

RGB-D カメラを用いた屋内環境のカテゴリ識別

水谷 仁[†] マルティネスモズス オスカル^{††} 倉爪 亮^{††} 岩下 友美^{††}
長谷川 勉^{††}

[†]九州大学大学院システム情報科学府 〒 819-0395 福岡西区元岡 744

^{††}九州大学大学院システム情報科学府 〒 819-0395 福岡西区元岡 744

E-mail: [†]{mizutani,omozos}@irvs.ait.kyushu-u.ac.jp, ^{††}{kurazume,yumi,hasegawa}@ait.kyushu-u.ac.jp

あらまし 本論文では、Kinect など RGB-D カメラから得られる RGB 画像と距離画像を同時に用いて、オフィス、台所など空間の認識を行う、屋内環境のカテゴリ識別手法を提案する。提案手法では、まず RGB 画像を濃淡画像に変換し、その濃淡画像および同時刻に得られた距離画像を、それぞれ局所二値パターンと短縮局所二値パターン、および局所ヒストグラムを用いて、近傍画素間の関係を表現した特徴ベクトルに変換する。その後、得られた濃淡および距離情報の特徴ベクトルを結合し、サポートベクトルマシンやランダムフォレストなどの識別器により、撮影された空間の種別を認識する。廊下、台所、研究室、オフィス、学習室の 5 つの異なるカテゴリに属する部屋に対して認識実験を行った結果、未知の空間においても提案手法により高い識別性能が得られることを確認した。

キーワード 空間認識, 空間識別, RGB-D カメラ, Local Binary Pattern

1. はじめに

日常生活環境で人間に対して様々なサービスを行うロボットにとって、ロボット周囲の空間の識別は重要な機能である。空間の識別は、例えば高次の概念的表現も含め空間情報を獲得するセマンティックマッピング [1-6] や、物体認識精度の向上に向けた空間種別に応じた事前知識としての利用 [7,8]、あるいは空間毎に実行可能な行動計画の立案 [9-11] など、様々な応用が考えられる。

空間の識別では、ロボットはセンサ情報を基にロボットの置かれたそれぞれの場所に対応したラベルを割り付ける。異なる空間に対して与えられたラベルは通常、オフィスや台所、研究室など、人間がそれぞれの場所に対して与えるラベルと同様である。これにより、人とロボットの円滑なコミュニケーションの実現が期待される [12, 13]。

本論文では、RGB-D カメラ (Microsoft Kinect [14]) を用いた新たな屋内環境の識別手法を提案する。Kinect センサは、RGB 画像に加えて、距離画像を高速に得ることができる低価格のカメラであり、ロボット分野で盛んに利用されている。図 1 に Kinect センサから得られた RGB 画像と距離画像の一例を示す。



図 1 Kinect から得られる RGB 画像と距離画像の一例

本論文で提案する手法の基本的な考え方は、濃淡画像と距離画像を共に次元削減された局所 2 値パターン (Local binary patterns) のヒストグラムからなる特徴ベクトルへ変換するものである。ただし本手法では、RGB-D カメラから得られた RGB 画像を濃淡画像へ変換する。その後、濃淡画像、距離画像それぞれの特徴ベクトルを結合して最終的な特徴ベクトルとし、各部屋において得られた特徴ベクトルを識別器で学習する。本論文では識別器として、サポートベクターマシン (SVMs) とランダムフォレスト (RFs) を用いた。実験では提案手法を 5 つの異なる空間カテゴリ、すなわち廊下、研究室、オフィス、台所、および学習室に対して適用し、平均で 92% の識別率であった。また、濃淡画像、および距離画像をそれぞれ独立して用いる場合と比較して、両者を同時に用いることで識別率が向上することを確認した。

本論文の構成は以下ようになる。まず第 2 章で関連手法について述べた後、第 3 章で提案する濃淡画像と距離画像の局所 2 値パターンを用いた空間識別手法について説明する。次に第 4 章で 5 種類の異なる空間に対する RGB-D カメラを用いた識別実験の結果を示す。

2. 関連手法

近年、移動ロボットによる空間の識別技術が向上し、ロボットは様々なセンサにより典型的な屋内空間が識別できるようになった。例えば、レーザレンジファインダにより得られる 2D 画像は、屋内環境で異なる空間を識別するのに用いることができる。Mozos らは 2D 画像をいくつかの幾何学的特徴を含むベクトルに変換し、それらを AdaBoost を用いて分類した [1], [2]。Friedman らは、ポロノイ図の各点に条件付き確率場を適用した。各点は

それぞれの地点でレーザ計測により得られる空間の幾何的特徴も表している。さらに、BrunskillらはSpectral Clusteringを用いて、屋内環境の2D下位マップを作成した[3]。その下位マップは局所的な2Dスキャンから得られる特徴ベクトルを用いて分類される。また、Shiらは全体をスキャンせず、それぞれの独立したスキャンを意味的ラベルへ分類する手法を提案している[4]。

一方、視覚センサも空間の認識に多く用いられてきた。例えば、WuとRehgによる手法では、家の中の複数の空間の識別にCENTRIST記述子を用い[5]、サポートベクターマシンにより空間を識別している。この記述子は、Ojalaらが提案している局所二値パターンと同様である[6]。さらに、Ranganathanは空間の識別のためのPLISシステムを提案している[7]。この手法では変化点を見つけることにより、一続きの画像列を分割する。その後、分割された画像はSIFT特徴量とBag-of-featuresを用いてカテゴリ分類される。Torralbaらはウェアラブルカメラから得られる画像の局所特徴量と大域特徴量を用いて、隠れマルコフモデルにより屋内・屋外環境の特定の空間の認識および空間の識別を行った[8]。

空間を識別するために、異なる種類のセンサを組み合わせる試みも行われてきた。Rottmannらは2Dレーザスキャンと視覚による物体検出を組み合わせ、プースティングを用いて屋内環境の空間を識別した[9]。Pronobisらは複数の視覚とレーザによる手がかりを組み合わせ、サポートベクトルマシンを用いて、屋内環境の空間を識別した[10]。

3. 濃淡および距離画像を用いた空間の識別

3.1 局所二値パターンを用いた濃淡画像からの特徴量画像生成

局所二値パターン(Local Binary Patterns, LBP)演算子[6],[11]は、濃淡画像のテクスチャ分析と分類を目的にOjalaにより提案された。この演算子は、参照ピクセルとその近傍ピクセルの濃淡値の大小関係をベクトル形式で表すものである。本稿ではそれを濃淡画像と距離画像に適用し、典型的な屋内空間の識別を行う。

濃淡画像を用いた空間の識別では、まずKinectセンサから得られるRGB画像を濃淡画像に変換し、その濃淡画像をLBPを用いて特徴量画像に変換する。LBPは近傍画素の情報を用いて注目画素に新たなラベルを付加するものであり、今回は濃淡画像に対して以下のように適用した。まず、濃淡画像のそれぞれの画素*i*に対して、その画素値*p(i)*を周囲8近傍の画素値 $p_1(i), \dots, p_8(i) \in \mathcal{N}(p(i))$ と比較する。次に、それぞれの近傍画素ごとに二値{0,1}を以下の式で決定した。

$$b_j(i) = \begin{cases} 1, & p(i) > p_j(i) \\ 0, & \text{otherwise} \end{cases} \quad (j = 1, \dots, 8) \quad (1)$$

ただし、周囲8近傍の画素値 $b_j(i)$ ($j = 1, \dots, 8$)の配置は図2の通りである。得られた周囲画素の二値 $b_j(i)$ は時計回りに $\{b_0(i), \dots, b_8(i)\}$ の順番で並べられ、図3に示すように0から255までのラベル $v^{\text{LBP}}(i)$ に変換される。注目画素の値は、このラベル $v^{\text{LBP}}(i)$ により置き換えられ、LBPに変換された特徴量画像 T_{gray} が生成される。




図2 $b_j(i)$ ($j = 1, \dots, 8$)の配置




図3 中心画素に対するLBPの計算例。この例では236がセットされる

3.2 局所二値パターンを用いた距離画像からの特徴量画像生成

同様にKinectセンサから得られる距離画像に、LBPを適用して特徴量画像を得ることができる。しかし、Kinectセンサでは、計測不能箇所および計測範囲外の距離値にnanがセットされるため、距離画像に対して単純にLBPの計算ができない。そこで、距離値がnanである画素、あるいは前章のLBPの計算で周囲画素にnanが含まれる場合には、LBPの出力を256とした。従って、LBPを用いて得られた特徴量画像 T_{depth} の画素値 $v^{\text{LBP}+}(i)$ は以下のように計算される。

$$v^{\text{LBP}+}(i) = \begin{cases} 256, & \delta_{\text{nan}}(p(i)) \vee \exists \delta_{\text{nan}}(\mathcal{N}(p(i))) \\ v^{\text{LBP}}(i), & \text{otherwise} \end{cases} \quad (2)$$

ここで $\delta_{\text{nan}}(\cdot)$ は、もし距離値にnanが設定されていた場合には1を、それ以外は0を返す関数であり、 $v^{\text{LBP}}(i)$ はLBPにより得られた特徴量である(図3)。

濃淡画像および同時刻に得られた距離画像と、それらの局所二値パターンの例を図4に示す。

3.3 局所ヒストグラムおよび特徴量ベクトルの生成

3.1, 3.2項の方法で得られた特徴量画像 $T_{\text{gray}}, T_{\text{depth}}$ を以下の2つの方法でそれぞれ特徴ベクトル $\mathbf{x}_{\text{gray}}, \mathbf{x}_{\text{depth}}$ に変換する。

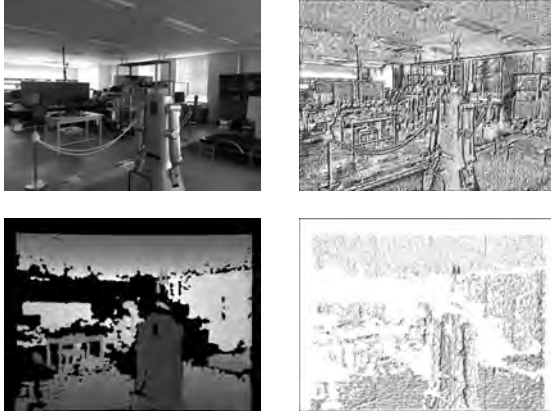


図 4 左列：“laboratory”の濃淡画像と距離画像，右列：それぞれの局所二値パターン画像

3.3.1 空間ピラミッドを用いた手法

まず，特徴量画像 T (T_{gray} および T_{depth}) に対して空間ピラミッド [12] を生成する．ただし，空間の大きさを表すレベル l を図 5 に示すように定義する．すなわち，初期画像を $p = 2^l \times 2^l$ 個の領域に分割したものをレベル l の画像とする．次に分割したそれぞれの領域で局所ヒストグラム H_p^l を計算する．ここで局所ヒストグラム H_p^l のそれぞれのピンは，レベル l の p 番目の画像において対応する画素値の画素数である．最後に，特徴ベクトル \mathbf{x}_T は，各レベルの局所ヒストグラムを結合したものと表される．

$$\mathbf{x}_T = \{\{H_1^0\}, \{H_1^1, \dots, H_{2^1 \times 2^1}^1\}, \dots, \{H_1^L, \dots, H_{2^L \times 2^L}^L\}\} \quad (3)$$




図 5 3層空間ピラミッド

3.4 濃淡情報と距離情報の統合

濃淡情報と距離情報を統合するため，前項の方法で得られた特徴ベクトル \mathbf{x}_{gray} と $\mathbf{x}_{\text{depth}}$ を結合し，最終的な特徴ベクトル \mathbf{x} とする．この特徴ベクトル \mathbf{x} が識別器の入力として用いられる．

$$\mathbf{x} = \{\mathbf{x}_{\text{gray}}, \mathbf{x}_{\text{depth}}\} \quad (4)$$

3.5 短縮局所二値パターンを用いた特徴ベクトルの次元削減

LBP の局所ヒストグラムを用いた手法では，特徴ベクトルの次元が，空間ピラミッドのレベルが高くなるにつれて指数関数的に増加する問題がある．

そこで本論文では特徴ベクトルの次元削減を目的に，Ojala ら [11] によって提案された評価値 U を参考に，局所二値パターンのサブセットである短縮局所二値パターン (Short Local Binary Pattern, SLBP) を新たに用いる．SLBP では，特定の代表的な LBP のみを用いることで，次元削減をはかる．

特定の代表的な LBP を見つけるため，式 (1) を用いて得られる二値 $b_j(i)$ の 0, 1 間の遷移の回数 $U(i)$ に注目する．

$$U(i) = |b_1(i) - b_8(i)| + \sum_{j=1}^7 |b_j(i) - b_{j+1}(i)| \quad (5)$$

例えば 00000000_2 , 11111111_2 , 01010101_2 では，0, 1 間の遷移の回数 U はそれぞれ 0, 0, 8 となる．これより，濃淡画像に対し，SLBP の値 $v^{\text{SLBP}}(i)$ は以下のように表される．

$$v^{\text{SLBP}}(i) = \begin{cases} v^{\text{LBP}}(i), & U(i) \leq U_{\text{Th}} \\ \text{nan}, & \text{otherwise} \end{cases} \quad (6)$$

同様に，距離画像に対しては，SLBP の値 $v^{\text{SLBP}+}(i)$ は以下のように表される．

$$v^{\text{SLBP}+}(i) = \begin{cases} v^{\text{LBP}}(i), & U(i) \leq U_{\text{Th}} \\ 256, & \delta_{\text{nan}}(p(i)) \vee \exists \delta_{\text{nan}}(\mathcal{N}(p(i))) \\ \text{nan}, & \text{otherwise} \end{cases} \quad (7)$$

U_{Th} は $U(i)$ に対する閾値である．ただし， $U_{\text{Th}} = 8$ のときは通常の LBP と等しく，最終的な記述子は CENTRIST [5] と等価である．ここで，短縮局所二値パターンを用いて得られた特徴量画像を局所ヒストグラムに変換する際，nan は考慮に入れない．それ以外の特徴ベクトルの計算方法は第 3.3, 3.4 項で示した通常の LBP と同様の方法で行う．第 4 章では， $U_{\text{Th}} = 2, 4, 6$ および 8 の SLBP の実験結果を示す． $U_{\text{Th}} = 2, 4$ および 6 の SLBP では，濃淡画像において 256 種類の LBP のうち，それぞれ 58 種類，198 種類，254 種類が用いられる．その結果， $U_{\text{Th}} = 8$ に比べて特徴ベクトルの次元は 22.7% ，77.3% ，99.2% に削減される．

3.6 識別方法

各画像を特徴ベクトルに変換し, Support Vector Machine (SVM) [13], [14] を用いて識別を行う. SVM には M 対の濃淡および距離画像の組から得られた M 個の m 次元特徴ベクトル $\mathbf{x}_i \in \mathcal{R}^m (i = 1, \dots, M)$ とともに, ラベル $y_i \in \{1, -1\}$ (すなわちそのカテゴリに属するか, 属さないか) が入力される. SVM の目的は 2 クラス $\{1, -1\}$ の学習データとの距離が最大となる超平面を見つけることであり, 次の最適化問題で表される.

$$\min_{\mathbf{w}, b, \xi} C \sum_{i=1}^M \xi_i + \frac{1}{2} \|\mathbf{w}\|^2 \quad (8)$$

$$\text{subject to } y_i (\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i \quad (9)$$

ここで, C はマージンパラメータ, \mathbf{w} は超平面に対する垂線, $\xi_i \geq 0$ は \mathbf{x}_i の誤分類に伴う超平面からの逸脱量, $\phi(\cdot)$ は非線形写像, b はバイアス項を表している. 実験では次のラジアル基底関数 (Radial Basis Function) カーネルを用いた.

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2), \quad \gamma > 0 \quad (10)$$

ここで, γ は分布の半径を制御するパラメータである.

多クラス問題の識別は一対一方式 [15] で行い, 実験では LIBSVM ライブラリ [16] を用いた. パラメータ C および γ は, $C \in [2^{-5}, 2^{-2}, \dots, 2^{16}]$ および $\gamma \in [2^{-12}, 2^{-9}, \dots, 2^3]$ の範囲でクロスバリデーションを用いた総当たり探索により決定した [17].

4. 識別実験

4.1 データセット

提案手法の性能評価のために, 屋内環境で実験を行った. 実験では, まず移動台車の上部, 高さ 125cm の位置に Kinect センサを固定し, 様々な空間で連続的に計測を行い, RGB および距離画像のデータセット^(注1)を構築した. 対象とした空間のカテゴリは “corridor”, “kitchen”, “laboratory (lab.)”, “office” および “study room (study)” の 5 つである. まず, それぞれのカテゴリ毎に, いくつかの異なる空間 (部屋) で RGB および距離画像の取得を同時に行った. 例えば, 表 1 ではカテゴリ “laboratory” は 4 つの異なる laboratory の情報を含んでおり, 同一のカテゴリには属するが実際には異なる空間 (部屋) の情報が含まれている. また, それぞれの空間で Kinect センサを異なる軌道で移動させ, RGB および距離画像列の対を複数得た. このあと, 各 RGB 画像列とそれに対応する距離画像列の同期をとり, 同時刻の RGB および距離画像を得た. 表 1 は実験で用いた空間毎の画像の組 (RGB 画像および距離画像) の数を示す. また, データセットに含まれる各カテゴリの RGB および距離画像の一例を図 6 に示す.

(注1): <http://robotics.ait.kyushu-u.ac.jp/~kurazume/r-cv-j.html#c10>

表 1 各カテゴリの RGB および距離画像の枚数

category	place	number of image sets
corridor	corridor 1	68
	corridor 2	42
	corridor 3	70
	corridor 4	99
kitchen	kitchen 1	73
	kitchen 2	65
	kitchen 3	53
laboratory	laboratory 1	99
	laboratory 2	99
	laboratory 3	81
	laboratory 4	78
study room	study room 1	71
	study room 2	70
	study room 3	49
	study room 4	62
office	office 1	57
	office 2	45
	office 3	47

4.2 実験結果

構築した RGB および距離画像のデータセットを用い, 空間のカテゴリ識別実験を行った.

実験では, leave-one out cross-validation 法を N 回適用し, 提案手法の識別性能を評価した. ただし, それぞれのカテゴリに含まれる空間数が異なることから, 学習データと評価データの N 個の組を以下のように決定した. まず各カテゴリに含まれるある一つの空間を評価データとする. この空間はそれぞれのカテゴリ内でランダムに決定される. また同じカテゴリの残りの空間のデータは, 学習データとして使用される. もし選択された評価データの組が既に評価に使用されていた場合には, それを破棄し, それ以前とは異なる学習, 評価データの組が得られるまで選択処理を続ける. これにより, 評価データは常に学習データには含まれない空間となる. なお, 本実験では $N = 10$ とした. また, それぞれの評価時には, 学習データを式 (10) で示したカーネルにより SVM に学習させ, 評価データをそれぞれ学習後の SVM で評価して識別率を求めた.

4.2.1 SLBP のヒストグラムによる識別性能

濃淡および距離画像に対する SLBP のヒストグラムを組み合わせた場合の識別性能を評価した. 0, 1 間の遷移の回数 U の閾値 U_{Th} は 2, 4, 6 および 8 を用いた. ただし, $U_{Th} = 8$ のときは通常の LBP と等しく, 最終的な記述子は CENTRIST [5] と等価である. 平均で最も高い識別性能が得られた $L = 0$ に対する結果を表 2 に示す. これより, $U_{Th} = 4$ の場合が最も識別率が高く, かつ CENTRIST に比べ標準偏差が減少したことがわかる.

図 7 は, 各カテゴリに対する識別率をプロットした

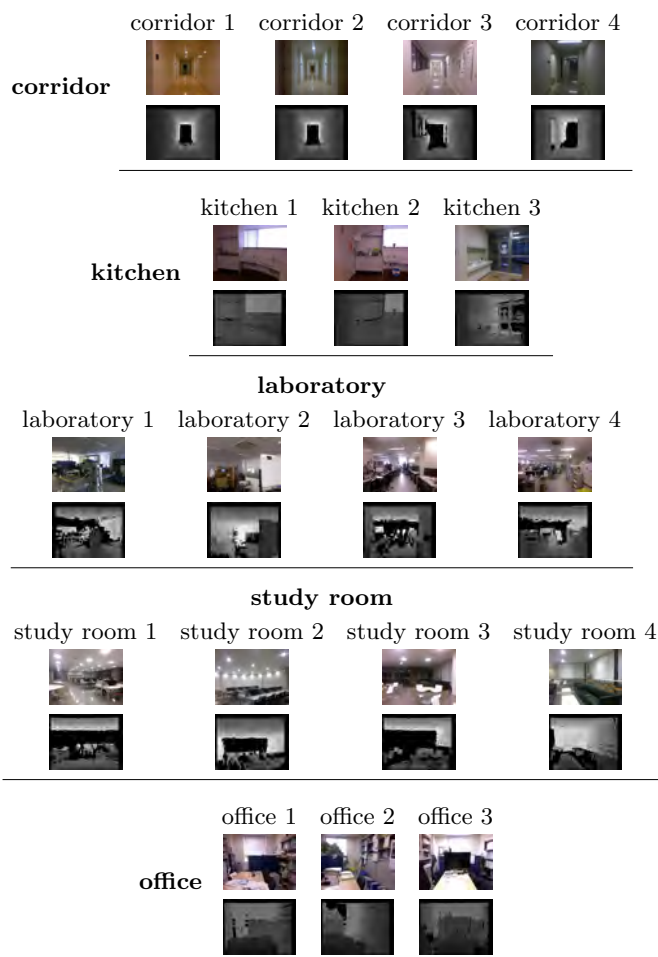


図 6 各カテゴリ (corridor, kitchen, laboratory, office, study room) での RGB および距離画像の例

ものである。これより、 $U_{Th} = 4$ の場合が各カテゴリにおいて最も高い識別率の大部分を占めているがわかる。特に、最も識別が難しいカテゴリである “kitchen” と “study room” で識別率が向上した。

表 2 U_{Th} に対する識別率 (%)

$U_{Th} = 2$	$U_{Th} = 4$	$U_{Th} = 6$	$U_{Th} = 8$ (CENTRIST)
87.27 ± 10.71	92.61 ± 4.78	89.71 ± 9.92	89.37 ± 8.85

4.2.2 マルチモダリティの性能検証

濃淡および距離画像のマルチモダリティの性能を検証するため、それぞれ単体で用いた場合との比較を行った。0, 1 間の遷移の回数 U の閾値 U_{Th} は 2, 4, 6 および 8 を用い、空間ピラミッドは $L = 0$ とした。実験結果を図 8 に示す。これより、濃淡および距離画像を組み合わせた場合はそれぞれ単体で用いる場合に比べ、高い識別率が得られ、標準偏差も大きく減少したことがわかる。

4.2.3 空間ピラミッドの性能検証

特徴量の計算に空間ピラミッドを用い、その性能を検証した。ただし、レベルは 3 種類 ($L = 0; 1; 2$) を用い




図 7 U_{Th} に対する各カテゴリの識別率 (%)

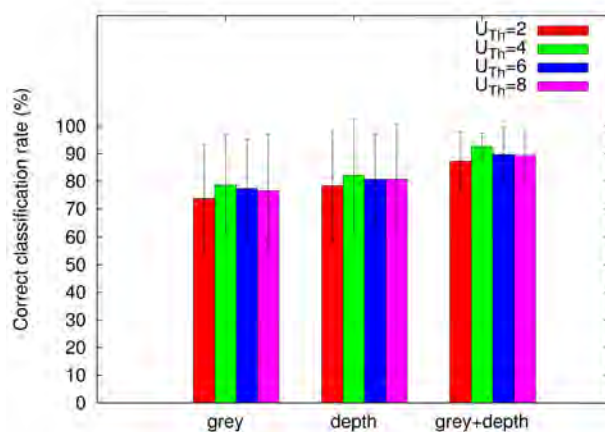


図 8 各モダリティの識別率 (%)

表 3 空間ピラミッドを用いた場合の識別率 (%)

L	SVMs	RFs
0	92.61 ± 4.78	85.74 ± 11.82
1	88.10 ± 15.76	87.57 ± 14.23
2	88.95 ± 14.18	88.43 ± 12.79

た。最も高い識別率を示した $U_{Th} = 4$ のときの実験結果を表 3 に示す。これより、識別率が最も高いのは $L = 0$ の場合であった。ただし、空間ピラミッドによる精度向上は [12] 等で報告されており、今後より詳細に検討する必要がある。

4.2.4 ランダムフォレストによる識別性能

SVMs との比較のため、識別器としてランダムフォレスト (RFs) を用いて SLBP のヒストグラムに対する識別性能を評価した。ただし、特徴量の計算には空間ピラミッドを用い、 U_{Th} は 4 とした。SVMs と RFs の識別率を表 3 に示す。これより、空間ピラミッドの各レベルで SVMs が RFs より識別率が高いことがわかる。また、SVMs の場合と異なり、RFs では空間ピラミッドにより識別率が向上した。

4.2.5 Bag-of-Features による識別性能

比較のため, Bag-of-Features (BoF) の手法 [18] を用いた識別実験を行った. 実験では, まず SIFT 演算子により学習用の濃淡および距離画像から特徴量を抽出し, それぞれ 200 個の Visual vocabulary からなる Codebook を作成した. その後, テスト画像に対しても同様に SIFT 演算子により特徴量を抽出し, SVMs により識別を行った. 実験の結果, 識別率は $64.76 \pm 18.96\%$ であり, 少数の局所特徴量ではなく, 画像全体から得られる特徴量を用いる提案手法の優位性が確認された. なお, 濃淡画像だけ用いた場合には, 識別率は $50.69 \pm 19.93\%$ であり, 距離画像では $53.19 \pm 10.61\%$ であった.

5. 結論と今後の課題

本稿では, Kinect センサから得られた RGB および距離画像を用いて, 空間を識別する手法を提案した. 提案手法では, 濃淡および距離画像から LBP および SLBP を用いてそれぞれ特徴ベクトルを抽出し, それらを組み合わせた特徴ベクトルを SVMs および RFs により識別した. 識別実験の結果, 特に新たに提案した SLBP を用いることにより, 5 つの空間のカテゴリにおいて高い識別精度を示すことが確認された.

今後は, より適当な記述子について検討するとともに, 学習, 評価データのカテゴリ数やデータ数を増やすことを目標とする.

謝辞

本研究の一部は, 日本学術振興会外国人特別研究員事業, 文部科学省科学研究費補助金基盤研究 (B) (課題番号 23360115) の支援を受けた. また実験にご協力いただいた九州大学内田誠一教授, 谷口倫一郎教授, 諸岡健一准教授に感謝いたします.

文 献

- [1] O. M. Mozos, C. Stachniss and W. Burgard: “Supervised learning of places from range data using AdaBoost”, IEEE International Conference on Robotics and Automation (ICRA) (2005). Barcelona, Spain.
- [2] O. M. Mozos and W. Burgard: “Supervised learning of topological maps using semantic information extracted from range data”, IEEE/RSJ International Conference on Intelligent Robots and Systems (ICRA) (2006). Beijing, China.
- [3] E. Brunskill, T. Kollar and N. Roy: “Topological mapping using spectral clustering and classification”, Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) (October 2007). San Diego.
- [4] L. Shi, S. Kodagoda and G. Dissanayake: “Laser range data based semantic labeling of places”, Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) (October 2010). Taipei, Taiwan.
- [5] J. Wu, H. I. Christensen and J. M. Rehg: “Visual place categorization: Problem, dataset, and algorithm”, Proc of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) (2009.). St. Louis, MO, USA.
- [6] T. Ojala, M. Pietikäinen and D. Harwood: “A comparative study of texture measures with classification based on featured distributions”, Pattern Recognition, **29**, 1, pp. 51–59 (1996).
- [7] A. Ranganathan: “Pliss: Detecting and labeling places using online change-point detection”, Robotics: Science and Systems VI (2010).
- [8] A. Torralba, K. P. Murphy, W. T. Freeman and M. A. Rubin: “Context-based vision system for place and object recognition”, International Conference on Computer Vision (ICCV) (2003). Nice, France.
- [9] A. Rottmann, O. M. Mozos, C. Stachniss and W. Burgard: “Semantic place classification of indoor environments with mobile robots using boosting”, National Conference on Artificial Intelligence (AAAI) (2005). Pittsburgh, PA, USA.
- [10] A. Pronobis, O. M. Mozos, B. Caputo and P. Jensfelt: “Multi-modal semantic place classification”, International Journal of Robotics Research, **29**, 2–3, pp. 298–320 (2010). February–March.
- [11] T. Ojala, M. Pietikäinen and T. Mäenpää: “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns”, IEEE Trans. on Pattern Analysis and Machine Intelligence, **24**, 7, pp. 971–987 (2002).
- [12] S. Lazebnik, C. Schmid and J. Ponce: “Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories”, IEEE Computer Society Conference on Computer Vision and Pattern Recognition (2006).
- [13] C. Cortes and V. Vapnik: “Support-vector network”, Machine Learning, **20**, pp. 273–297 (1995).
- [14] C. M. Bishop: “Pattern Recognition and Machine Learning”, Springer (2006).
- [15] S. Knerr, L. Personnaz and G. Dreyfus: “Single-layer learning revisited: a stepwise procedure for building and training a neural network”, Neurocomputing: Algorithms, Architectures and Applications (1990). J. Fogelman, Ed., Springer-Verlag.
- [16] C.-C. Chang and C.-J. Lin: “Libsvm: A library for support vector machines”, ACM Transactions on Intelligent Systems and Technology, **2**, pp. 27:1–27:27 (2011). software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [17] C.-W. Hsu, C.-C. Chang and C.-J. Lin: “A practical guide to support vector classification” (2010). <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>.
- [18] G. Csurka, C. Bray, C. Dance and L. Fan: “Visual categorization with bags of keypoints”, Workshop on Statistical Learning in Computer Vision, European Conference on Computer Vision, pp. 1–22 (2004).