
不均一電波伝搬環境における事前知識不要な低演算量位置推定法
Low Complexity Localization Method Without Prior Knowledge About
Propagation in Nonuniform Propagation Environments

1081006

研究代表者

慶應義塾大学 理工学部 教授

大槻 知明

[研究の目的]

今日、工場ではロボットが大きな役割を果たしている。人間とロボットが共存する環境では、ロボットが人間に合わせて自立行動することが求められる。それには位置情報が必要だが、屋内ではGPSは利用できない。他の位置推定法に、センサネットワークを用いた位置推定法がある。しかし、従来法の多くは伝搬環境の事前知識を必要とし、また、均一な電波伝搬環境に対する手法である。不均一伝搬環境に対する手法もあるが、演算に時間がかかるため、工場のようなリアルタイム性が要求される環境には適さない。本研究では、ロボットの自立行動に必要な位置情報を得るために、不均一伝搬環境における事前知識不要な低演算量位置推定法について研究する。

[研究の内容、成果]

提案法は集中処理・および分散処理のどちらでも実現可能である。以下では、分散処理について説明する。

二次元の $X_m \times Y_m$ のセンサフィールド上に、位置既知であるセンサが N 個、位置を推定したいターゲットが1個、ランダムに重なることなく置かれているとする。まず、データの受け

渡しのため、センサネットワークをサイクル状に構成する。説明のため、センサに $1, 2, \dots, N$ と順に番号をつける。このときデータはセンサ $1, 2, \dots, N, 1, 2, \dots, N, 1, 2, \dots$ と受け渡される。センサ1からセンサ N までのデータ受け渡しを1サイクルとする。

受信信号強度は伝搬距離の2～4乗に反比例することが知られており、センサ i ($i = 0, 1, \dots, N$) における受信信号強度はデシベル表現で次のように表される。

$$P_i = P_0 - 10\kappa \log \frac{d_i}{d_0} + X_i \quad (1)$$

ここで、 $d_i = \|\rho - \mathbf{r}_i\|$ はセンサ i とターゲットの距離を表し、 \mathbf{r}_i はセンサ i の位置、 ρ はターゲットの座標である。 P_0 はセンサとターゲットの距離が単位距離 d_0 だけ離れた場所での受信信号強度であり、 κ は減衰係数である。 X_i は雑音であり、平均0、分散 σ^2 の正規分布に従う。

提案法では各センサにおいて尤度関数を最大とする ρ, P_0, κ をそれぞれ順に推定する。以下、 n は提案法における推定計算の反復回数、 θ^n は n 回反復した後の推定値とする。なお、提案法での反復は1つのセンサ内で ρ, P_0, κ の推定を行うこととする。

提案法において、各センサは自身のセンサ情報と他の2つのセンサの情報を用いてターゲット

の位置を推定する．センサ i はセンサ $i-1$ ，センサ $i-2$ の情報を用いるため，センサ $i-1$ はセンサ情報 $\{P_{i-2}, \mathbf{r}_{i-2}\}$ ， $\{P_{i-1}, \mathbf{r}_{i-1}\}$ と，推定値 $\{\hat{\rho}^{i-1}, \hat{P}_0^{i-1}, \hat{\kappa}^{i-1}\}$ をセンサ i に送信する．センサ i ではこれらの情報を用いてターゲットの位置を推定し，同様にセンサ情報 $\{P_{i-1}, \mathbf{r}_{i-1}\}$ ， $\{P_i, \mathbf{r}_i\}$ ，推定値 $\{\hat{\rho}^i, \hat{P}_0^i, \hat{\kappa}^i\}$ をセンサ $i+1$ に送信する．

センサ i における負の尤度関数 $\ell(\theta)_i$ は次のように表される．

$$\ell(\hat{\theta})_i = \sum_{k=i-2}^i \left\{ P_k - P_0 + 10\kappa \log \left(\frac{d_k}{d_0} \right) \right\}^2 \quad (2)$$

提案法は未知パラメータが3つあるため，推定値の更新計算法として3通りが考えられる．

更新計算1では，1つのセンサ内で $[\hat{P}_0 \ \hat{\kappa}]$ と $\hat{\rho}$ を順に一度ずつ更新する．初めのセンサでは，初期値 ρ^0 を用いて $\ell(\hat{\theta})_i$ を最小にする $[\hat{P}_0^1 \ \hat{\kappa}^1]$ を推定し，次にその $[\hat{P}_0^1 \ \hat{\kappa}^1]$ を用いて $\ell(\hat{\theta})_i$ を最小にする $\hat{\rho}^1$ を推定する．同様にセンサ i では，センサ $i-1$ より得られた $\hat{\rho}^{i-1}$ を用いて $\ell(\hat{\theta})_i$ を最小にする $[\hat{P}_0^i \ \hat{\kappa}^i]$ を推定し，次にその $[\hat{P}_0^i \ \hat{\kappa}^i]$ を用いて $\ell(\hat{\theta})_i$ を最小にする $\hat{\rho}^i$ を推定する．

更新計算2では，1つのセンサ内で \hat{P}_0 と $[\hat{\rho} \ \hat{\kappa}]$ を順に一度ずつ更新する．初めのセンサでは，初期値 ρ^0 と κ^0 を用いて式(3)から \hat{P}_0^1 を計算し，次にその \hat{P}_0^1 を用いて $\ell(\hat{\theta})_i$ を最小にする $[\hat{\rho}^1 \ \hat{\kappa}^1]$ を推定する．同様にセンサ i では，センサ $i-1$ より得られた $\hat{\rho}^{i-1}$ と $\hat{\kappa}^{i-1}$ を用いて式(3)から \hat{P}_0^i を計算し，次にその \hat{P}_0^i を用いて $\ell(\hat{\theta})_i$ を最小にする $[\hat{\rho}^i \ \hat{\kappa}^i]$ を推定する．

$$\hat{P}_0^i = \frac{1}{3} \sum_{k=i-2}^i \left\{ P_k + 10\hat{\kappa} \log \left(\frac{\hat{d}_k}{d_0} \right) \right\} \quad (3)$$

更新計算3では，1つのセンサ内で $[\hat{\rho} \ \hat{P}_0]$ と $\hat{\kappa}$ を順に一度ずつ更新する．初めのセンサでは，初期値 κ^0 を用いて $\ell(\hat{\theta})_i$ を最小にする $[\hat{\rho}^1 \ \hat{P}_0^1]$ を推定し，次にその $[\hat{\rho}^1 \ \hat{P}_0^1]$ を用いて式(4)から $\hat{\kappa}^1$ を計算する．同様にセンサ i では，センサ $i-1$ より得られた $\hat{\kappa}^{i-1}$ を用いて $\ell(\hat{\theta})_i$ を最小に

する $[\hat{\rho}^i \ \hat{P}_0^i]$ を推定し，次にその $[\hat{\rho}^i \ \hat{P}_0^i]$ を用いて式(4)から $\hat{\kappa}^i$ を計算する．

$$\hat{\kappa}^i = \frac{1}{3} \sum_{k=i-2}^i \left\{ \frac{\hat{P}_0 - P_k}{\log \left(\frac{\hat{d}_k}{d_0} \right)} \right\} \quad (4)$$

提案法では以上の更新計算を各センサでそれぞれ行い，任意に定めた K サイクル分推定値を更新した後，ターゲットの推定位置を決定する．分散型では，集中型と違い，一回の反復計算において一部のセンサの情報しか用いないため雑音の影響を受け，サイクル数が増えても推定値 $\hat{\rho}$ が一定の値に収束しない．この雑音の影響を低減するため，提案法では平均推定座標を導入する．これは2サイクル目以降に各センサが推定したターゲットの位置を平均するものであり，1サイクル目の推定結果は実際のターゲットの位置から大きく離れている可能性があるため平均には含めない．

[計算機シミュレーションによる特性評価]

提案法と従来の集中位置推定法の特性を計算機シミュレーションにより評価した．フィールドサイズを $10 \text{ m} \times 10 \text{ m}$ とし，センサを10個，ターゲットを1個，試行ごとにランダムに配置する．単位距離 d_0 は 1 m とし，単位距離における受信信号強度は $P_0 = 0 \text{ dBm}$ とする．また雑音は $\mathcal{N}(0, 0.5)$ ，サイクル数は10，試行回数は10000回とする．なお，初期値 $\hat{\rho}^0$ はRSSIが最大値を示すセンサの付近とし，初期値 $\hat{\kappa}^0$ は3.0とする．また，他のシミュレーション結果から， $\Delta\kappa = 0.1$ と $\Delta\rho = 0.5$ を標準刻み幅として用いる．

提案法における推定精度と消費電力を考察するため，各更新計算についていくつかの計算量におけるRMSE特性を評価した．以下，提案法における演算量のうち大部分を占める最小尤度の比較回数を“計算量”とする．なお集中型に関しても，一回の反復で行われる最大尤度の比較回数を計算量とする．計算量は刻み幅に依存するが，各更新計算が標準刻み幅を用いる際に必要

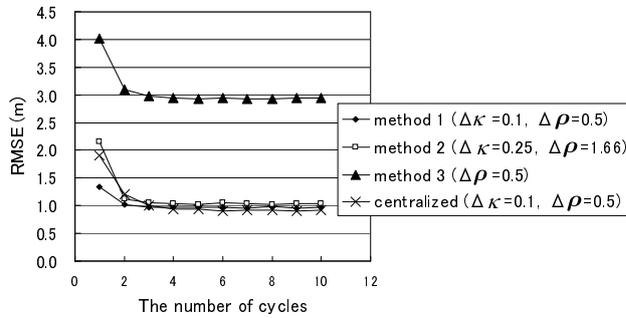


図 1: 計算量 400 回における更新計算 1, 2, 3 の RMSE 特性

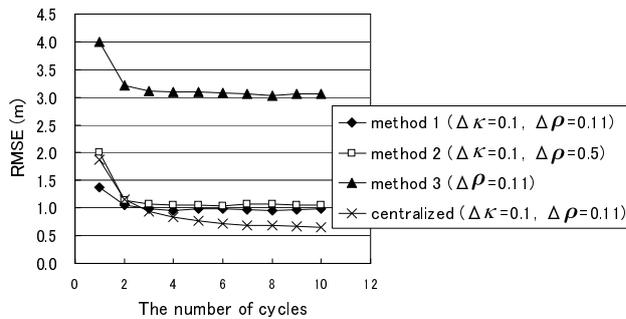


図 2: 計算量 8000 回における更新計算 1, 2, 3 の RMSE 特性

とする計算量, すなわち約 400, 8000 回のそれぞれで位置を推定し, その RMSE 特性を評価した.

図, に, それぞれ計算量が 400, 8000 回の際の RMSE 特性とサイクル数の関係を示す. いずれの結果についても推定値はサイクル数 5 で十分収束していると言え, これより推定値としてサイクル数 5-10 における RMSE 特性を平均したものを評価する.

表 1 に, 各計算量における更新計算 1, 2, 3 の推定値を示す. 各更新計算の刻み幅は標準刻み幅, または計算量に応じて最も推定精度が高くなる刻み幅に設定する. 表 1 より更新計算 1 がどちらの計算量においても高い推定精度を示すことが分かる. 推定値に差が生じた理由として, 更新計算 1, 2, 3 の初期値はそれぞれ ρ^0 , $[\rho^0 \kappa^0]$, κ^0 であり, これらの初期値により尤度関数の変数, 定数が決定されることが挙げられ

表 1: 計算量 400, 8000 回における更新計算 1, 2, 3 の RMSE 特性

	RMSE (m)	
	400 times	8000 times
method 1	0.97 ($\Delta\kappa=0.1, \Delta\rho=0.5$)	0.98 ($\Delta\kappa=0.1, \Delta\rho=0.11$)
method 2	1.03 ($\Delta\kappa=0.25, \Delta\rho=1.66$)	1.06 ($\Delta\kappa=0.1, \Delta\rho=0.5$)
method 3	2.94 ($\Delta\rho=0.5$)	3.07 ($\Delta\rho=0.11$)
centralized	0.95 ($\Delta\kappa=0.1, \Delta\rho=0.5$)	0.70 ($\Delta\kappa=0.1, \Delta\rho=0.11$)

る. 更新計算 3 の精度が劣化する理由として以下が考えられる. 更新計算 3 は $[\hat{\rho} \hat{P}_0]$ を推定する際, $\hat{\rho}$ を変数として \hat{P}_0 を導出する. このとき, $\hat{\rho}$, すなわち \hat{d} は \hat{P}_0 に log 関数として作用するため, 特に $\hat{d} < d_0$ のとき \hat{P}_0 の誤差が大きくなり, 結果 $\hat{\rho}$ の精度が劣化すると考えられる. また, どの更新計算についても, 計算量が 400 回の際の刻み幅は計算量が 8000 回の際の刻み幅より大きく荒くなっているが, RMSE 特性はどちらの計算量についてもほぼ同じである. これは, 刻み幅が大きいと推定値の候補となる値の数は少ないが, 平均推定座標を用いているため実際のターゲットの位置に近い推定結果が得られたと考えられる.

以上より, 提案法の分散型で実装する場合, 更新計算 1 が少ない計算量で高い推定精度を得られることが分かる.

[実験による特性評価]

提案法による RMSE 特性を Crossbow 社の MICAz を用いた実験により評価した. 実験には床面が 5.0 m × 5.0 m で, 高さが 3.0 m の部屋を利用し, フィールドサイズを 5 m × 5 m, センサが 8 個, ターゲットが 1 個とした. 部屋の床はカーペットであり, 壁は 1 面が窓, その他の 3 面がコンクリートである. センサは図 3 のよ

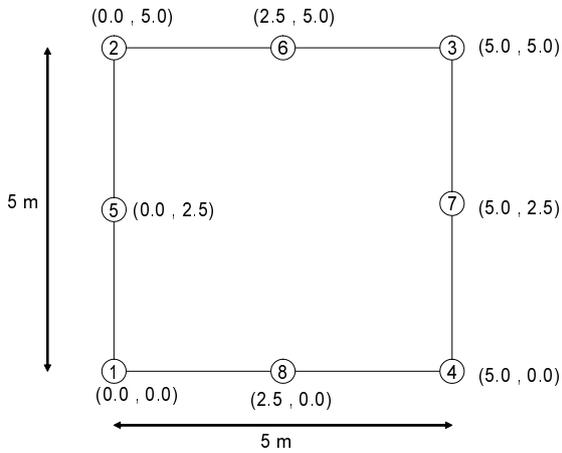


図 3: センサフィールドとセンサの配置

うに配置し、ターゲットはフィールドの四隅を除いた $(0, 1), (0, 2), \dots, (5, 3), (5, 4)$ の 32 通りに配置し、それぞれにおいて各センサが RSSI を測定しターゲットの位置を推定した。各更新計算における刻み幅はシミュレーション結果により $\Delta\kappa = 0.1, \Delta\rho = 0.5$ とした。このとき更新計算 1, 2, 3, 集中型位置推定法が必要とする計算量はそれぞれ約 400, 8000, 400, 400 回である。

図 4 に実験による各更新計算の RMSE 特性とサイクル数の関係を示す。ここで RMSE 特性は 32 通りの推定結果を平均したものである。図 4 より、シミュレーション結果と同様、提案法はサイクル数の増加とともに RMSE 特性が向上することが分かる。また、提案法を分散型で実装する場合、更新計算 1 が最も位置推定精度が高いことが分かる。

[今後の研究の方向、課題]

本研究課題では、ロボットの自立行動に必要な位置情報を得るために、不均一伝搬環境における事前知識不要な低演算量位置推定法について研究した。不均一環境において、事前知識不要で、かつ低演算量で位置推定を行うために、伝搬環境に関するパラメータ及び位置を、3つのセンサノードセットで推定し、その情報を受け渡し更新していく手法を提案した。提案手法

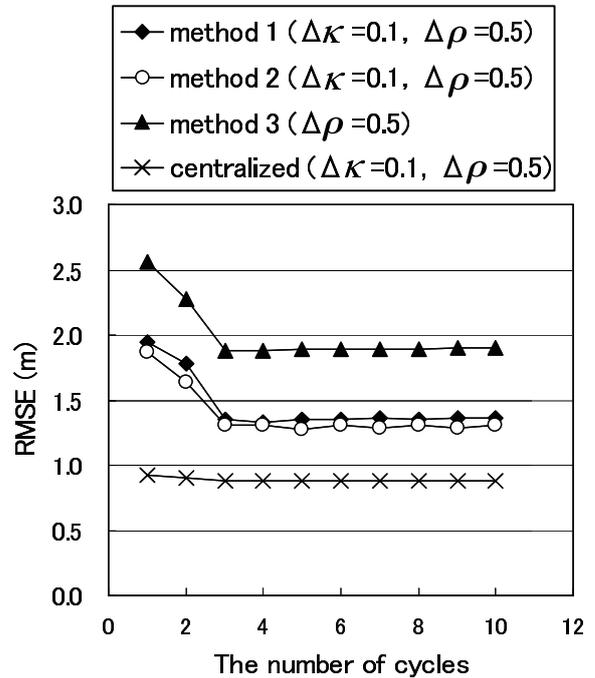


図 4: 実験における更新計算 1, 2, 3 の RMSE 特性

を計算機シミュレーションおよび実験により評価し、提案手法の有効性を評価した。今回報告した以外にも、TOA 情報と RSSI 情報を用いた事前知識不要な位置推定法を提案し、計算機シミュレーションにより、その有効性を確認した。今後の課題として、工場などの実際の環境でより精度の高い位置推定精度を得るための改善があげられる。

[成果の発表、論文等]

- [1] T. Mogi and T. Ohtsuki, "TOA Localization using RSS Weight with Path Loss Exponents Estimation in NLOS Environments," The 14th Asia-Pacific Conference on Communications (APCC2008), Akihabara, Japan, Oct. 2008.
- [2] Y. Nishi and T. Ohtsuki, "A Distributed Localization with Unknown Attenuation Coefficient in Wireless Sensor Networks," The 14th Asia-Pacific Conference on Communications (APCC2008), Akihabara, Japan, Oct. 2008.