

段階的推定モデルによる センサネットワークのトポロジ推定

渡辺 友太^{†1} 栗原 聡^{†2}
廣津 登志夫^{†3} 菅原 俊治^{†1}

本研究では、赤外線センサを用いたセンサネットワークのトポロジを、センサの時系列データのみから推定するモデルを提案する。近年、センサネットワークやユビキタスコンピューティングを活用した、人の行動に基づいた機能やサービスを提供するアプリケーションが提案されている。これらのサービスを実現するためには、現在の環境や人の習慣に即した動線に基づく、センサネットワークのトポロジ情報が必要である。また、このトポロジ情報は行動習慣の変化や環境の物理的变化により頻繁に変化するため、高精度に自動推定する手法が求められる。提案手法では、より確実性の高い隣接関係の推定結果を用いながら、段階的に推定する隣接関係の数を増やす手法を用いる。これにより、推定の精度を保ちながら、多くの隣接関係を推定することを可能とする。実験では、実際の環境で収集したセンサデータを用いて提案手法を評価し、従来手法と比較して高精度・広範囲に隣接関係が推定できることを示す。

Sensor Network Topology Estimation Using Incremental Estimation Model

YUTA WATANABE,^{†1} SATOSHI KURIHARA,^{†2}
TOSHIO HIROTSU^{†3} and TOSHIHARU SUGAWARA^{†1}

This paper proposes the method for accurately estimating topology of sensor networks from time-series data obtained from infrared proximity sensors. Recently, many applications, such as systems that assist with daily activities, have been proposed in the studies on sensor networks and pervasive computing. To realize these applications, the system needs the sensor-network topology reflecting people's moving lines collected in the actual environment and common daily behaviors. This kind of topology may change due to the changes in the environments and common behaviors and the failures of sensor devices. So the automated method to accurately estimate topology of sensor networks is required. Our proposed method is an incremental estimation methods in

which the reliable adjacent-relationship results are first identified, then other relationships are gradually estimated based on the previous results. It can estimate more topology with high accuracy. We show that, using actual data gathered from real-world environments, our method can estimate the topology more accurately than the conventional methods.

1. はじめに

近年、センサデバイスの高機能化が飛躍的に進んでおり、それらを結び付けたセンサネットワークやユビキタスコンピューティングを活用した様々なアプリケーションが提案されている。これらのアプリケーションでは、人の日常的な行為や作業を実世界とサイバー空間で結び付け、その両面からサポートすることが重要であり、そのためには人の行動からその意図や動機を予想する人間行動マイニングが必要である^{1),2)}。特に、人の行動に基づいた機能やサービスを提供するには、人の日常的な動線やある行動の後に予想される動線を推定することが求められる。

現在の環境や人の習慣に即した動線を推定するには、センサネットワークのトポロジ情報が必要である。しかし、センサネットワークにおけるトポロジは、人間の行動習慣の変化や環境の物理的变化、センサの故障・増設などにより頻繁に変化する。そのつどトポロジを手動で再設定するコストは、センサの数とともに増大し、設定ミスも起こりうる。センサネットワークについての前提条件はできるだけ少ない環境で、高精度にトポロジとそれに基づく動線を自動推定する手法が求められる。

本研究で対象とするセンサネットワークのトポロジは、動線推定で活用できるものである。人の移動により、設置されたセンサは時系列的に反応することから、人の動線はセンサの識別子の列で表すことができる。たとえば図1において、人が頻繁にセンサAからBに移動する場合、センサ列A, C, D, Bが動線を表す。また、この動線を表すセンサ列の中で、前後に並んでいるセンサの関係を、特に隣接関係と呼ぶ。図1の例でいうと、センサAとC, CとD, DとBが隣接関係にあるといえる。つまり、本研究における隣接関

^{†1} 早稲田大学大学院基幹理工学研究科

Department of Computer Science and Engineering, Waseda University

^{†2} 大阪大学産業科学研究所

The Institute of Scientific and Industrial Research, Osaka University

^{†3} 法政大学大学院情報科学研究科

Graduate School of Computer and Information Sciences, Hosei University




図 1 トポロジの例

Fig. 1 Example of topology.

係とは、A と B のように物理的に最も近い距離にあるセンサ間関係ではなく、人物が移動する際に連続して反応するセンサの関係性を指す。そしてセンサネットワークにおいて、存在する隣接関係の集合をトポロジと呼ぶ。

上記の設定のもと、本研究ではセンサの反応の時系列データのみからセンサネットワークのトポロジを高精度に推定する手法を提案する。特に反応間隔の分布の特徴を活用するとともに段階的に隣接関係を求める。つまり、1 度にすべての推定を行わず、確実性の高い隣接関係を推定し、その結果を反映させながら次の隣接関係を求め、その数を増やす。これにより、高精度にトポロジの推定が可能であることを示す。

本論文の構成は以下のとおりである。次の章で関連研究と本研究のねらいを述べる。3 章において本研究で扱う問題を定義し、4 章で本研究の提案手法の基本的なアイデアを示す。これをもとに、5 章で提案手法について詳細に述べ、さらに、実際の環境で収集したセンサデータを用いた推定結果を示す。環境データとして、各センサの反応頻度のばらつきが比較的小さいデータセットと、センサごとに反応頻度に差があり、通常ではあまり立ち入ることのない領域を一部に含む環境のデータセットを用いる。提案手法により、どちらの環境でも推定の精度を保ちながら、既存研究より多くの隣接関係を推定できることを示す。

2. 関連研究と本研究のねらい

人の動線やセンサネットワークのトポロジ推定については、これまでも多くの試みがある。たとえば、文献 3)、4) のように、環境中にいる人に RFID を携帯させ、ユーザごとの動線を得ている。RFID を用いることは動線の推定を容易にするが、一方でユーザの負担や配布コストの面から RFID を用いることは望ましくないと考えられる。しかし、単純なセ

ンサからのデータのみを用いて人物の動線を抽出する場合、その精度が課題になる。また、用いるセンサについてもコストや設置の容易さという点から、より安価で単純なセンサを用いることが求められる。

文献 5)–7) では、RFID を用いず、代わりにトポロジを既知とし、赤外線センサなどの単純なセンサから得られたデータとトポロジを結び付け、動線の推定をしている。この前提では、存在しない無効な動線をノイズデータとして除去でき、離れた場所で複数の人物が移動している場合でも、人物ごとの動線抽出が可能となる。文献 5) では人の移動速度を既知とすることで、より正確に動線を抽出している。しかし、前章で述べたようにトポロジをつねに正しく維持することは容易ではない。またセンサの故障などにより、データに不整合が発生することもある。人の移動速度もトポロジや習慣の変化に合わせて調整する必要がある。したがって、環境やセンサのトポロジ、人の移動速度を既知とせずに、センサの反応データのみからトポロジや動線を推定する必要がある。

このような課題に対して文献 8) は、ペジアンネットワークを用いて人物の追跡を行うが、その精度は高くない。また、文献 9)、10) は本研究と同様に、センサ間の反応間隔の長さや分布に注目し、センサが隣接関係にあるかを推定する。文献 8) と比較して高い精度で人物の追跡を行うが、あらかじめ決められた動線に対しての追跡であるため、実環境での推定には課題が残る。

センサネットワークのトポロジや人物の移動経路にも制約を与えない環境で、動線やトポロジを推定する手法として、モンテカルロ法や EM アルゴリズムを用いた手法が提案されている^{11),12)}。文献 12) はセンサ数が少ない環境ではあるが、高い精度で動線の推定を行う。文献 11) はカメラを使用した手法ではあるが、トポロジが未知な状態から段階的に隣接関係を推定していく有効性を示している。しかし、センサ数が少ないこと、カメラの使用などは、その適用の制約となる。

一方、我々もこれまで、センサ間の隣接関係を未知とし、人に RFID などの識別子を持たせずに、センサの時系列反応データのみから動線を推定する手法を提案してきた^{13),14)}。これらの研究では、Ant Colony Optimization (ACO) を用いて精度の高いトポロジの自動推定を行うが、推定できる隣接関係が多い一方で、推定の精度には課題があった。また、文献 15) では、動線が存在する可能性を示す推定スコアを定義し、精度良く動線を推定するとともに、動線の推定が隣接関係の推定にも応用できることを示した。さらに、文献 16) では、文献 13)、15) の手法を組み合わせ、より高精度な隣接関係の推定手法を提案した。

しかし、高い精度で隣接関係を推定できる一方で、一部の隣接関係しか推定できないとい

う課題を残した。これらの関連研究が示すことは、センサネットワークのトポロジ推定では、隣接関係を正しく推定できる精度と、推定できる隣接関係の多さはトレードオフの関係にあることである。既存研究では、いずれかの優位性を持つアルゴリズムを提案している。

本研究では反応データの間隔の特徴から、段階的に隣接関係を推定し、これまでの研究と比較して、高い精度を保ちながらも、多くの隣接関係を求めることをねらっている。文献 13), 15) では、各センサが時系列上で連続して反応しているかに注目して隣接関係を推定していた。そのため、連続して反応することが少ない距離が遠いセンサどうしの隣接関係を推定することが難しく、複数が移動したデータに対して誤った推定をすることが多かった。そこで本研究では、文献 9), 10) と同様に反応間隔に注目して推定を行う。反応間隔に注目することで、時系列上連続して反応していないが、実際は隣接関係にあるセンサも推定する。また、一般に推定結果の確実性はセンサごとに差があり、精度良く広範囲に隣接関係を推定するためには、確実性の高い推定結果から同定し、それを学習結果として他のセンサを推定していくことが望ましい。そこで本研究では、1 度にすべての隣接関係を推定するのではなく、確実性の高いセンサから段階的に隣接関係を推定する。

3. 問題の定義

3.1 センサと環境

本研究では、センサの前を物体が通過すると反応するセンサ（たとえば赤外線による近接センサなど）を用いる。環境に設置されたセンサの集合を $V = \{v_1, v_2, \dots, v_n\}$ とする。またセンサはオフィスや部屋などの室内に設置されていることを想定している。環境は複数の部屋にまたがっている可能性もあり、環境中を移動する人数も制限されない。また、センサが誤反応を起こしたり、センサの前に物を置いたりするなど、人の移動によらない反応も発生する。

3.2 時系列反応データ

センサの反応を記録した時系列反応データからは、ある時刻 t において反応したセンサの識別子が得られる。本研究ではある時刻 t において反応したセンサの集合を D_t とする。たとえば、時刻 t においてセンサ $v_i, v_j \in V$ が反応したとき、 $D_t = \{v_i, v_j\}$ と書く。時刻 i から $i+n$ に収集した時系列反応データを $D_{i,i+n} = \{D_i, D_{i+1}, \dots, D_{i+n}\}$ と書く。本論文で示す実験データは、センサの反応を 0.5 秒間隔で記録しているため、ある時刻 t と $t+1$ 間隔は 0.5 秒となる。

3.3 トポロジ

本論文で対象とする隣接関係は、人物が移動する際に連続して反応する 2 つのセンサの関係であり、これは動線上に並ぶセンサ列のうち、前後に並んでいるセンサのペアである。したがって、隣接関係は動線を構成する基本要素ともいえる。センサ v_i から v_j への動線を (v_i, v_j) と表す。トポロジは、このような動線の集合で表せ、たとえば、図 1 の環境は、 $\{(A, C), (C, A), (C, D), (D, C), (D, B), (B, D)\}$ と表せる。本論文が対象とする問題は、時系列データ $D_{i,i+n}$ から、トポロジを表す隣接関係の集合を推定することである。

4. 隣接関係の推定

4.1 単純なトポロジ推定

センサの時系列反応データの中で連続して反応するセンサを、隣接関係にあると推定するのが最も単純な推定手法であるが、複人数の同時移動やノイズなどにより、この手法では精度良く隣接関係を推定することができない。たとえば図 2 に示すセンサネットワークと人の動きを考える。反応データが $D_t = \{a\}$, $D_{t+1} = \{b, c\}$, $D_{t+2} = \{d\}$, $D_{t+3} = \{d\}$ とする。このとき連続した反応のみから推定すると、 (a, b) , (a, c) が隣接関係となる。センサ a, c, d とセンサ b の反応は異なる人物の移動によるものであり、センサ a, b を隣接関係とするのは間違いであるが、RFID などを仮定していないので、反応データから 2 人の動線と特定できない。また、センサの設置間隔は一定ではなく、隣接関係にあるセンサ間の反応間隔も一定ではない。反応間隔は移動する人物の動く速さにも影響される。たとえば図 2 のセンサ c, d は隣接関係にあるが、やや離れているため、反応間隔はやや長くなり、一連の動線として抽出できないこともある。

4.2 センサ間距離と反応間隔

センサ間の距離による反応間隔のばらつきが、実際の時系列データでどのように現れるの




図 2 動線推定の例

Fig. 2 Example of estimation.

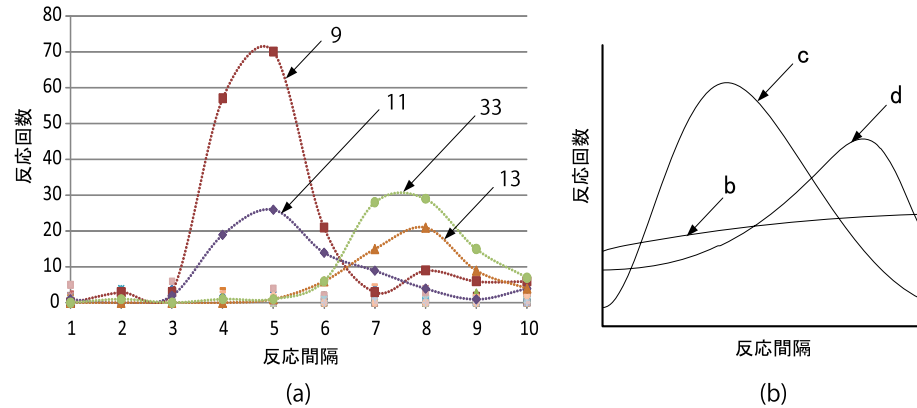


図3 センサ a 反応後の他のセンサの反応
Fig. 3 Reacts after sensor a reacted.




図4 環境 (A) のトポロジ
Fig. 4 Topology of environment (A).

かを図 3(a) に示す．反応間隔とは，あるセンサが反応した後，他のセンサが反応するまでの経過時間を指す．このグラフは，図 4 に示す環境から収集したデータに基づく．図 4 で記される数字はセンサの識別子である．以後，センサ n とは識別子 n のセンサを示すこととする．グラフでは，センサ 10 が反応した後にその他のセンサが反応した回数と，センサ 10 の反応からの経過時間（反応間隔）を示している．たとえば，センサ 9 はセンサ 10 の反応後，5 単位時間後に 70 回の反応があることを示す．図 3(a) では，センサ 10 の反応と相

関があると考えられるセンサ 9, 11, 33, 13 について，プロットされたデータを線で結んでいる．また，グラフの下の方には反応回数が少なくセンサ 10 と相関がないと考えられるデータがある．

図 3(b) はこのような反応間隔と回数の関係を簡略した模式図であり，図 2 の環境を想定し，センサ a が反応した後の b, c, d の反応回数と反応間隔を表している．図 2 の環境では，センサ a からの動線上にあるセンサは c, d である．動線上にセンサが存在する場合，図 3(b) のセンサ c, d のように，反応回数が最も多い反応間隔を中心に山のように分布する．ただし，実際の環境では人物の移動速度の違いやセンサの誤反応，異なる人物の移動による反応が含まれるため，ややばらつきが出る．一方，センサ b はセンサ a とは関係のない離れた場所に設置されている．この場合，センサ b の反応はセンサ a の反応と相関はなく，動線上にあるセンサのような特徴はない．

4.3 隣接関係にあるセンサの特徴

動線上にあるセンサは，図 3 に示すような特徴を持つが，反応回数が最も多くなる反応間隔は，センサ間の動線上の距離に依存する．図 3(b) の例では，センサ a が反応した後， c, d が続いて反応したが，センサ d の方が反応回数のピークは遅れて現れる．これはセンサ d が c と比べ， a から遠い距離にあることを示す．図 3(b) のみからは，センサ c, d が同じ動線上にあるかは判断できないが，反応回数のピークが現れた間隔が小さいセンサほど隣接関係にある可能性が高いと考えられる．

5. 提案手法

本研究における提案手法は，時系列反応データの分析，隣接関係の段階的推定，推定結果の補正によって構成される．この章では提案手法の詳細について述べる．

5.1 反応間隔とピーク

提案手法で用いる値や関数を定義する．正の整数 I とセンサ v_i, v_j に対し， $v_i \in D_t \wedge v_j \in D_{t+I} \wedge v_i, v_j \notin D_{t+1} \cup \dots \cup D_{t+I-1}$ を満たすとき， v_i の反応後の v_j の反応間隔は I であるとする．データの中でセンサ v_i, v_j が反応間隔 I で反応した回数を， $count(v_i, v_j, I)$ とする．

あるセンサのペア v_i, v_j について，反応間隔のピークを抽出するための指標として $UpDown(v_i, v_j, I)$ を以下で定義する．

$$UpDown(v_i, v_j, I) = \{count(v_i, v_j, I) - count(v_i, v_j, I - 1)\} + \{count(v_i, v_j, I) - count(v_i, v_j, I + 1)\}$$

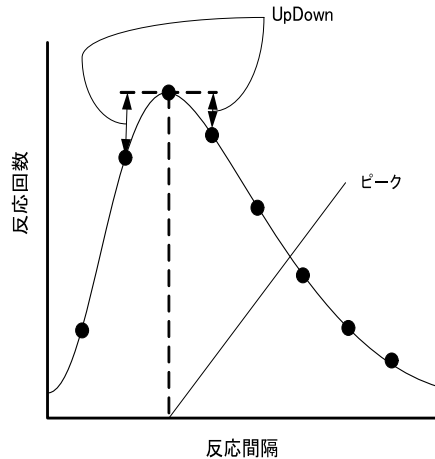


図5 反応間隔とピーク
Fig. 5 Interval and peak.

ただし $count(v_i, v_j) > count(v_i, v_j, I - 1)$ かつ $count(v_i, v_j) > count(v_i, v_j, I + 1)$ とし、それ以外の場合は $UpDown(v_i, v_j, I) = 0$ とする。

センサ v_i, v_j と正の整数 B について、

$$Peak(v_i, v_j) = \arg \max_{1 \leq I \leq B} UpDown(v_i, v_j, I)$$

とする (図5)。また、センサ v_i について、 $UpDown(v_i, v_k, Peak(v_i, v_k))$ (ただし $v_k \in V$) を大きい順に並べ、上位 $rank$ 位以内のセンサの集合を返すリストを $UpDownList(v_i, rank)$ とする。ただし $rank$ は正の整数である。

5.2 提案手法の詳細

推定の準備として、実験環境から得られたセンサの時系列反応データから、すべてのセンサ $v_i, v_j \in V$ の組について、 $1 \leq I \leq B$ の範囲で、 $count(v_i, v_j, I)$ を求めておく。

5.2.1 隣接関係の段階的推定

我々は確実なデータから段階的に推論する手法を提案するが、本研究では、精度の高い隣接関係の抽出を目的とするため、反応間隔に着目した段階的推定法を活用する。一般に確実性は、データ量やそのピーク値などいくつかの指標はあるが、対象としている実環境におけるセンサの隣接関係の推定を考慮すると、最初はセンサ間の距離や、隣接関係にあるセン

サ数は未知である。そこで、反応回数のピークが現れる反応間隔がより小さいセンサほど、隣接関係が存在する確実性が高いと考え、短い反応間隔にピークを持つセンサ間の隣接関係から推定を行い、その学習結果を反映させ、次に隣接関係にある可能性が比較的低いセンサ群についても推定を行う手法をとる。

ピークの反応間隔を I_{peak} 、推定された動線の集合を K とおく。 $K = \phi, I_{peak} = 1$ と初期化する。 I_{peak} を 1 から増加させながら、次に述べる動線候補の取得と学習を繰り返す。 $I_{peak} = i$ で動線候補の取得と学習を行った結果得られる K を K_i とすると、 $K_i - K_{i-1} = \phi$ または、 $I_{peak} = B$ のとき、処理を停止する。

5.2.2 動線候補の取得と学習

動線候補の集合を K' とおき、 $K' = \phi$ と初期化する。あるセンサ $v_i \in V$ について、 $v_j \in UpDownList(v_i, rank)$ かつ、 $Peak(v_i, v_j) = I_{peak}$ のとき、 (v_i, v_j) を動線の候補とし、 K' に加える。

次に、得られた動線候補の集合 K' の要素 (v_i, v_j) について、下記の条件のいずれかにあてはまる場合、 v_i から v_j への動線が存在すると推定し、 (v_i, v_j) を K に追加する。

条件 1: $(v_j, v_i) \in K \vee (v_j, v_i) \in K'$

条件 2: $((v_i, v_k), (v_k, v_j) \in K \cup K') \wedge ((v_i, v_k) \in K \vee (v_k, v_j) \in K)$ を満たす $v_k \in V$ が存在する。

条件 3: $((v_i, v_k), (v_k, v_l), (v_l, v_j) \in K \cup K') \wedge (|\{(v_i, v_k), (v_k, v_l), (v_l, v_j)\} \cap K| \geq 2)$ を満たす $v_k, v_l \in V$ が存在する。

条件 1 は隣接関係の推定、条件 2 は隣接の隣接の関係にある動線の推定および隣接関係の推定の補完、条件 3 は隣接の隣接の関係にある動線の推定の補完を狙っている。これらの条件は、推定結果が隣接の隣接にあたる関係であるかを評価指標としていることから設定しており (評価方法については 6.2 節で述べる)、より長い動線の推定を目的とする場合は条件を追加することが考えられる。

5.2.3 推定結果の補正

上記の繰返しが停止した結果、 K に含まれないセンサについて補正を行う。このようなセンサは反応回数が少ない、ピークが存在しないなど、十分信頼できるデータでない可能性がある。そこで、 K に 1 度も現れなかったセンサ v_i に対し、 $UpDownList(v_j, v_i, Peak(v_j, v_i))$ を最大化するようなセンサ v_j を見つけ、 (v_j, v_i) を K に加える。以上の処理の結果、 K に含まれる動線を推定結果とする。

6. 実験

6.1 実験環境とデータ

今回の実験では、大阪大学産業科学研究所の沼尾/栗原研究室 (A) と豊橋技術科学大学の旧廣津研究室 (B) で収集したデータを使用した。(A) については 44 個のセンサを設置し 121 日間分のデータ、(B) については 30 個のセンサを設置し 26 日間分のデータを用いた。図 4 に (A)、図 6 に (B) におけるセンサの配置図を示す。また、パラメータ B は、分析の対象とする反応間隔の上限値を定めるもので、十分に大きな値を定める必要がある。 B が小さすぎる場合は、 B より大きい反応間隔を示す隣接関係にあるセンサを推定することができない。本実験では、用いたデータに存在するピークが分析対象となるよう十分な値として $B = 10$ を用いた。なお図 3(a) に例示した反応間隔と回数のグラフは環境 (A) にお




図 6 環境 (B) のトポロジ
Fig. 6 Topology of environment (B).

けるセンサ 10 を基準としたものである。

6.2 評価手法

推定した動線の精度は、実際のトポロジと比較して評価する。実際のトポロジで隣接関係にある動線の集合を Top_{adj} とする。推定された動線の集合を Top_{est} とすると、推定した動線が、実際のトポロジで隣接関係にある割合である隣接正解率を、

$$a(Top_{est}) = \frac{|Top_{est} \cap Top_{adj}|}{|Top_{est}|}$$

と定義する。また、センサには誤反応がある点や、実際のアプリケーションでの利用を考えると、隣接の隣接を推定できることも十分価値があると思われる。そこで、隣接関係にある動線に加え、隣接の隣接までの動線を含めたトポロジを Top_{line} とし、動線正解率を以下の式で定義する。

$$a(Top_{est}) = \frac{|Top_{est} \cap Top_{line}|}{|Top_{est}|}$$

以上の隣接正解率、動線正解率を用いて推定結果を評価する。比較手法には、文献 13) が提案する Ant Colony Optimization (ACO) を用いた手法と、文献 16) が提案した文献 13), 15) を組み合わせた手法を用いる。

文献 13) が提案する手法はフェロモンモデルの一種である Ant Colony Optimization (ACO) を用いて、センサ間の隣接関係の推定を行う。ここでは概要を述べるが詳しくは文献 13) を参照されたい。ACO はアリの採餌行動における最適化手法をモデル化したもので、TSP やネットワークルーティングなど多くの最適化問題に対してその有効性が確認されている。文献 13) では、各センサが時系列的に反応しているかに着目して、アリエージェントの移動確率を決定し、フェロモンを排出させる。アリエージェントの移動とフェロモン排出により決定された、各センサ間のフェロモン量を用いて隣接関係の推定を行う。

文献 16) が提案する手法は、文献 15) が提案する動線推定の手法を隣接関係の推定に応用したうえで、文献 13) が提案する ACO を用いた手法と組み合わせたものである。文献 15) では、各センサ間に動線が存在する可能性を示す推定スコアを定義し動線の推定を行う。隣接関係は動線を構成する基本要素といえるため、動線推定の手法は隣接関係の手法にも適用できる。推定スコアおよび文献 16) が提案する手法の詳細は、文献 15), 16) を参照されたい。




図7 提案手法による環境 (A) の推定結果
Fig.7 Result of estimation (A) by our method.

6.3 実験結果

6.3.1 結果の概要

まず、提案手法により推定された隣接正解と動線正解の動線を、図7、図8に示す。図7、図8において実線は隣接正解、点線は動線正解を示す。不正解の導線は環境(A)については、(8, 47)の1つ、環境(B)については、(3, 37), (3, 45), (24, 13), (24, 21), (24, 39), (24, 44), (33, 3), (33, 7)の8つが推定された。提案手法の比較として、環境(A)については文献16)の手法による推定トポロジ、環境(B)については文献13)の手法による推定トポロジを、それぞれ図9、図10に示す*1。環境(B)については、図10以外に、(3, 8), (3, 13), (3, 24), (3, 33)の不正解の動線が文献13)の手法により推定されている。また提案手法および比較手法の隣接正解率、動線正解率を表1に示す。ただし、比較手法との精度を比較するため、ある動線 (v_i, v_j) と (v_j, v_i) (ただし、 $v_i, v_j \in V$) は、1つの動線とする。これは比較手法では動線の向きを考慮しないためである。

推定されたトポロジ図(図7と図9)と評価指標の結果から、環境(A)では、各正解率をあまり落とすことなく推定可能な動線の数約2倍に増えている。文献16)は、正解率を重視した手法であり、抽出できた隣接関係の数が少ないという課題があった。提案手法では1つだけ不正解であった。また、環境(B)では若干の精度低下は見られるものの推定可




図8 提案手法による環境 (B) の推定結果
Fig.8 Result of estimation (B) by our method.




図9 文献16)による環境 (A) の推定結果
Fig.9 Result of estimation (A) by Ref. 16)'s method.

*1 比較対象とした文献13)と文献16)では、環境(A)については文献16)が、環境(B)については文献13)のほうが良好な結果を得られている。

44 段階的推定モデルによるセンサネットワークのトポロジ推定




図 10 文献 13) による環境 (B) の推定結果
Fig. 10 Result of estimation (B) by Ref. 13)'s method.

表 1 各手法の精度
Table 1 Accuracy ratio of each method.

環境	(A)		(B)	
	提案手法	文献 16) の手法	提案手法	文献 13) の手法
全推定数	42	20	29	20
隣接正解数	37	20	16	14
動線正解数	4	0	6	2
不正解数	1	0	7	4
隣接正解率	88%	100%	55%	70%
動線正解率	98%	100%	76%	80%

能な動線の数約 40% ほど増えた。図 8 と図 10 を比較すると、実験環境の複数の部屋にまたがり広範囲に動線が推定できている。

表 2 段階的推定と一括推定の精度

Table 2 Accuracy of learning method and not learning method.

環境	(A)		(B)	
	提案手法	一括推定	提案手法	一括推定
全推定数	42	238	29	48
隣接正解数	37	76	16	25
動線正解数	4	58	6	12
不正解数	1	104	7	11
隣接正解率	88%	32%	55%	52%
動線正解率	98%	56%	76%	77%

6.3.2 段階的推定の効果検証

本提案手法の特徴である段階的推定手法の有効性を検証する。まず、段階的推定を行わず、1 度に推定を行った場合の隣接正解率、動線正解率との比較を表 2 に示す。ここで段階的推定を行わないとは、5.2.2 項で示した I_{peak} を段階的に増やさず、ある I_{peak} の値以下の条件で得られたすべての動線を候補とする手法である。閾値となる I_{peak} の値は、各環境で提案手法による推定結果が収束した時点での I_{peak} の値を用いた。環境 (A) については、段階的な推定を用いた場合の精度 (表 1) と比較して、大幅に精度が落ちていることが分かる。一方環境 (B) では、精度の低下はほとんどない。

次に、本提案手法が段階的推定を行うことにより、トポロジが推定する過程を図 11、図 12 に示す。また、図 11、図 12 に示した時点での、推定結果の精度を表 3 に示す。はじめのうちは隣接正解率が 100% で推移しているように、より確実な動線を推定している。その後、動線正解にあたる動線や、不正解の動線が推定され始める。ある手法でデータを 1 度に用いて推定を行うより、段階的にトポロジを推定する提案手法の有効性が確認できる。

7. 考 察

前章に示した結果から、提案手法により推定の精度を保ちながら、より多くの隣接関係を推定できたことが分かる。特に環境 (A) では、誤った推定を行った動線が 1 つだけでありながら、ほぼすべてのセンサについて動線を推定できており、比較手法の結果と比べても、本提案手法の有効性が確認できる。

一方で環境 (B) では、従来手法や比較手法に対し、精度や推定可能な動線の数が増えたものの大きな変化がなかった。また、提案手法により推定されたトポロジ図 7、図 8 を見ると、必ずしもすべての動線が推定されているわけではない。しかし、この大きな原因は

45 段階的推定モデルによるセンサネットワークのトポロジ推定

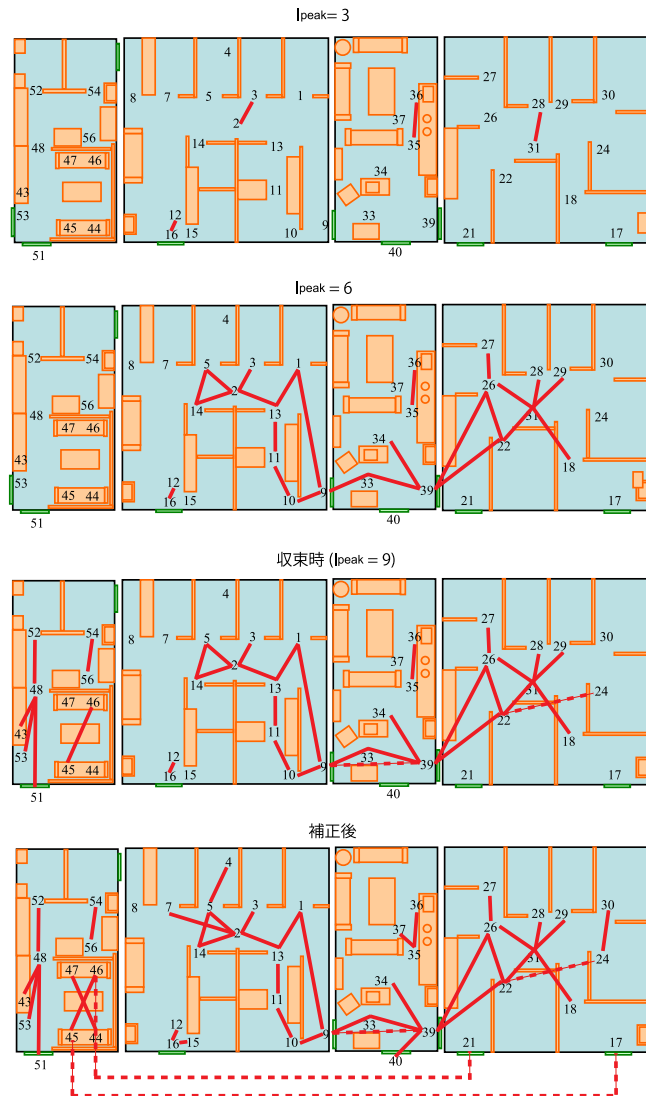


図 11 環境 (A) の段階的推定過程

Fig. 11 Progress of estimation (A) by learning.

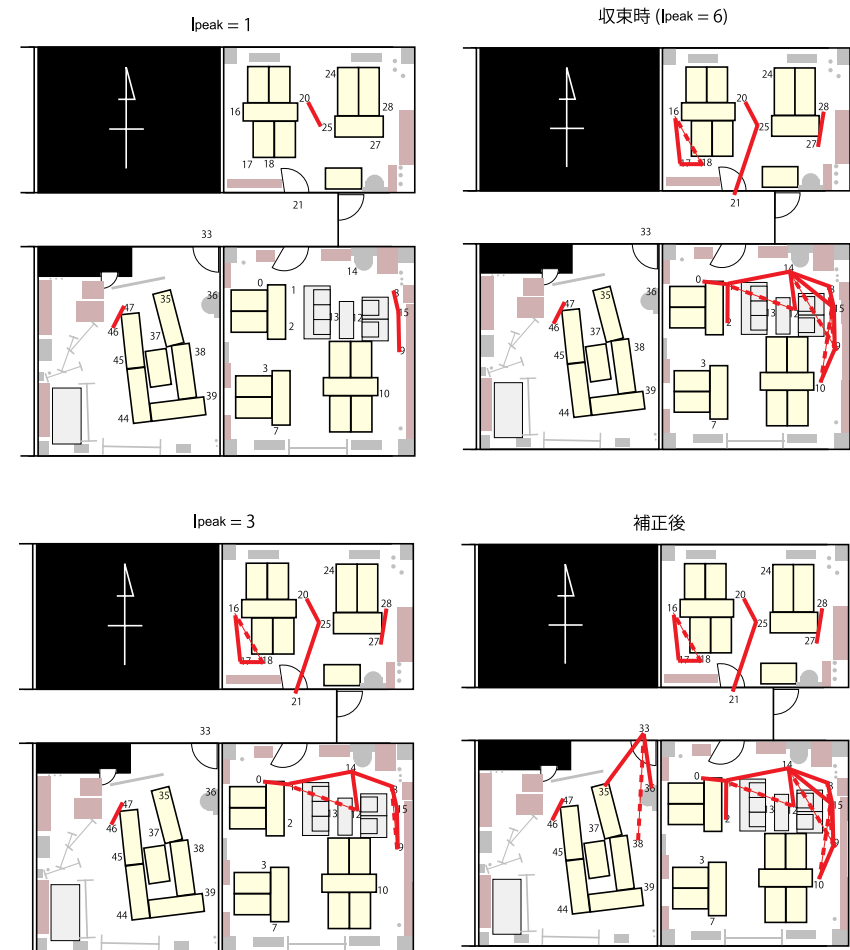


図 12 環境 (B) の段階的推定過程

Fig. 12 Progress of estimation (B) by learning.

表 3 段階的推定における精度の変化
Table 3 Progress of accuracy in our method.

環境	(A)				(B)			
	3	6	9 (収束時)	補正後	1	3	6 (収束時)	補正後
I_{peak}								
全推定数	4	24	32	42	4	14	19	29
隣接正解数	4	24	30	37	4	11	14	16
動線正解数	0	0	2	4	0	3	5	6
不正解数	0	0	0	1	0	0	0	7
隣接正解率	100%	100%	94%	88%	100%	79%	74%	55%
動線正解率	100%	100%	100%	98%	100%	100%	100%	76%

データにあると考えられる。実際推定できなかったエリアでは、人があまり通ることがなく、データに含まれるセンサの反応回数も極端に少ない。そのため、隣接関係や動線があると判断できる十分なデータが揃っていない。これは環境 (A) でもごく一部推定されなかった動線にもいえる。ただ、本来センサネットワークのトポロジや動線の情報は、人間の日常/非日常的行動の抽出や、人の動機や意図を先回りしたサービスに応用することを想定している。逆にこのような領域への侵入は、数の少ない稀なイベントとして、同定できる必要もある^{1),2)}。環境 (B) でも、十分な時間とともにデータが集まれば、隣接関係にはなるが頻度の少ない動線として抽出できると考えられる。

最後に 5.2.3 項で述べた推定結果の補正の効果について述べる。この補正は、環境中のすべてのセンサについて、少なくとも 1 つの動線を推定するために導入した。環境 A では一定の効果をあげたものの、提案手法が環境 (B) の推定で、比較手法より隣接正解率および動線正解率を落としたのは、この推定結果の補正を行ったためである。本来、この補正は暫定的なものであり十分なデータが集まれば不要になるものと考えられる。

これまで、正しく隣接関係や動線を推定することと、多くの動線を推定することはトレードオフの関係にあった。関連研究では、これらどちらか一方の優位性を持つ手法が提案されているが、本研究の提案手法はこのトレードオフをある程度解消する手法といえる。しかし、データが十分に得られていない環境では、無理に動線を推定することで精度を落とすという課題もある。この課題は、より多くの反応データを収集することで解決するが、得られたデータの量や内容から、自動的に閾値やパラメータを変化させ、動線が存在しないことを推定する手法も考えられる。

8. 結 論

本研究では、赤外線センサを用いたセンサネットワークのトポロジを、センサの時系列データのみから推定する手法を提案した。提案手法の特徴は、より確実性の高い隣接関係の推定結果を学習データとしながら、段階的に推定する隣接関係の数を増やしていく点にあり、実際のデータを用いて評価した結果、その有効性が確認された。また、正しく動線を推定することと、より多くの動線を推定することのトレードオフを解消し、推定の精度を保ちながら、広範囲に動線を推定した。

今後の課題としては、より多くの反応データを収集し、本提案手法の有効性を確認していくことや、動線が存在することの推定に加え、存在しないことの推定があげられる。

謝辞 本論文を改善するために有益なコメントをくださった査読者の方々に心から御礼申し上げます。なお本研究は科研費 (22300056) の助成を受けたものである。

参 考 文 献


- 1) Kurihara, S., Aoyagi, S., Takada, T., et al.: Agent-Based Human-Environment Interaction Framework for Ubiquitous Environments, *Proc. 2nd International Workshop on Networked Sensing Systems (INSS2005)*, pp.103–108 (2005).
- 2) 森 武俊, 野口博史, 佐藤知正: センサネットワークと生活行動, 電子情報通信学会誌, Vol.89, No.5, pp.430–435 (2006).
- 3) 吉田琢史, 小磯貴史, 服部可奈子, 豊嶋伊知郎, 今崎直樹: 顧客動線に基づく店舗内環境評価手法の提案, 電子情報通信学会技術研究報告, AI, Vol.104, No.727, pp.67–71 (2005).
- 4) 小磯貴史, 服部可奈子, 吉田琢史, 今崎直樹: 歩行者動線分析システムを用いた大型家電量販店での行動分析, 情報処理学会研究報告, UBI, Vol.2003, No.115, pp.61–66 (2003).
- 5) 藤森敬悟, 森山令子, 平井規郎, 石井 篤: センサーデータを活用した動線分析, 電子情報通信学会総合大会講演論文集, p.403 (2007).
- 6) Shrivastava, N., Madhow, R.M.U. and Suri, S.: Target tracking with binary proximity sensors: Fundamental limits, minimal descriptions, and algorithms, *Proc. 4th Int. Conf. Embedded Networked Sensor Systems (SenSys '06)*, New York, NY, USA, pp.251–264, ACM (2006).
- 7) Aslam, J., Butler, Z., Constantin, F., Crespi, V., Cybenko, G. and Rus, D.: Tracking a moving object with a binary sensor network, *Proc. 1st Int. Conf. on Embedded Networked Sensor Systems (SenSys '03)*, New York, NY, USA, pp.150–161, ACM (2003).

- 8) Hosokawa, T. and Kudo, M.: Person Tracking with Infrared Sensors, *Knowledge-Based Intelligent Information and Engineering Systems*, Khosla, R., Howlett, R.J. and Jain, L.C. (Eds.), LNCS, Vol.3684, pp.682–688, Springer (2005).
- 9) 本田誠一, 福井健一, 森山甲一, 栗原 聡, 沼尾正行: 赤外線センサーネットワークによる人物追跡, 第20回人工知能学会全国大会 (JSAI2006) (2006).
- 10) Honda, S., Fukui, K., Moriyama, K., Kurihara, S. and Numao, M.: Extracting Human Behaviors with Infrared Sensor Network, *4th Int. Conf. Networked Sensing Systems (INSS '07)*, pp.122–125 (2007).
- 11) Marinakis, D., Dudek, G. and Fleet, D.: Learning Sensor Network Topology through Monte Carlo Expectation Maximization, *Proc. 2005 IEEE Int. Conf. Robotics and Automation (ICRA 2005)*, pp.4581–4587 (2005).
- 12) Tamaki, H., Fukui, K., Moriyama, K., Kurihara, S. and Numao, M.: Automatic Acquisition of Sensor-Network Topology Based on Pheromone Communication Model, *4th Int. Conf. Networked Sensing Systems (INSS '07)*, p.292 (2007).
- 13) 高橋謙輔, 栗原 聡, 廣津登志夫, 菅原俊治: フェロモンモデルを用いたセンサネットワークトポロジーの自動推定, 電子情報通信学会論文誌 D, Vol.92, No.11, pp.1851–1860 (2009).
- 14) Takahashi, K., Kurihara, S., Hirotsu, T. and Sugawara, T.: Estimation of Sensor Network Topology Using Ant Colony Optimization, *Adaptive and Natural Computing Algorithms*, Kolehmainen, M., Toivanen, P. and Beliczynski, B. (Eds.), LNCS, Vol.5495, pp.263–272, Springer (2009).
- 15) 渡辺友太, 菅原俊治: センサネットワークにおける人物の動線推定, 電子情報通信学会総合大会, DS-2-5 (2010).
- 16) Watanabe, Y., Kurihara, S. and Sugawara, T.: Sensor Network Topology Estimation using Time-Series Data from infrared Human Presence Sensors, *Proc. 9th IEEE Conf. Sensors (SENSORS 2010)* (2010).

(平成 23 年 2 月 6 日受付)

(平成 23 年 4 月 7 日再受付)

(平成 23 年 5 月 2 日採録)



渡辺 友太

2010 年早稲田大学理工学部コンピュータネットワーク工学科卒業。現在、早稲田大学大学院基幹理工学研究科情報理工専攻菅原研究室修士課程在学中。



栗原 聡 (正会員)

1992 年慶應義塾大学大学院理工学研究科計算機科学専攻修士課程修了。同年日本電信電話株式会社入社。基礎研究所を経て未来ねっと研究所に所属。1998 年から慶應義塾大学大学院政策・メディア研究科専任講師 (有期)。現在、同大学環境情報学部非常勤講師。2004 年から大阪大学産業科学研究所知能システム科学研究部門准教授 (同大学大学院情報科学研究科情報数理学専攻准教授兼務)。マルチエージェント, ネットワーク科学等の研究に従事。著書『社会基盤としての情報通信』(共立出版, 共著)。翻訳『スモールワールド』(東京電機大学出版局, 共訳)。編集『Emergent Intelligence of Networked Agents』(Springer in Computational Intelligence Series) 等。博士 (工学)。人工知能学会, 日本ソフトウェア科学会, 電子情報通信学会, 人間情報学会, ACM, ESHIA 各会員。



廣津登志夫 (正会員)

1995 年慶應義塾大学大学院理工学研究科計算機科学専攻博士課程修了。同年日本電信電話株式会社入社。2004 年豊橋技術科学大学情報工学系助教授。2009 年より法政大学情報科学部コンピュータ科学科教授。分散システム, OS, ネットワーク, ユビキタスシステム等の研究に従事。博士 (工学)。日本ソフトウェア科学会, ACM, IEEE 各会員。



菅原 俊治 (正会員)

1982年早稲田大学大学院理工学研究科数学専攻修士課程修了。同年日本電信電話公社武蔵野電気通信研究所基礎研究部入所。1992～1993年マサチューセッツ大学アマースト校客員研究員。現在、早稲田大学理工学術院基幹理工学研究科情報理工学専攻教授。知識表現，学習，分散人工知能，マルチエージェントシステム，インターネット等の研究に従事。博士(工学)。日本ソフトウェア科学会，電子情報通信学会，人工知能学会，ISOC，IEEE，ACM各会員。
