

# 실시간성을 고려한 차량 움직임 상호의존성 활용 딥러닝 기반 차량 경로 예측 연구

오기성, 김희중, 임세준\*  
국민대학교

gsethan17@kookmin.ac.kr, jkdt333@kookmin.ac.kr, \*lim@kookmin.ac.kr

## A study on deep learning based vehicle trajectory prediction using the interdependencies of vehicle motion in real-time

Geesung Oh, Heejung Kim, Sejoon Lim\*  
Kookmin Univ.

### 요 약

본 논문은 차량경로 예측 딥러닝 모델의 성능 손실을 최소화하면서 복잡도 및 연산량을 줄여 모델의 예측 속도를 증가시키는 것을 목적으로 한다. Long Short Term Memory(LSTM)와 Convolutional Social Pooling(CS) 구조로 이루어져 있던 기존의 고성능 딥러닝 모델에서 LSTM 구조를 제거하고 CS 구조를 기반으로 차량 간 상호의존성을 학습하고 주행경로를 예측했다. 예측 정확도는 동일 수준을 유지하면서 예측 속도를 62.75% 감소시켰다. 실시간 경로 예측 문제 차원에서 예측 오차를 줄이는 것도 중요하지만 빠르게 예측하는 것 역시 중요한 성능 지표이다. 따라서 본 논문에서 제안한 차량 움직임의 상호의존성을 활용한 딥러닝 경로 예측 모델이 실시간 경로 예측 성능면에서 기존의 모델들 보다 우위를 차지했다.

### I. 서 론

교통사고 중 차대차 사고 유형은 74.6%로 가장 많은 비율을 차지한다.[1] 이러한 차대차 사고를 방지하기 위해 딥러닝 기술을 활용한 차량의 주행경로 예측 연구가 다양하게 진행되고 있다.

딥러닝 기법 중 Long Short Term Memory(LSTM)가 경로 예측에 많이 활용되고 있다. 비록 이 기법은 단위 객체의 움직임만을 학습하지만 시계열 예측 문제에서 높은 정확도를 보이며 차량경로 예측 문제에서도 좋은 성능을 보였다.[2, 3] 그러나 최근 자동차대수가 연평균 10.4%씩 지속적으로 증가[1]하면서 주행경로 예측에 있어서 주변차량과의 상호의존성이 부각되고 있다. 상호의존성을 학습하기 위하여 단위 객체의 움직임을 학습하는 LSTM 모델을 서로 연결하는 방식을 사용한다.[2] 차량경로 예측 문제에서도 LSTM 모델을 Convolutional Social Pooling(CS)구조로 연결한 모델(LSTM-CS)이 높은 정확도를 달성했다.[3]

LSTM-CS 모델과 같이 다양한 딥러닝 구조가 결합되면서 예측 정확도는 상승하지만 모델의 크기가 점점 증가한다. 이는 고성능의 연산 시스템을 필요로 하므로 차량 내 임베디드 시스템에 적용하기에는 제한적이다.

따라서 본 연구에서는 도로 위에서 실시간 경로 예측이 가능한 간소화된 딥러닝 모델 개발을 목적으로 한다. 기존의 높은 정확도의 차량경로 예측 딥러닝 모델(LSTM-CS)에서 LSTM 구조를 제거하여 주변차량과의 상호의존성만으로 주행 경로를 학습하는 딥러닝 모델(only-CS)을 제안한다. LSTM-CS 모델과 only-CS 모델의 차량경로 예측 오차 및 시간을 비교 분석한다.

### II. 문제 정의

도로 위의 기준차량을 임의로 선정하고  $h$  Hz 주기로 기준차량과 주변차량의 과거 이동경로를 입력 받아 기준차량의 주행경로를 예측한다. 주변차량은 기준차량을 제외한 관측범위 내 모든 차량을 말하며 관측 범위는 기준차량을 중심으로 전후방  $l$  m 및 인접한 좌우  $w$  개 차선 사이를 말한다. 모든 경로는 예측시점( $T_t$ )의 기준차량 위치  $(x^{T_t}, y^{T_t})$ 를 기준으로 상대좌표로 변환한다. 과거 이동경로( $X$ )는  $T_t$ 를 기준으로 이전  $T_p$ 초 동안의 위치를  $d$  만큼 Down sampling 한 것을 말한다. 주행경로( $Y$ ) 역시  $T_t$ 를 기준으로 이후  $T_f$ 초 까지의 위치를  $d$ 만큼 Down sampling 한 것을 말한다.

$$X = \left[ \left( x^{T_t - \frac{d}{h}} - x^{T_t}, y^{(T_t - \frac{d}{h})} - y^{T_t} \right) \right], \quad \left( i = 0, 1, \dots, \frac{T_p \times h}{d} \right) \quad (1)$$

$$Y = \left[ \left( x^{T_t + \frac{d}{h}} - x^{T_t}, y^{(T_t + \frac{d}{h})} - y^{T_t} \right) \right], \quad \left( i = 1, 2, \dots, \frac{T_f \times h}{d} \right) \quad (2)$$

### III. 알고리즘

#### ● LSTM-CS 모델

기준차량과 주변차량의 과거 이동경로를 LSTM 구조로 입력하여 개별 움직임을 예측한다. CS 구조는 주변차량 움직임 정보를 격자형태로 입력 받아 상호의존성을 예측한다. 상호의존성과 기준차량의 움직임이 합쳐진 정보는 LSTM 구조를 거쳐 기준차량의 주행경로를 순차적으로 출력한다.

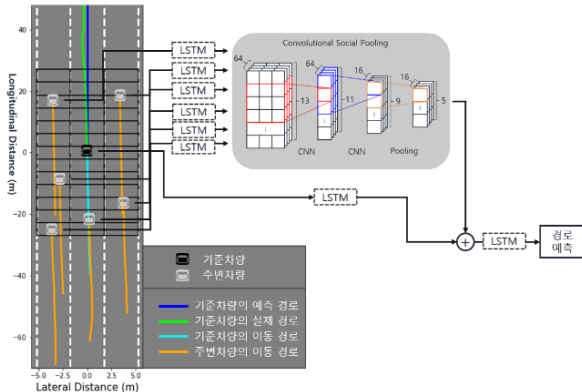
#### ● only-CS 모델

LSTM-CS 모델에서 LSTM 구조를 제거한 모델로서 주변차량의 과거 이동경로가 격자형태로 CS 구조에 입력되어 상호의존성을 예측한다. 주변차량의 상호의존성이 기준차량의 과거 이동경로와 결합되어 기준차량의 주행경로를 출력한다.

<그림 1>에서 LSTM 유/무에 따라 LSTM-CS 모델과 only-CS 모델로 구분된다.

두 딥러닝 모델의 학습은 예측경로( $\hat{Y}$ )와 실제경로( $Y$ ) 사이의 오차를 줄이는 방향으로 진행한다. 학습을 위하여 NGSIM 데이터를 사용했다. NGSIM 데이터는 미국 주간고속도로 제 80 호선[4]과 일반 국도 제 101 호선[5]의 실제 차량의 이동경로를 10Hz 주기로 관측한 데이터이다. 데이터를 Train, Validation, Test 로 나누어 Train 과 Validation 데이터는 모델 학습에 사용하고 Test 데이터는 학습된 모델의 성능 평가를 위해 실험에서 사용했다. 오차는 Mean Squared Error(MSE)값으로 산출하였다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i) \quad (3)$$




<그림 1> 딥러닝 모델 도식화

#### IV. 실험 및 결과 분석

NGSIM 데이터 중 학습에 사용하지 않은 Test 데이터를 기반으로 LSTM-CS 모델과 only-CS 모델의 경로예측 성능을 비교한다. 실험은 TensorFlow 프레임워크에서 진행되었다.[6] 실험에 사용된 Linux PC 의 CPU 는 i9-9980XE, GPU 는 Nvidia Titan RTX 를 사용했다. 예측 주기는 10Hz, 관측 범위는 기준차량을 중심으로 전후방 27m 및 인접한 좌우 1 차선 사이로 한정했다. 예측시점으로부터 과거 3 초동안의 이동경로를 입력 받아 미래 5 초까지의 주행경로를 예측한다. <그림 1>에서 관측 범위와 입출력경로를 확인할 수 있다. 실험 결과는 예측오차와 예측시간을 비교한다.

only-CS 모델의 예측시간은 평균 3.41ms, 표준편차 0.16ms 이며 MSE 값은 평균 14.54m, 표준편차 25.82m 이다. LSTM-CS 모델의 예측시간은 평균 9.17ms, 표준편차 0.62ms 이며 MSE 값은 평균 14.49m, 표준편차 29.77m 이다. 평균 예측시간은 only-CS 모델이 5.76ms 더 빠르며, 예측오차(MSE)는 LSTM-CS 모델이 0.05m 더 작다. 자세한 실험 결과는 <그림 2>와 같다.



<그림 2> 실험 결과 [예측오차 및 예측시간 산점도]

#### VI. 결론

LSTM-CS 모델에서 LSTM 구조를 제거하여 only-CS 모델을 제안했다. only-CS 모델은 LSTM-CS 모델 대비 62.75%의 예측속도 감소를 확인했으며, 이는 100km/h 주행환경에서 0.16m 의 예측오차를 줄일 수 있는 수치이다. 비록 예측오차는 0.05m 증가하지만 0.36%라는 미량에 불과하며 예측결과와 편차 또한 only-CS 모델이 더 작은 것을 확인할 수 있다. 따라서 도로 위에서의 실시간 경로 예측 성능면에서 only-CS 모델이 더 우수한 모델이다. 그러므로 본 연구를 통해 제안하는 딥러닝 경로 예측 모델은 차량 내 온-보드 환경에 적용되어 다양한 분야로 응용될 수 있다. 운전자에게 위험상황을 경고하거나 자율주행자동차 개발에 효과적일 것이다. 그러나 다양한 주행 환경 및 온-보드 환경에서 검증이 진행되지 않았다. 따라서 향후 주행 시뮬레이터를 활용한 다양한 주행 환경에서의 실험 및 PC 가 아닌 온-보드 환경에서의 검증을 진행할 예정이다.

#### ACKNOWLEDGMENT

이 연구는 2020 년도 산업통상자원부 'AI 기반자율주행컴퓨팅모델개발및서비스실증사업'의 재원으로 산업기술평가관리원(KEIT) 연구비 지원(20005673) 및 산업통상자원부 '산업전문인력역량강화사업'의 재원으로 한국산업기술진흥원(KIAT)의 지원(2020 년 미래형자동차 R&D 전문인력 양성사업, 과제번호: N0002428)을 받아 수행된 연구임.

#### 참 고 문 헌

- [1] 2019 년판 교통사고통계분석(2018 년통계), 도로교통공단, 2019-0203-004, 2019
- [2] Alexandre Alahi, Kratarth Goel, Vignesh Ramanathan, Alexandre Robicquet, Li Fei-Fei, Silvio Savarese. "Social LSTM: Human Trajectory Prediction in Crowded Spaces", The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 961-971
- [3] Nachiket Deo, Mohan M. Trivedi. "Convolutional Social Pooling for Vehicle Trajectory Prediction" The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, pp. 1468-1476, 2018
- [4] J.Colyar, J. Halkias Us highway i-80 dataset. Federal Highway Administration (FHWA), Tech. Rep. FHWA-HRT-06-137, 2006.
- [5] J.Colyar, J. Halkias Us highway 101 dataset. Federal Highway Administration (FHWA), Tech. Rep. FHWA-HRT-07-030, 2007.
- [6] Google TensorFlow API, <https://www.tensorflow.org/>