

딥러닝 기반 LSTM 모형을 이용한 항적 추적성능 향상에 관한 연구

황진하* · 이종민

LIG시스템

Improvement of Track Tracking Performance Using Deep Learning-based LSTM Model

Jin-Ha Hwang* · Jong-Min Lee

LIG System

E-mail : delight6956@gmail.com / ggimssae@naver.com

요 약

항적추적 기술에 딥러닝 기반 LSTM(Long Short-Term Memory) 모형을 적용하는 연구로서 기존의 항적추적기술의 경우, 항공기의 등속, 등가속, 급기동, 선회(3D) 비행 등 비행 특성에 따른 칼만 필터 기반의 LMIPDA를 활용한 실시간 항적 추적 시 등속, 등가속, 급기동, 선회(3D) 비행 가중치가 자동으로 변경된다. 이러한 과정에서 등속 비행 중 급기동 비행과 같이 비행 특성이 변경될 때, 항적 손실 및 항적 추적 성능이 하락하여 비행 특성 가중치 변경성능을 향상시킬 필요성이 있다. 본 연구는 레이더의 오차 모델이 적용된 시뮬레이터의 Plot과 표적을 딥러닝 기반 LSTM(Long Short-Term Memory) 모형을 적용하여 학습시키고, 칼만 필터를 활용한 항적추적 결과와 딥러닝 기반 LSTM(Long Short-Term Memory) 모형을 적용한 항적추적결과를 비교함으로써 미리 비행 특성의 변경과정을 예측하여 등속, 등가속, 급기동, 선회(3D) 비행 가중치변경을 신속하게 함으로써 항적추적성능을 향상하기 위한 연구이다.

ABSTRACT

This study applies a deep learning-based long short-term memory(LSTM) model to track tracking technology. In the case of existing track tracking technology, the weight of constant velocity, constant acceleration, stiff turn, and circular(3D) flight is automatically changed when tracking track in real time using LMIPDA based on Kalman filter according to flight characteristics of an aircraft such as constant velocity, constant acceleration, stiff turn, and circular(3D) flight. In this process, it is necessary to improve performance of changing flight characteristic weight, because changing flight characteristics such as stiff turn flight during constant velocity flight could incur the loss of track and decreasing of the tracking performance. This study is for improving track tracking performance by predicting the change of flight characteristics in advance and changing flight characteristic weigh rapidly. To get this result, this study makes deep learning-based Long Short-Term Memory(LSTM) model study the plot and target of simulator applied with radar error model, and compares the flight tracking results of using Kalman filter with those of deep learning-based Long Short-Term memory(LSTM) model.

키워드

Tracking, Deep learning, Long short-term memory (LSTM), Flight characteristics, Kalman filter

I. 서 론

미국의 차세대 공중지배(NGAD) 전투기와 영국, 스웨덴, 이탈리아 등이 공동으로 개발 중인 템페스트

트(Tempest) 전투기와 같은 성능이 향상된 전투기가 2030년~2035년에 실전 배치를 앞두고 있다. 항공기의 성능향상에 따라 등속, 등가속, 급기동, 선회(3D) 비행 등 비행 특성의 최대한도가 늘어나고, 다양한 비행 특성이 가능해지고 있는 가운데 이러한 상황에 맞게 항적추적에 활용되는 알고리즘 또

* speaker

한 성능을 향상할 필요가 있다.

본 논문에서는 레이더의 오차 모델이 적용된 시뮬레이터를 활용하여, 레이더가 탐지한 Plot과 표적의 위치를 학습시켜 예측한 항적과 칼만 필터를 활용한 항적추적 결과를 비교한다. 저자는 특히 시계열 데이터를 처리하기 적합한 딥러닝 기반 LSTM(Long Short-Term Memory) 모델을 사용해 각 비행 특성을 예측하여 항적추적 알고리즘의 비행 특성 가중치를 적용한다.

II. 본 론

2.1. 방법론

본 논문에서 제안한 항적추적성능 향상을 위한 방법론은 Fig.1과 같다. 먼저 시뮬레이터에서 비행 특성별 레이더의 항공기 탐지 정보인 Plot과 표적의 위치정보를 수집한다. Plot과 표적은 LSTM(Long Short-Term Memory) 모델 훈련 데이터로 사용하여 예측한다. Plot만 사용하여 칼만 필터를 활용한 실시간 항적추적 알고리즘에 입력하여 항적 정보를 예측한다. LSTM(Long Short-Term Memory) 결과와 칼만 필터를 활용한 결과의 오차를 비교하여, 각 비행 특성별 가중치 적용 여부를 판단한다.

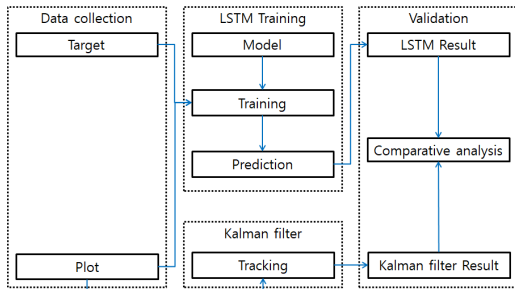


Fig 1: Methodology

2.2. 시나리오

레이더 탐지정보인 Plot과 표적을 실제와 유사하게 생성하기 위해 시뮬레이터(VirtualSim vsTASKER)에 오차 및 미탐지 모델이 적용된 장거리 레이더 26개, 근거리 레이더 4개, F15 전투기 1대를 사용한다. 시나리오는 Fig.2와 같다.

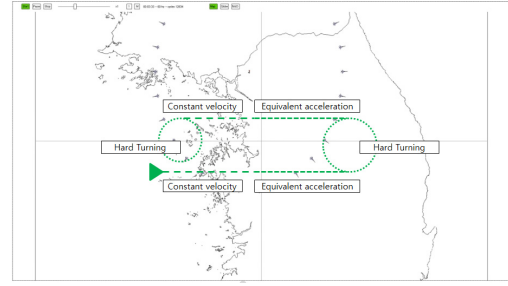


Fig 2: Scenario

2.3. 실험환경

실험환경은 LSTM과 칼만 필터가 각각 구축되었다. 특히 칼만 필터를 활용한 항적추적 알고리즘은 “자동화 방공체계 항적추적기술 개발사업”에서 개발된 능동추적기를 활용하였다. 구축된 사항은 Table.1과 같다.

Table. 1 Experimental environment

Sortation	LSTM	Kalman filter
Language	Python	C++
Library	TensorFlow 3.1	Linux GCC 4.8
OS	Windows 10	Linux CentOS 7.4
Tool	Google Colab	Eclipse

III. 실험 및 실험결과

3.1. 데이터 수집

3.1.1. Plot

Plot을 표준 레이더 감시자료 포맷인 ASTERIX (All purpose STructured Eurocontrol suRveillance Information eXchange)을 준수하여, 레이더의 좌표 및 탐지된 표적의 Range, Azimuth, Height를 대한민국 경기도 일대 기준의 Local 좌표로 변경한 자료와 탐지 시간을 활용한다. 레이더의 ARM 기준은 12초로 1개의 레이더당 12초에 한 번씩 탐지된 항공기의 SR Plot, SSR Plot 정보를 생성한다. 탐지된 형태는 Fig.3과 같다.




Fig 3: Plot

3.1.2. 표적

표적은 시나리오 시작 기준으로 1초에 한 번씩 대한민국 경기도 일대 기준의 Local 좌표와 생성 시간을 활용한다. 실제와 유사하게 실험하기 위해 항공기의 속도, 기종, 항공 경로와 같은 정보는 생성하지 않는다. 생성된 정보는 Fig.4와 같다.




Fig 4: Target

3.2. LSTM 훈련 및 예측

3.2.1. LSTM 모델

Plot과 표적을 학습하기 위해 LSTM모델의 시계열을 적용하여 4개의 레이어로 구성한다. 특히 Dense 레이어는 표적의 예측 위치 정보인 대한민국 경기도 일대 기준의 East, North, Up을 출력하기 위해 3으로 지정한다. 구축된 LSTM 모델은 Fig.5과 같다.

```

model = tf.keras.Sequential([
    tf.keras.layers.LSTM(units=64, return_sequences=True, input_shape=(trainFeature.shape[1], trainFeature.shape[2])),
    tf.keras.layers.LSTM(units=32, return_sequences=True, input_shape=(trainFeature.shape[1], trainFeature.shape[2])),
    tf.keras.layers.LSTM(units=16),
    tf.keras.layers.Dense(3)
])
    
```

Fig 5: LSTM Model

3.2.2. LSTM 학습

비행 특성의 변경 시점의 예측 결과를 출력하기 위해 Plot은 과거의 50개씩 중첩하여 학습데이터로 사용한다. 전체 데이터 중 80%는 훈련에 사용하고, 나머지 20%는 검증에 사용한다. 최대 1000회 학습을 기준으로 검증 손실 값이 20회 동안 향상되지 않으면 학습을 종료한다. 학습 결과는 Fig.6과 같다.

```

Epoch 1/1000
2/2 [-----] - 5s 1s/step - loss: 0.0263 - val_loss: 0.0210

Epoch 0001: val_loss improved from inf to 0.02101, saving model to model/tao_checkpoint.h5
Epoch 2/1000
2/2 [-----] - 0s 49ms/step - loss: 0.0185 - val_loss: 0.0139

⋮

Epoch 00071: val_loss did not improve from 0.00000
Epoch 72/1000
2/2 [-----] - 0s 50ms/step - loss: 3.4431e-06 - val_loss: 7.9865e-06

Epoch 00072: val_loss did not improve from 0.00000
    
```

Fig 6: LSTM Training History

3.2.3. LSTM 예측

비행 특성의 변경을 예측하기 위해 현시점의 Plot 정보를 기준으로 10가지의 정보를 출력한다. 출력 결과는 Fig.7과 같다.




Fig 7: LSTM Prediction Result

3.3. 칼만필터 항적추적

“자동화 방공체계 항적추적기술 개발사업”에서 개발된 능동추적기에 Plot을 입력하여 표적을 추적한 결과는 Fig.8과 같다.




Fig 8: Kalman filter Tracking Result

3.4. 결과 비교

LSTM 예측 결과와 칼만 필터를 활용한 항적추적 결과를 표적의 실제 위치를 평균 제곱근 오차(Root Mean Square Error; RMSE)로 확인한다. 각 비행 특성별 결과는 Table.2와 같다.

Table. 2 RMSE Result

Sortation	LSTM	Kalman filter
Constant velocity	0.004044	0.003872
Equivalent acceleration	0.038722	0.005506
Hard Turning	0.009229	0.012769

IV. 결 론

본 연구는 기존 칼만 필터를 활용한 항적추적성능을 딥러닝 기반 LSTM(Long Short-Term Memory) 모델을 적용하여 향상하는 방안을 제시해보았다.

LSTM(Long Short-Term Memory) 모델이 예측한 결과가 등가속도 구간의 학습데이터가 부족하여 다소 성능저하가 있었지만 급기동, 선회(3D) 비행 시 기존 칼만 필터를 활용한 항적추적성능보다 정확하였다. 항공기의 급기동, 선회(3D) 비행 이전에 미리 예측하여 가중치를 적용한다면 항적추적성능이 향상될 수 있음을 확인하였다.

Acknowledgement

본 연구는 방위사업청, 방위산업기술지원센터의 지원(사업명:자동화방공체계 항적추적기술 개발, 과제번호 UC180001D)하에 수행되었습니다

References

[1] Park Seung-hyo, Hanyang University. A Study on the Clutter Density Estimation for Improving Multiple Target Tracking Performance

[2] Soo-hyun, Oh. Inha University. In a flight clutter environment using an engagement simulator (vsTASKER) Radar vehicle detection and generation simulation

[3] Junho, S. (in press). Roadmap for e-commerce standardization in Korea. International Journal of IT Standards and Standardization Research.

[4] Angelos Delivorias and Nicole Scholz. (in press). Economic impact of epidemics and pandemics. European Parliamentary Research Service

[5] Meltzer MI, Cox NJ, Fukuda K. The economic impact of pandemic influenza in the United States: priorities for intervention. *Emerg Infect Dis.* 1999 Sep-Oct;5(5):659 - 71. doi: <http://dx.doi.org/10.3201/eid0505.990507> PMID:10511522

[6] Prager F, Wei D, Rose A. Total economic consequences of an influenza outbreak in the United States. *Risk Anal.* 2017 Jan;37(1):4 - 19. doi: <http://dx.doi.org/10.1111/risa.12625> PMID: 27214756

[7] Liu J-T, Hammitt JK, Wang J-D, Tsou M-W. Valuation of the risk of SARS in Taiwan. *Health Econ.* 2005 Jan;14(1):83 - 91. doi: <http://dx.doi.org/10.1002/hec.911> PMID: 15386665

[8] Maria Nicola,a,* Zaid Alsafi,b Catrin Sohrabi,c Ahmed Kerwan,d Ahmed Al-Jabir,d Christos Iosifidis,c Maliha Agha,e and Riaz Aghaf ,The socio-economic implications of the coronavirus pandemic (COVID-19): A review, *International Journal of Surgery*

[9] Ding X, Zhang Y, Liu T, Duan J, editors. Deep learning for event-driven stock prediction. *International Conference on Artificial Intelligence*; 2015.

[10] Yoshihara A, Fujikawa K, Seki K, Uehara K. *PRICAI 2014: Trends in Artificial Intelligence.* 2014:759 - 69.

[11] Kuremoto T, Kimura S, Kobayashi K, Obayashi M. Time series forecasting using a deep belief network with restricted Boltzmann machines. *Neurocomputing.* 2014;137(15):47 - 56.