

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ー推定

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ーを、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。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、より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. 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、それらを結びつ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つけ、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。

このような課題に対し、単純なセンサ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。3)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ることもできるが、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。また、4), 5)では、RFIDを用いず、代わりにトポロジーを既知とし、赤外線センサ等の単純なセンサから得られたデータとトポロジーを結び付け、動線の推定をしている。しかし、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・増設等により頻繁に変化するトポロジーを常に正しく維持することは容易ではない。センサの故障等により、データに不整合が発生することもある。また、センサネットワークのトポロジーや人物の移動経路にも制約を与えない環境で、動線やトポロジー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が^{6),7)}、少数のセンサ、カメラを使用している等、実験環境に制約がある。

他方我々もこれまで、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^{8),9)}。8)は、Ant Colony Optimization (ACO)を用いて精度の高いトポロジー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。9)は、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ー推定では、隣接関係を正しく推定でき

^{†1} 早稲田大学基幹理工学研究科

Department of Computer Science and Engineering, Waseda University, Japan

^{†2} 大阪大学産業科学研究所

The Institute of Scientific and Industrial Research, Osaka University, Japan

^{†3} 法政大学情報科学研究科

Graduate School of Computer and Information Sciences, Hosei University, Japan

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ー推定法を提案する。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、一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、その数を増やす手法である。これにより、高精度にトポロジーの推定が可能であることを示す。

2. 問題の定義

2.1 実験環境と時系列反応データ

本研究では、センサの前を物体が通過すると反応する赤外線センサを用いる。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等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など、人の移動によらない反応も発生する。

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。例えば、時刻 t においてセンサ $v_i, v_j \in V$ が反応した時、 $D_t = \{v_i, v_j\}$ 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。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。

2.2 トポロジー

センサネットワークにおけるトポロジーとは、環境におけるセンサの隣接関係の集合とする。本論文で対象とする隣接関係は、物理的に最も近い距離にあるセンサ間の関係ではなく、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る。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り、隣接関係は動線を構成する基本要素とも言える。本研究においてセンサ v_i から v_j への動線を (v_i, v_j) と表す。トポロジーは、このような動線の集合で表せ、例えば、図 1 の環境は、 $\{(a, c), (c, a), (c, d), (d, c)\}$ 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、トポロジーを表す隣接関係の集合を推定することである。




図 1 動線推定の例

Fig. 1 Example of estimation.

3. 隣接関係の推定

3.1 単純なトポロジー推定

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、複数人の同時移動やノイズなどにより、この手法では精度よく隣接関係を推定することができない。例えば図 1 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 $D_t = \{a\}, D_{t+1} = \{b, c\}, D_{t+2} = \{\}, D_{t+3} = \{d\}$ とする。このとき連続した反応のみから指定すると、 $(a, b), (a, c)$ 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。例えば図 1 のセンサ c, d は隣接関係にあるが、やや離れているため、動線として抽出できないこともある。

3.2 隣接関係にあるセンサの特徴

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かを図 2(a) に示す。このグラフは、実際の環境（環境については後で説明する）から収集したデータにもとづき、センサ 10 のあとにその他のセンサが反応した反応回数と反応の経過時間（反応間隔）を示している。たとえば、センサ 9 は 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 2(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 1 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 1 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 2(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

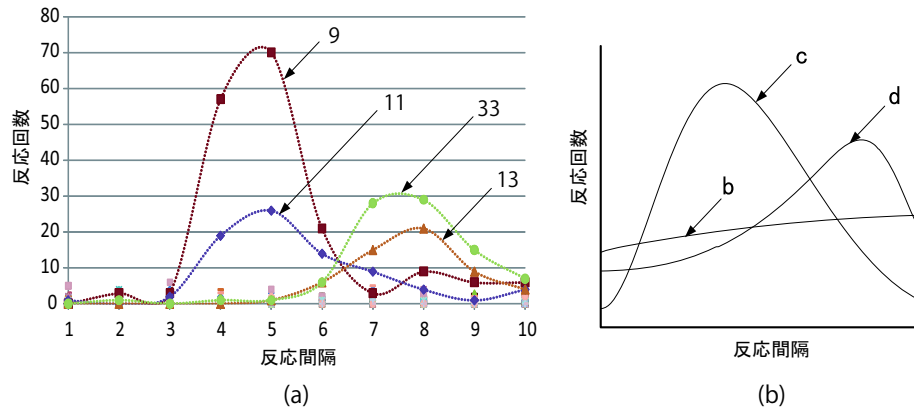


図2 センサ a 反応後の他のセンサの反応
Fig.2 Reacts after sensor a reacted.

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。

反応回数をもっと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。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。したがって、動線上にあるセンサの中でも、特に隣接関係にあるセンサは、反応回数のピークが現れた反応間隔が最も小さいセンサと推定できる。図 1 の環境では別途 c を基準とした反応間隔から d は a からより c からの方が近く、反応順序と合わせて、センサ a と隣接関係にあるのはセンサ c、その先に d があると推定される。

4. 提案手法

4.1 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、 $v_i \in D_t \wedge v_j \in D_{t+I} \wedge v_i, v_j \notin D_{t+1}, \dots, D_{t+I-1}$ 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。このとき、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。

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

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。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。

4.2 提案手法の詳細

定義した各関数、変数を用いて提案手法の詳細を述べる。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。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。

4.2.1 隣接関係の段階的推定

ピークの反応間隔が小さいほど、隣接関係にある可能性が高いと考えられる。そこでより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。ピークの反応間隔を I_{peak} とし、この I_{peak} を、1 から推定結果が収束するまで増加させ、次に述べる動線候補の取得と学習を繰り返す。推定された動線は、動線の集合 K に追加する。動線の候補の集合を K' とおく。

4.2.2 動線候補の取得と学習

$K = K' = \phi, I_{peak} = 1$ 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、得られた動線の候補について、下記の条件のいずれかに当てはまる場合、 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.

I_{peak} を増やしなが $I_{peak} = B$ までこの処理を繰り返す.

4.2.3 推定結果の補正

上記の繰り返しの結果, 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等, 十分信頼できるデータでない可能性がある. そこで, K に一度も現れなかったセンサ v_i に対し, $UpDown(v_j, v_i, Peak(v_j, v_i))$ 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.

5. 実験

5.1 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 3 に (A), 図 4 に (B) におけるセンサの配置図を実験結果と共に示す. また, 本実験では $B = 10$ を用いた. なお図 2(a) に例示した反応間隔と回数のグラフは環境 (A) におけるセンサ 10 を基準としたものである.

5.2 評価手法

推定した動線の精度は, 実際のトポロジーと比較して評価する. 実際のトポロジー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, 実際のトポロジーで隣接関係にある確率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ーを Top_{line} とし, 動線正解率を以下の式で定義する.




図 3 提案手法による環境 (A) の推定結果
Fig. 3 Result of estimation (A) by our method.

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

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, 8) が提案する Ant Colony Optimization (ACO) を用いた手法と, 9) が提案する手法を用いる.

5.3 実験結果

5.3.1 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 3, 図 4 に示す. 図 3, 図 4 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) について推定を行った 9), 環境 (B) について推定を行った 8) の隣接正解率, 動線正解率を表 1 に示す^{*1}. 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ーの図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

*1 比較対象とした 8) と 9) では, 環境 (A) については 9) が, 環境 (B) については 8) のほうが良好な結果を得られている.



図 4 提案手法による環境 (B) の推定結果
Fig. 4 Result of estimation (B) by our method.

すことなく推定可能な動線の数約 2 倍に増えている。9) 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能な動線数は約 40% ほど増えた。図 4 に示す通り、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たことが分かる。

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

環境	(A)		(B)	
	提案手法	9) の手法	提案手法	8) 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%

5.3.2 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、一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、4.2.2 節で示した 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全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わかる。一方環境 (B) では、精度の低下はほとんどない。

6. 考 察

前節に示す結果から、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することが分かる。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

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%

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)			
	I_{peak}	3	6	9(収束時) 補正後	1	3	6(収束時) 補正後	7
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%

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ー図 3, 図 4, 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、人があまり通る事がなく、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言える。ただ、本来センサネットワークのトポロジーや動線の情報は、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 4.2.3 節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。一方で、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。環境 (B) では補正前にそもそも推定可能な動線を推定しつくしてしまったため、補正による精度向上および推定数の向上を行うことはできなかった。

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、動線が存在しないということを推定する手法も考えられる。

7. 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ーを、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、存在しない事の推定があげられる。

参 考 文 献

- 1) Kurihara, S. et al.: Agent-Based Human-Environment Interaction Framework for Ubiquitous Environments, *Proceedings of 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) 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).
- 5) Shrivastava, N., Madhow, R. M.U. and Suri, S.: Target tracking with binary proximity sensors: fundamental limits, minimal descriptions, and algorithms, *Proc. of the 4th Int. Conf. on Embedded Networked Sensor Systems, SenSys '06*, New York, NY, USA, ACM, pp.251–264 (2006).
- 6) Marinakis, D., Dudek, G. and Fleet, D.: Learning Sensor Network Topology through Monte Carlo Expectation Maximization, *Proc. of the 2005 IEEE Int. Conf. on Robotics and Automation (ICRA 2005)*, pp.4581 – 4587 (2005).
- 7) Tamaki, H., Fukui, K., Moriyama, K., Kurihara, S. and Numao, M.: Automatic Acquisition of Sensor-Network Topology Based on Pheromone Communication Model, *Fourth Int. Conf. on Networked Sensing Systems (INSS '07)*, p.292 (2007).
- 8) 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).
- 9) Watanabe, Y., Kurihara, S. and Sugawara, T.: Sensor Network Topology Estimation using Time-Series Data from infrared Human Presence Sensors, *Proc. of the 9th IEEE Conf. on Sensors (SENSORS 2010)* (2010).