

ロボットの認識・行動計画とアルゴリズム

*三浦 純 (豊橋技術科学大学)

概要 ロボットなどの知的自律システムは一般に環境の認識，行動の計画，行動の実行のサイクルを繰り返して動作する．特に，認識および行動計画の過程では，周囲環境の状況や実行すべきタスクの複雑さに応じて，そこで必要となる情報処理も複雑になる．本稿では，筆者のこれまでの研究を中心に，いくつかの重要な情報処理とそのアルゴリズムについて紹介する．

Recognition and Planning of Robots and Their Algorithmic Aspects

*Jun Miura (Toyohashi University of Technology)

Abstract Intelligent autonomous systems such as robots operate by repeatedly performing environment recognition, action planning, and action execution. Especially in recognition and planning, necessary information processing tend to be complex as the complexity of environments and tasks increase. This report describes several important information processing in recognition and planning, mainly from the author's research projects, and discusses their algorithmic aspects.

1 はじめに

ロボットなど実世界で動作する知的システムは，一般にセンサ情報を基に環境を認識し，その結果から行動を計画 (プランニング) し，実行する．その過程でさまざまな情報処理を行うが，そのなかには，視覚情報処理や不確かさの下での行動計画など，かなりの計算コストを必要とするものがある．本稿では，複雑な情報処理を必要とする認識処理，行動計画処理の例を挙げ，それらに対するわれわれの，あるいは現在広く使われている手法を紹介する．

2 移動ロボットの位置推定と地図生成

位置の推定は移動ロボットの重要な機能の一つである．環境の地図が与えられている場合には，観測データと地図との照合によって自分の位置を推定する．その際，観測データの誤差 (例えば，距離センサの計測距離の誤差) や自己移動量の誤差 (例えば，エンコーダで計測した移動量の誤差) などを考慮して，推定を行う必要がある．

ロボットが移動しながら状態を推定する問題は以下のようなベイズ推定問題とみなせる．

$$p(\mathbf{x}_t | \mathbf{y}_{1:t}, \mathbf{u}_{1:t}) = \alpha p(\mathbf{y}_t | \mathbf{x}_t, \mathbf{y}_{1:t-1}, \mathbf{u}_{1:t}) p(\mathbf{x}_t | \mathbf{y}_{1:t-1}, \mathbf{u}_{1:t}) \quad (1)$$

$$= \alpha p(\mathbf{y}_t | \mathbf{x}_t) \int p(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{u}_t) p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}, \mathbf{u}_{1:t-1}) d\mathbf{x}_{t-1} \quad (2)$$

ここで， \mathbf{x} は状態量 (ロボットの位置・姿勢)， \mathbf{y} は観測値， \mathbf{u} は制御量 (ロボットの移動のための入力) であり，添字は時間あるいは時間範囲を表す．この式の中には再帰構造が表れており，ベイズフィルタとも呼ばれる．

位置の推定は位置追跡 (position tracking) と大域的な位置推定 (global localization) に分けられる．前者は位置に関する事前知識がある場合で，後者はまったくない場合である (kidnapping problem ともいう)．前者の場合は，ロボットは予測位置の近傍にあるので，例えば予測位置を中心とする正規分布でその不確かさを表すことは合理的である．例えば，ベイズフィルタの1種であるカルマンフィルタを用いて効率的に計算ができる．しかし，後者の場合にはどのような不確かさの分布であることすらわからない．そこで，統計学の分野で利用されてきたパーティクルフィルタをロボットの位置推定に適用した，Monte Carlo localization (MCL) 法が提案された [22]．

MCLでは，ロボットのある状態 (平面上を移動するロボットであれば，位置+姿勢の3自由度) を1つのサンプルとして表し，その集合として不確かさの確率分布を表現する．その基本的なアルゴリズムは以下のようなものである．

* 豊橋技術科学大学 情報工学系
Department of Information and Computer Sciences,
Toyohashi University of Technology,
<http://www.aisl.ics.tut.ac.jp/~jun>

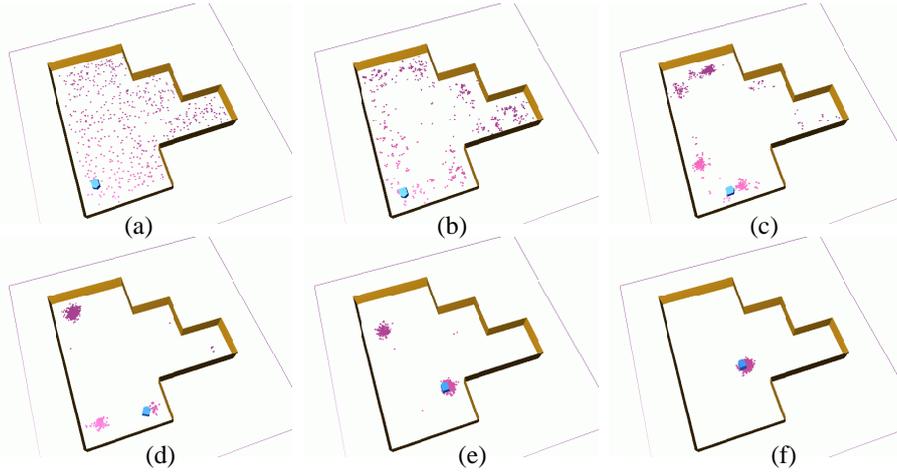


図 1: モンテカルロ位置推定法の実行例．領域内に分布する各点がある位置・姿勢を表すサンプルである．

時間 t における x_t の分布を N 個の重みつきサンプル集合 $S = \{s_t^i, w_t^i\}$ で表す． S_{t-1} から S_t を以下のように計算する．

1. 重み w_{t-1}^i を確率とみなし $\{s_{t-1}^i\}_{i=1}^N$ から N 個のサンプルを取り出し，一定重みのサンプル集合 $\{u_{t-1}^i\}_{i=1}^N$ を生成する．このとき，重みのより大きいサンプルが取り出される回数がより多くなる．
2. 各サンプル $\{u_{t-1}^i\}_{i=1}^N$ について，遷移確率 $p(s_t|s_{t-1} = u_{t-1}^i)$ にしたがって遷移させ，状態遷移後のサンプル集合 $\{s_t^i\}_{i=1}^N$ を生成する．
3. 各サンプルの重み w_t^i を正規化尤度 $\beta p(y_t|s = s_t^i)$ として計算する．

図 1 に MCL のシミュレーション例である．ここでは，壁の形状を既知とし，ロボットは前方 180 度の範囲の距離が計測できるセンサを持っているとしている．尤度は以下の式で計算している．

$$p(\mathbf{y}|\mathbf{x}) = \exp \left\{ -\kappa \sum_j (d_{map}^j(\mathbf{x}) - d_{obs}^j(\mathbf{y}))^2 \right\} \quad (3)$$

ここで， $d_{map}^j(\mathbf{x})$ は位置 \mathbf{x} を仮定したときに予測される距離データの j 番目の値， $d_{obs}^j(\mathbf{y})$ は実際に観測された，対応する方向の距離データを示す．初期状態は領域内で完全に未知であるので，等しい重みのサンプルをランダムに生成している．処理を繰り返すことにより正しい位置に収束していく様子が見られる．

未知環境中を効率よく行動するためには，地図の生成が不可欠である．観測の不確かさを考慮するため，対象空間を細かなセルに分割し，セルごとの障害物の存在確率を記述する確率的グリッド地図を用いることが多い．十分な解像度を持つセンサで観測する場合にはセルごとの確率を独立と考えて，ベイズ推定によりセルごとに存在確率を更新する手法がよく用いられる [17]．

ロボットが移動しながら観測し，絶対座標系における地図を作るためには観測を行った位置を知る必要がある．一方，自己位置を知るためには観測結果と地図との対応を調べなければならない．位置推定が視覚などのセンサ以外のセンサ（例えば GPS）で精度よく行える場合にはよいが，そうでない場合には位置推定と地図生成を同時に行わなければならない．この問題は SLAM (Simultaneous Localization and Mapping) と呼ばれ，ここ 10 年ほどの移動ロボット研究におけるホットな話題の一つとなっている．

SLAM では式 (1) の代わりに次式の条件付確率を計算する．

$$p(\mathbf{x}_{1:t}, \mathbf{m} | \mathbf{y}_{1:t}, \mathbf{u}_{1:t}) \quad (4)$$

ここで \mathbf{m} は地図を表す．地図に記述されるのが環境中の特徴的な物体（ランドマーク）の位置であり，ロボットの位置誤差が正規分布で近似できる場合には（拡張）カルマンフィルタを用いることができる [12]．しかし，位置の不確かさが大きい場合やグリッド地図を用いる場合には，逐次モンテカルロ法のような手法が必要である [22]．

パーティクルフィルタの問題点として，状態空間が大きくなると大量の数のサンプルを必要とすることが挙げられる．したがって，式 (4) の推定をある程度大きな環境に対して行おうとすると

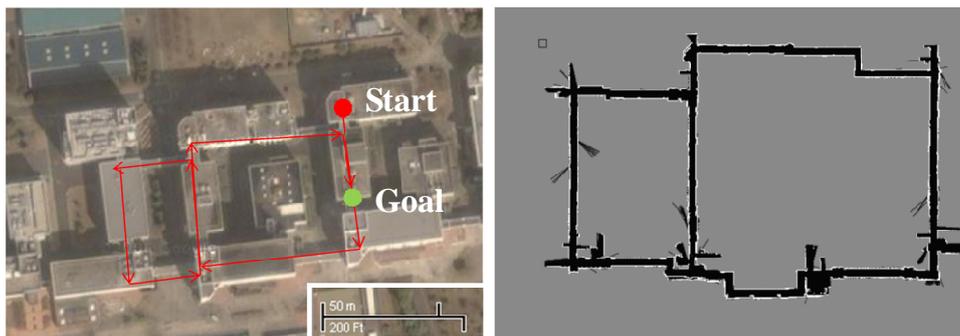


図 2: 効率的な SLAM の適用例．左側が実際の構造，右側が生成された地図

必要なサンプル数が膨大になる．そこで，変数間の確率的依存関係を考慮して，以下のように推定問題を分割することが提案されている (Rao-Blackwellized Particle Filter, RBPF と呼ぶ) [3] ．

$$p(\mathbf{x}_{1:t}, \mathbf{m} | \mathbf{y}_{1:t}, \mathbf{u}_{1:t}) = p(\mathbf{m} | \mathbf{x}_{1:t}, \mathbf{y}_{1:t}, \mathbf{u}_{1:t}) p(\mathbf{x}_{1:t} | \mathbf{y}_{1:t}, \mathbf{u}_{1:t}) \quad (5)$$

各サンプルは $\mathbf{x}_{1:t}$ およびその位置推定結果を基に計算した地図 \mathbf{m} を持ち，推定は逐次モンテカルロ法による $\mathbf{x}_{1:t}$ のサンプル集合の推定と，各サンプルごとの地図の推定から成る．後者はロボットの位置が与えられた下での地図の推定なので効率的に行える．これにより，必要なサンプル数を抑えることができる．さらに推定精度を上げてサンプル数を減らすには，よりよい移動量の見積り ($p(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{u}_t)$) が必要である．そこで，レーザ距離センサを用いた精度の良い移動量推定法 [10] と RBPF を組み合わせて広域の地図を生成した例を図 2 に示す．移動距離は約 500[m] であり，この長距離移動に対しサンプル数が 100 程度で廊下のループ構造が正しく復元されている．

3 不確かさの下での行動計画 (プランニング)

プランニングを行うための情報 (例えば，認識結果) に不確かさがあるときには，それを考慮したプランニングが必要である．不確かさが確率分布で表現できるときには，決定理論的プランニング [1] が有効である．決定理論的プランニングで行動の系列を決定する問題は AND/OR 木の探索となる (図 3 参照)．すなわち，現在の状態である行動 ((認識，移動など) $action_i$ をとったときの帰結を確率的に予測し (S_{ij}, P_{ij})，各帰結に対する次の行動の選択問題を再帰的に構成する．最終的には評価関数 (例えば，目的達成までの時間の期待値) を最適化する行動の系列 (実際には OR ノードが各レベルで一つだけの AND/OR 木) を生成するが，実際には予測の限界などから，最初の行動だけを実行して状態を更新し，その後同様のプランニングを繰り返す．

3.1 認識と行動の統一的プランニング

移動ロボットが観測地点や経路を選択しながら目的地へ向かう問題を考える [15]．物体の認識のための手順 (センサの配置など) を計画する場合には，できるだけ多くの情報が得られるような手順を近視眼的に選んでいってもよい (深い先読みをしなくてもよい)[21]．しかし，この問題では，目的地への移動とよりよい情報を得るための観測地点への移動が必ずしも一致しない．そのような場合，視覚と行動を統一的にプランニングすることが必要となる．

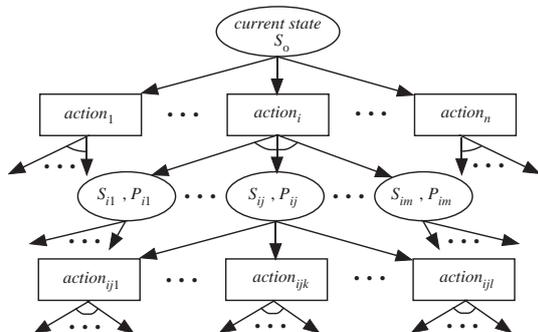


図 3: AND/OR 木探索

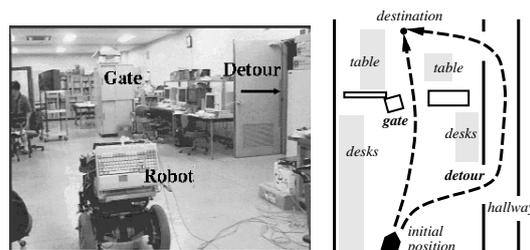


図 4: 視覚移動ロボットの観測地点選択問題の例

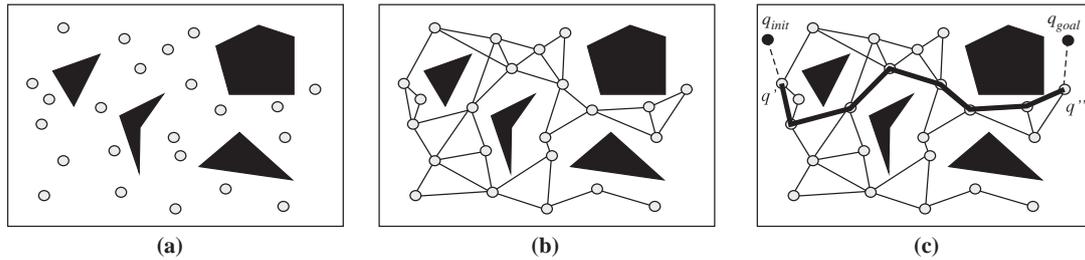


図 7: Probabilistic Roadmap 法による軌道計画

4 ロボットの軌道計画

移動ロボットやマニピュレータの衝突回避軌道を計画する問題は、ロボティクスにおける伝統的な問題の一つである。平面上を全方向可動型ロボットが移動する場合には、例えば障害物の頂点をむすぶグラフを生成し Dijkstra のアルゴリズムで最短経路を生成する、といった比較的単純な問題として扱える。しかし、ロボットアームのように自由度が多い場合、複数のロボットを同時に計画する場合、車輪型移動ロボットのように動きに拘束がある場合に計画問題の複雑さが増す。

衝突回避軌道の生成では、configuration space(C-space) と呼ばれる、変数空間 (ロボットアームなら関節角度の空間) で軌道を計画することが多い。しかし、3次元空間における障害物は C-space では複雑な形状をとるため、その計算は簡単ではない。そこで、Probabilistic Roadmap (PRM) 法 [7] と呼ばれるランダムサンプリングに基づく方法が提案され、複雑な軌道計画問題の解法の主流となっている。図 7 は PRM 法の基本的な考え方を示したものであり、以下のように軌道を生成する。(a) まず、C-space 内の自由空間 (ロボットと障害物の衝突が生じない空間) 内にランダムに milestone を配置する。(b) 近隣の milestone 同士を直線でつなぐことができる場合に segment を生成する。(c) 初期位置 q_{init} 、最終位置 q_{goal} に近い milestone q' 、 q'' を探し、さらにそれらの間を結ぶ最短経路を求める。この方法では、milestone を配置する際に、その位置 (ロボットアームならある姿勢) で実 3 次元空間においてロボットと障害物が衝突するかどうかだけを調べればよく、C-space における障害物を陽に計算する必要がない。

車型移動ロボットのように動きに拘束がある場合にも、ランダムサンプリングに基づくアルゴリズムが提案されている [5]。そこでは、ロボットの可能な行動集合を規定し、現在位置・姿勢を根ノードとし、ランダムに行動を選んで実行したときのロボットの位置・姿勢を新たなノードとして加える。次に根ノードと新たなノードのどちらかをランダムに選び、そこからの行動を再びランダムに選んでさらに新たなノードを付け加える。この処理を繰り返すことによりノード集合は木状に成長する。そして、目的地の十分近くに到達するか、あるいは目的地への簡単な軌道が生成できる位置に到達すれば終了する。できるだけ広い領域を探索するため、ノードの空間的な近傍に他のノードがある場合には重みを減らすなどの工夫を加える。動的障害物を含む環境に適用した例もある [8]。その場合には、前章で示したように、起こり得るさまざまな状況を予測し、各状況に対し軌道計画を行うことになる。

5 複数人物の同時追跡

人間とともに働くロボットや、監視カメラシステムなどは画像内の人物を発見・追跡する必要がある。隠蔽や画像処理の問題等により毎回対象物が正しく検出できるとは限らないので、通常はカルマンフィルタやパーティクルフィルタなどの統計的データ統合に基づく手法を用いる [9, 14]。複数人物の追跡では検出された候補領域間の対応付けが重要である。複数の対応付けの可能性が生じる場合には、対応付けの確からしさに応じて各追跡物体に対する寄与を計算する JPDAF (Joint Probabilistic Data Association Filter) などが用いられる [13]。図 8 は同じ画像特徴 (色) を持つ複数の人物や背景物体が存在し、また頻繁に隠蔽が生じる状況で複数人物の追跡を行った例である。

3~4 人程度の比較的少数の人物が行き交う場合には、領域間の対応の組合せもそれほど多くないが、多人数で隠蔽が頻繁に生じる場合には、直接統計的処理を行うとコストが高くなる可能性がある。そこで、対象に関する知識やもっと長い時間にわたる一貫性などの知識を導入し、ある程度組合せの候補を絞ることが有効である。

サッカー中継画像において、コーナーキックやゴール前でのフリーキックなど、多人数かつ隠蔽の多い状況で、各プレイヤーの移動経路を推定する手法を研究している [11]。その際、あるフ

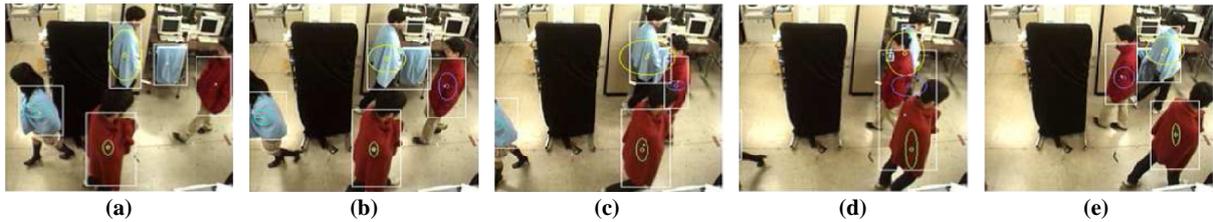


図 8: JPDAF による複数人物の同時追跡



図 9: 選手領域の抽出

図 10: 制約の伝播の有効性

フレームでは隠蔽が起こって一つの領域になっていても、時間が経過すれば複数の人物が重なっていることがわかる場合がある。そこで、時間とともに変化する領域およびそれらのつながりを考慮し、さらに画像を解析することによって得られる情報を加えて、人物の移動を推定する。

各フレームで色を用いて選手候補領域を抽出し (図 9 参照) ノードとする。隣り合うフレームのノード同士が画像上で重なり合うとき、そのノード間で人物の移動が起こる可能性があるとエッジを生成する。各ノードはその領域に含まれる人数の最大値および最小値を属性として持ち (人数制約と呼ぶ)、エッジを通して人数制約を伝播させることにより各領域の人数を限定し、各選手の移動経路の推定に役立てる。ここで生成されるグラフは、(1) 同一フレームに属するノード間にエッジはない、(2) グラフ全体を独立な複数の連結グラフに分けられる場合がある、という特徴を持つ。この特徴を生かした人数制約伝播法を研究している [11]。

各ノードに対応する選手領域の大きさや形から、そのノードに人数制約を直接与え、それをグラフを通して伝播させる。図 10 はフリーキックのシーンであり、多数の選手の重なりが存在する。図中の黒で囲んだ選手領域は、その大きさから最少人数 1、最大人数 4 という制約が与えられる。また、同フレームの他の 8 つの選手領域のうちどの一つについても、形状からは人数を確定できていない。フレーム内の全体人数制約 (合計 10 人) を用いれば、各領域の最少人数は 1、最大人数は 2 となり、より制約を強めることはできているが、人数を確定するには至っていない。しかし、以降のフレームを見ていくと、この領域は第 110 フレーム (図 10 (b) 参照) において 2 つの領域に分かれるため、図 10 (a) の時点で人数が 2 であったことが確定する。この制約を前のフレームへ伝播させると、図 10(a) の他のすべての領域の人数は 1 と確定する。また、図 10(b) の白で囲まれた領域は、このフレームからだけでは人数を確定させることができないが、図 10(a) で各領域の人数が確定したという情報を伝播させることにより、その人数は 3 と確定する。

情報不足の場合には、すべての領域の人数を確定させることはできないが、できるだけ人数を制約した後に、統計的手法によって各解釈の信頼性を評価する、といったアプローチが可能である。

6 複数能動カメラの同時視線プランニング

近年の安全・安心に対する要求の高まりもあり、視覚による監視はコンピュータビジョンにおいて活発に研究されている分野の一つであるが、そのほとんどは前章で述べたような追跡のための画像認識を扱っている。ここでは、比較的少数の能動カメラによる多数人物の広域監視の問題を扱う。その際、重要になるのはカメラの視線プランニングである。複数のカメラで監視するには視野の重なりをうまく避けることが必要であり、そのために複数のカメラの視線を同時に (集中制御で) 制御する問題を考える [20]。

図 11 に 16 台のカメラで 100 人の追跡をシミュレーションしている様子を示す。ここで、人物間の隠蔽はなく、視野に入っている人物の識別と位置・速度の取得が可能であると仮定している。個々の人物の動きには不確かさがあり、図 12 にあるような正規分布の位置誤差モデルを想定する。そして、一定時間内にできるだけ多くの人物を捕捉することを目標として視線をプランニングする。前章で述べたような統計的データ統合に基づく物体追跡システムの存在を仮定すると、観測

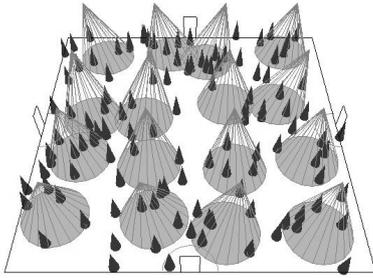


図 11: 多数人数追跡問題シミュレータ

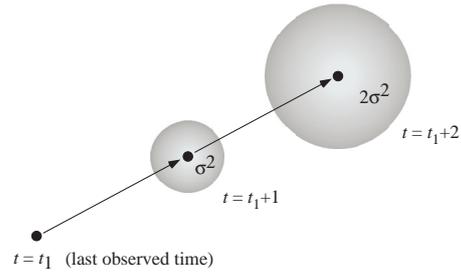


図 12: 移動の不確かさモデル

が得られない場合でもある程度物体位置が予測できるので、目を離す時間が短かければその間も捕捉されていたものとみなして（断続的な追跡と呼ぶ）捕捉人数を評価する。

プランニングにあたっては、現在視野に捉えられている人物、および少し前まで捉えられていた人物についてその将来の位置を予測し、ある先読み時間内の期待捕捉人数を最大化するような視線の系列を計算し、その第 1 ステップを実際に行う。その際、空間をグリッド状に離散化し、グリッド点を注視点の候補とすることにより、組合せ最適化問題として定式化する。

カメラ数を N_c 、先読みステップ数を T 、各カメラの可能な視線候補数を N_f とすると解空間の大きさは $N_f^{N_c T}$ となり、最適解を求めるのは困難である。そこで、多スタート局所探索法 (MLS 法)[23] を用いて、比較的良い解を短時間で求めることを考える。局所探索における解の近傍は、現在の解から、ある一つのカメラのある時間ステップにおける注視点とその 8 近傍のいずれかに移動させたものを用いる。したがって、近傍の数は $8TN_c$ となる。

解空間が広いので、ランダムに初期解を生成すると評価の良い局所最適解に到達する可能性が低くなる。そこで、よりよい位置に初期解を生成するため、各時間ステップごとに捕捉人数が多い場所をサンプルし、それらをできるだけ通るような形で初期解を生成する [20]。

表 1 に次の 5 つの手法の比較結果を示す。

1. 提案手法 (intermittent) .
2. 視野に入っている人物のみを捕捉しているとする評価関数を用い、MLS 法で解を求めるもの (continuous) .
3. カメラ同士の視野の重なりを考慮しないで、1 台ずつ独立にプランニングを行う手法 (independent) . この場合は、解をあるカメラの 5 ステップ分のカメラ注目点の組み合わせとし、MLS 法で各カメラについて 1 台ずつ解の探索を行う。
4. カメラ注目点を完全にランダムに決める手法 (random) .
5. カメラの注目点を初期位置のまま固定させる手法 (fixed) .

提案手法が最も良い結果を示している。なお、カメラの視野の合計は監視区域の約 50% であり、(4)(5) の結果がそれに対応している。また、すべての人物の軌跡が不確かさなくわかっていると仮定して提案手法でプランニングしたものを上限値と考えると、提案手法では上限値の 90 数% 程度の結果が得られている。

表 1: 5 つの手法についての平均捕捉率の比較

intermittent	continuous	independent	random	fixed
74.2%	70.8%	69.6%	48.8%	46.9%

7 おわりに

本稿では、ロボットなどの知的システムの認識と行動計画における代表的な問題をいくつか取り上げ、そこで行われている情報処理の方法を紹介した。複雑な環境で複雑なタスクを行おうとすると必然的に複雑な情報処理が要求される。近年、認識処理におけるサンプルに基づく手法や行動計画処理におけるランダム性に基づく手法など、効率の良い近似解法を用いることが一つの潮流になりつつある。このことから、ロボティクスや画像処理といった分野は、複雑・大規模問題を対象とするアルゴリズム研究の成果を応用する対象として適していると思う。本稿が、アルゴリズム研究者がそれらの分野に興味を持っていただく一助になれば幸いである。

謝辞

本稿で紹介した研究・実験の一部を行ってくれた三浦研究室 (大阪大学および豊橋技術科学大学) の学生諸氏に感謝する。

参考文献

- [1] J. Blythe. Decision-Theoretic Planning. *AI Magazine*, Vol. 20, No. 2, pp. 37–54, 1999.
- [2] T. Dean and M. Boddy. An Analysis of Time-Dependent Planning. In *Proceedings of AAAI-88*, pp. 49–54, 1988.
- [3] D. Hähnel, W. Burgard, D. Fox, and S. Thrun. An Efficient FastSLAM Algorithm for Generating Maps of Large-Scale Cyclic Environments from Raw Laser Range Measurements. In *Proceedings of 2003 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, pp. 206–211, 2003.
- [4] E.J. Horvitz. Reasoning about Beliefs and Actions under Computational Resource Constraints. In *Proc. the 3rd Workshop on Uncertainty in Artificial Intelligence*, Seattle, WA, July 1987.
- [5] D. Hsu, R. Kindel, J.C. Latombe, and S. Rock. Randomized Kinodynamic Motion Planning with Moving Obstacles. *Int. J. of Robotics Research*, Vol. 21, No. 3, pp. 233–255, 2002.
- [6] 茨木俊秀. 組合せ最適化 - 分枝限定法を中心として. 産業図書, 1983.
- [7] L.E. Kavraki, P. Svestka, J.C. Latombe, and M.H. Overmars. Probabilistic Roadmaps for Path Planning in High-Dimensional Configuration Spaces. *IEEE Trans. on Robotics and Automation*, Vol. 12, No. 4, pp. 566–580, 1996.
- [8] H. Koyasu and J. Miura. Mobile Robot Motion Planning Considering Path Ambiguity of Moving Obstacles. In *Proceedings of the 9th Int. Conf. on Intelligent Autonomous Systems*, pp. 85–93, 2006.
- [9] H. Koyasu, J. Miura, and Y. Shirai. Realtime Omnidirectional Stereo for Obstacle Detection and Tracking in Dynamic Environments. In *Proceedings of the 2001 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, pp. 31–36, 2001.
- [10] 子安大士, 三浦純, 白井良明. 不確かさを考慮した複数のスキャンマッチング結果の統合による移動ロボットの移動量推定. 日本ロボット学会誌, Vol. 23, No. 2, pp. 263–271, 2005.
- [11] 久保博之, 三浦純. サッカー中継画像における複雑隠蔽下での選手追跡. In *FIT2007*, No. H-067, 2007.
- [12] J.J. Leonard and H.F. Durrant-Whyte. Simultaneous Map Building and Localization for an Autonomous Mobile Robot. In *Proceedings of 1991 IEEE/RSJ Int. Workshop on Intelligent Robots and Systems*, pp. 1442–1447, 1991.
- [13] M. Liebens, T. Sakiyama, and J. Miura. Visual Tracking of Multiple Persons Using Person Model and Joint Probabilistic Data Association. In *Proceedings of IEEE Int. Conf. on Multisensor Fusion and Integration for Intelligent Systems*, pp. 547–552, 2006.
- [14] S. Maskell, M. Rollason, N. Gordon, and D. Salmond. Efficient Particle Filtering for Multiple Target Tracking with Application to Tracking in Structured Images. *Image and Vision Computing*, Vol. 21, No. 10, pp. 931–939, 2003.
- [15] 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.
- [16] 三浦純, 白井良明. プランニングコストと視覚の不確かさを考慮した移動ロボットの視覚と行動のプランニング. 人工知能学会誌, Vol. 13, No. 4, pp. 588–596, 1998.
- [17] 根岸善朗, 三浦純, 白井良明. 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. 日本ロボット学会誌, Vol. 21, No. 6, pp. 690–696, 2003.
- [18] S. Russell and E. Wefald. *Do The Right Thing*. The MIT Press, 1991.
- [19] 榎木哲夫. 資源制約下での人間-人工物の協調系のデザイン. 人工知能学会誌, Vol. 13, No. 3, pp. 371–378, 1998.
- [20] 武村紀子, 三浦純. 多スタート局所探索法を用いた多人数追跡のための同時視線プランニング. 日本ロボット学会誌, Vol. 25, No. 8, 2007. (to appear).
- [21] 滝沢穂高, 白井良明, 三浦純, 久野義徳. 不確実性を考慮した道路交差点シーン解釈のための注視行動の決定. 日本ロボット学会誌, Vol. 16, No. 3, pp. 345–352, 1998.
- [22] S. Thrun, W. Burgard, and D. Fox. *Probabilistic Robotics*. The MIT Press, 2005.
- [23] 柳浦睦憲, 茨木俊秀. 組合せ最適化 – メタ戦略を中心として –. 朝倉書店, 2004.
- [24] S. Zilberstein. Resource-Bounded Sensing and Planning in Autonomous Systems. *Autonomous Robots*, Vol. 3, No. 1, pp. 31–48, 1996.