

차량 속도와 위치 표현 방법이 LSTM 기반 차량 경로 예측에 미치는 영향 분석

최윤정¹, 임유진¹

¹숙명여자대학교 IT공학과

potatochips@sookmyung.ac.kr, yujin91@sookmyung.ac.kr

Performance Analysis of the LSTM based Vehicle Trajectory Prediction with the Vehicle Speed and Location Presentation

Yoonjeong Choi¹, Yujin Lim¹

¹Deptment of IT Engineering, Sookmyung Women's Univerity

요 약

차량이 사용자에게 다양한 서비스를 제공하기 위해서 차량의 위치 정보를 요구하는 환경에서 차량의 위치를 예측해 미리 알 수 있다면 높은 품질의 서비스를 만드는 것에 도움이 된다. 차량은 도시 환경에서 비교적 느린 속도를 갖는다는 특징이 있고 차량의 위치를 표시하는 방법도 여러 가지다. 본 논문은 Long Short-Term Memory(LSTM)을 사용해 차량의 이동 경로를 예측하는 과정에서 이동 속도와 위치 표현 방법이 미치는 영향을 분석하였다. 실험 결과 차량의 속도가 증가할수록, 차량의 이동 표현 방법이 세밀할수록 차량 이동 경로 예측이 어렵다는 것을 확인하였다.

1. 서론

5세대 이동통신(5G)의 등장으로 많은 양의 데이터를 전송할 수 있게 되면서 다양한 서비스를 가능하게 만들었다. 특히 차량이 인터넷과 연결되어 차량 내부에서 게임이나 음악 감상 등 엔터테인먼트를 즐기고 위치한 지역의 정보를 얻는 것이 가능해졌다 [1]. 차량 간 통신, 차량과 기반 시설 간 통신, 그리고 위치 기반 서비스 품질을 높이기 위해서 주로 차량의 위치 정보를 요구하는데 이때 차량의 위치를 미리 예측할 수 있으면 보다 다양한 서비스, 특히 실시간 기반 서비스를 사용자에게 끊임 없이 제공할 수 있다.

차량 위치 예측 환경은 크게 고속도로 환경과 도시 환경으로 나뉜다. [2]는 고속도로에서 주행하는 차량의 과거 패턴을 인코더 기반의 LSTM[3]으로 파악하고 미래의 주행 경로는 디코더 기반의 LSTM으로 예측하는 알고리즘을 제안했다. [4]는 시공간을 고려하는 어텐션 메커니즘 (Attention Mechanism)을 LSTM과 함께 사용해 여러 고속도로 시나리오에서 다양한 실험을 통해 미세한 차선 변경을 예측하였다. 도시에서 이동하는 실제 차량 데이터를 사용

한 [5]은 현재와 이전 시점의 위치 정보를 LSTM Recurrent Neural Network(RNN)에 사용해 미래 이동 경로를 예측하는 방법을 제시하였고 [6]은 Generative Adversarial Networks(GAN)을 통해 도시에서 움직이는 차량 경로를 매우 정밀하게 예측하는 방법을 제시하였다.

도시 환경에 있는 차량은 고속도로에 비해 차량의 평균 이동 속도는 느리고, 통행량의 변화폭은 보다 동적인 특징을 갖는다. 차량 위치를 표현하는 방법 중 하나는 격자 지도(Grid Map)를 사용하는 것으로, 한 칸의 크기가 작을수록 차량의 미세한 이동을 나타낼 수 있으며, 본 논문에서는 이러한 격자 지도 방법을 사용하였다. 본 연구에서는 도시 내 차량의 실제 이동 데이터를 사용해 속도와 위치 표현 방법이 LSTM을 통한 차량 위치 예측에 미치는 영향을 분석하였다.

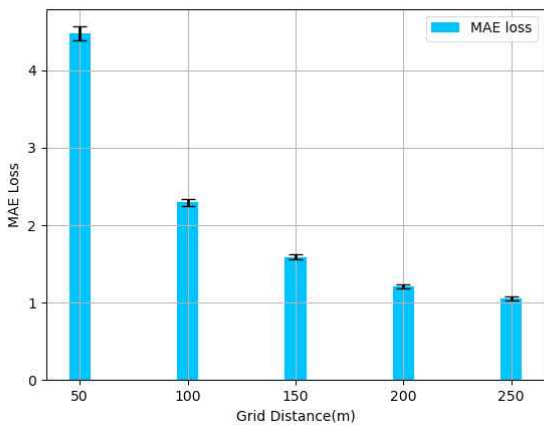
2. 차량 속도와 위치 표현법에 따른 경로 예측 분석

실험에 사용한 데이터는 샌프란시스코 택시 이동 경로 추적 데이터[7]로 차량별 위치는 위도, 경도로 표시되었고 표시된 타임스탬프가 함께 기록되어 있

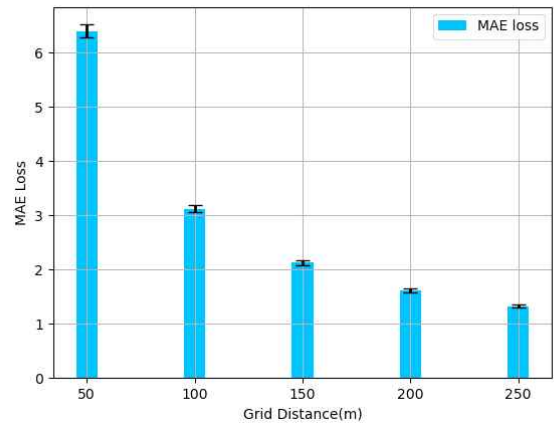
다. 위치가 기록된 시간 간격이 일정하지 않아 본 논문에서는 시간 간격을 60초로 동일하게 처리하였고, 총 이동 시간은 9분으로 하였다. 차량들의 평균 이동 속도는 약 16km/h이다. 이동 범위는 가로, 세로 모두 2.5km 반경 이내로 제한하였다. 해당 공간 내 공간 구분을 위한 격자 지도는 작게는 50m, 크게는 250m의 간격을 가지도록 설계하였고 차량의 위도, 경도로 표시된 위치 데이터는 2차원의 정수 좌표로 처리하였다.

차량 경로 예측 모델로는 LSTM을 사용하였다. LSTM은 주로 시계열 데이터를 다루기 위해 사용하는 딥러닝 기반 알고리즘으로 RNN과 비슷하지만 셀 내부에 게이트를 추가했다는 점이 다르다. 이 게이트들을 통해 현재 셀 정보를 다음 셀로 전달하는 과정을 제어하며 장단기 메모리를 학습하기 때문에 단기 메모리만 기억하는 RNN보다 과거 데이터를 효과적으로 기억한다. 본 논문에서는 자동차의 현재와 과거 이동 경로를 통해 미래 경로를 예측하는 과정이 필요하여 LSTM을 예측 모델로 선정하였다.


샌프란시스코 택시 데이터를 기반으로 차량 이동 속도가 평균적으로 [12, 16, 20]km/h인 차량 데이터를 사용하여 각각 실험하였다. 차량의 위치 표현 방법인 격자 간격은 [50, 100, 150, 200, 250]m로 다르게 적용하였다.



(그림 1) 평균 속도 12km/h인 환경에서 차량 경로 예측 오차




(그림 2) 평균 속도 16km/h인 환경에서 차량 경로 예측 오차




(그림 3) 평균 속도 20km/h인 환경에서 차량 경로 예측 오차

그림 1, 그림2, 그림 3은 각각 평균 속력이 12km/h, 16km/h, 20km/h인 상황에서 실제 차량의 경로와 예측 경로 간 평균 절대 오차(Mean Absolute Error, MAE)를 계산한 그래프이다. 모든 실험 시나리오에서 격자 간격이 증가하면 오차가 줄어드는 것을 확인하였다. 이는 격자 간격이 커지면 비교적 넓은 공간을 같은 위치라고 계산하여 실제값과 예측값 사이의 오차가 감소하기 때문이다. 반면에 속력이 감소하면 경로 예측 MAE가 줄어드는 모습을 보인다. 속력이 줄어들면 차량 위치의 변화량이 작아져 비교적 높은 성능의 결과를 보였다.



(그림 4) 평균 속도 12km/h, 격자 간격 50m 환경에서 차량 경로예측 결과



(그림 5) 평균 속도 20km/h, 격자 간격 250m 환경에서 차량 경로예측 결과

그림 4는 격자 간격 크기가 50m인 환경에서 평균 속도 12km/h 차량 중 하나의 이동 경로를, 그림 5는 격자 간격 크기가 250m인 환경에서 평균 속도 20km/h 차량 중 하나의 이동 경로를 예측한 결과이다. 모두 실제 차량의 이동 경로와 예측한 결과가 유사함을 확인할 수 있다.

3. 결론

본 논문에서는 차량의 이동 속도와 차량의 위치 표현 방법이 LSTM 기반 차량 경로 예측에 미치는 영향을 분석하였다. 차량이 평균 12km/h 속도일 때 차량 위치를 표현한 격자 간격이 커지면 예측 경로의 MAE가 커졌고 최대 약 4.2배 차이를 보였다. 차량 평균 속력이 16km/h일 때 격자 간격 크기에 따라 최대 4.8배, 평균 속력이 20km/h일 때는 최대 4.9배 차이가 발생했다. 속력이 작을수록 예측 오차가 감소했는데 격자 간격 50m를 기준으로 각 속도 사이에서 평균 1.4배 차이가 발생하였다. 이 연구를 바탕으로 사용자의 특성과 지역적 성격을 고려하여 보다 정확한 차량 경로 예측 방법에 대한 연구로 확장

할 예정이다.

사사문구

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 ICT혁신인재4.0 사업과 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행되었음 (IITP-2022(2022)-RS-2022-00156299, No. 2021R1F1A1047113).

참고문헌

[1] F. Yang, S. Wang, J. Li, Z. Liu and Q. Sun, "An Overview of Internet of Vehicles," in China Communications, vol. 11, no. 10, pp. 1-15, 2014

[2] S. H. Park, B. Kim, C. M. Kang, C. C. Chung and J. W. Choi, "Sequence-to-Sequence Prediction of Vehicle Trajectory via LSTM Encoder-Decoder Architecture," 2018 IEEE Intelligent Vehicles Symposium (IV), pp. 1672-1678, Changshu, China, June, 2018

[3] Graves, Alex. "Long short-term memory." Supervised sequence labelling with recurrent neural networks, 37-45, 2012

[4] L. Lin, W. Li, H. Bi and L. Qin, "Vehicle Trajectory Prediction Using LSTMs with Spatial - Temporal Attention Mechanisms," in IEEE Intelligent Transportation Systems Magazine, vol. 14, no. 2, pp. 197-208, 2022

[5] A. Ip, L. Irio and R. Oliveira, "Vehicle Trajectory Prediction based on LSTM Recurrent Neural Networks," 2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring), pp. 1-5, Helsinki, Finland, 2021

[6] L. Zhao, Y. Liu, A. Y. Al-Dubai, A. Y. Zomaya, G. Min and A. Hawbani, "A Novel Generation-Adversarial-Network-Based Vehicle Trajectory Prediction Method for Intelligent Vehicular Networks," in IEEE Internet of Things Journal, vol. 8, no. 3, pp. 2066-2077, 2021

[7] "The epfl/mobility dataset (v. 2009-02-24)", CRAWDDAD. lasted modified Feb 24, 2009, accessed Sep 1, 2022, <https://crawdad.org/epfl/mobility/20090224/>