前景と背景情報の共起表現を用いたBag-of-featuresによる画像分類

永橋　知行†　　伊原　有仁†　　藤吉　弘亘†

† 中部大学大学院工学研究科 〒 487-8501 愛知県春日井市松本町 1200
E-mail: †{nagahashi,ai}@vision.cs.chubu.ac.jp, ††hf@cs.chubu.ac.jp

あらまし　前景と背景情報の共起表現を用いた Bag-of-features による画像分類法を提案する．Bag-of-features では，ヒストグラムにより特徴を表現するため物体の位置情報は無視され，対象カテゴリからなる前景領域のみで特徴量を記述することで精度が向上すると考えられている．そこで，我々は予め画像セグメンテーションにより前景領域を抽出し，その領域のみで特徴量を記述する方法と，通常の Bag-of-features の認識率を調査する．実験結果から，前景領域のみで特徴量を記述するより，前景と背景領域それぞれから記述することで認識精度が向上することがわかった．選択された特徴量を調べた結果，Bag-of-features による画像分類では前景特徴だけでなく背景特徴も認識に使用しており，画像中のシーン全体をモデリングする手法であることが判明した．上記の調査結果に基づいて，我々は前景と背景の局所特徴の共起性に着目した 2+1 次元ベクトル量子化ヒストグラムを用いた Bag-of-features を提案する．評価実験により，提案手法は通常の Bag-of-features より認識率を約 3.8%向上させることができた．

キーワード　画像分類，Bag-of-features，SIFT 特徴量

Object Category Recognition by Bag-of-Features using co-occurrence representation by foreground and background information

Tomoyuki NAGAHASHI†, Arihito IHARA†, and Hironobu FUJIYOSHI†

† Dept. of Computer Science, Chubu Univ. Matsumoto 1200, Kasugai, Aichi, 487-8501 Japan
E-mail: †{nagahashi,ai}@vision.cs.chubu.ac.jp, ††hf@cs.chubu.ac.jp

Abstract　This paper proposes an image classification method based on a bag-of-features algorithm that uses co-occurrence expressions of foreground and background information. Since bag-of-features algorithms use histograms to express features, they ignore object position information. They are considered more precise since they only code feature values in foreground regions comprised of the target categories. We investigated a method that first uses image segmentation to extract foreground regions, then codes only the feature values for those regions. We compared this method's recognition rate to the recognition rate of the standard bag-of-features algorithm. Our experimental findings demonstrated that coding feature values from both foreground and background regions resulted in more precise recognition than coding feature values from foreground regions only. By examining selected feature values, we showed that bag-of-features image classification is an algorithm that models entire scenes in images, used in recognition of both foreground and background features. Based on these findings, we have proposed a bag-of-features algorithm that focuses on the co-occurrence of local features in the foreground and background, and uses 2+1D vector quantized histograms. Our evaluation testing showed that the proposed algorithm had a recognition rate about 3.8% better than the standard bag-of-features algorithm.

Key words　Objet category recognition，Bag-of-features，SIFT feature

1. はじめに

制約のない実世界シーンの画像に対して，計算機がその中に含まれる物体を一般的な名称で認識することを一般物体認識と呼ぶ [1]．一般物体認識問題における画像中の物体がどのカテゴリに属するかを求める画像分類問題に対して，近年では，Bag-of-features モデル [2] が提案され，多くの研究が取り組まれている．Bag-of-features は，画像を局所特徴量の集合とみなし，局所特徴量のヒストグラムをその画像の特徴量としてカテゴリを認識する手法である．Csurka ら [2] は，Bag-of-features に用いる局所特徴量にはアフィン変換に不変な特徴点 [3] を，識別器には SVM を用いる手法を提案している．また，Fei-Fei ら [4] は，局所特徴量にグリッド点に対して SIFT

特徴量 [5] で記述し，識別器に generative model である LDA(Latent Dirichlet Allocation) を用いる手法を提案し，13 カテゴリの自然風景画像を約 64%で認識可能であることを報告している．

Bag-of-features では，画像特徴を局所特徴量のヒストグラムで記述するため，局所特徴量の位置情報は利用しないアプローチである．近年では，Bag-of-features に局所特徴量の位置情報を考慮することによる認識精度の向上が試みられており，画像中の空間的な位置関係を記述する手法 [6] と画像中の前景領域から特徴量を記述する手法 [7] [8] [9] が提案されている．局所特徴量の空間的な位置情報を記述する手法として，Lazebnik らは，多重解像度ヒストグラムで表現する Spatial Pyramid Matching [6] を提案した．Spatial Pyramid Matching は，画像をグリッド分割し，その小領域単位の位置関係を記述することができる．一方，前景領域の局所特徴量を利用する手法として，Marcin ら [7] は，学習データのマスク画像を用いて，特徴量の関係から入力画像の前景領域に合わせて重み分布を求め，この重み分布を利用してベクトル量子化ヒストグラムを作成することで，背景情報を抑制する手法を提案した．また，鈴木ら [8] は，抽出された特徴量を SVM により前景と背景に識別し，前景特徴のみで特徴量を記述することで認識精度を向上させている．Bosch ら [9] は，学習画像との特徴量の類似度が高くなる注目領域（ROI）を決定し，その領域からシェイプやアピアランス特徴を Multiple Kernel Learning により学習する手法を提案している．これらの前景領域から特徴記述する手法では，背景情報はノイズと考え，背景を除去し，前景のみで特徴量を記述することで認識率が向上するという考えに基づいている．しかしながら，一方では物体間の関係をコンテキストとして利用することで，認識精度を向上させる手法 [10] や背景のみの情報だけでも認識が可能 [11] といった報告がされている．

この場合，対象カテゴリでない物体は背景に属していることになる．このように，画像分類問題において，Bag-of-features がどのような特徴を捉え，有効に働くかは明確でないといえる．

そこで，本稿ではまず，対象カテゴリ領域を前景，対象カテゴリでない物体は背景とし，Bag-of-features の前景と背景領域の特徴量を解析し，カテゴリ認識に有効な特徴量を調査する．前景領域を既知とし，画像全体から特徴量を抽出する方法，前景領域のみから特徴量を抽出する方法，前景領域と背景領域からそれぞれ特徴量を抽出する方法の認識率を比較する．識別器に AdaBoost を用いることで，弱識別器にどのような特徴量が選択されているかを調査し，前景情報と背景情報がどのように有効であるかを述べる．次に，調査により得られた結果から，前景と背景の局所特徴の共起性を用いた Bag-of-features として，前景と背景の 2+1 次元ベクトル量子化ヒストグラムを提案し，その有効性を示す．

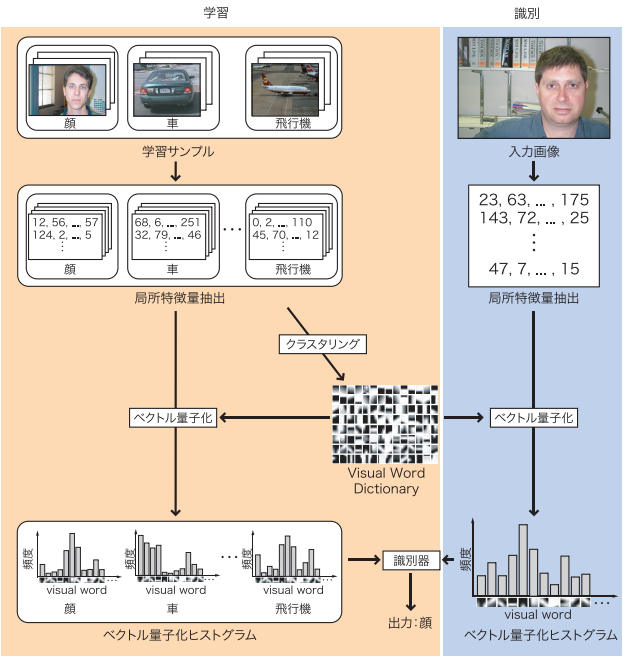

図 1　Bag-of-features の流れ

Fig. 1　Overview of Bag-of-features.

2.　Bag-of-features と画像局所特徴量

本章では，Bag-of-features による物体認識について述べる．Bag-of-features は，文書分類手法である Bag-of-words [12] を画像に適用した手法であり，Bag-of-words で文章を単語の集合と見なし，単語の語順を無視してその頻度で文章の分類を行うのと同様に，画像を局所特徴量の集合と見なし，その位置情報を無視して画像を認識する．Bag-of-features では，図 1 に示すように，はじめに画像から局所特徴量の抽出を行い，ベクトル量子化する．ベクトル量子化に用いるコードブックを，visual word dictionary と呼び，予め学習画像から作成しておく．ベクトル量子化された特徴量を用いて，ベクトル量子化ヒストグラムを作成する．得られたベクトル量子化ヒストグラムをその画像の特徴量として，識別器に入力することで物体カテゴリを計算する．

2.1　局所特徴量の抽出

本稿では，局所特徴量に SIFT 特徴量 [5] を用いる．SIFT 特徴量は．画像間の対応点探索を目的とした局所特徴であるため，DoG の極値をキーポイントとするが，画像分類問題ではキーポイントをグリッド上のサンプリング点を使用することで精度向上することが報告されている [4]．そこで，本手法では，キーポイントを 10 ピクセルごとのグリッド点とし，その点に対して 10, 20, 30, 40, 50 のスケールから SIFT 特徴量を抽出する．SIFT 特徴量は，回転変化，輝度変化に対して頑健な局所領域の記述を行うことができるため，Bag-of-features の局所特徴に有効とされている．

2.2　ベクトル量子化ヒストグラムの作成

各カテゴリの画像から得られた局所特徴量をベクトル

量子化する．Bag-of-features では，ベクトル量子化に用いられるコードブックを visual word dictionary，コードブックのセントロイドを visual word と呼ぶ．visual word dictionary は，各カテゴリの学習サンプルから得られる局所特徴量をクラスタリングすることで得る．本手法では，クラスタリング手法に k-means を用いる．入力された局所特徴量がクラスタリングの結果，visual word dictionary のどのクラスタに属するかを計算することでベクトル量子化し，1 枚の画像から visual word を要素とするヒストグラムを特徴量とする．

2.3 AdaBoost による識別

Bag-of-features における識別器には，通常マルチクラス SVM が用いられる．本稿では，識別に用いられる特徴量の解析が容易な AdaBoost [13] を識別器に利用する．AdaBoost 識別器は，対象カテゴリであるかないかの 2 クラスの分類しかできない．AdaBoost によるマルチクラス識別には，三宅らの手法 [14] と同様に，One-Versus-Rest 法として，カテゴリごとに識別器を構築し，それぞれの識別器の正規化された応答の最大値からカテゴリを決定する．

3. Bag-of-features における有効な特徴量の調査

本章では，Bag-of-features において前景領域のみで特徴記述する方法と背景情報を含んだ特徴記述方法の認識率を調査する．また，AdaBoost により選択された弱識別器の解析と，特徴量を可視化した結果から認識に有効な特徴量の傾向を調査する．

3.1 調 査 概 要

Bag-of-features において，前景と背景がどのように捉えられているかを確認するために，以下の異なる特徴抽出方法を比較する．

- **画像全体**　画像全体から局所特徴量を抽出し，ベクトル量子化ヒストグラムを作成する (図 2(a))．
- **前景のみ**　抽出された局所特徴量の位置が前景領域内にある局所特徴量のみを用いてベクトル量子化ヒストグラムを作成する (図 2(b))．
- **前景/背景領域**　局所特徴量の位置により，前景領域と背景領域に分離し，それぞれの領域に対して，ベクトル量子化ヒストグラムを作成する (図 2(c))．

SIFT 特徴量において，これらの手法により特徴記述をし，AdaBoost を用いた One-Versus-Rest 法によるマルチクラス識別器を構築する．

評価には，画像分類のためのデータベースである Caltech256 [15] を用いる．Caltech256 にはセグメンテーションデータがないため，各画像のセグメンテーション領域は手動により求めたものを使用する．すべてのセグメンテーションデータを用意することが困難なため，

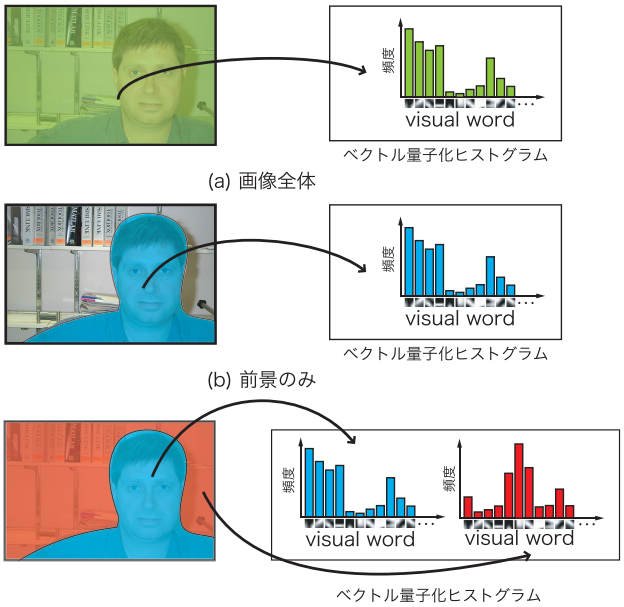

図 2　特徴抽出方法
Fig. 2　Feature extraction method.

表 1　各手法の調査結果
Table 1　Recognition rate.

画像全体	前景のみ	前景/背景領域
0.64	0.71	0.77

Caltech256 から，前景と背景が含まれている画像枚数が多い butterfly, elephant, hawksbill, helicopter, motorbikes, airplanes, car-side, faces-easy, toad の 9 カテゴリを評価実験に用いる．評価値には，f-measure を用いる．各カテゴリからランダムに 30 枚ずつ選びそれらを学習用画像とし，残りを評価用画像とする．これを，3 回試行し，その f-measure の平均値により評価する．また，ベクトル量子化に用いる visual word dictionary のサイズは事前実験から 100 とする．

3.2 調 査 項 目

本稿で調査する内容を以下に示す．

- **認識率から得られる有効な特徴の傾向**　各特徴抽出方法の認識率を比較し，背景情報を利用する有効性を確認する．
- **背景情報の有効性**　学習データから得られるベクトル量子化ヒストグラムの visual word を調査することで，Bag-of-features において，前景と背景がどのように処理されているかを確認する．

3.3 認識率から得られる有効な特徴の傾向

表 1 に，画像全体から特徴記述する方法，前景のみから特徴記述する方法，前景と背景から特徴記述する方法の認識率の調査結果を示す．表 1 より，画像全体から特徴記述する方法と前景のみから特徴記述する方法を比較すると，前景のみから特徴記述することで認識率を約 7%向上していることがわかる．次に，前景のみから特徴記述する方法と前景と背景から特徴記述する方法を比較

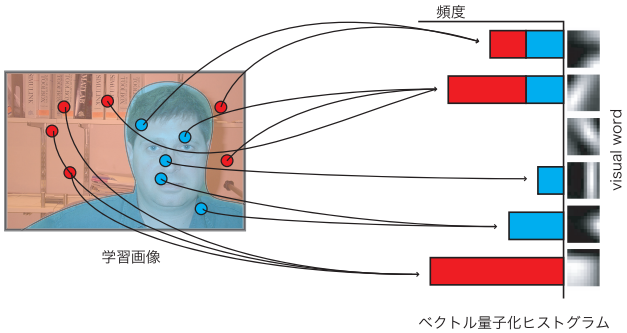

図 3　ベクトル量子化ヒストグラム
Fig. 3　Vector quantization histogram.

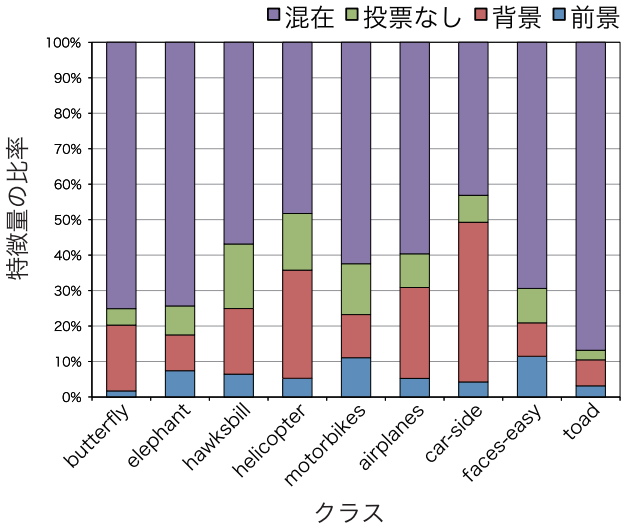

図 4　特徴量の比率
Fig. 4　The ratio of selected features.

すると，前景と背景から特徴記述する方法が約 5.6%認識精度が向上していることがわかる．前景のみから特徴抽出する方法と前景と背景から特徴抽出する方法の違いは，背景特徴の有無のみであるため，背景情報を追加したことで認識精度が向上しており，前景だけでなく背景にも認識に有効な特徴が存在するといえる．

3.4　背景情報の有効性

次に，一般的な Bag-of-features である画像全体から特徴量を抽出する方法における有効な特徴量について調べる．この手法では，図 3 に示すように，ベクトル量子化ヒストグラムの各 visual word に前景と背景の特徴が混在しているため，弱識別器だけでは背景情報をどのように使用しているかを判断することが困難である．そこで，AdaBoost により選択されたベクトル量子化ヒストグラムの visual word に対し，学習データに前景と背景が混在しているかを調査する．各識別器のポジティブデータと弱識別器から，前景のみで作成された visual word，背景のみで作成された visual word，投票がない visual word，前景と背景の両方が混在した visual word の比率を求める．図 4 に，前景，背景，投票なし，混在した特徴の比率を示す．図 4 から，前景と背景の特徴が選択されていることがわかる．また，前景と背景が混在した visual word が多いことがわかる．表 1 の実験結果から，前景と背景から特徴記述する方法は，前景と背景が混在した visual word を分離して記述することができるため認識精度が向上したと考えられる．また，画像全体から特徴記述をしても，前景だけでなく背景情報も用いた認識を実現しており，Bag-of-features では前景と背景の情報を利用してシーン全体をモデリングしているといえる．

4.　前景と背景の共起表現による画像分類

Bag-of-features による画像分類では前景情報だけでなく，背景情報も使用されており，それぞれの領域で記述する方法が有効であることがわかった．そこで，前景と背景の共起性を用いて画像分類精度を向上させる手法を提案する．従来，visual word の共起性を記述することで認識精度が向上することが知られている [16]．提案手法では，前景と背景の visual word の共起性を記述することで認識精度の向上を目指す．提案手法の流れを図 5 に示す．学習では，キーポイント識別器とカテゴリ識別器の 2 つの識別器を構築する．キーポイント識別器は，マスク画像を用いて前景と背景のキーポイントを学習用データとして使用し，キーポイント識別器を構築する．カテゴリ識別器は，前景と背景のキーポイントから，2 次元と 1 次元のベクトル量子化ヒストグラムを特徴量とし，カテゴリ識別器を構築する．未知入力画像に対しては，グリッドで与えたキーポイントを，予め構築したキーポイント識別器を用いて，前景と背景に識別する．そして，識別された前景と背景のキーポイントを前景と背景の visual word dictionary を参照して，2 次元と 1 次元のベクトル量子化ヒストグラムを作成する．このベクトル量子化ヒストグラム用いて，予め構築したカテゴリ識別器により，画像のカテゴリを識別する．

4.1　キーポイント識別器の構築

学習データでは，マスク画像からキーポイントを前景と背景に分ける．しかし，未知入力画像にはマスク画像を用いることができないため，キーポイントを前景と背景に識別する手法が必要である．前景情報を用いた Bag-of-features で用いられている前景と背景の識別手法として，SVM による識別 [8] と矩形による注目領域の検出 [9] が提案されている．SVM による識別 [8] では，キーポイントの局所特徴量を用いて SVM により前景と背景の識別を行う手法である．注目領域の検出 [9] では，学習画像には手動で注目領域が与えられ，入力画像に対しては学習画像の注目領域から得られる特徴量との類似度が最も高くなる矩形領域を選択している．本手法は 2 次元ベクトル量子化ヒストグラムを用いるため，前景と背景の境界が明確なほどパフォーマンスが良いと考えられる．そこで，鈴木らが提案した局所特徴の識別法 [8] によりキーポイント識別器を構築する．キーポイント識別器の構築に使用する学習用データは，手動により作成し

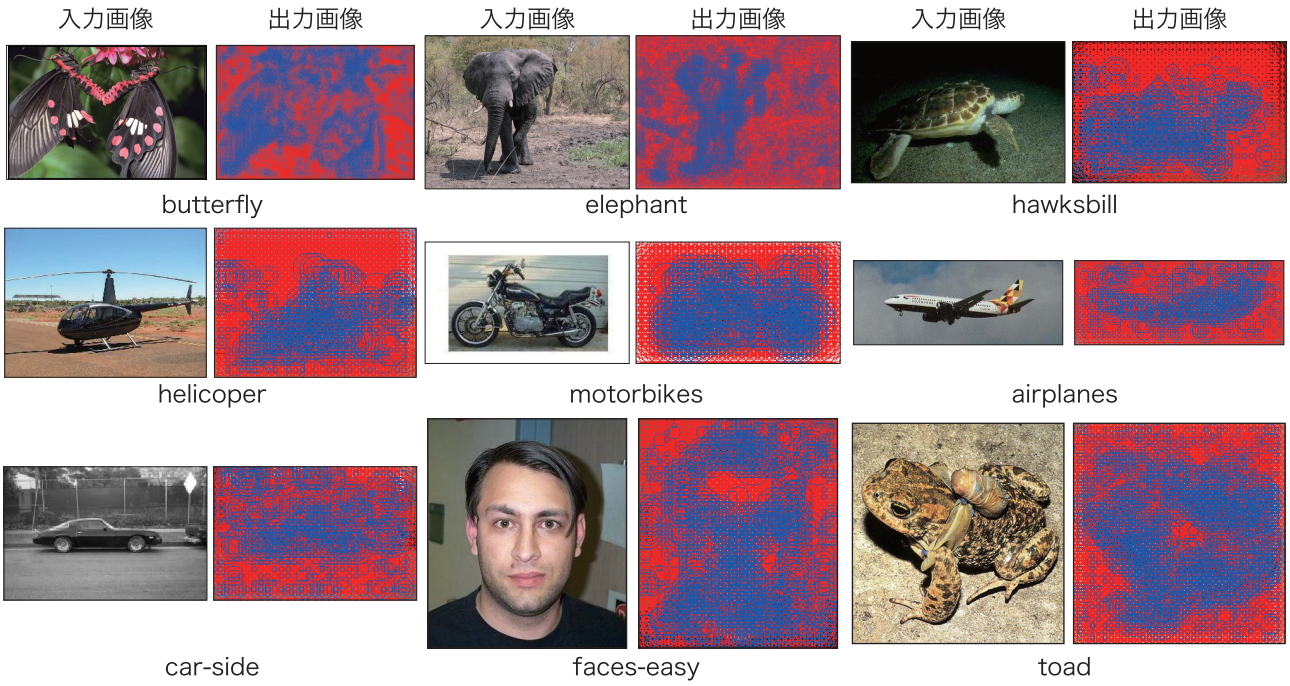

図 6　キーポイント識別による前景と背景の識別結果例

Fig. 6　Example of keypoint classification result.

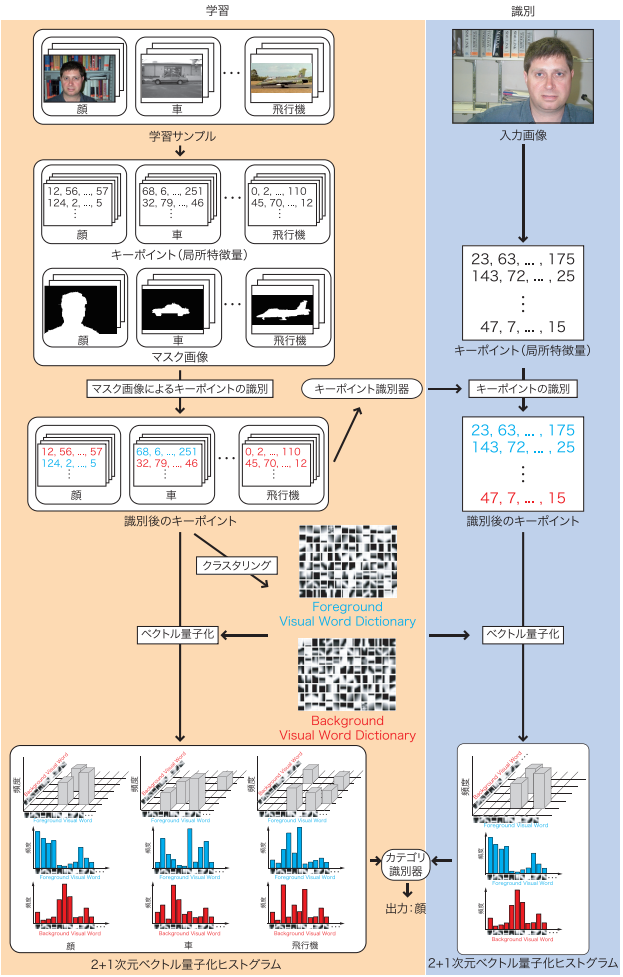

図 5　提案手法の流れ

Fig. 5　Overview of proposed method.

たマスク画像を用いる．マスク画像から得られる前景のキーポイントと背景のキーポイントの局所特徴量を用いて SVM によりキーポイント識別器を構築する．今回は SVM のライブラリとして LIBSVM(注1)を用いた．この SVM を使用して構築したキーポイント識別器により，入力画像のキーポイントを前景のキーポイントと背景のキーポイントに識別する．図 6 にキーポイント識別による前景と背景の識別結果を示す．評価用データ 2,411 枚を用いた実験より，約 77.98%の識別率を得た．

4.2　2+1 次元ベクトル量子化ヒストグラムの作成

キーポイント識別器により前景と背景に分けられた局所特徴を用いて，図 7 に示すように 2 次元と 1 次元のベクトル量子化ヒストグラムを作成する．はじめに，識別された前景のキーポイントは前景の visual word dictionary，背景のキーポイントは背景の visual word dictionary を参照することでベクトル量子化する．次に，前景のキーポイントが持つスケールを n 倍した領域に存在する背景のキーポイントと対応付けて，2 次元空間上で交差した visual word に投票することで 2 次元ベクトル量子化ヒストグラムを作成する．このとき，2 次元ベクトル量子化ヒストグラムの投票に使用されなかった局所特徴を用いて前景と背景の 1 次元ベクトル量子化ヒストグラムを作成する．学習では，マスク画像により識別したキーポイントを用いるのに対し，未知入力画像では，キーポイント識別器を用いて 2 次元ベクトル量子化ヒストグラムを作成する．

5.　評 価 実 験

提案手法の有効性を確認するために，評価実験を行う．比較対象として，従来の Bag-of-features を従来法 1，前

(注1)：http://www.csie.ntu.edu.tw/c̄jlin/libsvm/

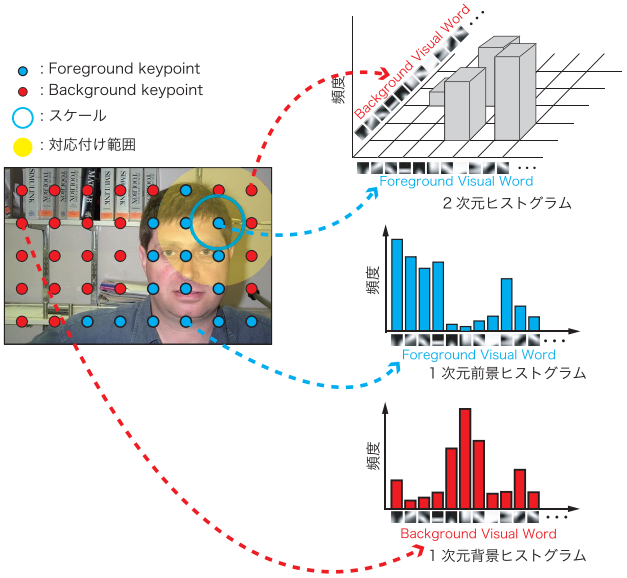

図 7　2+1 次元ベクトル量子化ヒストグラムの作成
Fig. 7　2+1D vector quantization histogram.

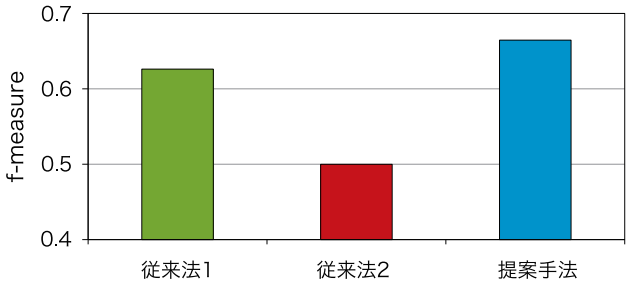

図 8　各手法の認識率
Fig. 8　Recognition rate.

景と背景領域から特徴抽出する Bag-of-features を従来法 2 とし，提案手法である 2+1 次元ベクトル量子化ヒストグラムによる Bag-of-features と比較する．評価実験は，3.1 章と同様のデータセットと評価法を用いる．学習データは前景と背景のマスクデータを使用し，評価データはキーポイント識別により前景と背景を識別する．visual word dictionary は各手法で共通とする．従来法との比較には，スケールが 4 倍の結果を用いる．

5.1　従来手法との比較

図 8 に，各手法における認識率を示す．図 8 から，通常の Bag-of-features である従来法 1 と前景と背景からそれぞれ特徴抽出する従来法 2 を比較すると，認識率が約 12.6%低下していることがわかる．前景と背景が既知の場合では，前景と背景領域からそれぞれ特徴抽出することで認識率を向上させることができたが，キーポイント識別器の誤識別が含まれるため従来の Bag-of-features より認識率が低下したと考えられる．しかし，提案手法は，従来法 1 と比較し認識率を約 3.8%向上させることができていることがわかる．

5.2　共起表現する範囲の傾向

提案手法において，前景と背景キーポイントを対応付ける範囲を前景キーポイントが持つスケールを基準とし

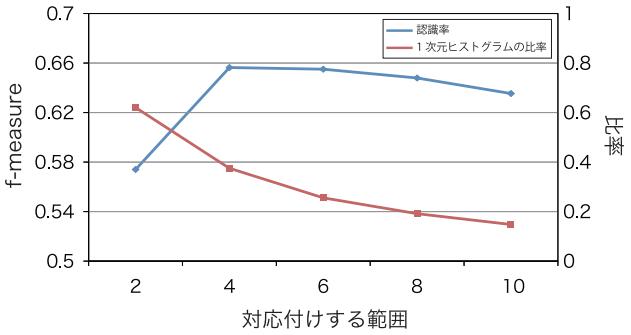

図 9　前景と背景の対応付ける範囲による認識率
Fig. 9　Recognition rate by changing scale.

て決定している．そこで，対応付ける範囲を前景キーポイントが持つスケールの 2 倍，4 倍，6 倍，8 倍，10 倍と変化させたときの画像分類精度を調べる．図 9 に対応付けする範囲を変化させたときの認識率と 1 次元ヒストグラムに使用される局所特徴の比率を示す．図 9 から，対応付けする範囲を大きくすることにより，1 次元ヒストグラムに利用される局所特徴が減少していることがわかる．また，キーポイントのスケールの 4 倍ときが最も認識率が高い認識率を得ることができた．対応付けするスケールの範囲を大きくすることで認識率が低下していることから，局所特徴の共起性の表現には空間的な制約が有効であるといえる．また，1 次元ヒストグラムに使用される局所特徴が減少に伴ない認識率が低下しているため，2 次元ヒストグラムで表現できない特徴を 1 次元ヒストグラムが補っていると考えられる．

5.3　考　　察

提案手法の有効性を示すために，2 次元ヒストグラムの効果と認識に利用された特徴量について考察する．

5.3.1　2 次元ヒストグラムの効果

従来法 2 と提案手法のコンフュージョンマトリクスを図 10 に示す．従来法 2 では butterfly と誤識別した数が 245，toad と誤認識した数が 196 であるが，提案手法では 135, 95 と誤識別が減少していることがわかる．ここで，提案手法による特徴表現がどのような効果があるかを調査するため，butterfly, elephant, toad の従来法 2 の前景と背景の 1 次元ヒストグラムと，提案手法の 2 次元ヒストグラムを図 11 に示す．図 11 の 1 次元ヒストグラムから，toad と elephant で同じ前景の visual word で頻度が高く，toad と butterfly では同じ背景の visual word で頻度が高いことから，toad の特徴的な visual word は，toad と butterfly, elephant を分離することが困難である．しかし，前景と背景を 2 次元ヒストグラムで表現することで，前景と背景の頻度の高い visual word のみで toad と elephant, buttefly を分離可能な特徴表現が可能となる．

5.3.2　認識に利用された特徴量の調査

AdaBoost の各弱識別器が，どのような位置情報を持つ特徴量を選択しているかを調査する．visual word が

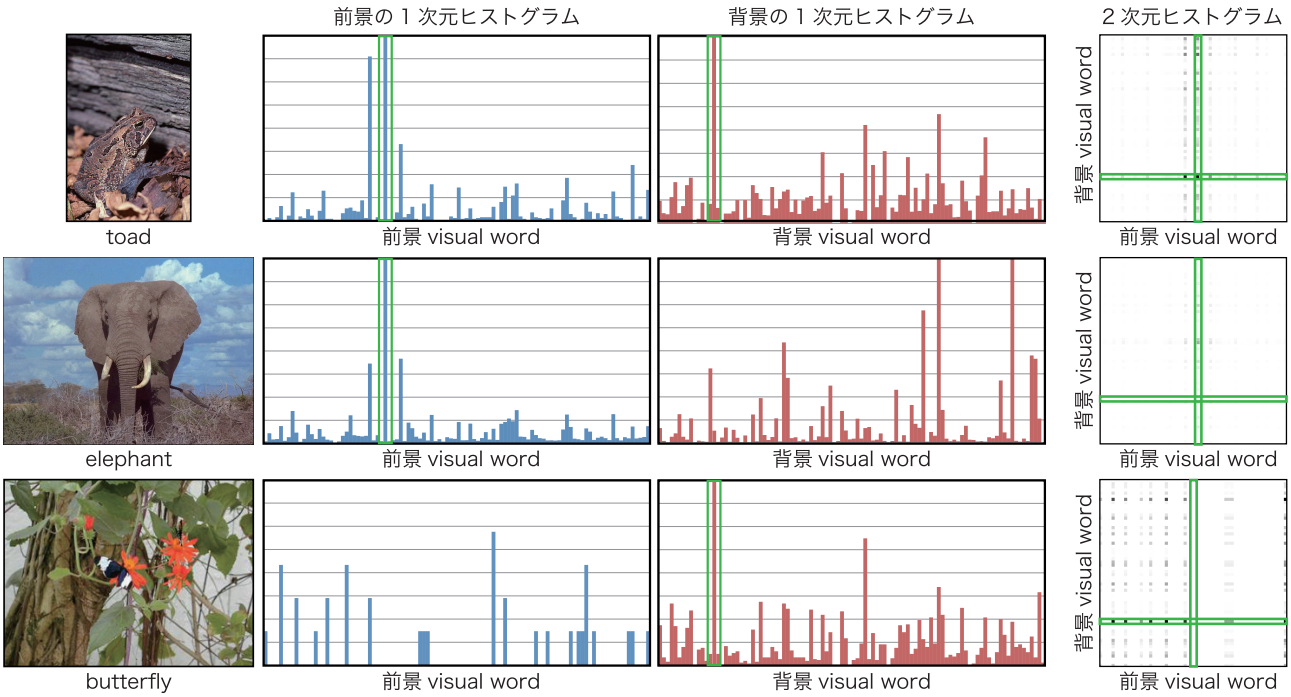

図 11　ベクトル量子化ヒストグラム例

Fig. 11　Example of vector quantization histogram.

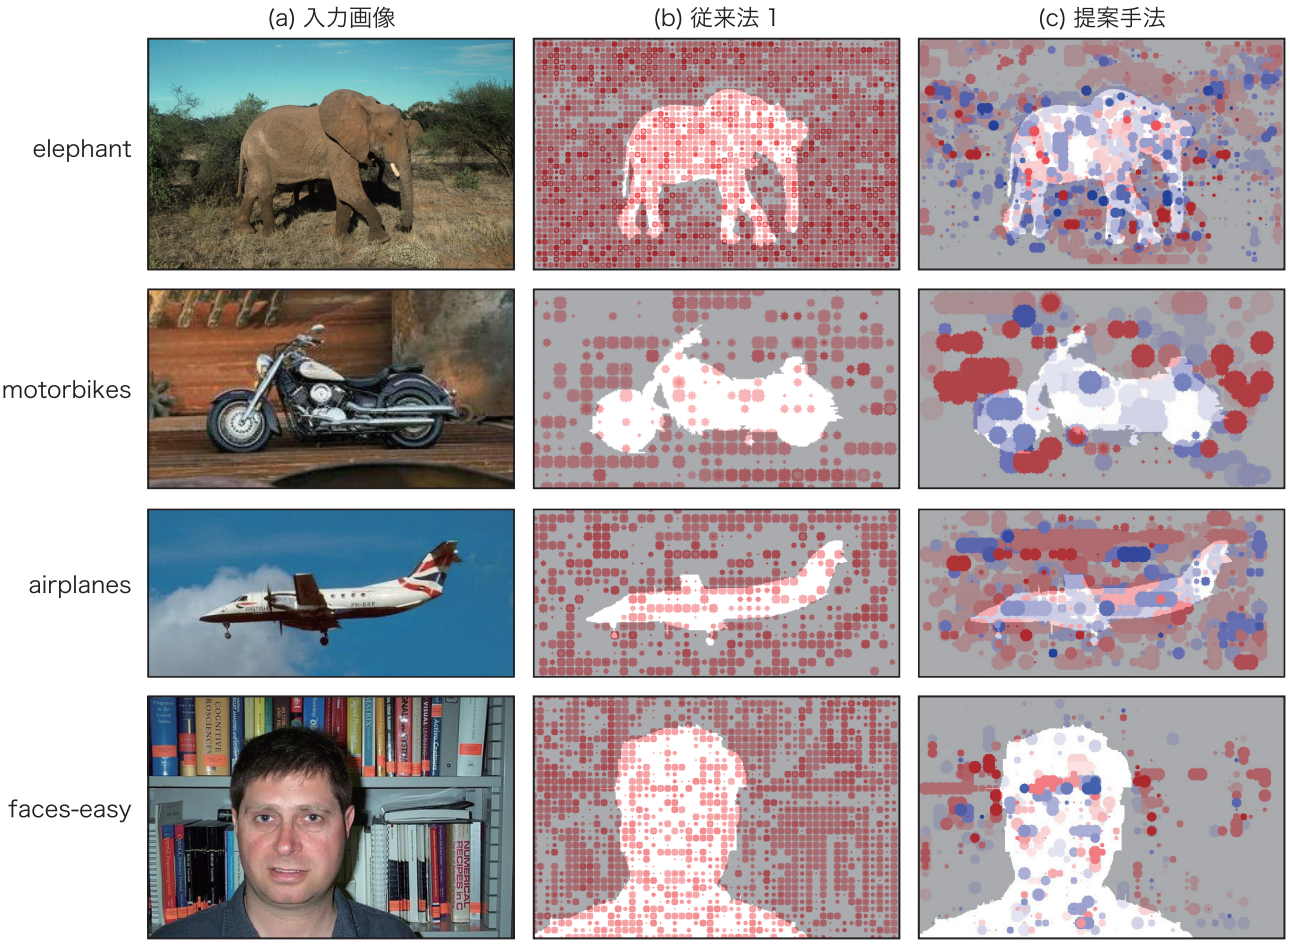

図 12　選択された特徴量の可視化例

Fig. 12　Example of visualization of select features.

画像中のどの位置から抽出された特徴なのかを調べることで，認識に使用されている特徴の位置情報を確認することができる．選択された特徴量の輝度値に AdaBoost の弱識別器の重みを利用し，色が濃いほど有効な特徴として可視化画像を作成する．また，前景と識別された局所特徴を青，背景と識別された局所特徴を赤とする．従

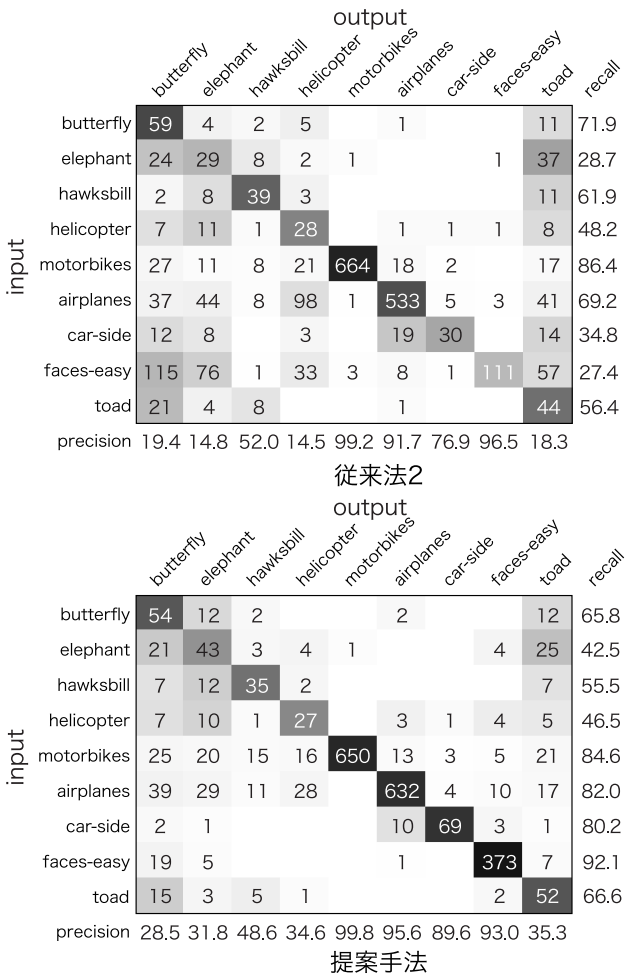

図 10　コンフュージョンマトリクス

Fig. 10　Confusion matrix.

来法で認識に失敗し提案手法で正解した画像の選択された特徴量の可視化例を図 12 に示す．図 12(b) から，従来法 1 では，画像全体から多くの特徴量が抽出されていることがわかる，そのため，visual word にはノイズが多く含まれており，これが誤識別した要因と考えられる．しかし，図 12(c) から，提案手法は従来法 1 より識別に利用されている特徴量が少ないことがわかる．提案手法では局所的な 2 つの局所特徴を用いてより分離能力が高い特徴量を表現可能なため，ノイズの影響が少なくなり認識することができたと考えられる．

6. おわりに

Bag-of-features における有効な特徴量の調査と，前景と背景の局所特徴の共起性を表現した 2+1 次元ベクトル量子化ヒストグラムによる Bag-of-features を提案した．はじめに，Bag-of-features の前景と背景領域の特徴量を解析し，カテゴリ認識に有効な特徴量の調査をした．その結果，前景と背景を分離して記述することで認識精度が向上することを確認した．

調査により得られた結果から，前景と背景の局所特徴の共起性を表現した 2+1 次元ベクトル量子化ヒストグラムによる Bag-of-features を提案した．実験により，従来法と比較し提案手法は 3.8%の認識精度向上を確認した．共起表現する範囲を変化させて実験を行った結果，共起表現は空間的な制約が有効であることがわかった．また，認識に利用された局所特徴を可視化し，従来法と提案手法でどのような特徴量が認識に利用されているかを調査した．その結果，提案手法では，局所的な 2 つの局所特徴を用いることで，ノイズの影響が少なくなることを確認した．

今後は，空間的な位置関係を考慮した共起表現による高精度化を目指す．

文　献

[1] 柳井啓司：“一般物体認識の現状と今後”, 情報処理学会論文誌. コンピュータビジョンとイメージメディア, **48**, 16, pp. 1–24 (2007).

[2] G. Csurka, C. R. Dance, L. Fan, J. Willamowski and C. Bray: “Visual categorization with bags of keypoints”, ECCV International Workshop on Statistical Learning in Computer Vision, pp. 1–22 (2004).

[3] K. Mikolajczyk and C. Schmid: “An affine invariant interest point detector”, ECCV (1), pp. 128–142 (2002).

[4] F.-F. Li and P. Perona: “A bayesian hierarchical model for learning natural scene categories”, CVPR, Vol. 2, pp. 524–531 (2005).

[5] D. G. Lowe: “Distinctive image features from scale-invariant keypoints”, IJCV, **60**, 2, pp. 91–110 (2004).

[6] S. Lazebnik, C. Schmid and J. Ponce: “Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories”, CVPR, pp. 2169–2178 (2006).

[7] M. Marszałek and C. Schmid: “Spatial weighting for bag-of-features”, CVPR, Vol. 2, pp. 2118–2125 (2006).

[8] 鈴木浩二, 松川徹, 栗田多喜夫：“サポートベクターマシンを用いた bag-of-features における局所特徴の初期特徴選択”, 電子情報通信学会パターン認識・メディア理解研究会, PRMU2008-240, pp. 7–12 (2009).

[9] A. Bosch, A. Zisserman and X. Munoz: “Image classification using rois and multiple kernel learning”, IJCV 2008 (2008).

[10] 岡部孝弘, 近藤雄飛, 木谷クリス真実, 佐藤洋一：“カテゴリの共起を考慮した回帰による複数物体認識”, 電子情報通信学会論文誌, **92-D**, 8, pp. 1115–1124 (2009).

[11] J. Zhang, M. Marszalek, S. Lazebnik and C. Schmid: “Local features and kernels for classification of texture and object categories: A comprehensive study”, IJCV, **73**, 2, pp. 213–238 (2007).

[12] C. D. Manning and H. Schtze: “Foundations of Statistical Natural Language Processing”, The MIT Press (1999).

[13] Y. Freund and R. E. Schapire: “A decision-theoretic generalization of on-line learning and an application to boosting”, Proceedings of the Second European Conference on Computational Learning Theory, pp. 23–37 (1995).

[14] 三宅信之, 滝口哲也, 有木康雄：“Multi-class adaboost を用いた雑音検出”, 情報処理学会研究報告. SLP, 音声言語情報処理, 136, pp. 7–12 (2006).

[15] G. Griffin, A. Holub and P. Perona: “Caltech-256 object category dataset”, Technical Report 7694, California Institute of Technology (2007).

[16] N. Herve and N. Boujemaa: “Visual word pairs for automatic image annotation”, ICME, Piscataway, NJ, USA, IEEE Press, pp. 430–433 (2009).