

Monte Carlo Dropout 및 Test-Time Augmentation을 이용한 CARLA 환경에서의 조건부 모방학습 기반 End-to-end 자율주행의 성능 향상

김창준, 김민, 김덕환*
인하대학교, *인하대학교

12211349dave@inha.edu, min222@inha.edu, *deokhwan@inha.ac.kr

Improvement of End-to-End Autonomous Driving Based on Conditional Imitation Learning in a CARLA Environment Using Monte Carlo Dropout and Test-Time Augmentation

CHANGJUNE KIM, Deok-Hwan Kim*
Inha Univ., * Inha Univ.

요약

본 논문은 CARLA 환경에서 조건부 모방학습(Conditional IL) 기반 end-to-end 자율주행 정책의 추론 안정성을 높이기 위해 Test-Time Augmentation(TTA)과 Monte Carlo Dropout(MC Dropout)을 결합한 추론 시점 양상을 제안한다. 입력 영상의 다중 변형(TTA)과 드롭아웃 활성화 반복 추론(MC Dropout) 결과를 평균해 조향/가속/제동을 산출하고, 출력 분산은 변동성 기반 불확실성 proxy로 해석한다. CARLA 0.8.2 Town01, CoRL2017 벤치마크(50 start-goal pairs)에서 Success Rate는 88%→92%, Km per Infraction은 2.34→3.37 km로 개선되어 재학습 없이도 성능의 향상을 보였다.

I. 서론

딥러닝 기반 자율주행에서 모방학습은 널리 활용되며, Codevilla 등의 조건부 모방학습(Conditional IL)은 고수준 명령(직진/좌우회전) 입력으로 교차로 등에서의 행동 모호성을 해소하고 분기(Branch) 구조로 명령별 정책을 학습한다[1]. 그러나 기존 CIL은 조명 변화, 노이즈, 장면 변화 등 학습 분포와 다른 상황에서 입력 변화에 민감해 제어 출력이 흔들릴 수 있고, 단일 추론에 의존할수록 이러한 불안정성이 누적될 수 있다. 본 연구는 재학습이나 구조 변경 없이 추론 단계만 보강해 정책의 출력 안정성과 주행 성능을 개선하는 방법을 제안한다. 이를 위해 Test-Time Augmentation(TTA)[2]으로 입력 영상을 다중 변형하고, Monte Carlo Dropout(MC Dropout)[3]으로 드롭아웃을 활성화한 반복 추론을 수행한 뒤, 다중 예측의 평균을 최종 제어로 사용한다. 출력 분산은 TTA 및 드롭아웃 샘플링에 따른 변동성 기반 불확실성 proxy로 정의하여 분석 지표로 제시한다.

II. 본론

2.1 제안하는 방법론

2.1.1 전체 개요

본 연구는 기존 Conditional IL(Branched) 구조는 그대로 유지하되, 추론 시점에만 (i) TTA로 입력 이미지를 다중 생성하고, (ii) 드롭아웃을 활성화한 상태에서 반복 추론(MC Dropout 샘플링)을 수행한 뒤, (iii) 샘플 평균을 최종 제어로 사용한다.

구현에서는 동일 상태에 대해 총 N=5 회 추론을 수행하며, 1 회는 원본 입력, 4 회는 TTA가 적용된 입력을 사용한다. 또한 모든 추론은 dropout 활성화 상태로 수행되어, 각 추론 결과가 MC Dropout 샘플에 해당한다. 모델 파라미터의 재학습 없이 다중 샘플 평균을 통해 출력 변동성을 완화하는 것이 핵심이다.

2.1.2 Inference-time 양상별 (Mean/Variance) 정의
동일한 상태에서 N 회 추론한 제어 출력 샘플을 $\{a_i\}_{i=1}^N$ 라 하자. 여기서 $a = (steer, throttle, brake)$ 는 조향/가속/제동의 벡터 출력이다. 본 연구는 최종 제어를 평균으로 정의한다.

$$\mu = \frac{1}{N} \sum_{i=1}^N a_i \quad (1)$$

또한 출력 변동성 (proxy)을 분산으로 정의할 수 있다.

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (a_i - \mu)^2 \quad (2)$$

본 연구에서는 최종 제어로 μ 를 사용하여 주행 안정성을 높이고, σ^2 는 각 제어 항목(steer/throttle/brake)별 원소-wise 분산으로 계산하여 출력 변동성 기반 불확실성 proxy로서 해석/분석 목적으로 제시한다.

2.1.3 TTA 설계

입력 영상 I 에 대해 다음을 적용한다[2].

- (i) 밝기 변화: $b \sim U(0.9, 1.1)$, $I \leftarrow bI$
- (ii) 가우시안 노이즈: $\epsilon \sim \mathcal{N}(0, 0.01)$, $I \leftarrow I + \epsilon$
- (iii) 색 클리핑: $I \leftarrow clip(I, 0, 1)$

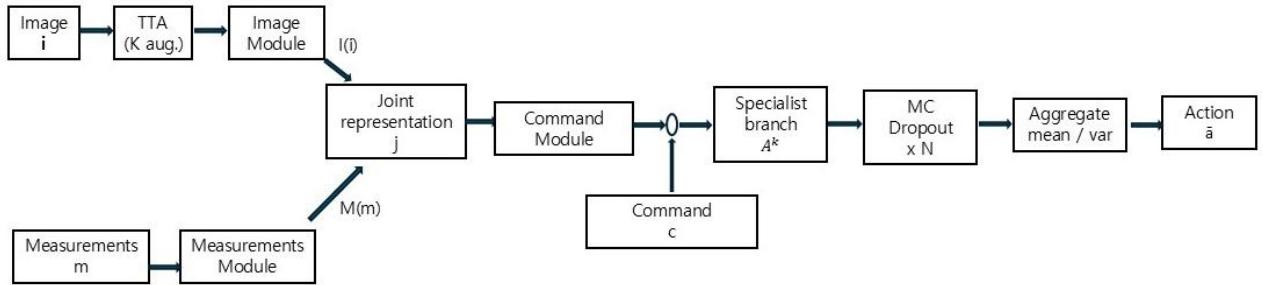


그림 1. 제안하는 방법론

구현에서는 총 $N = 5$ 회 추론 중 1 회는 원본 이미지를 사용하고, 나머지 4 회는 TTA 가 적용된 이미지를 사용하였다.

2.1.4 MC Dropout 설정 및 통합

본 연구는 추론 시에도 드롭아웃을 활성화하여 MC Dropout 샘플링을 수행한다[3]. 각 추론 출력은 조향(steer), 가속(throttle), 제동(brake)이며, 최종 출력은 식 (1)과 같이 각 항목별 평균으로 계산한다.

2.2 실험 및 결과

실험은 CARLA 시뮬레이터 0.8.2 버전의 Town01 환경에서 수행되었으며, CoRL2017 벤치마크 설정을 기준 연구[1]와 동일한 방식으로 적용하였다. 총 50 start-goal pairs 로 평가를 진행하였다. (기준 기법들의 수치는 [1]에서 보고된 값을 사용하였다.)

2.2.1 결과

표 1 은 원 논문[1]의 Town01 결과(비교 기준)를 정리하고, 본 연구의 제안 방법(Ours)을 동일 벤치마크 조건에서 추가 측정하여 비교한 결과를 보여준다.

표 1. 결과

* Non-conditional~shallow net 수치는 Codevilla et al.[1]에서 보고된 값이며, Ours 는 CoRL2017 벤치마크 설정에서 본 연구를 통해 실험한 결과이다.

| Model | Town 1 Success rate | Town 1 Km per infraction |
|----------------------------|---------------------|--------------------------|
| Non-conditional | 20% | 5.76 |
| Goal-conditional | 24% | 1.87 |
| Conditional IL | 88% | 2.34 |
| Conditional IL cmd. Input | 78% | 3.97 |
| Conditional IL no noise | 56% | 1.31 |
| Conditional IL no aug. | 80% | 4.03 |
| Conditional IL shallow net | 46% | 0.96 |
| Ours | 92% | 3.37 |

III. 결론

본 논문에서는 조건부 모방학습 기반 end-to-end 자율주행 정책의 추론 안정성과 성능을 향상시키기 위해 MC Dropout 과 TTA 를 결합한 추론 시점 양상을 알고리즘을 제안하였다. 제안 방법은 학습 재수행이나 네트워크 구조 변경 없이, 다중 추론 결과의 평균을 최종

제어로 사용하여 출력 변동성을 완화한다. CARLA 0.8.2 Town01, CoRL2017 벤치마크에서 제안법은 Conditional IL(Branched) 대비 Success Rate 및 Km per Infraction 을 유의미하게 향상시켰다. 또한 다중 샘플 출력의 분산은 입력 변형과 드롭아웃 샘플링에 대한 출력 변동성 기반 불확실성 proxy 로 정의할 수 있음을 논의하였다.

ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로

한국연구재단의 지원을 받아 수행된 연구임(No. RS-2024-00336286).

이 논문은 2025년도 정부(산업통상자원부)의 재원으로

한국산업기술진흥원의 지원을 받아 수행된 연구임(P0020536, 2025년 산업혁신인재성장지원사업).

이 논문은 2025년도 정부(산업통상자원부)의 재원으로

한국산업기술진흥원의 지원을 받아 수행된 연구임(P0017124, 2025년 산업혁신인재성장지원사업)

참 고 문 헌

- [1] Felipe Codevilla et al., "End-to-end Driving via Conditional Imitation Learning," IEEE International Conference on Robotics and Automation (ICRA), 2018, pp. 4693-4700.
- [2] Illdoo Kim, Younghoon Kim, Sungwoong Kim, "Learning Loss for Test-Time Augmentation," 34th Conference on NeuralIPS, 2020, pp. 1-2.
- [3] Yarin Gal, Zoubin Ghahramani, "Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning," PMLR, 2016, p. 4