

지식 증류를 이용한 경로 예측 과업의 영역 일반화

이명학, 이재구*
국민대학교

*jaekoo@kookmin.ac.kr

Domain Generalization of Trajectory Prediction through Knowledge Distillation

Myunghak Lee, Jaekoo Lee*

College of Computer Science, Kookmin University

요약

경로 예측(trajecory prediction) 혹은 움직임 예측(motion prediction)은 객체의 과거 경로를 보고 미래 경로를 예측하는 과업이다. 특히, 경로 예측은 로봇틱스(robotics), 자율주행 등에 필수적인 과업이다. 하지만 객체들의 미래 경로의 예측 분포는 장소에 따라 매우 큰 변동성을 가지기 때문에 모든 장소에 일반화된 모델을 만드는 것은 매우 도전적이다. 따라서 우리는 장소에 따라 변화하는 영역 격차를 극복하기 위하여 교사-학생 구조의 신경망을 가지는 지식 증류(knowledge distillation) 방법을 이용하였고, 결과적으로 영역 일반화 측면에서 향상된 미래 경로 예측 결과를 도출할 수 있었다.

I. 서론

최근 기계 학습은 눈부신 발전을 이루었다. 특히 자율주행, 혹은 로봇틱스(robotics)와 같은 산업에서도 많은 성과를 거두었다. 그러나 해당 산업은 충돌과 같은 문제로부터의 안전성을 보장하기 위해서는 자신과 같은 장면(scene)에 존재하는 다른 객체들의 미래 경로를 예측하여 사고를 예방하는 과정이 필수적이다[1]. 이렇게 과거 경로를 기반으로 미래 경로를 예측하는 과업을 경로 예측(trajecory prediction) 혹은 움직임 예측(motion prediction)이라고 한다[1, 2].

경로 예측은 [그림 1]과 같이 과거 수 초간의 움직임을 입력으로 받아와 미래 수 초간의 움직임을 예측하는 과업이다. 일반적인 경로 예측 모델들은 실제 값과 예측 경로의 정량화된 거리를 이용해 학습을 진행한다. 그러나 일반적으로 객체들의 움직임의 분포는 장소에 적용되는 응용 영역에 따라 크게 달라진다. 실제, 예측 목적인 미래 경로의 분포 역시 장면에 따른 분포 차이가 매우 크다(예: 건널목-간단함, 운동장-복잡함). 우리는 이러한 단점을 극복하기 위해 모든 장면(즉, 영역; domain)에 대하여 모델이 준수한 성능을 낼 수 있는 영역 일반화 방법을 제안한다.

우리는 영역 일반화를 얻기 위해 지식 증류(knowledge distillation)[3, 4] 방법을 사용하였다. 일반적인 지식 증류 방법은 교사로 설정된 모델이 학생으로 설정된 모델의 학습을 돕는 방법이다. 따라서 지식 증류 방법의 학생 모델은 주어진 경로 예측 정답 값의 단순 정보 외에 교사에게서 나오는 지식(예: 모델의 중간 계층 혹은 최종 계층의 출력 값)을 함께 이용하여 일반적인 방법보다 장면에 대한 일반화 성능을 높일 수 있었다[5].

우리는 여기서 영감을 얻어 지식 증류 방법이 경로 예측의 장면 변화에 따른 영역 일반화 문제도 해결할 수 있다고 가정하였고 이를 실험을 통해 증명하였다.

본 논문의 주요 기여점은 다음과 같다.

1. 경로 예측 모델에서 학습한 장면과 다른 장면에서 모델 성능이 떨어지는 영역 격차를 실험으로 확인하였다.
2. 교사-학생 모델을 이용해 학습 동안 보지 못했던 영역에서도 모델의 성능을 유지할 수 있는 경로 예측에 특화된 영역 일반화 기법을 제안하였다.

II. 본론

본 논문에서는 경로 예측용 데이터 집합 간의 존재하는 장면의 변화에 따른 영역 격차가 성능 저하에 미치는 영향을 실험을 통해 확인하였고, 이에 대한 해결책을 제시한다.




그림 1. 경로 예측 과업의 개요. 검은색 실선은 객체들의 과거 경로를 나타내고 회색 점선은 모델이 예측한 경로이고 주황색 실선은 실제 미래 경로이다.

모델	학습 데이터	테스트 데이터 집합	
		<a>같은 장면(영역) (ADE / FDE)	다른 장면(영역) (ADE / FDE)
Original Social GAN[2]	ETH[5]	0.22 / 0.30	0.92 / 1.70
	HOTEL[5]	0.09 / 0.12	0.95 / 1.72
	UNIV[5]	0.42 / 0.82	0.48 / 0.99
	ZARA1[6]	0.09 / 0.13	0.43 / 0.89
	ZARA2[6]	0.10 / 0.15	0.52 / 1.06
Social GAN (교사-학생)	ETH[5]	0.30 / 0.47	0.55 / 1.01
	HOTEL[5]	0.15 / 0.23	0.5 / 0.97
	UNIV[5]	0.28 / 0.53	0.32 / 0.63
	ZARA1[6]	0.13 / 0.21	0.38 / 0.75
	ZARA2[6]	0.17 / 0.32	0.37 / 0.74

표 1 영역 일반화 성능을 알아보기 위한 실험. (<a> 열은 학습에 사용한 데이터 집합과 같은 영역의 데이터 집합에 대한 평가 지표이며 열은 학습에 사용한 데이터 집합과 다른 영역의 데이터 집합에 대한 평가 지표다.

우리는 [표 1]의 5 가지 데이터 집합[5, 6]을 각각 다른 영역으로 보고 각각의 데이터 집합에 대하여 SocialGAN(social generative adversarial networks)[2] 모델을 학습시켰다. 그 후 5 가지 데이터 집합 중 학습에 사용한 데이터 집합을 제외하고 나머지 4 가지 데이터 집합으로 [표 1]의 <a> 열에 해당하는 다른 영역 데이터 집합을 생성한 후 영역 일반화 성능을 측정해 보았다.

우리는 평가 지표로 예측 경로와 실제 경로 사이의 평균 거리인 ADE(average distance error)와 마지막 위치의 거리인 FDE(final displacement error)를 사용했다.

[표 1]을 보면 테스트 데이터 집합으로 학습 데이터 집합과 같은 영역에 대한 성능은 준수하게 나왔으나 다른 영역에 대해서는 성능이 굉장히 떨어지는 것을 확인할 수 있다. 이러한 현상이 벌어진 이유는 앞서 제기되었던 문제대로 경로 예측 과업이 영역 격차에 취약하기 때문이다.

우리는 이러한 영역 격차를 완화하기 위해 지식 증류 방법을 이용하였다. 우리는 [그림 2]와 같이 학습이 완료된 교사 모델에게서 나오는 출력 값인 O^t 와 학생에게서 나오는 출력 값인 O^s 를 유클리드 거리로 비교하여 손실함수를 만들었다. 그리고 여기에 원래 모델을 학습하기 위해 실제 경로 G 와의 유클리드 거리도 계산하여 더해주었다. 이를 수식으로 나타내면 아래와 같다.

$$loss = \alpha \|O_t - O_s\|_2^2 + (1 - \alpha)\|O_s - G\|_2^2 \quad (1)$$

위 식에서 α 는 각각 지식 증류에 대한 손실 함수와 실제 경로 G 에 대한 손실 함수의 가중치를 나타내기 위한 하이퍼 파라미터이다. [표 1]에서 Original SocialGAN 모델과 우리가 제안한 방법인 SocialGAN(교사-학생) 모델을 비교해 보면 같은 영역의 경우 우리의 모델이 평균적으로 ADE 가 0.022, FDE 가 0.048 만큼 높다. 그러나 다른 영역의 경우 평균적으로 우리 모델이 ADE 에 대해 0.236, FDE 에 대해 0.452 만큼 낮다.

즉 우리는 실험을 통해 경로 예측 모델에서 지식 증류를 이용하면 같은 영역에 대한 성능은 다소 떨어지지만 다른 영역에 대한 성능은 현격히 증가하는 것을 확인할 수 있었다.




그림 2 경로 예측 과업에서의 교사-학생 구조. 학생 모델은 자신의 출력 O^s 를 교사 모델의 출력 O^t 와 일치시키는 방향으로 학습을 진행하게 된다.

III. 결론

본 논문에서 우리는 경로 예측 과업에서 장면별로 영역이 달라 모델 성능이 크게 저하된다는 것을 실험을 통해 증명하였다. 나아가 확인된 영역 격차에 따른 성능 저하를 해결하기 위해 지식 증류 기반의 교사-학습 모델을 이용하여 정량적 지표에서 모두 향상된 유의미한 결과를 제안하였다.

ACKNOWLEDGMENT

이 논문은 2022 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(No.RS-2022-00167194,미션 크리티컬 시스템을 위한 신뢰 가능한 인공지능)

참 고 문 헌

- [1] Yuning Chai, Benjamin Sapp, Mayank Bansal, and Dragomir Anguelov. Multipath: Multiple probabilistic anchor trajectory hypotheses for behavior prediction. arXiv preprint arXiv:1910.05449, 2019.
- [2] Agrim Gupta, Justin Johnson, Li Fei-Fei, Silvio Savarese, and Alexandre Alahi. Social gan: Socially acceptable trajectories with generative adversarial networks. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 3542-3549, 2014.
- [3] Adriana Romero, Nicolas Ballas, Samira Ebrahimi Kahou, Antoine Chassang, Carlo Gatta, and Yoshua Bengio. Fitnets: Hints for thin deep nets. arXiv preprint arXiv:1412.6550, 2014.
- [4] Geoffrey Hinton, Oriol Vinyals, Jeff Dean, et al. Distilling the knowledge in a neural network. arXiv preprint arXiv:1503.02531, 2(7), 2015.
- [5] Stefano Pellegrini, Andreas Ess, Konrad Schindler, and Luc Van Gool. You' ll never walk alone: Modeling social behavior for multi-target tracking. In 2009 IEEE 12th international conference on computer vision, pages 261-268. IEEE, 2009.
- [6] Alon Lerner, Yiorgos Chrysanthou, and Dani Lischinski. Crowds by example. In Computer graphics forum, volume 26, pages 655-664. Wiley Online Library, 2007.