

1. はじめに

経路予測とは、移動物体が未来にどのような経路を辿るか過去の軌跡から予測する技術であり、自動運転やロボットのナビゲーションへの応用が期待されている。深層学習による経路予測手法は多数提案されており、中でも動的物体同士の衝突を防ぐインタラクションを考慮した経路予測手法が注目されている [1, 2]。経路予測の評価指標には、Alahi 等 [1] が提案した真値と予測値のユークリッド距離を用いる。この評価指標は全データに対する平均を求める。そのため、インタラクション情報がどの程度予測経路に効果的なのか正確に評価できない。また、インタラクションを考慮した経路予測手法がどのような経路に頑健なのか不明確である。そこで本研究では、インタラクションを考慮した経路予測手法の効果を評価するために、新たな評価指標を提案する。提案した評価指標を用いて予測手法の評価を行い、経路予測全体の問題や課題を明確にする。

2. Displacement Error

予測手法の評価指標には、真値と予測値のユークリッド距離である Displacement Error を用いる [1]。Displacement Error による評価指標を図 1 に示す。この評価指標は、予測時刻における平均誤差の Average Displacement Error (ADE) 及び、予測最終時刻の誤差の Final Displacement Error (FDE) の 2 つの指標がある。

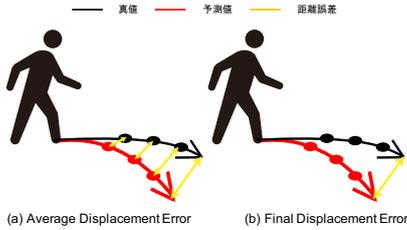


図 1: Displacement Error の概略図

3. 提案する評価指標

本研究では、新たな評価指標を提案し、それらにより従来の経路予測手法毎の精度分析を行う。

3.1 非線形経路に関する評価

従来のインタラクションを考慮した経路予測手法において、対象の動きが線形である場合に誤差が低減しているのか、非線形の場合に誤差が低減しているのか触れられていないため、これらを明確にする指標が必要である。そこで、非線形率毎の Displacement Error を算出し、評価を行う。非線形の経路の判定は、式 (1) のように x, y 方向についてのカーブフィッティングで推定した経路 $f(n)$ と実際の経路 t との残差が、ある閾値 θ_l を超える場合に非線形の経路と判定する。

$$t - f(n|x, y) \geq \theta_l \quad (1)$$

3.2 衝突率に関する評価指標

インタラクション情報がどの程度予測経路に効果的であるかを分析するために、以下の 2 つの衝突率に関する評価指標を提案する。

動的物体に関する評価指標

動的物体との衝突率を分析することで、インタラクションの処理が効果的なのかを定量的に確認できる。動的物体との衝突率は式 (2) で求める。式 (2) の s は 1 つのシーンにおけるフレームのサンプル数、 i はサンプル内にいる予測対象数、 c は衝突回数である。式 (2) より、予測対象 $\exists i \in \mathbb{N}^+, 2 \leq i$ と他対象 $j = i - 1$ の各予測時刻 t の予測値 $\mathbf{x}_t = (x_t, y_t)$ が 1 時刻でも距離値 θ_d 以内にいる場合に衝突したとみなす。この処理を全サンプルで繰り返し行うことで、動的物体との衝突率を算出する。

$$\text{collision rate} = \sum_s \left(\frac{\sum_i \sum_j c_s^{ij}}{i_s (i_s - 1)} \right) \quad (2)$$

$$c_s^{ij} = \begin{cases} 1 & \text{if } \|\mathbf{x}_t^i - \mathbf{x}_t^j\|_2 < \theta_d \\ 0 & \text{otherwise} \end{cases}$$

静的物体に関する評価指標

静的物体との衝突率に関する評価を行うことで、予測経路の正誤の判別が可能になる。静的物体との衝突率は式 (3) となる。式 (3) より、予測時刻 t 間の予測対象 i の予測値 \mathbf{x} が 1 時刻でも障害物領域 \mathbf{o} にいる場合に衝突したとみなす。この処理を全サンプル数で繰り返し行うことで、静的物体との衝突率を算出する。

$$\text{collision rate} = \sum_s \left(\frac{\sum_i c_s^i}{i_s} \right) \quad (3)$$

$$c_s^i = \begin{cases} 1 & \text{if } \mathbf{x}_t^i \in \mathbf{o} \\ 0 & \text{otherwise} \end{cases}$$

4. 評価実験

インタラクションを考慮した経路予測手法の効果を評価実験により検証する。

4.1 実験条件

本実験で使用する予測手法を表 1 に示す。表 1 の Interaction はインタラクションを考慮した手法、DL は深層学習による予測であるか否か、Env. は静的物体情報を考慮した手法であるか否か、Public はコードが公開されているか否かを意味している。

表 1: 予測手法の特徴の一覧

Method	Interaction	DL	Env.	Public
Vanilla-LSTM	-	✓	-	-
RED	-	✓	-	-
ConstVel	-	-	-	✓
Social-LSTM [1]	✓	✓	-	-
Social-GAN [2]	✓	✓	-	-
STGAT	✓	✓	-	✓
Trajectron	✓	✓	-	✓
Ours	-	✓	✓	-

データセットには Stanford Drone Dataset (SDD) [3] を使用する。SDD は、スタンフォード大学構内の異なる地点をドローンで空撮した経路予測のためのデータセットである。SDD には、bookstore, coupa など 8 つの異なる地点で撮影したサブセットがある。本実験では、各シーンから 1 つのサブセットを評価用、それ以外を学習用のシーンとし交差検証を行う。ネットワークには予測開始前 3.2 秒間の入力値を逐次入力し、その後の 4.8 秒間の予測値を逐次出力する。

非線形経路に関する評価におけるカーブフィッティングの閾値 θ_l を 0, 20, 40, 60, 80, 100 とする。閾値 0 の場合は従来の Displacement Error と同様のものになる。動的物体との衝突率に関する評価指標の閾値 θ_d は 10pixel とする。静的物体との衝突率に関する評価指標では、SDD に付与されたラベル情報を用い、予測値が障害物領域の範囲内にいた場合、接触したとみなす。ラベル情報は sidewalk, pavement, grass, bicycle storage, tree, building, roundabout の 7 種類で、そのうち障害物領域に tree, building, roundabout の 3 種類とする。

4.2 非線形経路に関する評価結果

非線形率に関する評価結果を図 3 に示す。図 3 の横軸は閾値、縦軸は真値と予測値の誤差を表している。非線形率 0 の場合、図 3(a) の ADE では Trajectron が最も誤差が小さい。一方、図 3(b) の FDE では ConstVel が小さい。次に、閾値を徐々に上げると、ADE, FDE のどちらも Vanilla-LSTM, RED, STGAT 及び、Trajectron が最も誤差が小さい。これらの結果より、深層学習による経路予測は非線形の経路に対し有効であることが確認できる。

4.3 動的物体との衝突率に関する評価結果

動的物体との衝突率に関する評価結果を表 2 に示す。表 2 より、Vanilla-LSTM が最も衝突回避を実現している。従来の予測手法では、インタラクションを考慮しているにも関わらず衝突率が高くなっているため、インタラクション情報が機能していないことが判明した。また、あるシーンにおける動的物体との衝突率の傾向を図 4 に示す。図 4 の横軸は対象数、左縦軸は対象数が存在するシーンの数、右縦

表 2: 衝突率による評価結果

	Method	Scene								AVG
		bookstore	coupa	deathCircle	gates	hyang	little	nexus	quad	
動的物体	Vanilla-LSTM	3.77	4.48	36.33	4.87	9.75	3.20	23.27	0.0	10.71
	RED	3.93	5.27	37.63	4.30	10.64	4.57	23.81	0.0	11.27
	ConstVel	3.62	7.32	37.68	4.17	10.01	2.59	22.47	0.0	10.98
	Social-LSTM	7.74	16.00	47.65	4.09	14.77	6.18	24.52	0.0	15.12
	Social-GAN	3.47	4.93	37.49	4.04	9.82	3.94	23.48	0.0	10.91
	STGAT	3.43	5.85	38.58	3.39	9.90	3.15	23.49	0.0	10.97
	Trajectron	4.34	8.10	46.12	4.43	11.02	2.94	25.44	0.0	12.80
	Ours	3.82	5.42	46.93	4.17	9.42	3.00	24.17	0.0	12.12
静的物体	Vanilla-LSTM	2.40	2.43	6.29	5.57	0.58	4.43	0.87	0.0	2.82
	RED	3.02	2.43	6.74	3.57	0.72	5.12	1.24	0.0	2.86
	ConstVel	2.89	2.67	4.86	4.26	0.85	2.35	1.31	0.0	2.40
	Social-LSTM	8.56	19.99	23.96	50.91	14.00	3.32	11.91	30.00	20.33
	Social-GAN	5.37	5.39	17.10	10.00	3.41	5.39	4.61	0.0	6.41
	STGAT	2.55	2.39	4.61	4.44	0.52	1.80	1.05	0.0	2.17
	Trajectron	1.98	1.72	3.56	3.48	0.27	1.93	0.75	0.0	1.71
	Ours	1.34	2.87	4.00	2.18	0.41	0.97	0.89	0.0	1.58

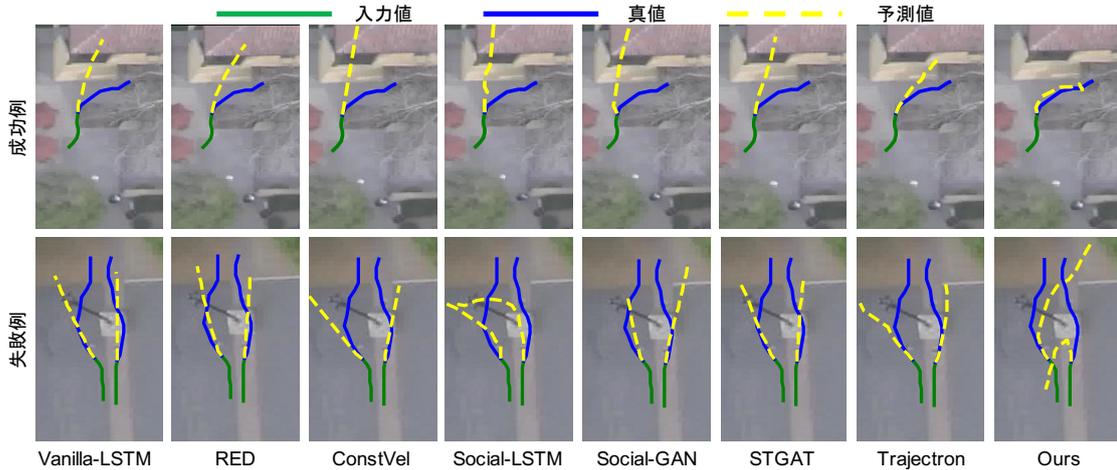


図 2: 手法毎の予測結果例

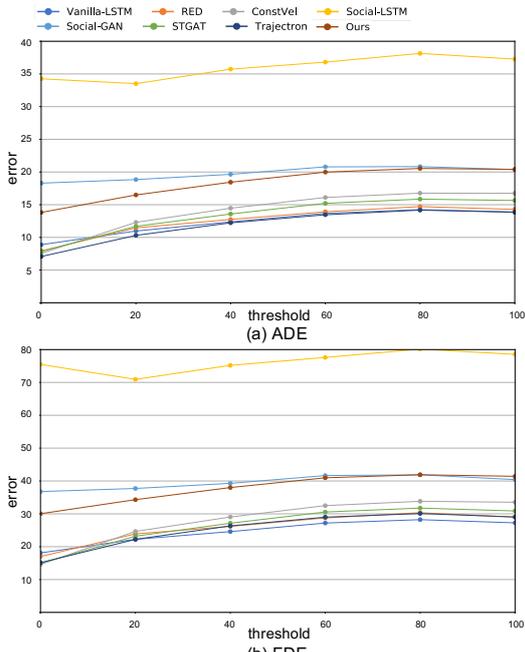


図 3: 非線形経路に関する評価結果

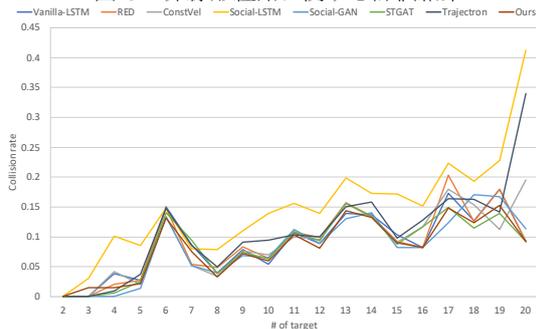


図 4: 動的物体との衝突率の傾向

軸は衝突率を示す。図 4 より、各予測手法は対象数が多い

シーンにおいて、衝突率が高くなる傾向が見られる。従って、インタラクションを考慮する場合、対象数が多いシーンでどれだけ衝突率を下げるができるかが重要になる。

4.4 静的物体との衝突率に関する評価結果

静的物体との衝突率に関する評価結果を表 2 に示す。表 2 より、静的物体情報を考慮した Ours は衝突率が最も衝突回避を実現している。また、各手法の予測結果例を図 2 に示す。図 2 の成功例では、ほとんどの予測手法が前方の障害物に衝突した経路を予測しているが、Ours は衝突回避を実現している。この結果より、静的物体との衝突回避には静的物体情報を考慮する予測モデルが有効であると言える。しかし、図 2 の失敗例で、Ours は建物との衝突回避をした経路を予測しているが、実際の経路とは異なった経路を予測している。そのため、このような経路を予測するのを防ぐのは今後の経路予測モデルの課題としてあげられる。

5. おわりに

本研究では、新たな評価指標を提案しインタラクションを考慮した経路予測手法の精度比較を行った。図 3 及び、表 2 から全ての評価において十分に満たす従来法はない結果となった。今後は、提案した全評価指標を満たす高精度な予測モデルの構築に取り組む。

参考文献

- [1] A. Alahi, *et al.*, "Social LSTM: Human Trajectory Prediction in Crowded Spaces", CVPR, 2016.
- [2] G. Agrim, *et al.*, "Social GAN: Socially Acceptable Trajectories With Generative Adversarial Networks", CVPR, 2018.
- [3] A. Robicquet, *et al.*, "Learning Social Etiquette: Human Trajectory Prediction In Crowded Scenes", ECCV, 2016.

研究業績

- [1] H. Minoura, *et al.*, "Path prediction using object attributes and semantic environment", VISAPP, 2019.
- [2] 箕浦 大晃 等, "移動対象の属性と環境情報を導入した LSTM による経路予測", 画像センシングシンポジウム, 2018.