

원호 스플라인 근사를 이용한 주행 기동 이벤트의 감지 및 분류

임채호¹⁾, 전진환¹⁾, 황윤진²⁾, 최세범^{*1)}

한국과학기술원 기계공학과¹⁾, 한국과학기술원 기계공학과, 한국엔컴퍼니(주)²⁾

Detection and Classification of Driving Maneuver Events using Arc Spline Approximation

Chaeho Lim¹⁾ · Jinhwan Jeon¹⁾ · Yoonjin Hwang²⁾ · Seibum B. Choi^{*1)}

¹⁾ Department of Mechanical Engineering, Korea Advanced Institute of Science and Technology,
291 Daehak-ro, Yuseong-gu, Daejeon 34141, Korea

²⁾ Department of Mechanical Engineering, Korea Advanced Institute of Science and Technology,
291 Daehak-ro, Yuseong-gu, Daejeon 34141, Korea and also, Hankook & Company, Seongnam, 13494, Korea

Abstract : Classification of driving maneuver events is essential for generating lane-level maps, developing advanced driver assistance systems, and analyzing driver behavior. Typically, maneuver events classification involves three key stages: segmentation of driving data, extraction of features, and classification process. However, existing studies that used threshold-based or sliding window approaches for segmentation have not adequately considered the various durations of maneuvers and face difficulties in distinguishing consecutively occurring events. This paper presents a novel algorithm that exhibits a high classification performance through segmentation using arc spline approximation and classification employing Convolutional Neural Network (CNN) and Long Short-Term Memory (LSTM), enabling the precise identification of consecutively occurred events. The effectiveness of this algorithm was validated using sensor data from real vehicle test drives in Sejong City, South Korea.

Key words : ADAS(첨단 운전자 보조 시스템) Driving Maneuver Event(주행 기동 이벤트), Segmentation(분할), Arc Spline Approximation(원호 스플라인 근사), Cascade Classifier(캐스케이드 분류기), Event Allocation(이벤트 할당),

Nomenclature

\bar{v} : mean velocity

r : radius

S : scenario

p : score

n^i : number of events for i^{th} scenario

TP : true positive

FP : false positive

FN : false negative

Subscripts

i : scenario index

j : event index

Allocation : scenario index for allocation

* 최세범, E-mail: sbchoi@kaist.ac.kr

1. 서론

현재, 첨단 운전자 보조 시스템(ADAS)은 운전의 다양한 측면을 지원하기 위해 여러 방식으로 발전하고 있다. 차선 수준의 지도를 기반으로 하여 차량의 정확한 위치를 확인하고 적절한 경로를 생성하며, 차선 변경 보조와 같이 특정 기동을 지원, 그리고 운전자의 성향을 분석하여 주행 기동에 반영하는 등 다양한 방식으로 운전자의 주행을 지원한다.

차선 수준 지도의 경우, 지도를 효율적으로 제작하고 활용하기 위해 도로 유형, 차선 조정 등의 다양한 요소를 고려하여 도로를 세분화하는 과정이 필수적이다. 특정 기동 보조 시스템과 운전자 성향 반영 시스템의 경우, 특정 주행 기동의 특성과 운전자의 성향을 정확히 분석하기 위해서는 특정 상황에서의 주행 데이터 추출이 중요한 역할을 한다. 이는 결국 주행 데이터에서의 기동 이벤트 감지 및 분류에 중점을 둔 연구에 대한 수요를 자연스럽게 증가시킨다.

주행 기동 분류는 기본적으로 분할 단계에 크게 의존한다. 일부 연구^{1),2)}에서는 임계값을 기반으로 데이터를 분할하거나 고정된 크기의 슬라이딩 윈도우를 사용하여 분할하였으나, 이는 다양한 기동들과 다양한 분포의 소요 시간에 대한 고려가 충분하지 않다는 한계점을 가진다. 물론 이러한 한계점을 극복하고자 다양한 크기의 윈도우를 동시에 사용한 연구³⁾도 진행되었지만, 윈도우의 크기는 여전히 고정되어 사용되었으며 연속적으로 발생하는 기동에 관한 구분은 고려되지 않았다.

도로 인프라 센서 기반의 차선 변경 거동 검출 연구⁴⁾와 기존에 존재하는 지도 기반의 기동 분류 연구⁵⁾도 진행되었지만, 차량 외부의 정보를 필요로 하는 한계점이 존재한다.

따라서 본 연구에서는 차량의 주행 궤적을 원호로 근사하여 데이터를 분할함으로써, 다양한 기동 및 각 기동의 다양한 소요 시간을 고려한 분할 기법을 소개한다. 분류 정확도를 높이기 위해 차선 유지 기동을 우선적으로 식별하여 제거한 후 좌회전, 우회전, 좌측 차선 변경, 우측 차선 변경, 회전 교차로 통과와 같은 세부적인 기동으로 분류하는 캐스케이드 분류기법을 사용한다. 또한 연이어 발생하는 기동 이벤트를 구분할 수 있는 이벤트 할

당 방법을 제안한다. 최종적으로, 세종시 주행 데이터셋을 통해 성능을 평가한다.

2. 주행 기동 이벤트 감지, 분류, 및 할당

본 장에서는 다양한 기동 및 각 기동의 다양한 소요 시간에도 강건하며, 연이어 발생하는 기동 이벤트를 구분할 수 있는, 높은 정확도의 분류 알고리즘을 소개한다.

본 연구의 전체적인 개략도는 Fig. 1과 같으며, 2.1장에서는 주행 데이터의 분할 과정을, 2.2장에서는 주행 기동 이벤트의 분류 과정을 자세히 다룬다.

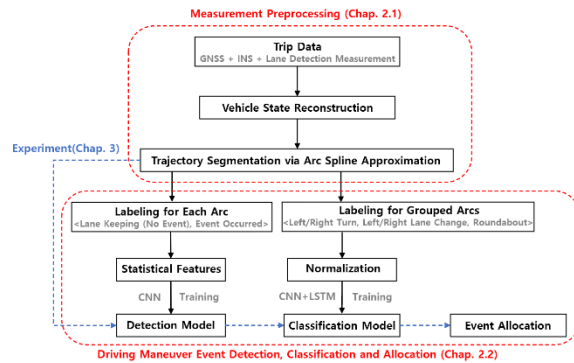


Fig. 1 알고리즘 개략도

2.1 주행 데이터 분할

주행 기동 분류에서 중요한 비중을 차지하는 데이터 분할 과정에 대해서 다룬다. 악의조건 환경에 대해서도 여러 센서들을 융합하여 차량의 주행 기록을 복원하고, 주행 궤적을 원호로 근사하여 효과적으로 주행 데이터를 분할한다.

2.1.1 차량 주행 기록 복원

차량 궤적을 원호로 근사하기 전, 센서 측정값으로 차량의 주행 기록을 복원하는 과정이 필요하다. GNSS만을 사용하는 경우, 다양한 상황에서 높은 정확도를 보일 수 있지만, GNSS 신호만을 의존하는 방식은 터널 통과, 다중 경로 간섭, 비가시선(NLOS) 수신과 같은 상황에서는 한계가 존재한다. 이 문제를 해결하기 위해, 이전 연구⁶⁾에서 설명된 바와 같이 GNSS, INS, 차선 인식 측정값을 통합하여 차량 주행 기록을 복원하였다. 다중 모달 센서 융합을 통해, 센서로 직접 측정되

지 않는 상태를 포함한 모든 트립에 대한 차량 주행 기록이 추정된다.

2.1.2 원호 스플라인 근사 기반 주행 궤적 분할

주행 기동 이벤트를 감지하고 분류할 때, 이벤트가 지속되는 시간을 충분히 고려하는 것이 중요하다. 임계값이나 슬라이딩 윈도우를 기반으로 한 데이터 분할 방식은 이벤트의 다양한 지속 시간을 모두 고려하지 못해, 감지와 분류의 정확도를 감소시킨다.

이 문제를 해결하기 위해서, 차량의 전체 궤적을 이전 연구⁷⁾에서 다룬 원호 스플라인 근사를 이용해 여러 개의 원호로 변환하는 방법을 사용하였다. 차량 궤적의 원호 스플라인 근사 예시는 Fig. 2와 같다.

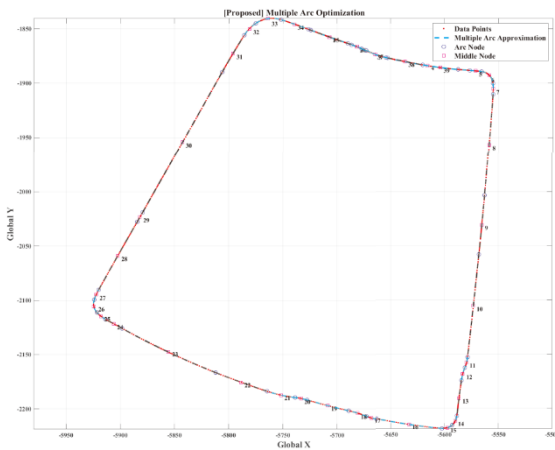


Fig. 2 차량 궤적 원호 스플라인 근사 예시, 1.35km 궤적 근사를 위해 39개의 원호 사용

이러한 접근 방식은 좌우회전, 차선 변경, 회전교차로 통과와 같은 곡선 형태의 궤적을 갖는 기동들을 효과적으로 나눌 수 있게 한다. 각각의 원호 혹은 연속된 여러 원호들은 하나의 이벤트 발생 구간을 나타낸다. 이러한 원호들을 기준으로 데이터를 분할하고 감지 및 분류를 진행함으로써, 더 높은 정확도를 얻을 수 있다. 또한 추후에 설명될 이벤트 할당을 통해 연속적으로 발생한 이벤트에 대한 구분도 가능하게 한다.

2.2 이벤트 감지, 분류, 및 할당

본 연구의 주된 목적은 좌회전, 우회전, 좌측 및 우측 차선 변경, 그리고 회전교차로 통과와 같은 주행 기동 이벤트가 발생하는 구간을 식별하고 그러한 이벤트를 분류하는 것이다.

주행 데이터의 대부분이 특별한 이벤트가 발생하지 않은 차선 유지 기동으로 이루어져 있어, 데이터 사이의 불균형이 분류 과정에서의 정확도를 저하시킬 수 있다. 분류 과정의 정확도와 효율성을 향상시키기 위해, 본 연구는 Fig. 3에서 확인할 수 있듯, 차선 유지 기동과 이벤트 발생 여부를 먼저 식별하는 단계를 거친 후, 이벤트가 발생한 구간에 대하여 보다 세밀한 분류를 진행하는 캐스케이드 분류 방식을 사용한다. 이러한 접근 방식은 불균형한 데이터 분포에서의 분류 정확도와 효율성을 향상시키기 위함이다.




Fig. 3 캐스케이드 분류 과정: 감지 및 분류

2.2.1 이벤트 감지

이벤트 감지 단계에서 주행 데이터는 차선 유지 구간과 이벤트 발생 구간으로 분류된다. 차량 궤적은 여러 개의 호로 근사 되며, 이에 기반하여 주행 데이터가 분할된다. 이 분할된 데이터는 각 원호 구간에 대한 이벤트의 발생 여부 감지에 사용된다.

Fig. 4-(a)에서 볼 수 있듯이, 감지 단계에서는 분류기로 합성곱 신경망 (CNN) 모델을 사용한다. 모델 훈련 과정에서, 원호 스플라인 근사를 통해 분할한 주행 데이터를 실제 주행 영상을 기반으로 차선 유지 혹은 이벤트 발생으로 라벨링하여 훈련 데이터로 사용한다. 차선 유지 범주 내에서의 기동 다양성을 고려하여, 감지 단계의 정확성과 효율성을 개선하기 위해 주행 데이터¹로부터

¹ Heading angles, yaw rates, lateral distances to left and right lines, lane measurement confidence metrics, (x, y) coordinates of vehicle trajectories

통계적 특성²을 추출해 모델 훈련에 사용한다. 과대적합과 과소적합을 방지하기 위해, 모델 훈련 시 교차 검증 기법이 적용된다.

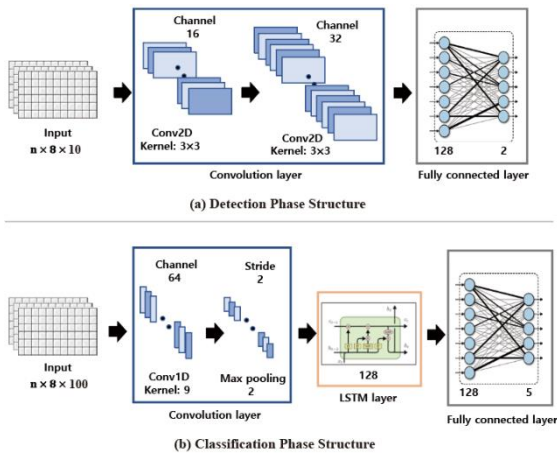


Fig. 4 신경망 모델 구조 (a) 감지 모델 (b) 분류 모델

감지 모델 훈련과는 별개로, 실제 감지 과정에서는 횡방향 가속도가 낮은 원호 구간을 차선 유지 기동으로 직접 분류한다. 이는 차선 유지 기동이 대체로 낮은 횡방향 가속도를 보이기 때문이다. 따라서, 아래의 조건을 충족하는 원호 구간에 한해 분류기를 활용한 감지를 실시한다.

$$\bar{v}^2 / r < 0.1 \text{ m/s}^2 \quad (1)$$

이를 통해 긴 차량 궤적을 따라 반복되는 감지 작업의 부담을 크게 줄일 수 있다.

2.2.2 이벤트 분류

이벤트 분류 단계에서는, 감지 단계를 통해 이벤트 발생으로 확인된 구간들이 Fig. 3과 같이 다섯 가지 유형의 기동으로 세분화된다. 해당 기동들은 흔히 여러 개의 연속된 원호로 구성되기 때문에, 분류 모델 선택, 훈련 데이터 구성, 그리고 분류 과정 전반에 걸쳐 원호들의 연속성을 고려하는 것은 매우 중요하다.

원호들 간의 연속성을 고려하기 위해, 분류

모델은 시계열 데이터 처리에 강점을 가지는 장 단기 메모리(LSTM)를 포함한다. 모델의 구조는 Fig. 4-(b)에 나타난 바와 같이 CNN과 LSTM이 결합되어 있으며, 이는 시계열 데이터를 기반으로 한 분류에서 높은 정확도를 달성한 선행 연구⁸⁾를 바탕으로 한다.

모델 훈련을 위해, 하나의 기동 이벤트를 구성하는 연속적인 원호들이 그룹화 되어 실제 주행 영상을 기반으로 라벨링된다. 차선 측정 신뢰도 지표를 제외한 모든 주행 데이터¹는 노이즈를 제거하기 위해 Savitzky-Golay 필터⁹⁾를 사용하여 평활화 과정을 거친 뒤, 정규화된다. 이러한 전처리된 데이터는 단일 원호 구간들과 그룹화된 원호 구간에 대한 모델 훈련을 위해 사용된다. 감지 단계의 모델과 마찬가지로 모델 훈련 과정에는 교차 검증이 적용된다.

2.2.3 이벤트 할당

연속된 원호로 이루어진 기동이 다양하게 존재하기 때문에, 각각의 원호를 단독으로 분류하는 접근법은 여러 개의 연속된 원호에 걸쳐 발생하는 기동을 정확히 식별하는 데 한계가 있다. 이러한 문제를 해결하고 정확한 이벤트를 할당하기 위해, 여러 연속된 원호가 분류될 때 가능한 모든 조합의 결과를 종합적으로 고려하는 방식을 채택한다.

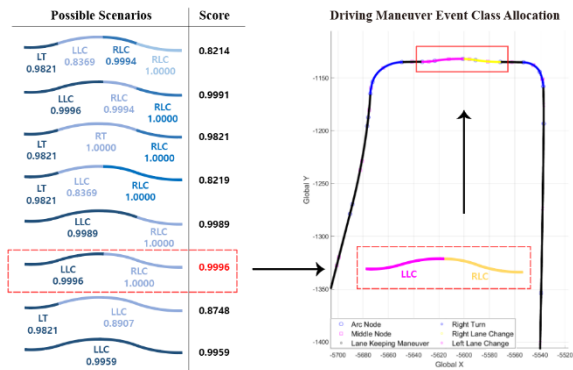


Fig. 5 네 개의 연속된 원호에 대한 이벤트 할당 예시

연속된 원호에 대한 이벤트 할당 예시는 Fig. 5에서 볼 수 있다. 네 개의 연속된 원호에 이벤트를 할당할 수 있는 경우는 총 8가지가 존재한다.

² Mean, Variance, Standard Deviation, Peak, RMS, Crest Factor, Shape Factor, Skewness, SMR, Peak-Peak Value

예를 들어, 첫 번째 시나리오는 각 원호가 개별적인 이벤트를 구성하는 경우를 보여주며, 이들은 각각 좌회전, 좌측 차선 변경, 우측 차선변경, 그리고 우측 차선 변경으로 분류되고, 모델로부터 각 분류에 대한 점수를 부여받는다. 여기서 주목해야 할 점은, 시나리오 1,2와 같이 두 개의 연속된 우측 차선 변경은 단일한 우측 차선 변경을 의미하는 것이 아닌, 두 차례에 걸쳐 별도의 우측 차선 변경이 발생했음을 의미한다.

각 시나리오의 최종 점수는 해당 이벤트들에 부여된 점수들을 곱함으로써 산출된다. 가장 높은 점수를 가지는 시나리오가 최종 이벤트 할당에 사용되며 식으로 표현하면 다음과 같다.

$$S_{Allocation} = \arg \max_i \prod_{j=1}^n p_{ij} \quad (2)$$

Fig. 5에 제시된 예시에서, 여섯 번째 시나리오(좌측 차선 변경 1회+우측 차선 변경 1회)가 가장 높은 점수를 얻었으며, 이 시나리오가 최종적으로 이벤트 할당에 적용된다.

3. 데이터 기반 검증

본 장에서는 앞서 언급한 이벤트 감지, 분류, 그리고 할당에 대한 정확도를 실제 주행 데이터를 사용하여 평가한다. 또한, 다양한 구성의 신경망 모델을 사용한 결과를 비교 분석한다.

3.1 주행 데이터 구성

3.1.1 차량 센서 구성

테슬라 모델 3 차량을 사용하였으며, GNSS RTK, Xsens MTi-670g 산업용 IMU, RT3100 산업용 INS, 그리고 Comma3 모듈 openpilot¹⁰⁾이 장착되었다. RTK로부터의 GNSS 측정값과 Xsens MTi-670g 및 RT3100으로부터의 IMU 측정값은 2.1.1에서 논의된 바와 같이 차량 기록을 복원하기 위해 융합되었다. 또한, 차선 측정값과 신뢰도 지표는 openpilot 모듈로부터 추출되었다.

3.1.2 데이터 수집 장소

세종시에서 45회의 주행, 총 127km의 데이터 수집이 실시되었으며, 이는 Fig. 6에서 빨간색 경로로 표시되었다. 해당 주행에 대하여 다양한 기동 이벤트가 감지, 분류되었으며 정확하게 할당되었다.

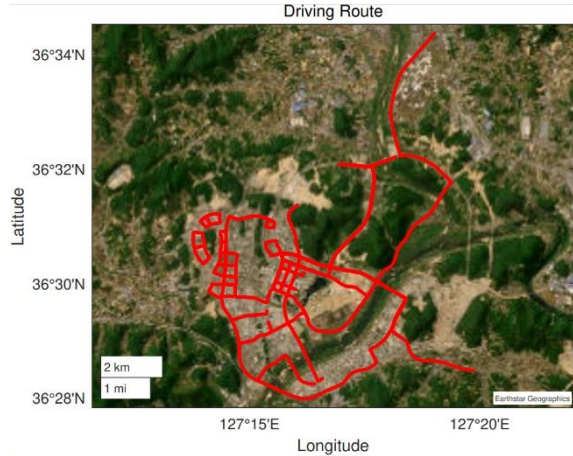


Fig. 6 데이터 수집을 위한 세종시 주행 경로

3.2 이벤트 감지, 분류, 및 할당

이벤트 감지, 분류, 그리고 할당 과정 각각에 대한 평가를 진행한다. 이후 최종 분류 결과를 시각적으로 제시한다.

3.2.1 이벤트 감지 및 분류 평가

감지 및 분류로 이루어지는 캐스케이드 분류기에 대한 평가는 3.1장에서 언급된 데이터를 사용하여 수행되었다. 감지 및 분류 결과에 대한 confusion matrix는 Fig. 7에서 볼 수 있다.




Fig. 7 Confusion Matrix (a) 감지 모델 (b) 분류 모델

분류기의 성능은 F1-score로 평가되며, 이는 다음과 같이 정의된다.

$$F1 - score = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (3)$$

이때, *precision*과 *recall*은 다음과 같이 정의된다.

$$precision = \frac{TP}{TP+FP} \quad (4)$$

$$recall = \frac{TP}{TP+FN} \quad (5)$$

이번 연구에서 제안한 분류기의 효과를 평가하기 위해, 다양한 프레임워크로 구현된 여러 네트워크 모델들의 분류 성능을 비교하였으며 이는 Table 1에서 확인할 수 있다.

Table 1 다양한 모델 구성 비교 (F1-score)

구분	CNN statistical	CNN time-series	CNN+LSTM time-series	Proposed
One-stage	0.9244	0.9219	0.9385	-
Cascade	0.9609	0.9537	0.9608	0.9716

단일 단계 분류기의 경우, 차선 유지 기동이 하나의 이벤트로 포함되어 별도의 감지 단계 없이 기동 분류가 이루어진다. 주행 데이터의 대부분은 차선 유지 기동을 나타내기에, 데이터의 불균형으로 인해 단일 단계 분류기를 사용하는 것은 분명한 한계를 드러낸다. 다른 모델들과 비교했을 때, 제안한 방법은 감지 단계에서 통계적 특징과 CNN을 사용하고 분류 단계에서 CNN과 LSTM을 결합해 시계열 데이터를 다룸으로써 가장 높은 점수를 보여준다.

3.2.2 이벤트 할당 평가

연속된 원호에 대한 실제 이벤트 라벨과 할당 결과를 비교함으로써 이벤트 할당의 정확도를 평가했으며, 결과는 Table 2에 제시되었다.

Table 2 연속된 원호들에 대한 이벤트 할당 정확도

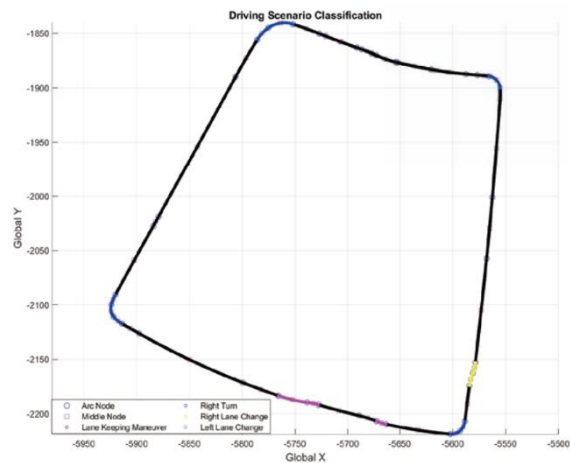
구분	2 arcs	3 arcs	4 arcs	5 arcs	Total
Valid Alloc.	186/190	102/108	36/40	30/35	354/373
Accuracy	97.89%	94.44%	90.00%	85.71%	94.91%

전체적으로, 약 95%의 연속된 원호가 실제 이벤트와 동일하게 할당되었다. 그러나 Table 2에서 볼 수 있듯이, 연속된 원호의 수가 증가함에 따라 이벤트 할당의 정확도가 감소하는 경향을 보인다. 이는 주로 두 가지 요인에 기인한다: 첫째, 연속된 원호가 하나씩 추가될 때마다 고려해야 할 경우의

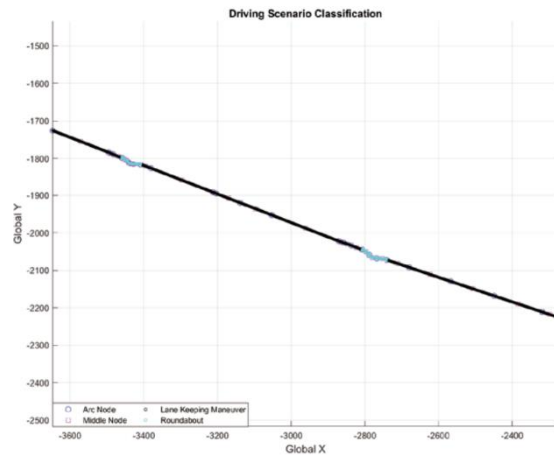
수가 두배로 증가하는 것과, 둘째, 4개나 5개의 연속 원호를 가지는 사례가 충분히 수집되지 않았다는 것이다. 그럼에도 불구하고, 이러한 정확도 감소가 일반적인 운전 상황에서 프레임워크의 전반적인 성능에 크게 영향을 미치지 않을 것으로 예상된다.

3.2.3 분류 결과 시각화

주행 기동 이벤트 분류의 결과를 시각화 한 결과는 Fig. 8과 같다. 주행 데이터는 센서 퓨전을 거쳐 운전 궤적을 복원하며, 복원된 궤적은 다수의 원호로 근사화되어 표현된다. 이 원호들은 감지, 분류, 할당 과정을 거쳐 분류된 후 지도 위에 표시된다.



(a) Driving Maneuver Event Allocation Result: Trip 1



(b) Driving Maneuver Event Allocation Result: Trip 2

Fig. 8 운전 기동 이벤트 할당 결과 (a) 총 네 번의 우회전, 두 번의 좌측 차선 변경, 한 번의 우측 차선 변경 (b) 두 번의 회전교차로

4. 결 론

본 연구에서는 원호 스플라인 근사를 활용하여 이벤트를 탐지, 분류, 그리고 할당하는 새로운 프레임워크의 주행 기동 분류 기법을 제안하였다. 원호 기반의 데이터 분할을 통해, 다양한 기동 및 각 기동의 다양한 소요 시간을 고려할 수 있었으며, 연속으로 발생하는 기동 이벤트를 식별하고 할당할 수 있었다. 또한, 캐스케이드 분류 방식을 통해 불균형한 데이터 분포에서도 높은 분류 정확도를 달성하였다. 실제 주행 데이터를 활용한 검증을 통해, 제안한 분류 기법의 유효성을 확인하였으며, 분류 결과를 시각적으로 표현하였다.

Acknowledgment

이 연구는 교육부 및 한국연구재단의 4단계 두뇌한국21 사업(4단계BK21 사업) 연구비 지원, 산업기술혁신사업 캐빈교체형 자율서플 공동생시 플랫폼 기술 개발 연구비 지원 (20014983), 정부(산업통상자원부 및 한국산업기술평가관리원)의 재원으로 자율주행기술개발혁신사업단의 지원 (20018181), 산업통상자원부와 한국산업기술진흥원의 미래형 자동차 튜닝부품 기술개발의 지원 (P0021036), 2023년도 정부(산업통상자원부)의 한국산업기술평가관리원의 지원을 받아 수행된 연구임 (20023815).

References

- 1) P. Brombacher, J. Masino, M. Frey, and F. Gauterin, "Driving event detection and driving style classification using artificial neural networks," in 2017 IEEE International Conference on Industrial Technology (ICIT), 2017, pp. 997-1002.
- 2) Beglerovic, Halil, Thomas Schloemicher, Steffen Metzner, and Martin Horn. 2018. "Deep Learning Applied to Scenario Classification for Lane-Keep-Assist Systems" *Applied Sciences* 8, no. 12: 2590.
- 3) J. Xie, K. Hu, G. Li, and Y. Guo, "Cnn-

based driving maneuver classification using multi-sliding window fusion," *Expert Systems with Applications*, vol. 169, p. 114442, 2021.

- 4) Jonghyun Cha, Taehyun Lee and Bongsob Song. (2022). Maneuver Classification of Lane Change Based on Roadside Sensors Using Field Operational Test Data. *Transactions of the Korean Society of Automotive Engineers*, 30(10), 831-838.
- 5) Hartjen, Lukas & Philipp, Robin & Schuldt, Fabian & Howar, Falk & Friedrich, Bernhard. (2019). Classification of Driving Maneuvers in Urban Traffic for Parametrization of Test Scenarios.
- 6) Jinhwan Jeon, Yoonjin Hwang, and Seibum B. Choi, 2023. Vehicle Motion Reconstruction via Multi-Modal Sensor Fusion. 한국자동차공학회 춘계학술대회, 평창.
- 7) J. Jeon, Y. Hwang, and S. B. Choi, "Reliability-based G1 continuous arc spline approximation," arXiv preprint arXiv:2401.09770, 2024
- 8) H. Pan, X. He, S. Tang, and F. Meng, "An improved bearing fault diagnosis method using one-dimensional cnn and lstm," *Strojniški vestnik - Journal of Mechanical Engineering*, vol. 64, no. 7-8, pp. 443-452, 2018.
- 9) A. Savitzky and M. J. E. Golay, "Smoothing and differentiation of data by simplified least squares procedures." *Analytical Chemistry*, vol. 36, no. 8, pp. 1627-1639, 1964.
- 10) Comma.ai, "openpilot," <https://github.com/commaai/openpilot>.