

# 時間変化する環境情報に対す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<sup>1,a)</sup> 伊藤 昌毅<sup>1</sup> 瀬崎 薫<sup>2,1</sup>

**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回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、実際に時間変化するスカラー場を作りその上での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

## Placement Determination of Sensor Nodes Using Confidence of Interpolation about Time-Varying Environmental Information

YUICHI NAKAMURA<sup>1,a)</sup> MASAKI ITO<sup>1</sup> KAORU SEZAKI<sup>2,1</sup>

**Abstract:** As the semiconductor technology advances, which can be seen in the recent spread of smartphones, 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 sets 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 time-varying 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急速に増加しており、個人保有率は2016年には56.8%にまでなっている [1]。スマートフォンの中には、多様なセンサ類が詰め込まれており様々なアプリケーションに活用されている。また、スマートフォンに限らず、いわゆる Internet of Things (IoT) という言葉にみられるように、身の回りのたくさんの機器

がネットワークに接続されるようになっている。こうした背景もあり、可動なセンサ群から得られる情報の活用に注目が集まっており、モバイルセンシングと呼ばれている [2], [3]。

モバイルセンシングでは、一般的に市民の所持するスマートフォンなどのデバイスでのセンシングを行い、それらのデータを収集・統合・解析して、広範囲における現象を把握・解明することができる。この際に一般市民からの協力を要請するなど参加者を募るものを特にモバイルクラウドセンシング、あるいは参加型センシングと呼ぶ。測定対象に注目すれば環境・インフラ・社会現象に大別することができるが [3]、たとえば都市における環境モニタリ

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

<sup>2</sup> 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

グ [4], [5] \*1, 放射線量 [6], 気象 [7], [8], [9], 水圏 [10], [11] 騒音 [12], [13], [14], そして交通 [15] と多岐にわたる. このようなモバイルセンシングの枠組みを使うことで, 測定に際して新しいハードウェアを導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 [16]) に比べてより高い空間分解能の情報を, より低コストで得ることができる. さらにそうした情報をもとにモデルを作れば, 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.

このモバイルセンシングのコストをそのままに測定の質を上げるためには, センサノードの動かし方を工夫すれば良い. そこで本稿では, モバイルセンシングにおけるセンサノードの配置決定問題を考える. ここで, 筆者らはすでに時間変化しない測定対象に対してのノード配置決定方法を提案している [17] が, 本稿ではこれを拡張して測定の対象である場が時間変化するような場合について考える.

## 2. モバイルセンシング

### 2.1 モバイルセンシング

モバイルセンシングとは, 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, それらがネットワークに接続されているものを指す. また各々のノードにはモビリティがあり, 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データ統合の手法が考えられている. すなわち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

先述の通り, 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 [13]. 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 [11]. 近年関心の高まる放射線のモニタリングにモバイルセンシングを用いる研究もなされている [6].

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モバイルセンシングにおけるセンシングデータの内挿を考える. ここでいうデータ内挿とは, 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推定し補完することで, 空間内での場\*2を推定するということである. つまり, 内挿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測定データを統合し, 空間内の任意の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

kriging というのは, 3.1 のような問題, すなわち空間内挿のために地理統計学で広く用いられる手法である. 本稿では kriging を用いて時空間内挿を行い, 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, その後にその特徴について論じる. なお, kriging は通常空間内挿の方法として用いる. 本稿ではこれを拡張した時空間 kriging を最初に用いるが, まずは簡単のために空間 kriging についてまとめ, それを時空間に拡張していく.




図 1 variogram の例 [18]

#### 3.2.1 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

\*2 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.

\*1 Creek watch. <http://creekwatch.researchlabs.ibm.com/>, Last accessed on 10 Jan 2019.

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  $\vec{r}_i$  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,  $\lambda_i$  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  $\lambda_i$  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.

### 3.2.2 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ーノード  $i (i = 1, \dots, N)$  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\*3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.

### 3.2.3 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,  $\gamma$  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  $h$  にまで拡張するために,  $h$  に対して  $\gamma$  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  $\gamma$  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.

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

### 3.2.4 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  $E \left[ (\hat{z} - z)^2 \right]$  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,

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

このように表すことができる. これを kriging variance と呼ぶ [18].

上記からわかるように, kriging の特徴は, 対象とするパラメータの空間的な自己相関を取り出して内挿を行え, 内挿の信頼度を簡単に計算できる点である.

### 3.2.5 時空間 kriging への拡張

上記で空間内挿の方法として導入した kriging を今度は時間軸, 空間軸方向に同時に行う方法について考える. このような kriging の類型を時空間 kriging (spatio-temporal kriging) というが, variogram を考える際に 2 つの方法がある.

1 つ目は分離モデル (separation model) と呼ばれていて, 空間軸方向と時間軸方向の variogram を分けるという方法である. たとえば分離モデルのうちの 1 つ, BM モデルでは variogram のフィッティング関数は,

$$\gamma(h, \Delta t) = \gamma_s(h) + \gamma_t(\Delta t) + \gamma_{st}(h_{st}) \quad (6)$$

と書かれる. ただし,  $\gamma_s, \gamma_t, \gamma_{st}$  はそれぞれ, 空間軸方向, 時間軸方向, 時空間方向の variogram を表し,  $h_{st}$  は

$$h_{st} := \sqrt{h^2 + \alpha(\Delta t)^2}$$

と定義され, 時空間的距離と解釈できる. ここに,  $\alpha$  は定数.

もう 1 つは非分離モデル (non-separation model) と呼ばれ, ここでは時空間軸の variogram を分けない. たとえば非分離モデルの 1 つである Cressie-Huang model では,

$$\gamma(h, \Delta t) = \begin{cases} 0 & (h = \Delta t = 0) \\ C_0 + \sigma^2 \left[ 1 - \frac{C_t \Delta t + 1}{\left[ (C_t \Delta t)^2 + C_s^2 h^2 \right]^{3/2}} \right] & (\text{otherwise}) \end{cases} \quad (7)$$

とする [19].

Lin ら [20] は分離モデル, 非分離モデルの中からいくつかの類型, 合わせて 6 つを北京市における PM<sub>2.5</sub> の大気中濃度の時空間内挿において比較した. その結果, 分離モデルの 1 つである BM モデルが variogram のプロットに対してもっとも良いフィッティングを与えることがわかった. そこで, 本研究でも BM モデルを用いて variogram のフィッティングを行う.

こうして求めた  $\hat{\gamma}$  を用いて,

\*3 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.

$$\hat{z}(\vec{x}, t) = \sum_i \lambda_i z(\vec{x}_i, t_i) \quad (8)$$

と  $(\vec{x}, t)$  における値を推定するときの重みを, 式 (4) を時空間方向に拡張して求める. すなわち,

$$\forall j; \sum_i \lambda_i \hat{\gamma}(h_{ij}, \Delta t_{ij}) - \phi = \hat{\gamma}(h_{0j}, \Delta t_{0j}) \quad (9)$$

をとけば良い. ここに,  $h_{ij} := |\vec{x}_i - \vec{x}_j|$  である. なお, 上記 2 式の和の中のダミーインデックスが各々のセンサノード, あるいはその場所について走るのではなく, 一度ずつの測定について走ることに注意する. このように重み  $\{\lambda_i\}_i$  を求め, 内挿を行うとき, kriging variance は次のように求められる:

$$\hat{\sigma}_e^2(\vec{x}, t) = \sum_i \hat{\lambda}_i \hat{\gamma}(h_{i,0}, \Delta t_{i,0}). \quad (10)$$

### 3.3 時空間 kriging における KVG 法

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  $\hat{\sigma}_{e,\text{tot}}^2 := \int dS \hat{\sigma}_e^2$  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 (10) のように時空間 kriging における kriging variance が求められるとき, これをセンサノードの配置に利用する方法を考える.

式 (4) から明らかにわかるように, センサノードのある点における重みはそのセンサノードを  $i_0$  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,

$$\hat{\sigma}_e^2(\vec{x}_{i_0}) = \hat{\gamma}(0). \quad (11)$$

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, 次回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,  $\hat{\sigma}_{e,\text{tot}}^2$  が小さくなるということがわかる. したがって, kriging variance の空間方向の gradient を用いて最急降下法的にノードの移動方向を決めることを考える.

$t = t_{\text{now}}$  までの測定値を使って,  $t = t_{\text{next}}$  の配置を行うとして, センサノードが  $\vec{x}_{\text{sensor}_i}$  ( $i = 1, \dots, N$ ) にあるとすると,  $\vec{x}_{\text{sensor}_i}$  にあるセンサを動かすべき方向  $\vec{e}_i$  は,

$$\vec{e}_\theta = \arg \max_{|\vec{e}_\theta|=1} \left\{ (\nabla_{\vec{x}} \hat{\sigma}_e^2(\vec{x}, t)) \cdot \vec{e}_\theta \Big|_{\vec{x}=\vec{x}_{\text{sensor}_i}, t=t_{\text{now}}} \right\} \quad (12)$$

として求められる. ただしここで,

$$\nabla_{\vec{x}} := \begin{pmatrix} \frac{\partial}{\partial x} & \frac{\partial}{\partial y} \end{pmatrix}$$

は空間方向についてのみの gradient を求めている, 時間方向は含まず,  $\vec{e}_\theta$  は空間軸の 2 次元平面上のベクトルである.

以上のように時空間上の各点における測定を内挿し, 各センサノードの存在する点での kriging variance gradient (KVG) を求めることで, それぞれのノードの移動方向を決めることができる.

## 4. 評価

### 4.1 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 2 次元の時空間変化するスカラー場を作り,  $t = 0$  から  $t = 9$  の間相異なる 5 個のセンサを用いてその時空間上の無作為な 5 点でそれぞれ 1 回ずつ測定を行う. これに加えて, KVG を用いて決めた  $t = 10$  におけるセンサの移動先 5 点でのセンシングの結果を合わせた計 10 のセンシングデータを時空間 kriging によって内挿し,  $t = 10$  におけるスカラー場を推定する. この場の推定と真値との MSE (Mean Squared Error) を調べて, 移動をランダムに行った場合と比較し, 提案手法の優位性を調べる.

#### 4.1.1 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位置を決めた.




図 2 シミュレーションを行った空間

#### 4.1.2 スカラー場

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ー場  $\Psi(\vec{x})$  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ー場

$$\begin{aligned} \Psi(\vec{x}) &= \sum_{i=1}^3 \Psi_i(\vec{x}) \quad (13) \\ &= \sum_{i=1}^3 \frac{c_i}{2\pi\sqrt{\det V_i}} \\ &\quad \times \exp\left[-\frac{1}{2} {}^t(\vec{x} - \vec{\mu}_i) V_i^{-1} (\vec{x} - \vec{\mu}_i)\right] \quad (14) \end{aligned}$$

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、 $c_i$  はスカラーの定数である。この混合 Gauss 分布のパラメタを時間変化させることで、スカラー場の時間変化を実現した。各々のパラメタについて、 $t = 0$  における値と  $t = 10$  における値を決め、それらを、経過時間に応じて内分する。すなわち、あるパラメタ  $A$  について、

$$A(t) = \frac{10-t}{10-0} A(t=0) + \frac{t-0}{10-0} A(t=10) \quad (15)$$

として、時刻  $t$  における値を決める。パラメタの初期値は1, 終値は2とした。

$i$	$c_i$	$\mu_i$	$\Sigma_i$
1	1.0	$\begin{pmatrix} -12 \\ 2.0 \end{pmatrix}$	$\begin{pmatrix} 40 & 0 \\ 0 & 20 \end{pmatrix}$
2	1.0	$\begin{pmatrix} 20 \\ 10 \end{pmatrix}$	$\begin{pmatrix} 20 & 0 \\ 0 & 40 \end{pmatrix}$
3	-30	$\begin{pmatrix} 0 \\ -60 \end{pmatrix}$	$\begin{pmatrix} 200 & 0 \\ 0 & 400 \end{pmatrix}$

表 1  $t = 0$  における Gauss 分布の各パラメタ

#### 4.1.3 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  $\Psi$  の値を得た。そして各々のセンサーノードは移動し、次

$i$	$c_i$	$\mu_i$	$\Sigma_i$
1	5	$\begin{pmatrix} 10 \\ -2.0 \end{pmatrix}$	$\begin{pmatrix} 40 & 0 \\ 0 & 20 \end{pmatrix}$
2	-20	$\begin{pmatrix} -16 \\ 10 \end{pmatrix}$	$\begin{pmatrix} 200 & 0 \\ 0 & 400 \end{pmatrix}$
3	1.0	$\begin{pmatrix} 40 \\ -10 \end{pmatrix}$	$\begin{pmatrix} 400 & 0 \\ 0 & 200 \end{pmatrix}$

表 2  $t = 10$  における Gauss 分布の各パラメタ

の点における測定を行う。この際、移動の距離  $\Delta r$  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ー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  $\Delta r$  と  $\theta$  の定義

#### 4.1.4 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  $\Delta r$  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。

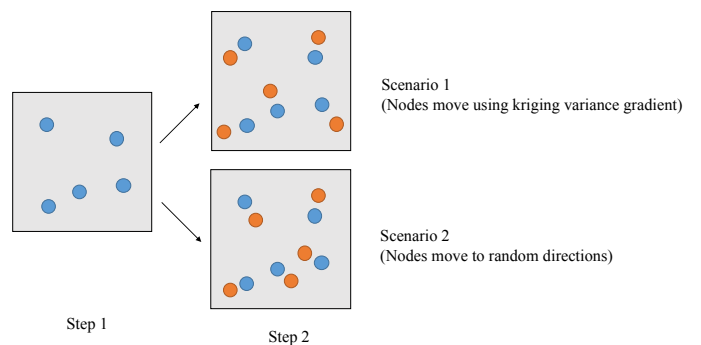


図 5 各センサーノードの動かし方

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、

$$\theta = \arg \max_{\theta} \left[ V(\vec{x}_i(t_1)) - V(\vec{x}_i(t_1) + d\vec{e}_{\theta}) \right]^2 \quad (16)$$

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、gradient 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 gradient の代わりに用いている。このため  $\hat{e}_\theta$  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  $\theta$  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。

#### 4.2 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

$$\delta_{\text{tot}} := \sum_{j \in J} [\hat{z}(\vec{r}_j) - \Psi(\vec{r}_j)] \quad (17)$$

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は2つあり、移動ステップの幅  $\Delta r$  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  $\delta_{\text{tot}}$  の大小を比較した。

$\Delta r$  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  $\delta_{\text{tot}}$  の比較を行った。

#### 4.3 シミュレーションの結果

図6に、試行1000回のうち、提案手法において  $\delta_{\text{tot}}(t=10)$  が小さくなった試行の割合を示した。95%CIを考慮して、ランダムに決めた際よりKVG法を用いた方が有意に良い推定を与えている領域があることがわかる。また、[17]のシミュレーションと比較して、KVG法とランダムな手法の場の推定の精度の差が小さくなっている。これは次元が増えたことによってより多くの測定点が必要になり、kriging自体の精度が下がっていることに対応すると思われる。あるいは、時間について、過去のセンシングデータをもとに現在あるいは未来のkrigingを行うということで、内挿ではなく外挿となっていることに対応すると思われる。



図6 シミュレーションの結果

周りの測定点のセンシングデータの線形和によって値を推定するという構造上、特に他の測定点から離れた点での外挿に対してordinary krigingはあまり正確な推定を与えない。そのため[21]で考えられているように、krigingの外からモデルを与えることでこの点を改善できる可能性がある。すなわち、今回はnaïveに3軸方向のkrigingを実装したが、時間方向についてはたとえば気温であれば、各点について「午前中は上昇し14時に最大になり夜にかけて下降する」という概形がある程度予想されるので、データ同化の要領でこれを事前にモデルに組み込むことで内挿の精度をさらにあげることができると考えられる。

#### 5. 結論

本稿では、KVGを用いたノード移動の方法を時間方向にも拡張することを試みた。すなわち、時間変化するような測定対象に対してもKVG法を用いられるようなスキームを考えた。krigingをnaïveに時空間に拡張する時空間krigingにおいて同様にKVGを定義しそれによってセンサーノードの移動を行うと、シミュレーションでは確かにランダムなノードの移動に比べて良い内挿の精度を与えたが、空間krigingでのKCG法に比べると提案手法の優位性は小さかった。時間方向の内挿や外挿について、ア prioriにモデルを与えるなどの工夫をすることでこの点の改善ができると考える。

#### 参考文献

- [1] 総務省：情報通信白書，日経印刷，Tokyo, Japan (2017).
- [2] Ganti, R., Ye, F. and Hei, H.: Mobile crowdsensing: Current state and future challenges, *IEEE Communications Magazine*, Vol. 49, No. 11, pp. 32–39 (online), DOI: 10.1109/MCOM.2011.6069707 (2011).
- [3] Liu, J., Shen, H., Narman, H. S., Chung, W. and Lin, Z.: A survey of mobile crowdsensing techniques: A critical component for the internet of things, *ACM Transactions on Cyber-Physical Systems*, Vol. 2, No. 3, p. 18 (2018).
- [4] McKercher, G. R. and Vanos, J. K.: Low-cost mobile air pollution monitoring in urban environments: a

- pilot study in Lubbock, Texas, *Environmental Technology*, Vol. 39, No. 12, pp. 1505–1514 (online), DOI: 10.1080/09593330.2017.1332106 (2018).
- [5] Lin, Y., Chiang, Y.-Y., Pan, F., Stripelis, D., Ambite, J. L., Eckel, S. P. and Habre, R.: Mining Public Datasets for Modeling Intra-City PM<sub>2.5</sub> Concentrations at a Fine Spatial Resolution, *Proceedings of the 25th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, SIGSPATIAL'17, New York, NY, USA, ACM, pp. 25:1–25:10 (online), DOI: 10.1145/3139958.3140013 (2017).
- [6] Sullivan, C. J.: Radioactive source localization in urban environments with sensor networks and the Internet of Things, *2016 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*, IEEE, pp. 384–388 (online), DOI: 10.1109/MFI.2016.7849518 (2016).
- [7] Holden, Z. A., Swanson, A., Klene, A. E., Abatzoglou, J. T., Dobrowski, S. Z., Cushman, S. A., Squires, J., Moisen, G. G. and Oyler, J. W.: Development of high-resolution (250 m) historical daily gridded air temperature data using reanalysis and distributed sensor networks for the US Northern Rocky Mountains, *International Journal of Climatology*, Vol. 36, No. 10, pp. 3620–3632 (online), DOI: 10.1002/joc.4580 (2016).
- [8] Kim, B., Seo, D. J., Noh, S. J., Prat, O. P. and Nelson, B. R.: Improving multisensor estimation of heavy-to-extreme precipitation via conditional bias-penalized optimal estimation, *Journal of Hydrology*, Vol. 556, pp. 1096–1109 (online), DOI: 10.1016/j.jhydrol.2016.10.052 (2018).
- [9] Sivaraman, V., Carrapetta, J., Hu, K. and Luxan, B. G.: HazeWatch: A participatory sensor system for monitoring air pollution in Sydney, *IEEE 38th Conference on Local Computer Networks*, Sydney, Australia, pp. 56–64 (online), DOI: 10.1109/LCNW.2013.6758498 (2013).
- [10] 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).
- [11] Zhang, C. and Zhao, Y.: High Precision Deep Sea Geomagnetic Data Sampling and Recovery with Three-Dimensional Compressive Sensing, *IEICE TRANSACTIONS on Fundamentals of Electronics, Communications and Computer Sciences*, Vol. E100-A, No. 9, pp. 1760–1762 (online), available from ([https://search.ieice.org/bin/summary.php?id=e100-a\\_9\\_1760](https://search.ieice.org/bin/summary.php?id=e100-a_9_1760)) (2017).
- [12] Rana, R. K., Chou, C. T., Kanhere, S. S., Bulusu, N. and Hu, W.: Ear-Phone : An End-to-End Participatory Urban Noise Mapping System, *Proceedings of the 9th ACM/IEEE International Conference on Information Processing in Sensor Networks*, Stockholm, Sweden, pp. 105–116 (2010).
- [13] Aoki, S., Lilo, G., Shimizu, K., Iwai, M. and Sezaki, K.: Efficient System Operation and User Analysis in Participatory Environmental Sensing, *DICOMO2013 Symposium*, Vol. 2013, pp. 2–7 (2013).
- [14] Sezaki, K., Konomi, S. and Ito, M.: User Participatory Sensing for Disaster Detection and Mitigation, *Journal of Disaster Research*, Vol. 11, No. 2, pp. 207–216 (online), DOI: 10.20965/jdr.2016.p0207 (2016).
- [15] Zhang, D., Xiong, H., Wang, L. and Chen, G.: CrowdRecruiter: Selecting Participants for Piggy-back Crowdsensing under Probabilistic Coverage Constraint, *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing - UbiComp '14 Adjunct*, New York, New York, USA, ACM Press, pp. 703–714 (online), DOI: 10.1145/2632048.2632059 (2014).
- [16] 気象庁：気象業務はいま 2017, 研精堂印刷 (2017).
- [17] 中村裕一, 伊藤昌毅, 瀬崎薫：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, 情報処理学会研究報告, Vol. 2018-MBL-8, No. 26, pp. 1–6 (2018).
- [18] Burrough, P. A., McDonnell, R. A. and Lloyd, C. D.: *Principles of Geographical Information Systems*, Oxford University Press, Oxford, United Kingdom (2015).
- [19] Montero, J. M., Fernandez-Aviles, G. and Mateu, J.: *Spatial and spatio-temporal geostatistical modeling and kriging*, John Wiley and Sons, Inc., Chichester, West Sussex, UK (2015).
- [20] Lin, J., Zhang, A., Chen, W., Lin, M., Lin, J., Zhang, A., Chen, W. and Lin, M.: Estimates of Daily PM<sub>2.5</sub> Exposure in Beijing Using Spatio-Temporal Kriging Model, *Sustainability*, Vol. 10, No. 8, p. 2772 (online), DOI: 10.3390/su10082772 (2018).
- [21] Qu, H. and Fu, M. C.: Gradient Extrapolated Stochastic Kriging, *ACM Transactions on Modeling and Computer Simulation*, Vol. 24, No. 4, pp. 1–25 (online), DOI: 10.1145/2658995 (2014).