

# 多視点画像による類似形状を有する3次元物体の高精度識別の検討

新垣 仁<sup>†</sup> 福井 和広<sup>††</sup>

<sup>†</sup> 筑波大学大学院 システム情報工学研究科 コンピュータサイエンス専攻

〒 305-8573 つくば市天王台 1-1-1

E-mail: [†niigaki@viplab.is.tsukuba.ac.jp](mailto:†niigaki@viplab.is.tsukuba.ac.jp), [††kfukui@cs.tsukuba.ac.jp](mailto:††kfukui@cs.tsukuba.ac.jp)

あらまし 近年、多視点画像を用いた3次元物体識別システムの有効性を示す研究成果が報告されている。しかしながら、これらのシステムで対象としているのは顔などの形状やテクスチャが明確に異なる物体であった。これに対して多視点画像認識の適用範囲が広がるに伴い、人の目では判断が極めて難しいような類似した形状、テクスチャ、色を有する物体同士を対象にする必要が出てくると考えられる。本稿では、このような類似物体を高精度に識別するためには、どのような視点の画像を獲得するか、更に単一の識別特徴の限界を超えるべく、複数の識別特徴を如何に統合することで性能向上ができるか検討する。具体的な類似物体として100個の“林檎”を用いて評価実験および考察を行ったので、これについて報告する。

キーワード 多視点画像, 類似形状, 制約相互部分空間法, 直交相互部分空間法

## Recognition of 3D Objects with Similar Shapes using Multi-View Images

Hitoshi NIIGAKI<sup>†</sup> and Kazuhiro FUKUI<sup>††</sup>

<sup>†</sup> University of Tsukuba, Graduate School of Systems and Information Engineering

〒 305-8573 1-1-1 Tennoudai, Tsukuba, Ibaragi, Japan

E-mail: [†niigaki@viplab.is.tsukuba.ac.jp](mailto:†niigaki@viplab.is.tsukuba.ac.jp), [††kfukui@cs.tsukuba.ac.jp](mailto:††kfukui@cs.tsukuba.ac.jp)

**Abstract** This paper describes an effective method for recognition of 3D objects with similar shapes using multiple features extracted from multi-view images. The validity of our method is shown through the evaluation experiments using 100 apples.

**Key words** Multi-View, Constrained Mutual Subspace Method, Orthogonal Mutual Subspace Method, Similar Shape

### 1. はじめに

物体識別はコンピュータビジョンの分野において重要な課題の1つである[1]。特に、3次元物体の識別は、顔認識や歩行者認識、また工業部品の分類等幅広い分野で研究が行われている。

3次元物体の識別としては、3次元情報を利用するモデルベースの手法と、物体の見え方に基づくアピアランスベースの手法がある。アピアランスベースの手法は、物体の姿勢や照明変動に対処しなければならない問題があるが、モデルベースの手法に比べて高精度な3次元情報の抽出が要求されない分、ノイズのある実環境においても有効な手法であり広く利用されている。

また、近年手軽にマルチカメラシステムが構築できるようになったこともあり、多視点画像を用いたアピアランスベースの手法による物体識別の研究が精力的に行われている。多視点画像を用いた識別法の大きな利点は、対象に関して単一視点のみでは得られない情報を利用できることにある。各視点から見た画

像パターンは高次元空間に局在するが、その分布形状は対象物の3次元形状や表面特性を反映している。これら多視点画像パターンの分布を用いた識別は3次元情報を陰に利用した手法であり、このことが高い識別性能を得られる要因の1つと考えられる。

多視点画像を用いた手法は、手形状や顔認識において、単一視点を用いた手法に比べて高い性能を実現している[2]。しかし、識別対象が顔や手など、個体ごとに形状やテクスチャが明確に異なるものであった。ところが、今後、多視点画像認識の適用範囲の拡大に伴い、形状・色・テクスチャが極めて類似した物体についても識別する必要が出てくると考えられる。例えば、生鮮食品のトレーサビリティの研究として画像により果物を個体識別する場合、単純に多視点画像を用いるだけでは識別は難しいと予想される。

このような類似した物体を高精度に識別するための鍵は、多視点画像から単一の特徴量だけでなく性質の異なる複数の特徴

量を用いることが識別に有効であると考えられる [3], [4]. 多視点画像から抽出した特徴量ごとに識別器を作成し, 各識別器で求めた類似度をアンサンブル学習により統合することで, 効果的な識別が可能となる.

本稿ではこの課題を具体的に考察するために, 100 個の林檎を対象として個体識別実験を行う. その際, 物体識別で広く利用されている計 6 種類の特徴量 (P 型フーリエ特徴 [5], 色ヒストグラム特徴 [6], 輝度値特徴, 周波数特徴, HOG 特徴 [7], HLAC 特徴 [8]) を用い, アンサンブル識別を行う. なお識別器として, 多視点画像識別において高い有効性が示されている相互部分空間法とその拡張である制約相互部分空間法, 直交相互部分空間法を用いる. これらの識別器を用いることで複数特徴量の有効性を更に引き出す.

以下では, まず 2 章で多視点画像を用いた識別手法について述べ, 3 章で評価に用いる特徴量について説明を行い, 4 章で多視点画像の有効性を実験により示す. 次に, 5 章では類似した物体として林檎 100 個体を対象として, 複数特徴によるアンサンブル識別を行い, 識別結果よりアンサンブル識別の有効性を示す. 6 章はまとめである.

## 2. 相互部分空間法による識別

ここでは, まず単一の入力パターンを用いた識別手法である部分空間法について述べ, 次に多数の入力パターンを用いた識別手法である相互部分空間法について述べる.

### 2.1 部分空間法 [9]

部分空間法は, 画像パターンが特徴空間上で一様に分布しているのではなく, 局所的空間に存在している性質に着目し, パターンの分布を低次元の線形部分空間で表現できることを利用した手法である. この手法では, 複数の視点画像から得られた学習パターン (以下, 辞書と呼ぶ) を各クラスごとに KL 展開 (主成分分析) して基底を求め, この基底で張る空間によって, 各クラスの学習パターンを表現する. 未知の入力データが入ってきたとき, 各クラスの部分空間に射影したときの長さが最も大きいもの, あるいは角度が最小となるクラスを識別結果とする. この手法では, パターンの分布を物体の姿勢や照明変動を含んだ部分空間により表現しているため, 物体の向きや照明条件の変動に対する入力パターンの変動に対してもロバストになっている.

しかしながら, この手法では入力に単一画像から得られたベクトルのみしか用いていないため, 類似した物体の識別は難しいと考えられる. そこで, 本稿では部分空間法を拡張した手法で




図 1 部分空間法のご概念図




図 2 相互部分空間法のご概念図

ある相互部分空間法を用いる [10]. この手法では, 入力側もベクトルから部分空間にすることで, さらにパターンの変動成分の吸収性を高めている.

### 2.2 相互部分空間法 (MSM)

相互部分空間法は部分空間法の拡張であり, 入力と辞書の部分空間の 2 つの部分空間の成す最小角度  $\theta_1$  に基づいて識別を行う手法である.

この最小角度を基準とした識別は, 正準角の概念を用いて一般化できる.  $m$  次元部分空間  $P$  と  $n$  次元部分空間  $Q$  (便宜上  $m \geq n$ ) の間には  $n$  個の正準角が定義でき, 第 1 正準角  $\theta_1$  は 2 つの部分空間のなす最小角となる. 第 2 正準角  $\theta_2$  は, 最小正準角に直交する方向で図った最小角, 同様にして  $n$  個の正準角  $\theta_i$  ( $i = 1, 2, \dots, n$ ) が求まる.  $u_i \in P, v_i \in Q$  とすると,

$$\cos^2 \theta_i = \max_{\substack{u_i \perp u_j (j = 1, 2, \dots, i-1) \\ v_i \perp v_j (j = 1, 2, \dots, i-1)}} \frac{|(u_i \cdot v_i)|^2}{\|u_i\|^2 \cdot \|v_i\|^2} \quad (1)$$

部分空間  $P$  と  $Q$  への各正規直交基底を  $\phi, \psi$  とし, 列方向に並べた行列を  $U = [\phi_1, \phi_2, \dots], V = [\psi_1, \psi_2, \dots]$  とすると,  $U^T V$  の第  $i$  番目に大きい特異値  $\mu_i$  が第  $i$  正準角  $\theta_i$  に対する  $\cos \theta_i$  となる.

ここで, 2 つの部分空間の構造的な類似性を測る尺度として, 第  $n$  正準角まで考慮した類似度  $S[n]$  を次のように定義する.

$$S[n] = \sum_{i=1}^n \frac{\cos^2 \theta_i}{n} \quad (2)$$

2 つの部分空間が一致するときは 1.0 になり, 直交するときには 0.0 となる.

### 2.3 制約相互部分空間法 (CMSM)

相互部分空間法は, クラス内パターン変動に対してロバストな手法であるが, 識別性能に関しては最良ではない. これは, 各クラスが KL 展開によって独立に部分空間を作成する為, 各クラスのパターンの分布を近似するには最適になっているが, 他クラスとの関係を考慮していないからである.

一般に, 物体の識別において各クラスのパターンの分布が接近している程識別が難しくなる. 同様に, 相互部分空間法においても, 各クラスの部分空間が接近している程, 識別は難しくなる. その為, 各クラスの部分空間の角度を離すこと, つまり直交化させることが有効である.

そこで, 各クラスの部分空間の“違い”を表す方向 (ベクトル) を求めて, そのベクトルが張る空間 (制約空間)  $C$  上に部




図 3 制約相互部分空間法の概念図




図 4 一般化差分空間の概念図

分空間を射影し、各クラスの部分空間の成す角度を広げてから相互部分空間法により識別する。(図 3 参照)。この手法を、制約相互部分空間法という [11]。

制約空間とは、識別性能を上げる為の特徴空間の総称であり、本稿では一般化差分空間を用いる。一般化差分空間  $D$  は、全クラスの部分空間の和空間から、識別に貢献しない全クラス部分空間の共通部分空間  $M$  を取り除いた空間になっている。

$k$  個の  $n$  次元クラス部分空間  $P_i$  に対する射影行列  $P_i$  の総和の平均を  $G (= \sum_{i=1}^k P_i)$  とし、 $G$  を固有値分解した基底を求める。固有値が小さい方から  $n_c$  個選んだ基底の張る空間が一般化差分空間  $D$  である。

### 2.3.1 識別の流れ

(1) 入力部分空間  $Q$  と辞書部分空間  $P$  の射影行列  $Q$  と  $P_i (i = 1, 2, \dots, k)$  を制約空間  $C$  へ射影する。

(2) 射影後の  $P_i^c$  と  $Q^c$  の基底に対して、グラムシュミットの直交化を行う。

(3)  $P_i^c$  と  $Q^c$  に相互部分空間法を適用して、最も類似度の高い辞書クラスを識別結果とする。

### 2.4 直交相互部分空間法 (OMSM)

直交相互部分空間法は、直交行列を用いて明示的に各クラス部分空間の関係を直交化したうえで、相互部分空間法を適法する手法である [12]。直交化行列  $O$  は、行列  $G$  の固有値をすべて 1 にする白色化変換を表す行列として次式で与えられる。

$$O = \Lambda^{-1/2} B^T \quad (3)$$

ここで、 $\Lambda^{-1/2}$  は行列  $G$  の固有の平方根の逆数を固有値の大きい順から並べた対角行列、 $B$  は行列  $G$  の固有ベクトルを並べた行列である。識別の流れとしては、まず直交化行列により各クラスの射影行列と入力部分空間を変換する。変換後の各部分空間の基底に対してグラムシュミットの直交化を行い、相互部分空間法により識別をする。

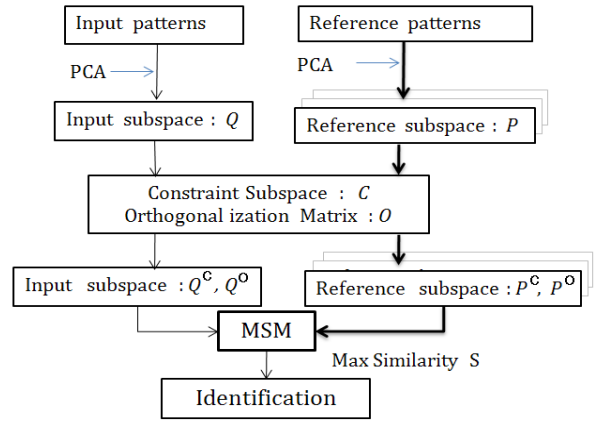


図 5 MSM, CMSM, OMSM の識別の流れ

図 5 に、以上で述べた識別の流れを示す。

## 3. 評価に用いた特徴量

### (1) 輪郭線特徴 (P 型フーリエ記述子) [5]

2 値化画像について、図 6 のように輪郭線上の点  $z_i (i = 1, 2, \dots, n)$  の位置座標を  $(x_i, y_i)$  とすると、 $x$  軸と線分  $(z_i, z_{i+1})$  の成す角  $\theta_i$  の指数関数と複素平面上における座標  $z_i$  の関係は次式ようになる。

$$\begin{aligned} \exp(j\theta_i) &= \cos(\theta_i) + j \sin(\theta_i) \\ &= \frac{x_{i+1} - x_i}{\delta} + j \frac{y_{i+1} - y_i}{\delta} \\ &= \frac{z_{i+1} - z_i}{\delta} = w_i \end{aligned} \quad (4)$$

ここで、 $\delta$  は線分の長さ  $|z_{i+1} - z_i|$  とする。式 (4) で定義される  $w_i$  を周期関数として、離散フーリエ変換を求めると次式ようになる。

$$C_k^{(P)} = \sum_{i=0}^{n-1} w_i \exp^{-j \frac{2\pi}{n} k i} \quad (5)$$

これを、P 型フーリエ記述子という。特徴ベクトルとしては、直流成分を除いた低次  $k=1 \sim 10$  と  $k=(n-10) \sim (n-1)$  の  $C_k$  を用いる。本稿では、画像の大きさを  $320 \times 240, 160 \times 120$  と 2 段階に変えて特徴抽出を行うので、特徴ベクトルの次元は  $80 (= 40 \times 2)$  次元である。

### (2) 色ヒストグラム特徴 [6]

RGB (Red, Green, Blue) 色空間において、RGB の各軸を 16 分割したヒストグラムを作成し、識別対象物の領域の大きさ (画素数) で割って正規化を行った  $48 (= 3 \times 16)$  次元特徴ベクトルを用いる。ヒストグラムにすることで位置情報は失われるが、形状変化や物体の大きさ等の変化にロバストになる。本稿では、画像の大きさを  $320 \times 240, 160 \times 120$  と 2 段階に変えて特徴抽




図 6 境界線と  $x$  軸の成す角度  $\theta_i$




図 7 HOG 特徴抽出：16x16 ピクセルの局所領域（ブロック）を 8x8 ピクセルに分けた領域（セル）ごとに方向ヒストグラムを作成する。

出を行うので、特徴ベクトルの次元は  $96(=46 \times 2)$  次元である。

### (3) 輝度値特徴

画像の大きさを  $32 \times 24$  に圧縮してから、画像をラスタースキャンした（輝度値を要素とする）ベクトルを用いる。

### (4) 周波数特徴（2次元フーリエ変換）

画像に対して 2 次元フーリエ変換を行い、直流成分を除いた低次の 10 次までを使用する。本稿では、画像の大きさを  $320 \times 240, 160 \times 120$  と 2 段階に変えて特徴抽出を行うので、特徴ベクトルの次元は  $198(=10 \times 10 \times 2 - 1)$  次元である。

### (5) Histograms of Oriented Gradients (HOG) 特徴 [7]

HOG は、エッジ強度を方向ごとにヒストグラムすることで、形状の変化に強いといわれており歩行者検出等に利用されている。図 2 のように、画像のある注目点を中心とした局所領域の輝度勾配とその向きを算出し、局所領域ごとに方向ヒストグラムを作成する。本稿では、画像の大きさを  $32 \times 24$  と圧縮したもののについて、画像を 6 等分割してその中心位置を注目点として 1 ブロック  $16(\text{画素}) \times 16(\text{画素}), 1 \text{セル} 8 \times 8$  の領域ごとに 8 方向ヒストグラムを作成する。特徴ベクトルの次元は、 $8(\text{ヒストグラム}) \times 4(\text{セル}) \times 6(\text{注目点}) = 192$  である。

### (6) 高次局所自己相関 (HLAC) 特徴 [8]

自己相関関数は定常時系列データの解析に有効な特徴の一つであるが、これを画像等に拡張したものとして HLAC 特徴がある。HLAC 特徴は次式で表現される。

$$X(a_1, \dots, a_n) = \int I(r)I(r+a_1) \dots I(r+a_n) dr \quad (6)$$

ただし、 $(a_1, \dots, a_n)$  は参照点周りにおける  $N$  個の変位、 $r$  は参照点、 $I(r)$  は参照点の輝度値を示す。ここでは、次数  $N$  を高々 2 次とし、変異を参照点周りの局所的な  $3 \times 3$  画素の領域に限定した 35 個の自己相関値を求める。本稿では、濃淡画像の大きさを  $320 \times 240, 160 \times 120$  と 2 段階に変えて HLAC 特徴 (HLAC 特徴 1) を抽出し、また大きさ  $320 \times 240$  の濃淡画像を  $x$  方向、 $y$  方向に微分 (Sobel フィルタ) した画像についても HLAC 特徴を抽出する (HLAC 特徴 2)。

## 4. 多視点画像を用いた類似物体の識別 (5 クラス識別実験)

多視点画像を用いることの有効性と各特徴量の識別性能を比較する。

### 4.1 実験の仕様

類似識別の物体として“林檎”を対象として選び、3 章で述




図 8 識別対象物の画像




図 9 3次元物体画像収集システム

べた特徴量を用いて 5 クラス個体識別実験を行う (図 8 参照)。実験で使用する画像は、図 9 のターンテーブルにより 1 個体につき 3 周分撮影した画像を用いる。識別対象は 1 周撮影するごとにターンテーブルから取り除き、別の物体を撮影する。

学習に用いる画像は、対象物を 1 回目に撮影を行った 1 周 200 視点 (視点間隔 1.8 度) により撮影した画像とする。評価データは、2 回目・3 回目に撮影した画像を利用する。ここで、評価データとして使用する画像は、図 9 に示すように 1 枚目の視点から  $\alpha$  度回転させた視点画像から視点範囲  $\theta$  (視点間隔 3.6 度) 分を用いる。このとき、 $\alpha = 36 \times i (i = 0, 1, 2, \dots, 9)$  度、 $\theta = 36, 46.8, 72, 90, 180, 360$  度とする。具体的には、視点範囲の開始画像を 20 枚ごとにづらし、視点範囲  $\theta$  は、36 度 (10 枚)、46.8 度 (13 枚)、72 度 (20 枚)、90 度 (25 枚)、180 度 (100 枚)、360 度 (50 枚) と変えるので、ある視点範囲における全施行回数  $10(=360/36)$  (分割)  $\times 2$  (周分)  $\times 5$  (クラス) = 100 回である。

### 4.2 実験の流れ

(1) 各クラスについて、学習画像 200 枚から特徴量を抽出して、200 個の特徴ベクトルに対してとした KL 展開 (主成分分析) を行い、固有値の上位 10 個に対応する基底を辞書部分空間としてシステムに登録する。

(2) 評価データについては、画像の視点範囲が  $\theta$  度 (画像枚数:  $e$  枚) とすると、まず  $e$  枚の画像から特徴量を抽出して、この  $e$  個の特徴ベクトルについて KL 展開を行い、固有値の大きい順に 3 個の基底を入力部分空間の基底とする。

(3) 入力部分空間と辞書部分空間について、MSM にて識別を行う。

### 4.3 実験結果

実験結果を図 10 に示す。輪郭線特徴と周波数特徴、色ヒストグラム特徴、HLAC 特徴 2 は視点範囲が 90 度以上では、識別率が 90 % 以上であり、視点範囲が 180 度以上だとほぼ 100 % の識別率であった。逆に、HOG 特徴と輝度値特徴では、視点範囲が広がっても識別率がそれほど上がらなかった。これは識別対象物が、撮影ごとにターンテーブルに置かれる位置が異なる為、位置不変特徴でない HOG 特徴と輝度値特徴では、視




図 10 視点範囲と特徴量を変えたときの識別率：林檎 (S[3])

点範囲が広がって得られる情報が増えると同時にノイズの量も多くなり性能が低下したと考えられる。また、HLAC 特徴 1 より HLAC 特徴 2 の識別率が高いのは、濃淡画像よりも微分画像を使用したことによりノイズなどに対してロバストになったと考えられる。

以上の結果より、位置不変特徴と多視点画像を用いることにより識別性能が向上することがわかった。ここで、視点範囲が多いほど識別が行いやすいことがわかったが、実用上限られた視点範囲で識別できることが望ましい。図 10 より、視点範囲が 90 度以上では個体識別に有効な情報が得られていると考えられるので、5 章の 100 個体識別実験では視点範囲を 90 度とし、特徴量としては、輪郭線特徴と周波数特徴、色ヒストグラム特徴、エッジ画像から抽出した HLAC 特徴を用いることにする。

## 5. 林檎 100 個体識別実験

ここでは、まず単一の特徴量による識別実験を行い、個々の特徴量での識別性能を比較する。識別には、相互部分空間法 (OMSM), 制約相互部分空間法 (CMSM) と直交相互部分空間法 (OMSM) を用いる。次に、複数特徴量を用いたアンサンブル識別による識別性能向上を検討する。

### 5.1 単一の特徴量による個体識別実験

#### 5.1.1 実験の仕様

識別対象物体は、類似形状物体として林檎 (富士) を 100 個体用いる (図 11 参照)。識別手法は、MSM, CMSM, OMSM と比較の為  $k$ -NN 法を用いる。 $k$ -NN 法は、入力を  $m$  枚とすると、入力 1 つに対して  $k$  の候補を選び、 $k \times m$  個の投票した結果、最も多く投票されたクラスを識別結果とする。




図 11 識別対象物の一部 (40 個)

### 5.1.2 実験の流れ

(1) MSM, CMSM, OMSM は、各クラスの部分空間の上位固有値 10 個に対応する基底を辞書データとしてシステムに登録する。 $k$ -NN 法については、辞書データは学習用データ 200 個を  $k$ -Means 法により 10 個にクラスタリングしたものを辞書データとする。評価データは、視点範囲 90 度 (25 枚) とする。視点開始角度  $\alpha$  は 36 度ごとにづらすので全実行回数は  $10(=360/36) \times 2$  (周分)  $\times 100$  (クラス) = 2000 回である。評価尺度としては、識別率、等価エラー率 (EER) を用いる。

(2) 学習段階では識別物体は未知とし、制約空間  $C$  と直交化行列  $O$  はあらかじめ評価には用いない 20 個を用いて作成する。制約空間と直交化行列ともに、固有値が小さい基底は識別性能を低下させる可能性があるため、固有値の値が  $10^{-6}$  以下のものは取り除く。

(3) 視点範囲 90 度分 (25 個) の特徴ベクトルから部分空間を作成する。上位固有値  $n$  個を入力部分空間の基底の数とする。 $n$  の値は 1 から 5 まで変化させる。(a)MSM: 入力部分空間と辞書部分空間について MSM にて識別を行う。

(b)CMSM: 入力部分空間と辞書部分空間を一般化差分空間  $D$  に射影してから、MSM にて識別を行う。

(c)OMSM: 入力部分空間と辞書部分空間を直交化行列  $O$  で変換してから、MSM にて識別を行う。

### 5.1.3 識別結果と考察

表 1, 2 に識別実験結果を示す。部分空間同士の識別結果は、類似度  $S[n]$  (式 (2)) の  $n$  の値を 1 から 5 に変化させたときの最も良い識別率の値を載せた。( ) 内の値は、そのときの  $n$  の値を示す。ここで、最も良い結果とは EER が 10 % 以下の結果のうち最も識別率が高いものとした。(ただし、10 % 以下がなければ 20 % 以下とした。) “CMSM- $x$ ” の  $x$  の値は、共通部分空間  $M$  の次元を表す。

MSM では、全ての特徴量で 5 クラス識別実験に比べて識別率が下がったが、MSM の改良手法である CMSM, OMSM では 90 % 以上の識別率が得られた。 $k$ -NN 法と比較すると、MSM では識別率は劣るが、CMSM は全ての特徴量、OMSM では輪郭線特徴以外では高い識別率を得ることができた。

HLAC 特徴について、MSM と  $k$ -NN 法ともに識別率が極端に悪かった。これは特徴空間上で各クラスのデータの分布が接近していて、線形な境界では識別できなかったことが原因であると考えられる。

表 1 個々の特徴量での識別率 (%)

	輪郭線	周波数	色ヒストグラム	HLAC
MSM	77(2)	89.75(4)	89.6(3)	54.9(5)
CMSM-1	85.6(3)	92.2(4)	94.55(1)	76.95(4)
CMSM-2	88.25(3)	93.4(4)	94.25(1)	94.9(2)
CMSM-5	88.25(2)	92.15(4)	94(1)	98.75(1)
CMSM-10	80.3(1)	90.65(5)	93(1)	99(1)
OMSM	82.2(5)	86.4(5)	98.45(1)	94.45(1)
NN	87.75	72.7	91.95	34.9
3-NN	79.4	69.35	83.4	28.85
5-NN	70.1	61.75	72.95	23.80

表 2 個々の特徴量での等価エラー率【EER】 (%)

	輪郭線	周波数	色ヒストグラム	HLAC
MSM	15.3(2)	6.2(4)	5.8(3)	21.7(5)
CMSM-1	8.4(3)	4.5(4)	4.1(1)	15.4(4)
CMSM-2	7.3(3)	3.9(4)	4.1(1)	17.9(2)
CMSM-5	7.7(2)	4.0(4)	5.1(1)	2.8(1)
CMSM-10	9.7(1)	4.4(5)	6.6(1)	1.6(1)
OMSM	10.8(5)	6.5(5)	8.9(1)	24.4(1)

周波数特徴では、OMSM では MSM に比べて識別性能が落ちてしまった。これは、各クラスの部分空間に重複空間があったことを考慮せずに直交化してしまったことが、OMSM で識別率や EER が悪化した原因であると考えられる。

輪郭線特徴については、識別率が 15 % 近く性能が下がった。この原因の一つに、前処理の段階で背景除去する際に林檎の“影”の部分の輪郭が安定して取り出すことが難しいため、輪郭情報にノイズが入ってしまったことが影響している可能性がある。

色ヒストグラム特徴では、どの識別手法でも高い識別率が得られ EER が低いことから、類似物体の識別に対して適した特徴であると考えられる。

### 5.2 複数特徴量によるアンサンブル識別

性質の異なる複数の特徴量を用いることで識別性能向上を検討する。識別器として、相互部分空間法 (MSM), 制約相互部分空間法 (CMSM), 直交相互部分空間法 (OMSM) を用いる。

#### 5.2.1 実験の流れ

(1)  $m$  個の特徴量について、入力部分空間  $Q$  と各辞書部分空間  $P_i$  との類似度  $S_i^p$  をそれぞれ求める。ただし、 $i = 1, 2, \dots, 100$  とし、 $p$  は特徴量の種類の違いを表す。

(2) 最大類似度の値  $S_{max}^p$  で各クラスの類似度を割って、類似度の最大値を 1.0 に正規化した値  $S_i^{p'} (= S_i^p / S_{max}^p)$  を求める。

(3) 正規化した類似度を複数の特徴量で平均した値  $S_i'' (= \sum_{p=1}^m S_i^{p'} / m)$  を新たな類似度とする。

(4) 100 クラス中、類似度が最も高いクラス ( $\max S_i''$ ) を識別結果とする。

#### 5.2.2 識別結果と考察

表 3,4 の結果より、MSM では最高識別率が 98.9 % , CMSM では 99.4 % , OMSM では 99.35 % であり、MSM, CMSM, OMSM 全ての手法において個々の特徴量の結果よりも良いことを確認した。特に MSM では、EER の値が輪郭線特徴では 15.35 % , 周波数特徴では 6.2 % , 色ヒストグラム特徴では 5.8 % , HLAC 特徴では 21.7 % と高かったが、複

表 3 複数特徴量のアンサンブル学習による識別率 (%)

	S[1]	S[2]	S[3]	S[4]	S[5]
MSM	94.3	90.75	97.9	98.75	<u>98.90</u>
CMSM-1	88.5	96.1	98.7	99.25	99.1
CMSM-2	91.5	98.05	99.1	<u>99.4</u>	99.25
CMSM-5	92.4	98.05	99.15	99.2	99.05
CMSM-10	91.95	97.95	99.1	99.05	98.75
OMSM	94.9	96.35	98.85	99.15	<u>99.35</u>

表 4 複数特徴量のアンサンブル学習による等価エラー率【EER】 (%)

	S[1]	S[2]	S[3]	S[4]	S[5]
MSM	45.9	2.8	0.8	0.3	<u>0.4</u>
CMSM-1	4.5	1.1	0.3	0.1	0.1
CMSM-2	3.2	0.7	0.2	<u>0.2</u>	0.2
CMSM-5	2.9	0.6	0.3	0.2	0.3
CMSM-10	3.1	0.6	0.3	0.3	0.4
OMSM	2.1	1.1	0.4	0.3	<u>0.3</u>

数の特徴量のアンサンブル識別によって、1 % 未満の値を得ることができた。

また、MSM, CMSM, OMSM において個々の特徴量で、最もよい識別率と基底の本数が異なっていたが、アンサンブル学習した結果では  $n = 4, 5$  と多いほうが識別率が高く、EER も  $n = 1, 2$  に比べて  $n = 4, 5$  の方が低くなっていることがわかった。これは、アンサンブル識別により、相互部分空間法の基底を増やしても安定して識別性能を得られる効果があるのではないかと考える。

## 6. まとめ

本稿では、類似した形状・模様・色を有する果物を識別対象として、多視点画像と複数特徴量を用いて個体識別実験を行った。制約相互部分空間法、直交相互部分空間法と位置不変特徴量を複数用いてアンサンブル識別を行うことにより高い精度の識別率を得ることができた。

今後の課題としては、より視点範囲を狭くした場合でも高い識別性能が得られるように、特徴量の種類を増やすことや複数の特徴量の統合方法の改良が考えられる。

### 文 献

- [1] 柳井 啓司, “一般物体認識の現状と今後,” CVIM-155, pp.121-134, 2006
- [2] 坂野 鋭, “パターン認識における主成分分析-顔画像認識を例として-,” 統計数理第 49 巻, 第 1 号, pp.23-42, 2001
- [3] 野宮 浩揮, 上原 邦昭, “相補的な視覚的学習による複数の認識手法の統合,” 信学論, Vol.J90-D, No.11, pp.3043-3054, 2007
- [4] 神谷 保徳, 矢野 良和, 大熊 繁, “一般物体認識のための扱う特徴量が異なる 3 種類の局所特徴タイプの統合利用,” MIRU2007, pp.1396-1401, 2007
- [5] 鄭 澤宇, 岩田 洋佳, 二宮 正士, 田村 義保, “P 形フーリエ記述子に基づくハナハス花卉の部分形状特徴の定量的評価,” 育種学研究, Vol.7, pp.133-142, 2005
- [6] 村瀬 洋, V.V.Vinod, “局所色情報を用いた高速物体探索-アクティブ探索法-,” 信学論 (D-II), Vol.J81-D-II, No.9, pp.2035-2042, 1998
- [7] N. Dalal, B. Triggs, “Histograms of Oriented Gradients for Human Detection,” IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.886-893, 2005
- [8] 白木 孝義, 大津 展之, “HLAC 特徴を用いた照明変化に頑健な物体認識,” 信学技報, PRMU2005-73, pp.59-63, 2005
- [9] 石井 健一郎, 上田 修功, 前田 英作, 村瀬 洋, “わかりやすいパターン認識,” オーム社, 1998
- [10] 前田 賢一, 渡辺 貞一, “局所的構造を導入したパターン・マッチング法,” 信学論 (D), Vol.J68-D, No.3, pp.345-352, 1985
- [11] 福井 和広, 山口 修, “一般化差分部分空間に基づく制約相互部分空間法,” 信学論 (D-II), pp.1622-1631, 2004
- [12] 河原 智一, 西山 正志, 山口 修, “直交相互部分空間法を用いた顔認識,” CVIM-151, pp.17-24, 2005