

# 시계열 데이터를 이용한 LSTM 기반 차량주행정보 예측에 관한 연구

김병준, 김동훈, 박근호, 김선형, 김서정, 정성환\*

한국전자기술연구원

{jun0420, clickmiss123, root, sh.kim, scott3554, \*shjeong}@keti.re.kr

## A Study on the Prediction of Vehicle Driving Information Based on LSTM Using Time Series Data

Byoungjun Kim, Donghoon Kim, Keunho Park, Seonhyeong Kim,

Seojeong Kim, Sunghwan Jeong\*

Korea Electronics Technology Institute

### 요약

본 논문은 차량 정보 생성에 관한 공개 시뮬레이션을 통해 획득한 차량 상태 및 제어에 관한 시계열 데이터를 이용하여 딥러닝 모델 중 순환 신경망 변형 모델인 LSTM을 통해 차량주행정보 예측에 관한 연구를 수행하였다. LSTM을 통해 각 센서 주기의 시간 지연 문제 해결과 시간 변화에 따른 차량 상태 및 제어에 관한 상호의존성 분석을 통해 차량주행정보 예측 정확도는 평균 MSE 0.016692와 평균 MAE 0.08449 결과 도출을 확인하였다.

### I. 서론

최근 IT 기술의 발달로 차량에 설치된 라이다, 레이더, 그리고 각종 센서를 통해 주행 환경을 인식하고, 주행 경로를 판단하여 구동장치를 제어하여 주행하는 자율주행 기술개발 및 고도화를 통해 안전한 서비스를 제공하고 있다[1].

이러한 기술은 각 센서로부터 주행 환경에 대한 도로정보, 차량 동특성을 파악하여 차량 조향각, 휠 토크 등과 같은 구동장치를 제어하지만 정확한 제어를 위해서는 고성능 관측 장치 센서와 같은 다양한 센서들을 사용할 수 있지만, 비용과 센서의 수명, 그리고 다양한 환경 적용 가능성으로 인해 실제 차량에 장착하여 적용하기 어려운 문제가 있다. 또한, 각 센서의 주기가 다르기 때문에 시간 지연 문제가 존재한다.

본 논문에서는 딥러닝 모델 중 순환 신경망(Recurrent Neural Network)의 장기 의존성 문제(Long-term dependencies)를 해결하기 위해 제시된 LSTM(Long Short-Term Memory)[2] 모델을 통해 차량 정보 생성에 관한 공개 시뮬레이션을 통해 획득한 차량 상태 및 제어에 관한 시계열 데이터를 활용하여 고성능 센서 대체를 위한 차량주행정보 예측에 관한 연구를 수행하였다.

### II. 본론

#### 2.1. 차량주행정보 데이터 수집 및 전처리

차량 상태 및 제어 관련 주행정보 데이터는 일반 차량을 통해 획득의 어려운 점이 존재하여 차량 상태 및 제어 관련 주행정보 생성에 관한 공개 시뮬레이션[3, 4]을 통해 시계열 데이터를 획득하였다. 획득한 데이터의 정보는 표 1과 같으며 차량 방향속도, 회전반경, 가속도, 조향각도, 휠 토크, 그리고 브레이크 압력 정보로 구성된다. 14가지의 차량 상태 및 제어에 대한 시계열 데이터인 총 347,984개를 획득 후  $[-1, 1]$  범위 값으로 대응하는 z score 정규화(z score normalization)를 통해 전처리를 수행한다.




그림 1. 차량 주행정보 예측을 위한 차량 상태 및 제어 구성[3]

표 1. 차량 주행정보 예측을 위한 차량 상태 및 제어 정보

차량 정보	매개변수 설명	매개변수	표기	단위
차량 상태	차량 방향 (종/횡) 속도	$v_x\_mps, v_y\_mps$	$v_x, v_y$	m/s
	차량 회전 반경	dpsi_radps	$\Psi$	rad/s
	차량 가속도	$a_x\_mps, a_y\_mps$	$a_x, a_y$	m/s <sup>2</sup>
차량 제어	조향 각도	deltawheel_rad	$\delta$	rad
	후방 좌/우측 휠 토크	TwheelRL, TwheelRR	$T_{RL}, T_{RR}$	Nm
	전/후방 브레이크 압력	pBrakeF_bar, pBrakeR_bar	$p_f, p_r$	bar

1	vx_mps	vy_mps	dpsi_radps	ax_mps	ay_mps	deltawheel_rad	TwheelRL_Nm	TwheelRR_Nm	pBrakeF_bar	pBrakeR_bar
2	3.012723124	-0.042042247	-0.013249793	4.483099937	0.037099998	-0.008726646	956.25	968.75	0	0
3	3.04944709	-0.041503864	-0.006169931	4.552899837	-0.196449995	-0.007853982	956.25	968.75	0	0
4	3.086254286	-0.041103987	-0.007695728	4.639900208	-0.162550002	-0.008726646	962.5	968.75	0	0
5	3.122877601	-0.040852488	-0.003493461	4.64700222	-0.227799997	-0.007853982	993.75	981.25	0	0
6	3.15719808	-0.040074352	-0.000449464	4.249599934	-0.192949995	-0.007853982	1043.75	968.75	0	0.100000001
7	3.19027535	-0.039921161	-0.003366668	4.02600023	-0.190200001	-0.006981317	943.75	993.75	0	0
8	3.222455781	-0.040140677	-0.002245934	4.009699821	-0.201299995	-0.006981317	943.75	993.75	0	0
9	3.25477557	-0.040190627	-0.008590865	3.955499887	-0.275000006	-0.00410521	950	993.75	0	0
10	3.287094996	-0.040675718	-0.007895053	4.122099876	-0.203250006	-0.00437856	1037.5	1000	0	0.100000001
11	3.321400314	-0.039270986	-0.010316662	4.294499874	-0.040649999	-0.00296706	987.5	1037.5	0	0
12	3.35787202	-0.03833349	-0.003115467	4.525650024	-0.052450001	-0.001570796	1006.25	1031.25	0	0
13	3.395642099	-0.035791374	-0.008490399	4.723400116	0.144500002	-0.000872665	1006.25	1031.25	0	0
14	3.433645419	-0.034252291	-0.004846524	4.659450054	-0.00675	0	1050	1075	0	0
15	3.471265798	-0.033097752	-0.001738461	4.627250195	0.020500001	0.000698132	1000	1031.25	0	0
16	3.50732595	-0.032172565	0.00543706	4.38409996	-0.038699999	0.000698132	975	1068.75	0	0
17	3.542065296	-0.031205241	0.007723859	4.244450092	0.01475	0.001570796	975	1075	0	0
18	3.576408016	-0.030512365	0.008787129	4.18380022	-0.126750007	0.000698132	975	1075	0	0
19	3.61007268	-0.030431937	0.007305452	4.08799821	-0.135199994	0	1081.25	1043.75	0	0
20	3.644315342	-0.030231547	0.003162389	4.205749989	-0.142199993	0.000698132	981.25	1031.25	0	0
21	3.680367895	-0.030629396	0.008143323	4.501450062	-0.218349993	0	1018.75	1043.75	0	0
22	3.718258151	-0.03078963	0.002999985	4.713600159	-0.203700006	-0.000872665	1081.25	1062.5	0	0
23	3.756947572	-0.031396234	0.011349518	4.800199986	-0.096299998	-0.001570796	1081.25	1062.5	0	0
24	3.797105739	-0.031509268	0.018214639	4.955850124	-0.279150009	-0.002268928	1012.5	1131.25	0	0
25	3.836096991	-0.031462713	0.016677182	4.821300003	-0.175750002	-0.002268928	1037.5	1031.25	0	0
26	3.873921984	-0.029429014	0.006020123	4.689099789	0.055100001	-0.002268928	1050	1037.5	0	0.100000001

그림 2. 공개 시뮬레이션을 통해 획득한 시계열 기반 차량 상태 및 제어 데이터

## 2.2. LSTM 기반 차량주행정보 예측 구조

공개 시뮬레이션을 통해 차량 상태 및 제어 시계열 데이터를 획득 후 전처리 과정을 수행하였다. 획득한 데이터를 시간  $t-n$ 부터  $t$  변화에 따른 차량 상태 및 제어 데이터를 누적 후 제안한 LSTM 기반 차량주행정보 예측 구조를 통해 시간  $t+1$ 에 대한 차량 방향속도, 회전반경, 그리고 가속도를 예측하는 구조를 그림 2와 같이 구성하였다.

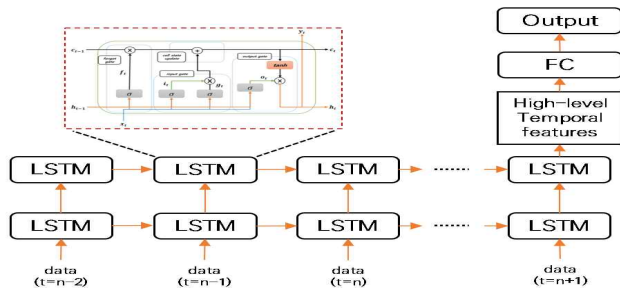


그림 3. 차량 상태 및 제어 시계열 데이터를 활용한 LSTM 기반 차량 주행정보 예측 구조

구성한 LSTM 기반 차량주행정보 예측 구조에 대해 학습 시 과적합 방지를 위해 L2 정규화(L2 normalization), 가중치 초기화(weight initialization), 학습률 감소(reduce learning rate), 매 단계(epoch) 배치 데이터 무순위(shuffle)를 구성 후 표 2를 통해 학습을 진행하였다.

표 2. LSTM 기반 차량주행정보 예측 구조 매개변수

매개변수	값
입력	차량 상태 및 제어 정보
출력	차량 방향 속도, 차량 회전반경, 차량 가속도
RNN 모델	LSTM(Long Short-Term Memory)
1계층 은닉 노드 수	150
2계층 은닉 노드 수	200
완전연결층 노드 수	10
데이터 수	총 데이터:347,984, 학습:226,190, 검증:86,996, 평가:34,798
timestep	8
batch size	1000
epochs	150
learning rate	0.0004
l2 regularization	0.001
reduce learning rate factor	0.8
patience learning rate	10
weight initializer	he
activation function	Leaky ReLU, tanh
optimization	Nesterov Adam
loss function	mean squared error

## 2.3. 차량주행정보 예측결과

표 2를 통해 LSTM 기반 차량 주행정보 예측 구조를 학습 후 10가지의 차량 상태 및 제어에 대한 34,798개에 대해 MSE(Mean Squared Error)와 MAE(Mean Absolute Error)에 대해 평가한 결과 평균 MSE는 0.016692, 평균 MAE는 0.08449의 결과가 도출되었다.




그림 4. 제안한 LSTM 기반 차량 주행정보 예측구조 성능평가 결과

이를 통해 시간  $t-n$ 부터  $t$  변화에 따른 차량 상태 및 제어 데이터에 대한 시간  $t+1$ 에 대한 차량 방향속도, 회전반경, 그리고 가속도를 예측할 시 차량 주행정보 뿐만 아니라 자율주행 기술에 접목하여 시공간 특징 분석과 융합 시 일반 차량의 주행정보 예측이 가능할 것으로 판단된다.

## III. 결론

본 논문에서는 차량 정보 생성에 관한 공개 시뮬레이션을 통해 획득한 차량 상태 및 제어에 관한 시계열 데이터를 이용하여 제안한 LSTM 기반 차량 주행정보 예측 구조에 관한 연구를 수행하였다. MSE와 MAE 성능지표를 통해 평가한 결과 평균 MSE는 0.016692, 평균 MAE는 0.08449의 결과 도출로 차량주행정보 예측 가능성을 확인하였다. 향후 CCTV를 통해 획득한 공간적인 특징정보와 각 차량 센서 정보 간의 융합을 통한 자율주행 연구에 대하여 진행할 예정이다.

## ACKNOWLEDGMENT

이 논문은 2021년도 정부(경찰청)의 재원으로 과학치안진흥센터의 지원을 받아 수행된 연구임(No.092021C28S02000, 협력적 교통제어전략 도입을 위한 교통정보 음영구간 정보생성 및 운영관리 기술개발)

## 참고문헌

- [1] 김현우, 박상현, "LSTM 기반의 차선 정보와 조향각을 활용한 LKAS 요각속도 예측모델", *한국자동차공학회 논문집*, Vol.26, No.2, pp.279-287, 2018.
- [2] Yu, Y., Si, X., Hu, C., & Zhang, J. "A review of recurrent neural networks: LSTM cells and network architectures." *Neural computation*, Vol.31, No.7, pp.1235-1270, 2019.
- [3] Hermansdorfer, Leonhard, et al. "End-to-end neural network for vehicle dynamics modeling." *2020 6th IEEE Congress on Information Science and Technology (CIST)*. IEEE, 2021.
- [4] Betz, Johannes, et al. "TUM Autonomous Motorsport: An Autonomous Racing Software for the Indy Autonomous Challenge." *arXiv preprint arXiv:2205.15979* (2022).