creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

도시계획학 박사학위논문

차량 라이다 센서기반 고속도로 혼잡 및 교통안전 모니터링 연구

2023년 2월

서울대학교 대학원

환경계획학과 교통학전공

김 홍 진

차량 라이다 센서기반 고속도로 혼잡 및 교통안전 모니터링 연구

지도교수 한 상 진

이 논문을 도시계획학 박사학위논문으로 제출함
2023년 2월

서울대학교 대학원
환경계획학과 교통학전공
김 홍 진

김홍진의 박사 학위논문을 인준함
2023년 2월

위 원 장 _____ (인)
부 위 원 장 _____ (인)
위 원 _____ (인)
위 원 _____ (인)
위 원 _____ (인)

국문초록

최근까지도 많은 데이터 기업에서는 최적 이동경로를 생성하는 다양한 길안내 서비스(Navigation) 기술을 발전시켜 왔다. 하지만 현재 상용화된 길안내 서비스들은 출발지로부터 목적지까지의 전역적인(global) 경로만을 안내하는 서비스를 중심으로 제공되고 있다. 이는 기술만으로는 해결하기 어려운 기존 데이터 수집방법의 한계이기도 하다.

일반적으로 교통현상은 너무나도 복잡(complex)하고 상대적(relative)이고 동적인(dynamic) 관계이기 때문에, 이를 해석하기 위해서는 정밀하고 충분한 데이터를 수집해야 한다. 그리고 교통현상을 분석하는 관점도 관리자, 운전자 등 다양한 관점을 고려해야 하는 어려움이 있다.

본 논문의 목적은 차량에 설치된 라이다 센서를 이용하여 주행하면서 주변차량에 대해서 끊김없고(seamless) 연속적인 구간 교통정보를 수집하는 방법론을 정립하고, 이러한 미시적이고 대규모 데이터를 활용하여 운전자 관점의 교통상태 및 안전성을 모니터링하는 것이다.

연구진행 과정은 선행연구를 통해 기존 검지체계의 문제점과 안전성 평가특징 등을 분석하였고, 도출된 문제점 개선을 위한 차세대 검지체계로 참여형 이동검지체계(MDS) 개념을 제안하였다.

이동검지체계 구현을 위해 라이다의 점군데이터를 수집하고 이를 딥러닝 기반의 Voxel-RCNN 모델을 통해 도로상의 다양한 객체 중 차량의 위치와 크기 등을 탐지하였다. 탐지된 개별차량을 교통정보로 활용하기 위해 탐지된 차량들에 ID를 부여한 뒤 추적을 수행하면서 차량별 속도, 가속도 등을 도출하고 데이터화하였다.

혼잡 등 다양한 조건에서 수집된 현장 교통정보를 바탕으로 시간과 공간에 따른 교통상태(밀도, 속도 등) 및 안전성평가(MTTC, 속도 표준편차)를 실시하였다. 또한 이러한 결과를 기존의 검지방식인 지점검지 및 구간검지와 비교해 보았다.

본 논문을 통해 계단식으로 표현되었던 기존 검지방식의 교통데이터가 아닌 시간과 공간에 따른 연속적인 교통정보를 수집하고 표현할 수가 있었으며, 이를 통해 미시적이고 정밀한 교통흐름을 확인할 수 있게 되었다. 또한 안전성 평가에서는 TTC보다 개선된 MTTC를 사용하였다. 이를 통해 민감하고 정밀하게 위험구간에 대한 정보를 수집할 수 있었다. 그리고 속도 표준편차를 이용한 안전성 평가방법에서도 실제 위험한 구간을 계량적으로 확인할 수가 있었다.

향후 장기간에 걸쳐 지속적으로 차량들의 이동데이터를 축적한다면, 지점검지기나 구간검지기에서 파악할 수 없었던 결측구간이나 차로별, 차로간 특성 등 다양한 교통현상도 분석할 수 있을 것이다. 이런 맥락으로 더 정확하고 운전자가 공감할 수 있는 교통정보를 제공하는데 이바지할 수 있을 것으로 기대된다.

주요어 : 라이다(Lidar), 객체탐지(Object Detection), 이동검지체계(MDS), 교통상태, MTTC(Modified TTC), 속도표준편차(Speed Standard Deviation)

학 번 : 2005-31243

목 차

제1장 서 론 ····· 1

제1절 연구 배경 및 목적 ····· 1

제2절 연구 범위 및 방법 ····· 4

제2장 선행연구 고찰 ····· 6

제1절 교통정보 수집 및 교통상태 측정방법 ····· 6

1. 기존 교통정보 수집체계 분석 ····· 6

2. 교통상태 측정지표와 방법 ····· 16

3. 차량검지 최신 라이다 기술 및 활용사례 ····· 18

제2절 교통안전 평가방법 ····· 26

1. 안전대리변수 지표별 특징 및 측정방법 ····· 26

2. 교통안전평가를 위한 데이터 수집방안 ····· 38

3. 속도분산과 교통안전의 관계 ····· 41

제3절 본 연구의 차별성 ····· 42

1. 선행연구 시사점 ····· 42

2. 본 연구의 차별성 ····· 44

제3장 차세대 검지체계 분석 및 최적센서 선정 ····· 47
제1절 차세대 검지체계 분석 ····· 47
1. 차세대 검지체계의 요구조건 ····· 47
2. 참여형 이동검지체계 제안 ····· 49
제2절 운행구간검지를 위한 차량센서 선정 ····· 52
1. 주요 차량센서 비교 ····· 52
2. 운행구간 교통정보수집을 위한 센서장비 선정 ····· 61
3. 차량검지를 위한 알고리즘 선정 ····· 64

제4장 라이다 센서기반 교통정보 수집 및 분석 방법론 정립 · 66
제1절 라이다 센서를 이용한 주행데이터 수집 ····· 66
1. 수집차량 및 장비 제원 ····· 67
2. 데이터 수집장비 점검절차 ····· 69
제2절 라이다 데이터를 활용한 교통정보 처리 ····· 73
1. 객체탐지를 통한 교통데이터 추출 ····· 73
2. 이동객체 추적 및 속도산출 방법 ····· 83
제3절 교통상태 및 안전성 모니터링 방법 ····· 89
1. 교통상태(혼잡) 모니터링 ····· 89
2. 교통안전성 모니터링 ····· 92
3. 안전성 평가 개선방안 ····· 98

제5장 라이다 센서를 이용한 현장 조사 및 교통 모니터링 105
제1절 현장데이터 수집 및 적정성 분석 ····· 105
1. 라이다 센서를 이용한 현장 데이터 수집 ····· 105
2. 교통정보 데이터 적정성 검토 ····· 109
제2절 고속도로 교통혼잡 및 안전성 분석 ····· 117
1. 라이다 교통정보를 통한 교통혼잡 모니터링 ····· 117
2. 기존검지방식과 비교분석 ····· 123
3. 고속도로 교통안전 모니터링 ····· 132

제6장 결론 및 향후 연구과제 ····· 145
제1절 결론 ····· 145
제2절 향후 연구과제 ····· 147

참고문헌 ····· 149

부 록 ····· 161

표 목 차

[표 1] 검지체계별 특성 비교 ····· 7
[표 2] 교통정보 수집방법의 구분 ····· 8
[표 3] 지점검지방식 교통정보 수집 방법 문제점 및 한계 ····· 10
[표 4] 국내 구간검지 정보 수집사례 ····· 11
[표 5] 구간검지방식 교통정보 수집 방법 문제점 및 한계 ····· 14
[표 6] 특성추출과 객체탐지방식 구분 ····· 24
[표 7] 안전대리변수의 관점별 지표 ····· 27
[표 8] 안전대리변수 임계값 및 해석 ····· 30
[표 9] 안전대리변수 활용 구분 ····· 30
[표 10] MTTC 전후방차량 속도와 가속도를 고려한 충돌위험 시나리오 ····· 33
[표 11] 다양한 TTC 개량지표 ····· 34
[표 12] 가속소음 식 & 차량속도의 관계 그래프 ····· 37
[표 13] 측정방법별 특장점 비교 ····· 40
[표 14] 검지방법별 교통안전 데이터 수집가능 여부 비교 ····· 45
[표 15] 차세대 검지체계 요구조건 분석 ····· 47
[표 16] 데이터 수집관점 비교 ····· 48
[표 17] 검지방식별 장단점 비교분석 ····· 51
[표 18] 차량센서별 장단점 비교 ····· 53
[표 19] 카메라 영상의 관점 비교 ····· 54
[표 20] 카메라와 라이다의 오류 상황에서의 데이터 비교 ····· 55
[표 21] 실제 카메라 기반 영상 검지 문제점 예시 ····· 56

[표 22] 라이다와 카메라 방식 비교 ····· 61
[표 23] 센서별 기능 구분 ····· 64
[표 24] 라이다 장비 제원 ····· 68
[표 25] 원시파일 수집형태 ····· 72
[표 26] 원시데이터 파일 명세서 ····· 72
[표 27] IoU 산출 예시 ····· 84
[표 28] 이동차량 동일여부 확인 및 추적 ID 부여과정 ····· 85
[표 29] 주변차량 속도 추정방법 ····· 87
[표 30] 라이다로 수집 가능한 이상적 교통정보 현황 ····· 88
[표 31] 차량객체 이미지별 정의 ····· 94
[표 32] TTC 계산 예시 ····· 95
[표 33] MTTC 계산 예시 ····· 96
[표 34] 차로변경에 따른 충돌여부(시간) 판단 과정 ····· 99
[표 35] 안전공간(sss) 상황별 결과 이미지 예시 ····· 104
[표 36] 현장 데이터 수집현황 ····· 105
[표 37] 다양한 데이터 수집 장면 ····· 108
[표 38] 적정 TTC 산출 시간간격 검토 ····· 109
[표 39] 차로별 시간별 TTC분포 ····· 114
[표 40] 현장데이터 MTTC 구간별 발생건수 ····· 115
[표 41] 교통용량편람 서비스수준(LOS) 기준표 ····· 121
[표 42] 버스전용차로 포함여부에 따른 구간전체 속도 표준편차 비교 ·· 136
[표 43] 표준편차 안전성평가 임계기준이상 위험구간 비율 ····· 137
[표 44] 표준편차 임계기준이상 위험구간 비율 ····· 142

그 림 목 차

<그림 1> 연구순서도 ····· 5
<그림 2> 기존 고속도로 지점 및 구간검지기의 한계 ····· 13
<그림 3> 2D 객체탐지 및 3D 객체탐지 예시 ····· 19
<그림 4> 딥러닝을 사용한 라이다 기반 3D 객체탐지 특성 구분방법 ····· 20
<그림 5> PointNet Architecture ····· 21
<그림 6> VoxelNet Architecture ····· 22
<그림 7> Point Pillars Architecture ····· 22
<그림 8> TTC 개념도 ····· 29
<그림 9> TIT와 TET 개념도 ····· 32
<그림 10> PET 개념도 ····· 35
<그림 11> SDI와 TTC 개념도 ····· 36
<그림 12> 고속도로 본선중심 수집 문제점 ····· 42
<그림 13> 평균적, 집계적 데이터 수집으로 인한 계단식 표출 예시 ····· 43
<그림 14> AVI에서 시간처짐(Time Lag) 현상 예시 ····· 43
<그림 15> 전체 연구 개념도 ····· 46
<그림 16> 이동검지체계(MDS) 개념도 ····· 49
<그림 17> 이동검지체계 시공도와 기존 검지방식 비교 ····· 50
<그림 18> 빛의 파장별 구분 ····· 52
<그림 19> 2차원과 3차원의 깊이 예시 ····· 57
<그림 20> 다양한 깊이추적 방법 ····· 58
<그림 21> 차량센서 종류 및 범위 ····· 59
<그림 22> 전방 카메라와 라이다 검지비교 ····· 62

<그림 23> 전후좌우 전메라 영상 화면 ····· 63
<그림 24> 전방향 라이다 검지사례 ····· 63
<그림 25> 객체탐지 알고리즘들의 성능비교 ····· 65
<그림 26> 라이다를 이용한 교통정보 수집 절차 ····· 66
<그림 27> 라이다 데이터 수집 흐름도 ····· 67
<그림 28> 라이다 수집차량(KETI) 및 라이다 센서 ····· 68
<그림 29> 데이터 수집차량 점검 및 설정 ····· 69
<그림 30> 데이터 수집을 위한 센서 설정 세부절차 ····· 70
<그림 31> 카메라와 라이다 기준점 보정 ····· 71
<그림 32> 교통데이터 생성을 위한 전처리 방법 흐름도 ····· 73
<그림 33> PCD자료의 반사율 표현 시각화 ····· 74
<그림 34> PCD자료의 거리에 따른 시각화 ····· 75
<그림 35> 인공지능학습을 통한 객체탐지 알고리즘 개념도 ····· 76
<그림 36> Voxel-RCNN 학습곡선 ····· 77
<그림 37> 고속도로를 주행하는 차량 시각화 ····· 77
<그림 38> 2차원 변환결과 시각화 및 좌표변환 예시 ····· 78
<그림 39> 밀도기반 차선검지 방식 흐름도 ····· 80
<그림 40> 차선인식 결과 ····· 80
<그림 41> 차량들의 객체검출 결과 화면 ····· 81
<그림 42> 최종 결과값(차량좌표) 개념도 ····· 82
<그림 43> 차량들의 객체검출 결과 시각화 ····· 82
<그림 44> 객체탐지 지표(IoU) 개념 ····· 83
<그림 45> 이동차량속도 추정 개념도 ····· 86
<그림 46> 주행공간의 개별속도 산출 ····· 87

<그림 47> 교통상태 및 안전성 모니터링 흐름도 ····· 89
<그림 48> 점유율(밀도) 산출 ····· 90
<그림 49> 밀도변화 그래프 예시 ····· 90
<그림 50> 밀도산출 예시 ····· 91
<그림 51> 양재 → 대왕판교IC 구간 속도결과 그래프 예시 ····· 92
<그림 52> 안전성 평가에 필요한 데이터 추출 ····· 93
<그림 53> TTC 산출결과 시각화 ····· 93
<그림 54> 교통상태 및 안전성평가 결과 화면 ····· 97
<그림 55> MTTC, 점유율 등 시각화 예시 ····· 97
<그림 56> 회피가능 안전공간 개념도 ····· 98
<그림 57> MTTC 및 회피가능 안전공간(SSS) 산출 결과 ····· 103
<그림 58> 경부선 서울방향 판교-반포구간 노선도 ····· 106
<그림 59> 경부선 부산방향 판교-오산구간 노선도 ····· 106
<그림 60> 분당내곡도시고속도로 내곡터널 노선도 ····· 107
<그림 61> 경기도 광명시 일직동 서독터널 노선도 ····· 107
<그림 62> 전차로 평균 TTC 결과 ····· 110
<그림 63> 차로별 TTC 발생횟수 결과 ····· 111
<그림 64> 차로별 MTTC 발생결과 산정 ····· 111
<그림 65> TTC와 MTTC 발생건수 결과 비교 ····· 112
<그림 66> 차로별 TTC 발생분포 누적 그래프 ····· 113
<그림 67> 구간별 MTTC 발생분포 누적 그래프 ····· 114
<그림 68> MTTC 1초,3초,4.5초이하 발생건수 그래프 ····· 116
<그림 69> 정체시 차로별 속도와 전체구간 속도평균 그래프 비교 ··· 117
<그림 70> 서행구간 차로별 속도와 전체구간 속도평균 그래프 비교118

<그림 71> 라이다 전체차로 속도 그래프(판교→반포) ····· 119
<그림 72> 라이다 차로별 속도 그래프(판교→반포) ····· 119
<그림 73> 라이다 전체차로로 속도 그래프(판교→오산) ····· 119
<그림 74> 밀도변화 그래프(판교→오산) ····· 120
<그림 75> 밀도변화 그래프(판교→반포) ····· 120
<그림 76> 차로별 밀도변화 그래프(판교→오산) ····· 121
<그림 77> 2,3,4 차로별 밀도변화 그래프(판교→오산) ····· 122
<그림 78> 5차로 밀도변화 그래프(판교→오산) ····· 122
<그림 79> 밀도값과 라이다 속도 비교(판교→오산) ····· 123
<그림 80> 밀도값과 VDS 속도 비교(판교→오산) ····· 123
<그림 81> 판교-오산구간(22.12.9) 속도(VDS) 자료 및 이동경로 ·· 124
<그림 82> VDS와 라이다의 동일구간 속도결과 비교(판교→오산) ··· 125
<그림 83> VDS와 라이다의 구간별 속도 차이(판교→오산) ····· 125
<그림 84> 판교-양재구간(22.9.20) 속도(VDS) 비교 ····· 127
<그림 85> 판교-양재구간(22.9.21) 속도(VDS) 비교 ····· 127
<그림 86> 판교-양재구간(22.9.23) 속도(VDS) 비교 ····· 127
<그림 87> 판교-양재구간(22.9.26) 속도(VDS) 비교 ····· 127
<그림 88> 판교-양재구간(22.9.27) 속도(VDS) 비교 ····· 127
<그림 89> VDS와 라이다의 동일구간 속도결과 비교 그래프 ·· 128
<그림 90> VDS와 라이다의 속도변화구간 상세 비교 그래프 ·· 128
<그림 91> 양재-한남대교구간(22.9.20) 24시간 구간검지 속도 시공도 · 129
<그림 92> 구간속도(22.9.20) 비교(판교→반포구간) ····· 130
<그림 93> 구간속도와 라이다 속도 비교 그래프(판교→반포구간) ··· 130
<그림 94> 지점검지 자료와 구간검지 자료 연결 그래프(판교→반포구간) ··· 131

<그림 95> 지점(구간) 속도와 라이다 속도 비교 그래프(판교→반포구간) ···· 131
<그림 96> MTTC 3초이하 발생건수 현황(판교→오산구간) ····· 132
<그림 97> MTTC 3초이하 발생건수 현황(판교→반포구간) ····· 133
<그림 98> 밀도와 MTTC 3초이하 발생건수 비교(판교→오산구간) ·· 133
<그림 99> 밀도와 MTTC 3초이하 발생건수 비교(판교→반포구간) ····· 134
<그림 100> 라이다 속도와 MTTC 발생 건수 비교(판교→오산구간) ··· 134
<그림 101> 라이다 속도와 MTTC 발생 건수 비교(판교→반포구간) ··· 135
<그림 102> VDS 속도와 MTTC 발생 건수 비교(판교→오산구간) ··· 135
<그림 103> VDS 속도와 MTTC 발생 건수 비교(판교→반포구간) ··· 136
<그림 104> 라이다속도 표준편차 그래프(판교→오산구간) ····· 137
<그림 105> 라이다속도 표준편차 그래프(판교→반포구간) ····· 138
<그림 106> 1차로 속도 표준편차 그래프(판교→반포구간) ····· 138
<그림 107> 2차로 속도 표준편차 그래프(판교→반포구간) ····· 139
<그림 108> 3차로 속도 표준편차 그래프(판교→반포구간) ····· 139
<그림 109> 4차로 속도 표준편차 그래프(판교→반포구간) ····· 139
<그림 110> 5차로 속도 표준편차 그래프(판교→반포구간) ····· 140
<그림 111> 버스전용차로를 고려한 표준편차 그래프 비교(판교→반포구간) ···· 140
<그림 112> 버스전용차로를 제외한 표준편차와 속도 비교(판교→반포구간) ···· 141
<그림 113> 버스전용차로를 제외한 표준편차와 밀도 비교(판교→반포구간) ···· 141
<그림 114> 평균속도와 실제사고 발생건수 비교(판교→반포구간) ··· 143
<그림 115> 표준편차와 실제사고 발생건수 비교(판교→반포구간) ··· 143
<그림 116> 표준편차와 실제사고 발생건수 비교(판교→오산구간) ··· 144
<그림 117> MTTC 발생 건수와 실제사고 건수 비교(판교→오산구간) ··· 144

제1장 서 론

제1절 연구의 배경 및 목적

1993년에 구축된 국내 고속도로의 교통관리체계(FTMS : Freeway Traffic Management System)는 우리나라의 교통발전과 ITS산업을 촉진하는데 큰 역할을 담당했다고 평가받고 있다. 이 시스템의 핵심요소인 교통정보 수집 시스템의 경우, 초기 지점검지기(VDS : 3,040대, 1~2km 간격)가 설치되었으며, 이후 30년간 시스템의 확대, 고도화가 진행되어, 다양한 형태의 교통정보 수집장치(차량분류기(AVC : 290대), 하이패스교통정보(DSRC : 1052대)가 추가로 설치되었으며, 국내 고속도로의 경우 이러한 시스템에서 생성되는 교통정보를 활용하여 다양한 교통정책 의사결정 및 교통관리에 적극적으로 이용되고 있다.

그러나, 고속도로 FTMS 교통정보 수집범위[1)]는 전체 고속도로 중에서 약 20.5% 공간범위에서 국한되고 있는 것이 실정이다. 더욱이 최근 모바일, 네비게이션 등 민간부문의 교통정보는 전국도로를 대상으로 개별차량의 초단위 수준의 궤적자료를 산출할 수 있는 환경이 구축되어 고속도로 교통정보의 경쟁력이 점점 약화되고 있는 상황으로 판단된다. 이에 고속도로에서도 지점검지체계 중심에서 하이패스 단말기를 활용한 경로형 교통정보 수집체계 확대 구축 등을 추진하여 보다 확대된 공간적 시간적 범위에서 안정적인 교통정보 수집환경을 조성하기 위한 노력을 기울이고 있다. 하지만 모든 검지체계는 각각의 장점과 단점을 가지고 있으며[1], 특히 특정한 공간에서 차량의 미시적인 움직임을 파악할 수 있는 교통정보를 수집하는 데는 여전히 한계점을 가지고 있는 것이 현실이다.

---

1) 한국도로공사 내부자료, 데이터 기반의 의사결정 지원을 위한 교통정보 수집활용 고도화 계획, 2021.7

최근 다양한 센서가 차량에 탑재됨과 더불어 통신, 인공지능 기술의 융합과 발전은 자율주행 기술을 더욱 향상시키고 있다. 이러한 추세는 시장흐름과 경제적·기술적 진보로 볼 때 더욱 가속화 될 것으로 예상된다. 이중에서 특히 자율주행과 안전운전을 지원하는 '첨단 운전자 보조 시스템(ADAS : Advanced Driver Assistance System)[2)]' 장착이 2022년 7월 유럽연합(EU)에서 의무화되면서 자연스럽게 차량에 부착되는 다양한 차량용 센서(카메라, 라이다, 레이더 등)의 증가와 시장규모 확대로 이어지고 있다. 한국과학기술정보연구원(KISTI)[3)]에 따르면 2020년 기준 세계 ADAS 시장 규모는 270억달러(약 35조원)를 기록하였고 2030년엔 829억달러(약 108조원)까지 커질 것으로 예상하고 있다. 이와 같은 시장 규모의 확대는 자연스럽게 센서관련 기술의 진보로 이어질 것으로 예상되며, 이러한 센서 기술은 자율주행 작동 메커니즘(인지-판단-제어)[4)]을 향상시키는데 큰 기여를 할 것으로 기대하고 있다.

이러한, 자율주행 기능지원을 위한 차량용 센서 기술의 발달은 도로의 유지관리 측면에서 또 다른, 중요한 의미를 갖게 된다. 전술한 바와 같이 교통정보를 수집, 가공하여 교통소통, 안전관리측면에 활용하는 ITS분야에서 기존의 검지체계가 가지고 있는 단점을 보완하고 음영지역을 채울 수 있는 좋은 방안이며, 이를 통하여 보다 고도화된 도로교통 관리를 수행할 수 있게 된다.

도로상에서 혼잡이 발생하는 원인은 연결로 분합류부, 엇갈림 구간 등과 같은 특정 도로구간에서의 차량간 상충, 차로변경을 위한 감가속 행태 등과 매우 깊은 관련이 있다. 또한 이와 같은 미시적인 차량의 거동과 도로구간의 종단경사, 평면선형 등의 세부적인 기하구조가 결합되면

---

2) 대표적 ADAS 종류 : Adaptive Cruise Control(ACC), 차선 이탈 경보 시스템(LDW; Lane Departure Warning), 자동 비상 브레이크(AEB; Automatic Emergency Braking), 전방 충돌 경고(FCW; Forward Collision Warning) 등이 있음(출처 : IT용어사전, 한국정보통신기술협회)

3) 이호신, "ADAS산업", ASTI 마켓 인사이트 제92호, 22.6

4) 현대자동차, 자율주행, https://www.hyundai.co.kr/tech/1075

교통사고 발생 가능성 등이 증가하게 되는데 차량용 센서의 응용은 이러한 도로에서의 교통상태와 안전성을 분석하는데 매우 유용하게 활용될 것이다.

차량용 센서에서 수집되는 교통데이터의 수집범위는 1차원[점(point), 선(line)]과 2차원[면(section)]을 넘어 3차원[연속적인 구간(space)]을 대상으로 한다. 차량용 센서 중 카메라 데이터의 경우 카메라 위치에 따라 도로의 통행량 및 대략적인 교통류 상태를 수집할 수 있으나 차량간의 거리, 속도 등 차량들의 세밀한 교통정보를 판단하기에는 한계가 있다. 하지만 라이다와 같은 3차원 데이터를 취득하는 센서는 추정치가 아닌 측정치를 기반으로 참값(Ground Truth)에 근사한 데이터의 취득이 가능하다. 따라서 연속적이고 미시적인 교통상태를 분석할 수 있기 때문에 기존 2차원 데이터보다 더 정밀한 도로교통상황 분석이 가능한 장점을 가지고 있다.

본 논문의 목적은 자율주행차량에 설치되고 있는 센서 중 하나인 라이다(LiDAR : Light Detection And Ranging) 센서를 이용하여 실시간으로 현장을 주행하면서 수집된 주변차량에 대한 데이터를 활용하여 끊김없고(seamless) 연속적인 고속도로 구간의 교통정보를 수집하는 방법론을 개발하고 이를 활용하여 도로 위 전체적인 운전자관점 교통상태 및 안전성을 모니터링하는 것이다. 본 논문에서 사용된 라이다 센서를 이용한 교통정보 수집방법은 Daganzo(1997)가 구분했던 교통정보 수집방식 중 하늘에서 내려다보는 항공기반(aerial-based)방법을 도로상에서 적용할 수 있도록 구현하였으며, 이 교통정보를 활용하여 고속도로 구간에 대한 교통상태, 안전성을 평가 및 모니터링하는 체계를 도출하고자 하였다.

결론적으로 본 논문의 핵심적인 내용은 첫째, 라이다 센서를 이용하여 차량데이터를 수집하는 것이고 둘째, 차량데이터를 이용하여 연속적인 교통정보를 만들어내는 것이며 셋째, 교통정보를 이용하여 교통상태(혼잡)를 모니터링하는 것이고 넷째, MTTC와 속도표준편차를 이용하여 안

전성을 변화를 모니터링하는 것이고 마지막으로, 실제 현장조사 자료를 수집하여 앞선 방법론에 적용하여 결과를 비교분석하는 것이다.

향후 자율주행차량의 증가에 따라 수집 가능한 차량용 센서의 규모는 더욱 확대될 것으로 예상된다. 또한 자율주행차량들이 서로의 정보를 공유하는 협력주행(CV : Connected Vehicle)이 실현되는 단계로 발전한다면, 본 연구에서 개발된 차량센서 기반의 교통자료를 활용한 교통소통, 안전측면의 모니터링 방법은 기존 고정식 검지장치의 사각지대 보완 및 교통상태(traffic state)에 대한 실시간 정보수집과 제공 환경을 구축하는데 활용될 수 있을 것이며, 이를 통해 모든 주행공간에 대한 스마트한 교통관리 및 안전한 주행환경이 구현되는데 기여하게 될 것으로 기대된다.

제2절 연구 범위 및 방법

본 논문의 공간적인 범위는 연속류 도로인 고속도로를 대상으로 수행한다. 구체적으로 고속도로 진·출입로 등이 포함된 경부선 서울방향 판교에서 반포구간과 부산방향 판교에서 오산까지를 시범구역으로 선정한 후 본 논문에서 개발된 방법론을 검증하였다.

시간적 범위는 차량에 부착된 센서를 비교하기 위하여 주간과 야간을 대상으로 비교하고자 한다. 선정된 시범구역내에서 한국전자기술연구원에서 자율주행 테스트를 위해 제작된 차량을 활용하여 주야간을 이동하며 데이터 수집에 활용하였다.

내용적 범위는 기존에 지점과 구간에서 검지하는 수동적인 교통정보 수집방식이 아닌 라이다 센서가 탑재된 이동하는 차량에서 직접 3차원의 주변공간 데이터를 수집하고 이를 교통정보로 분석하는 능동적 정보수집 방법을 적용하고자 한다. 궁극적으로 새로운 데이터를 통해 새로운 공간적 이해와 동태적 현상으로 교통상태를 판단하기 위해서 평면적인 단순 검지(Detection, Find)에서 입체적 차원의 3차원 진단(Examination,

Diagnosis)으로 발전하는 것을 목표로 하였다.

이를 위해 논문수행 과정으로 관련 국내·외 선행연구 고찰을 통하여, 본 논문의 방향과 방법, 기존 연구와의 차별성 등을 도출하고자 하였다.

또한 라이다 센서기반 데이터를 취득하고 이를 인공지능 학습을 통해 도로 내 차량의 정보를 추출한 후 교통정보로 변형하고 안전대리변수 등을 사용하여 이동구간내의 혼잡 및 안전성 모니터링을 수행하였다.

본 연구의 구성은 다음 <그림 1>과 같다.

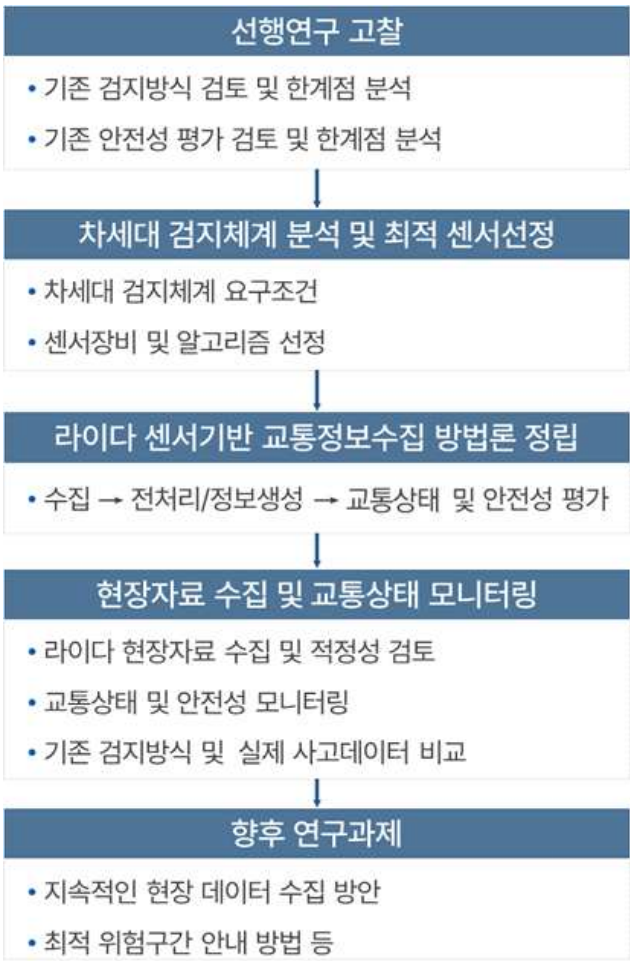

<그림 1> 연구순서도

제2장 선행연구 고찰

제1절 교통정보 수집 및 교통상태 측정방법

1. 기존 교통정보 수집체계 분석

교통정보의 수집과 제공의 법적근거로 수집의 경우는「국가통합교통체계효율화법」제12조(국가교통조사) 및 시행령 제8조(국가 교통조사의 실시)와 「도로법」제102조(도로에 관한 조사 등)가 있고, 제공은 「도로교통법」제145조(교통정보의 제공)이 있다[5].

교통정보수집과 제공의 주체별로는 국토교통부, 경찰청, 한국도로공사, 지자체 등의 공공부문과 T-map, 카카오, 아이나비 등이 민간부문의 대표적이라 할 수 있다.

교통정보 수집과 제공 목적은 크게 안전과 소통으로 구분할 수 있으며, 세부적으로 통행속도 개선, 교통사고 예방, 돌발상황의 부정적 영향완화, 교통상황 예측, 기타 과학적 교통정책지원 등을 목적으로 교통정보를 수집 · 제공하게 된다.

국내의 경우 도로부문 지능형 교통체계 설계편람(국토교통부, 2016)에서 [표 1]과 같이 교통정보 수집방법으로 특정지점에서 교통자료인 속도, 교통량, 점유율을 수집 및 가공하는 지점검지체계(point-based measurement)와 특정구간을 차량이 통과하는 통행시간으로부터 교통데이터를 수집하여 가공하는 구간검지체계(section-based measurement)로 구분하고 있다[40]. 이를 통해 두 가지 방법이 가지는 주요 수집자료, 사용기술, 주요기능, 문제점 등 각각의 특징에 대하여 [표 1]처럼 세부적으로 정리하였다.

---

5) 법제처 국가법령정보센터, www.law.go.kr

[표 1] 검지체계별 특성 비교 (출처 : 국토교통부, 2016)

구 분	지점검지체계	구간검지체계
수집자료	- 교통량, 지점속도, 밀도, 점유율 - 대리행렬길이	- 교통량(단말기 장착차량 또는 매칭차량) - 구간통행시간, 구간통행속도 - 차종, 차종 주행궤적(경로) 등
기술형태	- 루프, 영상, 레이저, 초음파, 초단파 등 - 인프라 기반 불특정 다수	- AVI, DSRC, RFID 등 - 특정차량기반 또는 인프라기반 불특정 다수
기능	- 돌발상황 검지 - 전수차량 검지 가능 - 차로별 차량검지 가능	- 지점검지기보다 정확한 통행시간 정보산출 - 구간 및 경로정보 제공가능
문제점	- 유지관리 어려움 - 경로추적 어려움 - 교통류 상태, 검지간격 등이 가공정보 신뢰성에 큰 영향을 미침	- 해당지점(구간)의 정체, 교통량 파악 어려움 - 실제 통행시간 정보가 이미 과거의 정보가 됨(시간처짐) - 버스전용차로 등 차로별 교통운영을 달리하는 경우 차로별 정보파악 불가

국외의 경우 Daganzo(1997)는 교통정보를 수집하는 방법으로 다음의 [표 2]와 같이 도로변에서 관찰하는 지점관점(point-based)방식, 교통흐름내 이동관점(mobile-based)방식, 하늘(조감도)에서 내려다보는 항공관점(aerial-based)방식으로 구분하였다[41]. 특히 이들 방법 중 시공도(time-space diagram) 측면에서 하늘에서 바라보는 항공관점 차량검지시스템(ADS : Aerial-based Vehicle Detection System)의 경우 특정간격에 따라 일정한 구간에서 차량의 이동궤적을 완전하게 묘사할 수 있다고 설명하고 있다. 결국 이러한 각 차량들의 정확한 이동정보를 통해 밀도, 속도 등의 산출이 가능하고 이를 통한 정확한 교통상태(혼잡, 돌발상황 등)를 파악할 수 있다고 주장하고 있다.

[표 2] 교통정보 수집방법의 구분(출처 : Daganzo, 1997)

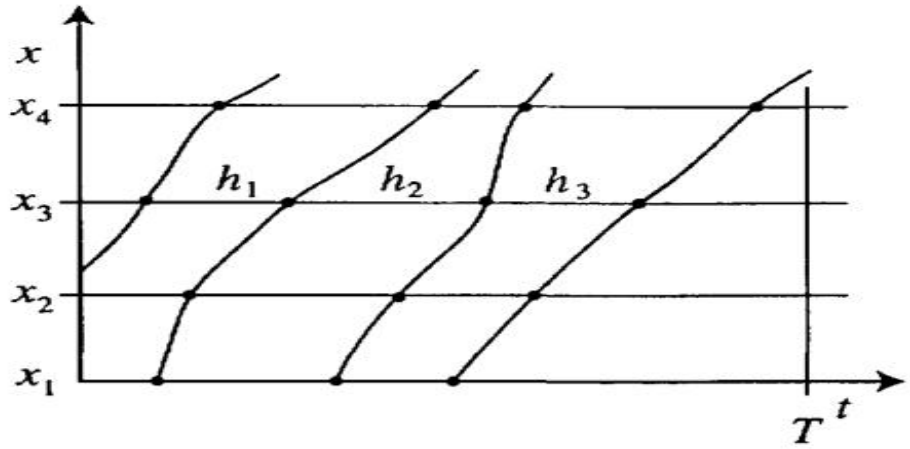

(a) 도로변(지점)에서 관측하는 경우(관측지점 고정)

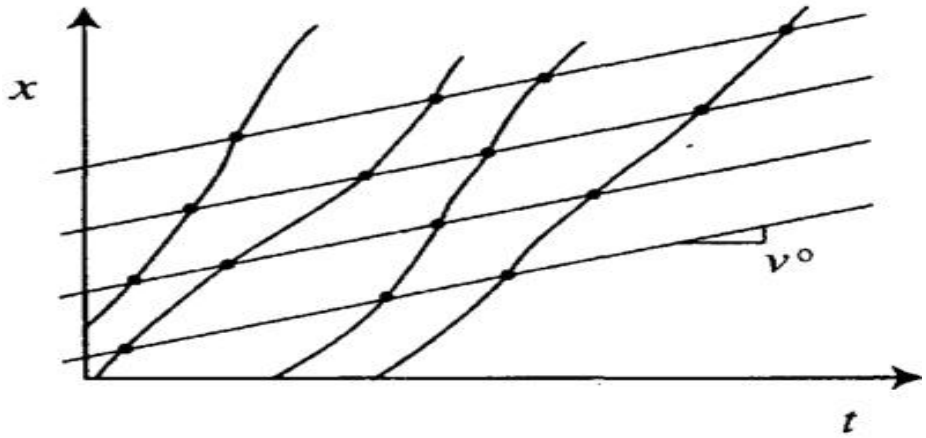

(b) 교통흐름 속에서 이동하며 관측하는 경우(관측점과 시간축 동시 이동)

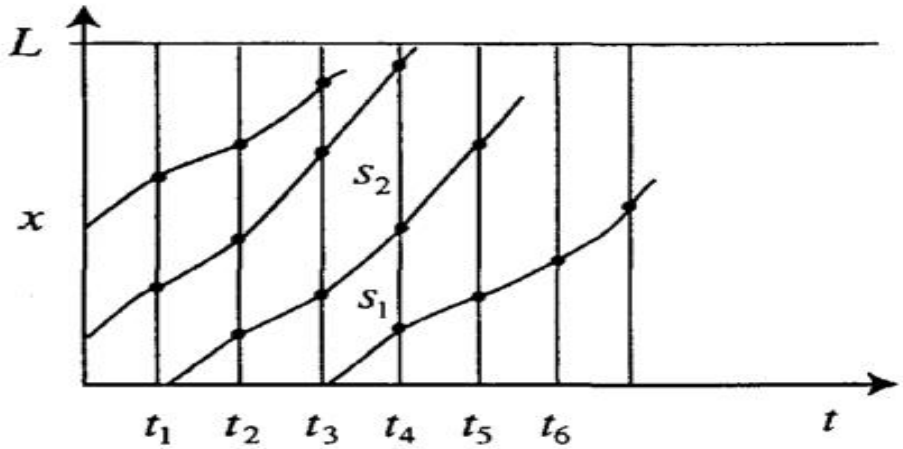

(c) 하늘에서 내려다보며 관측하는 경우(시간축 단위 이동)

가. 지점검지방식

교통정보 수집방식은 전통적으로 지점검지 방식(루프, 영상카메라 등)을 사용해서 교통량, 지점속도 등을 수집해왔다. 이러한 정보를 기반으로 일정구간의 통행시간을 추정한다.

최근 들어서는 루프방식보다는 비접촉방식인 영상검지방식을 많이 사용하고 있으며, 영상검지(CCTV) 기술은 관측지점을 관심영역으로 지정하는 ROI(Region of Interest) 방식을 사용한다. 이와 더불어 기술의 발전으로 인해 자동으로 영상을 분석하는 알고리즘이 다수 등장하였다. 대표적으로 딥러닝 분석방법인 YOLO(You Only Look Once) 모델을 사용하여 주로 교통정보를 추출하고 분석한다[42]. 이러한 YOLO 모델은 기존의 R-CNN 기반 모델인 2-Stage 알고리즘과 비교하여, 빠른 속도와 준수한 정확도를 보여주어 많은 상용화된 제품에 사용되고 있다.

김한수 외(2007)은 차량검지기 자료와 관련한 자료의 수집부터 가공, 저장, 품질 부문까지 전반적인 부분에 관한 국내외 연구동향을 검토하였다. 각 부문별로 검지기 설치기준, 통행시간추정, 자료저장 개념, 검지기 성능평가지표 등 주요이슈들을 검토하였다. 저자는 검지기관련 주요 검토분야로 자료 정확도 및 품질관리 개선, ITS 성장확산을 위한 다양한 활용방안 도출 등이 필요하다고 주장하고 있다[2].

조준한 외(2011)는 구간검지체계(UTIS, DSRC 등)방식은 다양한 원인으로 인해 특정지역에 편중되어 있고 지역별 통행패턴, 도로망 유형 등에 따라 적정 샘플수가 부족한 구간이 자주 발생하는 문제가 있다고 언급하고 있다. 이러한 문제점을 해결하기 위해 기존에 설치된 지점검지체계 활용을 극대화하고 지점검지 패턴데이터를 활용하여 실시간 소통상황 판단에 적합한 분류기준 등을 재정립하는 연구를 수행하였다[3].

이문엽 외(2020)는 교통정보 수집에 사용되는 다양한 장비의 운영현황과 문제점(신뢰성 부족, 유지보수 많은 비용 등)을 살펴보고 드론을 이용한 교통영상정보 수집방법을 통해 기존 수집방법의 문제점과 오차 해결

방안을 제시하였다. 드론을 이용할 경우 고도 30m, 카메라 각도 직하방향 90도로 촬영하는 것이 오차를 최소화하는 방법임을 확인하였다[4].

다음 [표 3]은 다양한 연구자들에 의해서 제기된 지점검지방식의 교통정보수집의 문제점과 한계 등에 대하여 정리하였다. 지점검지방식의 경우 일반적으로 교통량 측정 등에는 유용하고 특정구간의 정보를 수집하는데는 적합하나 교통상태를 측정하는데는 한계가 있음을 알 수가 있다.

[표 3] 지점검지방식 교통정보 수집 방법 문제점 및 한계

구 분	문제점 및 한계	연구자
지점검지방식 (교통량, 속도, 통행시간)	○ 교통상태(변화/정체)시 모형추정력이 낮아 오차발생	김성현 외(2005)[5] 조준한 외(2011)[3]
	○ 지점평균속도 산출을 통해 공간평균속도 환산으로 인한 오차 - 교통량 조사에 강점	백남철 외(2012)[6] 최기주 외(2009)[7] 정규수 (2021)[37]
	○ 동질구간 설정(본선중심 설치, 넓은 구간의 대푯값 등)의 한계 - 경로분석 불가, Headway 측정	조준한 외(2011)[3] 한동희 외(2018)[8] 김종진 외(2022)[1]
	○ 시공간적 연속성의 부족 - 수집주기(5분, 15분, 1시간)와 수집공간(고속도로 1km이상)의 한계	양인철 외(2019)[9]
	○ 설치시 많은 비용발생(설치수량과 추정오차 감소 등 양의 관계) - 유지보수(루프검지기)의 어려움(파손, 오버레이 등)	김성현 외(2005)[5] 이문엽 외(2020)[4] 도로공사 내부자료(2021)[11]
	○ ITS 정책추진 주체가 이원화(국토부, 경찰청)로 교통정보 운영관리 어려움	박용서 외(2013)[10]

나. 구간검지방식

구간검지 방식은 주로 통행시간을 산정하는 대표적인 방법이다. 이러한 구간검지를 통해 통행시간을 산출하기 위해서는 다양한 방법(AVI, RSE, TCS, GPS, 비콘, Probe Car 등)들이 개발되었다. 특히 스마트기기가 대중화되면서 적은 비용으로 넓은 공간에 대해서 교통정보를 수집하고 있다(Shi 2017)[84]. 기본적으로 구간통행정보를 산출하기 위해서는 기하학적인(공간) 정보와 GPS(이동궤적) 정보 등을 기반으로 한 지도와의 매칭이 필요하게 된다.

[표 4] 국내 구간검지 정보 수집사례 (출처 : 안계형, 2015)

구 분	정보수집방식	정보가공방식
서울시 (TOPIS)	* 스마트카드와 운행기록계(DTG) 정보를 이용 * 총 택시 7만대(법인 5만, 개인 2만) * 수집 10초, 전송 2분30초	* 국가표준노드링크 대상 * 최소 프로브 3대 * 맵매칭(GPS좌표) 오류 2%
팅크웨어 (아이나비)	* 스마트폰 어플 1,800만명 * 수집 3초, 전송 5분	* 링크 총 370만개 대상 가공 * 자체평가 단속류 74%, 연속류 93%
T-map	* 스마트폰 45만명/일 * 총 택시 7만대(법인 5만, 개인 2만) * 수집 3초, 전송 5분	* 국토부 기준링크 8만5천개 결합 * 고속도로 정보는 도로공사 자료 활용
현대 MnSoft	* 스마트폰 22만대/일, Mappy 5만대/일, 모젠 10만대/일 * 수집 3초, 전송 1분	* 국가표준노드링크 기반으로 10만개 기준 * 자체평가 정확도 75%임

안계형 외(2015)는 [표 4]에서와 같이 다양한 구간검지 정보사례를 검토하였다. 경찰청 UTIS 교통정보 수집방식을 단말기 기반의 링크 맵매칭

방식(구간소통정보생성)에서 센터 기반의 맵매칭 방식으로 전환하기 위한 교통정보 수집방식 개선을 수행하였다. 프로브정보 정확성 향상을 위해 GPS 원시데이터 수집항목 및 주기, 구간정보 생성 알고리즘 등을 도출하였다. 검증결과 97%이상의 맵매칭을 통한 링크통행속도 생성률을 보였으며 약 13%정도의 기준데이터와의 오차를 보였다[12].

장현호 외(2017)은 구간검지체계에서 신뢰할만한 구간통행시간 추정을 위해 통행경로 자료를 이용한 방법론을 개발하였다. 구간검지체계는 검지기 자료의 정확성과 대표 통행시간의 신뢰성이 중요성을 주장하고 있다. 하지만 기존방식은 대표통행시간을 제외한 값은 이상치(outlier)로 간주하고 있으며 특히 버스전용차로, 휴게소, 졸음쉼터 등의 존재 유무에 따라 정규분포가 아닌 다양한 형태로 나타나고 있음을 문제점으로 지적하고 있다. 또한 기존 통행시간 추정 알고리즘(Transmit, TransGuide 등)의 평활화 계수와 이상치 파라메터의 경우는 교통상태가 급격히 변화하는 경우 등을 고려하기 어려운 한계가 있음도 이야기하고 있다. 저자는 DSRC를 이용하여 대표그룹 중심탐색법(ERGM)을 개발하였다[13].

한동희 외(2017, 2018)은 고속도로 차량의 통행시간뿐만 아니라 통행경로를 분석하는 방법과 활용 고도화 방법론을 제시하였다. 이 연구에서 <그림 2>처럼 고속도로의 지점검지기는 전수화된 교통자료 수집에는 의미가 있으나 특정구간이라는 한계가 있고 구간검지기는 경로를 알 수 없고 통행완료 후에 정보를 취득하는 한계 등이 있어 교통자료 수집에 사각지대가 있음을 문제점으로 제시하고 있다. 이를 개선하기 위해 개별차량의 TCS(영업소통과)자료와 DSRC(본선부)자료를 통합하여 분석하였고 이를 통해 경로기반으로 혼잡원인을 구분하고 혼잡특성을 유형화하여 정체관리방안 및 통행시간 산정 정확도 향상기법 등을 제시하였다[8].

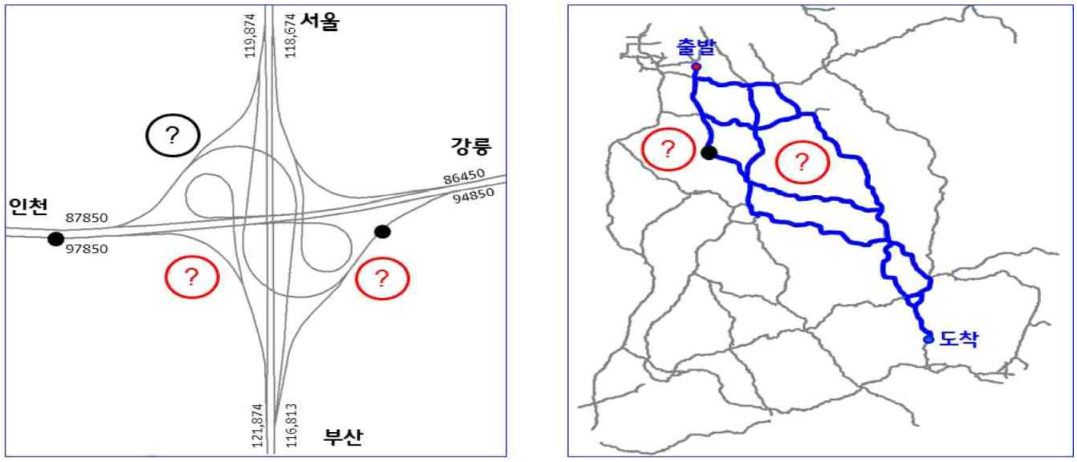

<그림 2> 기존 고속도로 지점 및 구간검지기의 한계 (출처 : 한동희, 2017)

김성훈 외(2020)는 Probe 차량을 이용한 통행시간 추정에는 3가지 문제가 있다고 언급하고 있다. 첫째, 장비장착차량비율(Market Penetration Rate, MPR)이다. 통행시간 추정시 probe 차량의 수가 일정수준 이하면 추정 정확도가 저하된다. 둘째, 수집된 데이터에 이상치(outlier)가 자주 관찰된다는 문제점이다. 이상치는 일시적으로 갓길에 정차하거나 유턴시에 발생할 수 있으며, 통신장비 자체 문제로 인한 측정 오류 등 다양한 요인으로 인하여 발생할 수 있다. 마지막 문제는 단일도로 구간에 다른 종류의 교통류(traffic stream)가 존재할 경우 발생한다. 특히 고속도로 분기지점에서는 각 차량의 진행방향에 대한 수요량의 불일치가 클 경우 해당 분기지점의 상류부에서 병목현상이 발생하며, 이를 분기지점 병목현상(diverge bottleneck)이라 부른다. 이러한 현상이 발생하였을 경우에는 동일 구간이라도 각 차량의 진행방향별로 통행시간이 크게 상이할 수 있으며, 이에 대한 정확한 분석 및 추정이 이루어지지 않는다면, ATIS 또는 ATMS 사용자들에게 부정확한 정보가 전달되어 비효율적인 ITS 운영의 가능성이 크다고 서술하고 있다[14].

오창환 외(2020)는 공공에서 관리중인 지점검지기의 공간적 정보한계를 보완하기 위해 민간의 구간 네비게이션 정보를 혼합하여 사용하고 있는

데, 이는 회사마다 상이한 속도산출방법을 사용하고 있어 한계가 있다고 지적하고 있다. 구간 공간평균속도(SMS : Space Mean Speed) 신뢰성 확보를 위하여 지점 공간평균속도와 비교분석을 통해 GPS 프로브 차량의 데이터 적정 수집주기를 연구하였다. 그 결과 8초 이내의 수집주기인 경우 95% 신뢰수준임을 도출하였다[15].

[표 5] 구간검지방식 교통정보 수집 방법 문제점 및 한계

구 분	문제점 및 한계	연구자
구간검지 방식 (속도, 통행시간)	○ 구간 길이에 따른 시간처짐 발생 - VDS의 단점을 보완하고자 하였으나 샘플이라는 한계	김성현 외(2005)[5] 백남철 외(2012)[6]
	○ 기반시설 필요 및 설치비용의 한계	도로공사 내부자료(2021)[11]
	○ 본선중심의 설치로 물리적 제공구간과 실제 정보제공 구간의 차이 발생	김수희 외(2016)[16]
	○ 샘플수가 적은 구간(새벽, 지방부 등)에 대한 통행시간 정확성 문제	장현호 외(2022)[13]
	○ 이상치 제거 및 대푯값 선정 방법별(필터링) 정확도 차이 발생 - 고속도로의 경우 휴게소, 졸음쉼터, 버스전용차로 등을 고려하여 통행시간 산출이 어려움	장현호 외(2017, 2022)[13]
	○ 차로별 등 세부적 구간정보(유고, 신호제어 등) 수집이 어려움	김성현 외(2005)[5]
	○ 변이구간에서 급격한 교통류 변화를 실시간으로 반영하기 한계(이상치로 제거) - 운전자 사이의 괴리감 발생	백남철 외(2012)[6] 김성훈 외(2020)[14]

[표 5]는 다양한 연구자들에 의해서 제기된 구간검지방식의 교통정보수집의 문제점과 한계 등에 대하여 정리한 것이다. 구간검지방식의 경우는 IT의 발달에 따라 다양한 기법들이 개발되고 발전해왔다. 특히 네이게이션 회사들이 정확한 통행시간 제공을 위해 많이 사용되고 있으나 근본적으로 구간검지방식의 경우는 시간처짐의 발생과 샘플 중심의 데이터 수집이라는 한계를 가지고 있다. 그럼에도 불구하고 다양한 장점과 편리성 등으로 인해 향후 구간검지방식 중심으로 교통정보 수집방식의 변화가 전망된다.

다. 항공기반 검지방식

항공기반 검지방식은 과거 실제로 항공기(경비행기, 헬리콥터 등)를 사용하여 교통정보를 수집하였으나 막대한 비용과 제한적인 항공경로 등이 한계로 지적되어 왔다. 최근들어 무인기(드론, 기구 등)방식이 도입됨으로써 많은 곳에서 교통정보 수집을 위한 보완적인 수단으로 활발히 사용되고 있다. 하지만 드론 또한 비행금지구역 등 한정된 지역과 숙련된 조종사 필요, 촬영시간 및 날씨에 따른 한계 등 여전히 많은 문제점을 가지고 있다. 물론 하늘에서 교통정보를 수집하는 방식은 일반적으로 앞서 언급한 지점검지 및 구간검지방식에 비해 교통밀도, 단구간 OD, 지체도 파악과 사고관제 등에 활용할 수 있는 장점이 있다.

백남철 외(2012)은 지점과 구간검지기 방법 이외에 공간검지 방법으로 항공기반 차량검지 시스템(ADS : Aerial-based vehicle Detection System)의 활용 가능성에 대해 연구하였다. 특히 기존 방식들의 문제점을 두 가지로 정리하고 있는데 도로변 관점인 VDS의 경우 갑작스러운 도로상의 정체상황을 감지하기 어렵다는 점과 이동기반 방식의 경우는 시간처짐 문제를 지적하고 있다. ADS방식은 구간밀도와 단구간의 OD를 측정할 수 있는 장점이 있다고 주장하고 있다. 하지만 이러한 장점에도 불구하고 비행속도 증가에 따른 정확성 하락과 운영비용 등의 기술적,

비용적 문제로 인해 VDS 등을 대체하기 보다는 보완적 방법으로 활용할 것을 주문하고 있다[6].

김수희 외(2016)는 기존의 교통조사분석 방법은 고속도로 본선 위주로 설치된 교통자료 수집체계(VDS, DSRC 등)의 시공간 집계 교통자료를 이용하여 추정 및 모형(simulation)을 기반으로 교통문제를 해결하는 방식이어서 IC/JCT 합·분류부, 엇갈림 구간, 종단경사 변화구간, 공사장 등 다양한 구간에서 나타나는 개별차량의 주행행태 분석자료를 기반으로 하는 실증적, 미시적 교통분석은 쉽지 않다고 주장하고 있으며 이를 위한 해결방안으로 드론을 활용한 방법을 제시하였다[16].

정보경 외(2021)는 미시적 교통정보 수집의 공간적, 시간적 한계를 극복하기 위해 항공뷰 관점 데이터 수집방법을 제안하였다. 기존 항공뷰는 차량 객체 검지와 추적 정확도 문제와 드론의 경우 기체 자세 변화로 인한 데이터 품질문제가 있었다고 한다. 이 연구에서는 250m구간을 드론으로 수직촬영하여 YOLO v5(차량검지)와 DeepSORT(차량추적)를 적용하고 영상정합 기법을 활용하여 차량 객체의 검지와 추적을 수행하였다. 그 결과 속도 데이터는 평균 MAE 3.49 km/h, RMSE 4.43 km/h, MAPE 5.18%의 오차 값을 도출하였고, 교통량 데이터는 평균 정밀도(Precision) 98.07% 결과를 도출하였다[17].

2. 교통상태 측정지표와 방법

차량보급의 지속적인 증가로 교통혼잡과 사고가 빈번해지면서 교통관리와 안전관리를 위해 교통상태(traffic state)에 대한 정밀한 진단과 모니터링이 더욱 필요로 하게 되었다. 일반적으로 교통상태는 용량분석을 통해 판단하며 해당 도로의 통행속도, 통행시간, 교통안전 등의 서비스상태를 설명하는 서비스수준(LOS: Level of Service)으로 구분한다.

도로용량편람(2013)에서는 고속도로와 같은 연속류의 서비스수준 판단을 위해 주요한 효과척도(MOE : Measure of Effectiveness)로 밀도를

사용하고 있다[18]. 밀도는 차량 통행상태의 질을 나타낼 수 있으며 신뢰성 높은 판단지표이다. 하지만 밀도는 측정자체가 어렵고 특히 지점검지기(시간적 연속정보 가능)는 공간적 연속정보 제공이 불가능하며 직관적으로 인식하기도 어려워서 실제 교통정보 제공시에는 속도를 주요척도로 사용하고 있다[9].

전통적인 밀도의 측정은 비행기나 기구(최근에는 드론활용) 등을 이용하여 일정공간을 촬영하고 계산하는 방식을 사용하였다. 이러한 버드뷰(BEV : Bird Eye View) 방식은 극히 제한적일 수밖에 없기 때문에 통상적으로 밀도의 측정은 도로의 노면에 설치된 지점검지(루프, 영상 등)로부터 얻은 정보를 이용하여 교통류 이론식, 점유율 등을 사용하여 추정하는 고정형 방식을 사용하고 있다. 하지만 이 방식은 관측장비의 설치 후 유지관리에 어려움과 정확도에 대한 의문이 많고 특히, 공간의 불연속성 및 관측 가능한 교통자료 한계 등의 문제를 가지고 있다.

하지만 최근 센서기술의 발전 덕분에 주행차량(Probe vehicle or Floating car)을 이용한 이동형 관측기술 개발이 활발해지고 있다. 자동차 공학 분야에서는 다양한 센서를 차량에 설치하여 주행의 효율성과 안전성을 향상시키는 ADAS(Adavanced Driving Assistant System) 기능 개발이 활발하게 연구되고 있기 때문에, 이러한 센서를 활용한 교통 관측기술(차두거리를 측정을 통한 밀도추정 등)의 개발도 추후 가능할 것으로 기대된다.

양인철 외(2018)는 다양한 차량센서 특징을 검토하고 센서로부터 수집되는 자료를 분석, 표출하는 시스템을 개발하였다. 자료의 수집은 레이더와 영상카메라, GPS 데이터를 사용하였다. 검증방법으로 동시 카메라 영상을 통해 육안으로 세는 방식을 사용하였고, 최저 5.3%에서 최대 50%의 오류값을 나타내었다[19].

임동현 외(2020)는 프로브차량에 설치된 첨단운전자보조시스템(ADAS)로부터 얻은 궤적데이터와 전방차량과의 차두거리를 이용하여 연속류 도로에서의 교통밀도를 분석하였다. 기존 VDS나 CCTV 등은 밀도추정에

공간적 제약과 교통혼잡시 신뢰도가 낮다는 한계가 있어 ADAS를 사용하였다고 한다. 이를 통해 30%의 표본율인 경우 교통밀도 참값과 대략 90% 정도 일치하는 것으로 분석되었다[20].

박재홍 외(2021)는 주체차량의 주행정보만을 이용하여 차량의 주행안전성을 평가하는 방법론을 제시하였다. 수집정보는 속도, 가속도, jerk(가속도의 변화량 의미)를 사용하였으며, 안전대리변수로 SDI(Stopping Distance Index)를 사용하였다. 주행안전성을 평가하는 분류방법으로 서포트벡터머신(SVM)을 사용하였으며 분류정확도는 80.1%로 나타났으며, 기타 특이도는 89%, 정밀도는 84.8%, 재현율은 69.9%로 나타났다. 또한 주체차량만을 분석한 한계를 개선해야 한다고 설명하고 있다[21].

Seo T. et al.(2015)는 일본 동경 외곽고속도로에서 GPS와 mono-eye 카메라가 설치된 프로브 차량을 이용하여 교통상태(TSE : Traffic State Estimation)와 밀도, 교통량 등을 측정하고 추정하였다. 그 결과 0.2%의 샘플 프로브 자료로 정밀한 시간당 교통량을 추정하였고 고정된 검지장치 등이 없어도 교통상태를 추정할 수 있음을 보여주었다[43][44][45].

3. 차량검지 최신 라이다 기술 및 활용 사례

가. 차량검지를 위한 라이다 기반의 3차원 객체탐지 기술

객체탐지(Object Detection)는 컴퓨터 비전(Computer Vision) 기술의 세부 분야 중 하나로써 주어진 데이터(주로 이미지)에서 사용자가 관심있는 객체를 탐지하는 기술이다. 본 논문의 연구에서는 라이다 센서를 통해 수집한 3차원 데이터에서 교통정보를 분석하기 위해 차량에 대한 검지를 중심으로 객체탐지 기술을 살펴보았다.

일반적인 2차원 카메라 영상에서 객체를 탐지하는 것[6]과 달리 3차원 데이터인 PCD(Point Cloud Data, 점군데이터)의 경우 몇 가지 어려움으

6) 일반적인 카메라 영상(2차원) 객체탐지 방법은 부록을 참조

로 인해 사물을 인식하고 해석하는데 매우 어려웠다. 이러한 이유 중 가장 큰 문제는 PCD는 기하학적인 요소가 현저히 부족하고 매우 분산적인 특징으로 인해 정렬되어 있고 정형화 되어있는 카메라 영상과는 달리 기존 딥러닝 감지방법에서 사용되기 어려웠다. PCD는 x, y, z축으로 이루어진 3차원 공간정보와 반사율에 따른 신호강도 정보를 포함하고 있으나 영상 이미지(2차원) 데이터의 픽셀과 달리 각각의 포인트 간 순서가 없고 밀집되어 있지 않고 규격화되지 않은 특성으로 인해 이를 곧바로 YOLO, R-CNN 등과 같은 이미지 기반 객체인식 신경망에 바로 입력하여 적용하는 것이 불가능했다(선민혁 2022)[24].

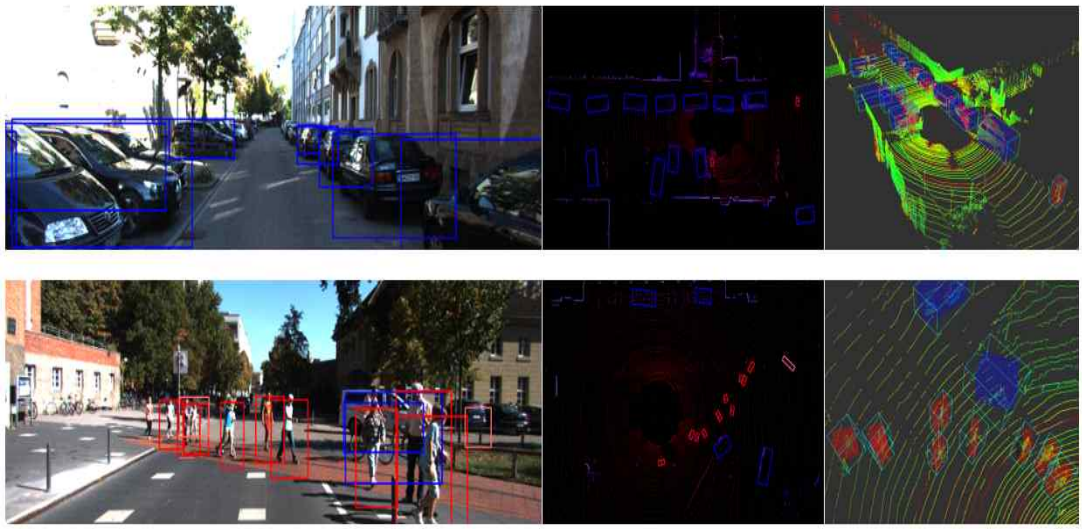

<그림 3> 2D 객체탐지 및 3D 객체탐지 예시 (출처 : Beltrán et al, 2018)

<그림 3>은 이미지 기반 객체 검출 방법과 라이다 기반 객체 검출 방법에 대한 예시를 보여준다. <그림 3>처럼 밀집되어 있고 한정된 평면에서 순서가 있는 2D 이미지 자료와는 다르게 3D 라이다 PCD의 경우에는 많은 영역들이 분산(sparse)된 특성이 있어서 기존의 표준 이미지 합성곱 네트워크 과정(standard image convolutional network pipeline)을 사용하기 어렵다[83]. 이로 인해 3D 객체탐지에 대해서는 3D 합성곱

(convolutional) 네트워크를 사용하거나 Bird-Eye's View(BEV, 조감도)로 3D data를 2D pseudo(가상) 이미지로 변환한 후 네트워크에 사용되었다.

초기에는 PCD의 특성(feature) 추출하기 위한 암호기(encoder)가 대부분 수작업(hand-crafted) 형태였으며 연속적 학습이 불가능하였다. 이에 대해 최초로 3D PCD에 대해 연속적(end-to-end)으로 학습하는 최초의 모델이 PointNet(Charles R. Qi, 2017)이다.

PointNet은 3D 이미지 분리를 수행한다. 이후 PointNet을 이용하여 최초로 3D 객체탐지를 수행하는 모형으로 VoxelNet이 나왔으며, 이를 개선하여 차례로 Point Pillars, Voxel RCNN 등이 나오게 되었다. 따라서 라이다와 같은 입체데이터에서의 객체탐지방법은 특성화(전처리) 추출방법에 따라 다음 <그림 4>와 같이 크게 Point, Pillar, Voxel 세 가지로 구분할 수가 있다[51].

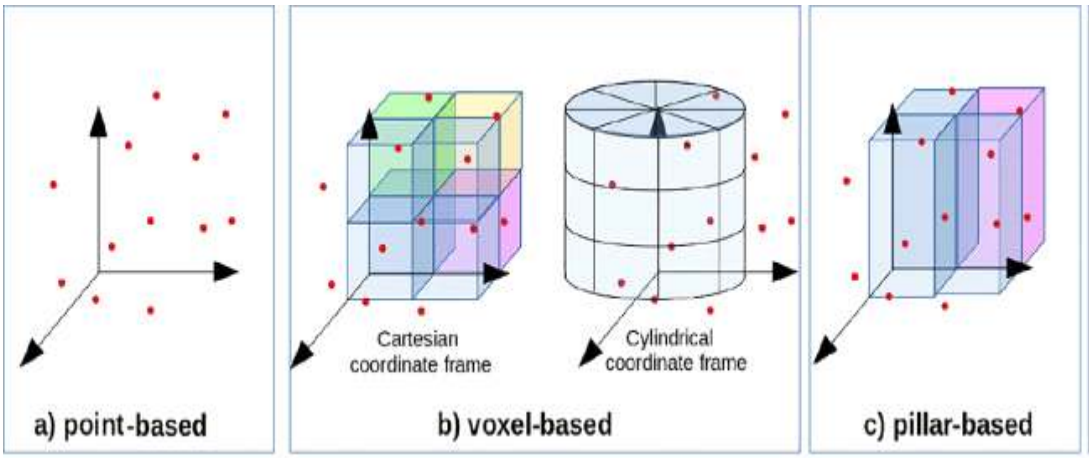

<그림 4> 딥 러닝을 사용한 라이다기반 3D 객체탐지 특성 구분방법
(출처 : Zamanakos et al, 2021)

(1) Point(점) 방식

Charles R. Qi et al.(2016)는 PointNet 논문에서 <그림 5>과 같이 연속적으로 3D points에 대해 학습(training)이 가능하도록 하였다. 3D points

set의 문제가 되는 특징인 1) 무질서, 2) 변환에 대한 보존성질(Invariance under transformations)을 해결하기 위해서 대상영역 최대치(Max pooling layer)를 대칭식으로 사용하였으며, 미니 네트워크(T-Net)를 통해 강체변환(rigid transformation)을 보장하였다[52].

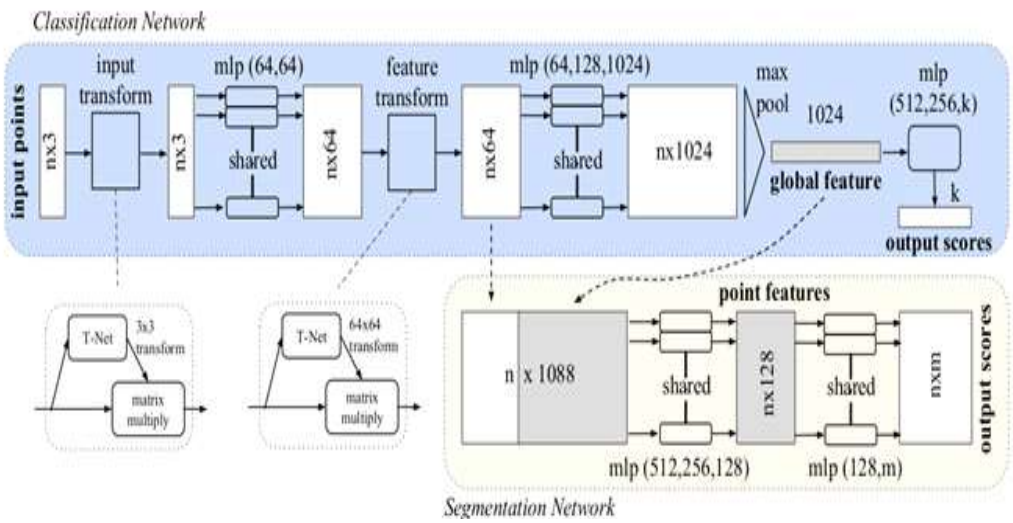

<그림 5> PointNet Architecture(출처 : Charles R. Qi, 2016)

(2) Voxel[7](복셀) 방식

Yin Zhou et al.(2017)는 VoxelNet 논문에서 <그림 6>과 같이 3D data와 2D data의 가장 큰 차이인 분산적인 특성을 고려하여, 공간을 (dx, dy, dz) 크기의 voxel로 나누고 비어있지 않은 voxel들에 PointNet을 적용한다. PointNet과 마찬가지로 복셀 특성 암호기(Voxel Feature Encoder)에서 대칭식(symmetric function)으로 점별수렴(point-wise) max pooling을 진행하여, 최종적으로 복셀수렴 특성(Voxel-wise Feature)을 생성한다. 하지만 여전히 3D convolutional network에서 병목(bottleneck)이 발생하는 단점이 있다[53].

---

7) 복셀(Voxel)은 2차원적인 픽셀(Pixcel)을 3차원의 형태로 구현한 것을 정의하며 Volume + Pixcel의 합성어로, 부피를 가진 픽셀이라는 의미 (출처 : 동아 프라임 영한사전)

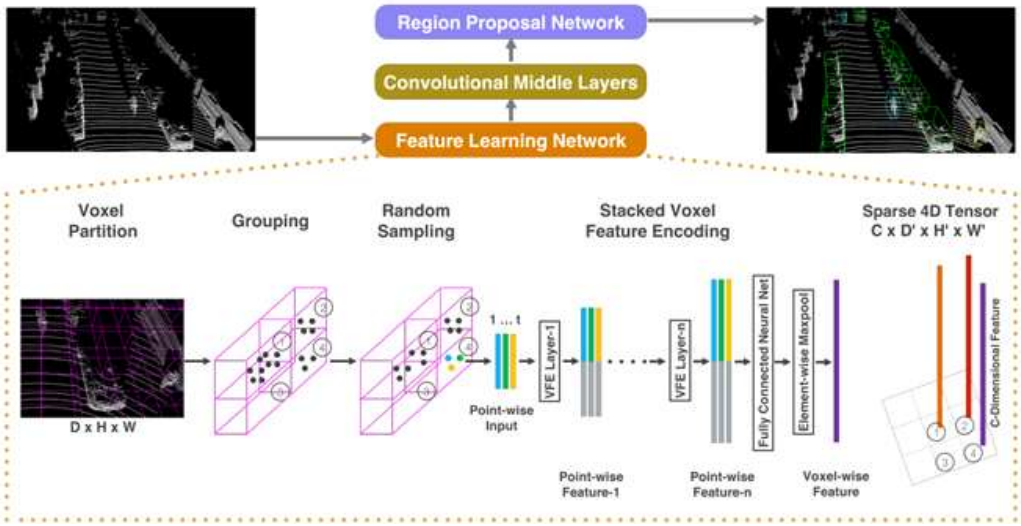

<그림 6> VoxelNet Architecture(출처 : Yin Zhou, 2017)

(3) Pillars(기둥) 방식

Alex H. Lan et al.(2019)는 Point Pillars 논문에서 <그림 7>과 같이 VoxelNet 에서의 최대 단점인 병목을 일으키는 3D convolutional network에 대해서 Point Pillars는 2D convolutional layers만 이용하여 3D 객체탐지에 대한 학습(training)이 가능하도록 하였다[54].

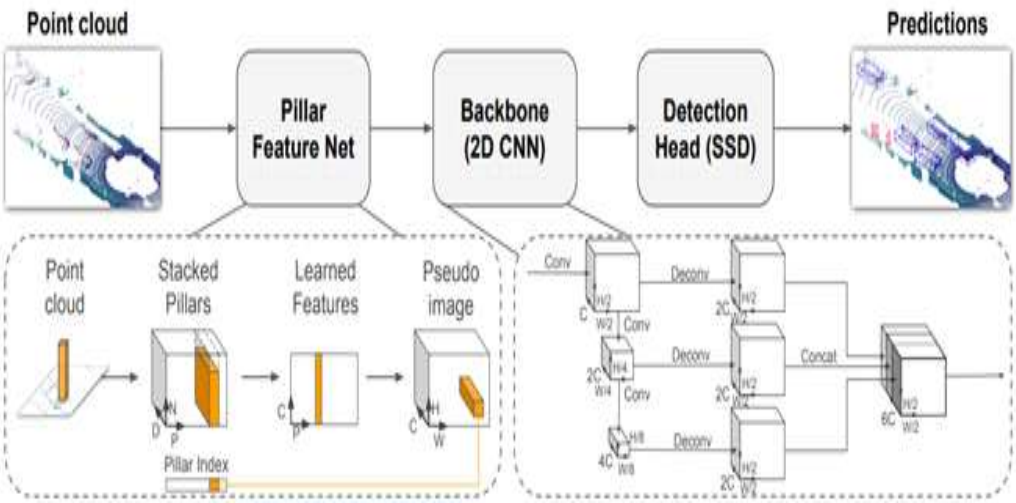

<그림 7> Point Pillars Architecture(출처 : Alex H. Lan, 2019)

나. 교통분야 라이다 활용사례

현재까지 교통정보 수집 및 제공분야에서 단독적으로 라이다센서 데이터를 사용하는 경우는 거의 없지만 연구용으로 교차로구간에 고정식으로 시범적용 하는 등 점차적으로 관심이 많아지고 있는 상황이다.

라이다 기술은 최초 1930년대 중반부터 기상관측 및 지형정보 데이터 추출을 위한 거리측정 등의 목적으로 주로 사용되었다. 현재 라이다 기술은 자율주행차량용 ADAS 센서, 무인로봇센서, 3차원 영상 모델링 기술 등에 사용되고 있다. 특히 라이다 센서는 국가전략 프로젝트 자율주행차량의 8대 부품으로 선정[8]되어, 사고예방 목적으로 전후방의 위험물을 검지하고 이를 회피하는 용도로 주로 사용되고 있다.

김재겸 외(2019)는 자율주행을 위한 라이다와 카메라 센서를 융합하는 기술에 대해 연구하였다. 데이터를 융합한 이유는 카메라만으로는 주변 환경을 인지하기 어렵고 자율주행의 중요한 정보인 차량의 깊이정보, 차량간 거리 등의 정보를 얻기 어렵기 때문이라고 하였다. 데이터 융합시 더 좋은 성능을 나타내고 있음을 도출하였다[22].

변예림 외(2020)는 라이다 PCD raw 데이터를 군집화하고 규칙기반으로 객체의 상대위치와 속도를 예측하고 추적하는 과정을 기술하였다. 이 논문에서는 딥러닝이 아닌 군집화를 통해서도 높은 수준의 차량과 보행자 구분성능을 보여주었다[23].

선민혁 외(2022)는 라이다 객체인식에 대한 개괄적인 개념과 [표 4]에서처럼 여기에서 사용되는 대표적인 인공신경망 알고리즘에 대해 소개하고 있다. 낮에만 좋은 성능을 보이는 카메라보다 라이다는 주변 환경영향을 적게 받는 장점이 있고 정확한 거리정보를 수집하는 등 자율주행 인지 기술발전에 있어 매우 중요하다고 언급하고 있다[24].

---

8) 과학기술전략회의 제2차, '9대 국가전략 프로젝트 선정'(2016.8)

[표 6] 특성추출과 객체탐지방식 구분(출처 : 선민혁 2022, 김윤범 2021)

특성추출 (인코딩)	객체탐지방식 설명	알고리즘 종류
이미지 투영 방식	PCD를 이미지로 투영하여 3차원 변환	YOLO, R-CNN
복셀 기반 방식	정육면체로 분할하여 대표특성 추출 (폭, 길이, 높이, 채널)	VoxelNet, SECOND, Fast Point-RCNN
포인트 기반 방식	포인트에서 직접 특성을 추출	Point Pillars, 3DSSD, PointRCNN
포인트복셀 기반 방식	포인트와 복셀 방식의 장단점을 활용하여 특성추출	PV-RCNN, Pyramid R-CNN
그래프 기반 방식	주변 포인트와의 관계를 정점(Vertex)과 간선(Edge)의 그래프로 표현	PC-RGNN, Point-GNN

문연국 (2022)는 자율주행차량용(ADAS : Advanced Driving Assistance System) 라이다 기술은 자동차 차량거리 제어와 전방 주시에 적용되고 있으며 주로 사용되는 기술 종류로는 Laser Rangefinder와 Imaging LIDAR[9]이 대표된다고 소개하고 있다. 현재 전 세계적인 추세는 라이다의 대량생산이 가능하도록 저가격화와 소형화에 집중하고 있다고 서술하고 있다. 국내의 경우도 효율적인 투자와 저변확대를 통해 기술 우위를 확보해야 한다고 주장하고 있다[25].

Zhao J. et al(2019) 연구에서는 라이다의 경우 정밀의료 장비에서 지도 생성에 이르기까지 다양한 분야에서 사용되는 원격감지 기술로 소개하고 있다. 또한 교통분야에서는 도로 사용자들을 정밀하게 추적 감지할 수 있는 잠재력이 있음에도 불구하고 주로 자율차량에만 사용되고 있는 점을 지적하고 있다. 저자는 이러한 장점을 활용하여 교차로에 고정식 라이다 센서(95%이상 검지, 한방향 30m 구간)를 사용하여 보행자와 차량

9) 레이저 빔의 진행 방향에 대한 공간에 대한 영상 모델링(거리정보를 포함)이 가능한 기술

을 감지하고 추적하는 기본개념, 솔루션 알고리즘, 적용지침 등을 연구하였다. 이를 통해 보행자와 차량의 위치, 속도, 방향 등의 라이다 데이터를 정확하게 수집하는 기술을 제안하였다[46].

Lesani A. et al(2019)는 많은 보행자 통행량을 모니터링하기 위해 적외선 센서 등을 사용하고 있기는 하지만 보행자를 검지하는 것은 매우 어렵다고 지적하고 있다. 저자는 이러한 문제를 해결하기 위해 새롭게 떠오르는 라이다 기술(최대 50m, 고정식 사용)을 기반으로 실시간 보행자 카운팅 시스템을 개발하고 평가하였다. 분석결과 실제 보행량과 비교하였을 때 97%이상 정확한 계산과 1.1%의 방향감지 오류결과를 보였다[47].

제2절 교통안전 평가방법

1. 안전대리변수(SSM) 지표별 특징 및 측정방법

가. 안전대리변수 개념

일반적으로 사고는 예측할 수 없이 매우 우연적이고 독립적으로 발생되는 하나의 사건이다. 특히 사고가 발생하기까지는 인적, 물적 원인 등이 다양하고 복잡하게 얽혀있어 실제의 사고자료를 가지고 분석을 한다고 해서 명백한 하나의 원인으로 설명하기가 불가능한 경우가 대부분이다. 이러한 사고의 독특한 특성으로 인해 실제로 발생한 사고의 분석이 아닌 교통사고가 유발될 수 있는 위험상황을 계량화하고 안전도를 평가할 수 있는 지표인 안전대리변수(SSM : Surrogate Safety Measure)이 개발되었다.

안전대리변수는 위험상황을 계량화하여 수치화하는 방법으로 구현한다. 다시 말해, 사고의 직접적인 원인이 될 수 있는 차량의 실제 거동자료를 측정하여 도로교통의 안전성을 판단하고 이를 개선하기 위해 사용하는 것이다. 일반적으로 교통상충이론(Conflict Theory)[10] 및 하인리히 법칙(Safety Pyramid)[11] 개념이 기초가 된다.

안전대리변수(SSM)는 [표 7]과 같이 크게 시간관점(Temporal/Time-based), 거리관점(Distance-based), 감속/속도관점(Deceleration/Speed-based)중심의 3가지 방향으로 연구되어 왔다(Mahmud 2017, Peng 2020, Amini 2022)[56][57][58].

---

10) S. E. Perkins(1968), "교통상충(Traffic Conflict)이란 둘 또는 그 이상의 도로 이용자 사이의 상호작용으로써 도로이용자들이 사고에 임박한 상황을 피하기 위한 회피행동을 발생시키는 사건이다"

11) 안전 피라미드 이론 또는 1:29:300의 법칙, “어떤 대형 사고가 발생하기 전에는 같은 원인으로 수십 차례의 경미한 사고와 수백 번의 징후가 반드시 나타난다는 것을 뜻하는 통계적 법칙” (출처 : Industrial Accident Prevention : A Scientific Approach, 허버트 윌리엄 하인리히, 1931)

[표 7] 안전대리변수의 관점별 지표 (출처 : Mahmud 2017, Peng 2020, Amini 2022)

구 분	지 표
시간중심	TTC(Time to Collision)
	MTTC(Modified TTC)
	GTTC(General for TTC)
	CTM(Comprehensive Time-base Measure)
	TET(Tome Exposed TTC)
	TIT(Time Integrated TTC)
	CI(Crash Index)
	H(Time Headway)
	TA(Time to Accident)
	PET(Post Encroachment Time)
	TAdv(Time Advantage)
거리중심	PICUD(Potential Index for Collision with Urgent Deceleration)
	PSD(Proportion of Stopping Distance)
	MTC(Margin to Collision)
	DSS(Difference of Space distance and Stopping distance)
	TIDSS(Time Integrated DSS)
	UD(Unsafe Density)
	SHD(Stopping Headway Distance)
감속/속도중심	DRAC(Deceleration Rate to Avoid a Crash)
	CPI(Crash Potential Index)
	CIF(Criticality Index Function)
	DSSM(Deceleration-baed Surrogate Safety Measure)

미국 FHWA(2008)는「Surrogate Safety Assessment Model(SSAM) and Validation」최종보고서에서 상충이론(conflict theory)을 기초로 교통 시뮬레이션 모델에 의해 도출된 데이터를 이용하여 안전대리평가 모

델을 개발하였다. 11개 시나리오의 이론적 검증 테스트를 수행하였고 실체 충돌 기록과도 비교하였다. 그 결과 교통상충과 실제 충돌의 비율은 약 20,000:1로 나타났다. 또한 다양한 시뮬레이션(VISSIM, PARAMICS, AIMSUN, TEXAS 등) 사용시의 지침들을 제시하였다[55].

Mahmud S.M.S. et al(2017)은 수많은 교통상충분석 기술 중 어떤것도 완벽한 안전대리변수의 지표로 사용되지 않음을 지적하고 있으며, 각 지표별로 장단점을 잘 살펴보고 계속적으로 발전시켜 나아가는 것이 필요하다고 이야기하고 있다[56].

Peng L. et al(2020)는 미시교통지표기반의 안전대리변수와 도로상 실시간 충돌 위험관계에 대해 연구하였다. 통계적으로 다양한 안전대리변수들은 통계적으로 일치하는 결과를 나타내었다[57].

Amini R.E. et al (2022)는 자동차와 보행자의 상호작용에 대해 연구하였으며 안전도평가를 위해서 시간적, 공간적(거리, 속도) 근접성을 구분하였고 사고위험을 초기조건과 회피행동을 통해 측정하였다[58].

윤일수 외(2011)는 미국 FHWA에서 상충이론을 기반으로 개발한 Surrogate Safety Assessment Model(SSAM)을 이용해 교통신호 제어유형별 안전도를 비교하였다. 유형별로 신호운영 시나리오에 대하여 TTC, PET, DR, MaxS, DeltaS 등의 안전대리변수(SSM)를 산출하였다. 이와 함께 직각충돌(Crossing), 추돌(Rear-end), 그리고 차로변경(Lane Change) 상충 횟수를 추정하였다[26].

나. 교통안전평가 주요지표 및 특징

(1) TTC(Time to Collision)

Hayward(1972)는 TTC(Time to Collision)개념을 처음 제시하였고 최초에 제안될 때에는 충돌심각도(Conflict Severity)를 측정하기 위한 목적이었다고 한다.

TTC는 <그림 8>과 같이 현재의 조건에서 전방 차량과의 충돌까지 걸리는 시간을 의미한다. 즉, 두 차량이 현재 속도와 동일한 경로로 진행할 때 전방 차량과 충돌 소요시간이 특정 임계값 이하이면, 차량 간 상충이 발생하는 것으로 판단하는 것이다[66].

TTC는 (식 1)과 같이 단순한 방정식으로 계산이 가능하며 [표 8]와 같이 사고확률이 높고 낮음을 직관적으로 이해하기가 매우 편리하다. 이러한 이유 등으로 TTC는 가장 많이 사용되는 안전대리변수(Archer, 2005)이고 SSAM(Surrogate Safety Assessment Model) 최종보고서(FHWA, 2008)를 비롯한 많은 보고서와 자료에서 기준지표로 사용되었다. 하지만 선행차량이 추종차량보다 빠른 경우는 분석이 불가능하며, 개별차량의 속도 수준, 가감속 능력, 기하구조 조건(구배 등), 인지반응시간 등 다양한 조건을 고려하기에는 한계가 있다.

TTC 식은 다음과 같다.

$$TTC = \frac{P_i(t) - P_{i-1}(t) - l_i}{V_{i-1}(t) - V_i(t)} = \frac{\text{두차량의 상대거리}}{\text{두차량의 상대속도}} \qquad \text{(식 1)}$$

여기서, P_i는 차량 위치, $V_i(t)$는 차량 속도, l_i은 차량 길이이다.

<그림 8> TTC 개념도(출처 : Ritesh Kapse, 2018)

[표 8] 안전대리변수 임계값 및 해석 (출처 : SSAM 2008, 오철 2009, 박성용 2015)

안전대리변수	임계값	연구자	의미
Time to Collision(TTC)	1.0 초	Hayward(1972)	작을수록 위험
	1.5 초	Grayson (1984), van der Horst (1984, 1990), Hyden (1987), SSAM(2008)	
	3초	Hirst and Graham (1997)	
	4초	van der Horst (1994)	
Deceleration Rate to Avoid Collision(DRAC)	3.4 ㎧	AASHTO(2004)	클수록 위험
	3.35 ㎧	Archer(2005)	

오철 외(2009)는 실시간 주행환경에서 위험상황을 검지하고 운전자에게 경고정보를 제공하는 경고정보시스템을 제안하였다. 차량의 카메라 영상을 이용하여 위험상황을 계량화여 나타낼 수 있는 SSM을 이용하여 경고정보지수(WII : Warning Information Index)를 도출하였다. 영상검지기 추적성능이 우수한 경우 SDI, TTC 등을 이용하고 추적성능이 미흡한 경우 가속소음이나 속도의 변동을 활용하는 것이 바람직하다고 서술하였다. 다음 [표 9]처럼 연구자는 안전대리변수 활용시 집계(Aggregated)방법과 비집계(Disaggregated)방법 두가지로 구분된다고 주장하였다[28].

[표 9] 안전대리변수 활용 구분 (출처 : 오철 2009)

구 분	종 류	비 고
비집계(Disaggregated) SSM	SDI, TTC 등	궤적확인 가능
집계(Aggregated) SSM	RSI, RSTI, SV, AN 등	궤적확인 미흡

장현익 외(2013)는 자동긴급제동장치(AEBS : Advanced Emergency Braking System)의 안전성 평가지표로 TTC, 차간거리, 감속량을 사용하였다. 유럽의 경우 TTC 1.4초 이전 1차경고, 0.8초 이전에 2차경고, 일본의 경우는 0.8초를 기준으로 하고 있었고 실제 주행 실험결과 1차경고 2.3초, 2차경고 1.1초를 보였다[29].

김범일(2021)은 자율주행차로 도입시 안전문제를 평가하는 지표로 TTC를 주요 분석지표로 사용했으며 자율주행자동차와 일반자동차의 상충유형에 따라 TTC 임계값을 달리 적용하였다. 자율주행자동차의 TTC 임계값은 0.6초로 설정하였고 일반자동차 TTC는 안전을 위한 추가 여유시간 등을 포함한 1.5초를 기준으로 설정하였다[30]. 이와 유사한 결과로는 Natalie R. L. et al.(2019)는 수동운전과 자율주행운전간의 TTC 판단의 정확성과 반응시간 차이를 확인하였고 연구결과 자율주행운전이 TTC 판단에 더 정확하고 빠른 것으로 나타났다[59].

Felipe J. et al.(2013)는 충돌회피시스템에 적용할 수 있도록 단순하게 개선된 TTC를 제안하였고 세부적으로는 교차로 등에서 차량이 충돌할 때 먼저 충돌하는 부분(차량 모서리)까지 고려하여 충돌위험성 TTC를 분석하였다[60].

Jade M. et al.(2014)는 108명의 1년간 실제 운전기록 데이터 활용하여 전방충돌경고 시스템의 경고표출 시기를 운전에 특성에 맞게 특성화하기 위한 연령, 성별 행동차이 분석하였다. 그 결과 제동 시 TTC는 성별과 30대 이상 vs 30세 미만 모두 통계적으로 유의미한 차이가 존재하였고 여성보단 남성이, 젊은 성인보다 고령자가 더 높은 TTC일 때 위험하다고 판단하였다[61].

(2) 다양한 TTC 개선지표

과거부터 오랜기간 동안 연구해온 수많은 안전대리변수(SSM) 중에서 시간을 기반으로 하는 지표인 TTC는 가장 활발한 연구되어 사용되고 있으며 지속적인 개선이 이루어지고 있는 분야이다.

Minderhoud and Bovy(2001)는 기존 TTC를 기반으로 발전시켜 <그림 9>와 같이 새로운 안전지표 2가지(TET : Time exposed TTC, TIT : Time Integrated TTC)를 제안하였다. TET(노출시간)와 TIT(노출면적)를 통해 TTC의 크기규모(magnitude)를 측정하였다. 저자는 논문에서 TTC는 안전성 평가를 위해 가장 기본적이고 강력한 기초지표라는 의의를 가진다고 말하고 있다. 측정된 TTC 결과를 제대로 구하려면 모든 차량의 연속적인 행동을 파악해야하나, 실제 파악이 어려워서 이산적인 값을 추정하여 사용하고 있는 한계가 있다고 설명하고 있다[62].

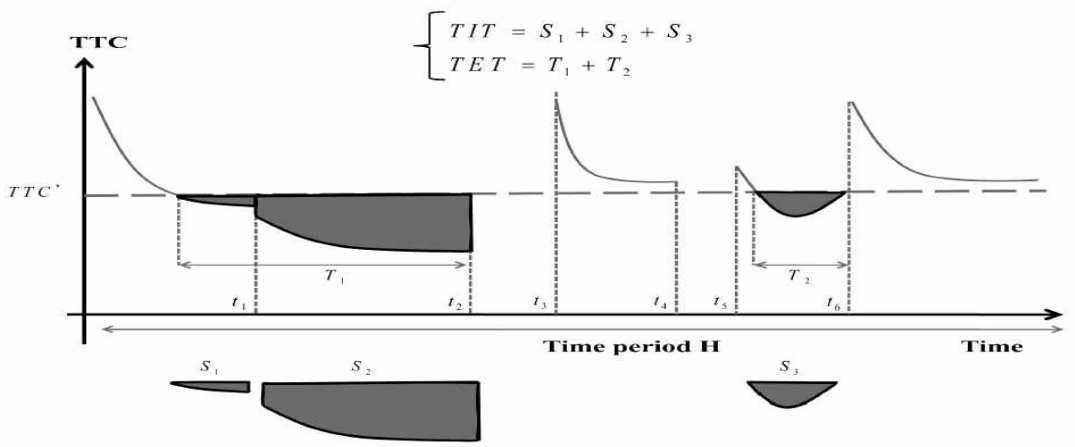

<그림 9> TIT와 TET 개념도(출처 : Minderhoud and Bovy, 2001)

Ozbay K. et al(2008)은 교차로 분석이 아닌, 링크기반 분석을 위해 미시적 시뮬레이션인 Paramics을 통해 잠재적 충돌 위험과 심각성을 분석하였다. 기존 TTC는 전방차량의 속도가 빠르거나 사고시 잠재적인 가감속을 고려하지 못하는 한계가 있었다. 이러한 문제점 등을 개선하기 위해서 다음 (식 3)과 [표 10]과 같이 가감속을 고려한 MTTC(Modified TTC)를 개발하였다. 또한 충돌심각도를 고려한 CI(Crash Index) 그리고 전체 구간에 대한 CI를 산출할 수 있는 CID(Crash Index Density)를 개발하였고 실제 사고데이터를 통해 검증하였다[63].

$$V_F t + \frac{1}{2}\alpha_F t^2 \geq D + V_L t + \frac{1}{2}\alpha_L t^2 \quad \text{(식 2)}$$

$$\frac{1}{2}\Delta\alpha t^2 + \Delta V t - D \geq 0 \quad \text{(식 3)}$$

여기서, F는 후방차량, L는 선두차량, D는 초기 상대거리

[표 10] MTTC 전후방차량 속도와 가속도를 고려한 충돌위험 시나리오
(단, C : 충돌발생, P : 충돌 가능성, I : 충돌 불가능)

V	$V_F > V_L$			$V_F \leq V_L$		
α	$\alpha_L > 0$	$\alpha_L < 0$	$\alpha_L = 0$	$\alpha_L > 0$	$\alpha_L < 0$	$\alpha_L = 0$
$\alpha_F > 0$	P	C	C	P	C	P
$\alpha_F < 0$	P	P	P	I	P	I
$\alpha_F = 0$	P	C	C	I	C	I

Behbahani H. et al(2015)는 TTC의 규모와 변동율을 고려한 CTM (Comprehensive Time-based Measure) 안전지표를 개발하였다. 이를 통해 TIT보다 더 정밀한 충돌 예측을 수행하였다[64].

Nadimi N. et al(2020)은 TTC가 다각적인 수정과 개선을 통해 [표 8]과 같이 지속적으로 MTTC, GTTC, TET, TIT, CTM, ETTC, TTCD 등으로 개량되어왔음을 보여주었다. 저자는 이러한 다양한 개선사항에 대해서 동시에 적용가능한 플랫폼을 제안하여 사고위험의 정밀도와 정확도를 높이는 연구를 진행하였다[65].

[표 11] 다양한 TTC 개량지표 (출처 : Nadimi et al, 2020)

구 분	연구자	장단점	산출식
TTC (Time to Collision) [66]	Hayward (1971)	간단하고 이해빠름, 차량운동특성 간과, 후방차량이 빠른 경우만 가능	$\frac{P_i(t)-P_{i-1}(t)-l_i}{V_{i-1}(t)-V_i(t)}$
MTTC (Modified TTC) [63]	Ozbay (2008)	가감속상황(상수) 고려, 차량별 운동특성 간과	$\frac{1}{2}(\ddot{X}_F-\ddot{X}_L)t^2+(\dot{X}_F-\dot{X}_L)t-(X_L-X_F-l_L)=0$
GTTC (General formulation TTC) [67]	Saffarzadeh (2013)	모든 차량운전 특성(MTTC에서 상충이 아닌것도)고려(미분), 적용이 복잡함	$X_{0F}-X_{0L}+L_L+\sum_{n=1}^{k}\left(\frac{1}{n!}\times\left[\frac{\partial^n X_F}{\partial t^n}-\frac{\partial^n X_L}{\partial t^n}\right]\times t^n\right)=0$
TET&TIT (Time exposed TTC & Time integrated TTC) [62]	Minderhoud and Bovy (2001)	위험의 강도와 지속도 고려, TTC 변화 간과	$\mathrm{TET_i}=\sum_{t=1}^{T}\delta_i(t)\cdot\tau$ $\mathrm{TIT_i}=\sum_{t=1}^{T}[\mathrm{TTC^*}-\mathrm{TTC_i}(t)]\cdot\tau$
CTM (Comprehensive time-based measure) [64]	Behbahani et al. (2015)	TTC의 크기와 변동율 고려, 공식을 정규화(충돌확률)하는 절차는 알려지지 않음	$CTM_i(H)=\frac{\sum_{t=1}^{T}\frac{1}{3}\left(\left(\delta_i(t)\times\frac{\frac{\partial TTC_i(t)}{\partial t}}{\tau}\right)+\delta_i(t)\left(\frac{TIT_i(t)}{\tau\times TTC}+\frac{TET_i(t)}{\tau}\right)\right)}{T}$ $\delta_i(t)=\begin{cases}0 & else\\ 1 & \forall\frac{\partial TTC_i(t)}{\partial t}<0\end{cases}$ $\delta_i(t)=\begin{cases}0 & else\\ 1 & \forall 0<TTC_i(t)<TTC\end{cases}$
TTC for a moving line section and a point [68]	Laureshyn et al. (2010)	측면 충돌 고려, 차량운동특성 간과	$\frac{(y_p)-k(x_p-x_1)}{(\dot{Y}_p-\dot{Y}_{\ln})-k(\dot{X}_p-\dot{X}_{\ln})}$
ETTC (Enhanced TTC) [69]	Kiefer et al. (2005)	선행차량 감속행위 고려(역TTC), 실제 차량운동특성 간과	$ETTC=\frac{1}{TTC}$
TTCD (Time to Collision with disturbance) [70]	Xie et al. (2018)	전방차량의 교란상황이나 저속 후미차량 등 고려, V2X기반이 갖추어져야 적용가능	$d^*=\frac{2\ddot{X}_L\ddot{X}_F-\ddot{X}_L}{2(X_L-X_F-l_L)}$ $\begin{cases}d\le d^* \rightarrow TTCD=\frac{(\dot{X}_L-\dot{X}_F)+\sqrt{(\dot{X}_L-\dot{X}_F)^2+2d(X_L-X_F-l_L)}}{d}\\ d>d^* \rightarrow TTCD=\frac{2d(X_L-X_F-l_L)+\dot{X}_L^2}{2d\dot{X}_F}\end{cases}$

(3) PET(Post-Encroachment Time)

Allen et al.(1977)은 PET를 <그림 10>과 같이 전방의 차량이 어느 한 지점을 통과한 시점과 후방의 차량이 그 지점에 도달한 시점의 시간차이로 정의(시간차이 0 = 추돌)하고 사고가 거의 일어날 뻔한 상황(near miss)을 계량화한 것이다. PET는 시공간적으로 차량간 근접성을 반영하고 있어 주행차량의 속도에 관계없이 측정가능하여 TTC한계점을 개선하였다[71].

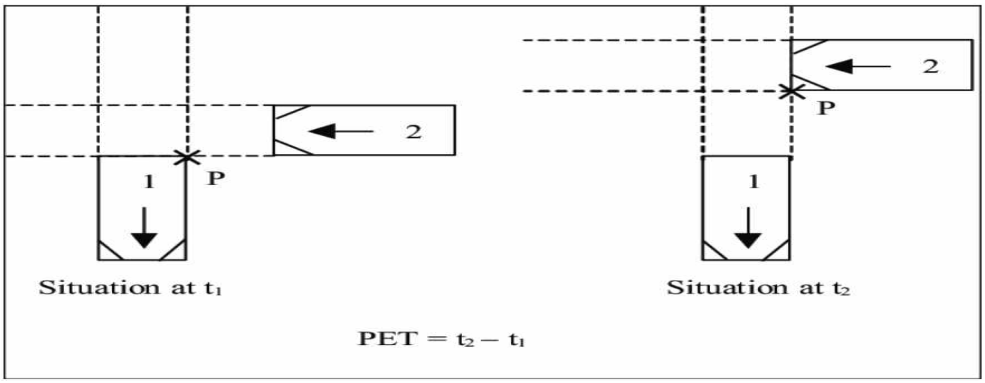

<그림 10> PET 개념도 (출처 : Allen, 1977)

(4) SDI(Stopping Distance Index)

Oh C et al.(2006, 2009)는 SDI 정의를 "선·후행 차량 간의 정지거리를 분석하여 두 차량의 최종 정지시 충돌여부를 판단하는 것"으로 다음 (식 4)처럼 방정식으로 표현하였다. 선행차량 급제동 시 차량별 정지거리를 비교하여, 충돌여부에 따라 안전(safe,0), 불안전(unsafe, 1)으로 표출하였다[72].

$$d_L > d_F$$

$$\Rightarrow V_L \times h + \frac{V_L^2}{2a_L^{dec}} + l_L > V_F \times t_R + \frac{V_F^2}{2a_F^{dec}} \quad \text{(식 4)}$$

$$\therefore SDI = \begin{cases} 0\,(safe) & \text{if } V_L \times h - V_F \times t_R + l_L + (\frac{V_L^2}{2a_L^{dec}} - \frac{V_F^2}{2a_F^{dec}}) > 0 \\ 1\,(unsafe)\,otherwise & \end{cases}$$

여기서, h는 차두시간, t_R는 브레이크반응시간, dec는 감속율

김준형 외(2008)는 차량영상 이미지분석 시스템의 개별차량 주행궤적 자료를 이용하여 연속류 교통상충 검지 및 분석시스템을 제안하였다. 차량 주행 패턴 분석을 차량추종과 차로변경 이벤트로 구분하여 분석하였고 차로변경시 인접차량 4대와의 상관관계 분석을 통해 <그림 11>과 같이 교통안전도(SDI, TTC 등)을 산출하였다[31].

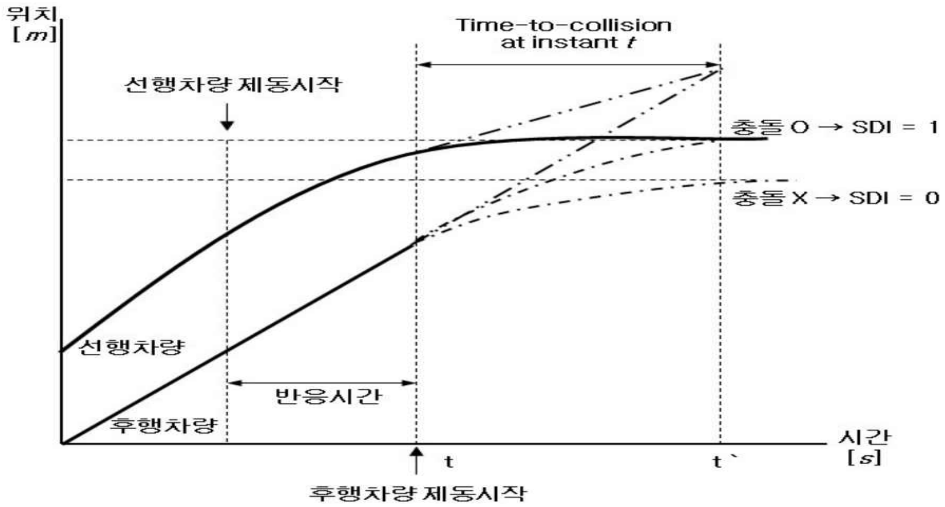

<그림 11> SDI와 TTC 개념도 (출처 : 김준형 2008)

(5) AN(Acceleration Noise, 가속소음)

고준호(2006)은 일반차량의 GPS 측정값을 이용하여 가속소음을 측정하고 특성을 분석하였다. Herman(1959), Jones(1962), Drew(1965) 등은 다음 [표 12]처럼 감가속도 평균값에 대한 감가속도의 표준편차로 변화크기(분산정도)를 가속소음(AN)으로 정의하였다. 연구결과 가속소음은 일반적인 통행시간보다 혼잡상태를 잘 보여주었으며, 교통혼잡이 증가함에 따라 편차가 커졌다. 측정된 차량의 가속도 평균의 편차가 큰 경우 위험한 움직임으로 판단하였고 편차가 작은 경우는 안정적인 주행으로 간주하였다[32].

[표 12] 가속소음 식 & 차량속도의 관계 그래프(출처 : Herman, 1959)

▷ 가속소음(σ) 식

$$\sigma^2 = \frac{1}{T}\sum_{1}^{T}(\alpha(t)-\overline{\alpha})^2$$

α : 감가속도

$\overline{\alpha}$: 평균 감가속도

T : 총 통행시간

t : 특정시간

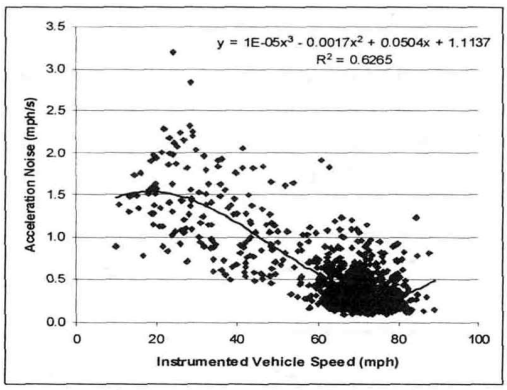

(6) DRAC(Deceleration Rate to Avoid Crash)

감속(Deceleration)은 운전자의 대표적 회피행동으로 교통안전에 대하여 시공간적으로 나타낼 수 있다. Cooper and Ferguson(1976), Gettman and Head(2003)는 후행하던 차량이 위험상황을 파악하고 감속을 시작할 때의 충돌회피가 가능한 감속도로서 DRAC(Deceleration Rate to Avoid Crash) 개념을 제시하였다. 이러한 개념은 연구자에 따라 회피감속을 고려하여 maximum deceleration rate (MaxDR), deceleration rate(DR), CPI(Crash Potential Index) 등으로 다양하게 제시되었다. 모든 지표들은 동일한 시점에서 운전자의 회피반응을 감속도의 크기로 나타내었다. 이러한 개념들은 감속도의 크기가 클수록 충돌이 발생할 확률이 높다는 것을 전제로 하고 있다[27]. AASHTO(2004)와 Archer(2005)는 적정 최대 감속도로 각각 3.4 ㎧와 3.35 ㎧를 제시하고 있다.

앞서 언급한 안전대리변수 이외에도 ACI(Aggregated Crash Index), SHD(Stopping Headway Diatance), DSSM(Deceleration-based Surrogate Safety Measure) 등등 지속적으로 연구자들에 의해 다양한 안전대리변수가 지속적으로 제안되고 있다.

2. 교통안전 평가를 위한 데이터 수집방안

교통안전성 평가를 위한 데이터 수집을 위해서는 차량거동(속도, 위치, 가속도 등)자료를 활용하는 것이 일반적이다. 차량거동을 측정하는 방법은 크게 지점에서 관찰(목측과 영상촬영 등) 그리고 차량 이동(궤적)정보를 통한 분석으로 구분할 수 있다.

과거 이러한 지점수집(목측 등)으로는 정밀한 분석이 매우 어려웠으며 이를 개선하기 위해 컴퓨터를 이용한 모의실험(시뮬레이션)이나 모의주행(시뮬레이터) 방법을 많이 사용하였다. 하지만 이 또한 현실묘사의 근본적 한계로 만족할 만한 결과를 도출하기 어려웠다.

차량이동(궤적)정보를 수집하기 위한 방법은 시뮬레이션 방법과 프루브(Probe) 차량을 통해 실측하는 방법이 있다.

시뮬레이션을 이용한 연구사례로 오철 외(2011)는 서해안고속도로 매송 IC 부근에서 동영상 촬영 자료를 분석하여 TTC를 기반으로 한 사고확률(crash potential)모형을 생성하고 이를 VISSIM 시뮬레이션 결과를 적용하였다. 분석결과 앞뒤차량의 속도와 각 차간간격이 산출된 후미추돌 확률모형에 유의미하게 적용되었다[33].

박현진(2018)은 자율주행차량을 대상으로 주행궤적자료를 이용하여 주변차량과의 상호작용 분석 및 실시간 주행 위험도를 계량화하는 방법을 수행하였다. VISSIM 시뮬레이션을 사용하여 중부고속도로 곤지암 부근 공사구간의 강제 차선변경 등에 따른 위험요소를 분석하였다. 이를 사용하여 기본 SSM을 수정한 실시간 위험노출도 지표와 위험심각도 지표를 개발하였다[34].

van der Horst et al.(1993)은 접근속도와 감속강도를 시뮬레이터를 사용하여 TTC를 계산하였고, 운전자 반응시간을 고려하여 TTC 4.0초를 임계값으로 제시하고 있다. 또한, 저시정 조건의 주행에서도 TTC를 활용하여 분석결과를 도출하였다[73].

Touran et al.(1999)는 Monte-Carlo[12] 시뮬레이션을 수행하여, 자율순항주행(AICC:Autonomous Intelligent Cruise Control)의 안전도 평가를 위해 TTC를 안전성지표로 사용하였다[74].

Lee J. D. et al.(2002)은 사고의 30%로 차지하는 후방추돌사고에 대해 주행시뮬레이터를 이용하여 후방 충돌경보장치(RECASs)의 설치에 따른 운전자 반응을 측정하였다. 다양한 시나리오별로 최소 TTC, 최대 DR(deceleration rate)를 측정하였다[75].

Gettman and Head(2003)은 미시교통류 시뮬레이션 모형(Vissim, Paramics, Aimsun, Texas)를 사용하여 비교분석하였다. 신호교차로나 입출구 IC에서 다양한 안전대리변수(SSM)을 사용하여 다양한 상충(conflict)상황을 분석하였다[76].

실제주행을 통한 연구사례로 Katja(2003)은 교차로 현장에서 장비를 이용해 TTC이론(접근로별, 차두시간 분포)와 실제 데이터를 비교하였다. 그 결과 headway와 TTC는 서로 독립적인 지표이기에 서로 다른 목적으로 활용해야 알 것을 주장하였다[77].

Hourdakis et al.(2006)은 미국 MnDOT(미네소타)의 고속도로 1마일 구간에서 영상검지시스템으로 다양한 SSM을 측정하였다. 이를 이용하여 실제사고와의 로그회귀 검지모형식을 제안하였고 그 결과 58%의 사고검지와 6.8%의 오검지율을 보였다[78].

Guido et al.(2012)는 이탈리아의 지방부 2차로 도로를 주행하면서 스마트폰에 내장된 GPS(AGPS)를 이용하여 1초단위로 차량 이동궤적자료를 얻고, 이를 통해 이용하여 TTC와 DRAC를 계산하였다. 합분류가 일어나는 곳에서는 잠재적 충돌위험이 높은 것으로 나타났다[79].

박성용 외(2015)는 기존 지점기반 안전대리변수 연구의 한계점을 극복하기 위해 실시간 궤적자료를 이용하여 안전대리변수를 산출하는 방법을

---

12) 반복된 무작위 추출(repeated random sampling)을 이용하여 함수의 값을 수리적으로 근사하는 알고리즘을 부르는 용어 (출처 : 두산백과사전)

검토하였다. [표 13]와 같이 단일 지점에서의 측정값은 실제로는 주행 경로상 어느 지점에서든 사고발생 가능성이 있음에도 불구하고 해당지점에 국한된 거동자료를 이용하게 된다는 점에서 한계로 지적되고 있으며, 차량 주행궤적을 연속적으로 측정하는 방법은 장비 등의 현실적인 어려움이 있다고 주장하고 있다. 이러한 한계를 극복하기 위해 RTK(Real Time Kinematics)-DGPS(Differential Global Positioning System)를 이용하여 차량궤적 데이터를 산출하고 이를 통한 SSM 지표값이 다양한 주행상황의 위험을 합리적으로 잘 설명해주고 있다. 분석결과 사고다발 구간에서 안전대리변수의 변동성이 높았으며 정체와 같은 외부요인이 있는 경우는 더 높은 변동성 값을 나타내는 것으로 연구되었다[27].

[표 13] 측정방법별 특장점 비교(출처 : 박성용 2015)
(○ : 매우좋음, △ : 좋음, × : 나쁨)

측정 차량	측정방법	지점측정			연속측정		
		측정 용이성	자료의 신뢰성	자료의 현실성	측정 용이성	자료의 신뢰성	자료의 현실성
개별 차량	목측	×	×	○	불가능		
	영상검지	○	△	○	×	△	○
	GPS	○	△	○	○	△	○
	RTK-DGPS	○	○	○	○	○	○
	시뮬레이션	○	○	×	○	○	×
	라이다	**○**	**○**	**○**	**○**	**○**	**○**
다수 차량	영상검지기	○	△	○	△	△	○
	시뮬레이션	○	○	×	○	○	×
	라이다	**○**	**○**	**○**	**○**	**○**	**○**

3. 속도분산과 교통안전과의 관계

일반적으로 주행(제한)속도가 높은 상태인 것보다 속도의 분산(표준편차)이 증가하는 것이 사고와 더 높은 상관관계(주요원인)를 가지고 있는 것으로 알려져 있다(Solomon, 1964).

추가적으로 관련 연구를 살펴보면 Glennon(1970)은 오르막구간에서 일반차량과 트럭간의 속도차이를 분석하였고 그 결과 속도차가 10mph (16km/h) 이상 발생할 경우 사고연루율이 급격히 증가한다고 주장하였다[95].

Garber & Gadiraju(1989)은 사고율-속도분산(편차의 제곱)간의 비선형(2차식) 회귀함수 추정하였고 그 결과 속도분산이 증가함에 따른 사고율 또한 급격히 증가하는 것을 발견하였다[96]. 또한 유사한 연구로 Quddus(2013)은 사고율을 예측하기 위한 다양한 형태의 모형을 추정하였고 심각도와 상관없이 속도의 표준편차는 사고율과 양의 상관간계를 보인다는 것을 밝혀내었다. 즉, 속도분산이 1% 증가하면 교통사고율이 0.3% 증가하는 것으로 연구결과를 도출하였다[97].

Hauer and Bonneson(1997)은 평균속도 변화와 교통사고 변화의 관계를 표현하기 위하여 Power 모델(평균속도를 적용한 사고수)을 제시하였고 이러한 모델의 전이성 확인을 위해 사고변이함수(AMF : Accident Modification Function)을 도출하였다. 이를 통해 평균속도의 작은 변화가 사고에는 큰 영향을 주는 것으로 나타났다[98].

Choudhary et al(2018)은 제한속도와 속도분산 중 어느 것도 단독으로 사고율에 영향을 주는 것이 아니며 서로 복합적으로 영향을 준다고 주장하고 있으며 기존의 속도분산 측정방식도 두 가지 차원(차로간의 분산과 차로내의 분산)을 모두 고려해야한다고 주장하였다[99].

정규수(2021)는 DTG를 활용하여 구간별, 차로별 속도편차가 발생하는 구간을 위험구간으로 정의하였고 이를 적용하기 위한 기준으로 속도의 표준편차가 8km/h 이상 되는 곳을 위험구간으로 정의하였다[37].

제3절 본 연구의 차별성

1. 선행연구 시사점

라이다 데이터를 이용하여 고속도로 혼잡 및 교통안전 모니터링을 위한 연구 수행에 앞서 관련분야 선행연구들을 분석해 보았다.

자율주행차의 감각(눈)기관이라고 할 수 있는 다양한 센서들이 존재하고 발전되어 왔다. 이러한 센서들은 주로 차량 자체의 안전한 주행과 사고예방 목적을 위해 활용되고 있다. 최근들어 차량에서 사용되는 레이더나 GPS센서와 같은 다양한 센서를 이용하여 교통상태 측정 등에 활용하기 위한 연구가 수행되었으나 센서가 설치된 주체차량(Ego) 중심의 단독적인 데이터 활용이거나 전방차량 움직임 파악정도에 한정된다는 단점이 존재한다.

교통정보 수집방법에 있어서도 지점검지방식과 구간검지방식 각각의 문제점(넓은 간격 설치, 시간처짐, 본선중심 수집, 집계자료 형태, 검지기 신뢰도 저하 등)을 개선하기 위해 다양한 연구가 진행되고 있었으며 특히 경로형 데이터수집을 위한 다양한 노력들이 현재 진행되고 있었다. 하지만 대부분이 데이터 수집이 <그림 12>와 같이 본선 중심으로 이루어지고 있으며 본선이외의 사각지대(램프, 영업소, 분기점, 휴게소 등) 정보에 대한 데이터 수집은 부족한 실정으로 고객이 원하는 맞춤형 정보제공에는 한계가 있는 상황이다.

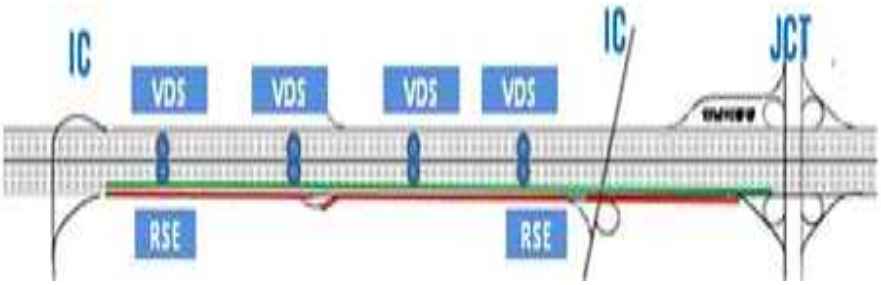

<그림 12> 교통자료 본선중심 수집 문제점(출처 : 김수희, 2016)

또한 Daganzo(1997)는 교통정보 수집방식 중 기존 평면적(지점, 구간) 교통데이터 수집방법이 주로 사용되고 있으나 <그림 13>과 <그림 14>와 같이 많은 한계점이 있고, 하늘(조감도)에서 내려다보는 항공기반(aerial-based)방식으로 교통정보 수집방식에 변화가 필요하지만 기술적, 경제적 문제 등으로 실용화되지 못하는 한계가 있음을 지적하고 있다. 항공기반 방식의 대안으로 드론, 무인기 등이 검토되고 있으나 각종 규제사항(운항가능지역과 고도, 비행체 무게, 조종자격, 야간시간 불가 등) 등으로 인해 원하는 곳에 대한 자료수집에도 제약이 있으며 수집된 영상자료 분석 또한 어려움이 있는 상황이다.

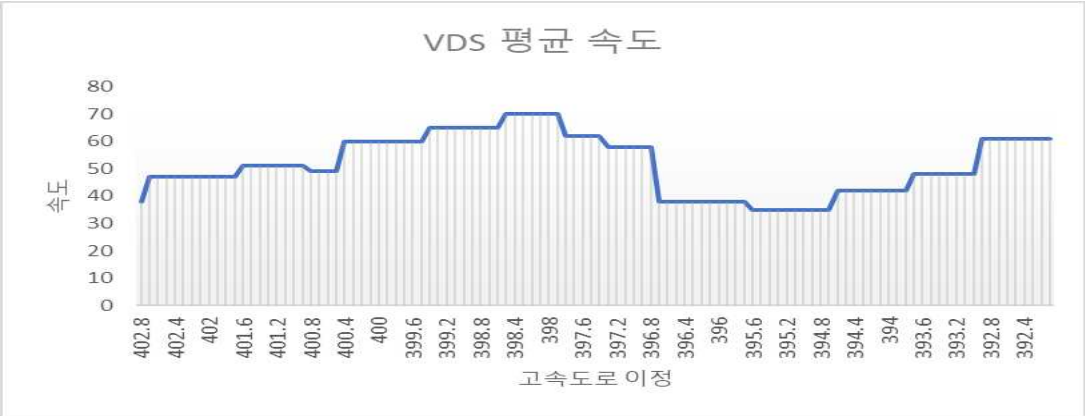

<그림 13> 평균적, 집계적 데이터 수집으로 인한 계단식 표출 예시

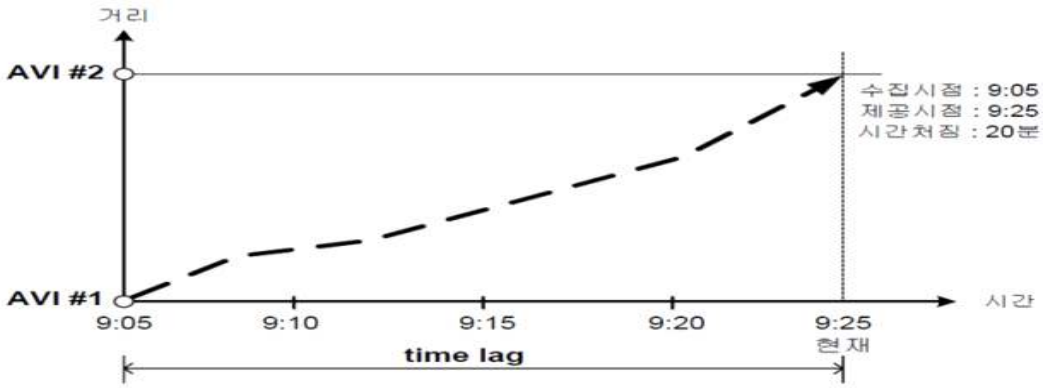

<그림 14> AVI에서 시간처짐(Time Lag) 현상 예시(출처 : 김은정, 2014)[35]

또한 주행도로의 안전성 평가를 위해 가장 광범위하게 사용하고 있는 TTC 분석방법의 경우도 기존에 대부분의 분석이 주체차량(Ego)과 선행차량과의 관계만을 분석하고 있거나 시뮬레이션을 통해 현실을 단순히 모사하여 분석하고 있어 교통흐름 상황에서의 차량이 가지는 대표성 및 현장 적합성 등에 대한 문제점이 지속적으로 제기되고 있다.

또한 교통사고 발생 특성상 특정지점에서의 사고가 그 지점만의 원인만으로 발생하는 것이 아니기 때문에 TTC 측정을 위해서는 특정지점보다는 연속적인 차량주행궤적을 통해 분석하는 것이 적절하지만 이러한 측정방법에는 현실적인 어려움이 있어 향후 연구되고 개발되어야할 과제로 남겨져 있다.

2. 본 연구의 차별성

기존 연구와의 차별성은 다음과 같다. 본 논문에서는 기존 평면적 검지방식과 교통상태 모니터링이 가지는 추정과 오차들을 보완하기 위해 자율주행 차량(probe vehicle)에 설치된 라이다 센서 측정값을 교통데이터로 변환하고 이를 이용한 실시간 교통안전성 평가 방식 개념과 방법을 제안하고자 한다.

i) 기존에 교통정보로 사용하지 않았던 차량센서 데이터 중 라이다 센서를 활용한 새로운 교통정보 수집 및 활용 방법을 제안

ii) 기존 프로브방식인 이동차량 단독 데이터수집 방법이 아닌 이동하는 공간 주변의 차량 모두에 대한 단구간 공간 교통정보를 수집하는 방법을 개발

iii) 기존 본선중심의 정보수집(지점 및 구간)이 아닌 시간적 연속성을 고려한 시공간적(spatiotemporal)인 정보수집방법으로 이동구간 전

체에 대한 연속적인 공간 데이터 수집을 통해 세부적(차선별, 전후방 등)이고 실질적인 교통안전성을 평가 및 비교

ⅳ) 안전성 평가시 차량의 다양한 개별데이터(가감속, 속도, 위치 등)을 활용하여 TTC, MTTC 등을 도출하고 주행좌우 공간의 추월 가능여부 분석을 통한 현실적인 안전성 평가 수행

[표 14] 검지방법별 교통안전 데이터 수집가능 여부 비교
(○ : 우수, △ : 보통, × : 나쁨)

구 분	차간 거리	차두 시간	가감속	공간 평균 속도	상충 지점수	가속 소음	속도 편차
지점 검지	△	△	×	△	×	×	×
구간 검지	△	△	△	△	×	△	△
라이다	O	O	O	O	O	O	O

향후 자율주행차 보급에 따른 더 많은 주행공간의 데이터 증가와 CV(Connected Vehicle)를 통한 정보공유는 다음의 <그림 15>처럼 운전자 및 교통관리자에게 실시간 위험성 산출을 통한 맞춤형 상호정보 소통이 가능하게 해줘서 더욱 안전하고 원활한 교통환경 구현에 이바지하는데 시작점이 될 것으로 기대된다.

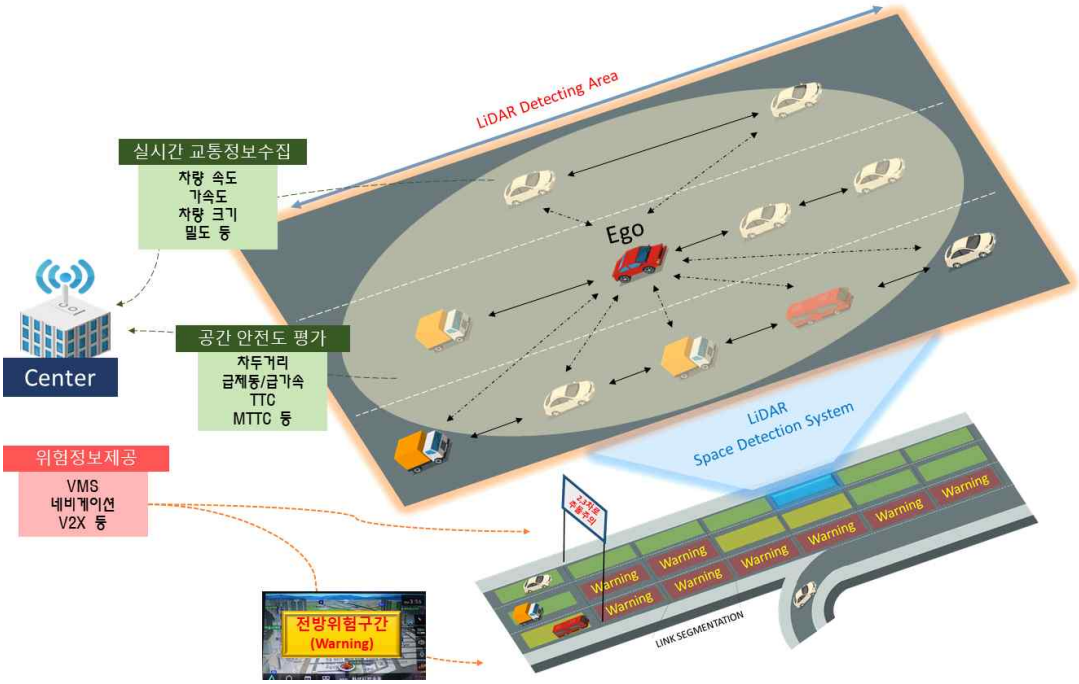

<그림 15> 전체 연구 개념도

제3장 차세대 검지체계 분석 및 최적센서 선정

본 장에서는 기존의 검지체계의 한계를 개선할 수 있는 차세대 검지체계가 가져야 할 특성들을 분석하고 이를 상시적으로 구현하기 위한 최적의 센서를 검토하고 선정하고자 한다.

제1절 차세대 검지체계 분석

이번 절에서는 교통정보 수집을 위해 앞서 검토한 항공기반 방식과 구간검지방식의 장점을 도로상에서 구현하기 위한 새로운 차세대 검지체계의 요구사항을 분석하고 정리하였다.

1. 차세대 검지체계의 요구조건

차세대 검지체계는 시대적 흐름인 탈중앙화, 탈평균화, 초개인화 등 다양한 변화를 반영하여 [표 15]와 같이 관리자 중심의 관제가 아닌 운전자가 공감할 수 있는 교통정보의 수집이 필요하다. 관리자는 다양한 정보를 분석하고 제공하는 상호협력적 검지체계로 변화를 추진해야 한다.

[표 15] 차세대 검지체계 요구조건 분석

기 존	개 선	비 고
관리자 중심	운전자 중심	탈중앙화
정보생산 주체와 소비자 분리	생산자와 소비자 동일	참여형
교통소통 중심	소통과 안전을 동시고려	영역확장
평균적, 집계적, 정태적 상황	개별적, 상황별 맞춤정보	초개인화
동질구간 단위 모호	세부적 구간 단위	세분화
한정적 목적을 위해 검지	다목적 검지	다목적
수집 및 분석 후 진단	현장에서 상태진단	실시간성

또한 기존의 평균적이고 정태적(static)이며 집계적인(aggregated) 교통정보에서 자율주행시대에 적합한 개별적이고 상황별 조건에 따른 동태적(dynamic)이며 미시적인(disaggregated) 정보제공이 필요하다. 또한 단순히 물리적 변화중심의 동질구간(homogeneous) 단위가 아닌 시간별, 공간별 그리고 환경별로 세부적이고 이질적(heterogeneous) 단위 제공이 가능해야 한다. 또한 수집된 데이터가 다양한 목적으로 제공이 가능해야 하고 수집 후 현장에서 바로 진단을 통하여 정보를 주변 운전자와 상호 공유하게 함으로써 기존 교통소통과 더불어 교통안전을 동시에 고려할 수 있는 검지체계로 발전되어야 한다.

결국 이러한 다양한 개선사항을 만족시키기 위한 차세대 검지체계는 개념적으로는 다음의 [표 16]와 같이 기존의 측면뷰(Side View)와 고정적 버드뷰(BEV : Bird Eye View) 같은 관리자적 관점에서 벗어나 미시적으로 운전자 주변을 끊임없이 살피고 관찰할 수 있는 어라운드뷰(Around View) 혹은 서라운드뷰(Surround View)로의 변화가 요구된다.

[표 16] 데이터 수집관점 비교

(출처 : 김수희 2016, Brandon Schoettle 2017)[101]

기 존			개 선
Side View	Bird View		Around(Surround) View
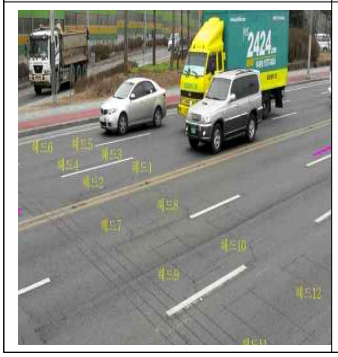	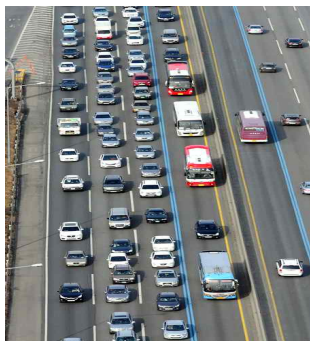	⇨	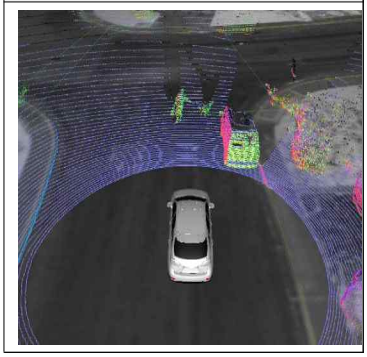

2. 참여형 이동검지체계(MDS) 제안

본 논문을 통해 제안하고자 하는 차세대 검지체계 방식을 “참여형 이동검지체계(MDS : Moving Detecction System)방식(이하 이동검지체계)”이라 명명하고 다음과 같이 정의한다. 이동검지체계는 <그림 16>과 같이 이동하는 차량(probe vehicle) 주변공간(차로별, 구간별)에 대하여 끊김없이(seamless) 연속적으로 운전자 관점에서 도로구간의 다양한 객체(차량, 사람, 시설물 등)를 탐지하여 교통정보화하고 현장에서 즉각적인 안전성 평가 등 상호정보 소통을 통해 살아있는 교통상태(traffic state)를 모니터링 할 수 있는 체계로 정의하고자 한다.

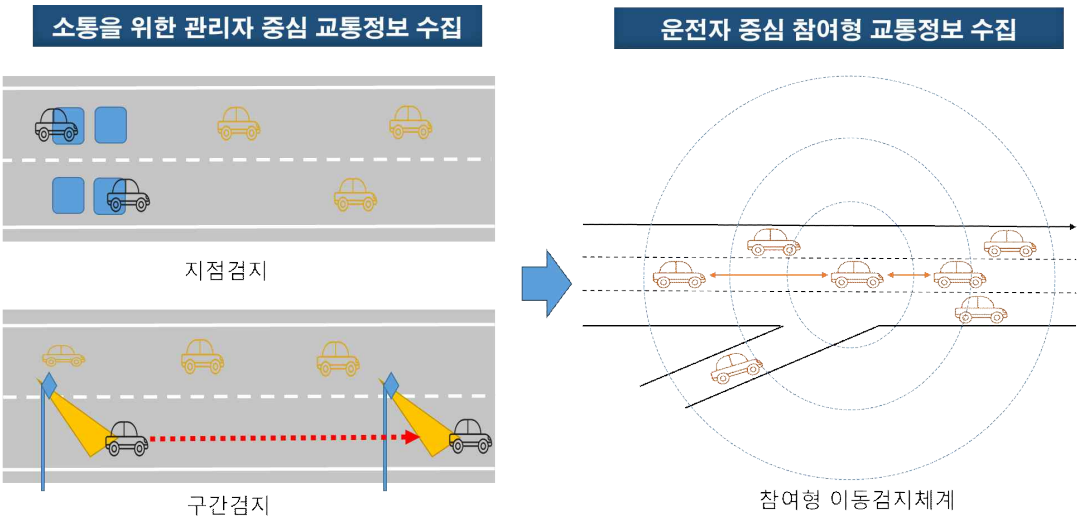

<그림 16> 이동검지체계(MDS) 개념도

이러한 이동검지체계(MDS)를 통해 앞서 분석하였던 기존 교통정보 검지(detection) 수준에서 한 단계 발전하여 실시간으로 검지와 교통상태에 대한 진단(examination)이 동시에 이루어지는 수준으로 향상하는 것을 목표로 한다. 또한 운전자 중심의 현장 참여형 정보수집을 통해 소통과 더불어 안전정보 제공을 위한 개별적, 상황별(차로별, 거리별 등) 맞춤정보를 제공하는 것을 원활히 수행하게 된다.

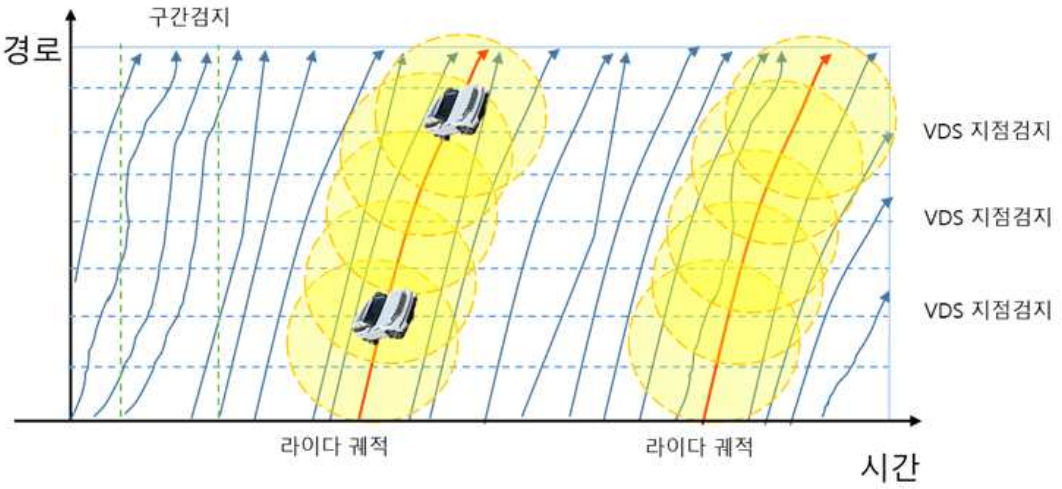

<그림 17> 이동검지체계 시공도와 기존 검지방식 비교

<그림 17>와 같이 구간검지방식에서 교통흐름 및 구간 기종점 분석이 가능한 장점과 항공기반 검지방식에서 연속적인 밀도측정 및 국지적 지체상황 파악이 가능한 장점을 동시에 만족할 수 있는 방식이 이동검지체계(MDS) 방식이다.

기존검지 방법들과 이동검지체계 방식에 대한 장단점은 다음 [표 17]과 같이 정리 및 비교하였다. 이러한 이동검지체계 방식은 이동하는 차로 및 기하구조 등 다양한 공간변화에 대한 정보와 더불어 시간대별로 교통상황(혼잡, 원활 등)의 변화상황을 실시간으로 수집하고 판단 할 수 있다는 장점을 가지고 있다. 하지만 이러한 수집정보가 한정된 공간에서의 공간평균속도(SMS : Space Mean Speed)이며 순간밀도를 사용한다는 점을 고려하여 현장상황에 맞게 적절하게 적용되어야 하는 점은 현재 개선해야 하는 한계임을 고려해야 한다.

[표 17] 검지방식별 장단점 비교분석

구분	지점검지체계(VDS) Vehicle Detection System	구간검지체계(SDS) Section Detection System	이동검지체계(MDS) Moving Detection System
종류	루프, 영상, 적외선 등	GPS, 네비, DSRC 등	라이다, 레이다, C-ITS 등
범위	1차원 점(point), 선(line)	2차원 면(section, face)	3차원 공간(space, room)
수집자료	통과교통량, 지점속도	구간통행시간, 경로	속도, 밀도, 차종 등
수준	검지 → 분석 (detection, find)		검지&진단 동시 (examination, diagnosis)
장점	* 전수조사 가능 (속도, 교통량 등) * 저렴하고 정확도 높음 * 차로별 정보수집 가능 * 차종구분 가능(영상) * 직관적분석 가능(영상) * 돌발상황검지 가능	* 기종점(OD) 중심 분석 * 구간 및 경로정보 제공 * 지점보다 정확한 통행시간(1~10초 단위 수집) * 교통관리 및 서비스 측면 편리한 사용	* 실시간 데이터 수집 * 미시적 행태분석 * 운전자관점 운행자료 * 차로 및 차량별 정보 수집 가능 * 밀도측정(운행구간) * 수집방법(주기, 공간 등) 상황별 조정가능 * 전방 시거정보 수집
단점	* 유지보수 어려움 (VDS) * 밀도 측정 어려움 * 수집주기(30초 수집, 5분단위 제공, VDS) * 경로분석 불가능 * 본선중심의 분석	* 최적구간 선정 어려움 * 시간처짐(Time-Lag) * 정체지점 파악 어려움 (교통류 동질성 전제) * 통신망 등 기반시설 필요 * 전체 교통량측정 한계	* 샘플조사 형태 * 시공간분석 어려움 * 장비별 검지영역 상이함 * 비교적 비용 고가 * 별도 시스템 구축 필요
개념도	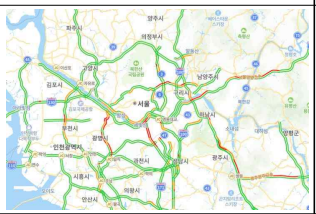		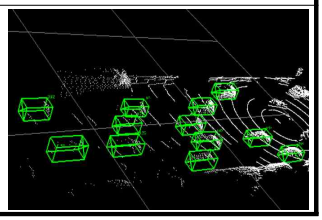

제2절 이동검지체계를 위한 차량센서 선정

이번 절에서는 자율주행차량에 사용되고 있는 다양한 센서들의 특징을 알아보고 이동검지체계 수집에 적합한 센서 및 객체탐지(차량검지) 알고리즘에 대해 선정하였다.

1. 주요 차량센서 비교

가. 센싱(Sensing)의 기본특성

우리가 사용하고 있는 모든 센서들은 궁극적으로 빛의 파장과 에너지를 사용하는 것이다. <그림 18>와 같이 빛의 파장에 따라서 가시광선, 전파, X선 등 다양한 이름으로 부르는 것이고 우리는 이러한 파장별 특성(거리, 에너지 특성 등)에 따라 용도에 맞게 활용하고 있는 것이다.

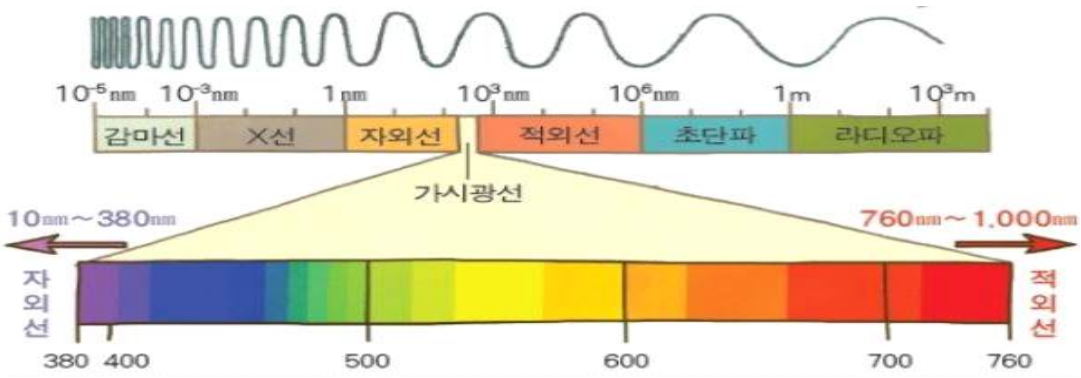

<그림 18> 빛의 파장별 구분(출처 : 물리학백과, 한국물리학회 www.kps.or.kr)

나. 주요 차량센서별 장단점 비교

미래의 교통(모빌리티)은 자율주행차량을 통해 우리가 목표로 하는 안전과 소통을 모두 만족할 수 있는 방향으로 발전해 나아가는 추세이다. 진정한 자율주행의 의미를 갖는 단계인 자율주행 4단계 이상의 목표를 달성하기 위해서는 자율주행의 핵심 역할인 눈을 담당하는 주요센서(라

이다, 레이다, 카메라 등)의 역할이 매우 중요하다. 이러한 센서들은 [표 18]과 같이 각기 장단점[13]을 가지고 있으며 현재까지도 활발하게 연구되고 있다. 안전과 주행목적 등 적절한 상황에 맞게 센서를 적용 및 융합하는 것이 필요하다.

[표 18] 차량센서별 장단점 비교

구 분	카메라	레이다	라이다
장 점	* 물체 구분가능 * 질감, 색상, 대비 정도 포착 가능 * 저렴한 가격	* 날씨 등 외부환경 영향 거의 없음 * 사물 투과 측정(가려진 물체) 가능 * 장거리 측정 가능	* 밀도 수집이 가능 * 정밀한 차량이동분석 가능 * 단구간 정보 취득 가능(미시적) * 직관적 분석 가능 * 3D 이미지 가능
단 점	* 날씨 등 외부환경에 취약 * 이미지학습 필요 * 정확한 거리 판독 어려움	* 작은 물체 식별 어려움 * 표지판 인식 불가 * 직선 거리만 측정 가능 * 정밀한 이미지 제공 어려움	* 데이터분석 어려움 * 비교적 고가장비 * 날씨에 영향받음 * 분석공간(전후방 각 60m) 한정
장단점 비교[14] 그래프	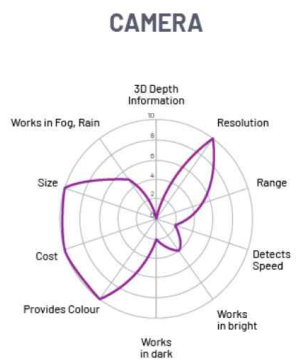	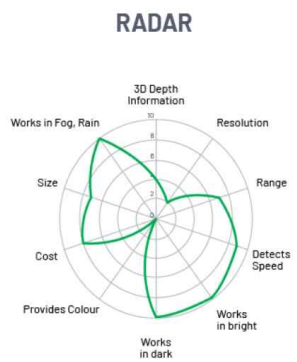	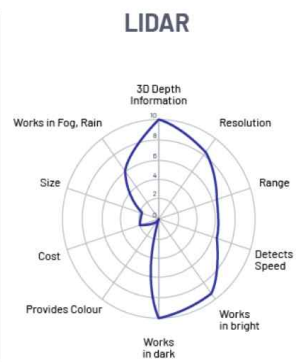

13) 한국일보(2021.7.17.), “자율주행차, 사람보다 안전한 운전 비밀은 ‘센서 3형제’에 있다”

14) HelloT(2020.6.30.), “2021년 자율주행차 레벨3 양산 시작, ADAS ‘라이다’ 대중화에 성큼”

다. 카메라(영상) 센서의 특징 및 한계

카메라는 일반적으로 우리 눈으로 볼 수 있는 가시광선을 사용함으로 가장 쉽게 인지하고 판단하기에 매우 편리한 센서이다.

카메라(영상) 센서를 소개하면 일반적으로 사람들은 다음 [표 19] 왼쪽의 CCTV 화면처럼 기둥의 높은 곳에서 관측(Top View)하거나 하늘에서 바라보는 조감도(BEV: Bird Eye View)와 같은 이미지를 주로 떠올린다.

[표 19] 카메라 영상의 관점 비교(출처 : 한국도로공사 교통정보센터, 자체 촬영)

CCTV(드론 등) 카메라 영상(관측용)	주행 데이터 카메라 영상(주행차량)

하지만 차량주행 데이터의 경우 관측용 이미지와는 다르게 차량의 전고 이상의 높이에서 데이터를 취득할 수가 없는 문제가 있다. CCTV 등에서 촬영되는 관측용 이미지의 경우 도로영역 Contour(등고선)를 통하여 도로상황 분석이 가능하지만, 차량에 설치된 카메라 주행데이터의 경우 도로의 전체상황을 분석하기에 다음 [표 20]과 같이 객체폐색(가림), 빛 번짐, 화면왜곡, 가시거리의 한계 등 단점이 존재하기 때문에 카메라를 사용한 주행데이터 분석에는 많은 어려움이 존재한다. 이러한 문제점들은 야간주행의 경우 주변환경(빛, 그림자, 날씨 등)에 민감하게 반응하여 물체를 탐지하고 인지하는데 많은 문제가 발생하게 된다.

[표 20] 카메라와 라이다의 오류 상황에서의 데이터 비교(출처 : 자체 촬영)

구 분	카메라 영상	라이다 영상
(a)		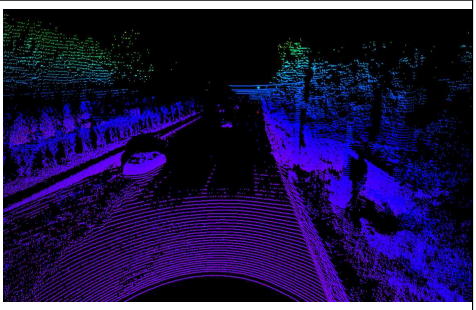
(b)		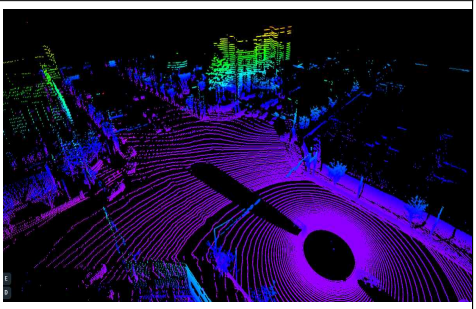
(c)	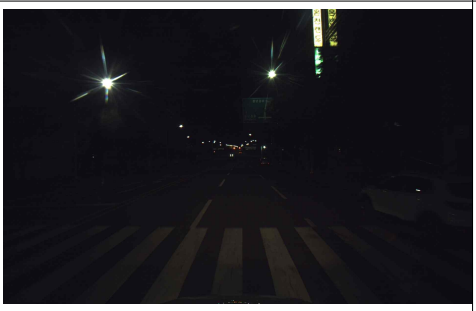	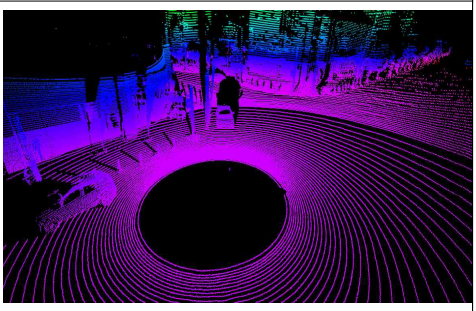
(d)		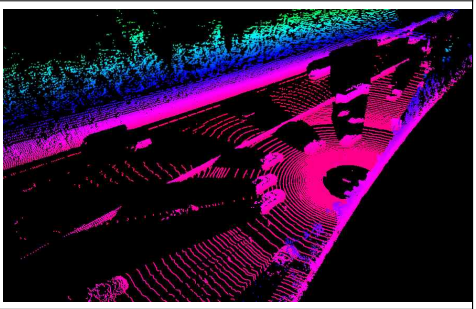
(a) Camera Noise (b) Small Object (c) Low-light Image (d) Occlusion ※ 라이다 영상 시각화(supervisely[15] 프로그램 사용)		

15) https://supervise.ly

최근 영상수집 자료분석에 많이 사용되고 있는 딥러닝 방식의 YOLO 알고리즘 또한 기존 목측이나 프레임 분석 방식 등에 비해서는 매우 빠르고 간편하게 분석이 가능한 장점을 가지고 있으나, 이 방식 또한 다음 [표 21]와 같은 영상이 가지고 있는 근본적인 문제는 지속적으로 발생되고 있다.

[표 21] 실제 카메라 기반 영상 검지 문제점 예시(출처 Chandel, 2015)[100]

미검지 영역발생	가림현상 발생

이와 더불어 <그림 19>과 같이 카메라 영상의 근본적인 한계는 수집되는 원본 데이터가 2차원(평면)이라는 문제이다. 따라서 카메라(영상) 속 물체에 대한 정확한 깊이(Depth)[16]를 알 수가 없었다. 이를 극복하기 위해 초창기에는 카메라 영상정보에서 비지도적인(Unsupervised) 인공지능 학습방식을 사용하여 차량운행에 필요한 위치와 깊이를 예측하는 기술을 구현하였다[85]. 하지만 이 방식도 자율주행을 위해서는 한계가 있었으며 최근 들어 Pseudo-LiDAR(유사라이다)라는 방식을 개발한 이후 정확도 증가로 획기적인 자율주행의 성능향상을 이루었다[86].

16) 위에서 밑바닥까지, 또는 겉에서 속까지의 거리(출처 : 네이버 국어사전)

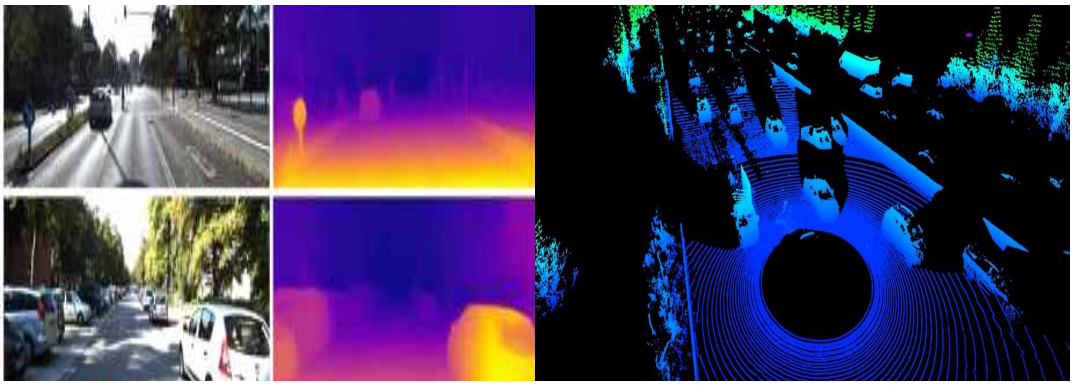

(a) 2차원(화면 및 깊이추정)[88]　　(b) 3차원(라이다 깊이측정)

<그림 19> 2차원과 3차원의 깊이 예시(출처 : (a) Alhashim, 2018, (b) 자체)

카메라 영상을 자율주행 등에 활용하기 위해서는 xy평면(2D)으로 나타나는 영상정보에서 깊이정보를 얻기 위해서는 Depth Estimation(깊이추정)을 수행해야 한다. 교통분야에서 영상을 통해 정확한 깊이추정 뿐만 아니라 상대적 속도, 가속도 그리고 조향각 등을 추정하는 것은 사고예방 등 안전한 주행을 위해서는 매우 중요하고 어려운 과정이다.

깊이추정 방법(김승기, 2019)으로 다음 <그림 20>과 같이 인간의 눈과 유사한 Stereo 카메라 방법, 비행시간(ToF : Time of Flight) 방법, 구조광(SL : Structured Light)을 이용한 방법 그리고 초점을 이용한 방법(DFD : Depth from Defocus) 등이 있으며 이중 최근에는 단일 카메라로 이용가능한 DFD 분야에 많은 연구가 진행되고 있다[36].

하지만 카메라 영상기반 깊이추정 방법은 실측지와 동일한 객체의 거리추정이 불가능하다. 왜곡, 번짐, 겹침 등 카메라의 고질적인 문제점이 존재하기 때문에 실측치에 가까운 거리정보를 추정한다는 것은 불가능에 가깝다. 반대로 라이다 센서는 적외선 신호를 발사하여 돌아오는 시간을 사용하여, 실측치의 거리정보를 취득할 수 있다. 따라서 속도, 방향, 거리정보 분석이 중요한 교통정보수집 방법에서 라이다 센서가 카메라 센서와 비교하여 폭넓고 정밀한 분석이 가능하다.

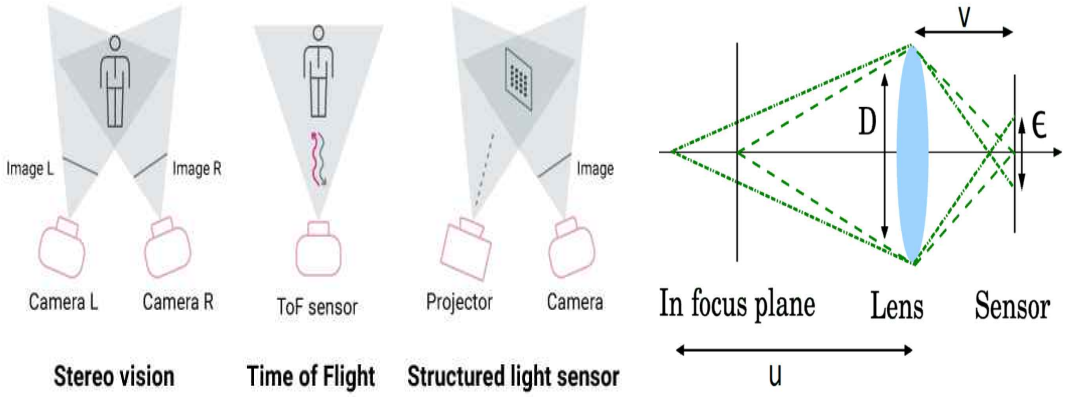

<그림 20> 다양한 깊이추정 방법

(출처: (좌)www.avsystem.com/blog/time-of-flight, (우)jun Zhou, 2015)

이러한 기술개발을 통한 성능향상에도 불구하고 라이다는 실측에 의한 참값(Ground-Truth)에 근사한 값이고, 카메라 영상기반 방식은 최대한 참값에 근사한 값을 도출하기 위해 노력하여 추정해야 한다는 점에서 명확한 차이가 존재한다.

라. 라이다 특징 및 한계

라이다(LiDAR : Light Detection And Ranging)는 빛(근적외선)의 반사를 이용하여 물체까지의 거리를 측정하고 형상까지 이미지화하는 3차원 영상센서 장비이다.

라이다 센서를 사용하여 수집된 포인트 클라우드 데이터(PCD : 점군데이터)는 2차원 이미지 데이터와 비교하여 분산(Sparse)되어 있다는 단점이 존재하여 객체분류 분야에서 쉽게 사용되기는 어렵지만, 차량위주로 존재하는 도로상황에서는 차량의 정확한 위치를 특정할 수 있기에 자율주행 분야에서 활발하게 연구되고 있는 센서이다. 다음 <그림 21>은 다양한 센서의 검지영역을 비교하고 있다.

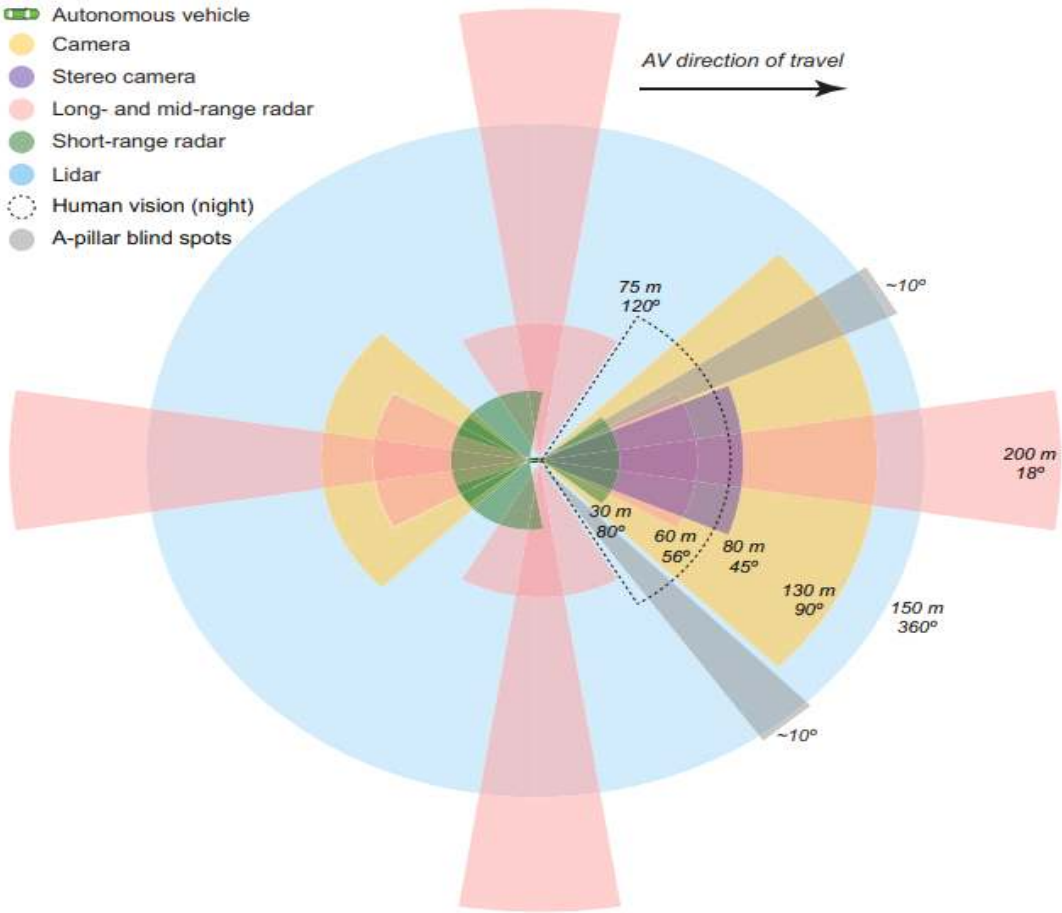

<그림 21> 차량센서 종류 및 범위(출처 : Brandon Schoettle, 2017)

라이다 센서의 주요 특징은 아래와 같다.

- ○ 인식 정확도가 높아 인식을 위한 센서로 주로 사용
  - 초당 20~300만개 점군 데이터 수집(주변 환경 및 장비에 따라 상이함)
- ○ 고해상 데이터를 추출함으로써 안전이 선행되어야하는 자율주행의 핵심기술로 활발하게 개발되는 추세
- ○ 하지만, 차량과 보행자 등의 필요한 객체 정보들을 검출함과 동시에 불필요한 정보들도 획득하게 되므로 그대로 사용할 수 없어 데이터 처리에 많은 어려움이 존재(변예림, 2020)[23].

○ 일반위성이나 항공영상에 비해 라이다 데이터는 다음과 같은 장점이 존재(김동환, 2021)[38].

ⅰ) 능동센서(스스로 신호를 발출하고 수신)로써 태양광의 가시광선에 의존하는 일반영상보다 다양한 정보를 얻을 수 있음

ⅱ) 2차원이 아닌 3차원정보를 제공가능하고 위치정보뿐만 아니라 신호강도 정보 등 다양한 정보제공이 가능함

라이다의 주요 한계로는 일반적으로 단가가 높아 경제적 측면에서 쉽게 적용하기 어려운 단점이 있다. Hecht(2018)는 라이다의 높은 비용이 센서를 선택하는데 많은 제한요소로 존재하지만 새로운 기술로 가격이 낮아지고 있다고 서술하고 있다[87]. 실제로 2018년 웨이모의 자율주행 자동차에 설치되었던 라이다의 경우 75,000달러(한화 약 9천만원)정도였으나 현재는 고급형과 저가형에 따라 가격차이가 존재하긴 하지만 1,000달러에서 50달러 수준까지 가격이 하락되었다. Velodyne (벨로다인), 루미나, 화웨이, HESAI 등 다양한 라이다 생산업체들이 신제품에 대한 계획을 발표하였으며, 가격은 수백달러 수준에서 출시할 것으로 예상된다. 또한 국내 현대차(오토엘), 삼성전자, 만도 등도 라이다 출시를 선언하고 개발 중에 있다[17]. 라이다는 초기에 비해 새로운 기술발달로 인하여 지속적으로 단가가 낮아질 전망이다.

추가적으로 가격과 더불어 라이다 센서의 단점은 비나 눈이 오는 기상악화의 상황에서 데이터의 품질이 저하된다는 점이다. 카메라의 경우도 동일한 문제가 발생하지만 라이다의 빛(레이저)가 빗방울 혹은 눈에 의해 차단되는 Weather Occlusion현상이 생기기 때문이다. 현재 악천후로 인하여 생기는 노이즈를 제거하기 위한 많은 연구들이 수행되고 있다. Jianqing(2020)는 기존 밀도기반 공간 클러스터링(DBSCAN) 방법이 눈이 오는 상황에서 정밀한 3D-SDBSCAN방법을 제안하였으며, 제안한

---

17) 아이뉴스24(2021.9.17.), “설득력 잃는 일론 머스크의 '라이다 무용론”, https://www.inews24.com/view/1405613

방법은 눈이 오는 악조건에서 실험해 보았을 때 기존 방법보다 우수한 결과를 보여주었다[89]. 이 외에도 악천후 상황에서의 라이다 데이터의 문제점들이 많이 제기되고 있으나, 개선방안에 대한 연구도 점차 제안되고 있는 추세이다[90][91][92].

2. 운행구간 정보수집을 위한 센서장비 선정

향후 자율주행 4단계이상 구현을 위해서는 작은 안전사고 문제가 절대로 발생되어서는 안되는 상황이다. 특히 자동차의 특성상 운전자의 생명과 직결되기 때문에 신뢰성이 보장되어야 한다는 측면에서 검토해 본다면 다음의 [표 22]와 같이 현재는 다소 경제적으로 불리하지만 차량용 센서 중 다양한 장점을 보유하고 있는 라이다 센서를 사용하는 것이 적절한 것으로 판단하였다.

[표 22] 라이다와 카메라 방식 비교

구 분	라이다	카메라(영상)
원 리	빛을 발사하여 물체의 형태를 **측정** (Measurement, 3D)	영상을 이용하여 물체를 **추정** (Estimation, 2D)
장 점	3차원 측정을 통해 정확한 물체 파악(객체인식 우수)이 가능	2차원 영상을 통해 인간의 눈과 유사한 직관적(객체 분류 우수) 파악
단 점	장비가 상대적으로 비싸고 3D 데이터 처리가 어려움	이물질, 역광, 야간 등에서 작동 안됨
정확도 [80]	86%	스테레오 9% (유사라이다 56%)
시각화 [102]	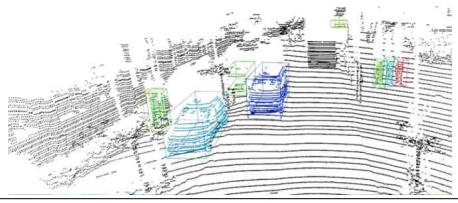	
선정	○	

다음 <그림 22>의 경우 실제 야간에 전방 카메라 화면(좌측)과 라이다 센서 검지 결과(우측) 차량의 객체탐지 결과를 비교한 예시이다. 전방카메라의 경우 대략 9대의 차량을 눈으로 확인할 수가 있는데 라이다의 경우는 이보다 많은 14대의 차량이 검출되고 있음을 확인할 수가 있다. 주황색 원형안의 영문자 L의 경우는 화면에서는 확인되지 않지만 라이다에서는 검출된 경우를 나타내고 있다. 물론 전방 카메라의 경우는 카메라 센서가 100% 모두를 검지한다는 것을 가정한다.

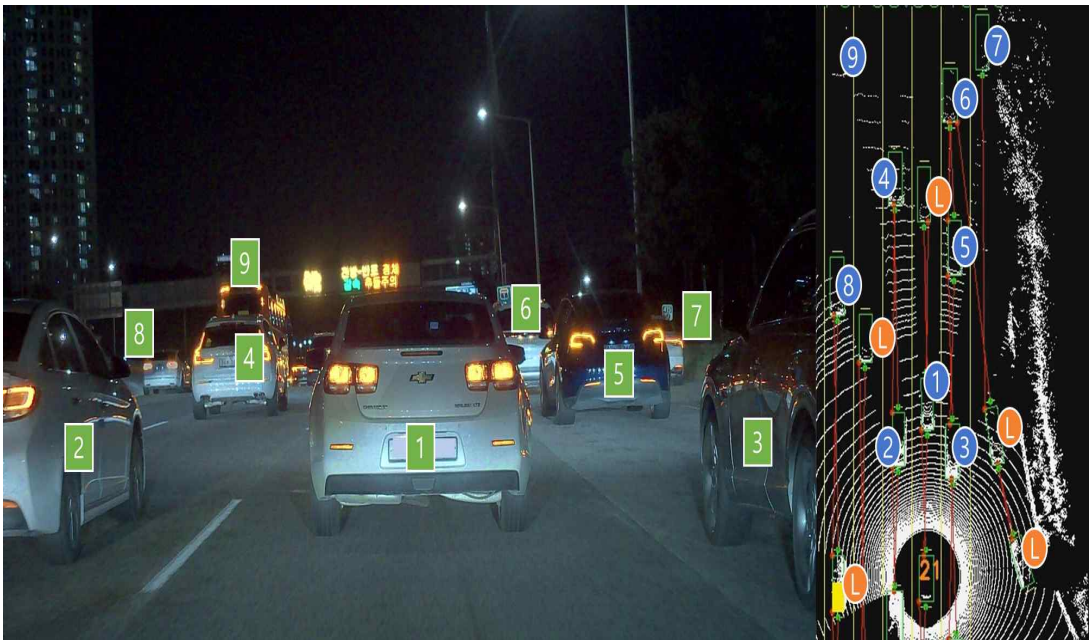

<그림 22> 전방 카메라와 라이다 검지비교 (주황색 L : 라이다추가 검지)

전방 카메라뿐만 아니라 후방 및 좌우 카메라의 경우도 유사한 결과를 보여주고 있음을 다음의 <그림 23>와 <그림 24>를 통해 확인하고 비교해 볼 수가 있다.

<그림 23> 전후좌우 카메라 영상 화면

영문자 L로 표시된 경우는 라이다에 의해 추가로 탐지된 차량의 사례를 보여주고 있다. 물론 카메라의 경우도 사람의 눈처럼 보이는 모든 차량 전체를 차량으로 탐지한다는 가정을 두고 비교한 것으로 실제로는 카메라에서 인식하지 못하는 경우가 빈번히 발생하기 때문에 라이다의 우수한 객체탐지 능력을 확인할 수가 있다.

정리하면 다음 [표 23]과 같이 카메라는 가시광선을 이용하기 때문에 색을 구별하는 능력을 탁월하나 야간과 악천후에 약점이 있으며 라이다 센서는 사물을 추정이 아닌 인지하고 입

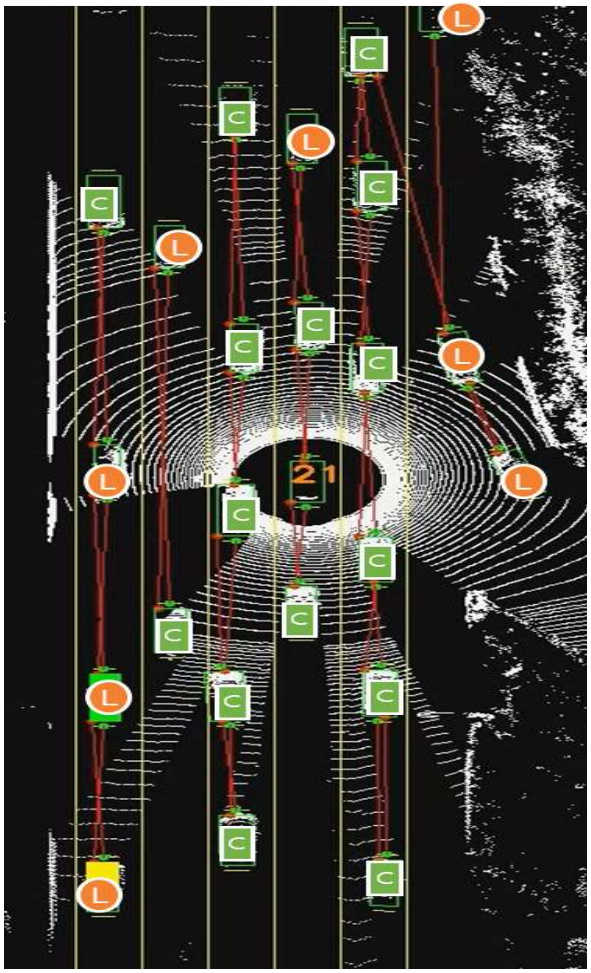

<그림 24> 전방향 라이다 검지사례

체적으로 측정이 가능하여 안전측면에서 탁월하다는 가장 큰 장점을 가지고 있다.

[표 23] 센서별 기능 구분 (○:양호, △:제한적, ×:나쁨)
(출처 : 키움증권 리서치, '자율주행 산업 미리보기', 21.9. 재구성)

구분	색깔	사물 인지	사물 구분	악천후 작동	조도 (야간)	해상도	거리 측정	3D 좌표	생산 원가
카메라	○	△	○	×	△	○	△	×	○
레이더	×	○	×	○	○	×	○	×	○
라이다	△	○	△	△	○	○	○	○	×

3. 차량검지를 위한 알고리즘 선정

앞서 선행연구에서도 살펴보았듯이 라이다를 이용한 객체탐지 방법은 주로 Pillar, Point, Voxel 기반의 알고리즘을 사용하고 있다. 이러한 다양한 객체 탐지 알고리즘 중 이번 논문에서는 관련분야 연구성능 결과 중 가장 우수한 것을 선정하여 논문에 적용할 예정이다. 알고리즘의 경우 추후 더 우수한 것을 사용하여 연구결과를 업데이트 한다면 지속적인 성능향상이 가능할 것으로 판단하고 있다.

다음의 <그림 25>은 최근 발표된 알고리즘 성능평가 결과를 비교하여 보여주고 있다. 검증을 위한 다양한 모델 중 Kitti[18]의 학습데이터를 사용하여 성능을 비교해보았을 때 Voxel R-CNN이 평균정밀도(AP : Average Precision)[19] 최대 90.90%로 가장 우수한 결과를 보여주었다. 또한 처리속도의 경우(FPS : Frame Per Second)도 25.2 Hz(헤르즈)로 평균이상의 처리속도를 보여주고 있다.

---

18) KITTI(Karlsruhe Institute of Technology and Toyota Technological Institute) Vision Benchmark, www.cvlibs.net/datasets/kitti/, 성능에 대한 비교결과를 리더보드(순위표)에 공개

19) AP(Average Precision) : 정밀도(Precision)과 재현율(Recall)을 종합한 수치

이러한 비교성능 결과를 바탕으로 이번 연구에서는 다양한 객체검지 방법(이미지, 복셀, 포인트 등) 중 교통분야 안전도 평가를 수행하기에 적합한 실시간성(처리속도)과 안전성(정확도)을 동시에 만족할 수 있는 Voxel R-CNN 방식을 선정하여 객체를 검지하고 향후 분석 처리하고자 한다[81].

Method	FPS (Hz)	AP_{3D} (%) Easy	Mod.	Hard
RGB+LiDAR				
MV3D (Chen et al. 2017)	-	74.97	63.63	54.00
AVOD-FPN (Ku et al. 2018)	10.0	83.07	71.76	65.73
F-PointNet (Qi et al. 2018)	5.9	82.19	69.79	60.59
PointSIFT+SENet (Zhao et al. 2019)	-	85.99	72.72	64.58
UberATG-MMF (Liang et al. 2019)	-	88.40	77.43	70.22
LiDAR-only				
Point-based:				
PointRCNN (Shi, Wang, and Li 2019)	10.0	86.96	75.64	70.70
STD (Yang et al. 2019)	12.5	87.95	79.71	75.09
Patches (Lehner et al. 2019)	-	88.67	77.20	71.82
3DSSD (Yang et al. 2020)	26.3	88.36	79.57	74.55
PV-RCNN (Shi et al. 2020a)	8.9	90.25	81.43	76.82
Voxel-based:				
VoxelNet (Zhou and Tuzel 2018)	-	77.47	65.11	57.73
SECOND (Yan, Mao, and Li 2018)	30.4	83.34	72.55	65.82
PointPillars (Lang et al. 2019)	42.4	82.58	74.31	68.99
Part-A^2 (Shi et al. 2020b)	-	87.81	78.49	73.51
TANet (Liu et al. 2020b)	28.7	85.94	75.76	68.32
HVNet (Ye, Xu, and Cao 2020)	31.0	87.21	77.58	71.79
SA-SSD (He et al. 2020)	25.0	88.75	79.79	74.16
Voxel R-CNN (ours)	25.2	**90.90**	**81.62**	**77.06**

<그림 25> 객체탐지 알고리즘들의 성능비교(출처 : Jiajun Deng et al, 2021)

제4장 라이다 센서기반 교통정보 수집 및 분석 방법론 정립

본 장에서는 이동검지체계에 적합한 데이터 수집 센서인 라이다를 이용한 교통정보 수집방법과 안전성 모니터링 방법 등에 대하여 기술한다.

교통정보 수집 등의 방법은 다음의 <그림 26>과 같이 구성되며, 주요 부분은 3개의 부분으로 나누어 설명한다. 순서는 1) 라이다 센서를 이용한 주행데이터 수집, 2) 라이다 데이터를 활용한 교통정보 처리 그리고 3) 교통상태 및 안전성 모니터링 순으로 진행된다. 각 부분별로 절차와 방법에 대해서 상세히 설명하고자 한다.

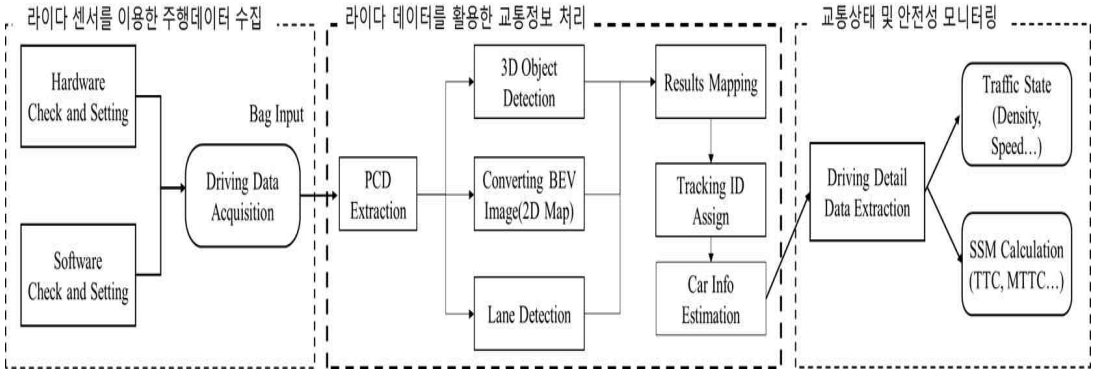

<그림 26> 라이다를 이용한 교통정보 수집 절차

제1절 라이다 센서를 통한 주행데이터 수집

본 절에서는 라이다를 이용한 데이터 수집 절차 및 방법에 대하여 설명한다. 데이터 수집 절차는 다음 <그림 27>과 같이 3개 부분으로 나누어 설명할 수 있다. i) Hardware 점검(Check) 및 설정(Setting), ii) Software 점검 및 설정, iii) 현장주행을 통한 데이터 취득 순으로 상세히 서술한다.

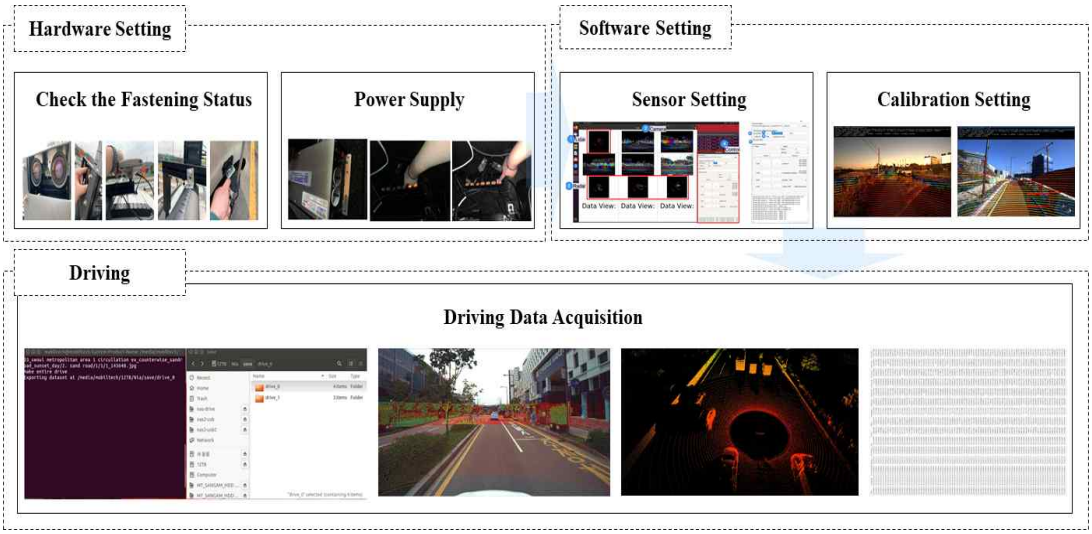

<그림 27> 라이다 데이터 수집 흐름도

1. 수집차량 및 장비 제원

데이터 수집장비는 <그림 28>와 같이 한국전자기술연구원(KETI)에서 보유중인 차량(현대 아이오닉 일렉트릭)에 설치된 센서를 활용하였다. 본 데이터 수집 차량은 높은 수준의 자율주행 연구에서 가장 핵심적인 역할을 하는 라이다, 레이더, 카메라, GNSS/INS 등 각 센서별로 동기화 되어진 데이터를 취득할 수 있다. 취득 차량에 장착되어진 카메라, 라이다, 레이더, GNSS/INS 센서 데이터들은 하나의 동기화 신호의 트리거링(Triggering)을 통해 데이터를 저장하게 된다.

수집차량에는 360도 주행공간 데이터 수집이 가능한 128ch(채널) 3D 라이다(HESAI Pandar128 제품)가 설치되어 있다. 이 라이다 장비의 설치높이는 약 2m, 측정가능거리는 약 200m까지이며 초당 약 340만개 이상의 포인트 취득이 가능한 고성능 센서이다. 그 외에도 카메라(Pointgrey사), GNSS/INS (Applanix LV 220) 등이 설치되어 있어 교통상황 및 위치정보 등을 확인할 수 있다. 라이다 센서 세부 제원은 다음의 [표 23]와 같다.

[표 24] 라이다 장비 제원 (출처 : HESAI 홈페이지)

구 분	내 용
Product	• HESAI Pandar 128
Data Points Generated	• 3,456,000 points/second (single return) • 6,912,000 points/second (dual return)
Range Capability	• 200 m@10% • *100 klux, PD>70%, FAR<1e-5
Accuracy	• ±2 cm (1 to 200 m)
Ingress Protection	• IP6K9K & IP6K7
Resolution	• 0.1° Finest horizontal resolution (10 Hz) • 0.125° Finest vertical resolution
Operating Temperature	• -40 ~ 85℃
Functional Safety - compliant to ISO 26262	• Comprehensive functional reporting for all lasers
Cyber Security - compliant to ISO 21434	• Encryption to safeguard against data breaches

본 논문에서의 라이다 데이터 분석범위는 해상도와 정확성 등을 고려하여 관심구역을 전후방 ±60m(120m 범위) 거리로 한정하고 해당범위 내에서 입체적 주행공간분석을 수행하였다.

<그림 28> 라이다 수집차량(KETI) 및 라이다 센서

2. 데이터 수집장비 점검절차

가. 하드웨어 점검 및 설정

본 차량에는 동기화를 위한 장치와 도로 분석을 위한 고정밀 센서가 장착되어 있다. 데이터 취득 전에는 <그림 29>과 같이 수집차량에 대해 통신오류 및 라이다 센서에서 취득되는 데이터의 노이즈 요소를 제거하기 위해 간단한 외관점검을 먼저 수행된다. 외관 점검시에는 라이다센서에 먼지나 이물질이 있는지를 먼저 체크한다. 또한 모든 센서들이 동기화를 위해 통합 연결되어 있기 때문에 한 센서에서 통신오류가 나면 센서에서 불균형한 데이터를 취득하게 되므로, 모든 센서의 체결상태를 확인하는 과정이 중요하다.

데이터 수집 차량에는 데이터 로깅을 위한 PC와 각종 센서들이 장착되어 있다. 우선 데이터 취득 센서들을 활성화 시키고 소프트웨어를 실행하기 위해서는 전원 공급을 실시한다. 전원공급 설정은 데이터 취득 장비와 소프트웨어를 실행하기 전 변환기(Inverter, 직류→교류변환)를 작동하는 과정이다. 먼저 차량 시동을 켠 후 차량 내부의 Inverter의 전원 버튼과 라이다 전원 버튼을 눌러 전원공급을 시킨다. 그 다음 차량 트렁크 쪽의 멀티탭의 메인 전원을 켠 다음 라이다, 카메라, 취득 PC의 전원 공급을 수행하고 기본적인 소프트웨어(S/W) 작동상태를 확인한다.

<그림 29> 데이터 수집차량 점검 및 설정

나. 소프트웨어 점검 및 설정

데이터를 취득하기 위한 소프트웨어 설정은 센서(sensor) 설정과 기준점(calibration)보정 순서로 진행된다. GPS 프로그램을 작동하여 동기화 설정을 마친 후 동기화된 카메라, 라이다, 레이다의 센서 데이터를 취득하기 위해 ROS[20](Robot Operating System)기반 프로그램을 실행한다. 센서 설정(sensor setting)을 위한 세부절차는 다음 <그림 30>과 같다.

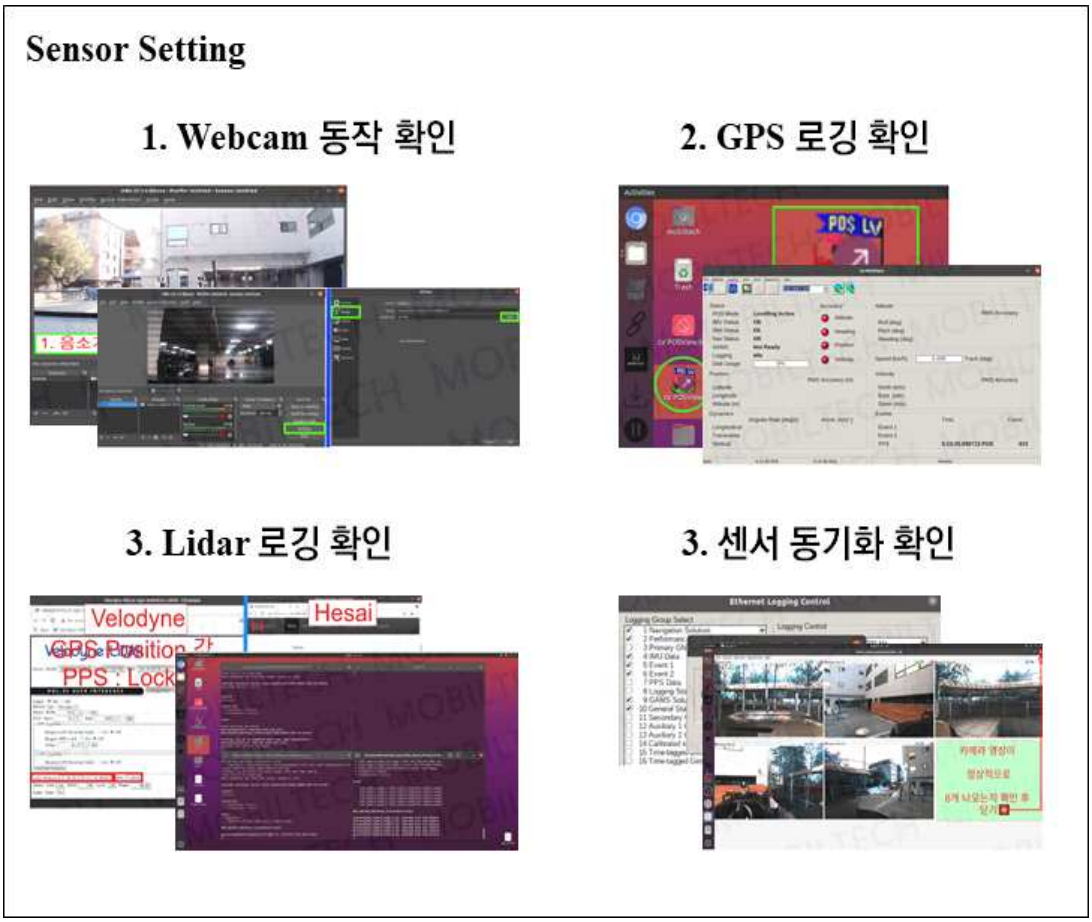

<그림 30> 데이터 수집을 위한 센서 설정 세부절차

20) 로봇을 위한 공개소스 운영체제, 유닉스 기반 플랫폼에서 작동 (출처 : 컴퓨터인터넷IT용어대사전, 전산용어사전편찬위원회 엮음)

본 차량의 데이터는 카메라, 라이다, 레이다, GPS센서가 동기화된 상태로 데이터가 저장된다. 먼저 차량에 설치된 카메라의 동작을 확인한다. 다음으로 GPS 로깅상태를 확인하는 전용프로그램(LV PosView)을 통해 GPS의 로깅 상태를 확인한다. 라이다는 데이터 로깅시 저장되는 로컬 파일과 HESAI사에서 제공하는 웹 뷰를 사용하여 로깅 상태를 확인한다. 모든 로깅 상태가 확인되었을 경우 최종 센서 동기화를 확인한 후 센서 설정을 마친다.

다음은 기준점 보정(calibration setting) 과정이다. 본 차량에서 취득되는 데이터는 시작(triggering) 신호에 맞춰 데이터의 동기화(sync)를 맞추는 구조를 사용한다. 초기에 지체(delay)가 발생한 경우 데이터의 싱크가 맞지 않는 문제가 존재한다. 따라서 카메라 기준점 보정을 통해 시간축을 다시 맞추는 과정을 수행한다. 다음 <그림 31>의 (a)는 기준점이 어긋난 데이터이며, (b)는 (a)의 동기화 상태에서 일정한 옵셋(offset)을 줘서 데이터의 기준점을 맞추는 과정이다. 카메라 영상을 사용하지 않더라도 도로분석을 위한 라이다와 GPS의 동기화를 맞추는 과정이 필요하기 때문에 해당 기준점을 맞춤으로써 데이터수집을 위한 센서 동기화가 활성화된다.

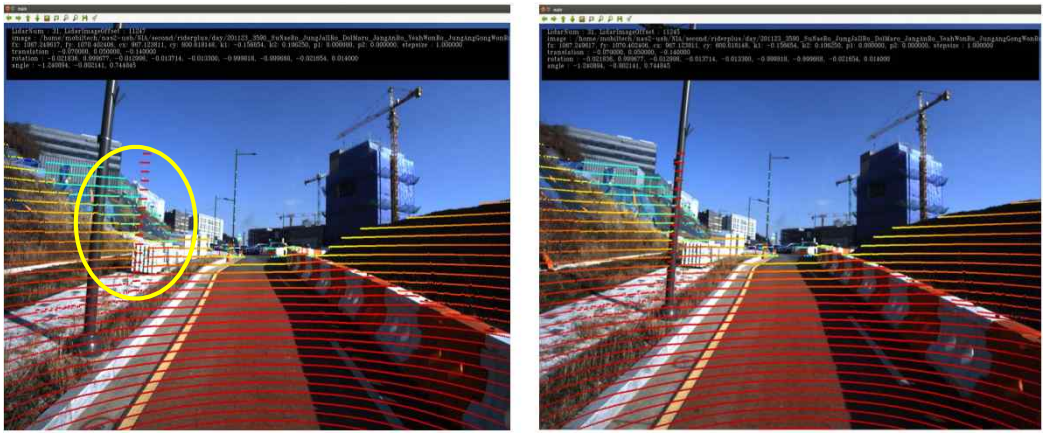

(a) (b)

<그림 31> 카메라와 라이다 기준점(calibration) 보정

다. 현장주행을 통한 데이터 취득

다양한 교통환경에서 안정적이고 고품질의 데이터 수집을 위해 운행전 주행지역을 사전에 선별한 후 데이터를 취득하였다. 앞서 언급하였듯이 현장주행을 통해 취득하는 데이터는 라이다, 카메라, GNSS/INS 등 다양하며 동시에 취득이 가능하다. 하지만 본 논문에서는 이들 중 관심 센서인 라이다를 중심으로 수집하였다. 라이다의 원시데이터 파일 형태와 명세서는 다음 [표 25] 및 [표 26]와 같다.

[표 25] 원시파일 수집형태

구 분	수집형태	설 명
LiDAR	3D 라이다 점군 데이터 (PCD : Point Cloud Data)	차량 지붕에 장착되어진 128ch의 회전형 라이다를 활용하여 취득 차량 주변의 점군 데이터를 수집하며, 센서는 타 센서와 동기화되어 동작

[표 26] 원시데이터 파일 명세서

No.	테이블명 (센서)	컬럼명	내용	값(예시)	(값 설명)
1	LiDAR	FILE_NAME	저장된 라이다 이름	001.bin	라이다 파일 이름 (bin)
2		TIME_STAMP	기록 시간	1558099596	[ms]
3		LIDAR_INDEX	데이터 순번	0	데이터 순번
4		LIDAR_ID	라이다 아이디	0	센서 식별 번호
5		LENGTH	데이터 길이	26679	한번 회전할 때 들어온 데이터 길이
6		X	포인트 클라우드 X	-2.665898	포인트 클라우드의 X 정보 [m]
7		Y	포인트 클라우드 Y	2.119031	포인트 클라우드의 Y 정보 [m]
8		Z	포인트 클라우드 Z	0.059443	포인트 클라우드의 Z 정보 [m]
9		INTENSITY	라이다 반사율	25	빛 반사율 정보

제2절 라이다 데이터를 활용한 교통정보 처리

본 절에서는 Ego 차량이 라이다 통해 주행하는 공간의 주변차량을 탐지하는 과정과 그 차량들의 위치와 크기 등을 파악하고 추적하는 과정 등으로 나누어 세부적으로 설명한다.

1. 객체(차량)탐지를 통한 교통데이터 추출

수집된 라이다 센서 데이터를 기반으로 교통데이터 추출 방법 및 절차 흐름도는 다음 <그림 32>과 같다. Point Cloud Data(점군자료) 중 관심영역의 데이터를 추출한 후 차량검지를 위한 객체탐지(Object Detection)가 선행되고 이동하는 공간에 대한 조감도(BEV) 형태의 2차원 평면 맵을 구성하는 과정을 진행하였다. 또한 동시에 PCD로부터 차선을 검출하는 알고리즘을 수행한다. 결국 최종적으로 검지 차량과 조감도 형태의 도로맵, 차선정보 등 3가지를 융합하여 교통데이터를 생성하였다.

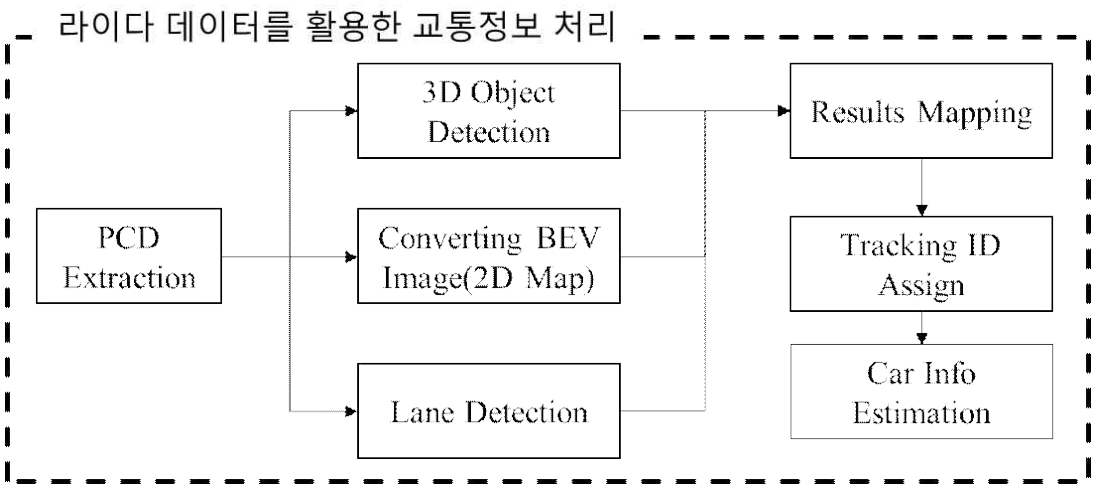

<그림 32> 교통데이터 생성을 위한 전처리 방법 흐름도

가. PCD 추출(Extraction)

초기에 수집된 PCD(점군) 원본 데이터 전부를 시각화하면 모든 공간 이미지 데이터를 볼 수 있겠지만, 실제 수집되는 초당 약 250만개[21](128 채널기준)가 넘는 데이터를 처리하여 모두 표현하기 위해서는 고성능 컴퓨터 연산자원을 필요로 하게 된다. 하지만 과다한 데이터 처리는 시간의 비효율이 발생하기 때문에 이러한 문제를 해소하기 위해 불필요한 정보나 위치의 데이터는 줄이고, 필요 이상의 데이터는 압축하는 가공과정을 필요로 한다. 이번 과정은 수집된 라이다 데이터 중 검지영역(ROI) 설정 등을 통해 필요한 데이터만을 추출하기 위한 1차 가공하는 과정이다.

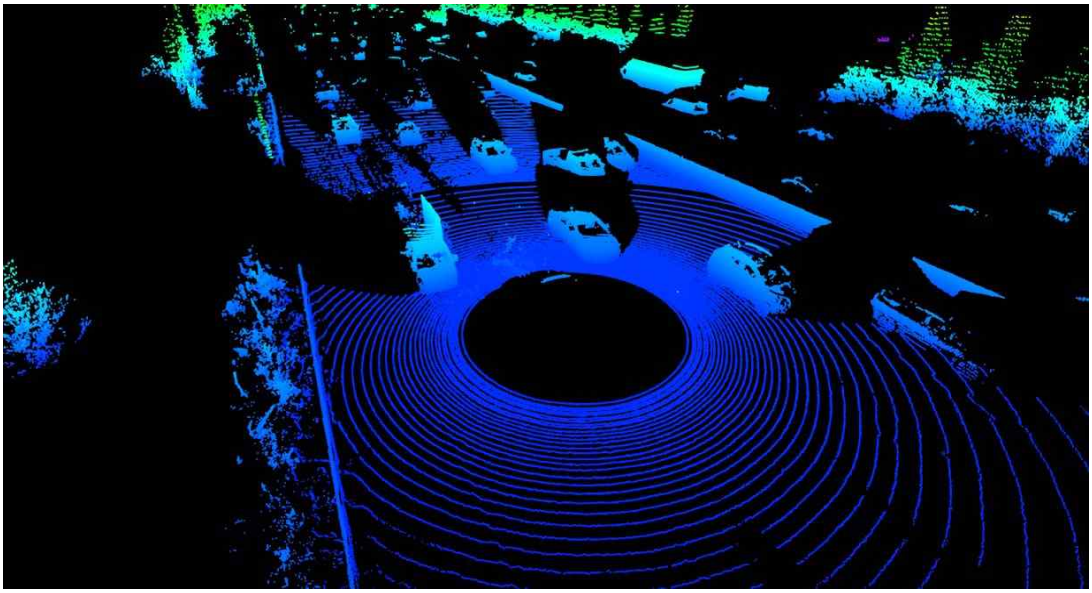

<그림 33> PCD자료의 반사율(intensity)표현 시각화

세부적으로 살펴보면 라이다 PCD가 센서(원점)로부터 방사되는 형태이기 때문에 반지름 성분과 각도로 데이터를 정리한다. 또한 앞서 언급하였듯이 라이다 센서는 이론적으로 200m 이상 감지할 수 있지만 방사되

21) 라이다 데이터 수집용량 70메가(MB)/초, 한시간 주행한 경우 약 252기가(GB) 데이터 처리필요

는 빛의 특성으로 무의미한 값들이 많이 분포하게 됨으로 일정범위(본 연구에서는 임계값 60m 설정)의 데이터 외에는 제거하는 등 관심 검지 영역(ROI : Region of Interest)을 설정한다. 다음 <그림 33>은 추출데이터에 반사율(강도)을 색깔로 표현하여 시각화한 결과화면이다. PCD는 거리에 따라 시각화도 가능한데 본 논문에서는 차량간의 거리를 기반으로 속도를 분석하기 위해 거리값에 따른 시각화 방법을 사용하였다. <그림 34>는 거리에 따른 PCD의 시각화 이미지를 보여준다.

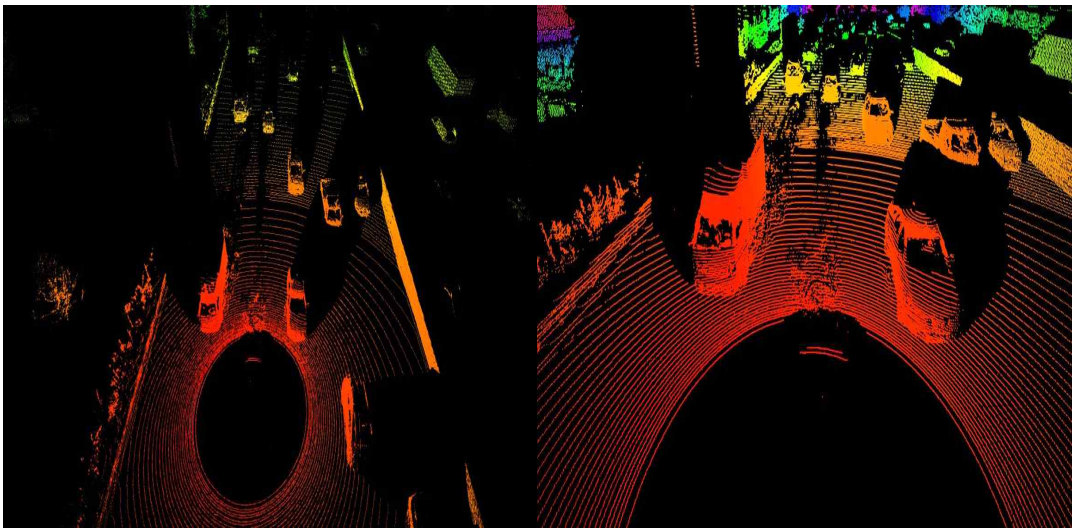

<그림 34> PCD자료의 거리에 따른 시각화

나. 객체탐지(3D Object Detection)

다음 단계는 추출된 PCD 자료를 기반으로 앞서 선정한 Voxel-RCNN 객체탐지 모델을 사용하여 고속도로를 주행하는 차량을 탐지하였다.

이러한 인공지능 모델을 학습시키기 위하여 학습용 데이터[22]는 <그림

22) 1. 학습용 데이터 2,880 set(1set=원본+라벨링) 사용, 인공지능학습에는 1회/약 5분이상 소요, 8000회이상 학습하여 사용함. 예상소요시간 = 5×8,000 = 40,000분(28일)

2. 고속도로(경부선, 영동선 등) 및 다양한 도로환경 구간에서 수집한 데이터를 학습에 사용

3. 대략 3차원 라벨링 시간 10분/장, 2,880장×10분 = 28,800분(20일) 단, 난이도에 따라 편차 발생

35>의 과정으로 진행하였다. 기존에 한국전자기술연구원에서 수집한 고속도로 학습용 주행데이터 2,880 set을 이용하였고 총 8,000회 정도의 반복학습을 통해 얻어진 가중치(weights)를 도출하여 사용하였다.

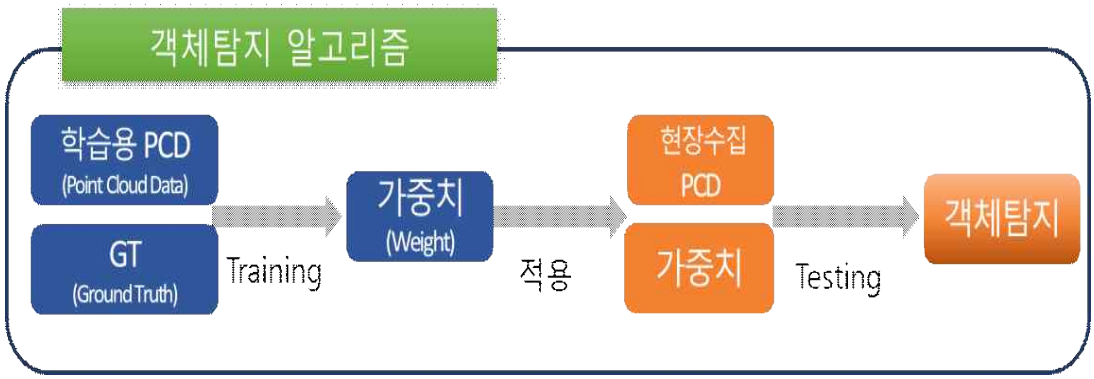

<그림 35> 인공지능학습을 통한 객체탐지 알고리즘 개념도

이러한 학습을 위해 사용한 물리적 환경은 엔비디아 Titan RTX GPU(Graphic Processing Unit)[23] 2대, RAM 128GB, CPU E5-1650 v4을 활용하였다. 학습 모델의 가중치는 모델의 손실함수(loss function)에 따른 계산을 통해 축적된다. 손실함수는 네트워크(모델)에 의한 결과값(output)과 GT(Ground Truth)와 비교하여 계산한 손실값(loss)을 손실함수에 적용하여 모델의 결과값이 GT에 가까워지도록 가중치(weights)를 업데이트 하는 과정으로 진행하였다.

반복 학습동안의 손실값(loss)을 그래프로 표현한 것을 학습곡선(learning curve)이라 한다. 본 논문의 학습모델의 learning curve는 <그림 36>과 같다. 본 논문에 사용된 Voxel-RCNN모델의 loss 값은 0.5 정도로 0에 가깝게 수렴한 것을 확인할 수 있다.

그 후 Voxel-RCNN 모델과 가중치를 이용하여 객체인식 과정을 통해 최종적으로 <그림 37>과 같이 차량의 위치정보 등을 산출하였다.

---

23) GPU : 중앙처리장치(CPU)의 그래픽 처리를 도와 컴퓨터 영상정보를 처리하거나 화면 출력을 담당하는 연산처리장치 (출처 : 두산백과사전, www.doopedia.co.kr)

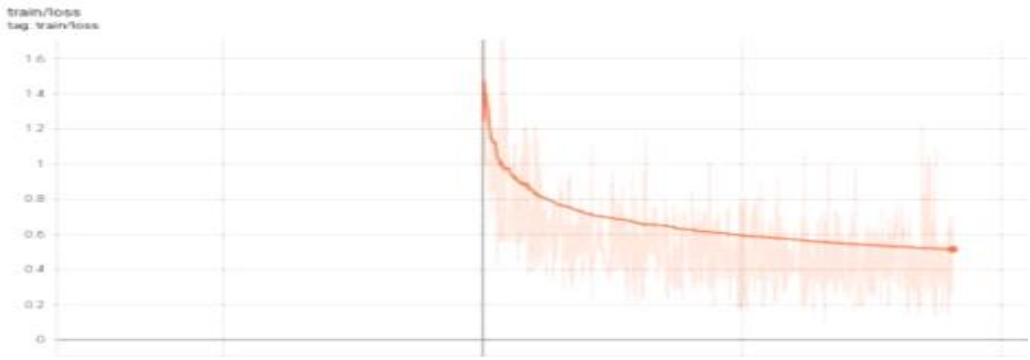

<그림 36> Voxel-RCNN 학습곡선(Learning Curve) 예시

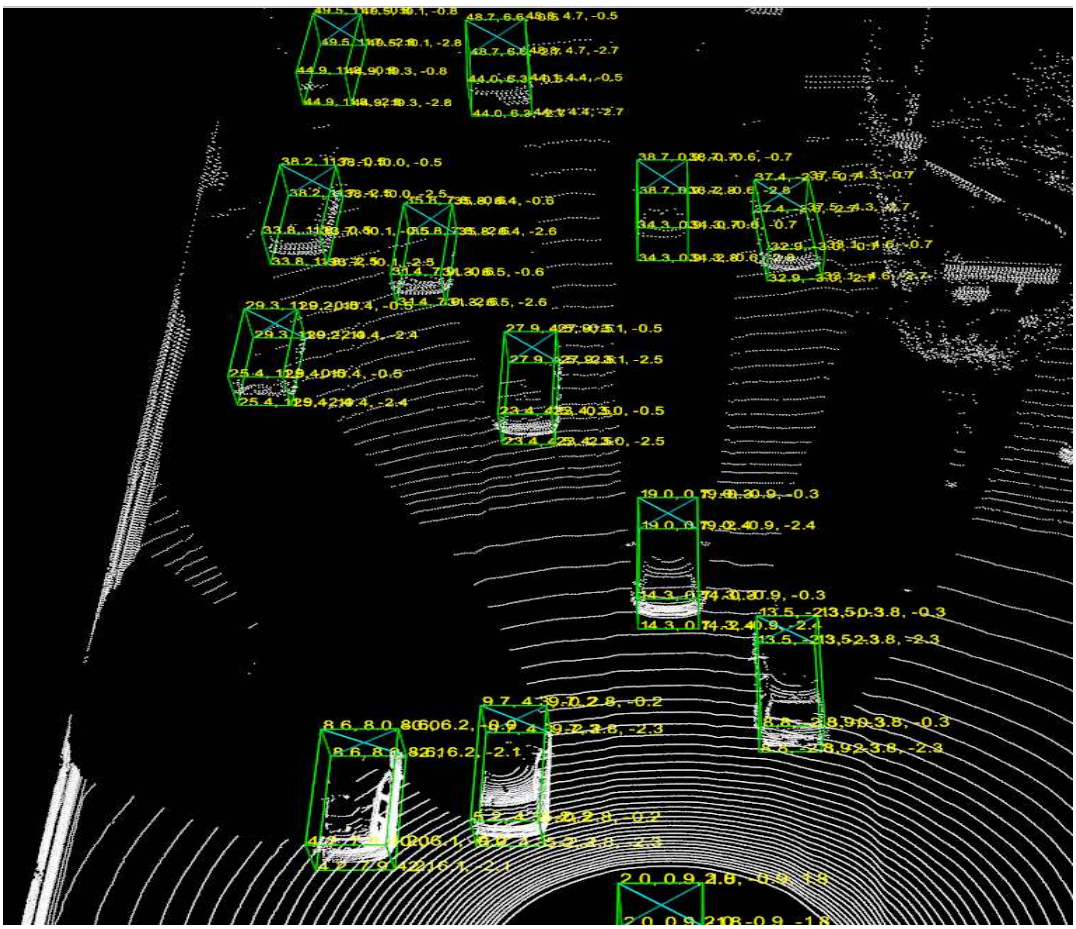

<그림 37> 고속도로를 주행하는 차량 시각화

이 단계에서 주체차량 주변을 이동하는 차량 등에 대한 차량 높이와 차

량길이 자료 등을 동시에 취득할 수 있으며, 이 자료는 기존 검지기로는 수집하기 어려운 자료로써 향후 밀도나 안전성 평가 등에 사용하는 기초 자료로 활용한다.

다. 2차원 평면 맵 형태로 변환

차량의 검출을 연속적이고 입체적으로 수행하기 위해 3차원의 라이다 데이터가 사용된다. 하지만 차량의 검출 이후 과정에서는 3차원의 특성인 PCD의 z값을 사용하지 않기 때문에 계산과정을 효율화하기 위해 2차원의 조감도(BEV : Bird Eye View) 맵 형태로 변환한다. 이를 위해서는 <그림 38>과 같이 3차원의 월드(xyz)좌표계[24]를 우리가 사용하는 일상의 2차원 xy좌표로 변환해 사용하였다.

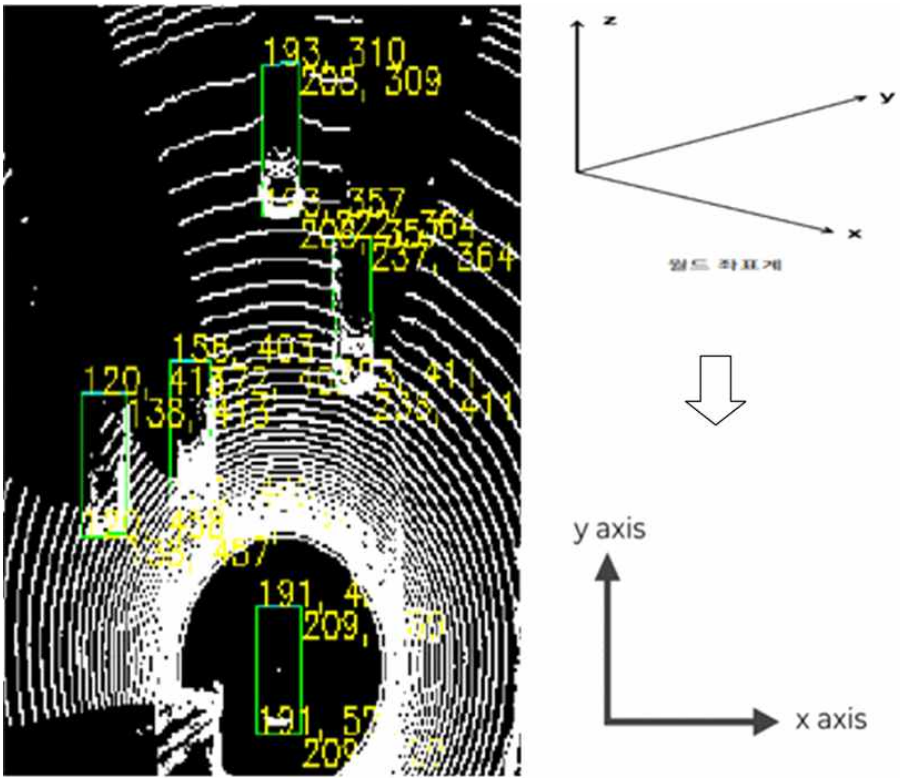

<그림 38> 2차원 변환결과 시각화 및 좌표변환 예시

24) 월드좌표계 : 컴퓨터 그래픽에서 응용 프로그램이 이용되는 독립적인 좌표계 (출처 : 컴퓨터인터넷IT용어대사전, 전산용어사전편찬위원회 엮음)

이렇게 변경하는 주요한 이유는 대용량의 3차원 빅데이터 자료를 실시간 연산 등에 활용하기 위해서다. 즉, 2차원 데이터로 변환하면 연산량 감소로 인해 프로세스의 효율성이 증대되고, 인지가능한 2D 맵 형태로 시각화가 가능함으로 연산과정의 진행 적정성 등 수행과정을 직관적으로 보여줌으로써 데이터 사용자가 쉽게 판단할 수 있도록 도와주게 된다.

라. 차선인식(Lane Detection)

고속도로를 이동하는 차량이 올바른 경로로 이동하는지 또는 차선을 변경하는지를 판단하기 위해서는 우선적으로 차선을 인식하는 과정이 필요하다. 차선검출은 자율주행 기술의 핵심요소 중 하나이기도 하며, 차로별 도로상황 분석을 통해 교통정보로 활용하기 위해서는 필수적으로 선행되어야 할 과정이다.

이번 논문에 사용한 고속도로 차선검출 방법은 라이다 센서를 활용하여 밀도기반 클러스터링을 통해 차선을 검지하는 알고리즘을 이용하여 적용하였다[82]. 이 방법은 기존 RANSAC[25]기반 알고리즘과 비교하여 연산량이 감소하기 때문에 더욱 빠른 속도와 국내 환경에 최적화된 차선을 검지할 수 있었다. 즉, 라이다 PCD로부터 표면의 반사정도를 비교하는 방법이며, 일반 포장부위와 차선도색 부위의 반사율(밀도)차이를 비교하여 차선을 검지하는 과정이며, 다음의 <그림 39>와 같은 순서를 통해 진행된다.

25) RANdom SAmple Consensus의 약자, 데이터 셋에서 노이즈를 제거하고 수학적 모델을 예측하는 알고리즘 (출처 : 박동진, 2014)

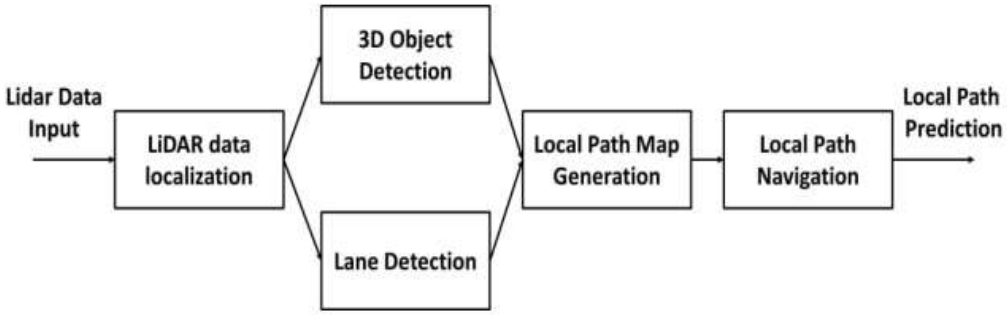

<그림 39> 밀도기반 차선검지 방식 흐름도 (출처 : 최승진 2022)

해당 과정으로 수행한 차선인식 검출결과는 다음의 <그림 40>와 같이 시각화하여 차선위치를 표현할 수 있었다.

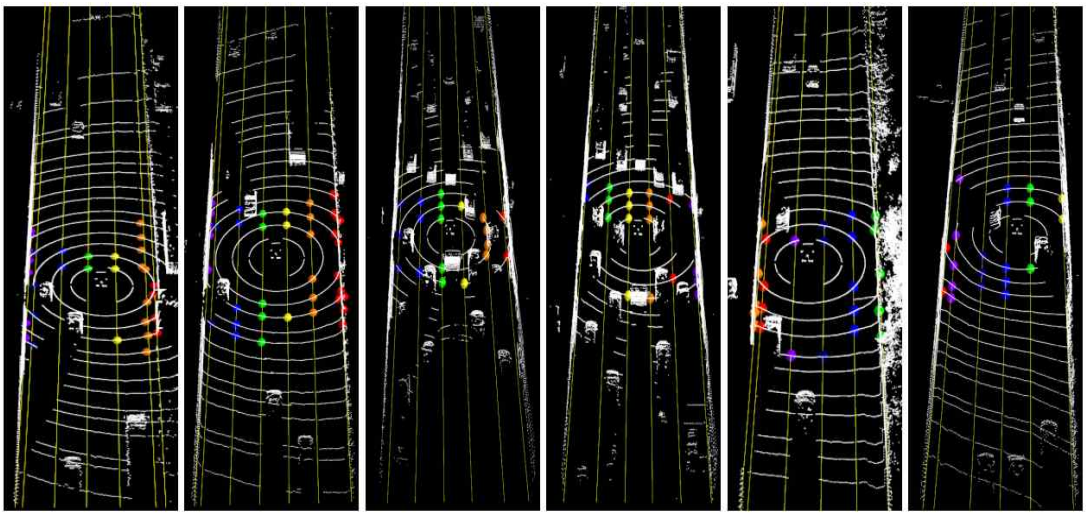

<그림 40> 차선인식 결과(Lane Detection Results)

마. 객체(차량)탐지 결과(Detection Result)

앞서 차량들에 대한 객체탐지와 시각화를 위해 2차원으로 변환 그리고 차선인식 등을 종합하여 최종적으로 검출된 각 차량들의 데이터 값은 <그림 41>과 같이 파일형태(CSV 등)로 결과를 산출하였고, 교통데이터

로 활용 가능하도록 만들었다.

이러한 결과 값은 향후 개별차량과 주변 차량의 속도, 차간간격 등 교통정보로 처리하기 위한 기초 데이터가 되는 것이다.

id	cx	cy	cz	dx	dy	dz	yaw
1	0	0	0	2	0.9	1.8	0
2	16.62983	-0.09285	-1.35406	2.369614	0.766537	1.077505	6.286695
3	-16.4887	-0.20546	-0.7871	2.385519	0.936872	1.103299	6.284615
4	7.435285	3.539789	-1.26629	2.261226	0.779071	1.030552	6.279392
5	-26.6822	3.377154	-0.70008	2.280218	0.794113	1.04179	6.318294
6	47.20548	10.98852	-1.80539	2.287853	0.78139	0.997191	6.248459
7	35.22774	-3.63328	-1.69715	2.231789	0.821528	1.018806	6.364261
8	27.33919	11.16627	-1.47665	1.909114	0.748996	0.94801	6.267471
9	-39.3758	6.848151	-0.47691	2.325869	0.869735	1.030617	6.229176
11	25.61919	3.773296	-1.47595	2.252908	0.720483	1.019433	6.285379
12	35.95421	10.91264	-1.50298	2.218387	0.846888	0.997094	6.253967
13	36.47383	0.137574	-1.71532	2.210095	0.763468	1.060426	6.288435
14	-37.4796	-3.59601	-0.50529	2.387863	0.845365	1.032064	6.284494
16	11.17838	-3.05081	-1.27895	2.328552	0.751032	0.985077	6.287667
17	-21.9081	-3.33727	-0.84473	2.334427	0.797494	0.963807	6.281527
18	33.55877	7.149803	-1.60404	2.216507	0.72063	0.976618	6.261284
19	46.38813	5.506181	-1.61749	2.332414	0.9752	1.085789	6.346209
21	6.420747	7.051452	-1.04802	2.220263	0.900389	1.03095	6.287024

<그림 41> 차량들의 객체검출 결과 화면

<그림 41>의 결과값에서 ID 1번차량은 항상 Ego 차량(기준점)을 의미하며, 차량좌표 값의 개념은 <그림 42>과 같이 cx, cy, cz는 Ego 차량과 중심축과의 상대적 거리를 나타내고 dx, dy, dz는 각 차량별 차량중심축에서의 크기(길이) 그리고 yaw값은 방향(각도)을 의미한다. 예를 들어 ID 2번차량 중심점은 기준점으로부터 (x, y, z : 16.62, -0.09, -1.35) 위치하고 있다는 의미이고, 차량박스의 크기는 x, y, z 방향으로 (2.36, 0.76, 1.07)×2 = (4.72, 1.52, 2.14)이라는 것을 알 수 있다. 즉, 길이 4.72m, 폭 1.52m, 높이 2.14m인 차량을 의미[26]한다.

26) 차량등록대수(20년 국토부) 기준 가장 많이 등록된 중형 승용차는 쏘나타와 중형 SUV는 싼타페로, 쏘나타 제원은 길이 4.90m, 폭 1.86m, 높이 1.45m, 싼타페 제원은 길이 4.80m, 폭 1.9m, 높이 1.71m

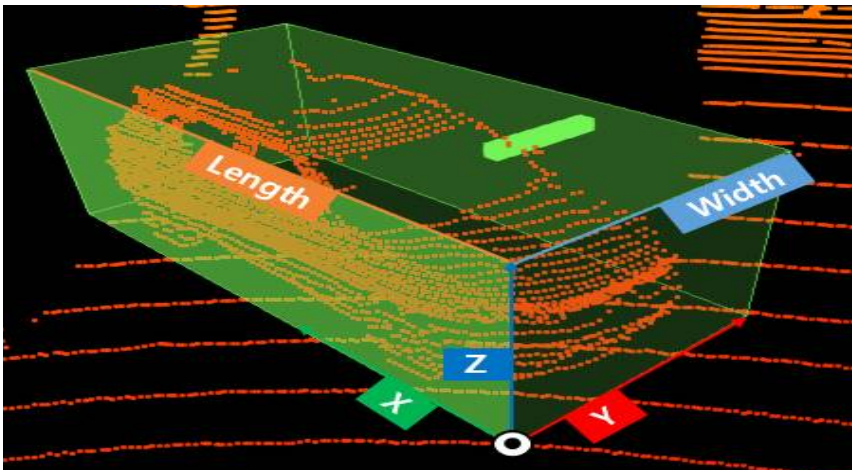

<그림 42> 최종 결과값(차량좌표) 개념도

다음 <그림 43>는 차량의 결과값을 한프레임(0.1초)내 검지가능한 공간에 속한 21대 차량에 대해 에고(Ego)차량을 기준점으로 주변 차량들의 위치와 크기값 등의 차량 데이터를 시각화하여 보여주고 있다.

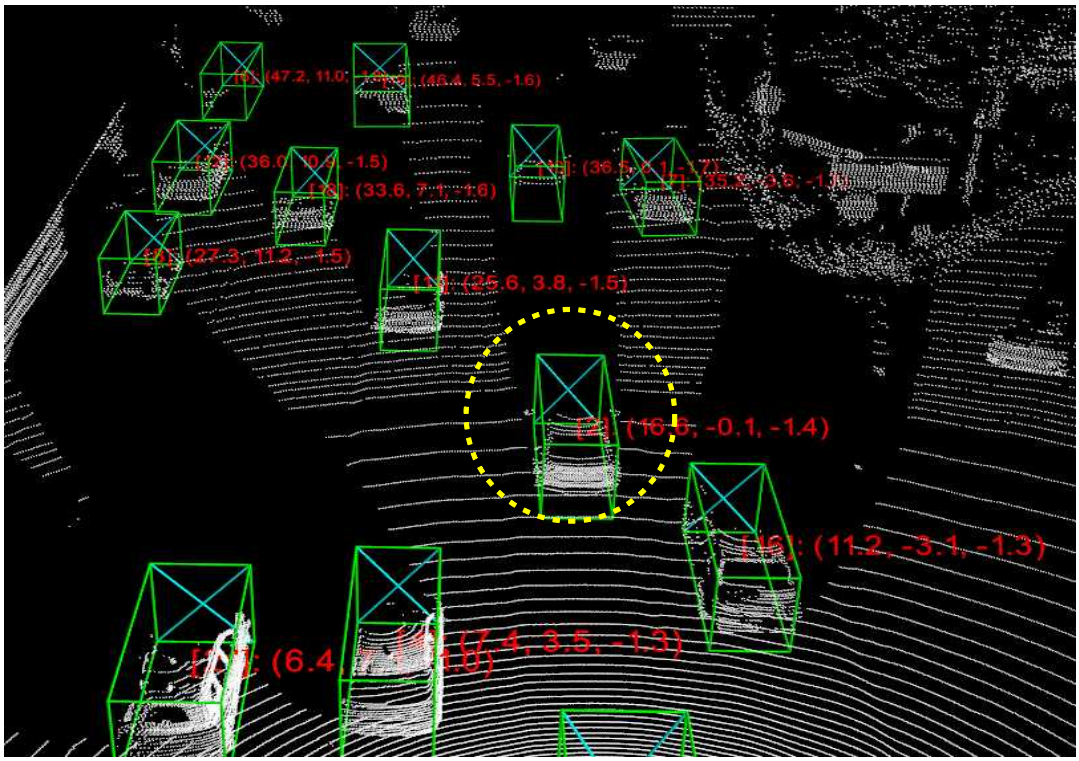

<그림 43> 차량들의 객체검출 결과 시각화

2. 이동객체 추적 및 속도산출 방법

앞서 생성한 차량정보를 바탕으로 차량간의 상관관계를 파악하기 위한 추적(tracking) ID를 할당 및 이를 통한 차량의 속도를 구하였다.

가. 이동차량 추적 ID 부여

본 논문에서는 주행중인 차량의 정보를 추출하기 위하여 차량의 고유 ID를 부여하였다. 차량을 식별하기 위한 고유 ID는 추적(tracking) ID로 정의하는데 Tracking ID를 부여하기 위해서는 차량의 추적이 필요하다. 일반적으로 추적방법은 포인트추적, 커널(kernel)추적, 실루엣추적 등으로 구분한다[103].

이번 논문에서는 컴퓨터 비전분야에서 객체추적 및 평가지표로 가장 대중적이고 안정적으로 사용되고 있는 포인트 추적 중 객체탐지 지표(IoU : Intersection over Union)방식을 사용하여 차량추적을 수행하였다. 이 방식은 전후 프레임(시간차)에서 <그림 44>와 같이 인식된 객체의 겹치는 정도(기준값설정 필요)에 따라 동일차량으로 인식할지 여부를 결정하는 방법이다[104].

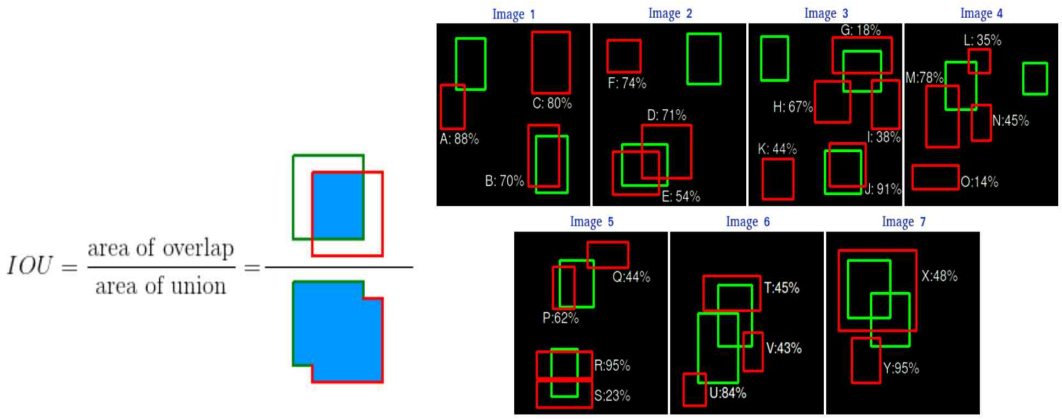

<그림 44> 객체탐지 지표(IoU) 개념(출처 : Rafael Padilla, 2020)

IoU 기준값은 추적 환경과 추적 객체에 따라 값을 달리한다. IoU 기준값을 산출하기 위한 본 논문에서의 식은 다음 (식 5)dhk 같다.

$$\frac{Car_L(t)}{\frac{\Delta v}{3.6}\times t + Car_L(t)} \qquad (식\ 5)$$

여기서, Car_L은 차량의 길이, Δv는 속도 편차, t는 단위시간

국내 고속도로의 최저속도는 50km/h, 최고 속도는 120km/h이다. 따라서 고속도로에서 발생하는 속도차이(Δv)는 최대 70km/h이다. 관련연구에 따르면 4차로 고속도로의 경우 운행차로와 추월차로의 속도차이는 누적 90%기준으로 30km/h 이하이다(Wakasugi 2005)[93]. 하지만 본 논문에서는 제한속도 최대차이(120km/h - 50km/h)인 70km/h를 사용하여 Δv값을 정의했으며, Car_L값은 승용차 평균길이 값인 4.4~4.6m를 사용하여 정의하였다. 정의된 값을 통해 계산한 예시는 [표 27]과 같다.

[표 27] IoU 산출 예시

구 분	내 용
조 건	$Car_L = 4.5(m), \Delta v = 70(km/h), t = 0.1(s)$
계산결과	$\frac{4.5(m)}{\frac{70(km/h)}{3.6}\times 0.1(s) + 4.5(m)} = 0.698$

차량길이가 4.5m인 경우 (식 5) 계산을 통해 나온 값은 0.698이다. 차량길이(4.4~4.6)에 따른 결과값 범위는 0.69~0.70이기 때문에 본 논문에서는 IoU 기준 임계값을 최대치인 0.7로 정의하여 실험을 수행하였다.

이동객체 추적방식은 [표 28]과 같이 연속하는 두 시간(t)간의 각 차량(object)마다의 픽셀면적을 IoU 기준값과 비교하여, 기준이상일 경우 동일 차량임을 확인하고 동일차량 ID(tracking ID)를 부여한다.

[표 28] 이동차량 동일여부 확인 및 추적 ID 부여과정

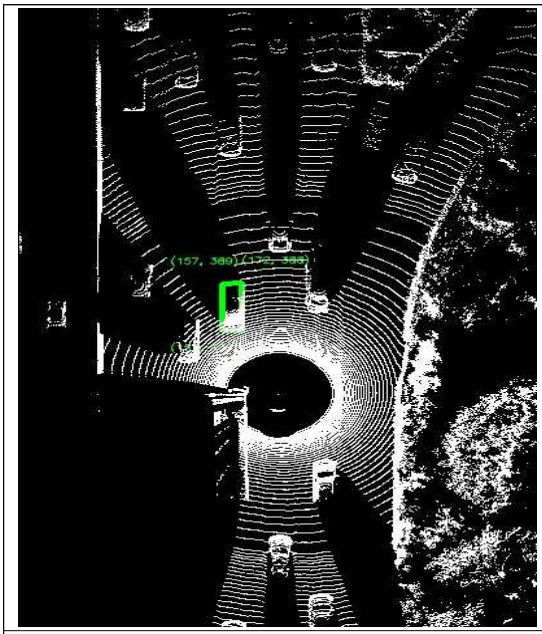	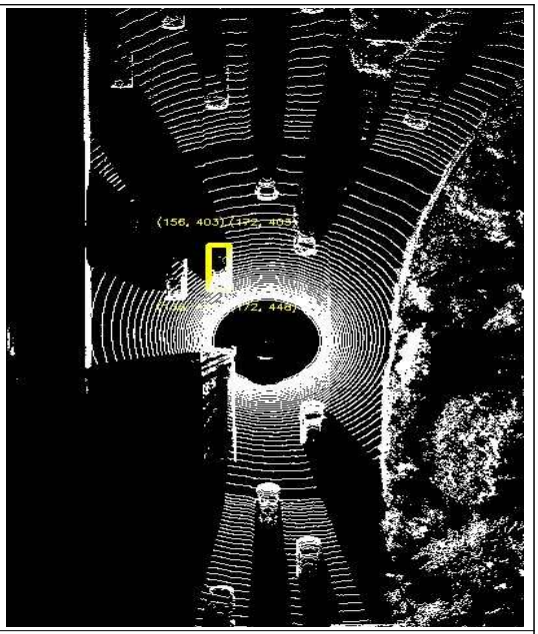
(a) $t-1(t=time)$	(b) $t(t=time)$
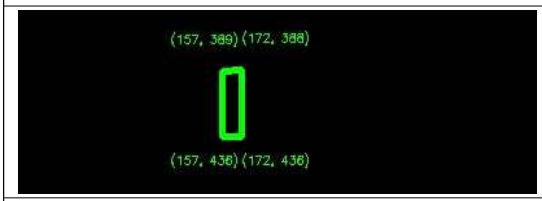	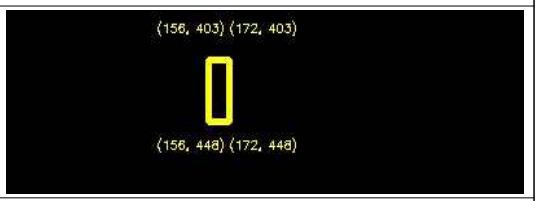
(c) $t-1(t=time)$ 위치값	(d) $t(t=time)$ 위치값
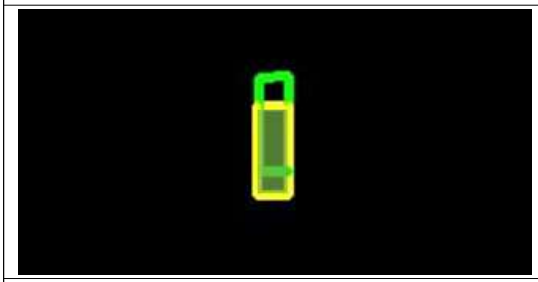	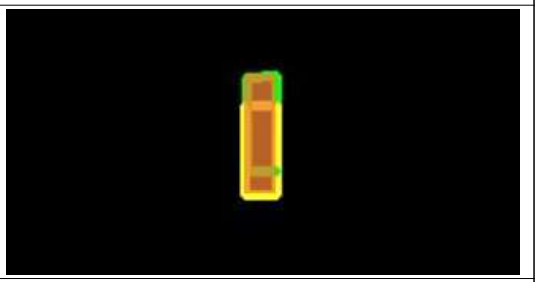
(e) $Car_L(t)$ = 720	(f) $\frac{\Delta v}{3.6}\times t+Car_L(t)$ = 944

$$\frac{Car_L(t)}{\frac{\Delta v}{3.6}\times t+Car_L(t)} = \frac{720}{944} = 0.7627$$

※ 판정기준(0.7)을 초과함으로 동일차량으로 간주하고 동일ID 사용

나. 이동주행차량 속도추정

앞서 이동차량 중 동일차량(ID)으로 판정된 차량들에 대해서 차량의 속도를 추정하게 된다. 현재 정확한 차량의 속도자료를 측정할 수 있는 것은 주체차량(Ego)이기 때문에 다음 <그림 45>과 같이 주체차량을 기준으로 주변차량 속도를 추정하는 방법을 사용하기 위해 다음 (식 6)을 적용하였다.

$$V_{other} = V_{Ego} + \frac{\Delta s}{\Delta t} \qquad \text{(식 6)}$$

여기서, Δv는 속도편차, Δs은 거리편차

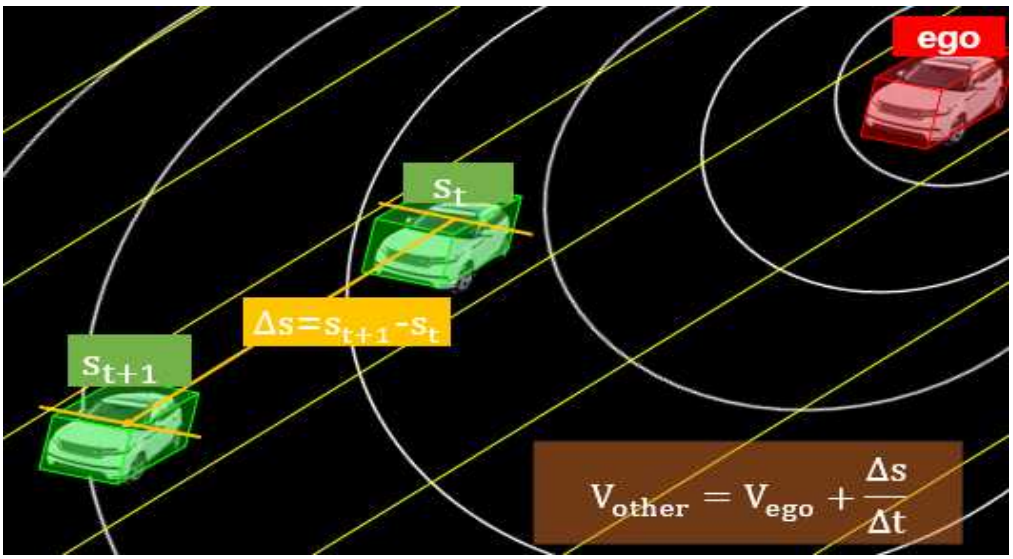

<그림 45> 이동차량속도 추정 개념도

다음의 [표 29]과 같이 주체(Ego)차량과 주변차량의 전후 시간(프레임) 상대적 이동거리을 통해 가속도를 계산하고 이를 속도로 환산한 후 주체차량과의 속도차이를 구하면 된다.

[표 29] 주변차량 속도 추정방법

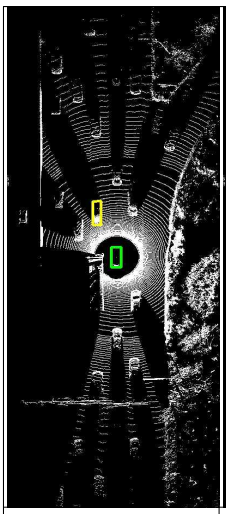	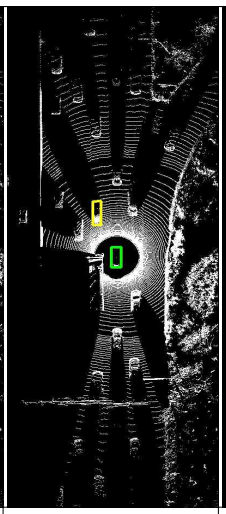			
$t-1(t=time)$	$t(t=time)$	상대 이동거리(s)	상대 가속도(a)	속도 계산(v)
계산과정) s = -2.1m/s, t = 1, ego_v = 25(km/h)일때 상대 가속도(a) = -2.1(s) * 3.6(h) = -7.6km/h 속도 계산(v) = ego_v+a = 17.4(km/h)				

속도추정 식을 사용하여 <그림 46>과 같이 실시간으로 개별차량의 속도 값을 산출하고 교통정보로 활용할 수가 있었다.

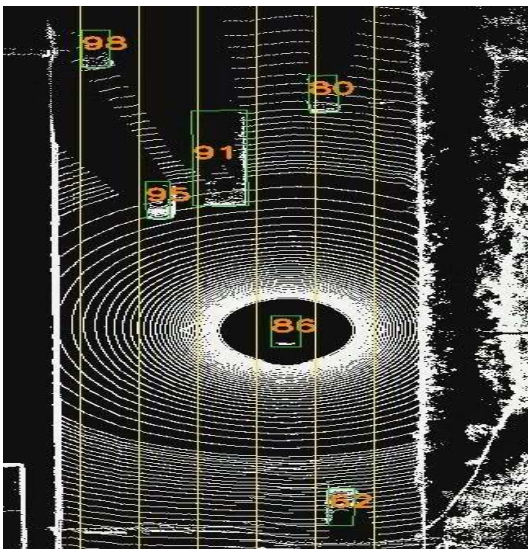

<그림 46> 주행공간의 개별속도 산출

이렇듯 라이다를 이용하면 이동구간에 대한 다양한 교통정보가 수집 가능하다. 이론적으로 수집가능한 모든 교통정보들은 다음 [표 30]과 같다. 하지만 이번 논문에서는 속도, 가속도, 밀도 등을 중심으로 교통정보를 수집하였다.

[표 30] 라이다로 수집 가능한 이상적 교통정보 현황

구 분	수집자료	수집내용	단 위
Ego (주체차량)	속도	단위시간(1초) 속도	km/h
	가감속	단위시간동안 순간 가감속	㎧
구간내 주변 주행 차량	속도	단위시간(1초) 속도	km/h
	가감속	단위시간동안 순간 가감속	㎧
	차간거리	앞차와 뒷차사이 거리	m
	차량크기	승용차, 화물차	m
	차량 높이정보	앞차 시거방해 여부	m
	차로변경 판단	주행각도 및 위치로 판단	횟수
	차로별 평균속도	검지구간내 차량 속도	km/h
	개별인지반응 시간	앞차 속도감속에 따른 뒷차 감속반응 시간(가정필요)	초
	조향각	곡선차로에 대한 개별차량 조향각	도(°)
검지영역 구간	구간내 차량수	차로별 차량수 구분필요(교통량)	대/초
	구간 밀도	검지가능한 공간의 차로별 밀도	대/km
	구간내 차로변경 차량	차로변경 판단이 된 차량수	대
위치정보	이동경로	GPS, 정밀지도상 위치	
	시설정보	차로수, IC, JC 등 시설물 정보	

제3절 교통상태 및 안전성 모니터링 방법

본 절에서는 앞장에서 수집하고 처리된 교통정보를 활용하여 밀도, 속도 등 교통상태 및 안전대리변수 등 안전성 평가결과의 지속적인 모니터링 방법에 대해 상세히 설명하고자 한다. 추가로 안전성 평가방법에 대한 개선방안을 제시하고자 한다.

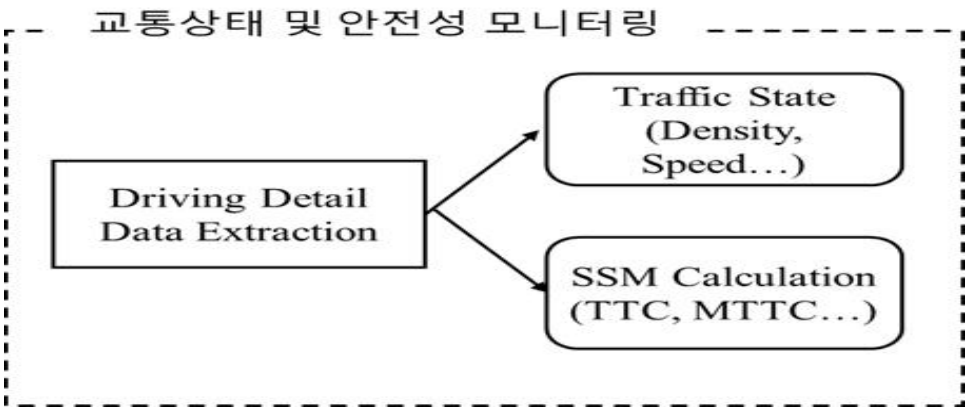

<그림 47> 교통상태 및 안전성 모니터링 흐름도

1. 교통상태(혼잡) 모니터링

수집된 개별차량들의 교통정보를 이용하여 교통상태 주요 효과척도인 밀도와 속도 등을 사용하여 연속적인 교통상태 모니터링을 수행하였다.

그 중 밀도는 교통혼잡을 표현하는 다양한 지표 중 가장 신뢰성이 높은 효과척도 중에 하나이다. 하지만 교통밀도는 항공사진 등에 의해 산출해야해서 관측이 어렵고 비용이 많이 들어서 속도와 교통량을 이용하여 추정하는 방식을 사용해왔다[9].

가. 점유율(밀도) 산출

운행구간에서 점유율(밀도)은 차량이 전체 도로에서 점유하고 있는 공간의 비율을 의미한다. 차로별로 산정하며 전체 한차로 면적 중에 차량

이 차지하고 있는 공간을 나누어서 산출한다. 기존에 밀도(대/km)보다 좀 더 세밀한 도로의 상황을 판단하는데 도움을 줄 수가 있으며 기존밀도 산정방식처럼 단위를 대/km로 산정하는 것도 가능하다.

예를 들어 <그림 48>의 빨간 점선 2차로 구간의 경우 전체 구간대비 차량이 차지하는 점유율 값은 약 29%(= 35m/120m)로 평가된다. 동일구간을 밀도로 계산하면 50대/km(6대/120m)로 표현할 수 있다. 라이다측정 결과를 이용한 점유율 계산을 하게 되면 차량의 길이를 알 수 있기 때문에 기존 차량대수를 사용하는 밀도에 비해서는 조금 더 정확하게 도로구간에서의 상황을 판단할 수 있게 된다. 하지만 본 논문에서는 <그림 49>과 같이 기존 밀도산출 기준과 방법을 사용하여 구간별 교통상태(혼잡)를 비교하였다.

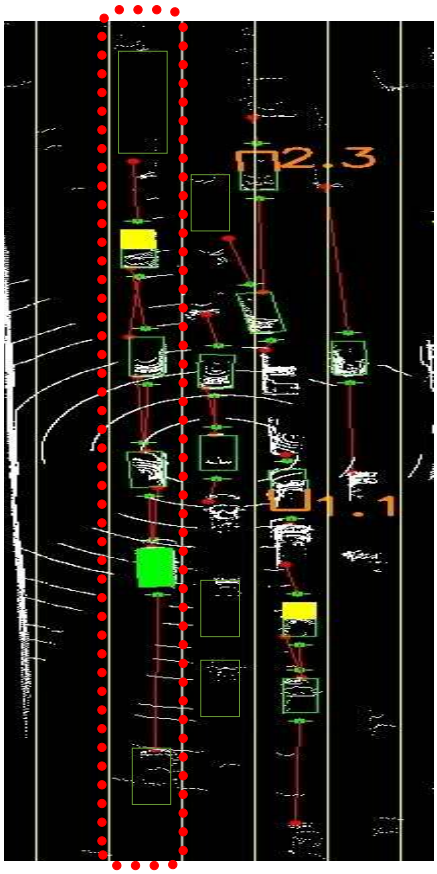

<그림 48> 점유율(밀도) 산출

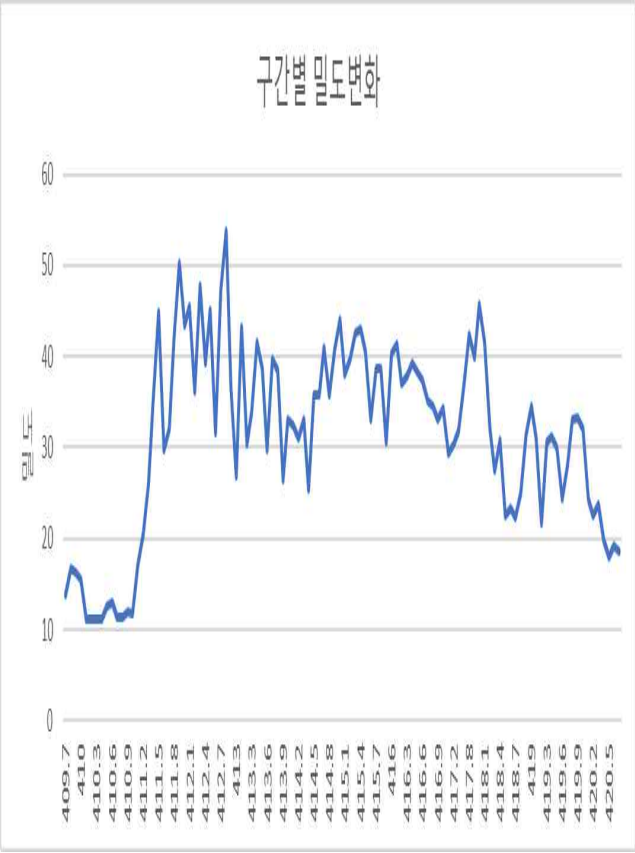

<그림 49> 밀도변화 그래프 예시

차량밀도 계산과정은 다음 <그림 50>의 영상 캡쳐화면을 예시로하여 각 차로별 그리고 전체 차로별로 설명하고자 한다.

각 차로별 계산은 라이다의 객체탐지 영역인 120m 단위에서의 객체 수를 밀도 단위인 대 / km 로 변환하는 과정이 우선 진행되고 그 다음으로 전체 차로별 밀도(검지공간 전체)를 계산하기 위해 앞서 산출한 각 차선밀도를 평균하여 최종적인 값을 도출한다.

○ 각 차로별 밀도계산

- 1차선 : 7대 / 120m = 58.33대 / 1km
- 2차선 : 8대 / 120m = 66.67대 / 1km
- 3차선 : 7대 / 120m = 58.33대 / 1km
- 4차선 : 7대 / 120m = 58.33대 / 1km
- 5차선 : 1대 / 120m = 8.33대 / 1km

○ 도로 전체 밀도계산

- (58.33 + 66.67 + 58.33 + 58.33 + 8.33)/5 = 50대 / 1km

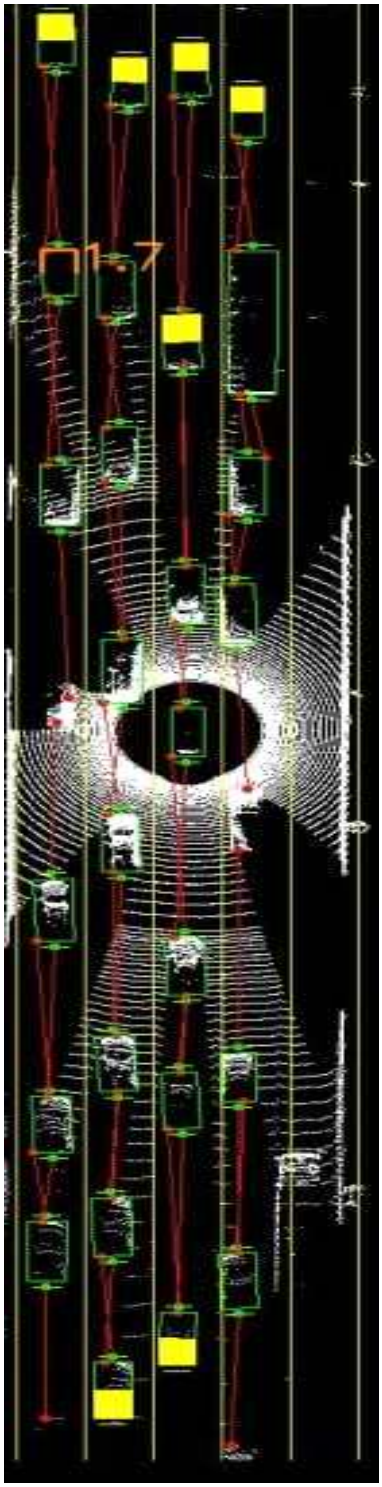

<그림 50> 밀도산출 예시

나. 주행구간 속도 산출

앞서 라이다센서를 이용하여 개별적으로 수집한 속도 결과 값은 필요에 따라 차로별, 전체 공간별 등 다음 <그림 51> 예시처럼 그래프 등으로 시각화하거나 데이터로 사용할 수 있다.

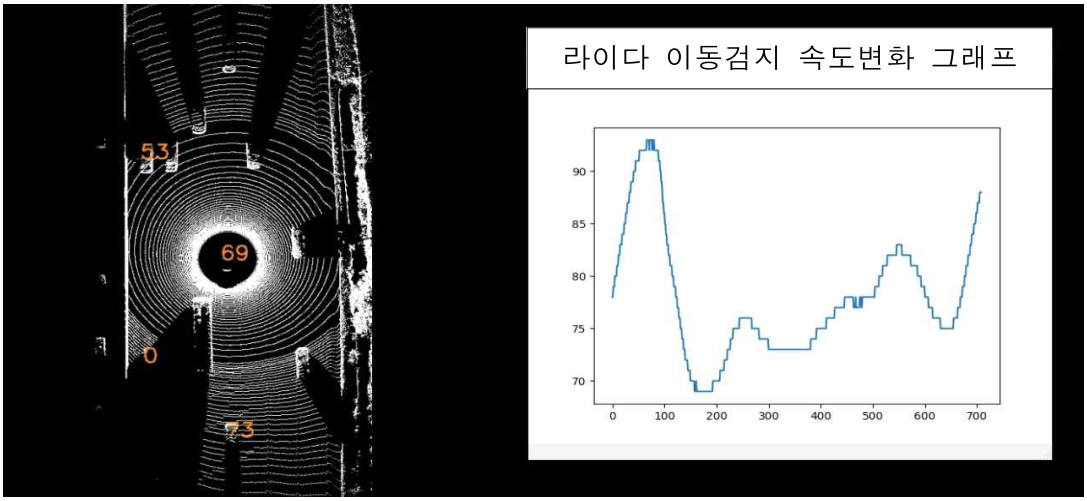

<그림 51> 양재(만남의광장) → 대왕판교IC 구간 속도결과 그래프 예시

2. 교통 안전성 모니터링

앞서 과정에서 부여한 개별차량의 고유 Tracking ID에 따른 차량의 방향, 속도, 가속도 등의 차량정보를 기반으로 안전성 평가를 수행하였다.

안전대리변수(TTC 모형 등)에 의한 안전성 계산은 다음 과정에 따라 수행된다.

가. 안전대리변수(SSM)에 의한 안전성 계산

(1) 주행데이터 추출

앞서 라이다 센서를 통해 추출한 다양한 데이터 중 다음 <그림 52>처럼 안전성평가에 필요한 교통데이터 자료(속도, 차간거리, 가감속도 등)

을 별도로 추출한다.

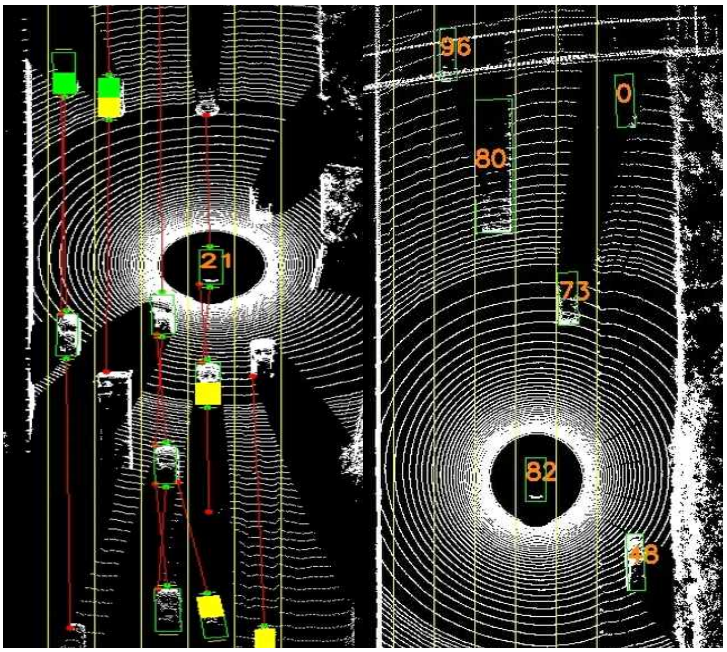

<그림 52> 안전성 평가에 필요한 데이터 추출

(2) TTC 계산 및 결과 도출

TTC는 현재시각(t)와 이전시각(t-1)의 차량간의 상대속도와 거리를 기반으로 계산되고 <그림 53>과 같이 동영상에 연속적으로 결과값이 표시된다.

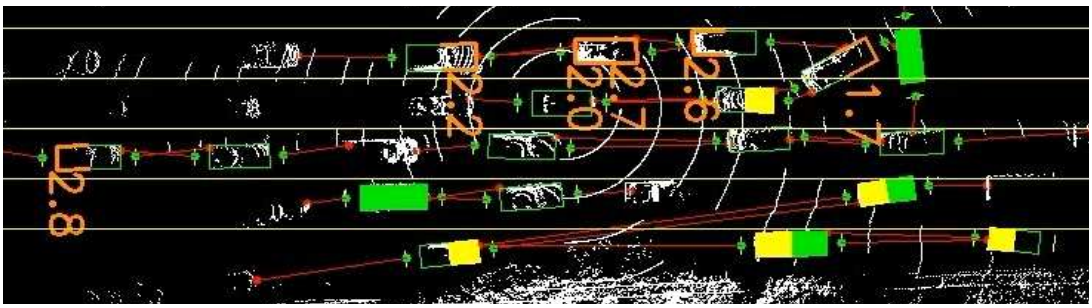

<그림 53> TTC 산출결과 시각화(동영상 캡처)

다음의 [표 31]은 TTC를 연산하고 표출하는 과정에서 차량의 상태를 나타내는 이미지를 표출하는 방법에 대한 설명이다.

[표 31] 차량객체 이미지별 정의

이미지	정의
	3D 좌표상에서 정상적으로 TTC 계산을 수행중 일 때 녹색외곽선 박스 형태의 이미지로 표현
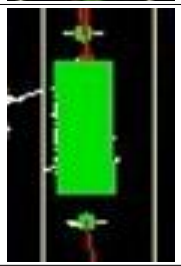	3D 좌표상에서 객체가 잡히고 Initializing(초기화) 되었을 때 녹색 박스 형태의 이미지로 표현
	3D 좌표상에서 2m이상 차이로 TTC 등을 계산 중이던 객체가 변경되었을 시, 재 Initializing(초기화)을 진행할 때 노란색 박스 형태의 이미지로 표현
	TTC가 3초 아래로 떨어져 위험한 상황일 때 주황색 박스 형태의 이미지로 표현하고 박스 옆에 TTC값을 표시함

다음의 [표 32]은 TTC 계산과정의 예시를 보여주고 있다.

[표 32] TTC 계산 예시

과 정	설 명	예 시
TTC 계산식	P_i는 차량 위치, $V_i(t)$는 차량 속도, l은 차량길이	$TTC = \frac{P_i(t) - P_{i-1}(t) - l_i}{V_{i-1}(t) - V_i(t)}$ = 상대거리/속도차
위험상황 결과 예시	오른쪽 예시의 TTC 계산은 아래와 같이 도출된다. ◦ 앞차와 뒷차와의 거리차이 P1 - P2 - 차량길이 = 7.1 - 1.5 - 4.5 = 1.1m ◦ 앞차와 뒷차와의 상대속도 = 1.226m/s ◦ TTC = 1.1/1.226= 0.897 본 논문에서는 TTC 3초 미만을 위험상황으로 정의	
일반상황 결과 예시	오른쪽 예시의 TTC계산은 아래와 같이 도출된다. ◦ 앞차와 뒷차와의 거리차이 P1 - P2 - 차량길이 = 11.5 - 1.8 - 4.6 = 5.1m ◦ 앞차와 뒷차와의 상대속도 = 0.8m/s ◦ TTC = 5.1/0.8= 6.375 TTC 결과가 임계값 3초 이상이기 때문에 해당 상황은 위험도 판단에서 일반(안전한)상황으로 분류	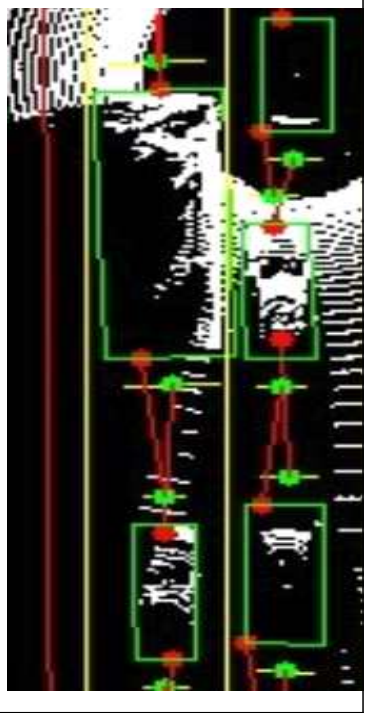

(3) MTTC 계산 및 결과 도출

MTTC는 현재시각(t)와 이전시각(t-1, t-2)의 차량간의 상대가속도, 상대속도와 거리를 기반으로 계산되고 다음 [표 33]과 같이 결과값이 표시된다.

[표 33] MTTC 계산 예시

과 정	설 명	예 시
MTTC 계산식	F는 후방차량, L은 선두차량, D는 초기 상대거리이다.	$V_F t + \frac{1}{2}\alpha_F t^2 \geq D + V_L t + \frac{1}{2}\alpha_L t^2$ $\frac{1}{2}\Delta\alpha t^2 + \Delta Vt - D \geq 0$
MTTC 결과 예시	오른쪽 예시의 MTTC 계산은 아래와 같이 도출된다. $\frac{1}{2}\Delta\alpha t^2 + \Delta Vt - D \geq 0$ ΔVt = 3.4㎧ $\Delta\alpha$ = -1.5㎧² D = 3.8m 일 때 MTTC = 2.5초 본 논문에서는 TTC 3초 미만을 위험상황으로 정의	

나. 운행구간 모니터링을 위한 데이터 산출

각 운행구간에 대한 밀도 및 MTTC 등 산출 결과는 다음 <그림 54> 처럼 연속적으로 파일형태로 저장 및 표출이 가능하도록 만들었다.

이정	s_time	e_time	위도	경도	1 평균 속도	2 평균 속도	3 평균 속도	4 평균 속도	5 평균 속도	1 표준 편차	2 표준 편차	3 표준 편차	4 표준 편차	5 표준 편차
410.9	15:46:51	15:46:56	37.42763747	127.0728594	82.43478261	115.52	101.0833333	77.24087591	66.77083333	1.345720656	8.488203579	12.61254887	7.105591042	6.305551732
411	15:46:56	15:47:01	37.42833858	127.0721499	70.89655172	112.627451	90.94339623	67.5754717	46.26136364	4.212827927	13.1058448	1.188229924	2.453138587	5.021531635
411.1	15:47:02	15:47:08	37.42904797	127.0714327	66.91935484	63.38016529	74.97435897	49.94244604	43.05333333	1.516557935	12.61722304	7.212834641	6.435926349	5.059363157
411.2	15:47:08	15:47:17	37.42975078	127.0707268	71	45.11445783	52.93571429	42.48908297	39.5138539	0	7.113039655	7.619721324	3.12422756	7.798335708
411.3	15:47:17	15:47:27	37.430448	127.0700229	-1	39.18118467	34.21848739	34.33333333	30.6695279	-1	4.700277402	7.240362663	6.156987635	3.080154982
411.4	15:47:27	15:47:42	37.43114964	127.0693151	-1	23.4213264	23.24208145	25.77461707	26.73421053	-1	6.417779498	2.956355714	6.43632089	5.044318133
411.5	15:47:42	15:48:14	37.43185375	127.0686033	80.625	6.005612245	8.103902954	9.353198469	8.951097804	1.494782593	6.238251745	6.346721267	9.493165617	7.326816451
411.6	15:48:14	15:48:25	37.43255403	127.0678947	81.34328358	22.69148936	28.1209068	29.71369295	19.40546697	1.93593079	3.63677024	5.582492531	2.31828812	1.629614094
411.7	15:48:25	15:48:38	37.43325433	127.0671892	89.25806452	23.06015038	27.95038168	27.62652439	20.26109661	5.730325341	3.447914044	2.485342499	2.841734504	2.974166553
411.8	15:48:39	15:48:53	37.43395453	127.0664808	106.6	10.72610837	18.7034384	22.8779473	2.63022113	0.8	8.940297773	4.887504058	5.129023148	2.839199233
411.9	15:48:53	15:49:31	37.43465575	127.0657746	82.94488189	4.914723286	11.13913471	8.185917722	5.251292658	10.01597707	4.486205302	7.329632509	6.959495684	6.329943603
412	15:49:32	15:49:51	37.43536128	127.0650627	70.39772727	5.738582677	14.35183443	17.90935391	16.50855086	6.065063465	5.7327083	5.015536907	2.835149141	5.365629589
412.1	15:49:51	15:50:09	37.43606017	127.0643573	72.76923077	4.330117161	11.76957295	19.50060024	15.28367104	3.524722491	5.779957402	2.973686407	2.785283246	5.28479573
412.2	15:50:09	15:50:22	37.436763	127.0636516	70.025	23.25083056	20.92112676	24.81639344	19.87207488	2.079513164	5.129085291	5.470996909	5.443515629	6.04733153
412.3	15:50:22	15:51:06	37.43746844	127.0629398	67.92592593	11.28960491	9.008743523	7.563682678	8.354357798	5.661044346	10.66799141	6.37430185	7.722956185	8.639671635
412.4	15:51:06	15:51:22	37.43817297	127.0622533	63.1294964	22.30184332	18.12873326	19.27392739	20.42261251	2.15524968	9.464882768	8.953990897	6.945631394	8.756762742
412.5	15:51:23	15:51:47	37.43890592	127.0616096	63.95652174	5.086919831	4.424485126	14.82261029	9.433291771	8.224979243	6.583449858	6.020323704	5.793692992	9.152553785
412.6	15:51:47	15:52:00	37.43965989	127.0610133	78.55555556	22.23123732	19.36552749	27.38940092	28.19917012	0.916245695	4.163893614	2.821610575	2.726044063	2.857936343
412.7	15:52:00	15:52:10	37.44044128	127.0604485	-1	8.038107753	18.60611511	34.51582278	28.36470588	-1	10.39141304	3.84144832	3.237889259	2.639505563
412.8	15:52:10	15:52:20	37.44121889	127.0598836	-1	3.757475083	14.29439252	33.84438776	26.13948498	-1	4.900322841	5.033742811	3.03613764	3.060875031
412.9	15:52:20	15:52:32	37.44200086	127.0593171	79.925	14	16.95526316	30.41889117	25.36013986	4.26548649	7.354160864	4.443575929	1.705496731	4.527656117
413	15:52:32	15:52:44	37.44278008	127.0587557	80.7037037	24.58139535	22.77728285	30.64574899	31.33425414	3.546670998	2.625745149	5.235591807	2.11558994	5.971977668
413.1	15:52:44	15:53:10	37.44356089	127.0581897	82.22857143	5.612432847	6.742783636	11.37975592	8.399410029	1.569089168	9.197053091	8.536299742	8.597070784	7.656666535
413.2	15:53:10	15:53:27	37.44434175	127.0576246	88.890625	20.53187919	18.2845787	20.87155963	23.17169069	3.255366663	11.71289617	7.147554577	3.184733031	4.590792043
413.3	15:53:27	15:53:40	37.4451215	127.0570516	81	5.800542741	15.95245902	27.69417476	29.25892857	1.507556723	8.29000148	4.356946839	2.215055512	3.057471924
413.4	15:53:40	15:53:52	37.44589022	127.0564422	-1	19.02439024	19.2159383	28.9507772	28.84067797	-1	2.931761234	3.561021915	2.35241292	2.624210528
413.5	15:53:52	15:54:02	37.44663706	127.0558019	-1	16.92099792	18.34982332	34.17557252	33.01388889	-1	4.072880218	6.494729445	1.675968063	2.48044046
413.6	15:54:02	15:54:12	37.44736606	127.0551429	-1	19.84990958	27.08965517	36.24545455	32.96855346	-1	3.623447475	3.028410853	1.032968922	2.574886088
413.7	15:54:12	15:54:23	37.44809736	127.0544846	-1	10.6584507	20	33.03937008	27.82137161	-1	6.657059611	8.806908869	4.247095487	5.623202335
413.8	15:54:23	15:54:59	37.44882553	127.0538199	82	4.057971014	1.171048361	8.101174345	28.24667089	4.727348738	4.631129884	3.24519256	10.73078074	7.312702312
413.9	15:54:59	15:55:14	37.44956075	127.0531514	-1	15.41846758	14.6079096	22.24234694	33.44051447	-1	8.536742085	8.803244435	8.903389781	6.7539793
414	15:55:15	15:56:20	37.45028158	127.0524873	82.21311475	9.396808125	5.097362637	5.118694362	23.82431646	5.385514129	5.209847123	4.875502078	6.277994214	15.78282923
414.1	15:56:21	15:56:33	37.45101553	127.0518199	-1	23.06417112	22.9223301	30.23560209	51.66440678	-1	5.213394554	5.823214318	6.039745282	3.202634652
414.2	15:56:33	15:56:46	37.45175014	127.0511751	-1	16.90909091	16.61290323	23.52857143	24.69152542	-1	5.621191701	6.876924572	8.450226419	14.27916923
414.3	15:56:46	15:57:42	37.45248472	127.0505235	77.87755102	11.10005817	4.657174454	6.270418668	6.919642857	9.270608929	6.645638301	5.607345796	8.249849941	7.133356608
414.4	15:57:42	15:57:56	37.45321831	127.0498626	92.0625	22.19117647	25.09076923	22.31652661	21.98135198	1.04893299	9.088454554	4.749679279	4.157687522	3.451242409
414.5	15:57:56	15:58:42	37.45394914	127.0492032	78.05555556	9.359501895	7.813352477	8.172749392	8.372881356	5.077972279	7.681085508	7.318881346	6.863883662	8.133641422
414.6	15:58:42	15:59:02	37.45468172	127.0485444	78.425	10.51269991	10.25151057	14.61410788	11.55542986	1.626153437	5.50631029	3.936547993	7.418747149	7.696467717
414.7	15:59:02	15:59:53	37.45540928	127.0478714	85.90697674	8.906200318	4.537677725	7	6.795454545	2.692055094	8.273923815	7.977382264	8.79927065	6.956944031
414.8	15:59:53	16:00:18	37.45612956	127.0471863	77.51428571	12.9770798	11.14936147	14.44459279	19.94112061	1.38091954	4.657212414	5.114177839	7.732592803	4.540662489
414.9	16:00:19	16:00:55	37.45684775	127.0465005	75.31428571	9.266886326	8.677591463	8.05234657	11.06875544	1.293310891	3.443614473	4.889761983	8.231146486	7.040821437
415	16:00:55	16:02:30	37.45756131	127.0458212	103	8.340137429	5.304422499	3.156704362	3.993665657	10.13085122	6.031555205	6.628517152	5.727438659	5.488548814
415.1	16:02:30	16:02:46	37.45828111	127.0451385	77.24242424	12.91255605	16.06804374	18.37239583	13.8858885	1.633555391	6.53939248	6.217619845	6.825913285	4.187259941
415.2	16:02:46	16:03:11	37.45899817	127.0444559	74.19277108	15.05169628	11.90893471	13.71388499	13.52446675	2.677248324	3.46324941	3.29761973	4.123553346	2.900000627

<그림 54> 교통상태 및 안전성평가 결과 화면

이러한 계산결과는 엑셀 등 다양한 분석도구를 활용하여 <그림 55>처럼 다양한 형태로 시각화하여 지속적으로 모니터링할 수가 있게 하였다.

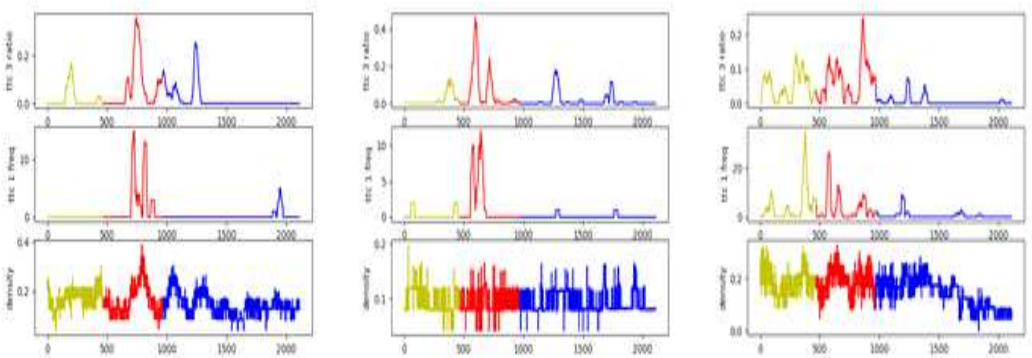

<그림 55> MTTC, 점유율 등 시각화 예시

3. 안전성 평가 개선방안

가. 회피가능 안전공간(SSS : Searching for Safety Space) 개념

본 논문에서는 위험상황에 놓인 운전자가 단순히 브레이크를 밟아 위험상황을 피하는 경우(Case 1)와 '회피가능 안전공간'이라는 개념을 도입하여 옆 차로의 상황에 따라 회피조향을 통해 위험상황을 피하는 경우(Case 2)를 함께 분석하여, 기존 연구보다 운전자의 의사선택 과정을 좀 더 세분화한 안전도 평가 방법을 제안하고자 하였다.

기존 안전성 평가모형(SSM)은 일반적으로 전후방 차량만 고려하여 모델 개발 및 평가를 진행하였으며, 특히 현장자료를 기반으로한 좌우차로에서 주행 중인 차량과의 상호작용은 심각하게 고려하지 못했다.

이는 기존 검식방식의 문제점으로부터 기인하는 것으로 데이터 수집의 제한으로 인한 연구범위의 한계였다. 하지만 본 연구에서 처음으로 활용을 시도하 는 라이다 장비를 이용함으로써 에고(Ego)차량 기준으로 약 60m반경 안의 모든 차량과의 상호작용을 분석할 수 있기 때문에 기존 연구와 다르게 앞 차량과 충돌의 피하기 위한 회피조향을 고려할 수 있다.

회피가능 안전공간에 대한 개념도는 아래의 <그림 56>과 같다.

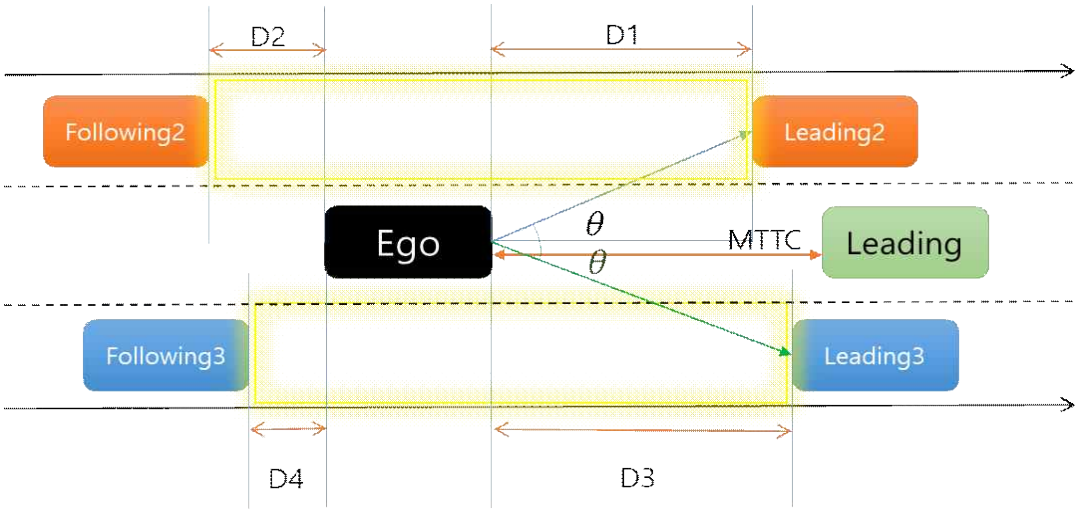

<그림 56> 회피가능 안전공간 개념도

회피가능 안전공간(SSS : Searching for Safety Space)은 <그림 56>의 노란색 표시구간을 표시하며, 동일시점에서 현재의 속도와 가속도를 유지할 경우 좌우차로 전방 및 후방 공간으로 이동가능한 안전공간을 의미한다.

정동훈(2011)에 따르면 일반적으로 차선변경시 진입각도 θ값은 통상 5~7° 정도임으로 실제 차선변경에 의한 이동거리의 증가는 크지 않은 것으로 연구되었다. 즉, $\cos(5^\circ \sim 7^\circ) \fallingdotseq 1$ (0.9962~0.9925)로 가정한다고 설명하고 있다.

다음의 [표 34]는 차로변경(회피조향)에 따른 충돌여부를 판단하는 과정에 대해 설명하였으며 이러한 과정을 통해 회피가능 안전공간을 판단하였다.

[표 34] 차로변경에 따른 충돌여부(시간) 판단 과정

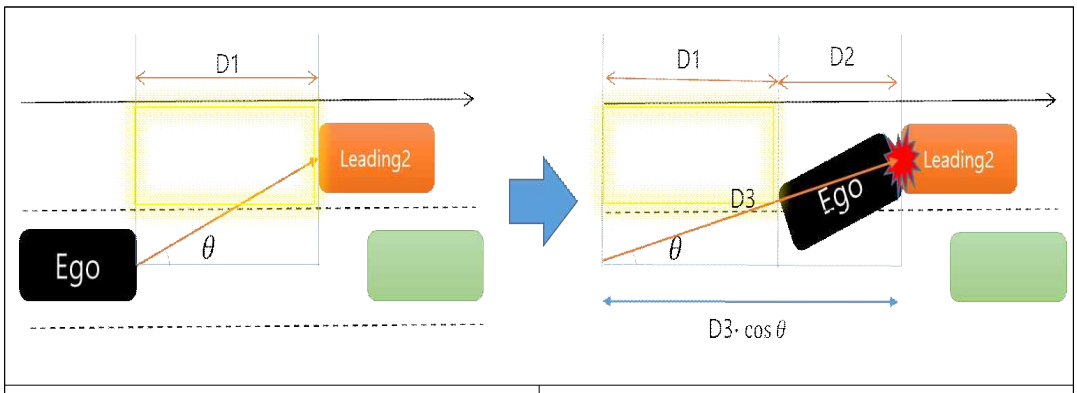

(a) 초기 시점	(b) 충돌예상 시점

L2 : 변경차로 전방(Leading2)차량
D1 : 주체(Ego)차량과 변경차로 전방차량(L2)과의 차간거리
D2 : L2가 t초동안 이동한 거리
D3 : 주체(Ego)차량이 t초동안 이동한 거리
D3 · cosθ : 주체(Ego)차량 차로변경 후 L2와의 수평거리

두 차량이 충돌(b 경우)하려면, D1 + D2 ≤ D3 · cosθ

모든 방향에 대한 안전공간 확보여부 판단을 방정식으로 표현해 보면 다음과 같다.

(1) 좌측차로 안전공간 확보여부

- 좌측차로 전방차량과 회피가능공간 검토 판단식

$$\cos\theta(V_{Ego}t+\frac{1}{2}a_{Ego}t^2)<(D_1+V_{L_2}t+\frac{1}{2}a_{L_2}t^2) \quad \text{(식 7)}$$

- 좌측차로 후방차량과 회피가능공간 검토 판단식

$$V_{F_2}t+\frac{1}{2}a_{F_2}t^2<D_2+\cos\theta(V_{Ego}t+\frac{1}{2}a_{Ego}t^2) \quad \text{(식 8)}$$

(2) 우측차로 안전공간 확보여부

- 우측차로 전방차량과 회피가능공간 검토 판단식

$$\cos\theta(V_{Ego}t+\frac{1}{2}a_{Ego}t^2)<(D_3+V_{L_3}t+\frac{1}{2}a_{L_3}t^2) \quad \text{(식 9)}$$

- 우측차로 후방차량과 회피가능공간 검토 판단식

$$V_{F_3}t+\frac{1}{2}a_{F_3}t^2<D_4+\cos\theta(V_{Ego}t+\frac{1}{2}a_{Ego}t^2) \quad \text{(식 10)}$$

여기서, V는 차량속도, t는 단위시간, D는 차간거리, θ는 조향각

나. 안전공간 확보 여부를 통한 안전성평가 개선방법

(1) 안전공간 확보여부를 통한 안전성평가 방법

- 1단계 : 기존 앞차와의 MTTC를 동일하게 계산(3초기준 확인)
- 2단계 : 회피가능 안전공간(SSS) 확보여부 평가를 위해 좌우차로의 전후방차량과 MTTC 계산

실제 현장데이터를 사용하여 MTTC와 추월가능 여부를 계산은 Ego차량의 검지공간 영역내 모든 차량에 대해서 각 차량별로 산출한다.

(2) 다른차로 차량과의 충돌예상시간 계산과정

다른 차로 차량과의 충돌예상(가능)시간 계산을 위한 과정은 다음과 같다.

t시점에서 앞차와의 충돌 발생까지 걸리는 시간을 x라 할 때, 두 차량 간의 관계식은 다음의 (식 11) 및 (식 12)로 나타낼 수 있다.

$$\cos\theta\left(V_{Ego}(t)x+\frac{1}{2}a_{Ego}(t)x^2\right)=d+V_L(t)x+\frac{1}{2}a_L(t)x^2 \quad \text{(식 11)}$$

(식 11)을 정리하면 (식 12)와 같이 x에 관한 2차 방정식이 된다.

$$\frac{1}{2}(a_L(t)-\cos\theta\, a_{Ego}(t))x^2+(V_L(t)-\cos\theta\, V_{Ego}(t))x+d=0 \quad \text{(식 12)}$$

단, $a_L(t)$는 시각 t일 때 선행차량의 가속도

$a_{Ego}(t)$는 시각 t일 때 Ego차량의 가속도

$V_L(t)$는 시각 t일 때 선행차량(Leading)의 속도

$V_{Ego}(t)$는 시각 t일 때 Ego차량의 속도

θ는 Ego차량 전방 방향으로부터 선행차량의 각도

d는 Ego차량과 선행차량과의 차간거리

Ego차량과 앞뒤차량의 조건에 따라 (식 12)에 대입하면 충돌예상(가능)시간 x를 산출할 수 있다.

1) 가속도가 동일한 경우($a_L(t)=\cos\theta\, a_{Ego}(t)$)

$$x=\begin{cases}\infty & \text{, if} \quad V_L(t)\geq\cos\theta\, V_{Ego}(t)\\ \dfrac{d}{\cos\theta\, V_{Ego}(t)-V_L(t)} & \text{, } otherwise\end{cases}$$

2) 가속도가 다를 경우($a_L(t) \neq \cos\theta\, a_{Ego}(t)$)

$$x = \frac{-(V_L(t) - \cos\theta\, V_{Ego}(t)) \pm \sqrt{D}}{a_L(t) - \cos\theta a_{Ego}(t)} \quad ,$$

$$D = (V_L(t) - \cos\theta\, V_{Ego}(t))^2 - 2(a_L(t) - \cos\theta\, a_{Ego}(t))d$$

$$(a_i(t) = \frac{V_i(t) - V_i(t-1)}{dt}, \quad V_i(t) = \frac{S_i(t) - S_i(t-1)}{dt} \ )$$

2-1) $D < 0$ 일 때, $x = \infty$

2-2) $D \geq 0$ 일 때

$$x_1 = \frac{-(V_L(t) - \cos\theta\, V_{Ego}(t)) - \sqrt{D}}{a_L(t) - \cos\theta\, a_{Ego}(t)},$$

$$x_2 = \frac{-(V_L(t) - \cos\theta\, V_{Ego}(t)) + \sqrt{D}}{a_L(t) - \cos\theta\, a_{Ego}(t)}$$ 라 하면

$$x = \begin{cases} \min(x_1, x_2) & \text{, if } x_1 \geq 0,\ x_2 \geq 0 \\ \max(x_1, x_2) & \text{, if } x_1 x_2 < 0 \\ \infty & \text{, } otherwise \end{cases}$$

앞서 충돌시간 판단 계산과정을 통한 결과를 시각화하여 표현하기 위해 다음의 <그림 57>과 같이 이동 중인 직사각형 박스모양의 차량을 4등분하여 나타내었다. 회피가능한 공간이 확보된 경우 정상(MTTC 임계시간 4.5초이상)은 녹색, 회피위험 상황(3초이상 4.5초미만)은 주황색, 회피불가 상황(3초미만)은 붉은색으로 표시하였으며, 연속적으로 회피가능 공간 확보 여부를 시각적으로 표현하여 쉽게 모니터링 할 수가 있다.

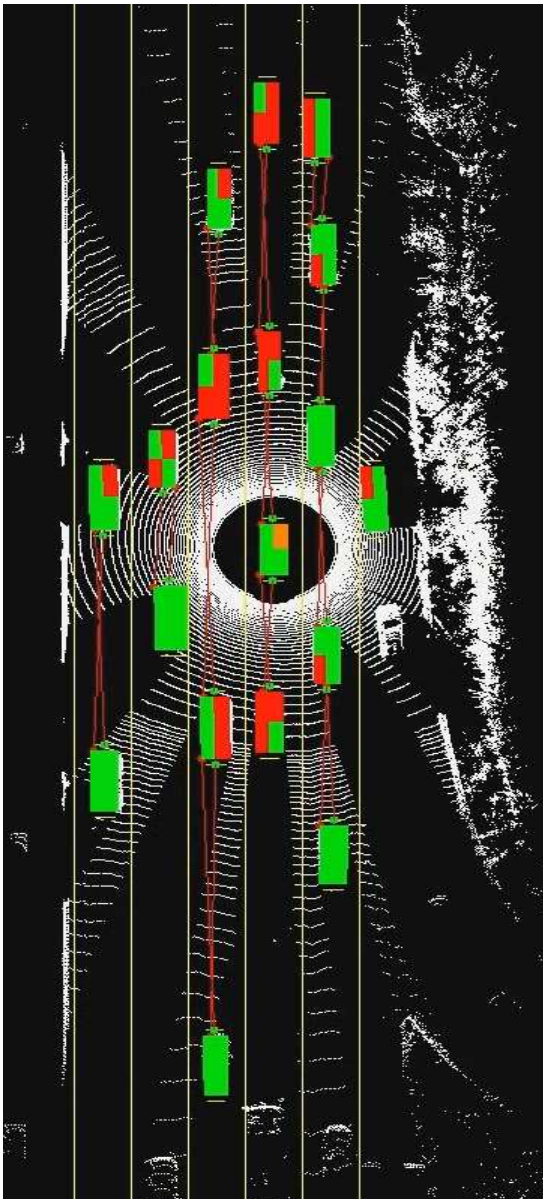

<그림 57> MTTC 및 회피가능
안전공간(sss)산출 결과(동영상 캡처)

다음의 [표 35]는 회피가능 안전공간 여부를 평가한 결과를 차량의 이미지로 나타낸 상태에 관한 설명 예시이다.

[표 35] 안전공간(sss) 상황별 결과 이미지 예시

이미지	설 명
	전후좌우 방향으로 모두 안전하게 이동가능할때 녹색 박스 형태의 이미지로 표현
	우측전방 방향으로 차선변경이 위험한 경우 녹색우측 방향에 적색표시 박스 형태의 이미지로 표현
	우측전방과 좌측후방 방향으로 차선변경이 위험한 경우 녹색우측과 좌측후방 방향에 적색표시 박스 형태의 이미지로 표현
	우측전방과 우측후방 방향으로 차선변경이 위험한 경우 우측방향에 적색표시 박스 형태의 이미지로 표현

제5장 라이다 센서를 이용한 현장조사 및 교통 모니터링

제1절 현장데이터 수집 및 적정성 분석

1. 라이다 센서를 이용한 현장 데이터 수집

가. 현장데이터 수집 개요

이번 논문에서는 총 8회의 현장조사를 통해 데이터를 수집하였다. 고속도로 경부선 서울방향으로 판교IC에서 진입하여 반포IC로 진출하는 약 12km 구간과 경부선 부산방향 판교IC에서 오산IC까지(약 28km) 구간을 통해 현장조사를 실시하였다. 추가로 밀폐된 공간인 터널에서의 데이터 수집 가능성과 적정성을 점검하기 위해 추가적인 현장조사를 실시하였다. 또한 현장조사시 라이다가 가진 장점을 확인하고 차별성을 보여주기 위해 일몰(야간) 시간대를 선정하여 조사를 실시하였다. 현장자료 취득시 주변 교통흐름에 순응하여 운행하였으며, 전체적인 조사현황은 [표 36]과 같다.

[표 36] 현장 데이터 수집현황

날 짜	수집시간	수집 구간	거리	기타
22.9.20 (화)	15:12 ~ 16:07	경부 판교~반포(서울)	12km	
22.9.21 (수)	14:50 ~ 16:57	경부 판교~반포(서울)	12km	
22.9.23 (금)	20:30 ~ 21:22	경부 판교~반포(서울)	12km	야간
22.9.26 (월)	10:50 ~ 12:30	경부 판교~반포(서울)	12km	
22.9.27 (화)	15:40 ~ 17:16	경부 판교~반포(서울)	12km	
22.12.09 (금)	19:08 ~ 19:34	경부 판교~오산(부산)	28km	야간
22.10.20 (목)	14:56 ~ 14:57	경기 성남시 내곡터널	1km	터널
22.11.25 (금)	10:25 ~ 10:25	경기 광명시 서독터널	0.6km	터널

나. 현장수집구간 특성

(1) 경부고속도로 서울방향 판교-반포구간

경부선 서울방향 판교-반포구간은 <그림 58>과 같이 판교부근을 지나면 달래내고개라는 오르막(최대 4.5%) 후 내리막(최대 - 4.7%)경사로 이루어진 구간으로, 중간에 금토분기점과 양재IC 및 서초IC 진출로가 있다. 서울과 경기도의 경계구간으로 상습적인 정체가 발생되는 구간이다.

<그림 58> 경부선 서울방향 판교-반포구간 노선도

(2) 경부고속도로 판교-오산구간

경부선 부산방향 판교-오산구간은 <그림 59>과 같이 판교IC로 고속도로에 진입하여 서울영업소를 시작으로 오산IC까지 이동하는 구간이며 신갈분기점, 수원IC, 기흥, 동탄분기점 등 다양한 변화구간이 존대한다. 수도권 주요도시를 연결하는 노선으로 출퇴근시 정체가 되는 구간이다.

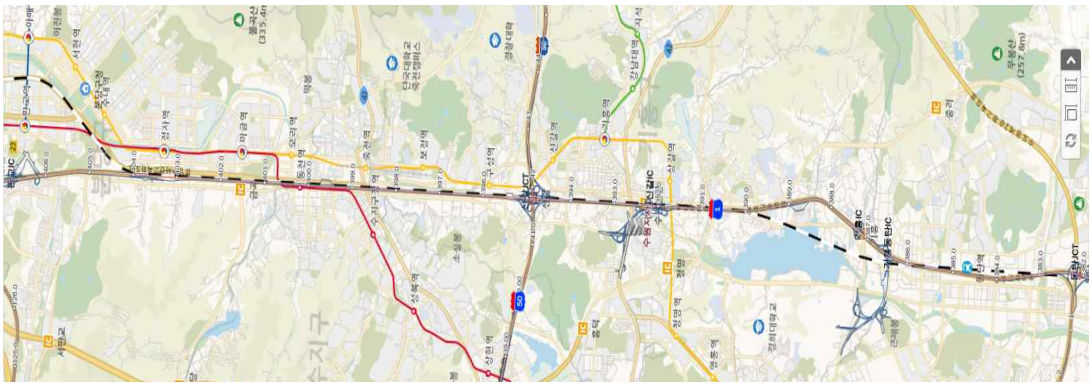

<그림 59> 경부선 부산방향 판교-오산구간 노선도

(3) 도시고속도로 및 일반도로 터널구간

터널구간에서 라이다 센서를 통한 교통정보 수집가능 및 성능확보 여부를 확인하기 위해 <그림 60>, <그림 61>과 같이 분당내곡도시고속도로 내곡터널(길이 1km)과 경기도 광명시 KTX 광명역 부근의 서독터널(길이 600m)을 통과하면서 데이터를 직접 수집했다.

<그림 60> 분당내곡도시고속도로 내곡터널 노선도

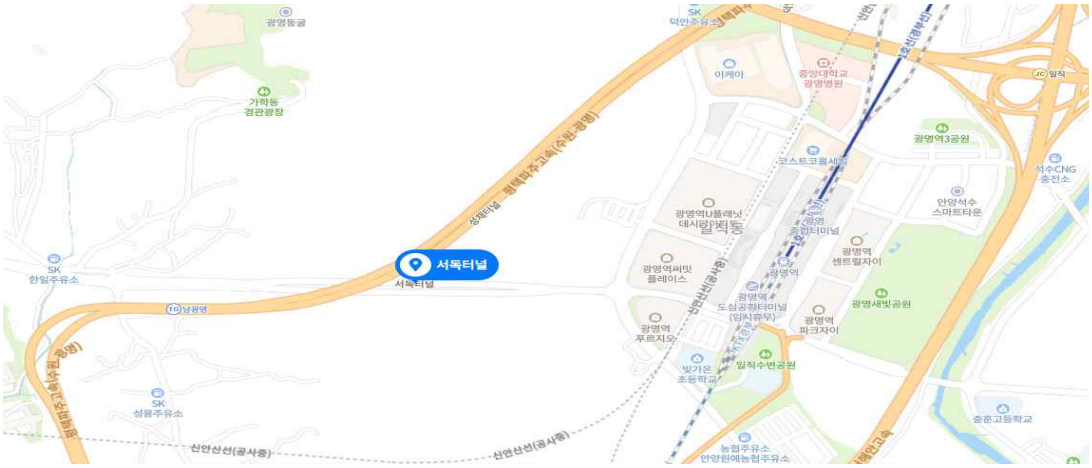

<그림 61> 경기도 광명시 일직동 서독터널 노선도

다음 [표 37]는 현장조사시 전방 카메라와 라이다 검지 결과를 동기화한 캡처화면을 보여주고 있다.

[표 37] 다양한 데이터(영상 및 라이다) 수집 장면

경부선 야간 주행데이터 수집장면

경부선 주간 주행데이터 수집장면

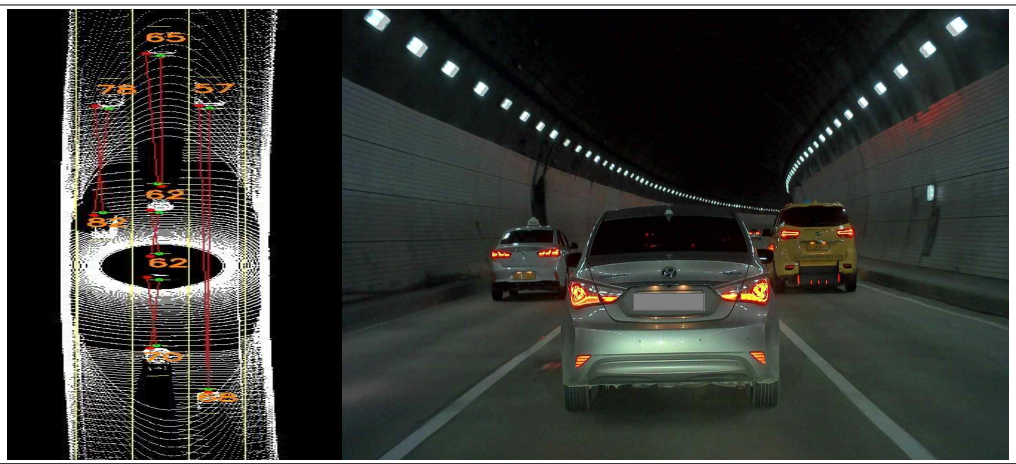

내곡터널내부 데이터 수집장면

2. 교통정보 데이터 적정성 검토

가. 안전성 평가 적정 시간단위 비교

안전성 평가를 위한 적정 시간단위 간격을 결정하기 위해 2가지(1초와 3초) 시나리오로 안전대리변수인 TTC를 산출한 후 다음 결과값을 비교하였다. 비교한 2가지 시나리오는 다음과 같다. (a) 1초단위 TTC 계산, (b) 3초단위 TTC 계산하는 경우이다. 최적의 적정 표출단위 시나리오를 찾기 위해 실험한 결과는 [표 38]과 같다.

[표 38] 적정 TTC 산출 시간간격 검토

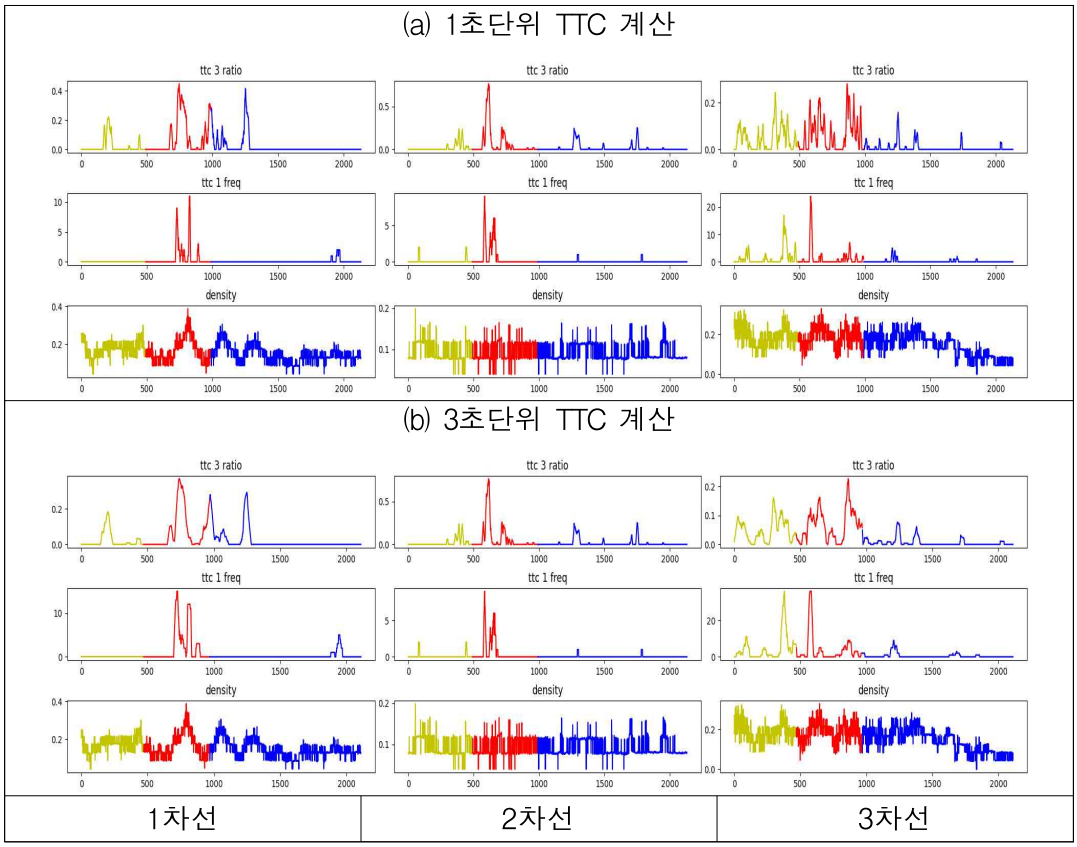

실험결과를 보면 두 시나리오에서 유사한 형태의 곡선이 표현되는 것을 확인할 수 있다. 하지만 1초 단위의 TTC와 3초 단위의 TTC의 실험결

과를 보면 변동폭 부분에서 차이가 있다. 3초 단위의 TTC 계산은 3초 간격 사이의 속도변화를 고려하지 않기 때문에 실험결과와 같이 변동폭이 크게 존재하지 않는 것을 확인할 수 있다. 일반적으로 안전을 중요시하는 자율주행 시스템에서 3초동안의 속도변화를 고려하지 않는 것은 큰 누적 오차를 발생시키게 된다. 따라서 적절한 TTC 산출간격을 구하기 위해 비교한 결과 1초단위로 표출하는 것이 가장 차량의 움직임을 적절하게 표현하는 것으로 나타났다. 또한 다른 동기화(카메라, GPS 등) 데이터들도 기본 1초를 기준으로 산출되고 있음으로, 본 논문에서는 모든 계산 기준은 1초 단위를 사용하여 수행하였다.

나. TTC 결과값의 활용 적정성

다음 <그림 62>는 모든 차로의 TTC 산출수치를 평균한 결과를 나타내는 그래프이다. 기존 논문에서 TTC값 산출은 주로 주체차량(Ego)에 대해 계산을 하게 되는데 본 연구에서는 구간 전체의 차량들에 대한 TTC값을 계산하기 때문에 전체 차량의 TTC값을 사용하는 경우 TTC 결과값이 평균화하게 되어 TTC의 특성이 희석(7.5초에서 10초사이)되어서 TTC 7.5초 이하로 내려가는 경우가 발생하지 않게 된다. 이러한 이유로 이번 연구에서는 TTC 결과값은 계산된 수치값 자체를 사용하기보다는 임계값(threshold) 이하를 나타낸 위험발생 건수를 사용하여 위험성을 평가하고자 하였다.

<그림 62> 전차로 평균 TTC 결과

다. 안전대리변수 중 TTC와 MTTC 적정성

다음 <그림 63>은 라이다 수집 데이터 중 양재IC전방 일부구간에 대해서 1차로에서 5차로까지 차로별로 TTC 산정 결과와 점유율(밀도) 결과를 비교하였다.

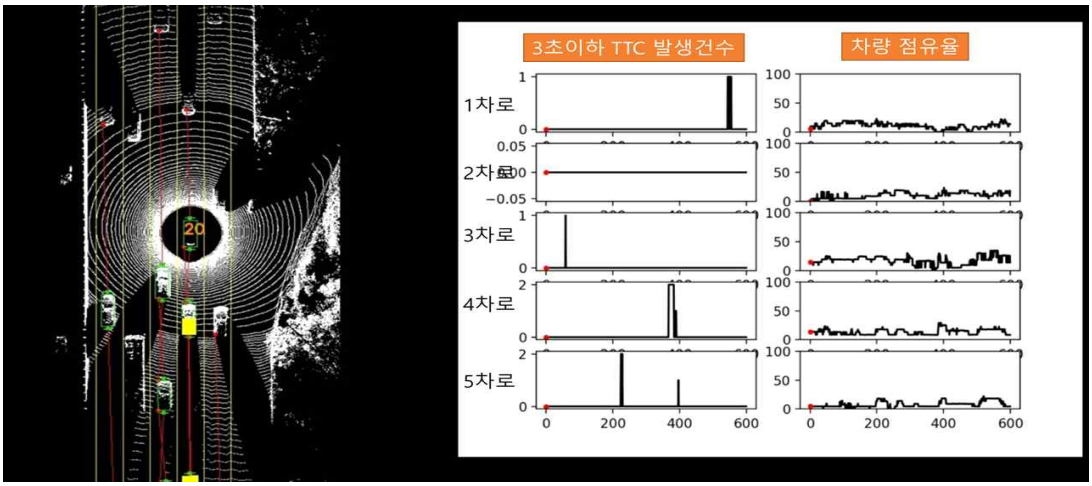

<그림 63> 차로별 TTC 발생횟수 결과

다음 <그림 64>은 라이다 수집 데이터 중 양재IC전방 일부(위의 TTC 계산과 동일)구간에 대해서 1차로에서 5차로까지 차로별로 MTTC 산정 결과와 점유율(밀도) 결과를 비교하였다.

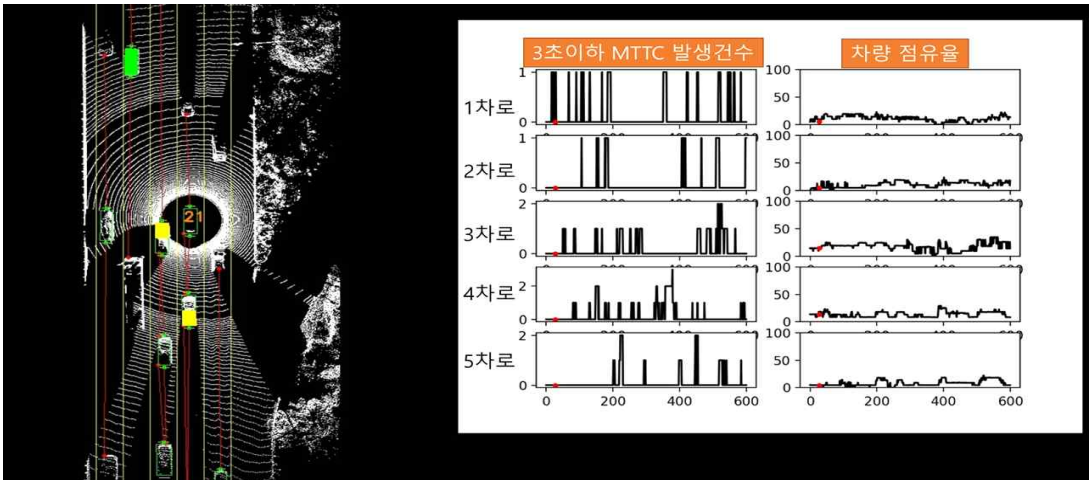

<그림 64> 차로별 MTTC 발생결과 산정

다음 <그림 65>은 전체차로에 대해 위험 판단의 임계값은 3초일 때 TTC와 MTTC 위험발생 건수를 비교하였다. 이 결과 역시 차로별 결과와 동일하게 MTTC 결과가 더 민감하게 반응하고 있음을 확인할 수 있었다. MTTC의 경우 속도뿐만 아니라 가감속 및 차로간격 등을 사용함으로 TTC에 비해 더 민감하게 반응하여 도로의 위험상황을 더 잘 보여주는 것을 알 수가 있다.

이번 논문에서는 모든 안전대리변수는 라이다의 데이터 수집특성(속도, 가속도, 차간거리 등)을 활용할 수 있는 MTTC를 사용하여 분석하였다.

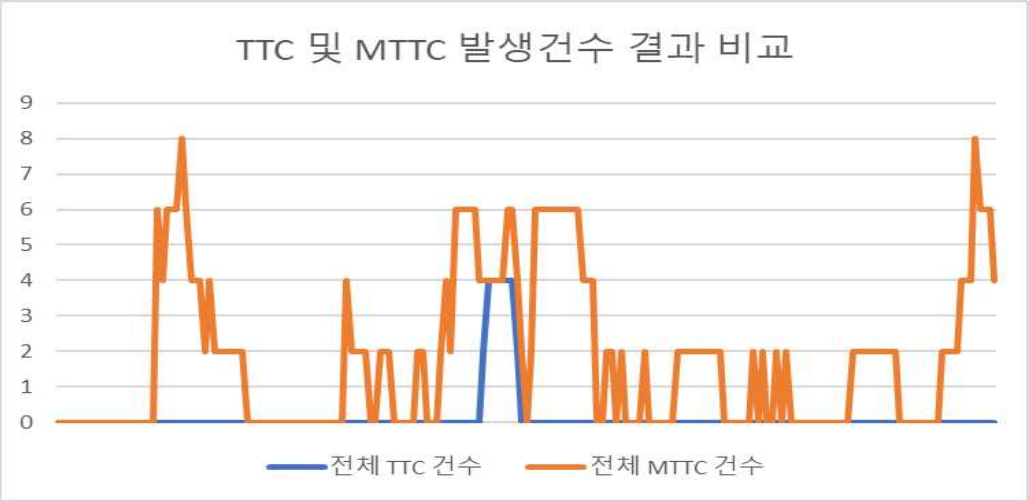

<그림 65> TTC와 MTTC 발생건수 결과 비교

라. MTTC 임계기준 적정성

선행 연구에서 살펴보았듯이 일반적으로 TTC 임계기준(threshold)은 1초에서 4초까지 다양한 기준값이 사용되고 있었다. 이러한 임계기준 중 어느 것이 이번 논문에 적정한지에 대해 검증하기 위하여 (1) 국내 법적 기준 및 해외사례와 (2) 현장 수집데이터 분석을 통해 적정한 기준값을 결정하고자 하였다.

(1) 국내 법적 기준 및 해외사례

국내 기준의 경우 국토교통부(2022.10.26.)에서 개정한「자동차 및 자동차부품의 성능과 기준에 관한 규칙」중 “승합자동차 및 차량총중량 3.5톤 초과 화물·특수자동차에 설치되는 비상자동제동장치의 구조 및 성능기준(제90조의3제1호 관련)”에서 충돌발생예상시간(TTC)을 3초 이하일 경우에만 비상자동제동(AEB)을 시작하라고 규정하고 있다.

또한 네덜란드 유일의 대형연구기관인 TNO(응용과학연구기구)에서 지속적으로 TTC를 연구한 van der Horst(1994)은 초창기에는 TTC임계값으로 1.5초를 제안(1984, 1990)하였으나, 연속류에서 CAS(Collision Avoidance System)에 적용하기 위해서는 TTC 기준값을 4초로 제안하였다[94].

(2) 현장수집 데이터 분석 사례

오철 외(2007)은 후미추돌 위험도 분석연구에서 TTC 임계기준을 기존의 연구(Hirst and Graham, 1997)결과인 3초를 사용하였으며, 이를 검증하기 위해서 영동선 월곶IC-안산(3차로)구간에서 15분간 관심구역을 70m로 한정하여 조사하였고 이를 통해 TTC 분포결과는 [표 39]와 같이 제시하였다. 그 결과 TTC가 3초 이하의 경우는 1차로는 약 10%, 2차로는 약 8%, 3차로는 약 7.5%인 것으로 분석되었다. <그림 66>과 같이 전체적으로 3초 이하는 약 9% 정도 비율을 차지하고 있었다[39].

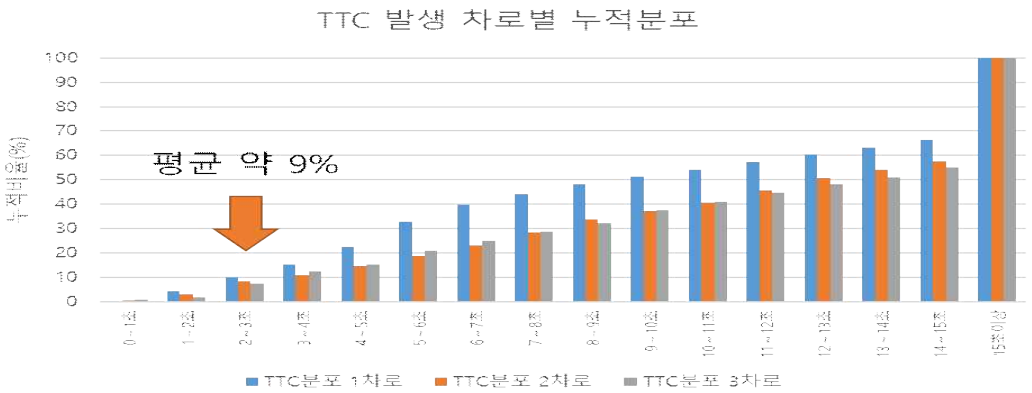

<그림 66> 차로별 TTC 발생분포 누적 그래프

[표 39] 차로별 시간별 TTC분포(출처 : 오철, 2007)

TTC분포	1차로		2차로		3차로	
	발생건	비율(%)	발생건	비율(%)	발생건	비율(%)
0～1초	18	0.43	26	0.61	27	1.04
1～2초	172	4.12	115	2.70	21	0.81
2～3초	229	5.49	221	5.19	149	5.72
3～4초	230	5.52	107	2.51	129	4.95
4～5초	292	7.00	157	3.69	77	2.95
5～6초	438	10.50	178	4.18	148	5.68
6～7초	285	6.83	191	4.49	107	4.10
7～8초	185	4.44	217	5.10	91	3.49
8～9초	160	3.84	230	5.40	93	3.57
9～10초	140	3.36	147	3.45	136	5.22
10～11초	114	2.73	152	3.57	96	3.68
11～12초	122	2.93	211	4.96	92	3.53
12～13초	133	3.19	206	4.84	93	3.57
13～14초	115	2.76	147	3.45	72	2.76
14～15초	133	3.19	149	3.50	105	4.03
15초이상	1404	33.67	1802	42.34	1171	44.92
총계	4170	100	4256	100	2607	100

이번 논문에서는 현장에서 수집한 데이터를 기본으로 하며 오철(2007)의 누적분포 방법을 사용하여 경부선 부산방향 판교-오산구간과 서울방향 판교-서초구간에서 MTTC 누적 분포결과를 분석해 보았다.

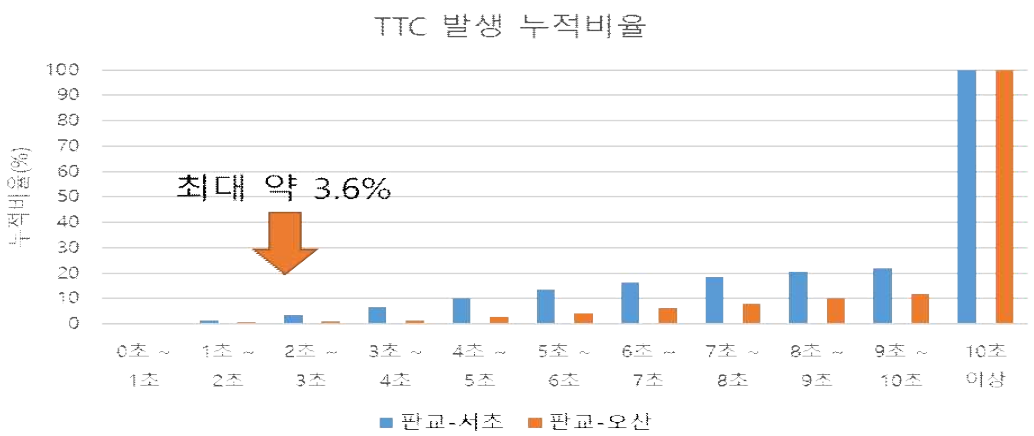

<그림 67> 구간별 MTTC 발생분포 누적 그래프

MTTC발생 분석결과 [표 40] 및 <그림 67>와 같이 경부선 부산방향 판교-오산구간에서 3초이하 누적비율은 약 1%로 나왔고 정체가 많이 발생하는 서울방향 판교-서초구간에서 약 4%의 MTTC 누적분포를 나타내었다.

[표 40] 현장데이터 MTTC 구간별 발생건수

구분	판교-오산 부산방향		판교-서초 서울방향	
	건수	비율(%)	건수	비율(%)
0초 ~ 1초	4	0.00	325	0.10
1초 ~ 2초	1,272	0.68	4,331	1.34
2초 ~ 3초	447	0.24	6,826	2.12
3초 ~ 4초	1,184	0.64	10,153	3.15
4초 ~ 5초	2,056	1.11	11,210	3.48
5초 ~ 6초	2,998	1.61	10,519	3.26
6초 ~ 7초	3,524	1.90	9,135	2.83
7초 ~ 8초	3,684	1.98	7,468	2.32
8초 ~ 9초	3,438	1.85	5,770	1.79
9초 ~ 10초	3,193	1.72	4,849	1.50
10초 이상	164,089	88.27	251,772	78.10
총 계	185,889	100	322,358	100

또한 경부선 부산방향 판교-오산 현장데이터를 이용하여 임계 기준값별(1초, 3초, 4.5초)로 MTTC 발생건수를 비교해 보았다. 그 결과 <그림 68>와 같이 임계기준 1초의 경우는 동일시점에서 최대 2건 정도로 매우 드물게 나타나는 반면, 3초 기준은 최대 6건, 4.5초 기준은 최대 9건 정도 나타나는 것을 볼 수 있다. 변화구간인 IC 진출입구간에서 적절하게 MTTC가 증가하고 기타구간에서 감소하는 경향을 보여주는 것이 안전성 평가를 결과를 적절하게 나타내는 지표라고 판단된다. 이러한 경향을 잘 보여주는 임계기준은 3초가 적절한 것으로 현장비교 결과 도출되었다. 즉, 3초 기준이 안전대리변수로서 사고위험을 적정하게 표현해 주고 있는 것으로 판단하고 3초를 사용하였다.

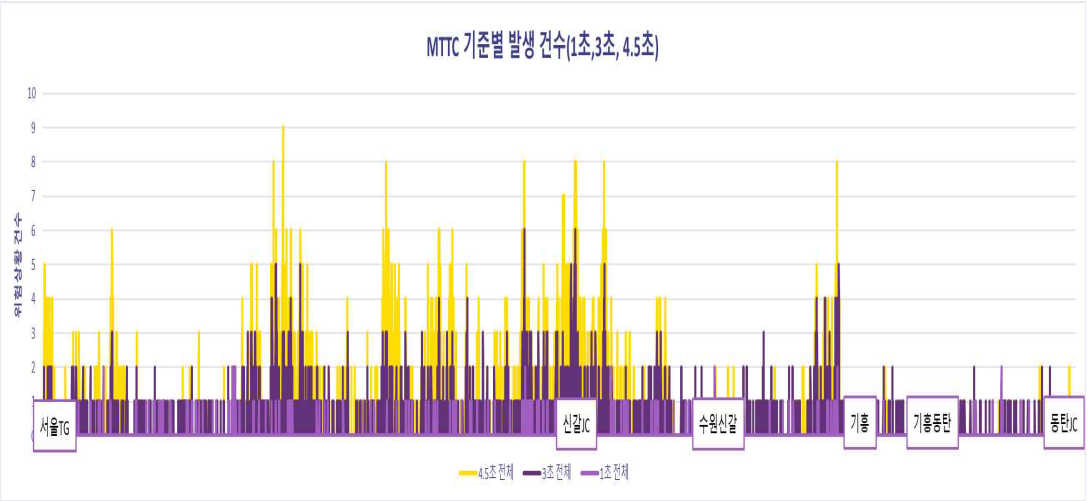

<그림 68> MTTC 1초, 3초, 4.5초이하 발생건수 그래프

앞서 (1) 국내 법적 기준 및 해외사례와 (2) 현장 수집데이터 분석을 통해 종합적으로 검토해 본 결과, 이번 논문에서는 위험상황을 적절히 표현해 줄 수 있는 임계기준(threshold)을 3초로 선정하여 연구에 적용하고 분석하였다.

제2절 고속도로 교통혼잡 및 안전성 분석

본 절에서는 라이다 센서에서 수집된 현장조사의 다양한 교통정보(속도, 밀도 등 혼잡상황)와 교통안전성 평가 결과 등을 중심으로 모니터링 하였다.

1. 라이다 교통정보를 통한 교통혼잡 모니터링

가. 차로별 속도 및 전체 평균속도 비교

현장(양재IC 진출로전방)에서 수집된 데이터를 통해 차로별 속도와 전체 구간 평균속도를 비교해 보았다.

일반적인 경우, 기존 검지방식의 교통정보는 공간전체의 평균속도 개념을 사용하고 있어 혼잡 등 교통류 변화상황에서 정확한 정보를 제공하기에는 한계가 있다. 다음의 <그림 69>와 같이 라이다 데이터를 이용하면 차로별로 속도차이를 바로 비교할 수 있는 장점이 있다.

경부선 1차로의 경우(맨위 진한 파란색)는 버스전용차로이기 때문에 예외를 둔다고 해도 2차로(주황색)와 5차로(하늘색)는 약 30km/h정도의 속도차이가 나고 있음을 확인할 수 있고, 특히 5차로 혼잡의 여파는 4차로(노란색)에도 영향을 주고 있음을 확인할 수가 있었다.

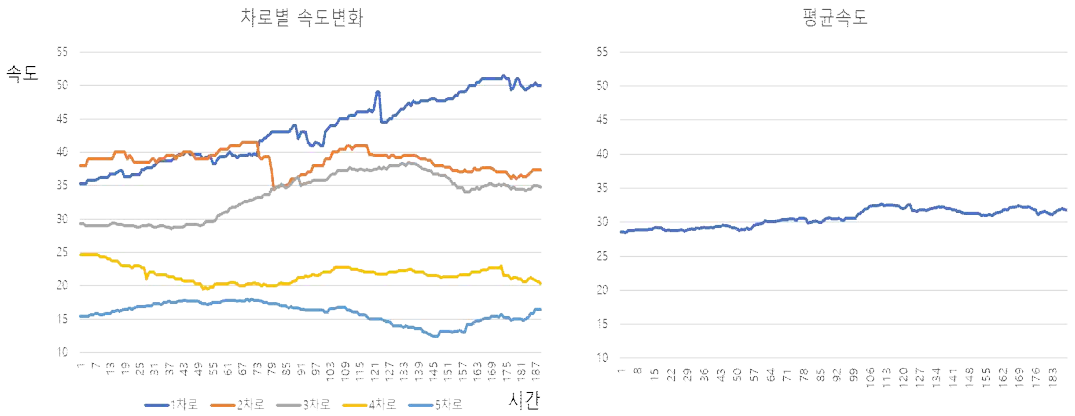

<그림 69> 정체시 차로별 속도와 전체구간 평균속도 그래프 비교

다음의 <그림 70>의 경우는 혼잡이 서서히 풀리고 있는 서행구간(양재IC 통과이후)에 대해서 차로별 속도와 전체 구간 평균속도를 비교해 보았다. 혼잡구간이후 속도가 급격히 증가하는 것을 확인할 수 있는데, 이러한 경우는 평균속도도 유사하게 증가되는 패턴을 보여주고 있음을 알 수가 있었다. 그럼에도 불구하고, 여전히 차로별 속도차이는 존재하는 것도 확인할 수가 있었다. 이러한 속도차이가 네비게이션 교통정보 제공시에 오차가 나타나는 원인 중 하나이다. 이를 보완하기 위해서는 연속적인 차로별 정보수집 등 종합적인 정보제공이 필요하며, 이러한 정보수집을 위해서는 이동검지체계(MDS) 방식이 도입되어야 한다.

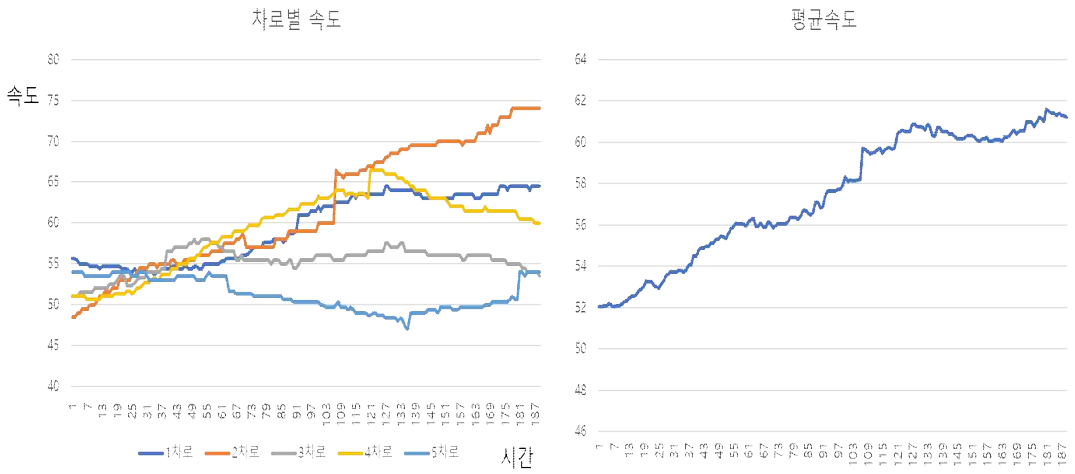

<그림 70> 서행구간 차로별 속도와 전체구간 평균속도 그래프 비교

다음의 <그림 71>의 경우는 경부선 서울방향 판교IC에서 반포IC까지의 평균속도를 나타내고 있다. 양재IC 전방부터 정체가 시작되고 있음을 속도 그래프를 통해 직관적으로 확인할 수가 있다. 또한 <그림 72>의 경우 차로별로 속도변화를 한눈에 확인할 수가 있는데 1차로는 버스전용차로로 인해 유사한 속도변화를 보여주고 있으며, 나머지 차선의 경우는 진출입로 부근에서 속도가 감소하는 등 교통여건에 따라 미시적으로 변화하고 있는 현상을 확인할 수가 있었다.

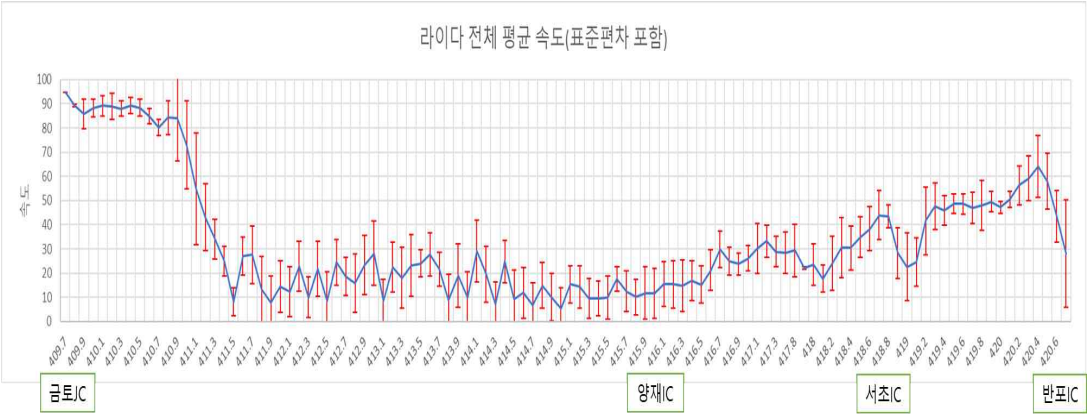

<그림 71> 라이다 전체차로 속도 그래프(판교→반포)

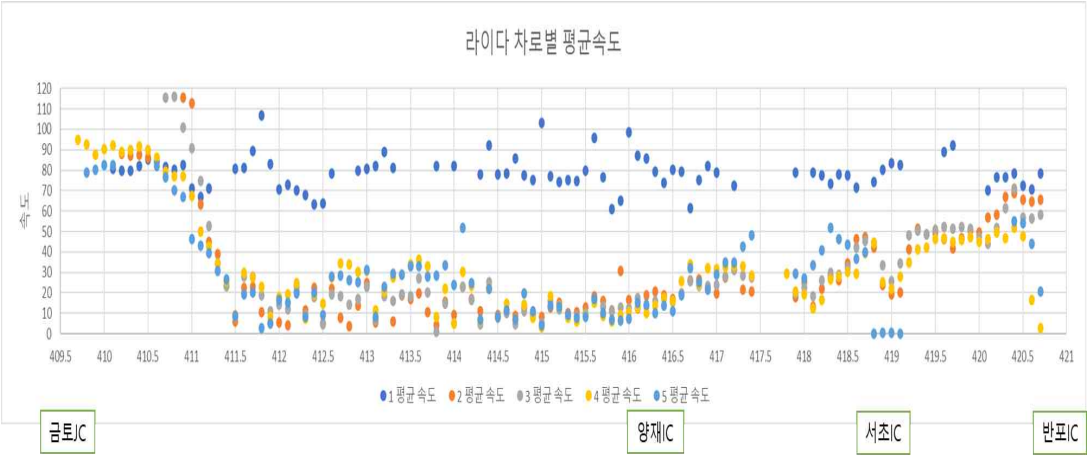

<그림 72> 라이다 차로별 속도 그래프(판교→반포)

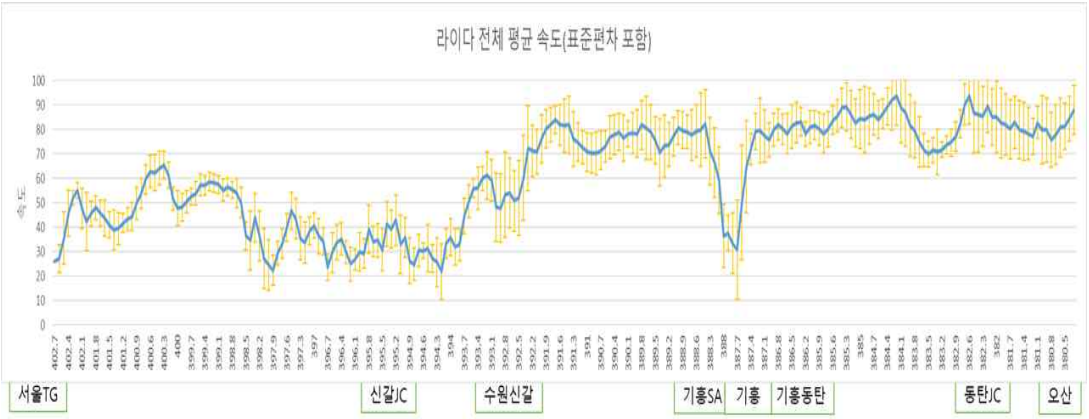

<그림 73> 라이다 전체차로 속도 그래프(판교→오산)

나. 차로별 밀도와 전체밀도 비교

다음의 <그림 74>은 경부선 부산방향 판교IC에서 오산IC구간의 밀도 변화를 현장데이터 값으로 나타내었다. 서울요금소에서 서비스수준 F로 정체구간을 나타내던 구간은 점차 남쪽으로 이동하면서 정체가 해소되고 있음을 확인할 수 있다. 경부선 서울방향 판교-반포구간의 경우 <그림 75>처럼 금토분기점이후 지속적으로 정체되고 있음을 확인할 수 있었다.

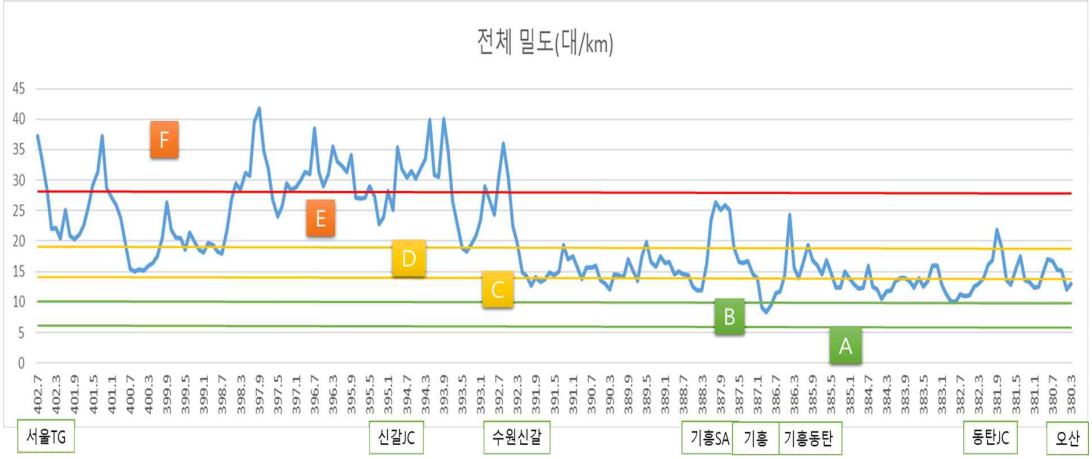

<그림 74> 밀도변화 그래프(판교→오산)

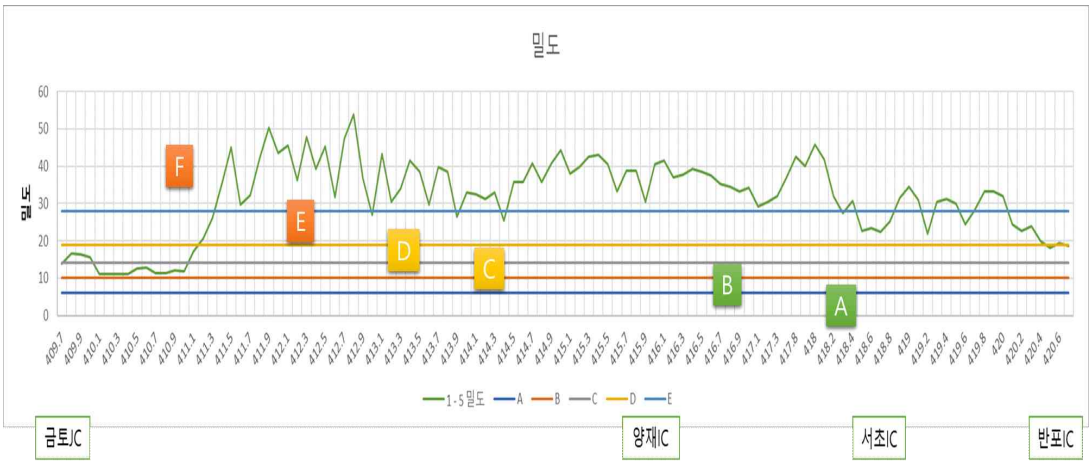

<그림 75> 밀도변화 그래프(판교→반포)

<그림 74>와 <그림 75>의 각 기준선은 다음의 [표 41]의 도로용량편람의 서비스수준(LOS)을 나타내고 있다.

[표 41] 교통용량편람 서비스수준(LOS) 기준표

서비스 수준	밀도(대/km)	구 분
A	≤6	녹색선
B	≤10	녹색선
C	≤14	황색선
D	≤19	황색선
E	≤28	적색선
F	〉28	적색선

<그림 76>은 각 차로별로 밀도변화를 전체적으로 나타내고 있다. 1차로의 경우 버스전용차로로 밀도가 매우 낮게 나타내고 있음을 알 수 있으며 <그림 77>과 같이 2차로에서 4차로는 전체평균과 유사한 패턴으로 밀도가 나타내고 있음을 확인할 수 있다. 5차로의 경우는 <그림 78>과 같이 IC, 분기점 등 변화구간에서 밀도가 증가하고 있음을 알 수가 있었다.

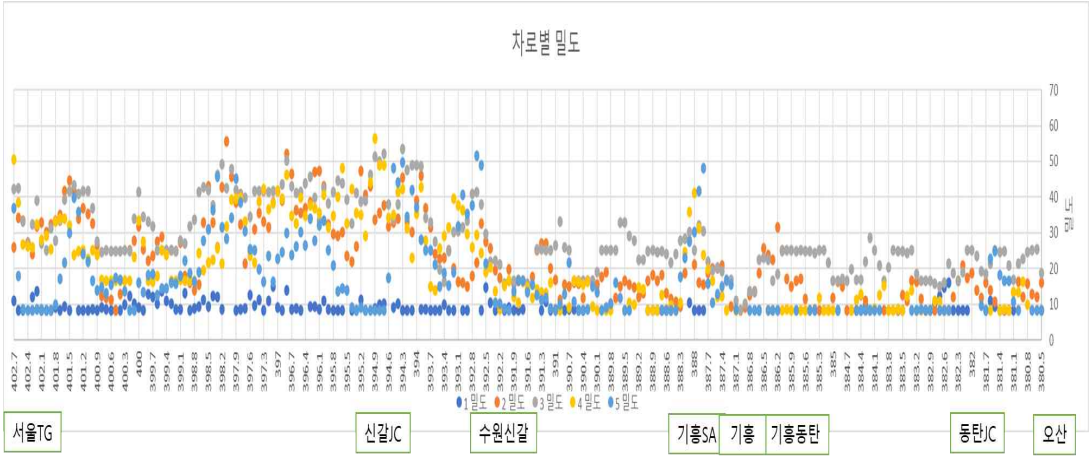

<그림 76> 차로별 밀도변화 그래프(판교→오산)

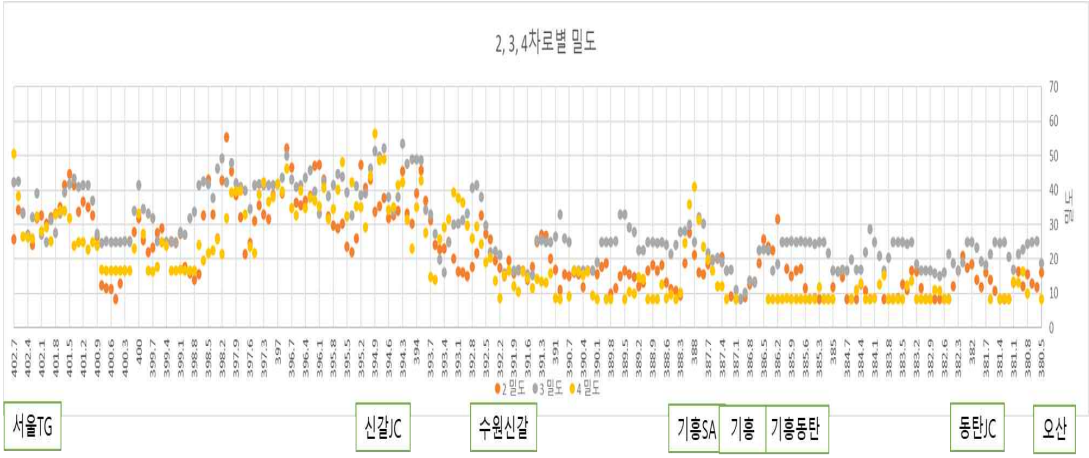

<그림 77> 2, 3, 4차로별 밀도변화 그래프(판교→오산)

<그림 78> 5차로 밀도변화 그래프(판교→오산)

다. 밀도와 평균속도 비교

다음의 <그림 79>는 경부선 부산방향 판교IC에서 오산IC구간까지 교통상황을 나타내는 밀도값과 라이다 속도를 그래프로 비교하였다. 밀도값은 아래쪽의 주황색으로 표시되며 라이다 속도는 파란색으로 표시되어 비교하였다. 이러한 비교를 통해 밀도값과 라이다 속도가 서로 역의 상관관계를 보여주고 있음을 확인할 수가 있다. 하지만 <그림 80>의 경우는 VDS속도와 밀도를 비교시 개략적인 추세만을 파악할 수 있었다.

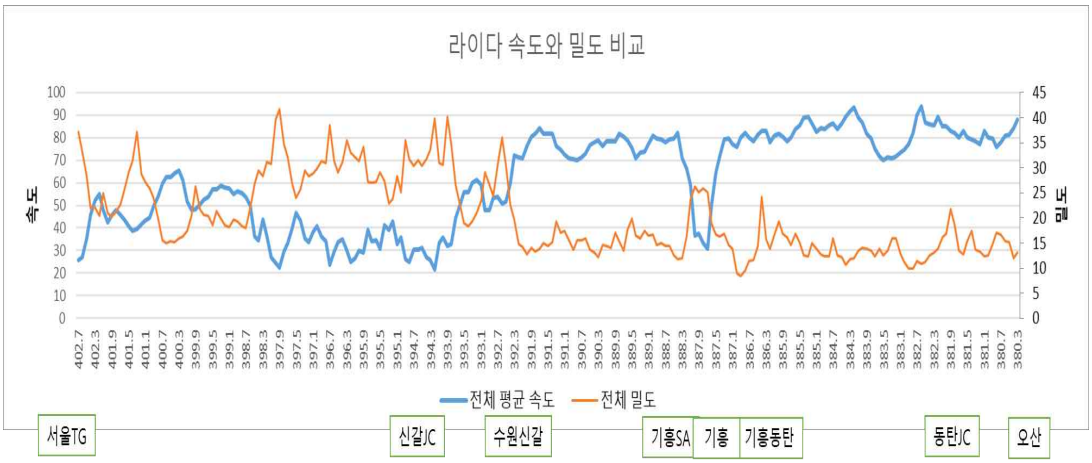

<그림 79> 밀도값과 라이다 속도 비교(판교→오산)

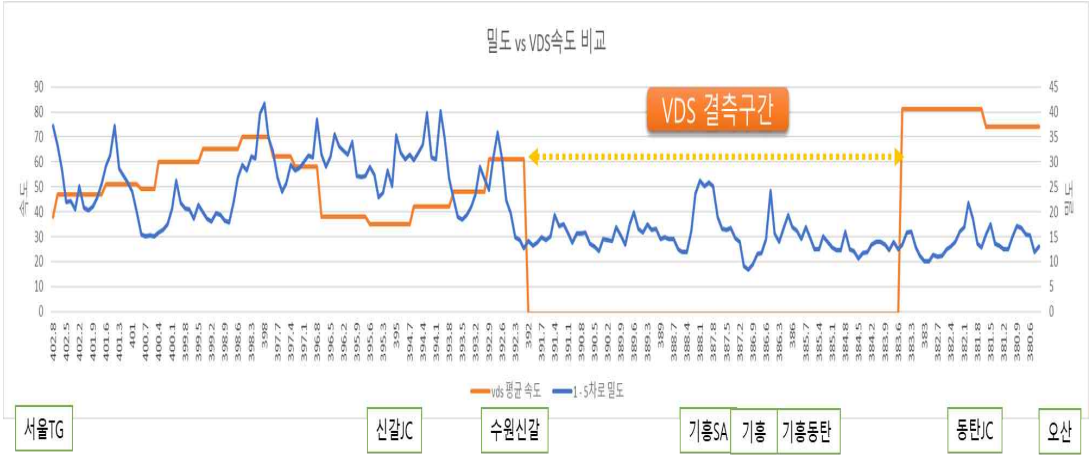

<그림 80> 밀도값과 VDS 속도 비교(판교→오산)

2. 기존검지방식과 비교분석

가. 지점검지기와 라이다 속도결과 비교

현장조사(22.12.09)를 실시한 경부선 부산방향 판교IC에서 오산IC까지 구간과 동일한 지점에서 VDS지점자료를 수집하여 비교 분석하였다. 고속도로 VDS 자료[27]는 일반적으로 약 1km 간격으로 설치되어 있으며 1

27) 한국도로공사 고속도로 공공데이터 포탈(http://data.ex.co.kr)

시간단위로 속도, 교통량 등의 정보를 제공해주고 있다. 하지만 좀 더 상세한 분석을 위해 5분 단위의 데이터를 요청 및 수집하여 비교하였다.

(1) 경부선 판교-오산구간 부산방향 비교

동일 시간과 구간에서 지점검지기와 라이다 결과를 비교하였다. 다음의 <그림 81>에서 화살표는 판교에서 오산까지 이동한 라이다 수집차량의 개략적인 통과궤적을 보여주고 있다.

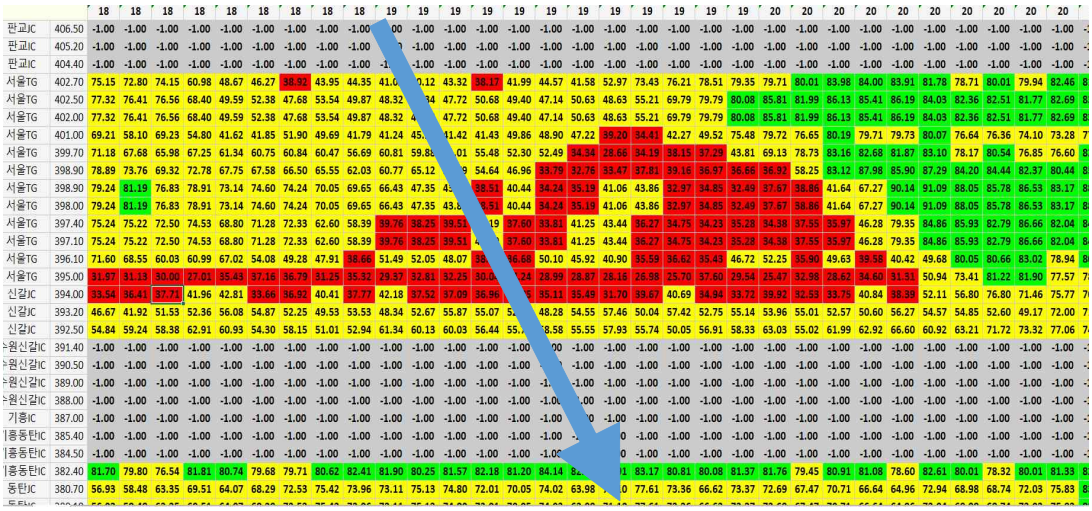

<그림 81> 판교-오산구간(22.12.9) 속도(VDS) 자료 및 이동경로

<그림 81>과 같이 VDS에서 노란색으로 표시된 부분은 속도 40~80km/h의 값을 의미한다. 적색으로 표시된 부분은 속도 40km/h 이하를 의미한다. 녹색으로 표시된 부분은 속도 80km/h 이상을 의미한다. 회색으로 표시된 부분(수원IC에서 기흥동탄IC)은 현재 결측구간으로 지점검지기의 손상(공사 등)으로 데이터가 취득되지 않는 구간이다.

실제로 데이터를 비교해 보았을 때 다소 차이가 발생하는 것을 확인할 수 있다. 지점 검지기는 해당 지점에서 통과된 차량을 대상으로 데이터를 전체차로에 대해 5분단위로 평균화한 것이기 때문에 지점 내의 세부구간에 대해서 정확한 속도 산출이 어렵다. 라이다 센서를 통해 도출된

속도 결과는 1초단위로 실측(GT : Ground Truth)에 의해 추출한 값이기 때문에 도로내의 정확한 속도값을 계산할 수 있었다.

위치	이정	19:05~10		19:10~15		19:15~20		19:20~25		19:25~30		19:25~30	
		VDS	LiDAR	VDS	LiDAR	VDS	LiDAR	VDS	LiDAR	VDS	LiDAR	VDS	LiDAR
서울TG	402.70	40.1	32.0										
서울TG	402.50	49.3	44.9										
서울TG	402.00	49.3	41.4	47.7	41.5								
서울TG	401.00			41.4	54.5								
서울TG	399.70			51.0	50.9								
서울TG	398.90			59.8	45.9								
서울TG	398.90			43.8	34.8								
서울TG	398.00			43.8	21.9	38.5	31.1						
서울TG	397.40					42.2	34.3						
서울TG	397.10					42.2	27.2						
서울TG	396.10					36.5	32.5	36.7	31.4				
서울TG	395.00							34.2	26.3				
신갈JC	394.00							30.9	40.1				
신갈JC	393.20							52.0	50.3				
신갈JC	392.50							55.8	71.8				
수원신갈IC	391.40							결측	75.6	결측	68.9		
수원신갈IC	390.50									결측	72.0		
수원신갈IC	389.00									결측	64.4		
수원신갈IC	388.00									결측	55.5		
기흥IC	387.00									결측	75.2		
기흥동탄IC	382.40											82.4	76.2
동탄JC	380.70											64.0	75.6

<그림 82> VDS와 라이다의 동일구간 속도결과 비교(판교→오산구간)

<그림 82>은 동일 시간과 구간이 매칭되는 VDS와 라이다의 속도만을 표시한 그림이고 다음 <그림 83>은 매칭되는 VDS와 라이다의 속도차이 값을 표시한 그림이다.

위치	이정	19:05~10	19:10~15	19:15~20	19:20~25	19:25~30	19:30~35
		Speed Difference	Speed Difference	Speed Difference	Speed Difference	Speed Difference	Speed Difference
서울TG	402.70	7.6					
서울TG	402.50	4.4					
서울TG	402.00	8.0	6.2				
서울TG	401.00		-13.1				
서울TG	399.70		0.1				
서울TG	398.90		13.9				
서울TG	398.90		9.0				
서울TG	398.00		21.9	7.4			
서울TG	397.40			7.9			
서울TG	397.10			15.0			
서울TG	396.10			4.8	5.3		
서울TG	395.00				7.9		
신갈JC	394.00				-0.2		
신갈JC	393.20				1.7		
신갈JC	392.50				-16.0		
수원신갈IC	391.40				결측	결측	
수원신갈IC	390.50					결측	
수원신갈IC	389.00					결측	
수원신갈IC	388.00					결측	
기흥IC	387.00					결측	
기흥동탄IC	382.40						6.3
동탄JC	380.70						-11.6

<그림 83> VDS와 라이다의 구간별 속도 차이(판교→오산구간)

실제로 <그림 82>의 결과를 보았을 때 차량이 움직인 경로를 알 수 있다. 시간에 따른 지점별 속도를 알 수가 있는데 서울TG 통과후 구간이나 신갈IC부근으로 진입할 때 지점검지기와 가장 속도차이가 큰 것을 확인할 수 있다. 실제로 지점 검지기에서는 구간의 평균으로 속도를 계산하기 때문에 진출입로 부분처럼 교통류가 불안정한 상황에서는 정밀한 속도 측정이 어렵다는 것을 알 수 있다. <그림 83>에서는 녹색으로 표시된 부분은 속도 5km/h 이내의 차이를 의미한다. 노란색 부분은 5~10km/h 이내의 차이를 의미한다. 적색부분은 10km/h 이상의 차이를 의미한다. 결측된 값을 제외하면 녹색 5건, 노란색 8건, 적색 7건으로 녹색을 제외한 수치를 오류라고 정의하였을 때, 오류율은 75%에 이르는 것을 알 수 있다. 본 실험에서는 지점검지기와 동일 구간을 비교하였을 때 실측값과는 상당한 차이가 있다는 것을 확인할 수 있었다. 라이다 센서 데이터를 활용한 교통정보는 그 구간을 실제 통과한 자료임으로 지점검지기보다 좀 더 세밀하고 정확한 데이터를 제공이 가능한 것을 확인할 수 있었다.

(2) 경부선 판교-양재구간 서울방향 비교

이번 데이터 비교는 경부선 판교-양재구간 서울방향의 VDS 데이터와 라이다 데이터의 비교를 실시하였다. 현장 자료수집은 판교IC에서 반포IC까지 실시하였으나 한국도로공사에서 관리하는 구간이 양재IC까지라 VDS자료가 양재IC까지만 존재하기 때문에 VDS 속도비교는 양재IC까지만 시행하였다. 현장조사 자료(5회) 중 가장 혼잡이 심했던 22년 9월 20일(화) 15시대의 자료를 대표자료로 이용하여 혼잡상황에서의 교통상태의 변화모습을 살펴보았다. 다음의 <그림 84>에서 화살표는 라이다 수집차량의 개략적인 통과궤적을 나타낸다.

		14	14	14	14	14	14	15	15	15	15	15	15	15	15	15	15	15	15	15	15	16	16	16	16	16
금토JC	415.30	25.90	23.95	22.10	26.25	23.54	26.80	25.60	19.40	20.76	24.23	24.60	23.43	27.94	25.24	30.97	[illegible]	27.67	27.94	25.92	36.24	30.28	33.14	27.23
금토JC	414.30	31.94	29.87	28.57	22.61	29.97	27.61	24.84	25.42	29.90	24.47	25.35	27.92	23.00	27.57	[illegible]	30.53	28.24	35.15	33.59	33.08	36.49	28.82	32.76
금토JC	413.20	30.53	27.59	27.88	27.91	30.59	32.85	27.20	25.73	31.28	29.24	28.66	29.35	27.57	[illegible]	30.38	26.44	32.11	33.36	36.22	32.30	36.99	38.30	36.50
금토JC	412.30	31.35	32.74	30.26	25.98	28.04	29.26	31.43	28.73	27.93	35.17	31.52	32.85	[illegible]	30.91	29.05	28.95	30.03	34.30	31.63	32.41	33.43	34.34	32.57
금토JC	411.60	94.34	86.20	31.44	30.02	27.28	30.84	31.31	30.92	26.05	31.66	35.26	[illegible]	23.01	25.23	29.79	26.82	29.16	29.93	41.69	51.26	73.45	65.89	71.39
금토JC	410.30	75.45	76.22	77.90	76.94	78.77	78.10	79.36	78.19	78.35	77.86	[illegible]	78.88	79.65	79.75	79.59	79.73	78.39	78.30	79.06	79.12	79.79	78.41	77.40
판교JC	408.20	85.15	85.67	85.09	87.46	88.05	90.30	89.21	84.88	88.75	[illegible]	86.59	90.28	89.44	92.56	94.09	90.67	90.11	88.12	90.94	87.56	87.11	90.07	88.95
판교JC	406.50	81.04	83.83	81.08	82.39	79.27	79.11	76.04	66.07	[illegible]	50.70	59.17	47.16	55.55	53.08	53.17	52.91	61.22	54.49	55.64	66.77	54.94	58.15	48.92

<그림 84> 판교-양재구간(22.9.20) 속도(VDS) 비교

다음의 <그림 85>에서 <그림 88>은 동일구간에서 취득한 일자별 VDS 시공도 자료이다. 일반적으로 경부선 서울방향으로 금토분기점을 지나 언덕(달래내고개)부터는 상습적으로 정체가 발생되고 있음을 확인할 수 있었다.

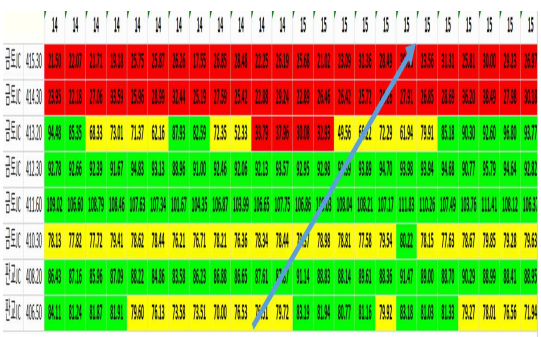

<그림 85> 판교-양재구간(22.9.21) 속도(VDS) 비교

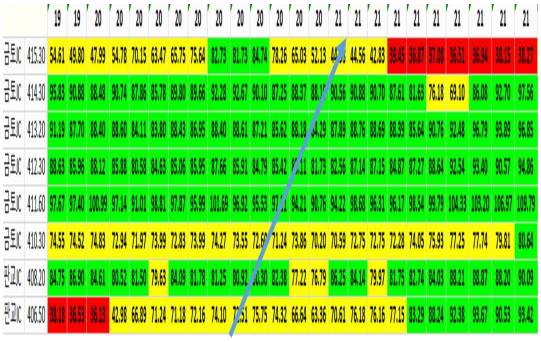

<그림 86> 판교-양재구간(22.9.23) 속도(VDS) 비교

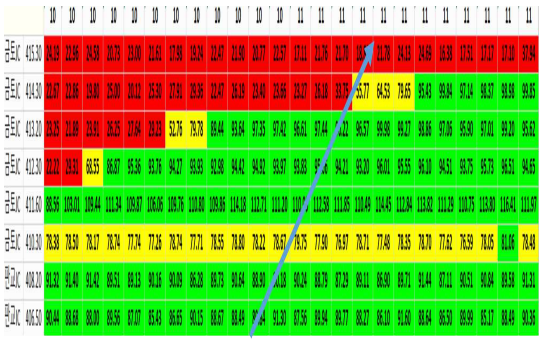

<그림 87> 판교-양재구간(22.9.26) 속도(VDS) 비교

<그림 88> 판교-양재구간(22.9.27) 속도(VDS) 비교

다음의 <그림 89>는 경부선 서울방향 금토분기점에서 양재IC 구간까지 VDS와 라이다 속도를 100m 단위구간으로 비교한 그래프이다. <그림 90>은 금토분기점 통과 후 양재IC 전방에서 속도가 급격히 감소하는 모습을 보였던(<그림 89>의 붉은색 동그라미 점선) 구간을 세부적으로 보여주고 있는데 특히 VDS의 경우는 갑자기 50km/h 이상 계단형으로 감소하고 있음을 보여주고 있다. 라이다 속도정보의 경우 어느 구간에서 정체가 발생하고 있으며 정체가 어떻게 변화되고 있는지 보여줄 수 있었다.

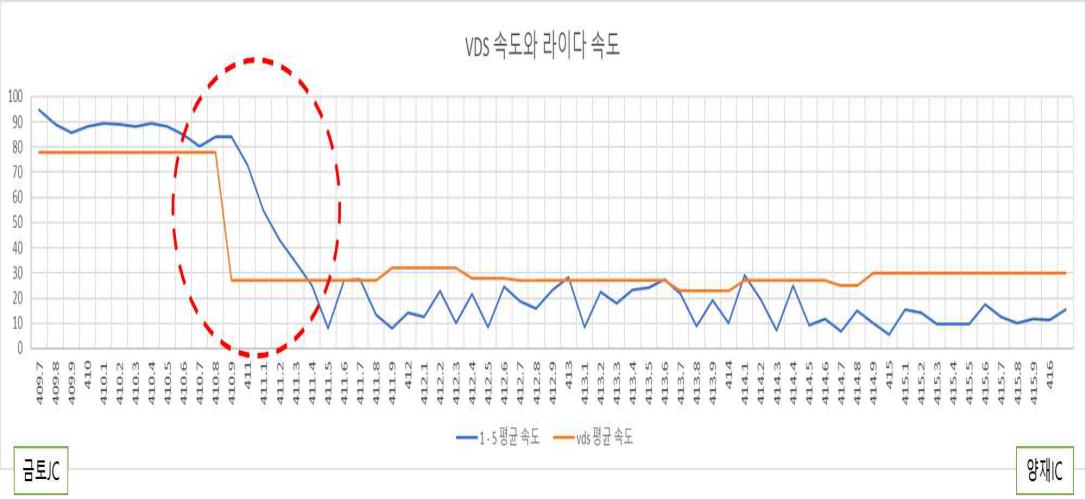

<그림 89> VDS와 라이다의 동일구간 속도결과 비교 그래프

<그림 90> VDS와 라이다의 속도변화구간 상세 비교 그래프

나. 구간검지기(양재-반포)와 라이다 속도결과 비교

앞서 언급하였듯이 경부고속도로 양재IC에서 한남대교 구간은 현재 한국도로공사의 관리가 아닌 서울시설공단에서 관리하고 있다. 따라서 양재IC-한남대교구간에 대해서는 VDS 자료를 사용할 수가 없어서 구간검지 방식으로 교통정보 등을 전문적으로 수집하고 있는 벤처기업인 ㈜모토브(MOTOV)[28]의 택시(Taxi) 운행기록데이터를 사용하여 구간속도값을 라이다 교통정보와 비교하였다. 구간검지 방식의 경우도 5분단위의 자료로 특정구간을 통과한 택시의 평균값을 사용하였으며 구간단위는 3개구간(양재-서초, 서초-반포, 반포-한남대교)의 정보를 수집하였다. 이 중에서 동일 구간의 자료를 비교할 수 있는 양재IC에서 반포IC구간의 속도정보를 상호 비교하였다. 이 구간은 <그림 91>의 24시간 시공도처럼 새벽시간대를 제외한 거의 하루종일 상습정체가 발생하는 대표적인 주요 교통혼잡구간 중에 한 곳이다.

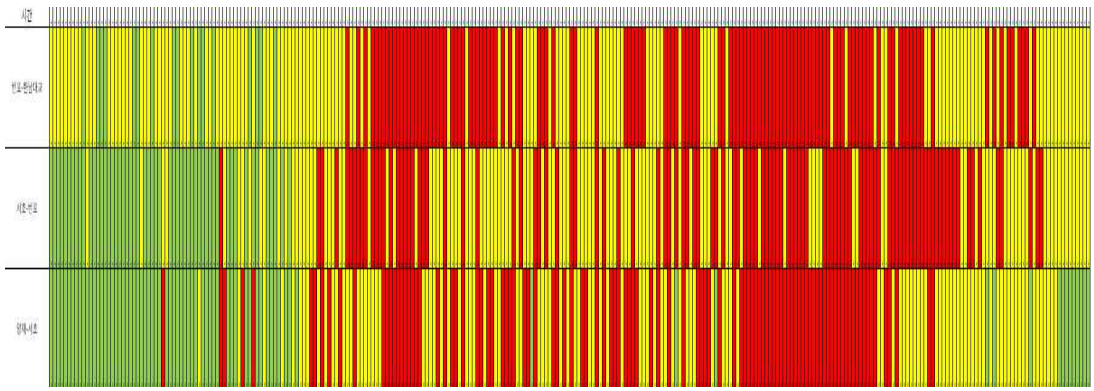

<그림 91> 양재-한남대교구간(22.9.20) 24시간 구간검지 속도 시공도

다음 <그림 92>의 화살표는 라이다 수집차량의 개략적인 통과궤적을 나타낸다.

28) 모토브는 서울시, 인천시 등에서 택시(2,000여대)를 이용하며 차량지붕에 LED 전광판을 달고 운행하며 운행시 각종 센서를 이용하여 차량속도, 미세먼지 등 다양한 정보를 수집하고 있음

구간	15	15	15	15	15	15	15	16	16	16	16	16	16	16	16	16	16	16	16	17	17	17	17	17	17	17	17
반포-한남대교	39	28	59	27	17	21	30	39	28	27	24	23	26	24	32	33	32	23	28	23	23	40	25	31	32	27	26
서초-반포	50	25	44	67	53	31	54	21	38	34	31	55	27	35	24	29	30	-1	47	19	12	11	32	23	13	49	54
양재-서초	35	51	49	70	-1	54	38	18	31	34	38	39	37	32	33	36	31	0	26	20	30	12	13	24	35	29	-1

<그림 92> 구간속도(22.9.20) 비교(판교→반포구간)

다음의 <그림 93>는 경부선 서울방향 양재IC에서 반포IC까지 구간검지방식 속도와 라이다 속도를 비교한 그래프이다. 구간검지 방식의 경우 IC단위의 속도제공으로 속도변화의 반영이 민감하지 않게 나타나고 있음을 확인할 수 있다. 라이다 속도데이터는 양재IC이후 속도가 지속적으로 증가하고 있음을 보여주고 있으며 특히 서초IC 통과 후(버스전용차로 해제)에는 속도가 많이 증가하고 있음을 확인할 수가 있다. 또한 반포IC이후 한남대교 구간까지 정체로 인해 다시 속도가 감소하고 있음을 확인할 수가 있다.

<그림 93> 구간속도와 라이다 속도 비교 그래프(판교→반포구간)

다음의 <그림 94>은 앞서 지점검지기(VDS) 속도자료와 구간검지 속도자

료를 연결하여 하나의 비교 데이터로 만들어 보았다. 양재IC부근에서 단절이 잠시 발생하기는 하나, 두 가지 데이터 모두 동일한 속도(30km/h)를 나타내고 있어 유사한 성능을 보여주는 것으로 판단되었다.

<그림 94> 지점검지 자료와 구간검지 자료 연결 그래프(판교→반포구간)

다음의 <그림 95>는 앞서 지점(구간)검지기 속도자료와 라이다 속도자료를 비교해 보았다. 앞서 검토한 것과 같이 라이다 방식은 이정별로 세부적인 소통변화를 알 수 있으며 운전자와 관리자에게 더 합리적 의사결정이 가능하도록 지원해 줄 수가 있는 자료임을 보여주고 있다.

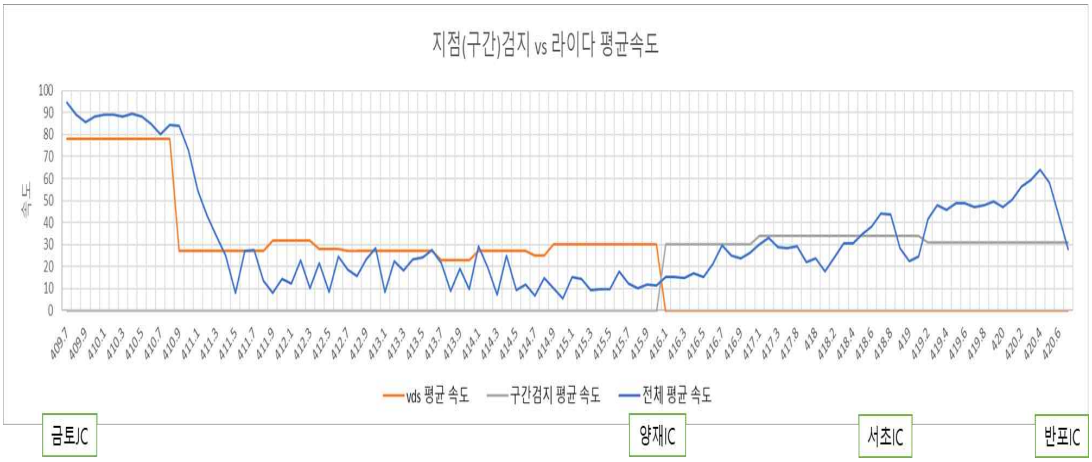

<그림 95> 지점(구간) 속도와 라이다 속도 비교 그래프(판교→반포구간)

3. 고속도로 교통안전성 모니터링

고속도로 안전성 모니터링은 안전대리변수인 MTTC와 속도편차에 따른 위험도를 기준으로 안전성을 평가하였으며 실제 현장 사고데이터와도 비교해 보았다.

가. 안전대리변수(MTTC)를 통한 안전성 진단

(1) MTTC 발생건수 비교

다음의 <그림 96>은 경부선 부산방향 판교에서 오산IC구간의 MTTC 발생건수를 통해 위치별 안전성을 비교해 보았다. 그 결과 분기점과 IC 부근에서 MTTC 발생이 빈번하게 나타나고 있음을 확인할 수 있다. 하지만 이것만을 통해서는 구체적인 사고의 원인이나 위험성을 단정하기에는 한계에 있었다.

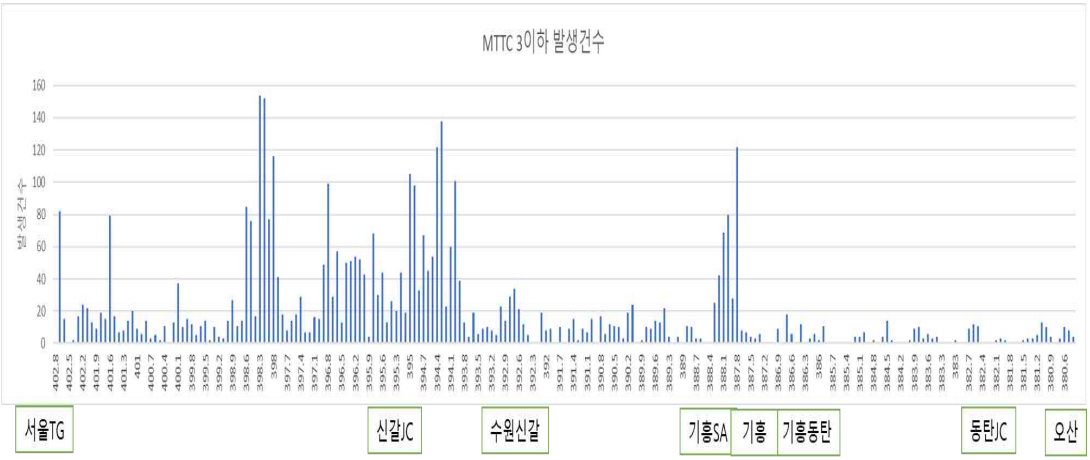

<그림 96> MTTC 3초이하 발생건수 현황(판교→오산구간)

다음의 <그림 97>에서는 상시 정체구간인 경부선 서울방향 판교에서 반포IC구간의 MTTC 발생건수를 통해 위치별 안전성을 비교해 보았다.

그 결과 지속적인 혼잡구간인 해당구간에서는 IC 등의 구간에서도 MTTC 발생이 뚜렷하게 증가되어 나타나지는 않고 있음을 확인할 수 있었다.

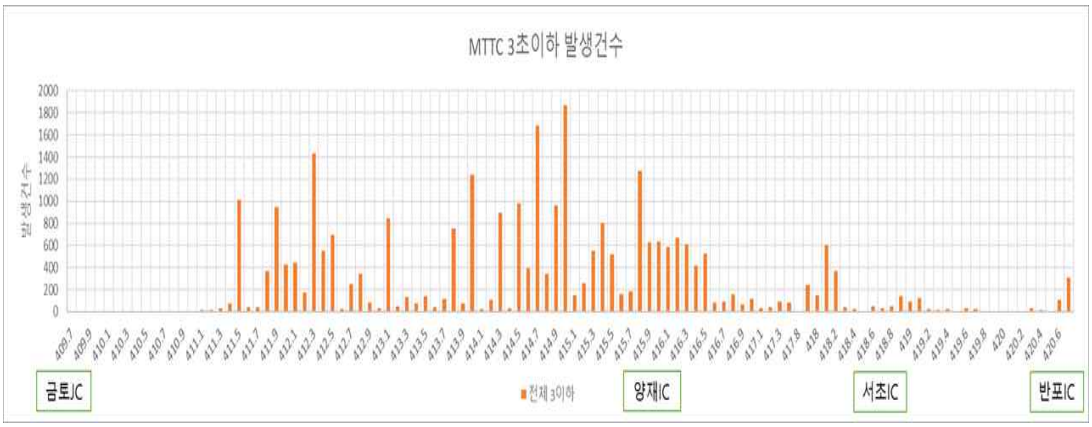

<그림 97> MTTC 3초이하 발생건수 현황(판교→반포구간)

(2) MTTC 발생구간 원인분석

앞서 MTTC 위험상황 발생건수만을 통해서 명확한 안전성 평가가 한계가 있었음으로 이번에는 속도(라이다, VDS), 밀도 등 다양한 요소를 고려하여 검토해 보았다.

다음의 <그림 98>는 경부선 부산방향 판교에서 오산IC구간의 밀도변화를 현장데이터 값과 MTTC를 통한 위험상황 발생건수와 비교하였다. 그 결과 그래프에서 확인할 수 있듯이 일반적으로 밀도값이 상승하면 위험 발생건수도 증가하고 있는 상황임을 확인할 수가 있었다. 또한 밀도가 높은 상황에서 MTTC 발생건수도 높은 수준임을 확인할 수가 있었다.

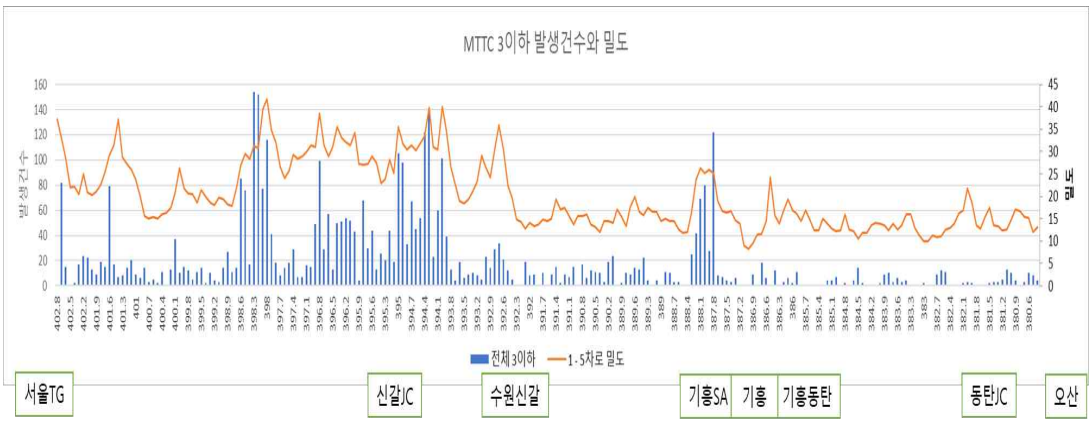

<그림 98> 밀도와 MTTC 3초이하 발생건수 비교(판교→오산구간)

다음의 <그림 99>에서도 역시 밀도가 높은 상황에서 MTTC 발생건수도 높은 수준임을 확인할 수가 있다.

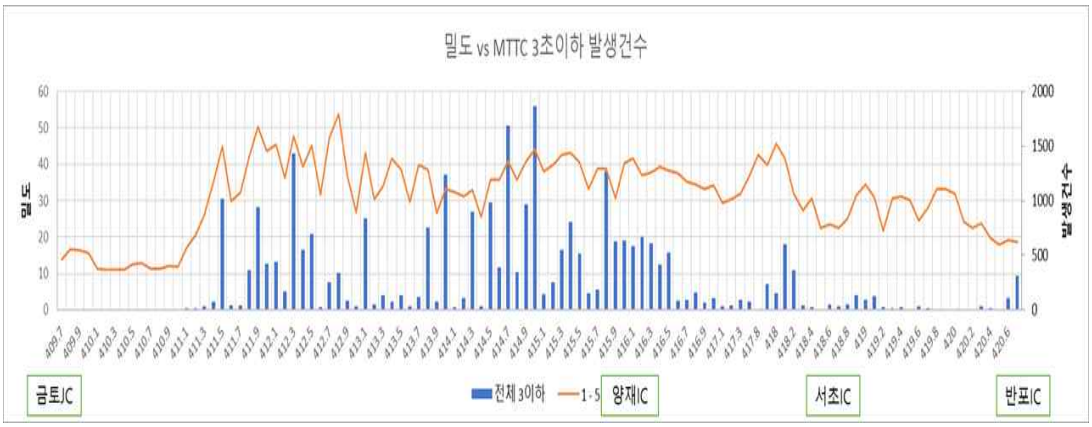

<그림 99> 밀도와 MTTC 3초이하 발생건수 비교(판교→반포구간)

다음의 <그림 100>은 경부선 부산방향 판교에서 오산IC구간의 평균속도와 MTTC의 위험상황 발생건수와 비교하였다. 평균속도와 위험상황 발생건수의 관계는 평균속도가 감소하는 상황에서 위험발생건수가 증가하고 있음을 확인할 수가 있었다. 이는 실제 도로의 운행상황을 살펴본 것과 동일한 경향을 보여주고 있음을 알 수가 있었다.

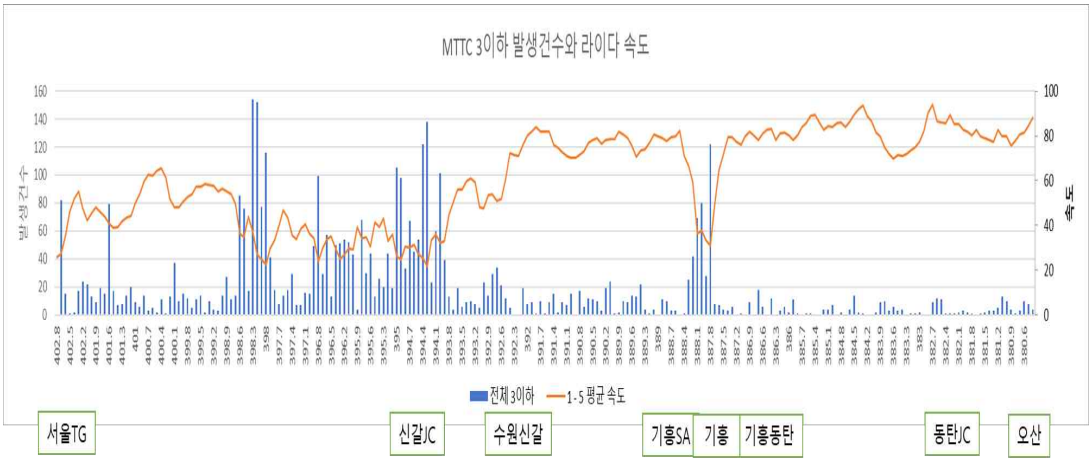

<그림 100> 라이다 속도와 MTTC 발생 건수 비교(판교→오산구간)

혼잡구간인 <그림 101>에서도 역시 평균속도가 급격히 감소한 상황에서 위험발생건수가 증가하고 있음을 확인할 수가 있었다.

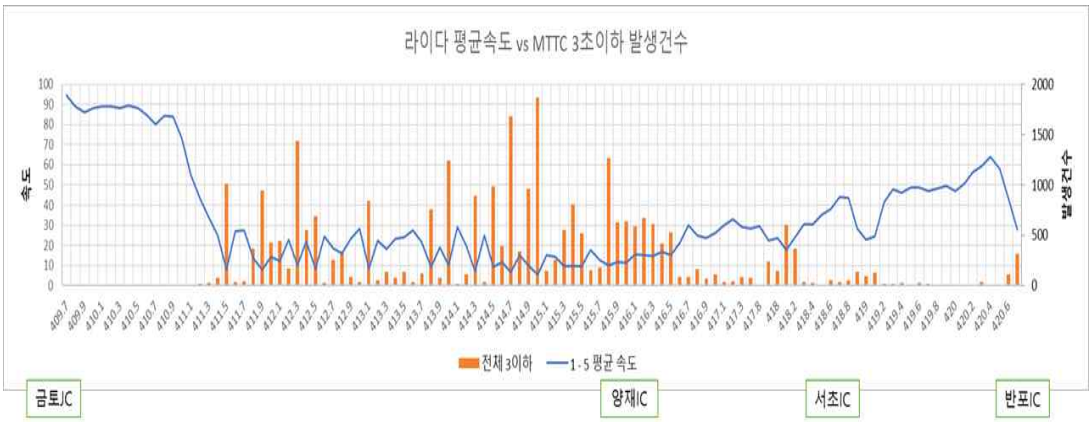

<그림 101> 라이다 속도와 MTTC 발생 건수 비교(판교→반포구간)

다음의 <그림 102>은 경부선 부산방향 판교에서 오산IC구간의 VDS 평균속도와 MTTC의 위험상황 발생건수와 비교하였다. VDS 평균속도와 위험상황 발생건수의 관계는 특별한 상관관계가 존재하지 않는 것처럼 보인다. 이러한 경향은 <그림 103>와 같이 경부선 서울방향 판교IC에서 반포IC의 비교 그래프에서도 나타나고 있다.

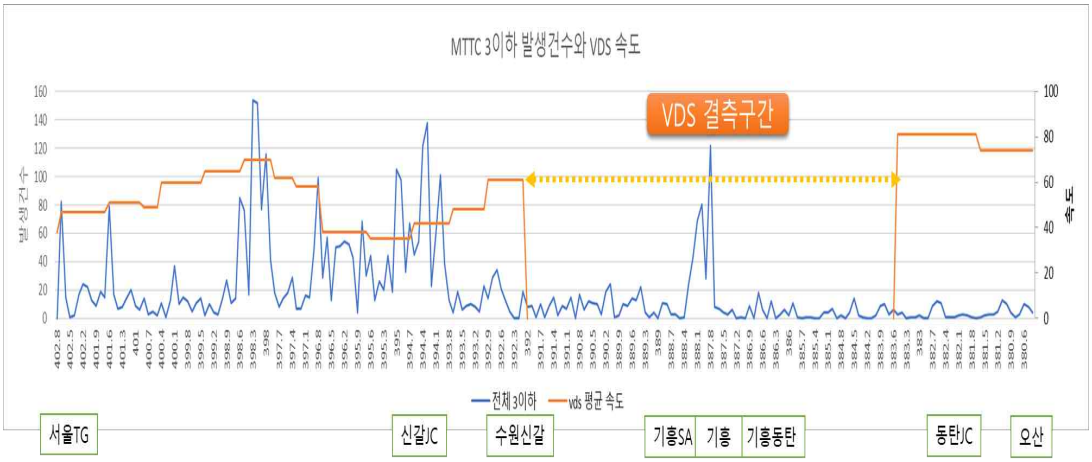

<그림 102> VDS 속도와 MTTC 발생 건수 비교(판교→오산구간)

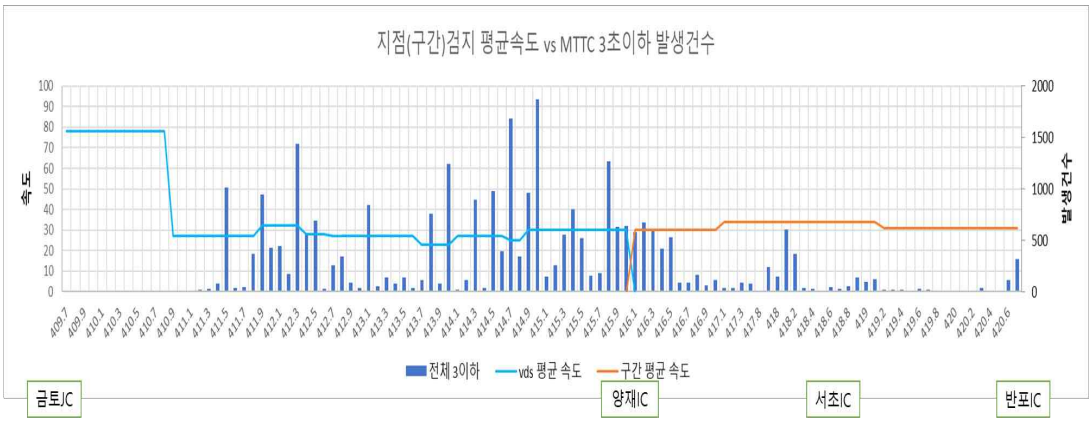

<그림 103> VDS 속도와 MTTC 발생 건수 비교(판교→반포구간)

나. 속도편차 기준 안전성 평가

앞서 관련논문 선행연구결과에 따라 속도분산이 10mile/h(16km/h) 이상인 경우와 표준편차가 8km/h 이상인 경우를 계량적인 위험구간으로 선정하였다. 특히 전체 차로별 표준편차가 8km/h 이상인 경우를 안전성에 영향을 주는 것으로 판단하여 위험구간으로 설정하였다[37].

고속도로 전체구간에 대해서 속도 표준편차를 산정해보면 [표 42]과 같이 안전성평가 8km/h 기준이하(판교-오산구간 : 7.82km/h 판교-반포구간 : 7.42km/h)로 나타나는 것으로 확인되었다. 하지만 버스전용차로를 포함할 경우는 혼잡 정도에 따라 표준편차가 증가(약 0.9~1.7km/h)하는 것도 확인할 수 있었다.

[표 42] 버스전용차로 포함여부에 따른 구간전체 속도 표준편차 비교

구 분	판교-오산구간	판교-반포구간
버스전용차로 포함	8.72	9.15
버스전용차로 제외	7.82	7.42

다음의 <그림 104>은 경부선 부산방향 판교IC에서 오산IC구간의 속도 표준편차와 안전성 평가기준인(8km/h)과 비교한 그래프이다. 일반적으로

분기점이나 IC부근에서 표준편차가 증가하고 있고 특히 위험구간 평가 임계기준을 상회하는 것을 확인할 수가 있었다.

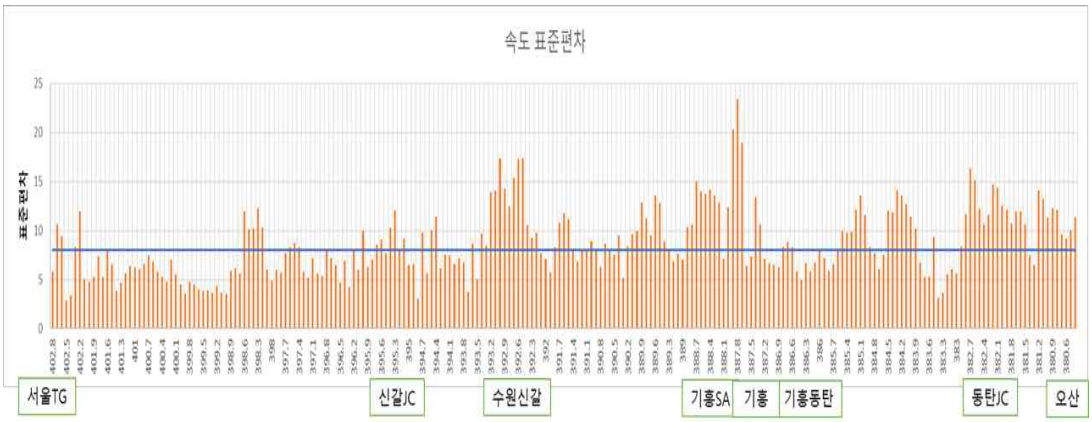

<그림 104> 라이다속도 표준편차 그래프(판교→오산구간)

다음 [표 43]은 위험구간 기준 상회하여 위험구간에 포함되는 구간의 비율을 보여주고 있다. 위험비율이 높은 구간을 살펴보면 후미구간 혼잡이 발생하는 수원신갈IC 등 진출로 구간에서 위험이 높음을 확인할 수가 있었다.

[표 43] 표준편차 안전성평가 임계기준(8km/h)이상 위험구간 비율

구 분	서울TG-신갈JC	신갈JC-수원신갈	수원신갈-기흥	기흥-기흥동탄	기흥동탄-동탄JC	동탄JC-오산
구간길이(km)	7.8	2.6	5.2	0.7	4.2	1.9
표준편차 기준이상(km)	2.1	1.4	3.5	0.3	2.3	1.7
위험구간비율(%)	27	54	67	43	55	89

<그림 105>는 경부선 서울방향 판교IC에서 반포IC구간의 속도 표준편차와 안전성 평가기준인(8km/h)과 비교한 그래프이다. 상습정체구간으로 표준편차가 평가기준을 상회하고 있으며 특히 속도변화구간에서 표준

편차가 증가하는 것을 확인할 수 있었다.

<그림 105> 라이다속도 표준편차 그래프(판교→반포구간)

<그림 106>에서 <그림 110>까지는 경부선 서울방향 판교IC에서 반포IC구간의 차로별 속도 표준편차와 안전성 평가기준인(8km/h)과 비교한 그래프이다. 앞서 선행연구에서 차로별로 차로내의 속도분산 정도를 검토해봐야 한다는 연구결과에 따라 별도로 살펴보았다[99].

1차로의 경우는 버스전용차로라 속도편차는 크게 나타나지 않았다. 그 외 2-4차로는 일부 구간에서 편차가 크게 나타나고 있었으며 5차로의 경우는 진출 등으로 인해 혼잡이 발생하는 경우 편차가 크게 나타나고 있음을 확인할 수 있었다.

<그림 106> 1차로 속도 표준편차 그래프(판교→반포구간)

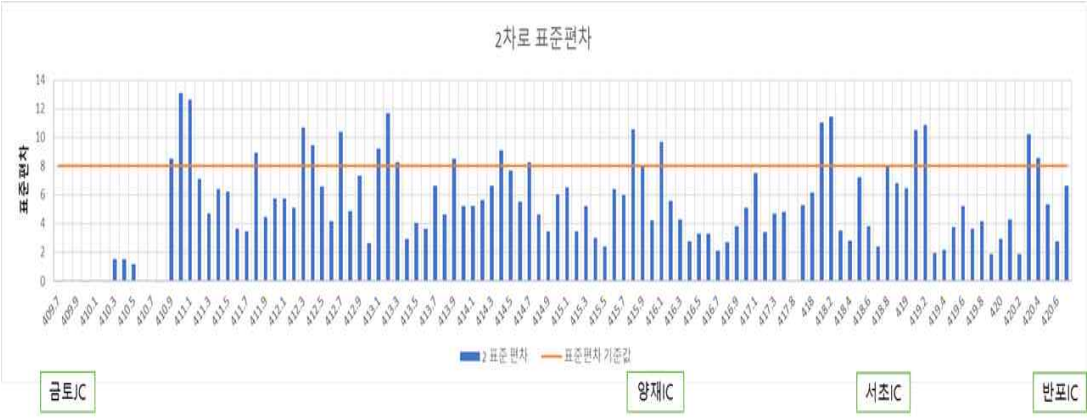

<그림 107> 2차로 속도 표준편차 그래프(판교→반포구간)

<그림 108> 3차로 속도 표준편차 그래프(판교→반포구간)

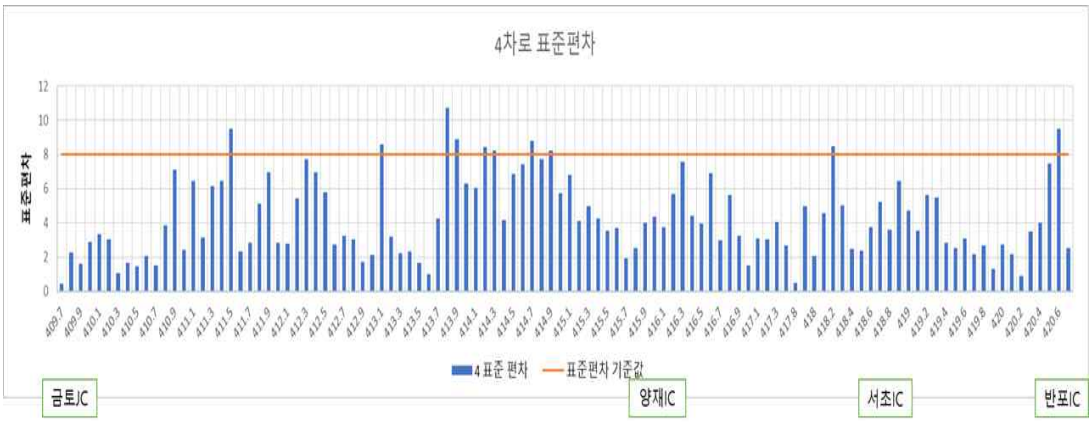

<그림 109> 4차로 속도 표준편차 그래프(판교→반포구간)

<그림 110> 5차로 속도 표준편차 그래프(판교→반포구간)

다음 <그림 111>에서는 혼잡구간에서 표준편차 발생의 원인이 경부선에서 운영하고 있는 버스전용차로 때문에 나타나는 것인지 확인해보기 위해 전용차로를 포함한 경우와 제외한 경우 두 가지를 비교해 보았다. 그 결과 전용차로를 포함한 경우 차로 전체의 표준편차가 크게 증가하고 있으며 추세에 있어서는 유사한 경향을 보였다.

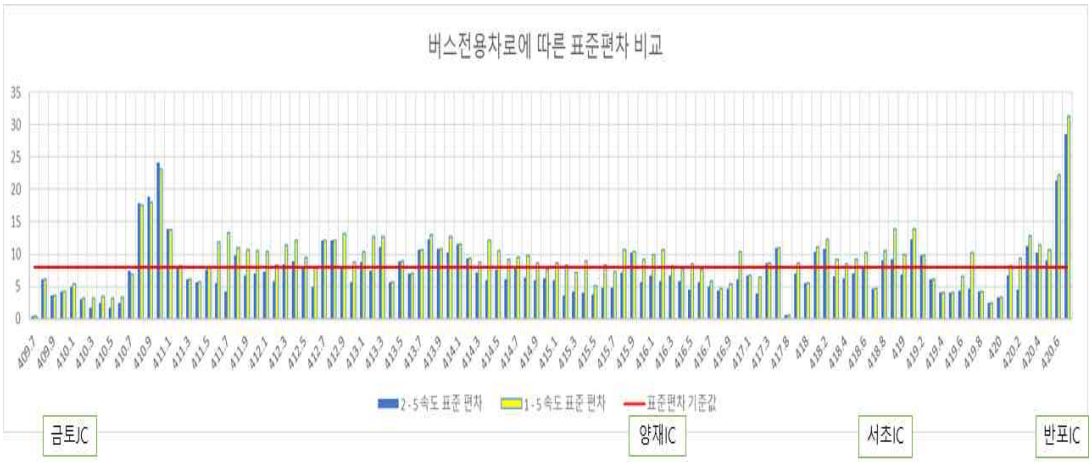

<그림 111> 버스전용차로를 고려한 표준편차 그래프 비교(판교→반포구간)

<그림 112>과 <그림 113>는 버스전용차로를 제외하고 속도와 밀도를 비교해 보았다. 비교결과 속도변화나 밀도변화가 급격히 일어나는 구간

에서 표준편차는 증가하고 있었고 특히 그 구간에서는 기준값(8km/h)이상을 초과하는 경우가 많음을 확인할 수 있었다.

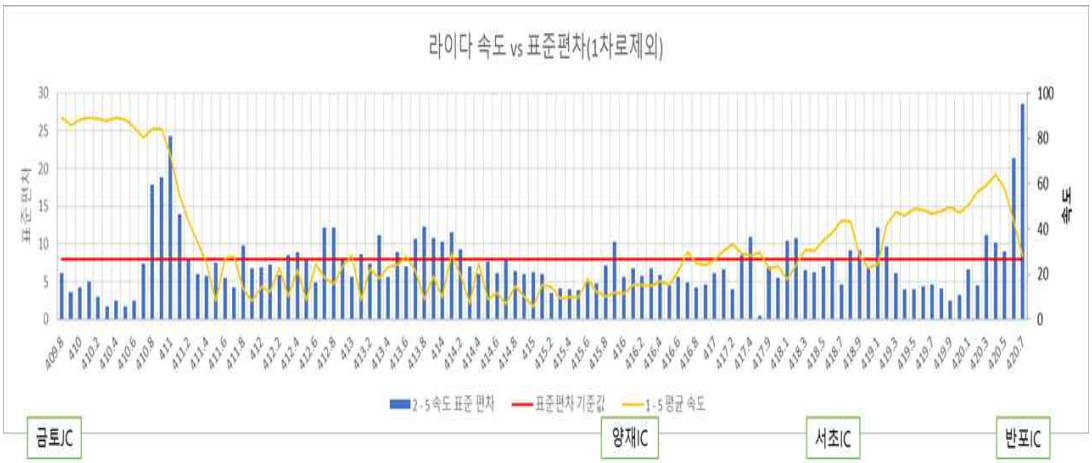

<그림 112> 버스전용차로를 제외한 표준편차와 속도 비교(판교→반포구간)

<그림 113> 버스전용차로를 제외한 표준편차와 밀도 비교(판교→반포구간)

다음의 [표 44]은 경부선 판교에서 반포구간에서의 위험구간에 포함되는 구간의 비율을 보여주고 있다. 상습정체구간인 판교에서 반포구간의 경우는 모든 구간에서 60%이상의 위험구간 비율을 나타내고 있다. 하지만 버스전용차로(1차로)를 제외하게 되면 20%이상 위험구간(표준편차를

고려한)이 감소하는 것을 확인할 수가 있다.

[표 44] 표준편차 임계기준(8km/h)이상 위험구간 비율(버스전용차로 포함비교)

구 분	금토JC-양재IC	양재IC-서초IC	서초IC-반포IC	금토JC-양재IC	양재IC-서초IC	서초IC-반포IC
	버스전용차로 포함(1-5차로)			버스전용차로 제외(2-5차로)		
구간길이(km)	64	23	21	64	23	21
표준편차 기준이상(km)	43	14	13	21	5	9
위험구간비율(%)	67	61	62	33	22	43

다. 실제 사고 사례와 비교

실제 동일구간에서 발생한 고속도로 사고사례와 MTTC 발생건수와 속도편차 결과를 비교하였다. 교통사고 데이터는 2013년부터 2019년까지 고속도로 경부선 부산방향 판교에서 오산구간에서 발생한 사고와 비교하였다. 7년간 총 129건의 교통사고가 발생하였으며 이로 인해 총 12명의 사망자와 50명의 부상자가 발생하였다. 사고발생 위치는 분기점이나 IC 구간에서 많이 발생하고 있음을 알 수 있었다. 특히, 서울신갈IC 부근에서 13건의 사고가 발생하여 단일 지점에서는 가장 높은 사고건수를 보여주고 있었다.

고속도로 서울방향 판교에서 양재구간의 경우는 7년간 총 38건의 교통사고가 발생하였고 이로 인해 총 11명의 사망자와 46명의 부상자가 발생하였다. 단, 양재IC에서 한남대교 구간은 세부적인 사고통계가 확인되지 않는 곳이라 제외하였다.

다음 <그림 114>에서 <그림 117>처럼 경부선 서울방향과 부산방향 모두에서 실제사고 건수와 밀도, 속도, 속도표준편차 그리고 MTTC발생건수와의 비교결과를 보면 뚜렷한 패턴이 확인되지는 않았다. 이는 실제 현장에서 수집된 혼잡 및 안전성 데이터가 한정적인 것이 주요한 이유로

판단된다. 향후 추가적으로 많은 데이터를 확보하고 누적하여 비교 및 모니터링한다면 실제사고와의 연관관계를 찾아낼 수 있는 것이라 기대하고 있다.

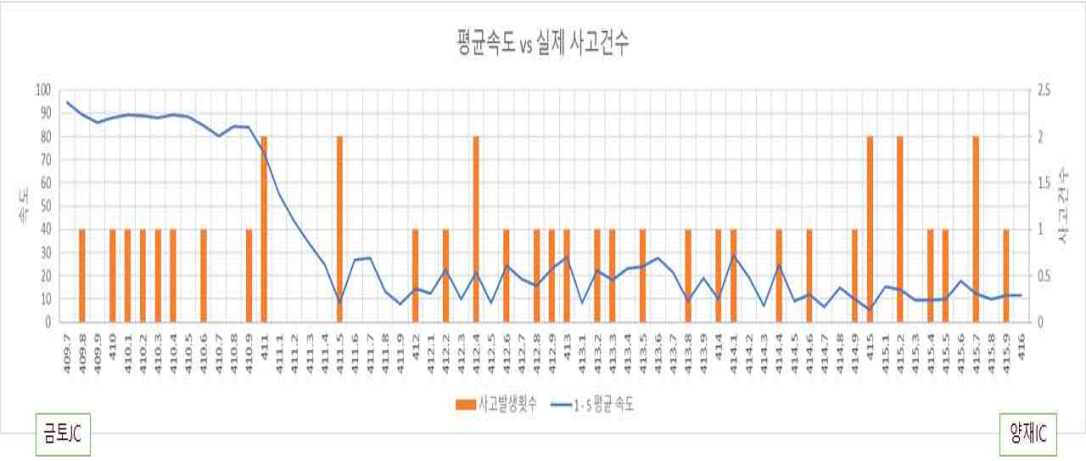

<그림 114> 평균속도와 실제사고 발생건수 비교(판교→반포구간)

<그림 115> 표준편차와 실제사고 발생건수 비교(판교→반포구간)

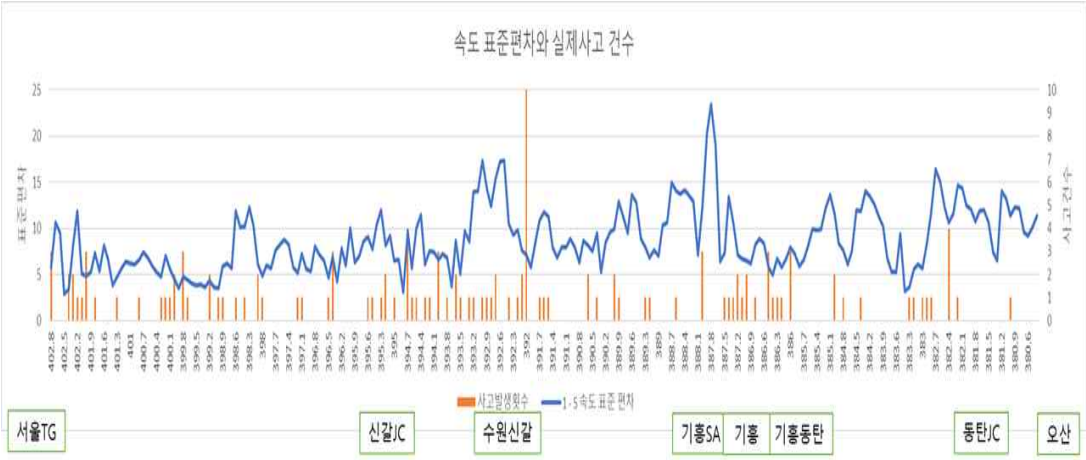

<그림 116> 표준편차와 실제사고 발생건수 비교(판교→오산구간)

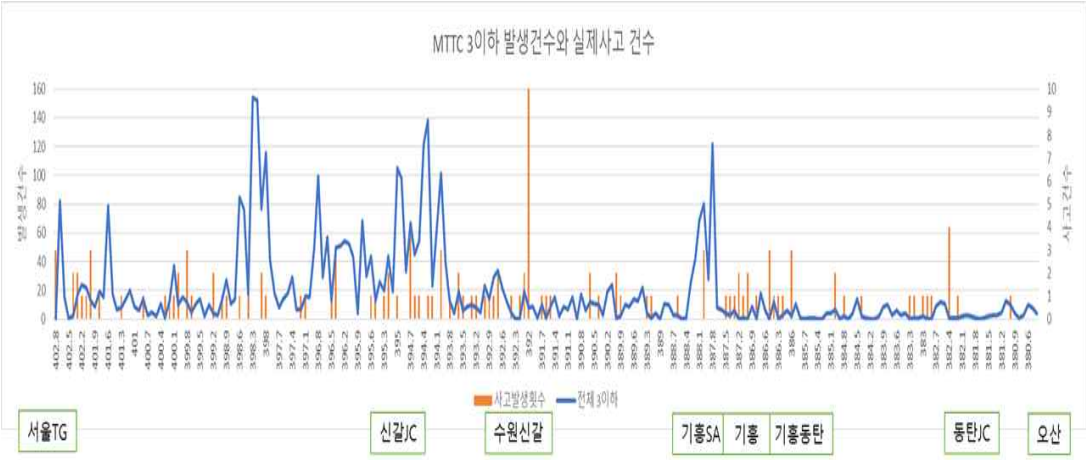

<그림 117> MTTC 발생 건수와 실제사고 건수 비교(판교→오산구간)

제6장 결론 및 향후 연구과제

제1절 결론

앞으로 도로교통의 가장 중요한 패러다임으로 도래할 자율주행차 시대를 앞두고 인공지능, 영상, 센서 등 다양한 분야에서 활발히 연구가 이루어지고 있으나, 교통분야는 아직 지점 및 구간검지체계를 기반으로한 전통적인 수집 및 분석방식에서 크게 벗어나지 못하고 있다. 과거 Daganzo(1997)가 제시했던 차세대 항공기반 검지방식(ADS)을 구현하기 위해 최근들어 드론 등 무인기를 이용하여 교통정보 수집에 이용하고 있지만 아직도 한정적 측면에서만 활용되고 있다.

본 논문에서는 시대적 흐름에 맞춰 미래 자율주행자동차 확대와 함께 자연스럽게 발전하고 있는 차량 센서장비 중 라이다의 교통분야 적용 가능성과 실제 교통혼잡 및 모니터링 방법 등에 대해서 연구하였다.

먼저 차세대 검지체계의 방향과 이를 구현하기 위한 센서 및 알고리즘을 살펴보았다. 그 결과 연속적이고 신뢰성 있으며 기존 검지방식들의 장점을 가지고 있으며, 추가적으로 도로주행 중 항공기반 검지방식을 모사할 수 있는 이동검지체계(MDS)를 제안하였고 이러한 차세대 검지체계에 적합한 센서로 라이다 센서장치와 도로공간에서 차량의 검지를 위한 객체탐지 모델로 Voxel-RCNN 방식을 선정하였다.

센서로부터 수집된 데이터를 교통분석에 활용하기 위해, 우선 3차원 공간 데이터에서 도로상 운행하는 모든 차량들을 찾아내고 교통데이터화하는 객체탐지 방법을 정리하였고, 다음으로 탐지된 차량 실시간 위치정보를 기반으로 개별 차량의 속도, 가감속 등 미시적 정보뿐만 아니라 운행구간의 밀도와 같은 거시적 정보까지 다양한 교통정보를 추출하는 방법론을 정립하였다.

이러한 교통데이터를 기초로 안전대리변수 중 속도, 가감속, 차간거리

등을 통해 더 정확하게 산출할 수 있는 MTTC(Modified TTC)를 사용하였고, 기존 주행차량 기준으로 주로 앞뒤차량에 한정되어 계산되던 안전성 평가방법의 범위를 이동하는 공간전체의 차로별·차량별로 확장하여 산출함으로써 새로운 라이다 데이터의 장점을 확인하였다.

또한 본 논문에서는 한발 더 나아가 기존 TTC, MTTC에서 반영하지 못했던 위험회피를 위한 차로변경이라는 운전자의 제2선택지를 반영해 "회피가능 안전공간(SSS)"이라는 개념을 도입하여 새롭게 취득되는 데이터 장점에 맞추어 새로운 안전성평가 모델을 제안하였다. 이와 더불어 고속도로상의 차로간, 차로내에서의 속도편차를 이용하여 안전성을 평가하고 위험구간을 선정하였다. 속도편차를 활용시 경부선처럼 버스전용차로가 있는 경우 이를 제외하여 평가하는 것이 더 위험을 적절하게 판단할 수 있는 것으로 비교결과 확인되었다.

기존에 이론적 산출방법이나 시뮬레이션을 통해 수행하던 위험성 평가를 현장 실측데이터를 직접 수집(경부선 판교-오산 구간 등)하여 적용한 결과, 고속도로 합류부와 같이 교통류(속도, 밀도 등)가 변화하는 교통특성을 가진 구간에서 실제 위험도가 더 높은 것을 확인할 수 있었다. 이는 기존에 집계적이고 통계적인 데이터 형태(계단식)를 가지고 있는 VDS나 구간검지방식과 라이다 센서를 동일구간에 대한 직접비교를 통해서 기존 방식보다 더 세밀하게 구간의 특성을 분석해 낼 수 있다는 점을 보여주었다.

또한 라이다 방식을 활용하면 정량적인 위험도 평가시 더 정확한 의사결정 및 판단이 가능하다는 사실도 확인할 수 있었다.

그럼에도 불구하고, 이번 논문에서는 라이다 데이터 수집을 위해 한 대의 차량만을 사용하였기 때문에 수집범위가 이동하는 한 대의 차량의 주변으로 한정되는 한계가 있었다. 향후 데이터 수집목적 차량이 증가되고 이들을 서로 연계(Connected Vehicle)할 수가 있다면, 거의 모든 도로상에서 데이터가 연속적으로 연결되고 전수조사 수준의 분석이 가능하게 되어, 향후 주행구간의 교통상태에 대한 수집과 진단 결과수준이 더욱

향상될 것이라 기대할 수 있는 것이다.

본 연구를 통한 주요 기여도는 크게 두 가지이다.

첫째, 새로운 데이터 수집 센서인 라이다를 이용하여 교통분석에 다각도로 적용해 보았다. 기존에도 기술적인 측면에서는 다양한 센서와 방식이 제안되었으나 계단식 결과값을 가지는 지점검지기와 구간검지기의 한계를 여전히 벗어나지 못하고 있었다. 이번에 새롭게 제안하는 이동검지 방식은 기존 방식의 장점과 항공기반방식의 장점을 동시에 가지고 있어서 연속적이고 주행공간 전체에 대한 다양한 교통정보를 수집하고 진단할 수 있도록 하여 살아있는 교통흐름을 파악하는데 기여할 수 있게 만들어 주었다.

둘째, 고속도로 안전성평가를 위해 안전대리변수(MTTC)를 이용한 방식과 속도 표준편차를 이용한 방식 등 안전성평가를 위한 새로운 방식을 제안하였다. 운전자의 특성을 고려하여 앞차량과의 관계뿐만 아니라 좌우 공간의 회피행동까지 고려함으로써 운전자 입장에서 좀 더 현실적인 안전도를 평가할 수는 방법을 마련하였다. 특히 기존에 연속적인 현장 이동차량의 속도편차를 구하기가 어려워 사용하지 못했던 속도편차 방식을 사용하여 이동구간의 안전성을 평가할 수 있게 되었다.

제2절 향후 연구과제

라이다 센서를 이용하여 데이터를 수집하고 이를 분석하고 활용하기 위해서는 다음과 같은 향후 연구가 필요하다.

첫째, 라이다 데이터의 활용이 주로 교통분석에 활용되었으나 차량추적 기능을 더욱 강화하여 차량행태분석이 가능하도록 만드는 것이 필요하다. 실제 현장에서의 차로변경 등 미시적인 움직임을 확인할 수 있다면 더욱 다양한 교통정보 수집이 가능하고 활용범위가 더 넓어질 것이다.

둘째, 현장에서 실시간으로 위험성평가 결과가 높게 나타난 구간에 대해 후방의 운전자에게 사전에 알려주거나 도로관리자에서 안전조치를 취

하게 만들 수 있는 편리한 시스템을 연구함으로써 좀 더 안전하고 편리한 이동이 이루어지도록 연구를 진행해야 할 것이다.

셋째, 라이다를 이용한 안전도 평가가 합리적인지 검증하기 위하여 장기간에 걸친 더 많은 데이터 축적을 통하여 다양한 변화구간에 대한 위험도 평가와 사고다발구간에 대한 비교분석이 이루어져야 할 것이다.

넷째, 교통분야에서 라이다 장비를 광범위하게 이용하기 위해서는 센서분야 및 이미지처리 전문가들과 협업하여 좀 더 편리하고 효율적으로 데이터를 처리하고 객체를 탐지하는 방법에 대한 연구가 진행되어야 할 것이다.

마지막으로 라이다 센서뿐만 아니라 다른 센서와도 융합을 통해 더 정밀한 데이터 수집 및 활용방안에 대해서도 연구가 필요할 것이다.

참 고 문 헌

[국내문헌]

- [1] 김종진 외(2022), 실시간 교통정보 정확도 향상을 위한 이질적 교통정보 융합 연구, 토목학회지논문집 제 42권 1호, 67～74
- [2] 김한수 외(2007), 차량검지기 자료 관련 연구동향 분석 및 발전방향, 한국ITS학회논문지 제6권 제1호 13-26
- [3] 조준한 외(2011), 지점검지기기반 도시부 소통상황 판단 알고리즘 개발, 대한교통학회 제64회 학술발표회, pp.818-823
- [4] 이문엽 외(2020), 드론을 이용한 교통영상정보 수집체계 정립에 관한 연구, 대한토목학회 Vol. 40, No. 4, pp.401-408
- [5] 김성현 외(2005), 일반국도의 지점 및 구간검지기 자료의 융합을 통한 통행시간 추정 알고리즘 개발, 대한교통학회지 제23권 제5호, 135 - 146
- [6] 백남철 외(2012), 항공기반 차량검지시스템의 실시간 교통자료 수집에의 활용 가능성에 관한 연구, 대한토목학회논문집 제32권 제2D호 129-136
- [7] 최기주 외(2009), RFID와 GPS 기반의 교통정보 수집체계 비교분석 연구, 대한토목학회논문집 제29권 제5D호, 571～578
- [8] 한동희 외(2018), 차량 통행경로 분석체계 및 활용 고도화 방안 연구, 한국도로공사 도로교통연구원
- [9] 양인철 (2019), 차량센서를 활용한 교통밀도 관측시스템 개발, 대한교통학회 제80회 학술발표회
- [10] 박용서 외(2013), 국내 ITS 산업 활성화를 위한 정책적 방안 연구, 디지털정책 및 운영지, 11(6) : 187～192

- [11] 한국도로공사 내부자료(2021), 데이터 기반의 의사결정 지원을 위한 교통정보 수집활용 고도화 계획, 교통처, 2021.7.
- [12] 안계형 외(2015), 프로브차량 기반 구간교통정보수집 정확도 제고방안 연구, 도로교통공단 교통과학연구원
- [13] 장현호 외(2017), 차량 통행경로자료를 이용한 구간통행시간 추정 방법론 개발, 2017년 한국ITS학회 춘계학술대회, pp.599-604
- [14] 김성훈 외(2020), 타임스탬프 데이터분석 기반의 도시부 연속류도로 교통류 분기지점 통행시간 추정 연구, 대한교통학회지 제38권 제2호, pp.148-165
- [15] 오창환 외(2020), 링크 공간평균속도 신뢰성 확보를 위한 프로브 차량 데이터 적정 수집주기 산정 연구, 한국ITS학회논문지 제19권 제5호, pp.70-81
- [16] 김수희 외 (2016), 고속도로 교통조사분석을 위한 무인항공기(드론) 활용방안 연구, 한국도로공사 도로교통연구원
- [17] 정보경 외(2021), 다중객체추적 알고리즘을 활용한 드론 항공영상 기반 미시적 교통데이터 추출, 한국ITS학회논문지 제20권 제5호, pp.83-99
- [18] 국토해양부 (2013), 2013년 도로용량편람
- [19] 양인철 외 (2018), 차량센서를 활용한 교통상태 관측 기술 개발, 디지털콘텐츠학회논문지 Vol. 19, No. 11, pp. 2131-2137
- [20] 임동현 외(2020), 표본 ADAS 차두거리 기반 연속류 시공간적 교통밀도 추정, 한국ITS학회논문지 제19권 제6호, pp.208-221
- [21] 박재홍 외(2021), Vehicle Sensor 자료를 이용한 후미 추돌사고의 주행안전성 평가 방법론 개발, 대한교통학회지 제39권 제6호, pp.826-837

- [22] 김재겸 외(2019), 자율주행을 위한 딥러닝 기반의 라이다 카메라 센서 융합 기술, ITS Brief, Vol.10 No.1, 14-19
- [23] 변예림 외 (2020), 자율주행을 위한 라이다 기반 객체 인식 및 분류, 자동차안전학회지, 제12권 제4호, pp.23-30
- [24] 선민혁 외(2022), 자율주행을 위한 딥러닝 기반 라이다 객체인식 신경망 연구 분석, 한국자동차공학회 논문집 제30권 제8호
- [25] 문연국 (2022), 자율주행차량용 라이다 센서 기술동향, OSIA S&TR Journal 제30권 제1호, pp.8-15
- [26] 윤일수 외(2011), SSAM을 이용한 신호교차로 안전성 평가, 한국ITS학회논문지 제10권 제6호, pp.1-14
- [27] 박성용 외(2015), 차량궤적자료를 이용한 SSM 산출 방법론 개발과 적용사례 분석, 대한교통학회지 제33권 제4호, pp.323-336
- [28] 오철 외(2009), SSM기반 고속도로 교통안전 경고정보 처리 및 가공기법, 대한교통학회지 제27권 제3호, pp.59-70
- [29] 장현익 외(2013), 차량긴급제동장치의 안전성 평가방법, 한국자동차공학회논문집 제21권 제5호, pp.162-168
- [30] 김범일 (2021), 고속도로 자율주행자동차 전용차로 기준설정에 관한 연구, 서울대학교 박사학위논문
- [31] 김준형 외(2008), 실시간 연속류 교통상충 검지 및 분석 시스템 개발, 교통기술과 정책, 제5권 제4호, pp.117-132
- [32] 고준호 (2006), GPS 장착차량으로부터 얻어진 Acceleration Noise의 특성 연구, 대한교통학회 제53회 학술발표회, pp.873-880
- [33] 오철 외(2011), 차량 주행궤적을 이용한 후미추돌 가능성 예측 모형,

대한교통학회지 제29권 제3호, pp.73-82

- [34] 박현진(2018), 자율주행환경에서 차량 간 사고위험도 분석기반 속도제어전략 개발 및 평가, 한양대학교 박사학위논문
- [35] 김은정 외(2014), 교통정보관리시스템 데이터 품질진단 및 평가체계 구축에 관한 연구, 도로교통공단 교통과학연구원
- [36] 김승기 외(2019), 단일 카메라를 이용한 3D 깊이 추정방법, 방송공학회 논문지 24권 2호, 2019.3.
- [37] 정규수 (2021), 위치기반 차량정보를 이용한 동적속도 동질공간 분할 최적화, 서울대학교 박사학위논문
- [38] 김동환 (2021), 능동센서 기반 라이다 기술의 원리와 활용동향 소개, 한국방위산업진흥회 국방기술, pp.154-159
- [39] 오철 외(2007), 영상기반 실시간 후미추돌 윙험도 분석기법 개발, 대한교통학회지, 제25권 5호, 173-182
- [40] 국토교통부(2016), 도로부문 지능형교통체계 설계편람, p45

[국외문헌]

- [41] Carlos F. Daganzo.(1997), Fundamentals of Transportation and Traffic Operations, 1st ed. Amsterdam : Pergamon Press, p.14.
- [42] Joseph Redmon et al., (2016), You Only Look Once : Unified, Real-Time Object Detection, arXiv:1506.02640v5
- [43] Seo, T., Kusakabe, T., Asakura, Y.(2016), Estimation of flow and density using probe vehicles with spacing measurement equipment, Transportation Research Part C 53, pp. 134 - 150

- [44] Seo, T., Kusakabe, T.(2015), Probe vehicle-based traffic state estimation method with spacing information and conservation law, Transportation Research Part C 59, pp. 391 - 403
- [45] Seo, T., Kusakabe, T., Asakura, Y.(2015), Traffic State Estimation with the Advanced Probe Vehicles using Data Assimilation, IEEE 18th International Conference on Intelligent Transportation Systems
- [46] Junxuan Zhao et al., (2019), Detection and tracking of pedestrians and vehicles using roadside LiDAR sensors, Transportation Research Part C 100 (2019) 68 - 87
- [47] Asad Lesani et al., (2020), Development and evaluation of a real-time pedestrian counting system for high-volume conditions based on 2D LiDAR, Transportation Research Part C 114 (2020) 20 - 35
- [48] Zhengxia Zou et al., (2019), Object Detection in 20 Years: A Survey, arXiv:1905.05055v2
- [49] LeCun Yann, et al.(1998), Gradient-based learning applied to document recognition. Proceedings of the IEEE 86.11 (1998): 2278-2324
- [50] Liu Li, et al. (2020), Deep learning for generic object detection: A survey. International journal of computer vision 128.2 (2020): 261-318
- [51] Zamanakos Georgios et al. (2021), A comprehensive survey of LIDAR-based 3D object detection methods with deep learning for autonomous driving. Computers & Graphics 99 (2021): 153-181
- [52] Charles R. Qi, Hao Su, Kaichun Mo, Leonidas J. Guibas (2016), PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation, https://arxiv.org/abs/1612.00593

- [53] Yin Zhou, Oncel Tuzel (2017), VoxelNet: End-to-End Learning for Point Cloud Based 3D Object Detection, https://arxiv.org/abs/1711.06396
- [54] Alex H. Lang, Sourabh Vora, Holger Caesar, Lubing Zhou, Jiong Yang (2019), PointPillars: Fast Encoders for Object Detection from Point Clouds, https://arxiv.org/pdf/1812.05784.pdf
- [55] FHWA(2008), Surrogate Safety Assessment Model and Validation: Final Report
- [56] S.M. Sohel Mahmud, Luis Ferreira, Md. Shamsul Hoque, Ahmad Tavassoli (2017), Application of proximal surrogate indicators for safety evaluation: A review of recent developments and research needs, IATSS Research 41 (2017) 153 - 163
- [57] Lingfeng Peng, Nengchao Lyu, and Chaozhong Wu (2020), A Road Traffic Crash Risk Assessment Method Using Vehicle Trajectory Data and Surrogate Safety Measures, CICTP 2020, 3657
- [58] Roja Ezzati Amini, Kui Yang, Constantinos Antoniou (2022), Development of a conflict risk evaluation model to assess pedestrian safety in interaction with vehicles, Accident Analysis and Prevention 175 (2022) 106773
- [59] Natalie R. L., Patricia R. D.(2019), Does automated driving affect time-to-collision judgments?, Transportation Research Part F 64 (2019) 25 - 37
- [60] Felipe J., José E. N., Fernando G.(2013), An Improved Method to Calculate the Time-to-Collision of Two Vehicles, Int. J. ITS Res. (2013) 11:34 - 42

- [61] Jade M., Kristoper D. Kusano, Hampton C. Gabler(2014), Age and Gender Differences in Time to Collision at Braking From the 100-Car Naturalistic Driving Study, Traffic Injury Prevention (2014) **15**, S15 - S20
- [62] Michiel M. M., Piet H.L. B.(2001), Extended time-to-collision measures for road traffic safety assessment, Accident Analysis and Prevention 33 (2001) 89 - 97
- [63] Ozbay et al.(2008), Derivation and Validation of New Simulation-Based Surrogate Safety Measure, TRR 2083, 105-113.
- [64] H. Behbahani, N. Nadimi & S.S. Naseralavi (2015), New time-based surrogate safety measure to assess crash risk in car-following scenarios, Transportation Letters, 7:4, 229-238
- [65] Navid Nadimi, David R Ragland and Amir Mohammadian Amiri (2020), An evaluation of time-to-collision as a surrogate safety measure and a proposal of a new method for its application in safety analysis, Transportation Letters, 12:7, 491-500
- [66] Hayward(1972), Near Miss Determination through Use of a Scale of Danger, Report no.TTSC 7115, The Pennsylvania State University, Pennsylvania
- [67] Minderhoud M. and P. H. L. Bovy. (2001), Extended Time-to-collision Measures for Road Traffic Safety Assessment, Accident Analysis and Prevention 33: 89 - 97.
- [68] Laureshyn, A., A. Svensson, and Hyden. (2010), Evaluation of Traffic Safety, Based on Micro-level Behavioral Data: Theoretical Framework and First Implementation, Accident Analysis and Prevention 42 (6): 1637 - 1646

- [69] Kiefer, R. J., D. J. Leblanc, and C. A. Flannagan. (2005), Developing an Inverse Time-to Collision Crash Alert Timing Approach Based on Drivers' Lastsecond Braking and Steering Judgments, Accident Analysis and Prevention 37: 295 - 303
- [70] Xie, K., D. Yang, K. Ozbay, and H. Yang. (2018), Use of Real-world Connected Vehicle Data in Identifying High-risk Locations Based on a New Surrogate Safety Measure, Accident Analysis and Prevention Article in Press
- [71] Allen B. L., Shin B. T., Cooper P. (1978), Analysis of Traffic Conflicts and Collisions, TRR, 667, pp.67-74
- [72] Oh, C., Park, S., and Ritchie, S.(2006), A method for Identifying rear-end collision risks using inductive loop detectors Accident Analysis Prevention 38 pp.291～301
- [73] van der Horst R., Hogema J. (1993), Time-To-Collision and Collision Avoidance Systems, 6th ICTCT workshop, Salzburg, Austria
- [74] Touran A., Brackstone M. A., McDonald M. (1999), A Collision Model for Safety Evaluation of Autonomous Intelligent Cruise Control. Accid Anal Prev 31, 567-578.
- [75] Lee J. D, McGehee D. V., Brown T. L., Reyes M. L. (2002), Collision Warning Timing, Driver Distraction, and Driver Response to Imminent Rear-End Collisions in a High-Fidelity Driving Simulator, Human Factors Vol 44(2), pp. 314-334.
- [76] Gettman D., Head L. (2003), Surrogate Safety Measures from Traffic Simulation Models. TRR, 1840, 104-115.
- [77] Katja Vogel(2003), A comparison of headway and time to collision as

safety indicators, Accident Analysis and Prevention 35 (2003) 427 - 433

- [78] Hourdakis J., Garg V., Michalopoulos P. G., Davis G. A. (2006), Real-time Detection of Crash-prone Conditions at Freeway High Crash Locations, TRR 1968, 83-91.
- [79] Guido G., Vitale A., Astarita V., Saccomanno F., Giofre, V. F., Gallelli, V. (2012), Estimation of Safety Performance Measures from Smartphone Sensors, Procedia - Soc. and Behavioral Sci. 54, 1095-1103.
- [80] Yurong You et al,(2020) PSEUDO-LIDAR++ : Accurate Depth for 3D Object Detection in Autonomous Driving, ICLR 2020
- [81] Jiajun Deng et al., (2021), Voxel R-CNN: Towards High Performance Voxel-based 3D Object Detection, Association for the Advancement of Artificial Intelligence(www.aaai.org), arXiv:2012.15712v2
- [82] Choi Seungjin et al., (2022), Point Cloud-Based Lane Detection for Optimal Local Path Planning, 2022 International Conference on Electronics, Information, and Communication (ICEIC) IEEE
- [83] Beltrán Jorge et al.(2018), "Birdnet: a 3d object detection framework from lidar information." 2018 21st International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2018
- [84] Shi C. Y. et al (2017), Estimation of Travel Time Distributions in Urban Road Networks Using Low-Frequency Floating Car Data, ISPRS Int. Geo-Inf., 6, MDPI, 253.
- [85] Zhou et al(2017), Unsupervised Learning of Depth and Ego-Motion from Video, arXiv:1704.07813v2, 2017.8
- [86] Wang et al(2020), Pseudo-LiDAR from Visual Depth Estimation :

Bridging the Gap in 3D Object Detection for Autonomous Driving, arXiv:1812.07179v6, 2020.2

- [87] Hecht Jeff(2018), Lidar for self-driving cars, Optics and Photonics News 29.1 (2018): 26-33
- [88] Ibraheem Alhashim et al(2019), High Quality Monocular Depth Estimation via Transfer Learning, arXiv:1812.11941v2 [cs.CV] 10 Mar 2019
- [89] Wu, Jianqing, et al(2020), Automatic vehicle detection with roadside LiDAR data under rainy and snowy conditions, IEEE Intelligent Transportation Systems Magazine 13.1 (2020): 197-209
- [90] Filgueira, A., et al(2017), "Quantifying the influence of rain in LiDAR performance." Measurement 95 (2017): 143-148
- [91] Kutila, Matti, et al(2018), "Automotive LiDAR performance verification in fog and rain." 2018 21st International Conference on Intelligent Transportation Systems (ITSC). IEEE
- [92] Goberville, Nick, et al(2020), "Analysis of LiDAR and camera data in real world weather conditions for autonomous vehicle operations." SAE Int. J. Advanc. Curr. Prac. Mobil 2 (2020): 2428-2434
- [93] Takashi Wakasugi(2005), “A study on warning timing for lane change decision and aid systems based on driver’s lane change maneuver”, Japan Automobile Research Institute, Paper Number 05-0290
- [94] Richard van der horst, et al(1994), “Time-to-collision and collision avoidance systems”, 6th ICTCT workshop Salzburg
- [95] Glennon(1970), "An Evaluation of Design Criteria for Operating Trucks Safely on Grades“, Highway Research Record 312, pp 93-112

- [96] Garber & Gadiraju(1989), “Factors Affecting Speed Variance and its Influence on Accidents”, Transportation Research Record 1213, pp 64-71
- [97] Quddus(2013), “Exploring the Relationship Between Average Speed, Speed Variation, and Accident Rates Using Spatial Statistical Models and GIS”, Journal of Transportation Safety & Security, volume 5, 2013 Issue 1, pp 27-45
- [98] E. Hauer, and J. Bonneson(2006), “An empirical examination of the relationship between speed and road accident based on data by elvik,” Chtistensen and Amundesen, NCHRP pp.17-25
- [99] Choudhary et al(2018), “Impacts of speed variations on freeway crashes by severity and vehicle type”, Accident Analysis & Prevention, Volume 121, December 2018, pp 213-222
- [100] Himanshu Chandel and Sonia Vatta(2015), "Occlusion detection and handling: a review." International Journal of Computer Applications 120.10
- [101] Brandon Schoettle(2017), "Sensor fusion: A comparison of sensing capabilities of human drivers and highly automated vehicles." University of Michigan
- [102] Aleksandr Kim, Aljoša Ošep, Laura Leal-Taixé(2021), "Eagermot: 3d multi-object tracking via sensor fusion." 2021 IEEE International Conference on Robotics and Automation (ICRA), IEEE
- [103] Himani S. Parekh1, Darshak G. Thakore, Udesang K. Jaliya(2014), “A Survey on Object Detection and Tracking Methods”, International Journal of Innovative Research in Computer and Communication Engineering Vol. 2, Issue 2

- [104] Rafael Padilla, Sergio L. Netto, Eduardo A. B. da Silva(2020), "A survey on performance metrics for object-detection algorithms." 2020 international conference on systems, signals and image processing (IWSSIP). IEEE

[웹사이트]

- 법제처 국가법령정보센터, www.law.go.kr
- Supervisely(2020), https://supervise.ly
- HelloT(2020.6.30.), “2021년 자율주행차 레벨3 양산 시작, ADAS ‘라이다’ 대중화에 성큼”, www.hellot.net/news/article.html?no=53130
- 매거진 한경(2020.9.30.), “자율주행차가 교통 체증을 없애줄까… 이유 없이 막히는 유령 체증 난제”, magazine.hankyung.com
- 한국일보(2021.7.17.), “자율주행차, 사람보다 안전한 운전 비밀은 ‘센서 3형제’에 있다”, www.hankookilbo.com/News/Read/A2021071409220002303?did=NA
- TESTWORKS(2021. 8. 24.), “교통량 계산을 위한 딥 러닝, YOLO V5 차량인식 적용 결과”, https://blog.testworks.co.kr/deep-learning-for-traffic-counting
- TESTWORKS 블로그(2021.11.10.), “3D 인공지능의 핵심 라이다 데이터”, https://blog.naver.com/testworks_mktg/222563960854
- 아이뉴스24(2021.9.17.), “설득력 잃는 일론 머스크의 '라이다 무용론'”, https://www.inews24.com/view/1405613
- STRADVISION 한국 블로그(2021.8.4.), “자율주행 차량 센싱 시스템”, https://blog.naver.com/stradvisionary/222456849899

부 록

1. 딥러닝을 활용한 객체탐지(Object Detection) 방법

최근 하드웨어(GPU)의 성능향상과 알고리즘 개발에 따라 많은 연산량을 수용할 수 있게 되어 딥러닝 기술이 활발하게 개발되고 비약적인 발전을 이루었다. 본 절에서는 딥러닝 기술 중 객체탐지 기술에 대해 서술하고자 한다. 객체탐지[29](Object detection)는 특정 객체가 어디 위치에 존재하는지를 파악해야 하기 때문에 컴퓨터 비전 기술에서 핵심이 되는 기술이다.

종래의 이미지 객체탐지방법으로 머신러닝(machine learning) 기반 Haar-cascade, SIFT, SURF Histogram of Gradient(HOG), Deformable Part Model(DPM)와 같은 알고리즘을 사용하여 객체 검지를 수행해 왔다. 하지만 <그림 118>에서 처럼 2012년 CNN[30](Convolutional Neural Network, 합성곱 인공신경망)의 등장으로 기존 알고리즘의 성능을 압도적으로 뛰어넘어 CNN을 활용한 딥러닝(deep learning) 방법이 학계의 주목을 받아 주류가 되었다. 객체탐지시 특징(feature) 추출단계에서 수동(hand craft)으로 디자인된 특징을 찾는 대신에 CNN을 이용하여 자동으로 추출된 특징을 찾는 방식을 사용하여 성능향상을 이뤄냈다[48].

---

29) 이미지나 동영상에서 사람, 동물, 차량 등 의미 있는 객체(object)의 종류와 그 위치(bounding box)를 정확하게 찾기 위한 컴퓨터 비전(computer vision) 기술 (출처 : 두산백과사전, www.doopedia.co.kr)

30) ImageNet 2012 대회에서 압도적 성능을 보여줌으로써 학계의 주목을 받음

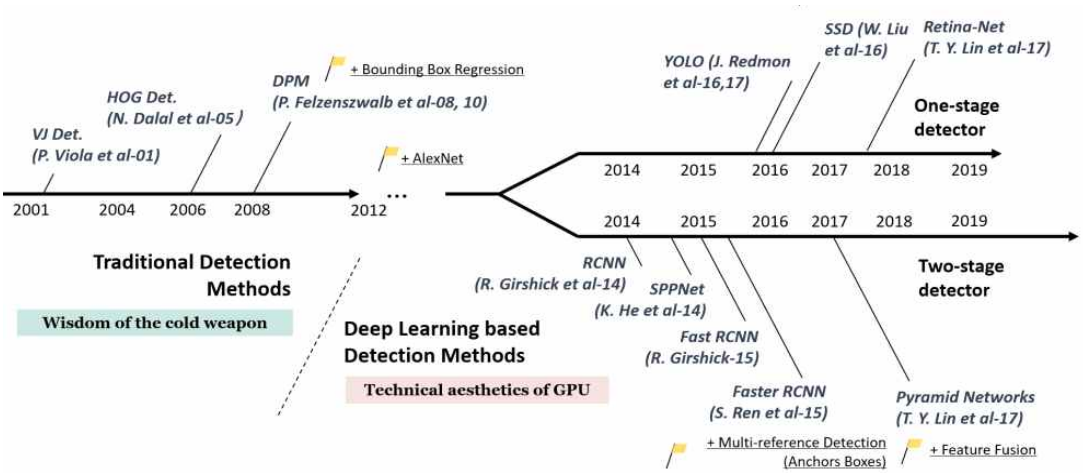

<그림 118> 객체탐지방법 발전도 (출처 : Zhengxia et. al. 2019)

CNN은 이미지를 분석하기 위해 패턴을 찾기에 유용한 알고리즘으로 LeCun et al(1998)에 의해 제안되었다[49]. Convolution layer와 Max pooling layer의 조합으로 구성된 모델이며, 기본적인 구조는 아래 <그림 119>과 같다.

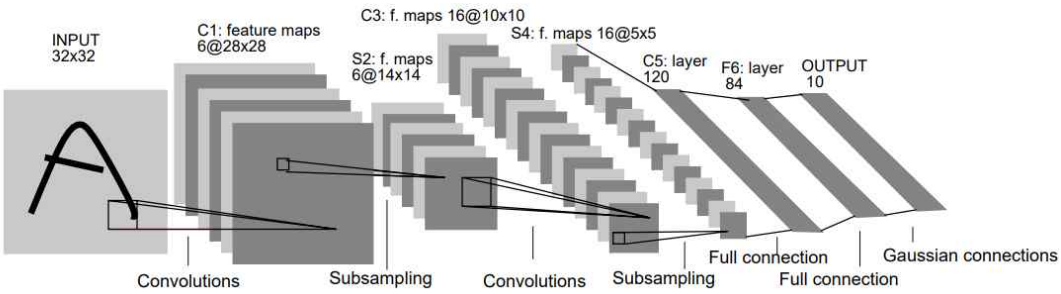

<그림 119> CNN 구조도 (출처 : LeCun, 1998)

CNN의 개발을 시작으로 CNN의 인식률을 향상시키기 위해 네트워크를 더 깊게 구성하는 방식으로 연구가 진행되었으며, ZFNet, VGG, GoogLeNet, DenseNet 등이 등장하였다.

본 논문에서는 2차원 이미지에서의 객체탐지와 라이다의 3차원 PCD(Point Cloud Data)자료를 활용한 객체탐지 방법을 비교하고 차이점을 소개하고자 한다.

2. 이미지 기반의 2D 객체탐지 방법

일반적으로 영상 이미지에서 객체탐지를 위해서는 분류(classification), 위치(localization), Bounding Box, 객체탐지의 과정을 통해 진행된다[42]. <그림 120>은 객체탐지 과정을 예시로 보여주는 것으로 입력으로 받은 이미지 내에서 Bounding box를 구하기 위한 위치(localization) 과정과 객체의 class를 구하기 위한 분류(classification) 과정이 수행된다. 두 과정을 종합해서 나온 결과물을 바탕으로 최종 객체탐지(object detection)의 결과가 출력된다.

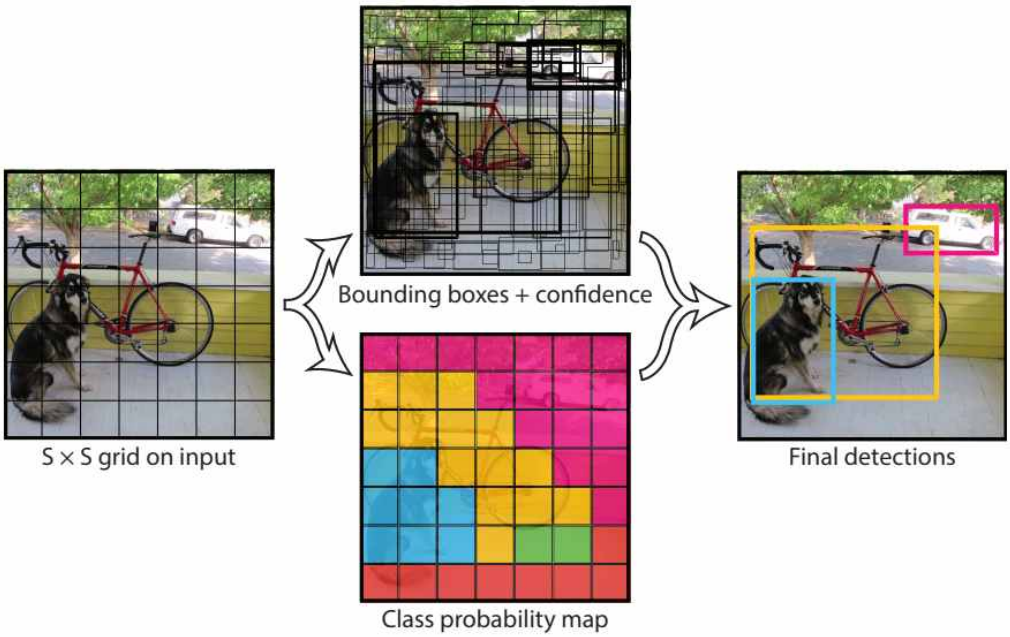

<그림 120> YOLO object detection 과정(출처 : Joseph Redmon et al, 2016)

<그림 121>은 이미지분야에서 R-CNN부터 CormerNet까지의 객체탐지 알고리즘 발전흐름을 보여준다[50].

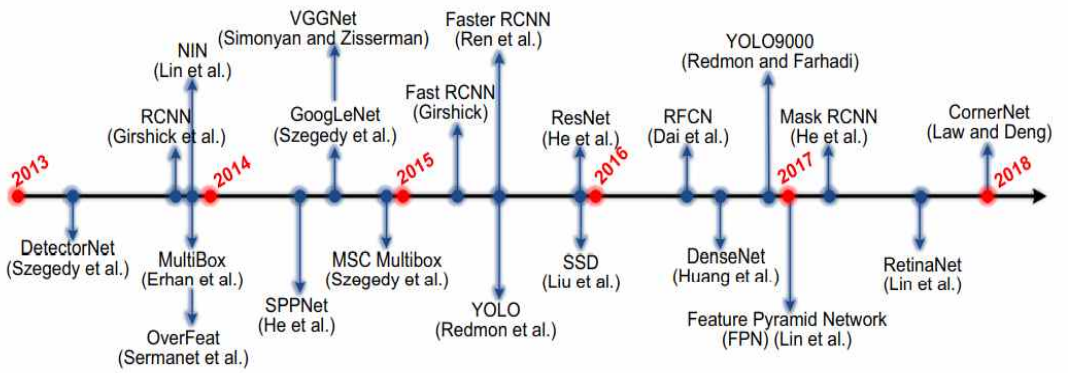

<그림 121> 객체탐지 알고리즘 모델 발전 (출처: Li Liu et al, 2019)

이미지에서의 객체탐지 방법은 <그림 122>과 같이 크게 영역제안(region proposals) 여부에 따라 1-Stage와 2-Stage방법으로 나눌 수가 있다.

이 두가지 방법의 대표적인 모델로는 탐지 성능이 우수한 2-Stage방법인 R-CNN, Faster R-CNN 등과 실시간 탐지에 적합한 1-Stage방법인 YOLO, SSD 등이 있다.

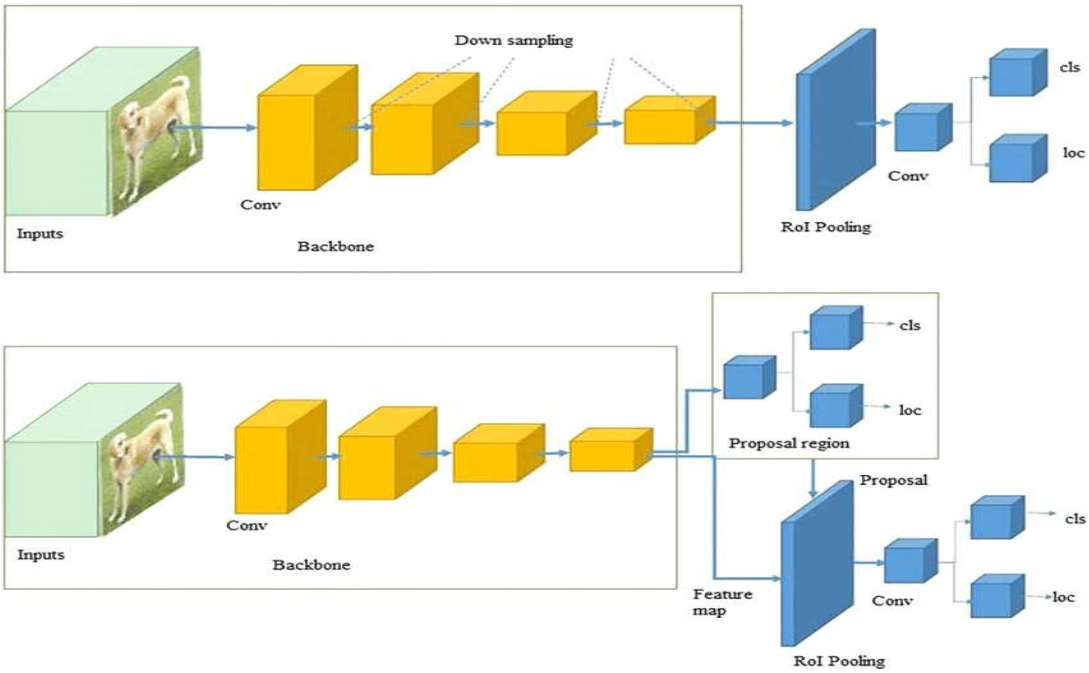

<그림 122> 1-stage vs 2-stage (출처 : Sankar K. Pal et al, 2021)

가. R-CNN(Region-CNN) 알고리즘

2-stage의 대표적인 알고리즘은 R-CNN이다. R-CNN은 후보 영역(Region Proposal)을 생성하고 이를 기반으로 CNN을 학습시켜 영상 내 객체의 위치를 찾아낸다. R-CNN의 객체 인식 과정은 <그림 123>와 같이 크게 세 단계로 이루어진다. 첫째, 입력된 영상에서 선택적 탐색(Selective Search) 알고리즘을 이용하여 후보 영역들을 생성한다. 둘째, 생성된 각 후보 영역들을 동일한 크기로 변환(Warped)하고, CNN을 통해 특징(feature)을 추출한다. 셋째, 추출된 특징을 이용하여 후보 영역 내의 객체를 SVM(Support Vector Machine, 선형분류기)을 이용하여 분류한다. 첫 번째 단계에서 생성된 후보 영역위치는 부정확하기 때문에, 최종 단계에서는 회귀분석(학습)을 통해 더욱 정확한 객체탐지 영역박스 위치를 보정한다. R-CNN을 PASCAL VOC(Visual Object Classes)[31] 2010 데이터 셋에 적용한 결과, 약 53.7%의 mAP(Mean Average Precision)를 기록하여 기존의 객체 검출 방법들에 비해 큰 폭의 성능향상을 보였다.

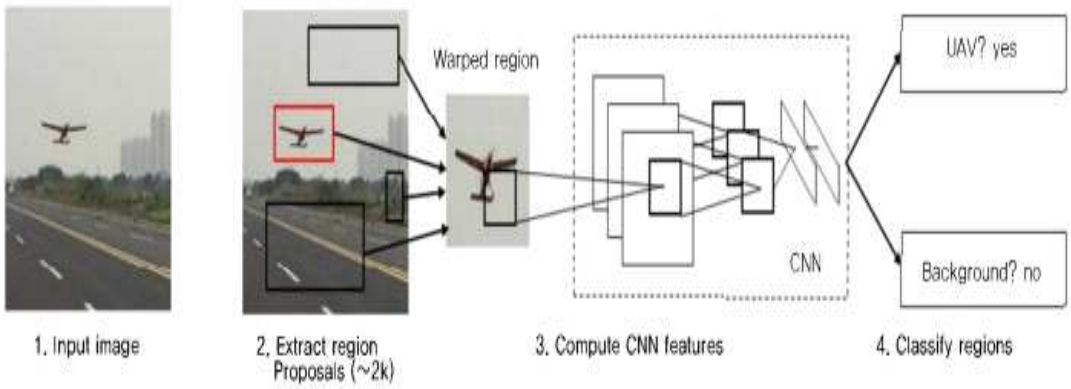

<그림 123> R-CNN 알고리즘 흐름도(출처 : Y. Yang et al, 2017)

31) PASCAL VOC Challenge(2005년에서 2012년 개최) 대회에서 사용하던 데이터셋, 범용적 사용

나. YOLO 알고리즘

1-Stage의 대표적인 알고리즘은 YOLO(You Only Look Once)이다. YOLO는 객체 인식 문제를 하나의 회귀 문제로 접근하여 <그림 124>과 같이 전체적인 구조를 간소화함으로써 훈련 및 검출 속도를 크게 향상시켰다[57]. 입력된 영상은 CNN을 거쳐 텐서(Tensor, n차원 행렬) 형태로 출력된다. 텐서는 카메라 영상을 격자 형태로 나누고 각 구역을 나타나게 되며, 이러한 해당 구역내의 객체를 인식한다. 이처럼 YOLO는 관심 영역을 추출하기 위한 2-Stage와는 달리 별도의 네트워크가 필요하지 않으며, 일련의 추론 과정을 거치면서 객체를 인식하고 탐지한다. PASCAL VOC 2007과 2012 데이터 셋으로 실험한 결과, 초당 최대 155장의 영상을 훈련하여 Faster R-CNN(18장/초)보다 월등히 빠른 훈련 속도를 보였다. 하지만 인식 정확도는 mAP기준 Faster R-CNN(73.2%)보다 다소 떨어지며(YOLO 63.4%), 특히 작은 물체를 인식하는 데에 어려움을 보였다.

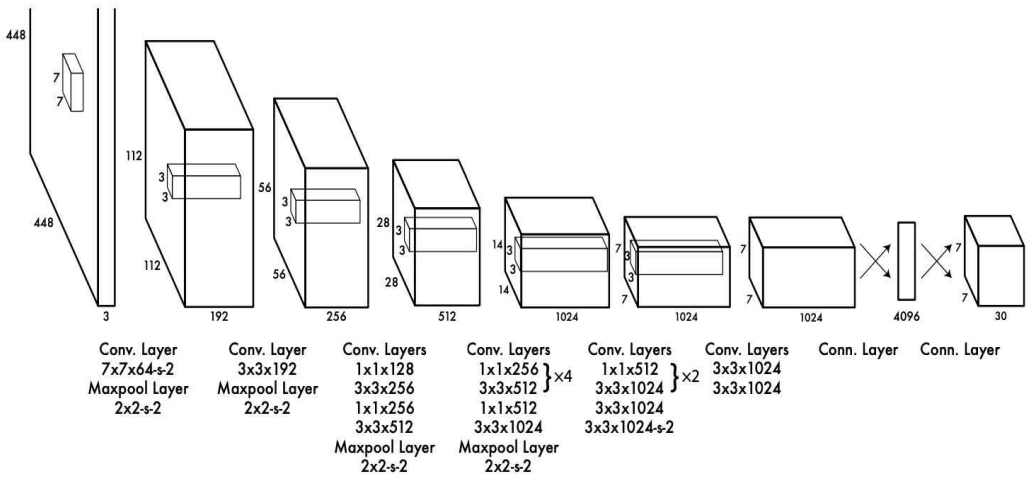

<그림 124> YOLO 알고리즘 흐름도 (출처 : Joseph Redmon et al, 2016)

Abstract

A Study on the Highway Congestion and Traffic Safety Monitoring Based on Vehicle Lidar Sensor

Kim, Hongjin

Department of Environmental Planing
The Graduate School of Environmental Studies
Seoul National University

Recently, many companies have developed traffic situation analysis-based navigation technology that generate an optimal route to a destination. However, the data collected by the traffic situation collection system (VDS, AVI) has a disadvantage in that it cannot recognize the situation of each lane in sections such as junctions or entrances and exits. Therefore, in this paper, unlike existing collection systems, we propose a method of analyzing traffic conditions using a LiDAR sensor.

In this paper, we establish a methodology to collect seamless and continuous section traffic information from surrounding vehicles through lidar sensors installed in driving vehicles, and use microscopic and large-scale data to analyze traffic conditions and monitor safety state on the road.

In the research process, problems and safety evaluation methods of the existing detection system were analyzed through previous studies, and the concept of a participatory movement detection system (MDS) for problem improvement is proposed.

In order to implement a moving detection system(MDS), the point cloud data of LIDAR was collected. The collected data were detected using the Voxel-RCNN model to detect the location and size of the vehicle. The detected individual vehicles were given IDs and tracked, and the speed and acceleration of each vehicle were collected and used as traffic information.

Based on the collected traffic information, traffic states (density, speed, etc.) and safety evaluation (MTTC, speed standard deviation) were monitored over temporal and spatial. In addition, these results were compared with the existing detection methods(point and section detection). For comparative experiments, field data were collected and compared under various conditions such as congested sections and tunnel sections.

The collection results of the existing detection method are expressed in a cascade of traffic data. However, in this paper, it was possible to collect and express continuous traffic information that moves alive

according to changes in temporal and spatial. In addition, through this, micro and precise traffic flow could be confirmed. MTTC, which was improved over TTC, was also used in safety evaluation. Through this, information on the risk section could be collected sensitively and precisely. In addition, the actual dangerous section could be quantitatively confirmed in the safety evaluation method using the standard deviation of speed.

Afterward, if traffic data is continuously accumulated through many vehicles, it will be possible to analyze various traffic phenomena, such as missing sections, lane-by-lane, and inter-lane characteristics, which could not be identified by point detectors or section detectors. In addition, it is expected to contribute to providing more accurate and driver-sympathetic traffic information.

keywords : Lidar, Object Detection, Moving Detection System (MDS), Traffic State, MTTC(Modified TTC), Speed Standard Deviation
Student Number : 2005-31243