

# 実歩行データに基づく歩行者モデルの提案

間宮 竜大<sup>†</sup> 藤田 悟<sup>†</sup>  
法政大学 情報科学部<sup>†</sup>

## 1. はじめに

近年、都市部における大規模商業施設の開業や、大型イベントの開催、また 2021 年に行われる東京オリンピックの開催による各地への観光客の増加により、特定の場所に人が集中し、混雑することが想定される。このような場面において、緊急事態が起きた際、避難にかかる時間がより長期に及ぶ可能性がある。そこで、事前に歩行者の動きをシミュレーションすることで、混雑の防止、効率の良い避難経路の提案をより正確にできることが期待されている。

歩行者の行動を表現する代表的なモデルとして Helbing の Social force モデルが存在する。このモデルは、歩行者に位置と速度とパラメータを与え、複数の歩行者の相互作用を計算することで、次の位置が決定的に決まるモデルである[1]。シンプルなモデル化を行っているため、各歩行者の多様な歩行状況を十分に反映しているは言えず、実歩行データとの差異が観測されている。そこで本論文は、実際の歩行者の動きを時系列変化するデータとして学習させ、確率的な移動モデルを構築することを目指す。歩行者の位置を、2次元ガウス分布の確率密度関数で表し、各歩行者の周囲の状況と過去の動きによって非決定的な歩行予測をできるようにしたいと考える。

## 2. Social-LSTM モデル

LSTM は再帰型ニューラルネットワーク (RNN) の問題点であった勾配消失問題を忘却ゲートの導入を行うことで起こらないように改良したものである。Alahi らは LSTM を歩行シミュレーションに適用し、さらに、歩行者相互間の影響を学習する手法 Social-LSTM (以下 S-LSTM, 図 1) を提案した[2]。

位置推定について時刻  $t$  の時の歩行者  $i$  の位置を  $\vec{x}_t^i = (\hat{x}, \hat{y})_t^i$  とする。各歩行者の次の位置の分布を平均を  $\mu_t^i = (\mu_x, \mu_y)_t^i$  として 2次元ガウス分布の確率密度関数(式(1))と仮定して表す。




図 1 S-LSTM モデル




図 2 S-Pooling 層 [2]

$$\mathbb{P}(\vec{x}_t^i) = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{|\Sigma|}} \exp\left\{-\frac{1}{2}(\vec{x}_t^i - \mu_t^i)^T \Sigma^{-1} (\vec{x}_t^i - \mu_t^i)\right\} \quad (1)$$

そして歩行者の位置の行動履歴を時系列データとして LSTM で学習を行うモデルである。

S-LSTM モデルでは歩行者本人の学習を行う際、隣人の LSTM の出力を S-pooling 層(図 2)を介して学習を行う。すなわち、式(2)より歩行者  $i$  と歩行者  $j$  の相対座標  $(x_t^j - x_t^i, y_t^j - y_t^i)$  を計算しそれがグリッド  $(m, n)$  内に存在するかを  $I_{mn}$  が確認を行い、時刻  $t-1$  歩行者  $j$  に対する隠れ層に入力を行う。

$$H_j^i(m, n, :) = \sum_{j \in N_i} I_{mn} [x_t^j - x_t^i, y_t^j - y_t^i] h_{t-1}^j \quad (2)$$

隣人の過去の軌道を加味して学習を行うことで、周囲の歩行者の相互作用を表現している。また、S-Pooling 層の隠れ状態をベクトル  $a_t^i$ 、座標を  $e_t^i$  とする。これら隠れ状態の結合を行い LSTM セルに時刻  $t$  に対応する隠れ層に入力する(式(3))。

$$\begin{aligned} e_t^i &= \phi(x_t^i, y_t^i, W_e) \quad (3) \\ a_t^i &= \phi(H_t^i; W_a) \\ h_t^i &= \phi(h_{t-1}^i, e_t^i, a_t^i; W_l) \end{aligned}$$

$\phi(\cdot)$  は非線形 ReRU の埋め込み関数である。  $W_e$ 、  $W_a$  は埋め込み関数の重みである。 LSTM での重みは  $W_l$  とする。

Proposal of Pedestrian Model Based on Actual Walking Record  
<sup>†</sup>Ryudai Mamiya, Satoru Fujita, Faculty of Computer and Information Sciences, Hosei University

式(1)の二次元ガウス分布の標準偏差を $\sigma_t^i = (\sigma_x, \sigma_y)_t^i$ 、相関係数を $\rho_t^i$ とする。これに基づき S-LSTM モデルの損失関数は式(4)の負の対数尤度を最小化するように学習を行う。

$$[\mu_t^i, \sigma_t^i, \rho_t^i] = W_p h_i^{t-1} \quad (4)$$

$$L^i(W_e, W_l, W_p) = - \sum_{t=T_{obs}+1}^{T_{pred}} \log(\mathbb{P}(x_t^i, y_t^i | \mu_t^i, \sigma_t^i, \rho_t^i))$$

以上により、Helbing の Social Force モデルのように、歩行者モデルを明示的に与える必要がなく、実際の人流の履歴データから、内在する要因を含めて歩行のあり方を学習できるようになったことで、予測の多様性が向上し精度が向上した。

### 3. 提案内容

S-LSTM を用いて、全ての実歩行データからの学習を行うと、学習結果は、期間全体を通じた平均的な動きになる。一方、歩行者の特徴は、朝夕の時間帯や、混雑の影響により変化すると考えられる。例えば、出勤時の道路では通過する人が多いため、通路方向の移動が多いと考えられる。一方、昼の時間では店に立ち寄る人が多いため、通路方向とは直交する方向の移動も増加すると考えられる。そのため、時間帯に分けて学習を行うことで、このような各区分の特徴を導き出すことができると考える。これらの各区分データの学習モデルを比較検討することで全体の平均で学習を行うことよりも高い精度で歩行予測ができると考えられる。

### 4. 学習する歩行データ

学習に使用する歩行データは大阪の商店街である Asia and Pacific Trade Center (通称 ATC ショッピングセンター)を使用する。このデータは JST CREST 戦略的創造推進事業にて提供されている。このデータは、時刻(ms)、方向者ID、歩行者のx座標とy座標z座標(mm)、速さ(mm/s)、速さ方向(rad)、体の方向(rad)を含んでいる。またデータは約0.03秒毎に記録されている[3]。

### 5. 実験

実験では、8ステップ(3.2秒)の軌跡観察を行い、それに続く12ステップ(4.8秒)間の軌道の予測を行う。使用する学習データは ATC の 10/24 10:30~10:35, 10/24 12:30~12:35, 10/24 15:30~15:35 である。

表1 実験結果

学習データ	予測データ	
	10/24 12:35~12:40	10/31 12:35~12:40
10/24 10:30~10:35	0.524,0.721	0.422,0.556
10/24 12:30~12:35	0.418,0.520	0.395,0.487
10/24 15:30~15:35	0.500,0.668	0.410,0.525

また、予測に使用するデータは10/24 12:35~12:40, 10/31 12:35~12:40 である。すなわち、朝・昼・夕の学習データを用いて、別の時間帯の朝・昼・夕のデータを予測して、それぞれの時間帯で、異なる歩行流の特徴が現れるかどうかを検証する。また性能評価を平均誤差、最終的な変位誤差の指標から評価を行う。平均絶対誤差(式(5))は軌道のすべての推定値 $\hat{y}$ を対象にした実データ $y$ との誤差の絶対値の平均である。最終変位誤差は予測期間終了時の予測値と真値との距離の差を表したものである。

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=0}^{n-1} |y - \hat{y}| \quad (5)$$

実験結果は、表1に示す。表の左の値が平均絶対誤差で右の値が最終変位誤差を示す。学習データ 10/24 12:30~12:35 の予測結果は 10/24 12:35~12:40、10/31 12:35~12:40 どちらの予測データも、他の学習データの結果と比べて精度の高い予測ができており、昼間の歩行流の特徴が抽出できていると言える。

### 6. まとめ

本研究では、時間帯による歩行流の特徴を抽出することで、予測精度の向上を実現することができた。

### 参考文献

[1] Dirk Helbing, Peter Molnar, "Social force model for pedestrian dynamics", PHYSICAL REVIEW E, Vol.51, No.5, pp.4282-4286, 1995.  
 [2] Alexandre Alahi, Kratharth Goel, Vignesh Ramanathan, Alexandre Robicquet, Li Fei-Fei, Silvio Savarese, "Social LSTM: Human Trajectory Prediction in Crowded Spaces", CVPR2016, pp.961-971, 2016.  
 [3] D. Brscic, T. Kanda, T. Ikeda, T. Miyashita, "Person position and body direction tracking in large public spaces using 3D range sensors", IEEE Transactions on Human-Machine Systems, Vol. 43, No. 6, pp. 522-534, 2013