

時系列センサーデータを使用したセンサー間の隣接関係の推定法の提案

高橋 謙輔† 菅原 俊治†

† 早稲田大学理工学部

E-mail: †k.takahashi@isl.cs.waseda.ac.jp

あらまし 本論文では、センサーの位置情報についての事前知識を必要とせず、センサーから得られた発火情報のみを用いたセンサー間の隣接関係の推定法を提案する。提案手法は Ant Colony Optimization を基本アルゴリズムとし、さらに、入力センサーデータの信頼性を推定することによってより正確な隣接関係を推定する。最後に、実際のセンサーデータを使用して、提案手法を評価する。

キーワード センサーネットワーク、トポロジー

Estimating Sensor Network Topology from Time-Series Sensor Data

Kensuke TAKAHASHI† and Toshiharu SUGAWARA†

† Faculty of Science and Engineering, Waseda University

E-mail: †k.takahashi@isl.cs.waseda.ac.jp

Abstract We will propose the method for estimating sensor network topology only from time-series sensor data, without prior knowledge about location information of sensors. The proposed method is based on the ant colony optimization but is further improved to construct more accurate topology by estimating the reliability of acquired sensor data. Finally, we will evaluate our method using the actual sensor data.

Key words Sensor Network, Topology

1. ま え が き

近年、情報通信端末の小型化、低コスト化が飛躍的に進みユビキタス社会への実現が着実に進んでいる。また、それに伴いセンサーネットワークやユビキタスコンピューティングの分野で様々なアプリケーションが提案されている。このユビキタス社会では、実世界と有機的に結ばれた context-awareness なサービスを提供することを想定している。実世界の対象やイベントに起因するデータは空間の至る所に存在し、その量も多い。このような情報を収集するために、大量のセンサーが配置され、それらが LAN あるいは無線通信を介して情報を提供できることを想定している (例えば [1])。

しかし、目的に合わせて個々のセンサーを手動で設定することに対する労力は、センサーネットワークの規模に比例して大きくなる。また、センサーの新設・増設や、配置変更、故障・破損などでネットワーク構造が変化する度に設定を変更することは大変手間であり、設定ミスも起こり得る。また、災害などで既存のネットワークが機能していない状況では、手動で設定すること自身が困難になる。この問題を解決するためには、センサー自身が設定を変更するような自動設定が必要である。

本研究では、このような自動設定の中でも、センサー間の隣接関係の推定に着目する。センサー間の隣接関係は、実世界の位置関係を示したものであり、センサーデータあるいはそれらの時系列面からの関連性や、それらを利用した行動の推定・サービス生成などを旨とした各種ユビキタスアプリケーションには必須の情報である。しかし、前述のように、これらの関係をすべてシステムに手動で設定する労力は大きい。

センサーあるいは広くノードの隣接関係、あるいはそれらのトポロジーの推定に関する研究は、例えば、[7],[8] などがある。これらは、無線の強度などから隣接関係を推定するもので、アドホックネットワークや無線機能を備えたセンサーへの適用を想定している。しかし、無線強度が必ずしも隣接関係を表しているわけではなく (たとえば壁で仕切られているなど)、また、すべてのセンサーが無線機能を備えているとも限らない。[4] では、無線などを前提とせず、センサーデータの時系列の関係から隣接関係を推定するアルゴリズムを提案している。[6] ではこれに加え、移動ロボットを介して、より精度を上げている。しかし、これらは環境中の人数が一定であること、行動パターンが同じ (例えば全ての人は同じ速度で歩くなど) などを前提としており、応用を考えるとこの前提は必ずしも合致しない。こ




図1 センサーネットワーク構造の表し方
Fig.1 Expression of sensor network structure.

れに対し[2]では、Ant Colony Optimization (ACO) [3]を適用し、タイムスタンプ付きのセンサー発火データのみからの隣接関係の抽出に成功しており、ユビキタス社会のアプリケーションの観点からはより自然な状況での提案法と言える。しかし、実用性を考えるとその精度は十分なものではなく、より効率的な推定法が必要である。

そこで、本研究では(1)環境中の人数などの前提条件を考えずに、(2)センサーから得られた時系列の発火データのみで、(3)短期間の使用データで、より精度の高い隣接関係推定のアルゴリズムの提案をする。

2. 問題の定義

2.1 センサーネットワークの表現方法

本研究では、センサー間のネットワーク構造を有向グラフ $G = (V, E)$ で表現する。ここで、各ノード $v_i \in V$ は実環境の各センサーに1対1対応している。また、 $e_{i,j} \in E$ は v_i から v_j に向かう隣接関係を表す。例としてセンサー数が3の場合のセンサーネットワークに対応したグラフを図1に示す。

ACOおよび提案アルゴリズムでは、解析前には全ノード間にエッジを張った完全グラフを用意する。そして、各エッジ $e_{i,j}$ 上で後述する各種フェロモン ($+\omega, -\omega, \epsilon, \tau$) の付加・蒸発を行わせ隣接関係を推定する。

エッジ $e_{i,j}$ が隣接関係ならば $a_{i,j} = 1$ 、非隣接関係ならば $a_{i,j} = 0$ とした行列 $A = \{a_{i,j}\}$ で隣接関係を表す。

2.2 入力データ

センサー $v_n (n \in V)$ からの入力データは、時系列の発火データなので $O^n = \{s_1, s_2, \dots, s_m, \dots\}$ と表す。ここで、 s_m はセンサー n が m 番目に発火した時刻である。これから、図2のように、入力データをタイムスパン T ごとに区切ったデータセット O_i^n を作成し、これを用いて解析を行う。

3. 発火データの特徴

本研究では、隣接関係の推定にあたって発火データの特徴として以下の仮説を立てた。

- (1) 隣接関係にあるセンサー間の発火時間間隔は短い。
- (2) 発火頻度の高いタイムスパンの発火データは隣接関係確率が低い。

仮説(1)は、隣接関係にあるセンサー同士は、どちらかが発

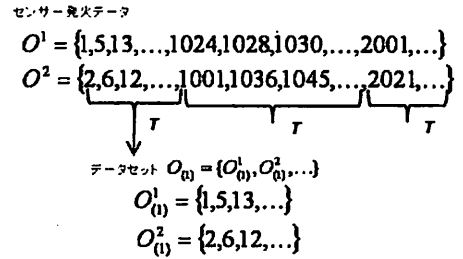


図2 タイムスパン $T = 1000$ におけるデータセットの作成
Fig.2 Generated data set when $T=1000$.

火すると比較的短い時間内にもう一方も発火することを想定している。例えば図5において、 $t = t_1$ にセンサー S_1 、 $t = t_2$ にセンサー S_2 、 $t = t_{10}$ にセンサー S_{10} が発火したとすると、 $(t_2 - t_1) < (t_{10} - t_1)$ になると想定できる。

仮説(2)は、環境中で行動している人数が多いほど、センサーの発火データから隣接関係を得られる確率は低くなることを想定している。しかし、本研究ではセンサーの発火データのみを使用し、環境中の人数を仮定していない。そこで、タイムスパン T における発火頻度が高ければ、その T の間に環境中で行動していた人数は多いと推定し、その時の発火データの隣接関係確率は低くなると想定する。以下でこの二つの仮説の妥当性について検証する。

3.1 発火時間間隔と隣接関係確率

データセット O_i から発火時間間隔 c の時の発火時間間隔度数分布 f^{dc} および隣接関係度数分布 nd^c を求める。ノード v_i, v_j におけるデータセットをそれぞれ $O_i^i = \{s_1^i, s_2^i, s_3^i, \dots\}$ 、 $O_i^j = \{s_1^j, s_2^j, s_3^j, \dots\}$ としたとき、 f^{dc}, nd^c を以下のように求める。

v_i, v_j に対し

$$D_c^{i,j}(t) = \{ (s_h^i, s_g^j) | s_h^i - s_g^j = c > 0, s_h^i \in O_i^i, s_g^j \in O_i^j \} \quad (1)$$

としたとき、

$$f^{dc} = \sum_{i,j} |D_c^{i,j}(t)| \quad (2)$$

$$E_c^{i,j}(t) = \begin{cases} \{ (s_h^i, s_g^j) | s_h^i - s_g^j = c > 0, s_h^i \in O_i^i, s_g^j \in O_i^j \} \\ \text{if } v_i, v_j \text{ が隣接関係にある} \\ \emptyset: v_i, v_j \text{ が隣接関係にない} \end{cases} \quad (3)$$

としたとき、

$$nd^c = \sum_{i,j} |E_c^{i,j}(t)| \quad (4)$$

と定義する。この時各発火時間間隔における隣接関係確率を、

$$\text{隣接関係確率 (\%)} = 100 \times \frac{nd^c}{f^{dc}} \quad (5)$$

とする。実際のセンサーデータとセンサー配置のレイアウト図をもとに求めた結果を図3に示す。図3は両対数グラフであり、横軸に発火時間間隔、縦軸に隣接関係確率をとった。図3より、発火時間間隔が長くなると隣接関係確率はほぼべき乗則で減少すると推定できる。また、両者の間には強い負の相関があり、相関係数は-0.91であった。




図3 発火時間間隔と隣接関係確率の関係(対数)

Fig. 3 Relationship between ignition time intervals and adjacency probabilities(double logarithm).




図4 発火頻度と隣接関係確率の関係(対数)

Fig. 4 Relationship between ignition frequencies and adjacency probabilities(double logarithm).

3.2 発火頻度と隣接関係確率

発火頻度と隣接関係確率を以下のように定義する。

$$\text{発火頻度 (\%)} = 100 \times \frac{\sum_i |O_i|}{T \times N} \quad (6)$$

$$\text{隣接関係確率 (\%)} = 100 \times \frac{\sum_i \gamma nd^c}{\sum_i \gamma fd^c} \quad (7)$$

なお、環境中のセンサー数を N とし、 $\gamma = 30$ とした。実際のセンサーデータとセンサー配置のレイアウト図をもとに求めた発火頻度と隣接関係確率を図4に表す。この図より、発火頻度が増えると、精度はほぼべき乗則で減少すると推定できる。また、この時の相関係数は-0.72であり、やはり強い負の相関関係があると推定できる。

4. 提案アルゴリズムの概要

[2]で提案された手法は、センサー i とセンサー j 間の標準移動時間 $smt_{i,j}$ を最初に推定し、その $smt_{i,j}$ に近い時間間隔で発火しているセンサー間を隣接関係にある可能性が高いと判断している。例えば、図5の経路で $t = t_1$ にセンサー S_1 が発火し、 $t = t_2$ にセンサー S_2 が発火したときに、 $|smt_{1,2} - (t_2 - t_1)|$ が小さければ隣接尤度を上げ、大きければ隣接尤度は上げない。しかし、この手法では $t = t_{10}$ にセンサー S_{10} が発火したときに、 $|smt_{1,10} - (t_{10} - t_1)|$ が小さければ隣接尤度が上がってしまう。しかし、 $smt_{1,10}$ は標準移動時間であるので、 $smt_{1,10} \approx (t_{10} - t_1)$ になる可能性が高いと推測できる。

そこで、提案手法では、第3.1節で検証したように、発火




図5 想定される経路

Fig. 5 An route example.

時間間隔が短ければ隣接関係にある可能性が高いという発火データの特徴を利用する。まず、 $\alpha - 1 = \gamma - \beta$ として、センサー v_i とセンサー v_j の発火時間間隔 c が $1 \leq c \leq \alpha$ の場合と $\beta \leq c \leq \gamma$ の場合の二つに分ける。そして、 $1 \leq c \leq \alpha$ の場合は隣接関係にある可能性が高いので、隣接尤度を $+\omega_{i,j} = ac^{-b}$ とおく。一方、 $\beta \leq c \leq \gamma$ の場合は隣接関係にない可能性が高いので、非隣接尤度を $-\omega_{i,j} = -a(\gamma - c + 1)^{-b}$ とおく。このように、各エッジが隣接関係であるのか、非隣接関係であるのかをデータセットごとに解析し、発火情報が得られる度に $+\omega_{i,j}$ と $-\omega_{i,j}$ を計算し、それを蓄積していくことで隣接関係を推定する。

以下の議論で必要な用語を定義する。

- エッジフェロモン $+\omega, -\omega$

各データセット O_i における各エッジの隣接尤度および非隣接尤度を表す。 $+\omega > 0, -\omega < 0$

- エージェントフェロモン ϵ

エージェントが移動経路の評価値としてエッジ上に排出することで生成されるもの。エージェントには、隣接尤度をもとに移動するポジティブエージェントと非隣接尤度をもとに移動するネガティブエージェントがあり、両者が排出したものの合計である。

- フェロモン分布 τ

エージェントフェロモンの蓄積であり、各エッジの隣接尤度を表す。各データセットの解析毎に更新される。このフェロモン分布を用いて隣接関係を推定する。

- 平均発火時間 $+m_{i,j}, -m_{i,j}$

センサー v_i, v_j 間の発火時間間隔の平均値である。発火時間間隔 c が $1 \leq c \leq \alpha$ の時の平均発火時間を $+m_{i,j}$ とし、 $\beta \leq c \leq \gamma$ の時の平均発火時間を $-m_{i,j}$ とする。

5. 提案アルゴリズム

解析を各データセット O_i ごとに行い、一回の解析毎にフェロモン分布 τ を更新する。データセット解析終了時には隣接関係の判定が行われ、各エージェントの再配置およびエッジフェロモン、エージェントフェロモンの破壊が行われる。次のデータセットがある場合には、更新されたフェロモン分布 τ を用いて新しく解析を行う。これを繰り返すことによって隣接関係推定の精度を高める。なお、第4章で述べた、 α, β, γ についてはそれぞれ、 $\alpha = 7, \beta = 24, \gamma = 30$ とした。

5.1 発火時間間隔度数分布の作成

最初に、データセット O_i から発火時間間隔の度数分布 $d_{i,j}(t)$

を求める。ここで、 $d_{i,j}^c(t)$ はセンサー v_i, v_j 間で発火間隔が c ($1 \leq c \leq \gamma$) となるデータ数を表す。具体的にはノード v_i, v_j におけるデータセットをそれぞれ $O_i^c = \{s_1^c, s_2^c, s_3^c, \dots\}$, $O_j^c = \{s_1^c, s_2^c, s_3^c, \dots\}$ としたとき、下記の方法でタイムスパン T で区切られたデータセット O_i から発火時間間隔度数分布を求め、なお、 $d_{i,j}^c(t)$ の初期値は 0 とする。

$$d_{i,j}^c(t) = \sum_{i,j} D_{i,j}^{c,j}(t) \quad (8)$$

ここで、 $D_{i,j}^{c,j}(t)$ は式 (1) のものである。

5.2 平均発火時間の更新

平均発火時間 $+m_{i,j}(t)$, $-m_{i,j}(t)$ を $d_{i,j}^c(t)$ より以下の式で更新する。

$$+m_{i,j}(t) = \frac{\sum_{c=1}^{\alpha} (d_{i,j}^c(t) \times c)}{\sum_{c=1}^{\alpha} d_{i,j}^c(t)} \quad (9)$$

$$-m_{i,j}(t) = \frac{\sum_{c=\beta}^{\gamma} (d_{i,j}^c(t) \times c)}{\sum_{c=\beta}^{\gamma} d_{i,j}^c(t)} \quad (10)$$

この平均発火時間は、後述するエージェントの移動に用いる。

5.3 エッジフェロモン $+\omega, -\omega$ の作成

発火時間間隔度数分布 $d_{i,j}^c(t)$ および第 3. 章で述べた発火データの特徴を用いて隣接尤度と非隣接尤度を表す $+\omega, -\omega$ を作成する。

最初に、第 3.1 節で述べた、発火時間間隔と隣接関係確率はべき乗則と推定できることを用いて、

$$\Delta_+ \omega_{i,j}^c(t) = d_{i,j}^c(t) a_i c^{-b_i} \quad (1 \leq c \leq \alpha) \quad (11)$$

$$+\omega_{i,j}(t) = \sum_{c=1}^{\alpha} \Delta_+ \omega_{i,j}^c(t) \quad (12)$$

$$\Delta_- \omega_{i,j}^c(t) = -d_{i,j}^c(t) a_i (\gamma - c + 1)^{-b_i} \quad (\beta \leq c \leq \gamma) \quad (13)$$

$$-\omega_{i,j}(t) = \sum_{c=\beta}^{\gamma} \Delta_- \omega_{i,j}^c(t) \quad (14)$$

とする。次に、第 3.2 節で述べた、発火頻度 $freq(t)$ と隣接関係確率はべき乗則と推定できることを用いて、隣接尤度 $+\omega_{i,j}(t)$ に重み付けを行う。

$$weight(t) = a_f \times freq(t)^{-b_f} \quad (15)$$

$$+\omega_{i,j}(t) = weight(t) \times +\omega_{i,j}(t) \quad (16)$$

このように、発火データの特徴に基づいて重み付けすることによって、推定精度を試みる。なお、本研究では $a_i = 0.5, b_i = 0.4, a_f = 0.3, b_f = 0.3$ とした。

5.4 エージェントの移動

エージェントは、隣接尤度に従って移動するポジティブエージェントと、非隣接尤度に従って移動するネガティブエージェントの二種類存在する。各ノードには各エージェントが N ($N = \text{ノード数}$) 匹ずつ割り当てられる。

エージェントの移動方法を述べる前に、ヒューリスティック値 $+\eta(t), -\eta(t)$ を以下の式で定める。

$$+\eta_{i,j}(t) = \frac{\nu}{+m_{i,j}(t)} \quad (17)$$

$$-\eta_{i,j}(t) = \frac{\nu}{\gamma - m_{i,j}(t) + 1} \quad (18)$$

ここで、 ν はヒューリスティック値が 1 未満になるのを防ぐための定数であり、本研究では $\nu = 10$ とした。 $+\eta_{i,j}$ は平均発火時間の逆数であり、 $+m_{i,j}(t)$ が小さい、すなわち、平均発火時間間隔が短いほど大きな値をとる。一方、 $-\eta_{i,j}$ は平均発火時間間隔が長いほど大きな値をとる。これは、隣接関係にあるセンサー同士は近い場所に存在し、隣接関係にないセンサー同士は遠い場所に存在する可能性が高いことを利用している。

5.4.1 ポジティブエージェントの移動

各ノードに割り当てられたポジティブエージェントの移動は、次の二種類のうち 1 つを選択する。

(1) 現在のフェロモン分布 $\tau(t)$ およびヒューリスティック値 $+\eta(t)$ をもとに移動する方法。

(2) $\tau(t)$ には関係なく $+\eta(t)$ のみをもとに移動する方法。方法 1 を選択したエージェントは、過去の解析の中で隣接尤度が高いとみなされたエッジを優先的に移動する。一方、方法 2 を選択したエージェントは過去の解析に関係なく移動する。これは、過去の解析だけを優先すると、局所解に陥る可能性があるため、それを防ぐためである。

エージェントがどちらの移動方法を選択するかは、次の確率 r ($0 \leq r \leq 1$) に従ってランダムに決定する。

(1) 方法 1 を選択する確率: $q_1 = r$

(2) 方法 2 を選択する確率: $q_2 = 1 - r$

本研究では $r = 0.7$ とした。

これらのことより、ノード v_i にいるポジティブエージェント k がノード v_j に移動する確率 $+p_{i,j}^k(t)$ を以下のように定める。

$$+p_{i,j}^k(t) = \frac{[\tau_{i,j}(t)] + [\eta_{i,j}(t)]^\lambda}{\sum_i \sum_{j,j \neq i} [\tau_{i,j}(t)] + [\eta_{i,j}(t)]^\lambda} \quad (19)$$

$$+p_{i,j}^k(t) = \frac{[+\eta_{i,j}(t)]^\lambda}{\sum_i \sum_{j,j \neq i} [+\eta_{i,j}(t)]^\lambda} \quad (20)$$

$$+p_{i,j}^k(t) = q_1 \cdot +p_{i,j}^k(t) + q_2 \cdot +p_{i,j}^k(t) \quad (21)$$

この計算により決定した確率に従って各ポジティブエージェントはランダムに移動する。ここで、 λ は $+\eta_{i,j}(t)$ の重みであり、各ポジティブエージェントにおけるヒューリスティック値の優先度を決定する。本研究では、 $\lambda = 1$ とした。

5.4.2 ネガティブエージェントの移動

ネガティブエージェントは上記で述べた移動方法のうち 2 番目の方法のみで移動する。よって、ノード v_i にいるネガティブエージェント l がノード v_j に移動する確率 $-p_{i,j}^l$ を以下のように定める。

$$-p_{i,j}^l(t) = \frac{[-\eta_{i,j}(t)]^\lambda}{\sum_i \sum_{j,j \neq i} [-\eta_{i,j}(t)]^\lambda} \quad (22)$$

5.5 エージェントフェロモン $\epsilon(t)$ の付加

各エージェントは移動時に、その経路の評価値としてエージェントフェロモンを排出する。 $e_{i,j}$ を通過したポジティブエージェント k が排出するエージェントフェロモン $\Delta_+ \epsilon_{i,j}^k(t)$ 、ネガティブエージェント l が排出するエージェントフェロモン $\Delta_- \epsilon_{i,j}^l(t)$ はエッジフェロモンの値を用いることで、データセット O_i の情報を反映させる。 $\Delta_+ \epsilon_{i,j}^k(t), \Delta_- \epsilon_{i,j}^l(t)$ は以下ようになる。

$$\Delta_+ \epsilon_{i,j}^k(t) = +\omega_{i,j}(t) \quad (23)$$

$$\Delta_- \epsilon_{i,j}^l(t) = -\omega_{i,j}(t) \quad (24)$$

よって、 $e_{i,j}$ を移動したポジティブエージェント数を x 、ネガティブエージェント数を y とした時のエージェントフェロモン $\epsilon_{i,j}(t)$ を以下の式で求める。

$$+\epsilon_{i,j}(t) = \sum_{k=1}^x \Delta_+ \epsilon_{i,j}^k(t) \quad (25)$$

$$-\epsilon_{i,j}(t) = \sum_{l=1}^y \Delta_- \epsilon_{i,j}^l(t) \quad (26)$$

$$\epsilon_{i,j}(t) = +\epsilon_{i,j}(t) + -\epsilon_{i,j}(t) \quad (27)$$

隣接尤度の高いエッジのエージェントフェロモンの値は正になり、非隣接尤度の高いエッジのエージェントフェロモンの値は負になる。

5.6 フェロモン分布の更新と蒸発

フェロモン分布 $\tau(t)$ はエッジフェロモン $\epsilon(t)$ を用いて更新される。ここで、フェロモン分布の極端な偏りを防ぐために Stützle らによって提案された MMAS(Max-Min Ant System)[5] の手法を用いて、 $\tau_{min} \leq \tau_{i,j}(t) \leq \tau_{max}$ となるように、 $\tau_{i,j}(t)$ の値を制限する。なお、本研究では $\tau_{max} = 1000$, $\tau_{min} = 0$ とし、フェロモン分布の初期値 $\tau(0) = \tau_{min}$ とした。

$$\tau_{i,j}(t) = \begin{cases} \tau_{max} & \text{if } \tau_{i,j}(t) + \epsilon_{i,j}(t) > \tau_{max} \\ \tau_{min} & \text{if } \tau_{i,j}(t) + \epsilon_{i,j}(t) < \tau_{min} \\ \tau_{i,j}(t) + \epsilon_{i,j}(t) & \text{otherwise} \end{cases} \quad (28)$$

このようにフェロモン分布を更新した後に、フェロモン分布は蒸発率 ρ で減少する。

$$\tau_{i,j}(t) \leftarrow (1 - \rho)\tau_{i,j}(t) \quad (29)$$

この蒸発により、古い情報は少しずつ弱くなり、新しい情報が強く反映されるようになる。 ρ が大きいほど新しい情報の重みが大きくなる。なお、本研究では $\rho = 0.01$ とした。

5.7 隣接関係の推定

フェロモン分布 $\tau(t)$ は隣接尤度を表しており、この $\tau(t)$ の値によって隣接関係にあるかどうかを判断する。フェロモン分布の平均 $\mu(t)$ 、分散 $\sigma^2(t)$ から正規分布確率密度関数を作成し、その確率が $prob$ 以上のものを隣接関係にあると判断する。なお、 N はノード数とする。

$$\mu(t) = \frac{2 \sum_{i=1}^N \sum_{j=i+1}^N (\tau_{i,j}(t) + \tau_{j,i}(t))}{N^2 - N} \quad (30)$$

$$\sigma^2(t) = \frac{2}{N^2 - N} \sum_{i=1}^N \sum_{j=i+1}^N ((\tau_{i,j}(t) + \tau_{j,i}(t)) - \mu(t))^2 \quad (31)$$

$$f(x) = \frac{1}{2} \left(1 + \operatorname{erf} \left(\frac{x - \mu(t)}{\sqrt{2\sigma^2(t)}} \right) \right) \quad (32)$$

として、分布関数を求め、全ての $e_{i,j}$ について、以下の条件式で判定し、第 2.1 節で述べたように行列 $A = \{a_{i,j}\}$ を用いて隣接関係を表す。なお、本研究では $prob = 0.6$ とした。

$$a_{i,j} = \begin{cases} 0 & \text{if } f(\tau_{i,j} + \tau_{j,i}) < prob \\ 1 & \text{otherwise} \end{cases} \quad (33)$$

6. 実験

6.1 実験データ

今回の解析実験の使用データとして、大阪大学産業科学研究所の沼尾/栗原研究室に取り付けられたセンサーネットワークにおける 2006/7/7~2006/7/17 の 10 日分のセンサー発火情報を頂いて使用した。

このセンサーネットワークには赤外線センサー (SHARP GP2Y0A02YK) が用いられており、各赤外線センサーは自身の発する赤外線レーザーの反射強度を読み取ることで人物の検知を行う。

各センサーノードからの情報は、センサーサーバーを経由してデータサーバーに送信される。データサーバーは、各センサーサーバーから送られてくるデータを一定間隔で読み取り、読み取ったデータにタイムスタンプを付加し保存する。これにより、各センサーノードからの情報がデータサーバー上で同期をとられながら蓄積される。今回は 4 つの部屋にわたって設置されている 56 個のセンサーノードの発火情報を解析に用いた。図 6 にセンサーネットワークの配置図を、図 7 に正解となる Topology Map を示す。

6.2 実験結果

実験によって得られたセンサーネットワークの隣接関係を、第 2.1 節で述べたように隣接行列 $A = \{a_{i,j}\}$ で表わし、正解の隣接関係行列を $A' = \{a'_{i,j}\}$ で表すと、実験によって得られた隣接関係の精度を以下の式によって求める。

$$\text{隣接精度} = 100 \times \frac{|\{a_{i,j} \in A | a_{i,j} = a'_{i,j} = 1\}|}{|\{a'_{i,j} \in A' | a'_{i,j} = 1\}|} \quad (34)$$

$$\text{非隣接精度} = 100 \times \frac{|\{a_{i,j} \in A | a_{i,j} = a'_{i,j} = 0\}|}{|\{a'_{i,j} \in A' | a'_{i,j} = 0\}|} \quad (35)$$

$$\text{精度} (\%) = \psi \times \text{隣接精度} + (1 - \psi) \times \text{非隣接精度} \quad (36)$$

ここで、 $\psi (0 < \psi < 1)$ は精度判定において隣接精度と、非隣接精度のどちらを優先させるかの重みである。すなわち、実験結果としてほぼ全てのノードが隣接関係にあるという結果や、非隣接関係にあるという結果が出た時の精度を抑えるためのものである。本研究では $\psi = 0.2$ とした。第 6.1 節でのデータを用いて、提案アルゴリズム実験 1 及び、比較用アルゴリズム実験 2、実験 3、実験 4 での解析を行った。ここで、実験 2 は [2] で提案されているアルゴリズムであり、実験 3 は提案アルゴリズムから第 5.3 節で述べた $weight(t)$ を、実験 4 はネガティブフェロモンを省略したものである。図 8 に各手法で解析した場合の精度の時系列変化を示す。また、図 9 に実験 1 での解析終了時の、図 10 に実験 2 の手法での解析終了時の Topology Map を示す。

図 8 より、提案手法が他の比較アルゴリズムよりも解析終了時の精度が高いことがわかる。(実験 1...90.93%, 実験 2...74.97%, 実験 3...85.48%, 実験 4...88.81%) 特に既存研究である実験 2 と比べて精度は 15% 向上し、精度の大幅な向上が




図6 センサー配置図

Fig. 6 Locations of sensors.




図7 センサーネットワークの正解 Topology Map

Fig. 7 Correct topological map of sensor network.




図8 精度の時系列変化

Fig. 8 Variation of precision over time.




図9 実験 1

Fig. 9 Topological map generated by experiment 1.

実現できた。更に使用したデータは 10 日分であり、この点でも既存研究の 30 日間分と比べて向上が実現できたと言える。

7. 結 論

本研究では、センサーネットワークにおけるセンサー間の隣接関係の推定法として、時系列センサーデータを用いた手法を提案した。

提案手法の特徴として、(1) 隣接関係のみではなく非隣接関係にも注目し、(2) 基本アルゴリズムとして ACO を用いたことが挙げられる。非隣接関係にも注目したことにより、隣接関係のみを注目したときより精度がよくなった。また、基本アルゴ




図10 実験 2

Fig. 10 Topological map generated by experiment 2.

リズムとして ACO を使用したことにより、(1) 解析時に過去の情報をもとにした解析を行うことができ、(2) 一定の割合でランダムな探索を行うことにより局所解に陥ることを防ぐことができた。(3) フェロモン分布を一定の割合で蒸発させることで、古い情報からの反映を弱くすることができた。その結果、提案アルゴリズムを使用した検証実験では 90.93% という精度で時系列センサーデータからセンサー間の隣接関係を推定できることが確かめられた。これにより、第 1 章で述べた、(1) 環境中の人数などの前提条件を考えずに、(2) センサーから得られた時系列の発火データのみで、(3) 短期間の使用データで、より精度の高い隣接関係推定のアルゴリズムが提案できたと考えられる。また、既存研究と比べて精度も 15% 向上した。更に、使用したデータは 10 日分と、比較的少ない日数のものでも隣接関係を推定することができた。

今後の目標としては、複数の環境におけるデータを取得し、その場合でもこの精度が保てるかどうかを検証したい。

謝辞 本研究は総務省戦略的情報通信研究開発制度 (SCOPE) の助成を受けている。本研究にあたりデータを提出いただいた大阪大学栗原准教授に感謝いたします。

文 献

- [1] "Cornell Database Group," <http://www.cs.cornell.edu/database/cougar/index.php>
- [2] 玉置洋ほか, "Ant Colony Optimization によるセンサー隣接関係抽出法の提案," 知識ベースシステム研究会 Vol.77, pp.21 - 28 (2007-3)
- [3] Marco Dorigo et al, "The Ant Colony Optimization Meta-heuristic," *New ideas in optimization*, McGraw-Hill Ltd., UK, pp. 11 - 32 (1999)
- [4] Dimitri Marinakis et al, "Topological Mapping through Distributed, Passive Sensors," *IJCAI-07* (2007-1)
- [5] T. Stützle et al, "The MAX - MIN ant system and local search for the traveling salesman problem," *Proceedings of IEEE Int. Conf. on Evolutionary Computation and Evolutionary Programming Conference*, pp. 309-314 (1997)
- [6] D. Marinakis et al, "Hybrid Inference for Sensor Network Localization using a Mobile Robot," *AAAI 2007*, pp. 1089-1094 (2007-7)
- [7] A. Savvides et al, "Dynamic fine-grained localization in ad-hoc networks of sensors," *Proc. ACM/IEEE MOBIKOM 2001*, pp. 166-179 (2001-4)
- [8] Jean-Phillippe Montillet et al, "Algorithm for Nodes Localization in Wireless Ad-Hoc Networks Based on Cost Function," *IJWWAN 2005*