

자율주행을 위한 실시간 차선인식 기술에 대한 고찰

곽대원*, 유지상*, 손민준*, 박민수*, 최동건*, 이성진^o

Rethinking Real-Time Lane Detection Technology for Autonomous Driving

Daewon Kwak*, Jisang Yoo*, Minjun Son*, Minsu Park*, Donggeon Choi*, Sungjin Lee^o

요약

자율주행에서 카메라를 통한 상황인지는 필수 동작 중에 하나이다. 특히 도로주행을 위한 차선인식 시스템은 완전 자율주행 뿐 아니라 ADAS (Advanced Driving Assistance System)를 위한 LKS (Lane Keeping System) 에 서도 필수 기능 중 하나이다. 하지만, 이런 차선인식 시스템은 도로 위의 다양한 상황들 (광학 반사, 날씨, 밤시간, 가림, 곡선 차선 등)에서 정확하고 실시간으로 동작해야 한다. 본 논문에서는 특히 한국 도로환경에서 밤시간에도 실시간으로 동작할 수 있는 딥러닝 기반 차선인식 시스템에 대해 고찰하고 성능 최적화를 위한 전략들을 제시하 였다. 이를 위해 기존 외국 지형 낮 시간대의 훈련 데이터인 TuSimple 데이터 셋에 더하여 한국 지형 낮 시간대 및 밤 시간대 데이터 셋을 구축하고 데이터 증식 기법들을 추가하여 훈련을 시켰으며 NVIDIA 2080ti 단일 GPU 에서 그 정확도 및 실시간 동작 속도를 측정하였다. 이런 추가 데이터셋 구축 및 데이터 증식 추가 훈련의 결과 Ultra Fast Lane Detection 모델을 기준으로 한국 지형 밤 시간대에 76.9%의 정확도에서 92.4%의 정확도 향상을 CLRNNet 모델을 기준으로 84.6%의 정확도에서 96.7%의 정확도 향상을 이룰 수 있었다.

Key Words : Autonomous Driving, Lane Detection, Dataset, Deep Learning, Data Augmentation

ABSTRACT

In autonomous driving, the lane detection system for road driving is one of the essential functions not only for fully autonomous driving but also for LKS (Lane Keeping System) in ADAS (Advanced Driving Assistance System). However, such a lane detection system must operate accurately and in real time under various conditions on the road (optical reflection, weather, night time, occlusion). In this paper, a deep learning-based lane detection system that can operate in real time even at night in the Korean road environment is considered so that strategies for performance optimization are presented. To this end, in addition to the TuSimple data set, which is the foreign terrain daytime training dataset, a Korean terrain daytime and nighttime dataset was newly built and data augmentation techniques were added for training. Moreover the accuracy and real-time operation speed were measured on a single NVIDIA 2080ti GPU. As a result of this additional dataset construction and data augmentation additional training, accuracy improved from 76.9% to 92.4% accuracy at night time in Korea based on the Ultra Fast Lane Detection model, and from 84.6% accuracy to 96.7% accuracy based on the CLRNNet model could make an improvement.

※ 이 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2023 신산업분야 특화 선도전문대학 지원사업)

• First Author : Dong-Seoul University, Department of Electric Engineering, kdw1181@naver.com, 학생회원

◦ Corresponding Author : Dong-Seoul University, Department of Electric Engineering, sungjinlee@du.ac.kr, 정회원

* Dong-Seoul University, Department of Electric Engineering

논문번호 : 202301-004-C-RE, Received January 7, 2023; Revised March 8, 2023; Accepted April 4, 2023

I. 서론

최근 딥러닝 기술의 비약적 발전^[1,2]으로 자율주행 기술은 운전 보조 기능 (ADAS: Advanced Driver Assistance System)을 넘어서 완전 자율주행 (FSD: Full Self Driving) 단계에 이르고 있다. 하지만, 완전 자율주행의 단계까지 수많은 기술들이 100%의 성능 안전성이 요구되고 있어 사실 이를 위해서는 여러 센서들, 즉, 카메라, 라이다, 레이더, GPS, 가속센서, 초음파 센서 등 여러 센서 입력들을 조합하여 차량 인지 정확도를 높여서 최적의 판단, 제어 과정이 수행되어야 하지만, 아직 이런 멀티 모달 센서들의 실시간 처리를 위해서는 더 많은 연구가 남아있다고 볼 수 있다. 그럼에도 ADAS의 여러 요소 기술들은 이전보다 그 기술 완성도가 높아져 우리의 자동차를 더욱 안전하고 편리하게 만들어 주고 있기 때문에 관련 요소 기술들은 더욱 관심을 받고 관련 기술 개발은 지속될 것으로 예상되고 있다^[3].

본 논문에서는 이런 자율주행의 여러 요소 기술들 중 ADAS의 한 부분인 LKA의 핵심기술이면서 완전 자율주행 (Full Self Driving)에서도 요구되는 기술인 Lane Detection 기술에 초점을 맞추어 연구하였다. 특히 Lane Detection 기술은 Lidar로는 사실상 구현되기 힘들고 Camera에 전적으로 의존해야 하기 때문에 빛에 대한 영향, 즉 밤에 그 성능이 보장이 될 수 있을지에 대한 점에 중점을 두어 연구하였다.

또한 지역마다의 도로 환경 특성이 다른 점은 기존 오픈 데이터 셋을 통한 훈련이 새로운 지역에서 운용 시 정확도 저하를 일으킬 수 있는 원인이 된다. 그러므로 해당 지역에서 새롭게 데이터 셋을 구축해야 하며 이 또한 다양한 변이에 대응하기 위해서는 더 많은 데이터 증식 기술을 적용해야 할 것이다. 이를 위해 본 논문에서는 기존 오픈 데이터 셋으로 한국지형에서 운용 시 성능과 그 한계를 분석하고 한국지형에서 새롭게 데이터 셋을 구축하였을 시, 어느 정도의 성능 향상이 일어날 수 있는지에 대해 실험을 통해 분석하였다.

2장에서는 관련 Lane Detection 연구에 대해 소개하고, 3장에서는 본 연구에 사용된 Lane Detection 모델들인 Ultra-Fast Lane Detection, CondLaneNet과 CLRNet을 설명한다. 4장에서는 해당 모델 훈련을 위해 사용된 TuSimple Dataset과 추가적으로 구축된 Custom Dataset, 적용된 데이터 증식 기술들에 대해 설명한다. 5장에서는 실험을 통해 두 Lane Detection 모델의 성능을 비교하고 추가적으로 구축된 Custom

Dataset으로 어느 정도의 성능향상이 일어날 수 있는지, 낮과 밤 시간대 별로 성능을 분석하였다. 또한 이런 추가 데이터 셋 구축에 대해 데이터 증식이 추가되었을 경우 어느 정도의 성능 향상이 일어나는지 실험을 통해 분석하여 최적 차선인식 방법론에 대해 제시하였다.

II. 관련 연구

딥러닝 출현 이전의 차선인식에 관한 연구는 Hough Transform^[4], RANSAC (RANDOM SAMPLE Consensus)^[5], Edge Detection^[6]과 같이 수학적 영상 처리 알고리즘에 기반한 연구들이 주를 이루었다. 하지만 딥러닝의 출현^[1,2]으로 많은 컴퓨터 비전 문제들이 딥러닝 기반으로 새롭게 재해석되어 성능에 큰 진보를 보이기 시작했다. 그 대표적인 접근법으로 다음의 4가지가 주요하다.

우선 차선을 segmentation의 대상으로 간주하여 차선 영역을 추출해 내는 접근이 있다. 이 방법들^[7,8]은 기존 Segmentation의 방법에서 후보 영역을 한정 짓는 부분을 최적화 하여 개량하는 접근법들로 높은 정확도를 가지지만 다소 느린 인식 속도 성능을 갖는다.

또한 object detection의 2 stage 방식에 기반한 anchor-based 접근법들^[9,10]이 있었다. 연구^[9]에서는 Proposal 단계에서 hourglass network에 기반하여 key point들을 추출하고 후처리 단계에서 각 세부 차선 영역을 결정하였다. LaneATT 연구^[10]에서는 차선이 사선으로 위치해 있다는 규칙을 이용하여 사전에 anchor들을 사선으로 배치하여 attention^[11,12] 방식에 기반 하여 세부 차선 영역을 결정하였다.

세 번째로 위의 object detection 방식에서 차선 인식에 맞게 추가 성능 개량한 row-wise detection 방식이 있다^[13-15]. 이 방식은 anchor로서 각 행 (row) 들을 삼고 각 행 마다 후보가 되는 차선 지점을 찾는다. 그리고 찾아진 각 행의 후보 지점들을 연결함으로써 전체 차선을 완성하는 방식이다. 특히 CondLaneNet^[16]은 차선 후보 Key Point 들 간 instance-level discrimination 문제들을 극복하기 위해 RIM (Recurrent Instance Module)을 제안하였다. 이는 Key Point 들 간 차선으로서의 연속성을 유지하는 특성을 이용한 것으로 해당 기법을 통하여 높은 성능을 달성하였다.

마지막으로 Lane의 곡선 혹은 직선 형태를 수학적 으로 모델링하려는 파라미터 예측 기반 시도들^[16,17] 또한 이루어 졌다. PolyLaneNet 연구^[16]는 Lane의 형

태를 Polynomial Equation으로 Fitting 하려 하였고 ShapePred 연구^[17]에서는 Cubic Curve로 Approximation 하여 표현하였다. 하지만 해당 연구들은 복잡한 딥러닝 연산으로 Feature Extraction 하고 Post-Processing 하는 것에 비해 적은 연산을 소모 할수 있고 한정된 데이터 셋에서는 꽤 높은 정확도를 이룰 수는 있으나 Equation 이 표현할 수 있는 형태에 한계가 있기 때문에 데이터 셋에 따라 그 성능이 떨어질 수 있다.

III. 시스템 모델

본 연구의 대상 차선인식 모델로는 기본적으로 속도에 최적화된 Row-wise 접근 기술들을 사용하였으며, 그중에서도 속도에 좀 더 최적화된 UFLD^[13]와 정확도에 좀 더 최적화된 CondLaneNet^[15]과 CLRNet^[18]이 사용되었다. 이 두 기술을 설명하기에 앞서 검출 대상이 되는 차선들과 이들의 정확도 검출 방법은 다음과 같다.

3.1 인식 대상 차선 및 레이블링 규칙, 정확도 계산

본 연구에서 인식 대상으로 하는 차선은 다음 그림 1과 같이 총 4개의 차선이다. 이는 현재 자신의 차량이 속한 차선 구간을 기준으로 왼쪽 차선 L, 오른쪽 차선 R을 인식하고 현재 차선 구간의 왼쪽 차선 구간 인식을 위한 왼쪽 차선구간의 왼쪽 차선 LL, 그리고 현재 차선 구간의 오른쪽 차선 구간 인식을 위한 오른쪽 차선구간의 오른쪽 차선 RR을 인식한다

이를 레이블링 하기 위해서는 그림 2에서 보듯이 각 이미지 별로 규칙적인 구간의 수평 기준선 h_sample을 정의하고 해당 수평 기준선과 4개의 차선이 만나는 픽셀 좌표에 해당하는 숫자를 lanes를 기재한다.

마지막으로 이런 차선인식 모델의 정확도를 평가하




그림 1. 인식 대상 차선
Fig. 1. Target Lanes for detection.

```

"lanes" : [
    [-2, -2, 310, 305, ..., 250], → L (현재차선 왼쪽)
    [-2, -2, 370, 375, ..., 401], → R (현재차선 오른쪽)
    [-2, -2, 220, 205, ..., 35], → LL (왼쪽차선 왼쪽)
    [-2, -2, 420, 426, ..., 602], → RR (오른쪽차선 오른쪽)
],
"h_samples" : [220, 230, 240, 250, ..., 470] → 수평 기준선
    
```

그림 2. 차선 인식 레이블링 규칙
Fig. 2. Labeling Rule for Lane Detection.

기 위해 다음의 메트릭 Acc (Accuracy)를 정의한다.

$$Acc = \frac{\sum_{i \in R} C_i}{\sum_{i \in R} S_i} \quad (1)$$

여기서, R 은 정확도 평가를 요구하는 총 점들의 집합이며 이 집합 R 의 원소로서 i 가 있다. 그리고 S_i 는 평가를 요구하는 점을 뜻하는 indicator 함수로서 그 참, 거짓에 따라 1 혹은 0의 값을 반환한다. 마찬가지로 C_i 은 평가를 요구하는 점들 중 정답 값과 일치하는 점을 뜻하는 indicator 함수로서 그 참, 거짓에 따라 1 혹은 0의 값을 반환한다. 이를 통해 다음의 두 모델의 정확도 지표를 평가한다.

3.2 Ultra Fast Lane Detection

우선 속도 최적화를 위해 사용된 UFLD의 전체 구조도는 그림 3과 같다. 그림에서 보듯이 ResNet을 Backbone으로 사용하고 있으며, 해당 블록의 출력 특징 값을 완전연결 층을 거쳐 Row-wise Anchor 방식으로 4개 차선 성분을 점의 형태로 검출한다.

UFLD에선 anchor를 행으로 배치하여 격자 형태를 이루게 된다. 차선은 일반적으로 수평 방향이고 앵커를 행 방향으로 배치하면 차선을 비교적 정확히 감지할 수 있다. 이에 더해 ResNet 블록의 해당 중간 계층




그림 3. UFLD의 전체 구조도
Fig. 3. Overall Architecture of UFLD.

의 특징값 (Feature) 들을 따로 추출하여 해당 차선의 전체 형태를 도출한다.

3.3 CondLaneNet

이제 그림 4와 같이 정확도 검출 최적화를 위해 사용된 CondLaneNet의 전체 구조를 알아본다. 일단, 전체 구조는 다중 크기의 특징값 추출을 위한 Backbone과 각 차선들의 시작점들을 탐지하기 위한 Proposal Head, 각 차선의 전체 형태를 도출하기 위한 Conditional Shape Head로 구성된다. 우선 Backbone으로 ResNet 기반의 FPN (Feature Pyramid Network) 구조^[19]를 사용한다. Proposal Head는 RIM (Recurrent Instance Module)을 통해 4개 종류의 차선이 겹쳐서 인식되지 않도록 각자의 연속적 특징을 통해 구분해낸다. 이렇게 도출된 4개 종류 차선들은 conditional convolution^[20,21] 연산을 통해 행축 (Row-wise)와 수직 축 (Vertical Range) 상에서 차선의 전체 형태를 도출하였다.




그림 4. CondLaneNet의 전체 구조도
Fig. 4. Overall Architecture of CondLaneNet.

3.4 CLRNet

CLRNet은 고차원과 저차원 특징을 완전히 사용할 수 있는 cross layer를 사용한 모델로 전체 구조는 그림5와 같다. 기본적으로 ResNet을 Backbone으로 사용하고 있다. 생성된 features map은 cross layer refinement modules을 거쳐 정제되고 다른 모듈과 합쳐지며 features map은 고차원과 저차원 정보를 모두 포함하게 된다. 또한 global-local attention 메커니즘을 사용하여 차선의 경계를 더욱 정확하게 예측한다. global attention 모듈은 전체 이미지에 초점을 맞춰 학습하고 local attention RIM은 차선의 경계가 포함될 수




그림 5. CLRNet의 전체 구조도
Fig. 5. Overall Architecture of CLRNet

있는 영역을 학습한다. CLRNet은 고차원 저차원의 특징을 합하는 cross layer 방식과 global-local attention 메커니즘을 통해 TuSimple, CuLane과 LLAMAS에서 최고 성능을 달성하였다.

IV. 데이터 셋 구축 및 데이터 증식 기법

4.1 TuSimple

본 연구에서는 기반 데이터 셋으로 TuSimple 데이터 셋^[22]을 사용하였다. TuSimple 데이터 셋은 3626장의 훈련 이미지와 2782장의 테스트 이미지로 구성된다. 해당 이미지들은 미국의 낮시간 일반도로 및 고속도로 주행 환경에서 촬영되었으며 해당 예시 이미지들은 그림 6에 나타내었다.



그림 6. TuSimple 데이터 셋의 예시
Fig. 6. Examples of TuSimple Dataset.

4.2 Custom Dataset

그림 6에서 보듯이 미국 지형은 한국 지형의 도로와는 많은 차이가 있어 실적용 시, 성능 저하가 발생할 수 있다. 또한 한국은 대부분의 차량들이 수도권 주요 도심지역 (Urban Area)에 분포하는데, 이런 환경과는 상당한 차이가 있다. 마지막으로 밤시간대의 데이터가 없다.

이전 연구^[23]에서는 이런 부족한 점을 극복하고자 한국 지형 도심지역을 중심으로 고속도로 시나리오와 교외지역 시나리오를 더하여 밤시간, 낮시간 모두에서 데이터를 취득하여 데이터 셋을 추가 구축하였다.

본 논문에선 Custom Dataset에 다양한 데이터 증식 기법을 적용하여 정확도에 끼치는 영향에 대해 실험하였다. 그림 7에서는 데이터 셋 구축을 위해 사용한 기기들의 스펙을 나타내었다. [24]에서는 해당 차선인식을 위해 사용된 데이터 셋인 DULane을 다운받을 수 있다.

위 구축된 기기들 중 Lane Detection을 위해서 직접적으로 영향을 미치는 왼쪽 카메라 (운전자 기준)에서 수집되는 영상 이미지를 통해 데이터 셋을 구축하였다. 카메라는 FHD (1920x1080) 30 FPS 126° 화각을 지닌 WebCam을 사용하여 영상을 획득하였다. 경

로는 동서울대학교를 중심으로 3가지 코스 즉, 교외 지형, 도심 지형, 고속도로 지형에 대해 낮 (12시30분~1시30분) 과 밤 (8시~9시) 시간대 각각에 대해 데이터를 획득하였다. 그림 8에서는 해당 주행 지역을 지도로 나타내었고, 그림 9에서는 해당 데이터 셋의 예시를 나타내었다.



그림 7. 자체 데이터 셋 DULane 구축을 위해 사용된 장비들
Fig. 7. Equipments utilized for Custom Dataset.

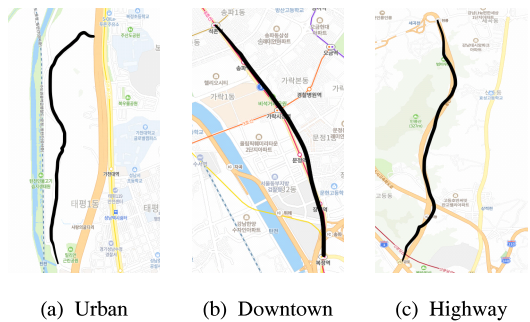


그림 8. DULane 데이터 셋 구축을 위한 3가지 주행 지역들
Fig. 8. Driving Area for building DULane Dataset.




그림 9. 구축된 Custom DULane Dataset의 예시
Fig. 9. Examples of Custom DULane Dataset.13

4.3 데이터 증식 기법

우선 형태적 데이터 증식 측면에서는 기본적으로 Rotation 기법을 적용하고 Random Crop, Shearing, Local Warping 들은 적용하지 않았다. 그 이유는 해당 기법들을 적용 시, 도로의 형태가 불연속이 되거나

비정상적인 형태의 도로가 나올 수 있기 때문이다. 또한 데이터 증식을 통한 밤 시간대의 정확도 향상 정도를 보기위해 색 변환 적 데이터 증식을 시도하였다. 색 변환 적 데이터 증식 측면에서는 낮 데이터를 흑백 이미지 변환 (Grayscale)하였고, 밝기 조정 (Brightness Control), CycleGAN^[25] 기반의 스타일 변환 (Style Transfer)을 적용하였다.

4.4 CycleGan

CycleGan은 도메인을 공유하지 않는 데이터 간 변환이 가능한 신경망이다. CycleGan은 적대적 손실을 사용하여 판별자가 $G(x)$ 와 y 를 구별할 수 없도록 학습하고 동시에 역방향 $F(y)$ 를 학습 하게 된다. 이런 방식은 $G(x)$ 와 y 의 의미 있는 관계를 보장하지 않아 Mode Collapse가 발생할 수 있다.

CycleGan은 $F(G(x)) \approx y$, $G(F(y)) \approx x$ 방식에 의한 Cycle Consistency Loss을 통해 Mode Collapse를 방지하여 더 정확한 결과를 도출하게 된다. 즉, Cycle Consistency Loss는 입력 이미지의 결과 이미지를 다시 입력 이미지로 회귀함으로서 생기는 차이를 손실로 사용하여 Mode Collapse 문제를 보완한다. CycleGan 기반의 스타일 변환을 통해 실제 한국도로에서 낮 시간대 이미지와 밤 시간대 이미지를 훈련시켜 낮 시간대 이미지를 밤처럼 스타일 변환을 하였다.

해당 실험은 Epoch=200, Learning Rate=0.0002, Adam Optimizer, Batch Size=1, Loss Weight ($\lambda = 10$) 의 설정으로 훈련하였으며 그림 10은 해당




그림 10. CycleGan을 사용한 밤시간 Style Transfer의 예시
Fig. 10. Examples of Nighttime Style Transfer Using CycleGan.

표 1. 차선인식을 위한 데이터 증식 기법들
Table 1. Data Augmentation Techniques for Lane Detection.

적용	대상 기술
기본 적용	Rotation
선택 적용	Grayscale, Brightness Control, Style Transfer
적용 제외	Random Crop, Shearing, Local Warping

변환 예시 이미지를 보여준다.

4.5 Evaluation Set

실험을 위해 다음과 같은 Evaluation Set을 정하여 진행하였다.

- BS (Basic Set) : TuSimple 데이터 셋에서 훈련을 진행
- BS+RD : 실제 한국도로에서 낮 시간대에 촬영하여 얻어진 데이터 셋을 추가하여 훈련
- BS+RN : 실제 한국도로에서 밤 시간대에 촬영하여 얻어진 데이터 셋을 추가하여 훈련
- BS+RD+RN : 실제 한국의 도로를 낮, 밤 시간대에 얻어진 데이터 셋을 추가하여 훈련
- BS+BS2D : TuSimple 데이터 셋을 Brightness를 어둡게 조정된 데이터 셋을 추가하여 훈련
- BS+RD2G : 실제 한국도로에서 낮 시간대에 촬영하여 얻어진 데이터를 Grayscale로 변환한 데이터 셋을 추가하여 훈련
- BS+RD2D : 실제 한국도로에서 낮 시간대에 촬영하여 얻어진 데이터에 Brightness를 어둡게 조정된 데이터 셋을 추가하여 훈련
- BS+RD2S : 실제 한국도로에서 낮 시간대에 촬영하여 얻어진 데이터를 Style Transfer로 밤 이미지로 변환한 데이터 셋을 추가하여 훈련
- BS+All(100) : 위 모든 데이터 증식기법들을 사용하고 데이터셋 크기에 따른 차이를 보기위해 크기를 조정하여 훈련
- BS+All(200) : 위 모든 데이터 증식기법들을 사용하여 훈련

Table 2는 데이터의 조합 별 훈련에 사용된 데이터

표 2. 데이터 조합 별 데이터 셋 크기
Table 2. Data Set Size by Data Augmentation.

데이터 조합	SIZE
BS	140K
BS+RD	140K + 50
BS+RN	140K + 50
BS+RD+RN	140K + 100
BS+BS2D	140K + 100
BS+RD2G	140K + 100
BS+RD2D	140K + 100
BS+RD2S	140K + 100
BS+All(100)	140K + 100
BS+All(250)	140K + 250

셋의 크기를 나타낸 표이다. Tusimple 데이터 셋 약 140,000장을 BS로 설정하고 Custom 데이터 셋을 더 하여 데이터 조합을 설정하였다.

V. 실험

Tusimple 데이터 셋에 대하여 사전 학습된 모델에 한국 지형 데이터를 추가한 데이터 조합을 학습시켜 추가 학습을 진행하였다. 해당 데이터 셋에 대해 Epoch=50, Learning Rate=0.1, Batch Size=32의 설정으로 각 조합 당 한 번씩 훈련하였고, NVIDIA 2080ti GPU 기준으로 실험하였다.

그러면 Ultra Fast Lane Detection의 결과는 다음 Table 3와 같이 얻어지고, CondLaneNet의 결과는 Table 4, CLRNet의 결과는 Table 5와 같이 얻어진다. 우선 Table 3의 BS의 정확도를 보면 낮 시간대에는 88.7%의 정확도를 얻지만 밤 시간대에서는 76.9%의 정확도를 얻는다. 또한 Table 4와 Table 5의 BS의 정확도 역시 낮 시간대에는 90.4%, 96.8%의 정확도를 얻지만, 밤시간대에는 78.2%, 84.6%로 시간대에 따라 정확도의 차이가 상당하다는 것을 알 수 있다. 이를 통해 TuSimple처럼 외국 도로 낮 시간 환경에서 얻어지는 데이터는 국내 자율주행 시 낮 시간대에는 어느 정도의 성능을 얻을 수 있으나 밤 시간대 자율주행 시 정확도에 한계가 있을 수 있다.

이제 Table 3, Table 4와 Table 5의 BS+RD, BS+RN의 경우를 살펴보자. 두 경우 보강된 시간대의 경우에서 두드러진 성능 향상이 나타남을 알 수 있다. 하지만 BS+RD의 경우 밤 시간대에서도 두 모델

표 3. UFLD의 정확도 및 지연 성능 결과
Table 3. The accuracy and Latency performances of UFLD.

데이터 조합	시간		지연 (FPS)
	낮	밤	
BS	88.7	76.9	93.5
BS+RD	92.6	83.7	90
BS+RN	89.2	92.4	75.2
BS+RD+RN	91.7	91.7	95.2
BS+BS2D	78.3	71.9	80
BS+RD2G	92.0	82.9	92.6
BS+RD2D	91.7	82.7	80
BS+RD2S	91.9	80.9	70.9
BS+All(100)	92.2	92.1	70.3
BS+All(250)	92.5	92.2	69.9

표 4. CondLaneNet의 정확도 및 지연 성능 결과
Table 4. The accuracy and Latency performances of CondLaneNet.

데이터 조합	시간		지연 (FPS)
	낮	밤	
BS	90.4	78.2	89.3
BS+RD	93.6	84.1	80.6
BS+RN	89.9	93.4	69.4
BS+RD+RN	93.2	93.3	82.6
BS+BS2D	78.9	73.3	82.6
BS+RD2G	93.0	83.6	84
BS+RD2D	92.2	83.4	75.8
BS+RD2S	92.7	82.1	62.9
BS+All(100)	92.7	93.3	61.3
BS+All(250)	92.9	93.5	60.2

표 5. CLRNet의 정확도 및 지연 성능 결과
Table 5. The accuracy and Latency performances of CLRNet.

데이터 조합	시간		지연 (FPS)
	낮	밤	
BS	96.8	84.6	88.9
BS+RD	96.7	89.9	81.7
BS+RN	96.7	96.3	71.5
BS+RD+RN	96.6	96.4	83.2
BS+BS2D	96.3	80.8	82.9
BS+RD2G	95.5	88.4	85.3
BS+RD2D	96.7	88.7	76.3
BS+RD2S	96.6	86.6	64.3
BS+All(100)	97.0	96.5	62.9
BS+All(250)	97.1	96.7	62.1

모두에서 성능 향상이 상당함을 알 수 있다. 이것은 시간대가 다를지라도 한국도로에 대한 특징이 학습이 되어 정확도가 향상되었기 때문이다.

다음으로 Table 3, Table 4와 Table 5의 BS+BS2D의 성능을 보면 좋지 않음을 알 수 있다. 심지어 BS 하나에 대해서만 훈련한 경우보다도 열화 되는데, 이를 통해 올바른 방향의 데이터 증식을 사용해야 한다는 것을 알 수 있다.

이제 한국지형 낮 데이터에 밤 스타일로의 다양한 변화를 하여 추가 훈련하였을 경우를 살펴보자. Table 3, Table 4와 Table 5의 BS+RD2G, BS+RD2D, BS+RD2S 모두의 경우에서 유사한 수준의 성능 향상이 일어남을 알 수 있다. 하지만, BS+RD 보다도 좋지

못한 성능을 내기 때문에 이 또한 그 자체로는 바람직한 데이터 증식 방식은 아니라는 것을 알 수 있다.

BS+RD2G, BS+RD2D, BS+RD2S 모두 추가한 데이터 셋의 이미지 수는 같지만 BS+RD2G, BS+RD2D가 BS+RD2S보다 약 2% 정도 성능 향상이 일어남을 알 수 있다. 또한 BS+All(100)과 BS+All(200)의 경우를 비교해 봐도 동일 데이터 증식 방식에 대해 데이터 장수에 따른 변화에 따라 성능이 유사함을 알 수 있다. 이를 통해 추가 데이터 셋의 이미지 수에 의한 정확도의 영향보다 데이터 증식 방법에 따른 영향이 더 크다 볼 수 있다.

UFLD의 경우 BS+RN 조합에선 6% 정도의 정확도 차이를 보이고 BS+RD의 경우 15% 정도의 정확도 차이를 볼 수 있다. CondLaneNet의 경우 BS+RD에선 78.2%에서 84.1%, BS+RN의 경우 93.4%로 정확도의 증가를 볼 수 있다. 마찬가지로 CLRNet의 경우 BS+RD에선 84.6%에서 89.9%로 정확도가 증가하고 BS+RN의 경우 96.3%로 정확도가 크게 증가한다.

실험 결과로 보아 Low Level과 High Level정보를 공유하는 실제 환경에 맞는 소규모 데이터를 추가하여 추가 학습을 통해 정확도를 증가 시킬 수 있다는 것을 알 수 있다.

마지막으로 위에서 언급된 모든 데이터 증식 방식을 혼합하여 사용하는 BS+All의 경우 낮과 밤 모두에서 가장 좋은 수준의 성능 향상이 일어난다는 것을 알 수 있다. 이는 BS+RD+RN 보다도 좋은 성능으로서 낮과 밤 모두에서 동일한 훈련 모델로 동작 시킬 경우 모든 데이터 증식 방식을 적용하는 것이 가장 좋은 정확도를 얻을 수 있다는 결론을 얻을 수 있다. BS+All(100)과 BS+All(250)을 비교해보면 정확도와 지연시간 차이가 있지만 매우 적은 것을 알 수 있다. 이를 보아 데이터 장수에 따른 성능의 변화는 적다는 것을 알 수 있다.

또한 모델 선택의 관점에서 보면, 정확도 관점에서는 CLRNet이 다른 모델보다 정확도 5%정도 앞서는 걸 알 수 있다. 속도관점에서는 UFLD가 다른 모델보다 10fps정도 빠르다는 것을 알 수 있다. 만약 동작 하드웨어가 충분히 좋다면 속도의 차이는 더 줄어들 것 이지만 정확도는 여전히 5% 정도 차이를 보이므로 CLRNet이 좋은 선택일 수 있다. 하지만, 고속으로 주행하며 하드웨어 성능이 좋지 못하다면 UFLD를 사용하는 것이 추천된다고 하겠다.

Fig 11, 12, 13에서 각각 UFLD, CondLaneNet과 CLRNet의 차선인식 결과 예시를 확인 할 수 있다.




그림 11. UFLD의 차선인식 결과 예시
Fig. 11. Result Examples of UFLD.




그림 13. CLRNet의 차선인식 결과 예시
Fig. 13. Result Examples of CLRNet.




그림 12. CondLaneNet의 차선인식 결과 예시
Fig. 12. Result Examples of CondLaneNet.

VI. 결 론

본 논문에서는 한국 도로환경에서 밤시간에도 실시간으로 정확하게 동작할 수 있는 딥러닝 기반 차선인식 시스템에 대해 고찰하고 성능 최적화를 위한 전략들을 제시하였다. 또한 딥러닝 기반 차선인식 방법 및 레이블링 원리에 대해 국내 논문으로서는 처음으로 제시하였다. 이를 위해 기존 외국 지형 낮 시간대의 훈련 데이터인 TuSimple 데이터 셋에 더하여 한국 지형 낮 시간대 및 밤 시간대 데이터 셋을 구축하고 데이터 증식 기법들을 추가하여 훈련을 시켰으며 NVIDIA 2080ti 단일 GPU에서 그 정확도 및 실시간 동작 속도를 측정하였다. 이런 추가 데이터셋 구축 및 데이터 증식 추가 훈련의 결과 Ultra Fast Lane Detection 모델을 기준으로 한국 지형 밤 시간대에 76.9 %의 정확도에서 한국 밤, 낮 데이터에 대해 추가 훈련을 시킨다면 92.4 %의 정확도 향상을 CondLaneNet 모델을 기준으로 78.2%의 정확도에서 93.4%의 정확도 향상을 이룰 수 있었다. CLRNet에서는 84.6%의 정확도에서 96.7%의 정확도 향상을 이룰 수 있었다. 이 실험들을 통해 주행 시 겪을 수 있는 다양한 환경의 데이터 셋에 대해 훈련을 하는 것이 안

정적 성능을 확보 할 수 있는 방안임을 알 수 있었다.

또한 실제 환경에 맞는 데이터 추가를 통한 추가 학습으로 정확도 향상을 이룰 수 있고 올바른 방향의 데이터 증식 전략이 필요하다는 것을 알 수 있었다.

References

- [1] A.Krizhevsky, I.Sutskever, G.E.Hinton, “ImageNet Classification with Deep Convolutional Neural Networks”, NIPS2015, (<https://doi.org/10.1145/3065386>)
- [2] K.He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, “Deep Residual Learning for Image Recognition”, IEEE Computer Vision and Pattern Recognition 2014, (<https://doi.org/10.48550/arXiv.1512.03385>)
- [3] D. Liang, Y. Guo, S. Zhang, Tai-Jiang Mu1 and Xiaolei Huang, “Lane Detection: A Survey with New Results”, JOURNAL OF COMPUTER SCIENCE AND TECHNOLOGY 35(3): 493-505 May 2020. (<https://doi.org/10.1007/s11390-020-0476-4>, <https://doi.org/10.1007/s11390-020-0476-4>)
- [4] G. Liu, F. Wörgötter, Irene Markelic, “Combining Statistical Hough Transform and Particle Filter for robust lane detection and tracking”, 2010 IEEE Intelligent Vehicles Symposium. 10.1109/IVS.2010.5548021.
- [5] A. Borkar, M. Hayes, and M. T. Smith, “Robust lane detection and tracking with ransac and kalman filter”, In Proceedings of the IEEE International Conference on Image Processing (ICIP), pages 3261 - 3264, 2009.10.1109/ICIP.2009.5413980.
- [6] P. M. Daigavane and P. R. Bajaj, “Road Lane Detection with Improved Canny Edges Using Ant Colony Optimization“, 2010 3rd International Conference on Emerging Trends in Engineering and Technology, 2010, pp. 76-80,10.1109/ICETET.2010.128.
- [7] S. Lee, J. Kim, Jae S. Yoon, S, Shin, Oleksandr Bailo, Namil Kim, Tae-Hee Lee, Hyun Seok Hong, Seung-Hoon Han, and In So Kweon, “VPGNet: Vanishing Point Guided Network for Lane and Road Marking Detection and Recognition”, In Proceedings of the IEEE International Conference on Computer Vision, pages 1947 - 1955, 2017.10.1109/ICCV.2017.215.
- [8] X. Pan, J. Shi, P. Luo, X. Wang, and X. Tang, “Spatial as deep: Spatial cnn for traffic scene understanding”, In Proceedings of the AAAI Conference on Artificial Intelligence, 2018.10.1609/aaai.v32i1.12301
- [9] Z. Chen, Q. Liu, C. Lian, “Pointlanenet: Efficient end-to-end cnns for accurate real-time lane detection”, In IEEE Intelligent Vehicles Symposium (IV), pages 2563 - 2568, 2019.10.1109/IVS.2019.8813778.
- [10] L.Tabelini, . Berriel, T. M Paixao, C. Badue, Alberto F De Souza, Thiago Olivera-Santos, “Keep your eyes on the lane: Attention-guided lane detection”, arXiv preprint arXiv:2010.12035, 2020. (<https://doi.org/10.48550/arXiv.2010.12035>)
- [11] J. Phillion, Fastdraw, “Addressing the long tail of lane detection by adapting a sequential prediction network“, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pages 11582 - 11591, 2019. (<https://doi.org/10.48550/arXiv.1905.04354>)
- [12] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N Gomez, u. Kaiser, and Illia Polosukhinm, “Attention is all you need”, In Advances in Neural Information Processing Systems, 2017. (<https://doi.org/10.48550/arXiv.1706.03762>)
- [13] Qin, Zequn and Wang, Huanyu and Li, Xi, “Ultra Fast Structure-aware Deep Lane Detection”,In Proceedings of IEEE Transactions on Pattern Analysis and Machine Intelligence, pages 1-14, 2022, (<https://doi.org/10.48550/arXiv.2004.11757>)
- [14] Seungwoo Yoo, Hee Seok Lee, Heesoo Myeong, Sungrack Yun, Hyoungwoo Park, Janghoon Cho, and Duck Hoon Kim, “End-to-end lane marker detection via row-wise classification”, In Proceedings of the IEEE Conference on Computer Vision and


- Pattern Recognition Workshops, pages 1006-1007, 2020.10.1109/CVPRW50498.2020.00511.
- [15] Lizhe Liu, Xiaohao Chen, Siyu Zhu, Ping Tan, “CondLaneNet: a Top-to-down Lane Detection Framework Based on Conditional Convolution”, ICCV 2021, (<https://doi.org/10.48550/arXiv.2105.05003>)
- [16] Lucas Tabelini, Rodrigo Berriel, Thiago M Paixao, Claudine Badue, Alberto F De Souza, and Thiago Oliveira-Santos, “Polylanenet: Lane estimation via deep polynomial regression”, In Proceedings of the International Conference on Pattern Recognition, 2020. (<https://doi.org/10.48550/arXiv.2004.10924>)
- [17] Ruijin Liu, Zejian Yuan, Tie Liu, and Zhiliang Xiong, “End-to-end lane shape prediction with transformers”, In Proceedings of the IEEE Winter Conference on Applications of Computer Vision, pages 3694 - 3702, 2021.10.1109/WACV48630.2021.00374.
- [18] Zheng, Tu and Huang, Yifei and Liu, Yang and Tang, Wenjian and Yang, Zheng and Cai, Deng and He, Xiaofei, “CLRNet: Cross Layer Refinement Network for Lane Detection”, Proceedings of the IEEE/CVF Conference on Computer Vision, pp.898-907, 2022 (<https://doi.org/10.48550/arXiv.2203.10350>)
- [19] Tsung-Yi Lin, Piotr Dollár, Ross Girshick, Kaiming He, Bharath Hariharan, and Serge Belongie. “Feature pyramid networks for object detection.” In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 2117-2125, 2017. (<https://doi.org/10.48550/arXiv.1612.03144>)
- [20] Xu Jia, Bert De Brabandere, Tinne Tuytelaars, and Luc Van Gool. “Dynamic filter networks.” In Advances in Neural Information Processing Systems, page 667-675, 2016, (<https://doi.org/10.48550/arXiv.1605.09673>)
- [21] B. Yang, G. Bender, Quoc V Le, and J. Ngiam. “Condconv: Conditionally parameterized convolutions for efficient inference.” In Advances in Neural Information Processing Systems, 2019. (<https://doi.org/10.48550/arXiv.1904.04971>)
- [22] TuSimple. Tusimple benchmark. <https://github.com/TuSimple/tusimple-benchmark/>, Accessed September, 2020
- [23] S.Koh, J.Han, Y.Lim, S. Lee, “A Study on the Real-Time Lane Detection at Night in Korea”, The 2ndKorea Artificial Intelligence Conference, B-2-3,2021,10.1109/ICCE56470.2023.10043513.
- [24] <https://github.com/SungjinDavidLee/DULane>
- [25] J. Zhu*, T. Park*, P. Isola, and A.A. Efros. “Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks”, in IEEE International Conference on Computer Vision (ICCV), 2017.10.1109/ICCV.2017.244.

곽 대 원 (Daewon Kwak)



2022년 2월 : 동서울대학교 전
자공학과 졸업
<관심분야> 딥러닝, 영상인식,
Computer Vision

유 지 상 (Jisang Yoo)



2022년 2월 : 동서울대학교 전
자공학과 졸업
<관심분야> 딥러닝, 영상인식

손 민 준 (Minjun Son)



2023년 2월: 동서울대학교 컴
퓨터정보과 졸업
<관심분야> 딥러닝, 영상인식

최 등 건 (Donggeon Choi)



2023년 2월: 동서울대학교 컴
퓨터정보과 졸업
<관심분야> 딥러닝, 영상인식

박 민 수 (Minsu Park)



2023년 2월: 동서울대학교 컴
퓨터정보과 졸업
<관심분야> 딥러닝, 영상인식

이 성 진 (Sungjin Lee)



2011년 8월: 연세대학교 전자
공학과 박사 졸업
2012년 9월~2016년 7월: 삼성
전자 DMC연구소 책임연구원
2016년 7월~현재: 동서울대학
교 전자공학과 조교수
<관심분야> 딥러닝, 영상인식,
3D Reconstruction,