

ベイジアンネットワークの構造学習と推論を用いた 移動ロボット位置決めのためのセンサプランニング

周 洪 鈞*¹ 坂 根 茂 幸*²

Sensor Planning for Mobile Robot Localization Using Structure Learning and Inference of Bayesian Network

Hongjun Zhou*¹ and Shigeyuki Sakane*²

In this paper we propose a novel method of sensor planning for a mobile robot localization problem. We represent causal relation between local sensing results, actions, and belief of the global localization using a Bayesian network. Initially, the structure of the Bayesian network is learned from the complete data of the environment using K2 algorithm combined with GA (genetic algorithm). In the execution phase, when the robot is kidnapped to some place, it plans an optimal sensing action by taking into account the trade-off between the sensing cost and the global localization belief which is obtained by inference in the Bayesian network. We have validated the learning and planning algorithm by simulation experiments in an office environment.

Key Words: Sensor planning, Mobile robot localization, Bayesian network structure learning, K2 algorithm, GA

1. はじめに

自律移動ロボットの構成にとって、ナビゲーションと自己位置決め技術は重要な役割を果たす。一般に、移動ロボットの位置決めにおいては、予め走行環境の地図を作成し、実行時に得られたセンサ情報と地図情報に照合して位置決めを行う。しかし、環境の構造によっては、局所的なセンシング情報のみではユニークに位置決めをできない場合がある。また、ロボットの装備するセンサのエラーやロボット姿勢の変動等により、それらの不確実な情報に基づいて行う誤推定が生じやすい。近年、このセンサ情報の局所性、センシングエラー、ロボットの位置・姿勢の不確実性などの問題に対処するために、確率・統計的なアプローチの研究が活発に行われている [1][2]。

移動ロボットの位置決め問題は、(1) position tracking と (2) global localization の二つのクラスに分けることができる。Position tracking は、ロボットのナビゲーションによく用いられる。ロボットの初期状態が判れば、環境地図の情報と外部センサ情報に基づいて自己位置を追跡することは比較的容易である [3]。一方、global localization は、ロボットの初期位置が不明であっても、そこから移動しながらセンシングを行って位置決めをす

る問題である。position tracking に比べて一般に難しいが、ロボットの自律移動にとって必要であり、汎用性・信頼性の高い手法の開拓が望まれる。本研究では、確率・統計的アプローチにより、この global localization 問題を扱い、センシング情報の局所性からユニークに位置決めができない場合のセンサプランニング方法を提案する。

本提案システムのポイントは以下の2つの処理である：(1) 作業環境を初期走行して得られたデータから、センシングして得られた証拠 (evidence)、交差点での行動 (action)、そして、ロボット自身が現在、作業環境のどこにいるかというグローバルな位置決めの信念度 (belief)[†] との間の因果関係を、ベイジアンネットワーク (Bayesian Network、以下では *BN* と略す) により表現する。本研究では、初期走行データから *BN* の構造学習を行い、通常は人手で行われる *BN* の構造設計の自動化を図った。(2) 実行時 (すなわち global localization を必要とする時) には、得られたセンシング情報に基づいて *BN* における位置決めの信念度 (belief) を計算し、センシング行動のコストも考慮して、適切なセンシング行動をロボットが自動計画する。そして、オフィス環境を例にシミュレーション実験を行い、本システムの有効性を確認した。

以下、2章では従来の移動ロボットのセンサプランニングの研究と本研究の位置づけについて述べる。3章では環境データの

原稿受付 2002年11月

*¹中央大学大学院理工学研究科

*²中央大学理工学部

*¹Graduate School of Science and Engineering, Chuo University

*²Faculty of Science and Engineering, Chuo University

[†]本論文では、移動ロボットが global localization を行なう際の、自分がある場所にいる確からしさの評価値を「グローバルな位置決めの信念度 (belief)」と定義する。

収集とBNの構成について、4章ではBNによる環境データの表現とその構造学習について述べる。5章では学習したBNに基づいて位置決め信念度を計算し、センシングコストを考慮した最適なセンシング行動の計画方法について述べる。6章ではシステムの有効性を確認するために行った実験について述べ、7章では本研究結果を総括し今後の課題について述べる。

2. 従来の研究

2.1 Global localization への確率・統計的アプローチ

Global localization に関して、ベイズ的アプローチで移動ロボットの誘導と位置決めをする方法が提案されている。Thrun [4]らは、パーティクルフィルタ (Particle Filter) を用いた移動ロボット位置決め方法を提案した。ロボットは位置決め信念度を移動とセンシングモデルに基づく条件付き確率で表し、その事後確率分布をパーティクル集合で近似して繰り返し更新する。しかし移動ロボットの行動はランダムであり、センサプランニングは行っていないので、パーティクル集合の収束が悪い場合が起こり得る。

環境情報とロボットの行動を、静的なBNや動的なBNでモデリングする研究も行われている。Asoh [5]らは予め構築したBNを用いて音声会話での応答をevidenceとしてBNに入力しロボット位置推定の曖昧さを減少させたが、センサプランニングの機能は含まれていない。Basyeら [6]のシステムは、動的なBN(DBN)を使ってセンサ情報を融合し、逐次行動を決定した。しかしこのPOMDP(部分観測可能なマルコフ決定過程)アプローチは、ロボットの行動および各センサ情報と、Global localizationの間の複雑な因果関係を記述できない。また、稲邑ら [7]は、ユーザと対話をしながら移動ロボットの自律行動モデルを段階的に獲得するシステムをBNを使って構築した。

2.2 移動ロボットのセンサプランニング

移動ロボットの誘導と位置決めセンサプランニングでは、これまで以下のような研究がある。

Foxら [8]は、移動ロボットの位置決め行動を計画するActive Markov Localizationを提案した。自己位置決めのためにソナーやレーザセンサでセンシングを行う際の適切なセンシング方向を、位置決め確率のエントロピーの期待値の評価に基づいて決定した。しかし、このシステムは一次マルコフ過程を基礎としているので、環境情報とロボット行動の間の複雑な因果関係を表すことができない。Jensfelt [9]らはMultiple Hypothesis Trackingを用いてロボットの位置決めを推論しているが、モデルが線形かつガウスノイズを仮定するカルマンフィルタ使っているので、非線形・非ガウスの状況に対応できない問題がある。

Kristensen [10]は、決定木を用いてセンシング行動を計画した。システムは各プランニングのステップで可能なセンサを選択しているので計算は複雑になる。しかも、ユーティリティを考慮した決定木は簡単すぎるので、センサ情報の間の因果関係やセンサ情報と行動の間の因果関係を表現することは難しい。三浦ら [11]は、ベイズ推定に基づき、センシングコストとセンシング不確かさのバランスを考慮して移動ロボットの行動計画を行っている。光永ら [12]は移動ロボットが効率的にランダムを観測する行動決定手法を提案した。システムは情報量基準




Fig. 1 (left) A graph representing an office. (right) A path (from A to A) as a solution of Chinese postman problem.

により生成した決定木に基づいて行動決定を行なった。しかし、決定木を用いるアプローチでは、POMDPと同様にイベント間の複雑な依存関係を表現することができない問題がある。

2.3 本研究の位置づけ

筆者らは、既に文献 [13]で移動ロボットの効率的な位置決め行動を計画するために、BNの再構築を行うシステムを提案した。しかし、このシステムは部分的な環境のみをモデリングしているので、局所的な最適解を得る可能性がある。また、推論に用いるベイジアンネットワーク(BN)のノード間の因果関係は、人間が設計するものであった。本研究では、これらの問題に対処し、より一般化したセンサプランニングシステムを構成する。

近年、データから最適なBN構造を学習する研究 [14] [15] [16]が、理論のみならず現実問題への応用も含めて発展しつつある。しかし、BN構造学習の移動ロボットへの応用、特にセンサプランニングへの応用については未開拓である。

本システムは、ローカルなセンサ情報と行動とグローバルな位置決め信念度との間の関係をベイジアンネットワーク(BN) [17] [18] [19]で表現する。システムは初めに、ノードの順序付けを探索するGAと結合したK2アルゴリズムを用いてBNの構造を学習する。そして、実行時には、学習したBNに基づき、自己位置決め信念度とセンシングコストのバランスを考慮しつつ能動的なセンシング行動を計画する。

3. 環境データの収集とBNの構成

3.1 初期走行経路の導出

本研究では、Fig.9に示すようなオフィス環境を例にシミュレーション実験を行なった(詳細は6章に述べる)。初めに、環境の情報を獲得するために、移動ロボットに環境内の各廊下を通過させる初期走行を行う必要がある。本研究では、この経路を導出するために中国人郵便配達員問題(Chinese postman problem)(Fig.1)の枠組みを適用した。ロボットの環境は、Fig.1(left)に示すように、交差点とその間の廊下のトポロジカルな関係をグラフにより表現できる。ロボットは各廊下を通過するために、*next node algorithm* [20]を用いて、交差点AからAまでの各廊下を少なくとも一回通過する最適な経路(Fig.1(right))を求める。この経路に従って、移動ロボットはFig.2のように環境情報を収集する。

3.2 システム構成の仮定

本システムの構成においては、以下の仮定を設けている：

- (1) 各交差点で移動ロボットは、予め *next node algorithm* により作られたコマンドリストから行動コマンドを得る。Fig.9




Fig. 2 The mobile robot gathers the environment information based on the path obtained from Fig.1.




Fig. 3 A set of the environment information of two neighboring corridors. The elements are mapped to nodes of BN.

の A, B, \dots, L は交差点のラベルであり、それらは移動する途中で移動ロボットに対して教示される。

- (2) ランドマークは廊下（の一部）に対してユニークな存在ではなく、少数のランドマークの観測のみでは自己位置の決定に不確実性が残る場合を取り扱う。実験環境では、廊下壁面の両側の所々に凹みがあるものとし、それらをランドマークとして用いる[†]。
- (3) 本システムではセンシングの局所性に起因する位置決めの不確実性を扱っているが、センサのエラーや環境の動的な変化による不確実性についてはまだ扱っていない。例えば、ランドマークの識別とセンシングコストの計算に用いる *local distance*（後述）の値は一定値を用いている。

3.3 環境情報データの記述と BN の構成

本システムでは、隣接する交差点の間の情報を *segment* (S_g) と定義する。一つの S_g は以下の四つの情報を含んでいる：

- (1) 二つ交差点のラベル。
- (2) 二つ交差点間のランドマークの情報。
- (3) 移動ロボットが各交差点に入る時にセンシングした交差点の幾何的な特徴。
- (4) 移動ロボットが各交差点に入る時の行動。

システムは二つの隣接する *segment* を一つの”環境情報セッ

ト”と呼ぶ (Fig.3)。Chinese postman problem の解として得られた経路は、環境のすべての廊下を少なくとも一回通過するので、ロボットが一方通行でセンシングした廊下については、逆方向からロボットが移動する時に生じる環境情報セットを新たなデータケースとして追加する。そして、各環境情報セットがもつ具体的情報（例えば、交差点のラベルやランドマークの幾何学的な特徴など）は、BN のノードのとり得る値 (value) として保存される。

本システムでは、センサ情報を BN の *observable variable*、また、交差点のラベルを BN の *hypothesis variable* として定義する。全ての隣り合う二つの廊下の環境情報を、BN の構造と条件付確率テーブルを学習するための訓練データとして保存する。例えば Fig.2 のデータ収集で得られたデータベースには 138 個のデータケースがある。また、Fig.5 は、この訓練データから後述の構造学習により求めた BN は 13 個の確率変数（ノード）を持つ。この中のノード *Head, Mid, Tail* は、Fig.3 に示すように隣り合う二つの廊下における三つ交差点のラベルを表している^{††}。この交差点ラベルのノードのとり得る値の数は 12 個で、 A, B, \dots, L である。ノード $Action1(a_1)$ と $Action2(a_2)$ は、各廊下に入る時のロボットの行動を定義しており、各々が三つの値：*go forward, turn left, turn right* のいずれかをとる。ノード H_f, M_f, T_f は、各々、*Head, Mid, Tail* の交差点の幾何的な特徴を表し、ノードのとり得る値は 1~6 の数値で、各々 C_1, \dots, C_6 の 6 形状に対応している。本研究では、SVM(Support Vector Machine)[23]を用いて、6 タイプの交差点の特徴を識別した。ノード $m_{h1}, m_{h2}, m_{t1}, m_{t2}$ は、Fig.3

に示すように、二つの廊下内の 4 つのランドマーク（それがない場合も含まれる）を表している。実験では、1 つの *segment* の廊下の両側にそれぞれ最大 2 個までの凹みがあることを想定し、それらをランドマークとして用いた。従って、このノードのとり得る値は 1 から 4 までの整数 4 個である。本論文では、廊下の両側にあるランドマークをリスト（幾何学的な特徴、*local distance*）で表現する。「幾何学的な特徴」は、ランドマークが廊下の左側にあるか右側にあるかを表している。ロボットが廊下に入る交差点とランドマークとの間の距離は *local distance* と定義している。Fig.2 のように、廊下 $F \rightarrow G, E \rightarrow H, J \rightarrow I$ は他の廊下より長いので、各廊下にあるランドマークは 4 種類に分けられている、各々は 1 から 4 までの整数で表す。1 と 3 は、各々短い廊下と長い廊下にある（進行方向を向いて）左側のランドマークを表し、2 と 4 は、各々短い廊下と長い廊下にある右側のランドマークを表す。ノード m_{h1}, m_{h2} は交差点 *Head* から交差点 *Mid* に至る廊下の（*Head* 側から数えて）第一番目と第二番目のランドマークを表し、ノード m_{t1}, m_{t2} は交差点 *Mid* から交差点 *Tail* に至る廊下の（*Mid* 側から数えて）第一番目と第二番目のランドマークを表す。また、ノード C_n は、初期走行で求めた全データケースのラベル（実験例では 138 個）を値としてもち変数である。

本システムが用いる BN は、Fig.1 のようなトポロジカルネッ

[†] ロボットに搭載するセンサが検出できるものであれば基本的には何でもよい

^{††} *Head* は第一番目の交差点である、*Mid* は二つの隣り合う廊下の間の交差点である。*Tail* は最後の交差点である

トワークのように廊下のランドマークと交差点の幾何的な関係を表すのではなく、Fig.5に示すように、検出したランドマークのノードと交差点のラベルのノードの間のような、2ノード間の依存関係を表現する。従って、トポロジカルネットワークでは、表現する環境の大きさに伴ってネットワークのサイズも増大するが、本システムのBNの表現においては、ノード数は増えずにノードのとり得る値の個数が増えることになる。

本システムでは、環境データは環境情報セット（＝隣接する二つの廊下の情報）におけるノードの依存関係をBNで表現している。ロボットは次の廊下にある環境情報しか予測できない。行動決定では、現在ロボットがいる交差点においてどの行動をとるべきか、また、次の廊下でどこまで行くべきかに限られている。しかし、もしもロボットが次の廊下に行ってもグローバルな位置決めへの信念度がまだ低ければ、さらに一つ先の廊下まで見に行く可能性がある。この場合には、1個のsegment情報を基本とする逐次決定問題として扱う必要があるが、これについては今後の課題とする。

4. データからBNの構造学習

BNは確率変数の間の依存関係を表現する有向グラフである。BNの矢印はノード間の因果関係を表す。しかし、実際の問題でノード間の因果関係を定めることは一般に難しい場合が多い。また、本研究では、ノード間の依存関係の事前知識を与えていない。そこで、本システムでは、ノード間の因果関係に関するネットワークの構造設計部分の自動化を図るためにBNの構造学習を導入した。

4.1 K2アルゴリズム

BNの構造学習手法として、本システムは構造学習アルゴリズムK2 [15]を用いた。このアルゴリズムは、可能な構造空間から最大スコアを持つBNの構造を探索する。BNの構造を評価するスコアは、BNの構造(B_s)とデータケース(D)の結合確率 $P(B_s, D)$ で定義される。

今、BNにある n 個ノードの集合を Z とし、 Z の中にある確率変数(ノード) x_i が、 r_i 個の取り得る値(v_{i1}, \dots, v_{ir_i})をもつものとする。また、データケース D には m 個のケースがあり、各ケースは、各ノードについて各々一つの値を含んでいるものとする。 B_s で、 Z の全変数を含む一つのBNの構造を表し、この各ノード x_i の親ノードリストは π_i で表す。そして、データケース D に対する親ノードリスト π_i の中の第 j 番名のユニークなインスタンスを w_{ij} で表す。そのような π_i のユニークなインスタンスが q_i 個あると仮定する。ノード x_i の値が v_{ik} で、かつ、親ノードリスト π_i のインスタンスが w_{ij} であるような D の中のケースの数を N_{ijk} で定義すれば、

$$N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$$

を用いて i 番目ノードとその親ノードの間のスコアfunction： $g(i, \pi_i)$ を計算し、これに基づいて結合確率 $P(B_s, D)$ を計算する [15]。なお、次式中の $P(B_s)$ はBNの可能な構造の確率であり、定数と見なしてよい。

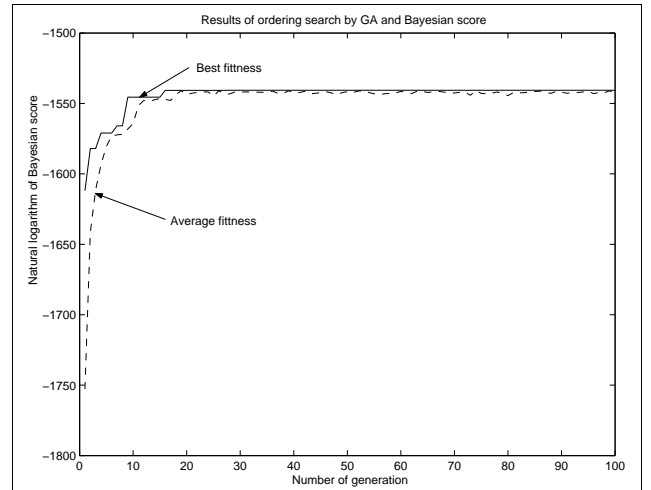


Fig. 4 The results of ordering search using GA and Bayesian score.

$$\begin{aligned} P(B_s, D) &= P(B_s) \prod_{i=1}^n g(i, \pi_i) \\ &= P(B_s) \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \prod_{k=1}^{r_i} N_{ijk}! \end{aligned}$$

K2アルゴリズムでは、初めに、各ノードの親ノードがない状態にしておく。そして、用意した親ノードを一個づつ加えてグラフを作る。このグラフを $g(i, \pi_i)$ により評価し、増加するノードだけを親として残す。このベイジアンスコアが最大になったとき、または、用意した親ノードがなくなると他のノードへ移る。全ノードについて親ノードを探索し、最適なBN構造を求める。しかし、構造空間の全探索は処理が膨大になる。例えば、BNの可能な構造は、ノードの数 $n=2$ では3個、 $n=3$ では25個、 $n=5$ では29,000個と増大していく。K2では、この探索空間を減らすために親子順序で探索空間を制限するノード間の順序づけ(ordering)を用いるが、このorderingを求めることは一般に容易ではない。本システムでは、文献 [16] が用いたように遺伝アルゴリズム(GA) [22]により準最適なorderingを探索し、得られたノードのorderingをK2に用いて準最適なBN構造を求めている。GA学習で用いるfitness値は、各orderingを用いて学習した構造の $P(B_s, D)$ [15]である。GAを導入する目的は、ordering空間において全探索をせずに最適なorderingを選択することが可能になるためである。もしGAを使わないとすれば、 $n!$ 回のK2学習を行う必要がある。本研究の例で言えば、ordering空間の全探索を行なうと $13! \approx 6.2270 \times 10^9$ 回のK2学習が必要であるが、GAを使えば100世代で8000回のK2学習実行で済み、計算時間を大幅に削減できる。

4.2 BNの構造学習結果の例

Fig.2の環境データに基づいて、K2アルゴリズムとGAによるorderingを用いて構造学習を行わせた。GA母集団のサイズは80である。遺伝子に交差(cross over)と突然変異(mutation)の操作を行なって、100世代探索した結果をFig.4に示す。各世代の80個のorderingに対応して求めたBN構造の $P(B_s, D)$ の平均値を、ここでは「平均fitnessスコア」と呼

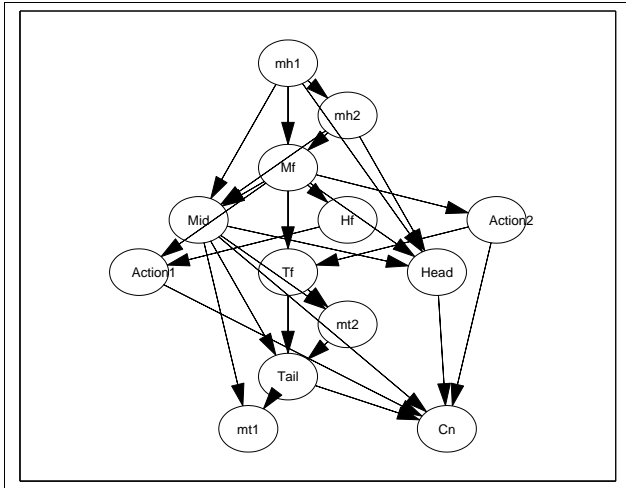


Fig. 5 Learned BN's structure by K2 and GA.

んでいる。点線は途中の個体群の平均 fitness スコアを示し、実線は各世代のベスト fitness スコアを示す。100 世代の探索により、準最適なノードの順序づけを獲得する。Fig.5 に、このアルゴリズムを用いて学習した BN の構造を示す。

4.3 BN の条件付確率テーブルの学習

BN の構造が求めれば、Chinese postman problem を解いた経路で観測データは完全なので、条件付確率のテーブル (CPT: conditional probability table) の値は、各変数値の頻度分布に基づき、最尤推定により求めることができる [14]。例えば、BN 中のあるノード X のノード値 x_i の条件付確率は $P(X = x_i | Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k)$ である。 Z_1, Z_2, \dots, Z_k は X の K 個の親ノードを示す。 z_1, z_2, \dots, z_k は、各親ノード Z_1, Z_2, \dots, Z_k のとる値である。

$$\begin{aligned} & P(X = x_i | Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k) \\ &= \frac{P(X = x_i, Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k)}{P(Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k)} \\ &\simeq \frac{N(X = x_i, Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k)}{N(Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k)} \end{aligned}$$

$N(X = x_i, Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k)$ はデータベースに「 $X = x_i, Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k$ 」のケースの数である。 $N(Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k)$ はデータベースにある「 $Z_1 = z_1, Z_2 = z_2, \dots, Z_k = z_k$ 」のケースの数である。本研究では、上記の式を用いて各ノード CPT を学習させている。もしも Chinese postman problem を適用しない場合には、環境データが不完全になる恐れがあるので、CPT を求めるために EM アルゴリズムの適用が考えられる。

5. センサプランニング

5.1 センサプランニングシステムの概要

センサプランニングシステムは三つのステップから成る：

- (1) 位置決めのための推論。ロボットは未知のスタート位置から出発し、ある廊下で新しいセンシング情報を発見する度に位置決めへの信念度を推論する。
- (2) センシング行動のための予測。もしも、センシングした廊

下の環境情報が不十分な場合には、センサプランナを起動して、実行可能な行動と、その行動に関連するセンサ情報を予測する。なお、センサプランナはセンシングした廊下の出口に来たときに起動する。

- (3) 位置決めのためのセンシング行動計画。センサプランナは予測した結果を用いて、位置決めへの信念度とセンシングコストのバランスを考慮し、次にロボットはどの廊下に進むべきか、また、センシングを行うためにその廊下のどこまで移動すべきかを計画する。

5.2 位置決めのための推論

ロボットは未知の初期位置から出発し、ポテンシャル法で廊下の真中を移動しながらセンシングを行う。現在ロボットがいる廊下から得たセンサ情報は、BN に evidence として入力される。交差点ラベルの確率は、位置決めへの信念度の評価値になる。交差点ラベルノードの確率は、BN により $P(\text{Head}, \text{Mid} | \text{得られたセンサ情報})$ として計算される。システムはグローバルな位置決めへの信念度 ($TolBef$) を以下の式で評価する：

$$TolBef = (1/2) \times (\max(P(\text{Head})) + \max(P(\text{Mid}))) \quad (1)$$

$\max(P(\text{Head}))$ と $\max(P(\text{Mid}))$ は、各々ノード Head と Mid の確率の最大値である。 Head と Mid のラベル推定における依存関係に関しては BN の中で既に反映されているので、結合密度関数を新たに構成する必要はなく、各ノードの値（すなわち交差点のラベル）に対する belief 値の最大値を求め、その平均により位置決めへの不確実性評価ができる。

もしも、 $TolBef > thd1$ (実験では $thd1=0.9$ とした) であれば、システムは位置決め処理を終了させる。この場合には、現在自分がある廊下の環境情報のみで位置決めができるので、センサプランニングをする必要はない。そうでなければ、位置決めが不確実な交差点で必要な情報を得るためのセンシング行動の計画（次にどの廊下にどこまで進むか）を立てる。

本システムの BN の構造は、Fig.5 に示すように多くのループが存在するので、ノードの belief 計算には Junction tree アルゴリズム [17] を用いた。

5.3 センシング行動のための予測

本センサプランナは、二つのプロセス：(1) 予測プロセスと (2) 計画プロセスとから構成される。予測プロセスは、実行可能な行動の結果得られるセンサ情報を予測するもので、以下の二つのステップから構成される：

- (1) センシングした廊下[†]から得たセンサ情報^{††}に基づいて、零でない確率値をもつ Cn ノード（データケースのラベルを値としてもつ変数ノード）、つまり、

$$P(\text{Cn} | \text{得られたセンサ情報}) \neq 0;$$

を満たす Cn ノードをデータベースから探し、リスト $\text{cnl} = (\text{cnl}_1, \text{cnl}_2, \dots)$ に保存する。これにより、ロボットが廊下のセンシングで得たセンサ情報に対して、データベース中のどのデータケースが類似しているかを評価する。

[†] 予測と後述の計画プロセスは中間交差点 (Mid) で行なう。

^{††} センサ情報はセンシングした廊下にあるランドマーク情報と交差点の幾何的な特徴の情報を含んでいる。

- (2) (1)の結果得た cnl_i に関して、センシング行動を先読み (look ahead) する。すなわち、可能な行動 (PA) と可能な行動に対応するセンサ情報 (SI) を予測する。予測は以下の条件付確率に基づいて行う：

$$P(PA|cnl_i, \text{得られたセンサ情報}) > thd2 \quad \dots (a)$$

$$P(SI|PA, cnl_i, \text{得られたセンサ情報}) > thd2 \quad \dots (b)$$

式 (a) と (b) の条件が満たされれば、その可能な行動をリスト $actlist$ に保存し、予測したセンサ情報は一つのマトリクス M_{sen} に保存する。なお、6章の実験では $thd2=0.9$ を用いた。

5.4 位置決めのためのセンシング行動計画

前節の予測プロセスにより、システムは実行可能な行動リスト ($actlist$) と行動に対応しているセンサ情報マトリクス (M_{sen}) が得られる。 $M_{sen} = (sn_1, sn_2, \dots, sn_n)^T$ と表せば、各特徴 sn_i は可能な行動に対応する予測したセンサ情報リストである。センサ情報リストに含まれているセンサ情報は、センシングコストに関してソートされる。センシングコストは、現在ロボットがいる交差点からセンシングを行なうランドマークまでの距離である。

ロボットはセンシング計画プロセスにより、 $actlist$ から最適な行動を選択し、この行動により位置決めの信念度を高める (従って曖昧さを減らす) のに十分なセンサ情報を得られる。例えば、Fig.6 のように $actlist$ と M_{sen} がある。実行可能な行動は “action1, action2, action3” である。Fig.6 の右側にある整数は予測したセンサ情報を表し、 M_{sen} における各行は左側にある行動に対応している予測したセンサ情報を表す。 M_{sen} の各行の要素特徴はセンシングコストでソートされ、左側のセンサ情報は右側の方より小さくなっている。各行動を評価する際に、システムは M_{sen} の各行とその行に対応する可能な行動を用いて、現在ロボットがいる交差点のラベルの確率とセンシングコストとを計算する。 BN は二つの隣接する廊下の環境情報一つ単位として使っているので、位置決めの信念度 $TolBef$ の評価は三つの交差点ラベルの確率を含み、次式で求める。

$$TolBef = (1/3) \times (\max(P(Head)) + \max(P(Mid)) + \max(P(Tail))) \quad (2)$$

以上の可能な行動と予測したセンサ情報を用いてセンシング行動計画を行なう。センシング行動計画は以下の三つのステップから成る：

- (1) 得られた情報、および、可能な行動とその行動に対応するセンサ情報に基づいて位置決めの信念度 ($TolBef$) を計算する。このステップでは、すべての可能な行動と行動に対応するセンサ情報 (Fig.6 の M_{sen} にあるすべての行) を評価しなければならない。例えば、Fig.6 の “action1” と “action1” に対応している三行のセンサ情報を評価する場合を例にとれば、以下の (a) から (d) までの手順になる。
 - (a) 空リスト $SenEvn$ を用意し、第一行の左側から第一目要素を $SenEvn$ に入れる
 - (b) $SenEvn$ と “action1” を用いて、式 (2) と BN により、

$TolBef$ を求める。

- (c) IF $TolBef > thd3$ (実験では $thd3=0.9$)
 - OR この行の要素を全部 $SenEvn$ に入れた
 - THEN 第一行のセンサ情報の評価をストップする。
 - ELSE
 - THEN 第一行の次の要素を $SenEvn$ に入れて、
 - GOTO (b)
- END IF

- (d) (a) から (c) までの手順で “action1” に対応する他の二つの行のセンサ情報を評価する。以上の手順が終了後に、 $TolBef > thd3$ になるセンサ情報リストの数 ($count$) を記述する。 $count$ は、ロボットがその行動をとると何個の可能な $location$ (グローバルな位置) を決定できるかを意味する。

(a) から (d) までの方法で、他の可能な行動 (“action2”、“action3”) を評価し、各行動に対応する $count$ を計算する。Fig.6 にある灰色と黒色でマークをした領域は、(c) の条件を満たすまで $SenEvn$ に入れたセンサ情報である。

- (2) システムは、ステップ (1) において、条件を満たすまで用いた各行のセンサ情報のセンシングコストを行毎に総和をとる ($Cost$)。また、行動毎に $TolBef > thd3$ を満たした行の $Cost$ の総和をとる。この総和の結果は各行動のセンシングコストになる。
- (3) $count$ を最大にして、かつ、より小さいセンシングコストをもつ行動が、最適なセンシング行動とする。

例えば、Fig.6 の場合は、“action1” と “action3” の $count$ は各々3であり、“action2” の $count$ は1である。従って、行動 “action2” をまず最適な行動の候補から除く。また、ステップ (2) のように “action1” と “action3” のセンシングコストを計算し、比較すると “action3” に対応するセンシングコストは “action1” より小さいので、最適な行動は “action3” である。

5.5 センサブランニングの処理の軽減

上に述べた方法は、予測したすべての可能性をチェックするので、5.4節のステップ (1) の計算コストが大きくなる。この推論の処理を軽減するために、 BN に基づき行動とセンサ情報を評価する代わりに、センサ情報の特徴 ($local\ distance$ と $geometrical\ feature$) を比較し、同じ行動で $location$ をユニークに決める可能性をチェックする。この処理手順を、Fig.6 を例に説明する。

- (i) M_{sen} にある同じ行動を持つセンサ情報リストを左側から右側へ逐次的に比較する。例えば、 $action1$ は三つのセンサ情報リスト $R1, R2, R3$ を持つ。Fig.6 の $R1$ 行のセンサ情報セットでは左側の第一番目の要素 (ランドマークのノード $mt1$ の値) は “1” であり、 $R2$ と $R3$ の第一番目の要素は “2” なので、システムはセンサ情報 “1” だけで、 $R1$ 行を $R2, R3$ と区別することができる。もちろん、多めにセンサ情報を取ることもできるが、センシングコストと信念度のバランスを考慮すれば、センサ情報 “1” だけを使う方が効

¹条件式 $TolBef > thd3$ はロボットが3つの交差点 (Head, Mid, Tail) のラベルをユニークに決められることを意味する。言い換えれば、ロボットは “action1” が入る廊下の最初のセンサ情報により位置決めができることを意味する。

actlist	M _{sen}			
	a2	mt1	mt2	
action1	1	2	2	R1
	2	2	2	R2
	2	2	1	R3
action2	2	2	2	
	2	2	2	
action3	1	2	1	
	1	2	2	
	1	1	5	

sensing cost $sc1 < sc2 < sc3$ increase

Fig. 6 A example of the predicted possible actions (actlist) and sensing information to be obtained from the actions (M_{sen}). The integer means the sensing information. The numbers from left to right are values of m_{t1} , m_{t2} , and Tf , respectively. Action1, action2, action3 are values of a_2 .

率がよい。

- (ii) ステップ (i) のようにセンサ情報の比較をするだけでなく、BN と式 (2) により選択したセンサ情報 (例えば、“1”) とそれらに対応する行動を用いて $TolBef$ をテストしなければならない。もし、 $TolBef > thd3$ であれば、“action1” と “1” だけで $location$ をユニークに決められる。また $TolBef \leq thd3$ ならば、“1” の右側[†]からセンサ情報を追加しなければならない。システムは $TolBef > thd3$ になるまで、センサ情報を追加しながら $TolBef$ のテストを行なう。
- (iii) ステップ (i)、(ii) のように、システムは他のセンサ情報セットと区別するための最も制限されたセンシングをする範囲 (Fig.6 中の灰色で示した部分) を求める。この範囲は $TolBef$ のテストを行なう前での範囲である。もし、同じ行動を持ち、かつ、センサ情報が全く同じであればこの二つのセンサ情報は互いに区別できない。また、 $location$ もユニークに決められない。この場合を Fig.6 中では黒い部分で示している。

6. 実 験

本プランニングシステムの有効性を評価するために、局所的に類似の場所が現れるオフィス環境を例にシミュレーション実験を行なった。実験システムの実装では、MATLAB の Bayes Net Tool Box [21] 及び、GA ToolBox [22] を用いた。また、交差点の幾何学特徴の識別には SVM(Support Vector Machine) [23]

[†]例えば、R1 の行において “1” が十分でなければ、右側の要素 “2” または “2, 2” を付け加えなければならない。




Fig. 7 Examples of global localization using BN inference

を用いた。実験環境において、廊下 $F \rightarrow G$, $E \rightarrow H$ と $J \rightarrow I$ の長さはその他より長い。Fig.7, Fig.9, Fig.10 中にある括弧つきの実数、黒い背景と括弧つきの実数、およびハッチングと括弧つきの実数で表した値は、それぞれノード $Tail$, Mid , と $Head$ がある交差点のラベルである確率であり、その交差点の場所に表示している。また、しきい値のパラメータは、 $thd1 = 0.9$, $thd2 = 0.9$, $thd3 = 0.9$ とした。

6.1 位置決めのための推論

最初に移動ロボットは未知の場所から出発する。Fig.7(a) のように、ロボットが交差点 D から出発するとしても一般性を失わない。一つの廊下のセンサ情報をセンシングして、5.2 節の式 (1) に基づき位置決めの信念度を計算する。ノード $Head$ と Mid の確率を BN により計算する。ロボットが廊下 $D \rightarrow C$ から得たセンサ情報は、二つのランドマーク (m_{h1}, m_{h2}) と交差点 C の幾何的な特徴 Tf である。例えば、二つのランドマーク情報はそれぞれ 2 で表し、交差点 B の幾何的な特徴 Tf は “ ” で表している。BN は以下の条件付確率を推論する。

$$P(Head, Mid | m_{h1} = 2, m_{h2} = 2, Tf = \text{“ ”})$$

推論した条件付確率は Table.1 のようになる。ノード $Head$ と Mid の値の中で最大確率を持つのは D と C である。かつ、ロボットの位置決めの信念度は式 (1) により、 $TolBef = (1/2) \times (1.0 + 1.0) > 0.9$ となるので、ロボットの出発点と現在の位置では D と C であることを同定できた。この場合には、ロボットは一つの廊下の情報のみで位置決めができるので、次

nodes	probability of the intersection's labels											
	A	B	C	D	E	F	G	H	I	J	K	L
Head	0	0	0	1.0	0	0	0	0	0	0	0	0
Mid	0	0	1.0	0	0	0	0	0	0	0	0	0

Table 1 The inferred probabilities of the nodes *Head* and *Mid* in Fig.7(a).

nodes	probability of the intersection's labels											
	A	B	C	D	E	F	G	H	I	J	K	L
Head	0	0	0	1.0	0	0	0	0	0	0	0	0
Mid	0.5714	0	0	0	0	0	0	0	0	0	0.4286	0

Table 2 The inferred probabilities of the node *Head* and *Mid* in Fig.9(a).

の廊下にセンシングをしに行く必要がない。もちろん、次の廊下にセンシングをしに行くかの行動計画をする必要もない。これでロボットの位置決めのプロセスは終了する。

Fig.7(b)は、位置決め の推論の もう一つの例である。ロボットはAからBまでのセンサ情報だけで、BNにより交差点のラベルの確率を計算し、位置決め の信念度を計算する。その結果、ロボットは自分がAから出発して、現在Bにいることを同定できている。

6.2 センシング行動のための予測

もし一つの廊下から得られたセンサ情報が不十分ならば、位置決めのために次の廊下にセンシングをしに行く必要がある。例えば、Fig.9のようにロボットは交差点DからKに向けて移動する。もちろん、ロボットは自己位置を知らない。ロボットがD→Kの廊下から得たセンサ情報は、ランドマーク(m_{h1}, m_{h2})と交差点Kの幾何的な特徴 Tf は" "である。得られたセンサ情報を用いて、BNを用いた推論により以下の条件付確率を計算する。

$$P(\text{Head}, \text{Mid} | m_{h1} = 1, m_{h2} = 2, Tf = " ")$$

この式中の1と2は、ロボットが得たランドマーク情報を表している。つまり、ノード m_{h1} と m_{h2} に対応している具体的な値である。BNにより推論した結果は、Table.2のようになった。式(1)に基づき、ロボットは位置決め の信念度を計算する。 $TolBef = (1/2) \times (1.0 + 0.5714) < 0.9$ なので、ロボットの現在地としては、Fig. 9(a)の点線と実線で書いた丸の二つの可能性がある。

5.3節に述べたアルゴリズムを用いて、可能な行動とその行動に対応する次の廊下のセンサ情報を予測する。その結果を、Fig.8に示す。交差点Kにいるロボットには、左折と右折の二つの可能な行動がある。各行動に対応して予測した情報には各々二組がある。

6.3 位置決めのためのセンシング行動計画

5.4節と5.5節のセンサプランニングのアルゴリズムを用いて、ロボットは位置決めに必要なセンシング領域を求めます。Fig.8のように必要なセンシング範囲[†]を灰色でマークした。Fig.8に

[†]ここではTable上での範囲を「センシング範囲」と呼んでいるが、走行環境におけるセンシング領域に対応し、どこまでセンシングをしに行くかを表す。

actlist	M_{sen}		
	mt1	mt2	Tf
turn left	2	2	3
	2	2	6
turn right	2	1	5
	1	1	5

Fig. 8 Predicted possible actions (**actlist**) and sensing information (M_{sen}) based on sensing information of the corridor ($D \rightarrow K$). (The integers of the table represent the predicted sensor information, i.e., values of the nodes (m_{h1}, m_{h2}, Tf).)

より、移動ロボットは行動 *Turn left* と *turn right* は両方二つの可能な *location* を決められる。ただし、5.5節により行動 *turn right* と *turn left* のセンシングコストを計算し比較すれば、*turn right* の場合はセンシングコストが *turn left* より小さいことが分る。従って、*turn right* は最適な行動であると考えられる。Fig.10に示すように、もしロボットが *turn left* の行動をとれば、交差点Jまで行かなければ十分なセンサ情報を得られない。BNにより推論した交差点D、KとJの確率の平均は $TolBef > 0.9$ とならない。もしも、*turn right* の行動をとれば、Fig.9(b)のように次の交差点Lまでに行かなくても位置決め の信念度は $TolBef > 0.9$ となり、位置決めができる。

今、ロボットがFig.11のように未知の交差点Kから出発して交差点Dに到着するとする。得られたセンサ情報によりロボットが現在いる可能性のある位置をFig.11では実線と点線の丸で表している。センシング行動のための予測のアルゴリズムに基づいて、予測したセンサ情報はFig.12のようになる。センサプランニングアルゴリズムを用いて、ロボットは位置決めのために必要なセンシング領域を決める(Fig.12に、灰色と黒色で必要なセンシング範囲をマークした)。ロボットは行動 *go forward* と *turn right* により、決めることが可能な *location* の数 (**count**) は4ある。行動 *turn left* の方は2である。行動 *go forward* と *turn right* により、行動 *turn left* の方が少ないのでまず候補から除く。行動 *go forward* と *turn right* は、共に4つの可能な *location* を決められるので、最適な行動を選択するためにセンシングコストを比較する。Fig.12に示すように行動 *go forward* のセンシングコストは行動 *turn right* より小さいので、行動 *go forward* が最適な行動である。もし移動ロボットはFig.14のように *turn right* の行動をとると、ロボットは交差点Eまで行かなければ位置決めができない。もしも、Fig.13のように行動 *go forward* すれば、ロボットは交差点Cまで行かなくても位置決めができる。もしもロボットが行動 *turn left* をとると、交差点Aに到着してもFig.15のように位置決め の曖昧さがまだ残っている。

以上述べてきた実験を通じて、本センサプランニングシステムの動作とその有効性を確認した。

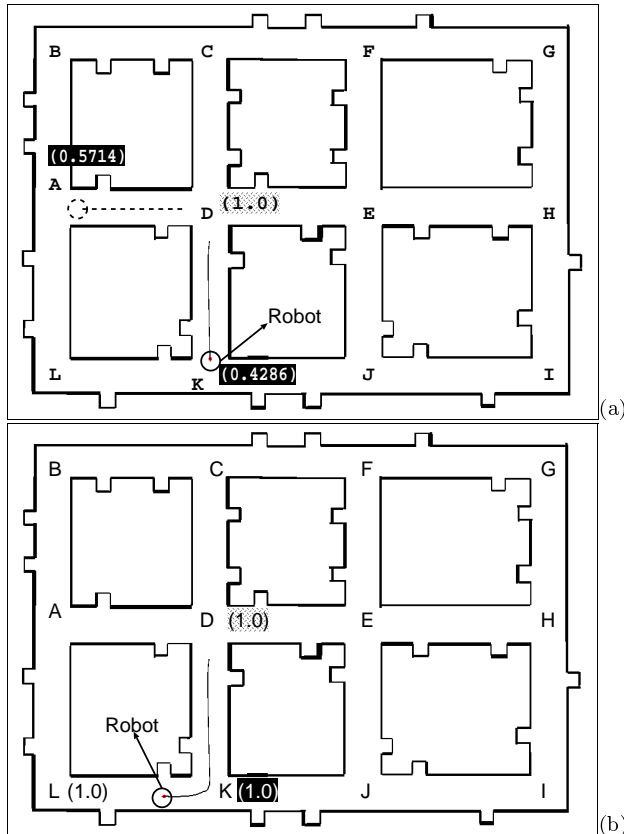


Fig. 9 An example of the experiments of sensor planning for the robot localization. (In the figure, the real numbers in (), () with black square, () with hatched square represent probability of node Tail, Mid, Head, respectively. If the intersection is the instantiation of node Tail, Mid, Head, the probability is shown at the intersection.




Fig. 10 The robot can not obtain sufficient sensor information for localization until it goes to the intersection J.

7. 結 論

本論文では、移動ロボットの不確実性を含むグローバルな位置決め問題を解決するセンサプランニング手法を提案した。システムは GA を結合した K2 アルゴリズムを用いて、バイジアンネットワークの構造を環境データから学習する。BN に基づい




Fig. 11 The robot can not localize itself only by the sensor information of the corridor (K → D). The slid circle and dot line circles mean the possible positions that inferred by BN based on the sensor information of the corridor (K → D).

actlist	M _{sen}		
	mt1	mt2	Tf
go forward	1	2	2
	2	2	2
	4	4	2
	1	2	1
turn left	1	2	2
	1	2	2
	1	1	2
turn right	2	2	2
	1	2	1
	2	1	2
	1	2	2

Fig. 12 Predicted possible actions (actlist) and sensing information to be obtained from the actions (M_{sen}) based on sensing information of the corridor (K → D). (The integers of the table represents values of the probabilistic variables (m_{h1}, m_{h2}, Tf) of the Bayesian network)

て得られたセンシング情報により可能なセンサ行動と、その行動に対応するセンシング情報を予測する。そして、グローバルな位置決め信念度とセンシングコストのバランスを考慮して最適な行動を求めるアルゴリズムを構成した。オフィス環境を想定したシミュレーション実験により、本プランニングシステムの有効性を確かめた。

今後の研究課題としては、以下の点が挙げられる：

- (1) 本システムでは、センシングが必要なところを予め教えて

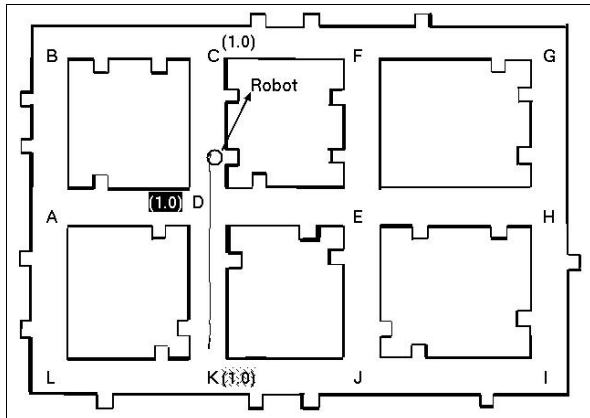


Fig. 13 The robot selects an optimal sensing action (go forward) using sensor planner, so it can localize itself only by using the sensor information of corridor ($K \rightarrow D$) and a part of the sensor information of the corridor ($D \rightarrow C$).




Fig. 14 The robot can not localize itself until it moves to the intersection E .




Fig. 15 If the robot performs “turn left” action, it can not localize itself even if it has sensed two corridors.

るので、必要なセンサ情報を自律的に選択する能力は持っていない。グローバルな位置情報に基づいて必要なセンサ情報を選択する問題は今後の課題である。

(2) BN の構造学習で得られる構造は、ノードの依存関係のみ

であり、センシングコストについては考慮していない。このセンシングコストを考慮した BN の構造学習については今後の課題である。

(3) 実ロボットを使って学習とセンサプランニングのアルゴリズムの有効性を検証することも今後の課題である。

参考文献

- [1] S. Thrun, “Probabilistic Algorithms in Robotics,” *AI Magazine*, 21(4):93-109, 2000.
- [2] S.Thrun, “Bayesian Landmark Learning for Mobile Robot Localization,” *Machine Learning* 33, pp.41-76, 1998.
- [3] N. Roy, W. Burgard, D. Fox, and S. Thrun, “Coastal navigation: Robot navigation under uncertainty in dynamic environments,” *In Proc. of the IEEE Int. Conf. on Robotics and Automation*, 1999.
- [4] S.Thrun, D.Fox, W.Burgard, and F.Dellaert, “Robust Monte Carlo Localization for Mobile Robots,” *Artificial Intelligence (AI)*, 2001.
- [5] H.Asoh, Y.Motomura, I.Hara, S.Akaho, S.Hayamizu, and T.Matsui, “Combining Probabilistic Map and Dialog for Robust Life-long Office Navigation,” *Proc. of the Int. Conf. on Intelligent Robots and Systems (IROS'96)*, pp.880-885, 1996.
- [6] K.Basye, T.Dean, J.Kirman, and M.Lejter, “A Decision-Theoretic Approach to Planning, Perception, and Control,” *IEEE Expert*, Vol.7, No.4, pp.58-65, 1992.
- [7] 稲邑, 稲葉, 井上: “ユーザとの対話に基づく段階的な行動決定モデルの獲得”, 日本ロボット学会誌, Vol.19, No.8, pp.983-990, 2001.
- [8] D. Fox, W. Burgard, and S. Thrun, “Active Markov Localization for Mobile Robots,” *Robotics and Autonomous Systems*, Vol.25, pp.195-207, 1998.
- [9] P.Jensfelt, S.Kristensen, “Active Global Localization for a Mobile Robot Using Multiple Hypothesis Tracking,” *Proc. of the Workshop on Reasoning with Uncertainty in Robot Navigation (by IJCAI'99)*, pp.13-22, 1999.
- [10] S.Kristensen, “Sensor Planning with Bayesian Decision Analysis,” *PhD thesis*, Faculty of Technology and Science, Aalborg University, Aalborg, Denmark, 1996.
- [11] 三浦, 白井: “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.
- [12] 光永, 浅田: “移動体の意思決定のための情報量基準に基づく観測対象選択戦略”, 日本ロボット学会誌, vol. 19, no. 6, pp.793-800, 2001.
- [13] H.Zhou, S.Sakane, “Sensor Planning for Mobile Robot Localization using Bayesian network Representation and Inference,” *Proc. IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, pp.440-446, 2002.
- [14] D. Heckerman, “A Bayesian approach to learning causal networks,” *Technical Report MSR-TR-95-04, Microsoft Research*, March, 1995.
- [15] G. Cooper and E. Herskovits, “A Bayesian method for the induction of probabilistic networks from data,” *Machine Learning*, 9:309-347, 1992.
- [16] P. Larranaga, C. Kuijpers, R. Murga, Y. Yurramendi, “Learning Bayesian network structures by searching for the best ordering with genetic algorithms,” *IEEE Trans. on System, Man and Cybernetics*. Vol. 26, No.4, pp.487-493, 1996.
- [17] F.V.Jensen, “Bayesian networks and Decision Graphs,” *Springer*, 2001.
- [18] R.G.Cowell, A.P.Dawid, S.L.Lauritzen, D.J.Spiegelhalter, “Probabilistic networks and expert systems,” Springer, 1999
- [19] J.Pearl, “Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference,” *Morgan Kaufmann*, 1988.
- [20] J.Edmonds and E.L.Johnson, “Matching Euler Tours and the Chinese Postman,” *Mathematical Programming*, 5, pp.88-124, 1973.

- [21] Kevin Murphy, "The Bayes Net Toolbox for Matlab," *Computing Science and Statistics*, vol 33, 2001. Software is available at <http://www.cs.berkeley.edu/~murphyk/Bayes/bnt.html>.
- [22] C.Houck, J.Joines, and M.Kay, "A Genetic Algorithm for Function Optimization: A Matlab Implementation," Technical Report NCSU-IE 95-09, 1995. Software is available at <http://www.ie.ncsu.edu/mirage/GAToolBox/gaot/>.
- [23] N. Cristianini and J. Shawe-Taylor, "An Introduction to Support Vector Machines," *Cambridge University Press*, 2000.

周 洪鈞 (Hongjun Zhou)

1972 年生まれ。1994 年、中国大連理工大学機械工学科卒業。2001 年、中央大学大学院理工学研究科博士課程前期課程修了。現在同大学大学院博士課程後期課程に在学中。IEEE の会員。

(日本ロボット学会学生会員)

坂根 茂幸 (Shigeyuki Sakane)

1949 年生まれ。1972 年、東京工業大学工学部制御工学科卒業。1974 年、同大学大学院修士課程修了。同年、通産省工業技術院電子技術総合研究所入所。1995 年、中央大学理工学部教授。知能ロボットシステムの研究に従事。工学博士、計測自動制御学会、人工知能学会、電気学会、IEEE の各会員。

(日本ロボット学会正会員)