

全方位ステレオとレーザレンジファインダの統合による 移動ロボットの地図生成

根 岸 善 朗* 三 浦 純* 白 井 良 明*

Map Generation of a Mobile Robot by Integrating Omnidirectional Stereo and Laser Range Finder

Yoshiro Negishi*, Jun Miura* and Yoshiaki Shirai*

This paper describes a map generation method using an omnidirectional stereo and a laser range finder. Omnidirectional stereo has an advantage of 3D range acquisition, while it may suffer from a low reliability and accuracy in range data. Laser range finders have advantage of reliable acquisition of data, while they usually obtain only 2D range information. By integrating these two sensors, a reliable map can be generated. Since the two sensors may detect different parts of an object, a separate probabilistic grid map is first generated by temporal integration of data from each sensor. The resultant two maps are then integrated using a logical integration rule. An ego-motion estimation method is also described, which is necessary for integration of sensor data obtained at different positions. Experimental results on autonomous navigation in unknown environments show the feasibility of the method.

Key Words: Mobile robot, Omnidirectional stereo, Laser range finder, Sensor fusion, Probabilistic model of uncertainty.

1. は じ め に

障害物や空いている空間を発見することは移動ロボットのセンサシステムに必要不可欠な機能である。この機能は、ロボットに地図が与えられている場合にも、未知障害物や地図の誤差に対処するために必要である。

多くの研究で障害物の発見にステレオ視を用いている[1][2]。ステレオ視は距離だけでなく、画像から視覚的特徴を得ることもできるという利点があるが、従来のステレオ視では通常のカメラを用いているため、視野が狭いという欠点がある。そこで、我々は全方位ステレオシステムを開発した[3]。このシステムはほぼ360度全景の距離情報を得ることができる。しかし依然として、誤対応が生じたり、遠い距離にある物体に対して比較的低い精度のデータしか得られないという、ステレオ視自体の欠点を持っている。

レーザレンジファインダ(LRF)も同様に広く用いられており、データの精度や信頼性の高いセンサである[4][5]。多くのLRFは2次元平面を走査し、その面内の距離を観測する。したがって、平らな壁に囲まれたような比較的単純な環境において、より有用といえる。しかし、LRFでテーブルを観測し

たときには、脚の部分しか観測されず、テーブルの領域を空いていると認識してしまう可能性がある。

信頼性の高い地図を作成するためには、複数のセンサデータを統合する手法が典型的である[6]~[9]。そこで、3次元的な観測が得られる全方位ステレオと、精度や信頼性の高い観測が得られるLRFのそれぞれの長所を組み合わせることで、より良い環境認識ができると考えられる。

本研究では全方位ステレオとLRFを統合して、静的環境下でロボットの移動可能な空き領域の地図を作成する手法を提案する。この2つのセンサは同じ物体を違う距離で観測する場合がありますが、直接確率的に重ね合わせることはしない。提案する手法では、各センサごとに時系列データを統合することで確率的障害物地図を作成する。この時系列統合はセンサの不確かさのモデルを用いて行なう。その結果作成された2枚の地図を、センサや環境の特徴を考慮して設定した規則によって統合する。

また、別の位置で得られたデータを統合するために必要となる、自己移動量推定の手法についても述べる。この手法をFig. 1の移動ロボットに実装して実験を行なった結果、ロボットは未知環境を自律的に移動することができた。

2. レンジセンサ

2.1 全方位ステレオ

本研究では、Fig. 1のように全方位カメラを垂直に配置し

原稿受付 2002年11月25日

*大阪大学大学院工学研究科

*Graduate School of Engineering, Osaka University




Fig. 2 Omnidirectional stereo generates a panoramic disparity image.




Fig. 1 Our mobile robot.

て使用している．入力された全方位画像をパノラマ画像に変換する．得られる 2 枚の画像は垂直方向にエビボーラ拘束を持つため [10]，通常のステレオ変換アルゴリズムを適用し，視差を得ることができる．本研究で使用しているパノラマ画像サイズは 360×50 で，視差の探索範囲は 50 である．画像入力からパノラマ変換，視差画像取得にかかる計算時間は Pentium III 850MHz の PC で 1 フレームあたり約 0.18[s] である．Fig. 2 に入力画像とパノラマ画像，そして視差画像の例を示す．視差画像（右下図）では，視差が大きい（距離が近い）点ほど明るく表示している．

全方位ステレオにより，ロボット全周における 3 次元的な障害物のセンサデータが得られるが，ここでは空いている領域の地図作成が目的であるので，視差画像から各方向における最近傍の障害物までの視差を取り出したものを全方位ステレオによるセンサデータとする．障害物までの距離が大きくなるとセンサデータの精度は悪くなるため，本研究ではロボット周囲 5[m] までのデータのみを使用し，5[m] を超えた部分のデータは使用しない．

2.2 レーザレンジファインダ (LRF)

本研究では SICK 社のレーザレンジファインダ (LRF) を使用している．この LRF を Fig. 1 のようにロボットの正面に，床面高さ 35[cm] の水平面を走査するように設置している．角度解像度は 1[deg] に設定しており，測距精度は ± 5 [cm] である．Fig. 2 の環境での観測データ例を Fig. 3 に示す．




Fig. 3 An example LRF measurement. The black triangle indicates the position and the direction of the robot.

3. センサの統合による地図生成

本節では，得られた 2 種類のセンサデータを統合し，空いている領域の地図を作成する手法を述べる．

不確かさを含んだセンサのセンサデータの統合手法として，センサの不確かさをモデル化したものを用いて，場所ごとに障害物の存在確率を計算する方法がある [6]．2 種のセンサのセンサデータを統合する際にも，同様に 2 つのセンサデータを同等に扱い，1 つの確率地を計算する手法が考えられる．この場合，どちらかのセンサデータが得られるたびにそれらを確率的に統合して 1 枚の地図を作ることになる．しかし，この手法は各センサから基本的に同じ距離の観測が得られる場合には適用できるが，それぞれ違う観測が得られる場合には不適切である．典型的な例として，ロボット正面にテーブルが存在する場合を考える．ステレオではテーブルの台の部分と，見えていれば脚の部分を観測することができるが，LRF では脚の部分しか観測することができない．その結果，ステレオからはその部分に障害物があるという観測が得られ，LRF からは空いているという観測が得られることになる．この 2 つの観測を単純に統合してしまうと，テーブルのある場所では障害物が存在している状態と空いている状態の間，障害物の存在確率でいうと 0.5 程度の状態に落ち着いてしまう可能性がある．ナビゲーションの面から考えると，この結果は望ましくない．この例では，ステレオでは障害物が存在するという観測があるため，LRF から障害物が存在しないという観測があっても障害物が存在していると認識すべきである．

物体の形状と，センサからどのような距離情報が得られるかを考慮して，センサデータから物体の存在位置を計算するためのモデルを作成し，それを用いて 2 種のセンサデータを一つの確率的な地図に統合することも考えられる．例えば，脚があ




Fig. 4 Determination of grid attributes.

ればその周辺にテーブルの存在の可能性を計算するという方法が考えられる。しかし、この統合方法では環境に存在する全ての物体モデルを用意する必要があり、現実的ではない。

そこで、我々は以下のような手法でセンサデータを統合する。まず、得られたセンサデータをセンサごとに時系列で統合し、グリッドごとの障害物の存在確率を示した地図（確率的障害物地図と呼ぶ）を2枚作成する。そして、それぞれの確率的障害物地図の各グリッドを、障害物の存在確率の値と観測の信頼性の指標となる観測回数に応じて分類する。最後にその分類をもとに統合を行ない、障害物の存在しない領域（空き領域）を表わす地図（空き領域地図）を作成する。

3.1 センサデータの時系列統合

Elfes[6]はOccupancy gridによって不確かさを含んだ超音波センサのデータを時系列統合する手法を提案している。グリッドは障害物の存在するかどうかの確からしさの値を持っており、センサデータを統計的に統合することで確からしさを更新している。グリッドの確率の更新は他のグリッドに対して独立に行なわれている。

Thrun[11]は前向きモデル（forward sensor model）を用いることで、グリッド同士が独立であるという仮定（独立仮定）を使うことなく超音波センサの観測から地図を作成している。前向きモデルとは、障害物（原因）が存在したときにどのような観測（結果）が得られるかをモデル化したものである。[6]では、観測（結果）が得られたときにどのような障害物（原因）が存在するかをモデル化する後ろ向きモデル（inverse model）が用いられているが、前向きモデルのほうがより自然なモデルである。我々も、ステレオ視に基づく前向きモデルを用いた環境認識を行なっている[12]。

独立仮定を置くと、あるグリッドに対して複数の観測が得られる場合に、矛盾が生じる場合がある。特に、超音波センサのように角度解像度の低いセンサを用いている場合、1つのデータから判断すべき領域が大きくなり、その分複数の観測が得られるグリッドの数が増える。しかし、独立仮定を置かずに前向きモデルを用いた確率的な障害物地図を作成する手法は、高次元の探索が必要となる（例えばEMアルゴリズム[11]を用いる）。そこで、我々は独立仮定の下で前向きモデルを適用する。本研究で用いている全方位ステレオやLRFは角度解像度が高いため、独立仮定を置いたときに起こる問題は少なくなり、また独立仮定を置くことで計算コストを減らしている。

3.2 センサデータの解釈と時系列統合手法

ある観測が得られたとき、その観測から観測範囲内のグリッドにFig. 4に示すようにラベルをつける。Fig. 4は観測のう

ちのある一方の角度解像度分のグリッドについてのラベル付けを示している。 R は各センサによる最も近い障害物までの距離であり、測距精度を考慮した距離 R_{min} から R_{max} の間に真の障害物までの距離があると考えられる[3]。そこで、この R_{min} から R_{max} の間に含まれる各グリッドを障害物があるという観測があった範囲として占有（occupied）とラベル付けし、それより手前に含まれるグリッドを障害物がないという観測があった範囲として空き（free）とラベル付けする。そして、占有領域の後方を、観測データからは判断のつかない範囲として不明（unknown）とラベル付けする。また、ステレオで特徴のない面を観測した場合などに対応付けができない場合には、その方向の全ての範囲にも不明のラベルを付ける。

これらの解釈を用いて、センサごとに確率的障害物地図を更新する。いま、障害物が存在すると観測された事象を O で表現する。上述のラベル付けにおいて、占有とラベル付けされたグリッドでは事象 O が起こり、空きとラベル付けされたグリッドでは事象 $\bar{O}$ が起こっている。不明と判断されたグリッドには、現在の観測から何の情報も得られないということなので、 O も $\bar{O}$ も起こらない。具体的には、以下の手法で確率的障害物地図の更新を行なう。

いま、障害物が存在するという事象を E で表現し、あるグリッドの障害物の存在確率を $P(E)$ で表現する。確率地図は以下の条件付き確率を計算することで更新する。

• 事象 O が起こったグリッドに対して： $P(E|O)$

• 事象 $\bar{O}$ が起こったグリッドに対して： $P(E|\bar{O})$

これらの確率は、ベイズの定理を用いて以下のように計算する。

$$P(E|O) = \frac{P(O|E)P(E)}{P(O|E)P(E) + P(O|\bar{E})P(\bar{E})}$$

$$P(E|\bar{O}) = \frac{P(\bar{O}|E)P(E)}{P(\bar{O}|E)P(E) + P(\bar{O}|\bar{E})P(\bar{E})}$$

ここで、 $P(E)$ は事前確率で、初期値は0.5とする。この式を計算するために、 $P(O|E)$ と $P(O|\bar{E})$ を決定する。これらは、センサの不確かさの前向きモデルに相当する。その他の項は、 $P(\bar{O}|E) = 1 - P(O|E)$ 、 $P(\bar{O}|\bar{E}) = 1 - P(O|\bar{E})$ 、 $P(\bar{E}) = 1 - P(E)$ で求められる。確率の更新はグリッドごとに独立に行なう（独立仮定）。


確率的障害物地図はロボット中心から前後左右5[m]の局所領域のみを保持している。移動量推定に基づき前回の観測位置における確率的障害物地図を今回の観測位置における地図に座標変換した後、変換した地図の各グリッドの確率値を、以上の計算を行なって更新する。

3.3 センサの不確かさのモデル

2つのセンサの不確かさのモデルである $P(O|E)$ と $P(O|\bar{E})$ は、以下のように決定する。

3.3.1 ステレオの不確かさのモデル

$P(O|E)$ は、実際に障害物が存在するときに観測が得られる確率である。ステレオの場合、例えば、十分な特徴を得にくい面を観測したときなど、状況によっては正しいマッチングが行なわれず、真の距離が得られない場合がある。このような誤ったマッチングが起こる場合は、一般に物体との距離が離れてい

Fig. 5 Stereo uncertainty model, $P(O|E)$

て物体の画像中のサイズが小さい場合に多い．そこで，物体の画像中でのサイズは距離に反比例することから， $P(O|E)$ も距離に反比例するモデルとした．上側の全方位カメラが床面を観測できる最小距離は 1.3[m] であるので，その距離における確率を経験的に 0.8 と設定した．それよりも近い距離にあるグリッドについては，障害物が発見されたとき（占有とラベル付けされたとき）にのみ確率を更新する．この領域で発見された障害物が真に最も近い障害物であるかどうかは分からないため，1.3[m] より近い領域の $P(O|E)$ の値は 0.5 に設定している．以上で決定したステレオの $P(O|E)$ を Fig. 5 に示す．次に， $P(O|\bar{E})$ であるが，これは存在しないものを観測する確率で，ステレオの誤対応の確率にあたり，現在 0.05 と設定している．

3.3.2 LRF の不確かさのモデル

LRF の観測は精度や信頼性が高く，またその信頼性は障害物までの距離に依存しない．このことから， $P(O|E)$ は 0.9 に， $P(O|\bar{E})$ は 0.05 に設定している．

3.4 2 種類の確率的障害物地図の統合

2 種類の確率的障害物地図を以下のように統合する．確率の値を用いて直接的に統合すると，一方のセンサから障害物が存在するという観測が得られ，他方のセンサから障害物が存在しないという観測が得られた場合，その空間の障害物の存在確率は下がってしまう．しかし，先に述べたようにこのような直接的な統合は望ましくない．そこで，以下のように確率地図のグリッドを分類し，その分類をもとにして統合を行なう．

まず 2 種類の確率地図の各グリッドごとを，その確率と 2 つのしきい値によって 3 種類に分類する．現在，しきい値は経験的に決定しており，0.7 を超えるグリッドについては障害物の存在する領域を示す障害物 (obstacle) と分類し，0.2 を下回るグリッドについては空いている領域を示す空き領域 (free space) と分類する．そして，この中間の値であるグリッドを判断のつかない領域を示す不定 (undecided) と分類する．

不定に分類される状況には，以下の 2 つがある．1 つはロボットがその領域を十分な回数観測しているのに，ステレオで特徴の少ない面を観測したときのようにセンサデータが得られず，状況を判断するに十分な情報が得られない場合である．この状況では，もう一つのセンサの観測を信頼することになる．この状況を，観測十分な不定 (undecided with observation) と分類する．もう一方の状況は，その部分の観測回数が少ないために，様子がはっきり分かっていない状況である．この状況では，さらに観測を重ねることでその領域を正しく認識できる可能性があり，たとえもう 1 つのセンサで空き領域と認識さ

Table 1 The integration rule.

OB: obstacle FS: free space

UD_{wt}: undecided with observationUD_{wo}: undecided without observation

		stereo			
		OB	UD _{wo}	UD _{wt}	FS
L	OB	OB	OB	OB	OB
R	UD _{wo}	OB	OB	OB	OB
F	UD _{wt}	OB	OB	OB	FS
	FS	OB	OB	FS	FS

れていてもその領域に立ち入ることは危険である．本研究では，不確かさの確率モデルを使い，また観測を確率的に統合しているため，グリッドの状態を決定するためには数回の観測が必要である．したがって，グリッドに対する観測が少ない場合は，その部分が十分な回数観測できるまで待たなければならない．この後者の状況を観測不十分な不定 (undecided without observation) と分類し，観測回数が十分な観測回数の基準である N を超えたとき（前者の状況），観測十分な不定と分類する．

十分な観測回数 N は以下のように決定した．典型的な状況として，ステレオの測距範囲で最も遠い 500[cm] 前方の領域の情報を知りたいとき，完全に未知（障害物の存在確率が 0.5）な領域が空きであると決定するためには，現在のステレオの不確かさのモデルとグリッドの分類のためのしきい値を用いた場合，5 回の観測が必要になる．このことから， $N = 5$ とした．同様に LRF では $N = 1$ とした．

最後に，これらの分類をもとにして，空き領域地図を作成する．以下の考えを基本として統合を行なう．

- 全ての障害物は，少なくとも一方のセンサにより観測がなされる．つまり，障害物だという分類は信頼できる．
- 前述のように，一方のセンサが観測不十分な不定の場合には，もう一方のセンサの観測を信頼する．
- もし両方のセンサが共に空いているとも障害物だとも決定できないときは，安全を考慮して障害物と認識する．

これらの考えに基づき，2 つのセンサから両方とも空きであると分類されたグリッドと，一方のセンサで空きであると分類され，他方のセンサでは観測十分な不定と分類されたグリッドを最終的な空き領域と判断する．それ以外の領域は侵入すべきでない障害物領域と判断する．以上の統合規則をまとめると Table 1 のようになる．確率的障害物地図の分類と統合の処理は毎フレーム，確率的障害物地図が更新された後に行なう．作成された空き領域地図は移動ロボットの経路生成に用いる．

4. LRF の観測データに基づく自己移動量推定

異なる場所で観測された複数のデータを統合する際，ロボットの自己移動量の推定が必要である．我々のロボットでは内界センサであるエンコーダの情報からデッドレコニングを行なっているが，その誤差はロボットが移動するにしたがって蓄積する．そのため，外界センサ（視覚や LRF）を用いた自己移動量推定は必須である．我々は 2 つのセンサを用いているが，十分な特徴が得られる場合には信頼性や精度により LRF の方




Fig. 6 Extracted feature points in LRF data.




Fig. 7 Ego-motion estimation using point features.

が自己移動量推定に適していると考えられる．そこで，LRFのデータから以下のように自己移動量を推定する．

4.1 特徴点の抽出と対応付け

平らな壁の直線を抽出して自己移動量推定を行なう手法はよく用いられている[13]．また，LuとMiliosは任意の形状の壁を許容した位置推定を提案している[14]．しかし，この手法は比較的なめらかな面のみに適用可能と思われる．屋内複雑環境では，Fig. 3のように，LRFでは平らな壁やなめらかな面はほとんど観測されず，テーブルや椅子の脚に対応する，多数の突き出た部分が観測される．そこで，これらの特徴を自己移動量推定に用いる．

部屋に存在するテーブルや椅子の脚の幅は5[cm]程度であるので，LRFのセンサデータ中で後ろに比べて40[cm]以上手前で，幅が10[cm]以下の部分を特徴点として抽出する．誤対応を防ぐために，距離が互いに30[cm]以内にある特徴点は使わない．Fig. 6にLRFのセンサデータから抽出した特徴点の例を示す．

連続する2フレーム間の特徴点集合の対応付けは，一方の特徴点集合をデッドレコニングの値を用いて座標変換し，変換後の特徴点間の距離がしきい値（現在は20[cm]）よりも近いもの同士を対応づける．この対応をもとに，以下の手法で自己移動量を推定する．

4.2 自己移動量推定

連続する2フレーム間の自己移動量 $(\Delta x, \Delta y, \Delta \theta)$ を以下のように推定する．現フレームの特徴点 (X'_i, Y'_i) と前フレームの特徴点 (X_i, Y_i) を i 番目の対応した特徴点とする $(i = 1, \dots, N)$ ．対応に誤りがない場合，以下の式が成立する（Fig. 7参照）．

$$\begin{pmatrix} \cos \Delta \theta & \sin \Delta \theta \\ -\sin \Delta \theta & \cos \Delta \theta \end{pmatrix} \begin{pmatrix} X'_i \\ Y'_i \end{pmatrix} + \begin{pmatrix} \Delta x \\ \Delta y \end{pmatrix} = \begin{pmatrix} X_i \\ Y_i \end{pmatrix}$$

ここで，以下の2乗距離の和 S を最小化する自己移動量を計算する．

$$S = \sum_{i=1}^N \left\{ \left[X_i - (X'_i \cos \Delta \theta + Y'_i \sin \Delta \theta + \Delta x) \right]^2 + \left[Y_i - (-X'_i \sin \Delta \theta + Y'_i \cos \Delta \theta + \Delta y) \right]^2 \right\} \quad (1)$$

自己移動量を最小化する S は以下の条件を満たす．

$$\frac{\partial S}{\partial \Delta x} = 0, \quad \frac{\partial S}{\partial \Delta y} = 0, \quad \frac{\partial S}{\partial \Delta \theta} = 0 \quad (2)$$

式(1)，(2)から解は解析的に求まり，以下ようになる．

$$\begin{aligned} \Delta \theta &= \tan^{-1} \frac{N[X_i Y'_i] - N[X'_i Y_i] - [X_i][Y'_i] + [Y_i][X'_i]}{N[X_i X'_i] + N[Y_i Y'_i] - [X_i][X'_i] - [Y_i][Y'_i]} \\ \Delta x &= \frac{[X_i] - [X'_i] \cos \Delta \theta - [Y'_i] \sin \Delta \theta}{N} \\ \Delta y &= \frac{[Y_i] + [X'_i] \sin \Delta \theta - [Y'_i] \cos \Delta \theta}{N} \end{aligned}$$

ここで， $[\cdot]$ は1から N までの総和を表わす．

5. 実験

提案した手法をFig. 1で示した移動ロボットに実装し，実験を行なった．全方位ステレオとLRFの観測，特徴点の抽出と自己移動量推定，そして確率的障害物地図の更新と空き領域地図の作成に必要な時間はフレームあたり約0.5[s]である．各センサから得られる情報には厳密には時間差が存在するが，その差は画像キャプチャのフレームレート程度であるため，同一時刻のデータと見なしている．

Fig. 8に自律移動の実験結果を示す．左から実験風景，ステレオ，LRFの確率的障害物地図，空き領域地図，そして実験の全体図を示している．各地図中の三角形はロボットの位置と姿勢を示す．ステレオ，LRFの確率的障害物地図は，白いほど障害物の存在確率が高いことを示している．空き領域地図は，白い部分が空き領域，黒い部分が障害物領域を示している．また，地図は1グリッドあたり5[cm]で，サイズは200×200(10[m]×10[m])である．なお，ロボットの初期位置から1[m]以内は空き領域だと仮定している．

ロボットは毎フレーム，センサからの情報を得て確率的障害物地図を更新し，空き領域地図を作成して経路を作成する．経路は現在のロボットの位置と地図中のローカルな目標点を円弧で結び，その円弧が障害物に衝突していた場合は目標点をずらす，という手法[15]を用いている．

地点(a)，(b)の地図を見ると，空き領域地図中で灰色の円で囲まれている部分にある，暗幕のかかったパーティションがステレオでは特徴がないためにはっきりと認識できていないが，LRFでは明確に認識されており，その結果，空き領域地図で障害物と認識されていることが分かる．逆に地点(c)，(d)では，灰色の丸で囲まれた部分にあるテーブルが，LRFでは脚の部分しか観測されていないが，ステレオではテーブルの上面が認識されており，障害物という認識ができています．このように，センサ単体では認識困難な屋内の複雑環境で地図を作成し，




Fig. 8 A navigation result. Black and white triangles indicate the robot position and orientation.

ロボットを安全に移動させることができた。

Fig. 8の(d)において、ステレオの確率地図の中で、テーブルの領域が小さくなっているが、これは以下のような理由による。テーブルに近づくと、テーブル上面や縁の見え方が上下のカメラで大きく異なってしまい、対応が取りづらくなるので、テーブルの奥にある物体が最も近いという観測が得られることがある。その結果、テーブル領域の障害物の存在確率が下がってしまい、地図中のテーブルに対応する障害物の領域は小さくなる。ただし、確率が下がるのはステレオで見える範囲にあるテーブル上面の領域であり、近づきすぎて見えなくなった領域については確率の更新を行わないため(3.3.1項参照)、テーブルの縁は更新されずに残る。そのため、ナビゲーションには問題ない。

6. お わ り に

本論文では、全方位ステレオとレーザレンジファインダを用いた空き領域地図作成手法を述べた。2種のセンサは違う物体を観測することがあるので、2種の観測を1つの確率的な地図に統合するのではなく、センサごとに確率的障害物地図を作り、確率や観測回数の値に応じて分類し、その分類をもとに1枚の地図に統計的に統合することで空き領域地図を作成した。作成された地図を用い、ロボットは安全に未知環境を移動する

ことができた。現在この手法は静的環境を仮定しているが、今後は移動障害物を発見する手法[3]を適用して、動的環境に対応できるように拡張することを考えている。

参 考 文 献

- [1] 岡田, 加賀美, 稲葉, 井上: “PCによる高速対応点探索に基づくロボット搭載可能な実時間視差画像・フロー生成法と実現”, 日本ロボット学会誌, Vol. 18, No. 6, pp. 896-901, 2000.
- [2] D. Murray and J. Little: “Using Real-Time Stereo Vision for Mobile Robot Navigation,” Autonomous Robots, Vol. 8, No. 2, pp. 161-171, 2000.
- [3] H. Koyasu, J. Miura, and Y. Shirai, “Recognizing Moving Obstacles for Robot Navigation Using Real-time Omnidirectional Stereo Vision,” J. of Robotics and Mechatronics, Vol. 14, No. 2, pp. 147-156, 2002.
- [4] M. Lindström and J.-O. Eklundh: “Detecting and Tracking Moving Objects from a Mobile Platform using a Laser Range Scanner,” Proc. of IEEE Int. Conf. on Intelligent Robots and Systems, pp. 1364-1369, 2001.
- [5] E. Prassler and J. Scholz: “Tracking Multiple Moving Objects for Real-Time Navigation” Autonomous Robots, Vol. 8, No. 2, pp. 105-116, 2000.
- [6] A. Elfes: “Sonar-Based Real-World Mapping and Navigation,” Int. J. of Robotics and Automat, Vol. 3, No. 3, pp. 249-265, 1987.
- [7] 浅田, 白井: “マルチセンサ情報を動的に統合することによる道路シーンの解釈とモデリング”, 情報処理学会論文誌, Vol. 31, No. 12, pp. 1743-1754, 1990.

- [8] N. Ayache and O.D. Faugeras, "Maintaining Representations of the Environment of a Mobile Robot," IEEE Trans. on Robotics and Automat, Vol. RA-5, No. 6, pp. 804-819, 1989.
- [9] T. Yata, A. Ohya, and S. Yuta, "Fusion of Omni-directional Sonar and Omni-directional Vision for Environment Recognition of Mobile Robots" Proc. of the 2001 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp. 3926-3931, 2001.
- [10] J. Gluckman, S.K. Nayar, K.J. Thoresz: "Real-Time Omnidirectional and Panoramic Stereo," In Proc. Image Understanding Workshop, Vol. 1, pp. 299-303, 1998.
- [11] S. Thrun: "Learning Occupancy Grids with Forward Models," Proc. of 2001 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp. 1676-1681, 2001.
- [12] Y. Sawano, J. Miura, and Y. Shirai: "Man Chasing Robot by an Environment Recognition Using Stereo Vision," Proc. of the 2000 Int. Conf. on Machine Automation, pp. 389-394, 2000.
- [13] I.J. Cox: "Blanche: Position Estimation for an Autonomous Robot Vehicle," Proc. of IEEE/RSJ Int. Workshop on Intelligent Robots and Systems, pp. 432-439, 1989.
- [14] F. Lu and E.E. Milios: "Robot Pose Estimation in Unknown Environments by Matching 2D Range Scans," Proc. of IEEE Conf. on Computer Vision and Pattern Recognition, 1994.
- [15] 根岸, 三浦, 白井: "確率的障害物地図に基づく視覚移動ロボットの行動制御", 計測自動制御学会第3回システムインテグレーション部門講演会, No. 2, pp115-116, 2002.

根岸 善朗 (Yoshiro Negishi)

2002年大阪大学工学部応用理工学科(機械系)卒業。現在同大学大学院工学研究科電子制御機械工学専攻博士前期課程在籍。コンピュータビジョンおよび自律移動ロボットの研究に従事。

(日本ロボット学会学生会員)

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。現在同大学院工学研究科電子制御機械工学専攻助教授。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, 日本機械学会, IEEE, AAAI各会員。

(日本ロボット学会正会員)

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。人工知能学会, 電子情報通信学会, 情報処理学会, 日本機械学会各会員。

(日本ロボット学会正会員)