

局所特徴に基づく Aspect モデルの構築と 3次元物体認識に関する研究

中田健一^{†1} 和田俊和^{†2}

3次元物体認識の一方式として、観測方向によって変化する3次元物体の「見え」をモデル化する方法がある。例えば、パラメトリック固有空間法では対象の見えの変化を固有空間内の多様体としてモデル化し、物体の種別や姿勢変化などを認識する。しかし、この方法では、対象を撮影した画像全体を固有空間に射影するため、背景の変化やオクルージョンの影響を受けやすいという問題がある。この問題を解決するために、本稿では画像の局所特徴に基づき対象モデルを構築し、背景の変化やオクルージョンの影響を受けにくい物体認識法を提案する。但し、広い角度の対象の「見え」をグルーピングすると、個々の物体の弁別性が低下するため、弁別性を維持しつつコンパクトなモデル化を行うという問題を解決する必要がある。本稿では Diverse Density (DD)を用いることにより、強い弁別性を持つ特徴を優先的に残し、弁別性を維持しながら対象の複数の見えをグルーピングする方法を提案する。Coil 画像セットを用いた実験により、対象物体のすべての見えから抽出した局所特徴を用いたモデル化よりも、複数の「見え」をまとめることによって、不要な特徴を捨て、サイズを小さくしたモデルの方が高い認識率が得られる事を明らかにし、さらにクエリ画像に背景画像を付加してもパラメトリック固有空間法よりも高い認識率が達成できることを確認した。

Multi-Aspect Modeling of 3D Objects based on Local Features and Its Application to 3D Object Recognition

KEN'ICHI NAKATA^{†1} TOSHIKAZU WADA^{†2}

Appearance based 3D object modeling is a handy approach for 3D object recognition. The most representative method in this approach is parametric-eigenspace method, which models the appearance variations of a 3D object by a manifold in eigenspace and recognizes the object name and the observation direction by using the manifolds of multiple objects. This method, however, is not robust against occlusions and background variations. For solving this problem, this paper proposes a robust 3D object modeling and recognition method based on local features. The inputs of this method are the images of objects representing their aspects. From these images, tons of local features are generated. Some are unique to an object and some are not. Also, some are created by specular highlight and shadows. By grouping the appearances of contiguous aspects, we can obtain a compact representation of an object, which indirectly excludes fragile and non-essential features. However, excessive grouping may cause poor recognition rate. The distinctive features unique to an object can be found by using the framework of Diverse Density (DD). The DD can be used also for controlling the grouping process. Our DD guided local feature selection and grouping is applied to Coil image dataset for object recognition task. Through comparative experiments with parametric-eigenspace method for occluded and background added input images, we confirmed that our method achieves much higher recognition rate.

1. はじめに

3次元物体認識を行う一つの方式として、様々な方向からの物体の「見え」に基づく物体のモデル化を行う方法がある。この方式では、様々な3次元物体の「見え」を表現しつつ、他の物体と区別し易いように物体のモデル化をしなければならない。見えに基づく3次元物体認識の代表的な手法として、パラメトリック固有空間法[1]がある。この手法は、画像を物体認識と同時に撮影方向などのパラメータ推定を行う手法である。しかし、入力画像に未知の背景が含まれる場合や、オクルージョンによって物体が一部隠されている場合には認識率が低下してしまう。未知の背景が認識対象物体に混入している場合には、対象物体以外の背景領域をマスクする手法[2][3]もあるが、オクルージョンには、対応することができない。

そこで、本論文では、局所特徴を基に物体を表現し、未

知の背景がある場合や、オクルージョンの発生している状況下でも安定に認識することができる手法を提案する。本手法では、物体の様々な「見え」から抽出される局所特徴を基に、対象物を表現する。しかし、全ての局所特徴量を利用すると、1) 物体を表現する特徴数が増えすぎてしまい計算コストが増加する、2) 鏡面反射によるハイライト部分や、映り込み、影、背景の混入など、必ずしも認識に有効でない部分の局所特徴量が含まれる、という二つの問題が生じる。また、物体認識が目的である場合、他の物体では観測されない、その物体固有の弁別性の高い特徴を積極的に用いるべきである。これら物体の「見え」のグルーピングと、弁別性の高い特徴の抽出、という2目的のために、Diverse Density(DD)[4][5]を用いる。具体的には、他物体の全 Aspect の見えを Negative に割り当て、同一物体の連続する Aspect の見えを Positive に割り当て、Positive に共通に含まれ、Negative には含まれない局所特徴量で DD の値が大きくなるようにしておく。グループの個数を変化させながら、画像集合に含まれる全局所特徴の DD の値から

^{†1} 〒640-8510 和歌山市 栄谷 930
和歌山大学 大学院システム工学研究科

^{†2} 〒640-8510 和歌山市 栄谷 930
和歌山大学 システム工学部 情報通信システム学科

計算される「共通度」が最大になる Aspect のグルーピングを求め、そのグループ内で DD の値に応じた特徴選択を行うことによって、物体識別に有効な局所特徴量の抽出を行うことが本研究の概要である。

2. 3次元物体の表現

2.1 パラメトリック固有空間法

アピアランススペースの固有空間法であり基本的にテンプレートマッチングを拡張した見かけの照合による手法として、村瀬らはパラメトリック固有空間法を提案している。この手法は、三次元物体の向きや光源の変化に対応して変動する離散的な二次元画像集合の共分散行列の固有ベクトルを基底とし、それによって張られる固有空間を求め、これら基底との内積計算によって画像を固有空間内の点に写像する。物体の向きや光源の変化によってパラメータ付けされた画像群は、固有空間内の順序づけされた点列に対応する。これらを補間する事によって、離散的な点列から連続的な多様体を構成し、物体の見えを表現する。認識段階では入力画像を固有空間内の点に写像し、その点に最も近い多様体と、その上での位置を検出することによって、物体の識別と姿勢推定を行う。このように多様体を構成すれば、多様体の作成時に用いた離散的な画像以外の画像が入力された場合でも物体の識別や向きの推定が可能となる。しかし、学習段階、認識段階において入力画像から対象物を切り出す前処理が必要となる。この処理が不正確な場合、対象の位置ずれや変化に弱いという欠点が表面化する。また、対象の切り出しを何度も行う場合は、画像を固有空間に写像するための内積計算も何度も行われるため、処理は簡単であっても計算量が多くなるという問題点もある。

2.2 Aspect Graph

もともと、Aspect Graph とは、観測される凸多面体の面の集合が方向によってどのように変化するかを計量情報と併せてグラフ構造で表現した物体表現法の一つの方法であった。近年では、一般の多面体や曲面物体、さらには多関節物体を表現するものまでが Aspect Graph に含まれている。これらのモデルでは、見えの集合からではなく、CADモデルから各面の見えを生成し、トポロジカルな見えの集合を生成するということが行われてきた。その一方で、見えの集合からアスペクトグラフを構築するという Appearance based Aspect Graph[6]という研究も生まれており、3次元物体認識でも利用されている。現在では、様々な対象の見えから、物体の観測方向をグルーピングして、同一アスペクトに関して計量情報をまとめ上げることが広義の Aspect Graph の意味である。これらを用いた様々な物体認識の方法が数多く提案されている。

3. 局所特徴を基にした物体の表現

本稿では、物体の見えを連続する Aspect についてグルーピングすることで、弁別性に優れ、かつ、コンパクトな物体モデルを構築することを目的としている。但し、観測時の背景の混入やオクルージョンに対する安定性の観点から、画像の局所特徴量により見えを表現する点がこれまでの研究と大きく異なる。

3.1 各 Aspect の表現

各 Aspect から Scale-Invariant Feature Transform(SIFT)[7]を用いて局所特徴量を抽出する。この局所特徴量群を用いて各 Aspect の見えを表現する。本研究では、抽出される128次元の特徴量に、特徴点の座標(x,y)、スケール、方向ベクトル(dx,dy)、を追加した合計133次元を、特徴ベクトルとして用いる。

3.2 局所特徴の白色化

前節で述べた入力特徴ベクトルの各要素は、ダイナミックレンジが異なるため、特徴ベクトル間の距離計算において、特定の要素が計算結果に大きく影響を与えることが考えられる。一例として、扱う画像サイズが異なると、特徴点の座標(x,y)の取り得る値の範囲は異なる。このとき、大きな画像サイズの局所特徴ほど座標(x,y)に依存した計算結果になる事が考えられる。

そこで、対象物体を指すモデルごとに、局所特徴の共分散行列を単位行列にする白色化を行う。白色化によって、各成分間の相関は0になり、各成分の分散は1になる。本研究では、Aspect から特徴ベクトルを抽出した段階で特徴量の白色化を行い、特徴選択後に元に戻して物体認識に使用する。

4. Diverse Density

Diverse Density は、特徴ベクトルの集合から成るバッグを、ポジティブバッグ、ネガティブバッグの二種類に分け、ポジティブバッグの集合に共通に含まれ、ネガティブバッグには含まれない特徴ベクトルで極大値をとるような尺度である。詳細な定義のため、まず、用語の定義を以下に行う。

バッグ: インスタンスの集合。本研究では画像を指し、記号 B で表す。

ラベル: 共通性を見出したいバッグに対してはポジティブ、共通性があってはいけないバッグに対してはネガティブのラベルを与える。それぞれ、 B_i^+ ($i = 1, \dots, m$), B_i^- ($i = 1, \dots, n$)と表す。

インスタンス: 個々の画像特徴ベクトル。 $B_{ij}^+ \in B_i^+$, $B_{ij}^- \in B_i^-$ と表す。

まず、特徴空間内のある入力ベクトル: x におけるインスタンス: B_{ij} からの影響を以下のように定義する。 σ はスケールリングパラメータである。

$$P(\mathbf{x}, \mathcal{B}_{ij}) = \exp\left(-\frac{\|\mathcal{B}_{ij} - \mathbf{x}\|^2}{\sigma^2}\right) \quad (1)$$

これは、図1に示すように、近ければ最大1の影響を受け、遠ければ影響が小さくなり0に近づくことを表している。

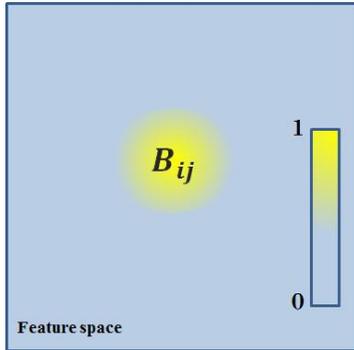


図1 インスタンス \mathcal{B}_{ij} からの影響

この値をもとにして、あるポジティブバッグ（共通性を見出したいある画像） \mathcal{B}_i^+ 内の全インスタンスから入力ベクトル \mathbf{x} への影響 $P_+(\mathbf{x}, \mathcal{B}_i^+)$ を次式のように定義する。

$$P_+(\mathbf{x}, \mathcal{B}_i^+) = 1 - \prod_{\mathcal{B}_{ij}^+ \in \mathcal{B}_i^+} (1 - P(\mathbf{x}, \mathcal{B}_{ij}^+)) \quad (2)$$

これは、入力ベクトル \mathbf{x} と近いインスタンスがバッグ \mathcal{B}_i^+ 内に一つでもあれば、右辺第2項の積項が小さくなり、それを1から引くという計算である。これは、ポジティブな画像内に入力ベクトル \mathbf{x} と近い特徴が少なくとも一つは含まれている度合いを表している。

全ポジティブバッグについて式(2)の値を図2及び式(3)に示すように掛け合わせる事で、全ポジティブバッグに含まれる共通特徴で値が大きくなる値を求めることができる。

$$\prod_i^m P_+(\mathbf{x}, \mathcal{B}_i^+) \quad (3)$$

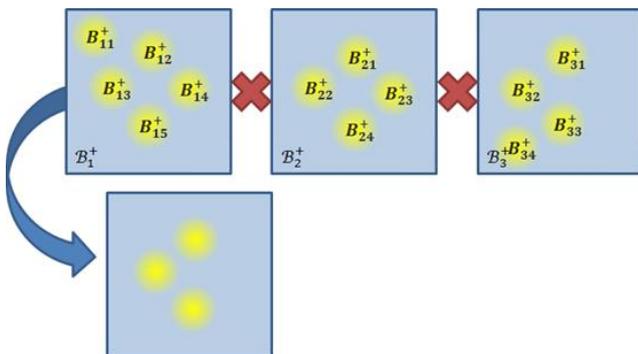


図2 ポジティブバッグからの共通特徴の抽出

逆に、ネガティブバッグ \mathcal{B}_i^- に含まれる全インスタンスから入力ベクトル \mathbf{x} への影響は、次式で定義される。

$$P_-(\mathbf{x}, \mathcal{B}_i^-) = \prod_{\mathcal{B}_{ij}^- \in \mathcal{B}_i^-} (1 - P(\mathbf{x}, \mathcal{B}_{ij}^-)) \quad (4)$$

これは、入力ベクトル \mathbf{x} と近いインスタンスがバッグ \mathcal{B}_i^- 内に一つでもあれば小さくなる値であり、ネガティブな画像内に入力ベクトル \mathbf{x} と近い特徴が含まれない時に大きな値になる。

ネガティブバッグもポジティブバッグと同様に、式(4)の値を次式のように互いに掛け合わせることで、統合することができる。これは図3に示すように、ネガティブバッグに含まれるいずれかの特徴ベクトルで0に落ち込むポテンシャルを形成する。

$$\prod_j^n P_-(\mathbf{x}, \mathcal{B}_j^-) \quad (5)$$

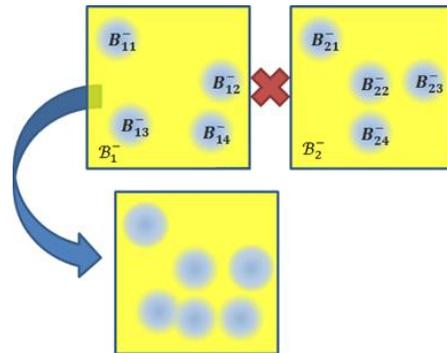


図3 ネガティブバッグの統合

入力ベクトル \mathbf{x} 、ポジティブバッグ \mathcal{B}_i^+ 、ネガティブバッグ \mathcal{B}_j^- における Diverse Density $DD(\mathbf{x}, \mathcal{B}_i^+, \mathcal{B}_j^-)$ は、全ポジティブバッグ、全ネガティブバッグに関して式(3)と(5)を掛け合わせた量であり、次式のように定義される。

$$DD(\mathbf{x}, \mathcal{B}_i^+, \mathcal{B}_j^-) = \prod_i^m P_+(\mathbf{x}, \mathcal{B}_i^+) \prod_j^n P_-(\mathbf{x}, \mathcal{B}_j^-) \quad (6)$$

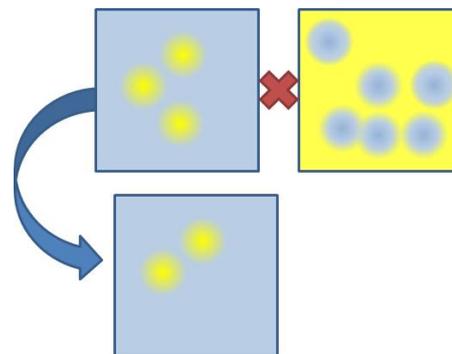


図4 ポジティブ/ネガティブバッグの統合

図4に示すように、 $DD(\mathbf{x}, \mathcal{B}_i^+, \mathcal{B}_j^-)$ の値が大きければ、その点は各ポジティブバッグに類似した特徴を含み、どのネガティブバッグにも類似した特徴が含まれないということを表している。

5. Aspect のグルーピング

前章で述べた DD は、ポジティブ/ネガティブのバッグが与えられたときに各特徴ベクトルについて計算されるものである。その特徴ベクトルの集合である画像集合の DD を総合することができれば、画像間の共通度が計算できるようになる。福井ら[8]は、全特徴空間内の DD の値を総合した親和度（後に共通度と呼んでいる）を定義し、画像のクラスタリングに適用し、顔画像クラスタリングにおいて有効性を示している。本研究においても、この共通度を用いることにする。

5.1 各グループの共通度の定義

ある物体を周囲から撮影した画像群が与えられたとき、連続した Aspect の画像をグループ化するものとする。このグループの共通度を定義することができれば、グループ数を固定して、共通度の和を高めるようなグループ化が行え、そのグループを代表する特徴選択が行える。

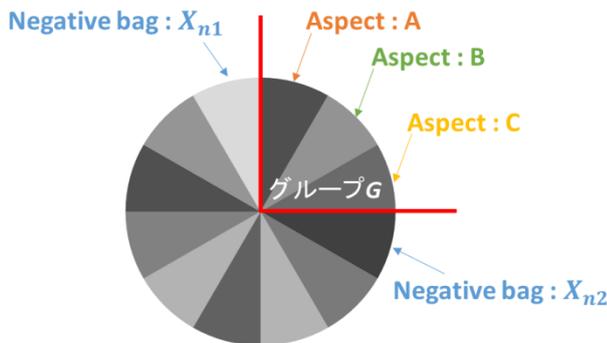


図5 グループの構成例

図5は物体が中央部に置かれているときの各 Aspect（濃淡の異なる扇状領域）を表している。物体が円の中心に存在するものと仮定して、扇型領域の弧から円の中心方向に観測することでその Aspect の画像が観測されるものとする。この連続する Aspect をまとめることが、ここで言うグルーピングである。図5の場合、Aspect A,B,C が一つのグループにまとめられている。

本研究では、以下に示す2枚の画像間の共通度に基づいてグループ内の画像集合の共通度を定義する。

あるグループに属する2枚の画像 $\{X_a, X_b\}$ の共通度を式(7)に示す。

$$Cp(X_{oa}, X_{ob}) = \prod_{x_{ai} \in X_{oa}} P_+(x_{ai}, X_{ob}) P_-(x_{ai}, X_{n1}) P_-(x_{ai}, X_{n2}) \quad (7)$$

但し、 X_{n1} , X_{n2} は当該グループに隣接する Aspect の画像である。このような割り当ては、あるグループとその外部で共通に観測される局所特徴に違いが出るようにするためのものであり、明確な見えの変化が起きる箇所をグループの境界とする効果がある。

式(7)を利用して、グループGの親和度を式(8)に示す。

$$Com(G) = \frac{1}{|G|C_2} \sum_{X_a, X_b \in G, a>b} \frac{Cp(X_a, X_b) + Cp(X_b, X_a)}{2} \quad (8)$$

但し、 $|G|$ はグループに属する画像の枚数を表す。式(8)の共通度は、グループ内全ての画像組の共通度の期待値になっている。

5.2 グルーピング手順

上記の共通度を基準として、物体の Aspect をグルーピングする方法について述べる。具体的には、共通度の和を可能な限り大きくするグルーピングを求める手法である。

まず、物体の Aspect を指定された個数に均等にグルーピングする。図6に示すのは3グループの例である。この図のように均等な分割としてあり得る分割は全て求めておき、これを初期状態とする。この初期状態に対応する共通度の総和を暫定値として記録しておく。

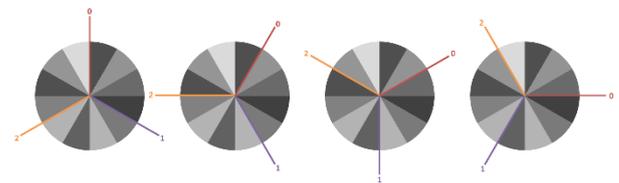


図6 均等割りグルーピング

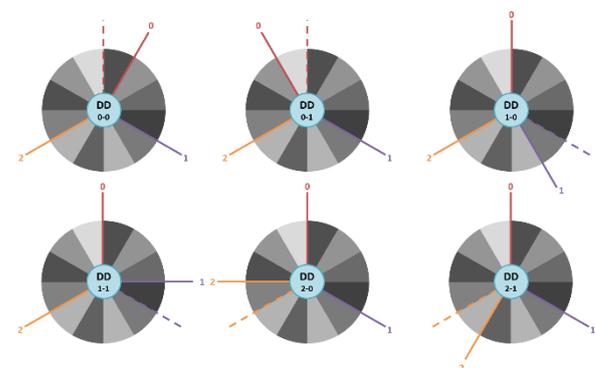


図7 グループ境界の更新

これらの初期状態からスタートして、グループの境界を図7に示すように、一つずつ変化させ共通度の総和を求める。求めた値が暫定値より大きい場合、グループ構成と暫定値を更新する。更新されたグループ構成から、引き続き同じ計算を続けていく。全てのグループの境が隣のグループ境目に追いつくまで探索を行っても暫定値が更新されなければグルーピングを終了する。これを全ての初期値について計算し、求められた最大共通度のグルーピングを結果とする。この計算では、最適解は得られないが、均等分割付近の準最適解が得られる筈である。

6. 特徴選択

ここでは、得られたグループ内で物体を特徴付ける特徴ベクトルの選択を行う方法について述べる。

6.1 弁別度の定義

本稿では「弁別性」という用語を、対象モデルが他のモデルとどの程度異なるのかを表すものとして用いる。局所特徴の弁別度とは、その局所特徴がどの程度対象モデル固有のものであるかを示す。弁別度が高ければ、その特徴の存在によって対象モデルを特定できる可能性が高いことを示している。これは、物体 o について、 B^+ と B^- を以下のように割り当てて計算した DD の値を各特徴の重要度とし、その重要度の高いものから特徴の選択を行えば良い。

B^+ : 物体 o の同一 Aspect グループ内の画像集合。

B^- : 物体 o 以外の物体の全 Aspect 画像集合。

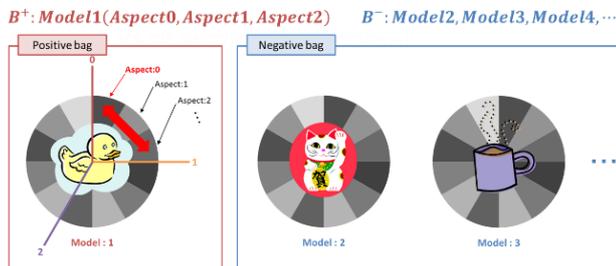


図 8 バッグの割り当て

物体 o の Aspect グループ内の画像をポジティブバッグに割り当てることで、瞬間的なハイライトの発生などを抑制しつつ、異なるアスペクト間で安定して観測できるテクスチャや物体形状などが特徴に反映される。他の物体の全 Aspect 画像をネガティブに割り当てることで、弁別度が高い特徴が選択されるようになる。このような割り当ては湯浅ら[9]の提案した画像検索用インデックスの重要度計算と同じく、弁別性を向上させる効果がある。これによって物体 o 固有の認識に有効な特徴の選択が行える。

このように、本手法では安定に観測でき、弁別度が高い局所特徴量が選択されるようになっている。

7. 認識手順

まず、入力画像から SIFT を用いて特徴抽出を行う。次に、各モデルの局所特徴をプールしたデータベースと、抽出した各局所特徴に対して、Approximate Nearest Neighbor Library を用いて最近傍の局所特徴を探索する。求めたデータベースの最近傍局所特徴の属するモデルに投票する。投票時の重みは全て均一である。最終的に投票数が最大となるモデルを認識結果とする。このとき、最近傍局所特徴までの距離で閾値処理を行う。閾値より遠い場合には投票を行わない。

投票時に閾値処理を行うことで、背景等から抽出された局所特徴の影響を排除できると考えられる。

8. 実験

8.1 データセット

本研究では、物体認識の対象モデルに Coil-20[10]データセットを用いる。このデータセットでは、物体を横から 360° 撮影した Aspect の画像セットでモデル表現している。図 10 の添え字はモデル番号を示している。

連続する Aspect の画像を交互に学習データ、テストデータに割り当てる。具体的には、偶数番号の画像を学習データ、偶数番号の画像をテストデータに割り当てる。

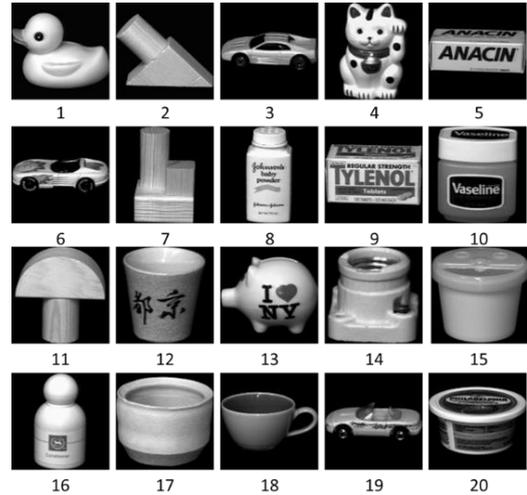


図 10 Coil-20

8.2 局所特徴量

本研究では、OpenCV(ver2.4.5)に実装されている SIFT を用いて局所特徴を抽出する。抽出される特徴量の中から、座標(x,y), size, orientation(sin,cos), descriptor(128dimension)の 133 次元を白色化して使用する。

図 11 に各モデルの平均 Aspect の特徴量数を示す。この特徴量数は、各モデルのそれぞれの Aspect から抽出された特徴量数の平均値である。

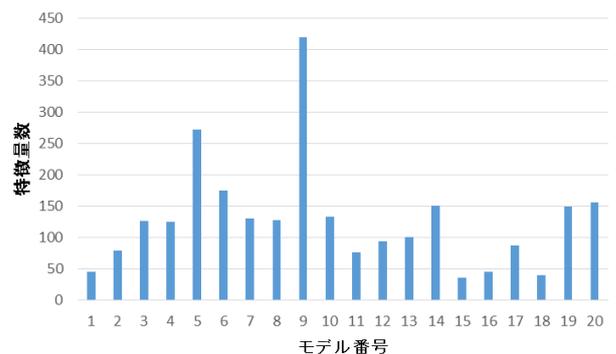


図 11 特徴量数

8.3 提案手法による認識実験

後述の 8.3.1 節, 8.3.2 節, 8.3.3 節で行う実験では、複数の見えをグルーピングすることで考えられる安定性の向上

を図るため、以下の2つの手法で認識実験を行った。

手法1：弁別性の観点から特徴選択を行ったデータベース（他モデルの特徴量に対して共通性の低い特徴量群）による認識

手法2：弁別性と安定性の観点から特徴選択を行ったデータベース（他モデルの特徴量に対して共通性の低く、グルーピングされたアスペクトに共通して観測される特徴量群）による認識

手法1の特徴量群は、グルーピングを考慮せず、弁別度を求める対象の特徴量が属する1枚の見え画像のみをポジティブバッグに与えて求めた。手法2の特徴量群は、弁別度を求める対象の特徴量が属するグループのAspectをポジティブバッグに与えて求めた。

8.3.1 背景なしテストデータによる認識実験

8.1節で述べた、学習に使用していない画像群をテストデータにした際の認識率を求めた。このとき、テストデータの背景は学習データ同様に無背景である。

手法1による認識率を図12に、手法2による認識率を図13に示す。ここで、図中の凡例に示される“閾値”とは、7章で述べた閾値となる距離を示している。具体的には、入力画像の各局所特徴に対する、データベースの局所特徴間の最近傍特徴までの二乗平均平方根である。また、横軸に示す「各Aspectの最大特徴量数」にある“all”とは、提案手法を行わず全ての局所特徴を使用した場合の認識率を示す。

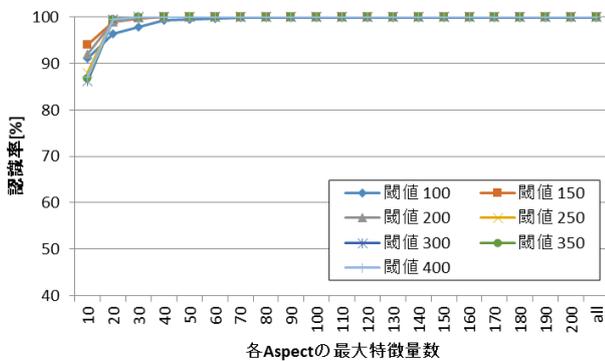


図12 弁別性を考慮した手法1による認識率

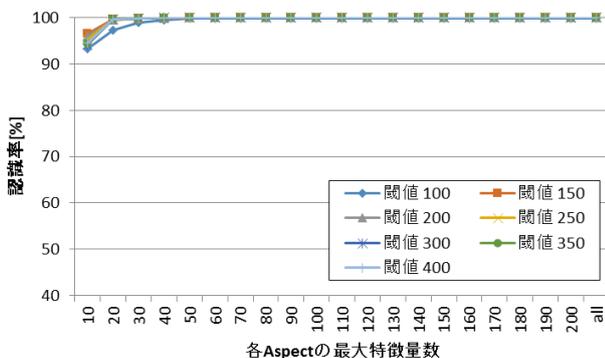


図13 弁別性と安定性を考慮した手法2による認識率

8.3.2 背景を合成したテストデータによる認識実験

図14に示すSift Flow Dataset[11]の画像を図15のように合成した。この背景を合成したテストデータでの認識率を図16、図17に示す。



図14 背景画像

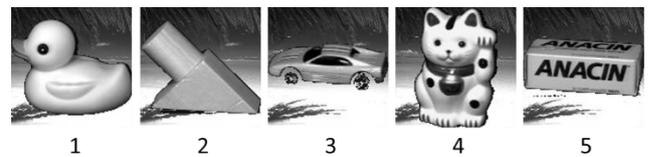


図15 背景を合成したテストデータ

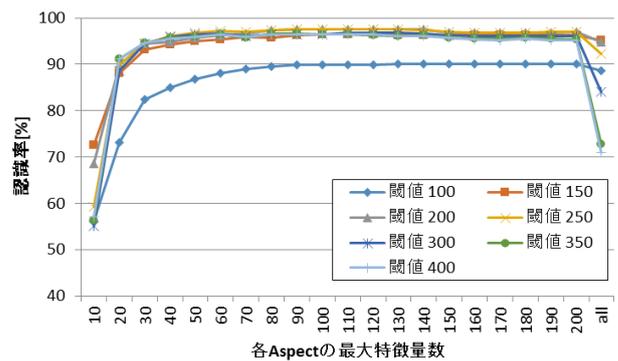


図16 弁別性を考慮した手法1による認識率

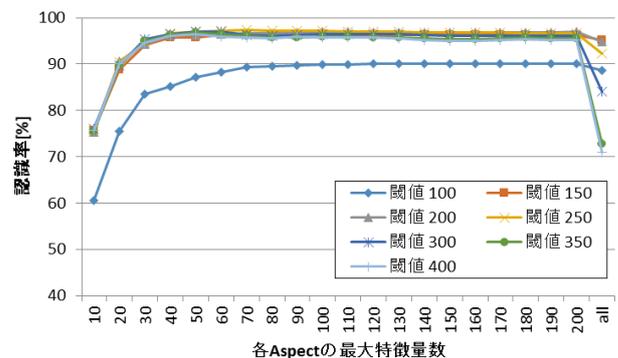


図17 弁別性と安定性を考慮した手法2による認識率

8.3.3 オクルージョンを加えたテストデータによる認識実験

図 18 に示すようにオクルージョンを右から 50%加えたテストデータを作成した. このテストデータを与えたときの認識率を図 19, 図 20 に示す.



図 18 オクルージョン(50%)を加えたテストデータ

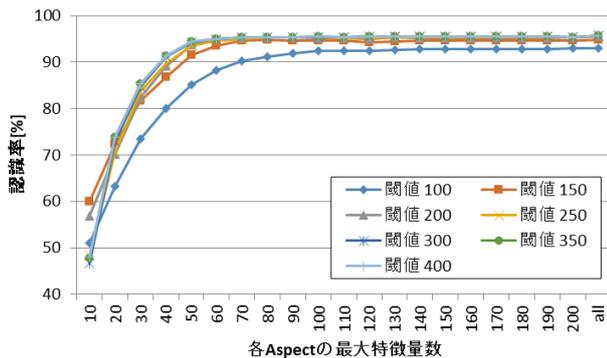


図 19 弁別性を考慮した手法 1 による認識率

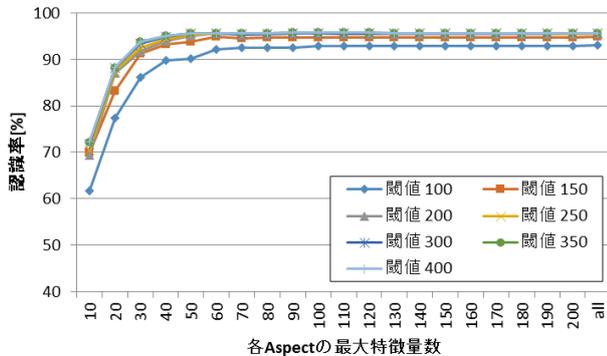


図 20 弁別性と安定性を考慮した手法 2 による認識率

8.4 パラメトリック固有空間との比較実験

8.3.1 節から 8.3.3 節と同様の認識実験を, 比較手法であるパラメトリック固有空間法で行った. パラメトリック固有空間の次元は, 累積寄与率が約 10%間隔になるように変更して実験を行った. 8.3.1 節から 8.3.3 節のテストデータによる認識率を図 21, 図 22, 図 23 に示す.

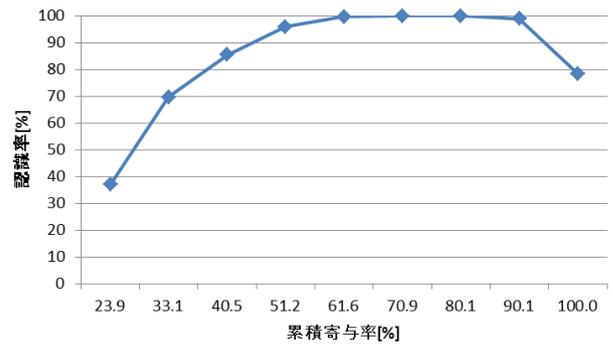


図 21 背景なしテストデータによる認識率

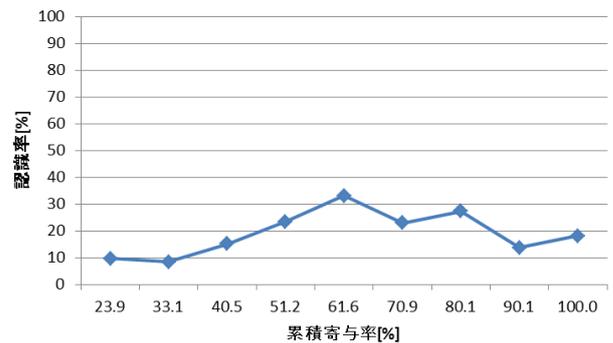


図 22 背景を合成したテストデータによる認識率

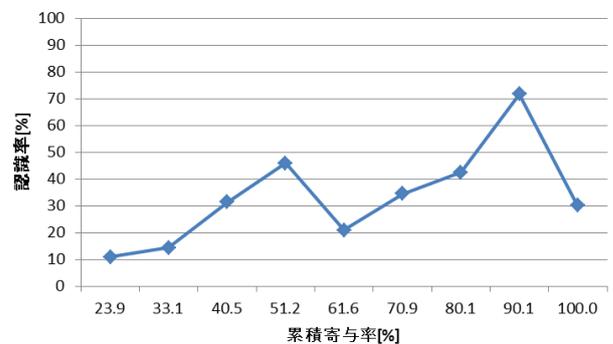


図 23 オクルージョンを加えたテストデータによる認識率

8.5 考察

ここでは実験で用いた, 弁別性の観点から特徴選択した手法 1 による認識率及び, 弁別性と安定性の観点から特徴選択を行った手法 2 による認識率と, パラメトリック固有空間法の認識率を比較する. 認識実験には 3 種のテストデータを与えた.

表 1 はそれぞれの認識実験の中で, 最も認識率が高い値を示す. テストデータに対して背景差分などを行わないで認識する場合には, パラメトリック固有空間法よりも提案手法の方が良い結果が得られた.

表 1 各手法による認識率の比較

	手法 1	手法 2	比較手法
背景混入なし	100.0%	100.0%	100.0%
背景混入あり	97.6%	97.4%	33.1%
オクルージョンあり	95.6%	95.8%	71.7%

8.3.2 節の背景を合成した際の実験から分かるように、学習画像から抽出された局所特徴全てを認識に使用するよりも、弁別性を考慮して特徴選択を行う手法 1 と、弁別性と安定性を考慮して特徴選択を行う手法 2 で提案するように特徴選択を行った方が、背景混入がもたらすノイズにロバストであると言える。

また、8.3.3 節のオクルージョンを与えたテストデータによる認識率から、弁別性を考慮して特徴選択を行う手法 1 よりも、弁別性と安定性を考慮して特徴選択を行う手法 2 の方が、各 Aspect の最大特徴量数が少ない際でも認識率が低下しづらく、オクルージョンに対して安定性が高いと言える。このことから、グルーピングによる共通性の高い特徴を選択することは、少ない特徴量数で認識率を高めることができると考えられる。

9. おわりに

提案手法では局所特徴を基にした物体認識を行った。局所的な情報を利用することで、物体にオクルージョンが発生している状況や、未知の背景がある場合にも高い認識率が得られた。この際、隣接する複数の見えのグルーピングを行うことで、より物体認識に有効な局所特徴を選択することが実験で示された。このとき、データベース上の局所特徴が削減されることによる、認識速度の向上も確認できた。局所特徴には対象物の回転、スケール変化に頑健という利点がある。比較対象である、パラメトリック固有空間法は、回転やスケール変化があると照合のずれが発生し、認識率が低下することが考えられる。今後は、提案手法の方が、回転やスケール変化に頑健である事について検証していく。

また、より広域の画像から認識対象物を探索する際に、ある決められた局所領域を順にスライドさせて照合していく手法がある。このとき、パラメトリック固有空間法では、学習データと入力データで少しのズレが照合に大きく影響することが考えられる。これに対して、提案手法では、窓枠を大きくしても照合が可能になることが期待できる。

参考文献

- 1) 村瀬洋, S.K.Nayar: 2次元照合による3次元物体認識—パラメトリック固有空間法, 信学論(D-II), vol.J77-D-II, no.11, pp.2179-2187 (1994).
- 2) 村瀬洋, S.K.Nayar: 多重解像度と固有空間表現による3次元物体のイメージスポッティング, 情報学論, vol.36, no.10,

pp.2234-2243 (1995).

- 3) K. Ohba and K. Ieuchi: Detectability, Uniqueness, and reliability of eigen windows for stable verification of partially occluded objects, IEEE Trans. Pattern Anal. Mach. Intell., vol.19, no.9, pp.1043-1047 (1997).
- 4) O. Maron and T. Lozano-Perez: A Framework for Multiple-Instance Learning, Advances in Neural Information Processing Systems 10, pp570-577, London, England, December (1997).
- 5) O. Maron and A. Ratan: Multiple-Instance Learning for Natural Scene Classification, Proceedings 15th International Conference on Machine Learning, pp341-349, Madison, Wisconsin, USA, July (1998).
- 6) S. Dutta Roy and N. Kulkarni: Active 3-D Object Recognition using Appearance- Based Aspect Graphs, In Proceedings of the Indian Conference on Computer Vision, Graphics and Image Processing, pp.40-45 (2004).
- 7) Lowe, David G: Distinctive image features from scale-invariant keypoints, International journal of computer vision, vol.60, no.2, pp.91-110 (2004).
- 8) 福井崇之, 和田俊和, 大池洋史: 人物顔画像の階層的クラスタリングと共通局所特徴量抽出の同時実行による顔モデル生成, 電子情報通信学会技術研究報告, vol.112, no.385(PRMU2012 84-129), pp23-28 (2012).
- 9) Keita Yuasa, Toshikazu Wada: Keypoint Reduction for Smart Image Retrieval, Multimedia(ISM), 2013 IEEE International Symposium on. IEEE, pp.351-358 (2013).
- 10) S.A.Nene, S.K.Nayar and H.Murase: Columbia Object Image Library (COIL-20), Technical Report CUCS-005-96 (1996).
- 11) Joseph Tighe and Svetlana Lazebnik: SuperParsing: Scalable Nonparametric Image Parsing with Superpixels, European Conference on Computer Vision (2010).

付録 最大親和度のグルーピング結果

指定グループ数: 2~5 のときに、各モデルの最大親和度を得たグルーピング結果を図 24 に示す。

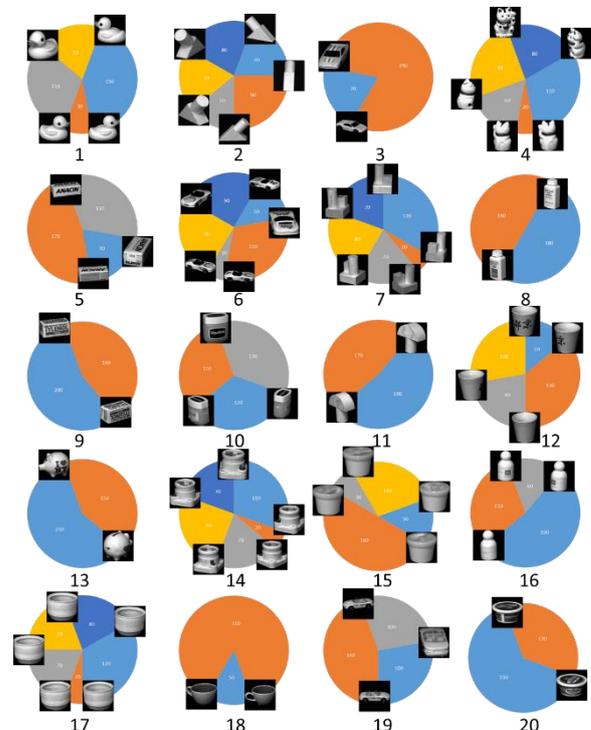


図 24 最大親和度のグルーピング結果