークを用いた場合には、教師データに対する誤認識も見られるため、教師データも識別対象とし、精度を検証する。

(1) 階層型ニューラルネットワーク

ここでは、提案システムの比較対象として、ニューラルネットワークによる識別を行う。表-2に、ニューラルネットワークの学習環境を示す。

本研究では、学習回数10,000回で学習を行った。表-3は階層型ニューラルネットワークで行った学習の結果の一部である。出力は A ランク (1, 0, 0), B ランク (0, 1, 0), C ランク (0, 0, 1) の3パターンを理想値とする。ここで、左から順に A, B, C に関するニューロンの出力であり、3つの出力のうち最も値の大きいものをシステムの判定とする。表内では、判定結果となる最大出力を下線により示している。

表-3より、A ランクおよび C ランクについては、対応する出力が1に近く、残りの出力が0に近く、的確に認識が来ていることが確認できる。一方で、B ランクの画像の認識精度は低い。データ5に関しては誤認

表-2 ニューラルネットワークの学習環境

ネットワークの層の数	3
学習パターン数	20
第1層目のユニット数	512
第2層目のユニット数	64
第3層目のユニット数	3
学習回数	10,000
許容誤差	0.01
学習係数	0.3
慣性係数	0.9
シグモイド関数の傾き	1.0
学習後の誤差	8.513E-03

表-3 ニューラルネットワークの識別結果

データ 番号	損傷 ランク	出力値			判定
1	A	<u>0.989</u>	0.011	0.002	A
2	B	0.011	<u>0.231</u>	0.159	B
3	C	0.032	0.001	<u>0.993</u>	C
4	A	<u>0.851</u>	0.154	0.001	A
5	B	0.165	0.005	<u>0.736</u>	C
6	C	0.006	0.001	<u>0.999</u>	C

識を起こしており、データ2は誤認識ではないがBに関する出力値が0.231と低く、認識できているとはいえない。これはBランクの画像が、AランクあるいはCランクの画像に類似していることに起因していると考えられる。このようにBランクの画像の認識が困難であるため、全体としての認識率は約68%であった。

(2) AdaBoost

次に、AdaBoostを用いた提案システムにより損傷度判定を行う。AdaBoostで学習させるにあたり、弱学習アルゴリズムとして階層型ニューラルネットワークを用いている。また、先のニューラルネットワークによる実験結果と比較を行うために、階層型ニューラルネットワークと同じパラメータで学習を行った。表-5に学習時のパラメータ値を示す。

本システムでは損傷度 A, B, C の3段階で判定するが、前節で述べた AdaBoost アルゴリズムは2値判定用である。そこで本研究では、AdaBoost を多値問題に拡張し、重み付き多数決により、判定を行うものとする。すなわち、3つの出力値のうち最も高い出力値を判定結果とするものとして識別を行った。表-5は AdaBoost で行った学習の結果の一部である。ここで、左から順に A, B, C に関する出力であり、3つの出力のうち最も値の大きいものをシステムの判定とする。表内では、判定結果となる最大出力を下線により示して

表-4 AdaBoost の学習環境

ラウンドの数	30
一つの学習機の学習回数	1000
学習パターン総数	20
ネットワーク層の数	3
第1層目のユニット数	512
第2層目のユニット数	64
第3層目のユニット数	3
学習係数	0.3
慣性係数	0.9
シグモイド関数の傾き	1.0

いる。

表-5 AdaBoost の認識結果

データ 番号	損傷 ランク	出力値			判定
1	A	<u>10.181</u>	6.894	2.714	A
2	B	6.600	<u>10.753</u>	2.267	B
3	C	1.824	6.827	<u>10.790</u>	C
4	A	<u>11.960</u>	7.223	1.549	A
5	B	5.257	<u>8.095</u>	4.243	B
6	C	1.672	6.834	<u>11.016</u>	C

表-5より、AdaBoostを用いた提案システムによって、的確に識別できていることが確認できる。データ5を除く画像では、対象となるランクに関する出力が10を超えており、他の出力に比べて非常に大きく、的確に認識できているといえる。また、データ5に関しても、Bランクであるという出力が一番大きく、認識できている。

以上のように、ニューラルネットワーク単体では、認識が困難であったBランクの画像に対しても正確に認識できていることがわかる。これは、AdaBoostを用いることにより、Bランクの認識に強いネットワークの構築が可能となっているためであると考えられる。

このことを確認するために、ニューラルネットワークおよびAdaBoostの損傷ランクごとの認識率を、表-6に示す。

表-6に示すように、ニューラルネットワークでは、Bランクの認識率が約40%と非常に低く、全体の認識率の低下につながっている。また、Aランクの認識率も高くなく、このことから、AランクとBランクの画像の認識が困難であったといえる。

一方で、AdaBoostでは、すべてのランクにおいて90%以上の認識率が得られている。ニューラルネットワーク単体では、識別が困難であるAランクとBラン

表-6 損傷ランクによる認識率の比較

手法	認識率 (%)			
	ランク A	ランク B	ランク C	合計
NN	60.0	38.5	87.5	68.1
AdaBoost	90.0	92.3	95.8	93.6

クの判定を、複数の識別器を複合することにより識別が可能になっているといえる。

このことは、ラウンド数と正解数の推移を示した、表-7により確認できる。

表-7 ラウンドごとの識別結果

ラウンド数	正解数
1	32
10	40
20	43
30	45

表-7において、ラウンド数を増やす、すなわち弱学習アルゴリズムを増やすごとに正解数が増えていることが確認できる。AdaBoostを用いることにより、最終的に94%の正解率を得ることができ、ニューラルネットワークによる認識率を20%以上上回っている。

4.3 考察

実画像を使用した実験において、AdaBoostを用いた提案システムの認識精度は、ニューラルネットワークの認識制度を大きく上回っており、提案システムが有効であるといえる。

ニューラルネットワーク単体での認識率は約70%と低く実用にたえるとはいえない。学習パラメータ等や構造の変更などにより精度が改善されることも考えられるが、調整の困難さが残される。一方でAdaBoostを用いた場合では、ニューラルネットワークの各種パラメータ等は同じであり、ラウンド数以外に新たに設定するパラメータはなく、設計は容易である。こういったことから、提案システムが有効であるといえる。

また、学習に用いる入力値については、提案システムでは現画像そのものではなく、現画像の縦横におけるひびわれのヒストグラムを用いている。提案システムでは少ない教師データによる学習を用いた提案システムにおいて、90%以上の認識率を有しており、非教師データの多くを認識可能である汎用的なルールを獲得できたことは有意であるといえる。このことから、提案システムでの入力方法が効果的であると考えられるが、今後、ひびわれの幅や密度など、入力値についての検証が必要であると考えられる。

5. おわりに

本研究では、橋梁におけるひびわれの損傷度判定を常時行うための支援を目的として、効率的かつ経済的に、自動的な損傷判断が可能なシステムの構築を行った。

教師となる画像が多くなく、また、判別が困難である、RC床版のひびわれの損傷判定を目的として、AdaBoostを用いた判定システムの提案を行った。実際の画像を用いた実験により、階層型ニューラルネットワークだけでは認識率が低く、教師データが少ないために、汎用的なルールの獲得は難しいことが確認された。ここでは、弱学習アルゴリズムを組み合わせるAdaBoostを用いて学習を行うことで、認識率が低く、多大な労力とコストがかかるという従来の問題点を解決することができた。以下に本手法の利点を示す。

- 容量の大きい画像データであっても、弱学習アルゴリズムを組み合わせることで複雑な計算をすることなく計算効率的に学習を行うことができる
- 少ない教師データから学習を繰り返して複数の仮説を得ることにより、細かいクラスタリングが可能のため、高い認識率を得ることができた
- 高い精度で損傷度を認識できるため、専門家に依存することなく判定結果を得ることでき、誤診の防止、時間、労力およびコストを削減することが可能であると考えられる

以上のことより、AdaBoostを用いた提案システムを用いることで、容易に低コストでひびわれの損傷診断が可能となることから、橋梁の維持管理において非常に効果的であるといえる。

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.4-26,1990.
- 2) 原田隆郎, 呉智深, 吉田典史, 岩松幸雄:ニューラルネットワークによる道路舗装の補修計画最適化モデル, 土木学会論文集, No.700, VI-54, pp.145-157, 2002
- 3) 長通伸幸, 香月智, 深和岳人:副関数分類・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
- 4) 松井繁之, 前田幸雄, 道路橋 RC 床版の劣化度判定法の一提案, 土木学会論文集, 通号 374, pp. p419~426, 1986
- 5) 佐々木 聡, 渡邊 一悟, 小出 博, デジタル画像によるコンクリート床版劣化判定システムの開発, コンクリート工学年次論文集, Vol.25, No.1, pp. 1775~1780, 2003
- 6) 宮本文穂, 串田守可, 足立幸郎, 松本正人, Bridge Management System(BMS)の開発, 土木学会論文集, No.560/VI-34,pp.91-106,1997.
- 7) 宮本文穂, 河村圭, 中村秀明, Bridge Management System(BMS)を利用した既設橋梁の最適維持管理計画の策定, 土木学会論文集, No.588/VI-38,pp.191-208,1998.
- 8) 中村秀明, 白倉篤志, 宮本文穂, 階層構造モデルを用いた構造物維持管理支援システムの実用化, 土木学会論文集, No.777/VI-65,pp.125-138,2004.
- 9) 株式会社タダノ 技術研究所, ひび割れ検出ソフトウェア「ひびけん」 Ver.1.0,

- <http://sys.tadano.co.jp/products/hibiken/setumei.pdf>, (2009-07-12 参照).
- 10) 瀧内 裕之, 広兼 道幸, 林 勲, ガボールフィルタを用いたコンクリート構造物上のひび割れ抽出に関する研究, 第 22 回ファジィシステムシンポジウム講演論文集, pp.185-188, 2006
 - 11) 阪神高速道路公団監修, 都市高速道路研究会編著, 都市高速道路における道路橋の点検・補修マニュアル, 2004
 - 12) 石井健一郎, 上田修功, 前田英作, 村瀬洋共著: わかりやすいパターン認識, オーム社, 1998.
 - 13) 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
 - 14) 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
 - 15) 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.1391-1399, 1997
 - 16) 中村雅之, 野宮浩揮, 上原邦昭, 重み更新規則の修正による Boosting アルゴリズムの改善について, 情報処理学会論文誌 Vol.45, NO.3, pp.1001-1013, 2004
 - 17) 小野田 崇, Gunnar Ratsch, Klaus Robert Muller, 2 値分類問題における AdaBoost の漸近特性解析と改善, 人工知能学会誌 Vol.15, No.24, 2005
 - 18) 塚本浩司, 颯々野学, AdaBoost と能動学習を用いたテキスト分類, 情報処理学会研究報告 自然言語処理研究会報告, Vol.2001, No.112(20011120) pp.81-88, 2001
 - 19) 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
 - 20) 古田均, 服部洋, AdaBoost による多自由度構造物のヘルスマモニタリングに関する研究, 構造工学論文集 A 論文 52A, pp.651-658, 2006

(2009 年 4 月 9 日 受付)