

논문 2023-18-28

# 자율 주행을 위한 심층 학습 기반 차선 인식 모델 분석

## (Analysis of Deep Learning-Based Lane Detection Models for Autonomous Driving)

이 현 종, 윤 의 현, 하 정 민, 이 재 구\*  
(Hyunjong Lee, Euihyun Yoon, Jungmin Ha, Jaekoo Lee)

Abstract : With the recent surge in the autonomous driving market, the significance of lane detection technology has escalated. Lane detection plays a pivotal role in autonomous driving systems by identifying lanes to ensure safe vehicle operation. Traditional lane detection models rely on engineers manually extracting lane features from predefined environments. However, real-world road conditions present diverse challenges, hampering the engineers' ability to extract adaptable lane features, resulting in limited performance. Consequently, recent research has focused on developing deep learning based lane detection models to extract lane features directly from data. In this paper, we classify lane detection models into four categories: cluster-based, curve-based, information propagation-based, and anchor-based methods. We conduct an extensive analysis of the strengths and weaknesses of each approach, evaluate the model's performance on an embedded board, and assess their practicality and effectiveness. Based on our findings, we propose future research directions and potential enhancements.

Keywords : Autonomous driving, Deep Learning, Lane Detection, Embedded System

### 1. 서 론

최근 자율 주행 기술의 발전으로 인해 자율 주행이 적용되는 분야가 점점 확대되고 있다. 국내에서는 3단계 자율 주행 차량이 도입될 예정이며, 정부는 2027년까지 완전 자율 주행 차량을 도입할 계획이다 [1].

하지만 자율 주행 관련 사고가 증가하여 상용화에 대한 문제가 제기되고 있다. 이미 상용화된 2단계 자율 주행 사고는 2021년부터 2022년까지 400건 이상 발생했으며, 4단계 완전 자율 주행 차량의 시범 운행 중에도 130건의 사고가 발생했다 [2].

자율 주행 사고가 증가하면서, 자율 주행 안전에 대한 관심이 높아졌다. 따라서 자율 주행의 안전에 기반이 되는 차선 인식 기술을 개발하는 것은 중요하다. 차선 인식은 그림 1에서 보이듯 입력 영상에서 차선을 분류하는 과업이다. 차선 이탈을 방지하기 위해서는 높은 차선 인식 성능이 필수이며, 또한 실시간으로 동작하기 때문에 빠른 추론 속도도 중요하다.

전통적인 차선 인식 방법은 차선의 형태와 색상 등 특징들을 수동으로 추출하는 특징 공학 (Feature Engineering)이 사용되었다 [3]. 이 방법에는 형태학적 연산을 사용하여 노이즈를 제거하고 밝기에 대한 기울기 (Gradient)를 계산하여




그림 1. 차선 인식 예시  
Fig. 1. Lane detection example

차선 외곽선을 추출하는 방식, 미리 정의한 차선 색상 범위를 기반으로 차선 후보를 추출하는 방식, 로버트 마스크 (Robert Mask)와 허프 변환 (Hough Transform)을 이용하여 직선을 추출하는 방식 등이 있다 [4-6]. 하지만 전통적인 차선 인식 방법은 특정 상황에 따라 차선의 특징을 추출하기 때문에, 비, 안개, 조명 조건, 부분 폐색 등 다양한 환경 조건에서 사용하기 어려운 한계점이 있다. 이러한 한계점을 개선하기 위해 최근에는 차선 인식에 딥러닝 기술을 활용한 연구가 진행되고 있다 [7].

딥러닝은 모델이 많은 양의 데이터로부터 일반화된 특징을 학습하기 하여 필요한 특징을 자동으로 추출할 수 있기 때문에 엔지니어의 주관에 의존하지 않는다. 따라서 모델의 일반화 성능이 향상되어 다양한 환경 조건에서도 높은 차선 인식 성능을 보여준다.

\*Corresponding Author (hong@em.org)  
Received: Jun. 17, 2023, Revised: Aug. 3, 2023, Accepted: Aug. 31, 2023.  
Hyunjong Lee: Kookmin University (M.S. Student.)  
Euihyun Yoon: Kookmin University (M.S. Student.)  
Jungmin Ha: Kookmin University (M.S. Student.)  
Jaekoo Lee: Kookmin University (Assistant Professor)  
※ 이 성과는 정부 (과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No.RS-2023-0021248).

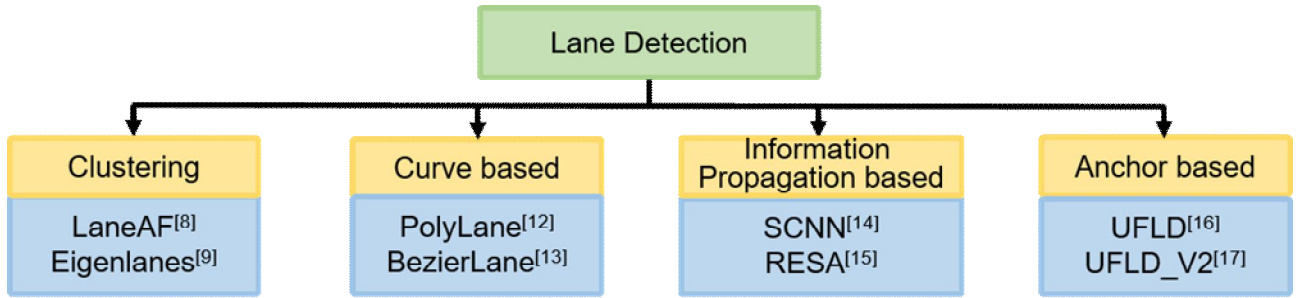


그림 2. 차선 인식 모델 분류  
Fig. 2. Taxonomy of Lane Detection models

본 논문에서는 그림 2에서 보이듯 딥러닝 기반 차선 인식 모델을 분류하고, 분류 기준에 맞게 분석 및 평가했다. 본 논문의 기여를 정리하면 다음과 같다.

- 차선 검출 모델을 정보 전파, 곡선 기반, 클러스터링, 앵커 기반의 네 가지 방식으로 분류하고, 각 모델을 구조적으로 분석했다.
- 대표적인 공개 데이터 집합을 통해 분류한 모델의 정확도를 검증하고, 임베딩 보드를 활용하여 추론 시 성능을 평가했다
- 실험 결과를 종합하여 각 분류 방식의 장단점을 파악하고, 장단점의 원인을 분석했다.

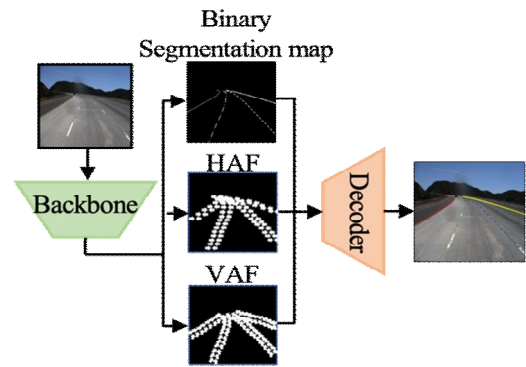


그림 3. LaneAF의 구조  
Fig. 3. Overview of LaneAF

II. 본론

딥러닝 기반 차선 인식은 이미지 분할 과업에서 파생되어 독자적으로 발전되었다. 이 섹션에서는 차선 인식을 분류하고 각 분류에 대표적인 모델을 소개한다.

1. 군집화 방식

차선은 도로 환경에 따라 차선의 개수 혹은 형상이 변화한다. 하지만 전통적인 차선 인식은 고정된 개수의 차선만 인식하거나 다양한 차선 형상에 대한 정보를 활용하지 못한다.

군집화 방식은 위 한계점을 해결하기 위해 만들어진 방법이다. 주로 차선을 픽셀 단위로 예측한 이진 분할 영상에 군집화를 사용하여 개별적인 차선 객체를 구분한다. 혹은 다양한 차선 형상의 정보를 활용하기 위해 학습 데이터에서 차선을 군집화하여 차선 후보를 형성한다.

1.1 Lane Affinity Fields (LaneAF) [8]

LaneAF는 이진 분할 영상에서 차선을 분리하고 선호도 필드 (Affinity Fields)를 이용하여 차선간의 클러스터링을 수행한다. 모델은 그림 3 에서 보이듯 백본망, 선호도 필드, 디코더로 되어 있으며 선호도 필드는 위치와 방향으로 인코딩된 유닛 벡터로 구성된다.

입력 이미지가 주어지면 백본망에서 이진 분할 영상과 서로 다른 선호도 필드인 Horizontal Affinity Field (HAF)와 Vertical Affinity field (VAF)를 추출한다. 이때 HAF는 차선 픽셀을 수평 방향으로 클러스터링하고 VAF는 차선 픽




그림 4. Eigenlanes의 구조  
Fig. 4. Overview of Eigenlanes

셀을 수직 방향으로 클러스터링한다. 이후 디코더는 HAF와 VAF의 예측값을 사용하여 행 단위로 디코딩을 수행하고 이후 차선 픽셀을 예측한다.

LaneAF는 선호도 필드를 사용하여 명시적으로 차선의 관계를 학습할 수 있어 디버깅이 쉬운 장점이 있다. 그러나 이를 구하기 위해 추가적인 연산 비용이 발생하는 문제점이 있다.

1.2 Eigenlanes [9]

Eigenlanes는 그림 4에서 보이듯 Eigenline Space를 구성하는 단계, Eigenline Space에서 차선 후보를 클러스터링하는 단계, 제안된 SIIC-Net을 사용하여 최적의 차선을 찾고 조정하는 단계로 구성된다.

각 단계에 대해서 살펴보면 Eigenlane은 차선 정보를 저차원으로 투영시켜 표현한 값이다. 학습 전 미리 훈련 데이터 집합에 특이값 분해를 사용하여 계산한다.

이후 Eigenlane을 K-means 알고리즘을 사용하여 제한된 수의 차선 후보를 생성한다. 이 과정은 학습 전 미리 수행하기 때문에 학습 속도에 영향을 미치지 않는다 [10].

SIIC-Net은 인코더, 디코더, Self-Lane Identification (SI) 모듈, Inter-Lane Correlation (IC) 모듈로 구성된다. 인코더에서 특징맵을 추출하고 디코더에서 이를 이용하여 이진 분할 영상을 만든다.

SI 모듈에서 차선 특징 맵을 생성하고 정보를 예측하며, Non-Maximum Suppression (NMS)를 통해 중복 차선 후보를 제거한다. IC 모듈에서는 선택된 차선 쌍의 관계 점수를 추정하고, 최적의 차선을 결정하는 Maximum Weight Clique Selection (MWCS) 알고리즘을 사용한다 [11].

Eigenlanes는 차선 정답 데이터 기반으로 다양한 형태의 차선을 처리할 수 있다는 장점이 있다. 하지만 Eigenlane을 구하기 위해 미리 차선 정답 데이터를 가지고 있어야 하고 추가적인 후처리가 필요하다는 단점이 있다.

2. 곡선 기반 방식

기존 딥러닝 기반 차선 인식 모델은 주로 이미지 분할 방식으로 구성되어 되어 있다. 따라서 모든 이미지 픽셀을 구분하기 때문에 연산 비용이 많이 드는 단점이 있다.

이러한 단점을 해소하기 위해 곡선 기반 방식은 차선을 곡선으로 모델링하고 곡선의 매개 변수 혹은 조절점을 구한다. 이때 이미지 픽셀에 비해 매개 변수 혹은 조절점의 개수는 매우 적기 때문에 연산량이 감소할 수 있다.

2.1 PolyLaneNet [12]

PolyLane은 차선을 다항식으로 근사해서 모델링한 방식이다. 그림 5에서 보이듯 모델 구조는 특징을 추출하는 백본망, 차선의 파라미터를 추출하는 완전 연결 층으로 구성된다.

PolyLane은 백본망에서 이미지의 특징을 추출하고 완전 연결층에서 다항식에 대한 파라미터, 각 차선이 시작하는 y 축 좌표, 각 차선에 대한 신뢰도 값 그리고 전체 차선이 끝나는 y 축 좌표인 공유 높이를 추출한다.

그림 5에서 보이듯 차선의 파라미터 (Lane Param)는 다항식의 차수를 의미한다. 차수를 높게 설정할 수록 차선에 더 잘 근사할 수 있다. 각 차선에 따라 이미지상에서 시작하는 위치가 다르므로 시작 위치를 각각 추출하지만, 차선의 끝나는 위치는 원근법에 의해 비슷한 위치에 형성되므로 그림 5에서 보이듯 공유하는 높이 (Shared Height)으로 추출한다. 신뢰도는 차선 후보 중 차선으로 선택하기 위한 임계값이다.

PolyLane은 다항식으로 차선을 추출하기 때문에 후처리가 필요 없고 구조가 간결하여 실시간 처리에 적합하다는 장점이 있다. 하지만 차선을 근사하고 차선이 끝나는 높이를 공유하기 때문에 예측값에 오차가 내재되어 있다. 따라서 다른 방식에 비해 오차를 줄이기 어려워 학습하기 힘들고 이로 인해 정확도가 낮다는 단점이 있다.




그림 5. PolyLaneNet의 구조  
Fig. 5. Overview of PolyLaneNet




그림 6. BezierLaneNet의 구조  
Fig. 6. Overview of BezierLaneNet

2.2 BezierLaneNet [13]

BezierLaneNet은 차선을 Bezier 곡선으로 모델링한 방식이다. 그림 6에서 보이듯 모델 구조는 인코더와 2개의 합성곱 층, 그리고 차선 유무를 판단하는 분류 분기와 조절점을 추출하는 회귀 분기로 구성되어 있다.

인코더는 차선이 대칭적으로 존재하는 특징을 활용하여 구성되어 있다. 일반적인 인코더와 동일하게 입력 이미지로부터 특징 맵을 추출하며 이후 추출된 특징을 좌우 대칭으로 이동시킨 후 합성곱 연산을 진행하여 차선의 대칭적인 특성을 모델링한다.

2개의 합성곱 층은 차선 후보에서 차선을 선택하는 NMS 기능을 대체하는 역할을 수행한다. 분류 분기는 차선인지 아닌지 판단하는 데 사용되며 학습 시에만 적용되고 추론 시에는 제거된다. 그리고 회귀 분기는 그림 6에서 보이듯 Bezier 곡선의 4개의 조절점을 추출한다. BezierLaneNet은 학습할 때 추가적인 정답 라벨이 필요하지만 차선을 Bezier 곡선으로 모델링하기 때문에 기존 분할 방식에 비해 빠르게 추론 가능하다. 또한 차선 별로 다른 조절점을 사용하여 차선을 표현하기 때문에 PolyLaneNet보다 차선을 더 자연스럽게 근사한다.

3. 정보 전파 방식

차선은 상하로 길고 얇은 모양으로 정의되어 있다. 그리고 이미지 상에서 자동차에 의해 가려지거나 조명 조건에 의해 보이지 않는 경우가 있다. 기존 합성곱 기반 모델은 이미지에서 특징을 추출하는 데 특화되어 있어 물체를 구분할 수 있지만 차선과 같이 얇고 긴 객체나 이미지 상에서




그림 7. SCNN의 구조  
Fig. 7. Overview of SCNN




그림 8. RESA의 구조  
Fig. 8. Overview of RESA

가려진 객체는 구분하기 힘들다는 단점이 있다. 따라서 정보 전파 방식은 모델의 같은 층 안에서 행과 열 단위로 공간 정보를 전파하여 합성곱 신경망의 단점을 보완했다.

3.1 Spatial Convolution Neural Network (SCNN) [14]

SCNN은 Spatial CNN 모듈을 활용하여 효과적으로 공간 정보를 학습하는 방식이다. SCNN 구조는 그림 7과 같이 백본망과 Spatial CNN 모듈로 구성되어 있다.

SCNN은 모델의 같은 층 내에서 정보를 전파하여 공간 관계를 학습할 수 있다. 그림 7에서 보이듯 SCNN 모듈은 맨 위의 은닉층 뒤에 순차적으로 추가되어 D, U, R, L 총 4 가지 방향으로 정보를 전파한다. 이때 각 방향은 아래쪽, 위쪽, 오른쪽, 왼쪽 방향을 의미한다.

SCNN 모듈의 연산 순서는 그림 7의 빨간색 박스에서 확인할 수 있다. 먼저 입력 이미지와 백본망을 사용하여 추출된 특징 맵이 입력으로 들어온다. 특징 맵을 높이 방향으로 나눠 슬라이스를 만들고 첫 번째 슬라이스를 합성곱 신경망을 사용하여 특징 맵을 추출한다. 그리고 추출된 특징 맵으로 두 번째 슬라이스를 업데이트한다. 두 번째 슬라이스를 합성곱 신경망에 통과시키고 위 과정을 반복해 마지막 슬라이스까지 업데이트한다.

3.2 Recurrent Feature-Shift Aggregator (RESA) [15]

RESA는 SCNN에서 영향을 받아 보다 효율적으로 공간 정보를 학습하기 위해 만들어진 모델이다. 그림 8에서 보이듯 백본망, RESA 모듈, 디코더 모듈로 구성되어 있다.

인코더는 ResNet 혹은 VGGNet으로 구성되어 있으며 입력 이미지에서 특징 맵을 추출하는 역할을 한다. 인코더를

통과하면 특징 맵은 입력 이미지에 비해 해상도가 1/8배 줄어든다. RESA 모듈은 특징 맵 내에서 SCNN과 동일한 방향으로 정보를 전파해 보다 풍부한 특징 맵을 추출하는 역할을 한다.

그림 8에서 보이듯 각 방향 모듈은 연산을 병렬적으로 처리한다. 이를 위해 슬라이스 업데이트 보폭 K를 정의한다. 이를 위해 슬라이스 업데이트 보폭 K를 정의한다. 그림에서는 K를 1과 2로 설정했다. 그리고 특징 맵을 높이 방향으로 슬라이스 한다. 슬라이스를 1차원 합성곱 신경망에 적용한 후 앞서 정의한 K에 따라 병렬적으로 슬라이스를 업데이트 한다.

RESA 모듈은 인코더를 통해 추출한 특징 맵을 활용하여 풍부한 특징 맵을 만든다. 그리고 디코더는 픽셀을 정확히 예측하기 위해 두 개의 브랜치로 구성된다. 첫번째 브랜치는 Coarse-grained 브랜치로 거친 이미지를 생성한다. 두번째 브랜치는 Fine-detailed 브랜치로 정보 손실을 최소화하여 세밀한 이미지 분할을 수행한다.

RESA는 SCNN과 동일하게 같은 층 내에서 공간 정보를 전파해 차선을 잘 탐지할 수 있게 설계되었다. 하지만 RESA는 SCNN과 다르게 병렬적으로 공간 정보를 전파하여 빠르게 추론이 가능하고 장거리 전파 시 정보가 손실될 수 있는 문제를 해소했다. 그리고 2개의 브랜치로 구성된 디코더를 제안하여 SCNN에 비해 세밀한 이미지 분할을 가능하게 했다.

4. 앵커 기반 방식

앵커 기반 방식은 이미지 분할 방식이 연산 비용이 많은 점을 해결하기 위해 제안되었다. 이미지 분할 방식은 픽셀별로 예측해야 한다는 문제점이 있었지만, 앵커 기반 방식은 사전에 정의한 각 앵커에 대해 차선을 예측한다. 따라서 이미지 분할 방식에 비해 연산량이 줄어들기 때문에 추론 속도가 빠르다는 장점이 있다.

4.1 Ultra Fast Lane Detection (UFLD) [16]

UFLD [14]는 추론 속도 향상을 위해 제안된 모델이다. 그림 9에서 보이듯 수평적으로 정의된 행 앵커에서 차선과 배경을 구분하여 행 단위로 차선을 분할한다. 기본적인 모델은 백본망, 행 앵커를 기반으로 차선을 구분하는 분류 네트워크로 구성되며 학습할 때 보조 네트워크를 추가한다. 행 앵커는 사전에 정의되어 있으며, 고정된 위치의 앵커를 바

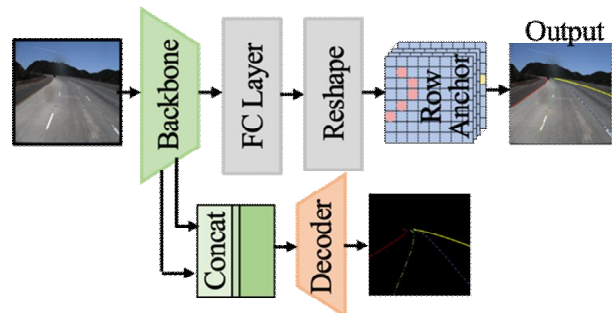


그림 9. UFLD의 구조  
Fig. 9. Overview of UFLD

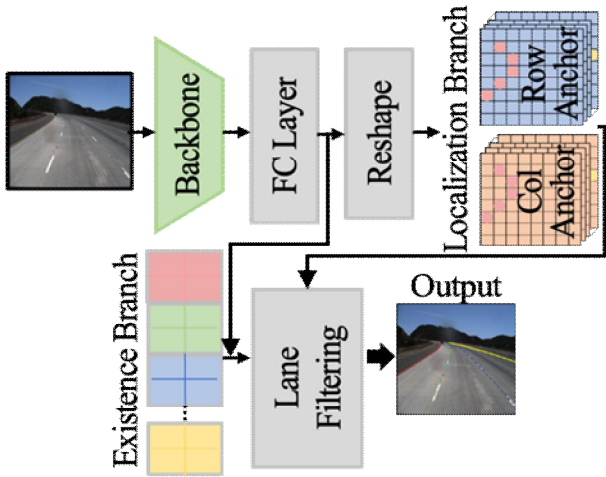


그림 10. UFLD\_V2의 구조  
Fig. 10. Overview of UFLD\_V2

탕으로 각 앵커가 배경인지 차선인지를 구별하는 방식이다. 행 앵커를 사용하기 때문에 이미지 분할 방식에 비해 큰 수용 영역을 지니고 있어 전역적인 정보를 얻을 수 있다.

보조 분류기는 학습 시 지역적인 정보 추출에 도움을 주기 위해 설계되었다. 백본망에서 다양한 크기의 특징 맵을 입력받아 이미지 분할 과업을 수행한다. 그리고 학습이 끝난 후 모델을 추론할 때는 보조 분류기를 제거하여 추론 시간을 향상시킨다.

UFLD는 수용 영역이 다른 모델에 비해 크기 때문에 다양한 환경 조건에서도 차선을 잘 인식할 수 있다. 또한 기존 분할 방식에 비해 예측해야 할 픽셀 수가 적기 때문에 추론 속도 측면에서도 이점을 보였다. 하지만 행 기반 앵커를 사용하기 때문에 차선과 예측값 사이의 거리가 작더라도 상황에 따라 오차가 커질 수 있는 문제점이 있다.

4.2 UFLD\_V2 [17]

UFLD\_V2는 앞서 언급한 UFLD 모델의 행 기반 오차를 줄여 성능을 높이기 위해 개발된 모델이며, 그림 10과 같이 백본망과 Localization 분기, Existence 분기로 구성되어 있다.

동작 흐름은 그림 10에서 보이듯 입력 이미지가 들어오면 백본망에서 2개의 분기에 입력으로 들어갈 특징 맵을 추출한다.

이전 버전의 네트워크는 행 앵커를 사용하여 차선을 인식했다. 하지만 한 종류의 앵커만 사용하면 차선과 앵커의 각도가 작아질 때 에러가 커지는 문제점이 발생할 수 있다. 구체적으로 행 기반 앵커는 수평 방향의 차선을 잘 예측하지 못하고 열 기반 앵커는 수직 방향의 차선을 잘 예측하지 못한다. 따라서 이를 해결하기 위해 Localization 분기에서 두 가지 종류의 앵커를 동시에 사용하여 차선을 더 정확하게 구분한다.

Existence 분기는 차선 간의 순서 정보를 활용하여 차선의 유무를 분류하는 네트워크로 구성된다. 그리고 차선의 순서 관계를 모델링하여 인접한 차선을 가깝게 만드는 작업을 수행한다. 이 정보를 바탕으로 Localization 분기의 결과

값을 필터링하여 최종적인 차선 위치를 구분한다.

UFLD\_V2는 행과 열 기반의 앵커와 차선의 순서를 모델링하여 이전 버전의 문제점을 해소했으며 빠른 속도를 보장한다. 하지만 앵커 위치 자체는 고정이기 때문에 앵커 자체에 의한 행 에러, 즉 앵커에 의해 위치가 강제되기 때문에 여전히 내제되는 오차가 존재한다는 단점이 있다.

III. 실험 결과

1. 데이터 집합

Tusimple은 차선 인식 과업에서 널리 사용되는 벤치마크 데이터 집합이다. 고속 도로 위의 차선이미지와 차선 마킹형식의 라벨이 제공된다. 학습 영상은 총 3,626장, 검증 영상 총 358장, 테스트 영상 2,782장 제공된다.

2. 평가 지표

Tusimple의 데이터 집합에 대한 성능을 평가하기 위해 Accuracy, False Positive (FP), False Negative (FN)을 사용했다. Accuracy는 아래 식으로 정의된다.

$$\frac{\sum_{clip} C_{clip}}{\sum_{clip} S_{clip}} * 100. \tag{1}$$

$C_{clip}$ 은 모델이 맞게 예측한 차선의 좌표 수이고  $S_{clip}$ 은 정답값으로 제공된 차선의 좌표 수이다. FP는 실제 정답값이 아니지만 모델이 차선이 있다고 예측한 값이고 FN은 실제 정답값은 차선이지만 모델이 차선이 아니라고 예측한 값이다. 그리고 정답률을 백분율로 표현하기 위해 100을 곱했다.

그리고 모델의 추론 속도를 예측하기 위해 Inference Latency를 사용했다. 이를 위해 각 모델을 임베디드 보드에서 50회 추론시켜서 나온 값을 평균을 측정값으로 사용했다.

3. 모델 실험 결과

모델이 실제 환경에서 사용될 때의 성능을 정확하게 평가하기 위해 임베디드 보드인 NVIDIA Jetson Orin을 사용했다. 표 1에서 보이듯 정보 전과 방식의 모델들은 Accuracy

표 1. Tusimple 데이터의 차선 검출 성능 실험 결과

Table 1. The experiment results of Lane detection in Tusimple dataset

Model \ Metric	Accuracy	FP	FN
LaneAF[8]	95.11	0.039	0.036
Eigenlanes[9]	94.26	0.062	0.073
SCNN[12]	95.25	0.063	0.064
RESA[13]	96.82	0.036	0.025
UFLD[14]	95.91	0.189	0.037
UFLD_V2[15]	95.91	0.032	0.043
Polylanenet[16]	88.07	0.277	0.195
Bezierlanenet[17]	95.65	0.051	0.039
mean	94.65	0.087	0.064

표 2. 장치 내 에너지 평가

Table 2. On-device energy evaluation

Model \ Metric	Average Inference Time(ms)	Average Power(W)
LaneAF[8]	57.38 ± 3.8	21.89 ± 0.82
Eigenlanes[9]	55.68 ± 11.4	12.94 ± 0.52
SCNN[12]	97.78 ± 6.2	18.72 ± 0.12
RESA[13]	55.16 ± 4.5	27.18 ± 0.21
UFLD[14]	62.01 ± 3.3	15.72 ± 0.31
UFLD_V2[15]	60.64 ± 4.6	15.73 ± 0.22
Polylanenet[16]	34.34 ± 2.1	25.89 ± 0.13
Bezierlanenet[17]	45.11 ± 4.4	20.70 ± 0.11
mean	58.51	19.85

표 3. 분류 방식별 성능 비교

Table 3. Performance comparison of methods

Method \ Metric	Accuracy	Energy Efficient	Inference Speed
Clustering	중	상	중
Information Propagation based	상	중	하
Anchor based	상	상	중
Curve based	하	하	상

가 평균보다 높게 측정되었다. 또한 위 분류 모델 중 RESA의 정확도가 96.82로 가장 높게 측정되었다. 이는 특징 맵에 정보를 전파하는 방식이 다른 방식에 비해 차선의 특징을 잘 추출할 수 있음을 보여준다. 하지만 표 2에서 보듯이 정보 전파 방식은 추가적인 연산이 요구되기 때문에 Inference Time이 평균보다 17.96ms 더 높게 측정된다. 또한 에너지 측면에서도 평균보다 34.19W를 더 많이 사용하기 때문에 시간과 에너지 측면에서 다른 모델에 비해 효율적인 결과를 보인다.

반면 곡선 기반 방식은 Accuracy가 평균보다 낮게 측정되어 다른 모델에 비해 가장 성능이 낮았다. 하지만 bezierLaneNet의 Accuracy를 살펴보면 전체 평균보다 오히려 1.0 높은 결과를 보인다. 이는 PolyLane에서 낮은 성능의 원인이 되었던 차선 끝점 y값 공유와, 학습의 어려움을 잘 해결했다고 판단할 수 있다.

또한 곡선 기반 방식은 Inference Time이 전체 평균보다 18.78 더 낮게 측정되었다. 이는 다른 방식에 비해 모델이 예측해야 하는 값이 적기 때문에 나온 결과라 판단된다. 하지만 에너지 측면에서 평균보다 34.47W 높은 결과를 보였다.

클러스터링 방식은 Accuracy가 전체 평균과 근사한 값을 보여줬다. 또한 추가적인 클러스터링 연산량이 있음에도 불구하고 Inference time은 전체 평균보다 낮은 결과를 보였다. 그리고 에너지 효율 측면에서도 전체 평균보다 2428mA 더 낮게 측정되었다. 이는 실제 임베디드 환경에서 동작되기 좋은 방식이라고 판단할 수 있다.

마지막으로 앵커 기반 방식은 Accuracy가 평균보다 높게 측정되었다. 이는 차선을 앵커로 근사하는 방식이 유의미한

결과를 보였다는 것을 의미한다. 두 모델의 성능은 거의 동일하게 측정되었지만 UFLD모델이 FP가 0.187 낮은 결과를 보였다. 이는 UFLD\_V2가 행과 열 앵커를 사용하기 때문에 차선이 아닌 곳을 오인식하는 경우가 낮아진 결과이다. 하지만 Inference time은 평균보다 2.82ms 높게 측정되고 Power는 평균보다 41.22W 낮게 측정되어 속도와 에너지 사이의 이율 배반을 가지고 있는 것으로 파악된다.

## IV. 결론

본 논문에서는 차선 인식에 대해 네 가지 방식인 정보 전파 방식, 곡선 기반 방식, 클러스터링 방식, 앵커 기반 방식으로 구분하고 비교 분석하였다. 이를 위해 각 방식의 정확도, 처리 속도, 전력 소모량 등의 성능 지표를 측정하였다.

그 결과, 표 3에서 확인 할 수 있듯이 정보 전파 방식과 곡선 기반 방식은 다른 방식에 비해 전력 소모량이 높은 것으로 나타났다. 이는 두 방식 모두 추가적인 연산 혹은 후처리 과정이 존재하기 때문이다. 따라서 앵커 기반 방식의 추가 모듈과 후처리 과정을 적용하여, 에너지 측면에서 효율적인 모델을 개발하는 연구가 진행될 것이 효율적이라 판단된다. 또한, 앵커 기반 방식은 전력 소모량이 낮지만, 다른 방식에 비해 처리 속도가 느린 점이 확인되었다. 따라서 고정된 앵커를 동적으로 처리하여 앵커의 수를 줄이며 후처리를 가속화하는 연구가 필요하다. 마지막으로, 클러스터링 방식은 다른 방식에 비해 정확도가 낮은 것으로 나타났다. 이에 대해 정보 전파 방식을 결합하여 차선에 대한 특징을 추출하여 정확도를 높일 수 있을 것으로 예상된다.

정리하자면, 본 논문에서는 각 방식에 대해 분석하고 각 방식의 단점을 보완하기 위한 연구 방향을 제시한다. 이를 바탕으로 제한된 리소스에서 고성능의 효율적인 모델이 개발될 것이라 기대한다.

## References

- [1] 머니투데이, “내년 추석엔 장거리 운전 편해진다”... 자율주행 ‘레벨3’ 적용 신차는?, Retrieved April 26, 2023. <https://news.mt.co.kr/mtview.php?no=2022090813293289390>
- [2] 인사이트42, “美, 레벨2 자율주행 사고차 3대 중 2대는 ‘테슬라’,” Retrieved April 26, 2023. <https://www.tech42.co.kr/美-레벨2-자율주행-사고차-3대-중-2대는-테슬라/>
- [3] C. S Bae, Y. Y Park, T. T Tran, Y. LIU, H. G Lyu, S. B Joe, H. M. Joe. “형태학적 연산을 적용한 차선 인식,” 대한전자공학회 학술대회, pp. 369-371. 2010. (in Korean)
- [4] Y. Chen, M. He, Y. Zhang, “Robust Lane Detection Based on Gradient Direction,” 2011 6th IEEE Conference on Industrial Electronics and Applications, Beijing, China, pp. 1547-1552, 2011.
- [5] K. Y. Chiu, S. F. Lin, “Lane Detection Using Color-based Segmentation,” in Intelligent Vehicles Symposium, 2005. Proceedings. IEEE, pp. 706 - 711, 2005.

- [6] A. Mammeri, A. F. Boukerche, G. Lu, "Lane Detection and Tracking System Based on the MSER Algorithm, Hough Transform and Kalman Filter," International Conference on Modeling, Analysis and Simulation of Wireless and Mobile Systems, pp. 259-266, 2014.
- [7] Y. Zhang, Z. Lu, X. Zhang, J. H. Xue, Q. Liao, "Deep Learning in Lane Marking Detection: A Survey," in IEEE Transactions on Intelligent Transportation Systems, Vol. 23, No. 7, pp. 5976-5992, July 2022.
- [8] H. Abualsaud, S. Liu, D. B. Lu, K. Situ, A. Rangesh and M. M. Trivedi, "LaneAF: Robust Multi-Lane Detection With Affinity Fields," in IEEE Robotics and Automation Letters, Vol. 6, No. 4, pp. 7477-7484, Oct. 2021.
- [9] D. W. Jin, W. H. Park, S. G. Jeong, H. Y. Kwon, C S Kim, "Eigenlanes: Data-Driven Lane Descriptors for Structurally Diverse Laness," Accepted to Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 17163-17171, 2022.
- [10] J. A. Hartigan, M. A. Wong, "Algorithm AS 136: A K-means Clustering Algorithm," Journal of the Royal Statistical Society. Series c (applied statistics), Vol. 28, No. 1, pp. 100-108. 1979.
- [11] D. W. Jin, W. H. Park, S. G. Jeong, C. S. Kim. "Harmonious Semantic Line Detection Via Maximal Weight Clique Selection," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021.
- [12] L. Tabelini, R. Berriel, T. M. Paixao, C. Badue, A. F. De Souza, T. Oliveira-Santos "Polylanenet: Lane Estimation Via Deep Polynomial Regression," 2020 25th International Conference on Pattern Recognition (ICPR). IEEE, pp. 6150-6156, 2021.
- [13] Z. Feng, S. Guo, X. Tan, K. Xu, M. Wang, L. Ma "Rethinking Efficient Lane Detection Via Curve Modeling," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 17062-17070, 2022.
- [14] X. Pan, J. Shi, P. Luo, X. Wang, X. Tan, "Spatial as Deep: Spatial cnn for Traffic Scene Understanding," Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 32. No. 1. 2018.
- [15] T. Zheng, H. Fang, Y. Zhang, W. Tang, Z. Yang, H. Liu, D. Cai, "Resa: Recurrent Feature-shift Aggregator for Lane Detection," Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 35, No. 4, pp. 3547-3554, 2021.
- [16] Z. Qin, H. Wang, X. Li "Ultra Fast Structure-aware Deep Lane Detection," Computer Vision - ECCV 2020: 16th European Conference, Glasgow, UK, August 23 - 28, 2020, Proceedings, Part XXIV 16. Springer International Publishing, pp. 276-291, 2020.
- [17] Z. Qin, P. Zhang, X. Li, "Ultra Fast Deep Lane Detection with Hybrid Anchor Driven Ordinal Classification," IEEE Transactions on Pattern Analysis and Machine Intelligence 2022.

**Hyunjong LEE (이 현 중)**



2022 Automobile and IT Convergence from Kookmin University (B.S.)  
2022~Computer Science from Kookmin University (M.S.)

Field of Interests: Autonomous Driving, Vision Segmentation  
Email: dlrhkswhd10@kookmin.ac.kr

**Euihyun Yoon (윤 의 현)**



2022 Department of Electrical Engineering from PaiChai University (B.S.)  
2022~Computer Science from Kookmin University (M.S.)

Field of Interests: Self-Supervised Learning, Object Detection  
Email: dbsdmlgus50@kookmin.ac.kr

**Jungmin Ha (하 정 민)**



2022 Automobile and IT Convergence from Kookmin University (B.S.)  
2022~Computer Science from Kookmin University (M.S.)

Field of Interests: Object Detection, Computer Vision, Transformer  
Email: 20173430@kookmin.ac.kr

**Jaekoo Lee (이 재 구)**



2018 Electrical and Computer Engineering from Seoul National University (Ph.D)  
2018~College of Computer Science at Kookmin University (Assistant Professor)

Career:  
2011~2013 Assistance Research Engineer, LG Electronics R&D Campus  
2018 Data Scientist, SK Telecom Research Center  
Field of Interests: artificial intelligence(AI), machine learning, deep learning(ML), data science(DS) and their applications.  
Email: jaekoo@kookmin.ac.kr