

時空間分散された微小センシング情報に基づく状態推定技術

State Estimation Based on Small Sensing Data Collected over Different Time and Space



塩田 茂雄 (Shigeo SHIODA, Dr. Eng.)

千葉大学大学院 工学研究科 都市環境システムコース
教授

(Professor, Department of Urban Environment & Systems,
Graduate School of Engineering, Chiba University)

電子情報通信学会 日本オペレーションズリサーチ学会 米国電気電子学
会 (IEEE) 米国計算機学会 (ACM)

受賞：電子情報通信学会 ネットワークシステム研究賞 (2003 年度) 情
報ネットワーク研究賞 (2004 年度) 電子情報通信学会通信ソサエティ活
動功労賞 (2007 年度, 2013 年度) IEEE MASS Best Poster Award (2013
年度)

著書：インターネットプロトコル, オーム社, 2005 年度 (共著) 待ち行列
理論の基礎と応用, 共立出版, 2014 年度 (共著)

研究専門分野：通信工学 コンピュータネットワーク 性能評価 オペレ
ーションズリサーチ

あらまし 将来のユビキタス空間では、位置の不明な
もしくは位置が秘匿された多数のセンサが収集する位
置属性を持たない微小データから、有意な情報を抽出
し、実世界のリアルタイムな状態を推定するための基
盤技術が必要になる。本稿では、センシング結果を 1
ビット情報に縮約して通知するバイナリセンサに焦点
を絞り、(1)位置属性を持たない 1 ビット情報を用いた
対象物形状推定、(2)内部距離計測による対象物の形状
認識、(3)センサの近接関係情報を利用した位置推定技
術について概説する。また、近年注目を集めているソ
ーシャルセンサを用いた実世界の推定に関連して、(4)
ランダムウォークサンプリングにより収集されたデー
タに含まれるバイアスの除去法について説明する。

1. はじめに

センサが取得した物理情報をその通信機能を介して
収集し、様々な分析や制御に用いるセンサネットワ
ークが注目されている。センサネットワークの研究には、
高度なセンシング機能、マルチホップ通信機能、測位
機能等を持つ高機能センサの使用を前提とするものが
少なくない。センサは画像のような豊富な情報を取得
し、取得したデータをマルチホップ通信機能によりゲ
ートウェイに転送する。また、センサは測位機能を用
いて自分の位置を知り、データに位置情報をタグ付け
する。このような機能を持つセンサは必然的に高価な
ものとなるため、少数のセンサを注意深く設置する利
用法が中心となる。

一方で、センサネットワークの初期の研究は、「スマ
ートダスト」のように多数の安価な小型センサを広範
囲に配置して、環境モニタリング等への応用を志向す
るものであった。機器コストを抑える観点からは、セ
ンサに高度な通信機能を搭載することは禁止的である
ため、安価な小型センサが自律的に通信ネットワー
クを構成し、マルチホップ通信でセンシングデータを転
送するといった仮定は現実的でない。しかし、複数の
ゲートウェイを広域に配置し、センサといずれか一つ
のゲートウェイを狭帯域 (数 kbps 以下) ではあるが、
長距離 (数 km) の無線リンクにより 1 ホップで接続
するセンサ収容形態も提案されており [1]、このような
センサ収容用のインフラストラクチャが実現されれば、
スマートダストのように安価な小型センサを多数配置
して、各センサが取得する (一つ一つは微細な) セン
シング情報を大量に収集することが可能になると考え
られる。

このような無数のセンサから収集した情報を通して
実世界を観る「スマートダスト」のアプローチは、次
のような意味でも現実味を帯びている。例えば、個人
が所有する携帯端末にセンシング機能を埋め込めば、
多数の携帯端末から (通信機能を介して) 大量の環境
情報を取得することは技術的には充分可能である。ま
た、Twitter や Facebook のようなオンラインソーシャ
ルネットワーク上に存在する大量の情報から、実世界
の状態を解析する研究が数多く行われているが、オン
ラインソーシャルネットワークのユーザを一種のセン

時空間分散された微小センシング情報に基づく状態推定技術

State Estimation Based on Small Sensing Data Collected over Different Time and Space

サ（しばしばソーシャルセンサと呼ばれる）とみなせば、これはソーシャルセンサが発信する大量のセンシング情報を収集して現実世界を分析するアプローチに他ならない。

ただし、スマートダストで想定する安価な小型センサに測位機能が搭載されることは、実際には期待できない。個人情報保護の問題から、個人が所有する携帯端末が収集したセンシング情報にも位置情報をタグ付けすることには困難が想定される。このような場合、センサの測位機能を利用せずに各センサの位置を推定する技術を用いるか、位置属性を持たないセンシング情報を集約し、統計的な処理等を施して有意な情報を抽出する技術が必要になる。

本稿では、センシング結果を1ビット情報に縮約して通知するバイナリセンサに主として焦点を絞り、位置の不明なもしくは位置が秘匿された多数のセンサが収集する微小データから実世界のリアルタイムな状態を推定するための基盤技術について、筆者らが取り組んできた研究成果を中心に紹介する。

2. 位置属性を持たない1ビット情報を用いた物体形状推定

低機能センサの一例として、1ビット情報（対象物の有無、温度や湿度が定められたしきい値以下であるか、など）を通知するバイナリセンサを考える。バイナリセンサのような低機能センサは通常は測位機能を持たないと考えられるため、センシングデータには位置属性はタグ付けされない。各センサから通知されてくるのは位置属性を持たない1ビット情報である。このため、位置属性を持たない多数の1ビット情報を集約し、統計的な処理等を施すことで有意な情報を抽出する技術が必要になる。

簡単のため、ここでは対象物の有無を検知し、通知するタイプのバイナリセンサを考える。各センサは同一形状のセンシングエリアを有し、センシングエリアと対象物が一部でも重なれば対象物を検知できるとする。対象物を検知した場合はビット「1」を、何も検知しなければビット「0」をゲートウェイ経由でサーバに送信する。このような対象物検知用のバイナリセンサを監視領域に多数配置し、各バイナリセンサの反

応から対象物の有無のみならず、形状に関する何らかの情報を得ることを考える。

センサが一定の密度 λ で監視領域にランダムに均一に撒かれているとする。このとき、対象物が凸形状であるならば、対象物を検知したセンサ数 N の期待値、対象物の面積と周囲長、センシングエリアの面積と周囲長、およびセンサ密度との間に以下の関係が存在することが、積分幾何学の公式から導かれる[2][3]。

$$E[N] = \lambda \left(\frac{1}{2\pi} |T| |A| + \|T\| + \|A\| \right) \quad (1)$$

ここで $\|T\|$ および $|T|$ は対象物の面積および周囲長、 $\|A\|$ および $|A|$ はセンシングエリアの面積および周囲長、 $E[N]$ は対象物を検知したセンサ数の期待値である。各センサが形状の異なる2種類のセンシングエリア（種類1、種類2）を使い分けて物体を検知できるならば、以下の二つの式が得られる。

$$E[N_1] = \lambda \left(\frac{1}{2\pi} |T| |A_1| + \|T\| + \|A_1\| \right) \quad (2)$$

$$E[N_2] = \lambda \left(\frac{1}{2\pi} |T| |A_2| + \|T\| + \|A_2\| \right) \quad (3)$$

ここで、 $\|A_i\|$ および $|A_i|$ は、種類 i ($i = 1, 2$) のセンシングエリアの面積および周囲長である。式(2)と式(3)は対象物の面積、周囲長を未知変数とする2元連立方程式と見なすことができ、センサの密度、センシングエリアの面積、周囲長が既知であるならば、時間を変えて対象物を検知したセンサ数 (N_1 と N_2) を複数回調べ、その平均を検知センサ数の期待値とみなすことで、対象物の面積と周囲長が推定できる。同様に、形状の異なる3種類以上のセンシングエリアが使い分けられるならば、対象物の面積、周囲長、センサ密度を未知変数とする3元連立方程式が得られ、センサの正確な密度が不明であっても、対象物の面積と周囲長が推定できる。故障やバッテリー切れにより稼働中のセンサ数は時間とともに減少し、センサ密度を正確に把握することは実際には困難なため、このようなアプローチも有効である。

シミュレーション実験を用いて、センシングエリアが円の場合について、3種類以上のセンシングエリア半径を使い分けて（表1）、形状の異なる9種類の対象物（表2）の形状推定精度を評価した結果を示す[4]。

時空間分散された微小センシング情報に基づく状態推定技術

State Estimation Based on Small Sensing Data Collected over Different Time and Space

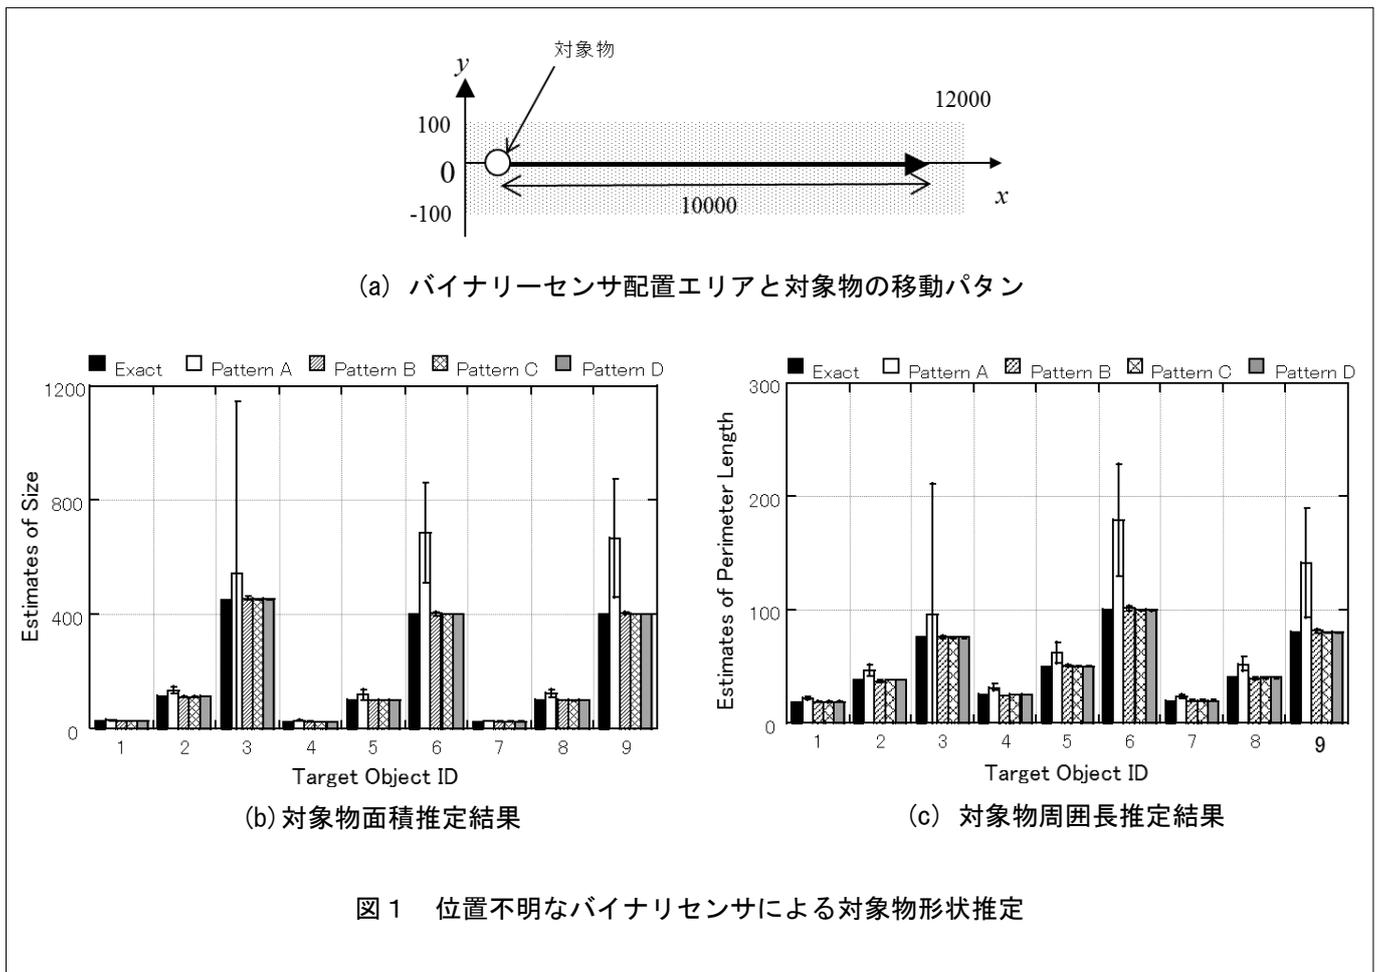
表1 センシングエリア半径の組み合わせ

パターン	センシングエリア半径の組み合わせ
A	(10, 1, 0.1)
B	(1, 0.1, 0.01)
C	(0.1, 0.01, 0.001)
D	(10, 1, 0.1, 0.01, 0.001)

表2 シミュレーションに用いた対象物形状

ID	形状	パラメータ
1	円	半径 = 3
2	円	半径 = 6
3	円	半径 = 12
4	長方形	縦 = 2.5 横 = 10
5	長方形	縦 = 5 横 = 20
6	長方形	縦 = 10 横 = 40
7	正方形	縦 = 横 = 5
8	正方形	縦 = 横 = 10
9	正方形	縦 = 横 = 20

センサは図1(a)に示した領域に密度0.1でランダムに配置し、対象物を速度100で動かし、100通りの時刻 ($t = 1, \dots, 100$) において対象物を検出したセンサ数を求め、上述の手法で各対象物の面積 (図1(b)) と周囲長 (図1(c)) を推定した。推定にあたり、センサ密度は不明とした。良好な推定結果が得られていることが確認できる。



時空間分散された微小センシング情報に基づく状態推定技術

State Estimation Based on Small Sensing Data Collected over Different Time and Space

なお、複数のバイナリセンサを組み合わせた複合バイナリセンサを用いれば、対象物が多角形の場合の内部角度の推定や[5]、複数の対象物が存在する場合への拡張[6]も可能である。

3. 内部距離の計測に基づく物体形状推定

2章で述べた手法は、データの位置属性を利用しないがゆえに

- ・ 十分な精度を確保するためには、センサを高密度に配置しなければならない
- ・ 対象物が凸形状である必要がある
- ・ 形状に関して得られる情報が周囲長や面積等に限られる

などの制約を持つ。もし4章で述べるような技術を用いて各バイナリセンサの位置が推定できるならば、位置情報を利用することで獲得できる知識の量や質を大きく改善することができる。

バイナリセンサの位置が既知であるとして、バイナリセンサの反応から対象物の形状を判定する手法を紹介する[7]。対象物が占有する2次元平面上のエリア内の任意の2点を結んだ距離を「内部距離」(Inner Distance)と定義する。内部距離は両端の選び方により、値の変わる確率変数とみなせる。内部距離の確率特性(期待値、分散など)は対象物の形状に依存して決まり、形状が既知であれば、内部距離の確率特性は解析的に(もしくは簡単なシミュレーションにより)求まる。一方、対象物の内部距離は対象物を同時に検知したセンサ間の距離により計測できる。例えば、図2において時刻1ではセンサA, B, Cが対象物を同時に検知している。

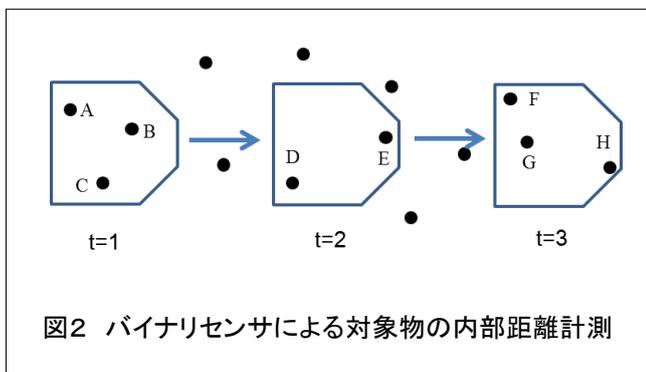


図2 バイナリセンサによる対象物の内部距離計測

このとき、A-B, A-C, B-C間の距離は、それぞれ対象物の内部距離の計測結果と見なすことができる。同様に、時刻2ではD-E間の距離を、時刻3ではF-G, G-H, F-H間の距離をそれぞれ内部距離の計測結果とみなせる。これら内部距離の複数回の計測結果から、例えば、内部距離の期待値や分散が推測できる。監視領域に存在する(通過する)対象物が、形状が既知の幾つかの候補に限定されていれば、このような内部距離の計測結果から、監視領域に存在する対象物の形状を候補形状の中から選択することが可能である。

4. センサの近接関係情報を利用した位置推定技術

3章でも述べたように、センサが取得した情報に取得位置の情報を付与できれば、情報の有用性は著しく高まる。取得位置の情報を付与するために、センサに測位機能を持たせるための研究が広く行われている。

センサの位置を推定する最も直接的な手段はGPS(Global Positioning System)である。GPSはセンサにGPS受信機を搭載すれば利用できるが、GPS受信機の搭載は消費電力量や機器コストの点で望ましくない。このため、(アンカーと呼ばれる)一部のセンサにGPS受信機等を搭載して測位機能を持たせ、その他のセンサはアンカーが同報する位置情報を利用して自らの位置を推定する手法が多数提案されてきた。

センサの位置推定手法の一つに、センサが隣接するセンサまでの距離と隣接するセンサの推定位置を利用して相互に三辺測量を行い、全体として位置推定精度を高める協調位置推定(Cooperative Localization)がある。センサ*i*の推定位置を \vec{x}_i 、センサ*i*-*j*間の距離を d_{ij} とすると、協調位置推定は以下の目的関数を最小化する最適化問題として定式化できる。

$$\epsilon(\vec{x}_1, \dots, \vec{x}_N) = \sum_{i=1}^N \sum_{j=i+1}^N \left(\|\vec{x}_i - \vec{x}_j\| - d_{ij} \right)^2 \quad (4)$$

ここで、式(4)の2番目の和は距離測定が可能なセンサ間についてのみ取る。この目的関数は非凸な非線形関数であるので、最適解を解析的に求めることができず、降下法により数値的に解を求める手段がとられる。その場合、大域的最適解への収束性は必ずしも保障されない。しかし、センサ数が増えるほど、大域的最適解への収束性は向上し、かつ位置推定誤差も減少するこ

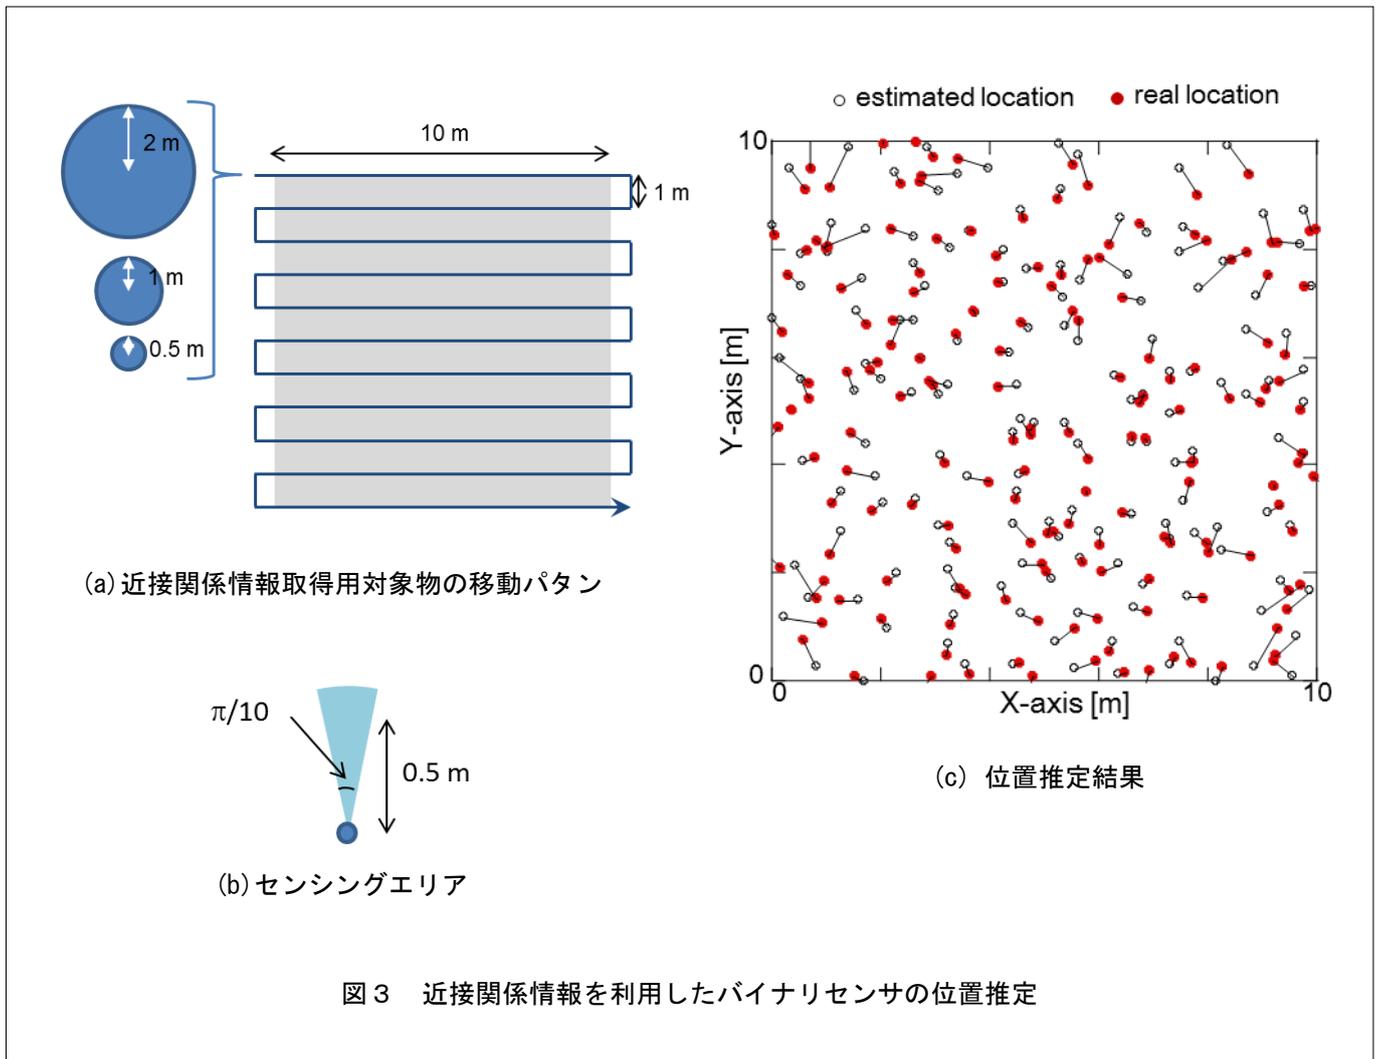
時空間分散された微小センシング情報に基づく状態推定技術

State Estimation Based on Small Sensing Data Collected over Different Time and Space

とが確認されている[8][9]。従って、2章や3章で説明したような多数の小型センサを利用するケースほど、協調位置推定の精度は向上する。

協調位置推定では、センサの位置推定に隣接センサ間の距離の情報が必要になるが、バイナリセンサのような低機能センサには、隣接センサとの距離を測定するための機能は搭載されないと考えられる。しかし、対象物を同時に検知したバイナリセンサは互いに近い位置にあるとみなせるので、対象物に対するセンサの反応から、どのセンサ同士が近接関係にあるかの情報を得ることができる。この点に着目し、対象物に対するセンサの反応から近接関係の情報を得て、バイナリセンサの位置を推定する技術について研究を進めている[10]。

シミュレーション実験により、近接関係情報からバイナリセンサの位置を推定した結果を示す[10]。約200個のバイナリセンサを10m×10mの領域にランダムに配置する。図3(a)に示す経路に沿って、近接関係を調べるための対象物を領域に通し、各バイナリセンサの反応から、どのセンサ同士が近接関係にあるかを調べる。その後、得られた近接関係情報から式(4)を目的関数とする最適化問題を解くことで、バイナリセンサの位置を決定する。バイナリセンサは図3(b)に示す扇形のセンシングエリアを有するとする。推定結果を図3(c)に示す。驚くほど正確にセンサの位置が推定される様子がわかる。



時空間分散された微小センシング情報に基づく状態推定技術

State Estimation Based on Small Sensing Data Collected over Different Time and Space

5. ランダムウォークサンプリング

Twitter や Facebook のようなオンラインソーシャルネットワーク上に存在する大量の情報を、実世界の状態を解析するためのソーシャルセンサとして利用する研究が数多く行われている。オンラインソーシャルネットワークに存在するデータは莫大であるため、実際には解析対象とするデータをサンプリングにより絞りこむ必要があり、その際のサンプリング手法の一つに、ネットワーク内をランダムウォークしながら訪問先のノードのデータを収集するランダムウォークサンプリングがある。隣接ノードの一つを等確率に選んで推移する古典的なランダムウォークでは、高次数ノードほど訪問されやすい傾向にある。従って、古典的なランダムウォークをデータサンプリングに用いると、高次数ノードのデータを偏って収集する結果となり、収集されたデータにバイアスが発生する。

ランダムウォークサンプリングに伴い発生するバイアスを回避するために、ランダムウォークにおける隣接ノードへの推移確率を **Metropolis-Hastings** アルゴリズムにより調整して、均一なサンプリングを実現する手法が提案されている。一方、古典的なランダムウォークでは、各ノードへの訪問確率が次数に比例する事実に着目すると、次数の逆数の重みを掛けて平均化することで、サンプリングデータに含まれるバイアスを除去することが可能ではないかと考えられる。筆者らはランダムウォークサンプリングにより収集した、データに含まれるバイアスを除去する手法について研究を進めている[11][12]。

インターネット上で公開されている4つのオンラインソーシャルネットワークおよび P2P (Facebook, Gplus, Twitter, Gnutella : 表 3) のトポロジーデータ[13]を用いて、コンピュータ上に仮想的にこれらネットワークを構築し、ネットワーク上でランダムウォークさせながら、訪問先ノードの次数のデータを収集させ、収集データに基づいて平均次数を推定させた結果を示す。平均次数の推定には、(1)MH アルゴリズムにより均一なサンプリングを実現して訪問ノードの次数の単純平均を取るもの (以下、MH サンプリング)、(2)古典的なランダムウォークサンプリングを行って事後にバイアスを除去するもの (以下、事後バイアス除去)

の二通りを用いた。

表 3 ネットワークデータ

Network	ノード数	リンク数
Facebook	4,039	88,234
Gplus	107,614	13,673.453
Twitter	81,306	1,768.149
Gnutella	62,586	147,892

ランダムウォークを開始するノードを 100 通り変えて、ランダムウォークのステップ数が丁度ノード数の 10 分の 1 に達した時の平均次数の推定値を 100 通り求め、その平均を取った結果を表 4 に示す。なお、MH サンプリングでは、同じノードに留まって連続してサンプリングを行うことがあるが、同じノードに連続して 2 回以上留まる場合はステップ数にカウントしないこととした。MH サンプリングと事後バイアス除去の二つの手法には大差はなく、ほぼ偏りなく推定できていることがわかる。

次に、100 通りの平均次数の推定値の変動係数をランダムウォークのステップ数の関数としてプロットした結果を図 4 に示す (ステップ数そのものではなく、ステップ数のノード数に対する比を X 軸にとった)。MH サンプリングよりも、事後バイアス除去法の方が推定値の変動係数が小さい。これは、MH サンプリングに比べて通常のランダムウォークによるサンプリングの方が、次数の大きいハブノードを訪問する回数が多いため、ネットワーク内をより広くサンプリングできる結果となったためと考えられる。

表 4 平均次数

Network	MR sampling	事後バイアス除去	真値
Facebook	45.59	45.59	43.69
Gplus	362.6	378.1	397.1
Twitter	44.80	46.30	46.28
Gnutella	4.729	4.723	4.726

時空間分散された微小センシング情報に基づく状態推定技術

State Estimation Based on Small Sensing Data Collected over Different Time and Space

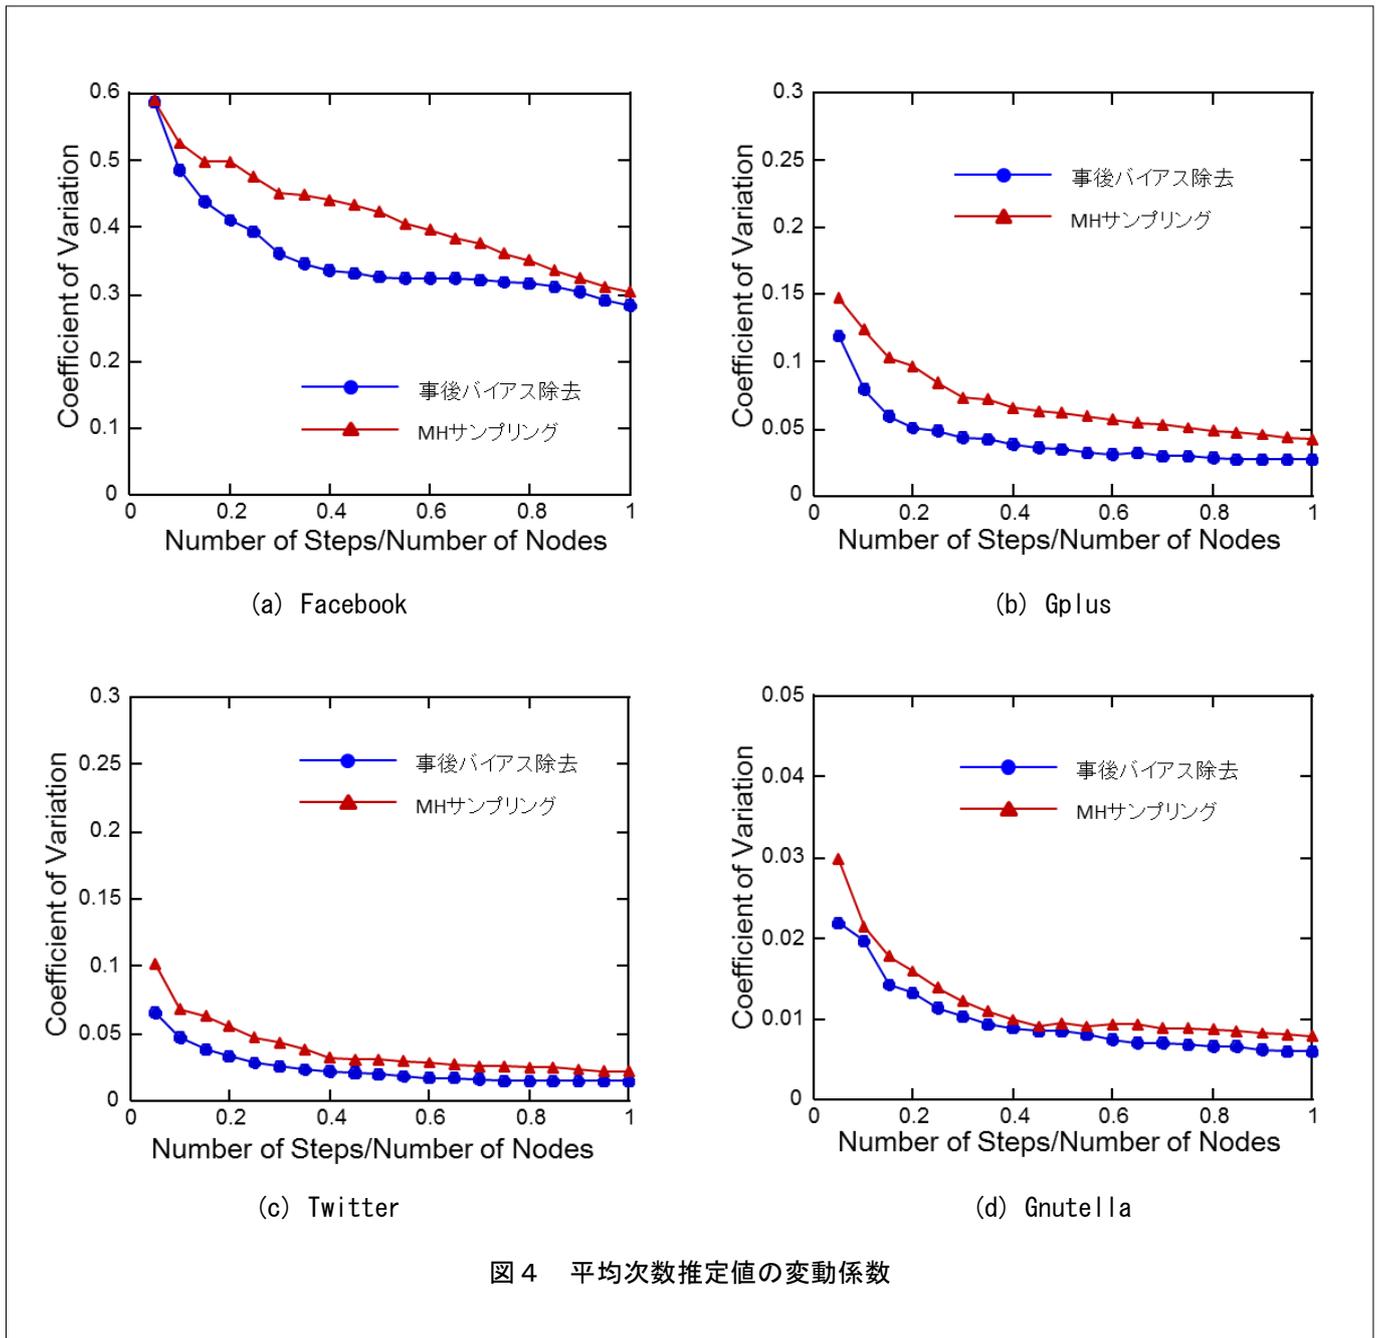


図4 平均次数推定値の変動係数

6. おわりに

本稿では、位置の不明なもしくは位置が秘匿された多数のセンサが収集する位置属性を持たない微小データから、有意な情報を抽出し、実世界のリアルタイムな状態を推定するための基盤技術の一例として、筆者らが現在進めている研究の一部を紹介した。

Web上などに存在する大規模で様々な非構造化データに何らかの法則性を見出し、新たな知識を獲得し、

価値を創造するビッグデータ解析が近年注目を集めている。本稿で紹介した技術は、まさにビッグデータ解析の一手法と位置付けることもできる。この分野は多くのニーズが潜んでいると考えられ、それら潜在的ニーズを掘り起こし、適切な技術ソリューションを提供していくことが肝要である。

時空間分散された微小センシング情報に基づく状態推定技術

State Estimation Based on Small Sensing Data Collected over Different Time and Space

参考文献

- [1] H. Saito, O. Kagami, and M. Umehira, "Wide area ubiquitous network: the network operator's view of a sensor network," *IEEE Commun. Magazine*, vol.46, pp.112-120, 2008.
- [2] L. Santal, "Integral Geometry and Geometric Probability," Cambridge Mathematical Library, 2004.
- [3] H. Saito, S. Shimogawa, S. Shioda, and J. Harada, "Shape Estimation Using Networked Binary Sensors," *IEEE INFOCOM*, 2009.
- [4] 山下賢也, 塩田茂雄, 齋藤洋, "センサ密度が未知のバイナリセンサネットワークによる対象物形状推定," *電子情報通信学会論文誌*, vol. J95-D, no. 1, pp. 54-66, 2012.
- [5] H. Saito, S. Shioda, and S. Tanaka, "Stochastic geometric filter and its application to shape estimation for target objects," *IEEE Trans. Signal Processing*, vol. 59, no. 10, pp. 4971-4984, 2011.
- [6] H. Saito, S. Shimogawa, S. Tanaka, and S. Shioda, "Estimating parameters of multiple heterogeneous target objects using composite sensor nodes," *IEEE Trans. Mobile Computing*, vol. 11, no.1, pp. 125-138, 2012.
- [7] S. Shioda and T. Hayashi, "Inner-distance-based shape recognition of target object using binary sensors," *IEEE ICPADS*, 2012.
- [8] S. Shioda and K. Shimamura, "Cooperative Localization Revisited: Error Bound, Scaling, and Convergence," *ACM MSWiM'13*, 2013.
- [9] S. Shioda and K. Shimamura, "Anchor-free localization: estimation of relative locations of sensors," *IEEE PIMRC*, 2013.
- [10] S. Shioda and K. Shimamura, "Relative Localization of Sensors Based on Their Responses to Moving Objects," *IEEE MASS*, 2013.
- [11] S. Shioda, "Unbiased Estimation Based on Biased Sampled Data of Communication Networks," *IEEE AINA*, 2014.
- [12] S. Shioda, "Random-Walk-Based Biased Sampling for Data Collection on Communication Networks," *IFIP WG7.3 Performance*, 2014.
- [13] "Stanford large network dataset collection". <http://snap.stanford.edu/data/>

この研究は、平成21年度SCAT研究助成の対象として採用され、平成22～24年度に実施されたものです。