

センシングシステムにおける内挿の信頼度を用いたセンサーノードの配置決定

中村 裕一^{1,a)} 伊藤 昌毅¹ 瀬崎 薫^{2,1}

概要: 近年スマートフォンの普及に見られるように半導体技術が進歩しており、参加型センシングをはじめとするセンシングシステムの活用に注目が集まっている。しかし、各ノードが動くような系において最適な測定を可能にするようなセンサーの配置決定について、確立した方法は少ない。そこで本研究では、センサーノードでの測定データを空間的に内挿しながら、各点における内挿の信頼度を計算しそれをもとに次の測定でのセンサーの配置を決定する方法を提案する。本稿では、実際にスカラー場を作りその上でセンサーノードたちの挙動をシミュレーションし、提案手法でのノードの配置決定が有用かを検討する。

キーワード: kriging, アクティブセンシング, センシングシステム

English Title

YUICHI NAKAMURA^{1,a)} MASAKI ITO¹ KAORU SEZAKI^{2,1}

Abstract: As the semiconductor technology advances, which can be seen in the recent spread of smart-phones, sensing system including participatory sensing has attracted great attention these days. However, there is few established ways of such a determination of positioning of sensor nodes that enables the optimal measurement with regard to the confidence of interpolation. This study proposes a method to determine the optimal positioning of sensor nodes after one set of measurement at each point, by using the result of interpolation of that set of measurement. In this paper, we will show whether that method is valid by simulating a scalar field and sensor nodes on it.

1. はじめに

今日では、スマートフォンの保有率は目覚ましく増加しており、2011年には14.6%であった個人保有率は2016年には56.8%にまでなっている[1]。近年の半導体技術の発達等によってスマートフォンにはより多種類のセンサが組み込まれるようになってきているため、今日では街を歩く人の半分以上がインターネットに接続された複数のセンサを持ち歩いているといえる。こうした背景から、移動可能なセンサノード群から得られる情報の活用に注目が集

まっており、本稿ではこれを含むより一般的なクラスであるセンシングシステムについて扱う。

空間にセンサノードが散在している場合、それらから集められる情報は、生データの時点では単に各点でのパラメータ(例えば気温など)を示すのみである。しかし、これを適切に分析すれば、センサノードが置かれていない場所のパラメータを推定することができ、ある程度の時間測定を行えば未来のパラメータを推定することができる。あるいは各センサノードが移動可能である場合は、より詳しく測定を行いたい場所にノードを動かせば、前述のような推定の精度を高めることができる。

センシングシステムの一類型として、前述の通り、スマートフォンを持った複数の人が街を歩きながら目的の測定を行うモバイルセンシングシステムが挙げられる。モバイルセンシングでは、測定に際して新しいハードウェアを

¹ 東京大学生産技術研究所
IIS, The University of Tokyo, Meguro, Tokyo 153-8505, Japan

² 東京大学空間情報科学研究センター
CSIS, The University of Tokyo, Kashiwa, Chiba, 277-0882, Japan

a) y-nakamura@mcl.iis.u-tokyo.ac.jp

購入することなく既存技術（たとえば気温などを測るためのアメダスは全国に約 1300 か所の観測点を持つ [2]）に比べて空間分解能がより高い情報を、より低コストで得ることができる。また空間分解能がより高い情報を用いてモデルを作れば、時間方向の将来予測も可能になる。こうしたことから、モバイルセンシングなどのセンシングシステムは政策決定などの文脈でも大きな期待を持たれている。

2. センシングシステム

2.1 センシングシステム

センシングシステムとは、スマートフォンに代表されるようなセンサを備えたセンサノードが空間に散在しており、またそれらがネットワークに接続されているものを指す。センシングシステムの一類型であるモバイルセンシングシステムでは、ノードを動かせば同数の固定型センサに比べて高い空間分解能が実現できるという利点を持つ一方で、大型や固定型のセンサに比べてデータの較正が安定せず誤差が乗りやすいという欠点がある。こういった欠点を解消するためにも様々なデータ較正の手法が考えられている。モバイルセンシングの例に限らず、複数のセンサノードから集まるデータを集約し、それを空間全体に内挿するために様々な手法が考えられている。

2.2 センシングシステムの活用例

センシングシステムは、先述のモバイルセンシングネットワークに加えて多数の活用例がある。

たとえば世田谷区全体の騒音データをのべ 40 人が 6 時間程度で取ることができたという研究がある [3]。また、無人潜航艇を使って各点での磁気強度をはかり、それを海中の 3 次元空間方向に内挿して探査海域全体の磁気のマップを作った例もある [4]。固定センサの例としては、毎日の天気予報で欠かすことのできないアメダスをあげることができる [2]。

このように、センシングシステムは気象、交通をはじめとした幅広い分野で活用されている。

3. センサデータの統合

3.1 問題の設定

前節で述べたようなセンシングシステムでのデータ統合を考える。ここでいうデータ統合とは、たとえば気温などの同一のパラメタについて各測定点での測定値を、考えている空間全体において補完して、空間全体での場^{*1}を推定するということである。データ統合を行う際に考えるべき問題は、あるパラメタについて複数のセンサノードからの

^{*1} 考えているパラメタがスカラーであればスカラー場、ベクトルであればベクトル場となる。ベクトル場の場合は、成分表示をして各成分ごとに考えればスカラー場に関する議論の単純な拡張として捉えることができるため、本稿では、スカラー場の場合に限って議論を進める。

測定データを統合し、空間全体について各点での値を推定するというものである。本稿では、このようにある時刻、ある領域の中に散在している複数のセンサノードから集まった測定値をいかにして統合し、空間の各点での値を推定するという問題を考える。

3.2 kriging

3.2.1 kriging とは

kriging というのは、上記のような問題、すなわち空間内挿のための一つの手法である。本稿では kriging を用いて空間内挿を行い、かつ、内挿自体の信頼度を計算する。以下ではまず kriging の概要を述べ、その後にはその特徴について論じる。

3.2.2 kriging の問題設定

kriging では空間内挿を、測定点における測定値の重み付き和として、

$$\hat{z}(\vec{r}) = \sum_{i \in I} \lambda_i z(\vec{r}_i) \quad (1)$$

のように行う。ここに、測定したセンサーノード i すべてからなる集合を I 、センサーノード i の座標を \vec{r}_i 、測定点 \vec{r} における測定値を $z(\vec{r}_i)$ 、任意の点 \vec{r} において空間内挿を行なったを $\hat{z}(\vec{r})$ とし、 λ_i は \vec{r} ごとに定まる重みで、規格化条件 $\sum_{i \in I} \lambda_i = 1$ に従う。

kriging においては、この重み λ_i を z の空間的自己相関を用いて定めるところに特徴がある。具体的には以下の方法による。

3.2.3 手順 1: semivariance の計算

まずは、自己相関を計算する。空間内に散らばった各センサノード $i (i = 1, \dots, N)$ の位置を \vec{x}_i とし、そこで得られたスカラーの観測値を $z(\vec{x}_i)$ とすると、

$$\gamma(\vec{h}) := \frac{1}{2n} \sum_{i=1}^n \left[z(\vec{x}_i + \vec{h}) - z(\vec{x}_i) \right]^2 \quad (2)$$

で定義される^{*2}量を semivariance と呼ぶ。理想的な例では semivariance は $|\vec{h}|$ のみに依存する。もし、 \vec{h} の方向にも依存する、すなわち semivariance が異方性を持つ場合には、空間に対して適当な Affine 変換をおこなって $|\vec{h}|$ のみに依存するようにする。以下の議論ではこの操作を前提とするため semivariance の引数を単に h と表記する。

3.2.4 手順 2: variogram のプロットとそのフィッティング

次に、semivariance を連続的な h に対して拡張する。式 2 の段階では、 γ は離散的な h にだけしか定義されていない。より詳細に言えば、任意の 2 つの測定点間の距離以外の h に対しては定義されない。これを全ての h にまで拡張

^{*2} 理論的には観測値ではなく真の値に対して定義されるが、実用上は式 2 を用いるので、ここでは簡単のためにこの値を定義として掲げた。

張するために、 h に対して γ をプロットする。そうするとたとえば図 1 のようになり、これを variogram と呼ぶ。直感にたがわず、 h の増加に伴って γ も増加するのが一般的である。そしてこのプロットを適当なモデルでフィッティングすることで $\hat{\gamma}(h)$ を知ることができる。ここで用いる関数にはいくつか代表的なものがあるが、たとえば下記の spherical model が挙げられる。




図 1 variogram の例 [5]

$$\hat{\gamma}(h) = \begin{cases} c_0 + c_1 \left[\frac{3h}{2a} - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right] & 0 \leq h < a \\ c_0 + c_1 & a \leq h. \end{cases} \quad (3)$$

3.2.5 手順 3: 重みの計算

このようにして全ての h に対して semivariance $\hat{\gamma}(h)$ を求めたら、最後に、これを用いてそれぞれの点 \vec{x} における重み $[\lambda_i]_{i \in I}$ を求める。

重みは、推定の variance $E[(\hat{z} - z)^2]$ を最小化するようなものを選ぶ。規格化条件のもとで解くため、Lagrange の未定乗数法を用いることができる。上記を満たすような重み $[\lambda_i]_{i \in I}$ は、連立方程式

$$\forall j \in I; \sum_{i=1}^N \lambda_i \hat{\gamma}(\vec{x}_i - \vec{x}_j) = \hat{\gamma}(\vec{x}_j - \vec{x}_0) \quad (4)$$

の解として得られる。このようにして得られた重み $[\lambda_i]_{i \in I}$ を用いた線形和として kriging を行なった際の variance は、

$$\hat{\sigma}_e^2(\vec{x}) := \sum_{i=1}^N \hat{\lambda}_i \gamma(\vec{x}_i - \vec{x}) + \phi. \quad (5)$$

というように表すことができる。これを kriging variance と呼ぶ [5]。

3.2.6 kriging の特徴

kriging の特徴は、空間的な自己相関を取り出して内挿を行える点、また内挿を行う際に簡単に信頼度を計算できる点である。

kriging では、semivariance として、データの空間的な自己相関を用いている。そのため、内挿したいパラメータの測定点が少ない場合、そのパラメータと同様の空間分布をするような別のパラメータがあれば、そのパラメータの空間的な自己相関をも用いることができる [5]。たとえば Liang らは、川の中の汚染物質 ($\text{NO}_3\text{-N}$) の量の推定に cokriging を用いた。ここでは空間方向でなく時間方向の内挿を行っているが、頻繁に測ることのできない $\text{NO}_3\text{-N}$ 量の時間内挿に、時間ごとの流量のデータを用いている。 $\text{NO}_3\text{-N}$ 量と川の流量には相関があるため、cokriging を用いることで、単に $\text{NO}_3\text{-N}$ 量のみを用いた kriging をする場合よりも、平均誤差を 48% 減らすことができた [6]。

信頼度の計算については、kriging を行う際の重みの計算をすればあとは簡単な線形和として kriging variance が求められるため、簡便に信頼度を計算することができると言える。

4. kriging variance gradient を用いた配置決定

本節以降では、前節にて論じた kriging を用いて測定結果を内挿し、センサーノードたちの配置決定を行う方法をのべる。

ここで考えるのは、 N のこのセンサーノードからなるセンシングシステムについて、まず最初に N のこのセンサーを空間にランダムに配置し、同時に測定を行った上で、各センサーノードを移動させ、同時に 2 度目の測定を行うという状況である。1 度目の測定と 2 度目の測定を合わせて行う空間内挿の精度がもっとも高くなるように、1 度目の測定から 2 度目の測定までの移動方法の決め方を考える。

ノードの配置決定においては、空間全体での内挿の精度がもっとも良くなるように、ノードを配置したい。すなわち、空間全体での kriging variance の積分 $\hat{\sigma}_{e,\text{tot}} := \int dS \hat{\sigma}_e^2$ ができるだけ小さくなるような空間内挿を行えるような、センサーノードの配置決定方法を得たい。そこで、本稿では、kriging variance gradient を用いる方法について論じる。

式 4 から明らかにわかるように、センサーノードのある点における重みはそのセンサーノードを i_0 として、 $\lambda_i = \delta_{i,i_0}$ である。よって、その点での kriging variance は式 5 より、

$$\hat{\sigma}_e^2(\vec{x}_{i_0}) = \hat{\gamma}(0). \quad (6)$$

となり、 $\gamma(h)$ が h の単調増加関数であることを考えれば、kriging variance としての最小値となることがわかる。よって、空間全体の kriging variance が与えられた場合、次の測定ではなるべく kriging variance の高い点について新しく測定を行うと、 $\hat{\sigma}_{e,\text{tot}}$ が小さくなるということがわかる。

kriging variance も空間全体について定義される量なので、これをスカラー場として捉える。すると、1 度目と 2 度

目の測定を合わせた空間内挿の variance を小さくするためには、1 度目の測定が終わった段階でそれぞれのセンサーノードを、その位置から見て kriging variance がもっとも急峻な方向に進めればよい。そうすれば 1 度目の variance が一番大きいところで 2 度目の測定を行える。

数学的にかけば、

$$\vec{e}_\theta = \arg \max_{|\vec{e}_\theta|=1} [\nabla V(\vec{x}) \cdot \vec{e}_\theta] \quad (7)$$

なる方向 \vec{e}_θ にノードを進めれば良いことがわかる。これを kriging variance gradient と呼ぶことにし、本稿ではこれを用いた配置決定を考える。

5. 評価

5.1 シミュレーション

前節の手法の有効性を検証するため、次のようなシミュレーションを行った。観測対象に見立てたとある 2 次元のスカラ場を作り、その上に 5 個のセンサーノードをおく。この初期位置に加えて、それぞれのノードについて初期位置での kriging variance gradient を用いて決めた移動先における測定値から、空間全体での kriging variance を求める。この値が、移動先をランダムに決めた場合に比べて優位に良くなるかどうかを調べる。

5.1.1 シミュレーションのフィールド

観測の対象と見立てた 2 次元の正方形を作った。計算の都合から、この正方形のサイズを 40x40 とし、0.5x0.5 の正方形に区切り、その格子点上において空間内挿を行うことにした。なお、のちに述べる kriging variance gradient の計算の都合から、センサーの初期位置が空間の端にならないよう、図 2 にある網かけの領域の中に一様分布するようにセンサーの初期位置を決めた。




図 2 シミュレーションを行った空間

5.1.2 スカラ場

前項で述べた 2 次元平面の上に、たとえば気温のような測定したいパラメータに見立てたスカラ場 $\Psi(\vec{x})$ を、図 3 のように作った。今回は、




図 3 今回シミュレーションで用いたスカラ場

$$\Psi(\vec{x}) = \sum_{i=1}^3 \Psi_i(\vec{x}) \quad (8)$$

$$= \sum_{i=1}^3 \frac{c_i}{2\pi\sqrt{\det V_i}} \times \exp \left[-\frac{1}{2} {}^t(\vec{x} - \vec{\mu}_i) V_i^{-1} (\vec{x} - \vec{\mu}_i) \right] \quad (9)$$

という 3 つのガウス分布の和とした。ここに、 $\vec{\mu}_i$ は平均値ベクトル、 V_i は共分散行列、 c_i はスカラ場の定数である。

5.1.3 センサーノード

このシミュレーションでは 5 つのセンサーノードを用意した。各々のセンサーノードの初期位置は前述の通り図 2 のなかに一様分布であるとし、まず各点で仮想的に測定を行った。すなわち、センサーノードが置かれた点における Ψ の値を得た。そして各々のセンサーノードは移動し、次の点における測定を行う。この際、移動の距離 Δr はあらかじめ決まっているとした。また、短時間での測定、移動、測定を再現しているため、1 回目の測定時と 2 回目の測定時においてはスカラ場は変化しないとした。すなわち、1 回目の測定から 2 回目の測定までにかかる時間を微小とする近似をした。




図 4 Δr と θ の定義

5.1.4 センサーノードの移動

センサーノード i の 1 回目の位置 $\vec{x}_i(t_1)$ から 2 回目の位置 $\vec{x}_i(t_2)$ までの距離は前述の通り Δr で一定であるが、その方向については 2 つの方法で決め、双方の結果を比較した。1 つ目は本稿で提案している kriging variance gradient を用いる方法、もう 1 つは角度をランダムに決める方法である。

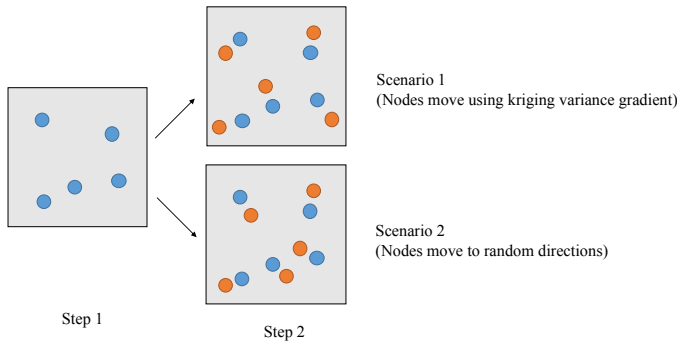


図 5 各センサーノードの動かし方

1 つ目の方法では時刻 t_1 における kriging variance gradient の方向にノードを動かした。具体的には、

$$\theta = \arg \max_{\theta} \left[V(\vec{x}_i(t_1)) - V(\vec{x}_i(t_1) + d\vec{e}_{\theta}) \right]^2 \quad (10)$$

として与えられる。本来は V の較差ではなく $\text{grad}V$ を用いるべきところではあるが、このシミュレーションでは空間内挿を離散的な点において行っているため、 grad そのものを求めることはできない。そこでいわゆる平均変化率を grad の代わりに用いている。このため \vec{e}_{θ} にチルダをつけて区別している。なおこの平均変化率を求める際の幅 d も事前に決めておくパラメーターである。

比較のために、2 つ目の方法として、ランダムな移動先の決定を行なった。具体的には $[0, 2\pi)$ で一様分布となるように乱数を発生させて、それを θ とし、 t_2 におけるノードの位置を決定した。

以上のようにして決めた t_2 におけるセンサーノードの位置にて、それぞれのシナリオにおいて、仮想的に測定を行い、 t_1 における 5 点の測定値と合わせて空間内挿を行なった。

5.2 シミュレーションの評価方法

ここでは、できるだけ精度の良い空間内挿を行えるような、センサーノードの配置決定方法を得たい。そのため、前項であげた 2 つのシナリオについて、kriging で内挿した推定値の誤差を比べる。ただし、今回空間内挿は格子点についてのみ行なっているため、実際には

$$\delta_{\text{tot}} := \sum_{j \in J} [\hat{z}(\vec{r}_j) - \Psi(\vec{r}_j)] \quad (11)$$

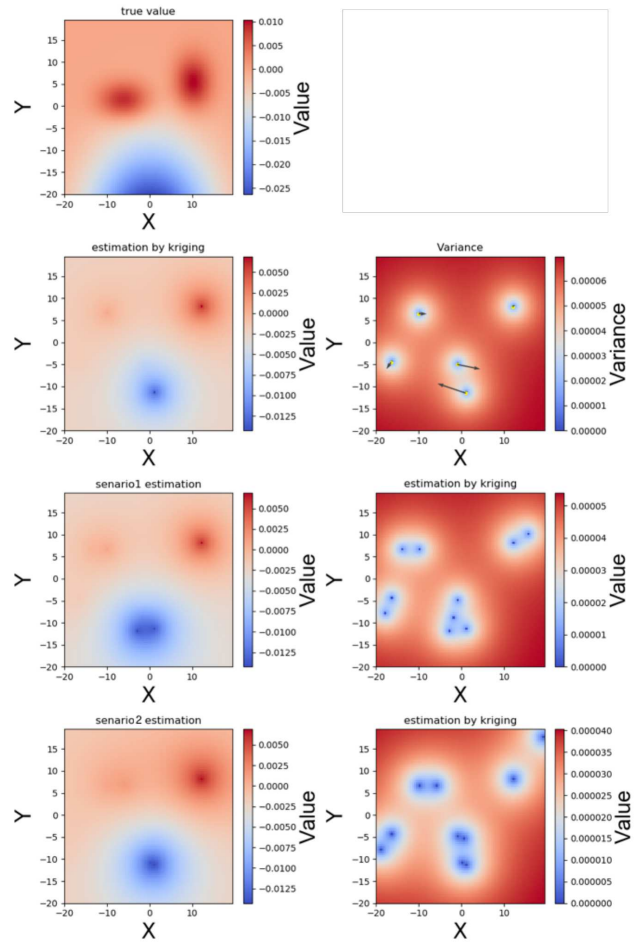


図 6 シミュレーションの例。最上段左の図が真値、上から 2 段目左が t_1 における kriging の結果、右が kriging variance。3 段目はシナリオ 1、4 段目はシナリオ 2 での kriging の結果と variance。

を比較した。ただしここで、 J は今考えている空間内の格子点全てからなる集合、 \vec{r}_j は格子点 j の座標である。

このシミュレーションにおいて変化させられるパラメーターは 2 つあり、移動ステップの幅 Δr と、kriging variance の平均変化率を求める際のサンプル幅 d である。これらを変化させながら、シナリオ 1 と 2 の間で δ_{tot} の大小を比較した。

Δr は 0.5 から 20 まで、 d は 0.5 から 10 まで、それぞれ 0.5 間隔で変えていき、各々の $\Delta r, d$ の組に対して 1000 回初期位置を変えながらシナリオ 1 と 2 における δ_{tot} の比較を行った。

5.3 シミュレーションの結果

前項に説明したようにパラメーターを変えつつ、めいめいのパラメーターの組みに対して 1000 回の試行のうちシナリオ 1 の方がシナリオ 2 よりも $\hat{\sigma}_{e, \text{tot}}$ が小さくなるような回数の割合を計算した。その結果図 7 が得られた。試行を 1000 回行っているため、

$$53.38\% \times \left(1 - 2 \cdot \frac{1}{\sqrt{1000}}\right) = 50.00\% \quad (12)$$

より、かかる割合が53.4%を超えていれば95%信頼区間において、シナリオ1が優位に良い精度を与え得ると言える。図7を見ると、シナリオ1の方が良い精度を与えている割合が70%を超えているところもあるので、今回のシミュレーションの結果、適切にパラメタを選べば、提案手法によってセンサーノードノ配置決定をすることでランダムに配置決定をするよりも優位に良い kriging の精度が得られるということがいえる。

- Press, 3 edition, chapter 9, pp. 171–200 (2015).
- [6] Liang, X., Schilling, K. and Zhang, Y.-k.: Co-Kriging Estimation of Nitrate-Nitrogen Loads in an Agricultural River, *Water Resource Management*, Vol. 30, pp. 1771–1784 (online), DOI: 10.1007/s11269-016-1250-9 (2016).




図7 それぞれの Δr および d においての、シナリオ1がシナリオ2よりも良い精度を与えた回数の割合

6. まとめ

本稿では、センシングシステムにおいて、1度測定を行った後に次のタイムステップでのノードの配置を決定するための方法を提案した。kriging variance の gradient を用いることで、ランダムに配置するよりも、精度の良い内挿が可能になるような方法であることが確認できた。

今後の課題として、3ステップ目以降も考慮に入れた配置決定、パラメーター $\Delta r, d$ の決め方、実際のデータを用いた検証に取り組む。

参考文献

- [1] 総務省：情報通信白書，日経印刷，Tokyo, Japan (2017).
- [2] 気象庁：気象業務はいま2017，研精堂印刷 (2017).
- [3] Sezaki, K.: 都市をセンシングする，生産研究，Vol. 65, No. 3, pp. 691–697 (2013).
- [4] ZHANG, C. and ZHAO, Y.: *High Precision Deep Sea Geomagnetic Data Sampling and Recovery with Three-Dimensional Compressive Sensing*, Vol. E100-A, No. 9, Institute of Electronics, Information and Communication Engineers (2017).
- [5] Burrough, P. A., McDonnell, R. A. and Lloyd, C. D.: *Interpolation 2: Geostatistical Approaches*, *Principles of Geographical Information Systems*, Oxford University