



# 도로교통사고감정사 소식지



- 03. 도로 위의 보이지 않는 킬러, '2차 사고'의 메커니즘과 사회적 해법 ... 엄정식
- 07. AI 대전환 시대, 교통사고 전문가의 역할 ..... 조민제
- 14. 배달 이륜차 사고 예방을 위한 주행 데이터 기반 위험 징후 분석과 활용 가능성 ..... 조은솔
- 20. 머신러닝을 활용한 탑승자 상해 예측 모형 개발 ..... 정동훈
- 41. 자동차 창유리 틸팅 정도에 따른 가시거리에 관한 실험 ..... 김경동



### 도로교통사고감정사란?

교통사고의 원인을 체계적으로 조사 분석 감정할 인력을 배출하기 위해 도입된 제도로서 대부분의 교통사고는 경찰조사 결과의 처분을 따르지만 간혹 사고원인규명 자체가 모호하거나 사고관련 당사자들의 주장이 상반되어 판단하기 어려운 경우 과학적이고 체계적인 조사 분석으로 공정한 사고조사를 하기 위한 공인자격제도이다.



# 도로교통사고감정사 소식지



Part  
01

## 엄정식

- 한라대학교 기계자동차공학과 겸임교수
- PITSTOP Motorsport 감독 겸 드라이버
- 합동가공업사 정비책임자

# 도로 위의 보이지 않는 킬러, '2차 사고'의 메커니즘과 사회적 해법

교통사고 현장에서 우리는 흔히 첫 번째 충돌 상황에만 집중하곤 합니다. 그러나 통계와 실례를 살펴보면 사고 발생 그 자체보다 무서운 것은 사고 이후의 도로 환경입니다.

특히 고속도로처럼 차량이 고속으로 질주하는 환경에서 사고나 고장으로 멈춰 선 차량은 뒤따르는 운전자들에게 피할 수 없는 '거대한 장애물'이 됩니다. 이를 '2차 사고'라 부르며, 이는 단순한 추가 사고를 넘어 도로 위의 연쇄적인 비극으로 이어지곤 합니다.

## 1

## 2차 사고 왜 일반 사고보다 더 치명적인가?

고속도로 사고 중 약 20~30%가 2차 사고로 분류될 만큼 그 빈도가 높습니다. 더욱 주목해야 할 점은 2차 사고의 치사율이 일반 사고에 비해 훨씬 높다는 것입니다. 그 이유는 다음과 같은 세 가지 구조적 위험성 때문입니다.

### 감속 없는 충돌



후속 운전자는 전방에 정지 차량이 있을 것이라 예상하지 못하고 평소

주행 속도를 유지합니다. 결과적으로 브레이크를 충분히 밟지 못한 상태에서 엄청난 운동 에너지를 가진 채 충돌하게 됩니다.

### 시야의 사각지대



야간의 어두운 도로, 짙은 안개, 비 내리는 날씨는 정차된 차량을

발견하는 시점을 늦춥니다. 또한, 터널 입구나 굽어지는 커브길 같은 도로 구조는 운전자가 대응할 수 있는 물리적 시야를 극도로 제한합니다.

### 연쇄적 파생 피해



2차 사고는 단일 충돌로 끝나지 않는 경우가 많습니다.

사고 차량과 파편이 도로의 여러 차로를 점유하게 되면서, 뒤따르던 여러 대의 차량이 도미노처럼 엮히는 대형 연쇄 사고로 번지기 때문입니다.

## 2차 사고의 치명적인 연쇄 과정: 왜 멈출 수 없는가?



\* 출처 : 저자재구성

Fig. 1 2차 사고 발생 과정

## 2

### 제동의 공학적 분석 : 왜 인간의 감각은 물리적 한계를 넘지 못하는가?

운전자가 전방의 위험을 인지하고 차를 완전히 세우기까지의 과정을 공학적으로 분석해 보면, 우리가 왜 2차 사고에 취약한지 명확해집니다. 차량이 멈추기 위해서는 '공주 거리'와 '제동 거리'라는 두 가지 물리적 구간을 반드시 거쳐야 합니다.

#### 인지 실패와 반응 지연

사람은 위험을 발견한 즉시 멈출 수 없습니다. 뇌가 상황을 판단하고 발이 브레이크를 밟기까지 소요되는 '반응 시간' 동안 차량은 주행 속도 그대로 전진합니다.

Table.1 주행 속도별 제동 거리

평균 승용차의 속도별 제동 거리

주행 속도	건조 노면 제동 거리	젖은 노면 제동거리
50km/h	35m	41m
60km/h	45m	54m
70km/h	56m	69m
80km/h	69m	85m
90km/h	83m	103m
100km/h	98m	122m
110km/h	113m	144m

**속도와 노면의 변수**

시속 100km로 달릴 때, 마른 노면에서의 정지 거리는 약 98m인 반면 비에 젖은 노면에서는 122m까지 늘어납니다. 시속 110km라면 젖은 길에서의 정지 거리는 무려 144m에 달합니다.

**거리가 확보되지 않은 비극**

2차 사고의 핵심 메커니즘은 운전자가 위험을 깨달았을 때 남은 거리가 이미 차량의 최소 정지 거리보다 짧다는 데 있습니다. 이는 운전자의 의지와 상관없이 물리적으로 충돌이 이미 확정된 상태임을 의미합니다.

**3****현장 조사원이 전하는 도로 위 현실**

과거 자동차 보험 사고 현장에서 초동 조사원으로 근무하며 수많은 현장을 누볐던 필자의 경험에 따르면, 사고 현장은 상상보다 훨씬 혼란스럽습니다. 1차 사고의 충격으로 당황한 운전자들은 비상등 점등이나 안전한 대피 같은 기본적인 조치를 잊기 쉽습니다.

조사 과정에서 가장 빈번하게 목격된 원인은 '전방 주시 부족'이었습니다. 하지만 이를 단순히 개인의 부주의로만 치부하기에는 현재의 도로 시스템에 한계가 큼니다. 사고가 발생했을 때 그 위험 신호를 후속 차량에 실시간으로 전달할 수 있는 매개체가 부족하기 때문에, 운전자가 아주 짧은 순간만 주의를 놓쳐도 2차 사고의 희생자가 될 수 있는 구조입니다.

**4****지속 가능한 안전을 위한 '지능형 시스템'으로의 전환**

이제는 운전자의 개인적인 주의력에만 기댈 것이 아니라, 도로 자체가 사고를 감지하고 경고하는 시스템적인 대응이 필요합니다.

**해외 사례와의 비교**

국내는 여전히 비상등이나 삼각대 설치 같은 운전자의 수동적 대응에 의존하는 경향이 큼니다. 반면 해외 교통 선진국들은 사고 자동 감지 시스템, 스마트 도로 인프라, 고속도로 전광판 실시간 경고 등을 통해 시스템이 먼저 위험을 알리는 구조를 갖추고 있습니다.

**우리가 나아가야 할 방향****CCTV 및 센서 네트워크**

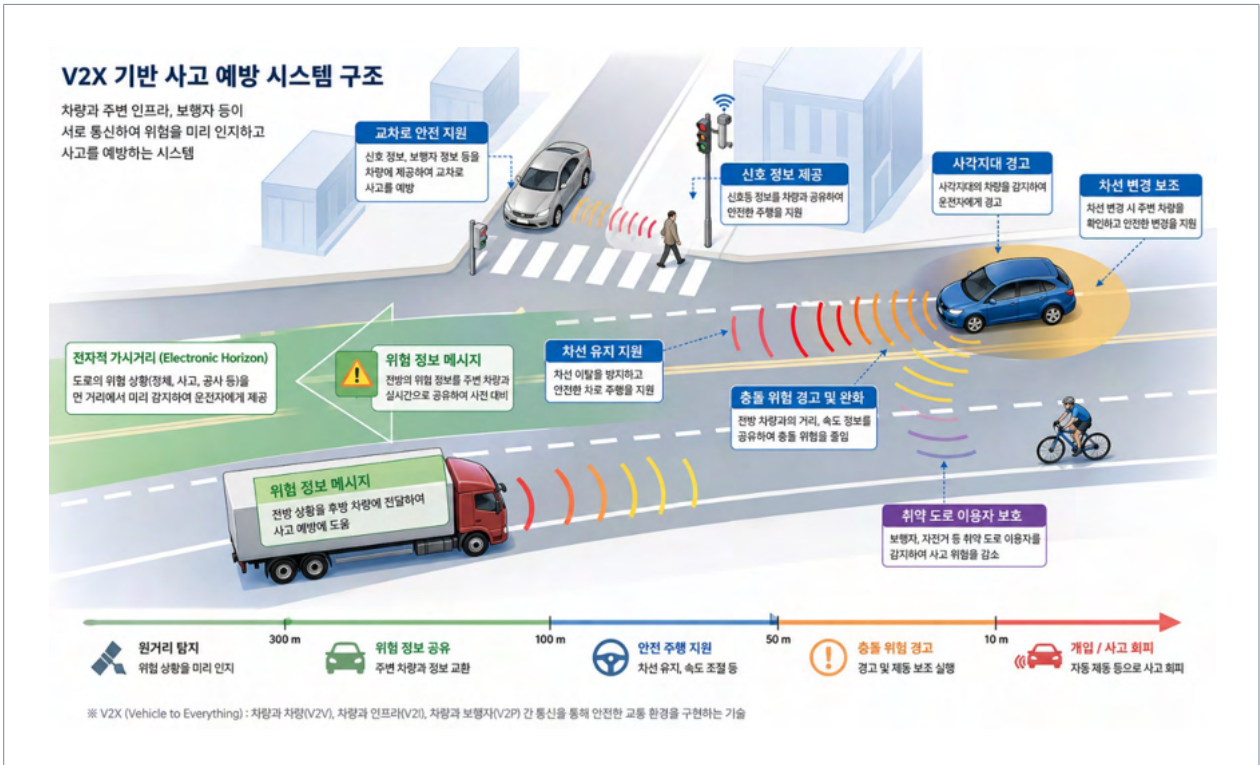
인공지능이 사고를 즉각 감지하여 관리 센터에 보고하는 체계가 확대되어야 합니다.

**스마트 전광판 알림**

사고 지점 수 킬로미터 전방부터 후속 차량들이 위험을 인지하고 감속할 수 있도록 시각적 정보를 제공해야 합니다.

**V2X(차량-사물 간 통신)**

V2X(차량-사물 간 통신) : 사고 차량의 위치 정보가 주변 차량의 내비게이션이나 계기판에 즉시 팝업으로 뜨게 하여 인간의 눈보다 빠른 시스템의 눈으로 사고를 예방해야 합니다.



\* 출처: V2X 및 지능형 교통 시스템 관련 자료를 참고하여 저자 재구성

Fig. 2 사고 예방 시스템 구조

## 5 결론 : "다음 사고만큼은 반드시 막아야 한다"

2차 사고는 개인의 실수와 도로의 구조적 결함이 맞물려 발생하는 전형적인 인재입니다. 1차 사고를 완벽히 통제할 수는 없지만, 그 이후의 추가 사고는 고도화된 기술과 세밀한 제도를 통해 충분히 방지할 수 있습니다.

사고가 발생했을 때 가장 중요한 원칙은 '운전자가 위험을 보기 전에 시스템이 먼저 알려주는 것'입니다. 보다 안전한 대한민국 도로를 만들기 위해서는 개인의 안전 수칙 준수는 물론, 도로 인프라의 스마트화와 같은 국가적 차원의 발전이 함께 이루어져야 합니다. 1차 사고를 피할 수 없었다면, 그다음 사고만큼은 반드시 막아야 한다는 것이 우리 사회가 공유해야 할 가장 큰 숙제입니다.

Part

## 02



조민제

• 경찰대학 공공안전학과 연구원

# AI 대전환 시대, 교통사고 전문가의 역할

1

## 서론 : 교통사고 전문가의 역할 재정립

현시대의 인공지능 기술은 보조적 활용 단계를 지나, 업무의 주요 의사결정과 현장 업무에 직접 사용되는 시점에 있다. 불과 몇 년 전만 해도 AI는 문서를 요약하거나 질문에 답하는 기능 정도로 인식되는 경우가 많았지만, 이제는 텍스트뿐 아니라 이미지, 음성, 영상, 각종 센서 데이터까지 해석하고, 필요한 도구를 자동으로 호출해 연속적으로 수행하는 방향으로 빠르게 진화하고 있다. 2022년 11월 ChatGPT<sup>1)</sup>의 공개는 이러한 변화의 출발점이었고, 이후 GPT-4는 이미지와 텍스트를 함께 다루는 멀티모달 모델로 확장되었으며, GPT-4o(‘o’는 ‘omni’)는 텍스트·음성·이미지·비디오를 통합적으로 처리하는 방향을 보여주었다. 최근에는 이러한 흐름이 ‘에이전트’라는 개념으로 발전되고 있으며, AI는 단순 문답을 넘어 도구 사용, 작업 분해, 다중 단계 실행을 수행하는 구조로 발전하고 있다.

이 변화는 교통사고 분야에 특별한 의미를 가져올 가능성이 많다. 교통사고 조사는 복합적이고 다층적인 영역이기 때문이다. 교통사고는 단지 차량의 접촉만을 조사·분석하지 않는다. 운전자와 목격자의 진술, 블랙박스와 CCTV 영상, 현장 사진, 현장도면, 노면 흔적, 도로 구조, 신호 주기, 제한속도, 차량 손상, 기상과 조도, 요즈음에는 차량 내 기록과 통신 이력까지 함께 보아야 비로소 전체 정황이 드러난다. 따라서 서로 다른 형식의 증거를 연결하고 구조화해 사실관계를 재구성하는 고도의 전문 작업이라 할 수 있다.

따라서, 오늘날의 AI, 특히 AI의 멀티모달은 교통사고 조사 분야에 활용할 가치가 높다.

1) Generative Pre-trained Transformer / 인공지능경망 언어모델의 한 종류



<그림 1> 생성형 AI의 종류 (출처 : 각 사업자 로고)

그러나 이 변화가 곧바로 ‘AI가 교통사고 전문가를 대신한다.’는 뜻은 아니다. 오히려 진짜 전문가가 필요한 시대라 할 수 있다. AI가 다루는 데이터가 많아질수록, 사고 판단이 공학적 분석과 법적 책임 판단을 동시에 포함할수록, 결과를 검증하고 선별하는 교통사고 전문가의 역할은 더욱 중요해질 것이다. AI 시대의 교통사고 전문가는 단순히 조사 경력이 많은 사람이 아니라, 멀티모달 증거를 공학적으로 해석하고, 법률적으로 검증하며, AI 결과를 비판적으로 활용할 수 있는 이른바 하이브리드 전문가로 발전해야 한다.

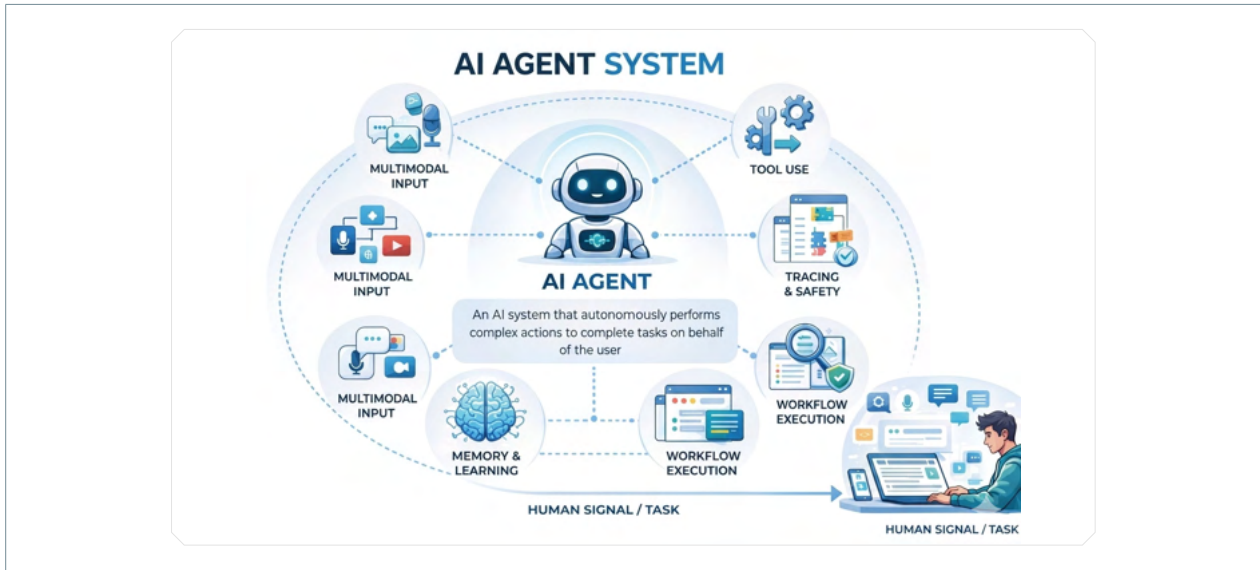
## 2 AI 에이전트 그리고 피지컬 AI

최근 AI는 크게 세 분야로 설명된다. 첫째는 언어모델의 대중화이다. ChatGPT의 등장은 LLM<sup>2)</sup>이 인공지능 연구 대상이 아니라 일반 사용자와 현장 실무자가 사용하는 도구가 될 수 있음을 보여주었다. 둘째는 멀티모달화이다. GPT-4는 이미지와 텍스트를 함께 입력받아 해석하는 방향을 제시했고, GPT-4o(‘o’는 ‘omni’)는 텍스트·오디오·이미지·비디오를 하나의 모델이 통합적으로 처리하는 방향을 제시했다. 셋째는 에이전트화이다. 최근 AI는 질문에 답하는 수준을 넘어 알아서 도구를 사용하고, 단계를 나누어 처리하고, 다른 모듈과 협력하며, 작업을 끝까지 수행하는 구조로 발전하고, 이는 AI가 더 이상 ‘기존 검색엔진보다 편한 검색툴’이 아니라, 정식 업무 절차를 수행하는 실제 에이전트로 발전하고 있음을 뜻한다.

게다가, 최근 업계에서는 피지컬 AI(Physical AI)라는 표현이 대두되고 있다. 피지컬 AI는 카메라, 로봇, 자율주행차와 같은 시스템이 물리 세계를 인식하고, 이해하고, 추론하고, 실제 행동을 수행하거나 조정하는 기술을 통칭한다. 즉, 화면 속 텍스트를 해석하는 수준을 넘어, 실제 공간과 객체, 이동체, 환경 변화까지 다루는 단계로 진입하고 있다는 것이다. 자율주행과 스마트 모빌리티가 바로 이 피지컬 AI의 대표적 응용 영역이라는 점을 고려하면, 교통사고 분야는 AI 변화의 중심에 있다고 해도 과언이 아니다.

이러한 흐름은 교통사고 전문가에게 두 가지 메시지를 던진다. 하나는 사고 분석 대상이 더 복잡해진다는 점이다. 과거에는 사람의 조향, 제동, 주시 태만이 핵심 변수였다면, 앞으로는 운전자 보조 시스템의 개입 시점, 자동화

2) Large Language Model / 거대 언어 모델



<그림 2> AI 에이전트의 개념 (출처 : 생성형 AI 활용 생성 이미지)

시스템의 인지 한계, 지도와 센서의 불일치, 통신 기반 경고 체계의 작동 여부까지 함께 검토해야 한다. 다른 하나는 분석 도구도 달라진다는 점이다. 이제 전문가는 단순히 현장 사진을 보며 판단하는 수준이 아니라, AI가 추출한 거리·속도·객체 추적 결과와 법률 추천 결과를 함께 검토하는 역할로 이동하게 된다. 다시 말해 AI 발전은 교통사고 전문가의 업무를 단순화하기보다, 오히려 더 고차원적인 판단자로 역할을 승격시키고 있다.

### 3

## 교통사고 조사와 AI 멀티모달<sup>3)</sup>

교통사고 조사는 기본적으로 '멀티모달한' 업무라 할 수 있다. 사고 원인을 밝히려면 당사자의 진술, 자동차에 남아있는 기록, 현장에 남은 흔적, 교통 인프라의 상태, 법규 기준이 하나의 분석 체계에서 분석되어야 한다. 당사자 진술은 사고 인지 및 반응을 알 수 있지만, 기억 왜곡 및 자기방어 가능성이 있다. 영상자료는 현상 상황이 담겨있지만 렌즈 왜곡과 시야각 한계, 조도 등이 문제가 있을 수 있다. 현장 사진 및 도면은 현장 구조를 파악하는 데 유용하지만, 사고의 시간적 전개를 알 수 없다. 결국 교통사고의 실제적 진실은 하나의 증거로는 알 수 없고, 서로 다른 성질의 증거가 연결될 때 비로소 알 수 있다.

이것이 멀티모달의 본질이라 할 수 있다. 멀티모달은 텍스트, 이미지, 영상, 음성 등 이질적 데이터를 동시에 다루며, 각각의 데이터를 공통된 맥락으로 정렬하고 분석할 수 있다.

교통사고 조사에 이를 적용하면, 각각의 증거를 하나의 사건으로 연결하는 일련의 과정이 통합업무 체계로 연결될 수 있다. 교통사고 분석 AI의 역할은 '결론을 대신 내려주는 것'이 아니라, 흩어진 증거를 연결 가능한 형태로

3) Multimodal / 텍스트, 이미지, 오디오, 비디오, 센서 데이터 등 다양한 유형의 정보(모달리티)를 동시에 처리하고 통합적으로 이해하는 인공지능

구조화해 주는 것이다. 이 기능은 교통사고 조사에서 매우 실질적인 가치가 있다고 생각된다.

교통사고 현장에서는 조사시간이 부족하고, 조사관의 주의를 분산되기 쉽고, 초기 진술은 놓치면 다시 확보하기 어렵다. 영상은 수십 분 분량이지만 실제로 의미 있는 장면은 몇 초에 불과할 수 있다. 여러 정보가 넘쳐나는 현대에 중요한 것은 ‘데이터가 있느냐’보다, ‘그 데이터를 얼마나 빨리, 정확하게, 비교 가능한 상태로 구조화하느냐’이다. 멀티모달은 이 구조화의 병목을 줄여 줄 수 있다. 따라서 교통사고 분야에서 AI의 핵심 가치는 증거 간 연결성과 조사 프로세스의 통합에 있다고 본다.

#### 4

### 할루시네이션<sup>4)</sup> 과 법적 책임의 문제

다만 교통사고 조사에 AI를 사용할 때 반드시 잊지 말아야 할 점이 있다. 생성형 AI는 본질적으로 ‘그럴듯한 응답을 생성하는 기술’이지, 스스로 진실을 보증하는 기술이 아니라는 것을 염두해 두어야 한다. ChatGPT의 개발사인 OpenAI는 공식적으로 할루시네이션을 ‘사실이 아닌 답을 그럴듯하고 자신 있게 생성하는 현상’으로 설명하고 있다. 즉, AI의 답이 언어적 유창해 보여도 정확성을 보증 하지는 않는다는 것이다.

교통사고 조사에서는 이러한 위험이 더욱 직접적 영향을 준다. 일반 사무 영역에서 잘못된 정보는 수정할 수 있지만, 교통사고 조사에서의 오류는 곧바로 과실 판단, 형사책임, 행정처분, 민사상 손해배상, 보험 처리로 연결된다. AI가 영상의 기준점을 잘못 인식해 속도를 과대 또는 과소 추정하거나, 법률 추천 기능이 유사 조문을 혼동하거나, 사고유형 분류가 잘못되어 다른 판례를 연결하는 경우, 그 오류는 단순한 기술적 오답으로는 볼 수 없다. 따라서 교통사고 조사분야 에서의 AI의 도입은 분석 결과를 누가, 어떤 기준으로 검증할 것인가에 대한 고민이 먼저 수반되어야 한다.

이 부분에서 교통사고 전문가의 역할이 중요해진다. AI시대의 교통사고 전문가는 단순히 ‘AI를 잘 쓰는 사용자’가 아니라, AI가 제시한 결과를 공학적으로 검증하고 법적으로 해석할 수 있는 사람이어야 한다. 속도 추정 결과가 어떤 영상 전처리와 기준점 설정에 기반했는지 이해해야 하고, 동시에 그 결과가 실제 법률상 과실 판단이나 증거 능력 검토에서 어떤 의미를 가지는지 설명할 수 있어야 한다. 교통사고 전문가는 공학과 법률 가운데 어느 한 축만 아는 사람이 아니라, 데이터 분석-사고 재현-법규 해석-문서화 책임을 함께 감당하는 하이브리드 전문가가 되어야 한다.

#### 5

### AI 대전환 시대 ‘하이브리드 교통사고 전문가’

전통적으로 교통사고 조사 전문성은 크게 두 갈래로 나뉘어 왔다. 하나는 차량 운동학, 충돌 역학, 영상분석, 도로공학, 측량과 같은 공학적 전문성이고, 다른 하나는 도로교통법, 교통사고처리특례법, 형사절차, 민사책임, 보

4) Hallucination, 환각 / 생성형 AI가 거짓 정보를 마치 사실인 것처럼 그럴듯하게 꾸며내어 답변하는 현상

험 실무와 같은 법률·제도적 전문성이다. 과거에는 경험 많은 전문가가 이 두 영역 사이를 실무적으로 이어주는 방식으로 기능해 왔다. 그러나 AI가 개입하면, 두 영역은 단순 병렬 관계가 아니라 상호 검증 관계로 볼 수 있다. AI가 추출한 공학적 결과를 법적으로 해석해야 하고, 반대로 법적 판단 기준에 맞게 어떤 데이터를 수집하고 어떤 분석을 수행해야 할지도 결정해야 하기 때문이다.

예를 들어, 영상 기반 속도 추정 모델을 교통사고 조사에 사용한다고 하면, 특정 사고유형에서 어떤 기준점을 잡았는지, 촬영각과 원근 왜곡은 어떻게 교정했는지, 객체 추적의 누락 구간은 어떻게 보정했는지, 악천후·야간·역광 상황에서 오차가 얼마나 커지는지까지 이해해야 한다. 동시에 그 결과가 법원이나 수사 단계에서 어떤 수준의 참고자료인지, 직접증거인지 보조정황인지, 조사보고서에 어떤 방식으로 기재되어야 하는지도 판단해야 한다. 이는 공학, 법률 한 분야의 지식으로는 해결하기 어렵다고 볼 수 있다.

따라서, 앞으로 교통사고 전문가에게 요구되는 역량은 다음과 같다. 첫째, 멀티모달 데이터 해석 역량이다. 진술, 영상, 사진, 도면, 위치정보, 인프라 정보를 한 맥락에서 읽어낼 수 있어야 한다. 둘째는 AI 결과 검증 역량이다. 모델이 내놓은 값이 어떤 한계와 가정을 갖는지 파악할 수 있어야 한다. 셋째, 법적 적합성 판단 역량이다. 기술 결과를 법률상 책임 판단과 연결할 수 있어야 한다. 넷째, 문서화와 설명 책임 역량이다. 조사 결과를 보고서, 법정, 행정 절차, 보험 심사 과정에서 설명할 수 있어야 한다. 다섯째, 새로운 모빌리티 기술의 이해 역량이다. 자율주행, 원격개입, V2X, 센서융합, 소프트웨어 업데이트 문제까지 이해해야 한다. 현실적으로 AI 시대의 교통사고 전문성은 한 분야의 숙련을 넘어, 여러 전문영역을 연결하는 역량으로 재편될 수밖에 없다.

## 6

## AI시대, 교통사고 조사를 위한 경찰청의 연구개발 사업

AI가 산업 전반의 업무 방식을 바꾸고 있는 지금, 경찰청 역시 교통사고 조사 분야의 미래를 대비한 연구개발로 미래를 대비하고 있다. 경찰청은 과학기술정보통신부와 함께 현장 중심의 치안문제 해결을 위한「치안현장 맞춤형 연구개발사업(폴리스랩3.0)」을 추진하고 있다. 이는 이미 만들어진 기술의 도입이 아니라, 실제 치안현장의 문제를 자체 연구개발을 통해 해결하려는 시도라는 점에서 큰 의미를 갖는다.

폴리스랩 3.0 중 하나의 과제인「지능형 교통사고현장 데이터 처리 및 스마트 분석 시스템」은 AI시대 교통사고 조사체계의 전환을 보여주는 대표적 사례라 할 수 있다. 해당과제는 과제는 2025년부터 2027년까지 30개월 동안 총사업비 13.87억 원 규모로 진행된다.

과제의 목표는 AI 교통사고 조사 지원 시스템 개발, 다른 하나는 교통사고 조사 데이터 처리 및 공유 시스템 구축이다. 즉, AI를 교통사고 조사 현장에 실제로 적용해 조사 지원, 데이터 처리, 증거 관리, 분석 고도화를 동시에 이루겠다는 구상이다.

특히, 해당 과제의 강점은 단순히 최신 AI 기술을 나열하는 데 그치지 않고 교통사고 현장의 실제 문제를 정확히 짚고 해결하려 하는데 있다. 사건초기 현장출동 단계에서 수집하는 증거의 중요성을 고려하여 AI 음성인식 기술을 적용해 운전자와 목격자의 초기 진술 유실을 줄이고, 데이터 인계 자동화를 통해 누락을 방지하며, 영상 및 이미지 용량 최소화와 개인정보 비식별화로 데이터 관리의 안전성과 효율성을 높이겠다는 구상을 제시한다.



<그림 3> 경찰청 폴리랩3.0 착수보고 (출처 : 경찰청)

또한 스마트폰·LiDAR<sup>5)</sup>·포토그래메트리<sup>6)</sup> 기반 3D 측량을 통해 측정의 정밀도를 높이면서도 도로 위 조사시간을 단축해 현장 조사관 안전을 확보하고, 단순 텍스트 중심 검토를 넘어 이미지·영상 기반 이해도 향상과 법률 DB 연계를 통해 보다 정밀한 사고 해석과 법적 판단 지원을 가능하게 하는 기술을 개발하는 것이 목적이다.

이는 단순히 현장에 시를 활용하는 수준이 아니라, 초기 현장출동-현장 조사-결과 보고-자료 보존-후속 분석의 전 과정을 다시 설계하는 치안 혁신 기술이라 평가할 수 있다

## 7 자율주행·원격개입·V2X 시대, 미래의 교통사고

앞으로 교통사고의 양상은 지금보다 더 복잡해질 가능성이 높다. SAE<sup>7)</sup>와 NHTSA<sup>8)</sup>의 자율주행 관련 문서에서, 자율주행 교통사고 조사에서 고려해야 할 문제가 단순히 '운전자의 개입여부'만이 아니라, 원격 개입, 시스템과 인간의 역할 전환 과정 등으로 다양해질 것이라고 예상하고 있다.

여기에 V2X<sup>9)</sup> 통신을 고려하면 사고 원인은 더욱 다층화된다. V2X는 V2V(차량 대 차량), V2I(차량 대 인프라), V2P(차량 대 보행자)를 포괄하는 개념이다. 미래의 교통사고는 더 이상 운전자의 과실이나 고의로 설명되지 않을 수 있다. 잘못된 V2X 메시지, 메시지 지연, 인프라와 차량 간 정보 불일치, 소프트웨어 버전 차이, 지도(LDM<sup>10)</sup>) 누락, 운영설계영역(ODD<sup>11)</sup>) 이탈, 센서융합 실패, 원격운영 개입 시점 오류 등이 원인이 복합적으로 얽힌 사고가

5) Light Detection And Ranging / 레이저 펄스를 발사, 반사되어 돌아오는 시간(ToF)을 측정하여 주변 환경을 측정하는 센서

6) Photogrammetry / 다양한 각도에서 촬영한 수많은 사진을 분석하여 실제 객체나 공간을 정밀한 3D 가상 모델로 변환하는 기술

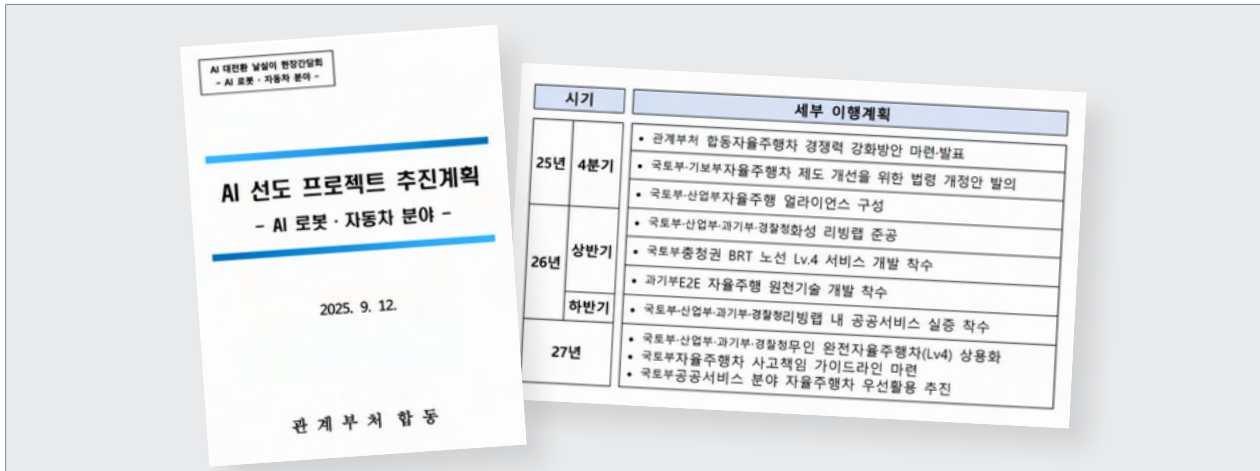
7) Society of Automotive Engineers / 국제자동차기술자협회

8) National Highway Traffic Safety Administration / 美 도로교통 안전국

9) Vehicle-to-Everything

10) Local Dynamic Map / 도로상의 동적정보(인프라 제공정보, 센서 정보, 날씨정보 등)를 실시간으로 수집-가공-제공-저장-관리하는 정밀지도

11) Operational Design Domain / 자율주행 시스템(ADS)이 안전하게 작동하도록 설계된 지리적 위치, 도로 유형, 기상 조건, 속도 제한 등의 구체적 환경 범위



<그림 4> AI선도 프로젝트 추진계획 / '27년 자율주행 사고책임 가이드라인 마련 (출처 : 관계부처 합동)

등장할 가능성이 크다.

이런 변화는 사고조사의 기준 자체를 바꾼다. 과거에는 충돌 직전 몇 초 동안의 운전자 행위가 핵심이었다면, 앞으로는 시스템 로그, 객체·사건 탐지와 대응(OEDR<sup>12)</sup>) 수행 여부, ODD 조건 충족 여부, HMI<sup>13)</sup> 설계, 인간-시스템 역할분담, 통신 인프라 상태, 업데이트 이력, 원격 지원 기록 등이 함께 조사 대상이 된다. 미래의 교통사고 조사는 소프트웨어, 통신, 지도, 센서, 법규, 인간요인이 결합된 총체적 원인 분석으로 확장될 것으로 보인다.

## 8

### 결론 : AI 대전환 시대, 교통사고 전문가의 역할

AI 대전환 시대에 교통사고 전문가의 역할은 축소되지 않는다. 오히려 훨씬 더 정교하고 무거운 책임을 지게 될 것으로 예측할 수 있다. 멀티모달 증거를 구조화하고, AI가 추출한 결과를 검증하며, 공학적 사실을 법적 판단과 연결하고, 자율주행·원격개입·V2X·피지컬 AI 시대의 새로운 사고원인을 해석하는 전문가로 발전해야 한다. 즉 미래의 교통사고 전문가는 조사자이면서 데이터 해석자이고, 동시에 법적 검증자여야 하는 것이다.

결국 핵심은 AI 자체가 아니다. AI를 제대로 이해하고, 한계를 알고, 증거와 법규의 언어로 다시 검증할 수 있는 역량이다. 앞으로의 교통사고 전문가는 더 많은 데이터를 다루게 될 것이고, 더 복잡한 기술 시스템을 이해해야 하며, 더 엄격한 책임을 요구받게 될 것이다. 그러나 바로 그 이유로, AI 시대의 교통사고 조사 업무는 이전 보다 더욱 중요한 업무가 될 것이며 교통사고 전문가는 다양한 전문성을 폭넓게 함양해야 하는 시대가 될 것으로 생각한다.

12) Object and Event Detection and Response / 자율주행 시스템이 주행 중 차량 주변의 보행자, 타 차량, 동물, 장애물 등을 감지하고 적절한 제어 및 반응을 수행하는 것

13) Human Machine Interface / 사람과 시스템 간의 상호작용을 가능하게 하는 사용자 인터페이스

Part

# 03



조은솔

• (주)하이스트시스템텍스  
연구개발전담부서 책임연구원

## 배달 이륜차 사고 예방을 위한 주행 데이터 기반 위험 징후 분석과 활용 가능성

- 플랫폼 노동 구조 변화와  
SAFESCOOT 운영 체계를 중심으로 -

1

### 문제 제기 : 이륜차 사고 감소의 한계

한국도로교통공단이 2025년 5월 발표한 「2024년 교통사고 통계분석」에 따르면, 2024년 한 해 동안 발생한 전체 교통사고 사망자는 2,521명으로 역대 최저(12년 연속 감소)를 기록하였다. 그럼에도 이륜차 교통사고는 여전히 15,290건, 사망자 361명 수준이며, 전체 교통사고 사망자 중 이륜차 사망 비중은 14.3%에 이른다. 이륜차 등록대수는 약 230만 대 수준으로 전체 자동차의 약 9~10% 수준에 해당함에도 불구하고, 사망 비중은 상대적으로 높은 수준을 보이며, 이륜차 교통안전은 전체 교통사고가 감소하는 흐름 속에서도 구조적 취약성이 두드러지는 영역으로 남아 있다.

이륜차 사고 건수는 2021년 20,598건에서 2024년 15,290건으로 약 25.8% 감소하였으나, 감소 폭의 상당 부분은 코로나19로 인한 비대면 배달 수요가 급증했던 시기의 정점에서 완화된 결과로 해석할 수 있다. 반면 이 기간 동안 배달 이륜차의 주행 빈도와 플랫폼 종사자 규모는 지속적으로 확대되었다. 한국고용정보원 「플랫폼 종사자 규모와 근로 실태」 조사에 따르면 전체 플랫폼 종사자는 약 90만 명 수준이며, 이 중 배달운전 직종은 약 50만 명 내외로 가장 큰 비중을 차지한다. 즉, 단위 주행 노출 대비 이륜차 사고 위험은 여전히 높은 수준으로 평가할 수 있다.

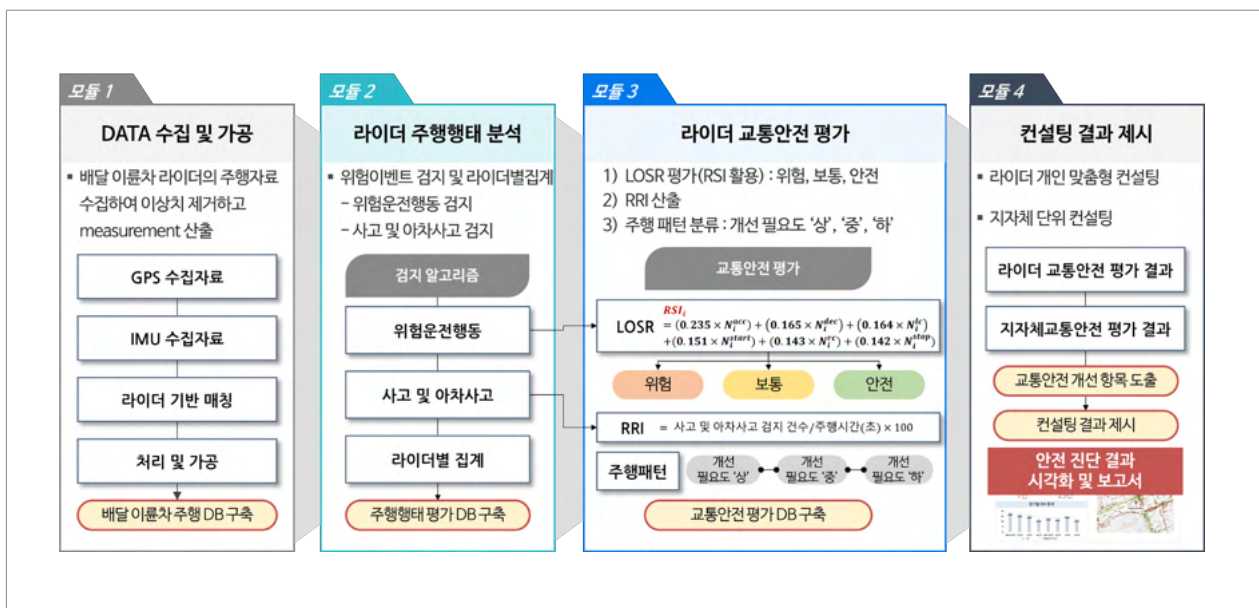
## 2

## 배달 이륜차 위험의 구조적 배경 : 플랫폼 노동과 시 배차

배달 이륜차 사고는 개인 부주의의 누적만의 영향보다는, 플랫폼 노동의 구조에 내재된 위험이 도로로 외재화되는 현상에 가깝다. 근로복지공단에 따르면 배달 라이더의 산재 승인 건수는 최근 몇 년간 급격히 증가하였으며, 보험급여 지급 규모 또한 크게 증가하는 추세를 보이고 있다. 또한 배달 노동자 산재 사망자 수 역시 지속적으로 증가하는 경향이 확인되었다. 최근에는 배달 플랫폼 종사자의 산재 승인 건수가 상위권을 차지하며, 배달업은 산업재해 주요 업종 중 하나로 부상하고 있는 상황이다.

이와 같은 양상은 플랫폼 노동의 인센티브 구조와 맞닿아 있다. 대부분의 배달 라이더는 근로기준법상 근로자가 아닌 ‘플랫폼 종사자(특수형태 근로종사자)’ 지위에 해당하며, 수입은 건당 배달료와 피크 프로모션, 날씨 할증 등 변동 보상에 영향을 받는다. 시간 제약이 강하고 변동 보상이 큰 체계는 건당 회전율을 높이기 위한 위험운전행동(급가속, 급감속, 급진로변경)을 사실상 합리적 선택으로 이어지게 한다. 2023년 라이더유니온 실태조사에서도 자동 배차 수락 비율이 높아질수록 하루 평균 주행거리와 주행강도가 증가하는 경향이 확인되었으며, 알고리즘 배차가 ‘사고 확률’은 낮추더라도 ‘주행 노출과 속도 유지 부담’은 오히려 높인다는 지적이 제기된다. 즉, 플랫폼 환경에서의 위험 주행은 개인 일탈적 행동만은 아니라 시간, 경로, 인센티브가 복합적으로 작용한 구조적 산물로 이해할 필요가 있다.

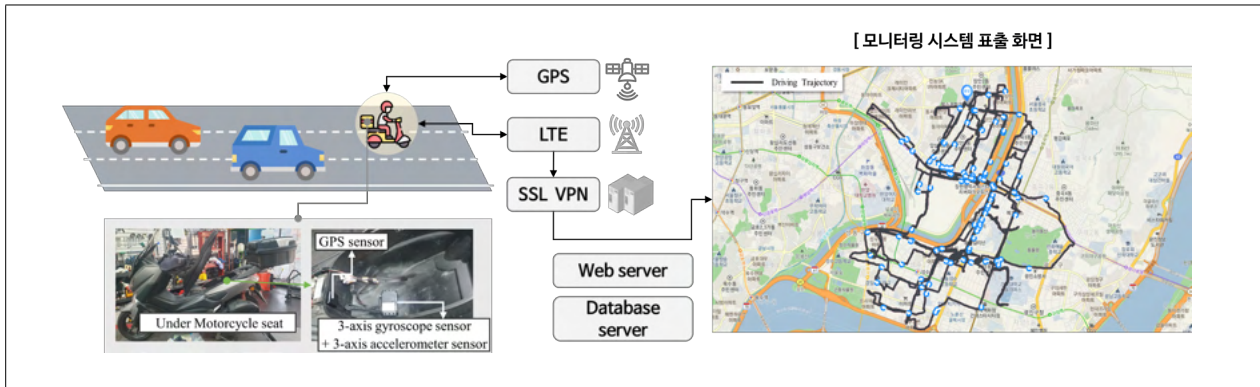
위와 같은 관점에서 보면, 배달 이륜차 교통안전은 주행 결과(사고 건수)만이 아니라 주행 과정에서 누적되는 위험 신호를 실시간으로 검지 및 관리하는 방향으로 이동해야 한다. 본 원고는 한국형 100대 이륜차 주행자료 연구(K-100NRS) 기반 교통안전 모니터링 체계와, 이를 실서비스로 확장한 SAFESCOOT 플랫폼을 중심으로 이 방향을 구체화한다.



[그림1] SAFESCOOT 구축 기반 프레임워크

### 3.1 데이터 수집 체계

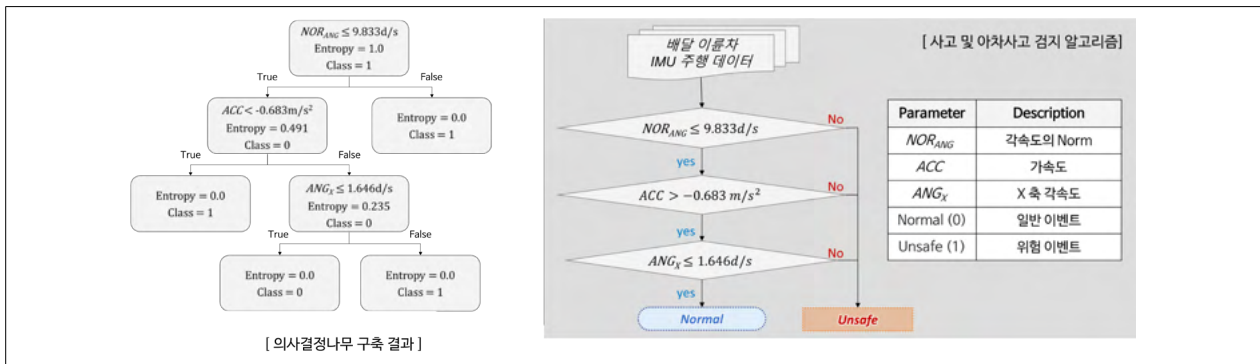
2021년 산업안전보건공단에서는 배달 이륜차 100대에 통신 게이트웨이‘SeDA-Gateway(GPS + 6축IMU 내장, LTE 실시간 전송)’를 장착하여, 5대 도시 라이더 100명의 실제 배달 주행을 약80일간 1초 단위로 연속 수집하였다.



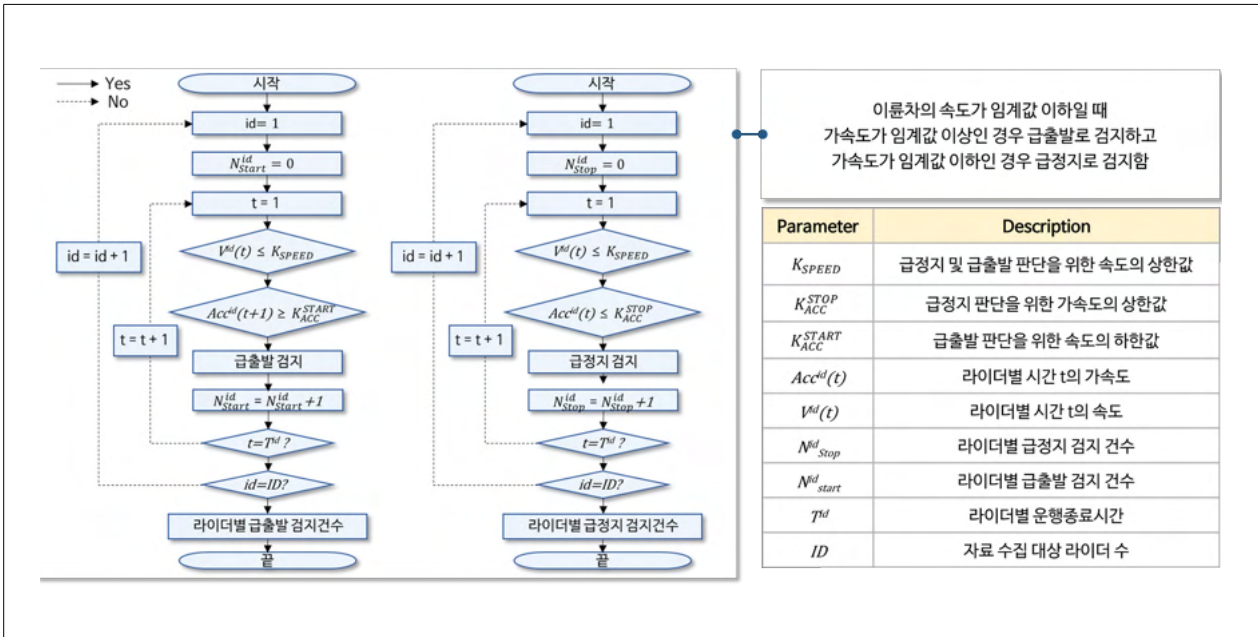
[그림2] K-100NRS 데이터 수집 체계 구성도(SeDA-Gateway 기반)

### 3.2 위험 이벤트 감지 알고리즘-Unsafe 분류 & 위험운전행동 감지

수집된 데이터를 대상으로 의사결정나무 분석을 수행한 결과, 위험 이벤트와 정상 이벤트를 가장 잘 구분하는 세 변수는 ① 각속도Norm(NOR\_ANG), ② 가속도(ACC), ③ X축 각속도(ANG\_X)로 도출되었다. 각속도Norm은 3축 각속도를 벡터 합성한 값으로, 이륜차가 어느 방향으로 얼마나 격렬하게 회전하는지를 종합적으로 표현한다. ANG\_X는 좌우 기울기(롤링)의 변화량을 뜻하며, 균형 이탈 및 전도의 직접 전조로 기능한다. 이후 동일 데이터셋에 서포트 벡터 머신(SVM)을 적용하여, 1초 단위 스트리밍 데이터만으로도 위험 기동 여부를 99.5%의 정확도로 실시간 판별할 수 있음을 검증하였다.



[그림3] 의사결정나무 기반 위험 이벤트 자동 분류 알고리즘



[그림4] 급출발 및 급정지 알고리즘

### 3.3 주행 안전지표 기반 라이더 안전등급 평가

K-100NRS 기반 모니터링 체계에서는 라이더의 주행 안전 수준을 정량화하기 위해 두 가지 평가지표를 활용한다.

**주행 위험 지수(RRI: Riding Risk Index)** 결정트리 분류 알고리즘을 통해 판별된 위험 이벤트의 발생 비율이다. 전체 주행 시간 대비 위험 이벤트 발생 시간의 비율(%)로 산출되며, 값이 클수록 주행 시간 중 위험 기동의 비율이 높음을 나타낸다.

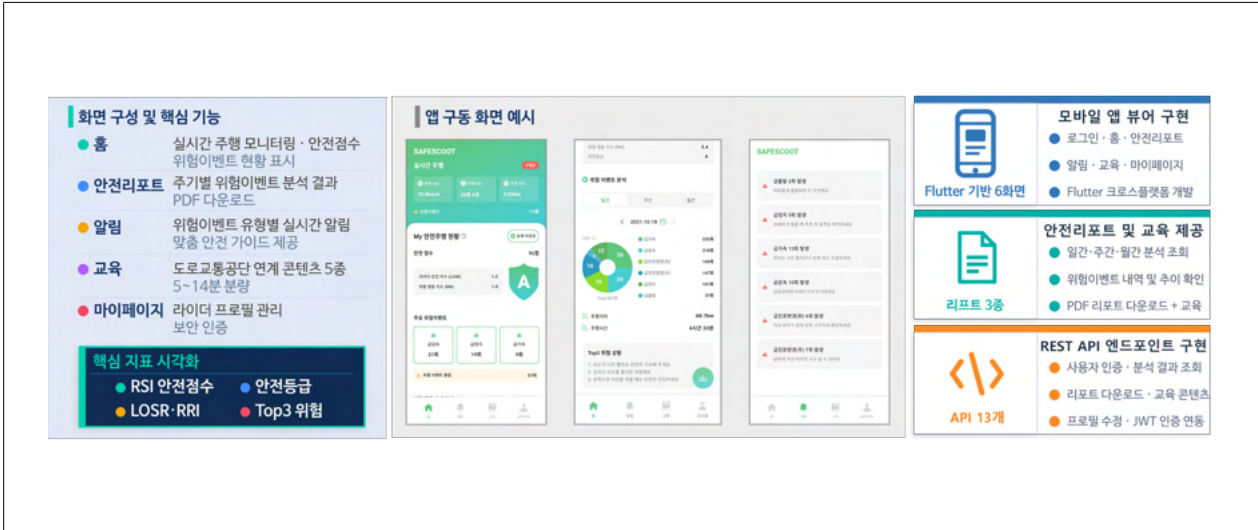
$$RRI(\%) = (\text{위험 이벤트 발생 건수} / \text{총 주행 시간}) \times 100$$

**주행 안전 지수(RSI: Riding Safety Index)** 6종 위험운전행동 검지 결과를 집계하여 산출하는 SAFESCOOT의 핵심 운영 안전점수이다. RSI는 급가속, 급감속, 급출발, 급정지, 급진로변경(좌·우) 6종 위험운전행동의 발생 빈도와 강도를 종합하여 라이더별 A-E 5단계 안전등급을 부여하는 기반이 된다. RRI가 '위험 주행 시간 비율'을 나타내는 연구 지표라면, RSI는 '6종 위험운전행동의 누적 빈도'를 반영하는 실서비스 운영 지표이다.

## 4 SAFESCOOT- 연구 방법론의 실서비스 전환

최근에는 이러한 데이터 기반 모니터링 체계를 실제 서비스 형태로 구현하고 주행 데이터 기반 교통안전 관리가 적용되는 단계로 발전시키고 있다. K-100NRS에서 검증된 위험 징후 도출, 위험운전행동 검지, 안전등급 분류 방법론은, 하이스트시스템즈(HyST Systems)를 통해 스트리밍 기반 실서비스 플랫폼인 SAFESCOOT로 구현되

었다. SAFESCOOT는 ① 라이더 이륜차에 수집된 1초 단위 GPS·IMU 데이터를 가공하고, ② 서버의 실시간 검지 엔진이 6종 위험 이벤트(급가속, 급감속, 급출발, 급정지, 급좌변경, 급우변경)를 식별하며, ③ 라이더별 RSI 와 A~E 5단계 안전등급을 산출하여 개인별 리포트를 제공하는 구조다.



[그림5] SAFESCOOT 실서비스의 주요 기능

SAFESCOOT가 의미를 갖는 지점은 기술적 검지 정확도보다 정책 및 산업 구조와의 연계에 있다. <그림5>와 같이, SAFESCOOT는 라이더 개인의 안전 운행 데이터를 ① 보험사에는 개인별 위험도에 따른 보험료 할인 근거로, ② 지자체에는 교통안전 KPI 달성과 데이터 기반 정책 의사결정의 근거로 제공한다. 이는 단속 중심의 사후 대응 체계를 '안전 운행이 경제적 이익으로 되돌아오는' 행태 변화 유도 체계로 전환하는 시도이며, 플랫폼 노동자의 수입 변동성 문제를 완화하는 보완적 효과도 기대된다.



[그림6] SAFESCOOT 사업 모델(보험료 감면·성과 기반 보조금)

## 5

## 감정 실무/연구/정책-세 분야에서의 활용 가능성

**(1) 교통사고 감정 실무**

블랙박스 및 EDR 체계화되어 있지 않은 이륜차 사고에서 SAFESCOOT가 축적하는 충돌 전1초 단위 주행 로그는 객관적인 증거의 공백을 메운다. 충돌 직전 가속 여부, 각속도 급변의 시점(위험 인지 및 회피 시점), 평상시 주행 패턴에서의 이탈 정도, X축 각속도 급변에 따른 전도 직전 상태 추정 등 기존에 목격자 진술에 의존하던 부분을 데이터로 보완할 수 있다. 다만 수집 장비 인증·데이터 보존·법적 증거력 인정을 위한 제도 논의가 선행되어야 한다.

**(2) 교통공학 연구**

RRI는 사고가 발생해야만 관측되는 기존 통계의 한계를 보완하는 선행 지표(leading indicator)로 기능한다. 지역RRI 분포와 사고율 간 상관구조, 도로 기하 요인과의 복합 모형, 사고 예측 모형의 설명변수 확장 등은 대규모 실시간 자연주행 데이터가 있어야 가능한 연구 주제이며, SAFESCOOT가 그 기반이 된다.

**(3) 교통안전 정책**

주행안전지표 집계 결과는 ① 고위험 시간과 지역의 집중 관리, ② 50대 이상 라이더 맞춤 안전교육, ③ 플랫폼 사업자시 배차·인센티브 구조의 규제 근거, ④ 보험료 할인·성과 보조금 등 긍정적 행태 변화 유도 정책 설계로 직접 연결된다.

## 6

## 결론 및 제언

배달 이륜차 사고는 개인 일탈이 아니라 플랫폼 노동 구조의 산물이며, 결과가 아닌 과정의 문제이다. 또한 더 이상 사고 이후 대응의 문제가 아니라, 데이터 기반 주행 과정 관리의 문제로 전환되고 있다. 문제 해결의 단위 역시 '사고 후 사후 처벌'에서 '주행 과정 중 위험 징후의 상시 모니터링과 완화'로 이동해야 한다. K-100NRS 기반 체계는 이것이 공학적으로 실현 가능함을 결정트리95.7%·SVM 99.5%의 정확도로 보였고, SAFESCOOT는 이를 실시간 서비스·보험·지자체 정책과 연결하는 운영 체계로 확장하였다.

향후 ① 주행 데이터 수집·포맷 표준화, ② 주행 로그 법적 증거력 제도 설계, ③ 퀵서비스, 전기 자전거 및 PM까지의 확장 연구, ④ 플랫폼의 배차 및 인센티브 알고리즘 공공 감사(audit) 프레임워크 마련이 필요하다.



정동훈

• 서울지부 사고조사연구원

심락현

• 서울지부 사고조사연구원

박기정

• 교통사고종합분석센터 사고조사연구원

백자은

• 교통사고종합분석센터 사고조사연구원

# 머신러닝을 활용한 탑승자 상해 예측 모형 개발

## The Development of a Passenger Injury Prediction Model in Traffic Accidents by Machine Learning

### Key Words

저속 후미추돌 교통사고, 탑승자 상해 예측, MADYMO, 지도학습, 엘라스틱넷 회귀

### Contents

#### I. 서론

- 1 연구의 필요성 및 목표
- 2 연구의 적용 및 절차

#### II. 기존 이론 및 선행 연구 검토

- 1 기존 이론 검토
- 2 관련 연구 동향 분석
- 3 주요 시사점 및 차별성

#### III. AI 기반 충격력 분석 모델 연구

- 1 데이터 확보 및 가공
- 2 저속 후미추돌 사고의 충격력 예측 모델 구축

#### IV. 탑승자 상해 예측 모형 구축 및 성능 검증

- 1 저속 후미추돌 사고의 상해 예측 모형 연구
- 2 예측 모형 신뢰성 검증
- 3 선행 연구 실험 데이터 비교분석을 통한 검증

#### V. 연구 결과 및 향후 개선점

## I. 서론

### 1

### 연구의 필요성 및 목표

자동긴급제동시스템(AEBS, Autonomous Emergency Braking System)은 차량 충돌 시 사고의 중대성을 낮추는 데 효과적인 기술이지만, 반면 저속 추돌 사고의 빈도를 증가시킬 가능성도 있다. 이로 인해 경미한 수준의 사고에서 발생하는 경제적 손실을 정밀하게 평가하는 것이 필수적이다. 국내에서 보고된 교통사고 통계 자료에 의하면, 경미한 사고로 인해 발생하는 사회적 비용은 지속적으로 증가하고 있으며, 이는 의료기관의 과잉진료나 보험사기와 같은 부정적인 사회 현상과 깊은 연관이 있는 것으로 나타났다.

한국뿐만 아니라 미국에서도 경상자 치료비의 상당 부분이 불필요한 의료 행위로 인해 과다하게 증가하고 있다는 연구 결과가 보고된 바 있다. 이에 따라

영국과 독일 등 유럽 국가에서는 특정 속도 이하에서 발생한 경미한 사고에 대해 보험 책임을 제한하는 정책을 도입하여 사회적 비용을 줄이고자 노력하고 있다.

국내에서는 한국도로교통공단과 국립과학수사연구원이 교통사고 데이터를 분석하고, MADYMO-(MAtheMatical DYnamic MOdels) 시뮬레이션을 활용하여 충격력을 산출한 후, 기존 연구에서 제시된 상해 기준과 비교하여 탑승자의 부상 가능성을 평가한다. 그러나 MADYMO 프로그램은 비용이 높고 구조가 복잡하여 경찰이나 보험사 등 실무 기관에서 활용하기 어려운 한계가 있다. 따라서 교통사고 현장에서 수집된 정보를 기반으로 차량 충격력을 효과적으로 평가하고, 이를 통해 신속하고 직관적으로 탑승자의 부상 가능성을 예측할 수 있는 실용적인 판단 기준이 요구된다.

본 연구는 저속 후미추돌 사고로 인한 보험사기와 도덕적 해이로 발생하는 사회적 비용을 감소시키고자, 교통사고 데이터와 MADYMO 해석 데이터로 머신러닝 회귀 모델을 개발하고, 이를 선행 연구에서 수행된 실제 차량 추돌 실험 결과와 비교 분석하였다. 이를 통해 사고 현장에서 수집된 정보를 활용하여 차량의 충격력과 탑승자의 부상 가능성을 보다 정밀하게 예측하는 방안을 제안하며, 경찰 및 보험사 등 실무 기관이 신속한 의사결정을 내릴 수 있도록 지원하는 도구를 마련하는 것을 목표로 한다.

## 2

## 연구의 적용 및 절차

본 연구의 목적은 저속 후미추돌 교통사고에서 탑승자의 상해 가능성을 예측할 수 있는 머신러닝 기반 충격력 분석 모델을 개발하는 것이다. 연구 범위는 2020년부터 2022년까지 한국도로교통공단에서 수집한 저속 후미추돌 사고 데이터를 활용하여, 사고 발생 시 차량에 가해지는 충격력과 이에 따른 탑승자의 상해 여부를 예측하는 데 중점을 두었다. 이를 위해 추돌 속도, 차량 간 중량 차이, 추돌 각도 등 다양한 변수를 분석하고, 보다 정밀한 상해 예측이 가능하도록 모델을 설계하였다.

연구 절차는 다음과 같이 구성된다. 첫째, 기존 연구 검토 및 이론적 분석을 수행하였다. 저속 후미추돌 사고와 관련된 선행 연구를 분석하여 사고 발생 시 충격력과 탑승자 상해 임계값(속도 변화량, 충격 가속도 등)에 대한 연구 결과를 검토하고, 상해 여부를 결정하는 주요 변수를 도출하였다. 또한, 이전 탑승자 상해를 예측하는 모델의 제약을 파악하고 이를 보완하기 위한 머신러닝 기법의 필요성을 논의하였으며, 기존 시뮬레이션 프로그램을 통해 분석된 충격력과 탑승자 상해 여부에 대한 대법원 판례를 조사하였다.

둘째, 데이터 수집 및 전처리를 수행하였다. 한국도로교통공단에서 제공하는 저속 후미추돌 사고 데이터를 활용하여 종속 변수와 독립 변수를 통계적 기법을 통해 선정하였으며, 모델의 예측 성능을 향상시키기 위해 원핫 인코딩 등의 데이터 전처리 기법을 적용하였다.

셋째, 충격력 예측 모델을 개발하였다. 머신러닝을 활용하여 충격력을 예측하기 위해 선형, 엘라스틱넷, 의사결정나무, 랜덤 포레스트 등 다양한 회귀 모델을 적용하고, 속도 변화량 및 충격 가속도를 예측하는 데 있어 각 모델의 성능을 평가하였다. 또한, 주요 변수의 중요도를 분석하여 정량적으로 도출하였다.

넷째, 상해 예측 모델을 구축하고 평가하였다. 충격력 예측 결과를 바탕으로, 기존 연구에서 정의된 상해 기준(속도 변화량 8~10 km/h, 최대 충격 가속도 5~7G)과 비교하여 탑승자의 상해 가능성을 예측하는 모델을 개발하

였다. 예측 값과 상해 기준을 비교하여 상해 여부를 판단하였으며, 혼동 행렬을 활용하여 모델의 예측 성능을 평가하였다.

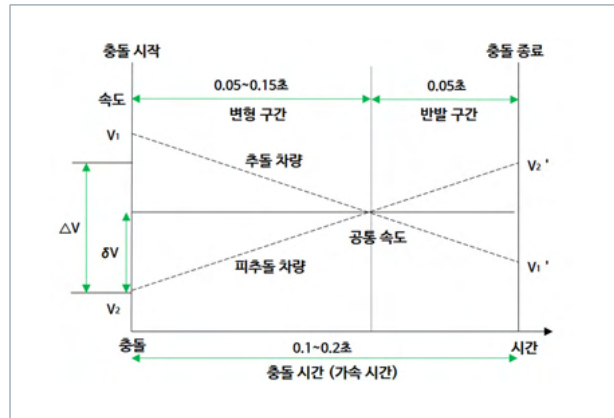
## II. 기존 이론 및 선행 연구 검토

### 1 기존 이론 검토

#### 1) 저속 후미추돌 교통사고의 개념

저속 후미추돌 사고는 일반적으로 차량이 급정지 가능한 낮은 속도 영역에서 발생하는 사고로, 특히 자동 변속 차량이 가속 페달 조작 없이 전진('D') 또는 후진('R') 모드에서 서행 중 발생하는 추돌 사고로 정의된다. 즉, 저속 상태에서 차량 간 접촉이 발생하면 차량 변형이 상대적으로 적고, 충돌 에너지가 낮다는 특징이 있다.

이러한 유형의 충돌 사고는 주로 차량의 진행 방향과 일치하는 종축 방향(X축)을 중심으로 해석하며, 전체 충돌 상황을 변형 단계와 반발 단계라는 두 가지 영역으로 나누어 분석할 수 있다. 변형 영역에서는 추돌차량과 피추돌차량의 속도가 동일하게 되는 순간까지 두 차량 간의 운동 에너지가 전달되고, 이때 일부 구조적 변형이 발생한다. 반발 영역에서는 두 차량이 접촉한 이후 다시 분리되며, 이 과정에서 일부 운동 에너지가 반발 형태로 소모된다. 변형 영역은 충돌 직후 동일한 속도에 이를 때까지 진행되며, 반발 영역은 약 0.05초의 짧은 시간 동안 이루어진다. 이와 같은 과정에서 나타나는 속도의 변화(Delta-V)와 충돌 지속 시간은 사고의 심각도를 평가하고 탑승자 상해 가능성을 예측하기 위한 핵심적인 변수로 활용된다. 이때의 충격력 지표는 사고의 위험성을 판단하는데 중요한 기준으로 작용한다.



<그림 1> 저속 후미추돌 시 접촉 지속 시간, 변형 영역, 그리고 탄성 복원 영역의 핵심 요소

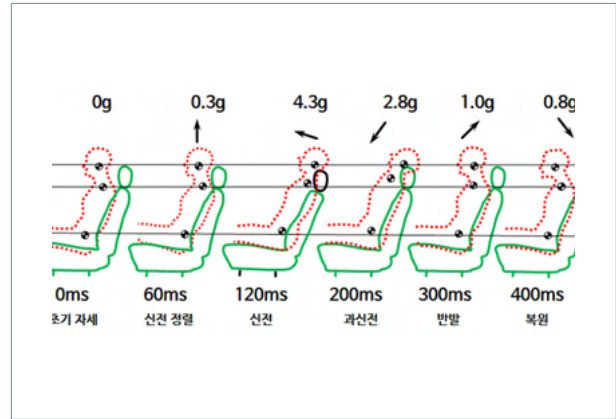
#### 2) 인체 충격 하중 및 동역학적 특성

저속 후미추돌 사고에서는 피추돌 차량이 앞으로 가속되지만, 탑승자는 관성의 영향으로 초기에는 제자리를 유지하려는 경향을 보인다. 이로 인해 상반신이 좌석 등받이에 의해 앞으로 밀리며, 목과 머리는 이후 지연된 반응을 보이며 여러 단계의 운동을 거친다. 충격 초기에 탑승자의 몸은 중립 자세를 유지하지만, 이후 척추가 신전되면서 목이 뒤로 젖혀지고, 머리와 상반신이 함께 움직이게 된다. 이후 극단적인 후굴 상태에 도달한 뒤, 머리는 반동 운동을 통해 본래 자세로 돌아간다. 이러한 신체 반응은 충돌 시 발생하는 속도 변화와 충격 가속도의 영향을 받는다.

며, 상해 임계값을 넘어서면 탑승자가 부상을 입을 가능성이 커진다.

교통사고는 다양한 원인과 결과를 동반하며, 특히 차량 손상과 탑승자의 상해 발생 여부에 대한 연구가 활발히 이루어지고 있다. 탑승자의 상해는 충돌 시 발생하는 충격에 의해 발생하며, 이 충격은 신체에 직접적 또는 간접적으로 영향을 미친다. 탑승자가 받는 충격의 정도는 차량의 속도 변화와 충격 가속도를 통해 평가할 수 있으며, 해당 값이 상해 임계값(즉, 인체가 견딜 수 있는 한계)을 초과하면 부상이 발생할 가능성이 증가한다.

속도 변화량(Delta-V, km/h)은 충돌 시 차량의 초기 속도에서 최종 속도로 변화하는 정도를 의미하며, 충돌 후 두 차량이 일정 시간 동안 동일한 속도로 이동할 때의 속도 차이를 나타낸다. 반면, 충격 가속도는 속도 변화가 단위 시간 동안 얼마나 빠르게 일어나는지를 나타내는 값으로, 충돌 시간이 짧고 속도 변화가 클수록 충격 가속도는 증가한다. 일반적으로 충격 가속도는  $m/s^2$ 로 측정 가능하지만, 실험 데이터와 비교를 쉽게 하기 위해  $9.8m/s^2$ 을 '1G'로 표현한다.



<그림 2> 저속 후미추돌 시 탑승자의 머리와 목의 움직임 메커니즘

### 3) MADYMO 시뮬레이션 프로그램

교통사고 및 자동차 안전성 연구에서는 실차와 인체를 이용한 실험이 어려운 경우가 많기 때문에 시뮬레이션 툴을 활용하여 더 정확하고 효율적인 분석을 수행하고 있다. MADYMO(MAthematical DYnamic MOdels)는 차량 충돌 및 탑승자의 동역학적 반응을 정밀하게 분석할 수 있는 소프트웨어로, 인체 상해 연구와 차량 안전성 평가 분야에서 중요한 역할을 한다. 이 프로그램은 네덜란드 TNO Automotive에서 개발되었으며, 3차원 동역학 해석을 통해 차량과 탑승자의 움직임을 정교하게 시뮬레이션할 수 있다(TNO, 2010).

특히, MADYMO는 다물체 동역학(Multi-Body Dynamics)과 유한요소 분석(Finite Element Analysis) 기법을 결합하여 안전 시스템의 동작을 정밀하게 모델링할 수 있도록 지원한다. 또한, 공기역학적 시뮬레이션 기능을 통해 에어백 전개 시 탑승자와의 상호작용을 분석할 수 있으며, MATLAB 및 LS-DYNA 등 다양한 해석 도구와의 연계를 통해 더욱 심층적인 연구 수행이 가능하다.

### 4) AI 학습 모델

머신러닝은 주어진 데이터를 기반으로 특정한 규칙이나 패턴을 발견하여 향후 데이터를 예측하거나 분류 및 의사결정 등의 작업을 수행하는 기술이다. 일반적으로 머신러닝은 알고리즘이 데이터를 학습하는 방식에 따라 지도 학습, 비지도 학습, 그리고 강화 학습으로 구분된다. 이 중 지도 학습은 입력 데이터와 그에 대응하는 정답 레이블을 바탕으로 패턴을 학습하며, 주로 회귀와 분류 문제로 세부적으로 나뉜다. 본 연구에서는 충돌 사고의 충격력을 예측하기 위해 선형 회귀 모델, 엘라스틱넷 회귀 모델, 의사결정나무 회귀 모델, 랜덤 포레스트 회귀 모델 등 총 4가지

머신러닝 회귀 기법을 적용하였다. 각 모델을 활용하여 탑승자가 경험할 수 있는 충격력을 예측하는 정량적 모델을 구축하고, 이 모델들의 성능을 상호 비교하여 최적의 충격력 예측 모형을 개발하였다.

선형 회귀분석은 독립 변수와 종속 변수 사이의 관계를 선형 형태로 모델링하는 기법으로, 변수들 간의 선형성을 전제로 한다. 이 모델은 구현이 간단하고 해석이 용이하다는 장점이 있지만, 데이터가 비선형적 특성을 가질 경우 성능 저하가 발생할 수 있다.

한편, 엘라스틱넷 회귀는 2005년 Hui Zou와 Trevor Hastie에 의해 제안된 방법으로, 라쏘(Lasso)와 릿지(Ridge) 회귀의 규제(Regularization) 기법을 결합하여 개발되었다. 이 알고리즘은 과적합을 방지하는 동시에 다중공선성이 큰 데이터 환경에서도 변수의 선택과 계수 축소를 효과적으로 수행할 수 있도록 고안되었다. 특히, 라쏘 회귀가 상관관계가 높은 변수들에 대해 불안정한 결과를 초래할 수 있는 문제를 보완하는 역할을 한다(Zou, H. & Hastie, T., 2005). 의사결정나무 회귀는 트리 구조를 활용하여 데이터를 분류하고 예측하는 기법으로, 비선형 데이터에서도 효과적으로 작동하며 해석이 용이하고 시각화가 가능하다는 장점이 있다. 그러나 트리의 깊이가 과도하게 증가하면 모델이 훈련 데이터에 지나치게 적합하여 과적합이 발생할 수 있다. 한편, Ross Quinlan은 ID3 및 C4.5 알고리즘을 통해 의사결정나무 기법을 발전시켜 기계 학습 및 데이터 마이닝 분야의 기초를 확립하는 데 기여했다(Quinlan, J. Ross, 1993).

랜덤 포레스트(Random Forest)는 Leo Breiman이 1984년에 제안한 CART 알고리즘과 1996년 발표한 배깅(Bagging) 기법을 결합하여 2001년 Breiman과 Cutler에 의해 개발된 앙상블 학습의 모델이다(Breiman, L., 2001). 이 기법은 여러 개의 의사결정나무를 구축하고, 각각의 나무가 서로 다른 데이터 샘플과 특징을 사용하여 학습하도록 설계되어 있다. 랜덤 포레스트 회귀에서는 개별 트리의 예측 값을 평균 내어 최종 예측을 산출하며, 고차원 데이터에서도 강건한 성능을 보이고 과적합을 효율적으로 완화하는 것으로 알려져 있다.

**<표 1> 지도 학습에서의 회귀 유형 및 정의**

유형	정의
선형회귀	입력 변수와 출력 변수 간의 선형 관계를 직선을 사용하여 모델링함. 잔차(residual)의 제곱합을 최소화하여 최적의 직선을 찾지만, 비선형 데이터나 다중 공선성 문제에서 한계를 가짐.
엘라스틱넷 회귀	Ridge 회귀와 Lasso 회귀를 결합하여 L1 및 L2 정규화를 적용함. 상관관계가 높은 특징을 함께 선택하고, 과적합을 방지하여 고차원 데이터 셋에서 성능을 향상시킴.
결정 트리 회귀	입력 데이터를 특징 값에 따라 여러 구역으로 분할하여 트리 구조를 형성함. 비선형 관계를 효과적으로 모델링할 수 있으나, 가지치기나 정규화를 적용하지 않으면 과적합될 가능성이 있음.
랜덤 포레스트 회귀	데이터와 특징을 무작위로 선택하여 여러 개의 결정 트리를 생성한 후, 각 트리의 예측 값을 평균 내어 최종 결과를 도출함. 단일 결정 트리보다 안정적인 예측을 제공하며, 과적합을 줄이는 데 효과적임.

## 5) 법원 판례 조사: MADYMO 시뮬레이션 기반 탑승자 상해분석의 법적 인용 사례

저속 후미추돌 교통사고에서 발생한 탑승자 상해의 인과관계를 입증하는 것은 법적 분쟁에서 중요한 쟁점이 된다. 특히 충격력이 미미한 사고에서는 상해 발생 가능성을 과학적으로 입증하는 것이 어려워 법원이 객관적인 분

석 도구를 활용하는 사례가 증가하고 있다. 이에 따라 차량과 인체 간의 상호작용을 정밀하게 모델링하고 분석할 수 있는 도구로 인체의 상해와 안전 장비의 영향을 연구하는 데 중요한 소프트웨어로 인정받고 있는 MADYMO 시뮬레이션 결과는 법원의 판결에서 신뢰할 수 있는 법적 근거로 인정되고 있는 추세이다. MADYMO 시뮬레이션에 의해 도출된 결과에 따른 탑승자의 상해여부가 법원의 판결 근거로 채택된 사례를 조사하였다. 총 13건의 판례를 분석한 결과, 10건(약 77%)에서 MADYMO 분석이 중요한 증거로 활용되었으며, 이 중 일부는 판결의 핵심 법적 근거(primary evidence)로 작용했다. 반면, 3건(약 23%)에서는 MADYMO 분석이 판결의 핵심 증거로 인정되지 않았으며, 법원이 기각한 사례도 존재했다. 이는 사고 당시 충돌 각도, 차량 손상 정도 등 추가 변수가 판결에 영향을 미쳤기 때문으로 분석된다.

결과적으로 법원은 후미추돌 사고에서 발생한 탑승자 상해의 정도를 객관적으로 평가하기 위해 MADYMO 시뮬레이션을 활용한 정량적 분석 결과를 증거로 채택하는 사례가 더 적극적으로 활용되고 있는 추세임을 알 수 있다.

<표 2> 저속 후미추돌 사고에서 MADYMO 시뮬레이션 결과를 인용한 법적 판례

No	Court	Case Number & Type	Verdict Date	Use of Madymo Analysis
1	대구지방법원	2021나303965 손해배상(자)	2022. 1. 20.	Adoption
2	서울남부지방법원	2023나60344 구상금	2023. 10. 13.	Adoption
3	서울남부지방법원	2024고정197 보험사기 방지특별법위반	2024. 7. 11.	Adoption
4	서울중앙지방법원	2015나54331 부당이득금반환	2016. 4. 22.	Dismissal
5	서울중앙지방법원	2020나6022 보험금	2020. 9. 2.	Dismissal
6	인천지방법원	2021나59994 구상금	2022. 9. 7.	Dismissal
7	인천지방법원 부천지원	2017가단101456 채무부존재확인	2017. 6. 23.	Adoption
8	인천지방법원	2016노347 사기	2016. 7. 20.	Adoption
9	전주지방법원	2021가단6602 채무부존재확인	2021. 11. 9.	Adoption
10	서울중앙지방법원	2019나47614 구상금	2020. 5. 12.	Adoption
11	서울중앙지방법원	2021나71078 부당이득금반환	2022. 7. 8.	Adoption
12	서울중앙지방법원	2021나69532 구상금	2023. 1. 18.	Adoption
13	수원지방법원	2021나93939 손해배상(자)	2022. 10. 5.	Adoption

## 2

## 관련 연구 동향 분석

## 1) 탑승자의 상해 기준 연구

기존의 교통사고 관련 연구에서는 탑승자의 상해를 보다 정확히 평가하기 위해 건강한 성인 그룹을 중심으로 상해 임계값을 설정하였다. 특히, 상해 예측의 신뢰도를 높이고자 고령층(65세 이상), 청소년 및 아동(19세 미만), 기존에 질환을 앓고 있는 대상자는 분석에서 제외한 후, 건강 상태가 양호한 성인만을 대상으로 상해 임계값 연구를 수행해왔다. 이러한 연구 결과를 통해 일반적으로 저속 후미추돌 사고에서 탑승자의 상해 여부를 판단하는 기준값들이 제시되었다.

구체적으로 기존 연구에서는 상해 평가를 위한 속도 변화량의 임계값을 8~10 km/h, 최대 충격가속도의 기준 범위를 5~7G로 설정하여 이 범위를 초과하면 상해가 발생할 가능성이 높다고 보고 있다.

**<표 3> 문헌 검토를 기반으로 한 상해 임계값 종합표**

해당 연도	연구자	기존 연구를 기반으로 한 탑승자 상해 임계값			해당 연도	연구자	기존 연구를 기반으로 한 탑승자 상해 임계값		
		델타-V (km/h)	최대 충격 가속도 (G)	평균 충격 가속도 (G)			델타-V (km/h)	최대 충격 가속도 (G)	평균 충격 가속도 (G)
1994	Szabo, T. J. et al.	8	5~6		2001	Braun, T. A. et al.	7.2		
1995	McConnell, W. E. et al.	8			2002	Krafft, M. et al.	7.7	6.7	3
1996	Szabo, T. J. et al.	8~10			2003	Kullgren, A. et al.	10		
1997	Castro, W. H. et al.	10~15			2005	Moss, R. T. et al.	8		
1999	Walz, F. et al.	10			2005	Hynd, D. et al.	10		
1999	Zuby, D. S. et al.	11	7		2012	Hong S. W. et al.	8		
2000	Krafft, M. et al.		6						

**2) 사고 요인을 반영한 충격력 분석**

기존 연구에서 탑승자의 상해 임계값이 제시되었지만, 사고 발생 시 탑승자의 실제 상해 수준을 정확히 평가하기 위해서는 사고 데이터를 기반으로 충격력을 측정하는 과정이 필수적이다. 이를 위해 차량의 속도 변화량과 최대 충격 가속도를 도출한 뒤, 기존 연구에서 제시된 상해 임계값과 비교하여 분석하는 것이 중요하다.

이재원(2021)의 연구에서는 실제 차량을 이용한 59건의 저속 후미추돌 실험을 수행하였다. 실험에서는 충돌 차량과 피충돌 차량의 질량, 충돌 속도, 겹침량 등의 조건을 설정하고, 차량의 동적 특성과 관련된 변수로 속도 변화량, 평균 충격 가속도, 최대 충격 가속도를 선정하였다. 또한, 다중 선형 회귀 분석을 활용하여 충격력, 목상해지수(NIC) 예측 모델을 개발하였으며, 연구 결과를 바탕으로 속도 변화량 기준을 8~10km/h 범위로 규정하는 것이 적절하다고 제안하였다. Moravcová, Pavlína 등(2024)의 연구에서는 차량이 충돌 시에 속도, 차량 질량, 변형의 깊이와 폭과 같은 다양한 요인이 에너지 등가 속도(EES) 계산에 미치는 영향을 분석하여 차량 충격력을 평가하였다. 그러나 EES는 차량 변형이 발생하지 않는 상황에서는 정확한 측정이 어려우며, 특히 후미추돌 사고와 같이 차량 변형이 미미한 경우에는 적용에 한계가 있다.

이전 연구에서도 사고 발생 시 충격력을 산출하려는 다양한 시도가 이루어졌다. 하지만 이러한 연구들은 주로 충돌 속도, 차량 중량, 손상 깊이 등의 제한된 변수를 중심으로 분석을 수행했기 때문에 보다 정밀한 충격력 계산과 탑승자 상해 예측에는 한계가 있었다. 또한, 사고 데이터를 활용한 충격력 도출 연구가 진행되었음에도 불구하고 여전히 큰 오차가 발생하는 문제가 존재하며, 이를 최소화하기 위한 추가적인 연구가 필요하다.

**<표 4> 실차 충돌 테스트에서의 상해 임계값**

연도	연구자	연구방법론	독립변수	종속변수	비고
1995	McConnell, W. E. et al.	충돌 차량 속도를 기반으로 한 탑승자 상해 분석	충돌속도	$\Delta V$	제한된 변수
2009	Kang, S. M.	손상 깊이와 $\Delta V$ 간의 상관관계 및 수식 분석	차량 손상 깊이	$\Delta V$ , 충격가속도	제한된 변수
2015	Kim, M. J.	MADYMO 시뮬레이션 결과 도출	차량 중량, 속도	$\Delta V$ , 충격가속도	제한된 변수
2017	Cormier, J. et al.	충돌 테스트 데이터와 실제 사고 데이터 비교	성별	$\Delta V$	제한된 변수
2020	Lee, K. S.	MADYMO 시뮬레이션 결과 및 모델 개발	차량 중량, 속도	$\Delta V$ , 충격가속도	고속충돌
2021	Lee, J. W. et al.	실차 테스트를 통한 차량 거동 및 경추 손상 지수 예측	차량 중량, 옵션, 속도	$\Delta V$ , 충격가속도	제한된 변수
2022	Baek, S. R. et al.	시뮬레이션 및 머신러닝을 활용한 손상 예측	속도, 차량 중량, 옵션, 충돌각	$\Delta V$ , 충격가속도, NIC	제한된 변수
2024	Moravcová, Pavlína, et al	다양한 변수가 에너지 등가 속도 계산에 미치는 영향 분석	속도, 차량 질량, 변형 깊이	에너지 등가 속도(EES)	제한된 변수

## 3

## 주요 시사점 및 차별성

선행 연구에 따르면 탑승자 상해 임계값은 속도 변화량이 8~10km/h, 최대 충격가속도가 5~7G로 도출되었다. 그러나 기존 연구들은 충돌 속도, 차량 중량 등 일부 제한된 변수만을 고려하여 충격력을 분석했기 때문에 정확성에 한계가 있었다. 국내에서는 MADYMO 프로그램을 활용한 시뮬레이션으로 상해 분석을 수행하고 있으나 이 프로그램은 고가의 비용과 복잡한 과정으로 인해 경찰과 보험사 등에서 활용하기에 한계가 있다. 이에 따라 저속 후미추돌 교통사고에서 기초 자료만을 바탕으로 신속, 정확하게 충격력을 도출하여 탑승자의 상해를 판단할 수 있는 효과적인 방법이 필요하다. 이에 따라 기존 연구의 한계와 문제점을 보완하기 위해 아래와 같은 연구 진행 방향을 수립하였다. 첫째, 국내에서 발생한 저속 후미추돌 교통사고의 특성을 분석하고, 충격력에 영향을 미치는 주요 변수를 도출하였다. 이를 기반으로 교통사고의 특성을 정량적으로 분석하고, 충격력 예측 모델을 구축하였다. 둘째, MADYMO 시뮬레이션의 한계 극복하기 위해, 여러 유형의 교통사고 데이터와 기존에 수행된 MADYMO 시뮬레이션 결과를 활용하였다. 이를 통해 연속적인 결과값을 효과적으로 예측할 수 있는 회귀 기반 지도학습 기법을 적용하여 충격력을 산출하고, 선행 연구의 결과와 비교하여 모델의 예측 정확도를 검증하였다. 셋째, 머신러닝 회귀 기법을 활용한 충격력 예측 모델을 구축하여 실제 저속 후미추돌 사고 데이터를 분석하였다. 또한, 기존 연구에서 제시된 상해 임계값(Delta-V 8~10km/h, 최대 충격가속도 5~7G)와 비교하여 탑승자의 상해 가능성을 예측하는 모델을 개발하였으며, 혼동 행렬을 이용하여 모델의 예측 성능을 검증하였다. 넷째, 기존 연구에서 수행된 실차 충돌 시험 데이터를 활용하여, 본 연구에서 개발한 예측 모델의 결과값과 비교 분석함으로써 모델의 신뢰성을 평가하였다.

## Ⅲ. AI 기반 충격력 분석 모델 연구

## 1

## 데이터 확보 및 가공

본 연구에서는 한국도로교통공단에서 제공한 저속 후미추돌 교통사고 심층 분석 데이터를 활용하였다. 해당 데이터는 경찰의 실황조사서, MADYMO 시뮬레이션 결과, 탑승자의 상해 여부 등 다양한 요소를 포함하고 있다. 연구 초반에는 저속 후미추돌 사고의 탑승자 상해 분석 프로세스를 자세히 검토한 후, 연구에 필요한 데이터를 체계적으로 선별하고 수집하였다. 이후, 수집된 데이터는 연구의 목적에 맞도록 정밀한 전처리 과정을 거쳐 분석에 활용되었다.

## 1) 저속 후미추돌 교통사고의 탑승자 상해 분석 방법

MADYMO를 활용한 저속 후미추돌 교통사고 분석은 사고 현장 및 차량 관련 데이터를 바탕으로 시뮬레이션을 수행하여 사고 상황을 재현하고 해석하는 방법이다. 이 과정에서 사고 차량의 속도 변화량 및 충격 가속도를 산출

<표 5> MADYMO 기반 저속 후미추돌 사고 분석 초기 데이터

Strucking Vehicle Type	Struck Vehicle Type	Weight difference between vehicles	Speed Difference	Delta-V	Impact Acceleration	Impact Angle	Impact Offset	Striking Vehicle Driver Sex	Striking Vehicle Driver Age	Struck Vehicle Driver Sex	Struck Vehicle Driver Age	Injury Status	Number of Injured	Injury Days	Number of Injured Areas
SEDAN	SUV	35	3.4	2.7	1.3	0	100	MAN	71	MAN	36	No injury	1	42	2
SEDAN	SUV	0	3.0	0.6	0.39	0	100	MAN	21	WOMAN	34	No injury	2	14	2
SEDAN	SEDAN	0	1.7	0.072	0.04	0	100	MAN	77	MAN	56	No injury	1	14	4
SEDAN	SUV	-185	8.0	4.7	2.2	0	100	MAN	37	MAN	37	No injury	1	14	3
SEDAN	SEDAN	215	2.9	0.9	0.51	0	100	WOMAN	75	MAN	30	No injury	1	14	2
SEDAN	SUV	-90	5.5	2.3	1.43	0	100	MAN	70	MAN	43	No injury	1	14	1
SEDAN	MPV	-445	8.0	4	2	0	80	MAN	62	MAN	49	No injury	1	14	1
SEDAN	SUV	-545	2.3	0.11	0.09	0	100	MAN	68	WOMAN	70	No injury	2	14	4
SUV	SEDAN	140	6.1	4.9	2.3	0	90	MAN	58	MAN	68	No injury	2	14	1
SEDAN	SEDAN	140	5.3	2.3	1.27	0	100	MAN	75	MAN	72	No injury	1	14	2
SEDAN	SUV	-310	5.6	3	1.4	0	100	MAN	37	MAN	49	No injury	1	14	1

한 후, 기존 연구에서 제시된 상해 임계값과 비교하여 탑승자의 상해 가능성을 평가한다. 본 연구에서는 다음과 같은 절차를 통해 분석을 진행하였다. 첫째, 경찰 조사서 및 현장 자료 등 사고 관련 데이터를 수집하였다. 둘째, 차량 손상 정도와 충돌 유형을 분석하여 충격력 계산에 필요한 기초 데이터를 구축하였다. 셋째, MADYMO 프로그램을 활용하여 사고 상황을 시뮬레이션하고, 해당 데이터를 기반으로 충격력을 산출하였다. 마지막으로, 도출된 충격력을 기존 연구의 상해 임계값 기준과 비교하여 탑승자의 상해 발생 가능성을 평가하였다.

## 2) 데이터 수집 및 전처리 과정

국내 저속 후미추돌 교통사고에 대한 공학적 분석은 한국도로교통공단의 MADYMO 시뮬레이션 결과와 탑승자 상해 분석 데이터를 활용하여 수행되었다. 본 연구에서는 국내 저속 후미추돌 사고에서 탑승자의 상해 가능성을 예측하는 모델을 개발하기 위해, 2020년부터 2022년까지 수집된 데이터를 사용하였다.

해당 데이터는 경찰의 실황조사서, MADYMO 시뮬레이션 분석 결과, 탑승자의 상해 여부 등 다양한 교통사고 관련 정보를 포함하고 있다. 연구 과정에서는 수집된 데이터를 바탕으로 후미추돌 사고 데이터를 체계적으로 전처리하였다. 이 과정에서 복합 변수를 생성하고 일부 변수를 최적화하였으며, 이상치를 제거한 후 최종적으로 534건의 데이터를 확보하였다. 정제된 데이터는 연속형 변수 11개와 범주형 변수 5개로 구성되었다.

## 2 저속 후미추돌 사고의 충격력 예측 모델 구축

### 1) AI 학습 기반 분석 절차

교통사고 분석의 최신 경향에서는 빅데이터, 머신러닝 기법이 활발히 도입되고 있으며, 이를 활용한 연구가 지속적으로 증가하고 있다. 특히, 선형 및 로지스틱 회귀, 랜덤 포레스트, 서포트 벡터 머신(SVM), 딥러닝 기반 모델

등이 교통사고 예측 및 분석에 널리 적용되고 있다. 교통 흐름과 같은 연속형 데이터를 처리할 때, 변수 간 관계가 선형적일 경우 선형 회귀 모델이 효과적인 성능을 보인다. 또한, 과적합 문제를 완화하고 예측 성능을 향상시키기 위해 엘라스틱넷과 같은 정규화 기법이 활용될 수 있다.

본 연구에서는 저속 후미추돌 사고에서 충격력을 예측하는 모델을 구축하기 위해 통계적 방법을 사용하여 종속변수와 독립변수를 선정하였다. 범주형 변수는 원-핫 인코딩을 적용하여 변환하였으며, 데이터 세트를 학습(80%)과 테스트(20%) 데이터로 분할하여 머신러닝 모델을 훈련하였다. 또한, 선형, 엘라스틱넷, 의사결정나무 및 랜덤 포레스트 회귀 모델을 비교 분석하여 저속 후미추돌 사고에서 충격력을 보다 정밀하게 예측할 수 있도록 하였다.

본 연구에서는 엘라스틱넷과 의사결정나무 및 랜덤 포레스트 회귀 모델의 성능을 극대화하기 위해 하이퍼파라미터 최적화를 수행하였다. 엘라스틱넷에서는 알파( $\alpha$ )와 비율( $\lambda$ ) 매개변수가 핵심적인 역할을 하며, 의사결정나무 및 랜덤 포레스트의 경우 트리 깊이, 분할 기준, 노드의 미니멈 샘플 수 등이 모델의 예측 성능에 영향을 미친다. 이러한 하이퍼파라미터의 최적 조합을 도출하고자 K-겹 교차 검증(K-fold cross-validation) 및 그리드 탐색(Grid Search) 기법을 적용하였다.

머신러닝 모델의 성능은 실제 값과 예측 값 간의 차이를 기반으로 평가되었다. 주요 성능 지표는 다음과 같다. 평균 절대 오차(MAE)와 평균 제곱 오차(MSE) 그리고 제곱근 평균 제곱 오차(RMSE) 및 결정 계수( $R^2$ )를 사용하였으며, 이를 통해 각 모델을 오차와 변동성 측면에서 종합적으로 비교·분석하였다. 최종적으로, 저속 후미추돌 사고에서 충격력을 예측하는 최적의 모델을 선정하고, 기존 연구에서 보고된 오차 값과 비교하여 새롭게 개발된 모델의 정확도를 검증하였다.

또한, 변수 중요도 분석을 수행하여 각 독립 변수가 모델 예측에 미치는 영향을 평가하였다. 본 연구의 모델 구현은 Google Colab과 Python 3.10.12 환경에서 진행되었으며, 머신러닝 알고리즘은 Scikit-learn 라이브러리를 활용하여 구축되었다.

<표 6> 저속 후미추돌에서의 탑승자 상해 분석 흐름도

단계	세부내용
변수 선택	통계적 기법을 활용한 변수 선택 / 원-핫 인코딩(One-Hot Encoding) 적용
하이퍼파라미터 튜닝	모델 최적화를 위한 하이퍼파라미터 튜닝 수행
모델 개발	머신러닝 모델 선택 / 변수 중요도 분석 수행
모델 분석	머신러닝 회귀 모델 선택 / 평가 지표(Evaluation Metrics) 활용하여 성능 평가
모델 검증	기존 연구의 정확도 비교를 통해 최종 모델 선정

## 2) 종속 변수 및 독립 변수 정의, 원-핫 인코딩 기법

속도 변화량과 최대 충격 가속도는 기존 연구에서 저속 후미추돌 교통사고 발생 시 탑승자의 상해 여부를 결정하는 중요한 요인으로 확인되었다. 이에 따라 본 연구에서는 이러한 두 변수를 종속 변수로 설정하여 분석을 진행하였다.

본 연구는 변수 간의 관계를 규명하는 것보다 모델의 예측 성능을 높이는 데 중점을 두었다. 이에 따라 독립 변

수 선정할 때 연속형 변수는 상관관계 분석을 활용하여 평가하였고, 범주형 변수의 경우 분산분석(ANOVA)을 적용하여 통계적으로 유의미성이 낮은 변수는 제외하였다. 그러나 통계적 유의성이 다소 낮더라도 실제 사고 상황에서 중요한 역할을 하는 변수는 포함하였으며, 실질적인 연관성이 부족한 변수는 분석에서 배제하여 보다 현실적인 예측 모델을 구축하고자 하였다.

본 연구에서는 연속형 변수의 피어슨 상관관계 분석 및 p-value 검정을 활용하여 독립 변수를 선정하였다. 분석 결과, 상대 속도 차이는 속도 변화량(상관계수 0.8894)과 최대 충격 가속도(상관계수 0.8613)가 높은 양의 상관관계를 나타내어 두 종속 변수에 상당한 핵심 변수로 작용하는 것으로 확인되었다.

중량 차이는 속도 변화량(0.1392) 및 최대 충격 가속도(0.1511)와 다소 약한 양의 상관관계를 보였으나, 통계적으로 유의미한 변수로 판별되어 독립 변수로 포함되었다.

**<표 7> 연속 변수와 종속 변수 간의 상관 분석 결과**

연속변수	상관관계			
	속도변화량(km/h)		최대충격가속도(G)	
	계수	P-값	계수	P-값
속도 차	0.8894	0.0000***	0.8613	0.0000***
중량 차	0.1392	0.0013***	0.1511	0.0005***
추돌차량 운전자 연령	-0.1037	0.0165**	-0.0890	0.0398*
피추돌차량 운전자 연령	-0.0123	0.7771	-0.0054	0.9013
부상자 수	-0.0542	0.2109	-0.0314	0.4695
부상일 수	-0.0286	0.5098	-0.0427	0.3241
부상 부위 수	0.0786	0.0695**	0.0678	0.1175

\*p<0.1, \*\*p<0.05, \*\*\*p<0.01

결과와 별개로 실질적인 중요성이 있다고 판단되는 변수 역시 포함하였다. 추돌차량 운전자 성별과 피추돌차량 운전자 성별의 경우에는 통계적으로 유의하지 않아 독립 변수에서 제외되었다.

상해 분석 결과의 경우 통계적으로 유의성을 보였으나, 데이터의 98%가 '상해 없음'에 해당하여 편중된 분포를 보였기 때문에 종속 변수에 미치는 영향이 제한적이라고 판단하여 포함하지 않았다.

반면, 추돌차량 유형, 피추돌차량 유형, 충돌 각도, 충돌 옵셋은 속도 변화량 또는 최대 충격 가속도와 유의미한 관계를 보였으며, 이에 따라 독립 변수로 선정

**<표 8> 범주형 변수와 종속 변수 간의 ANOVA 분석 결과**

범주형 변수	ANOVA			
	속도변화량(km/h)		최대충격가속도(G)	
	F	P-값	F	P-값
추돌차량 유형	1.9894	0.0948*	2.7095	0.0295**
피추돌차량 유형	1.3845	0.2380	3.7818	0.0048***
추돌차량 운전자 성별	0.0322	0.8576	0.5267	0.4683
피추돌차량 운전자 성별	2.5238	0.1127	4.3069	0.0384**
부상여부	80.0880	0.0000***	96.7353	0.0000***
충돌각도	2.1531	0.0316***	2.3775	0.1410
충돌 옵셋	3.9172	0.0000***	2.2464	0.0179**

\*p<0.1, \*\*p<0.05, \*\*\*p<0.01

반면, 피추돌차량 운전자의 연령, 부상자 수, 부상 기간은 종속 변수와의 상관성이 낮거나 음의 상관관계를 나타내어 통계적으로 유의하지 않은 것으로 분석되어 제외되었다. 추돌차량 운전자의 연령, 부상 부위는 통계적으로 유의성을 보였으나, 종속 변수와의 상관관계가 약하고 충격력과의 명확한 인과관계를 입증하기 어려운 것으로 판단되어 독립 변수에서 제외하였다.

범주형 변수는 ANOVA 검정을 통해 분석하였으며, 두 종속 변수 중 하나라도 통계적으로 유의미한 경우 독립 변수로 선정하였다. 또한, 분석

결과를 보였으며, 이에 따라 독립 변수로 선정

되었다. 최종적으로 독립 변수는 상대 속도 차, 중량 차, 추돌차량 유형, 피추돌차량 유형, 충돌 각도, 충돌 옵셋으로 결정하였다.

속도 차는 사고 차량 간 속도 차이를 의미하며, 충돌 강도에 영향을 미치는 핵심 요인이다. 충돌각도와 충돌옵셋은 사고 시 차량의 충격 방향과 접촉 지점 또는 중첩 정도를 나타낸다.

&lt;표 9&gt; 종속 변수 및 독립 변수 선택

선택된 변수	변수	유형	선택된 변수	변수	유형
종속변수	속도변화량(km/h)	연속형	선택되지 않은 변수	추돌차량 운전자 성별	범주형
	최대 충격 가속도(G)	연속형		추돌차량 운전자 연령	연속형
독립변수	속도 차(km/h)	연속형		피추돌차량 운전자 성별	범주형
	중량 차(kg)	연속형		피추돌차량 운전자 연령	연속형
	추돌차량 유형	범주형		부상 여부	범주형
	피추돌차량 유형	범주형		부상자 수	연속형
	충돌 각도(°)	범주형		부상일 수	연속형
	충돌 옵션(%)	범주형		부상 부위 수	연속형

후미추돌 교통사고에서 충격력을 기반으로 상해를 예측하기 위해 적절한 변수 선택과 변환이 필수적이며, 특히 범주형 데이터 처리를 위해 원-핫 인코딩이 활용된다. 이 기법은 각 범주를 개별 이진 변수로 변환하여 모델이 효과적으로 해석할 수 있도록 돕고, 예측 성능을 향상시키는 역할을 한다. 본 연구에서는 4개의 범주형 독립 변수를 원-핫 인코딩하여 각 카테고리를 이진 변수로 변환하였다. 이를 통해 범주형 정보를 유지하면서도 머신러닝 모델이 분석 가능한 형태로 표현할 수 있었다. 이 과정은 데이터의 비선형 관계를 효과적으로 반영하며, 예측 성능 향상에 기여한다.

&lt;표 10&gt; 원-핫 인코딩 이후 종속 및 독립 변수

구분	변수	데이터 유형	
종속 변수	속도변화량(km/h)	연속형	-
	최대 충격 가속도(G)	연속형	-
독립 변수	속도 차(km/h)	연속형	-
	중량 차(kg)	연속형	-
	추돌차량 유형	COMPACT, MPV, SEDAN, SUV, Small Truck	1 or otherwise=0
	피추돌차량 유형	COMPACT, MPV, SEDAN, SUV, Small Truck	1 or otherwise=0
	충돌 각도(°)	0, 10, 20, 30, 40, 50, 60, 70, 80, 90	1 or otherwise=0
	충돌 옵션(%)	0, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100	1 or otherwise=0

### 3) 하이퍼파라미터 최적화 기법

엘라스틱넷 회귀 모델의 하이퍼파라미터 최적화는 alpha 값과 L1 ratio를 조정하는 방식으로 이루어졌다. 의사결정나무 회귀 모델의 경우, 트리의 구조를 조정하는 max depth, 노드 분할 시 최소 샘플 수인 min samples split, 리프 노드의 최소 샘플 수인 min samples leaf 등의 하이퍼파라미터를 최적화하였다.

랜덤 포레스트 회귀 모델에서는 max depth, min samples leaf, min samples split 외에도 max features(최대 선택 특성 수)와 n estimators(트리 개수) 등을 포함하여 최적의 조합을 찾았다. 하이퍼파라미터 튜닝 과정에서는 가능한 모든 조합을 체계적으로 탐색하는 그리드 서치(Grid Search) 기법을 활용하였다.

이 방법은 사전에 설정된 다양한 하이퍼파라미터 값을 조합하여 최적의 모델을 도출하는 방식으로, 모델 성능

을 극대화하는 데 효과적이다. 또한, K-fold 교차 검증(K=5)을 적용하여 데이터를 5개 폴드로 분할한 후, 각 폴드를 검증 데이터로 활용하며 반복적으로 성능 평가를 진행함으로써 모델의 일반화 특성을 향상시켰다. 모델 평가에는 음의 평균 제곱 오차(NMSE, Negative Mean Squared Error)를 사용하였으며, 해당 값의 절댓값이 작을수록 모델의 예측 성능이 우수한 것으로 판단하였다.

엘라스틱넷 회귀 모델의 경우, 속도 변화량 예측에서는 alpha 값을 0.1, L1 ratio를 0.9로 설정했을 때 |NMSE| 값이 1.1512로 가장 우수한 성능을 기록하였다. 최대 충격 가속도 예측에서는 alpha가 0.01, L1 ratio가 0.9일 때 |NMSE| 0.3958을 나타내며 최적의 결과를 보였다.

의사결정나무 회귀 모델에서는 속도 변화량 예측을 위해 max depth를 5, min samples split을 4, min samples leaf를 5로 설정했을 때 |NMSE| 값이 1.227로 가장 적절한 성능을 보였다. 반면, 최대 충격 가속도 예측에서는 max depth 5, min samples split 2, min samples leaf 5의 설정에서 |NMSE| 4.600을 기록하였다. 랜덤 포레스트 회귀 모델의 경우, 속도 변화량 예측에서는 n estimators를 100, max depth를 제한 없이(None),

min samples split을 2, min samples leaf를 2, max features를 sqrt로 설정했을 때 |NMSE| 값이 1.0616으로 가장 좋은 결과를 보였다.

최대 충격 가속도 예측에서는 n estimators를 200, max depth를 10, min samples split을 1, min samples leaf를 5, max features를 sqrt로 설정했을 때 |NMSE| 0.4337로 최적화된 성능을 기록하였다.

**[표 11] 각 회귀 모델별 하이퍼파라미터 최적화 결과**

회귀 모델	속도변화량(km/h)  NMSE	최대충격가속도(G)  NMSE
엘라스틱넷	1.1512	0.3958
결정 트리	1.227	4.600
랜덤 포레스트	1.0616	0.4337

#### 4) AI 학습을 활용한 분석

본 연구에서는 머신러닝 기반 회귀 지도학습을 활용하여 저속 후미추돌 교통사고에서 충격력을 예측하는 모델을 개발하였다. 이를 위해 선형 회귀, 엘라스틱넷 회귀, 의사결정나무 회귀, 랜덤 포레스트 회귀 등 총 네 가지 회귀 모델을 비교·평가하였다. 분석 과정에서는 Python을 사용하여 속도 변화량과 최대 충격 가속도를 종속 변수로 설정하고, 관련 독립 변수 데이터를 불러온 후 전처리하였다. 이후, 전체 데이터를 학습용(80%)과 테스트용(20%)으로 분할하여 모델을 훈련하고 성능을 검증하였다.

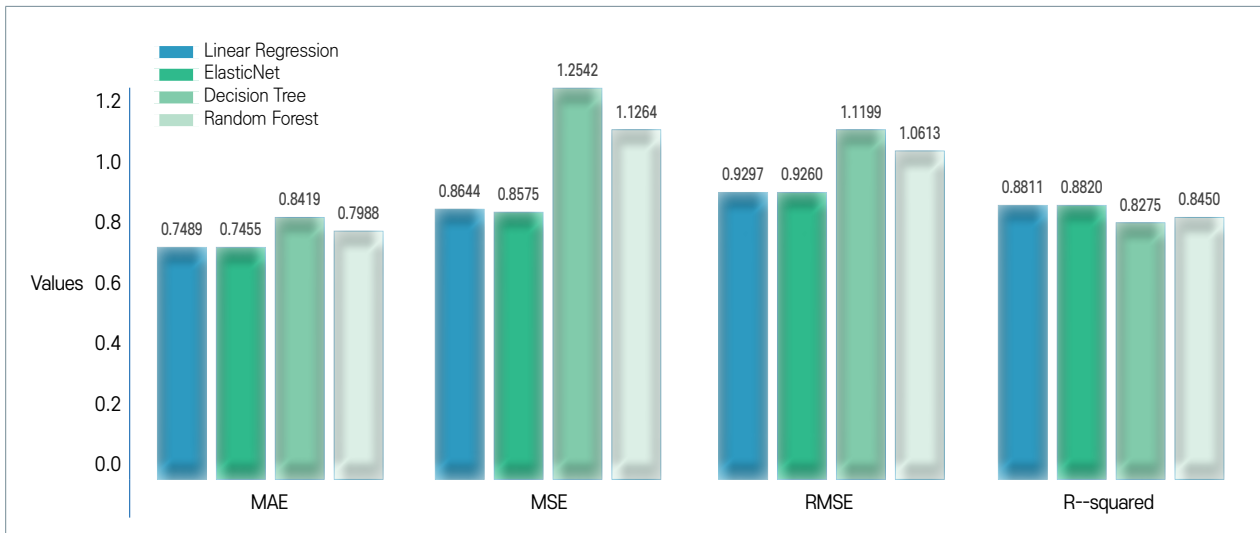
모델의 성능 평가의 경우 MAE, MSE, RMSE, R-Squared 지표를 사용하였으며 이를 통해 모델 예측 정확도와 데이터의 설명력 평가가 가능하다.

여기서 MAE는 예측 값과 실제 값의 차이 절댓값을 평균 내어 예측 오차의 크기를 직관적으로 측정하는 지표이다. MSE는 예측 값과 실제 값 간 차이의 제곱 평균을 계산하여 큰 오차에 더 큰 패널티를 부여한다. RMSE는 MSE의 제곱근을 취해 원래 데이터의 단위와 동일한 오차를 측정하는 지표이다.

R-Squared는 모델이 주어진 데이터를 얼마나 잘 설명하는지를 나타내며, 값이 1에 가까울수록 모델의 성능이 우수함을 의미한다. 한편, 엘라스틱넷 회귀는 L1(라쏘) 및 L2(릿지) 정규화를 결합하여 모델의 복잡도를 조절하고 과적합을 방지하는 역할을 한다.

&lt;표 12&gt; 머신러닝 모델 성능 평가 결과

종속변수	회귀 모델	성능평가지표			
		MAE	MSE	RMSE	R-Squared
속도변화량 (km/h)	선형	0.7489	0.8644	0.9297	0.8811
	엘라스틱넷	0.7455	0.8575	0.9260	0.8820
	의사결정나무	0.8419	1.2542	1.1199	0.8275
	랜덤포레스트	0.7988	1.1264	1.0613	0.8450
최대충격가속도 (G)	선형	0.4114	0.3190	0.5648	0.8355
	엘라스틱넷	0.4145	0.3223	0.5677	0.8338
	의사결정나무	0.4643	0.4270	0.6534	0.7798
	랜덤포레스트	0.4331	0.3408	0.5837	0.8242



&lt;그림 3&gt; 모델 성능 비교(종속변수: Delta-V)



&lt;그림 4&gt; 모델 성능 비교(종속변수: 최대 충격가속도)

이를 통해 모델의 안정성을 향상시키는 데 강점을 보였다. 엘라스틱넷 회귀 모델은 속도 변화량 예측에서 MAE 0.7455, MSE 0.8575, RMSE 0.9260, R-Squared 0.8820을 기록하며 높은 예측 성능을 보였다. 이는 선형 회귀와 유사한 수준의 정확도를 유지하면서도 보다 복잡한 데이터 구조를 처리하는 데 강점을 나타냈다.

또한, 최대 충격 가속도 예측에서는 MAE 0.4145, MSE 0.3223, RMSE 0.5677, R-Squared 0.8338을 기록하며 안정적인 결과를 도출하였다. 반면, 의사결정나무 회귀는 단일 트리 기반의 모델 구조로 인해 복잡한 데이터 패턴을 충분히 반영하지 못하는 한계를 보였으며, 그 결과 속도 변화량 및 최대 충격 가속도 예측에서 상대적으로 낮은 성능을 보였다. 랜덤 포레스트 회귀는 다수의 의사결정나무를 결합하여 단일 트리 모델의 한계를 보완하였으나, 엘라스틱넷 회귀 및 선형 회귀 모델보다 설명력이 다소 부족한 것으로 나타났다. 결론적으로, 엘라스틱넷 회귀는 L1 및 L2 정규화를 적용하여 과적합 문제를 효과적으로 방지하면서도 높은 예측 성능을 유지하였다. 또한, 복잡한 데이터 구조를 보다 안정적으로 처리할 수 있는 강점을 바탕으로 신뢰성 높은 예측 결과를 제공하였다.

## 5) 충격력 모델의 정확도 평가

본 연구에서는 각 회귀 모델의 충격력 예측 성능을 객관적으로 평가하기 위해 평균 제곱 오차(MSE)와 결정계수(R-Squared)를 주요 평가 지표로 선정하여 분석하였다. 평균 제곱 오차(MSE)는 예측 값과 실제 측정값 간 차이를 제곱한 값들의 평균으로 나타낸 것으로, 예측 오차가 작을수록 이 값이 작아져 모델의 예측력이 우수함을 의미한다. 결정계수(R-Squared)는 모델이 독립 변수를 통해 종속 변수를 얼마나 효과적으로 설명하는지를 정량적으로 나타내며, 이 값이 1에 근접할수록 데이터에 대한 설명력이 높다고 평가할 수 있다. 이러한 기준을 통해 본 연구에서 개발된 예측 모델의 성능을 평가한 결과, 속도 변화량 예측 모델은 0.8820의 결정계수와 0.8575의 MSE 값을 나타내어 매우 우수한 성능을 보였다. 또한 최대 충격 가속도 예측 모델은 결정계수가 0.8338, MSE가 0.3223으로 나타나, 모델의 예측력이 안정적이고 신뢰할 수 있는 수준임을 확인할 수 있었다.

<표 13> 모델 정확도 검증

종속 변수	성능평가지표	이재원	백세룡	본 연구
속도변화량 (km/h)	R-Squared	0.8580	-	0.8820
	MSE	-	1.9780	0.8575
최대충격가속도 (G)	R-Squared	0.7800	-	0.8338
	MSE	-	-	0.3223

## 6) 변수 중요도 평가

엘라스틱넷 회귀 모델은 선형 회귀의 해석 가능성과 라쏘 및 릿지 회귀의 정규화 기법을 결합하여 변수 선택과 모델의 안정성을 동시에 확보할 수 있는 특징을 가진다. 특히, 모델의 계수를 기반으로 변수의 기여도를 분석할 수 있어 해석이 용이하다는 장점이 있다. 변수 중요도 분석에는 순열 중요도(Permutation Importance) 기법을 적용하였다. 이 방법은 특정 변수의 값을 무작위로 섞은 후 모델의 예측 성능 변화를 측정하는 방식으로, 비선형 모델에서도 변수의 영향력을 일관되게 평가할 수 있도록 해준다.

이를 통해 모든 독립 변수에 대해 모델이 예측에 미치는 상대적 중요도를 효과적으로 분석할 수 있었다. 엘라스틱넷 회귀 모델을 활용한 분석 결과, 속도 변화량과 최대 충격 가속도 예측에 가장 큰 영향을 미치는 변수는 상대 속도 차로 확인되었다.

이 변수는 충격 강도를 설명하는 핵심적인 요인으로 작용하며, 모델의 예측 성능을 높이는 데 중요한 역할을 하였다. 또한, 중량 차 역시 충격력과 밀접한 관련이 있으며 주요 변수로 도출되었다.

반면, 충돌 옵션, 충돌 각도는 비교적 영향력이 낮았으나, 예측 모델이 보다 정교한 결과를 도출하는 데 기여할 수 있는 보조적 요소로 작용하였다. 한편, 추돌차량과 피추돌차량의 유형은 모델에서 나타난 계수 값이 0에 가까웠으나, 특정 조건에서는 유의미한 정보를 제공할 가능성이 있는 변수로 평가되었다.

결과적으로, 상대 속도 차와 중량 차는 충격력 예측에서 가장 핵심적인 역할을 하는 변수로 나타났으며, 충돌 옵션과 충돌 각도는 보조적 역할을 수행하는 보완적 요소로 확인되었다. 차량 유형 변수 또한 특정 시나리오에서 유용한 정보를 제공할 수 있는 가능성이 있으며, 다양한 사고 유형을 고려할 때 모델의 예측 성능을 향상시키는 데 기여할 수 있음을 시사하였다.

<표 14> 변수 중요도 평가

변수	속도변화량(km/h)		최대충격가속도(G)	
	중요도	표준편차	중요도	표준편차
속도 차	1.6428	0.0626	1.5508	0.0747
중량 차	0.0671	0.0038	0.0701	0.0072
추돌 옵션	0.0136	0.0017	0.0165	0.0025
추돌 각도	0.0011	0.0006	0.0017	0.0011
추돌차량 유형	0.0000	0.0000	0.0004	0.0006
피추돌차량 유형	0.0000	0.0000	-0.0001	0.0001

## IV. 탑승자 상해 예측 모형 구축 및 성능 검증

머신러닝 기반 엘라스틱넷 회귀 모델을 활용하여 저속 후미추돌 사고에서 충격력을 예측하는 모델을 구축하고, 실제 사고 데이터를 적용하여 예측 성능을 평가하였다.

이어서, 도출된 충격력 예측 값을 기존 연구에서 제시된 상해 임계값(Delta-V: 810km/h, 최대 충격 가속도: 57G)과 비교하여 탑승자 상해 가능성을 평가하는 모델을 개발하였다. 또한, 혼동 행렬 분석을 통해 예측 모델의 성능을 검증하고 그 정확도를 분석하였다.

### 1 저속 후미추돌 사고의 상해 예측 모형 구축

본 연구에서는 Python과 Google Colab을 활용하여 저속 후미추돌 사고에서 탑승자의 상해 가능성을 예측하는 모델을 개발하였으며, 구축된 충격력 예측 모델을 파일 형식으로 저장하여 후속 분석에 활용할 수 있도록 하였다. 충격력 예측 모델의 저장 및 재사용을 위해 Pipeline을 적용하여 데이터 전처리와 모델 학습 과정을 일관되게 수행하였다.

이 과정에서 범주형 변수(예: 추돌차량 유형, 피추돌차량 유형)는 원-핫 인코딩을 통해 변환하였으며, 다중 종속 변수를 효과적으로 처리하기 위해 Scikit-learn 라이브러리의 MultiOutputRegressor를 활용하여 엘라스틱넷 회귀 모델과 결합하였다. 이 방식은 데이터 전처리와 모델 학습 과정을 하나의 흐름으로 통합함으로써 코드의 간결성을 유지하고 실행 효율성을 향상시키는 데 기여하였다.

또한, 훈련 데이터와 테스트 데이터 간 전처리 과정의 일관성을 유지하도록 하여 데이터 처리의 일관성을 확보하였다. 아울러, 속도 변화량과 최대 충격 가속도를 동시에 예측할 수 있도록 모델을 Pickle 모듈을 이용하여 저장

및 로드할 수 있도록 구현하였다. 이를 통해 모델을 쉽게 배포하고 다양한 환경에서 활용할 수 있도록 하였으며, 추후 분석 및 확장 연구에도 유용하게 적용될 수 있도록 설계하였다.

탑승자 상해 예측 모델의 성능을 평가하기 위해 실제 발생한 저속 후미추돌 사고 사례 534건을 활용하였다. 확보된 데이터는 분석 목적에 맞게 전처리 과정을 수행한 후, 머신러닝 기반 엘라스틱넷 회귀 모델에 적용하여 상해 여부를 예측하였다.

상해 여부는 모델을 통해 예측된 속도 변화량과 최대 충격 가속도의 결과값을 기존 연구에서 제시한 상해 기준(Delta-V 8~10km/h, 최대 충격 가속도 5~7G)과 비교하여 판단하였다. 예측된 두 값 중 하나라도 설정된 상해 임계값 범위에 포함되거나 이를 초과할 경우에는 '상해 발생'으로 분류하였으며, 두 값 모두 임계값보다 낮은 경우에는 '상해 없음'으로 구분한 결과 534건 중 519건은 상해 없음, 15건은 상해 발생으로 구분되었다.

```

40 from sklearn.linear_model import ElasticNet
41 from sklearn.model_selection import train_test_split
42 from sklearn.pipeline import Pipeline
43 from sklearn.compose import ColumnTransformer
44 from sklearn.preprocessing import OneHotEncoder
45 from sklearn.multioutput import MultiOutputRegressor
46 import joblib
47
48 # Define the preprocessor (One-Hot Encoding for categorical columns)
49 preprocessor = ColumnTransformer(
50     transformers=[
51         ('cat', OneHotEncoder(drop='first'), ['Striking_Vehicle_Type', 'Struck_Vehicle_Type'])
52     ],
53     remainder='passthrough' # Keep numerical columns as they are
54 )
55
56 # Optimal Hyperparameter Settings (Pre-determined Values)
57 best_params_dv = {'alpha': 0.1, 'l1_ratio': 0.9} # Optimal Parameters for Delta-V
58 best_params_la = {'alpha': 0.01, 'l1_ratio': 0.9} # Optimal Parameters for Impact Acceleration
59
60 # Create Two ElasticNet Models
61 elasticnet_dv = ElasticNet(alpha=best_params_dv['alpha'], l1_ratio=best_params_dv['l1_ratio'])
62 elasticnet_la = ElasticNet(alpha=best_params_la['alpha'], l1_ratio=best_params_la['l1_ratio'])
63
64 # Configure Regression Using Two ElasticNet Models with MultiOutputRegressor
65 class CustomMultiOutputElasticNet(MultiOutputRegressor):
66     def __init__(self):
67         super().__init__(estimators=[
68             self.estimator_dv, elasticnet_la
69         ])
70     def fit(self, X, y):
71         for i, est in enumerate(self.estimators_):
72             est.fit(X, y.iloc[:, i])
73         return self
74
75     def predict(self, X):
76         predictions = [est.predict(X) for est in self.estimators_]
77         return pd.DataFrame(predictions).T
78
79 # Define the pipeline: preprocessing + CustomMultiOutputElasticNet
80 pipeline = Pipeline(steps=[
81     ('preprocessor', preprocessor),
82     ('model', CustomMultiOutputElasticNet())
83 ])
84
85 # Define dependent and independent variables
86 X = df.drop(columns=['Delta-V', 'Impact Acceleration']) # Features
87 y = df[['Delta-V', 'Impact Acceleration']] # Target variables
88
89 # Train-test split (80% train, 20% test)
90 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
91
92 # Define dependent and independent variables
93 X = df.drop(columns=['Delta-V', 'Impact Acceleration']) # Features
94 y = df[['Delta-V', 'Impact Acceleration']] # Target variables
95
96 # Train-test split (80% train, 20% test)
97 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
98
99 # Train the model using the pipeline
100 pipeline.fit(X_train, y_train)

```

**<그림 5> 파이프라인과 피클을 이용한 충격력 예측 모델 저장 코드**

## 2 예측 모형 신뢰성 검증

상해 예측 모델의 성능을 객관적으로 평가하고 타당성을 검증하기 위해 혼동 행렬을 사용한 분석을 수행하였다. 혼동 행렬 분석을 활용하면 모델의 예측 결과와 실제 사고 데이터에서 확인된 상해 여부 사이의 일치도를 명확하게 파악할 수 있다. 이를 통해 상해 발생 예측이 정확하게 이루어졌는지, 또는 잘못 분류된 사례가 얼마나 존재하는지 파악할 수 있다.

모델의 예측 결과와 실제 상해 발생 여부를 비교하여 참 양성(True Positive), 거짓 양성(False Positive), 참 음성(True Negative), 거짓 음성(False Negative)의 비율을 분석함으로써 모델의 신뢰도와 정확성을 종합적으로 평가하였다.

**<표 15> 혼동행렬 분석 결과**

구분		실제 값	
		긍정	부정
예측 값	긍정	TP : 참 양성	FP : 거짓 양성
	부정	FN : 거짓 음성	TN : 참 음성

참 양성(TP)은 실제로 상해가 없는 경우를 정확히 예측한 것을 의미하며, 참 음성(TN)은 실제로 상해가 있는 경우를 올바르게 예측한 것을 뜻한다. 반면, 거짓 양성(FP)은 실제로 상해가 있음에도 불구하고 상해가 없다고 잘못 예측한 경우이며, 거짓 음성(FN)은 실제로 상해가 없지만 상해가 있다고 잘못 예측한 경우를 의미한다. 실제 값이 양성(Positive)인데, 모델이 잘못 음성(Negative)으로 예측한 경우 (Type II Error)

참 양성(TP)은 실제로 상해가 없는 경우를 정확히 예측한 것을 의미하며, 참 음성(TN)은 실제로 상해가 있는 경우를 올바르게 예측한 것을 뜻한다.

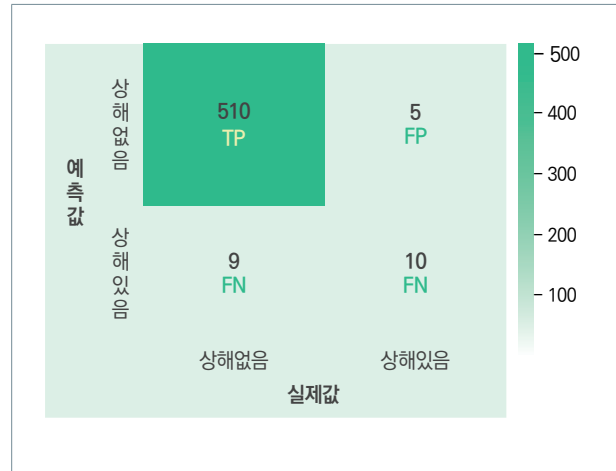
반면, 거짓 양성(FP)은 실제로 상해가 있음에도 불구하고 상해가 없다고 잘못 예측한 경우이며, 거짓 음성(FN)은 실제로 상해가 없지만 상해가 있다고 잘못

예측한 경우를 의미한다.

탑승자의 상해 여부를 예측한 모델의 성능 평가를 위해 혼동 행렬을 통해 분석하였다.

그 결과, 실제로 상해가 발생하지 않은 사례 510건은 모델이 정확히 '상해 없음'으로 예측하였고, 실제 상해가 발생한 10건 중 1건을 정확히 '상해 있음'으로 분류하였다. 그러나 실제로는 상해가 발생하였으나 모델이 잘못 예측하여 '상해 없음'으로 분류한 사례는 총 9건이었으며, 반대로 실제로 상해가 없었음에도 모델이 잘못하여 '상해 있음'으로 예측한 사례는 총 5건으로 나타났다.

상해 예측 모델의 성능을 정량적으로 평가하기 위해 혼동 행렬로부터 도출 가능한 지표들인 정확도, 정밀도, 재현율, 그리고 F1 점수를 계산하였다. 정확도는 전체 예측 결과 중 정확하게 분류된 비율을 나타내며, 정밀도는 모델이 상해로 분류한 예측 중 실제로 상해가 발생한 비율을 의미한다. 재현율은 실제 상해가 발생한 사례 중에서 모델이 정확하게 상해를 탐지한 비율을 나타내는 지표로, 모델이 실제 상해 사례를 얼마나 빠짐없이 예측했는지 판단하는 기준이다. 또한, 정밀도와 재현율을 균형 있게 고려한 F1 점수는 상해 예측 모형의 종합적인 성능을 평가하는 데 유용하다.



<그림 6> 탑승자 상해 예측 혼동 행렬 분석 결과

<표 16> 혼동행렬 기반 성능평가 지표

성능지표	정의	공식
정확도 (Accuracy)	전체 샘플에서 올바르게 예측한 비율	$\frac{TP + TN}{TP + TN + FP + FN}$
정밀도 (Precision)	양성 예측한 사례 중 실제로 양성인 비율	$\frac{TP}{TP + FP}$
재현율 (Recall)	실제 양성 사례 중 올바르게 양성으로 예측한 비율	$\frac{TP}{TP + FN}$
F1 점수 (F1 Score)	정밀도와 재현율의 조화 평균	$\frac{Precision \times Recall}{Precision + Recall} \times 2$

본 연구에서 구축한 저속 후미추돌 사고 상해 예측 모델의 성능을 혼동 행렬 분석을 통해 평가하였다.

평가 결과, 정확도는 97.38%로 나타나 모델의 전반적인 예측 정확도가 매우 높은 것으로 확인되었다.

정밀도의 경우 98.27%를 기록하여 모델이 '상해 없음'으로 예측한 사례 중 실제로 상해가 없었던 비율이 높게 나타났다. 재현율은 99.03%로 나타나, 실제 상해가 없는 사례를 거의 대부분 정확히 예측한 것으로 나타났다.

또한, 정밀도와 재현율을 동시에 고려한 F1 점수는 98.65%로, 모델이 높은 수준의 균형을 유지하며 우수한 성능을 보였다.

결론적으로, 개발된 상해 예측 모형은 실제 저속 후미추돌 사고 데이터를 바탕으로 한 성능 평가에서 높은 예측 정확성과 신뢰도를 나타냈으며, 실제 사고 상황에서 상해 발생 여부를 효과적으로 예측할 수 있음을 입증하였다.

본 연구에서는 개발된 탑승자 상해 예측 모형의 신뢰성을 검증하기 위해 최근 한국도로교통공단에서 MADYMO 시뮬레이션을 활용하여 실제 저속 충돌 교통사고의 탑승자 상해를 분석한 사례의 결과값과 탑승자 상해 예측 모형의 예측 값 간의 오차를 비교 분석하였다. 속도 차, 중량 차, 차량 유형, 충돌 각도, 충돌 옵션 등 다양한 교통사고 관련 변수들을 고려하되 변수 중요도가 높은 속도 차와 중량 차를 우선하여 3가지 사례를 선정하였다.

**사례1** 스포티지가 사고 장소 길을 직진 진행하던 중, 앞서 정차 후 출발 진행하던 카니발의 뒤 범퍼부분을 스포티지 의 앞 범퍼부분으로 충돌하여 카니발 운전자 및 동승자는 의료기관에서 2주 진단을 받은사고로, 6가지 입력변수를 활용한 MADYMO 시뮬레이션 결과 피추돌차인 카니발의 속도 변화량이 4.7km/h, 최대 충격가속도는 2.3G로 분석 되었고, 본 연구의 탑승자 상해 예측 모형 분석 결과는 속도 변화량 5.58km/h, 최대 충격가속도 2.97G로 예측되어, 오차는 각각 속도 변화량  $\pm 0.88$  km/h, 최대 충격가속도  $\pm 0.67$ G로 나타났으며, 탑승자 경추 상해 기준치인 속도 변화량 8~10km/h, 충격가속도(G) 5~7G 보다 낮게 분석되어 상해가 없는 것으로 분석되었다.

**사례2** 택시의 전방 범퍼가 정차 중인 캐스퍼의 후방 범퍼를 충돌하여 캐스퍼 운전자 및 동승자가 의료기관에서 2주 진단을 받은 사고로, 6가지 입력변수를 활용한 MADYMO 시뮬레이션 결과 피추돌차인 캐스퍼의 속도 변화량이 2.3km/h, 최대 충격가속도는 1.4G로 분석 되었고, 본 연구의 탑승자 상해 예측 모형 분석 결과는 속도 변화량 2.67km/h, 최대 충격가속도 1.92G로 예측되어, 오차는 각각 속도 변화량  $\pm 0.37$  km/h, 최대 충격가속도  $\pm 0.52$ G로 나타났으며, 탑승자 경추 상해 기준치인 속도 변화량 8~10km/h, 충격가속도(G) 5~7G 보다 낮게 분석되어 상해가 없는 것으로 분석되었다.

**사례3** 투싼이 동대문완구골목 방면에서 청계천 방향으로 차로 구분없는 이면도로(일방통행)를 좌측 길 가장자리에 정차하기 위해 서행하던 중 앞 범퍼 부분으로 좌측 길 가장자리에 정차 중이던 포터 우측 뒤 범퍼 부분을 추

<표 17> 후미 충돌사고 사례 1

입력변수	입력값
속도 차(km/h)	10
중량 차(kg)	-652
추돌차량 유형	SUV
피추돌차량 유형	MPV
충돌 각도(°)	0
충돌 옵션(%)	100

<표 18> 후미 충돌사고 사례 2

입력변수	입력값
속도 차(km/h)	4.2
중량 차(kg)	440
추돌차량 유형	SEDAN
피추돌차량 유형	COMPACT
충돌 각도(°)	0
충돌 옵션(%)	100

<표 19> 후미 충돌사고 사례 3

입력변수	입력값
속도 차(km/h)	1.49
중량 차(kg)	-295
추돌차량 유형	SUV
피추돌차량 유형	Small Truck
충돌 각도(°)	0
충돌 옵션(%)	70

돌하여 포터 운전자가 의료기관에서 2주 진단을 받은 사고로, 6가지 입력변수를 활용한 MAYMO 시뮬레이션 결과 피추돌차인 포터의 속도 변화량이 0.5km/h, 최대 충격가속도는 0.3G로 분석되었고, 본 연구의 탑승자 상해 예측 모형 분석 결과는 속도 변화량 0.90km/h, 최대 충격가속도 0.72G로 예측되어, 오차는 각각 속도 변화량  $\pm 0.40$  km/h, 최대 충격가속도  $\pm 0.42$ G로 나타났으며, 탑승자 경추 상해 기준치인 속도 변화량 8~10km/h, 충격가속도(G) 5~7G 보다 낮게 분석되어 상해가 없는 것으로 분석되었다.

따라서 실제 사고 사례를 대상으로 속도 차와 중량 차 변수를 우선적으로 고려하여 속도 변화량 및 최대 충격가속도에 대한 MADYMO 시뮬레이션 결과와 예측 값을 비교·분석한 결과 비교적 작은 오차가 발생하는 것으로 나타났다. 이를 통해 본 연구의 예측 모형이 저속 후미추돌 사고에서 신뢰할 수 있는 상해 평가 도구로 활용될 수 있음을 확인하였다.

## V. 연구 결과 및 향후 개선점

본 연구에서는 머신러닝을 활용하여 저속 후미추돌 교통사고에서 발생하는 탑승자의 상해 여부를 예측하는 모델을 개발하였다. 연구의 핵심은 충돌 시 차량과 탑승자가 받는 충격력(속도 변화량 및 최대 충격 가속도)을 정량적으로 분석하고 이를 바탕으로 신속하고 정확한 상해 예측이 가능한 방법론을 제시하는 데 있다. 실차 충돌 실험 데이터를 활용하여 예측 모델의 성능을 검증하였으며 본 연구에서 제안한 모델이 기존 방식보다 높은 정확도를 보이며 실무 적용 가능성이 높음을 확인하였다. 연구의 주요 성과는 아래와 같다.

첫째, 머신러닝을 활용한 회귀 기법으로 속도 변화량(Delta-V)과 최대 충격 가속도(Peak Impact Acceleration)를 예측하는 모델을 구축하였다. 다양한 회귀 분석 방법(선형, 엘라스틱넷, 의사결정나무, 랜덤 포레스트 회귀)을 검토한 결과, 엘라스틱넷 회귀 모델이 가장 우수한 예측 성능을 보였다. 특히, 이 모델은 과적합을 효과적으로 방지하면서도 낮은 오차율을 유지하며, 저속 후미추돌 사고에서 발생하는 충격력을 보다 정밀하게 예측할 수 있는 도구임이 입증되었다. 기존 연구들과 비교했을 때, 본 연구의 예측 모델은 변동성을 보다 잘 반영하는 것으로 분석되었다.

둘째, 상해 발생 가능성을 예측하기 위해 혼동 행렬을 적용하여 모델의 성능을 평가한 결과, 예측 정확도는 97.38%, F1 점수는 98.65%로 나타나 높은 신뢰도를 보였다. 이는 기존의 상해 예측 기법들보다 향상된 결과로 모델이 실제 사고 데이터를 기반으로 효과적으로 학습되었음을 의미한다. 본 연구에서 개발한 상해 예측 모델은 사고 발생 후 탑승자의 상해 가능성을 빠르게 분석할 수 있도록 설계되었으며 이를 활용하면 교통사고 조사 과정에서 신속하고 정확한 의사 결정을 내리는 데 기여할 수 있다.

셋째, 본 연구에서 제시한 상해 예측 모델은 기존 MADYMO 기반 시뮬레이션 분석과 비교했을 때 비용과 시간이 절약되며, 다양한 사고 조건에서도 안정적인 성능을 보이는 것으로 확인되었다. MADYMO와 같은 기존의 방식은 높은 비용과 복잡한 절차로 인해 실무에서 즉각적인 적용이 어렵다는 한계가 있었다. 반면, 본 연구에서 개발한 모델은 저비용으로도 신속한 예측이 가능하여 경찰, 보험사, 사법기관 등에서 사고 조사 및 보상 평가 과정에 실질적으로 활용될 수 있을 것으로 기대된다. 특히, 본 연구에서 개발된 모델은 프로그램 형태로 구현될 경우 현장에서 직접 사용할 수 있는 도구로 자리 잡을 가능성이 크다.

넷째, 실제 후미 추돌 사고 사례를 대상으로, 속도 차와 종량 차 변수를 우선적으로 고려하여 탑승자 상해 예측 모형의 신뢰성을 검증하였다. MADYMO 시뮬레이션 결과와 본 연구의 예측 값을 비교·분석한 결과, 속도 변화량 및 최대 충격가속도에서 비교적 작은 오차가 발생하는 것으로 나타났다. 또한, 모든 사례에서 탑승자 경추 상해 기준치를 초과하지 않아 상해가 발생하지 않는 것으로 분석되었다. 이를 통해 본 연구의 예측 모형이 저속 후미 추돌 사고에서 신뢰할 수 있는 상해 평가 도구로 활용될 수 있음을 확인하였다.

향후 연구에서는 보다 다양한 차량 유형과 사고 상황을 고려한 데이터를 수집하고, 이를 머신러닝 모델에 추가하여 예측 정확도를 향상시키는 작업이 요구된다. 또한, 시뮬레이션에서 사용된 인체 모형 및 더미의 정밀도를 개선하는 연구를 병행할 경우 상해 발생 가능성에 대한 예측 신뢰도를 한층 더 높일 수 있을 것으로 보인다. 또한, 실차 실험의 데이터와의 오차 최소화를 위한 차량의 차체 강성, 충격 에너지 분산 특성 등에 대한 반영하여 예측 모델의 보완을 진행함으로써 예측 신뢰도를 높이고 실제 사고 분석 및 실무 적용 가능성을 극대화할 수 있을 것으로 기대된다.

마지막으로 본 연구에서 개발한 예측 모델을 실시간으로 활용할 수 있는 프로그램으로 구축한다면 경찰과 보험사가 현장에서 실시간으로 데이터를 수집하고 이를 바탕으로 신속하게 탑승자의 상해 여부를 판단할 수 있을 것으로 기대된다. 이와 같은 접근법은 불필요한 행정 절차를 줄이고 보험금 과다 청구 및 보험 사기를 방지하는 데 기여하며 교통사고에 따른 사회적·경제적 비용 절감 효과를 가져올 것으로 예상된다.

#### 참고문헌

1. 강성모(2009), "후미추돌사고의 충격정도에 따른 승차자의 상해심각도 추정에 관한 연구", 동국대학교 박사학위청구논문.
2. 김명주(2015), "추돌사고에서 종량과 충돌속도가 상해에 미치는 영향에 관한 연구", 아주대학교 석사학위청구논문.
3. 백세룡(2022), "머신러닝을 이용한 후방추돌시 탑승자의 경추상해 예측모델 개발", 가천대학교 박사학위청구논문.
4. 이경수(2020), "주행 중 추돌사고에서 종량과 상대속도 차이에 따른 탑승자 상해 위험도 연구", 아주대학교 석사학위청구논문.
5. 이재원(2021), "저속추돌사고에 의한 차량거동 및 탑승자 목상해 예측에 관한 연구", 한양대학교 박사학위청구논문.
6. 홍성우 외(2012), "저속 후방 추돌 자원자 실험을 통한 두부와 경부의 동작분석", 『자동차안전학회지』, 4(2), 37-43.
7. Braun, T. A. et al. (2001), "Rear-end impact testing with human test subjects", SAE Technical Paper No. 2001-01-0168, 1-6.
8. Breiman, L. (2001), "Random Forests. Machine Learning", 45(1), 5-32.
9. Castro, W. H., Schilgen, M., Meyer, S., Weber, M., Peuker, C., & Wörtler, K. (1997), "Do whiplash injuries occur in low-speed rear impacts?", European Spine Journal, vol. 6, 366-375.
10. Cormier, J., Gwin, L., Reinhart, L., Wood, R., & Bain, C. (2018), "A comprehensive review of low-speed rear impact volunteer studies and a comparison to real-world outcomes". Spine, 43(18), 1250.
11. Hynd, D., & van Ratingen, M. (2005), "Challenges in the development of a regulatory test procedure for neck protection in rear-end impacts", In 19th International Technical Conference on the Enhanced Safety of Vehicles, 5-48.
12. Krafft, M., Kullgren, A., Tingvall, C., Bostrom, O., Fredriksson, R. (2000), "How crash severity in rear impacts influences short- and long-term consequences to the neck", analysis and prevention, 32(2), 187-195.
13. Krafft, M. et al. (2002), "Influence of Crash Pulse Characteristics on Whiplash Associated Disorders in Rear Impacts—Crash Recording in Real Life Crashes", Traffic Injury Prevention, 3(2), 141-149.
14. Kullgren, A., Eriksson, L., Boström, O., & Krafft, M. (2003), "Validation of neck injury criteria using reconstructed real-life rear-end crashes with recorded crash pulses", In Proc. 18th ESV Conf, 1-13.
15. McConnell, W. E. et al. (1995), "Human head and neck kinematics after low velocity rear-end impacts—understanding whiplash", SAE Transactions, 3106-3129.
16. Moravcová, P., Bucshházy, K., Zúvala, R., Semela, M., & Bradáč, A. (2024), "What should I use to calculate vehicle EES?", PLoS one, 19(2), e0297940.
17. Moss, R. T., Bardas, A. M., Hughes, M. C., & Happer, A. J. (2005), "Injury symptom risk curves for occupants involved in rear end low speed motor vehicle collisions", SAE Technical Paper No. 2005-01-0296, 1-8.
18. Quinlan, J. Ross (1993), "C4.5: Programs for Machine Learning". Morgan Kaufmann Publishers.
19. Szabo, T. J. et al. (1994), "Human occupant kinematic response to low speed rear-end impacts", SAE transactions, 630-642.
20. Szabo, T. J., & Welcher, J. B. (1996), "Human subject kinematics and electromyographic activity during low speed rear impacts", SAE transactions, 1924-1944.
21. Walz, F., & Muser, M. H. (1999), "Bemessung der Verletzungsschwelle der HWS bei Heckkollisionen", ETH Zurich.
22. Zou, H., & Hastie, T. (2005), "Regularization and variable selection via the elastic net", Journal of the Royal Statistical Society Series B: Statistical Methodology, 67(2), 301-320.
23. Zubby, D. S., Vann, D. T., Lund, A. K., & Morris, C. R. (1999), "Crash test evaluation of whiplash injury risk", SAE Technical Paper No. 99SC17, 1-9.

Part

## 05



김경동

• 울산·경남지부 사고조사연구원

최귀남

• 교통사고종합분석센터 사고조사연구원

## 자동차 창유리 틴팅 정도에 따른 가시거리에 관한 실험

Experiment on the viewing distance  
according to the tinting level

### Key Words

틴팅, 야간주행, 보행자 인지

### Contents

#### I. 서론

- 1 연구의 배경 및 목적
- 2 연구의 방법 및 범위

#### II. 본론

- 1 측정
- 2 측정결과 분석

#### III. 결론 및 향후 과제

### 요약

70%와 40%.’ 2013년 6월 개정된 도로교통법 시행령 제 28조에 따르면 자동차 앞면 창유리의 투과율은 70% 미만, 운전석 좌우 옆면 창유리는 40% 미만일 때 운행이 금지된다.

요인 경호용, 구급용 및 장의용 자동차만이 예외로 인정된다. 도로교통법이 투과율 70%, 40%를 지정한 이유는 외부에서 운전자가 보이도록 한 것이다. 그러나 최근 출시된 차들을 보면 밖에서 운전자가 아예 보이지 않을만큼 진한 경우가 많으며, 뒷좌석 좌우 옆면과 뒷면 창유리 경우에는 투과율에 제한이 없다.

그러나 실질적인 단속이 없는 것이 사실이다. 운전자의 틴팅 정도에 따른 야간에 가시거리를 확인함으로써 운전자의 사물 인지지점, 위험 인지지점을 대략적으로 추정하고자 실험하였다. 실험 차량을 정지상태에서 자동차 전조등에 대한 거리별 밝기(조도:Lux), 인지정도를 측정하여 보행자 의복 색깔별로 운전자가 인지하는 범위를 측정하여 틴팅정도에 따른 운전자의 가시거리를 얻을 수 있었다.

## I. 서론

### 1

#### 연구의 배경 및 목적

도로교통법에서 자동차 유리의 투과율 기준을 별도로 책정하고 있다. 시행령 제 28조 '자동차 창유리 가시광선 투과율의 기준'에 따르면 자동차 앞 유리 투과율은 70%미만, 운전석 좌우 옆면 창유리 투과율은 40%미만이면 규제를 받는다. 즉 자동차 틴팅을 진하게 하면 법에 저촉된다는 이야기이다. 해외의 여러 나라들의 경우 틴팅 농도를 규제하나 우리나라의 경우 자동차 틴팅의 경우 실질적인 규제가 잘 이루어지지 않는다. 실질적으로 도로에 다니는 자동차들 중 틴팅을 하지 않은 자동차가 거의 없으며 실내가 안보일 정도로 짙게 틴팅을 한 차들도 적지 않다.

자동차 틴팅이 너무 진하면 어두운 터널이나 지하주차장에서 외부를 제대로 볼 수 없어 위험할 수 있고 특히 야간 주행시 자체 불빛을 가지고 있지 않는 보행자, 도로 구조물을 인지하기 쉽지 않다.

운전자의 틴팅 정도에 따른 가시거리를 확인함으로써 운전자의 사물 인지지점, 위험 인지지점을 대략적으로 추정해 볼 수 있을 것이다.

### 2

#### 연구의 방법 및 범위

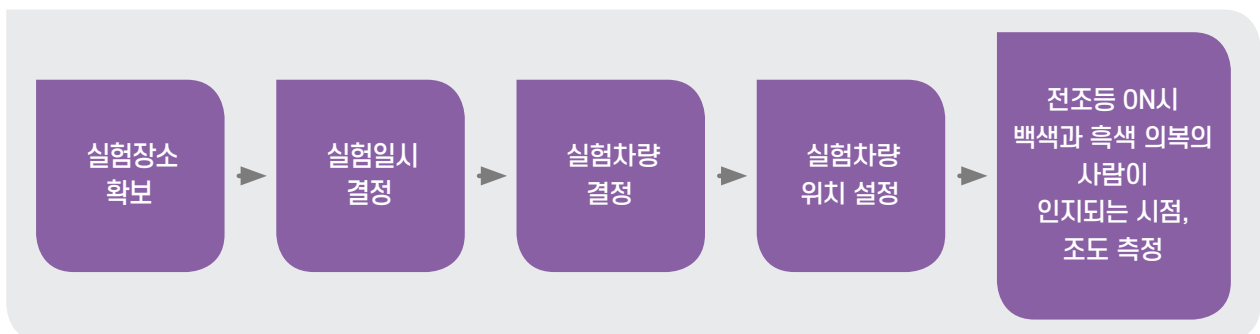
실험 차량을 정지상태에서 자동차 전조등에 대한 거리별 밝기(조도:Lux), 인지정도를 측정하여 보행자 의복 색깔로 운전자가 인지하는 범위를 도식화하고자 한다.

## II. 본론

### 1

#### 측정

##### 1) 측정과정






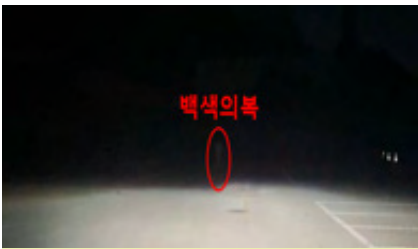
백색, 흑색 의복 착용상태



아반떼 실험장면



싼타페 실험장면



보행자 인지 장면

## 2) 측정결과

실험자 ① (아반떼, 백색의복)				실험자 ① (아반떼, 흑색의복)			
틴팅정도	구분	밝기(LUX)	거리(m)	틴팅정도	구분	밝기(LUX)	거리(m)
100%	물체	20	39	100%	물체	40	30.6
	사람	30	35.4		사람	50	29.7
44.70%	물체	30	35.6	44.70%	물체	190	25.1
	사람	50	30.2		사람	440	22.7
33.90%	물체	50	30.6	33.90%	물체	330	24
	사람	70	27		사람	790	19.9
18.80%	물체	70	25.5	18.80%	물체	650	18.5
	사람	160	19.3		사람	1050	16
5.00%	물체	150	19.6	5.00%	물체	230	15.6
	사람	230	16		사람	1910	12.2

실험자 ① (싼타페, 백색의복)			
틴팅정도	구분	밝기(LUX)	거리(m)
100%	물체	20	54.3
	사람	40	45.3
70+50%	물체	50	40.2
	사람	70	36.4
44.70%	물체	40	46
	사람	50	40.8
33.90%	물체	50	40.8
	사람	110	34.6
18.80%	물체	110	34.6
	사람	180	29.1
5.00%	물체	180	29.1
	사람	400	22.7


실험자 ① (싼타페, 흑색의복)			
틴팅정도	구분	밝기(LUX)	거리(m)
100%	물체	80	37.8
	사람	110	34.3
70+50%	물체	260	24.1
	사람	490	20.1
44.70%	물체	120	33
	사람	210	27.9
33.90%	물체	210	26.7
	사람	360	22.2
18.80%	물체	400	22.9
	사람	500	20.3
5.00%	물체	690	19.6
	사람	2390	20

실험자 ② (아반떼, 백색의복)			
틴팅정도	구분	밝기(LUX)	거리(m)
100%	물체	30	35.3
	사람	50	30.7
44.70%	물체	60	29.4
	사람	130	21
33.90%	물체	80	25
	사람	160	20
18.80%	물체	90	24
	사람	200	16.5
5.00%	물체	130	20.4
	사람	380	15.7


실험자 ② (아반떼, 흑색의복)			
틴팅정도	구분	밝기(LUX)	거리(m)
100%	물체	60	25
	사람	90	22.2
44.70%	물체	190	25.1
	사람	930	18
33.90%	물체	650	19.2
	사람	1050	15.6
18.80%	물체	960	17.6
	사람	1480	14
5.00%	물체	1550	14.6
	사람	2480	12

실험자 ② (싼타페, 백색의복)			
틴팅정도	구분	밝기(LUX)	거리(m)
100%	물체	30	48.8
	사람	60	40.6
70+50%	물체	90	33.7
	사람	130	30.1
50(44.70)%	물체	20	39.1
	사람	110	31.9
35(33.90)%	물체	90	33.4
	사람	190	25.5
15(18.80)%	물체	140	28.5
	사람	260	23.3
5.00%	물체	160	27.1
	사람	380	21.8


실험자 ② (싼타페, 흑색의복)			
틴팅정도	구분	밝기(LUX)	거리(m)
100%	물체	80	37.8
	사람	110	34.3
70+50%	물체	260	24.1
	사람	490	20.1
44.70%	물체	280	24.1
	사람	590	20
33.90%	물체	390	22.2
	사람	690	19
18.80%	물체	760	19.1
	사람	4850	15
5.00%	물체	640	18.9
	사람	2200	16.3




실험자1(싼타페, 백색의복)



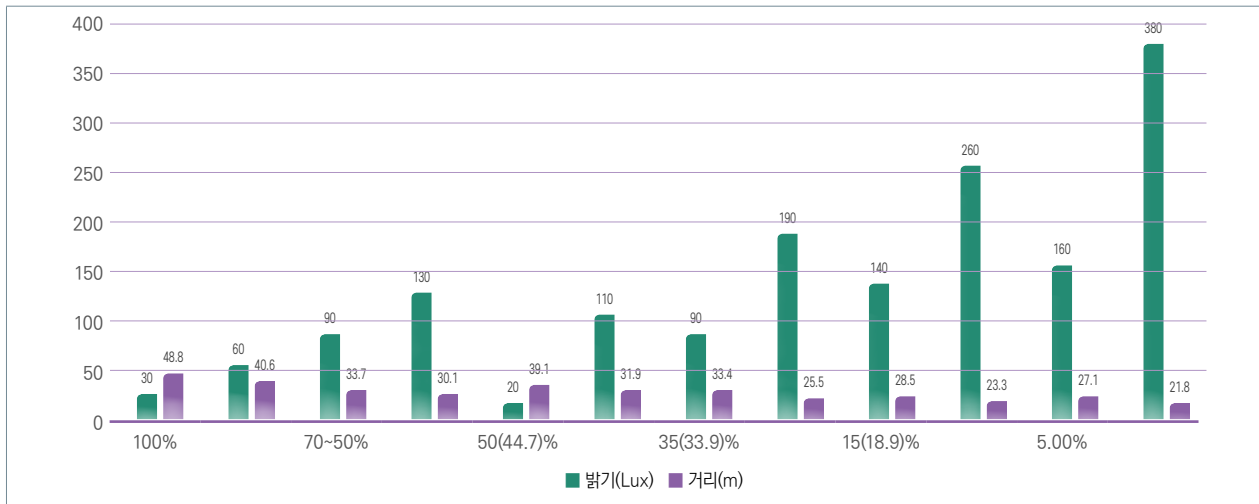
실험자1(싼타페, 흑색의복)



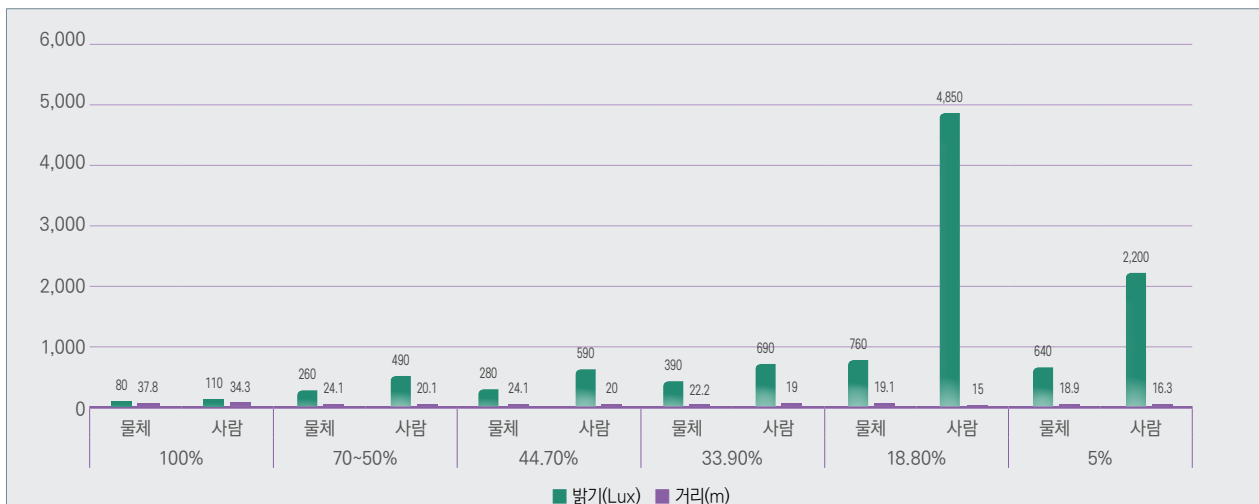
실험자1(아반떼, 백색의복)




실험자1(아반떼, 흑색의복)



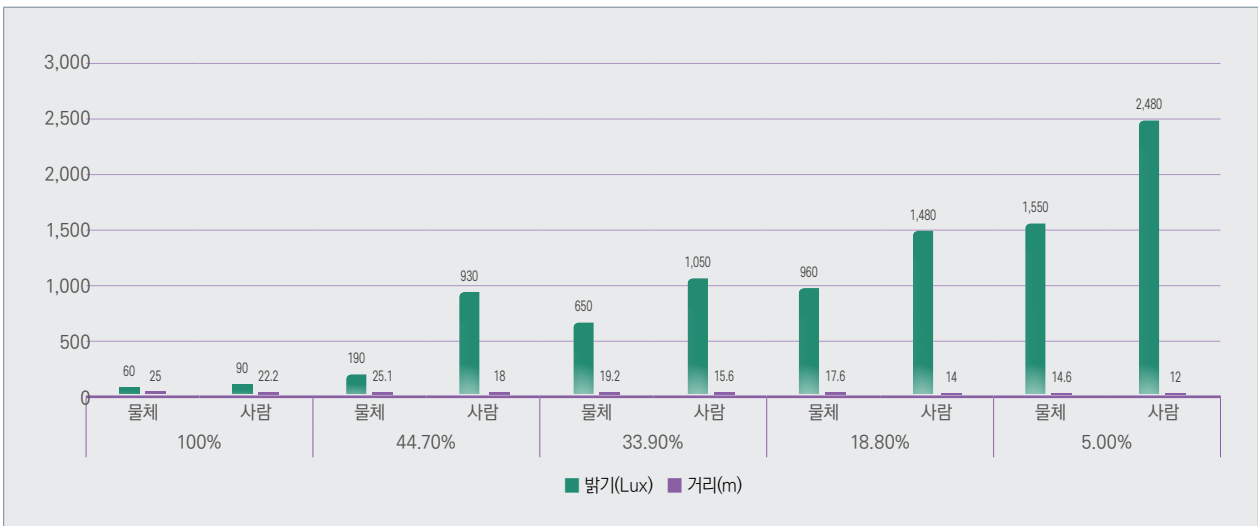
실험자2(싼타페, 백색의복)



실험자2(싼타페, 흑색의복)



실험자2(아반떼, 백색의복)



실험자2(아반떼, 흑색의복)

2

측정결과 분석

백색 의복을 착용한 사람을 운전자가 물체로 인지하기 위한 조도값은 틴팅 정도에 따라 최소 20Lux, 최대 180Lux, 인지가능 거리는 최대 54.3m에서 최소 19.6m로 나타나며, 백색 의복을 착용한 사람을 운전자가 사람으로 인지하기 위한 조도값은 틴팅 정도에 따라 최소 30Lux에서 최대 400Lux, 인지가능 거리는 최소 15.7m, 최대 45.3m로 나타남. 흑색 의복을 착용한 사람을 운전자가 물체로 인지하기 위한 조도값은 틴팅 정도에 따라 최소 40Lux, 최대 1550Lux, 인지가능 거리는 최대 37.8m, 최소 14.6m로 나타나며, 흑색 의복을 착용한 사람을 운전자가 사람으로 인지하기 위한 조도값은 틴팅 정도에 따라 최소 50Lux, 최대 2480Lux, 인지가능 거리는 최소 12m, 최대 34.3m로 나타남.

■ 백색

구분	물체 인식	사람 인식
조도(Lux)	20-180	30-400
거리(m)	19.6-54.3	15.7-45.3

■ 흑색

구분	물체 인식	사람 인식
조도(Lux)	40-1550	50-2480
거리(m)	14.6-37.8	12-34.3

국민 농도로 일컬어지는 앞유리 30%(실제 실험 측정시 33.9%) 틴팅의 경우 백색 의복을 착용한 사람을 운전자가 물체로 인지하기 위한 조도값은 최소 50Lux, 최대 80Lux, 인지가능 거리는 최소 25m, 최대 40.8m로 나타내며, 백색 의복을 착용한 사람을 운전자가 사람으로 인지하기 위한 조도값은 최소 70Lux, 최대 190Lux, 인지가능 거리는 최소 20m 최대 34.8m로 나타남.

흑색 의복을 착용한 사람을 운전자가 물체로 인지하기 위한 조도값은 최소 210Lux, 최대 650Lux, 인지가능 거리는 최소 19.2m, 최대 26.7m로 나타내며, 흑색 의복을 착용한 사람을 운전자가 사람으로 인지하기 위한 조도값은 최소 360Lux, 최대 1050Lux, 인지가능 거리는 최소 15.6m, 최대 22.2m로 나타남.

■ 백색

구분	물체 인식	사람 인식
조도(Lux)	50-80	70-190
거리(m)	25-40.8	20-34.8

■ 흑색

구분	물체 인식	사람 인식
조도(Lux)	210-650	360-1050
거리(m)	19.2-26.7	15.6-22.2

### Ⅲ. 결론 및 향후과제

1) 야간 주행중인 운전자가 틴팅 정도에 따라 전방보행자를 사람으로 인식하기 위해서는 최소 30Lux이상, 12m에서 가능한 것으로 나타남.

2) 같은 틴팅 정도일 때, SUV 운전자가 승용차 운전자에 비해 백색 의복의 보행자를 물체로 인지할 때 최소 4.6m, 최대 15.4m, 백색 의복의 보행자를 사람으로 인지할 때 최소 9.9m, 최대 16.2m 앞서 인지하는 것으로 나타내며, SUV 운전자가 승용차 운전자에 비해 흑색 의복의 보행자를 물체로 인지할 때 최소 1m, 최대 12m, 흑색 의복의 보행자를 사람으로 인지할 때 최소 2.1m, 최대 12.1m 앞서 인지하는 것으로 나타남.

3) 실험자들의 개별 시력의 차이를 고려해야하며, 실제 사고에 있어서는 정지시력보다 30~50% 낮아지는 동체시력에 의존하여야 하므로 실제 인지거리보다 훨씬 가까운 지점에 이르러서야 보행자를 인식할 것으로 추정됨.

이러한 결과는 야간 운전자의 보행자 충격사고 분석에 절대치로 적용하기에는 어려우나 참고자료로서 활용될 수 있을 것으로 판단되며, 향후 안전하고 밀폐된 실험장소를 확보한 상태에서 다양한 차종별 실험과 움직이는 차량에서의 실험이 이루어져야 할 것이다.



## 2026년 공인자격 도로교통사고감정사 자격검정 공고

자격기본법 제23조 및 한국도로교통공단 도로교통사고감정사 자격관리규칙 제16조에 의거,  
2026년도 제22회 공인자격 도로교통사고감정사 자격검정 시행계획을 다음과 같이 공고합니다.

## 1. 응시자격 및 시험일정

가. 응시자격 : 2026년 시험접수 종료일 기준, 만 18세 이상인 자(학력제한 없음)  
나. 응시제한 : 자격이 취소된 후 1년이 경과하지 않은 자  
시험 부정행위자로 3년이 경과하지 않은 자

## 다. 시험일정

접수기간	시험일자	시험 구분	운영시간		준비물	합격자 발표
			입실시간	시험시간		
'26.08.03.(월) 09:00 ~ '26.08.13.(목) 18:00	'26.09.13.(일)	1차 시험	09:00	09:30~12:00	신분증, 공학계산기, 필기구 등	'26.10.21.(수) 예정
		2차 시험	13:00	13:30~16:00		

\* 1차시험 일부면제자는 입실 09:00, 시험시간 09:30~10:45

## 2. 시험지역 및 원서접수

가. 시험장소 : 한국도로교통공단 및 외부시험장  
(최종 시험 장소는 7월 중 안전운전통합민원 홈페이지에 발표 예정)  
나. 원서접수 : 공단 홈페이지를 이용 온라인 시험접수  
한국도로교통공단 안전운전통합민원(<https://safedriving.or.kr>)

- 본인 인증 후 시험 접수(휴대전화인증 등)
- 최근 6개월 이내 촬영한 여권사진규격(3.5cmx4.5cm)사진 파일 첨부
- 1차시험 일부면제 신청자는 교육이수증 사본 또는 경력증명서 제출

\* 컬러사진, 1차시험 일부면제자 제출서류는 스캔하여 JPG파일 업로드

## 3. 응시수수료 및 자격증 발급비

응시수수료(부가세 포함)	납부방법	납부기한
• 일반응시자 • 1차시험 일부 면제자	77,000원 신용카드 계좌이체(인터넷 뱅킹) 가상계좌(무통장 입금)	접수마감 시까지 (가상계좌의 경우 접수 마감 익일 16:00까지, 미납 시 자동 접수취소)
• 1차시험 전부면제자	44,000원	
자격증 발급비(부가세 포함)	납부방법	비고
• 공인자격증(카드형)	5,500원 신용카드 계좌이체 (인터넷 뱅킹)	- 자격시험 합격자에 해당하며 신청자에 한하여 발급 - 발송비용(택배비 3,500원)은 수취인 부담
• 공인자격증서(증서형)	11,000원	

\* 시험접수 수수료, 자격증 발급 수수료 납부는 안전운전통합민원 홈페이지 이용

## 4. 접수취소 및 환불기준

접수취소(환불) 방법	접수취소(환불) 신청기간	환불금액	환불기간	비고
안전운전통합민원 홈페이지 이용 (승인취소 또는 계좌 환불)	'26.08.03.(월) ~ '26.08.13.(목) 24:00	납입액의 100%	신청일로부터 15일 이내	접수취소(환불) 신청기간 이후 응시수수료 환불 불가
	'26.08.14.(금) ~ '26.09.07.(월) 24:00	납입액의 50%		

\* 본인 사망 또는 가족 경조사 등 불가피한 사유로 응시하지 못한 경우 증빙자료 제출 시 50% 환불,  
코로나19 관련 수험자 100% 환불 허용

자격증 발급비 환불
합격자에 한하여 신청하며 자격증 발송 이전 취소 시 (1주일 내) 100% 환불, 그 이후 취소 시에는 환불 불가

본 자격검정은 공인자격 취득을 위한 자격시험이므로 한국도로교통공단에서 자격취득자에게 취업을 알선하거나 보장하지 않습니다.

2026년 3월 24일

 한국도로교통공단 이사장

강원특별자치도 원주시 혁신로2(반곡동)

## · 도로교통사고감정사 자격취득 우대사항 ·

- 한국도로교통공단 채용 시 가산점 부여 및 자격수당 지급
- 국가평생교육진흥원 학점은행제 10학점(교통, 토목) 인정
- 교통안전담당자로 지정 가능한 자격증으로 관련분야 취업가능