

딥러닝 모델 기반 보행자 GPS 경로 예측 시스템 연구

윤승원⁰, 이원희*, 이규철*

⁰충남대학교 컴퓨터융합학부,

*충남대학교 컴퓨터융합학부

e-mail: yoonoch11@gmail.com⁰, k334lwh@gmail.com*, kclee@cnu.ac.kr*

A study on the Deep Learning model-based pedestrian GPS trajectory prediction system

Seung-Won Yoon⁰, Won-Hee Lee*, Kyu-Chul Lee*

⁰Dept. of Computer Science, Chung-Nam National University,

*Dept. of Computer Science, Chung-Nam National University

● 요약 ●

본 논문에서는 딥러닝 모델 기반 보행자의 GPS 경로를 예측하는 시스템을 제안한다. 다양한 경로 예측 방식들 중 본 논문은 GPS 데이터 기반 경로 예측 연구이다. 시계열 데이터인 보행자의 GPS 경로를 학습하여 다음 경로를 예측하도록 하는 딥러닝 모델 기반 연구이다. 본 논문에서는 보행자의 GPS 경로를 딥러닝 모델이 학습할 수 있도록 데이터 구성 방식을 제시하였으며, 예측 범위에 큰 제약이 없는 예측 딥러닝 모델을 제안한다. 본 논문의 딥러닝 모델에 적합한 파라미터들을 제시하였으며, 우수한 예측 성능을 보이는 결과를 제시한다.

키워드: 딥러닝 모델(Deep learning model), 경로 예측(trajectory prediction), 보행자(pedestrian)

I. Introduction

보행자의 경로는 관측치가 시간적 순서를 가지는 시계열 데이터이다. 시계열 데이터는 이전 데이터가 다음 데이터에 영향을 끼치는 종속적인 관계이다. 이전 경로가 다음 경로 위치에 영향을 끼치는 것이다. 즉, 이전 경로의 패턴 등을 파악하고 학습하면 다음 경로 예측이 가능하다는 것이다. 본 연구에서는 이전 경로들을 학습하여 다음 경로 위치를 예측하는 딥러닝 모델을 생성하였다.

보행자의 경로를 예측하는 연구는 보행자들에게 많은 도움을 줄 수 있다. 위험상황, 위험객체 및 인물과의 접촉 여부 등을 예측할 수 있어 보행자의 위험 정도를 파악할 수 있으며, 위험정도에 따라 알람 등을 통해 다양한 사건 사고 등을 예방할 수 있다. 또한 보행자들의 경로들을 학습 및 예측을 통해 보행자들의 생활 패턴을 파악하여 다양한 마케팅 비즈니스에 접목 할 수 있어, 기업과 보행자들에게 많은 편의들을 제공할 수 있다. 또한 해당 연구 메커니즘을 발전하여 보행자 뿐 아니라 자동차, 무인기 등의 충돌방지 시스템 개발 또한 가능하다.

보행자의 경로를 예측하는 연구는 활용하는 데이터에 따라 영상을 통한 예측과 GPS 데이터를 통한 예측으로 나눌 수 있다. 본 연구팀은 예측 범위에 제한 없이 가장 넓은 범위의 보행자 경로를 예측할 수 있는 GPS 데이터를 통한 보행자 경로 예측 연구를 진행하였다.

본 연구팀은 경로 예측을 위하여 다음과 같은 방법을 제시한다. 이전 경로의 범위를 'Look_back' 이라 지정하였고, 해당 Look_back 길이만큼을 딥러닝 모델이 학습하도록 하였다. 학습 이후 경로를 예측하는 위치를 바로 다음 위치가 아닌 'Forward_length' 만큼의 길이를 설정하여 해당 길이 이후를 예측하도록 하였다. 그리하여 경로 예측 위치 범위를 늘리는 것이 가능하였다. 본 연구팀은 우수한 성능의 보행자 경로 예측 딥러닝 모델을 생성하였으며, 학습 방법 또한 제시한다.

본 논문의 구성은 2장에서는 경로 예측 관련연구와 그 배경에 대해 제시하고, 3장에서는 연구팀의 데이터 구성 및 딥러닝 모델에 대해 제시하고, 4장에서는 결론 및 향후 연구를 제시한다.

II. Preliminaries

1. Related works

1.1 영상기반 경로 예측 딥러닝 모델 연구

딥러닝 모델을 통하여 보행자의 경로를 예측하는 연구는 어떤 데이터를 활용하느냐에 따라 크게 두가지로 구분된다. 영상을 통한 예측과 GPS를 통한 예측이다. 영상기반 경로 예측 연구는 ETH, UCY, Stanford Drone Dataset, Birds-eye view 오픈데이터 셋 위주로 연구가 이루어진다. 보행자들을 Social pooling layer로 연결하여 다음 경로를 예측하는 Social-LSTM 연구[1], 시공간적 구조를 파악하여 radar도 함께 고려하여 보행자의 경로를 예측하는 연구[2] 등이 있다. 해당 영상기반 연구들은 카메라 프레임 안에서 객체를 인식하여 해당 객체가 다음에 어느 위치로 진행 할 것인지를 예측하는 연구이다. 하지만, 객체의 경로 예측 범위는 카메라를 벗어날 수 없어, 넓은 범위의 객체 경로 예측이 불가능하다는 제약점이 있다.




Fig. 1. 영상기반 경로 예측 연구 예시

1.2 GPS 기반 경로 예측 딥러닝 모델 연구

GPS 데이터를 통한 경로 예측 딥러닝 모델 연구는 보행자의 경로 GPS 데이터를 기반으로 다음 보행자의 위치를 GPS 좌표로 예측하는 연구이다. GPS 기반 연구는 GPS 데이터를 어떤 방식으로 모델에 입력하는지에 따라 두 가지로 분류할 수 있다. 먼저, 지도를 그리드(grid)화 하여 해당 경로 GPS 값을 그리드화 된 값으로 매칭하여 모델에 입력하는 방식이다, 해당 방법은 복잡한 GPS 값들을 그리드된 지도의 id 값으로 단순하게 처리하여 모델의 학습이 수월하다는 장점이 있으나, 보행자가 다니는 지도에 대해 전부 그리드화를 진행해야하는 제약이 존재한다. 대표 연구로는 지도를 [Fig. 2]와 같이 보르누이 다이어그램 방식으로 그리드화 하여 딥러닝 모델에 입력한 연구가 있다[3].




Fig. 2. 지도 그리드를 통한 경로 예측 연구

이외 다른 GPS 기반 연구는 GPS 데이터 경로 자체를 학습하고 예측하는 연구이다. 해당 연구는 지도 그리드를 통한 연구보다는 딥러닝 입력이 복잡하여 딥러닝 모델 학습에 어려움이 있을 수 있지만, 우수한 컴퓨팅 파워 기반의 딥러닝 모델을 통하여 준수한 예측 성능을 보일 수 있다. GPS 경로 데이터 자체를 활용하기에 데이터 전처리에 많은 비용이 들지 않으며, 다른 연구방법들과 달리 경로 예측 범위에 제약을 받지 않는다. 본 연구는 제약없는 보행자의 넓은 범위의 경로를 예측하기 위하여 해당 GPS 자체를 학습하는 예측 방식을 적용하여 연구를 진행하였다.

III. The Proposed Scheme

1. Dataset

1.1 데이터 셋

본 연구에서 활용한 데이터 셋은 마이크로소프트 연구소가 수집한 GeoLife(Ver.1.3) [4] 오픈 데이터 셋이다. 해당 데이터 셋은 182명의 대상자들의 경로로 이루어져있으며, 5년 동안 수집된 경로 데이터 셋이다. 총 17,621개의 경로 데이터 셋으로 이루어져 있다. 본 연구팀은 해당 데이터 셋들 중 보행자의 데이터이며 온전히 경로 데이터 셋이 끊기지 않은 데이터를 선별하여 해당 딥러닝 모델에 학습데이터로 활용하였다. 해당 모델 학습을 위해 선정한 데이터는 2초 단위로 수집된 3,185개의 GPS 좌표(위도,경도)들로 이루어진 경로 데이터 셋이다.

1.2 학습 및 성능측정을 위한 데이터 셋 설정

본 연구진은 해당 경로 데이터 학습을 위하여 경로 데이터 셋의 구성을 ‘Look_back’ 과 ‘Forward_length’ 개념을 제시하여 구성하였다. 딥러닝 모델이 일정 단위만큼을 학습하도록 하기 위하여, 일정 단위만큼의 경로 데이터를 학습데이터들로 구성되도록 하였다. 여기서 일정 단위가 Look_back의 개념이다. Look_back 만큼의 경로 데이터가 X데이터가 되는 것이다. 딥러닝 모델이 일정 단위만큼의 X데이터를 학습 후 이후 경로를 예측하도록 해야 하는데, 마지막 X데이터에서부터 Forward_length 이후의 GPS 좌표를 Y데이터로 설정하였다. 이러한 개념으로 [Fig.3]과 같이 딥러닝 모델의 학습데이터 셋을 구성하였다. 딥러닝 모델 학습이 된 이후 성능평가를 위해 테스트 데이터를 생성하였는데, 테스트 데이터 구성 또한 같은 개념으로 생성하였다. 학습데이터의 마지막 경로 이후 데이터들을 테스트 데이터로 구성하였으며, 학습된 모델이 테스트 셋의 X 데이터를 보고 Forward_length 이후의 위치를 예측하도록 하였다. 테스트 데이터는 [Fig.4]와 같이 구성하였다.




Fig. 3. 본 연구팀 예측 모델의 학습 방법

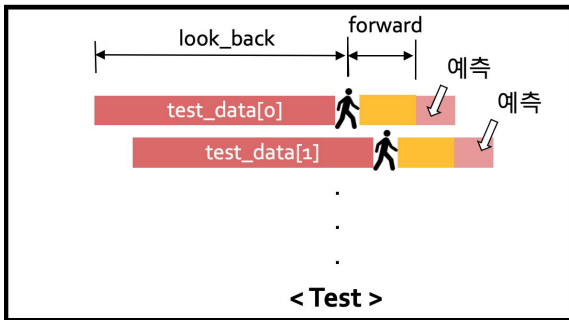


Fig. 4. 본 연구팀 예측 모델의 성능 측정 방법

hidden-state에 cell-state[Fig.6]를 추가하여 핵심적인 문제를 해결하였다.

본 연구 딥러닝 모델의 최적화 함수는 아담(Adam) 최적화함수를 활용하였다. 아담 최적화 함수는 그래디언트가 커져도 스텝사이즈는 어느정도 정해져있어 어떤 목적함수를 사용한다고 하더라도 안정적인 최적화를 위한 하강이 가능하도록 하기에 대부분의 딥러닝 연구들에서 활용되고 있다. 손실함수는 실제 GPS 좌표와 모델이 예측한 좌표와의 거리를 최소화 하기위해 평균제곱오차(MSE)를 활용하였다. 평균제곱오차는 예측모델의 정확성 측정 방법으로 주로 활용된다.




Fig. 5. LSTM 딥러닝 모델

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

Fig. 6. LSTM 딥러닝 모델의 Cell state 수식

2. Deep Learning Model

2.1 모델 입력을 위한 GPS 데이터 셋 스케일링

본 연구진은 GPS 경로 데이터 셋을 모델에 입력하기 위하여 최대-최소 스케일러(MinMaxScaler)를 적용하였다. 최대-최소 스케일러는 데이터 셋의 분포는 그대로 적용되 모든 데이터 셋들을 0과 1 사이에 있도록 한다. 해당 스케일러를 통하여 데이터의 오버플로우 및 언더플로우를 방지하여 딥러닝 모델의 최적화과정에서의 안정성 및 수렴 속도를 향상시켜 모델의 학습을 돕는다. 그리하여 본 연구팀은 복잡한 GPS 데이터 셋을 최대-최소 스케일러를 적용하여 모델이 경로를 학습하는데 도움이 되도록 하였다.

2.2 경로 예측 딥러닝 모델 구성

경로 데이터와 같은 시계열 데이터 예측은 바로 이전의 데이터를 기반으로 예측하는 Hidden Markov 모델 등과 같은 수학적 확률 예측 모델이 주로 활용되었다[5]. 그러나 이런 수학적 확률 모델은 많은 이전 데이터를 학습 할 수 없는 문제점이 있다. 딥러닝 모델은 확률 모델들 보다 더 많은 이전 데이터들을 학습할 수 있으며, 비선형적 활성화함수들을 통해서 기존 해결할 수 없던 문제들을 해결할 수 있도록 한다. 본 연구팀은 시계열 데이터인 경로 데이터를 예측하기 위해서 LSTM(Long Short Term Model)[6]을 개발하였다. LSTM [Fig.5] 모델은 시계열 모델에 특화된 RNN(Recurrent-Neural Network) 모델의 기울기 소실 문제(vanishing gradient) 문제를 어느 정도 해결한 모델이다. 기울기 소실 문제는 이전 데이터와 그 데이터를 사용하는 지점의 거리가 멀 경우 이전 데이터의 그래디언트가 크게 줄어 학습능력이 크게 줄게 되는 문제이다. LSTM 모델은 이러한 문제를 RNN의

2.3 딥러닝 모델 초매개변수 구성

본 연구 모델은 수많은 실험들을 거쳐 다음과 같은 최적의 초매개변수를 구성하였다. 딥러닝 모델은 3개의 LSTM 레이어로 구성하였으며, 전체 학습 횟수를 나타내는 에폭(Epoch)은 100, 학습 개수 단위인 배치(Batch)사이즈는 70으로 설정하였다. 총 3,185개의 경로 데이터들을 8:2 비율로 학습과 테스트 데이터를 구성하였다. 본 연구의 실험은 Intel(R) Core(TM) i7-7700 CPU @ 3.60GHz, 32GB RAM, GeForce GTX 1080 Ti GPU 환경에서 진행하였다.

3. Evaluation

3.1 본 경로 예측 모델의 성능 제시

본 연구진은 최적의 Look_back 길이를 찾기 위해 먼저 Forward_length를 0으로 고정시키고, 다양한 실험을 통해서 해당 경로 예측 딥러닝 모델에 적합한 look_back 길이는 10 임을 확인하였다. look_back 길이가 10일 때 테스트 데이터를 예측한 정확도는 98.31이며, 평균제곱오차(MSE)는 0.011676의 우수한 예측 성능을 보임을 확인하였다. Look_back 길이를 계속해서 늘려가며 성능을 측정하였지만, 정확도는[Table 1]과 같이 98 이상이 나오는 우수한 경로 예측 딥러닝 모델임을 알 수 있다. 이후 Forward_length 증가에 따른 성능 또한 평가하였다. Forward_length는 앞서 설명하였듯, 최종 학습 지점으로부터 해당 길이 이후의 위치를 예측하는 것이다. 본 연구의 모델은 [Table 2]와 같은 성능을 보였으며, 예상과 같이 Forward_length가 길어질수록 예측 성능은 감소하였으나, 97, 96의 정확도를 보이며 우수한 예측성능 모델임을 증명하였다. 즉, 본 모델은

보행자의 현재까지 위치를 기반으로 바로 다음 위치가 아닌 일정 시간 이후의 위치 또한 우수한 성능으로 예측함을 알 수 있다.

Table 1. Look_back 길이에 따른 딥러닝 모델 성능표

look_back	학습시간(초)	MSE	Accuracy(%)
10	53.9189	0.011676	98.31
30	120.9739	0.011952	98.23
50	211.2159	0.012490	98.15
70	292.7043	0.013055	98.06

Table 2. Forward_Length 별 딥러닝 모델 성능표
(look_back=10)

Forward_Length	학습시간(초)	MSE	Accuracy(%)
5	80.9846	0.019315	97.83
10	80.3256	0.021425	96.70
15	77.3833	0.022491	96.53

IV. Conclusions

본 연구는 딥러닝 모델 기반 보행자의 GPS 경로를 예측하는 연구이다. 본 연구는 딥러닝 모델 생성을 위해 경로 데이터를 Look_back과 Forward_length 개념을 생성하여 학습, 테스트 데이터를 구성하였으며, 우수한 예측 성능을 보이는 딥러닝 모델을 생성하였다. 본 연구의 보행자 경로 예측 모델은 현재 시점까지의 학습된 경로를 기반으로 일정 시간 이후에 있을 위치까지도 예측할 수 있는 모델이다.

본 연구진은 해당 연구를 더욱 발전하여 다양한 이동수단의 경로 예측 딥러닝 연구를 진행할 것이며, 그에 적합한 Look_back, Forward_length를 찾는 실험을 진행할 것이다. 또한 경로 예측에 더욱 적합한 손실함수에 관한 연구를 진행할 예정이다.

ACKNOWLEDGEMENT

본 과제(결과물)는 2022년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다. (2021RIS-004)

REFERENCES

- [1] Alahi, Alexandre, et al. "Social lstm: Human trajectory prediction in crowded spaces." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [2] Bock, Julian, et al. "Self-learning Trajectory Prediction with Recurrent Neural Networks at Intelligent Intersections." VEHITS. 2017.
- [3] Duives, Dorine C., Guangxing Wang, and Jiwon Kim. "Forecasting pedestrian movements using recurrent neural networks: An application of crowd monitoring data." Sensors19.2 (2019): 382.
- [4] Zheng, Yu, Xing Xie, and Wei-Ying Ma. "GeoLife: A collaborative social networking service among user, location and trajectory." IEEE Data Eng. Bull. 33.2 (2010): 32-39.
- [5] Roberts, Stephen, et al. "Gaussian processes for time-series modelling." Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences 371.1984 (2013): 20110550.
- [6] Sherstinsky, Alex. "Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network." Physica D: Nonlinear Phenomena 404 (2020): 132306