

비행체의 궤적 예측을 위한 순환 신경망 기반 기법들의 정량적 비교 평가에 관한 연구

Objective Evaluation of Recurrent Neural Network Based Techniques for Trajectory Prediction of Flight Vehicles

이 창 진*, 박 인 희*, 정 찬 호**★

Chang Jin Lee*, In Hee Park*, Chanho Jung**★

Abstract

In this paper, we present an experimental comparative study of recurrent neural network based techniques for trajectory prediction of flight vehicles. We defined and investigated various relationships between input and output under the same experimental setup. In particular, we proposed a relationship based on the relative positions of flight vehicles. Furthermore, we conducted an ablation study on the network architectures and hyperparameters. We believe that this comprehensive comparative study serves as a reference point and guide for developers in choosing an appropriate recurrent neural network based techniques for building (flight) vehicle trajectory prediction systems.

요 약

본 논문에서는 비행체의 궤적 예측에 적절한 순환 신경망 기반 기법을 탐구하기 위하여 정량적인 비교 평가 연구를 수행하였다. 이를 위해 본 논문에서는 비행체의 궤적 예측 작업을 수행하기 위한 다양한 입력 및 출력 관계들을 정의하고 동일한 실험 환경에서 비교 평가하였다. 특히 비행체 위치의 상대값 기반 입출력 관계를 제안하여 비행체의 궤적 예측에 적합함을 보였다. 또한 비행체 궤적 예측에 효율적인 네트워크 구조 및 하이퍼파라미터를 결정하기 위한 다양한 ablation study(비교 실험)를 진행하였다. 본 논문에서 제시된 정량적 비교 평가 결과는 비행체의 궤적 예측을 위해 순환 신경망 기반 기법을 이용하거나 비행체의 궤적 예측에 특화된 딥러닝 기법을 연구하고자 하는 연구자 및 개발자들에게 실질적인 도움이 될 것으로 예상된다.

Key words : Flight vehicles, Trajectory prediction, Recurrent neural network, Long short-term memory network, Objective evaluation

* The 5th R&D Institute-1st Directorate, Agency for Defense Development, Korea. Senior Engineer.

** Dept. of Electrical Engineering, Hanbat National University, Korea. Associate Professor.

★ Corresponding author

E-mail : peterjung@hanbat.ac.kr, Tel : +82-42-821-1095
Manuscript received Aug. 19, 2021; revised Sep. 13, 2021; accepted Sep. 15, 2021.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

움직이는 사람 또는 물체의 궤적을 예측하는 작업은 사람 또는 물체의 상태를 인식하는 데 있어 핵심적인 작업들 중 하나이다[1-3]. 학계 및 산업계에서는 최근 딥러닝 기술의 발전을 발판으로 다양한 “순환 신경망 기반 궤적 예측 방법”들에 대한 연구를 이전보다 더욱 활발하게 진행하고 있다. 본 논문에서는 “비행체”의 궤적을 예측하는 작업에 집중한다. 비행체의 궤적을 예측하기 위해 추적레이더, 광학장비 및 텔레메트리 등이 이용되어 왔다

[4], [5]. 본 논문에서는 텔레메트리 기반 비행체의 “위도 및 경도” 궤적 예측에 집중하며, 사전에 정의된 목적에 따라 설계한 비행체의 궤적에 대해 분석하는 것을 목표로 한다. 비행체의 궤적 예측은 비행체의 성능 평가를 위해 반드시 필요한 핵심적인 기술이다. 그러나 이러한 중요성에도 불구하고 비행체의 궤적 예측에 초점을 둔 순환 신경망 기반 궤적 예측 방법들의 정량적인 비교 평가에 대한 연구는 없었다[6].

본 논문에서는 이러한 기존연구들의 미흡한 점을 보완하기 위하여 비행체의 궤적 예측에 적절한 순환 신경망 기반 기법을 탐구하기 위한 정량적인 비교 평가 연구를 수행하였다. 본 논문에서는 이를 위해 비행체의 궤적 예측 작업을 수행하기 위한 다양한 입출력 관계들을 정의하고 정량적으로 비교 평가하였다. 특히 비행체의 위도 및 경도 좌표의 상대값 기반 입출력 관계가 절대값 기반 관계보다 비행체의 궤적 예측에 적합함을 보였다. 또한 비행체 궤적 예측에 효율적인 “순환 신경망 네트워크 구조 및 하이퍼파라미터”를 결정하기 위한 다양한 비교 실험을 진행하였다. 본 논문에서 제시하는 정량적 비교 평가 결과는 비행체의 궤적 예측 시스템을 연구·개발하는 연구자 및 개발자들에게 실질적인 큰 도움을 제공할 것으로 판단된다.

II. 비행체의 궤적 예측을 위한 순환 신경망 기반 기법들

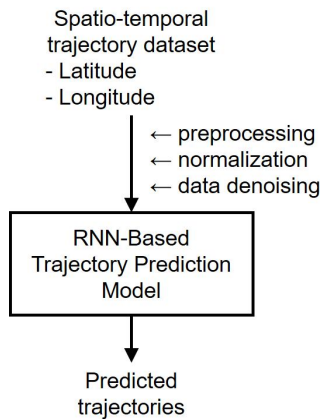


Fig. 1. Pipeline for trajectory prediction of flight vehicles.
그림 1. 비행체 궤적 예측 파이프라인

본 논문에서는 비행체의 궤적 예측을 위한 “베이스라인” 네트워크 구조(baseline network architecture)

로써 2차원 장단기 메모리(two-dimensional long short-term memory)[7]를 이용한다. 우리의 최근 이전 연구[8], [9]에서 우리는 2차원 장단기 메모리가 비행체의 궤적 예측 문제보다 더욱 복잡하고 어려운 선박의 궤적 예측 문제를 해결하는 데 있어 효율적인 순환 신경망 구조임을 보였다. 본 논문에서 초점을 두는 사전에 정의된 목적에 따라 설계한 비행체와 달리 선박의 경우 목적지의 위도 및 경도 좌표를 알 수 없기 때문이다[8], [9]. 그림 1은 비행체 궤적 예측 파이프라인을 보여준다. 그림 2는 비행체의 궤적 예측을 위한 2차원 LSTM 기반 베이스라인 네트워크 구조를 보여준다. 그림 2에서 FFN (feed forward network)은 순방향 신경망을 나타내며 본 논문에서는 FC(fully connected) layer를 이용하였다. x_t 는 시간 t 에서 비행체의 위도 또는 경도 좌표를 나타내며, y_t 는 시간 $t+1$ 에서 비행체의 위도 또는 경도 좌표를 나타낸다. 본 논문에서는 비행체의 궤적 예측을 위한 순환 신경망 기반 기법들의 정량적 비교 평가를 위해 다음과 같은 손실 함수를 이용한다.




Fig. 2. Baseline network structure based on LSTM.
그림 2. 비행체의 궤적 예측을 위한 2차원 LSTM 기반 베이스라인 네트워크(레이어 개수 3인 경우)

$$L = (y_{t+1} - \hat{y}_{t+1})^2 \tag{1}$$

식 (1)에서 y_{t+1} 은 실제(ground truth) 비행체 좌표를 나타내며, \hat{y}_{t+1} 은 순환 신경망에 의해 예측된 비행체 좌표(위도 또는 경도)를 나타낸다. 총 100 epoch에 걸쳐 학습을 진행하였으며 초기 학습률은 0.1로 설정하였다. 안정적인 학습을 위해 학습률을 50 epoch에서 0.01로 감소시켰다.

III. 실험 결과: 정량적 비교 평가 결과

Table 1. Prediction error w.r.t. input and output.

표 1. 입출력 관계 변화에 따른 비행체 궤적 예측 오차

Method	Avg. error
Baseline (absolute value-based)	0.1356
Difference between absolute values-based [8]	0.0437
Acceleration value-based [9]	0.1396
Relative value-based	0.0053

Table 2. Ablation study.

표 2. 비교 실험 결과

2.1. [모듈 변화에 따른 비행체 궤적 예측 오차]

Method	Avg. error
RNN-based	0.0178
LSTM-based [10]	0.0053
GRU-based [11]	0.0082

2.2. [스택 형태 심층 순환 신경망에서 레이어 개수(number of layers) 변화에 따른 비행체 궤적 예측 오차]

Method	Avg. error
1	0.0124
2	0.0064
3	0.0053
4	0.0094
5	0.0168

2.3. [상대값 범위 변화에 따른 비행체 궤적 예측 오차]

Method	Avg. error
[0, 1]	0.0053
[0, 100]	0.0054
[0, 10000]	0.0056

2.4. [위도/경도 동시 학습 여부에 따른 위도 예측 오차]

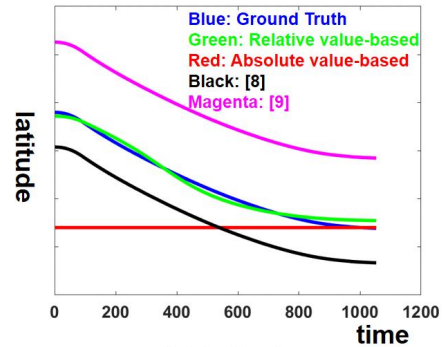
Method	Avg. error
training only with latitude	0.0078
training with latitude and longitude	0.0076

2.5. [위도/경도 동시 학습 여부에 따른 경도 예측 오차]


Method	Avg. error
training only with longitude	0.0028
training with latitude and longitude	0.0031

2.6. [리샘플링 여부에 따른 비행체 궤적 예측 오차]

Method	Avg. error
without resampling	0.0053
with resampling	0.0054



(a) latitude



(b) longitude

Fig. 3. Examples of prediction results. (blue: ground truth, green: relative value-based, red: baseline (absolute value-based), black: difference between absolute values-based [8], magenta: acceleration value-based [9]), (x-axis: time, y-axis: (a) latitude, (b) longitude).

그림 3. 예측 결과의 예 (파란색: 실제 궤적, 녹색: 상대값 기반, 빨간색: 베이스라인 (절대값 기반), 검은색: 절대값 차이 기반 [8], 자홍색: 가속도 기반 [9]), (x축: 시간, y축: (a) 위도/(b) 경도)

본 논문에서는 정량적 비교 평가를 위해 수집된 총 18개의 비행체 이동 궤적 데이터를 이용하였다. 각 궤적 데이터는 발사시점부터 탄착시점까지 시간에 따른 위도 및 경도 좌표로 구성되어 있다. 성능 측정 지표로써 궤적 예측에서 일반적으로 많이 사용되는 MAE(mean absolute error)를 이용하였다. 표 1은 입출력 관계 변화에 따른 비행체 궤적 예측 오차를 나타낸다. 위도 및 경도 좌표의 절대값 기반 예측 방법을 베이스라인으로 설정하였다. 또한 순환 신경망 기반 선박 궤적 예측에서 높은 성능을 제공하였던 절대값의 차이 기반 예측 방법 [8] 및 가속도 기반 예측 방법 [9]을 비행체 궤적 예측에 적용하여 실험하였다. 본 논문에서는 비행체 위치의 상대값 기반 예측 방법을 제안한다. 상대값 기반 예측 방법에서는 비행체의 발사지점 및 탄착지점의 위도 및 경도 좌표를 기준으로 궤적 내 위도 및 경

도 좌표의 절대값을 정규화한다(예: [0, 1], [0, 100] 등). 정규화를 통한 상대값 기반 예측이 가능한 이유는 본 논문에서 분석하고자 하는 비행체의 경우 사람, 차량, 선박 등과는 달리 궤적의 시작지점 및 종료지점이 사전 정보로 주어지기 때문이다. 본 논문에서는 이러한 비행체 관련 도메인 지식(domain knowledge)을 적극적으로 활용한 상대값 기반 예측 방법에 대해 실험하고 위에서 언급한 기존 방법들과의 정량적인 비교 평가를 실시하였다. 표 1에서 보는 바와 같이 상대값 기반 예측 방법이 기존 방법들보다 비행체 궤적 예측에 보다 적합한 방법임을 알 수 있다. 표 1 및 표 2에서는 위도 예측 오차 및 경도 예측 오차의 평균값을 보여준다(표 2.4 및 표 2.5 제외). 표 2에서는 상대값 기반 예측 방법을 베이스라인으로 설정한 후 비행체 궤적 예측에 효율적인 네트워크 구조 및 하이퍼파라미터를 결정하기 위해 수행한 다양한 비교 실험 결과를 보여준다. 2차원 심층 순환 신경망을 구성하는 모듈 변화, 레이어 개수 변화에 따른 예측 오차뿐만 아니라 상대값 범위 변화, 위도/경도 동시 학습 여부에 따른 예측 오차를 보여준다. 마지막으로 좌표 데이터 수신 시간 간격이 불규칙적인 점을 고려하여 데이터 수신 시간이 일정하도록 리샘플링하여 비교 실험하였다.

IV. 결론

본 논문에서는 비행체의 궤적 예측에 적합한 순환 신경망 기반 기법을 탐구하기 위하여 다양한 정량적 비교 평가 연구를 수행하였다. 비교 평가 결과는 비행체 궤적 예측 시스템을 연구·개발하는 연구자 및 개발자들에게 큰 도움을 제공할 것으로 판단된다.

References

[1] T. Jin, "Tracking of Person Walking Pattern and Trajectory Following with 2D Laser Scanner," *The Transactions of the Korean Institute of Electrical Engineers*, vol.67, no.7, pp.903-909, 2018. DOI: 10.5370/KIEE.2018.67.7.903

[2] S. Choi, J. Kim, H. Yu, D. Ka, and H. Yeo, "Deep-learning Based Urban Vehicle Trajectory Prediction," *Journal of Korean Society of Transportation*, vol.37, no.5, pp.422-429, 2019.

DOI: 10.7470/jkst.2019.37.5.422

[3] M. Gao, G. Shi, and S. Li, "Online prediction of ship behavior with automatic identification system sensor data using bidirectional long short-term memory recurrent neural network," *Sensors*, vol.18, no.12, pp.4211-4226, 2018. DOI: 10.3390/s18124211

[4] S. Jang, "The Optical Tracking Method of Flight Target using Kalman Filter with DTW," *J. Adv. Navig. Technol.*, vol.25, no.3, pp.217-222, 2021. DOI: 10.12673/jant.2021.25.3.217

[5] J. H. Oh, S. H. Lee, B. H. Lee, and J.-I. Park, "Statistical Model of 3D Positions in Tracking Fast Objects Using IR Stereo Camera," *Journal of The Institute of Electronics and Information Engineers*, vol.52, no.1, 2015. <http://dx.doi.org/10.5573/ieie.2015.52.1.089>

[6] Z. Shi, M. Xu, Q. Pan, B. Yan and H. Zhang, "LSTM-based Flight Trajectory Prediction," *2018 International Joint Conference on Neural Networks (IJCNN)*, pp.1-8, 2018. doi: 10.1109/IJCNN.2018.8489734.

[7] A. Graves, S. Fernández, and J. Schmidhuber, "Multi-dimensional recurrent neural networks," *International conference on artificial neural networks*, pp.549-558, 2007.

[8] J. Kim, C. Jung, D. Kang, and C. J. Lee, "A New Vessel Path Prediction Method using Long Short-term Memory," *The Transactions of the Korean Institute of Electrical Engineers*, vol.69, no.7, pp. 1131-1134, 2020. DOI: 10.5370/KIEE.2020.69.7.1131

[9] J. Kim, C. Jung, D. Kang, and C. J. Lee, "A New Vessel Path Prediction Method Based on Anticipation of Acceleration of Vessel," *Journal of Institute of Korean Electrical and Electronics Engineers*, vol.24, no.4, pp.1176-1179, 2020. DOI: 10.7471/ikeee.2020.24.4.1176

[10] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol.9, no.8, pp.1735-1780, 1997. DOI: 10.1162/neco.1997.9.8.1735

[11] K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, "Learning phrase representations using RNN encoder-decoder for statistical machine translation," *arXiv preprint arXiv:1406.1078*, 2014.