

# 차량 OBD 및 GPS·IMU 센서 퓨전 데이터 활용한 칼만 필터 기반 PINN 차량 속도 예측 기법

강지수, 이지환, 김준영

성신여자대학교

20221322@sungshin.ac.kr, 20231415@sungshin.ac.kr, jkim@sungshin.ac.kr

## Vehicle Speed Prediction Approach using Physics-Informed Neural Network based on Kalman Filter with GPS·IMU Sensor Fusion and Vehicle OBD Data

Ji Soo Kang, Ji Hwan Lee, Joon Young Kim

Sungshin Women's Univ.

### 요약

본 연구는 GPS·IMU의 센서 오차와 기존 딥러닝 모델의 블랙박스 문제를 해결하기 위해 물리 정보 신경망(Physics-Informed Neural Network, PINN) 기반의 차량 속도 추정 모델을 제안한다. 가속도 바이어스가 보정된 칼만 필터 데이터를 LSTM 구조에 입력하고, 운동학적 원리를 학습 제약 조건으로 적용하여 물리적 타당성을 확보하였다. 실험 결과, MAE 0.836 km/h의 정확도를 달성하며 칼만 필터만 적용한 방법 대비 14.6% 성능을 개선하였으며, 물리적 인과관계 분석을 통해 예측 결과의 신뢰성과 설명 가능성을 검증하였다.

### I. 서론

자율주행 및 첨단 운전자 보조 시스템(Advanced Driver Assistance System, ADAS)에서 정밀한 차량 속도 추정은 필수 요소이다[1]. 최근에는 스마트폰을 포함한 다양한 독립형 기기의 센서를 활용하여 차량의 속도 및 주행 상태를 파악하는 연구가 지속적으로 진행되고 있다[2]. 그러나 일반적으로 사용하는 저가형 센서 중, GPS는 도심 내 신호 단절 문제와 IMU는 바이어스로 인한 오차 누적이 존재한다. 이를 위해 활용되는 기존 딥러닝 연구들의 경우 통계 패턴에만 의존하는 '블랙박스' 문제로 신뢰성 확보에 대한 난제가 존재한다[3]. 특히 해당 모델의 경우, 물리 역학적인 환경 고려를 하지 않고 훈련을 진행하는 바 시계열적 특성은 학습하지만, 실질적인 예측 정확률을 도출 및 개선에 문제가 잔존한다. 본 연구에서는 이를 해결하고자 물리 역학적 원리를 학습에 반영한 Physics-Informed Neural Network(PINN)[4] 기반의 제안 모델을 통해 실질적인 예측 개선 향성을 대한 가능성을 확보한다. 구체적으로 실제 차량내 OBD 데이터 및 GPS와 IMU로 수집한 실측 데이터를 기반으로 하여 전처리 및 최적화를 수행하여 정확도와 물리적 타당성을 정량적으로 검증하고자 한다.

### II. 데이터 수집 및 전처리



그림 1. OBD 속도/GPS 위치 기반 두 주행 데이터셋의 주행 궤적  
그림 1과 같이, 2016년형 현대자동차 아반떼 AD GDi 1.6 가솔린 차량을 사용하여 서울 도심 동일 코스를 약 6분간 2회 주행하였다. 모델의 일반화 성능 검증을 위해 두 주행 데이터를 각각 학습용(35,251개)과 검증용(34,822개)으로 데이터셋을 구축하였으며, 10ms 간격(100Hz)으로 샘플링

된 데이터의 과거 10개 타임스텝을 하나의 입력 시퀀스로 구성하였다. Raspberry Pi 4 기반 데이터 수집 및 통합 관리 시스템을 통해 차량 루프 중앙에 Quectel GNSS 액티브 안테나(Ublox NEO-M8N)와 좌측 후석 도어 하단 내벽에 SparkFun 6DoF IMU를 설치하여 위치 및 관성 데이터를 수집하였다. 동시에 OBD II(On-Board Diagnostics II, 온 보드 진단 II) 포트를 통해 훨 속도 센서 기반의 속도 데이터를 수집하였다.

모델 학습의 기준값(Ground Truth)으로는 OBD 데이터를 사용하였다.

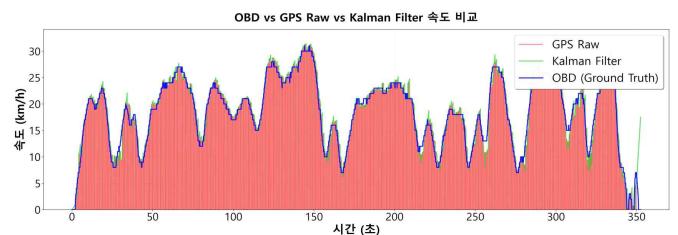


그림 2. GPS(빨강), OBD(파랑), 칼만 필터 출력(초록) 속도 비교  
그림 2와 같이 GPS 데이터는 IMU 대비 낮은 샘플링 주기로 인해, IMU 기준으로 시간축을 정렬하면 GPS 값이 존재하지 않는 구간이 관찰된다. IMU 데이터는 정지 상태의 자이로 바이어스 제거, 중력 벡터 차감, 센서-차량 간 좌표계 변환을 거쳤다. 전처리한 IMU는 높은 샘플링 주기를 갖지만 오차가 누적되고, GPS는 절대 정보를 제공하나 결측 구간이 존재한다. 이를 보완하기 위해 선형 칼만 필터를 적용하여 두 센서를 융합하였다[5]. GPS 값이 유효한 구간에서는 식 (1)을 이용해 측정 업데이트를 수행하고, 결측 구간에서는 식 (2)를 이용해 예측만 수행하였다. 식(1)~(2)의  $F, H$ 는 상태 전이 및 관측 행렬,  $P$ 는 오차 공분산,  $K$ 는 칼만 이득이며,  $Q$ 와  $R$ 은 각각 모델과 센서의 노이즈 공분산 행렬로 시스템의 신뢰도를 결정한다.

$$K(k) = P(k|k-1)H(k)^T[H(k)P(k|k-1)H(k)^T + R(k)]^{(-1)} \quad (1)$$
$$\hat{x}(k|k) = \hat{x}(k|k-1) + K(k)[z(k) - H(k)\hat{x}(k|k-1)]$$

$$\hat{x}(k|k-1) = F(k)\hat{x}(k-1|k-1) \quad (2)$$
$$P(k|k-1) = F(k)P(k-1|k-1)F(k)^T + Q(k)$$

상태 벡터  $x = [p, v, b]^T$ 는 위치, 속도, 가속도 바이어스로 구성되어 센서 드리프트를 보정한다. 시스템 행렬  $F$ 는 등가속도 운동 모델에 기반하여

식 (3)과 같이 정의되며, 이는 Grewal 등[6]의 모델을 따른다.

$$F = \begin{bmatrix} 1 & \Delta t & \frac{1}{2} \Delta t^2 \\ 0 & 1 & \Delta t \\ 0 & 0 & 1 \end{bmatrix} \quad (3)$$

본 연구에서는 그리드 서치를 통해 시스템 파라미터의 최적값( $Q=0.001$ ,  $R=1.0$ ,  $Q_{bias}=0.01$ )을 선정하여 적용하였다.

### III. 모델 설계

앞서 작성된 칼만 필터 예측치내 데이터의 시간적 의존성 학습을 통한 개선을 위해 Long Short-Term Memory(LSTM) 기반 PINN 모델을 그림 3과 같이 적용하였다[4]. 칼만 필터를 거친 속도와 전처리된 IMU 가속도가 정규화되어 입력된다. 2개의 LSTM 레이어(64 units), ReLU가 적용된 완전 연결 레이어(32 units), 출력 레이어(1 unit)로 구성하였고, 학습 조건은 배치 크기 128, Adam (학습률 0.001), Epoch 100으로 설정하였다. 손실 함수는 데이터 손실과 물리 손실의 가중합으로 구성되며, 물리 손실은 운동학적 관계식( $v_t = v_{t-1} + \alpha \Delta t$ )을 제약 조건으로 활용한다. 물리 손실 가중치는 그리드 서치를 통해 0.5를 적용하였으며, 이는 모델이 물리적 인과관계를 준수하도록 유도하여 비현실적인 예측을 방지한다.

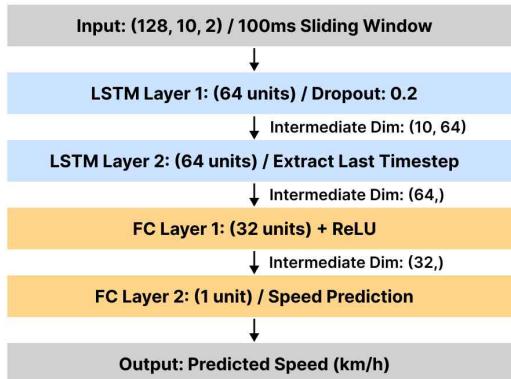


그림 3. PINN 모델 아키텍처 다이어그램

### IV. 실험 결과

표 2. GPS 단일, GPS+IMU 칼만 필터, PINN 학습 모델 성능 비교

방법	MAE(km/h)	RMSE(km/h)	R <sup>2</sup>
GPS 단일	3.190	5.224	0.4868
GPS+IMU 칼만 필터	0.979	1.301	0.9682
PINN 학습 모델	0.836	1.185	0.9736

표 2에서 PINN 학습 모델은 Train MAE 0.771 km/h, Test MAE 0.836 km/h의 성능을 달성하였으며, 일반화 오차 8.44%로 과적합 없이 안정적으로 학습하였다. 이는 칼만 필터만 적용한 GPS+IMU 대비 14.6%, GPS 단일 대비 73.8% 개선된 결과이다. 특히 잔차 평균 0.004 km/h 및 R<sup>2</sup> 0.9736을 기록하고 잔차 정규성(p=0.082)을 확보하여, 물리적 편향 없이 운동학적 원리를 준수함을 검증하였다.

표 3. 정지/저속/중속/고속 4개 속도 구간 예측 성능 평가 결과

속도 구간	F1 Score	데이터 비율
정지 (0~5 km/h)	0.901	5.2%
저속 (5~15 km/h)	0.885	22.3%
중속 (15~25 km/h)	0.914	50.6%
고속 (25+ km/h)	0.900	21.9%

표 3은 속도 구간별 분류 성능 평가 결과, 모든 구간에서 F1 Score 0.8 이상을 달성하였다. 중속 구간(15~25 km/h)에서 0.914로 가장 높은 성능

을 나타냈으며, 전체 데이터의 50.6%를 차지하는 주행 환경에서 안정적인 속도 추정이 가능함을 확인하였다.

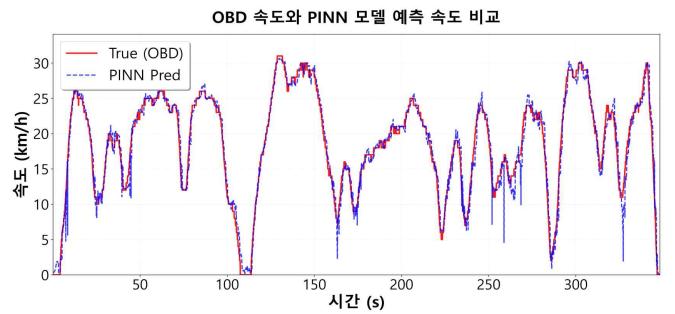


그림 4. OBD 실측 속도 대비 PINN 모델 예측 성능 비교

그림 4에서 제안 모델은 급가속 및 급감속이 빈번한 환경에서도 OBD 실측치를 정밀하게 추종한다. 또한 세약 조건 덕분에 예측값이 뛰지 않고 안정적인 속도 곡선을 유지하였다. 이러한 결과는 통계적 패턴에만 의존하는 일반적인 LSTM과 달리, 모델이 물리적 인과관계에 기반한 높은 추정 신뢰성과 설명 가능성을 갖추었음을 보여준다.

### V. 결 론

본 연구는 PINN을 활용하여 외부 센서 데이터만으로 정밀한 차량 속도 추정 모델을 제안하였으며 물리 역학적 원리를 적용함으로써 예측 결과의 신뢰성을 확보하였다. 향후 연구에서는 다양한 주행 데이터셋 구축을 통해 학습 적용 및 물리 기반의 역문제 해결 도입으로 공기 저항 및 마찰력 등 차량의 동역학적 특성 반영한 모델의 범용성을 확장할 예정이다. 추가로 V2X 통신 및 ADAS 연동을 통해 실시간 자율주행 환경에 부합하는 속도 추정 플랫폼으로 고도화하여, 주행 안전성 향상에 기여하고자 한다.

### ACKNOWLEDGMENT

본 논문은 한국연구재단 논문연구과제 (2022R1G1A1009023)의 연구 결과로 수행되었습니다.

### 참 고 문 헌

- [1] H. Ragab, S. Givigi, and A. Noureddin, "Automotive Speed Estimation: Sensor Types and Error Characteristics from OBD-II to ADAS," arXiv preprint arXiv:2501.00242, 2025.
- [2] A. Khandakar et al., "Harnessing Smartphone Sensors for Enhanced Road Safety: A Comprehensive Dataset and Review," Scientific Data, vol. 12, no. 418, 2025, doi: 10.1038/s41597-024-04193-0.
- [3] Guang, Xingxing et al. "IMU Data and GPS Position Information Direct Fusion Based on LSTM." Sensors (Basel, Switzerland) vol. 21, 7 2500. 3 Apr. 2021.
- [4] M. Raissi, P. Perdikaris, and G. E. Karniadakis, "Physics-Informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations," Journal of Computational Physics, vol. 378, pp. 686 - 707, 2019.
- [5] R. E. Kalman, "A New Approach to Linear Filtering and Prediction Theory," Journal of Basic Engineering, vol. 82, no. 1, pp. 35 - 45, 1960.
- [6] M. S. Grewal, L. R. Weill, and A. P. Andrews, Global Positioning Systems, Inertial Navigation, and Integration, 2nd ed. Hoboken, NJ: Wiley, 2007.