

# 차량 횡방향 속도 추정을 위한 연구

## Study on Vehicle Lateral Velocity Estimation

황 규 용\* · 성 민 상\*\* · 한 철 희\*\* · 오 종 석†  
Gyu Yong Hwang\*, Min-sang Seong\*\*, Chul-hee Han\*\* and Jong Seok Oh†

(Received July 10, 2023 ; Revised July 20, 2023 ; Accepted August 17, 2023)

**Key Words :** Velocity Estimation(속도 추정), Long Short-term Memory(LSTM 장단기 메모리), Kalman Filter (칼만필터), Hybrid Estimator(하이브리드 추정기), Vehicle State Estimation(차량 상태추정)

### ABSTRACT

This study focuses on the estimation of lateral velocity in vehicles. As the demand for advanced vehicle control systems increases, accurately estimating the longitudinal and lateral velocities of a vehicle is crucial for enhancing safety and performance. However, it is challenging to estimate these velocities using conventional model-based estimators. In this study, a state estimator that combines a model-based estimator and a lateral estimation module, which can be applied to both existing and future vehicles, is proposed. The proposed approach employs a hybrid estimation logic that integrates wheel speed sensors and an inertial measurement unit sensor to estimate longitudinal velocity and then utilizes the estimated longitudinal velocity to estimate the lateral velocity. The performance of the estimation algorithm is evaluated by considering various road conditions. The results demonstrate the effectiveness and accuracy of the proposed method in estimating the state variables of the vehicle.

### 1. 서 론

최근 차량에 대한 관심은 단순히 고급화와 성능 향상에 그치지 않고 승객의 안전을 최우선으로 생각하는 방향으로 나아감에 따라 소비자들은 점차 승차감과 조종 안정성에 관심을 가지는 추세이다. 차량 안정성 제어 시스템을 사용하여 승차감, 조향성, 가속 성능을 향상시키기 위해 차량의 종방향 및 횡방향 속도를 아는 것이 중요하다. 종방향 속도는 직접 측정이 가능한 센서가 있으나, 횡방향 속도는 센서를 추

가 장착해야 하는 경제적인 소요가 있다. 따라서 일반적으로 장착된 센서들과 추정기를 사용하여 횡방향 속도를 추정하며, 이를 위한 다양한 여러 연구가 진행되고 있다<sup>(1)</sup>.

이러한 속도 추정을 위해 전통적으로 많이 사용하던 모델 기반 추정<sup>(2)</sup> 차량 근사모델을 사용하기에 실제 값과 주행 상황에 따라 상당한 오차가 발생하며, 타이어의 비선형성으로 인해 슬립 각이 커지는 경우 오차가 발생하게 되어 추정이 어렵다<sup>(3)</sup>. 또한 기존 횡방향 속도 추정 논문들은 저속과 고속에서 변화하는 차체 슬립각 방향과 저속 환경에서의 다양한 가정으

† Corresponding Author ; Member, Department of Future Convergence Engineering, Kongju National University, Professor  
E-mail : Jongseok@kongju.ac.kr

\* Department of Future Convergence Engineering, Kongju National University, Student

\*\* Institute of Advanced Chassis Development Team, Hyundai Motor Company

# A part of this paper was presented at the KSNVE 2023 Annual Spring Conference

‡ Recommended by Editor Hyuk Lee

© The Korean Society for Noise and Vibration Engineering

로 인해 특정 속도에서의 추정을 목표로 하며, 전역 속도 구간을 고려하지 못하는 한계가 있다. 이러한 오차 요인들을 보상하고자 차량 동역학 기반 추정기 관련 연구들이 진행됐으며 최근에는 인공지능 기법을 이용하여 추정기 및 제어기 설계 연구들이 수행되고 있다<sup>(4,5)</sup>. 센서 데이터의 인공지능 추정기법은 1-D CNN (convolution neural network)과 LSTM (long short-term memory)이 주로 사용된다. 1-D CNN은 합성곱을 이용하여 시계열 분석이나 텍스트 분석에서 좋은 성능을 보여주는데, 데이터 세트의 차원에 크게 의존하고 고정된 길이의 데이터를 사용해야 한다는 한계가 있다<sup>(6)</sup>. LSTM은 시계열 데이터나 긴 의존 관계를 가진 데이터에 특화된 알고리즘이며 RNN(recurrent neural network)의 한 종류이다. 셀, 입력 게이트, 출력 게이트, 망각 게이트를 이용해 기존 RNN의 기울기 소실 문제를 방지하도록 개발되었다. LSTM은 시퀀스 데이터의 패턴을 학습하는 데 용이하며, 이전 예측 결과를 피드백으로 활용하여 한 번에 한 지점씩 처리한다. 따라서 입력 시퀀스 데이터의 길이에 제한이 없으며, 추정 대상과 학습 데이터 간의 연관성이 있는 경우에 유용하게 사용된다. 이에 이 연구에서는 횡방향 속도와 종방향 속도 사이의 연관성을 이용하여 LSTM을 통한 학습을 수행하였다.

이 연구는 기존 추정 방법의 한계를 극복하고 일반 차량과 다양한 모빌리티에 적용이 가능한 새로운 접근 방식을 제안한다. 제안된 방법은 상대적으로 추정이 어려운 횡방향 속도를 추정하기 위해 하이브리드 추정기를 설계하였다. 이 방법은 모델 기반 종방향 속도 추정기의 추정값을 인공지능 기반 횡방향 속도 추정기의 입력으로 활용하는 방법이다. 휠 스피드 센서와 관성 측정 장치로부터 얻은 정보를 종합하여 종방향 및 횡방향 속도를 추정한다. 제안된 추정기는 Simulink&CarMaker 환경에서 데이터 획득 및 성능평가를 진행하였다. CarMaker와 같은 시뮬레이터는 실제 실험 결과와 매우 유사한 결과를 얻을 수 있기에 많은 연구<sup>(5,7,8)</sup>에서 성능 확인을 위해 사용하며 비용 절감 및 안전에 이점이 있다.

이 논문의 나머지 부분은 다음과 같이 구성되어 있다. 2장에서는 데이터 분석과 제안된 속도 추정기의 추정 과정, 3장에서는 추정기의 성능분석을 하였으며 마지막으로 4장에서는 결론을 요약한다.

## 2. 데이터 분석

이 연구에서는 모빌리티 차량에 대해서 획득 가능한 IMU 센서와 휠 스피드 센서를 사용하여 종 및 횡방향 속도 추정하고 알고리즘의 성능평가를 수행하였다. 학습과 테스트를 위해 사용된 차량 데이터는 CarMaker를 통해 획득하였으며 Table 1에 나타내었다. 가상 주행 시뮬레이션을 위해 Table 2에 기재된 CarMaker 기본 차량인 IPG company car 차량 제원으로 사용하였다.  $m$ 은 공차중량,  $I_z$ 는 관성 모멘트,  $l_f$ 와  $l_r$ 은 무게중심으로부터 앞 차축, 뒷 차축까지의 거리를 말한다. 학습 데이터로 7가지 다른 주행속도에서 센서값을 획득하였고, 다른 속도에서는 시퀀스 길이가 다르며, 동일 속도에서는 훈련, 테스트, 검증 데이터의 길이가 같다.

이 논문은 기존 상태 추정 방법의 한계를 극복하기 위해 모델 기반 추정기인 칼만필터와 데이터 기반 추정기인 LSTM 추정기를 통합한 하이브리드 추정기를 설계하였다. 직접적인 측정(휠 스피드 센서)이 가능한 종방향 속도는 칼만 필터를 통해 추정하며, 이를 상대적으로 추정이 어려운 횡방향 속도의 추정기 학습 데이터로 활용하였다. 제안하는 하이브리드 추정기의 흐름도를 Fig. 1에 나타내었다.

### 2.1 모델기반 종방향 속도 추정기

이 연구에서는 종방향 속도 추정을 위한 칼만필

Table 1 CarMaker sensor

Sensor type	Obtainable values
Wheel speed sensor	Wheel angular velocity [rad/s]
IMU sensor	<b>Accelerometer</b> Acceleration in X, Y, Z-axis [m/s <sup>2</sup> ] <b>Gyroscope</b> Rotational velocity in X, Y, Z-axis [rad/s]

Table 2 Vehicle parameters

Parameter	$m$ [kg]	$I_z$ [kgm <sup>2</sup> ]	$l_f$ [m]	$l_r$ [m]
Value	1600.10	2393.840	1.311	-1.311




Fig. 1 Flowchart of proposed hybrid estimator

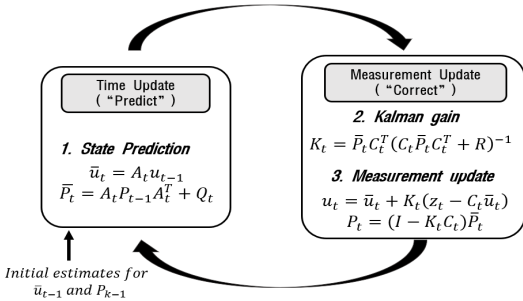


Fig. 2 Concept of Kalman filter




Fig. 3 Flowchart of longitudinal velocity estimator

터 기반의 센서 퓨전 추정기를 설계하였다. 칼만필터는 잡음이 포함되어있는 역학적 상태를 추정하는 재귀 필터이며, 시스템방정식을 정확히 알고 있다면, 높은 신뢰성과 재현성을 보여준다고 알려져 있다<sup>(9)</sup>. 또한, 시스템 동작에 대해 모델링 한 수식을 사용하기에 다양한 환경에서 사용할 수 있다. 이러한 이유로 칼만필터를 이용하여 다양한 속도, 주행 상황에서 종방향 속도를 예측하는 종방향 속도 추정기를 칼만필터를 통해 설계하였다. 칼만필터는 Fig. 2와 같이 세 단계로 구성되어 있으며, 두 번째 단계에서는 칼만 계인을 계산하여 슬립이나 잠김이 발생했을 때 휠 스피드 센서와 IMU 센서의 신

뢰도를 결정한다. 슬립이나 잠김이 발생하면 휠 스피드 센서와의 오차가 커지므로, IMU 센서를 사용한 슬립 판단 로직을 추가하여 슬립이 자주 발생하는 급출발, 급제동에서 추정 오차가 증가하지 않게 하였다.

설계된 종방향 속도 추정기를 Fig. 3에 나타내었다. 휠 스피드 센서의 회전속도( $\omega_t$ )와 IMU 센서의 종방향 가속도( $a_{x,s}$ )를 입력으로 사용한다. 휠 스피드 센서로부터 받은 회전속도는 타이어 모델을 사용하여 선속도( $v_{x,w}$ )로 변환된다. 또한 IMU 센서에서 획득할 수 있는 종방향 가속도 값( $a_{x,s}$ )은 노이즈 제거 후에 슬립 판단 로직의 입력으로 들어간다. 슬립 판단 로직은 휠 속도의 변화량, 추정 오차 및 가속도의 크기를 고려하여 슬립이나 잠김을 판단하고, 칼만필터 로직에서 사용된다. 칼만필터는 판단 로직의 결과와 센서값들을 사용하여 슬립이나 잠김이 없을 때는 휠 속도 값을 기반으로 추정하고, 슬립이나 잠김으로 판단되면 칼만 이득 값을 감소시켜 IMU 센서의 종방향 가속도 값을 사용하여 최종 종방향 속도를 계산한다. 칼만필터의 시스템 모델은 A, B, H, Q, R 행렬로 나타낼 수 있으며, A, B는 상태전이 행렬로 시스템의 운동 방정식을 포함한 행렬이다. H는 실제 측정값과 시스템 상태 간의 관계를 나타내는 행렬이다. Q와 R은 시스템, 측정 노이즈를 나타내는 공분산 행렬이며 잡음이나 불확실성을 나타내는 행렬이다. 식 (1)에 시스템 및 측정 방정식과 공분산 행렬을 나타내었다.

$$x_{k+1} = A \cdot x_k + B \cdot u_k + w_k$$

$$z_k = H \cdot x_k + v_k \tag{1}$$

여기서  $x_k$ 는 추정 대상인 종방향 속도이며  $u_k$ 는 종방향 가속도 값,  $z_k$ 는 4바퀴 휠 속도 값이다. 자세한 시스템 모델의 행렬을 식 (2)에 나타내었다.

$$\begin{aligned} A &= [1] \\ B &= \tau(\text{sampling time}) \\ H &= [1111]^T \\ Q &= 100 \\ R &= \begin{bmatrix} 500 & 0 & 0 & 0 \\ 0 & 500 & 0 & 0 \\ 0 & 0 & 500 & 0 \\ 0 & 0 & 0 & 500 \end{bmatrix} \end{aligned} \tag{2}$$

### 2.2 하이브리드 횡방향 속도 추정기

이 연구에서는 횡방향 속도 추정을 위한 LSTM 기반의 하이브리드 추정기를 설계하였다. Fig. 4에 LSTM의 구조를 나타내었으며, 아래의 단계를 거쳐 계산하게 된다. 식 (3)과 같이 첫 번째 단계로 시그모이드 함수를 사용하여 어떤 정보를 삭제할지를 결정한다.

$$f_t = \text{sigmoid}(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{3}$$

시그모이드 함수는 실수 전체를 정의역으로 가지면서 함수 값으로는 0부터 1까지를 반환하므로 정보를 잊거나 기억하기 위한 비선형 함수이다. 여기서  $W_f$ 와  $b_f$ 는 Cell state  $c_{t-1}$ 에 0, 1을 출력하기 위한  $f_t$ 의 가중치이며, 0은 완전히 잊음, 1은 완전히 기억함을 의미한다.

두 번째 단계는 입력값과 이전 단계의 출력 값을 곱해줌으로써 입력 값의 일정 부분만 받아들여 셀 스테이트에 전해준다. 식 (4)~ 식 (6)과 같이 시그모이드 함수와 하이퍼볼릭 탄젠트(tanh) 함수를 사용하여 셀 스테이트에 새로운 정보를 저장할지를 결정하는 두 부분과 업데이트하는 부분으로 나뉘어 있다.

$$i_t = \text{sigmoid}(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{4}$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{5}$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \tag{6}$$

세 번째 단계에서는 식 (7)의 마지막 시그모이드 함수와 식 (8)의 마지막 하이퍼볼릭 탄젠트 셀스테이트 출력값과 곱하여 최종 출력을 도출한다.

$$o_t = \text{sigmoid}(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{7}$$

$$h_t = o_t * \tanh(c_t) \tag{8}$$

LSTM의 가중치 갱신은 역전파(back propagation)를 통해 갱신되며 오차를 줄이는 방향으로 진행된다. LSTM의 입력인  $x_t$ 에는 학습 데이터가 들어가게 되며 이를 LSTM의 특성 및 식 (9)와 식 (10)의 차량 동역학 기반 수식을 고려하여 IMU 센서의 요레이트 값( $\dot{\psi}$ ), 횡방향 가속도 값 그리고 추정 종방향 속도( $v$ )로 선




Fig. 4 Concept of LSTM network

정하였다. 동역학 수식과 LSTM 역전파의 자세한 내용은 참고논문들(7,10) 참고하길 바란다.

$$m \cdot v \cdot (\dot{\psi} + \dot{\beta}) = C_f(\delta_f - \beta - \frac{l_f \dot{\psi}}{v}) + C_r(\delta_r - \beta + \frac{l_r \dot{\psi}}{v}) \tag{9}$$

$$\Theta \ddot{\psi} = C_f(\delta_f - \beta - \frac{l_f \dot{\psi}}{v})l_f + C_r(\delta_r - \beta + \frac{l_r \dot{\psi}}{v})l_r \tag{10}$$

LSTM 기반의 횡방향 속도 추정기는 다양한 센서 입력과 추정된 종방향 속도를 이용해서 횡방향 속도 하나만 추정하는 MISO(multi input single output) 방식과 다양한 센서 값을 이용해서 종/횡방향 속도를 추정하는 MIMO(multi input multi output) 방식으로 구현할 수 있다. 두 방법의 성능은 거의 비슷하지만 MIMO 방식의 경우 데이터의 학습해야 할 패턴이 많아지기에 MIMO에서 훈련 및 테스트에 드는 시간이 늘어나며(11) 필요한 연산자원이 늘어나기에 시스템 부하가 커진다고 알려져 있다(12). 상기의 이유로 계산이 빠르고 정확도가 높은 칼만필터를 사용하여 종방향 속도를 추정하고 추정된 종방향 속도를 받아 LSTM이 횡방향 속도를 추정하도록 하는 MISO로 하이브리드 네트워크를 설계하였다.

설계한 LSTM 네트워크의 구조를 Fig. 5에 나타내었으며 획득한 센서값과 추정 종방향 속도가 LSTM 알고리즘의 학습 데이터로 사용되게 된다. 학습하지 않았던 속도에 대한 성능을 높이기 위해 네트워크의 강건성을 높이는 방법의(13) 하나인 dropout layer를 추가하여 학습하지 않았던 속도 조건에서도 성능을 확인하였다. 사용된 하이퍼 파라미터는 총 5개이며 최




Fig. 5 Flowchart of lateral velocity estimator

Table 3 Information of hyper-parameter

Hyper-parameter	Selected value	Range
Max epoch	17 000	5000 ~ 50 000
Mini-batch size	1	0 ~ 200
Learning rate	0.01	0 ~ 1
Activation function	Softmax	
Solver	Adam	

적화 작업은 random search 방법을 통해 선정하였다. random search 방법은 실험과 이론을 통해 하이퍼 파라미터의 범위를 지정한 후, 그 범위 내에서 임의로 값을 선택하여 최상의 결과를 도출하는 하이퍼 파라미터를 결정하는 최적화 방법이다<sup>(14)</sup>. 적용한 하이퍼 파라미터의 범위와 최적화된 값은 Table 3에 도시하였다.

### 3. 속도 추정 결과 및 분석

#### 3.1 모델기반 종방향 속도 추정기

종방향 속도 추정기는 비교를 위해 비 구동륜 평균 속도를 사용하였다. 비 구동륜은 구동륜에 비해 슬립이 작아 실제 속도와 유사하여 ABS (anti-lock braking system) 같은 시스템에서 비 구동륜의 속도를 실제 주행속도로 가정한다. 따라서 비 구동륜을 현 방식의 속도 추정 방법으로 가정하고 설계한 추정기와 비교하였다. Table 4에 주행 조건별 각 속도에서의 CarMaker에서 획득한 실제 종방향 속도와 RMSE (root mean square error) 값을 도출하였다. 수식은 식 (7)에 나타내었고 데이터 간의 예측값과 실제값의 차이를 나타내는 평가지표이다. Fig. 6에 일부 추정 결과인 시속 130 km/h에서 제동시점 그래프를 나타내었다.

$$RMSE = \sqrt{\frac{1}{m} \sum (x_{estimated\ value} - x_{actual\ value})^2} \quad (7)$$

Table 4 RMSE results of longitudinal velocity

Road condition	Velocity [km/h]	Non-driven wheel [RMSE]	Estimator [RMSE]
Lane change test	30	0.0114	0.0040
	80	0.0310	0.0136
	130	0.0508	0.0509
Slalom	30	0.0107	0.0037
	80	0.0307	0.0132
	130	0.1515	0.1760
Full braking	30	0.0179	0.0055
	80	0.0762	0.0160
	130	0.1608	0.0312
Average		0.0623	0.0349

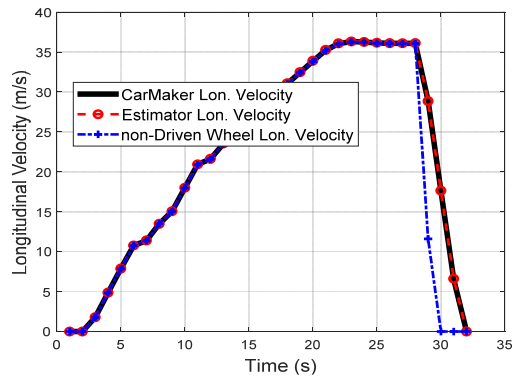
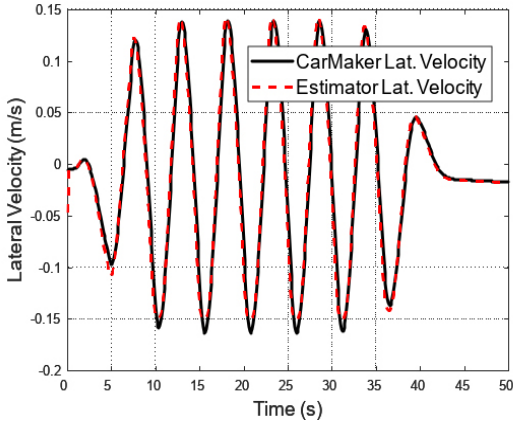


Fig. 6 Result of estimated longitudinal velocity

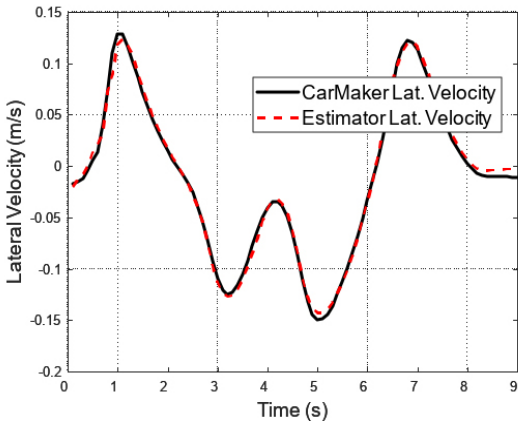
여기서  $m$ 은 데이터의 개수,  $x_{estimated\ value}$ 는 추정값,  $x_{actual\ value}$ 는 실제값을 나타낸다. Table 4에 나타난 것과 같이 종방향 속도 추정기의 추정값과 비 구동륜 평균 속도의 RMSE 값 비교를 통해 바퀴의 슬립이 많이 발생하는 급제동 시험에서 고속으로 갈수록 설계한 추정기의 오차가 비 구동륜 평균 속도보다 성능이 좋은 것을 확인하였다. 설계한 센서 퓨전 종방향 추정기의 평균 RMSE 값은 0.0349, 비 구동륜 평균 속도의 RMSE는 0.0623으로 도출되어 설계한 종방향 속도 추정기의 우수한 성능을 확인하였다.

#### 3.2 하이브리드 횡방향 속도 추정기

횡방향 속도는 CarMaker에서 획득한 실제 횡방향 속도와 횡방향 속도 추정기의 추정값을 비교하였으



(a) 50 km/h & slalom



(b) 50 km/h & lane change test

Fig. 7 Result of estimated lateral velocity

며, 기존 연구 결과와<sup>(5,7,8)</sup> 비교분석을 통해 설계한 추정기의 성능을 확인하였다. Fig. 7에 추정 결과의 일부를 나타내었다. LSTM이 학습한 차선변경시험과 학습하지 못한 도로인 슬라럼 주행에서 속도별 하이브리드 추정기의 결과를 Table 5에 도시하였다. 성능평가를 진행한 모든 속도에서 낮은 RMSE 값을 확인하였다. 또한 횡방향 속도 추정기는 고속으로 갈수록 RMSE 값이 커지는 경향을 보였으며 Table 6에 나타난 것처럼 같은 기동 조건인 이전 연구들의<sup>(5,7,8)</sup> 평균 RMSE 값에서 하이브리드 추정기가 개선된 결과를 보이는 것을 확인하였으나 고속 구간에서 하이브리드 추정기가 비교한 논문들보다 비교적 오차가 크다. 이는 고속에서 변화하는 횡방향 속도의 경향에 따른 실험 조건의 차이에 기인하며 하이브리드 추정기는 전

Table 5 RMSE results of lateral velocity

Velocity [km/h]	Lane change test (RMSE)	Slalom (RMSE)
Train data		
10	0.0045	0.0042
20	0.0051	0.0036
30	0.0090	0.0067
40	0.0114	0.0088
50	0.0158	0.0132
60	0.0175	0.0220
70	0.0191	0.0201
Test data		
5	0.0058	0.0033
15	0.0043	0.0036
25	0.0067	0.0042
35	0.0099	0.0074
45	0.0121	0.0104
55	0.0134	0.0115
65	0.0146	0.0121
Average	0.0099	0.0088

Table 6 Compare with previous studies

Previous studies method	Velocity [km/h]	Previous studies (RMSE)	Hybrid estimator (RMSE)
LSTM-based, lane change	30	0.05	0.0090
	50	0.06	0.0158
kernel regression, lane change	70	0.018	0.0191
Cubature Kalman filter, lane change	60	0.0107	0.0175
Average		0.035	0.015

속도 구간에서 추정을 목표로 하지만 비교한 논문은 특정 속도에서 추정을 목표로 하는 차이가 있다. 고속에서는 차체 슬립각이 차량의 헤딩 방향과 일치하지 않아 인자들을 새롭게 튜닝의 소요가 있어 비교한 연구들은 특정 속도에서 횡방향 속도만을 추정하였으나 이 연구에서는 하이브리드 추정기를 설계하여 전 구간에서의 횡방향 속도를 추정할 수 있다.

## 4. 결 론

이 연구에서는 기존 차량을 포함한 다양한 모빌리티에 적용하기 위한 종방향 및 횡방향 속도 추정을 진행하였다. 종방향 속도 추정에는 칼만필터를 사용하였으며 추정 오차의 원인인 슬립과 잠김을 고려하여 설계하였다. 횡방향 속도 추정의 경우 기존 모델 기반 추정기의 한계들로 인해 추정이 어려운 문제가 있었기에 상대적으로 추정이 어려운 횡방향 속도를 추정하기 위해 종방향 속도를 먼저 추정하여 휠 스피드 센서, IMU 센서값과 함께 횡방향 속도 추정기에 입력으로 사용하였다. 이때 인공신경망으로 시계열 데이터를 대상으로 하는 인공지능 방법 중 가변적인 데이터 추정에 유리한 LSTM을 사용하였다. 추정기의 성능을 평가하기 위해 종방향 속도 추정기는 고속에서 풀 브레이크 시험을 통해 확인했고, 비교 대상으로 비 구동륜 평균 속도를 사용했다. 횡방향 속도는 횡 거동이 주인 차선변경, 슬라립 주행시험에서 기존 연구들과 추정 성능 비교를 통해 설계한 네트워크의 적용 가능성을 확인하였다.

이 연구는 차량 동역학 모델을 사용하지 않음으로써 이전 연구<sup>(7,8)</sup> 같은 모델기반 방법이 하기 어려운 기존 차량과 상이한 특성을 가진 다양한 모빌리티 차량에 적용 가능할 것으로 판단된다. 특히, 네 바퀴가 독립 조향하는 모빌리티인 4WIS는 좌우로 주행하는 크랩 주행 모드와 제자리에서 회전하는 제로턴 모드같이 바퀴의 각도가 기존 차량과 상이한 거동을 보인다. 이러한 경우 기존의 차량 동역학 모델을 적용하여 속도를 추정하기 대단히 어려운 단점이 있다. 하지만 이 논문에서 제안한 모델 기반 및 데이터 기반을 통합한 하이브리드 방법을 효과적으로 적용한다면 높은 정확도를 보이는 속도 추정기를 4WIS 모빌리티 차량에 맞추어 개발 가능할 것으로 사료되어 향후 연구로는 독립 조향 모드를 가지는 4WIS 모빌리티 차량에 대한 종 및 횡방향 속도 추정기를 개발하여 성능을 평가할 예정이다.

## 후 기

이 연구는 현대자동차그룹의 지원을 받아 수행된 연구임(No. T101600123020129).

## References

- (1) Ungoren, A. Y., Peng, H. and Tseng, H. E., 2004, A Study on Lateral Speed Estimation Methods, *International Journal of Vehicle Autonomous Systems*, Vol. 2, No. 1-2, pp. 126-144.
- (2) Jin, X., Yin, G. and Chen, N. 2019, Advanced Estimation Techniques for Vehicle System Dynamic State: A Survey, *Sensors*, Vol. 19, No. 19, 4289.
- (3) Vaskov, S., Berntorp, K. and Quirynen, R. 2021, Cornering Stiffness Adaptive, Stochastic Nonlinear Model Predictive Control for Vehicles, *Proceedings of the 2021 American Control Conference (ACC)*, pp. 154-159.
- (4) Kim, S. W., Oh, K.-Y. and Lee, S., 2021, Physics-informed Neural Network for Estimation of Lithium-ion Battery State-of-health, *Transactions of the Korean Society for Noise and Vibration Engineering*, Vol. 31 No. 2, pp. 177-184.
- (5) Kong, D., Wen, W., Zhao, R., Lv, Z. and Liu, K., et al., 2022, Vehicle Lateral Velocity Estimation Based on Long Short-term Memory Network, *World Electric Vehicle Journal*, Vol. 13, No. 1, 1.
- (6) Weytjens, H. and De Weerd, J., 2020, Process Outcome Prediction: CNN vs. LSTM (with Attention), *Proceedings of the BPM 2020 International Workshops*, pp. 321-333.
- (7) Fathazam, A., 2022, Vehicle Lateral and Longitudinal Velocity Estimation Using Machine Learning Algorithms, *Master's Thesis*, University of Waterloo, Ontario, Canada.
- (8) Wan, W., Feng, J., Song, B. and Li, X., 2021, Vehicle State Estimation Using Interacting Multiple Model Based on Square Root Cubature Kalman Filter, *Applied Sciences*, Vol. 11, No. 22, 10772.
- (9) Wang, J.-G., 2009, Reliability Analysis in Kalman Filtering, *Journal of Global Positioning Systems*, Vol. 8, No. 1, pp. 101-111.
- (10) Hochreiter, S. and Schmidhuber, J. 1997, Long

Short-term Memory, Neural Computation, Vol. 9, No. 8, pp. 1735~1780.

(11) Bolboacă, R. and Haller, P., 2023, Performance Analysis of Long Short-term Memory Predictive Neural Networks on Time Series Data, Mathematics, Vol. 11, No. 6, 1432.

(12) Chen, C., Zhang, P., Zhang, H., Dai, J. and Yi, Y., et al., 2020, Deep Learning on Computational-resource-limited Platforms: A Survey, Mobile Information Systems, Vol. 2020, 8454327.

(13) Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R., 2014, Dropout: A Simple Way to Prevent Neural Networks from Overfitting, Journal of Machine Learning Research, Vol. 15, No. 1, pp. 1929~1958.

(14) Bergstra, J. and Bengio, Y., 2012, Random Search for Hyper-parameter Optimization, Journal of Machine Learning Research, Vol. 13, No. 2, pp. 281~305.



**Gyu Yong Hwang** is a Master's student. he is currently pursuing a Master's degree program at Kongju National University. His research interests are intelligence control and machine learning



**Jong Seok Oh** received the Ph.D. degree in Mechanical Engineering from Inha University in 2015. He is currently an associate professor in Kongju National University. His research interests are robust controller design and control of various systems using smart actuators such as magnetorheological (MR), electrorheological (ER) fluids, and piezo actuators.