

무인항공기 비행 상태 예측을 위한 개선된 CNN-LSTM 혼합모델

서현우¹ · 최은주² · 김병수¹ · 문용호^{1,†}¹경상국립대학교 일반대학원 기계항공우주공학부²한국항공우주연구원 항공연구소

An Improved CNN-LSTM Hybrid Model for Predicting UAV Flight State

Hyun Woo Seo¹, Eun Ju Choi², Byoung Soo Kim¹ and Yong Ho Moon^{1,†}¹School of Mechanical and Aerospace Engineering, Gyeongsang National University²Korea Aerospace Research Institute

Abstract

In recent years, as the commercialization of unmanned aerial vehicles (UAVs) has been actively promoted, much attention has been focused on developing a technology to ensure the safety of UAVs. In general, the UAV has the potential to enter an uncontrollable state caused by sudden maneuvers, disturbances, and pilot error. To prevent entering an uncontrolled situation, it is essential to predict the flight state of the UAV. In this paper, we propose a flight state prediction technique based on an improved CNN-LSTM hybrid mode to enhance the flight state prediction performance. Simulation results show that the proposed prediction technique offers better state prediction performance than the existing prediction technique, and can be operated in real-time in an on-board environment.

초 록

최근에 무인항공기의 사업화가 활발하게 추진됨에 따라 무인항공기의 안전성 확보를 위한 기술 개발에 많은 관심이 집중되고 있다. 일반적으로 무인항공기는 운용 중 급기동, 외란, 조종사 실수 등으로 인하여 조종 불능의 상태로 진입할 가능성을 지닌다. 조종 불능 상태로의 진입을 예방하기 위해서는 무인항공기의 비행 상태를 예측하는 것이 필수적으로 요구된다. 본 논문에서는 무인항공기의 비행 상태 예측 성능의 향상을 위하여 개선된 CNN-LSTM 혼합모델을 제안한다. 모의실험은 제안하는 모델을 이용한 예측 기법이 기존 예측 기법에 비하여 비행 상태 예측 성능이 우수하며 온보드 환경에서 실시간으로 운용됨을 보인다.

Key Words : UAV(무인항공기), CNN(합성곱 신경망), LSTM(장단기 기억 신경망), Loss of Control(조종 불능), Prediction(예측)

1. 서 론

무인항공기(UAV)는 드론 임무 장비의 다양화, 배터리 및 통신 기술의 발전, 인공지능 기술의 도입 등에 힘입어 그 활용이 더욱 확대되고 있다. 특히, 무인항공기를 이용하여 사람 또는 화물을 운송하는 차세대 도

심교통 체계인 UAM(Urban Air Mobility)에 대한 연구가 활발히 진행되고 있으며, 이에 따라 무인항공기의 안전성 확보에도 많은 관심이 집중되고 있다[1,2]. 일반적으로 무인항공기는 운용 중 급기동이나 외란, 조종사의 실수 등의 원인으로 조종 불능 상태 및 실속 상태에 빠질 수 있다. 조종사가 탑승하지 않는 무인항공기에서 비행 상태 변화는 쉽게 파악될 수 없기 때문에 무인항공기가 비정상 비행 상태와 같은 조종 불능의 상태에 빠질 위험성은 항상 존재한다. 따라서 무인

Received: Mar. 05, 2024 Revised: Mar. 27, 2024 Accepted: Apr. 16, 2024

† Corresponding Author

Tel: +82-55-772-1374, E-mail: yhmoon5@gnu.ac.kr

© The Society for Aerospace System Engineering

항공기의 안전성을 확보하기 위해서 무인항공기의 비행 상태를 예측하여 조종 불능의 비행 상태로 진입하는 것을 예방하는 것이 필수적으로 요구된다.

지금까지 항공기의 비행 상태 추정은 주로 칼만 필터에 기반하여 수행되었다[3,4]. 그러나 칼만 필터는 초기 상태 추정값으로 야기되는 오차 발산으로 인하여 성능이 저하될 수 있다. 또한 선형화 작업으로 인하여 계산량이 증가하고 비선형 시스템 추정에 한계를 지닌다. 최근에 칼만 필터를 이용한 기존 상태 추정 기법의 한계를 해결하기 위해 딥러닝 모델을 이용한 상태 추정 기법이 제시되고 있다. CNN(Convolutional Neural Network) 모델은 복잡한 비선형 시스템에 대한 효과적인 특징 추출이 가능하기에 시스템 이상 식별에 활용되고 있다[5,6]. 반면에 무인항공기 자세 추정, 무인항공기 비행시간 향상을 위한 상승기류 예측, 항공기 이상 상태 예측 등과 같은 시계열 데이터 관련 추정에는 LSTM(Long Short Term Memory) 모델이 활용되고 있다[7-9].

최근에 무인항공기의 비행 상태 예측을 위하여 CNN 모델과 LSTM 모델을 결합한 CNN-LSTM 혼합모델을 이용한 예측 기법이 제시되었다[10]. CNN 모델에서는 시간축 방향의 합성곱 연산을 통해 비행 데이터의 시간적 특징을 추출한다. 그리고 LSTM 모델에서는 추출된 특징들의 단,장기적 시계열 특성들을 추출한다. MLP 구조의 Fully-connected layer에서는 LSTM 모델에서 생성된 시계열 특성을 이용하여 특정 미래 시점의 비행 상태 변수 예측을 수행한다. 이 기법은 NARX(Nonlinear AutoRegressive eXogenous) 모델과 CNN 모델을 이용한 예측 기법보다 우수한 성능을 보인다. 그러나 현재 시점보다 목표로 하는 미래 예측 시점이 증가할수록 예측 성능이 저하되는 한계를 지닌다.

본 논문에서는 무인항공기 비행 상태 예측 성능의 향상을 위하여 개선된 CNN-LSTM 혼합모델을 제안한다. 제안 기법에서는 데이터의 시,공간적 특징을 보다 효과적으로 반영하기 위하여 1차원 형식의 합성곱 연산을 2차원 형식의 합성곱 연산으로 대체한다. 그리고 CNN의 합성곱 연산 수행 과정에서 발생하는 가장자리 효과(Edge Effect)를 개선하기 위해 입력 데이터에 현재 시점 데이터를 추가(Padding)한다. 또한 각

입력 데이터의 상관성 분석을 통하여 입력 데이터 길이를 결정한다. 모의실험을 통해 제안하는 CNN-LSTM 모델을 활용한 예측 기법이 기존 예측 기법보다 우수한 예측 성능을 지니고 있음을 알 수 있다. 또한 온도 환경에서의 실험은 제안 기법이 30 Hz 주기의 데이터에 대하여 실시간으로 운용될 수 있음을 보인다.

2. 기존 비행 상태 예측 기법

Figure 1과 같이 기존 비행 상태 예측 기법은 Convolution layer, LSTM layer, Fully-connected layer로 구성되는 CNN-LSTM 혼합모델에 기반하고 있다[10]. 50x6 크기의 입력 데이터에 대해 Convolution layer에서는 3x6 형태의 kernel을 이용한 합성곱 연산을 통하여 시,공간적 특징이 동시에 추출된다. 그리고 300개의 kernel들에 기초하여 48x300 크기의 feature map이 생성된다. Feature map을 입력으로 사용하는 LSTM layer에서는 1x300 크기의 특징 데이터들에 대한 장, 단기적 시간 의존성을 파악하기 위하여 cell state와 hidden state를 통하여 회귀 연산이 48회 수행된다. LSTM의 출력인 hidden state가 각 time step별로 1x16 크기의 벡터를 출력하기 때문에 LSTM에서는 48x16 크기의 2차원 벡터가 최종 생성된다. 그리고 2개의 은닉층과 1개의 출력층으로 구성되는 Fully-connected layer에서는 48x16 벡터를 평탄화하여 얻어진 1x768 벡터를 입력으로 하여 현재 시점을 기준으로 0.2초 이후 시점에 대한 비행 상태 변수값을 최종 예측하여 출력한다.

기존 예측 기법에서는 성능 검증을 위하여 비정상 비

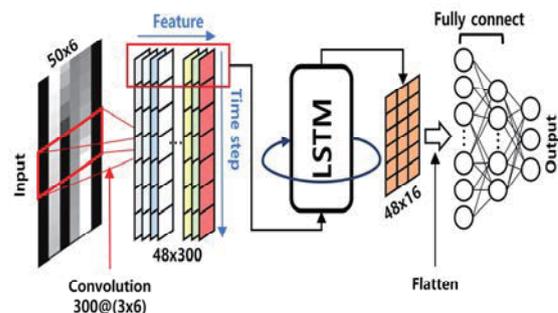


Fig. 1 Hybrid Model Structure of Existing Technique

Table 1 Conditions for Generating Flight Data

Case	Initial V (V_0) [m/s]	Cmd V (V_C) [m/s]	Cmd Phi(ϕ_C) [deg]	Flight State
UL-1	21	10	-45 ~ +45	Stall
UL-2	21	5	-45 ~ +45	Stall
UL-3	18	10	-45 ~ +45	Stall
UL-4	18	5	-45 ~ +45	Stall
UL-5	15	10	-45 ~ +45	Stall
UL-6	15	5	-45 ~ +45	Stall
UT-2	19	7	35	Stall
UT-3	20	11	32	Stall

행 시나리오를 설정하였다. 그리고 Table 1의 비행 데이터 생성 조건들을 이용한 모의 시뮬레이션을 통하여 50Hz의 비행 데이터를 생성하여 학습 데이터 및 테스트 데이터로 사용하였다.

현재 시점을 기준으로 0.2초 이후 시점에 대한 비행 상태 변수 예측에 있어서 기존 예측 기법은 NARX모델과 CNN모델을 이용한 예측 기법들보다 우수한 성능을 보였다. 특히 기존 예측 기법은 변화가 큰 피치 각속도 q 에 대하여 상대적으로 정확한 예측을 수행하였다. 그러나 현재 시점보다 목표로 하는 미래 예측 시점이 증가할수록 예측 성능이 저하된다. 또한 데이터의 생성 주기가 30 Hz인 경우 성능이 저하되는 현상이 나타난다.

3. 제안하는 비행 상태 예측 기법

3.1 입력 데이터 구성

본 논문에서는 기존 예측 기법과 동일하게 비행 시나리오 및 비행 조건을 설정하고 시뮬레이션을 통하여 생성된 30 Hz 주기의 비행 데이터를 학습 데이터 및 테스트 데이터로 사용한다. 그리고 생성된 비행 데이터들 가운데 Upset 상황 발생 시 변화가 급격한 5개의 종축 비행 상태변수 $q, \alpha, \theta, \delta_e, A_z$ 를 입력 데이터로 선정한다. Table 2는 선정된 입력 데이터를 정리한 것이다.

일반적으로 선정된 입력 데이터들을 CNN-LSTM 혼합모델의 입력으로 사용하기 위해서는 window

Table 2 Input Data used in the Proposed Technique

α (deg)	받음각
q (deg/s)	피치 각속도
θ (deg)	피치각
δ_e (deg)	엘리베이터 출력
A_z (m/s^2)	Z축 가속도

sliding 기법을 통하여 2차원 계조 영상을 구성하여야 한다. 본 논문에서는 합성곱 연산 효과를 고려하여 Fig. 2와 같이 예측 대상이 되는 q, θ, α 를 중앙에 배치하고 δ_e, q 를 좌우로 중복 배치한다. 이러한 입력 데이터 구성은 변수간 상관성 추출을 용이하게 할 것이다.

입력으로 사용되는 2차원 계조 영상에 있어서 열의 길이를 결정하기 위해 피어슨 상관계수를 이용하여 현재 시점(t) 데이터와 과거 시점(t-1~t-59) 데이터간 상관도를 분석하였다[11]. A_z, δ_e, q, α 는 과거 59 time step까지 강한 상관성을 보였지만 θ 는 25 time step 이후로 상관성이 약화되는 경향을 보였다. 비행 상태 변수들은 모델 학습에 함께 사용되어야 하기 때문에 본 논문에서는 현재 데이터와 과거 29 time step까지의 데이터들로 2차원 계조 영상을 구성한다.

기존 예측 기법에서 현재 시점 데이터는 2차원 계조 영상의 하단 끝 부분에 위치한다. 그런데 일반적으로 가장자리에 위치한 데이터에는 합성곱 연산 과정에서

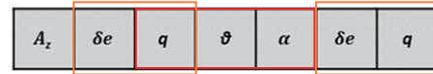


Fig. 2 Input Data Arrangement

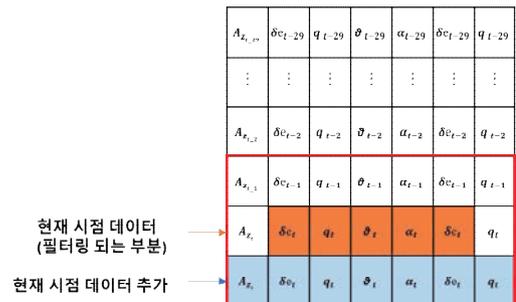


Fig. 3 Input Data Architecture based on Current Data Padding

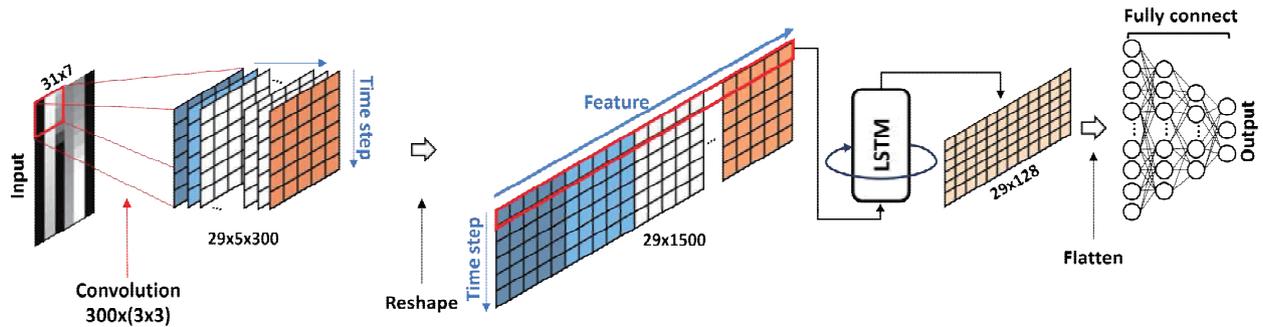


Fig. 4 Proposed CNN-LSTM Hybrid Model Structure

필터링이 수행되지 않는 모서리 효과(Edge Effect)가 존재한다고 알려져 있다. 이러한 사실은 기존 예측 기법에 있어서 중요한 역할을 담당하는 현재 시점 데이터의 특징이 혼합모델에 제대로 반영되지 못한다는 것을 의미한다. 이러한 문제를 해결하기 위해 본 논문에서는 Fig. 3과 같이 현재 시점 데이터를 하단에 추가하여 합성곱 연산을 통하여 현재 시점 데이터의 특징이 혼합모델에 반영되도록 한다.

3.2 개선된 CNN-LSTM 모델 구조

본 논문에서는 무인항공기 비행 상태 예측 성능의 향상을 위하여 개선된 CNN-LSTM 혼합모델을 제안한다. 제안하는 모델의 구조는 Convolution layer, LSTM layer, Fully-connected layer로 구성된다. Figure 4는 31x7의 크기로 입력되는 비행 데이터에 대한 제안하는 혼합모델의 구조를 나타낸 것이다.

Convolution layer에서는 31x7 입력에 대해 각기 다른 초기 가중치를 지니는 300개의 3x3 kernel을 기반으로 합성곱 연산이 수행된다. 기존 예측 기법에서 사용된 혼합모델에서는 3x6 kernel을 이용한 합성곱 연산이 수행되기 때문에 시간축 방향의 필터링은 수행되지만 입력 변수들간의 공간적 상관성은 충분히 고려되지 못하는 한계를 지닌다. 본 논문에서는 입력되는 상태 변수들간 시,공간적 특징 추출을 동시에 수행하기 위하여 3x3 크기의 kernel을 이용하여 합성곱 연산을 수행한다. 합성곱 연산의 수행이 완료되면 29x5x300 크기의 feature map이 출력되며 이것은 29x1500으로 재구성된 후 LSTM 모델로 입력된다.

4개의 Gate로 구성되는 LSTM모델은 현재 출력된 cell state와 hidden state가 회귀되어 다음 연산에 대

한 입력으로 재사용되는 구조를 지닌다. Fig. 4의 LSTM은 1x1500 크기의 데이터가 29번 회귀되면서 학습되어진다. 이때 LSTM의 출력 크기를 나타내는 unit은 실험을 통하여 128로 설정하였다. 따라서 LSTM은 29x128로 구성되는 특징을 출력하게 되고 이것은 Dense Layer의 입력으로 사용되기 위해 평면화 과정을 거쳐 1차원으로 변환된다.

Fully-connected layer는 3개의 Dense layer로 구성된다. 512, 256 노드로 구성되는 1, 2번째 Dense layer는 특징 패턴 학습을 위해 사용된다. 그리고 3개의 노드를 지니는 3번째 Dense layer는 q , θ , α 변수에 대한 예측값을 출력한다. 3개의 Dense layer에서 활성화 함수는 tanh, sigmoid, linear 순으로 설정된다.

4. 모의 실험 및 결과

4.1 모델 학습 조건

본 논문에서는 제안하는 예측 기법의 성능을 확인하기 위하여 Table 3에 제시된 학습 조건을 기초로 하여 혼합 모델을 학습하였다. 혼합 모델의 학습에 필요한 초기 가중치, 학습률, 배치 크기와 같은 학습 파라미터는 실험적 탐색을 통하여 가장 우수한 예측 성능을 가져오는 최적의 값들로 설정하였다.

Table 3 Training Conditions

Optimizer	Loss Function	Max Epoch	Patience
Adam	MSE	500	30

4.2 예측 성능 분석

4.2.1 기존 탐지 기법과의 성능 비교

본 논문에서는 제안하는 CNN-LSTM 혼합 모델의 우수성을 확인하기 위하여 현재 시점을 기준으로 0.5 초 이후의 미래 시점에서의 비행 상태 변수 예측을 수행하였다. 4.1절에 언급한 바와 같이 실험적 탐색을 통하여 가장 우수한 성능을 가져오는 최적의 학습 파라미터들이 학습에 사용되었다. Table 4는 학습에 사용된 파라미터들을 정리한 것이다.

Figure 5는 기존 혼합 모델과 제안하는 혼합 모델의 Training & Validation Loss 그래프이다. Fig. 5에서 기존 혼합 모델은 633 Epoch에서 Loss값이 1.296 e-5으로 수렴하는 반면에 제안하는 혼합 모델은 360 Epoch에서 Loss값이 0.487e-5에 수렴하고 있다. 전반적으로 제안 모델의 학습 속도와 학습 상태가 상대적으로 우수함을 알 수 있다.

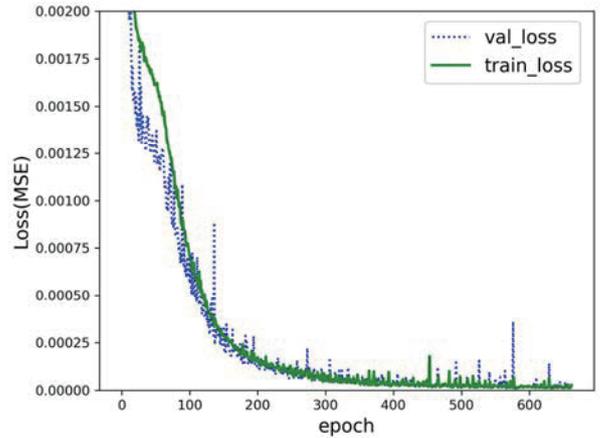
그리고 Table 5의 RMSE(Root Mean Square Error) 값은 2개의 테스트 데이터에 대하여 제안하는 혼합 모델의 예측 오차가 기존 모델에 비해 평균적으로 약 150% 개선되는 것을 보여준다. Fig. 6은 0.5초 미래 시점에 있어서 q , θ , α 변수에 대한 예측 그래프이다. q , θ , α 변수 모두에서 제안하는 혼합 모델이 기존 모델에 비하여 우수한 예측 정확도를 보이고 있음을 쉽게 확인할 수 있다.

Table 4 Training Parameters

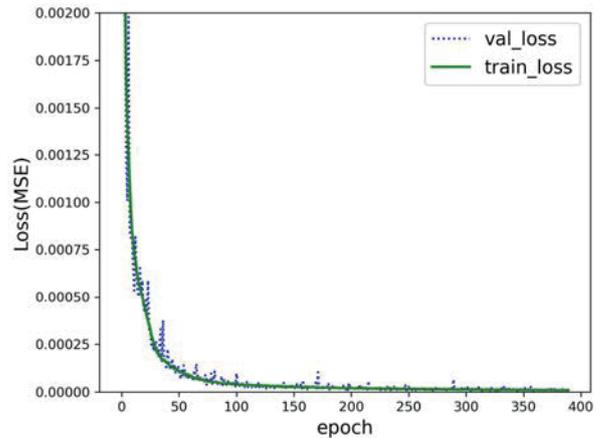
Technique	Learning rate	Batch size	Unit
Existing	0.0001	64	16
Proposed	0.00005	16	128

Table 5 RMSE Comparisons for Existing and Proposed Techniques

Test data	Technique	α	q	θ
UT-2	Existing	0.3166	2.9049	0.3355
	Proposed	0.0735	0.8400	0.1561
UT-3	Existing	0.0939	1.4494	0.4488
	Proposed	0.0857	0.7590	0.2189



(a) Existing Model



(b) Proposed Model

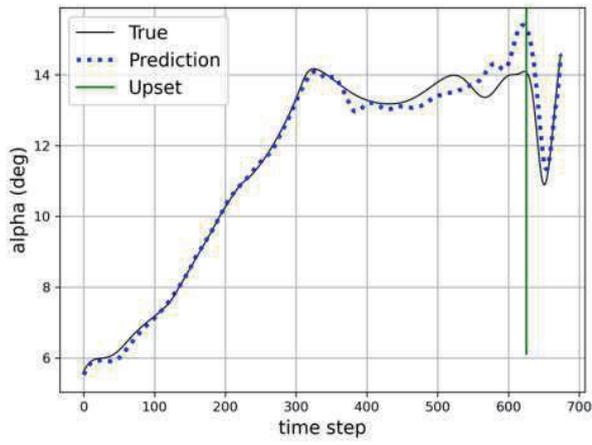
Fig. 5 Training and Validation Loss Graphs

4.2.2 LSTM Unit 설정과 현재 데이터 추가 효과

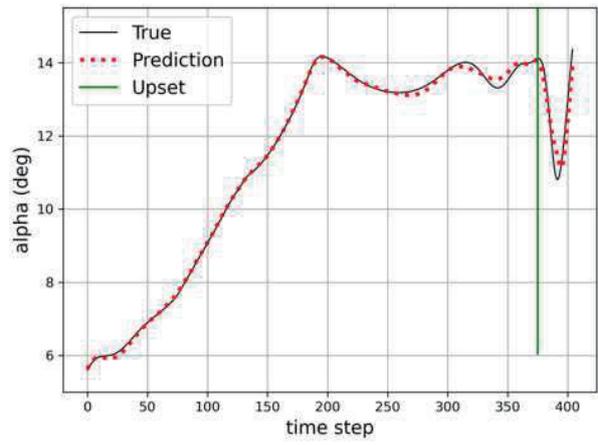
제안하는 혼합 모델의 특징인 LSTM의 unit 설정과 현재 시점 데이터의 추가가 예측 성능에 미치는 효과를 살펴보는 것은 의미있는 일일 것이다.

본 논문에서는 LSTM unit을 32, 64, 128, 256으로 변경하면서 학습을 수행하여 Loss값이 가장 작은 값으로 수렴하는 128을 unit 파라미터의 최종 값으로 선정하였다. 그리고 Table 6은 UT-2와 UT-3 테스트 데이터에 대하여 unit 설정에 따른 예측 결과이다. unit이 128일 때 예측 성능이 가장 우수함을 알 수 있다.

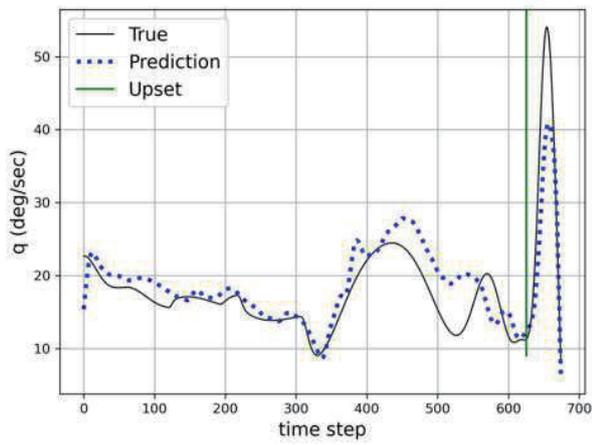
현재 시점 데이터 추가가 예측 성능에 미치는 영향을 확인하기 위하여 UT-2와 UT-3 테스트 데이터에 대한 예측 결과를 비교하였다. Table 7에서 데이터를 추가한 경우가 데이터를 추가하지 않은 경우에 비하여



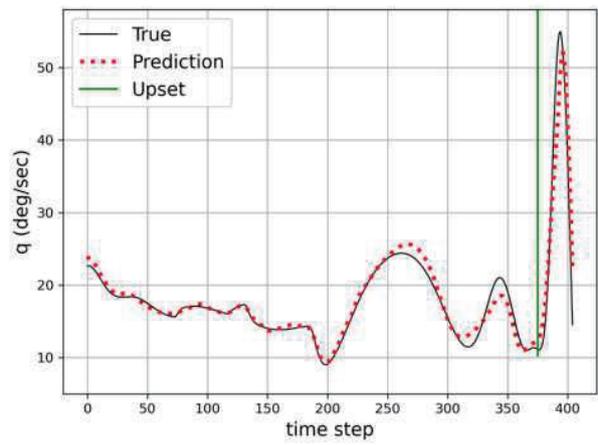
(a) α Prediction by existing model



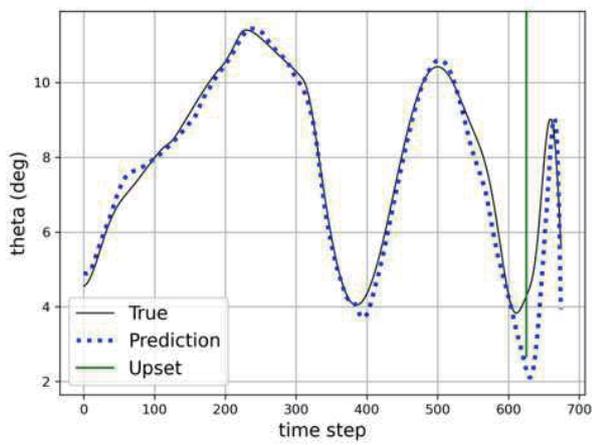
(b) α Prediction by proposed model



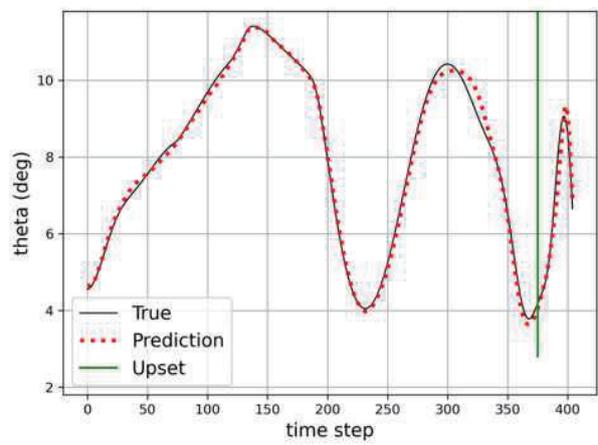
(c) q Prediction by existing model



(d) q Prediction by proposed model



(e) θ Prediction by existing model



(f) θ Prediction by proposed model

Fig. 6 Prediction Graphs for α , q , and θ Flight States

Table 6 RMSE according to Unit of LSTM

Test Set	Unit	α	q	θ
UT-2	32	0.0889	1.0761	0.1936
	64	0.1357	1.5625	0.2063
	128	0.0735	0.8400	0.1561
	256	0.1312	1.2667	0.2032
UT-3	32	0.1040	0.8670	0.2963
	64	0.0707	0.7759	0.2769
	128	0.0857	0.7590	0.2189
	256	0.1078	0.9488	0.3010

Table 7 RMSE Comparisons for Padding Current Data or not

Test Data	Padding	α	q	θ
UT-2	No	0.1012	1.1164	0.1989
	Yes	0.0735	0.8400	0.1561
UT-3	No	0.1130	0.9901	0.3259
	Yes	0.0857	0.7590	0.2189

항상 예측 성능이 우수하다는 것을 쉽게 확인할 수 있다. 이러한 사실은 현재 데이터 추가로 인하여 가장자리 효과가 개선되었음을 의미한다.

4.2.3 실시간 구동 가능성 검증

본 논문에서 제안하는 혼합모델을 이용한 비행 상태 예측 기법이 실시간으로 동작할 수 있는지를 확인하는 것은 중요한 일이다. Table 8은 PC 환경과 온보드 환경에서 제안된 예측 기법의 실행 시간에 대한 실험 결과를 보여준다. Table 8에서 제안하는 예측 기법이 온보드 환경에서 평균 0.022초 소요되는 것을 알 수 있다. 이러한 실험 결과는 30 Hz 데이터 수신 환경에서 제안 기법이 실시간으로 비행 상태 예측을 수행할 수 있음을 의미한다.

5. 결 론

본 논문에서는 무인기 비정상 비행 상태 예측을 위한 개선된 CNN-LSTM 모델을 제안하였다. 기존 모델

Table 8 Execution Time for Predictions on PC and Jetson TX2 Environments

	Execution Time	UT-2	UT-3
PC	Min	0.0030sec	0.0030sec
	Max	0.0050sec	0.0050sec
	Average	0.0036sec	0.0036sec
Jetson TX2	Min	0.0193sec	0.0194sec
	Max	0.0540sec	0.0474sec
	Average	0.0221sec	0.0218sec

한계를 극복하고 시,공간적 특징을 보다 효과적으로 반영하기 위하여 제안하는 혼합모델에서는 2차원 형식의 합성곱 연산이 적용되며 입력 데이터에 현재 시점 데이터가 추가된다. 또한 상관성 분석을 통하여 입력 데이터 길이를 결정함으로써 자원의 불필요한 낭비를 제거한다. 모의실험을 통해 제안하는 CNN-LSTM 모델을 활용한 예측 기법이 기존 예측 기법보다 우수한 예측 성능을 지니고 있음을 알 수 있었다. 또한 PC와 온보드 환경에서의 구동 실험을 통하여 제안 기법이 30 Hz 주기의 데이터에 대하여 실시간으로 운용될 수 있음을 확인하였다.

후 기

본 논문은 항공우주연구원의 국토교통부 연구개발사업의 연구비 지원(21ACTO-B151664-03)에 의해 수행되었습니다.

References

- [1] Lee Hae Chang, "Recent Trends and Prospects of UAM," *Korea Aerospace Research Institute*, Vol. 21, No. 2, pp. 3-12, Dec. 2023
- [2] Choi Joo Won, "Unmanned Aerial System Certification Technology Trends," *Korea Aerospace Research Institute*, Vol. 4, No. 1, pp. 100-107, Sept. 2006
- [3] Zhang Xianwei, Shang Junqian, Zhang Qian., "Application Of Kalman Filter Algorithm In Track

- Prediction,” *5th International Conference on Information Science, Computer Technology and Transportation (ISCTT)*, pp.292-296, Nov. 2020
- [4] Taewon Uhm, Kyoungyong Jo, Seungkeun Kim, “Estimation of Battery State of Charge for UAV Using Adaptive Extended Kalman Filter,” *The Korean Society for Aeronautical and Space Sciences*, Vol. 51, No. 4, pp. 243-251, April 2023
- [5] Julio Galvan, Ashok Raja, Yanyan Li, Jiawei Yuan, “Sensor Data-Driven UAV Anomaly Detection using Deep Learning Approach,” *IEEE Military Communications Conference (MILCOM)*, pp. 589-594, Nov. 2021
- [6] Hyun-Jae Im, Tae-Rim Kim, Jong-Gyu Song and Bum-Su Kim, “Anomaly Detections Model of Aviation System by CNN,” *Korea Aerospace Research Institute*, Vol. 17, No. 4, pp. 67-74, Aug. 2023
- [7] Yaohua Liu, and Yimin Zhou and Xiang Li, “Attitude Estimation of Unmanned Aerial Vehicle Based on LSTM Neural Network,” *International Joint Conference on Neural Networks (IJCNN)*, July 2018
- [8] Yuxiang Zhang, Ke Li, Jingyi Liu, “Intelligent Prediction Method for Updraft of UAV That Is Based on LSTM Network,” *IEEE Transactions on Cognitive and Developmental Systems*, Vol. 15, No. 2, pp. 464-475, 2020
- [9] Zihao Cao, Yongxin Zhu, Zhanrui Sun, Menglin Wang, Yu Zheng, Peng Xiong, Junjie Hou, Li Tian, “Improving Prediction Accuracy in LSTM Network Model for Aircraft Testing Flight Data”, *2018 IEEE International Conference on Smart Cloud*, pp.7-12, Sept. 2018
- [10] Jinsang Park and Min jae Song and Eun ju Choi and Young Ho Moon and Byoung Soo Kim, “Flight State Prediction Techniques Using a Hybrid CNN-LSTM Model,” *Journal of Aerospace System Engineering*, Vol. 16, No. 4, pp. 45-52, 2022
- [11] Jules J. Berman, Principles and Practice of Big Data, 2nd Ed, Academic Press, 2018
- [12] Russell W. Duren, “Performance enhancement of avionics systems,” *IEEE Aerospace and Electronic Systems Magazine*, Vol. 25, No. 7, pp. 25-29, July 2010