

1. はじめに

経路予測は、歩行者や自動車などの物体が未来にどのような経路で移動するかを予測する問題である。深層学習による経路予測には、歩行者間の相互作用を考慮した手法 [1] や予測対象周囲の動的な環境を考慮した手法 [2] が提案されている。しかし、これらの手法は全ての予測対象物体を同一の種類として予測しており、予測対象の種類に応じた経路を予測することが難しい。そこで、本研究では、予測対象の種類を属性とし、属性及び環境情報を導入することで予測対象の種類に応じた経路予測を実現する。

2. 提案手法

提案手法のネットワーク構成を図 1 に示す。まず、歩行者や自転車などの予測対象の属性を抽出する。次に、観測した過去と現時刻の座標から移動量  $(\Delta x_t, \Delta y_t)$  を求める。そして、予測対象を中心とする静的な環境マップを Convolutional Neural Network (CNN) へ入力し、特徴ベクトルを抽出する。予測対象の移動量、属性情報、及び環境に関する特徴ベクトルを連結し、Long Short-Term Memory (LSTM) へ入力する。LSTM の出力として、次時刻までの移動量を得る。以下に各入力情報の表現方法について説明する。




図 1：提案手法のネットワーク構成

2.1. 属性情報の表現

予測対象の属性を導入することで、対象の種類に応じた経路を予測することが期待できる。本研究では、属性を one-hot vector で表現する。具体的には、対象の種類に対応するベクトルの要素を 1、それ以外の要素を 0 とすることで、予測対象の属性を表現する。

2.2. 環境情報の表現

環境情報を導入することで、障害物の有無や対象の属性に応じた領域を考慮する経路予測が可能になる。本研究では、画像に付与された歩道や建物などの静的な環境をシーンラベルとして用いる。環境情報の導入手順を図 2 に示す。まず、シーンラベルから予測対象を中心とする  $100 \times 100$  の領域に着目する。次に、シーンラベル毎に分割したラベルマップを作成する。そして、ラベルマップを 0 または 1 で表現されたバイナリマップにする。バイナリマップを CNN へ入力し、環境に関する特徴量を抽出する。




図 2：環境情報の取得

3. 評価実験

提案手法の有効性を評価実験により検証する。

3.1. 実験条件

本実験では、移動量のみを入力とする場合、移動量と属性を入力とする場合、移動量と環境を入力とする場合、そして、移動量と属性及び環境を入力とする場合の経路予測

手法について性能比較を行う。実験には、Stanford Drone Dataset (SDD) [3] を用いる。予測対象の属性は歩行者や自転車などの 6 種類で、シーンラベルは road や sidewalk, building などの 7 種類である。予測対象の数は学習用に 5,365、評価用に 1,082 である。ネットワークには予測開始前の 4 フレームの移動経路を観測として入力し、その後の 8 フレームの移動経路を予測結果として出力する。評価方法として、予測の最終フレームにおける真値と予測値のユークリッド距離 (Final displacement error) 及び各予測フレームにおける真値と予測値のユークリッド距離の平均 (Average displacement error) を用いる。

3.2. 実験結果

予測精度の比較結果を表 1 に示す。移動量のみを入力とする場合と比較して、属性または環境情報を導入することで予測精度が向上した。また、属性及び環境情報の両方を導入した場合が最も予測精度が高い結果となった。

表 1：評価結果 (単位: pixel)

入力	Final disp. error	Avg. disp. error
移動量	196	86
移動量+属性	184	83
移動量+環境	172	76
移動量+属性+環境	<b>109</b>	<b>53</b>

経路予測例を図 3 に示す。予測対象が歩行者の場合 (図 3(a)), 全ての経路予測手法の予測結果が真値に近い経路を辿っていることがわかる。予想対象が自動車の場合 (図 3(b)), 車道に沿って曲がっているが、環境情報を導入した予測では、直進していることがわかる (青色)。属性及び環境情報の両方を導入した場合では、真値に近い経路を予測できている (赤色)。予測対象が自転車の場合 (図 3(c)), 属性情報を導入した場合には、障害物を回避せず直進している (紫色)。環境情報を導入すると、障害物を回避する経路を予測している (青色)。属性及び環境情報の両方を導入した場合には、真値に近い経路を辿っていることがわかる (赤色)。これらの結果から、高精度な経路予測を行うためには、属性及び環境情報の両者の導入が必要不可欠であることがわかる。

● 真値 ● 移動量のみ ● 移動量+属性 ● 移動量+環境 ● 移動量+属性+環境




図 3：予測結果例

4. おわりに

本研究では、移動対象の属性と環境情報を導入した経路予測手法を提案した。今後は、複数対象の相互作用及び動的な環境を考慮した経路予測を行う。

参考文献

[1] A. Alahi, *et al.*, “Social LSTM: Human trajectory prediction in crowded spaces”, CVPR, pp. 961-971, 2016.  
 [2] N. Lee, *et al.*, “DESIRE: Distant future prediction in dynamic scenes with interacting agents”, CVPR, pp. 336-345, 2017.  
 [3] A. Robicquet, *et al.*, “Learning Social Etiquette: Human Trajectory Understanding in Crowded Scenes”, ECCV, pp. 549-565, 2016.