

論文 ASR 診断のためのパターン認識手法の開発

大島 義信^{*1}・八木 康人^{*2}・河野 広隆^{*3}

要旨：本研究では、劣化要因のうち特徴的なひび割れパターンを有する ASR 劣化に着目し、ひび割れのパターンから劣化要因が ASR であるかを判定するシステムの開発を行った。判定のシステムとして、ニューラルネットワーク (NN)、AdaBoost 増強された NN、およびサポートベクターマシンを用い、また特徴ベクトルとして局所自己相関関数とフラクタル次元を用いた。その結果、教師データの設定によって誤答率が変化するが、全てのアルゴリズムにおいて良好な判定が行えることが明らかとなった。

キーワード：ASR、ひび割れ、パターン認識、AdaBoost、SVM

1. はじめに

コンクリート構造物の維持管理を行う場合、その初期段階において、外観の状況から劣化要因を推定することが行われる。特に定期点検・日常点検などで外観を調査する場合、現場技術者が変状を判断するケースが多い。しかし劣化要因の判定が困難な場合などを含め、最終的に専門家による判断を仰ぐ場合が多く、劣化構造物の急増に伴い専門家の負担が増大することが予想される。このような状況下で、現場において大まかに劣化要因を判断することができれば、速やかに劣化要因に応じた対応策を講じることが可能となり、維持管理作業の合理化へ繋がると思われる。

現在、外観の状況などから劣化要因を判定するシステムが開発され、一定の成果を収めている¹⁾。しかしこのシステムでは、加算される各項目の重み付けの根拠に疑問が残る。またこのシステムでは、ひび割れパターンなどの外観の情報を十分に活かしているとはいえない。ひび割れのパターンを利用して劣化判定を行うシステムに関しては、道路橋床版の下面に発生したひび割れパターンから疲労劣化度を推定する事例がある²⁾。しかしこの事例では、損傷を疲労ひび割れに限定しており、要因の識別は行っていない。

コンクリート構造物の劣化現象のうち、アルカリ骨材反応 (ASR) については、構造物の外観に特徴的なひび割れ形状を示すことが知られている。この特徴的なパターンに着目し、ひび割れ形状のフラクタル次元により劣化程度を判断する研究が行われており^{3), 4)}、フラクタル次元と ASR には強い相関があることが明らかとなっている。

またひび割れの画像から、機械的にひび割れをトレースする技術に関しても研究が進められている。武田ら⁵⁾は、画像からひび割れ情報を抽出する際に、離散ウェー

レットを適用し、輪郭の強調とノイズ除去を行っている。この技法では、経験的な技法が試行されているものの、効率よくノイズ除去を行うことに成功している。また河村ら⁶⁾は、デジタル画像からひび割れ抽出を行う技術として、対話型遺伝的アルゴリズムとよばれる手法を利用している。この技法では、画像処理に必要な閾値などの条件を遺伝的アルゴリズムによって決定しており、ひび割れパターンの抽出に成功している。

一方、画像情報から機械的にパターンを分類するシステムが開発され、通信分野などで研究が進められている^{7), 8), 9), 10)}。近年では、基本的な識別アルゴリズムであるニューラルネットワーク (NN) に加え¹¹⁾、NN を AdaBoost 理論により増強した学習機械^{12), 13)}や、サポートベクターマシン (SVM)¹⁴⁾と呼ばれる高度な学習機械が開発され、様々な分野で適用が始まっている。よってこのような学習機械をひび割れの識別に用いれば、現場での初動点検において、ひび割れの画像から大まかに劣化要因を判定するシステムが構築できる可能性がある。また劣化要因のうち ASR 劣化に関しては、ひび割れの発生が特徴的であるため、要因推定システムの初期段階として、ASR を判別するシステムの構築が可能であると考えられる。

よって本研究では、ひび割れ画像のパターンから劣化要因を推定するシステムの初期段階として、劣化要因を ASR に限定し、ひび割れの要因が ASR であるか否かを判定するシステムの開発を行う。またパターンを数値化した特徴ベクトルの作成には、高次局所自己相関関数を用いるとともに、フラクタル次元を次数として用いる。また識別機械として、通常の NN に加え、NN を AdaBoost 増強した学習機械、および SVM を用いる。ただし、パターン認識を行うひび割れ画像に関しては、直接画像情報からひび割れを抽出することはせず、ひび割れのトレース画を用いることとする。前述の通り、画像からひび

*1 京都大学 工学研究科助教 博 (工) (正会員)

*2 (株) 構造計画研究所 工修

*3 京都大学 経営管理研究部教授 博 (工) (正会員)

割れ情報を抽出する技術に関しては、現在でもある程度確立されており、トレースされたひび割れ画像を前提としても一般性を失わないと思われる。

2. 劣化判定システム

2.1 システムの概要

本研究において開発するシステムは、コンクリート構造物の外観から抽出したひび割れ画像（トレース画）の特徴量（ベクトル）を入力値とし、劣化要因が ASR であるかの可否を二値（偽/真）で出力するシステムである。以下では、入力値となる特徴ベクトルの作成法、および判定を行う学習機械の種別について述べる。

2.2 特徴ベクトル

(1) 高次局所自己相関関数

高次局所自己相関関数は、図-1に示す各マスクパターンに対し、適合するパターンが画像中にどの程度存在するかを数値化したものである。すなわち、この手法により得られる特徴ベクトルの成分は、局所マスクの数だけ得られることになる。ここで、局所マスクのサイズを大きくすると、局所パターンが増加し、複雑な局所パターンの抽出が可能になる。しかしマスク数を大きくすると、特徴ベクトルの次元が増加し、計算の効率が低下する。よって、本研究では局所マスクの大きさを 3×3 とする¹⁰⁾。これにより局所マスクの数は25個となり、効率のよい計算を行うことができると考えられる。

具体的な抽出法は、以下のプロセスによる。まずデジタル画像上の点 (x, y) について、図-1に示した25種類の局所マスクを掛け合わせる。すなわち、 (x, y) を局所マスクの中央の点としたとき、黒で示された位置に存在するピクセルの輝度値（本研究では1または0）を、マスクの数値と掛け合わせる。ここで、マスクに該当したピクセルのうち、点 (x, y) を除いたピクセルの数を高次局所自己相関関数の次元 N とする。このとき、高次自己相関関数の値は N の値が大きくなるほど大きくなる傾向があるため、 $(N+1)$ 乗根をとって正規化する。つまり、 $w \times h$ のサイズの画像における、局所パターンを表す特徴ベクトルの i 成分 $F(i)$ は、画像上の座標 (x, y) における輝度値を $I(x, y)$ とすると、以下の式(1)のように表される。

$$\begin{aligned}
 F(2) &= \frac{1}{wh} \sum_x \sum_y I(x, y) \\
 F(3) &= \frac{1}{wh} \sum_x \sum_y \sqrt{I(x, y)I(x, y+1)} \\
 &\vdots \\
 F(26) &= \frac{1}{wh} \sum_x \sum_y \sqrt[25]{I(x, y)I(x-1, y+1)I(x+1, y+1)}
 \end{aligned}
 \tag{1}$$

(2) フラクタル次元

本研究では、特徴ベクトルの最初の成分 $F(1)$ として、フラクタル次元を用いる。また図形のフラクタル次元は、ボックスカウンティング法により算定する。以上より、システムの入力値となる特徴ベクトルは、以下のようにフラクタル次元の成分を含む26次元となる。

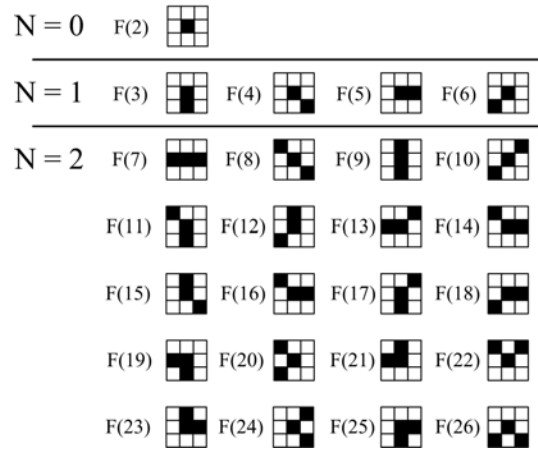


図-1 局所マスクパターン

2.3 学習機械

(1) ニューラルネットワーク (NN)

本研究で用いる NN は、入力層、中間層、出力層の三層からなる単純パーセプトロンとする。入力層のノード数は特徴ベクトルの次元となるため 26 個あり、中間層のノード数は 5 つ、出力層のノードは 1 つである。中間層のノード数は、識別精度に関係しており試行錯誤的に決定される。本研究では、基本的な ASR 画像に対する識別解析を行い、解の収束性や計算時間などを考慮してノード数を 5 と設定した。NN では、入力層および中間層で出力される値に対し、結合強さ（重み）を掛け合わせ、次層への入力値としている。また各ノードでは、入力値に対しある閾値を定め、その閾値を超えた場合のみ 1 を出力させている。本研究では、入出力を規定する関数として、以下の式(2)に示すシグモイド関数 f を用いる。

$$f(u) = \frac{1}{1 + \exp(-\theta u)}
 \tag{2}$$

ただし、 u を入力値、 θ を閾値とする。以上の結合強さおよび閾値が NN の識別能力を決定することになる。教師付き NN では、教師信号と呼ばれる特徴ベクトルと正解の組み合わせに対し、誤差が最小となるようこれらのパラメータを決定する。本研究では、誤差最小とする最適手法として、学習誤差逆伝播法を用いる。この手法は、パラメータの修正を出力層側から入力層側へ遡って行うもので、バックプロパゲーション手法とも呼ばれる。最適化では適切な学習率を設定して、収束計算を行う。以上の手順により収束したパラメータにより、他の識別

組み合わせを解くことになる。

本研究の場合、教師データの出力値として、ASR である場合 0 を、ASR でない場合 1 を与えている。また NN での出力層のノードは 1 つであり、出力値は 0 から 1 の間の数値を取る。そのため、本研究では 0.5 を閾値として、0.5 以上のものを非 ASR、0.5 未満のものを ASR と判断させる。また結合強さの初期値については、多次元のベクトルとして表現されるため、その成分を乱数で与え大きさを 1 として正規化する。

(2) AdaBoost による NN の増強

一般に NN の問題点として、局所解に陥りやすいという点が挙げられる。特に中間層の層数が増えるとこの傾向が強くなり、結合強さの初期値や学習速度の設定に応じて局所解が得られやすくなる。そのため NN は弱学習機械と呼ばれるが、このような欠点を回避する有力な手段に Boosting がある。Boosting (増強) とは、選択的に重要な例題を学習することで、精度の高い学習機械を構成する手法である。本研究では、代表的な Boosting 手法である AdaBoost を用い、NN を増強させる。この手法では、複数の学習機械に対し誤答率の高い例題を重点的に学習させ、学習機械の信頼度を決定する。最終的に各学習機械の回答に信頼度で重み付けを行い、多数決により解を決定する。いま、教師データを $\{(x_i, d_i)\} (i=1 \sim N)$ 、 t 回目の学習 (機械) におけるデータ i に対する重みを $D_t(i)$ とする。初期値 $t=0$ では、重みを均一に $1/N$ とする。次に $t=1 \sim T$ に対し、以下のステップを繰り返す。

1) NN を試行的に構成し、次の式(3)で表される条件を満たす学習機械 f_t を決定する。

$$\varepsilon_t = \sum_{i=1}^N D_t(i) |f_t(x_i) - d_i| < 0.5 \quad (3)$$

ここで ε_t は誤答率と呼ばれる。また絶対値の項については、正解なら 0 を、誤答なら 1 を返す。

2) 次に誤答率を用いて、以下の式(4)のように学習機械の信頼度 α_t を定義する。

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_t}{\varepsilon_t} \right) \quad (4)$$

さらに信頼度を用いて重み $D_t(i)$ を更新する

$$D_{t+1}(i) = \frac{D_t(i) \exp(-\alpha_t d_i f_t(x_i))}{\sum_{i=1}^N D_t(i) \exp(-\alpha_t d_i f_t(x_i))} \quad (5)$$

3) 最終的な学習機械の構成 H は、生成したすべての学習機械 $t(0 \sim T)$ を信頼度で重み付けし、多数決で判断する。すなわち、以下の式(6)のように表現できる。

$$H(x) = \text{sign} \left(\sum_{i=1}^T \alpha_i f_i(x) \right) \quad (6)$$

以上のプロセスを繰り返し、教師データによる誤答率がある閾値を下回った段階で終了する。また最終的な回

答として、ASR である場合 0 を返し、ASR でない場合 1 を返すものとする。

(3) サポートベクターマシン (SVM)

サポートベクターマシンは、二クラスの分類問題を解く学習機械である。そもそも SVM は線形の識別器であるが、カーネルトリックと呼ばれる変換により、非線形問題を線形問題に変換し、複雑な分類を可能にしている。ここで線形分類とは、図-2 に示すような空間において、線形関数によりサンプルのクラス (二値) を分ける場合をいう。

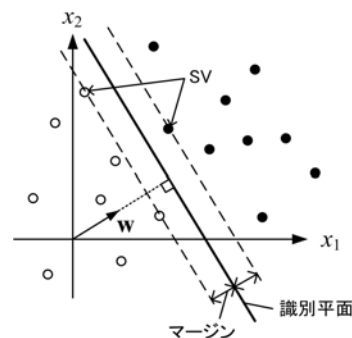


図-2 線形識別問題

図の例は、二変数 (x_1, x_2) の場合であるが、本研究の特徴ベクトルのように多次元の場合、識別面は超平面となる。いま、識別器を f 、パラメータを w, b (NN での重みと閾値) とすれば、

$$f(x) = \text{sign}(w^T x + b) \quad (7)$$

と表現できる。線形分離可能な場合、各サンプル (x_i, y_i) に対して、次の式(8)で表される制約条件を満たす w, b が存在することを意味する。

$$y_i (w^T x_i + b) \geq 1 \quad (8)$$

この条件下で、識別平面と最も識別平面に近いサンプルとの距離 (マージン) を最小することが、識別問題を解くことと同値となる。この問題は、ラグランジュ乗数 λ を導入した最小化問題となり、次の式(9)で表される関係が得られる。

$$w = \sum_{i=1}^N \lambda_i y_i x_i \quad (9)$$

しかし一般的な分類問題では、厳密に線形関数で分類できないことも多い。そのため SVM では、場合により識別面とサンプルとの境界条件である式(9)の右辺に対しパラメータ ξ_i を導入し、マージンを緩和 (ソフトマージン) することで様々な問題に柔軟に対応している。また境界に存在するサンプルは、識別の可否を決定するものであり、サポートベクターと呼ばれる。

次に、非線形関数により特徴ベクトル空間を非線形空間へ変換する。いま、変換を行う非線形関数 Φ を式(10)のように定義する。

$$\Phi(\mathbf{x}) = (\varphi_1(\mathbf{x}), \varphi_2(\mathbf{x}), \dots, \varphi_N(\mathbf{x}))^T \quad (10)$$

このベクトルを新たな入力ベクトルとして識別器に代入すると、

$$\begin{aligned} f(\mathbf{x}) &= \text{sign}(\mathbf{w}^T \Phi(\mathbf{x}) + b) \\ &= \text{sign}\left(\sum_{i=1}^N \lambda_i y_i \Phi^T(\mathbf{x}_i) \Phi(\mathbf{x}) + b\right) \\ &= \text{sign}\left(\sum_{i=1}^N \lambda_i y_i K(\mathbf{x}_i, \mathbf{x}) + b\right) \end{aligned} \quad (11)$$

となる。このときカーネル K を以下の式(12)のように定義している。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \Phi^T(\mathbf{x}_i) \Phi(\mathbf{x}_j) \quad (12)$$

本研究では、カーネルとしてガウス関数

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right) \quad (13)$$

を導入する。またここでの分散は初期値として 0.5 を与える。また研究ではマージンの緩和を行っていない。以上のように SVM では、複雑な境界面を非線形空間で表現するが、座標変換に用いる非線形関数 Φ を直接計算するのではなく、カーネルを計算するため、演算が非常に効率的となっている。

3. 入力データ

3.1 入力画像の前処理

本研究では、ひび割れをトレースした画像を入力として用いて検証を行う。本研究では、ひび割れのデジタル画像である原画像を 32 枚用意した。このうち 17 枚は ASR によるひび割れの画像 (ASR 画像)、残り 15 枚は ASR 以外の要因によるひび割れの画像 (非 ASR 画像) である。ただし、ASR の有無に関する判断は、現場技術者の判断による。これらの画像の縮尺は不明で、そのばらつきも大きい。よって、画像の縮尺を 1 ピクセルあたり約 0.2mm~1mm 程度に補正した。このようにして作成されたひび割れ画像に対して、人間の手作業でトレースを行い、ひび割れのトレース画を作成した。すなわちひび割れ画像に対して、明らかにひび割れと思われる箇所を、作業者の判断により 1 ピクセル幅の線でなぞる形式で作成した。ただし、元画像のひび割れ幅については考慮せず、ひび割れの形状のみに着目している。

以上の条件によって作られたトレース画データの一例を図-3 に示す。また事前検討として、これらのトレース画に対し、フラクタル次元を含まない特徴ベクトルを作成し、前述の NN による識別実験を数回試行した。その結果、機械学習による誤認識の頻度が高いデータが 4 枚含まれていることがわかった。その内訳は、ASR 画像が 1 枚、非 ASR 画像が 3 枚である。また入手できる画

像が限られていたため、画像の寸法 (縦横比) について統一化は行っていない。また画像を回転して識別を行った場合でも、ほぼ同一の結果が得られていることを確認している。またひび割れ密度の多い箇所を集中的に切り出した場合、ASR と判断されやすいことも確認している。

3.2 教師データ

初期のデータセットとして、判定が容易である 28 枚の画像から、ASR 画像と非 ASR 画像を各 5 枚ずつ用意し、学習のための教師データとする。さらに、判定が難しいと思われる 4 枚のうち、非 ASR 画像 1 枚を教師データとする。すなわち、判定が困難である 3 枚を含む 21 枚をシステム検証用の判定データとする。初期のデータセット一覧を表-1 に示す。ただし、教師データの影響を検討するため、検証データに含まれる判定が困難なデータを教師データに含めた場合や、特定のデータ以外のすべてものを教師データとした場合についても検討を行っている。

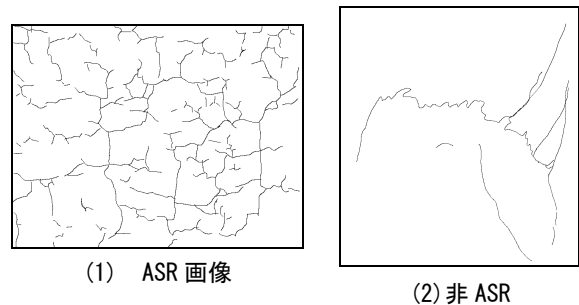


図-3 トレース画

表-1 データセット一覧 (初期)

種別	教師データ 11 枚	検証データ 21 枚
ASR 17 枚 A シリーズ	易 5 枚 難 なし	易 11 枚 難 1 枚
非 ASR 15 枚 N シリーズ	易 5 枚 難 1 枚	易 7 枚 難 2 枚

4. システムの検証

4.1 フラクタル次元の影響

ここでは、フラクタル次元の効果を確認するために、特徴ベクトルの成分としてフラクタル次元を含む場合と含まない場合について、通常の NN による識別を行った。これらの識別率を表-2 に示す。ここで識別率とは、識別対象とする画像数に対する識別に成功した画像数の割合である。表より、フラクタル次元を成分として含む場合、識別率が上がっていることがわかる。ただし、いずれの場合も識別が困難なサンプルについては誤認識している。よって以下での検討では、特徴ベクトルとして常にフラクタル次元を含むものとする。

表-2 フラクタル次元の有無による識別率

フラクタル次元	識別率
有	90.5%
無	85.7%

4.2 システムの検証

(1) 初期の教師データセットによる識別

初期設定時の教師データによる識別について、それぞれのアルゴリズムで推定した結果を表-3 に示す。表より、すべてのアルゴリズムにおいて、概ね良好な結果が得られていることがわかる。

表-3 識別率（初期の教師データセット）


Algorithm	NN1	NN2	NN3	Ada.	SVM
識別率 %	95.2	90.5	90.5	90.5	95.2

ただし NN では、収束条件の閾値として 0.1, また学習率として 0.01 を設定した。表中 NN の推定値として NN1 ~ NN3 まで示してあるが、これは結合強さの初期値の違いにより推定結果が異なっていることを意味している。また初期値の与え方によっては、解が収束せず発散した。本研究では、結合強さの初期値はベクトル成分として乱数で与えているため、初期値を直接的に改善することができない。そのため複数回の試行を通じて、広く初期値を呼び出し適切な解を判断する必要がある。AdaBoost (表中 Ada.) では、以上の条件で構成された NN を弱学習機械とした。ただし、NN の呼び出し方によらず同一の識別率が得られているため、AdaBoost による結果は一つのみを示している。さらに SVM で使用されるガウス関数の分散については、0.5 の値を設定した。

NN について、識別率は 95.2%~90.5% となっている。誤認識した具体例を見ると、事前検討時に NN で判定が困難とされていたサンプル A-1 および N-1 を誤認識していた (図-4)。A-1 の特徴として、ひび割れ密度に偏りがあることが挙げられ、判定を困難にしている一因と考えられる。この点については別途検討を行う。また N-1 に関しては、斜め方向にひび割れが伸びている形状であり、ピクセル形状としてより複雑なものとして認識されやすいといえる。次に AdaBoost による結果について、NN を弱学習機械として利用しているため、試行 (結合強さ初期値の設定の違い) によって解が発散する場合があった。しかし解が収束した場合、認識率として 90.5% が得られている。AdaBoost の場合も NN 同様、A-1 および N-1 を誤認識している。最後に SVM による結果では、安定した認識率 95.2% が得られている。しかし、分散の設定によっては誤認識が増加することもある上、A-1 について誤認識している。以上の検討結果では、SVM が最も安定した結果を示すことがわかった。



(1) A-1 (ASR)



(2) N-1 (非 ASR)

図-4 判定が困難なトレース画像

しかし、いずれのアルゴリズムでも、A-1 については誤認識している。A-1 についての誤認識は、「ASR」であるものを「非 ASR」であると判断することであり、「危険側の誤認識」である。システムの信頼性を確保するためには、危険側の誤認識は避けるべきである。しかし初期検討時の教師データのセットでは、AdaBoost による NN の増強や SVM を用いても改善することができなかった。よって以下では、A-1 の認識に焦点を当て、更新した教師データによる検討を行う。

(2) 更新した教師データセットによる識別

次に、教師データとして判定の困難なデータを多く含めたケースについて検討を行う。ただし、問題となる A-1 については、常に検証側に入れるものとする。Case1 は上述 N-1 のデータを教師データとして含んだ場合、Case2 は A-1 以外のデータすべてを教師データとした場合である。ただし Case2 については、A-1 の判定についてのみ検討している。この場合の結果を表-4 に示す。

表-4 識別率（更新した教師データセット）

Algorithm	NN1	NN2	Ada.1	Ada.2	SVM
Case 1 識別率 %	95.2	100	76.2	100	95.2
Case2 識別率* %	0	100	100	-	100**

* : A-1 の判定, ** : 分散を 0.1 と設定した場合

Case1 において、NN の判定として 100% の識別が行えている場合がある。しかし初期値により A-1 の判定を誤る場合も確認された。さらに AdaBoost では、NN の呼び出し方 (初期値の設定) によって識別率が異なった (表中 Ada.1, Ada.2)。すなわち、AdaBoost では 100% の識別が行える場合もあるが、呼び出し方によっては識別率が 76.2% に低下する場合があることが確認された。また SVM についても A-1 の識別が適切に行えていない。以上より、教師データとして非 ASR データを増加させた場合、NN や AdaBoost において 100% の識別率を達成できる場合もあるが、初期値によって発散や誤認識する可能性もあることが分かった。

次に、A-1 以外を全て教師データとした Case2 において、NN では初期値によって A-1 を誤認識する場合が確認された。しかし AdaBoost では、複数回の試行でも安定して正しい認識が行われていた。また SVM について、カーネル関数の分散を 0.5 と設定した場合では、正しく判定が行われなかった。しかし分散を 0.1 と設定した場合、常に正しい判定が行えることを確認した。これは、SVM において関数の分散によって境界面が変化することを意味し、正しい認識のためには適切な分散の設定が必要であることを示唆している。

以上より、A-1 の識別問題において教師データを増やした場合、AdaBoost および SVM を用いれば、常に正しい判断が行われることが明らかとなった。

5. 結論

コンクリート構造物のひび割れパターンから、劣化要因が ASR であるかを判定するシステムを構築し、いくつかのアルゴリズムにより同定精度を検証した。その結果、以下の知見が得られた。

- (1) 初期の教師データセットにおいて、識別アルゴリズムとして、NN、AdaBoost により増強された NN、および SVM を用いた結果、すべてのアルゴリズムで概ね良好な結果が得られた。ただし通常の NN では、結合強さの初期値の違いにより解が変化し、発散する場合や局所解に陥ることが確認された。そのため、複数回の試行を通じて適切な解を判断する必要がある。またいずれの手法でも、あるデータに対して危険側の誤認識を行っており、アルゴリズムの改善ではこの誤認識を解消できなかった。
- (2) 危険側の誤認識が生じるデータについて、教師データの数を増やすことで、AdaBoost および SVM のアルゴリズムで正しい認識が行えることが明らかとなった。よって、システムの信頼性向上のためには、適切なアルゴリズムの選択と多くの教師データが必要であることがわかった。

本検討では、検証するデータ総数が少ないため、検討精度に限界があった。今後、教師データや検討データの数を増やし、検討を行っていく予定である。また本研究において、ASR 損傷に関して良好な識別結果が得られたので、引き続き他の損傷要因に関しても識別が行えるシステムを構築していく予定である。

謝辞

鹿島建設の三浦悟氏には、ひび割れ画像処理に関して有益なアドバイスを頂いた。ここに記して謝意を表す。

参考文献

- 1) 金田尚志, 魚本健人: コンクリート構造物の劣化診断プログラムの開発(1), 生産研究 55 巻 4 号, pp389-392, 2003
- 2) 楠瀬芳之ほか: パターン認識手法を用いた床版のひびわれ形状の抽出と分類に関する研究, 土木学会第 58 回年次学術講演会, CS5-009, 2003
- 3) 王鉄成ほか: ASR によるコンクリートの膨張におよぼすアルカリ量の影響, コンクリート工学年次論文報告集, Vol.16, No.1, pp.1067-1072, 1994
- 4) 西林新蔵ほか: コンクリートの ASR ひび割れに対するフラクタル解析と評価, コンクリート工学年次論文報告集, Vol.15, No.1, pp.911-916, 1992
- 5) 武田均, 堀口賢一, 小山哲, 丸屋剛: ウェーブレット変換を用いたコンクリートのひび割れ画像解析手法の開発, コンクリート工学年次論文集, Vol.28, No.1, pp1895-1900, 2006
- 6) 河村圭, 宮本文穂, 中村秀明, 佐藤亮: 対話型遺伝的アルゴリズムによるデジタル画像からのひび割れ抽出, 土木学会論文集 No.742/VI-60, pp115-131, 2003
- 7) 麻生英樹ほか: パターン認識と学習の統計学, 岩波書店, 2003
- 8) Richard O. Duda et al.: Pattern Classification, Wiley, 2001
- 9) 久保正明, ザヘル・アグバリ, 牧之内顕文: ウェーブレットと SOM を用いたエッジ抽出による類似画像検索システムの開発, 第 13 回データ工学ワークショップ (DEWS 2002) B1-3, 2002
- 10) 福井佳紀, 小西修: 画像クラスタリングによる類似検索システム, DEWS2002, B1-4-8, 2002
- 11) 作田健, 香月智, 坊原尚記: PSO と BP 学習則併用型複関数分類学習ニューラルネットワークによるコンクリート材料の損傷検出法, 土木学会論文集 F Vol.62 No.4, pp567-580, 2006
- 12) 林伸治, 長谷川修: 低解像度画像からの顔検出, 画像電子学会誌, Vo.34, No.6, pp.726-737, 2005
- 13) 三宅信之, 滝口哲也, 有木康雄: Multi-class AdaBoost を用いた雑音検出, 第 8 回音声言語シンポジウム, SIG-SLP64, pp.7-12, 2006
- 14) Nello Cristianini and John Shawe-Taylor: An introduction to Support Vector Machines and other kernel-based learning methods, Cambridge University Press, 2000