

그래프를 활용한 차선 인식 성능 개선

이현종, 이재구*

국민대학교

*jaekoo@kookmin.ac.kr

Improving Lane Segmentation Performance Using Graphs

Hyunjong Lee, Jaekoo Lee*

College of Computer Science, Kookmin Univ.

요 약

차선 인식은 자율 주행 시 도로 장면에서 차선을 분할하는 과업이다. 하지만, 기존 차선 인식 모델은 차선이 차에 의해 가려지거나 강한 조명 조건, 날씨 환경과 같은 외부 환경에 의해 정보가 가려지는 경우 차선을 인식하기 어려운 문제점이 있었다. 이러한 차선 인식의 불안정성은 자율 주행 차량의 주된 사고 원인이 되었다. 위 한계점을 해소하기 위해, 본 논문에서는 도로 장면에서 맥락적인 정보(contextual information)를 추출하는 그래프 모듈을 활용하여 차선 감지에 대한 IoU를 1.83% 높이고 실시간성을 보존하는 모델을 제안한다.

I. 서 론

차선 인식은 영상에서 차선과 배경을 분리하는 과업이다. 주로 자율 주행 자동차에서 동작하기 때문에 높은 정확성과 실시간성이 요구된다.

하지만 실제 자율 주행 환경에서는 다양한 외부 요소가 존재하기 때문에 정확한 차선 인식을 수행하기에 어려운 문제점이 있다. 이러한 문제점은 차선 인식의 실패를 야기하며 자율 주행 차량의 주된 사고 원인이 된다.[1] 따라서 차선 인식의 성능을 높이는 연구는 필수적이며, 언급된 한계점을 해소해야 한다.

실제 주행 환경에서 차선이 차에 의해 가려지거나 환경 조건에 의해 카메라상에 보이지 않는 경우 주행 중인 차의 위치와 같은 맥락적인 정보를 바탕으로 차선의 위치를 분할해야 한다. 하지만 기존 연구되고 있던 합성곱 신경망(convolutional neural network) 기반 차선 인식 모델은 지역성에 대한 유도 편향(inductive bias)이 존재하기 때문에 맥락적인 정보를 추출하는데 한계점이 존재했다[2].

해당 한계점을 극복하기 위해 비전 분야에서 맥락적인 정보를 추출할 수 있는 트랜스포머(transformer) 기반 모델이 차선 인식 분야에 적용되고 있다[3]. 하지만 트랜스포머 기반 모델은 연산량이 입력 영상의 제곱에 비례하기 때문에 실시간성을 보존할 수 없으며 같은 용량(capacity)의 합성곱 기반 모델에 비해 성능이 떨어지는 것을 알 수 있다[4].

따라서 본 연구에서는 실시간성을 보존하면서 영상 전체의 맥락적인 관계를 모델링할 수 있는 그래프 신경망(graph neural network)[5]을 추가하여 차선 분할을 수행한다.

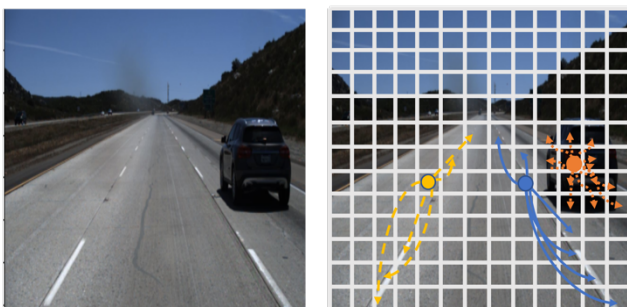


그림 1. 그래프 연결 시각화

II. 본 론

본 논문에서는 영상의 맥락적인 정보를 추출하기 위해 Vision GNN[6] 모델의 그래프 모듈을 활용하였다.

비전 분야에서 합성곱 혹은 트랜스포머 기반 모델은 고정된 형태에 따라 영상의 픽셀간 연산이 결정된다. 즉 연산하는 대상이 고정적이기 때문에 복잡한 개체를 추출하기 어렵다는 단점이 있다. 이를 극복하기 위해 Vision GNN은 영상을 패치로 나누고 KNN(k-nearest-neighbor)을 적용하여 그래프를 구성하고 GNN(graph neural network)을 적용한 형태를 제안하였다. 결과적으로 패치를 그래프 방식으로 구성하면 영상 격자내의 거리와 상관없이 유사한 의미를 지니는 패치끼리 연결이 될 수 있어 전역적인 정보를 추출할 수 있다. [그림 1]은 각 영상 패치가 다른 패치와 어떻게 연결되어 있는지를 시각화한 그림이다. [그림 1]에서 같은 색깔의 화살표는 서로 같은 객체와 연결되어 있는 것을 확인할 수 있다. 이는 영상 격자 거리상의 영향을 받지 않고 넓은 범위에서 유사한 의미를 지니는 패치끼리 연결된 것이다. 이를 통해 Vision GNN 모델은

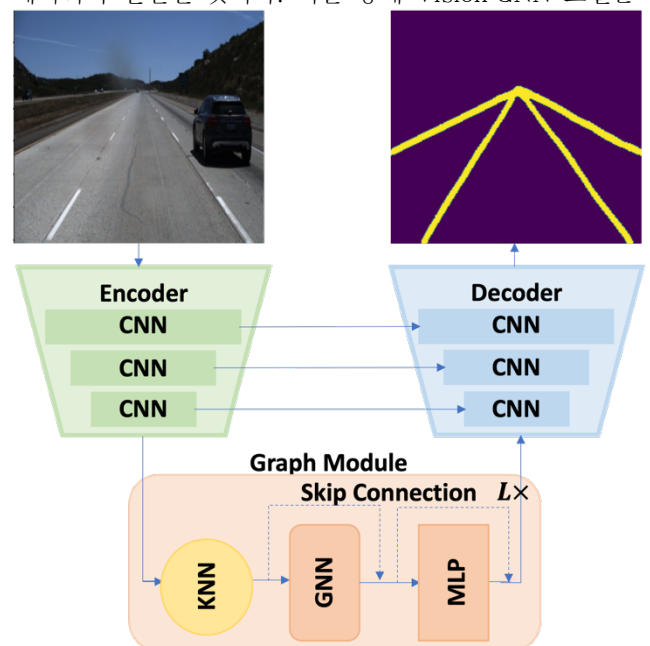


그림 2. 제안 모델

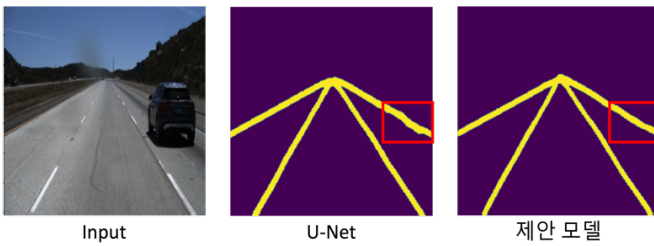


그림 3. 객체 영역의 차선 검출

전역적인 정보를 추출한다는 것을 알 수 있다.

본 논문에서는 그래프 구조를 활용하면 전역적인 특징을 잘 추출하여 차선 인식의 성능을 높일 수 있는지 확인하기 위해, Vision GNN 의 그래프 모듈과 영상 분할 과업에서 널리 사용되는 U-Net[7]을 활용하여 모델을 구성하였다.

[그림 2]에서 보듯이 다운 샘플링(down-sampling)을 수행하여 추상화된 정보를 추출하는 인코더(encoder), 합성곱 신경망을 통과한 특징 맵에서 전역적인 정보를 추출하기 위한 그래프 모듈, 그리고 업 샘플링(up-sampling)을 수행하여 원본 해상도로 복원하는 디코더(decoder)로 구성되어 있다. 그리고 인코더에서 다양한 해상도의 특징 맵을 디코더에 추가하여 세밀한 영상 분할을 수행한다. 그래프 모듈은 그래프 신경망과 완전 연결층(fully connected layer)으로 구성되어 있다. 그래프 모듈을 적용하기 전, KNN 알고리즘을 사용하여 각 노드를 유사도에 맞게 구분하여 그래프를 구성한다. 그리고 그래프 신경망을 통과하여 전역적인 정보를 추출하고 완전 연결 층을 통해 지나친 획일화(over-smoothing) 문제를 방지한다.

III. 실험

본 논문에서는 차선 분할 모델의 성능을 실험하기 위해 Tusimple[8] 차선 데이터 집합을 사용하여 영상 분할 (semantic segmentation) 데이터 집합으로 변환했다. 변환된 데이터는 [그림 3]에서 볼 수 있듯이 입력 데이터에서 차선과 배경을 분할한다.

본 논문에서는 pixel-accuracy, IoU(Intersection over unit)와 FPS(Frame per seconds)를 성능 지표로 사용했다. 실험은 U-Net 과 제안된 모델을 Tusimple 데이터 집합으로 처음부터 학습하여 비교했다.

추가적으로 차선 데이터의 클래스 불균형을 해소하기 위해 weighted binary cross entropy loss 를 사용했다. 또한 가중치 감쇠(weight decay)와 학습 조기 중지(early stopping)를 사용하여 그래프 신경망의 오버피팅(over-fitting) 문제에 대응하였다.

실험 결과는 [표 1]에서 알 수 있듯이 기존 U-Net 에 비해 제안 모델이 정확도가 0.04%p, IoU 가 1.83%p 높았다. 따라서 픽셀 자체의 정확도는 거의 상승하지 않았지만, IoU 가 상승한 것으로 보아 제안된 모델이 전역적인 정보를 잘 추출하여 기존 U-Net 보다 더 세밀한 차선 분할을 수행했다고 판단할 수 있다.

또한 차에 의해 차선이 가려진 데이터인 [그림 3]에서 알 수 있듯이 기존 U-Net 은 가려진 차선 부분이 불안정하게 예측되는 것을 알 수 있다. 하지만 제안된 모델의 경우 전역적인 정보를 바탕으로 영상 분할을 수행하기 때문에 차선이 가려진 경우에도 다음과 같이 기존 모델보다 잘 예측하는 것을 알 수 있다.

FPS 는 U-Net 에 비해 FPS 가 3%p 낮게 측정되었다. 이는 제안된 모델이 전역적인 정보를 얻기 위해 추가 연산을 진행할 때 FPS 의 변화가 거의 없다는 것을 의미한다.

표 1. 정량적 지표 비교 결과

Model	U-Net	Ours
Metric		
Accuracy	97.51	97.75
IoU	60.02	61.85
FPS	142	139

IV. 결 론

차선 인식은 정확도를 높이기 위해 전역적인 정보를 추출하는 동시에 실시간성을 보존하기 위한 연구가 필요하다. 따라서 본 논문에서는 맥락적인 정보를 잘 추출하는 동시에 실시간성을 보존할 수 있는 그래프 기반 차선 인식 모델을 제안한다.

제안 모델은 실험 결과에서 알 수 있듯이, 기존 U-Net 에 비해 세밀하게 차선을 분할할 수 있으며 실시간성도 유지되는 이점을 가지고 있다. 따라서 앞으로 차선 인식 분야에서 맥락적인 정보를 잘 추출하는 그래프 기반 모델이 많은 연구가 필요하다.

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] American Automobile Association , "Evaluating Active. Driving Assistance Systems Full Research Report", "2020 (<https://newsroom.aaa.com/asset/report-fact-sheet-evaluating-active-driver-assistance-systems/>)
- [2] Zheng, Tu, et al. "Resa: Recurrent feature-shift aggregator for lane detection." *Proceedings of the AAAI Conference on Artificial Intelligence*. Vol. 35. No. 4. 2021.
- [3] Liu, Ruijin, et al. "End-to-end lane shape prediction with transformers." *Proceedings of the IEEE/CVF winter conference on applications of computer vision*. 2021.
- [4] Guo, Jianyuan, et al. "Cmt: Convolutional neural networks meet vision transformers." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022.
- [5] Lu, Yi, et al. "CNN-G: Convolutional neural network combined with graph for image segmentation with theoretical analysis." *IEEE Transactions on Cognitive and Developmental Systems* 13.3 (2020): 631-644.
- [6] Han, Kai, et al. "Vision GNN: An Image is Worth Graph of Nodes." *arXiv preprint arXiv:2206.00272* (2022).
- [7] Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation." *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015.
- [8] Tusimple lane challenge, <https://github.com/Tusimple/tusimple-benchmark>