



< 응용 논문 >

머신러닝을 이용한 후미추돌 사고의 차량 유효충돌속도 예측 모델 개발에 대한 연구

백 세 룡¹⁾ · 윤 준 규²⁾ · 임 종 한²⁾

가천삼승자동차연구센터¹⁾ · 가천대학교 기계공학과²⁾

A Study on the Development of Delta-V Prediction Model for Rear-end Collision Accidents Using Machine Learning

Seryong Baek¹⁾ · Junkyu Yoon²⁾ · Jonghan Lim^{*2)}

¹⁾Gachon-Samsung Automotive Research Center, 1342 Seongnam-daero, Sujeong-gu, Seongnam-si, Gyeonggi 13120, Korea

²⁾Department of Mechanical Engineering, Gachon University, Gyeonggi 13120, Korea

(Received 27 August 2021 / Revised 23 December 2021 / Accepted 28 December 2021)

Abstract : With the increasing number of vehicles equipped with ADAS(Advanced Driver Assistance Systems), passenger injury characteristics are changing in the event of a collision. AEBS(Autonomous Emergency Braking System) is the representative ADAS. It is a system that activates the brake to avoid collision, or mitigate impact in a collision risk situation. Recent rear-end collisions tend to be low-speed collisions because collisions are completely unavoidable in all accident situations. Low-speed collisions have a relatively higher risk of causing neck injuries than other types of injuries. The characteristics of neck injuries vary from person to person. Neck injuries are generally known to occur at an effective collision speed of 8 km/h or higher. In this study, actual crash test data were programmed as machine learning techniques to derive effective collision speeds under collision conditions. As a result, we have developed a model that could induce effective collision speeds from vehicle collisions. The developed model can calculate an effective collision speed by taking into account the speed, weight, angle, and offset of the vehicle. Using the developed model, it is possible to estimate the seriousness of a passenger's neck injuries in traffic accidents without using any other analysis program.

Key words : Machine learning(기계학습), Traffic accident(교통사고), Rear impact(후방추돌), Crash test(충돌시험), Whiplash injury(목상해)

1. 서론

최근 ADAS(Advanced Driver Assistance Systems)가 장착된 차량의 보급이 급격하게 증가하고 있다. ADAS는 운전자를 보조하는 시스템으로 편의장치와 안전장치로 나눌 수 있다. 편의장치는 앞 차와의 거리를 유지하고 차로를 유지하는 장치가 있고 안전장치는 위험 상황에서 자동으로 제동하여 충돌을 회피하거나 충격을 경감하는 장치가 있다. 충돌 회피를 위한 대표적인 ADAS는 AEB(Autonomous Emergency Braking)를 꼽을 수 있다.^{1,2)} AEB의 장착으로 추돌 사고가 줄어들고 있지만 아직 모든 운행조건에서 회피할 수 없기 때문에 충격을 경감하

는데 주목적을 두고 있다. 그에 따라 최근 추돌사고는 다소 낮은 속도에서 발생하는 경향을 보인다. 낮은 속도에서의 추돌 사고는 다른 부상보다 목 부상의 확률이 상대적으로 높다. 목 부상은 사람에 따른 차이는 있지만 대체적으로 Delta-V 8 km/h 이상에서 발생하는 것으로 알려져 있으며 현재 우리나라에서 목상해를 판단하는데 기준이 되고 있다. 차량의 충돌에 의한 Delta-V는 운동량 보존법칙에 따라 계산될 수 있으나 차종, 오프셋, 차체 강성 등을 고려하지 않기 때문에 조건에 따라 오차가 발생할 수 있다. 목상해에 관련된 연구로 조희창과 박인송³⁾은 실차시험을 통해 저속 후방 충격 조건에서 목 부상의

*A part of this paper was presented at the KSAE 2021 Spring Conference

*Corresponding author, E-mail: kkjong@gachon.ac.kr


³⁾This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium provided the original work is properly cited.

영향에 대해 분석했다. 그 결과로 저속 측면 후방 충돌 시 목상해의 가능성은 약 10 % 수준으로 나타났으며 한 달 이상의 장기 목상해 증상이 없는 것으로 나타났다. 하지만 목 부상에 대한 더 많은 연구를 위해 차체 구조, 프레임 구조 및 후방충돌 패턴의 영향을 평가해야 한다고 제안하였다. 또한 박진수 등⁴⁾은 목상해 분석을 위해 MADYMO (MAtheMatical DYnamic MOdel) 프로그램을 이용해 시트의 설정 및 착좌 조건에 따른 영향을 분석하였다. 그 결과로 목상해를 최소화하기 위한 헤드레스트의 높이, 시트백 각도, 시트백 토크를 제안하였다. 장명수 등⁵⁾은 복미 목상해(IIHS, Insurance Institute Highway Safety) 및 IQS(Initial Quality Study) 인자분석을 통한 상관관계 분석에 대한 연구를 수행하였다. 그 결과로 탑승자 상해를 줄이면서 동시에 탑승자의 안락함까지 향상시킬 수 있는 방법에 대한 가이드를 제시하였다. 목상해 분석을 위한 많은 연구가 이루어지고 있지만 차체구조와 안전장치가 개선되거나 상해 측정을 위한 입력변수가 변경되는 경우 기존 모델을 사용하지 못하게 된다. 따라서 새로운 문제를 해결하기 위해 새로운 연구를 수행해야하며 이 때 긴 시간이 소요되므로 개발이 완료되는 시점에서 다시 새로운 문제에 직면하게 되는 악순환이 계속되고 있다. 머신러닝을 도입하여 목상해 모델을 구축하면 데이터의 재분류만으로 빠른 시간에 새로운 모델을 만들 수 있다는 장점이 있다. 본 연구에서는 저속 충돌시험 데이터를 분석하여 차량 형태, 오프셋, 차체 강성 등이 고려된 Delta-V 예측모델을 구하고자 한다. 모델은 많은 복잡성을 가지고 있기 때문에 머신러닝 기법을 이용하였다. 총 255건의 시험데이터를 수집하였고 본 연구의 목적에 적합하지 않은 19건을 제외하고 191건은 트레이닝 데이터 셋으로 구성하고 45건은 검증용 데이터 셋으로 구성하여 모델을 도출하고자 한다.

2. 이론적 배경

2.1 편타손상

편타손상(Whiplash injury)은 신체가 갑자기 가속 또는 감속되어 체간부와 두부의 심한 진단 현상이 일어나면서 경부에 과도한 신전 및 굴곡이 일어나는 현상으로 경추의 탈구, 골절, 경수 및 주위 연조직에 일으키는 손상으로 후방충돌로 인한 선행 차량의 탑승자에게 발생할 수 있는 가장 빈번한 부상이다.^{6,7)} 후방충돌의 경우 저속에서도 탑승자의 경추 상해가 발생할 확률인 높기 때문에 헤드레스트와 같은 구속장치가 적용되고 있으며 국내외에서 진행되는 차량 안전도 평가에 머리구속장치를 평가하고 있다.⁸⁾



(A) Hyperextension

(B) Hyperflexion

Fig. 1 Whiplash injury

Fig. 1은 충돌로 인한 탑승자 경부의 신전 및 굴곡을 나타낸 것이다.

2.2 운동량 보존법칙을 이용한 Delta-V 계산

차량의 중량과 충돌전후 속도를 이용해 Delta-V를 계산할 수 있다. 식 (1)은 운동량 보존법칙에 대한 공식으로 여기서 m_1 은 충돌 차량의 질량, v_1 은 충돌 차량의 초기속도, m_2 는 피충돌 차량의 질량, v_2 는 피충돌 차량의 초기속도, v_1' 은 충돌 차량의 충돌 후 속도, v_2' 는 피충돌 차량의 충돌 후 속도를 의미한다. 식 (2)는 반발계수(e) 계산 공식을 나타낸 것이며 각 요소는 식 (1)과 동일하다. 식 (3)은 식 (1)과 (2)를 연립해서 정리한 것으로 이 식을 이용해 두 차량의 질량과 충돌 전 속도를 적용하여 2차량의 충돌 후 속도를 구할 수 있다.

$$m_1v_1 + m_2v_2 = m_1v_1' + m_2v_2' \quad (1)$$

$$e = \frac{v_2' - v_1'}{v_1 - v_2} \quad (2)$$

$$v_2' = v_2 + \frac{m_1(1+e)}{m_1+m_2}(v_1 - v_2) \quad (3)$$

2.3 머신러닝

머신러닝의 개념은 다양하게 표현할 수 있으나 일반적으로는 애플리케이션을 수정하지 않고도 데이터를 기반으로 패턴을 학습하고 결과를 예측하는 알고리즘 기법을 통칭한다. 매우 복잡한 조건으로 인해 기존의 소프트웨어 코드만으로는 해결하기 어려웠던 많은 문제점들을 머신러닝을 이용해 해결할 수 있다. 수시로 변하는 외부 조건에 맞춰서 기존 로직을 다시 수정하고 검증하는 프로세스는 많은 시간과 비용이 요구되지만 머신러닝 알고리즘은 데이터를 기반으로 통계적인 신뢰도를 강화

하고 예측 오류를 최소화하기 위한 다양한 수학적 기법을 적용해 데이터 내의 패턴을 스스로 인지하고 신뢰도 있는 예측결과를 도출해 내기 때문에 시간과 비용을 효과적으로 줄일 수 있다.⁹⁾ 본 연구에서는 Keras 모델을 사용하였으며 Error는 MSE(Mean Squared Error)를 이용했다. MSE는 회귀(Regression) 용도의 딥러닝 모델을 훈련시킬 때 많이 사용되는 손실함수이다.¹⁰⁾

$$L = \frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2 \quad (4)$$

식 (4)는 MSE를 계산하는 식으로 여기서 N 은 샘플개수이고 t_i 는 샘플 i 의 진짜 타깃값, y_i 는 t_i 에 대한 모델의 예측 값을 나타낸다.¹¹⁾

3. 연구방법

3.1 데이터 수집

데이터는 AGU(Die Arbeitsgruppe für Unfallmechanik) Zurich에서 시험한 255건의 충돌 시험 자료를 사용하였다.¹²⁾

모델의 정확도 판단을 위해 총 255 케이스 중 저속 추돌 상황에서 탑승자의 목상해 판단을 위한 Delta-V를 추



Fig. 2 Rear-end collision test




Fig. 3 Raw data distribution

정하기에 적합한 케이스만 선정하였다. 236케이스가 최종 선정되었으며 약 80%는 학습데이터로 나머지 약 20%는 검증을 위한 데이터로 사용했다.

3.2 변수 정의

초기 데이터는 시험에서만 알 수 있는 정보로 구성되어 있지만 실제 사고에서 확인할 수 있는 정보는 제한적이다. 본 모델을 실제 사고에서 사용될 모델이므로 일반적인 사고조사에서 확인할 수 있는 값을 분류하였다. 1차량의 경우 알 수 없는 정보인 Delta-V, Acceleration를 제외하였다. 또한 Year(차량 연식)은 영향이 크지 않을 것으로 판단하여 제외하였고 Division(충돌부위)는 추돌 사고 단일 조건이므로 제외하였다. 2차량의 경우 Model, Weight, Initial speed, Direction, Offset을 Input 데이터로 사용하였다. 그 외의 데이터는 실제 교통사고 조사에서 확인하기 어려운 요소이므로 제외하였다.

Table 1 Data set

| Vehicle no. | Item |
|-----------------------|---------------|
| Vehicle 1 (Strike) | Model |
| | Year |
| | Weight |
| | Initial speed |
| | Delta-V |
| | Acceleration |
| | Division |
| | Direction |
| | Offset |
| | EES |
| Vehicle 2 (Struck) | Model |
| | Year |
| | Weight |
| | Initial speed |
| | Delta-V |
| | Acceleration |
| | Division |
| | Direction |
| | Offset |
| | EES |

3.3 데이터 가공 및 분류

본 연구는 저속 추돌 상황에서 탑승자의 목상해 판단을 위한 Delta-V를 추정하기 위한 연구로 저속 충돌 실험 시험 데이터를 학습데이터로 사용하였다. 머신러닝은

Table 2 Number of data

| Test type | Number of case |
|-----------------|----------------|
| Vehicle to Wall | 15 |
| Front to Side | 3 |
| Front to Front | 1 |
| Front to Rear | 236 |

Table 3 Vehicle classification

| Vehicle no. | Code |
|---------------|------|
| Sedan | 1 |
| Hatchback | 2 |
| SUV | 3 |
| Mini VAN | 4 |
| VAN | 5 |
| Truck | 6 |
| Barrier Starr | 7 |

학습에 사용되는 데이터의 양과 질이 모두 중요하므로 시험데이터의 오류 또는 범위를 벗어나는 데이터를 가공하고 분류해야 결과의 정확성을 높일 수 있다. 따라서 수집된 255건의 데이터 중 고정벽 충돌, 측면충돌 등의 조건은 연구의 범위를 벗어난 조건이므로 제외하였다.

Table 2는 수집된 시험 데이터의 시험유형에 따른 수량을 나타낸 것으로 본 연구에 적합한 충돌조건인 경우 236건으로 확인되었다. 191건은 학습데이터로 45건은 검증에 위한 데이터로 분류하였다.

머신러닝은 범주형 데이터를 이용해 학습하는 분류 모델과 숫자형태를 학습하는 회귀 모델로 나눌 수 있다.⁹⁾ 현재 수집된 데이터의 경우 차량모델명으로 구분된 범주형으로 볼 수 있다. 하지만 차량의 모델이 매우 다양하므로 학습이 제대로 이루어지지 않을 수 있기 때문에 차량의 형상으로 분류하여 데이터를 수치화했다. 차량은 Table 3과 같이 차종으로 분류하였으며 숫자 코드로 적용하였다.

3.4 머신러닝 모델 학습 및 개선 효과 검증

머신러닝은 Tensorflow Keras 모델을 이용하였다. Keras는 사용자 친화적으로 개발되었기 때문에 간단한 신경망을 구성할 때는 몇 줄만의 코드로 모델을 만들 수 있다. 준비된 191건의 학습데이터를 이용해 머신러닝 학습을 진행하였다. 총 2,500회의 반복 학습을 진행하였으며 그 결과 Loss는 1.8로 확인되었다. Fig. 4는 학습 횟수에 따른 Loss를 그래프로 나타낸 것이다. 약 250회까지 학습하며 빠르게 Loss가 줄어드는 것을 볼 수 있었고 500회 이상에서는 일정 수준의 Loss를 유지하는 것을 확인




Fig. 4 Loss according to number of learning




Fig. 5 Coefficient of restitution according to impact velocity

하여 충분히 학습된 것을 확인하였다.

개발된 모델의 검증은 식 (3)과 운동량보존법칙으로 계산된 기존 방식과 비교하는 방식으로 수행되었다.

식 (3)에 적용되는 반발계수는 Fig. 5와 같이 기존에 시험을 통해 도출된 자료를 바탕으로 적용하였다. 식 (5)는 시험을 통해 도출된 충돌 조건인 반발계수를 나타낸 것으로 시험결과에서 제공하는 충돌 차량의 초기 속도를 v_1 에 대입하여 반발계수를 계산했다.

$$e = 0.7828 \exp(-0.159 \cdot v_1) \tag{5}$$

계산된 반발계수는 식 (3)에 적용하여 피충돌 차량의 Delta-V를 계산하였다.

4. 결과 및 고찰

Fig. 6은 머신러닝 모델의 전개 구조로 개발된 모델은 9개의 변수에 대한 가중치와 1개의 편향으로 구성된 형태를 확인할 수 있다.

$$y = W_1x_1 + W_2x_2 + \dots + W_9x_9 + b \tag{6}$$




Fig. 6 Computational structure of model

Table 4 Model

| Item | Value |
|-----------------------|-------------|
| W1 (V1-Model) | -0.46139488 |
| W2 (V1-Weight) | +0.00308991 |
| W3 (V1-Initial speed) | +0.45211607 |
| W4 (V1-Direction) | -0.00133027 |
| W5 (V1-Offset) | -0.17292602 |
| W6 (V2-Model) | +0.04548939 |
| W7 (V2-Weight) | -0.00340788 |
| W8 (V2-Direction) | +0.00536290 |
| W9 (V2-Offset) | +0.19274679 |
| b | +0.48036796 |

식 (6)은 학습된 모델을 수식으로 나타낸 것으로 W 는 각 항의 가중치, x 는 각 항목의 입력값, b 는 편향을 나타낸 것으로 충돌차량의 형상과 속도에 따른 영향이 가장 큰 것으로 나타났다. 실제 이론식의 경우 두 차량의 속도, 질량, 반발계수만으로 계산되지만 머신러닝 학습 모델의 경우 질량에 의한 영향이 1번 차량의 경우 +0.00308991, 2번 차량의 경우 -0.00340788로 다른 변수에 비해 다소 작게 나타났다. 차량의 질량에 의한 영향이 작은 이유는 수집된 시험 차량이 대부분 비슷한 중량으로 구성된 영향으로 판단된다.

Table 5는 실차시험, 운동량 보존법칙으로 계산된 이론값, 머신러닝 학습모델로 예측된 Delta-V를 나타낸 것이다.

이론식으로 도출한 Delta-V는 실차시험과 비교했을 때 최대 6.03 km/h의 오차를 나타냈고 최소 0.06 km/h의 오차를 나타냈다. 머신러닝을 통해 학습된 모델을 이용했을 때 최대 2.43 km/h의 오차를 나타냈고 최소 0.07 km/h의 오차를 나타냈다. 45개의 결과를 종합해 계산된

Table 5 Prediction data from ML model

| No. | Experiment | Theory | ML model |
|-----|------------|--------|----------|
| 1 | 5.40 | 5.18 | 5.25 |
| 2 | 6.20 | 6.62 | 7.65 |
| 3 | 6.60 | 7.01 | 8.00 |
| 4 | 7.70 | 6.80 | 7.83 |
| 5 | 8.40 | 7.96 | 9.31 |
| 6 | 8.40 | 6.94 | 7.08 |
| 7 | 8.50 | 8.40 | 8.77 |
| 8 | 8.60 | 9.76 | 9.67 |
| 9 | 8.60 | 7.83 | 10.58 |
| 10 | 8.80 | 9.69 | 10.95 |
| 11 | 9.00 | 10.39 | 11.43 |
| 12 | 9.10 | 8.47 | 9.43 |
| 13 | 9.30 | 9.62 | 10.94 |
| 14 | 9.40 | 7.84 | 8.82 |
| 15 | 9.50 | 7.69 | 9.19 |
| 16 | 9.60 | 9.40 | 10.27 |
| 17 | 9.80 | 9.03 | 9.94 |
| 18 | 9.90 | 8.80 | 10.16 |
| 19 | 9.90 | 9.84 | 10.90 |
| 20 | 10.00 | 9.73 | 10.11 |
| 21 | 10.00 | 9.77 | 10.67 |
| 22 | 10.10 | 9.49 | 10.65 |
| 23 | 10.10 | 9.66 | 8.76 |
| 24 | 10.30 | 9.68 | 9.76 |
| 25 | 10.30 | 10.48 | 10.15 |
| 26 | 10.40 | 9.21 | 10.56 |
| 27 | 10.50 | 10.22 | 10.23 |
| 28 | 10.60 | 9.79 | 10.49 |
| 29 | 10.70 | 9.77 | 10.30 |
| 30 | 10.70 | 9.15 | 9.30 |
| 31 | 10.80 | 9.12 | 9.98 |
| 32 | 10.90 | 10.45 | 11.66 |
| 33 | 10.90 | 10.68 | 10.52 |
| 34 | 11.00 | 9.67 | 10.64 |
| 35 | 11.00 | 11.27 | 11.07 |
| 36 | 11.10 | 10.16 | 10.25 |
| 37 | 11.20 | 10.22 | 10.27 |
| 38 | 11.30 | 10.68 | 12.34 |
| 39 | 11.50 | 9.56 | 9.97 |
| 40 | 11.70 | 9.75 | 10.10 |
| 41 | 11.80 | 9.70 | 10.66 |
| 42 | 12.10 | 10.22 | 11.55 |
| 43 | 12.30 | 11.14 | 12.74 |
| 44 | 12.60 | 9.88 | 10.28 |
| 45 | 16.40 | 10.37 | 14.10 |
| MSE | - | 1.01 | 0.60 |




Fig. 7 Validation Data

MSE는 이론식의 경우 1.01, 머신러닝 학습모델의 경우 0.60으로 머신러닝으로 학습한 모델로 예측된 결과가 더욱 정확한 것으로 확인되었다. Fig. 7은 학습을 통해 개발된 모델에 45건의 테스트 셋을 적용해 예측된 Delta-V와 실차 시험의 Delta-V를 비교한 것이다.

X-축은 실차 시험의 Delta-V이고 Y축은 머신러닝 모델로 예측된 Delta-V를 나타낸 것이다. 머신러닝으로 예측된 모델은 실차 시험과 비교했을 때 다소 오차가 있는 관계로 최소, 최대 범위의 추세선을 그려 각 속도에 대한 오차범위를 설정하였다. 목상해 판단을 위한 기준인 8 km/h를 포함하는 예측 Delta-V 범위는 6.5~9.8 km/h 범위로 나타났다. 따라서 학습된 모델을 사용해 도출된 Delta-V가 6.5~9.8 km/h 범위로 예측되는 경우 추가적인 분석을 수행할 필요가 있으며 6.5 km/h 보다 낮은 경우는 8 km/h 이하, 9.8 km/h보다 높은 경우는 8 km/h이상의 Delta-V를 가지는 것으로 판단할 수 있다. Delta-V 8 km/h를 기준으로 했을 때 오차는 -1.5에서 +1.8로 상해를 판단하기 위한 모델로 사용하기에는 다소 보완이 필요할 것으로 판단된다. 또한 Delta-V 6~10 km/h 범위에 위치한 데이터가 다소 부족한 관계로 추후 추가적인 시험 또는 시뮬레이션을 통해 데이터를 보완하여 모델의 정확도를 높이는 연구가 필요할 것으로 판단된다.

5. 결론

본 연구에서는 분석에 많은 시간과 비용이 필요한 목상해 분석을 빠르게 할 수 있는 모델을 개발하기 위해 머신러닝 기법을 적용하였다. 전체 236건의 저속 후방추돌 시험 데이터 중 191건은 학습데이터로 45건은 검증에 위한 데이터로 분류하여 모델을 개발하고 분석했을 때 다음과 같은 결론을 얻을 수 있었다.

- 1) 차량의 중량, 형상, 속도, 옵션, 각도 등을 고려하는 모델을 개발하여 기존에 차량의 속도, 중량만 사용하던 이론식보다 정확한 Delta-V 예측 모델을 개발하였다.

- 2) 개발된 모델과 이론식을 MSE로 비교했을 때 이론식은 1.01, 개발된 모델은 0.60으로 머신러닝으로 개발된 모델이 더 정확한 결과를 나타내는 것으로 확인되었다.

- 3) 개발된 모델의 경우 최대 $y = 3.0787e^{0.1457x}$, 최소 $y = 3.2324e^{0.0898x}$ 의 오차를 가지므로 예측된 Delta-V에 최소, 최대 범위의 오차를 적용해야하며 계산결과가 오차범위에 포함될 경우 본 모델만을 이용해 상해 유무를 판단하기에는 다소 어려울 것으로 판단된다.

- 4) 따라서 오차범위를 줄이기 위해 추가적인 시험 및 시뮬레이션 데이터를 통한 추가학습을 통해 모델을 개선하는 후속 연구가 필요할 것으로 보인다.

본 연구는 우리나라에서 목상해를 판단하는데 기준이 되는 Delta-V 8 km/h를 확인하기 위한 방법을 머신러닝 학습 연구로 진행한 것으로 개발된 모델을 이용하면 아주 빠른 시간 내에 별도의 하드웨어나 소프트웨어 없이 Delta-V를 추정할 수 있다. 하지만 실제 사고에서 탑승자의 상해는 충돌 시 좌좌 자세, 근육의 긴장도, 기존 부상 여부 등에 따라 달라질 수 있다. 따라서 추후 위에 나열된 항목을 포함한 상해수치 데이터를 이용하여 머신러닝 모델을 개선할 필요가 있다. 다만 본 연구에서 Delta-V를 추정하는 모델만으로도 부상위험이 아주 낮거나 높은 조건을 구분할 수 있다. 따라서 오차범위 내에 포함되는 케이스만 분석을 진행할 경우 분석할 케이스의 감소로 더욱 정확한 분석이 진행될 수 있을 뿐만 아니라 불필요하게 발생하는 사회적 비용을 절감할 수 있을 것으로 기대된다.

References

- 1) S. M. Lee, Y. H. Hwang and B. J. Kang, "Trend of Global NCAP Regarding ADAS," KSAE Fall Conference Proceedings, pp.849-854, 2019.
- 2) S. R. Baek, C. H. Kim, Y. W. Kim, J. K. Yoon and J. H. Lim, "A Study on the Development and Verification of Machine Learning Model for Whiplash Injury Analysis," KSAE Spring Conference Proceedings, p.622, 2021.
- 3) H. C. Jo and I. S. Park, "A Study on the Neck Injury in Low Speed Rear Impact through the Real Car Test," The Journal of The Korea Society of Mechanical Technology, Vol.13, No.1, pp.49-56, 2011.
- 4) J. S. Park, J. K. Cho, J. H. Lim and J. K. Yoon, "Effects of Seating Conditions in Low Speed Rear-end Collision on the Neck Injury through MADYMO Analysis," The Journal of The Korea

- Society of Mechanical Technology, Vol.21, No.1, pp.76-84, 2019.
- 5) M. S. Jang, D. U. Son and K. C. Kim, "Correlation Analysis by IIHS Whiplash and IQS Factors," KSAE Fall Conference Proceedings, pp.839-842, 2018.
 - 6) M. J. Kim and I. S. Yun, "Whiplash Injury Conditions of Rear-End Collisions at Low-Speed," The Journal of The Korea Institute of Intelligent Transport Systems, Vol.18, No.2, pp.58-76, 2019.
 - 7) S. J. Kim, W. J. Jeon, W. S. Park, Y. I. Seo and K. Son, "Occupant Neck Injury Assessment Caused by Backward Movement of a Preceding Vehicle at a Low Impact Velocity," Transactions of KSAE, Vol.21, No.3, pp.66-73, 2013.
 - 8) H. C. Jo and Y. E. Kim, "A Biomechanical Anaysis in the Neck Injury according to the Position of Head Restraint during Low Speed Rear-end Impact," Transactions of KSAE, Vol.13, No.1, pp.132-139, 2005.
 - 9) C. M. Kwon, Machine Learning by Python, Wikibooks, Paju, pp.1-6, 2020.
 - 10) Google Limited Liability Company, TensorFlow, <https://www.tensorflow.org/overview>, 2021.
 - 11) C. Albon, Machine Learning with Python Cookbook, Hanbit Media Inc., Seoul, pp.302-304, 2019.
 - 12) AGU Zürich, The Working Group on Accident Mechanics, <http://crashdb.agu.ch/>, 2021.