

移動ロボットによる時間制約を考慮した 環境情報要約のための視点計画

増 沢 広 朗* 三 浦 純*

Viewpoint Planning for Environment Information Summarization with Time Constraint

Hiroaki Masuzawa* and Jun Miura*

Mapping is an activity of making a useful description of an environment. Not only geometric information such as free space but also object placements are important if the map is used for human-robot communication. We call such a map making *environment information summarization* because how to summarize may change depending on the goal of the mapping and the context. Environment information summarization usually includes searching for specified objects in the environment and may sometimes have to be finished with in a limited time. It is, therefore, crucial to make a good observation plan for efficient summarization. We develop an observation planning method with time constraint. Experimental results using a vision-based humanoid robot show the effectiveness of the proposed planning method.

Key Words: Environment Information Summarization, Viewpoint Planning, Mobile Robot

1. は じ め に

環境モデルの生成はロボティクスにおいて活発に研究されている分野の一つである。地図生成は環境モデル化の重要な一つの方法であり[1]、これまでに多くの地図生成あるいはSLAM (simultaneous localization and mapping, 地図と位置の同時推定)の手法が開発されてきた。これらの手法のほとんどは、カルマンフィルタ[2][3]やパーティクルフィルタ[4][5]のような統計的推定手法を用いており、またそれらの手法の主目的は正確な自由空間地図の作成である。このような幾何学的形状の地図は、安全な行動を計画するために重要である。

一方、地図を人間-ロボット間の情報伝達のメディアとして用いる場合には、環境の意味的情報も重要となる。例えば、ロボットに目的地を指示するとき、その座標値でなく、その場所の名前や物体の名前で指示できれば有用である。そのような意味的情報を含んだ地図の生成には、ロボットによる物体認識[6]、あるいは空間の属性での分類や分割[7]が必要となる。

これまでに環境の意味的情報を抽出する移動ロボットシステムがいくつか提案されている。Vasudevanら[8]は物体記述に基づく屋内環境表現を提案した。この手法では、部屋や廊下といった場所は、そこにある物体によって特徴付けられ、複数物体間の位置関係により、知っている場所かどうかを判別してい

る。Galindoら[9]は、“is-a”関係や“has”関係によって物体や場所を関係付けることにより、意味的情報とそれらの空間的關係を階層的に表現し、環境地図の生成に利用することを提案している。空間的な関係が地図中に表現されているため、それを用いてロボットを目的地へ誘導することができる。この研究では、意味的情報抽出や地図生成の効率化のための観測計画の問題は扱っていない。

幾何学的情報と意味的情報の両方が含まれている環境の記述を作成することをここでは環境情報要約と呼ぶ。これは、どのような情報を含むべきかは、その地図をどのように使うかという環境記述の目的、あるいはその生成にどの程度の時間がかけられるかといった状況に依存するからである。本研究では、環境情報要約の例として、部屋の自由空間形状と重要物体の位置を記述した地図を作ることを考える。その際、効率的に要約を得るためには、適切に観測を計画することが重要となる。

移動ロボットの観測計画問題について、これまでいくつかの研究がなされている。Makerenkoら[10]は効率的かつ確実な地図作成のために、ある観測地点で観測した場合の、情報の増加量、観測地点までの移動コスト、その観測地点での位置決め精度の三つの効用を総合的に評価する integrated exploration を提案した。SujinとMeggiolaro[11]は、複数ロボットを用いた未知領域の探索のために情報ゲイン基準を用いている。これらの研究は未知領域観測問題を対象とし、物体の認識・探索は扱っていない。Wangら[12]は観測のコストと観測地点間の移動コストの両方を考慮した、観測地点決定手法を提案しているが、そこでは観測の不確かさは考慮されていない。

原稿受付 2009年12月20日

*豊橋技術科学大学

*Toyohashi University of Technology

■本論文は学術性で評価されました。

Tsotsos ら [13] [14] は、視覚物体探索問題の一般的解法を提案した。探索対象物体の位置の確率分布と物体発見手続きの確率的モデルを用いて、物体探索問題を統計的最適化問題として定式化した。Saidi ら [15] も同様のアプローチで、ヒューマノイドによる物体探索を行っている。これらの研究は、環境中で一つの物体を探索する問題を扱っている。

本論文では次のような状況を扱う。ロボットは与えられた時間制約条件の下で、ある部屋の自由空間の概形と既知の物体の種類と場所を調べることとする。ロボットには、部屋に存在する物体の数はあらかじめ与えない。ロボットは部屋に入り、観測行動を計画して部屋の形状の計測や物体の探索を行いながら部屋の中を動き回り、そして部屋から出て行く。物体認識に不確かさがあることを考慮すれば、一般に、物体に近づくほど認識性能は高まる。しかし物体の位置と次の目的地が離れている場合には、認識の信頼性を上げることと移動距離を短くすることは同時に達成できない。Miura と Shirai [16] は、不確かさを考慮した経路計画問題において、観測位置のよさと移動コストのトレードオフを扱った。本論文の状況でも同様のトレードオフが生じる。

先に述べたように、情報環境要約は地図の目的や状況に依存する。本論文では、時間制約により要約を行う上での状況が変化する場合を扱う。例えば、多くの物体が存在する場合、時間制約下ではより価値の高い物体を優先的に観測することが必要になる。その際、観測を行って情報を得ることによる効用と制約を満たさないことによる損失とのトレードオフを考慮して、最適な観測計画を生成する必要がある。伊藤ら [17] は、自動車の知的ナビゲーションにおいて、目的地への到着予定時刻と目標時刻とのずれによる損失を表すいくつかの制約について議論している。本研究でも、同様に複数の時間的制約を用いて行動の生成・評価を行う。

2. 提案手法の概要

本論文での環境情報要約は (1) 自由空間地図の作成、および (2) 特定物体の発見の二つの処理からなる。今回使用するロボットは自由空間を認識するためのレーザ距離センサと特定物体を発見するためのステレオカメラを備えている (Fig. 1 参照)。ロボットの首はパン・チルト可能で、視線方向を変えることができる。ロボットには物体を発見するための特定物体の見えモデル、要約をする部屋の壁の形状と特定物体の平均存在個数を与えておく。自由空間地図の作成と特定物体の発見はそれぞれ価値を持つが、その相対的な重要度はユーザがあらかじめ設定するものとする。なお、本論文では、一つの部屋に数個の重要物体がある状況を想定する。

環境情報要約では 2 種類の視点計画を行う (Fig. 2 参照)。ロボットは、現在位置での観測により部屋の概形と特定候補物体を取得し、その情報に基づき視点計画を生成する。その後、未知領域の探索、もしくは候補物体の検証を行う。そのために候補物体と未知領域を位置関係に基づきグループ化し、視点計画問題を観測を行うグループを選択する大域的視点計画と、グループ内の物体検証のための局所的視点計画に階層的に分割する。大域的視点計画では、与えられた時間的制約条件の下でより多




Fig. 1 The robot with stereo vision and laser range finder




Fig. 2 Flow of two-stage observation planning and execution

くの環境情報を取得できる計画を生成する。局所的視点計画では、候補物体を効率的に検証するための視点計画を生成する。

観測を行う際に新たに得られた情報は随時要約結果の更新に用いられ、視点計画は最新の情報に基づいて行う。以上の計画生成と観測行動を効用がある間、繰り返し行う。

3. 物体の見えモデルと物体認識

3.1 物体認識の手順と使用する特徴量

物体認識は 2 段階から構成される。第 1 段階では、色情報を用いて候補物体を見つける。候補物体の色情報は、色ヒストグラムによってモデル化し、色情報を用いた物体探索の効率的な手法であるアクティブ探索法 [18] を用いる。

第 2 段階は、局所特徴を用いて候補物体の検証を行う。局所特徴は SIFT [19] を用い、それぞれの物体から事前に SIFT 特徴を抽出しておく。物体モデルと入力画像で特徴のマッチングを取り十分な数のマッチング数が得られたら認識できたとする。

3.2 物体の見えモデル

SIFT 特徴はある程度のスケール変化に対してはロバストであるが、大きなスケール変化には影響を受ける。したがって、SIFT 特徴のマッチング数は、物体とカメラの距離の増加につれて減少する。また物体の面と光軸となす角の増加もマッチング数の減少の原因となる。これらの影響をモデル化する。作成したモデルを用いることで、ロボットから物体までの距離と物体面との角度より SIFT 特徴のマッチング数を予測することができる。

本論文では直方体形状の物体を対象とし、ロボットの視点と物体の位置関係を考慮して、各物体を四つの側面のモデルの集合として表現する。各面のモデル化のパラメータとして Fig. 3 に示す距離 d と鉛直軸に対する角度 θ を用いる。これらをパラ

メータとしたときの SIFT 特徴のマッチング数を実際に計測し関数でフィッティングを行う。距離に関しては指数関数でフィッティングを行い、角度に対してはシグモイド関数でフィッティングを行う。Fig. 4 の物体についてのモデルを Fig. 5 に示す距離変化に対しては、物体の面ごとに、角度変化に対してはすべての物体で一つのモデルで表現する。

この見えモデルを用いることで、ロボットの現在位置 $\mathbf{X}$ 、物体位置 $\mathbf{X}_{obj}$ と物体の姿勢 θ_{obj} より、予測マッチング数 $\hat{z}(\mathbf{X}, \mathbf{X}_{obj}, \theta_{obj}) = \{\hat{z}_1, \hat{z}_2, \dots, \hat{z}_{N_{model}}\}$ を計算できる。ここで N_{model} は、物体の面の数である。

本研究では SIFT 特徴が十分にマッチングしたときに物体を認識できたとしている。しかし、物体の向きに関する情報がなければ、どの向きから検証を行うと効率がよいか判断することができない。そのため物体の方向の不確かさを SIFT 特徴のマッチング数より推定し、それを認識成功確率に反映させる。そこで SIFT 特徴のマッチング数の予測 $\hat{z}$ と実観測より得られた SIFT 特徴のマッチング数 $z = \{z_1, z_2, \dots, z_{N_{model}}\}$ より、物体の離散化した姿勢 $\{\theta_1, \theta_2, \dots, \theta_{N_{theta}}\}$ (N_{theta} は姿勢の離散化数) の事後確率をベイズの定理を用いて、次式で求める。

$$P(\theta_i | z, \hat{z}) = \alpha P(z | \hat{z}, \theta_i) P(\theta_i) \quad (1)$$

ここで $P(z | \hat{z}, \theta_i)$ は尤度関数であり次式より求める。

$$P(z | \hat{z}, \theta_i) = \exp \left(-k_{pose} \sum_{j=1}^{N_{model}} |z_j - \hat{z}_j| \right) \quad (2)$$

ここで、 k_{pose} は比例定数であり実験的に値を 0.1 とした。この姿勢の推定により、物体の認識の成功確率を、しきい値を超えるマッチング数が得られる姿勢をとる確率として、以下のよう計算できる。

$$P_{recog}(\mathbf{X}, \mathbf{X}_{obj}) = \sum_{i=1}^{N_{theta}} P_{recog}^i(\mathbf{X}, \mathbf{X}_{obj}, \theta_i) \quad (3)$$




Fig. 3 Observation parameters for appearance modeling



Fig. 4 Target objects




Fig. 5 SIFT appearance modeling

$$P_{recog}^i(\mathbf{X}, \mathbf{X}_{obj}, \theta_i) = \begin{cases} P(\theta_i) & \exists j \{ \hat{z}_j \geq th_{match} \} \\ 0 & otherwise \end{cases} \quad (4)$$

ここで th_{match} は、認識に必要な SIFT 特徴のマッチング数である。この認識成功確率を利用して物体の検証計画を作成する。

4. 観測グループの作成

ロボットには、あらかじめ自由空間の形状や候補物体の位置は与えられていない。そのため、自分でそれらの情報を獲得するための視点計画を生成する必要がある。視点計画を効率的に生成するため観測グループを生成し、問題を階層的に分割する。

4.1 候補物体検出と自由空間形状取得

候補物体検出は、現在地から見える可能性がある未観測の領域すべてについて、見る方向を変えながら行う。色情報によって物体候補が見つかった場合は、ステレオ視を用いてその位置を計算し地図に記録する。本研究では、色情報によって正しい物体候補の検出に失敗することはないと仮定している。ただし、物体以外の場所に候補が検出されることはあり得る。

物体候補の検出と同時に、レーザ距離センサで周囲の幾何学形状を取得し地図を作成する。部屋の形状の表現としてグリッド地図を用いる。地図中の各セルは、自由領域、障害物領域、未観測領域のいずれかの属性を持つ。ロボットの移動量は比較的小さいので、ロボットのオドメトリ情報が正しいとして複数地点で得られた距離情報を統合する。また、この幾何学地図よりそれぞれの未観測領域の面積を求めることができる。

4.2 候補物体と未知領域による観測グループ作成

候補物体検出と自由空間形状取得後、候補物体と未知領域それぞれをグループ化する。候補物体によるグループ作成においては、同一視点で検証可能な候補物体を一つのグループとする。これは同一視点で検証することにより、検証コストを軽減できる可能性があるためである。物体の見えモデルより、物体を認識できる最大距離 R_{max} が定義でき、二つの物体間の距離がそれぞれの認識最大距離の和より近い場合、それらは同一視点で検証できるものとする。三つ以上の場合についても同様に同一視点で観測できる場合は、一つのグループとする。また未知領域については地図中の未観測領域の中で一定面積以上を持つ連結領域を一つのグループとする。Fig. 6 はグループ化の例である。図中、白色は自由空間、黒色は障害物領域、灰色は未観測領域を表す。この図では、未知領域が一つ、候補物体が二つある。候補物体はお互いに十分に近いため一つのグループとなり、未知領域がもう一つのグループとなる。




Fig. 6 Grouping




Fig. 7 One object verification

5. 候補物体検証のための視点計画

5.1 候補物体を一つ持つグループを検証するための視点計画

まず、候補物体が一つある場合の視点計画を考える。検証のための視点計画は、現在位置 X_s から次の目的地 X_g に向かうまでに物体を検証する行動の中で時間コストを最小とするような計画を生成する。物体を検証するための観測候補点は、3種類の半径の同心円上に24点に設ける (Fig. 7 参照)。検証を行う位置の半径は次のように決定する。最小の半径は、どの方向から検証しても、物体を認識できる距離とする。最大の半径は、物体の1面のみが検証できる距離とする。残りの一つは、最大と最小の半径の平均の値とする。

このときに候補物体 obj を検証する計画の期待実行時間は、次のように考える。まずロボットは観測候補点集合 S_{obs} から観測点 X を選び、現在位置 X_s から移動する。そしてその地点で検証作業を行う。候補物体を認識できた場合は目的地に移動し、候補物体を認識できない場合は、残りの観測候補点集合を用いて再帰的に検証作業計画を立てる。これをすべての候補点で計算し、最小のものを期待実行時間とする。以上を式で表現すると次式となる。

$$t_{single}(X_s, X_g, obj, S_{obs}) = \min_{X \in S_{obs}} \left[\begin{aligned} & \frac{dist(X_s, X)}{v_{robot}} + t_{verify} \\ & + P_{recog}(X, X_{obj}) \frac{dist(X, X_g)}{v_{robot}} \\ & + (1 - P_{recog}(X, X_{obj})) \cdot t_{single}(X, X_g, obj, S_{obs} - \{X\}) \end{aligned} \right] \quad (5)$$

ここで、 v_{robot} はロボットの平均移動速度、 $dist$ は2点間の直線距離を取得する関数である。また、 $P_{recog}(X, X_{obj})$ は位置 X から X_{obj} にある候補物体を検証するときの成功確率 (式 (1) 参照)、 t_{verify} は検証を行うための時間であり、右辺第3項が観測成功時、第4項が観測失敗時の観測コストを表す。なお、ロボットの移動量はユークリッド距離で近似しているが、ロボットの機構的拘束を考慮したパスプランナを利用すれば、より正確な移動コストを見積もることができる。

視点計画は再帰計算となるため、そのまま計算するとまったく同じ状況に対して何度も計画生成を行う可能性がある。そこで、計算結果の近似値をテーブルに記憶し再利用することにより、計算量を減らすことを考える。 t_{single} の近似値 $\hat{t}_{single}$ の計算を以下のように行う。実際に観測を行うときには、観測点




Fig. 8 Viewpoint candidate sets




Fig. 9 Two observation strategies

候補に障害物が存在して到達不可能となっていることもあるため、まず検証する物体の周囲の状況を5種類の観測候補点集合のどれかに近似する。近似する観測候補点集合を Fig. 8 に示す。どの集合に近似するかは、より多くの方向から観測が可能なパターンより、パターンを45°ごとに回転させながら当てはめ探索していく。もし、パターン中のすべての観測候補点に障害物がないときには、そのパターンについて t_{single} を次の近似式で計算する。

$$\hat{t}_{single}(X_s, X_g, obj, S_{obs}^{type}) = \min_{X_a \in S_{obs}^{type}, X_b \in S_{obs}^{type}} \left[\begin{aligned} & \frac{dist(X_s, X_a)}{v_{robot}} \\ & + t_{single}(X_a, X_b, obj, S_{obs}^{type}) \\ & + \frac{dist(X_b, X_g)}{v_{robot}} \end{aligned} \right] \quad (6)$$

ここで S_{obs}^{type} は現在の状況に近似した観測候補点集合である。式 (6) の第2項部分についてテーブルを作成する。このテーブルは、スタート位置とゴール位置が観測候補点の場合について、それらの位置と観測候補点集合よりから実行時間を牽くことのできるテーブルであり、これにより視点計画時間が約1/6に短縮された。

5.2 候補物体を複数持つグループを検証するための視点計画

候補物体が近くに複数ある場合には、逐次観測戦略と同時観測戦略の二つの戦略を考える。逐次観測戦略とは複数ある候補を一つずつ検証していく戦略であり、同時観測は同じ位置で複数の物体の観測を行う戦略である。逐次観測戦略 (Fig. 9 (a) 参照) では、一つずつ物体を検証していく。このときの期待検証時間 t_{seq} は、次式で与えられる。

$$t_{seq}(\mathbf{X}_s, \mathbf{X}_g, \{obj_1, obj_2\}) = \min_{\mathbf{X} \in S_{obs_1}} \left[\begin{array}{l} t_{single}(\mathbf{X}_s, \mathbf{X}, obj_1, S_{obs_1}) \\ + t_{single}(\mathbf{X}, \mathbf{X}_g, obj_2, S_{obs_2}) \end{array} \right] \quad (7)$$

ここでは、 obj_1 から先に見た場合のコストを計算しているが、 obj_2 から見た場合も同様に計算する。

同時観測戦略 (Fig. 9 (b) 参照) では、同一の観測点から二つの物体を検証することを考える。そのような検証ができる場所は、Fig. 9 (b) に示す二つの観測可能領域の重なり部分である。

この重なり部分が含まれている障害物地図のセルの中心の集合を、同時観測候補点集合 S_{par} とする。計算を簡単にするため、同時に二つの物体を検証する回数を 1 回とした。同時観測戦略の期待検証時間 t_{par} は、次のように考える。まず、同時観測候補点のうち一つを選び、そこに移動する。そこでそれぞれの物体の検証を行う。ここで考えられる結果は、それぞれの物体に対して認識成功と認識失敗があるため四つである。両方認識に成功した場合は、目的地へと向かう。片方失敗した場合は、認識に失敗した物体を再度検証する計画を立てる。両方失敗した場合は、逐次戦略で計画を生成する。以上を式で表すと次式になる。

$$t_{par}(\mathbf{X}_s, \mathbf{X}_g, S_{par}, \{obj_1, obj_2\}) = \min_{\mathbf{X} \in S_{par}} \left[\begin{array}{l} \frac{dist(\mathbf{X}_s, \mathbf{X})}{v_{robot}} + 2t_{verify} \\ + P_{recog}(\mathbf{X}, \mathbf{X}_{obj_1}) P_{recog}(\mathbf{X}, \mathbf{X}_{obj_2}) \\ \cdot \frac{dist(\mathbf{X}, \mathbf{X}_g)}{v_{robot}} \\ + (1 - P_{recog}(\mathbf{X}, \mathbf{X}_{obj_1})) P_{recog}(\mathbf{X}, \mathbf{X}_{obj_2}) \\ \cdot t_{single}(\mathbf{X}, \mathbf{X}_g, obj_1, S_{obs_1}) \\ + P_{recog}(\mathbf{X}, \mathbf{X}_{obj_1}) (1 - P_{recog}(\mathbf{X}, \mathbf{X}_{obj_2})) \\ \cdot t_{single}(\mathbf{X}, \mathbf{X}_g, obj_2, S_{obs_2}) \\ + (1 - P_{recog}(\mathbf{X}, \mathbf{X}_{obj_1})) (1 - P_{recog}(\mathbf{X}, \mathbf{X}_{obj_2})) \\ \cdot t_{seq}(\mathbf{X}, \mathbf{X}_g, \{obj_1, obj_2\}) \end{array} \right] \quad (8)$$

実際には逐次観測戦略と同時観測戦略を比較し、より良いものを選択する。三つ以上の物体が一つのグループに含まれる場合も同様に、すべての物体を同一視点で観測する戦略と逐次戦略とを比較して検証計画を生成する。

5.3 未知領域を観測するための計画

未知領域のグループ G を観測するための期待時間 t_u は、未知領域の形状取得時間とそのなかから候補物体を発見し、検証を行うための時間であり、次式で定義する。

$$t_u(G) = t_{sea} + \hat{t}_{obj}(G) \quad (9)$$

ここで t_{sea} は未知領域の形状を取得し、領域中から候補物体を検出するために要する時間であり、現在は定数としている。また $\hat{t}_{obj}$ は未知領域に物体がある場合の検証に必要な時間であり、それぞれの物体の平均存在確率と物体の検証に必要な時間より、その期待値を求める。

$$\hat{t}_{obj}(G) = \frac{A_G}{A_U} \left\{ \sum_{j=1}^M \bar{n}_j t_{single}(\mathbf{X}_s, \mathbf{X}_g, obj_j, S_{obj_j}) + t_{dist} \left(\sum_{j=1}^M \bar{n}_j - 1 \right) \right\} \quad (10)$$

上式中の t_{single} は、物体の平均存在位置が未知領域の重心位置であり、スタート位置とゴール位置が、未知領域の出入り口点 (6.3 節参照) であるとして計算する。また、 A_G は、グループ G の未知領域の面積、 A_U は未知領域の総面積、 $\bar{n}_j$ は、 obj_j の 1 部屋当たりの平均存在個数、 t_{dist} は、未知領域内の物体を観測するための移動に要する時間の平均である。

6. グループの観測順の計画

6.1 観測の効用と損失関数

グループの観測順の計画を立てるときには、様々なグループの組み合わせとその観測順を考えて、最も効用の高い観測順を選択する必要がある。あるグループの組み合わせとその観測順が $\mathcal{G} = \{G_1, G_2, \dots, G_N\}$ の場合の効用 U を、次式で定義する。

$$U(\mathcal{G}) = V(\mathcal{G}) - L \left(t_{mov}(\mathcal{G}) + \sum_{i=1}^N t_{obs}(G_i) \right) \quad (11)$$

ここで V はグループを観測することに対する価値である。 t_{mov} はグループ間の移動時間である。 t_{obs} はグループ内の候補物体を検証するためのコストである (5 章参照)。また L は制限時間 t_{limit} を超過することに対する損失関数である。

時間にかかわる損失としては、経過時間に関する損失と、制限時間超過に関する損失が考えられるが、本論文では制限時間内に環境情報要約を行う、という目的を想定し、制限時間超過に関する損失のみを考える。なお、具体的な制限時間の例としては、バッテリー利用による連続稼働時間の制限やショッピングセンターで閉店時間中に地図生成を行う場合など、ロボットの活動状況に依存した活動時間の制限が考えられる。

本論文では、Fig. 10 に示す 3 種類の損失関数を考える。 $L_1(t)$ は、制限時間 t_{limit} を超える行動は選択できない制約、 $L_2(t)$ は、制限時間 t_{limit} を過ぎた場合、徐々に損失が大きくなるような制約制約であり、また $L_3(t)$ は、時間的制約のない場合を示す。それぞれの制約は、次式で表現される。

$$L_1(t) = \begin{cases} 0 & t < t_{limit} \\ \infty & \text{otherwise} \end{cases} \quad (12)$$

$$L_2(t) = \begin{cases} 0 & t < t_{limit} \\ k_{lim}(t - t_{limit})^2 & \text{otherwise} \end{cases} \quad (13)$$

$$L_3(t) = 0 \quad (14)$$

ここで、 k_{lim} は比例係数である。

6.2 グループの観測価値

各グループの期待観測価値 V は、次式で定義する。

$$V(\mathcal{G}) = \sum_{i=1}^N V_{obs}(G_i) \quad (15)$$




Fig. 10 Loss function

$$V_{obs}(G_i) = \begin{cases} \sum_{Obj \in G_i} V_{obj}(Obj) & (G_i \text{が物体候補のグループの場合}) \\ V_{unk}(G_i) & (G_i \text{が未知領域の場合}) \end{cases} \quad (16)$$

$$V_{unk}(G_i) = k_{area} A_{G_i} + \frac{A_{G_i}}{A_U} \sum_{j=1}^M \bar{n}_j V_{obj}(obj_j) \quad (17)$$

ここで $V_{obj}(Obj)$ はそれぞれの物体の価値である。 A_{G_i} は未知領域 G_i の面積である。 V_{unk} の第 1 項は形状取得に対する価値であり、未知領域の面積に比例するとする。 k_{area} は未知領域の形状取得に対する価値に対する係数である。第 2 項は未知領域中の物体が検証できたときの期待価値である。未知領域が複数あった場合はそれぞれに物体が存在する確率はその面積に比例するとする。

6.3 グループ間の移動時間

グループ間の移動を考えるために、各グループに出入り口点候補を決定する。候補物体によるグループでは、グループに所属する候補物体それぞれの最外周の観測候補点集合を出入り口候補点集合とする。未知領域によるグループは、未知領域のなかで自由領域と接続しているセルの中心を出入り口候補点集合とする。例えば、Fig. 6 において、候補物体のグループと未観測領域のグループの出入り口点候補を黒丸で示す。

グループ間の移動時間 t_{mov} を次式で定義する。

$$t_{mov}(G) = \frac{1}{v_{robot}} \{ dist_{g-p}(G_1, \mathbf{X}_c) + \sum_{i=1}^{N-1} dist_{g-g}(G_i, G_{i+1}) + dist_{g-p}(G_N, \mathbf{O}) \} \quad (18)$$

ここで、 $\mathbf{X}_c$ は現在位置、 $\mathbf{O}$ は部屋の入り口の位置である。また v_{robot} は、ロボットの平均移動速度である。また $dist_*$ はそれぞれグループ間、グループとある地点までの距離で、次式で定義される。

$$dist_{g-p}(G, \mathbf{X}) = \min_{\mathbf{X}_G \in S_G} dist(\mathbf{X}_G, \mathbf{X}) \quad (19)$$

$$dist_{g-g}(G_i, G_j) = \min_{\mathbf{X}_i \in S_i, \mathbf{X}_j \in S_j} dist(\mathbf{X}_i, \mathbf{X}_j) \quad (20)$$

ここで S_G は、それぞれのグループの出入り口候補点集合である。例としてグループ間移動時間を考える。グループの出入り口点は、前後に観測するグループに最も近い観測点を選ばれる。Fig. 6 を例に取ると、A, B の順で見る場合は実線の移動によってかかる時間を、逆に B, A の順で見る場合は破線の移動によってかかる時間を考えることになる。それぞれの行動で選ばれた出入り口点は、矢印の根元と先の黒丸となる。

6.4 探索方法について

最適な組み合わせとその観測順を探索するために、現在は全探索を行っている。しかし、グループ数が n のとき、考えなければならない観測順の組み合わせの数は $\sum_{i=1}^n n! P_i$ と指数オーダーであるためあまり好ましい方法ではない。しかし現在グルー

プ数がそれほど多くない状況を想定しているため、計算時間は現実的な時間に収まっている。

7. 実験

7.1 実験環境

実験結果として $7.0 \text{ [m]} \times 5.5 \text{ [m]}$ の部屋の環境情報要約結果を示す。Fig. 1 のロボットを使用した。発見する物体は Fig. 4 の 3 種類である、それが部屋のどこに、いくつあるかはロボットに知らされていない。また、パラメータは $k_{lim} = 0.5$, $v_{robot} = 0.4 \text{ [m/s]}$ と設定した。実験に使用した PC の CPU は Core 2 Duo 2 GHz である。

7.2 シミュレーション実験

まず、正しく視点計画が生成されていることを確認するために、シミュレーション実験を行った。シミュレーション実験環境を Fig. 11 に示す。実験パラメータは t_{limit} は 30 秒である。

Fig. 11 (a) は、未知領域がなく、物体が二つ離れてある場合である。ロボット向かって手前側（図の下側）には Object A があり、奥側（図の上側）には Object B がある。またロボットの現在位置はスタート位置であり、白丸で示してある。この環境では、Object B の価値は Object A の価値の半分としてある。今回の環境では、物体が離れているため二つのグループが作成されている。ここで考えられる行動は、4 とおりであるが、スタート位置がゴール位置と等しいため、 $G_A \rightarrow G_B$ と $G_B \rightarrow G_A$ はまったく逆の行動になり、コスト、価値ともに同じとなる。そのため、 G_A , G_B , $G_A \rightarrow G_B$ の 3 とおりについて考える。それぞれの価値と観測に必要な時間、それに伴う損失を Table 1 に示す。 $L_1(t)$ を用いた場合は、奥にある Object A を検証すると検証のために必要な時間が t_{limit} を超えてしてしまうので、損失が ∞ となる。そのため、手前の Object B を検証する行動が生成される。 $L_2(t)$ を用いた場合は、いくらか損失が出るものの、手前の Object B を検証するよりも奥の Object A を検証するほうがより高い効用を得られる。しかし、二つの物体を検証すると損失が価値を上回る。そのため、奥の Object A を検証する行動が生成される。 $L_3(t)$ を用いた場合は、時間にかかわらず損失がないため最も価値の高くなるよう




Fig. 11 Simulation experimental environments

Table 1 Simulation experimental result

Objects G	Reward V	Loss L			Utility U		
		L_1	L_2	L_3	L_1	L_2	L_3
G_A	50	0	0	0	50	50	50
G_B	100	0	2.76	0	$-\infty$	97.24	100
$G_A \rightarrow G_B$	150	∞	296.26	0	$-\infty$	-146.26	150

に両方の物体を検証する行動が生成される。これにより、与えた条件により違った行動が生成されていることが分かる。

Fig. 11 (b) は、候補物体が四つあり、三つのグループを形成している。また未知領域が二つある。 $L_1(t)$ を用いた場合には、 $G_B \rightarrow G_C \rightarrow G_E$ の順の検証計画が生成された。 $L_2(t)$ を用いた場合には、 $G_B \rightarrow G_C \rightarrow G_D$ の順の検証計画が生成された。 $L_3(t)$ を用いた場合には、 $G_B \rightarrow G_E \rightarrow G_C \rightarrow G_D \rightarrow G_A$ の順の検証計画が生成された。この結果より、制限時間に対する制限がより緩くなるに従い、より多くのグループを検証する計画が生成されている。また、これらの計画の価値とコストをすべて計算するのに約 900 [ms] 程度で行える。そのため、全解探索であるものの十分実用的な時間で計算することができる。

7.3 実機実験

実験環境を Fig. 12 に示す。実験環境には二つの物体がある。この環境実際に $L_3(t)$ を用いて要約を作成するためには 90 秒かかる。実験では、その 60% の時間である 55 秒を t_{limit} として設定した。損失関数として $L_2(t)$ を用いた場合、計画と実行の過程を Fig. 13 に示す。図中の左列が実際のロボットの様子、中列がロボットが実行した行動、右列がロボットが作成した地

図である。また、ロボットが作成した地図においてサムネイルで示した位置に候補物体があり、サムネイルに丸がついているものは検証済みの物体である。

同じ環境で、 $L_1(t)$ を用いて環境要約を作成した場合は、最初のステップは未知領域を観測する行動が選択されるものの、次のステップでは現在の制約条件の基では物体検証を行えないと判断されたため、次にゴール位置（初期位置）へ向かう計画を立てた。この問題に対しては、移動コストの見積もりをより正




Fig. 12 Experimental environment




Fig. 13 Experimental results

確に行うようにするか、あるいはある程度マージンを考慮して予測をするなどの対策が必要である。しかし、特に未知領域の観測コストの見積りは不確かさが大きい。そのため提案手法のように、何らかの行動を行うたびにオンラインで計画する手法が、予想以上に時間がかかったような場合でも対処できる。

8. まとめと今後の課題

本論文は、時間制約付環境情報要約のための視点計画について述べた。視点計画のために物体の見えモデルを作成し視点計画に利用した。また視点計画を、観測グループを選択する大域視点計画と物体を検証するため局所視点計画に分割し、それぞれで計算を行うことで効率的に計画生成を行った。また提案手法によって実際にステレオカメラとLRFを備えたヒューマノイドロボットで環境情報要約を行った。

現在は、比較的小規模な環境下で少数の物体を対象に実験を行っている。今後より複雑な環境に提案手法を適用するためには、物体認識能力の向上と計画生成の効率化が必要となる。そのために、まず他の画像特徴を利用した認識手法の開発とモデル化を検討する。また、計画生成の効率化のためには、短い時間で比較的良好な計画を生成する近似アルゴリズムの開発を検討する。さらに、認識や移動の結果やそれらのコストに関する見積りに含まれる不確かさを考慮することにより、より現実的な環境へ適用できるよう改良することも今後の課題である。

謝辞 本研究はNEDO「次世代ロボット知能化技術開発プロジェクト」の一環として実施中のものである。

参考文献

- [1] S. Thrun, W. Burgard and D. Fox: Probabilistic Robotics. The MIT Press, 2005.
- [2] J.J. Leonard and H.F. Durrant-Whyte: "Simultaneous Map Building and Localization for an Autonomous Mobile Robot," Proceedings of 1991 IEEE/RSJ Int. Workshop on Intelligent Robots and Systems, pp.1442-1447, 1991.
- [3] J.E. Guivant and E.M. Nebot: "Optimization of the Simultaneous Localization and Map-Building Algorithm for Real-Time Implementation," IEEE Trans. on Robotics and Automation, vol.17, no.3, pp.242-257, 2001.
- [4] M. Montemerlo, S. Thrun, D. Koller and B. Wegbreit: "Fast-SLAM: A Factored Solution to the Simultaneous Localization and Mapping Problem," Proceedings of AAAI National Conf. on Artificial Intelligence, pp.593-598, 2002.
- [5] G. Grisetti, C. Stachniss and W. Burgard: "Improving Grid-based SLAM with Rao-Blackwellized Particle Filters by Adaptive Proposals and Selective Resampling," Proceedings of 2005 IEEE Int. Conf. on Robotics and Automation, pp.2432-2437, 2005.
- [6] M. Tomono: "3-D Object Map Building Using Dense Object Models with SIFT-Based Recognition Features," Proceedings of the 2006 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp.1885-1890, 2006.
- [7] Z. Zivkovic, O. Booij and B. Kröse: "From Images to Rooms," Robotics and Autonomous Systems, vol.55, no.5, pp.411-418, 2007.
- [8] S. Vasudevan, S. Gächter, V. Nguyen and R. Siegwart: "Cognitive Maps for Mobile Robots—An Object Based Approach," Robotics and Autonomous Systems, vol.55, no.5, pp.359-371, 2007.
- [9] C. Galinodo, A. Saffiotti, S. Coradeschi, P. Buschka, J.A. Fernández Madrigal and J. González: "Mobile Robotics," Proceedings of the 2005 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp.3492-3497, 2005.
- [10] A.A. Makarenko, S.B. Williams, F. Bourgault and H.F. Durrant-Whyte: "An Experiment in Integrated Exploration," Proceedings of 2002 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp.534-539, 2002.
- [11] V.A. Sujaan and M.A. Meggiolaro: "Intelligent and Efficient Strategy for Unstructured Environment Sensing Using Mobile Robot Agents," J. of Intelligent Robotic Systems, vol.43, pp.217-253, 2005.
- [12] P. Wang, R. Krishnamurti and K. Gupta: "View Planning Problem with Combined View and Traveling Cost," Proceedings of 2007 IEEE Int. Conf. on Robotics and Automation, pp.711-716, 2007.
- [13] Y. Ye and J.K. Tsotsos: "Sensor Planning for 3D Object Search," Computer Vision and Image Understanding, vol.73, no.2, pp.145-168, 1999.
- [14] K. Shubina: "Visual Search for an Object in a 3D Environment Using a Mobile Robot," Technical Report CSE-2008-02, Department of Computer Science and Engineering, York University, 2008.
- [15] F. Saidi, O. Stasse, K. Yokoi and F. Kanehiro: "Online Object Search with a Humanoid Robot," Proceedings of the 2005 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp.1677-1682, 2007.
- [16] J. Miura and Y. Shirai: "Vision and Motion Planning for a Mobile Robot under Uncertainty," Int. J. of Robotics Research, vol.16, no.6, pp.806-825, 1997.
- [17] 伊藤元邦, 三浦純, 白井良明: "道路シーンの視覚認識に基づく運転支援システム," 日本ロボット学会誌, vol.19, no.5, pp.603-611, 2001.
- [18] V.V. Vinod and H. Murase: "Image Retrieval Using Efficient Local Area Matching," Machine Vision and Applications, vol.11, pp.7-15, 1997.
- [19] D.G. Lowe: "Distinctive Image Features from Scale-Invariant Keypoints," Int. J. of Computer Vision, vol.60, no.2, pp.91-110, 2004.



増沢 広朗 (Hiroaki Masuzawa)

2008 年豊橋技術科学大学情報工学課程卒業。2010 年同大学大学院情報工学専攻修士課程修了。同年日立製作所入社。在学中は、移動ロボットの環境認識および行動計画に関する研究に従事。

(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)