

## 〈응용논문〉

## 인공 신경망 기반 오버스티어 판단 알고리즘 개발

강성욱<sup>1)</sup> · 김민지<sup>1)</sup> · 이요셉<sup>1)</sup> · 유승한<sup>\*1,2)</sup>한국기술교육대학교 기계공학부<sup>1)</sup> · 한국기술교육대학교 기계공학과 미래융합공학전공<sup>2)</sup>

## Development of Oversteer Prediction Algorithm Based on Artificial Neural Networks

Sungwook Kang<sup>1)</sup> · Minji Kim<sup>1)</sup> · Joseph Lee<sup>1)</sup> · Seung-Han You<sup>\*1,2)</sup><sup>1)</sup>School of Mechanical Engineering, Korea University of Technology and Education, Chungnam 31253, Korea<sup>2)</sup>Future Convergence Engineering, Department of Mechanical Engineering, Korea University of Technology and Education, Chungnam 31253, Korea

(Received 6 April 2023 / Revised 4 May 2023 / Accepted 9 May 2023)

**Abstract** : As the development of control systems used to improve vehicle driving stability becomes more advanced, determining the intervention time of the control logic has become increasingly important. Oversteer is one of the critical factors in determining the lateral stability of a vehicle. Therefore, not only autonomous vehicles, but all vehicles require accurate predictions and judgments for oversteer to ensure driving safety. In this paper, a neural network-based artificial intelligence methodology was used to predict the presence or absence of oversteer. While previous research has been painstakingly conducted with complex judgment conditions and lookup tables, the oversteer decision model based on artificial neural networks of this paper can save time and cost because it can determine whether oversteer occurs without having to consider different individual variables. This model has been validated by using real vehicle experimental data under different driving scenarios.

**Key words** : Artificial neural network(인공 신경망), Unbalanced data(불균형 데이터), Prediction(예측), Oversteer(오버스티어), Experimental validation(실험적 검증)

## 1. 서론

오늘날 운행되는 대부분의 차량에는 주행 안정성 향상을 위한 다양한 능동형 안전장치가 보급되어 있다. 차량의 급제동시 바퀴가 잠기는 현상을 방지하는 ABS(Anti-lock Braking System)를 시작으로, 미끄러운 노면에서 타이어의 Spin을 방지하는 TCS(Traction Control System), 차체 횡 미끄러움을 감지하여 각 바퀴 제/구동을 독립적으로 제어함으로써 운전자가 의도한 대로 차량이 선회하도록 돕는 ESC(Electronic Stability Control)가 그 예이다. 또한, 능동형 운전자 보조 시스템인 ADAS(Advanced Driver Assistance System)의 보급과 운전자의 차량 제어 개입을 줄이기 위한 자율주행 기술 개발이 진행됨에 따라 차량의 주행 안정성은 더욱이 중요해지고 있는 추세이다.<sup>1)</sup>

이러한 이유로, 최근 차량의 횡방향 안정성을 향상시키기 위해 통합 사시 제어에 대한 연구가 다시금 활발하게 진행되고 있다.<sup>2,3)</sup>

하지만, 이러한 능동 제어 시스템의 적절한 개입을 위해서는 운전자의 의도대로 차량이 거동하고 있는지를 판별하여 제어 시점을 결정하는 것이 매우 중요하다. 특히, 차량 선회 중 횡방향 안정성에 대한 정확한 판단은 차량의 안정성 제어의 성능을 결정짓는 중요한 요소 중 하나이다. 수많은 실차 시험 및 파라미터 튜닝에 의해 설정된 기준 요레이트를 이용해 언더스티어와 오버스티어의 경계를 설정하여<sup>4)</sup> 횡방향 안정성을 판단하거나, Fuzzy relational model<sup>5)</sup>이나 Sliding mode observer<sup>6)</sup>를 설계하여 횡방향 안정성을 판단하는 등 차량의 횡방향 안정성 판단에 대한 연구들이 진행되었다. 한편, 최근에는 심층신

\*Corresponding author, E-mail: shyoo@koreatech.ac.kr

<sup>†</sup>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.

경망과 같은 인공지능 방법론을 활용하여 횡 안정성과 연관성이 높은 차량의 횡슬립각 및 롤각을 추정하거나,<sup>7,8)</sup> 차량의 횡 미끄럼 상태를 유지하기 위한 제어를 설계하는 연구<sup>9)</sup>도 발표되었다.

그러나 실제 차량에 적용되고 있는 대부분의 횡방향 안정성 판단 알고리즘은 수많은 룩업테이블과 판단 조건들의 조합을 기반으로 설계된다. 따라서 차종 마다, 혹은 구동형태/헨가시스템사양/판매지역 마다 차별화되는 룩업테이블과 판단 조건에 대한 수많은 파라미터를 테스트 엔지니어가 반복적으로 튜닝해줘야 하는 어려움이 존재한다. 횡방향 안정성을 판단하기 위해서는 오버스티어의 발생 유무에 대한 판단도 특히 중요하다. 즉, 오버스티어 발생 유무를 실시간으로 판단 및 예측하여 안정성 제어 시스템이 적절한 시점에 상황에 적합한 제어량으로 개입을 해야 한다. 하지만, 다양한 선회 상황에서 적절한 시점에 오버스티어를 판단 및 예측하기는 타이어/노면의 불확실성 등으로 인해 여전히 어려운 문제이다.

따라서 본 논문에서는 다양한 노면 조건에서의 실차 주행 데이터를 이용해 오버스티어를 판단, 예측하는 신경망 기반 인공지능 방법론을 제안한다. 실차 주행 데이터는 약 30분 간의 계측 데이터로 100 Hz의 주기로 샘플링 되었으며, 서킷 주행을 포함한 주행 시험장에서의 다양한 선회 시나리오(차선변경, 이중 차선변경, 사인 조향 입력, 스텝 입력, 슬라럼 등)에 대한 계측 결과이다. 속도 범위는 0 ~ 180 kph, 노면 조건은 평지이며 마른 아스팔트, 젖은 아스팔트, 저마찰로가 포함되어 있다.

실차 주행 데이터 내 오버스티어 데이터 비율은 4.42 %이다. 학습에 방해되는 데이터 불균형을 해소하기 위해 오버 샘플링 방식 중 하나인 SMOTE(Synthetic Minority Over-sampling Technique)과 언더 샘플링 방식 중 하나인 Tomek's link 방법을 동시에 활용하였다.<sup>10)</sup>

한편, 본 연구의 궁극적 목표는 차종 및 노면에 관계없이 오버스티어를 예측할 수 있는 모델을 수립하는 것이며, 더 나아가 다음 단계에서는 제어량 또한 예측을 하는 것이다. 이것이 실현된다면 차종마다 ESC 튜닝에 필요한 시간과 비용을 많은 부분 절감할 수 있을 것으로 예상된다.

결과적으로 본 연구에서 학습된 오버스티어 예측 모델은 오버스티어인 경우와 오버스티어가 아닌 경우를 각각 93.3 %, 99.8 %의 정확도로 구분하였다.

본 논문의 구조는 다음과 같다. 2장에서 수집한 데이터의 정보와 모델을 구성하기 위해 사용된 신호, 학습 데이터와 검증 데이터의 구성, 학습 데이터의 표준화에 대해 설명하였다. 3장에서는 데이터의 불균형을 샘플링을 통

해 해결하였다. 4장에서는 ANN(Artificial Neural Network)을 이용해 오버스티어를 예측하는 모델을 개발하고, 저역 통과 필터 기반의 후처리를 통해 예측 성능을 향상시켰다. 5장에서는 실차 데이터 기반 검증을 통해 성능을 확인하였으며 6장 결론을 통해 본 논문을 마무리하였다.

## 2. 데이터 구성

### 2.1 학습 모델 입력 데이터

#### 2.1.1 수집 데이터 정보

독일 B사 준대형 세단의 주행 데이터를 오버스티어 예측 모델의 학습 입력 데이터로 활용하였다. 서로 다른 60개 주행 시나리오의 차량 CAN 데이터를 100 Hz의 샘플링 주기로 수집하였다.

여러 계측 신호 중 차량 횡 동역학에 영향을 미치는 11개의 신호(조향각(Steer), 측정 요레이트(BodyRateZ), 4개의 바퀴 속도(Wh\_RR, Wh\_RL, Wh\_FR, Wh\_FL), 종방향 속도(VelocityForward), 횡방향 가속도(LatAcc), 종방향 가속도(LongAcc), 액셀 포지션 센서값(APS), 엔진 토크(EngTorq))를 우선적으로 학습 데이터로 선정하였다. 오버스티어에 대한 데이터 라벨링은 ESC 시스템의 On/off 신호, 실제 휠 제동 압력, 차량의 횡슬립각 등을 통해 ESC 개발 전문가에 의해 직접 수행되었다.

#### 2.1.2 입력 신호 선정

입력 변수가 많으면 과적합이 발생할 확률이 증가한다. 따라서 과적합 방지 및 예측 모델의 경량화를 위해 입력 변수를 최소화해야 할 필요성이 있다. 두 변수 간 공분산을 각각의 표준편차의 곱으로 나눈 피어슨 상관계수를 사용해 입력 변수 간 선형 상관관계를 Fig. 1과 같이 파악하였다. 입력데이터 중 특징 간 상관관계가 높은

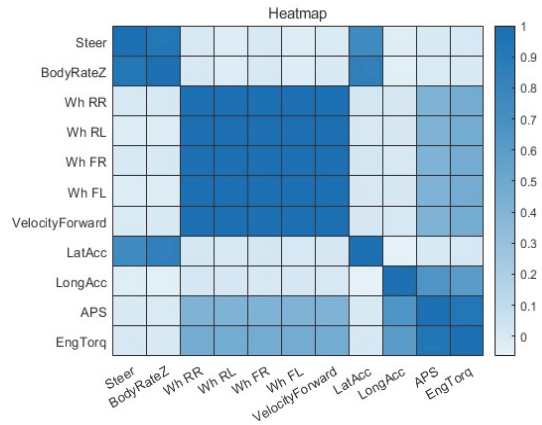


Fig. 1 Pearson correlation coefficient table between features

5개의 신호들(종방향속도, 4개 휠속도) 중 중복이 되는 4개의 휠속도를 학습에서 제외하였다. 또한, 정확한 학습을 위해서 ESC 작동 결과에 직접적인 영향을 받는 신호는 제외가필요한데, ESC 작동이 종방향 가속도에 영향을 주었다고 판단되어 종방향 가속도를 학습에서 제외하였다. 따라서 모델 학습에 사용한 입력 신호는 6개의 신호(조향각, 측정 요레이트, 종방향 속도, 횡방향 속도, 엑셀 포지션 센서값, 엔진 토크)를 선정하였다.

### 2.1.3 입력 신호 추가 생성

수집된 CAN 데이터는 시계열 데이터로 n번째 값이 n-1번째 값과 연관되어 있다. 이에 따라 본 논문에서는 과거 동적인 차량 움직임을 반영하기 위하여 조향각 미분 값, 측정 요레이트 미분 값, 횡방향 속도 미분 값을 새로운 입력 데이터로 추가하였다. 오버스티어 발생 시 추정 요레이트와 측정 요레이트 간 차이를 확인할 수 있다. 이에 따라 추가적인 모델 학습 성능 향상을 위하여 일종의 도메인 지식이라고 할 수 있는 기준 요레이트와 측정 요레이트 차이 값과 기준 요레이트를 입력 데이터로 추가하였다. 사용된 기준 요레이트는 실측 조향각, 종방향 속도, 요레이트 관계를 통해 경험적 방법(정상상태 바이시클 모델 기반)으로 개발되었다. 기준 요레이트의 입력 사용은 사용하지 않았을 경우 대비 분류 정확도(Accuracy)기준 약 10%의 개선도가 있었으며 예측을 위한 신경망의 규모로 대폭 감소시키는 효과도 있었다.

결과적으로, 본 논문 모델의 입력 데이터로는 조향각, 측정 요레이트, 종방향 속도, 횡방향 속도, 엑셀 포지션 센서값, 엔진 토크, 조향각 미분 값, 측정 요레이트 미분 값, 횡방향 속도 미분 값, 기준 요레이트와 측정 요레이트 차이 값, 기준 요레이트 중 11개의 신호와 오버스티어 레이블을 선정하였다.

### 2.2 학습 데이터와 검증 데이터

100 Hz로 샘플링된 시계열 학습데이터는 Random shuffle 방식으로 데이터를 학습데이터와 검증데이터로 나눌 시 특정 시나리오 내 n번째 데이터와 n-1번째 데이터가 각각 학습데이터와 검증데이터로 나눌 가능성이 있다. n번째 데이터와 n-1번째 데이터는 비슷한 수치를 가진다. n번째 데이터와 n-1번째 데이터가 각각 학습데이터와 검증데이터로 나눌 시 모델 학습을 한 후 학습데이터로 성능 평가를 하는 것과 동일하다. 본 논문에서는 이러한 문제를 해결하기 위해 60개 시나리오 데이터 셋 중 특정 선회 시나리오 5개 데이터셋을 검증 데이터로 선정하였다.

### 2.3 데이터 표준화

출력 신호를 제외한 11개 입력 신호는 서로 다른 데이터 분포를 나타낸다. 모델 학습을 위하여 11개 신호를 서로 비슷한 데이터 분포로 변형할 필요가 있다. 오버스티어 발생시, 차량 거동에 급격한 변화가 생겨 특정 신호들이 최댓값과 최솟값을 가진다. 이 최대, 최소값은 오버스티어 판단의 중요한 특징이다. 따라서 각 신호의 최댓값, 최솟값은 이상치로 제거할 요소가 아니라 오버스티어 판단에 있어 중요한 요소이다. 각 신호 데이터 분포를 서로 일정하게 하며 최댓값, 최솟값 특징을 유지하기 위해 본 논문에서는 11개 신호들의 평균과 분산을 각각 0과 1로 설정해 표준화하였다.

## 3. 불균형 데이터의 처리

수집된 계측 데이터는 100 Hz로 샘플링된 약 30분간의 주행 데이터로 전체 데이터 중 오버스티어로 라벨링된 비율은 약 4.4%이다. 이러한, 불균형 데이터 학습 시 데이터 개수가 많은 오버스티어가 아닌 뉴트럴스티어(Neutral steer)가 오버스티어보다 많이 학습되어 모델은 편향된 분류를 할 가능성이 높다. 편향 분류 문제를 해결하기 위하여 불균형 데이터 기법 중 가장 성능이 우수한 SMOTE 방법 및 Tomek 방법을 사용했다.<sup>9)</sup> 이 때 샘플링의 비율에 따라 학습 모델의 Specificity과 Recall 값이 달라진다. 모델이 Negative라고 예측하는 횟수가 많아지는 편향 분류가 일어날 경우 Specificity 값이 상승하고 Recall 값이 하강하게 된다. 이러한 Specificity과 Recall의 Trade-off 관계 속에서 Specificity값과 Recall 값이 가장 비슷하게 나오도록 뉴트럴스티어와 오버스티어의 학습 데이터 비율을 15:2로 샘플링을 진행하였다.

## 4. 오버스티어 예측 모델

### 4.1 예측 모델 설계

본 논문에서 오버스티어 예측을 위해 설계된 ANN(Artificial Neural Network) 모델은 Table 1과 같이 차량 MCU의 연산능력을 고려하여 노드 256개의 단일 층으로 구성하였다.

Table 1 ANN model structure

Layer name	Output shape	Parameters
	Input (1 x 11)	
Dense	(1 x 256)	3072
Dropout	(1 x 256)	0
Output	(1 x 1)	257




Fig. 2 Output of ANN model for low-mu 70 kph slalom




Fig. 3 Oversteer prediction result of original ANN model for low-mu 70 kph slalom

입력층은 오버스티어 라벨을 제외한 11개의 신호(조향각, 측정 요레이트, 종방향 속도, 횡방향 가속도, 엑셀 포지션 센서 값, 엔진 토크, 조향각 미분 값, 횡방향 속도 미분 값, 횡방향 가속도 미분 값, 측정 요레이트, 기준 요레이트와 측정 요레이트 차이 값)를 입력한다. 은닉층의 노드 수는 시행착오 방식으로 결정하였다. Fig. 2와 같이 모델의 최종 출력은 시그모이드 연산을 통해 0 ~ 1사이의 값이 출력된다.

#### 4.2 모델 출력 후처리

본 연구에서는 학습된 ANN 모델의 최종 출력 값의 후처리를 통해 예측 정확도를 개선하였다. 후처리에는 적절한 판단의 기준값 설정과 잦은 예측 변동을 감소시키기 위한 저역 통과 필터를 통한 출력 값 변동 둔감화가 포함된다.

우선 후처리 전의 모델 출력과 최종 예측 결과인 Figs. 2, 3 대비 후처리가 적용된 후의 모델 출력과 최종 예측 결과인 Figs. 4, 5에서 보다 오버스티어를 효과적으로 예측하고 있음을 확인할 수 있다.

기존 예측 결과인 Fig. 3을 보면 오버스티어인 경우와 아닌 경우가 짧은 시간에 반복적으로 나타난다. 그러나 차량의 오버스티어는 이렇게 짧은 시간동안 거동이 반복적으로 변하지 않는다. 따라서 측면의 고려를 위해서 모델 출력 값에 저역 통과 필터를 적용하여 빈번한 예측 값의 변화를 최소화하였다(Fig. 5). 최종적으로 필터링된 출력 값이 0.4보다 큰 경우를 오버스티어로 판단하였다. 이러한 모델 출력의 후처리를 통해 오버스티어에 대한 예측 정확도인 Recall를 약 2% 가량 개선할 수 있었다.




Fig. 4 Filtered Output of ANN model for low-mu 70 kph slalom




Fig. 5 Oversteer prediction result of proposed ANN model for low-mu 70 kph slalom



### 5. 실차 주행 데이터 기반 모델 검증

#### 5.1 모델 검증 시나리오

다양한 상황에서 모델의 예측 정확도를 평가하기 위해 Table 2와 같이 5종류의 선회 시나리오를 각기 다른 속도, 노면 조건에서 주행한 데이터들로 학습에 사용되지 않은 검증데이터를 구성하였다. 검증데이터 총 샘플 수는 약 90초 데이터에 해당하는 9,069개이다. 9,069개의 데이터 중 오버스티어 데이터는 597개, 뉴트럴스티어 데이터는 8,472개이다.

Table 2 Driving scenarios for experimental verification

Scenario No.	Maneuver	Speed (kph)	Peak $\mu$	Yaw rate (deg/sec)
1	Double lane change	150	0.9	-18 ~ 18
2	Sine	125	0.9	-28 ~ 26
3	Sine	125	0.9	-28 ~ 28
4	Slalom	50	0.3	-10 ~ 12
5	Slalom	70	0.4	-10 ~ 5

#### 5.2 모델 예측 성능 검증

본 연구에서 제안된 오버스티어 예측 모델의 예측 결과를 Table 3과 같이 혼동행렬(Confusion matrix)로 나타내었다. 한편, 최대 마찰계수가 0.9인 노면에서 이중차선 변경 상황인 시나리오1에서의 예측 결과를 Fig. 6에, 노면 마찰계수가 낮은 노면에서 70 kph 슬라럼 조항(시나리오5)에 대한 예측 결과를 Fig. 7에 각각 나타냈다. Table 3의 혼동행렬(Confusion matrix)에서 뉴트럴스티어에 대한 예측 정확도인 Specificity, 오버스티어에 대한 예측 정확도 Recall은 각각 99.8%, 93.3%로 측정된다. 실제 ESC 개발 시 미제어보다 불필요한 제어가 더 소비자 클레임이 많은데 이러한 관점에서 Recall 보다 Specificity에 중점을 뒤 설계한 측면이 존재한다.

전체적으로 보면, 노면 마찰계수에는 큰 영향이 없이 오버스티어를 비교적 정확히 예측하는 것을 확인할 수 있었다. 다만, 다소간의 실제 라벨보다 오버스티어를 일찍 감지하거나 지연 감지하는 부분이 관찰되었으며 이 부분을 Table 4에 시나리오 별로 평균 지연시간을 나타

Table 3 Confusion matrix representing model prediction performance

		Truth	
		Neutral steer	Oversteer
Model result	Neutral steer	8456	40
	Oversteer	16	557

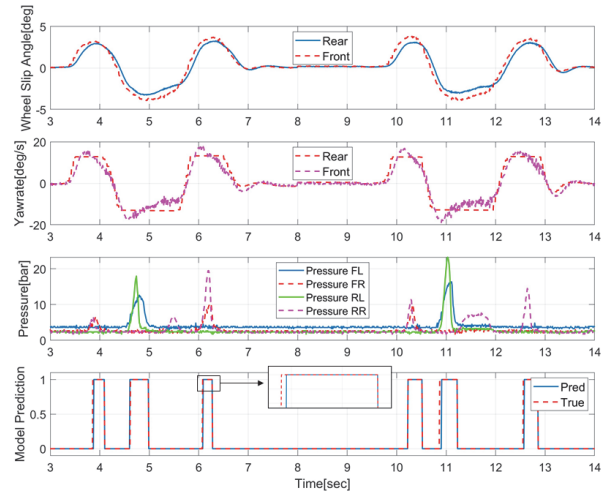


Fig. 6 Model prediction results for high-mu double lane changes




Fig. 7 Model prediction results for low-mu 70 kph slalom

Table 4 Time delay of oversteer prediction for driving scenarios

Scenario No. (No. of oversteers)	Average time delay(sec)	
	At starting points	At ending points
1 (6)	0.013	0
2 (1)	-0.04	0
3 (1)	-0.01	0
4 (1)	0.11	-0.02
5 (2)	0.055	-0.015




Fig. 8 Model prediction results for ESC off experimental data

났다. 양수는 지연 예측을, 음수는 이른 예측을 의미하며 최대 100 ms, 평균적으로는 대부분 수십 ms 정도의 예측 시간 오차를 나타냈다. 실제 라벨에 해당하는 ESC의 제어 Flag도 여러 오차 기준에 대한 Threshold 조합 개념이기 때문에 이 정도의 예측 오차는 어느 정도 예상 가능한 측면도 있다.

한편, 본 연구에서 제안된 ANN 모델은 ESC가 실제로 작동 중인 차량의 운전 데이터를 이용하여 학습하였다. 따라서, 학습된 모델이 실제 액추에이팅된 제동압에 즉각적인 영향을 받는 휠속도와 같은 신호를 입력에서 배제했음에도 불구하고 전반적인 차량의 거동에 근거한 오버스티어 예측이 아니고 직접적인 엔진과 제동 제어 결과에 근거해서 예측할 수 있다는 의심을 가질 수 있다. 이에 대한 검증을 위해 30개의 ESC off 시험 데이터로 추가적인 테스트를 진행하였다. 여기서 ESC off는 실제 차량에서 ESC 스위치를 Off하여 실제 ESC 제어 동작이 일어나지 않게 설정하고 계측한 데이터로, 라벨에 해당하는 ESC 동작 Flag 신호가 존재하지 않는다. 따라서, 대안적인 방법으로 참값을 요레이트 오차(계측치, 모델값 차이), 횡슬립각 정보를 활용하여 유추하였으며 이를 Fig. 8에 나타냈다. 참고로 오버스티어 시작 시점과, 종료 시점에서의 평균 지연 예측시간은 각각 0.02, 0.06초로 나타났다. 이를 통해 제안 오버스티어 예측 모델은 전반적인 차량 거동 정보로 오버스티어를 적절히 예측하고 있음을 확인할 수 있었다.

## 6. 결론

본 논문에서는 인공지능 기반 인공지능 방법론을 이용한 오버스티어 판단 모델을 제안했다. 본 모델은 차

량 CAN 데이터를 포함한 총 11개 시그널을 입력으로 하여 실제 차량 주행 데이터를 기반으로 학습되었으며 추가적인 출력 신호의 후처리를 통해 오버스티어 예측 성능을 향상시켰다. 모델의 성능을 검증하기 위해 학습에 사용되지 않은 주행 데이터를 활용해 테스트하였고, 그 결과 비교적 정확한 오버스티어 예측이 가능함을 확인하였다. 실제로 차량 제어에서 횡방향 안정성 판단하기 위해서는 타이어나 노면 등의 불확실성과 다양한 차량 파라미터들을 고려해야 하며 대부분의 경우 개발 엔지니어의 수고스러운 튜닝과정이 필요하다. 하지만 본 논문에서 제안한 모델은 이러한 부분을 경험적 튜닝에 의존하지 않아도 되기 때문에 개발 시간과 비용의 절감을 기대할 수 있다. 본 논문에서 제안된 오버스티어 발생 유무 예측 모델은 학습에 활용된 하나의 차종에만 적합할 수 있다. 따라서 향후 차종에 관계없이 오버스티어 발생 유무를 예측할 수 있는 하나의 모델을 개발하는 것이 목표이다. 나아가 오버스티어 발생 유무를 예측하는 것뿐만 아니라 제어시스템의 적절한 제어량을 예측하는 연구를 진행할 예정이다.

## 후 기

본 과제(결과물)는 2023년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과임(2021RIS-004). 이 논문은 2023학년도 한국기술교육대학교 교육연구진흥과제 지원에 의하여 연구되었음.

## References

- 1) W. K. Cho and S. H. You, "Development of Integrated Chassis Control to Improve Lateral Vehicle Stability," Transactions of KSAE, Vol.27, No.8, pp.619-626, 2019.
- 2) J. H. Song, "Design of Integrated Dynamics Control System to Enhance Lateral Stability of SUV," Transactions of KSAE, Vol.29, No.8, pp.781-787, 2021.
- 3) D. H. Kim, T. Y. Chung, S. W. Oh, S. G. Ko and T. J. Yeo, "Handling Control of ESC-MDPS Integrated Control System," KSAE Annual Conference Proceedings, pp.1222-1227, 2009.
- 4) K. J. Ann, E. H. Joa, Y. I. Koh, K. S. Yi and K. M. Sohn, "An Investigation of the Lateral Stability Criteria for Integrated Chassis Control," Journal of Auto-Vehicle Safety Association, Vol.9, No.2, pp.26-32, 2017.
- 5) P. Amann, J. M. Perronne, G. L. Gissinger and P. M.

- Frank, "Identification of Fuzzy Relational Models for Fault Detection," Control Engineering Practice, Vol.9, No.5, pp.555-562, 2001.
- 6) C. Edwards, R. G. Hebden and S. K. Spurgeon, "Sliding Mode Observers for Vehicle Mode Detection, Vehicle System Dynamics," International Journal of Vehicle Mechanics and Mobility, Vol.43, No.11, pp.823-843, 2005.
- 7) Z. Ding, S. Zhao, M. Wei and G. Jia, "Estimation Method of Vehicle Centroid Sideslip Angle Based on DNN-EKF Fusion," 2018 International Computers, Signals and Systems Conference (ICOMSSC), pp. 692-695, 2018.
- 8) L. P. González, S. S. Sánchez, J. Garcia-Guzman, M. J. L. Boada and B. L. Boada, "Simultaneous Estimation of Vehicle Roll and Sideslip Angles through a Deep Learning Approach," Sensors, Vol.20, No.13, Paper No.3679, 2020.
- 9) T. Lee, D. Seo, J. Lee and Y. Kang, "Real-time Drift-driving Control for an Autonomous Vehicle: Learning from Nonlinear Model Predictive Control Via a Deep Neural Network," Electronics, Vol.11, No.17, Paper No.2651, 2022.
- 10) K. Lee, J. Lim, K. Bok and J. Yoo, "Handling Method of Imbalance Data for Machine Learning: Focused on Sampling," The Journal of the Korea Contents Association, Vol.19, No.11, pp.567-577, 2019.