

スマートフォンを用いたクラウドソーシングによる屋内地図の自動生成

Automatic Generation of Indoor Maps using Crowdsourcing with Smartphones

学籍番号 47-136733

氏 名 稲葉 瞳 Inaba, Hitomi

指導教員 瀬崎 薫 教授

1. 研究背景・目的

近年、クラウドソーシングを用いたサービスやプロジェクトが盛んに行われている。その中でも地図の生成プロジェクトとして OpenStreetMap(OSM)がある。地図のプロバイダーは大きく Web map service と Crowdsourcing-based map の二つに分かれており、Web map service の一つとして Google Maps と Crowdsourcing-based map の一つとして OSM が挙げられる。この2つを地図上の情報量で比べたとき、正確な地図情報の提供を行っている会社があるため、Google Maps の方が多いのに対し、場所によってはクラウドソーシングの参加者が多いと OSM の方が多く情報量をもつ。しかし、クラウドソーシングの場合、地図のトレース作業が手作業であるため、精度や信頼性はその参加者達に依存してしまう。

本研究では、屋内地図に焦点を当てる。屋内測位の精度の向上、トレース作業の自動化を実現するために、スマートフォンを用いたクラウドソーシングによる歩行者データから、Pedestrian Dead Reckoning(PDR)を用いて高精度の軌跡を取得する。そして、屋内の構造物の検出を行うことで、パラメトリックとノンパラメトリックの基盤地図の自動生成を行う手法を提案し、その手法を評価する。

2. 既存研究・本研究の要件

PDR の手法を利用して測位精度を高める研究は盛んに行われている。Stirling[1]は靴にセンサを内蔵し細かく歩幅や歩長を推定する PDR を行っている、垣内[2]は PDR を行うにあたって歩行者の移動状態から歩幅を推定し、磁場ベクトルの偏向量の分布地図を用いてマップマッチングを行っている。

構造物検出の研究では、K Zhabg ら[3]は屋内の Wi-Fi のビーコンを特定の方向にだけ送ることで、スマートフォンとビーコンの角度から場所を推定し交差点やドアを検出している。また、屋内地図の自動生成の研究で、SLAM を用いたロボットの自己位置推定や、レーザースキャナを用いたものなど、画像処理を用いた地図生成が盛んである。

本研究では、高価なデバイスではなくスマートフォンのみを用いて安価により現実的に行う。また、建物構造の特徴条件を取り入れ屋外と屋内で異なる PDR のシステムモデルを適用する。取得した歩行者の軌跡データからは構造物の検出を行い、地図の自動生成を行う。構造物の検出要件として、位置の推定誤差が 2.89m 以下で CEP-67%を満たすこととする。

3. 手法

提案手法の流れを以下に示す。

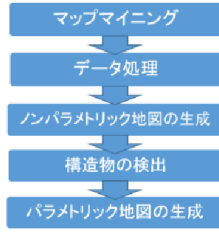


図1. 手法フロー

図1の手法の詳細をセクション毎に以下で説明する.

3.1. マップマイニング

既存の地図のメタデータは殆どカラーで、特別なランドマークがついていることが多い. バイナリ地図を作成するにあたり、初めに地図のカラーである場所を検出し、そのカラーが屋内外どちらに属しているかを見ることで、屋内外のバイナリ地図を生成する. これにより既存の地図から屋内の白地図が生成可能となる.

3.2. データ処理

屋外ではPDRとGPSのデータをExtended Kalman Filter(EKF)により統合し位置を推定する. 屋内ではGPSの精度が低いためPDRに建物構造の特徴を条件に加え位置を推定する. PDRの初期値で自分の歩幅や閾値を設定するため、既存手法で行われているような複雑なステップや進行方向の検出をしない. 初めに屋外モデルの導出式を示す.

$$\mathbf{x} = [X, Y, H]^T$$

$$X(t+1) = X(t) + (L + w_L(t)) \cos(h(t))$$

$$Y(t+1) = Y(t) + (L + w_L(t)) \sin(h(t))$$

$$H(t+1) = H(t) + T(t)\omega_z(t) + w_z(t)$$

GPSは精度値が5m以下のときの値のみを使用する. PDRの屋内モデルを以下に示す.

$$X(t+1) = X(t) + L(t) \cos(h(t))$$

$$Y(t+1) = Y(t) + L(t) \sin(h(t))$$

$$H(t+1) = H(t) + T(t)\omega_z(t) + b_z(t) + w_z(t)$$

$$L(t+1) = L(t) + w_L(t)$$

$$b_z(t+1) = b_z(t) + w_b(t)$$

X, Y は位置, H は進行方向, L はステップ長, ω_z はジャイロスコープ, $T(t)$ はステップ t 毎の時間, $w_L(t)$ はステップ長におけるプロセスノイズ, $w_z(t)$ はジャイロにおけるプロセスノイズ, $b_z(t)$ はジャイロバイアス, $w_b(t)$ はジャイロバイアスにおけるプロセスノイズである.

上記の屋内モデルに以下の条件を加えフィルタリングを行う.

- ・磁気強度 $\geq 30\mu T$
- ・ジャイロスコープの値が ± 0.5 以上の時に角度を 90 度の倍数に補正する

ジャイロスコープの値の補正は、学校などの建物の構造上、90度のターンが多いことを考慮した.

3.3. 地図の生成

PDRシステムで得られた軌跡をもとに、エントランスと交差点の検出を行いパラメトリックとノンパラメトリックの基盤地図を生成をする. 基盤地図とは、この研究ではエントランスと交差点と廊下といった構造上基盤となる構造物のみの地図と定義する.

3.3.1. ノンパラメトリック地図の生成

2次元正規分布を用い、ヒートマップを作成することをノンパラメトリック地図の生成とする. 取得した各データセットで求められた位置に2次元正規分布を適用することで生成される. 以下に概要を示す.

2次元正規分布

$$f(x, y) = \frac{1}{2\pi\sigma_k^x\sigma_k^y} e^{-\frac{1}{2}\left\{-\left(\frac{x-\mu_k^x}{\sigma_k^x}\right)^2 + \left(\frac{y-\mu_k^y}{\sigma_k^y}\right)^2\right\}}$$

$$\mu_k^x = \mu_k^y = 0$$

$$\sigma_k^x = \sigma_{initE} + \sum_{k=2}^L w_k$$

$$\sigma_k^y = \sigma_{initE} + \sum_{k=2}^L w_k$$

時間 k における μ_k が平均で σ_k は各次元 x, y における標準偏差である. σ_{initE} は σ の初期位置で GPS の精度の閾値である 5m である. 屋内に入ればセンサの誤差が蓄積されることを考慮し, σ_k にステップ長のプロセスノイズ w_k を総ステップ数 L までステップ毎に追加していくことにした.

3.3.2. パラメトリック地図

パラメトリック地図はノードとパスで構成される.

3.3.3. ノード検出

各軌跡でノードにあたる入口と交差点を検出した後, 全軌跡のノードを統合し各ノードに 2 次元正規分布を適用してヒートマップを作る. その際, 閾値を設けクラスタリング時のノイズを除去. 推定ノードが $\pm\sigma$ 以下に含まれる確率を表すカットオフ σ を設け, 一番適切な値で検出を行った. σ は $\pm1\sigma, \pm2\sigma, \pm3\sigma$, 閾値は 0.0, 0.05, 0.1, 0.15 から最適な値を設定した.

入口検出

入口の検出はバイナリ地図とデータ処理で得られた軌跡をもとに行った. 軌跡が黒(屋外)から白(屋内)に地図の色が変わった後 10 点の場所が白のままだったら屋内に入ったことを認識し, 白になった初めの点を入口と検出する.

交差点検出

交差点はバイナリ地図上で屋内にいるときにジャイロスコープの値を見ることで検出する. 値が ±0.5 以上の時にターンをしたと認識し, 交差点を検出したものとする.

3.3.4. パス検出

取得した軌跡のデータセット 1 つずつをもとに, 検出されたノードを繋げていくことで, ネットワークポロジを生成する. その

結果がパラメトリック地図となる.

4. 評価実験

上記手法を検証し, 評価するために Linköping University の B-building で実験を行った. Sensor fusion app と Quant2Orient というアプリケーションを用いて 3 人の被験者に GPS, GPS accuracy, 加速度センサ, ジャイロスコープ, 地磁気センサのデータ取得を行ってもらった. デバイスは個人の所有しているスマートフォンを用い, データ取得時は, 端末を出来るだけ地面に水平に保ち, 屋外から屋内に入り屋外に出るルートと指定し, 被験者自身でルート設定は行ってもらった.

5. 結果

5.1. データ処理

データ処理の結果を以下に示す.

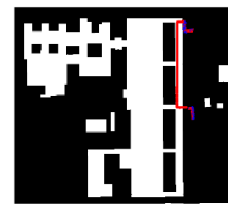


図 2. データ処理で得られた軌跡
赤が求められた軌跡で青が GPS のデータである. この結果から, 建物の構造上の特徴を条件に入れることで測位精度が向上することが分かった.

5.2. ノンパラメトリック地図

正規分布を用いて, ヒートマップを生成した. 以下, σ は $\pm2\sigma$, 閾値 0.1 と設定した.

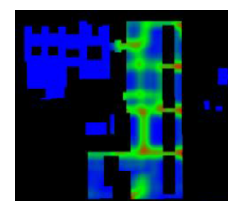


図 3. ノンパラメトリック地図

赤色部に一番データが分布しており、続いて緑、そして青の部分には1つもデータが存在していない。

5.3. ノード検出

まず、ノードのみを抽出したヒートマップを以下に示す。

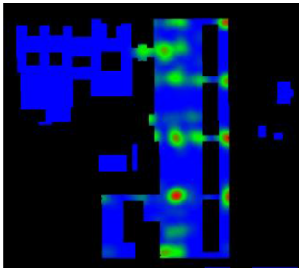


図 4. ノード抽出をしたヒートマップ
図 4 から、求められたカットオフ σ と閾値でクラスタリングを行い、ノードを検出した結果が赤い点で図 5 に示されている。

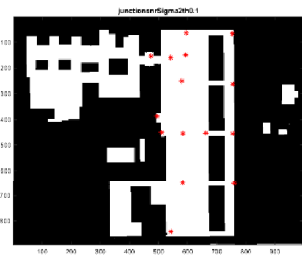


図 5. 検出されたノード
5.4. パラメトリック地図

パス検出をしたパラメトリック地図を、図 6 に示す。

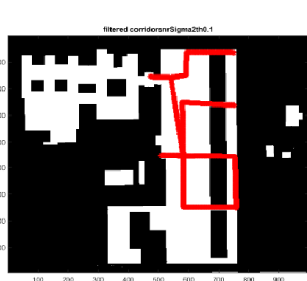


図 6. パラメトリック地図
6. 考察
カットオフ σ と閾値は以下の Cumulative

Distribution Function(CDF)の結果より求められた。

表 1. 各 σ と閾値による結果

	0.0	0.05	0.1	0.15
$\pm 1\sigma$	26	26	50%(2.76m)	15
$\pm 2\sigma$	8	16	67%(2.76m)	8
$\pm 3\sigma$	4	17	67%(2.76m)	8

左側に CDF の結果, 右に検出されたノード数を記している. CEP-67%を満たし且つノードが一番多く検出された値は σ が $\pm 2\sigma$, 閾値 0.1 だった. ノード検出から行われたパラメトリック地図生成の結果では, パスがすべて検出されていない. この要因として, 軌跡の数やルートの偏りが挙げられる。

7. 結論

最初に定義した要件の誤差が 2.88m における CEP-67%を満たした結果が得られた. これにより, スマートフォンのセンサのみを用いたクラウドソーシングによる地図生成が可能であると示せた。

8. 今後の課題

高精度の屋内測位を実現するためにスマートフォンでデータ取得可能な Wi-Fi を用いる事が挙げられる. また, 屋外での構造物検出をすることで, 屋内外の地図の生成も期待できる。

参考文献

[1]R G Stirling, “Development of a Pedestrian Navigation System Using Shoe Mounted Sesors”, Master thesis, University of Alberta

[2]垣内紀明, “携帯端末向け歩行者デッドレコニングの精度向上にかかわる研究”, 修士論文, 東京大学

[3] K Zhabg, H Hu, W Dai, Y Shen and M Z. Win, “Indoor Localization Algorithm For Smartphones”, <http://arxiv.org/pdf/1503.07628v1.pdf>