移動ロボット搭載全方位カメラを用いた床際点 トラッキングによる静止障害物と移動障害物の識別

田 崎 豪* 十 倉 征 司* 園 浦 隆 史*
尾 崎 文 夫* 松日楽 信 人*

Classification of Static and Dynamic Obstacles Based on Tracked Floor Boundary Points by an Omnidirectional Camera Mounted on a Mobile Robot

Tsuyoshi Tasaki*, Seiji Tokura*, Takafumi Sonoura*,
Fumio Ozaki* and Nobuto Matsuhira*

Locating all obstacles around a moving robot and classifying them as static obstacles or not by a sensor are essential for the robot's smooth movement and avoid problems in calibrating many sensors. However, there are few works on locating and classifying all obstacles around a robot while it is moving by only one omnidirectional camera. In order to locate obstacles, we regard floor boundary points where robots can measure the distance and direction from the robot by one omnidirectional camera as obstacles. Tracking them, we can classify obstacles by comparing the movement of each tracked point with odometry data. Moreover, our method changes a threshold to detect the points based on the result of comparing in order to enhance classification. The classification ratio of our method is 85.0%, which is four times higher than that of a method without changing a parameter to detect the points and that of a previous method.

Key Words: Obstacle Classification, Omnidirectional Camera, Floor Detection, Mobile Robot

1. は じ め に

空港や大型スーパーにおいては、ロボットによる案内や搬送の需要があり、複数のロボットが開発されている[1][2]。ロボットが移動する際、障害物検出が必要であるが、特にスムーズな移動を行うために、移動障害物と静止障害物を区別した移動手法は有効である[3]。したがってロボット移動中においても、ロボット周囲の障害物を検出し、検出した障害物を移動障害物と静止障害物に識別することは重要である。近年、ロボット移動中の障害物識別に関する研究の多くが、LRFやステレオカメラなどの距離計測センサを用いている[4]~[7]。しかし、LRFやステレオカメラを用いる場合、全周囲の障害物を識別するためには、センサを複数台用意する必要があり、キャリブレーション回数、計算量、コストなどが増加する。

全周囲の識別はできないが、ロボット移動中の単独カメラによる移動障害物検出手法も開発されている。例えば、ロボットの移動によるカメラ画像の違いのなかから、モデルの適用や幾何学的手法によって、カメラ前にある移動障害物を検出する手

法がある[8]。モデル化手法としては、識別すべき移動障害物がカメラ視野内に一つとする仮定を持つモデルを利用したり[9]、移動障害物の移動モデルをあらかじめ持たせたり[10]することで、移動障害物を検出する。幾何学的手法としては、オプティカルフローを用いる手法が多い[11][12]。ロボット移動によって生じるオプティカルフローのなかから、大多数のフローが示す方向と異なる方向を示すフローを持つ場所に移動障害物があるとする。また、移動ステレオによるエッジベース幾何から移動障害物と静止障害物を識別する幾何学的手法もある[13]。モデル化による手法は、仮定したモデルと異なる場合には精度が悪化するが、幾何学的手法は、歪みが少ない一般的な画角のカメラにおいては、特別な仮定もなく有効に働く。

全方位カメラのように、一つのセンサで全周囲の画像を取得できるセンサもある。しかし、撮像画像は歪みが大きいため、通常画像を用いて開発された幾何学的手法をそのまま適用することは難しい。全方位カメラ画像を、歪みの少ない画像に変換することもできる[14]が、ロボット移動中の高速処理などのため低解像度画像を使用したい場合、画像にあいまいな部分が生じる。したがって、従来手法をそのまま適用しても高い精度を得られない。

本研究では、従来あまり行われていなかった、一台の全方位カメラによる、ロボット移動中の障害物識別という課題に取り組む。課題解決のため、一台の全方位カメラでも距離計測が可能

原稿受付 2010年4月12日

*東芝研究開発センター

*Toshiba Corporate Research & Development Center

■本論文は学術性で評価されました。

であり、比較的高い分解能で撮像される、障害物と床面との境界点「床際点」に着目した。同様の課題に取り組んだ手法や、床面に着目して障害物を検出する手法は開発されてはいる [15]～[17]。しかし、従来手法は、ロボット移動に伴う床色の微小変動を考慮していない、静止障害物と移動障害物の識別ができないなど、動的環境に対して問題があった。本研究では、床際点の検出閾値を動的に変更することで、正確に床際点をトラッキングし、ロボット動作からは起こりえない軌跡を持つ床際点を移動障害物として識別する。移動中に全周囲の障害物を識別することで、特に移動障害物を検出することを目的とする。

以下 2 章、3 章で、それぞれ床際点の検出手法と、床際点のトラッキングによる障害物識別手法について述べる。4 章で、開発した床際点検出手法と移動障害物検出手法の効果を確認し、5 章でまとめる。

2. 床 際 点 検 出

2.1 Ward 法に基づく床際点検出

従来、色の検出には GMM (Gaussian Mixture Model) が多く用いられてきた [18]。GMM は正規分布の混合数を増やせば色が一様でなくても一つの GMM で対象色を検出することが可能である。しかし混合数などのパラメータを決めるためには、多くの実験を必要とし、ロボット起動直後に高速かつ精度よく学習することは難しい。本研究では、事前設定が少ない、ボトムアップ的手法により床面を構成する色を抽出する。抽出された色のデータの偏差を考慮して検出を行うことで、GMM と同様の識別能力を持ちつつ、学習が容易な床面検出器を提案する。

床面を構成する色は、ロボット起動時に、ロボット周囲の指定した範囲内にある色をボトムアップ的にクラスタリングして抽出する。ロボット起動時は、指定した範囲内には床面だけが撮像されるようにロボットを設置することで、クラスタリングの結果得られるすべてのクラスが床色を構成すると考える。空港や大型スーパーにおいて、床色は一様ではないが周期的であり、床面も広い。したがって、指定範囲に障害物がない場所でロボットを起動し、床面を構成する多くの床色を抽出することは可能である。

床色データは一様ではないので、データの偏差を考慮し、各クラスターのデータ量が偏っていても、クラスタリングが可能な手法の利用が望ましい。ここでは階層的クラスタリングの一種である Ward 法 [19] を用いた。Ward 法を基にした床色データのクラスタリング手順を以下に示す。

1. N 個の対象となる床色データが与えられたとき、一個の対象だけを含む N 個のクラスターがある状態を初期状態とする。ここで用いる床色データは RGB の値を要素に持つ三次元ベクトルである。
2. 初期状態から始めて、式 (1) に示すクラスター間距離 $D(C_1, C_2)$ が最小になる二つのクラスター C_1, C_2 を逐次的に一つのクラスターとしてまとめる。ただし、 c_i はクラスター C_i 内の床色データ平均である。

$$D(C_1, C_2) = d(C_1 \cup C_2) - d(C_1) - d(C_2) \quad (1)$$

$$d(C_i) = \sum_{x \in C_i} \|x - c_i\|$$

Fig. 1 The omnidirectional image of cross-stripes on the floor

3. 手順 2 の逐次過程で、クラスター C_k が、式 (2) (3) を満たすとき、 C_k を一つの床色クラスターとして抽出し、 C_k 内のデータを逐次過程から除外する。式 (2) を満たし、式 (3) を満たさない場合は、床色クラスターとして抽出しないが、 C_k 内のデータを逐次過程から除外する。ただし、 T_D, T_N は閾値を表す定数であり、 $|C_k|$ はクラスター C_k の要素数を表す。

$$\min_{k \neq i} D(C_k, C_i) > T_D \quad (2)$$

$$|C_k| > T_N \quad (3)$$

Ward 法に基づいて得られた各床色クラスター内データは、データの偏差を考慮して一つにまとめられている。したがって、データの偏差を考慮できるように、各床色クラスターのデータ平均からのマハラノビス距離を、床面検出器に用いる。色データ I は、式 (4) を満たす床色クラスター k が一つでもあるとき、床色であるとする。ただし、 $\mu_k, \sum_k, \sigma_r$ はそれぞれ床色クラスター k のデータ平均、共分散行列、方向 r の検出閾値となる定数を示す。

$$\sqrt{(I - \mu_k)^T \sum_k^{-1} (I - \mu_k)} < \sigma_r \quad (4)$$

式 (4) を用いて、ロボットの頭頂に搭載されたミラー型の全方位カメラで床際点を検出する例を考える。頭頂に搭載されたミラー型の全方位カメラで画像を撮像した場合、床面は画像中心から外側に向かって投影されている (Fig. 1)。床面と障害物との境界点である床際点の画像上の位置を調べるため、画像中心から各方向に放射状に式 (4) の真偽を計算する。ノイズ除去のため、式 (4) が連続 p 回偽となったら、初めに偽となった位置を床際点の画像上の位置とする。

2.2 画像座標からロボット座標への床際点位置変換

検出された床際点までの距離を求める手法を述べる。ここでは、全方位カメラが床面と水平に設置され、ロボットが平らな床面を走行するという条件で床際点までの距離を求める。双曲面型のミラーで構成される全方位カメラを用いた場合、ロボットの接地部分の重心を原点とするロボット座標系の点 (X, Y, Z) は、画像座標系の点 (x, y) に式 (5) のように投影される [20]。ただし b, c はミラー固有パラメータ、 f はレンズの焦点距離を表す。Fig. 2 にはロボット座標系の点 G と、画像座標系の点 g の対応を示す。

Fig. 2 The image coordinates and the robot coordinates

Fig. 3 The bird's-eye image

$$\begin{aligned} x &= \frac{Xf(b^2 - c^2)}{(b^2 + c^2)(Z - c) - 2bc\sqrt{X^2 + Y^2 + (Z - c)^2}} \\ y &= \frac{Yf(b^2 - c^2)}{(b^2 + c^2)(Z - c) - 2bc\sqrt{X^2 + Y^2 + (Z - c)^2}} \end{aligned} \quad (5)$$

障害物の高さは様々だが、車輪走行ロボットの場合、床面と水平に設置した全方位カメラと、平らな床面までの高さは、ほぼ変わらない。したがって床際点について、 Z は定数と考えることができ、式 (5) を用いて、画像座標系位置からロボット座標系位置を求めることができる。定数 Z , b , c , f を決定するため、床面にテープで Fig. 1 で示す格子点を作成し、格子点 m のロボット座標 (X_m, Y_m) と画像座標 (x_m, y_m) との対応を n 組獲得する。 n 組の対応点から、式 (6) で示す評価関数 F を最小にするカメラパラメータ、 Z , b , c , f を滑降シンプレックス法 [21] で求める。

$$\begin{aligned} F &= \sum_{m=0}^{n-1} \left| x_m - X_m f \frac{b^2 - c^2}{(b^2 + c^2)(Z - c) - 2bc\sqrt{X_m^2 + Y_m^2 + (Z - c)^2}} \right| \\ &+ \sum_{m=0}^{n-1} \left| y_m - Y_m f \frac{b^2 - c^2}{(b^2 + c^2)(Z - c) - 2bc\sqrt{X_m^2 + Y_m^2 + (Z - c)^2}} \right| \end{aligned} \quad (6)$$

得られたカメラパラメータを用いて、画像上のすべての点が床面上の点であるとし、投影した画像を Fig. 3 に示す。床面上の点に対しては画像上の距離が実距離と一対一に対応するので、歪みがなくなり、格子が正方形になっていることが確認できる。

3. 床際点トラッキングによる障害物識別

3.1 理想条件下での床際点トラッキングによる障害物識別

提案した Ward 法に基づく床面検出手法により、時刻 $t - dt$ において、床際点 m を画像上で検出する。検出点をトラッキングすれば、時刻 t における床際点 m の画像上の位置を計算できる。ここでは、トラッキング手法として、並進回転運動するロボットに搭載した全方位カメラで撮像した画像中でも動作することが知られている [22] ピラミッド型 Lucas-Kanade 法 [23] を用いる。Lucas-Kanade 法は、トラッキング点周囲では一様かつ小さな変化しか起きないと仮定して立てた連立方程式を解くことで、高速かつ頑健なトラッキングを行う手法である [24]。ピラミッド型 Lucas-Kanade 法は、Lucas-Kanade 法をトラッキング点の大きな変化にも応用できるように改善している。大きな変化に対応するため、トラッキング点周囲の画像において、広い範囲を示す粗い画像から、狭い範囲を示す詳細な画像まで、複数の画像をピラミッド画像として用意する。広い範囲の画像から順に Lucas-Kanade 法を適用し、広い範囲の画像のトラッキング結果を詳細な画像で利用することで、トラッキング点の大きな変化にも対応可能にする。

画像上の位置から、点 m のロボット座標系での時刻 $t - dt$, t における位置 $(X_m^{(t-dt)}, Y_m^{(t-dt)})$, $(X_m^{(t)}, Y_m^{(t)})$ をそれぞれ求める。また、時刻 $t - dt$ に対する時刻 t のロボットの相対位置姿勢 $(dX, dY, d\theta)$ は、オドメトリから得られる。床際点 m が示す障害物が静止障害物である場合、 $(dX, dY, d\theta)$ と $(X_m^{(t-dt)}, Y_m^{(t-dt)})$ から $(X_m^{(t)}, Y_m^{(t)})$ が式 (7) で計算できる。

$$\begin{pmatrix} X_m^{(t)} \\ Y_m^{(t)} \end{pmatrix} = \begin{pmatrix} \cos d\theta & -\sin d\theta \\ \sin d\theta & \cos d\theta \end{pmatrix} \begin{pmatrix} X_m^{(t-dt)} \\ Y_m^{(t-dt)} \end{pmatrix} + \begin{pmatrix} dX \\ dY \end{pmatrix} \quad (7)$$

床際点 m が移動している場合には、式 (7) は偽となるので、式 (7) は障害物が静止しているか移動しているかを示す判別式となる。ただし、式 (7) が障害物の判別式となるためには、以下のような代表的な条件を満たす必要がある。

1. オドメトリが正しく得られること
2. 推定したカメラパラメータが正しいこと
3. 床際点 m のトラッキングが成功していること
4. 床際点 m が正しく床面と障害物の境界位置に検出できていること

条件 1 について、短距離であれば、ある程度正しくオドメトリは得られる。また、条件 2 についても Fig. 3 に示すように式 (7) の真偽に影響を与えないほどには正しく推定できている。床際点 m が正しく障害物と床面との境界に位置していると、床際点 m は輝度変化が大ききところに位置していることが多いので、Lucas-Kanade 法に基づくトラッキングも正しく行いやすい。したがって、条件 3 も満たされる可能性が高い。しかし、条件 4 に関しては、床面と障害物の色が類似した場合など、満

たされない場合がある。

3.2 床際点の誤検出に対応した障害物識別

判別式成立の条件 4 以外が満たされているとき、式 (7) が偽となる場合は以下の二とおりに分けられる。

- 床際点 m が「移動障害物」と床面の境界に位置している
- 床際点 m が床面上にない

床際点 m が床面上にない場合は、式 (4) の検出閾値 σ_r が大きく、床面と障害物の区別がつかなくなることが原因の一つである。全方位の床面と障害物は様々であり、すべて同じ閾値で表すことができない。したがって、式 (7) を偽とする床際点 m については、絶対値が十分に小さい正数 $d\sigma$ だけ σ_r を小さくし、床際点 m が存在する方向に新たな床際点 m' を検出する。新たな床際点 m' について時刻 t から時刻 $t-dt$ へトラッキングし、再び式 (7) で検証するという 2 パス識別を行う。2 パス目も式 (7) が偽となれば m は移動障害物、真ならば静止障害物として時刻 t における最終的な識別結果を出す。時刻 $t+1$ 以降は、2 パス目で静止障害物として識別された場合は、 σ_r を $\sigma_r - d\sigma$ で置き換え、 m' を床際点として用い、移動障害物の場合、 σ_r を変更せず、 m' は用いない。1 パス目で式 (7) を真とする床際点は静止障害物として識別する。判別式の結果に応じて、検出閾値を σ_r から $\sigma_r - d\sigma$ に変更していくことが特徴となる。Fig. 4 に 2 パスで静止障害物と移動障害物を識別する手

Fig. 4 The steps of the obstacle classification

順を示す。

あらかじめ σ_r を小さくすれば、すべての床際点が床面上に位置すると考えられるが、障害物との境界より手前に位置することが多くなる。障害物との境界に位置しないと、ロボットが移動できる範囲を正確につかめず、ロボットの移動制御に問題が生じる。2 パス識別手法ならば、1 パス目は検出閾値を大きめに取ることで、床面を取りこぼすことなく検出する。さらに移動障害物と識別された床際点が存在した方向だけ閾値を厳しく識別しなおすことで、より正確な障害物位置定位と識別が可能になる。また、2 パス行うことで 1 パスよりも演算量が小さくなるが、床面検出とトラッキングは 1 [ms] 以下で行えるため、移動制御に影響を与えない程度の差である。

Fig. 5 に、種々の床際点に対応する処理の例を示す。床際点 a は、正確に床面と静止障害物の境界に検出されているため、式 (7) が真となり、 σ_r の変更や 2 パス識別をする必要はなく、静止障害物として識別される。床際点 b は、床面と静止障害物である壁の境界線上ではなく、壁面上に誤検出されている。床際点が床面上にない場合、式 (7) は偽となり、閾値 σ_r を $d\sigma$ だけ減少して新たな床際点 b' を検出する。新たに検出された床際点 b' を用いて再度式 (7) の真偽を見ると、 b' が正しく床面と壁の境界線上に配置されているため、式 (7) が真となり、静止障害物として識別される。床際点 c は、床と移動障害物である人との境界線上にあるため、式 (7) は偽となり、 σ_r を $d\sigma$ 減少させて新たな床際点 c' を検出する。ここで、 $d\sigma$ は十分小さく設定されているため、 c と c' は画像上で近い位置に検出される。2 パス目の識別にかけた結果、やはり式 (7) が偽となるため、床際点 c' は移動障害物として識別される。

4. 床際点検出能力評価と障害物識別実験

4.1 障害物識別システムと評価用ロボット ApriTauTM

Fig. 6, Fig. 7 にそれぞれ、障害物識別システム評価用ロボット ApriTauTM [25] と導入した障害物識別システムの概要を示す。ApriTauTM はエンコーダからオドメトリを得る台車を備えており、回転運動と並進運動を行う。オドメトリは、進んだ距離に対して 1.0% ずれる精度、具体的には 1.0 [m] 進むと、1.0 [cm] ずれる精度で得られる。また、高さ 120 [cm] の頭頂に全方位カメラを備えており、移動による床からの高さは変わら

Fig. 5 The example of classification process by using floor boundary points

Fig. 6 ApriTauTM Fig. 7 The classification system in ApriTauTM

ない。使用した全方位カメラの仰角は約 15° 、俯角は約 55° である。キャリブレーションには Fig. 1 で示した床面上の格子を用いた。格子の一辺の長さは $50[\text{cm}]$ である。カメラ画像のサイズは $320[\text{pixel}] \times 240[\text{pixel}]$ であり、 $30[\text{fps}]$ で撮像できる。ApriTauTM は移動中にオドメトリと同期してカメラ画像を時系列で撮像する。ApriTauTM が使用している CPU は Intel Core2 Duo の $1.4[\text{GHz}]$ で、メモリは $2[\text{GB}]$ である。実験で用いた床色クラスタリングに用いる閾値 T_D 、 T_N 、 p は、画像サイズを考慮して経験的にそれぞれ $18,000$ 、 $10[\text{pixel}]$ 、 3 回とした。動的閾値変更に用いる σ_r の初期値と定数 $d\sigma$ も経験的に、それぞれ 10 、 3 とした。ピラミッド型 Lucas-Kanade 法はビジョンライブラリ OpenCV の関数 [23] を用い、引数であるトラッキングに用いたウィンドウサイズは、 $3[\text{pixel}] \times 3[\text{pixel}]$ 、ピラミッド画像数は 3 とした。

ApriTauTM 内に実装された障害物識別システムは、時系列のカメラ画像とオドメトリデータを入力とし、全周囲の方向ごとの障害物識別結果を出力する。システムはまず、全方向の床際点を床面検出により検出する。初回以降は、方向ごとにトラッキングで得られた床際点または、2 パス識別に用いた床際点を用いて、毎時刻、ロボット座標系における各方向の床際点位置を保存する。得られたオドメトリも毎時刻保存されており、床際点のトラッキング結果との比較に用いられる。また、すべての床際点の識別後、 360° 各方向を 1° ごとに区切った範囲を探索し、各方向の範囲で床際点がトラッキング可能か、床際点が存

Fig. 8 The output of classification system

在するかを確認する。トラッキングが不可能になった床際点は消去し、床際点が無い範囲の方向へは、床面検出を再度行い、床際点を新たに検出する。ここでトラッキングが不可能となる床際点とは、以下の三つのいずれかの点とする。

1. 1° ごとに区切った範囲の、よりロボット側に他の床際点が存在する位置に検出された床際点
2. ロボットから $d[\text{m}]$ 以上離れた位置に検出された床際点
3. Lucas-Kanade 法で用いる方程式が解けない床際点

d は、全方位カメラ画像の分解能を考慮して $6[\text{m}]$ とした。

Fig. 8 は出力例である。Fig. 8 の中の床面と障害物の境界に多く位置している点と四角形が、床際点であり、それぞれ静止障害物、移動障害物を示す。また、移動障害物と判断された床際点の集まっている方向に向かって中心から直線が引かれている。ここでは、全周囲 360° の障害物を 1° 間隔で識別したため、 360 個の床際点を使用されている。

ソフトウェアは、再利用性を高めるため、安藤らが開発した OpenRTM-aist [26] に基づいて実装した。RTM は、ロボットを構成する要素プログラムをネットワークでつなぐ共通プラットフォームである。OpenRTM-aist は RTM の一実装形態であり、要素プログラムは RT コンポーネント (RTC) とよばれる。ここでは、画像キャプチャ RTC、障害物識別 RTC、モーター制御 RTC と、目標位置までの移動指令をモーター制御 RTC へ出力するシナリオ実行 RTC を作成した。

4.2 床際点検出能力評価実験

4.2.1 実験内容

Ward 法でクラスタリングしたあとにマハラノビス距離を用いた開発手法による床面検出器の床面検出能力を評価するため、GMM を用いた従来手法による床面検出器と比較を行った。GMM を用いた従来手法とは、入力として RGB 三次元ベクトルを与えて得た GMM の出力が、検出閾値より大きければ、対象色として識別する、文献 [18] でも用いられた手法である。実験手順として、開発手法、GMM とともに同じ学習画像を用いて、検出器を学習し、テスト画像で検出を行う、という作業を二回行う。一回目は、GMM の学習をするため人手で設定する混合数と検出閾値をテスト画像に合わせて、実験前検証を行う。二

Fig. 9 The output of first test

Fig. 10 The output of second test

回目は、一回目に最適とした混合数、検出閾値を用いて、一回目とは異なる画像について検出器を学習し、床面検出を行う。学習した検出器を用いて評価画像中の床色の検出を行い、以下の二指標で評価する。

- 床面を正しく床面とした割合 (Hit)
- 床面以外を正しく床面以外とした割合 (CR)

4.2.2 検出結果と考察

事前検証を行い最適設定した GMM で検出した結果と開発した検出器で床面を検出した結果をそれぞれ Fig. 9 に示す。ここで GMM の最適設定は混合数 3、検出閾値 0.04 となった。95% もの高精度で床面検出を行うことができているため、設定は問題ないと考えられる。Fig. 9 中の (a), (b) で示される白黒図中の白部分はシステムが床面であると判断した部分である。Fig. 10 は新たに事前検証をせず、一回目の床面検出における最適設定と同じ設定を用いて学習と床面検出を行った結果である。また、検出器の出力を基に計算した、Hit, CR を Table 1 に示す。Table 1 から、時間をかけて事前検証した GMM による検出器と開発手法の床面検出能力はほとんど変わらないことが分かる。しかし一回目とは別の場所で行った二回目の実験では、一回目の床面で最適設定とした混合数、検出閾値を用いた GMM と開発手法とで、Hit に大きな差が出た。したがって、両

Table 1 Comparing the GMM method with our method

Method	Hit	CR
GMM, First Test (Optimized Parameters)	0.95 (7277/7655)	0.95 (65826/69145)
Ours, First Test (Optimized Parameters)	0.94 (7210/7655)	0.96 (66029/69145)
GMM, Second Test (First Test Parameters)	0.73 (13204/18022)	0.96 (203953/212378)
Ours, Second Test (First Test Parameters)	0.90 (16245/18022)	0.95 (202061/212378)

手法の最大検出性能に違いは少ないが、開発手法が学習をより容易に行うことができると考えられる。二回目の実験で GMM の Hit が下がった理由として、二回目の実験場所における床面は、色違いのタイルが一回目の実験場所に比べて多かったことがあげられる。メインとなる床色に加え、100 [pixel] ほどの単位で広がる床色が複数あり、一回目の実験で用いた混合数では対応しきれなかった。開発手法は、床色を、床色データの偏差に基づきボトムアップ的に抽出している。したがって、GMM ほど経験的な設定をしなくても、多様な色も学習し、検出が可能になったと考えられる。

4.3 従来手法との比較による 2 パス障害物識別効果確認実験

4.3.1 実験内容

識別を 2 パスに分けて行う効果を調べるため、従来システムと 1 パスだけで移動障害物を検出するシステムと、2 パスで移動障害物を検出する開発システムとの比較を行った。ここでは実装が容易であったため、従来システムとして、得られた全方位画像をパノラマ展開し、全体の背景の流れと異なる場所を検出する手法をとった。床色は、ロボットの左右 50 [cm]、前方 200 [cm] の矩形領域を指定範囲として、指定範囲に障害物がない状態でロボットを起動し、撮像画像の指定範囲内データを用いて学習している。実験手順は以下のとおりである。

1. ApriTauTM と別ロボットが 3.0 [m] 離れた位置からすれ違う方向に、それぞれ 0.6 [m/s] のスピードで 3.0 秒間同時に直線移動を開始する。
2. ApriTauTM は移動中に時系列で同期させて、全方位カメラ画像とオドメトリを 1.0 秒間に 30 データ記録する。
3. 取得した時系列のカメラ画像とオドメトリデータを入力とし、2 パス障害物識別システムと 1 パス障害物識別システムと従来システムの出力を得る。
4. 出力結果から識別率を算出し、比較する。

ここで用いる識別率は式 (8) (9) で示した再現率 R 、適合率 P から計算される F 値として、式 (10) のように定義する。ただし、 A , O , C はそれぞれ移動障害物が撮像された入力画像の枚数、システムが移動障害物として検出した全出力数、システムの正しい移動障害物位置出力数である。

$$R = C/A \quad (8)$$

$$P = C/O \quad (9)$$

$$F = 2RP/(R + P) \quad (10)$$

Fig. 11 The experimental setting

Table 2 The classification ratios

Method	Recall Ratio	Precision Ratio	F-value
Previous	0.18 (3/17)	0.25 (3/12)	0.21
1 Path	0.63 (10/16)	0.13 (10/79)	0.21
2 Path	0.94 (17/18)	0.77 (17/22)	0.85

周囲環境も含めた実験設定を Fig. 11 に図示する。周囲は静止障害物が設置されており、ApriTau™ と別ロボットは 1.5 [m] 離れてすれ違う。

4.3.2 実験結果と考察

従来システムで識別した場合と、1パスだけで識別した場合と、2パスで識別した場合の識別率を Table 2 に示す。2パスで識別を行う方式の識別率は他システムの識別率より 4 倍高くなった。2パス識別により、1パス目で識別した出力のうち移動障害物だけを適切に選択でき、識別率の計算に用いた適合率が改善されたことが一因と考えられる。

従来システムの識別率が低い理由は、歪みの影響もあるが、ApriTau™ と障害物はすれ違う向きに進んでいたことが大きな問題となった。すなわち、背景の流れと同じ方向に障害物も進んでいたため、障害物の移動の方向が背景の流れに埋もれてしまったことが識別率を下げた一因と考えられる。今回の実験では、実装が容易であったことと、低解像度の全方位画像をパノラマ展開した際に最も精度がよくなる移動体検出手法に見当がつかなかったため、単純な手法と比較した。今後はさらに複雑な手法との比較も重要であると考えている。

また、改善されたとはいえ、2パスで識別を行った場合も適合率はまだ低い。原因として、今回は誤差が小さいとして取り扱わなかったトラッキングミスの影響が考えられる。実際、トラッキングミスは数画素単位の誤差でしかなかったが、全方位カメラ画像の場合、遠方の物体ほど距離計測分解能は悪くなる。数画素単位の誤差が、実距離にすると数 [m] の誤差になり、式 (7) が成り立たなくなる。したがって、遠方にある床際点を扱う場合は、式 (7) の成立を短期的な 1 回の移動量で判断せず、トラッキング時間を長くし、移動量の平均を用いて判断するといった誤差対策が必要である。

4.4 人を識別対象とした識別精度の確認実験

4.4.1 実験内容

2パス障害物識別手法が、識別対象が人であっても動作するこ

Fig. 12 The experimental setting (Pattern 1 and 3)

Fig. 13 The experimental setting (Pattern 2 and 4)

とを確認するため、識別対象をロボットではなく、人に変更した。実験協力者となる人は ApriTau™ 周囲を、経路や速度をあらかじめ定めた Pattern 1 から Pattern 5 までの 5 パターンで移動する。Pattern 1 から Pattern 4 は、二種類の経路と、二種類の速度の組み合わせである。二種類の移動経路は、ロボットとすれ違う経路とロボットとすれ違ったあとに並走する経路である。二種類の移動速度は人が歩く速度の約 1 [m/s] と、軽く走る速度の約 2 [m/s] である。人が歩いてすれ違う場合、歩いてすれ違ったあとに歩いて並走した場合、人が走ってすれ違う場合、走ってすれ違ったあとに走って並走した場合をそれぞれ Pattern 1, 2, 3, 4 と表す。すれ違うだけの経路の場合は 3 秒間、すれ違って並走する経路の場合は 6 秒間、人とロボットは移動する。また、回転運動についても検証を行うため、Pattern 5 として、ロボットが 90° 反時計回りに 0.5 [rad/s] で 3 秒間旋回した際に、人がロボットから半径 2.0 [m] の円周上を歩いて移動する場合も実験した。Pattern 1 と 3 の移動経路、Pattern 2 と 4 の移動経路、Pattern 5 の移動経路をそれぞれ Fig. 12, Fig. 13, Fig. 14 に示す。正確な正解を得て、開発手法の基本性能を知るため、移動障害物となる実験協力者は一人とする。実験手順と周囲環境、精度評価指標は 4.3.1 項と同様の設定で、同期した画像とオドメトリデータから、2パス識別を行い、識別率で評価する。また、ここでは急に動き出した人への対応も考察するため、人が動き出してから正しく識別し始めるまでの時間も計算速度評価指標として使用する。

Fig. 14 The experimental setting (Pattern 5)

Table 3 The classification ratios in various cases

Pattern	Recall Ratio	Precision Ratio	F-value
1	1.00 (21/21)	0.64 (21/33)	0.79
2	0.98 (42/43)	0.64 (42/67)	0.77
3	0.80 (16/20)	0.64 (16/29)	0.71
4	0.93 (42/45)	0.59 (42/74)	0.72
5	0.93 (13/14)	0.57 (13/23)	0.71

Table 4 The calculation time of the classification

Pattern	1	2	3	4	5
Time [ms]	810	720	330	420	90

4.4.2 実験結果と考察

識別結果を Table 3 に示す。人が歩いている場合は、識別対象が移動ロボットである場合よりも精度は悪くなるが、識別率 0.77 以上の高精度で識別している。走っている場合は、歩いている場合よりも精度が落ち、識別率 0.71 程度である。人が移動している方向に関してはあまり精度に違いが見られていない。また、回転運動に対しても識別率 0.71 となり走っている場合と同程度の精度となった。

Table 4 に、急に動き出した人を正しく検出するまでの時間を示す。ロボットから距離が遠い場所でゆっくり移動を開始している Pattern 1 や Pattern 2 は識別に時間がかかっているが、近距離で移動を開始している Pattern 5 では 90 [ms] で識別が完了している。いったん識別したあとは、すべてのパターンにおいて平均 23 [ms] で障害物をトラッキングできており、画像取得のフレームレート内で計算を終えている。

ApriTau™ は 0.6 [m/s] で移動するよう設定されているため、Pattern 2 と Pattern 3 の折り返し以降、ロボットから見た人の移動速度はほぼ等しい。したがって、人が走っている場合と歩いている場合で精度に差が出た理由として、障害物の床面との接触境界の複雑さが考えられる。歩いている場合は両足が地面についており、走っている場合よりも床際点を安定して検出することができる。屋内施設での利用を考えた場合、移動障害物は人工物か人であることが多いので、人が走っている姿以上に床面との接触境界が複雑になることは少ない。しかし、開発手法を屋外で使用する際は、地面との接触境界が複雑な移動障害物も多いため、複雑な境界線に対応できるよう、カメラの

解像度や床際点の数を増加する必要があると考える。回転運動が、直進運動中に直線上を歩いている人を識別するよりも識別率が低くなった理由は、回転方向の画像中のトラッキング領域の変化が、直進方向の変化よりも大きかったことが考えられる。回転運動に関しては、カメラのフレームレートを上げるなどして、画像変化を、ピラミッド型 Lucas-Kanade 法がより正確にトラッキングできる範囲にする工夫が必要となる。

計算速度について、Pattern 5 で最も速く障害物を識別できた理由は、近距離で移動する物体は、画像中で大きく移動し、動きがとらえやすかったためであると考えられる。近距離にある物体ほど高速に識別できることは移動ロボットにとって都合がよい。実際の大型スーパーでは、曲がり角のように、見え方が変化する場所において、人が急に現れた場合などに対応する必要がある。Pattern 5 のように 1 [m/s] で歩く人が急に現れた場合、90 [ms] の識別時間の間に人は 9 [cm] 進む。大型スーパーの通路幅を考慮すると 9 [cm] は十分に小さく、ロボットの移動に十分なスペースとして確保できる。ロボットが角を曲がるとき、死角になる位置から 10 [cm] 以上の間隔をとって移動することで、開発手法が有効に働き、必要に応じて停止または回避行動をとることができると考えられる。

5. おわりに

本研究では、移動中のロボットによる移動障害物検出を目的とし、一つの移動全方位カメラによる全周囲障害物識別という課題に取り組んだ。課題解決のため、一つの全方位カメラでも実距離を計測可能な障害物と床面の境界点である床際点に着目した。まず Ward 法を用いて床色をクラスタリングし、マハラノビス距離を用いて床面を検出した。床面検出の結果から、床面と床面以外の部分の境界点である「床際点」を検出した。次に、検出した床際点をトラッキングし、床際点の軌跡とオドメトリとの比較結果に応じて障害物を識別した。床際点誤検出による誤識別を減少するため、一回目の比較結果に基づき、閾値を変更して新たな床際点を見つけ、再度比較をするという 2 パス識別方式を開発した。開発した床面検出法と GMM による床面検出法を比較した結果、同等の検出性能があり、学習がより容易に行えることが判明した。さらに、背景の流れと異なる場所を検出する従来手法、1 パスによる障害物識別手法と 2 パスによる障害物識別手法を比較した。比較の結果、2 パス障害物識別手法による識別率は他手法の識別率よりも 4 倍高くなることが分かった。開発した障害物識別手法は、移動障害物と床面の境界線が単純であれば、より精度が高くなることも判明した。

開発手法は、学習時の床色パターンが広がる屋内の環境において、ロボットから距離 3 [m] 程度までの障害物識別が行える。現状では、床色パターンが変わる場所へ移動した場合は、床色パターン境界が静止障害物として識別され、回転中や遠方障害物識別時は、識別が不安定になる。今後は適用範囲拡大を目指し、床際点を遠方拡散して識別する手法や、障害物との距離やロボット動作に応じた障害物識別手法を開発する予定である。

謝辞 本研究の一部は、独立行政法人新エネルギー・産業技術総合開発機構 (NEDO) の戦略的先端ロボット要素技術開発プロジェクトの支援により行われた。

参 考 文 献

- [1] 宮下善太, 神田崇行, 塩見昌裕, 石黒浩, 萩田紀博: “顧客と顔見知りになるショッピングモール案内ロボット”, 日本ロボット学会誌, vol.26, no.7, pp.821–832, 2008.
- [2] 神田真司, 村瀬有一, 沢崎直之, 麻田務: “サービスロボット「enon」の開発”, 日本ロボット学会誌, vol.24, no.3, pp.288–291, 2006.
- [3] M. Takahashi and T. Suzuki: “Multi Scale Moving Control Method for Autonomous Omni-directional Mobile Robot,” 6th International Conference on Informatics in Control, Automation and Robotics, pp.449–452, 2009.
- [4] Z. Jia, A. Balasuriya and S. Challa: “Sensor Fusion based 3D Target Visual Tracking for Autonomous Vehicles with IMM,” IEEE International Conference on Robotics and Automation, pp.1841–1846, 2005.
- [5] M. Weser, D. Westhoff, M. Hiiser and J. Zhang: “Multimodal People Tracking and Trajectory Prediction based on Leamed Generalized Motion Patterns,” IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems, pp.541–546, 2006.
- [6] Z. Chen and S.T. Birchfield: “Person Following with a Mobile Robot Using Binocular Feature-Based Tracking,” IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.815–820, 2007.
- [7] H. Kwon, Y. Yoon, J.B. Park and A.C. Kak: “Person Tracking with a Mobile Robot using Two Uncalibrated Independently Moving Cameras,” IEEE International Conference on Robotics and Automation, pp.2877–2883, 2005.
- [8] 小関亮介, 箕浦良文, 藤吉弘亘, 秋田時彦, 柿並俊明: “協調的な複数の Mean-Shift トラッカによる後方車両追跡”, 画像の認識・理解シンポジウム, pp.419–426, 2005.
- [9] P. Nordlund and T. Uhlin: “Closing the Loop: Pursuing a Moving Object by a Moving Observer,” Image and Vision Computing, pp.400–407, vol.14, issue 4, 1996.
- [10] B. Jung and G.S. Sukhatme: “Detecting Moving Objects using a Single Camera on a Mobile Robot in an Outdoor Environment,” Conference on Intelligent Autonomous Systems, pp.980–987, 2004.
- [11] G. Chivilo, F. Mezzaro, A. Sgorbissa and R. Zaccaria: “Follow-the-Leader Behavior through Optical Flow Minimization,” IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.3182–3187, 2004.
- [12] M. Piaggio, R. Formaro, A. Piombo, L. Sanna and R. Zaccaria: “An Optical-Flow Person Following Behavior,” IEEE ISIC/CIRNISAS Joint Conference, pp.4078–4083, 1998.
- [13] A. Kundu, K.M. Krishna and J. Sivaswamy: “Moving Object Detection by Multi-View Geometric Techniques from a Single Camera Mounted Robot,” IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.4306–4312, 2009.
- [14] Y. Negishi, J. Miura and Y. Shirai: “Calibration of Omnidirectional Stereo for Mobile Robots,” IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.2600–2605, 2004.
- [15] 山澤一誠, 八木康史, 谷内田正彦: “移動ロボットのナビゲーションのための全方位視覚系 HyperOmniVision の提案”, 電子情報通信学会論文誌 D-2, vol.J79-D-2, no.5, pp.698–707, 1996.
- [16] I. Horswill: “Visual Collision Avoidance by Segmentation,” IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.902–909, 1994.
- [17] N.X. Dao, B.-J. You and S.-R. Oh: “Visual navigation for indoor mobile robots Using a single camera,” IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.3389–3394, 2005.
- [18] H. Takeshima, T. Ida and T. Kaneko: “Extracting Object Regions Using Locally Estimated Probability Density Functions,” IAPR Conference on Machine Vision Applications, pp.465–468, 2007.
- [19] J.H. Ward: “Hierarchical Grouping to Optimize an Objective Function,” Journal of the American Statistical Association, vol.58, no.301, pp.236–244, 1963.
- [20] 山澤一誠, 尾上良雄, 横矢直和, 竹村治雄: “全方位画像からの視線追従型実時間画像生成によるテレプレゼンス”, 電子情報通信学会論文誌 D-2, vol.J81-D-2, no.5, pp.880–887, 1998.
- [21] J.A. Nelder and R. Mead: “A simplex method for function minimization,” Computer Journal, vol.7, pp.308–313, 1965.
- [22] 川西亮輔, 山下淳, 金子透: “全方位カメラを用いた周囲環境計測のための特徴点フローモデルによる位置姿勢推定”, 映像情報メディア学会技術報告, vol.33, no.11, pp.65–68, 2009.
- [23] J.-Y. Bouguet: “Pyramidal Implementation of the Lucas Kanade Feature Tracker,” OpenCV Documentation, Intel Corporation, Microprocessor Research Labs, 1999.
- [24] B.D. Lucas and T. Kanade: “An Iterative Image Registration Technique with an Application to Stereo Vision,” International Joint Conference on Artificial Intelligence, pp.674–679, 1981.
- [25] S. Tokura, T. Tasaki, T. Sonoura, M. Sano, N. Matsuhira and K. Komoriya: “Robotic Transportation System for Shopping Support Services,” IEEE International Symposium on Robot and Human Interactive Communication, p.320, 2009.
- [26] N. Ando, T. Suehiro, K. Kitagaki, T. Kotoku and W.-K. Yoon: “RT-Middleware: Distributed Component Middleware for RT (Robot Technology),” IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.3555–3560, 2005.

田崎 豪 (Tsuyoshi Tasaki)

2006 年京都大学大学院情報学研究科知能情報学専攻修士課程修了。同年 (株) 東芝入社。ロボットビジョンなどを用いたロボット周囲環境認識の研究開発に従事。現在研究開発センターヒューマンセントリックラボラトリー研究員。

(日本ロボット学会正会員)

十倉征司 (Seiji Tokura)

2004 年名古屋大学大学院電気工学専攻博士後期課程満了。同年 (株) 東芝入社。博士 (工学)。自律移動ロボットの制御とロボットシステムの設計に関する研究に従事。現在同社研究開発センターヒューマンセントリックラボラトリー研究主務。

(日本ロボット学会正会員)

園浦隆史 (Takafumi Sonoura)

2003 年東京工業大学理工学研究科機械制御システム専攻修士課程修了。同年 (株) 東芝入社。移動作業ロボットをはじめロボット制御技術の研究・開発に従事。現在同社研究開発センター機械・システムラボラトリー研究員。

(日本ロボット学会正会員)

尾崎文夫 (Fumio Ozaki)

1983 年京都大学大学院修士課程 (電気工学専攻) 修了。同年 (株) 東芝入社。博士 (工学)。原子力発電所用、産業用、サービスロボットなどの研究開発に従事。ロボットコントローラのソフトウェアシステムに興味を持つ。国際熱核融合実験炉 (ITER) の遠隔保守装置の開発にも従事。現在同社電力システム社新技術応用システム技術部部長代理。

(日本ロボット学会正会員)

松日楽信人 (Nobuto Matsuhira)

1982 年東京工業大学大学院修士課程修了。(株) 東芝研究開発センターにてロボットの研究開発に従事。同社技監を経て 2011 年より芝浦工業大学機械機能工学科教授。日本機械学会 (フェロー, 評議員), 計測自動制御学会 (SI 部門前部門長) 等の会員。工学博士。

(日本ロボット学会正会員)