

橋梁損傷度判定における複合特徴選択のための アンサンブルシステムの構築

An Ensemble System for Multiple Feature Selection
in Damage Judgment of Bridge

中津功一郎*・野村泰稔**・古田均***・足立渉****・服部洋†

Koichiro Nakatsu, Hitoshi Furuta, Yasutoshi Nomura, Wataru Adachi and Hiroshi Hattori

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

**正会員 博士(情報学) 立命館大学助教 理工学部 (〒 525-8577 滋賀県草津市野路東 1-1-1)

***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)

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

†正会員 博士(情報学) 京都大学助教 工学部 (〒 615-8530 京都府京都市西京区京都大学桂)

Recently, it has become more and more important to establish a rational maintenance program for infrastructures. In bridge structures, concrete slabs are suffering from damage, because they directly resist applied loads. In this study, an attempt is made to develop a new damage detection method for concrete slabs with cracks, by using pattern recognition techniques. In the pattern recognition, the feature extraction is a quite important process, because the recognition rate depends on the characteristic of the recognition object. However, it is not easy to find out appropriate features to improve the recognition rate. The proposed method can select efficient features among various features by introducing fuzzy ensemble learning method with classifiers consisting of many feature vectors. Numerical examples are presented to demonstrate the efficiency and applicability of the proposed method.

Key Words : damage detection, feature selection, fuzzy ensemble learning, neural network, 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⁾。近年、既設のコンクリート構造物の劣化の進展に伴い、その維持管理をいかに効率的かつ適切に行うかが重要な課題となってきた^{2),3),4)}。長期的な視野でライフサイクルコスト最小化を目指した社会基盤施設の維持管理を実現するためには、高度な技術を要する破壊・非破壊検査法を実施する前段階の日常点検の精度改善および効率化を図ることは重要な検討課題の一つとして位置付けられる。したがって、本研究では日常点検の中でも目視点検に着目し、検討を行った。

橋梁のコンクリート床版を対象にした目視点検では、コンクリートの表面に顕在化したひび割れなどの損傷要因に関する視覚的な情報から、専門家が床版内部の健全性を評価する。しかし、専門家の長年の経験により裏付けられた評価であるため、今後想定される診断対象の増大と経験豊富な専門技術者不足といった問題への対応が急務である。そのため、目視点検により、コンクリート構造物の表面的な健全性を的確に評価し、さらに詳細な調査を必要とする対象物の特定を実現する評価システムの構築は極めて重要であると考えられる。

本研究ではこのような状況を踏まえ、橋梁の床版におけるひび割れを対象に、経験豊富な専門家が実際に目視点検に基づき健全性を評価した事例をもとに、橋梁の損傷度判定を支援するシステムの構築を試みる。現在、橋梁の損傷度判定において、橋梁のひび割れを有するデジタル画像から得られる特徴をもとに、ニューラルネットワーク等のパターン認識手法により学習・認識を行うシステムの開発が進められている。橋梁診断の専門家不足を補い、専門家による診断の差異・見過ごしを低減することに対して有効であると考えられ、精度の改善が期待されている。

しかし、ひび割れ画像から得られる特徴量としてはひび割れ幅、ひび割れ長さ、ひび割れ密度といったように様々なものが考えられ、認識の際に用いる特徴によっては認識結果が大きく異なる。そのため、橋梁の損傷度判定において、認識に用いる特徴を選択することは、認識性能を左右する極めて重要な処理となる。また、考えられる全ての特徴を用いて認識を行うことも考えられるが、各特徴が持つ特性を損なう可能性がある。

そこで本研究では、ひび割れ幅、ひび割れ長さ、ひび割れ密度などの異なる特徴ベクトルを用いて複数の識別器を構築し、ファジィアンサンブル学習手法⁵⁾を用いた提案手法により、効果的な特徴の選択を自動で行うシステムを構築する。また、対象から得られる特

徴により、精度の高いアルゴリズムが異なるため、本研究ではファジィ推論^{6),7)}を用いた識別器とニューラルネットワーク⁸⁾を用いた識別器をシステムへ取り入れる。これにより、特徴ベクトルの特性に基いた効果的な識別器の構築を試みる。特徴別、手法別に識別器を構築し、提案手法を用いてより効果的な識別器を選択することで、認識性能の向上を実現する。

2. パターン認識の課題

2.1 特徴抽出

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⁹⁾。このパターン認識を行う処理の中で重要となるのが、膨大な情報を持つ原パターンから識別に必要な本質的な特徴を抽出することである。パターン認識の中でも、特徴抽出は認識性能を左右する極めて重要な処理と言える。しかし、有効な特徴を抽出するための系統的な手段は現状では存在しない。そのため、効果的かつ安定性のある特徴を設計者が探し出すことが必要となる。パターン認識では、この特徴抽出が性能の大半を決定付ける重要な処理であるにもかかわらず、認識対象に依存してしまうため、統一的、一般的な特徴抽出法を実現することは難しく、その開発が望まれる。

橋梁の損傷度判定においても、この特徴抽出が認識性能を左右する重要な処理と言える。橋梁のひび割れ画像から特徴抽出を行う際、ひび割れ幅、ひび割れ長さ、ひび割れ密度といったように様々な特徴が考えられる。こういった考えられる全ての特徴を一度に用いて認識を行った場合、パターン認識における次元の呪い^{10),11)}という問題に直面することとなる。そのため、あまりに多くの特徴量を一度に考慮することは困難であり、最も効果的であると考えられる特徴を選び出すことが必要となる¹²⁾。しかし、数多く考えられる特徴量の中から最も効果的であると考えられる特徴を選び出すことは難しく、仮に選び出すことができたとしても、対象が複雑であるため、その特徴を用いた認識精度にも限界がある。例えば、ひび割れ幅でしか判定できない画像、ひび割れ長さでしか判定できない画像といったことが考えられるということである。

2.2 手法の選択

パターン認識には、既知の学習用のサンプル集合から特徴ベクトルとクラスとの対応関係を知識として学習することが必要である。この学習した特徴ベクトルとクラスとの対応関係に関する確率的知識を利用して、与えられた未知の認識対象の特徴ベクトルからその対象がどのクラスに属しているかを推定（決定）する方法が必要となる。しかし、こういったパターン認識の

課題として、認識対象のデータ数が少ない場合やデータにノイズが含まれる場合に、その認識精度を大きく低下させてしまうことが挙げられる。現在、様々な手法を用いてこのパターン認識における精度改善が行われているが、認識を行う対象や対象から得られる特徴と手法の組み合わせにより認識精度に違いがある。そのため、対象やその特徴に合わせて手法を選択し、識別方法を決定する必要がある。

本研究では、ファジィ推論とニューラルネットワークの2つの手法を用いて認識を行う。現在、ニューラルネットワークを用いたひび割れの損傷度判定システムの開発が進められている。しかし、ニューラルネットワークだけで全ての認識を行うことは困難であると考えられるため、ファジィ推論を用いた認識も行う。これは例えば、ニューラルネットワークによる認識率が80%で、ファジィ推論による認識率も80%であった場合にも、認識可能な事例が異なる可能性が考えられるためである。双方の20%の誤認識を補うことが可能となれば、100%認識できるシステムを構築することができる。そこで、2つの手法を用いて各識別器を構築し、特徴や入力に合った手法による識別器を自動的に選択することで認識性能の向上を試みる。

3. 提案手法

石渕らにより提案されたファジィアンサンブル学習手法⁵⁾では、ファジィ識別器とファジィアンサンプルの入力ベクトルが全て同一の特徴ベクトルとなる。本研究で扱うひび割れ画像からの損傷度判定では、ひび割れを反映する特徴を的確に抽出することが最も重要である。そのため、異なる特徴ベクトルを用いて特徴ごとに識別器を構築し、提案手法により効果的な特徴を用いた識別器の選択を自動で行う。その際、ファジィアンサンブルシステムの入力ベクトルは全ての特徴ベクトルとなる。以下で、ファジィアンサンブル学習手法を用いた提案手法について説明する。

3.1 特徴選択と識別器構築

2. で述べたように、パターン認識における特徴抽出は認識性能を左右する極めて重要な処理である。しかし、有効な特徴を抽出するための系統的な手段が存在しないのが現状である。ひび割れの損傷度判定においてもこの特徴抽出が重要な処理となっており、ひび割れ幅、ひび割れ長さ、ひび割れ密度といったような様々な特徴が考えられる。こういった様々な特徴の中から効果的なものを見出すことは難しく、また、全ての特徴を考慮し、これらの組み合わせを特徴ベクトルとして同時に入力する場合、学習データ数によっては次元の呪いを引き起こす可能性があり、必ずしも認識性能が向上するとは限らない。

そこで提案手法では、まず様々な特徴を抽出し、抽出した特徴ごとに識別器を構築する。そして、ファジィアンサンブルシステムによりその識別器の認識結果に信頼度を与える。これにより、どの特徴によって構築された識別器の認識結果を選択するかを決定する。つまり、設計者は特徴を限定する必要がなく、効果的であると考えられる特徴をいくつか抽出すれば、ファジィアンサンブルシステムによりその対象に合わせた特徴が選択される。

本研究では、さらに特徴の特性に基づく識別器構築を考える。パターン認識における最も基本的な課題が、未知の対象がどのクラスに属しているかを判定する識別方法を開発することである。石渕らによる手法では、ファジィ推論を用いたファジィ識別器⁵⁾のみで認識を行っている。しかし、識別器を構築する手法としては他にも考えられ、他の手法を用いることにより認識結果も異なってくる。そこで、パターン認識を行う対象や、対象から抽出する特徴によりどの手法を用いるかを効果的に決定する必要がある。つまり、対象や特徴の特性に基づく識別器構築を行う必要がある。そのため、提案手法ではファジィアンサンブルシステムの中にファジィ識別器とは別の手法で構築された識別器も組み込み、アンサンブルシステムにより自動的に選択する。本研究では、誤差逆伝播法を用いたニューラルネットワークによる識別器をシステムの中に組み込むこととした。

3.2 ファジィアンサンブル学習手法との比較

ファジィアンサンブル学習手法の概要を図-1に示す。手法の特徴としては、2種類のファジィシステムから構成されていることがあげられる。1つめは、入力パターンからクラスを提示するファジィ識別器である。2つめは、構築された各ファジィ識別器に重みを割り当てるファジィアンサンブルシステムである。この割り当てられた重みに基づいて、入力パターンに対する最終的なクラスの決定を行う。このアンサンブルシステムは、識別器への信頼度割り当ての方法に重点を置いている。そのため、学習器の構築法、特に学習用パターンの取り扱いに焦点をあてる Bagging 法や Boosting 法^{13),14)}とは違う形式でのアンサンブル学習である。

次に、提案手法の概要を図-2に示す。提案手法では、識別器構築方法に汎用性を持たせることで、より差別化された識別器が構築されることとなる。まず、特徴1, 2, 3というように特徴ごとに各識別器を構築する。そして、同じ特徴1を用いた識別器でもファジィ推論とニューラルネットワークの2つの手法を用いてそれぞれで識別器を構築する。これらの識別器1~4は単体でも識別器としての機能を持っている。しかし、対象によって認識結果に差異が生じるため、どの識別器を使用すればよいかを判断することは難しい。そこで、

特徴別、また手法別に構築された識別器をアンサンブルシステムに組み込むことでパターン認識の精度改善を行う。先述のように、ファジィアンサンブルシステムでは各識別器に対し信頼度を算出し、その信頼度を基に最終的な結果を決定する。そのために、提案手法では全ての特徴ベクトルを受け取り、それらを入力とする必要がある。そして、出力は各識別器に対する重みベクトルとなる。この重みベクトルを用いて、ファジィアンサンブルシステムの最終的な出力を求め、識別結果の決定を行う。本研究において提案するファジィアンサンブルシステムの最終的な出力は、最も重みベクトルの値が大きい識別器による識別結果を採用することとした。




図-1 ファジィアンサンブル学習手法




図-2 提案手法

3.3 ファジィアンサンブルシステムの構築

石渕らの手法では、ファジィアンサンブルシステムの入力はいくつかの識別器と同じパターンベクトルであり、出力は各識別器による識別結果に対する重みベクトルとなる。ただし、提案手法においては特徴別に識別器を構築し、ファジィアンサンブルシステムの入力はいくつかの識別器に用いた全ての特徴ベクトルとなる。ファジィアンサンブルシステムでは、以下の形式のファジィIf-Thenルールが用いられる。

$$\begin{aligned} \text{Rule } R_k : & \text{If } x_1 \text{ is } A_{k1} \text{ and } \dots \text{ and } x_n \text{ is } A_{kn} \\ & \text{then } \vec{w}_k = (w_{k1}, \dots, w_{kL}), \quad k = 1, 2, \dots, K \end{aligned} \quad (1)$$

L 個の識別器があるとする、 $\vec{w}_k = (w_{k1}, \dots, w_{kL})$ は、結論部の実数値ベクトルである。また、 K はファジィアンサンブルシステムにおけるファジィIf-Then

ルール数である。条件部ファジィ集合として、図-3のような0～1の区間を3分割に分割した三角型ファジィ集合を用いることとする。




図-3 ファジィ集合

教師データとしては、各識別器がどの学習用パターンに対して正しい識別を行ったかという情報を用いることとし、 $\vec{t}_p = (t_{p1}, t_{p2}, \dots, t_{pL})$ を教師ベクトルとする。P 番目の学習用パターン $\vec{x}_p$ に対する教師ベクトル $\vec{t}_p$ の各要素は、以下の式で決定される。

$$t_{pl} = \begin{cases} 1, l \text{ 番目の識別器が} \\ \text{学習用パターン } \vec{x}_p \text{ を} \\ \text{正しく識別するとき} \\ 0, \text{ それ以外のとき} \end{cases} \quad l = 1, 2, \dots, L \quad (2)$$

次に、ファジィ If-Then ルール R_k の結論部重みベクトル $\vec{w}_k$ の決定方法を示す。まず、次のように $\beta_l(R_k) (l = 1, 2, \dots, L)$ を計算する。

$$\beta_l(R_k) = \sum_{p=1}^m t_{pl} \cdot \mu_{k1}(x_{p1}) \cdot \dots \cdot \mu_{kn}(x_{pn}), \quad l = 1, 2, \dots, L \quad (3)$$

ここで、 $\mu_{kj}(\cdot), j = 1, 2, \dots, n$ は、条件部ファジィ集合 A_{kj} のメンバシップ関数である。k 番目のファジィ If-Then ルールにおける結論部重みベクトル $\vec{w}_k$ の l 番目の要素 w_{kl} を以下のように決定する。

$$w_{kl} = \frac{\beta_l(R_k)}{\sum_{q=1}^L \beta_q(R_k)}, \quad l = 1, 2, \dots, L \quad (4)$$

実数値ベクトル $\vec{W} = (W_1, W_2, \dots, W_L)$ を L 個の識別器に対する信頼度の割合を表わす信頼度ベクトルとすると、ファジィアンサンプルシステムは、入力パターン $\vec{x}$ から $\vec{W}$ を計算し、各識別器への信頼度を求めるものである。入力パターン $\vec{x}$ のファジィ If-Then ルール R_k に対する適合度は、式 (5) のように計算される。そして、信頼度ベクトルの l 番目の要素 W_l を式 (6)

で決定する。

$$\alpha_k(\vec{x}) = \mu_{k1}(x_1) \cdot \dots \cdot \mu_{kn}(x_n) \quad (5)$$

$$W_l = \frac{\sum_{k=1}^K \alpha_k(\vec{x}) \cdot w_{kl}}{\sum_{k=1}^K \alpha_k(\vec{x})}, \quad l = 1, 2, \dots, L \quad (6)$$

最終的な識別の決定では、識別器が識別したクラスとファジィアンサンプルシステムによって算出された信頼度ベクトル $\vec{W}$ を用いて、入力パターンに対する識別結果を決定する。ここで、入力パターンからの最終的な識別結果の決定に対して、さまざまな方法が考えられる。本研究では、最終的な識別結果として最大の信頼度の要素 W_l を持つ識別器による識別結果を採用する手法を用いる。したがって、ファジィアンサンプルシステムからの信頼度ベクトル $\vec{W}$ の要素 $W_l, l = 1, 2, \dots, L$ を求め、最も信頼度の高い識別器によって識別された結果を最終的なシステムの出力とする。

4. 橋梁の損傷度判定

本研究では、構造物の健全性評価の自動化を目的として、ひび割れを有するコンクリート床版のデジタル画像から橋梁の損傷度判定を行う。その際、特徴別、手法別に識別器を構築し、提案手法によりその識別器の選択を行うことで、より認識精度の高いシステムの構築を実現する。

4.1 前処理

現在、デジタル画像をニューラルネットワークにより学習・認識を行う手法が広く用いられており、橋梁の損傷度判定においても応用されている。これは、デジタル画像により学習を行うことで、見落としのミスを低減することが見込まれるためである。また、デジタルカメラの普及により手軽に判定用デジタル画像を収集することができるため、今後の維持管理のための情報として蓄積も容易となり、効率的に診断を行うことが可能となる。しかし、判定に用いる特徴により認識結果に差異が生じるため、特徴選択が困難であるという問題がある。

以上のことから本研究では、市販のデジタルカメラの画像を用いて提案手法により特徴を選択することで、認識精度を改善するシステムを構築する。デジタル画像は阪神高速道路株式会社から提供された、床版部分にひび割れによる損傷を含む46枚の画像(図-4)を使用した。ただし、床版観測時にホワイトチョークにより、ひび割れ領域のトレースが行われている。デジタル画像は照明の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、ひび割れだけをうまく抽出できず、認識させることは難しい。そのため、ひび割れの特徴抽出においては、検出ソフ

トを用いてひび割れ箇所を検出し、2 値化処理¹⁵⁾を施した画像（図-5）を利用することとした。



図-4 デジタル画像




図-5 2 値化画像

4.2 特徴抽出

本研究では、予め専門家が判定基準¹⁶⁾に基づいて A(早急に補修)、B(状況に応じて補修)、C(損傷軽微)の3つのランクに判定したデジタルカメラによるひび割れ画像を用いて、ファジィアンサンブル学習手法を用いた提案手法により損傷度ランクを判定するシステムを構築する。ひび割れ画像の特徴抽出は、2 値化処理を施した画像から行う。ただし、元の画像データは 1782×1220 ピクセルとサイズが大きく、識別器構築のための学習に非常に多くの時間がかかってしまうため、2 値化した画像を 50×50 ピクセルのサイズに圧縮した。今回用いる特徴は、ひび割れの密度（図-6）と画像を十字に分割した領域ごとのひび割れの平均・分散（図-7）とした。

密度では、画像の左上から黒色マスを探索し、黒色マスを中心として 7×7 の四角形を作成する。この四角形内に属する黒色マスの数を保存し、画像の右下に至るまで処理を繰り返す。この情報を用いて、四角形

内に属していた黒色マスの数の最大値と、四角形内にある黒色マスの数の合計値の2つを密度に関する入力とする。また、平均・分散では、画像の特徴のバリエーションを豊富にするために、画像全体におけるひび割れの平均・分散ではなく、画像を十字に分割した各領域ごとの黒色マスの数の平均と分散を算出し、それらを入力とした。そのため、平均で4入力、分散で4入力となりそれらを合わせた8つを平均・分散の入力とする。




図-6 密度（ひび割れ）




図-7 平均・分散（十字分割）

4.3 システム構築

今回は、密度と平均・分散の2つの特徴を用いてそれぞれ識別器を構築し、さらに特徴の中でもファジィ推論と誤差逆伝播法を用いたニューラルネットワークの2つの手法を用いて識別器構築を行った。ファジィ推論では、メンバシップ関数を三角形型に2~4分割したファジィ集合を用いて3つの識別器を構築した。ニューラルネットワークは3層構造とし、各層のニューロンの数として入力層は密度で2、平均・分散で8、中間層は共に50、出力層は共に3とした。識別器の数は合計8個となり、ファジィアンサンブルシステムの出力は8となる。今回は三角形型に3分割したファジィ集合を用いてファジィアンサンブルシステムを構築した。特徴として密度を用いた識別器では2入力、平均・分散を用いた識別器では8入力となり、ファジィアンサンブルシステムへの入力はその全てを入力とするため10入力となる。各識別器の出力は3出力となるが、ファジィアンサンブルシステムの出力は識別器の数となる。

各識別器の学習に関して、ひび割れ画像46枚の中から、損傷度がA、B、Cの画像それぞれ3枚ずつ計9枚を学習のためのデータとし、残り37枚の画像を未知データとして推論を行った。ただし、アンサンブルシステムに汎化能力を持たせるため、9枚の学習データに対してCross-validation手法¹⁷⁾を適用した。各識別器は8枚の学習データで学習を行い、残りの1枚で推論を行うという処理をパターンを入れ替えて9回行った。これによる結果を、ファジィアンサンブルシステムに与える各識別器の教師データとして用いた。

4.4 識別結果

表-1に各識別器の未知データに対する認識率と提案手法による結果について示す。

表-1 識別結果

Each classifier	Density (Cracks)				Average-Variance (Cross division)			
	F2	F3	F4	NN	F2	F3	F4	NN
Recognition rate	70%	59%	81%	81%	78%	73%	59%	59%
Result of proposed method using the above classifiers								
Recognition rate	92%							

F2: Fuzzy classifier (2 division Membership function)
F3: Fuzzy classifier (3 division Membership function)
F4: Fuzzy classifier (4 division Membership function)
NN: Neural network classifier

識別器単体で最も認識率が高かったのは81%で、密度を用いた4分割ファジィとニューラルネットワークの2つの識別器が同等であった。これらを含む8つの識別器の結果を比較すると、同じ手法を用いた識別器でも、特徴の違いにより大きく認識率に違いがあることが確認できる。また、同じ特徴の中でも手法により

認識率に差があることも確認できる。提案手法ではこれら8つの識別器を基に識別を行い、92%という高い認識率を得ることができた。実際に提案手法で推論を行う際は、単体で認識率の高かった上位3つの識別器の識別結果を採用することが多かった。これは、3つの識別器の認識率はそれほど変わらないが、得意とする対象がそれぞれ異なるため、それらを組み合わせることにより認識率の改善を行うことができたと考えられる。また、本研究のデータでは、3つの識別器に採用が偏ったが、ファジィアンサンブルを用いることにより、特徴が適切に選択された結果と考えられる。

4.5 各識別器の特性




図-8 損傷度 A の一例




図-9 損傷度 B の一例

認識に使ったひび割れ画像の一例を図-8、図-9に示す。図-8、9を見ると、診断に使用する特徴を誤れば、誤診断をしてしまうことが考えられる。しかし、本研究では、ファジィアンサンブルを用いて、各識別器の特性を活かし、診断を行う事で、高い識別結果を得ることができた。以下に、詳細な考察をする。

表-2に、各識別器の認識結果の詳細を示し、各識別器の特性について考察する。表-2は、各識別器がどの

表-2 各識別器の識別結果

Density(Cracks)				Average Variance (Cross division)				FE	Image number	Damage level
F2	F3	F4	NN	F2	F3	F4	NN			
			FE						1	Damage level A
			FE						2	
FE									3	
			FE						4	
			FE						5	
			FE						6	Damage level B
			FE						7	
			FE						8	
			FE						9	
			FE						10	
			FE						11	
			FE						12	
			FE						13	
			FE						14	
			FE						15	
			FE						16	
				FE					17	Damage level C
				FE					18	
		FE							19	
			FE						20	
				FE					21	
				FE					22	
				FE					23	
				FE					24	
				FE					25	
		FE							26	
		FE							27	
				FE					28	
				FE					29	
				FE					30	
				FE					31	
				FE					32	
				FE					33	
				FE					34	
				FE					35	
			FE						36	
			FE						37	

FE: Fuzzy ensemble system

画像を認識し、どの画像を誤認識したのかということを示している。この表の中で、白色マスが認識、灰色マスが誤認識、FEと表記されているマスは提案手法で識別に採用された識別器である。まず、識別器単体で見えていくと、どの識別器も必ず7個以上の誤認識があることが分かる。しかし、画像番号ごとに表を見ていくと、どの画像も必ず認識している識別器がある。これは、識別器の組み合わせによっては、誤認識がなくなる可能性を示している。提案手法では誤認識のデータをなくすことはできなかったが、3個にまで減らすことができた。

次に、各画像ごとに提案手法により選択した識別器の結果について考察する。損傷度Aと損傷度Bの画像1～16であるが、この画像の中で最も認識精度が高いのは特徴に密度を用いたニューラルネットワークの識別器である。そのため、提案手法においてもほぼその識別器の結果を採用している。損傷度Cの画像17～37では、密度を用いてメンバシップ関数を2分割したファジィ識別器の認識精度が高い。しかし、提案手法ではこの識別器の結果を採用していない。これは、この識別器が実際は損傷度Aか損傷度Cの判別しかできておらず、全体としての認識率が悪いためであると考えられる。そのため、損傷度Cの画像の中で次に認識

精度が高い平均・分散の特徴を用いたファジィ識別器の結果が主に採用されている。この範囲は誤認識が2個あるが、画像番号20に関しては画像1～16の範囲の誤認識と同様に、高い認識率の識別器の結果を採用したことにより、誤認識を回避できなかったためと考えられる。残りの1個は、画像番号26であるが、これは密度を用いたファジィ識別器の結果を採用している。この識別器は8つの識別器の中で最も認識精度が高かった識別器であり、その識別器の結果を採用することで安定的な答えを導き出そうとしたためだと考えられる。また、学習データが少なかったということも、誤認識に繋がった一要因であると考えられる。

表-2から、密度と平均・分散の2つの特徴によって認識できる画像が異なること、また、メンバシップ関数の分割数が異なるファジィ識別器とニューラルネットワークによる識別器を用いることによって認識できる画像が異なることを確認できた。そして提案手法では、異なる特徴と手法によって構築した識別器を各画像に対して効果的に選択することができた。

その結果、単体で最も認識率の高い識別器の結果よりも約10%も認識率を改善することができた。

また、学習機を選択において、ひとつの学習機だけに偏らず、複数の学習機を入力データにより選択していることが分かる。これは、入力データに応じて、どの特徴を選択するべきかを提案手法により可能としていることになる。デジカメなどの写真によるデジタルデータは距離や光の入射角など一定にするのは難しく、診断する写真によって診断し易い特徴が異なる。しかし、既存の方法では、精度が高いであろう特徴と学習機を特定し用いるために精度の向上に限界があった。本手法では、診断する写真、つまり入力データ毎に診断に用いる特徴と学習機を選択するために、大幅な改善が見られたと考えられる。

5. おわりに

本研究では、ひび割れを有するコンクリート床版のデジタル画像から複数の特徴量を抽出し、特徴別、手法別に識別器を構築した。そして、差別化された識別器を複数構築し、これらの識別器をファジィアンサンブルを用いた提案手法により効果的に選択することで、より高精度な認識システムの構築を試みた。以下に本研究を通じて得られた知見をまとめる。

- 1) 今回の認識に用いたデジタル画像から、密度と平均・分散の2つの特徴量を抽出しシステムを構築した。実験結果から、認識できる対象が用いる特徴により異なることが確認され、特徴別に構築した識別器を提案手法により効果的に選択することで、90%以上の高精度な認識結果が得られた。今回、特徴別に識別器を構築する有効性が示された

ため、今後、認識対象から様々な特徴量を抽出し、システムに取り入れていくことで、さらに識別性能の向上が期待できる。

- 2) 認識に用いた手法としては、特徴の特性を捉えた識別器を構築するため、ファジィ推論と誤差逆伝播法を用いたニューラルネットワークの2つをシステムに取り入れ、ファジィ推論であってもメンバシップ関数の分割数により認識結果の異なることが確認できた。今後は、特徴量と同様に、様々な手法をシステムの中へ取り入れていくことで、各特徴量にとって適切な手法を用いた識別器を構築することが可能となると考えられる。
- 3) 実験結果では、特徴別、手法別に構築した各識別器の認識結果と提案手法による結果を比較し、提案手法では単体で最も認識率の高い識別器よりも10%以上認識率が改善された。これは、特徴別、手法別に構築された識別器を提案手法により効果的に選択することができたためであると考えられる。
- 4) 専門家が画像により診断する際には、画像の種類により、ひび割れ幅、ひび割れ長さ、ひび割れ密度などの多くの特徴を考慮した上で、診断を行っている。しかし、既存のパターン認識を用いた画像診断システムでは、特定の特徴を決定し、その特徴により、診断を行っていたので、学習精度の改善には限界があった。本研究で提案した手法は、画像により特徴と識別器を効果的に選択することができる。その結果、学習精度の大幅な改善に繋がり、専門家の代わりを担う画像診断システムの実用化への可能性を示すことができた。

今後の課題として、ファジィアンサンブルシステムで作成されるルール数の削減が挙げられる。本研究によるファジィアンサンブルシステムは全ての特徴ベクトルを入力とするため、認識に用いる特徴量が増えると、それに伴いファジィアンサンブルシステムへの入力も増加してしまう。ファジィアンサンブル学習手法では、入力数が増加するとルール数が指数的に増加してしまうため、学習にかかる時間が膨大となってしまう。今回の橋梁の損傷度判定においても、ファジィアンサンブルシステムへの入力は10であり、メンバシップ関数を3分割にしたファジィ集合を用いると、 3^{10} のルールを作成することとなった。そのため、今後さらに特徴量を抽出しシステムへ取り入れていくためには、入力数に伴うルール数の爆発を防ぐ必要がある。そこで、遺伝的アルゴリズム(GA)などの最適化手法を用いて認識精度を落とさずにルール数を最小化することができれば、様々な特徴と手法をシステムの中に組み込むことが可能となり、さらなる認識性能の向上が期待できる。

本研究において特徴と手法の組み合わせにより、認識結果に差異が出ることが確認できたため、それらを上手く組み合わせることでさらなる認識性能の向上が期待できる。また、構造物の健全性評価という分野に限らず、特徴抽出を柔軟に行い、様々な特徴をシステムに組み込んでいくことは、パターン認識全般の発展において有効な方法の一つであると考えられる。

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) 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.
- 3) 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.
- 4) 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.
- 5) 中井学, 中島智晴, 石淵久生: パターン識別のためのファジィアンサンブル学習手法の提案, 知能と情報(日本知能情報ファジィ学会誌), Vol.15, No.6, pp.671-681, 2003.
- 6) Ishibuchi, H., Nozaki, K., Tanaka, H.: Distributed representation of fuzzy rules and its application to pattern classification, *Fuzzy Sets and Systems*, Vol.52, No.1, pp.21-32, 1992.
- 7) Ishibuchi, H., Nakashima, T.: Effect of rule weights in fuzzy rule-based classification systems, *IEEE Trans. on Fuzzy Systems*, Vol.9, No.4, pp.506-515, 2001.
- 8) 古橋武, 林勲: ファジィ・ニューラルネットワーク, 朝倉書店, 1996.
- 9) 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.
- 10) Bellman, R.: *Adaptive Control Processes: A Guided Tour*, Princeton University Press, 1961.
- 11) 麻生英樹, 津田宏治, 村田昇: パターン認識と学習の統計学 -新しい概念と手法-, 統計科学のフロンティア 6, 岩波書店, 2004.
- 12) 藤川祐介, 諸岡健一, 長橋宏: 高次元特徴の圧縮に基づく多クラスパターンの認識, 電子情報通信学会技術研究報告 PRMU, pp.97-102, 2004.
- 13) Freund, Y., Schaire, R. E.: A decision-theoretic generalization of on-line learning and an application to boosting, *Journal of Computer and System Sciences*, Vol.55, No.1, pp.119-139, 1997.
- 14) Nakashima, T., Nakai, G., Ishibuchi, H.: A boosting algorithm of fuzzy rule-based systems for pattern classification problems, *Proc. of the 2002 International Conference on Fuzzy Systems and Knowledge Discovery*, pp.255-258, 2002.
- 15) 谷口慶治: 画像処理工学一応用編一, 共立出版, 1999.
- 16) 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.
- 17) Stone, M.: Cross-validated choice and assessment of statistic all predictions, *Journal of Royal Statistical Society*, Vol.B36, pp.111-147, 1974.

(2010年3月9日 受付)