

연속학습의 자율주행 엣지 스트리밍 적응성 분석

이지은, 홍서희, 김지수, 김윤희
숙명여자대학교

{mariewldms, seohee0320, smwujisue, yulan}@sookmyung.ac.kr

An Adaptability Analysis of Autonomous Edge Streaming using Continual Learning

Jieun Lee, Seohee Hong, Jisue Kim, Yoonhee Kim
Sookmyung Women's University

요약

자율주행 차량의 주행 중 실시간 스트리밍 데이터 처리 성능 향상을 위해 엣지 내에서 딥러닝 학습 연구가 진행되고 있다. 그러나, 딥러닝 학습 중 실시간으로 모델 파라미터가 조정되면서 파괴적 망각이 발생하고 실시간 적응 능력이 떨어지므로 연속학습(Continual Learning)을 도입할 필요가 있다. 본 논문에서는 연속학습을 온라인 학습 알고리즘에 도입할 학습 모델을 제안한다. 실험을 통해 스트리밍 데이터에 연속학습을 적용하면 학습 중 GPU 사용량이 크게 증가하지 않으면서 과거 기억을 보존하고 동시에 새로운 데이터에 대한 적응 능력이 향상되었음을 보였다.

I. 서론

온디바이스 AI의 중요성이 부각됨에 따라, 자율주행 엣지 내 실시간 스트리밍 데이터 처리 과정에서 딥러닝 학습이 시도되고 있다. 그러나 새로운 데이터 학습 시 기존 모델 가중치가 조정되면서 과거 지식이 급격히 손실되는 파괴적 망각(Catastrophic forgetting) 문제가 발생한다. 이러한 상황에서 연속학습(Continual Learning)은 망각을 방지하면서 실시간 데이터에 적용할 수 있는 방법[1]으로 주목받고 있다. 따라서 자원이 한정된 자율주행 엣지에서 연속학습은 실시간 적응 능력 향상을 위한 해결책이 될 수 있다.

본 논문에서는 자율주행 엣지의 스트리밍 데이터 처리 과정에서 연속학습을 적용할 수 있는 온라인 학습 모델을 제시하고, 학습 및 평가 결과를 기반으로 연속학습 알고리즘의 성능을 평가한다.

II. FM 기반 온라인 연속학습 모델




그림 1. 자율주행 엣지의 FM 기반 온라인 학습 모델

2.1 온라인 연속학습 모델

본 논문에서는 그림 1 과 같이 자율주행 엣지에 연속학습을 도입하여 주행 여부를 추론하는 온라인 연속학습 모델을 제안한다. YOLO v8 을 통한 객체 탐지 결과를 바탕으로 바운딩박스 좌표, 추정 거리, 중심점 좌표 등을 포함한 특징 벡터를 추출하고, 이를 FM(Factorization Machine)[3] 기반의 분류 모델에 입력하여 주행 여부를 결정하는 이진 분류 모델을 학습한다. 지도학습을 통한 초기 모델 구축 후 자기 지도학습을 통해 라벨이 없는 실시간 데이터에 대해 지속적인 학습을 수행한다 [2]. 자기 지도학습 단계에서는 원본 입력과 노이즈가 추가된 입력 간의 임베딩 일관성을 유지하는 일관성 손실을 활용하여 라벨이 없는 상황에서도 효과적인 학습 신호를 생성한다. 모델은 새로운 프레임이 유입될 때마다 즉시 학습을 수행할 수 있으며, Adam optimizer 를 활용한 효율적인 파라미터 업데이트를 통해 엣지의 제약사항을 고려한 실용적인 온라인 연속학습 모델을 구현한다. 각 태스크가 마무리될 때마다 자기 지도학습 기반 평가 모델 예측값과 임의 라벨(ground truth)을 비교하여 연속학습 성능 지표를 통해 성능을 종합적으로 평가한다.

2.2 연속학습

본 논문에서는 대표적인 연속학습 알고리즘[1]인 Regularization-Based Approach 방법론 기반 EWC 와 Replay-Based Approach 방법론 기반 Rehearsal 을 활용한다. EWC 는 가중치 변화를 최소화하는 방식으로, 중요한 가중치일수록 페널티가 증가해 값 이전 기억을 보존한다. Rehearsal 은 학습 과정에서 이전에 학습한 데이터 샘플들을 메모리에 저장해두고, 새로운 태스크를 학습할 때 이전 데이터를 함께 사용하여 모델이 이전 지식을 망각하지 않도록 한다.

III. 실험 및 결과

3.1 스트리밍 데이터

본 논문에서는 실제 자율주행 상황에서의 도로와 주행 차량을 모방한 실험환경을 설계하고 RC 카 시점 전면 영상을 촬영했다. 성능 측정을 위해 기존 자율주행 알고리즘이 예측하기 어려운 돌발 상황을 설계했다. 앞 자동차 주행 상황(일반 주행), 건인차에 실린 자동차가 낙하하는 상황(건인차 낙하), 맞은편 도로에서 주행하던 자동차가 유턴하는 상황(유턴)을 가정했다. 지도학습 모델에서 일반 주행 데이터가, 자기 지도학습 모델에서 일반 주행, 건인차 낙하, 유턴 데이터가 프레임 단위로 차례대로 학습된다.

3.2 주행 여부 라벨링

327 개의 프레임에 대해 0 을 ‘멈춤’, 1 을 ‘주행’으로 하는 라벨을 붙이고, 지도학습을 수행하였다. 이후 854 개의 프레임은 라벨 없이 자기 지도학습을 수행하였다.

3.3 성능 지표

평가에 활용할 성능 지표로는 IM(Intransience measure), FWT(Forward transfer), BWT(Backward transfer)를 사용하였다. 통상적인 지표 [1]보다 간소화된 버전으로 사용하였다.

IM 은 식 (1)과 같이 최종적으로 모델이 모든 평가 실험에 대해 얼마나 평균적으로 잘 수행했는지를 의미한다.

$$IM = \frac{1}{T} \sum_{i=1}^T A_i \quad (1)$$

BWT 는 식 (2)와 같이 마지막 평가 실험이 다른 과거 평가 실험들보다 상대적으로 잘 수행되는지를 나타낸다.

$$BWT = \frac{1}{T-1} \sum_{i=1}^{T-1} (A_T - A_i) \quad (2)$$

FWT 는 식 (3)와 같이 baseline_acc=0.5 대비 새로운 평가 실험 후 성능이 얼마나 향상되었는지를 보여준다.

$$FWT = \frac{1}{T-1} \sum_{i=2}^T (A_i - \text{baseline_acc}) \quad (3)$$

T 는 전체 평가 실험 수, A_i 는 i 번째 평가 실험의 정확도이다.

3.4 실험결과




그림 2. 각 태스크 학습 종료 시점의 일반 주행 데이터 정확도 변화 학습 모델이 동작하는 자율주행 옻지로 NVIDIA Jetson AGX Orin 32GB 를 사용한다. 각 태스크별 학습이 마무리될 때마다 첫 번째 태스크에서 학습했던 일반 주행 데이터 정확도를 측정해 과거 데이터 보존 능력인 안정성을 평가했다. 그림 2 와 같이 Rehearsal 기법이 연속학습 미적용 모델인 Naive 대비 5%, 3%, 3% 정확도가 높았다. EWC 기법은 다른 두 기법에 비해 정확도는 떨어지지만, 성능 변화폭이 0.6%로 가장 작아 안정성 측면에서 뛰어나다.




그림 3. 모든 태스크 학습 후 유턴 데이터 성능 평가 결과 비교

세 번째 유턴 태스크 학습 종료 후 유턴 데이터를 이용해 모델을 평가해 최종 성능 지표를 계산했다. 그림 3 에서 Rehearsal 기법이 Accuracy 0.761, FWT 0.105, BWT 0.171, IM 0.61 로 모든 성능 지표에서 우위를 보였다. 특히 안정성을 나타내는 BWT 에서 유일하게 양수 값을 기록하면서 적응성을 나타내는 FWT 가 가장 커 파괴적 망각 문제를 해결하면서 적응 능력이 뛰어난 모습을 보인다.

	Naive	EWC	Rehearsal
GPU Usage(%)	41.5	41.83	41.40

표 1. 온라인 학습 중 GPU 사용량 평균(%)

온라인 학습 중 옻지의 GPU 사용량 평균값을 측정한 결과, 표 1 과 같이 GPU 사용량이 연속학습 알고리즘을 사용했음에도 41%로 크게 차이 나지 않았다.

IV. 결론

본 논문에서는 자율주행 옻지에 실시간으로 유입되는 스트리밍 데이터를 기반으로 주행 여부를 판단하는 과정에서 온라인 학습 알고리즘에 연속학습을 적용하는 모델을 제안하였다. 또한, 옻지의 모델 학습 과정에서 GPU 사용량을 측정하고, 모델 평가 과정에서 성능 지표를 기반으로 연속학습 안정성과 적응성을 측정했다. 분석 결과, 연속학습을 적용하면 GPU 사용량이 크게 증가하지 않으면서, 과거 기억을 보존하고 동시에 새로운 데이터에 대한 적응 능력이 개선되었다. 향후 연구로는 자율주행 환경에 맞는 대용량 스트리밍 데이터에 적합한 연속학습 모델을 개발할 예정이다.

ACKNOWLEDGMENT

This work is supported by the United States Office of Naval Research Global (N62909-25-1-2082)

참 고 문 헌

- [1] Liyuan Wang, Xingxing Zhang, Hang Su and Jun Zhu, "A Comprehensive Survey of Continual Learning: Theory, Method and Application", in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 46, no.8, pp. 5362-5383, Aug. 2024
- [2] Botos Csabal, Wenxuan Zhang, Matthias Müller, Ser-Nam Lim, Mohamed Elhoseiny, Philip H.S. Torr1, and Adel Bibi1, "Label Delay in Online Continual Learning, 2024(<https://arxiv.org/pdf/2312.00923>).
- [3] A. -P. Ta, "Factorization machines with follow-the-regularized-leader for CTR prediction in display advertising," 2015 IEEE International Conference on Big Data (Big Data), Santa Clara, CA, USA, 2015, pp. 2889-2891, doi: 10.1109/BigData.2015.7364112.