

SVMによる物体と位置の視覚学習に基づく 屋外移動ロボットの位置推定

三浦 純^{*1} 森田 英夫^{*2} ヒルド ミハエル^{*3} 白井 良明^{*4}

A View-Based Outdoor Localization

Using Object and Location Recognition Based on Support Vector Learning

Jun Miura^{*1}, Hideo Morita^{*2}, Michael Hild^{*3} and Yoshiaki Shirai^{*4}

This paper describes a view-based localization method using support vector machines in outdoor environments. We have been developing a two-phase vision-based navigation method. In the training phase, the robot acquires image sequences along the desired route and automatically learns the route visually. In the subsequent autonomous navigation phase, the robot moves by localizing itself based on the comparison between input images and the learned route representation. Our previous localization method uses an object recognition method which is robust to changes of weather and the seasons; however it has many parameters and threshold values to be manually adjusted. This paper, therefore, applies a support vector machine (SVM) algorithm to this object recognition problem. SVM is also applied to discriminating locations based on the recognition results. In addition, to cope with image shifts caused by the variation of the robot's heading, we use a panoramic camera; we search the panoramic image for the region which matches the model image best. This two-stage SVM-based localization approach with a panoramic camera exhibits a considerable localization performance for real outdoor image data without any manual adjustment of parameters and threshold values.

Key Words: Outdoor mobile robot, View-based localization, Support vector machine.

1. はじめに

屋外移動ロボットの研究が盛んに行われている。移動のためには、ロボットの位置推定が必要であり、さまざまな方法が提案されている。GPSは位置推定のためのセンサとしてよく用いられているが[1][2]、高い建物の近くでは衛星の隠蔽やマルチパスなどの現象により、信頼できる位置情報が常に得られるとは限らない。また、測定した位置と環境との対応を取るための地図を与える必要がある。道路境界や歩道などの局所的な特徴

を認識しロボットを誘導する方法もあるが[3][4]、そのような特徴が必ずしも得られない場所を移動するためにはロボットの位置推定が必要である。

本論文では、ロボットが与えられた経路上のどの位置にあるかを決定する、という意味での位置推定問題を対象とする。屋外環境は、屋内に比べてロボットの移動範囲が広がるため、あらかじめ環境の地図を与えることが難しい。そこで、われわれは、ユーザが一度ロボットを誘導して経路を学習させたあと、ロボットが学習結果を利用して自律的に位置を推定する、という2段階の方法を研究している。同様の方法はこれまでにいくつか提案されており、それぞれ異なる地図の表現法や学習法を用いている。

Maeyamaら[5]らは、誘導時にオドメトリデータと経路の周囲で観測した立ち木などのランドマークの位置を地図に記録し、自律移動時に利用した。この手法は経路の比較的近くの物体をランドマークとして用いているので、駐車車両の移動などにより周囲の物体の配置が変化すると誘導時に作成した地図が利用できない可能性がある。

位置推定に物体の見えを直接用いる方法もある。この場合、現在位置で取得した画像と学習画像との物体の見えを比較し、もっ

原稿受付

^{*1}大阪大学大学院工学研究科，現在豊橋技術科学大学

^{*2}大阪大学大学院工学研究科，現在松下電器産業株式会社

^{*3}大阪電気通信大学総合情報学部

^{*4}立命館大学情報理工学部

^{*1}Graduate School of Engineering, Osaka University, Currently with Toyohashi University of Technology

^{*2}Graduate School of Engineering, Osaka University, Currently with Matsushita Electric Industrial Co., Ltd.

^{*3}Faculty of Information Science and Arts, Osaka Electro-Communication University

^{*4}College of Information Science and Engineering, Ritsumeikan University

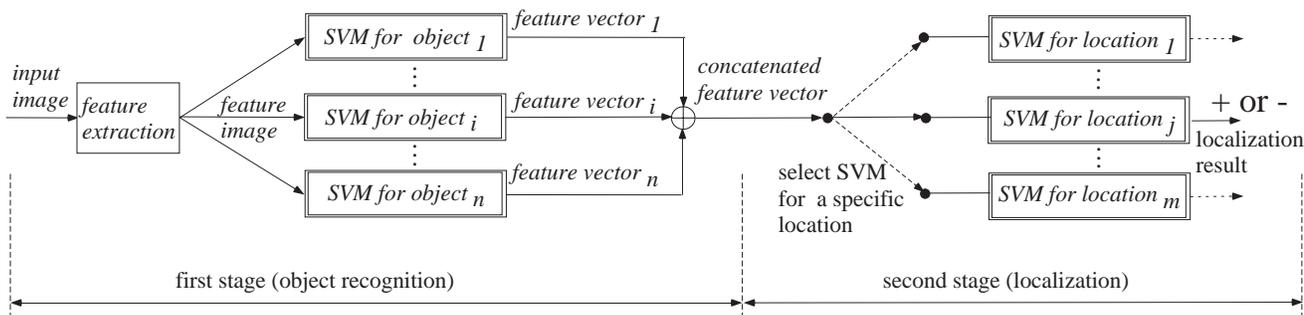


Fig. 1 Two-stage localization using SVMs.

とも適合する学習画像の取得位置にいと推定するものである。Li [6] は誘導時に得た画像から経路に沿ったパノラマ画像を作成し、自律移動時の位置推定に利用している。この手法は画像の直接比較により位置推定を行うので、天候や季節の変化による画像中の物体の色の変化に対応できない。Takeuchi ら [7] は、天候の変化による物体の色の変化を正規化により吸収し、同様の手法を用いて経路に沿った位置の決定に用いているが、季節の変化による物体そのものの色の変化を考慮していない。Bradley ら [8] は画像照合に基づく位置推定において、見えの変化に対応するために多様な条件下で学習した画像データベースを用いているが、画像を取得するためのコストが高くなる。

われわれの従来手法 [9] では、屋外に存在する特徴的な物体（建物、木など）に対し、見えの変化を考慮したモデルを作成し、それを用いて物体認識を行った。そして、画像同士を直接照合するのではなく、認識の結果同士を照合することによって、見えの変化に対応することができた。しかしながら、そのモデルは色やエッジ密度といった画像特徴の可能な範囲として定義され、その範囲は集めたデータから手作業で決定していた。また、画像同士の照合の判定も手動で設定したしきい値を用いていた。このような手動のパラメータ調整は多様な環境に適用しようとする際の欠点となる。そこで、本論文では学習機構の導入により自動的にモデルを獲得し、それをもとに位置推定を行う手法を提案する。

近年、パターン識別器としてサポートベクトルマシン (support vector machine, 以下 SVM) が注目を集めており、3次元物体認識 [10]、顔認識 [11] ~ [13]、パターンマッチングに基づく物体追跡 [14] などに適用され、優れた識別性能を持つことが示されている。われわれの見えに基づく位置推定問題は、現在の入力画像に最も近い学習画像を探索することに帰着されるので、SVM に基づく認識手法の利用に適している。SVM を位置推定に利用した例としては、Yamano ら [15] によるものがあるが、この研究は屋内環境に設置された RFID からの信号パターンを SVM により識別するものであり、環境の事前の整備が必要となり、屋外環境には適さない。

本論文で提案する位置推定手法では、画像中の物体の認識を行い、その結果を用いて位置を推定する、という2段階の処理それぞれを SVM で行う。物体認識のための SVM は、あらかじめ多様な条件下で得た物体の画像群から学習する。位置推定のための SVM は、実際の経路ごとに得た認識結果列から学習

する。したがって、第1段階の SVM の結果を第2段階の SVM で利用することになる。

屋外環境ではロボットの走行可能な領域が比較的に広い場所が多いため、学習時と自律移動時では、ロボットの向きや経路からの横方向の位置にずれが生じる可能性がある。屋外環境では比較的遠方の物体を観測することが多いので、経路からの横方向の位置のずれがあっても、画像内の物体の位置の変化はあまり生じない。それに対し、向きのずれについては、ずれが小さくても画像内の物体の位置が大きく変化するため、位置推定性能が落ちてしまう。この問題に対処するため、全方位カメラで得られるパノラマ画像を用い、学習画像に最もよく適合する領域を入力画像の中から探索することにより、向きの変化に対応する。全方位画像全体、あるいはそこから得られる何らかの特徴量を比較することにより位置推定を行う手法が提案されているが (例えば [16] [17])、本論文の対象とする屋外での比較的粗い位置推定では、経路の両側の物体までの距離が近くかつその変化が大きいか見えの変化が大きくなり、画像照合の性能を低下させる可能性があるため、進行方向に沿った部分のみを用いる。

2. 提案手法の概要

2.1 サポートベクトルマシン

サポートベクトルマシン (support vector machine, SVM) [18] ~ [20] は2クラスの識別器であり、2クラスのいずれかにラベルづけされたサンプルの集合からなる学習データを識別することのできる超平面を計算する。学習データが線形分離可能な場合には、完全に識別することのできる超平面は無数に存在するので、マージン最大化 (最も識別平面に近いサンプルまでの距離を最大化する) に基づいて超平面を決定する。最も識別平面に近いサンプルの集合をサポートベクトルと呼び、識別平面はサポートベクトルの集合のみによって規定される。線形分離不可能な場合には、一部のサンプルが識別平面を越えて反対側に存在することを許した評価関数を用いて、最適な分割平面を計算する。

通常の識別問題では、対象とするデータの定義された空間 (データ空間) においては、非線形の識別面が必要となることが多い。そこで、低次元のデータ空間から仮想的な高次元空間へマッピングし、高次元空間で線形識別平面を求めることが考えられる。SVM の計算においてはデータベクトル同士の内積が

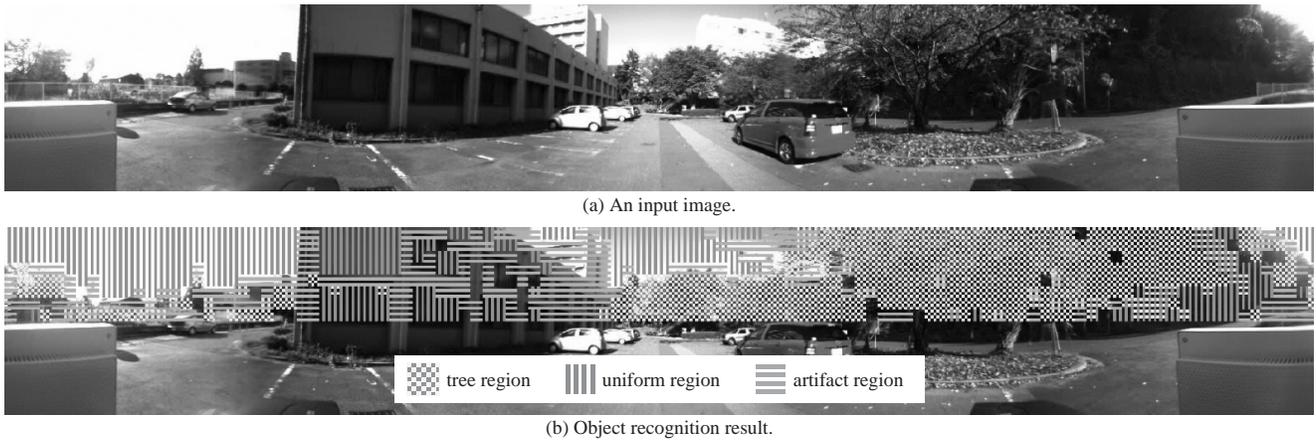


Fig. 2 An input panoramic image and the recognition result.

計算できればよいという点に着目し、高次元空間での内積を低次元空間でのデータから計算するためのカーネル関数を利用し、陽に高次元空間へのマッピングを行うことなく非線形の識別面を求めることができる。これをカーネルトリックという。

SVM の詳細については、上記参考文献等を参照されたい。なお、本論文では、SVM のソフトウェアとして SVM^{light} [21] を用いた。

2.2 2段階の位置推定

Fig. 1 にわれわれの提案する、SVM を用いた位置推定手法の概要を示す。全体の処理は2段階に分けられる。第1段階では画像中の物体を認識する。そのために、画像をウインドウと呼ばれる小領域に分割し、ウインドウごとに色やエッジ密度などの画像特徴のベクトルを抽出し、その結果を並べた特徴画像を生成する。次に、物体ごとに学習させた SVM (物体認識 SVM と呼ぶ) に特徴画像を入力し、ウインドウごとに対応する物体があるかどうかを判別し、それらを1次元に並べたベクトルを出力する。最後に、物体ごとの出力ベクトルをすべて結合したベクトルを生成する (特徴ベクトルと呼ぶ)。季節や天候の変化による物体の見えの変化に対処するために、多様な状況下で取得した画像を学習に用いる。

第2段階では、第1段階の認識結果 (特徴ベクトル) を用いた位置の推定を行う。推定を行いたい位置の集合をあらかじめ決めておき、各位置を他の位置から識別するような SVM (位置推定 SVM と呼ぶ) を、位置ごとに生成しておく。識別を画像そのものではなく物体認識結果に基づいて行うことにより、屋外での位置推定のロバスト性を向上させる。

ロボットがある位置にいるかどうかを判別するためには、入力画像を物体認識 SVM に与えて得た特徴ベクトルに、その位置に対応した位置推定 SVM を適用してその出力結果を調べる。もし、ロボットが学習時に走行した経路上を走行している場合には、適用する位置推定 SVM を経路に沿って順に切り替えていけばよく、その場合には一度に1つ (あるいは少数) の位置推定 SVM を適用すればよい。

上記のような2段階の SVM を用いる方法ではなく、各位置に対して多様な状況で取得した画像を用いて SVM を学習させるという、1段階の方法も可能である。しかし、そのためには多

様な条件下での画像をすべての位置で取得する必要がある。それに対し2段階の方法では、第1段階の SVM のために (位置は問わず) 多様な状況で物体を取得した画像と、第2段階の SVM のためにすべての位置においてある特定の状況下で取得した画像とがあればよく、それらの組み合わせを全部取得する必要はない。

2.3 パノラマ画像とその利用法

パノラマ画像の取得には PointGrey 社の LadyBug2 を用いる。Fig. 2(a) にパノラマ画像 (サイズは 1800×256 ピクセル) の例を示す。本論文では大学の構内のような環境を想定しており、画像中には建物、木、車、自転車などの物体が存在する。車や自転車などは時間ごとに変化するので、画像の上半分に存在する建物、木、空という比較的大きな物体を位置推定に用いる。そのために、画像の上部 1800×128 ピクセルの領域のみを処理の対象とする。

位置推定 SVM に対してこのパノラマ画像を次のように利用する。学習時には上記領域の水平方向の中央部の 304×128 ピクセルの領域を取り出し、学習画像とする。位置推定時には、同じ大きさの領域を、上記処理領域内を水平に移動させながら、各位置において物体認識 SVM を適用して特徴ベクトルを取り出し、位置推定 SVM へ入力してその出力値を計算する。そして、最大となる出力値を現在の入力画像に対する評価値とする。

3. 物体認識 SVM

3.1 認識対象物体と認識に用いる画像特徴

本論文では、認識の対象として4つの物体クラスを考える。以下に、各物体クラスとその見えについて簡単に説明する。

- 葉のある木: 葉のエッジが多く観測される。また、葉の色は季節によって変化する。
- 葉のない木 (落葉した木): 枝のみが観測される。枝のエッジの方向はさまざまである。
- 空と建物の側壁: とともに様な領域として観測される。
- 建物の窓と境界: 強い直線セグメントが観測される。

木について2つの物体クラスを用いるのは、季節の変化による見えの大きな変化に対応するためであり、画像中のある場所でどちらかが認識されれば、そこに木が存在すると考える。

認識にあたっては、処理対象領域を 16×16 ピクセルの大き

Table 1 Objects, region names, and image features used.

object	region name	image features used			
		(r, g, b)	$f_{density}$	$f_{distrib}$	f_{hough}
trees with leaves	<i>tree region</i>	✓	✓		
trees without leaves	<i>tree region</i>	✓	✓	✓	✓
sky, building side walls	<i>uniform region</i>	✓	✓		
building windows and boundaries	<i>artifact region</i>	✓	✓	✓	✓

さを持つ小領域 (ウインドウ) に分割し, 各ウインドウごとに上記の 4 種の物体クラスに属するかどうかを判定する. Table 1 は, 認識する物体クラスごとに, その物体が存在するとしたときに付ける領域名 (ラベル), および利用する画像特徴をまとめたものである. 木の認識においては 2 つの物体クラスを設定しているが, 認識結果のラベルは同一のもの (“tree”) とする. 一般に, より多くの特徴を用いることが必ずしもよりよい認識結果をもたらすとは限らない. そこで, いくつかの特徴量の組合わせに対し認識実験を行い, 最も認識率が高くなる組合わせを選択した.

各画像特徴は以下のように計算する.

- (r, g, b)

この特徴は正規化した色であり, 例えば $r = R / (R + G + B)$ (R, G, B はカラー入力画像のピクセル値) のように計算する. 各ピクセルの正規化した色の値をウインドウごとに平均化したものを特徴とする. 各要素の値の範囲は $[0, 1]$ である.

- $f_{density}$

この特徴はエッジ密度であり, ウインドウ内のエッジの数をウインドウの面積で割って計算する. エッジはソーベルオペレータで計算した勾配値が 3 以上の点とする. このしきい値は使用するカメラで白紙を撮像することによって見積もったノイズレベルに基づくもので, 認識処理とは独立に見積もることができるカメラの特性パラメータであり, 物体認識のためのパラメータではない.

- $f_{distrib}$

この特徴はエッジ方向の分散であり, さまざまな方向のエッジを持つ落葉した木の認識に有効である. エッジ方向は周期的なので, 方向の分散は循環統計 (circular statistics) [22] を用いて, 以下のように計算する. ウインドウ内に n 個のエッジがあったとし, その方向と大きさをそれぞれ ϕ_1, \dots, ϕ_n と a_1, \dots, a_n とする. まず, 各方向値を単位円周上の点に変換し, 次にそれらの, 各エッジの強さで重みづけした平均位置 (\bar{x}, \bar{y}) を次式で求める.

$$(\bar{x}, \bar{y}) = \frac{1}{\sum_{i=1}^n a_i} \left(\sum_{i=1}^n a_i \cos 2\phi_i, \sum_{i=1}^n a_i \sin 2\phi_i \right). \quad (1)$$

ここで, 値 $d = (\bar{x}^2 + \bar{y}^2)^{1/2}$ を考えると, d はエッジ方向がばらばらになっているときには小さくなり, その値の範囲は $[0, 1]$ である. そこで, $S = 1 - d$ を方向の分散として用いる. すなわち, $f_{distrib} = S$ である.

- f_{hough}

この特徴は, 各ウインドウに対してハフ変換を適用したときの, ハフ空間における投票の最大値である. ウインドウ内に強

い直線エッジが存在するときには, この値が大きくなる. この投票値を, 多くの画像を処理して得た最大値 (現在は, 300) で割って正規化した値を特徴量として用いる. なお, パノラマ画像中では空間内の直線は歪んで投影されるが, ハフ変換は小さなウインドウごとに行うため, その影響はほとんどない.

各ウインドウに対し上記の 6 つの値が得られるので, 入力画像がこの 6 つ組の 19×8 の配列に変換される. この配列を特徴画像と呼び, 物体認識 SVM への入力となる (Fig. 1 参照). 物体認識 SVM は, Table 1 にしたがって, 6 つ組の中の 4 つあるいは 6 つの特徴量を用いる.

3.2 物体認識 SVM の学習と認識

各物体クラスごとに 1 つの SVM を用いる. ある物体クラスのための学習データは次のように生成する. 多様な季節, 天候のもとで取得した画像から, その物体クラスに属するピクセルのみからなるウインドウを 300 個選択し正例 (positive sample) とする. また, その物体クラスをまったく含まないウインドウをランダムに同数選択し負例 (negative sample) とする. 物体認識には, RBF カーネル ($K(x_1, x_2) = \exp(-\gamma \|x_1 - x_2\|^2)$, $\gamma = 50$) を用いた SVM を利用した.

各 SVM は特徴値の組を入力とし, 正の場合 (入力に対応する物体クラスに属すると判断される場合) には 1 を, そうでない場合には 0 を出力する. 特徴画像の大きさは 19×8 なので, 各物体認識 SVM の出力はそれらを並べた 152 次元の 0-1 ベクトル (特徴ベクトル) となる (Fig. 1 参照). ただし, 葉のある木と葉のない木の 2 つの物体クラスについては, どちらかの SVM が 1 を出力する場合には 1 を, そうでない場合には 0 を値とする, 一つの特徴ベクトルを生成する.

3.3 物体認識結果

Fig. 2(b) に, Fig. 2(a) の入力画像に対する認識結果 (ラベルづけ結果) を示す. 各ウインドウ上の模様はラベル (tree, uniform, artifact) を示す. 模様のないウインドウは, どのラベルもつけられなかったものを示す. また, 複数のラベルが同時につけられたウインドウについては, SVM の出力値がもっとも大きいラベルに対応する模様を描いている.

各物体クラスごとに 400 サンプルを選択し, それを 4 つのグループに分け, そのうちの 3 グループ (300 サンプル) を SVM の学習に用い, 残りの 1 グループ (100 サンプル) の認識テストを, 4 通り行った結果の平均の認識率を求めた. その結果, 葉のある木は約 92.5%, 葉のない木は約 77.5%, 一樣領域は 94.5%, 建物領域は 84.5% の認識率が得られた. なお, 後に示す位置推定の結果から, これらの物体認識の結果は許容できるものと判断できる.

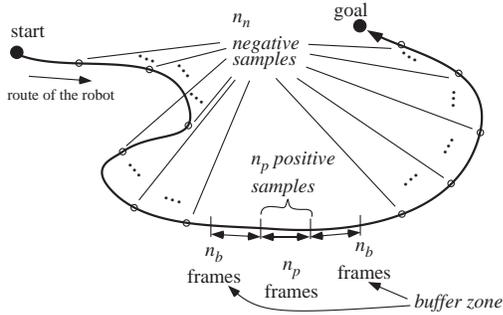


Fig. 3 Making training data for localization SVM.

4. 位置推定 SVM

第 2 段階では、第 1 段階の物体認識の結果に位置推定 SVM を適用する (Fig. 1 参照). 物体認識 SVM から 3 つのラベル (tree, uniform, artifact) それぞれに対する 152 次元の 0-1 ベクトルが出力されるので、それらを結合した 456 次元の 0-1 ベクトルを位置推定 SVM の入力として用いる.

4.1 位置推定 SVM のための学習データ生成

学習時に誘導された経路上の、位置推定を行う地点ごとに SVM を用意する. 各位置推定 SVM に対し、その位置の近傍で取得したデータを正例、それ以外の場所で取得したデータを負例として学習データを生成する. その具体的な手順は以下のようなものである (Fig. 3 参照).

推定を行う位置を中心とするある長さの領域を考え、ロボットがその領域内に存在すればその位置にいるものとし、その領域内で取得した n_p 枚の画像を正例とする. 風景が連続的に変化するとすると、その領域の近傍は推定を行いたい位置と似た風景である可能性が高い. そこで、その領域の前後に同じ長さの領域を緩衝領域 (buffer zone) として設定し (ロボットが一定速度で動くとして、 $n_b = n_p$)、それらを除いた位置で得た画像列から等間隔で画像を n_n 枚抽出し負例とする.

以下 (4.2 節) で述べる実験では、画像を 1.5 秒ごとに取得しながらロボットを秒速約 $0.8 [m/s]$ で移動させた. 正例の画像数 $n_p = 6$ とした (これは約 $7 [m]$ の移動量に相当する). また、負例の画像数 $n_n = 50$ とした. なお、この場合、特徴ベクトルの次元 (= 456) よりサンプル数が少なく線形識別可能であることから、カーネルトリックを用いない、線形 SVM を用いる.

4.2 位置推定実験

4.2.1 画像の取得

Fig. 4 に、実験に用いたわれわれのキャンパス内の長さ約 $350 [m]$ の経路を示す. 図中の Start から Goal までロボットを移動させ、1 回の走行で約 300 枚の画像を取得した.

学習用とテスト用の 2 組の画像セットを取得した. 学習用の画像は 2005 年 11 月 12 日午前 11 時頃 (天候晴れ) に、ロボットを手で押しながら動かして取得した. テスト用の画像は 2005 年 12 月 28 日午後 4 時頃 (天候曇り) に、ロボットをジョイスティックで動かしながら取得した. 2 組の画像の違いをまとめると以下ようになる.

(1) テスト画像では多くの木で落葉していたが、学習画像では

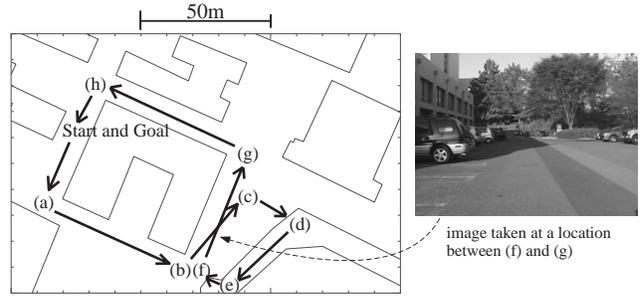


Fig. 4 The route used for experiment.



(a) A training image taken on 2005/11/12 at 11am (sunny).



(b) A test image taken on 2005/12/28 at 4pm (cloudy).

Fig. 5 A training and a test image with object recognition results taken at a same location.

そのような木はほとんどなかった.

- (2) 天候と時間が異なるため、物体の見えが異なる.
- (3) 学習画像取得時にはロボットを手で押したため、移動可能領域に対するロボットの方向は極めて安定していたが、テスト画像取得時にはジョイスティックを用いたためロボットの方向にある程度のばらつきが見られた.

Fig. 5 に、ほぼ同じ位置で取得した学習用とテスト用の画像の例とそれぞれの物体認識結果を示す. 見えの変化にもかかわらず全体としては似た認識結果が得られていることから、物体認識 SVM の有効性が示されている. しかし、画像を細かく見ると認識結果の差異が各所で見受けられる. 本研究では、このような認識の不確かさに対するロバスト性を位置推定 SVM によって実現している.

4.2.2 位置推定 SVM の適用結果

経路上に 50 の地点を選び、それぞれについて学習画像データから 6 枚の正例画像, 50 枚の負例画像を取り出して、位置推定 SVM を学習させた. 次に、約 300 枚のテスト用画像をそれら 50 の位置推定 SVM に入力として与えた.

Fig. 4 の (f)-(g) 上のある位置 (その位置で取得した画像を同図の右に示す) に対する位置推定 SVM の出力値を、すべてのテスト画像に対して計算した結果を Fig. 6 に示す. グラフは各テスト画像に対する SVM 値の変化を表し、その値が最大となる位置で取得した画像およびその最大値を得た画像中でのウィンドウの位置を図の上部に示す. テスト時にロボットは同位置を 2 度通っているため、グラフは 2 か所で明確な正の値を出力

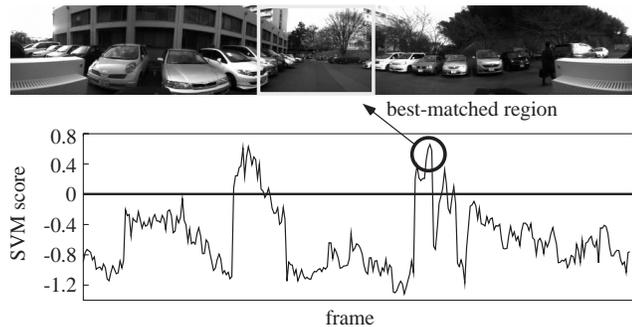


Fig. 6 Result of a localization experiment in our campus.

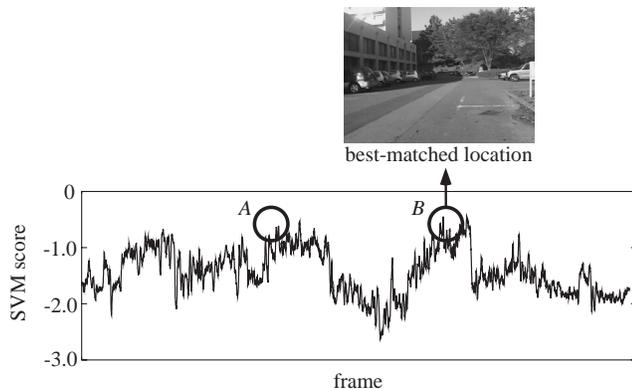


Fig. 7 Localization failure when using a conventional camera.

する領域を持っている．このことから，この位置を正しく推定できていることが分かる．

比較のために，2段階のSVMを通常のカメラ（画角約50度）を用いて同様の実験を行った際の失敗例をFig. 7に示す．同じ経路を走行させながら取得した約12,000枚の画像列を取得し，Fig. 4の画像に示した位置に対する位置推定SVMへ入力として与えた．SVM値は正しい位置の付近（図中のAおよびB）で高い値を示してはいるものの，その値は負であり，位置の推定に失敗している．

4.2.3 位置推定能力の評価

位置推定能力を評価するにあたり，以下の2つの場合を考える．もし，ロボットがこれまでの移動履歴を持っていれば，およその位置を知っているため，現在の入力画像を予測される位置（あるいはその近傍）に対応する位置推定SVMへ入力し，その結果が正になるかどうかを見ればよい．一方，ロボットの現在位置に関する予測がない場合には，すべての位置に対するSVMを適用し，出力が正になるかどうかを調べる必要がある．そして，複数のSVM値が正になった場合には，その値の大きい位置にいる可能性が高いと判断できる．これら2つの場合を考えて，以下の統計量をSVMによる位置推定手法の評価に用いる．

- (1) 成功率 (*success ratio*): 正しく位置推定が行えた位置の数とすべての位置の数の比．位置の予測がある程度行える場合の性能評価に対応する．
- (2) 最高得点率 (*highest-score ratio*): 正しく推定が行え，かつ最大のSVM値を得た位置の数とすべての位置の数の比．位置の予測ができない場合の性能評価に対応する．

Table 2 Comparison of localization methods.

	Success ratio	Highest-score ratio
SVM (panoramic)	96%	96%
SVM (conventional) [23]	88%	78%
Hand-crafted models [9]	95%	57%

以上の評価基準に基づいて，(1)2段階のSVMを用いた位置推定手法をパノラマ画像に適用したもの（提案手法），(2)その手法を通常のカメラに対して用いたもの[23]，(3)手動でのパラメータ調整を伴う物体モデルを用いた方法[9]の3つの手法を比較した．その際，各位置に対して，学習画像と同じ位置から撮影したと見せる画像をテスト画像から手動で選択し，それらを入力として位置推定を行った．

比較の結果をTable 2に示す．この結果から，本論文で提案する手法は，他の方法に比べ極めて高い性能を示していることが分かる．われわれの従来法[9]では，物体認識結果同士を照合する際に，対応する物体の領域がどの程度一致しているかを計算し，その一致の程度があるしきい値を越えるかどうかで，照合の成功を判断していた．その際，比較的緩いしきい値を用いることで高い成功率を達成していたが，その影響で最高得点率が下がる結果になっていた．それに対し，本論文で提案する手法では，手動のパラメータ調整を行うことなく高い成功率と最高得点率を両立している．

5. おわりに

本論文では，サポートベクトルマシン(SVM)を用いた，屋外移動ロボットのための新たな位置推定手法を提案した．提案手法は，物体認識のためのSVMと位置推定のためのSVMを2段階で動作させることにより，季節や天候の変化に対応するとともに，物体認識や位置推定のためのパラメータ調整を完全に排除することができる．さらに，パノラマ画像を用いることにより，学習時と自律走行時のカメラ方向のずれに対処した．実際の画像を用いた実験で，従来手法に比べ極めて高い位置推定性能が得られることを示した．

本論文で提案した位置推定手法は，環境内，あるいは経路上でのおおまかな大域的な位置を推定するものである．実際にナビゲーションを行うためには，ロボットの近傍の通行可能領域や障害物の認識が必要となる．そのような機能を実現して，実際にナビゲーションを行えるシステムを実現することが今後の課題である．

参考文献

- [1] R. Thrapp, C. Westbrook, and D. Subramanian. Robust Localization Algorithms for an Autonomous Campus Tour Guide. In *Proceedings of 2001 IEEE Int. Conf. on Robotics and Automation*, pp. 2065–2071, 2001.
- [2] 大野和則, 坪内孝司, 重松文治, 前山祥一, 油田信一. DGPSとオドメトリを用いた建物付近の歩道環境での自己位置推定とナビゲーション. 第8回ロボティクスシンポジウム予稿集, 2003.
- [3] H. Ishiguro, K. Nishikawa, and H. Mori. Mobile Robot Navigation by Visual Sign Patterns Existing in Outdoor Environments. In *Proceedings of IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, pp. 636–641, 1992.

- [4] J.D. Crisman and C.E. Thorpe. SCARF: A Color Vision System that Tracks Roads and Intersections. *IEEE Trans. on Robotics and Automat.*, Vol. 9, No. 1, pp. 49–58, 1993.
- [5] S. Maeyama, A. Ohya, and S. Yuta. Autonomous Mobile Robot System for Long Distance Outdoor Navigation in University Campus. *J. of Robotics and Mechatronics*, Vol. 9, No. 5, pp. 348–353, 1997.
- [6] S. Li. Localization along Routes Based upon Iconic and Global Positioning System Information in Large-Scale Outdoor Environments. *Advanced Robotics*, Vol. 15, No. 7, pp. 749–762, 2001.
- [7] Y. Takeuchi and M. Hebert. Evaluation of Image-Based Landmark Recognition Techniques. Technical Report CMU-CS-95-116, The Robotics Institute, Carnegie Mellon University, July 1998.
- [8] D.M. Bradley, R. Patel, N. Vandapel, and S.M. Thayer. Real-Time Image-Based Topological Localization in Large Outdoor Environments. In *Proceedings of the 2005 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, pp. 3062–3069, 2005.
- [9] 桂浩章, 三浦純, ヒルド・ミハヤエル, 白井良明. 季節や天候の変化にロバストな視覚認識に基づく移動ロボットの屋外ナビゲーション. *日本ロボット学会誌*, Vol. 23, No. 1, pp. 75–83, 2005.
- [10] M. Pontil and A. Verri. Support Vector Machines for 3D Object Recognition. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 20, No. 6, pp. 637–646, 1998.
- [11] G. Guo, S.Z. Li, and K. Chan. Face Recognition by Support Vector Machines. In *Proceedings of the 4th IEEE Int. Conf. on Automatic Face and Gesture Recognition*, pp. 195–201, 2000.
- [12] B. Heisele, P. Ho, and T. Poggio. Face Recognition with Support Vector Machines: Global versus Component-Based Approach. In *Proceedings of the 8th Int. Conf. on Computer Vision*, pp. 688–694, 2001.
- [13] 岡部孝広, 佐藤洋一. 照明変化を伴う顔認識. *情報処理学会研究報告*, No. CVIM 2003-139-10, pp. 69–76, 2003.
- [14] S. Avidan. Support Vector Tracking. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 26, No. 8, pp. 1064–1072, 2004.
- [15] K. Yamano, K. Tanaka, M. Hirayama, E. Kondo, Y. Kimuro, and M. Matsumoto. Self-Localization of Mobile Robots with RFID System by using Support Vector Machine. In *Proceedings of 2004 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, pp. 3756–3761, 2004.
- [16] 若佐英彦, 栗飯原述宏, 横矢直和, 竹村治雄. 全方位画像を用いた記憶に基づく位置推定. *電子情報通信学会論文誌*, Vol. J. 81-D-II, No. 2, pp. 310–320, 2001.
- [17] 松本吉央, 稲葉雅幸, 井上博允. 全方位ビューシーケンスを用いた経路表現と地図表現. *日本ロボット学会誌*, Vol. 20, No. 4, pp. 395–403, 2002.
- [18] V.N. Vapnik. *Statistical Learning Theory*. John Wiley & Sons, New York, 1998.
- [19] C.J.C. Burges. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, Vol. 2, No. 2, pp. 121–167, 1998.
- [20] 栗田多喜夫, 西田健次. カーネル学習法とその画像認識への応用. *情報処理学会研究報告*, No. CVIM 2004-145-25, pp. 187–194, 2004.
- [21] T. Joachims. Making Large-Scale SVM Learning Practical. In B. Schölkopf, C. Burges, and A. Smola, editors, *Advances in Kernel Methods – Support Vector Learning*. The MIT Press, 1999.
- [22] E. Batschelet. *Circular Statistics in Biology*. Academic Press Inc., London, 1981.
- [23] H. Morita, M. Hild, J. Miura, and Y. Shirai. View-Based Localization in Outdoor Environments Based on Support Vector Learning. In *Proceedings of 2005 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, pp. 3083–3088, 2005.

三浦 純 (Jun Miura)

1984年東京大学工学部機械工学科卒業. 1989年同大学院工学系研究科情報工学専攻博士課程修了, 工学博士. 同年大阪大学助手. 同大学院工学研究科機械工学専攻助教授を経て, 2007年豊橋技術科学大学情報工学系教授. 知能ロボット, 人工知能, コンピュータビジョンの研究に従事. 1994年~1995年CMU 客員研究員. 1997年ロボット学会論文賞受賞. 人工知能学会, 電子情報通信学会, 情報処理学会, システム制御情報学会, 日本機械学会, IEEE, AAAI 各会員. (日本ロボット学会正会員)

森田 英夫 (Hideo Morita)

2004年同志社大学工学部機械工学科卒業. 2006年大阪大学大学院工学研究科電子制御機械工学専攻修士課程修了. 同年松下電器産業株式会社入社. 在学中は屋外移動ロボットの研究に従事.

ヒルド ミハヤエル (Michael Hild)

Michael Hild received the Ph.D. from Osaka University in 1993. Since 1994 he has been on the faculty of Osaka Electro-Communication University in the Department of Engineering Informatics, where he presently holds the position of Professor. He is also affiliated with the Visual Information Research Institute at OECU. His research fields are computer vision, pattern recognition, color science and imaging, and robotics applications. Dr. Hild is a member of the IEEE, EIC, IPS, JSAI and IS&T.

白井 良明 (Yoshiaki Shirai)

1964年名古屋大学工学部機械工学科卒業. 1969年東京大学大学院工学系博士課程修了. 工学博士. 同年, 電子技術総合研究所入所, コンピュータビジョン, ロボティクスの研究に従事. 1971年~1972年, MIT AI ラボ客員研究員. 1988年大阪大学工学部電子制御機械工学科教授. 2005年立命館大学情報理工学部知能情報学科教授. 人工知能学会, 電子情報通信学会, 情報処理学会, 日本機械学会等各会員. (日本ロボット学会正会員)