

# 追従ロボットのための歩行者経路予測における歩行者密度の影響度評価

赤羽根 里奈, 加藤 由花<sup>†</sup>      浅田 郁弥<sup>‡</sup>      加藤 宏一朗, 松日楽 信人<sup>§</sup>  
 東京女子大学<sup>†</sup>      芝浦工業大学<sup>‡</sup>      芝浦工業大学<sup>§</sup>

## 1 はじめに

近年, サービスロボットの普及に伴い, 人と共存するロボットに対する期待が高まっている. これらサービスロボットの一種に人物自動追従ロボットあり, 荷物の運搬や案内等, 様々な用途での利用が期待されている. 通常, 人物追従には Laser Range Scanner (LRS) 等の計測データが用いられるが, 障害物による遮蔽等でロボットが人を見失うケースが多々発生する. このような背景から, 我々はこれまで, 人の未来の移動経路を機械学習モデル (RNN (Recurrent Neural Network) ベースの手法) を用いて予測し, その結果を追従制御に利用する手法の研究を進めてきた. ここでは, 訓練データをあらかじめ収集しておくことの難しい公共空間へのロボットの設置を想定し, 公開されているデータセットを用いて予測器を構築する手法を提案した [1].

ただし, 既存の研究用データセットをそのまま利用したのみで, 訓練データ構成法については未検討であった. 訓練データは, 予測対象環境で計測されるデータと類似したデータである必要がある. 本稿では, 類似度を特徴付ける要素の1つとして, 歩行者密度に着目し, 予測精度への影響度合を評価する.

## 2 予測モデル

対象とする経路予測手法の概要を 図 1 に示す. 前述したように, ここでは, 公開されているデータ

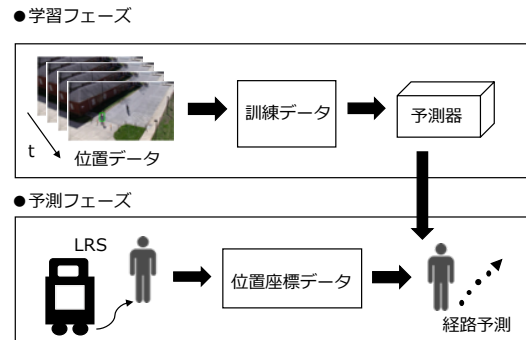


図 1 予測モデルの概要.




図 2 Social LSTM のイメージ ([3] を参考に作成).

セットを用いて予測器を構築しておき, ロボットに搭載された LRS によるセンシング結果を用いて経路を予測する. 手法は学習フェーズ (オフライン) と予測フェーズ (オンライン) の2つに分けられる.

学習フェーズでは, 画像から歩行者の位置座標を系列データとして抽出することで訓練データを構成する. その後, この訓練データを用いて予測器を構築する. 予測器の構築には文献 [2] で提案された Social LSTM を利用する ( 図 2 参照). これは, 各歩行者の軌跡を LSTM (Long Short-Term Memory) でモデル化し, 隠れ層の状態を共有することで, 人と人の相互作用をモデルに組み込む手法である.

予測フェーズでは, LRS で歩行者軌跡を計測し, 事前に構築しておいた予測器を用いて経路予測を行う. このとき, 計測データの座標系はロボットに固定されたローカル座標系である. そのため, SLAM 等で構築しておいた環境地図を用いてロボットの自己位置推定を行い, 計測データをリアルタイムでワールド座標系 (環境側の座標系) に変換する.

Evaluation of the influence of pedestrian density on trajectory prediction for a human-following mobile robot

<sup>†</sup> Rina Akabane and Yuka Kato, Graduate School of Science, Tokyo Woman's Christian University

<sup>‡</sup> Ikumi Asada, Graduate School of Mechanical Engineering, Shibaura Institute of Technology

<sup>§</sup> Koichiro Kato and Nobuto Matsuhira, Engineering Science and Mechanics, Shibaura Institute of Technology

### 3 評価実験

#### 3.1 実験の方法

本稿では、実環境での計測データと予測器構築用の訓練データ間の類似度を特徴づける指標の一例として歩行者密度を取り上げ、その影響度合を評価する。そのため、歩行者密度の異なる複数の訓練データセットを構築し、実環境で計測されたデータをテストデータとして、経路の予測精度を評価する。

訓練データとしては、歩行者密度が公開されている3種類のデータセットを用いて構成することにした。具体的には、以下の3種類である（いずれも Trajectory Forecasting Benchmark<sup>\*1</sup>から取得）、それぞれの歩行者密度をカッコ内に示す。

- DS1 : UCY Dataset (9.24)
- DS2 : ETH Dataset (5.60)
- DS3 : PETS2009 Benchmark Data (4.15)

なお、各密度は、画像内の人物専有面積をグリッドごとに確率分布として表現し、その総計値として算出されている。

テストデータとしては、実際に博物館（深川江戸博物館 (<https://www.kcg.or.jp>)）で計測したデータを用いる。なお、今回の実験では、訓練データと同様の尺度で歩行者密度を算出することができなかつたため、目視で密度の類似度を推定し、テストデータはDS1と最も類似していることを確認した。

予測精度の評価は、予測経路と真の経路とのフレームごとの誤差の平均 (Average Error)、および最終的な到達地点の予測値と真値の差 (Final Error) を用いて行う。単位はメートルである。

#### 3.2 実験の結果

実験の結果を表1に、経路予測の結果を可視化したものを図3に示す。ここからは、テストデータと類似しているデータセットでの予測結果が良好であることがわかる。また、歩行者密度が予測精度に

表1 歩行者密度と予測精度との関係。

種類	歩行者密度	Average Error	Final Error
DS1	9.24	<b>0.73</b>	<b>1.24</b>
DS2	5.60	0.79	1.32
DS3	4.15	0.81	1.51

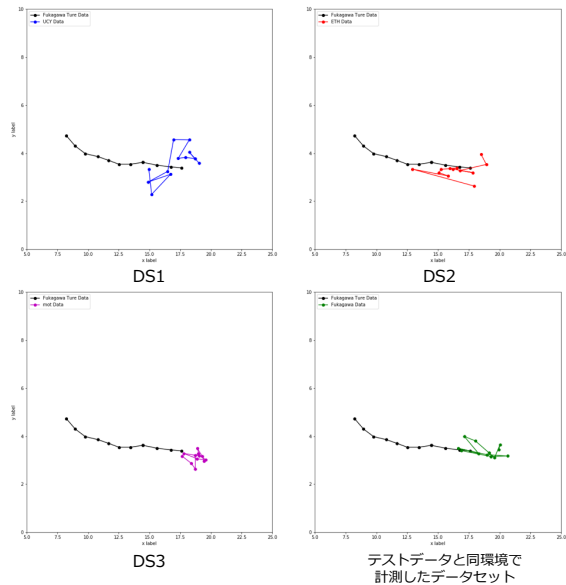


図3 データセットごとの予測結果。(黒線：真値、色付き線：予測値)

影響を与えているだろうことも推察できる。一方、テストデータの歩行者密度を目視で確認しているため、定量的な比較は不十分である。密度以外の要素が実験結果に影響を与えている可能性も大きく、今後さらなる検討が必要である。

### 4 おわりに

本稿では、人物追従ロボットのための歩行者経路予測手法において、適切な訓練データを構成するための手法について検討した。特に、歩行者密度が予測精度に影響を与えることを確認した。今後、訓練データとテストデータの特徴付ける類似度として、ロボット制御での利用という観点から、様々な特徴量を用いた実験を行っていく予定である。

### 参考文献

- [1] 赤羽根 里奈, 加藤 由花: 人物自動追従ロボットのための機械学習による歩行者経路予測手法, 情報処理学会マルチメディア通信と分散処理ワークショップ, pp. 62–67 (2019).
- [2] Alahi, A., Goel, K., Ramanathan, V., Robicquet, A., Fei-Fei, L., Savarese, S.: Social LSTM: Human Trajectory Prediction in Crowded Spaces, *Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016)*, pp. 961–971 (2016).
- [3] Gupta, A., Johnson, J., Fei-Fei, L., Savarese, S., Alahi, A.: Social GAN: Socially Acceptable Trajectories With Generative Adversarial Networks, *Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2018)*, pp. 2255–2264 (2018).

<sup>\*1</sup> <http://trajnet.stanford.edu/>