

移動ロボットのための階層 SFA を用いた自己位置推定の実験的評価

～学習データや走行環境の変化による影響調査～

○今中 真之 (筑波大学), 萬 礼応 (筑波大学), 大矢 晃久 (筑波大学)

Experimental Evaluation for Mobile Robot Localization with Hierarchical SFA

～Investigating the Influence of Training Data Size and Environmental Change～

○Masayuki IMANAKA (University of Tsukuba), Ayanori YOROZU (University of Tsukuba) and Akihisa OHYA (University of Tsukuba)

Abstract: A method of self-localization for a mobile robot using hierarchical SFA (Slow Feature Analysis) has been proposed. However, the applicable environmental conditions and the necessary data for learning have not been sufficiently investigated. In this report, the influences of route change and unexpected objects are verified experimentally.

1. 緒言

カメラを用いたロボットの自己位置推定には、事前に作成した地図と画像中の対応する特徴点を用いて推定する手法や画像と自己位置のデータからそれぞれの関係を学習する手法がある。また、画像と自己位置の対応関係を学習する手法では、画像中の特徴量を抽出してから自己位置と対応付けるものと、画像と自己位置を直接対応付けるものがある。特徴量と自己位置を対応付ける方法では、特徴量の抽出過程で画像中のノイズなどを除去する可能性が考えられる。そのため画像と自己位置を直接対応付ける方法よりロバストになると考えられる。

画像から特徴量を抽出する方法として Slow Feature Analysis(以下, SFA と呼ぶ)[1]がある。また, SFA で特徴量を抽出し, 位置と対応づけることで自己位置推定に適用した研究が報告されている[2]。しかし, 文献[2]では走行経路など学習データ取得方法の影響や人が画像に映り込むことで生じる位置推定への影響について十分な検証が行われていない。

そこで本研究では, 走行環境やロボットの走行経路などの条件を変化させ, 自己位置推定の影響を調査する。また, 学習時に存在しなかった人などの障害物の影響などを実験的に検証し, 階層 SFA を用いた自己位置推定の特性や課題を明らかにすることを目的とする。

2. 階層 SFA を用いた自己位置推定

SFA とは複数の時系列データの中から変化の遅い特徴量を抽出する教師なしの機械学習であり, 2002 年に Wiskott[1]らにより提案された。また SFA は入力データ

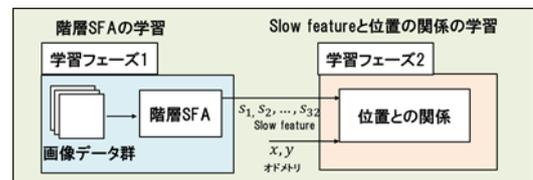


Fig 1: Learning self-localization using hierarchical SFA

の次元数に制限がないため, 画像などの次元数が大きいデータの処理にも利用することができる。しかし, SFA の計算量は入力データの次元に依存するため, 画像などの次元の大きいデータを処理する際には, SFA を階層化した, 階層 SFA を使用する。

文献[2]では, 階層 SFA の特徴量とその特徴量を取得した位置の対応づけを別途学習することで位置推定に適用している。Fig.1 に階層 SFA を用いた自己位置推定の学習過程を示す。はじめに, 学習フェーズ 1 として, ロボットが環境を走行中に取得した画像データ群から階層 SFA を学習する。次に, 学習フェーズ 2 として, 学習済み階層 SFA により抽出した特徴量と画像の取得位置から, 特徴量と自己位置の写像を学習により求めることで階層 SFA を自己位置推定に適用している。本研究では, この文献[2]の手法を適用し, 階層 SFA 学習時のデータ数, 学習時と異なる経路で走行した場合, 学習時にいなかった人による自己位置精度への影響を実験的に検証する。

3. 実験

3.1 実験概要と評価

本稿では階層 SFA を用いた自己位置推定の学習時の

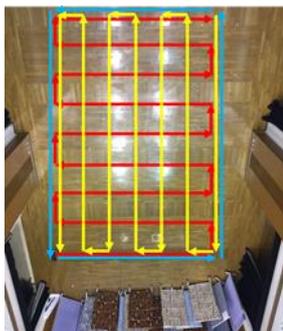


Fig.2: Experimental environment and robot trajectory

Table 1: Combination of training data and test data

学習	検証環境		人がいる環境下
	走行経路1	走行経路2	
走行経路1 × 3周	●	●	●
走行経路1 × 5周	●	●	●
走行経路2 × 1周	●	●	●

青: 学習枚数の影響 赤: 学習と実際の走行経路の違い 紫: 人の影響

データ数による影響 (検証 1), 学習時と異なる走行経路の位置推定 (検証 2), 学習時に存在しなかった障害物が及ぼす影響 (検証 3) を調査するため, 学習時のデータと検証時のデータを組み合わせ 3 種類の実験を行った. Table.1 に各実験に使用した学習時のデータと検証時のデータを示す.

また, Fig. 2 に示す検証環境 (7×9m の屋内環境) と設定したロボットの走行経路を示す. ロボットを 2 種類の経路で走行させる. Fig. 2 の青矢印で示す環境を半時計周りに一周している経路を走行経路 1 とする. また, 赤と黄色の矢印で示す格子状に走行した経路を走行経路 2 とする.

データの取得に使用したロボットを Fig.3 に示す. ロボットには全天球カメラ (RICOH THETA S®) と測域センサ (北陽電機社製 UTM-30LX®) を搭載している. また全天球カメラは高さ 0.406m, 測域センサは高さ 0.234m に設置した. ロボットは設定した走行経路を手動で走行させた. 並進速度は 0.3m/s, 旋回速度は 15deg/s とした.

Fig. 4 に示すように, 全天球カメラで取得したパノラマ画像をトリミングした 40×320pixel を入力とし, 学習フェーズ 2 の階層 SFA の特徴量から位置の写像を学習する際のロボットの自己位置は, 測域センサとエンコーダ移動情報を用いた AMCL (Adaptive Monte Carlo Localization) により取得した. また, 特徴量から位置への写像には最小二乗法を使用した.

3.2 (検証 1) 学習時のデータ数による影響

学習時のデータ数による影響を検証するため, 走行経路 1 を 6 周走行し, 画像およびロボットの自己位置のデータを取得した. 6 周分の走行データから, 3 周分

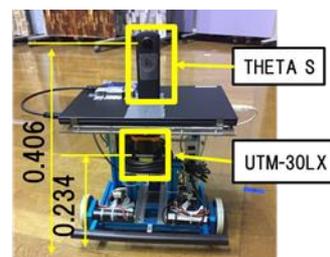


Fig.3: Robot configuration

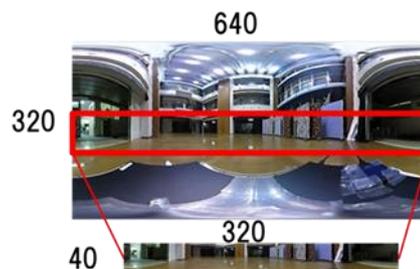
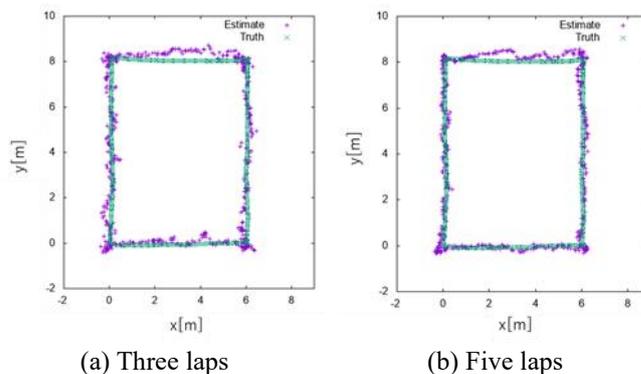


Fig.4: Input image from Omni-camera



(a) Three laps (b) Five laps
Fig.5: Influence of training data size
(Learning)Trajectory 1⇒(Test)Trajectory 1

までの走行で取得したデータと 5 周分までの走行で取得したデータを切り取り, 総数が異なる 2 種類のデータを作成した. また 3 周分までの画像数は 1578 枚で 5 周分までの画像数は 2663 枚であった. 3 周分と 5 周分のそれぞれのデータを用いて SFA 特徴量を学習した. 検証データには 6 周目に取得したデータを使用した. Fig. 5(a)と Fig. 5(b)に, それぞれ 3 周分と 5 周分のデータで学習した位置推定システムに検証データの画像を入力し, 推定した値を示す. Fig.5 より, 学習のデータ数が多いほど, 位置の精度が向上していることが確認できる.

3.3 (検証 2) 学習時と異なる経路の位置推定

学習のデータ取得時の走行経路と異なる経路のデータを入力した際の, 位置推定結果を検証する. 走行経路 1 を 6 周, 走行経路 2 を 2 周し, 画像およびロボットの自己位置のデータを取得した. 走行経路 1 の 5 周

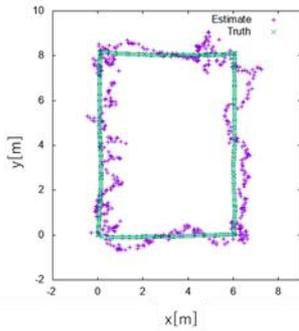


Fig .6: (Learning)Trajectory 2⇒(Test)Trajectory 1

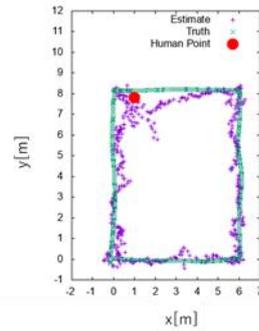


Fig .8: Results in human existing environment

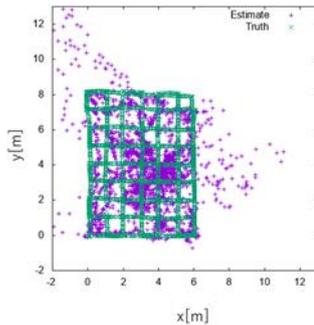


Fig .7: (Learning)Trajectory 1⇒(Test)Trajectory 2

までのデータ, 走行経路 2 の 1 周までのデータを切り取り, 学習データを作成した. また, 走行経路 1,2 の残りの 1 周のデータを検証データとした.

3.3.1 (学習) 走行経路 2⇒(検証) 走行経路 1

走行経路 1×5 周分のデータで学習したものと, 走行経路 2×1 周分のデータで新たに学習したものを使用した. また, 学習後に検証データとして走行経路 1×1 周分の画像を入力し, 位置を推定した. Fig.7 に走行経路 2×1 周分のデータを用いて学習した場合の走行経路 1 に対しての推定結果を示す. Fig. 5, 6 の比較より, 走行経路 2 は経路 1 を含むデータであるが, 学習時と同じ走行経路に特化して学習した方が, 自己位置の誤差が小さいことが確認できる.

3.3.2 (学習) 走行経路 1⇒(検証) 走行経路 2

Fig. 7 に走行経路 1×5 周分のデータで学習したものに, 検証データとして走行経路 2×1 周分の画像データを入力し, 位置を推定した結果を示す. Fig. 7 より, 学習時に通過したことがない経路に適用した場合には, 自己位置の推定が困難であることが確認できる.

3.4 (検証 3) 学習時にいなかった人の影響

人による位置推定システムの影響を確認するため, 人がいない環境のデータで学習を行った位置推定システムに, 人がいる環境で取得したデータを入力した. また出力された推定値を確認した. 位置推定システムは前節で走行経路 1×5 周で学習したものを使用した. また, 検証データは Fig. 8 の赤い位置に人がいる環境で, 走行経路 1 でロボットを走行させた場合のデータを使用した. Fig. 8 に結果を示す. Fig. 8 より, ロボットが人に近づくほど, 自己位置の誤差が大きくなる傾向があることを確認した.

4. 結言

本稿では階層 SFA を用いた自己位置推定の特性や問題点を明らかにするため, 学習時のデータ数の影響, 学習時の走行経路と異なる経路の位置推定, 学習時に存在しなかった人の影響を実験的に検証した.

今後は, 学習経路からのズレと自己位置推定の関係, 照明条件による影響などを調査していき, 画像と位置を直接対応づけた自己位置推定とロバスト性の比較を行う.

参考文献

- [1] Wiskott L, Sejnowski T :“Slow feature analysis: Unsupervised learning of invariances”, Neural Computation, Vol.14, pp.715—770(2002)
- [2] Metaka B, Franzius M :“Bio-inspired visual self-localization in real world scenarios using Slow Feature Analysis”, PLOS ONE, Vol. 13, no. 9, pp. 1-18(2018)