

딥러닝 모델 기반의 도심 저고도 무인 항공기 실시간 경로 예측 연구

장 다 현*, 윤 승 원*, 박 태 원*, 윤 혜 원*, 이 규 철°

Real-Time Trajectory Prediction for Urban Low-Altitude Unmanned Aerial Vehicles Based on Deep Learning Model

Da-hyun Jang*, Seung-won Yoon*, Tae-won Park*, Hye-won Yoon*, Kyu-chul Lee°

요 약

전 세계 항공 교통량의 증가와 자율 주행 항공기 개발로 인해, 무인 항공기의 활용 범위가 넓어지고 있다. 이로 인해 안전한 항공 교통 관리를 위해서 무인 항공기의 경로를 예측하는 기술의 필요성이 더욱 높아지고 있다. 본 연구는 딥러닝 모델을 기반으로 무인 항공기의 경로를 예측하는 방법을 제시한다. 시계열 예측에 적합한 딥러닝 모델인 GRU(Gated Recurrent Unit) 구조 기반의 예측 모델을 제안한다. 모델 학습에 있어서 look_back, forward_length 개념을 적용하여 다양한 예측 거리에서의 성능을 분석한다. 또한, 본 모델의 성능을 입증하기 위해 RNN(Recurrent Neural Network) 및 LSTM(Long Short-Term Memory) 모델과의 비교 실험을 진행하였다. 실험 결과, 본 모델이 RMSE 0.0037로 가장 우수한 예측 성능을 보였으며, 실시간 예측 가능성도 입증하였다.

키워드 : 무인 항공기, 자율 주행 항공기, 경로 예측, 딥러닝

Key Words : UAV(Unmanned Aerial Vehicle), Autonomous aircraft, Trajectory Prediction, Deep Learning

ABSTRACT

The continuous increase in global air traffic and autonomous aircraft development have made accurate trajectory prediction crucial for safe air traffic management. This study proposes a method for predicting UAV trajectories based on a deep learning model. Specifically, we propose a prediction model based on the GRU (Gated Recurrent Unit) architecture, which is well-suited for time series prediction. We applied look_back and forward_length to assess model performance across different ranges. Furthermore, to validate the performance of the proposed model, we conducted comparative experiments with RNN (Recurrent Neural Network) and LSTM (Long Short-Term Memory) models. The experimental results showed that our model achieved the best prediction performance with an RMSE of 0.0037 and demonstrated real-time prediction capability.

※ 이 연구는 충남대학교(교육·연구 및 학생지도비)에 의해 지원되었음

• First Author : Chungnam National University Department of Computer Science & Engineering, dahyunjang11@gmail.com, 학생회원

° Corresponding Author : Chungnam National University Department of Computer Science & Engineering, klee@cnu.ac.kr, 정회원

* Chungnam National University Department of Computer Science & Engineering, yoonenoch11@gmail.com, 학생회원, taewon1876@gmail.com, 학생회원, hyewony1001@gmail.com, 학생회원

논문번호 : 202409-208-A-RN, Received September 13, 2024; Revised October 10, 2024; Accepted October 11, 2024

I. 서 론

1.1 본 연구의 목적 및 필요성

현재 자율 주행 항공기 시장은 빠르게 발전하고 있으며, 연평균 17.06%의 높은 성장세를 보이고 있다^[1]. 또한, 미래 항공 교통 시스템의 핵심 요소로, 물류, 운송 분야 등에서 광범위한 활용 가능성을 가진다. 자율 주행 항공기는 인공지능과 기타 기술을 사용하여 조종사의 개입 없이 스스로 비행할 수 있는 항공기를 의미한다. 그 종류로는 무인 항공기와 드론이 대표적인 예이다. 이러한 미래의 자율 주행 항공기는 주로 도심 속 저고도 비행에 중점을 두고 있다. 저고도에서는 비행 중에 장애물이나 항공기 간의 충돌 위험성이 증가한다. 이러한 상황에서 자율 주행 항공기의 안전성을 확보하는 것이 매우 중요한 문제로 대두되고 있다. 본 연구는 이러한 위험을 극복하기 위해서 무인 항공기 실시간 경로 예측 딥러닝 모델을 제안한다. 본 모델을 통해 잠재적 충돌을 예측하여 사고를 방지할 수 있으며, 효율적인 항공 교통 관리 시스템 구축에 중요한 역할을 할 것이다.

1.2 경로 예측 관련 연구

경로 예측 연구는 다양한 분야에서 많이 이루어지고 있다. 초기에는 전통적인 방법인 확률적 예측 모델을 적용해 경로를 예측하는 방식을 많이 사용하였다^[2]. 이후에 머신러닝, 딥러닝 기반의 경로 예측으로 발전하였다. 기존 연구로 RNN 기반의 차량 목적지 예측 연구 및 선박 경로 예측 연구가 진행되었다^{[3][4]}. 항공기 경로 예측에 관한 연구로는 CNN-LSTM 구조로 시공간 특성을 고려한 모델이 제안되었으며, 예측 성능 RMSE 10.192, MAE 8.595, MAPE 4.56를 달성하였다^[5]. 또한, Bi-LSTM 기반으로 양방향 의존성을 학습한 항공기 경로 예측 방식이 있으며, 위도 RMSE 0.0264, 경도 RMSE 0.0222, 고도 RMSE 52.341의 성능을 기록하였다^[6]. Recurrent LSTM 구조를 활용해 무인 항공기의 경로를 예측하는 연구도 수행되었다^[7]. 실험 결과, 평균 예측 오차로 6.52미터를 제시하였다. 또한, 시계열 예측 최적화를 위해 Bi-LSTM과 LSTM을 결합한 모델을 사용한 무인 항공기 경로 예측 연구도 제안되었는데, 해당 모델은 최소 예측 오차 0.011미터를 달성하였다^[8].

선행 연구에서는 LSTM 모델 기반의 소형 항공기 경로 예측 연구를 수행하였다^[9]. 그러나 미래의 자율 주행 항공기는 주로 무인 항공기의 도심 속 저고도 비행에 중점을 두고 있기 때문에, 본 연구에서는 도심 저고도에서 비행한 무인 항공기의 경로 예측을 다루었다. 또한, LSTM 모델뿐만 아니라 RNN, GRU와 같은 다양

한 시계열 예측 최적화 모델로 성능을 비교 분석하였으며, 그 결과 GRU 모델이 가장 우수한 경로 예측 모델임을 제안한다. 더 나아가, 자율 주행 항공기의 충돌 위험을 줄이고 효율적인 교통 관리를 지원하기 위해 실시간 예측 가능성을 함께 제시하여 연구를 발전시켰다. 특히, 기존 무인 항공기 경로 예측 연구들은 주로 단기적인 다음 위치 예측에 집중한다. 이와 달리 본 연구에서는 다양한 거리에서의 예측 성능을 평가하며, 최적의 학습 데이터 길이를 제시한다. 이를 통해, 본 연구는 무인 항공기의 실시간 경로 예측 모델을 제안한다.

1.3 본 연구의 제안 방법

본 연구에서는 무인 항공기 경로 예측을 위해 실제 도심 저고도 범위에서 비행한 무인 항공기의 시계열 경로 데이터를 사용한다. 데이터셋의 위도, 경도, 고도 정보를 바탕으로 앞으로의 위치를 예측하는 것을 목표로 한다. 딥러닝 모델로는 시계열 예측에 적합한 GRU 구조 기반의 모델을 개발하였다. 또한, 추가로 시계열 예측에 최적화된 RNN 및 LSTM 모델과의 비교 실험을 진행하여, 본 모델을 가장 우수한 무인 항공기 경로 예측 모델로 제안한다. 본 연구에서는 look_back과 forward_length 개념을 적용하여 학습을 진행한다. 학습 데이터 단위인 look_back 값을 설정하고 다양한 forward_length에서의 예측 성능을 분석한다. 여러 look_back과 forward_length를 설정해서 본 모델의 경로 예측 성능을 평가하며, 동시에 실시간 예측 가능성도 우수함을 입증한다.

2장에서는 무인 항공기 데이터셋과 전처리 방식을 설명한다. 또한, 본 연구에서 제안하는 무인 항공기 경로 예측 딥러닝 모델에 대해 설명한다. 3장에서는 본 모델의 경로 예측 성능 실험 결과와 실시간 예측 가능성을 제시한다. 4장에서는 본 연구의 결론과 향후 연구 방향을 제시하며 마무리한다.

II. 본 론

2.1 데이터셋

본 연구는 무인 항공기의 실제 비행 중 데이터를 수집한 데이터셋을 사용하였다. UMAV(Urban Micro Aerial Vehicle) 데이터셋은 취리히(Zurich) 도시에서 약 45분간 비행한 초소형 무인 항공기의 데이터를 포함하고 있다^[10]. 지상 5미터에서 15미터의 저고도 범위에서 도심 거리를 비행한 무인항공기의 시계열 데이터이다. 본 연구에서는 데이터셋에서 GPS 센서를 통해 수집한 위치 정보인 위도, 경도, 고도 정보만을 사용한다.

2.2 데이터 전처리

본 데이터셋은 무인 항공기의 비행 중 경로 데이터가 마이크로초 단위로 수집되었다. 데이터의 시간 간격이 너무 짧으면 경로의 변화가 거의 없는 경우가 많다. 또한, 모델이 매우 단기적인 패턴만 학습하게 되어 장기적인 예측 성능이 저하될 수 있다. 반면, 시간 간격이 너무 길면 중요한 경로 변화를 놓칠 수 있다. 따라서 실험 데이터의 적절한 간격을 설정하기 위해, 여러 시간 간격에서의 위치 평균 변화율을 측정하였다. 본 연구에서는 0.1초에서 0.5초까지의 시간 간격으로 데이터를 리샘플링하고, 각 간격에서의 위도, 경도, 고도 평균 변화율을 측정하였다. 위치 변화율은 식 (1)과 같이 유클리드 거리(Euclidean Distance) 기반으로 계산하였다. 두 연속된 좌표 간의 차이(Δlat , Δlon , Δalt)를 3차원 공간에서의 거리로 표현한다. 이렇게 계산된 위치 변화율을 바탕으로, 각 시간 간격에서 모든 좌표의 평균 변화율을 측정하였으며, [그림 1]에서 이를 그래프로 비교하였다. 그래프에서 시간 간격이 0.3초를 넘어가면서부터 평균 변화율이 급격하게 증가하는 것을 확인하였다. 해당 구간에서 경로의 중요한 변화가 나타나기 시작함을 의미한다. 이를 통해 0.3초 간격에서 경로의 중요한 변화를 포착할 수 있으며, 불필요한 데이터를 줄여 처리 효율성을 높일 수 있는 점을 확인하였다. 따라서 0.3초를 가장 적절한 시간 간격으로 설정하여 데이터를 샘플링하였다.

$$\Delta r_i = \sqrt{(\Delta lat_i)^2 + (\Delta lon_i)^2 + (\Delta alt_i)^2} \quad (1)$$




그림 1. 데이터셋의 시간 간격에 따른 위도, 경도, 고도의 평균 변화율

Fig. 1. Average rate of change in latitude, longitude, and altitude over time in a dataset

2.3 데이터 라벨링

본 연구에서는 무인 항공기 경로 예측을 위해 look_back과 forward_length 개념을 제시한다. 경로 예측에 있어서는 좋은 예측 성능을 위한 최적의 학습 길이를 찾는 것이 중요하다. 이를 위해서 학습 데이터 단위를 의미하는 look_back과 예측 거리를 의미하는 forward_length를 적용한다. [그림 2]와 같이 look_back 길이만큼의 데이터를 학습하고 forward_length 이후의 위치를 예측한다. 학습 과정에 있어서, look_back 길이를 조정하면서 최적의 학습 데이터 길이를 찾는다. 또한, forward_length를 적용함으로써 바로 다음 위치 좌표뿐만 아니라 더 먼 거리의 위치까지도 예측할 수 있다. 따라서 본 연구는 최적의 학습 길이와 다양한 예측 거리에서의 성능을 제시한다.




그림 2. 본 논문에서 사용한 데이터 라벨링 방식
Fig. 2. The data labeling approach used in this paper

2.4 딥러닝 모델

본 연구에서는 무인 항공기의 비행 경로 데이터를 사용한다. 경로 데이터는 순차적으로 기록된 시계열 데이터로 과거 데이터가 현재의 상태에 영향을 미친다. 이러한 시계열 데이터 예측에 적합한 딥러닝 모델인 GRU 구조를 기반으로 경로 예측 모델을 개발하였다.

2.4.1 GRU 모델

GRU(Gated Recurrent Unit) 모델은 LSTM(Long Short-Term Memory)의 장기 의존성 문제 해결을 유지하면서 구조를 간소화한 모델이다^[11]. LSTM 모델은 RNN(Recurrent Neural Network)의 한 종류로, RNN이 가진 장기 의존성 문제를 보완하기 위해 개발되었으며, 주로 시계열 데이터 예측에 많이 사용된다. GRU

모델은 LSTM보다 구조가 간소하기에 학습해야 하는 매개변수가 적고 학습 속도가 빠르다는 장점이 있다. 본 연구에서는 GRU 구조 기반의 모델을 개발하였다. 또한 RNN 및 LSTM 모델과의 비교 실험을 통해 본 모델의 우수한 예측 성능을 제시하였다.

GRU는 [그림 3]과 같이 hidden state h_t 를 통해 정보를 학습하는 구조이다. GRU의 핵심은 hidden state h_t 가 직접 다음 단계로 전달되어 순차적으로 정보를 이어주는 방식이다. GRU는 Update gate z_t 와 Reset gate r_t 로 두가지 gate를 사용하여 정보를 조절한다. Update gate z_t 는 식 (2)과 같이 계산되어 이전 hidden state h_{t-1} 를 얼마나 유지할지 결정한다. 또한 Reset gate r_t 는 식 (3)과 같이 정의되며, 이전 hidden state h_{t-1} 인 과거의 정보를 얼마나 잊을지를 결정한다. 이 두가지 gate를 통해 새로운 입력 정보가 hidden state h_t 에 반영된다. 새로운 정보를 얼마나 반영할지는 식 (4)와 (5)를 통해 계산된다. 새로운 후보 hidden state $\tilde{h}_t$ 는 Reset gate r_t 를 적용한 이전 hidden state h_{t-1} 와 현재 입력 x_t 의 결합을 통해 구해진다(식 4). 이후 최종 hidden state h_t 는 Update gate z_t 를 통해 이전 hidden state h_{t-1} 와 새로운 후보 hidden state $\tilde{h}_t$ 의 가중합을 계산하여 결정된다(식 5). GRU는 이러한 구조를 통해 LSTM보다 계산이 효율적이면서도, 두개의 gate를 사용하여 RNN의 기울기 소실 문제를 해결할 수 있다.

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (2)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (3)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t]) \quad (4)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (5)$$




그림 3. GRU 모델 구조
Fig. 3. GRU Model Structure

2.4.2 본 모델의 하이퍼파라미터 설정 방법

본 연구에서는 무인 항공기 경로 예측 모델로 GRU 기반 모델을 제안한다. 신경망을 설계할 때는 하이퍼파라미터의 적절한 선택이 모델 성능에 중요한 영향을 미친다. 본 연구에서는 무인 항공기 경로 예측 모델에 있어서 최적의 Hidden layer node 수와 layer 수를 결정하기 위해 validation loss를 측정한다. Hidden layer node 수가 너무 적으면 모델이 데이터의 특성들을 제대로 학습하지 못할 수 있으며, 너무 많으면 모델 과적합이 발생할 수 있다. 또한, layer 수에 따라서도 모델의 성능이 크게 달라질 수 있다. 따라서 본 논문에서는 hidden layer node 수와 layer 수에 따른 validation loss를 관찰하여 최적의 모델 구성을 찾는다. 모델 학습 과정에 있어서 training loss는 학습 데이터에 대한 적합성을 평가하지만, 과적합의 위험성이 있다. 반면, validation loss는 모델의 일반화 성능을 평가하기 위해 사용되어 하이퍼파라미터 최적화 과정에서 더 유용한 지표로 사용된다. 따라서 본 연구에서는 데이터셋을 6 : 2 : 2 비율의 훈련, 검증, 테스트 데이터로 분할하였으며, 검증 데이터에서 loss를 측정하였다. 실험의 손실 함수는 MSE(Mean Squared Error)를 사용한다. MSE는 식 (6)과 같이 실제 값과 예측 값의 차이를 제공한 후에 그 평균을 구한 값이며, 경로 예측의 정확도를 효과적으로 평가하는데 적합하다^[12]. MSE를 통해 모델은 예측 값과 실제 값 간의 차이를 줄이도록 훈련한다.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (6)$$

2.4.3 Hidden layer node 수에 따른 loss 측정

GRU 모델에서 hidden layer node 수에 따른 validation loss를 측정하기 위해, node 수를 16, 32, 64, 128로 설정하였다. 먼저, 단일 layer 구조에서 hidden layer node 수에 따른 validation loss를 측정하여 최적의 node 수를 결정하였다. [그림 4]와 같이 학습 epoch이 증가함에 따른 검증 세트의 loss 값 변화를 그래프로 시각화한다. 특히, loss의 변화가 집중적으로 나타나는 epoch 약 70에서 120 사이의 구간을 확대하여 강조하였다. Validation loss를 측정한 이유는 모델의 새로운 데이터에 대한 일반화 능력을 평가하기 위함이다. 다양한 예측 거리에서 가장 적합한 값을 찾기 위해 forward_length를 바로 다음 위치인 0과 더 먼 거리의 위치인 20으로 설정하였다. 각각의 forward_length에 대해 validation loss를 측정한 그래프를 [그림 4]와 [그림 5]로 나타내었다. [그림 4]와 같이 forward_length가 0 일 때는 node 수가 64, 128인 경우에 비교적 낮은 loss가 측정되었다. 이에 비해 node 수가 16, 32인 경우에는 더 높고 불안정한 loss를 보였다. [그림 5]와 같이 forward_length가 20으로 증가한 경우에는 예측 거리




그림 4. Hidden layer node 수에 따른 validation loss (forward_length = 0)

Fig. 4. Validation loss as the number of hidden layer nodes (forward_length = 0)




그림 5. Hidden layer node 수에 따른 validation loss (forward_length = 20)

Fig. 5. Validation loss as the number of hidden layer nodes (forward_length = 20)

가 길어져 예측이 더 어려워질 수밖에 없다. 따라서 전체적으로 loss가 증가한 것을 확인할 수 있다. 특히, forward_length가 20일 때, node가 128인 경우의 loss는 매우 불안정하게 높았다. 따라서 forward_length가 길어져도 일관되게 낮은 loss를 보인 node 64를 최종 모델의 Hidden layer node 수로 선택해 개발하였다.

2.4.4 Layer 수에 따른 loss 측정

GRU 모델에서 layer 수에 따른 validation loss를 측정하기 위해, layer 수를 1, 2, 3으로 설정하여 loss 값을 비교한다. 마찬가지로 forward_length를 0과 20으로 설정하여 각 epoch에서 검증 세트 loss 값을 측정하였다. [그림 6]에서 forward_length가 0일 때는 layer의 수가 1, 2인 경우에 loss가 낮게 측정되었으며, layer 수가 3인 경우에는 비교적 불안정하고 높은 loss를 나타내었다. [그림 7]에서 forward_length를 20으로 설정한 경우, 예상대로 예측 거리가 멀어져 validation loss가 전반적으로 증가하는 경향이 나타났다. 특히, layer 수 증가에 따라서 validation loss는 더욱 불안정해지며, 모델의 성능이 layer 수의 영향을 크게 받는다는 점을 확인하였다. 이를 통해 단일 layer 구조만이 forward_length




그림 6. Layer 수에 따른 validation loss (forward_length = 0)
Fig. 6. Validation loss as the number of layers (forward_length = 0)




그림 7. Layer 수에 따른 validation loss (forward_length = 20)

Fig. 7. Validation loss as the number of layers (forward_length = 20)

가 길어지더라도 loss가 일관되게 낮고 안정적인임을 알 수 있다. 따라서, 본 연구에서는 낮은 loss와 빠른 예측 시간을 나타낸 단일 layer 구조를 선택하여 개발을 진행하였다. 본 모델의 validation loss 측정을 통해서 설정한 Hidden layer node 수와 layer 수는 [표 1]에 나타내었다.

표 1. 모델 하이퍼파라미터 설정

Table 1. Model hyperparameters setting

Parameters	Value
Layer	1
Hidden layer nodes	64

2.4.5 본 연구의 전체 프레임워크

본 연구에서는 무인 항공기 경로 예측 방법을 제시한다. 실제 무인 항공기의 경로 데이터에서 위도, 경도, 고도 값을 사용한다. 또한, 데이터의 시간 간격을 적절히 설정하여 리샘플링하고 학습 효율을 높이기 위해 정규화를 진행한다. 해당 전처리를 거친 데이터를 모델의 입력 데이터로 사용한다. 본 연구에서는 경로 예측 모델로 GRU 구조 기반의 딥러닝 모델을 제안한다. 본 모델을 통해서 look_back 만큼의 데이터를 학습하고




그림 8. 본 연구의 전체 프레임워크
Fig. 8. The overall framework

forward_length 이후의 위치(위도, 경도, 고도)를 예측하는 것을 목표로 한다. 본 연구의 전체 프레임워크는 [그림 8]에 나와있다.

III. 실험

3.1 모델 실험 구성

본 연구에서는 실험 데이터로 무인 항공기 데이터셋의 위도, 경도, 고도 정보만을 사용한다. 해당 데이터는 0.3초 간격이며, 총 9038개의 경로 포인트를 가진다. 실험에 있어서 데이터의 훈련과 검증, 테스트 데이터를 6 : 2 : 2로 나누어 진행하였다. 또한 모델의 학습 효율을 높이기 위해 MinMaxScaler를 적용해 입력 데이터를 0과 1 사이의 값으로 스케일링하였다.

본 모델의 실험을 위해서 여러 look_back과 forward_length 값을 적용해 성능 실험을 진행하였다. look_back은 10, 20, 30, 40으로 설정하고 forward_length를 5, 10, 15, 20으로 설정한다. 각 파라미터를 조정하여 본 모델과 RNN, LSTM 모델의 성능을 비교한다. 실험을 진행할 모든 모델의 파라미터 설정은 [표 2]와 같이 설정하였고, 예측 성능 평가 지표로는 RMSE(Root Mean Squared Error)를 사용하였다. RMSE는 회귀 예측 모델에 대한 성능 지표로 많이 사용하며, 많은 경로 예측 연구에 적용되고 있다. RMSE는 식 (7)과 같이 MSE의 제곱근으로 오차의 크기를 더 직관적으로 이해할 수 있다^[13]. 또한, 모델이 예측한 값이 실제 값과 얼마나 가까운지를 평가하는 지표이다. 본 모델은 forward_length 이후의 위도, 경도, 고도 값을 예측하며, 이에 따른 RMSE 성능을 제시한다. 또한, 평균 예측 시간을 측정하여 경로 예측에 있어서 중요한 실시간 예측 가능성을 함께 제시한다. 본 연구의 실험은 Intel® Xeon® Gold 6346 CPU @ 3.10GHz, RAM 128GB, NVIDIA RTX A6000 환경에서 진행하였다.

표 2. 모델 전체 파라미터 설정
Table 2. All parameters setting

Parameters	Value
Layer	1
Hidden layer nodes	64
Optimizer	Adam
Epoch	90
Batch size	70
Loss function	Mean Squared Error

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (7)$$

3.2 모델 실험 결과

3.2.1 look_back 길이에 따른 성능 결과

look_back 길이를 10, 20, 30, 40으로 조정하여 각 모델의 RMSE 값을 측정된 결과를 [표 3]과 같이 제시한다. 본 모델인 GRU 모델은 모든 look_back에서 RMSE 값 0.005 아래로 꾸준히 가장 낮은 오차를 기록하였다. look_back이 너무 짧으면 충분한 패턴을 학습하지 못할 수 있으며, 너무 길면 비효율적인 정보가 포함될 수 있다. 따라서 적절한 look_back 설정이 필수적이다. 본 모델은 특히 look_back이 20일 때 RMSE 0.00370으로 매우 낮은 예측 오차를 보였다. 또한, 모든 look_back에서 GRU 모델이 꾸준히 가장 좋은 성능을 나타내었다. RNN과 LSTM 모델은 GRU에 비해 다소 높은 오차를 보였지만, 세 모델 모두 높은 성능을 기록한 것을 확인하였다. 따라서 GRU 기반의 모델이 가장 우수한 예측을 보였으며, 최적의 look_back 값은 20으로 나타났다.

표 3. look_back 길이에 따른 RMSE 성능표
Table 3. RMSE based on look_back

look_back \ Model	10	20	30	40
RNN	0.00619	0.00500	0.00459	0.00537
LSTM	0.00566	0.00535	0.00695	0.00580
GRU(Ours)	0.00437	0.00370	0.00400	0.00413

3.2.2 forward_length 길이에 따른 성능 결과

최적의 look_back 값을 20으로 설정하고 forward_length를 5, 10, 15, 20으로 조정하여 각 모델의 RMSE를 측정된 결과를 [표 4]와 같이 제시하였다. for-

표 4. forward_length 길이에 따른 RMSE 성능표
Table 4. RMSE based on forward_length

forward_length Model	5 (1.5s later)	10 (3s later)	15 (4.5s later)	20 (6s later)
RNN	0.01269	0.01510	0.03742	0.05103
LSTM	0.01439	0.02735	0.03353	0.03604
GRU(Ours)	0.00997	0.01462	0.02680	0.02976

ward_length를 다양하게 설정하면서 모델은 더 먼 거리의 위치 좌표를 예측할 수 있다. forward_length가 길어질수록 모델의 예측 거리가 멀어지기 때문에 예측 오차는 높아질 수밖에 없다. RNN과 LSTM 모델은 forward_length가 15, 20일 때부터 급격히 높아지는 오차를 보였다. 하지만 GRU 모델은 유일하게 예측 거리가 길어져도 꾸준히 RMSE 0.03 미만의 낮은 오차를 나타내었다. 이와 같이 본 모델은 다양한 예측 거리에서도 가장 좋은 경로 예측 성능을 보였다.

3.2.3 모델 예측 결과 시각화

각 딥러닝 모델의 경로 예측 결과를 시각화하여 실제 경로와 비교한다. 예측 결과는 경로 변화 패턴이 명확하게 드러나는 구간을 선택하였다. [그림 9]와 같이 forward_length가 0일 때는 바로 다음 위치를 예측하는 것이므로 모든 모델이 좋은 예측 결과를 나타내었다. 특히, 빨간색으로 표시된 GRU 기반의 본 모델이 검은색인 실제 경로와 가장 유사한 예측을 보였다. [그림




그림 9. 각 딥러닝 모델의 예측 결과와 실제 경로 비교 (forward_length = 0)
Fig. 9. Plot of predicted versus actual Trajectory for each deep learning model (forward_length = 0)




그림 10. 각 딥러닝 모델의 예측 결과와 실제 경로 비교 (forward_length = 20)
Fig. 10. Plot of predicted versus actual Trajectory for each deep learning model (forward_length = 20)

10]에서 forward_length가 20일 때는 예측 거리가 길어져서 모든 모델의 오차가 증가하였다. 하지만 본 모델이 여전히 실제 경로와 가장 가까운 결과를 나타내었다. 또한, 급격한 경로 변화에서 RNN과 LSTM은 매우 불안정한 패턴을 보였지만 GRU 모델만이 유일하게 유사한 패턴을 예측해냈다. 이를 통해 본 모델이 실제 경로와 비교하였을 때, 가장 우수한 예측을 보임을 입증하였다.

3.2.4 실시간 성능 평가를 위한 예측 시간 측정

본 연구에서는 모든 딥러닝 모델의 실시간 예측 가능성을 함께 평가하였다. 모델의 학습이 완료된 후, 예측 단계에서 하나의 경로 포인트를 예측하는데 소요되는 시간을 측정한다. 각 데이터 포인트에 대해 look_back이 20일 때, 모든 forward_length에서의 개별 예측 시간을 측정하고, 평균을 계산해 [표 5]에 제시하였다. 평균 예측 시간은 실시간 시스템에서 모델이 새로운 입력 데이터를 얼마나 신속하게 처리하여 경로 좌표를 예측해 내는지 평가하는 중요한 지표이다. 따라서 모든 모델의 평균 예측 시간을 측정해 실시간 예측 가능성을 평가하였다. 간단한 구조를 가진 RNN과 GRU 모델이 평균 예측 시간 약 0.031초로 가장 짧았으며, 다음으로 LSTM 모델도 약 0.032초로 빠른 예측 시간을 보였다. 모든 모델의 평균 예측 시간은 데이터셋의 시간 간격인 0.3초보다 훨씬 짧은 0.0311초에서 0.0323초 범위로 나타나 실시간 예측 가능성이 우수함을 확인하였다. GRU 기반의 본 모델은 무인 항공기 경로 예측에 가장 높은

표 5. 각 딥러닝 모델의 평균 예측 시간

Table 5. Average prediction time for each deep learning model

Model	Average prediction time(s)
RNN	0.03180
LSTM	0.03232
GRU(Ours)	0.03115

성능을 보였으며, 약 0.031초의 예측 시간으로 실시간 예측에 있어서도 우수함을 입증하였다.

3.3 실험 결과 분석

본 연구에서는 시계열 예측에 특화된 여러 딥러닝 모델 중에 GRU 기반의 모델이 무인 항공기 실시간 경로 예측에 가장 뛰어난 모델임을 시사한다. GRU는 LSTM보다 적은 gate를 사용하여, 더욱 간소화된 구조를 가지므로 실시간 경로 예측에 적합한 모델이다. 또한, GRU는 LSTM과 같이 장기 의존성 문제를 개선하여, RNN 보다 장기적인 경로 패턴을 더 효과적으로 학습할 수 있다. 무인 항공기는 비행 경로가 복잡하고 급격히 변화할 수 있는 특성을 지닌다. 특히, 저고도에서 비행하는 무인 항공기는 기타 장애물과의 충돌 위험이 있어, 안전한 비행을 위한 실시간 경로 예측이 매우 중요하다. 이러한 무인 항공기의 특징을 고려하였을 때, 본 연구에서는 시계열 예측에 적합한 딥러닝 모델인 RNN과 LSTM 및 GRU중에 GRU가 가장 적합한 모델임을 확인하였다.

본 연구의 실험 결과, 비교적 간소화된 구조를 가진 GRU가 LSTM보다 우수한 경로 예측 성능을 기록하였다. 또한, GRU는 경로 예측 시간이 매우 짧아 실시간 예측에 더욱 적합하다는 것을 입증하였다. LSTM은 forward_length가 길어짐에도 RNN에 비해서 상대적으로 좋은 성능을 유지했고, RNN은 forward_length가 10 이하인 단기 예측에서 강점을 나타냈다. 반면, GRU는 모든 forward_length에서 뛰어난 성능을 기록했으며, 급격한 경로 변화에서도 가장 유사한 예측을 보였다. 실험 결과로 보아, GRU는 무인 항공기의 복잡한 패턴을 빠르게 학습하고 먼 예측 거리에서도 가장 뛰어난 성능을 보이는 것을 확인하였다. 이를 통해 본 연구는 GRU가 무인 항공기의 비행 특징과 실시간 경로 예측 요구에 가장 적합한 모델임을 시사한다.

IV. 결 론

본 연구에서는 딥러닝 기반의 도심 저고도 무인 항공기 경로 예측 모델을 개발하였다. 시계열 예측에 적합한 GRU 구조를 기반으로 무인 항공기의 경로를 효과적으로 예측하는 모델을 제안한다. 또한, 무인 항공기 경로 예측에 look_back과 forward_length 개념을 제시한다. 다양한 look_back을 설정하여 예측 성능을 평가하고, 최적의 look_back 값을 도출하였다. 또한, forward_length를 지정해 바로 다음 위치 뿐만 아니라 더 먼거리를 예측하는 성능을 제시하였다. 더 나아가, 시계열 예측에 최적화된 RNN 및 LSTM 모델과의 비교 실험을 진행하였다. 성능 실험 결과, GRU 구조 기반의 본 모델이 모든 forward_length에서 가장 높은 성능을 보임을 입증하였다. 또한, 본 모델은 약 0.031초의 평균 예측 시간을 기록하여 실시간 예측 가능성도 우수함을 제시하였다. 따라서 경로 예측 성능과 실시간 예측 가능성 모두 우수한 무인 항공기 경로 예측 모델을 제안하였다.

본 연구는 forward_length가 길어지면서 예측 오차가 많이 불안정해지는 한계가 있다. 향후 연구에서는 forward_length가 길어져도 최대한 높은 성능을 유지할 수 있는 모델을 개발하고자 한다. 또한, 날씨와 같은 다른 정보를 함께 고려하지 않았기에 이를 보완해 다양한 환경에서 높은 성능을 내는 모델을 개발하고자 한다.

References

- [1] E. Schulz, *Global Networks, Global Citizens. Global Market Forecast 2018-2037*, Airbus, Blagnac Cedex, France, 2018.
- [2] D. Varshneya and G. Srinivasaraghavan, "Human trajectory prediction using spatially aware deep attention models," *arXiv Preprint*, arXiv:1705.09436, 2017, Retrieved Aug. 25, 2024. (<https://doi.org/10.48550/arXiv.1705.09436>)
- [3] Y. Endo, K. Nishida, H. Toda, and H. Sawada, "Predicting destinations from partial trajectories using recurrent neural network," in *Proc. Pacific-Asia Conf. Knowledge Discovery and Data Mining (PAKDD 2017)*, pp. 504-515, Jeju, South Korea, May 2017. (https://doi.org/10.1007/978-3-319-57454-7_13)
- [4] Y. Suo, X. Zhang, J. Chen, and Y. Wang, "A

- ship trajectory prediction framework based on a recurrent neural network,” *Sensors*, vol. 20, no. 18, p. 5133, Sep. 2020.
(<https://doi.org/10.3390/s20185133>)
- [5] L. Ma and S. Tian, “A hybrid CNN-LSTM model for aircraft 4D trajectory prediction,” *IEEE Access*, vol. 8, pp. 134668-134680, Aug. 2020.
(<https://doi.org/10.1109/ACCESS.2020.3010963>)
- [6] D. Sahadevan, S. Ponnusamy, S. Tamilvanan, and M. Varadarajan, “Ground-based 4D trajectory prediction using bi-directional LSTM networks,” *Applied Intell.*, vol. 52, no. 14, pp. 16417-16434, Dec. 2022.
(<https://doi.org/10.1007/s10489-022-03309-6>)
- [7] Y. Zhang, Q. Zhang, X. Chen, and Y. Zhao, “Recurrent LSTM-based UAV trajectory prediction with ADS-B information,” in *Proc. IEEE GLOBECOM 2022*, Rio de Janeiro, Brazil, Dec. 2022.
(<https://doi.org/10.1109/GLOBECOM48099.2022.10000919>)
- [8] P. Shu, C. Chen, B. Chen, K. Su, S. Chen, H. Liu, and F. Huang, “Trajectory prediction of UAV based on LSTM,” in *Proc. 2021 2nd Int. Conf. Big Data & Artificial Intell. & Softw. Eng. (ICBASE)*, pp. 448-451, Guangzhou, China, Sep. 2021.
(<https://doi.org/10.1109/ICBASE53849.2021.00089>)
- [9] D. H. Jang, S. W. Yoon, T. W. Park, H. J. Kim, and K. C. Lee, “A study on the low-altitude small aircraft trajectory prediction based on deep learning model,” in *Proc. IEEE Conf. 2024*, pp. 2196-2200, Jeju, Korea, Jun. 2024.
- [10] A. L. Majdik, C. Till, and D. Scaramuzza, “The Zurich urban micro aerial vehicle dataset,” *Int. J. Robot. Res.*, vol. 36, no. 3, pp. 269-273, 2017.
(<https://doi.org/10.1177/0278364917702237>)
- [11] S. Zargar, “Introduction to sequence learning models: RNN, LSTM, GRU,” *Dept. of Mech. and Aerospace Eng., North Carolina State Univ.*, 2021.
(<https://doi.org/10.13140/RG.2.2.36370.99522>)

Univ, 2021.

(<https://doi.org/10.13140/RG.2.2.36370.99522>)

- [12] K. Das, J. Jiang, and J. N. K. Rao, “Mean squared error of empirical predictor,” *Ann. Stat.*, vol. 32, no. 2, pp. 818-840, 2004.
(<https://doi.org/10.1214/009053604000000201>)
- [13] T. O. Hodson, “Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not,” *Geosci. Model Dev. Discuss.*, vol. 2022, pp. 1-10, 2022.
(<https://doi.org/10.5194/gmd-15-5481-2022>)

장 다 현 (Da-hyun Jang)



2023년 2월 : 충남대학교 수학과 졸업
2023년 3월~현재 : 충남대학교 컴퓨터공학과 석사과정
<관심분야> 딥러닝, 기계학습, 경로 예측

윤 승 원 (Seung-won Yoon)



2018년 2월 : 충남대학교 컴퓨터공학과 졸업
2018년 3월~현재 : 충남대학교 컴퓨터공학과 석박사통합과정
<관심분야> 딥러닝, 기계학습, 바이오인포메틱스, 경로예측

박 태 원 (Tae-won Park)



2023년 2월 : 한밭대학교 컴퓨터 공학과 졸업
2023년 3월~현재 : 충남대학교 컴퓨터공학과 석사과정
<관심분야> 딥러닝, 기계학습, 경로 예측, 헬스케어

윤 혜 원 (Hye-won Yoon)



2022년 8월 : 한남대학교 컴퓨
터통신무인기술학과 졸업
2022년 9월~현재 : 충남대학교
컴퓨터공학과 석박사통합과정
<관심분야> 딤러닝, 기계학습,
경로 예측, 바이오인포메틱스

이 규 철 (Kyu-chul Lee)



1984년 2월 : 서울대학교 컴퓨
터공학과 학사
1986년 2월 : 서울대학교 컴퓨
터공학과 석사
1990년 2월 : 서울대학교 컴퓨
터공학과 박사
1990년 3월~현재 : 충남대학교
컴퓨터공학과 교수

<관심분야> 데이터베이스, XML, 정보 통합, 사물
인터넷, 기계 학습