

# 部分観測環境における移動履歴情報を用いた ロボットのトポロジカル地図作成

Learning Topological Maps with Historical Data of Vehicle Behavior.

金崎弘文\*<sup>1</sup>      矢入健久\*<sup>1\*2</sup>      堀浩一\*<sup>1\*2</sup>  
Hirofumi Kanazaki      Takehisa Yairi      Koichi Hori

\*<sup>1</sup>東京大学大学院工学系研究科航空宇宙工学専攻  
Department of Aeronautics and Astronautics, The University of Tokyo.

\*<sup>2</sup>東京大学先端科学技術研究センター  
Research Center for Advanced Science and Technology.

Topological maps are useful abstract representations of the environment for robotic navigation and human-robot interaction. The sensory limitations of mobile robots hide features of the environment for the robots. In this paper, we consider a special case of corridor environments and variable-length Markov models. We propose a topological map learning method for splitting compound states which contains some essentially different states with the Prediction Suffix Tree.

## 1. はじめに

人間の行動を支援するロボットにおいては、自律的に行動するだけでなく、人間と情報交換しながら行動する必要がある。人間に位置情報や道順情報を提供する際には、正確な距離や方向よりもそれらを抽象化したランドマークやそれらの関係といった定性的な情報として提供する必要がある。また、人間からロボットに行動を指示する際には、定量的な数値データで行動を指示するのではなく、「何々の前」「何々のある場所」といった定性的な情報が使われる。つまり、ロボットは定量的な数値データの地図のほかに、それを抽象化した地図を持つ必要がある。

ロボットが使用する地図の作成は、従来 2 つの方法が研究されてきた。

**メトリック地図** 環境を正確に測量することによって、作成した地図。

**トポロジカル地図** 正確な計測を行わずに、環境中のランドマークをノード、ランドマーク間を移動するための行動をアークとして表現したグラフ構造の地図。

本研究では、環境を抽象化して表現するトポロジカル地図に注目する。

メトリック地図は、ロボットに依存せずに環境そのものを記述している点で汎用性が高い。しかし、環境を正確に計測するコストが高く、データ量が膨大になる。

一方、トポロジカル地図は、環境から得られる情報を抽象化してノードとアークで表現するためにデータの圧縮が可能である。また定量的データだけでなく、定性的なデータからもトポロジカル地図を作成することが出来る。ただし、個別のタスクやロボット構造に特化するためにメトリック地図に比べて汎用性が低いという欠点がある。

トポロジカル地図の作成では個々のロボットのトポロジカル地図自動獲得および、異なるセンサ・アクチュエータを備えたロボット間での地図共有が課題となる。

上記 2 種類の地図作成手法を、どちらか一方だけでなく、双方を組み合わせて利用する研究もある [Thrun 98]。

本研究では、トポロジカル地図の作成において問題となる Perceptual Aliasing によって縮退した各地点を、可変長 N-gram モデルで環境をモデル化することによって分割することを提案する。分割の判定には予測接尾木 [Ron 98] を用いる。

## 2. 従来研究

従来のトポロジカル地図作成研究では、ロボットの移動過程を隠れマルコフモデルもしくは部分観測マルコフ決定過程でモデル化している [Shatkay 97][Koenig 96]。これらの研究では、EM アルゴリズムを用いてモデルのパラメータ推定を行うことが主な課題となる。EM アルゴリズムはモデルの尤度を局所最大化することが保証された強力なパラメータ推定手法である。しかし、局所解に収束しやすいという欠点がある。また、モデルのノード数を決定するのが困難である。モデルのパラメータを増やすことによって尤度が高くなるので、ノード数が多くデータに過特化したモデルほど適したモデルと判断される。尤度とパラメータ数のトレードオフを考慮した AIC や BIC といった情報量基準を用いたノード数の選択方法が提案されている。

部分観測マルコフ決定過程のパラメータを直接推定しない方法も提案されている [Yairi 02]。モデルの各ノードを分割または統合することによってモデルの尤度の増加が最大なるノードについて分割・統合を繰り返す方法である。

## 3. 問題の概要

ロボットのセンサには知覚能力に限界がある。したがって、実際には異なる地点がロボットにとっては同一のセンサ入力として知覚される。このような環境を部分観測環境と呼ぶ。部分観測環境では、トポロジカル地図作成の過程において実際には異なる地点を同じノードに抽象化してしまうという問題が発生する。これを、Perceptual Aliasing と呼ぶ。図 1 の環境で

連絡先: 金崎弘文, 東京大学大学院工学系研究科, 〒 153-8904 東京都目黒区駒場 4-6-1 東京大学先端科学技術研究センター, Tel: 03-5452-5289, Fax: 03-5454-5312, kanazaki@ai.rcast.u-tokyo.ac.jp




図 1: 実際の環境

Perceptual Aliasing が生じている場合、各地点での観測値のみで環境を認識すると図 2 のようになる。図 1 に比べて図 2 では、ノードが縮退しているために歪んだ形になっている。

トポロジカル地図作成では、地図作成の前提条件に応じて環境を 2 種類に分けることができる。

**廊下環境** ロボットの移動可能な経路がある程度決まっている。トポロジカル地図のノードとなる地点は交差点または、廊下の途中の地点である。廊下で結ばれた 2 地点間は移動可能。それ以外の地点間を直接移動することはできない。

**オープンスペース環境** ロボットの移動経路の制約が少ない。任意の 2 地点間を移動することが可能。ただし、障害物等によって移動が妨げられる場合がある。

オープンスペース環境では、環境内の各地点でロボットが実行可能な行動に制約がほとんどないのに対して、廊下環境では廊下によってロボットの行動が制約を受ける。

本研究では、廊下環境を想定する。ここで想定しているロボットは、都市や施設内での移動支援ロボットである。このような環境では、トポロジカル地図のノードとなる地点は交差点、曲がり角や建物の入り口などである。

廊下環境中を移動するロボットに関して 3 つの仮定をおく。

**仮定 1** ロボットは廊下環境中の各地点で、センサデータによる位置の特定を行う。ただし、全ての地点を完全に識別することは出来ない。(Perceptual Aliasing Problem)

**仮定 2** 各観測地点での観測値には再現性があり、同じ地点で毎回同じ観測データを得るものとする。

**仮定 3** ロボットは 1 ステップごとに必ず別の地点に移動し、同じ地点に留まることはないものとする。

## 4. 提案手法

### 4.1 予測接尾木によるノード分割

ロボットの移動を可変長 N-gram モデルでモデル化する。可変長 N-gram モデルは予測接尾木によって表現する。予測接




図 2: 縮退したトポロジカル地図

尾木の枝の成長によって縮退しているノードを特定して、分割対象とする。

廊下環境を移動するロボットの観測値系列は、Perceptual Aliasing のない完全観測環境では単純マルコフ過程であり、2-gram モデルで表現することができる。一方、部分観測環境では Perceptual Aliasing によって観測値と真の地点とが 1 対 1 に対応しない。廊下環境を仮定できる場合には地点間の移動に制約があるので、ある縮退しているノードへの経路をたどる事によって実際にどの地点にいるのかを特定できる。この時にたどる経路の長さは縮退しているノードが連続している場合には長くなる。

廊下環境下での各地点から次の地点への遷移確率分布は多項分布に従う。実際には異なる複数の地点が縮退しているノードに注目すると、このノードでの遷移確率分布は、複数の地点での遷移確率分布の混合分布として観測される。あるノードに至るまでの履歴を条件として、条件付き遷移確率分布を比較することによって、縮退しているノードの分割を行う。

2 つの遷移確率分布の比較には、確率分布のカルバック・ライブラー距離に観測値系列の出現確率を掛けた値  $\Delta H(w\alpha, \alpha)$  を用いる。この値が閾値  $\epsilon_0$  よりも大きければ、2 つの確率分布が異なる分布であると判断して、ノードの分割を行う。

$\Delta H(w\alpha, \alpha)$  は次のように定義される。

$$\begin{aligned} \Delta H(w\alpha, \alpha) &= P(w\alpha) \times D(P(\cdot|w\alpha) || P(\cdot|\alpha)) \\ &= P(w\alpha) \sum_{w'} P(w'|w\alpha) \ln \frac{P(w'|w\alpha)}{P(w'|\alpha)} \quad (1) \end{aligned}$$

本研究における予測接尾木の構築アルゴリズムを以下に示す。

1. ラベルが空の根のみの予測接尾木  $T$  を作る。根には観測値の生起確率分布を記録する。
2.  $\tilde{P}(w) \geq \epsilon_1$  となる観測値  $w$  が存在すれば、ラベルが  $w$  である節点を予測接尾木  $T$  に追加する。
3. ラベルが  $\alpha$  の節点に関して、再帰的に次の操作を繰り返す。

- (a)  $\tilde{P}(w\alpha) \geq \epsilon_1$  となる観測値系列  $w\alpha$  があれば、ラベルが  $w\alpha$  の節点を予測接尾木  $T$  に追加する。観測値系列  $w\alpha$  の条件付きの遷移確率分布  $P(\cdot|w\alpha)$  を記録する。

4. 予測接尾木  $T$  の葉節点ごとに次の枝刈り操作を繰り返す行う。

- (a) 葉節点のラベルを  $\alpha$  として,  $\Delta H(\alpha, \text{suffix}(\alpha)) \leq \epsilon_0$  ならば, 葉節点  $\alpha$  を予測接尾木  $T$  から取り除く。

#### 4.2 葉節点の統合によるトポロジカル地図への変換

各葉節点を状態とすることによって, 予測接尾木を確率有限オートマトンに変換することが出来る。この際, 予測接尾木の各葉節点がオートマトンの各状態となる。

予測接尾木によるノードの分割を行うと, 縮退しているノードは真の観測地点よりも細かく分割される。このような過剰な分割は, 観測地点に到達する際の向きの違いを反映したものである。実際には同じ観測地点であってもその地点に到達する経路が異なるために予測接尾木による分割の対象となる。

予測接尾木の葉節点  $\alpha w$  と  $\beta w$  のように分割対象となっているノードの観測値が同じものについて, 条件付き遷移確率分布が同じとみなせるものを統合する (図 3)。確率分布の同一性判定は,  $\chi^2$  検定や AIC などの情報量基準を用いて行う。




図 3: 予測接尾木の葉ノードの統合

## 5. シミュレーション

### 5.1 シミュレーション環境

筆者らの所属する東京大学先端科学技術研究センターのある東京大学駒場リサーチキャンパスを想定した実験環境を作成した。環境中の各地点でロボットが観測を行う。

シミュレータでの観測値は各地点を特定することのできる離散的な値である。センサを用いたロボットの環境認識ではプリミティブなセンサ入力のノイズ除去, 特徴量抽出, クラスタリング, パターンマッチング等の処理を行う。本シミュレータでは, これらの処理を前提として, 離散的な観測値のみを用いる。つまり, 各地点ではカメラやレンジファインダ等によるセンサ入力を処理することによって離散的な観測値に変換する。この時, 観測値からだけでは実際には異なる各地点を一意に特定することはできない。

シミュレーションには, 図 1 の環境を用いた。実際の観測地点数は 35 である。ロボットは環境中をランダムに移動しながら各地点での観測値を収集する。35 地点のうち, 3 組 6 地点ではそれぞれ Perceptual Aliasing がおきている (図 1 および図 2 の A, B, C)。

### 5.2 結果

観測データを処理して得たトポロジカル地図を図 4 に示す。縮退していたノード A, B, C はそれぞれ 2 つに分割された。ただし, シミュレーション環境中の隣接する 2 つの縮退ノード間での A-B-A-B-という遷移に対しては明確に A1, A2, B1, B2 間のどの遷移であるか決定できなかった。図 4 の A1-B2 お

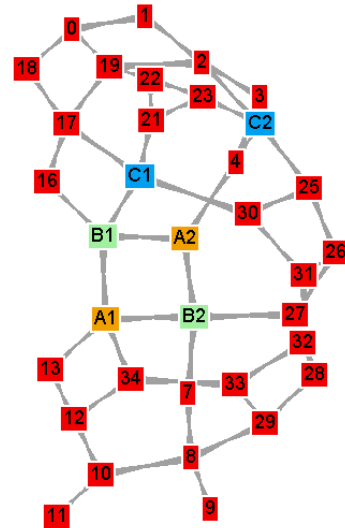


図 4: 予測接尾木から変換したトポロジカル地図




図 5: 不確定なリンクを切断したトポロジカル地図

よび A2-B1 のリンクはこのような曖昧性による。このような曖昧性に起因するリンクを切断した地図を図 5 に示す。これは, 実際の環境と一致している。

## 6. 考察

従来研究では, 隠れマルコフモデルや部分観測マルコフ決定過程によるモデル化を行い, モデルのパラメータを EM アルゴリズムで推定することによって, トポロジカル地図を作成する。EM アルゴリズムではモデルの尤度を局所最大化するパラメータを求める。EM アルゴリズムはモデルパラメータ推定手法であって, トポロジカル地図の構造を明確に規定することができない。トポロジカル地図のノード数を決定するのも困難である。

本研究では, 可変長 N-gram モデルを利用して, トポロジカル地図のローカルな構造を推定することによって, Perceptual Aliasing の生じているノードの分割を行った。

従来研究における EM アルゴリズムでは, 観測データ全体に対してモデルの尤度を計算する。一方, 提案手法ではデータ全体に対してでなく, 注目するノードに到達するまでの数ステップについてのみ考慮している。この点が両手法で異なる。

本手法は、各地点のローカルな関係を利用する方法である。したがって、ローカルな関係の全く同じ2つの地域を区別することは困難である。つまり、Perceptual Aliasingによって縮退しているノードの周りが全て同様に縮退したノードで囲まれていて、このような地域が複数ある場合には区別が困難となる。このような場合には、反復的にノードの分割・統合を繰り返す必要がある。

## 7. 今後の課題

本稿で提案する手法は、各ノードにおけるローカルな予測性能を利用した地図作成である。一方、EMアルゴリズムを用いて地図のグローバルな尤度を局所最大化する手法がある。ローカル/グローバルそれぞれの評価手法を利用したノード数およびパラメータの決定が今後の課題である。

また、予測接尾木は環境中の各地点でどれくらいPerceptual Aliasingが生じているかによって構造が異なる。したがって逆に、木の構造からそのロボットのセンサ系の性能や種類が環境に適しているかを判断する方法について議論する。

本稿では問題を単純化するために、第3節において廊下環境におけるロボットに移動および観測について3つの仮定を行った。実際のロボットを用いた地図作成を行う際には、ロボットのセンサの種類によってはロボットの向きによって観測値が異なるために仮定2を満たすことが難しい。逆に仮定2を満たすためには方向に依存しない観測データの利用が望ましい。また、環境が変化した場合にも仮定2を満たすことが難しい。したがって、各状態では観測値が確率的に出力されるとする隠れマルコフモデルへの適用が今後の課題である。

## 8. おわりに

本稿では、ロボットのトポロジカル地図作成においてPerceptual Aliasingによって縮退したノードを特定し分割するために予測接尾木を利用する手法を提案した。廊下環境および各地点での観測値の再現性を仮定した環境では、Perceptual Aliasingにより縮退したノードを特定し分割することが出来た。

## 参考文献

- [Thrun 98] Sebastian Thrun, Steffen Gutmann, Dieter Fox, Wolfram Burgard, and Benjamin J. Kuipers, Integrating Topological and Metric Maps for Mobile Robot Navigation: A Statistical Approach, Proceedings of AAAI-98, pp.989-995, 1998.
- [Ron 98] Dana Ron, Yoram Singer, Naftali Tishby, The Power of Amnesia: Learning Probabilistic Automata with Variable Memory Length, Machine Learning, Vol.25, pp.117-149, 1996.
- [Shatkay 97] Hagit Shatkay, Leslie Pack Kaelbling, Learning Topological Maps with Weak Local Odometric Information, IJCAI, pp.920-929, 1997.
- [Koenig 96] Sven Koenig, Reid G. Simmons, Unsupervised learning of probabilistic models for robot navigation, In Proceedings of the IEEE International Conference on Robotics and Automation, 1996.
- [Yairi 02] Learning Topological Maps from Sequential Observation and Action Data under Partially Observed

Element, Takehisa Yairi, Masahito Togami, Koichi Hori, Proceedings of 7th Pacific Rim International Conference on Artificial Intelligence (PRICAI 2002), Tokyo, August, 2002, pp.305 - 314.