

## CNN-LSTM 혼합모델을 이용한 비행상태 예측 기법

박진상<sup>1</sup> · 송민재<sup>1</sup> · 최은주<sup>2</sup> · 김병수<sup>1</sup> · 문용호<sup>1,†</sup><sup>1</sup>경상국립대학교 일반대학원 기계항공공학부<sup>2</sup>한국항공우주연구원 항공연구소

## Flight State Prediction Techniques Using a Hybrid CNN-LSTM Model

Jinsang Park<sup>1</sup>, Min jae Song<sup>1</sup>, Eun ju Choi<sup>2</sup>, Byoung soo Kim<sup>1</sup> and Young ho Moon<sup>1,†</sup><sup>1</sup>School of Mechanical and Aerospace Engineering, Gyeongsang National University<sup>2</sup>Korea Aerospace Research Institute

## Abstract

In the field of UAM, which is attracting attention as a next-generation transportation system, technology developments for using UAVs have been actively conducted in recent years. Since UAVs adopted with these technologies are mainly operated in urban areas, it is imperative that accidents are prevented. However, it is not easy to predict the abnormal flight state of an UAV causing a crash, because of its strong non-linearity. In this paper, we propose a method for predicting a flight state of an UAV, based on a CNN-LSTM hybrid model. To predict flight state variables at a specific point in the future, the proposed model combines the CNN model extracting temporal and spatial features between flight data, with the LSTM model extracting a short and long-term temporal dependence of the extracted features. Simulation results show that the proposed method has better performance than the prediction methods, which are based on the existing artificial neural network model.

## 초 록

최근 차세대 운송시스템으로 주목받고 있는 UAM 분야에서 무인항공기 활용을 위한 기술 개발이 활발히 진행되고 있다. 이러한 기술이 적용된 무인항공기는 주로 도심에서 운용되기 때문에 추락사고를 예방하는 것이 중요하다. 그러나 충돌이 발생하는 무인항공기는 비선형성이 강하기 때문에 비정상 비행상태를 예측하는 것은 쉽지 않은 일이다. 본 논문에서는 CNN-LSTM 혼합모델을 이용하여 무인항공기의 비행상태를 예측하는 방법을 제안한다. 제안 모델은 비행 데이터간의 시간적, 공간적 특징을 추출하는 CNN 모델과 추출된 특징의 장단기 시간 의존성을 추출하는 LSTM 모델을 결합하여 미래의 특정 시점에서 비행 상태변수를 예측한다. 모의 실험은 제안하는 방법이 기존 인공신경망 모델에 기반한 예측 방법보다 우수한 성능을 보인다.

**Key Words:** UAV(무인항공기), UAM(도심형 항공 이동 수단), CNN(합성곱 신경망), LSTM(장단기 메모리)

## 1. 서 론

무인항공기는 미국을 필두로 군사용 목적으로 개발되었으나, 최근에는 민간분야에서 활발하게 개발, 적

용되고 있다[1]. 특히, 유, 무인항공기를 이용하여 도심 내외에서 사람 또는 화물을 운송하는 차세대 교통체계인 UAM(Urban Air Mobility)에 대한 큰 관심과 활발한 연구가 집중되고 있다[2,3]. 도심 상공에서 운용되는 만큼 무인항공기가 추락할 경우 지상의 건물 및 차량 그리고 사람과의 충돌 사고로 이어질 가능성이 매우 높기 때문에 무인항공기의 안정적인 운용은 매우 중요한 필수 요소로 인식된다. 무인항공기의 안

Received: Apr. 20, 2022 Revised: Jul. 07, 2022 Accepted: Jul. 19 2022

† Corresponding Author

Tel: +82-055-772-1374, E-mail: yhmoon@gnu.ac.kr

© The Society for Aerospace System Engineering

정적인 운용을 위해서는 무엇보다도 통제 불능의 상태에 빠지는 것을 예방하는 것이 중요하다. 이러한 통제 불능의 상태는 항공기의 비정상 비행 상태 진입으로부터 시작되기 때문에 사전에 무인항공기의 비정상 비행 상태를 예측하여 비정상 비행 상태에 도달하는 것을 방지하는 기술의 개발은 중요한 의미를 지닌다.

최근 딥러닝 기술이 발달하면서 다양한 분야에서 인공신경망을 이용한 시스템 식별 및 상태 예측 관련 연구들이 수행되어왔다. 다양한 인공신경망 모델들 가운데에서도 NARX(Nonlinear AutoRegressive eXogenous) 모델은 회귀적 구조와 입력 데이터의 시간 지연을 고려할 수 있는 특징으로 인하여 시계열 데이터 연구에 널리 활용되었다. 항공기의 비정상 비행 상태 탐지의 경우 NARX 모델과 Multi Step 예측 기법을 활용하여 비행 데이터를 학습하여 종, 횡축 상태변수들을 예측하는 연구가 수행되었다[4]. 그러나 NARX 모델은 비교적 단순한 MLP(Multi-Layer Perceptron) 구조에 기반하기에 입력 데이터의 크기에 비례하여 모델의 복잡도가 쉽게 증가되고 이로 인한 과소 적합 문제가 발생할 수 있다는 단점을 지닌다.

합성곱 연산에 기반한 특징 추출 능력을 보유하고 있는 CNN(Convolutional Neural Network) 모델은 영상처리 분야뿐만 아니라 시스템 상태 예측 분야의 연구에도 활용되어 왔다[5-7]. CNN 모델은 NARX 모델과 달리 입력 데이터의 크기가 증가하여도 모델의 복잡도가 쉽게 증가하지 않고 잡음에 대해 강건한 예측이 가능한 장점을 지닌다. 그러나 Pooling 과정에 의하여 정보 손실이 발생할 수 있으며 먼 시점의 데이터 간 특징을 추출하기 위해 모델의 깊이를 깊게 구성할수록 학습이 쉽지 않고 계산량이 증가한다는 한계를 지닌다. 한편 기존의 RNN 모델의 고질적인 문제인 기울기 소실 현상을 개선한 LSTM 모델은 Cell 개념을 토대로 시계열 데이터 예측에 특화된 인공신경망 모델로 알려져 있다. Cell 구조는 과거의 입력에 대한 정보를 반영하기 때문에 장기 시간 의존성을 고려할 수 있는 특징을 지니고 있어서 시계열 데이터 예측 및 결합 탐지에 활용되어 왔다[8,9]. 최근에는 다양한 분야에서 CNN 모델과 LSTM 모델을 혼합하여 시계열 데이터 예측을 수행하는 연구들이 진행되었으나[10-12] 무인 항공기의 비행 데이터 예측에 대한 연구에는 아

직 적용되지 못하였다.

본 논문에서는 CNN 모델과 LSTM 모델의 장점을 결합한 CNN-LSTM 혼합 모델에 기반한 비행 상태변수 예측 기법을 제안한다. 혼합 모델의 CNN부는 convolution layer를 통해 입력되는 비행 데이터의 다양한 시, 공간적 특징들을 추출하고 LSTM부에서는 추출된 특징들의 단, 장기적 시계열 특성들을 추출한다. 그리고 MLP 구조의 fully-connected layer부에서는 비행 상태변수 예측을 수행한다. 모의실험은 NARX 모델과 CNN 모델 기반 예측 기법들에 비하여 제안하는 기법이 우수한 성능을 지니고 있음을 보인다.

## 2. 기존 인공신경망 기반 비행 상태 예측

### 2.1 NARX 모델을 이용한 비행상태 예측

NARX 모델은 일반적인 MLP 구조와 유사하지만 미래 예측을 위해 현재 출력이 회귀되어 모델의 입력으로 재사용된다는 특징을 지닌다. NARX 모델에서는 MLP 구조와 동일한 open loop 형태에서 학습이 진행되며 학습이 완료될 경우에는 closed loop 형태로 변환하여 예측을 수행한다. 따라서 미래 시점의 비행 상태 변수를 예측하기 위해서는 먼저 현재 시점부터 일정 기간의 과거 시점까지의 비행 데이터를 사용하여 open loop 구조에서 오차 역전과 방식에 의하여 학습이 진행된다. 그리고 학습이 완료되면 closed loop 구조로 변환하여 multi step 예측 기법을 통해 목표하는 미래 시점의 비행 상태변수를 예측한다. Fig. 1은 closed loop 형태의 NARX 모델 구조를 보여준다.




Fig. 1 Flight state prediction using NARX model with closed loop

## 2.2 CNN 모델을 이용한 비행상태 예측

CNN 모델의 기능적 구조는 크게 convolution layer, pooling layer, 그리고 fully-connected layer로 나뉜다. convolution layer에서는 고유한 가중치를 지닌 다수의 kernel들에 의하여 합성곱 연산이 수행되어 입력 데이터의 다양한 특징들이 추출된다. 추출된 특징들은 pooling layer에서 pooling 연산을 통해 down sampling 된다. 이러한 pooling 연산은 데이터의 크기를 감소시키기 때문에 모델의 복잡도를 줄여서 과적합 문제를 억제할 수 있으며 sampling 효과로 인해 잡음 제거도 수행된다. 마지막으로 pooling layer의 출력들은 1차원 벡터 형태로 변환되어 최종 출력층과 전연결되고 출력층의 활성화 함수에 따라 회귀분석 또는 분류를 수행하게 된다.

Figure 2는 CNN 모델 구조를 이용한 비행 상태 예측 방식을 나타낸 것이다. Fig. 2에서 알 수 있듯이 convolution layer와 pooling layer가 2번 반복되는 구조를 지닌다. 그리고 2번째 convolution layer와 pooling layer를 거친 2차원 데이터는 1차원 데이터로 평탄화되어 128개의 뉴런으로 구성된 은닉층(Hidden Layer)과 전연결된 후 은닉층은 최종 출력층의 뉴런들과 연결된다.




Fig. 2 Flight state prediction using CNN model

## 3. 제안하는 혼합 모델기반 예측 기법

본 논문에서는 무인항공기의 비행 상태 변수를 예측하기 위해 CNN-LSTM 혼합모델을 제안한다. Fig. 3은 50x6의 크기로 입력되는 비행 데이터에 대한 제안하는 혼합모델의 구조를 나타낸 것이다.




Fig. 3 Proposed hybrid model structure to predict flight status variables

### 3.1 Convolution Layer

Convolution layer에서는 3x6 형태의 kernel들을 이용한 합성곱 연산을 통하여 입력 데이터에 대한 시, 공간적 특징들을 추출한다. Fig. 3에 표시된 바와 같이 kernel의 열의 크기와 입력 데이터의 열의 크기가 동일하기 때문에 3 time step에 해당하는 비행 데이터들의 시, 공간적인 관계들이 동시에 반영된다. 또한 300개의 서로 다른 가중치를 지니는 kernel들이 사용되기 때문에 입력된 비행 데이터에 대하여 각기 다른 300가지의 특징들이 추출되어 Fig. 3에서와 같이 48x300 형태의 feature map이 최종 생성된다. 생성된 feature map의 정보 손실을 방지하기 위하여 feature map은 pooling 연산 없이 곧바로 LSTM의 입력으로 사용된다.

### 3.2 LSTM

Figure 4와 같이 4개의 Gate들로 구성된 LSTM 모델은 현재 출력된 cell state와 hidden state가 회귀되어 다음 입력에 대한 연산에 재사용된다. forget gate는 가중치에 의하여 입력되는 cell state에 포함된 과거 정보를 얼마나 유지할지를 결정하는 역할을 수행한다. 그리고 input gate와 cell gate는 현재 시점에 들어온 입력 데이터와 hidden state 정보를 cell state에 얼마나 반영할지를 결정하며, 마지막으로 output gate는 LSTM 모델의 출력인 hidden state에 cell state의 정보를 어느 정도 포함할 것인지를 결정하는 역할을 담당한다.

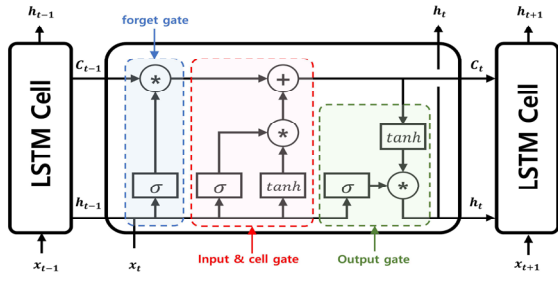


Fig. 4 Basic structure of LSTM model

Figure 3의 LSTM 부는 convolution layer에서 추출된  $48 \times 300$  형태의 feature map에 대한 회귀 연산을 수행한다. 입력되는  $1 \times 300$  크기의 특징 데이터들에 대한 장, 단기적 시간 의존성을 파악하기 위하여 LSTM에서는 cell state와 hidden state의 회귀를 통해 48번의 연산이 수행된다. 따라서 LSTM의 출력인 hidden state는 각 time step 별로  $1 \times 16$  크기의 벡터로 출력되어 최종  $48 \times 16$  크기의 2차원 벡터 형태가 LSTM 부에서 생성된다.


### 3.3 Fully-Connected Layer

LSTM 부의 출력으로 생성된  $48 \times 16$  크기의 출력 데이터는 은닉층과의 전연결을 위해 평탄화 과정을 통해  $1 \times 769$  형태의 1차원 벡터로 변환된다. 변환된 출력 벡터는 256개의 뉴런들로 구성되는 첫 번째 은닉층과 완전 전연결된 후 64개의 뉴런들로 구성되는 두 번째 은닉층을 거쳐 최종 예측값을 생성하는 output layer와 연결된다. output layer에서는  $t_c + 0.2 \text{ sec}$  시점의  $\alpha, q, \theta$ 에 대한 예측값을 출력한다.


## 4. 모의 실험 및 결과

### 4.1 실험 데이터 생성

본 논문에서는 모의 실험을 수행하기 위하여 비정상 비행 시나리오를 구성하고 무인항공기 시뮬레이션을 통하여 실험 데이터를 생성하였다. 무인항공기 운영 중 조종 불능 상태를 발생시키기 위하여 공기역학적으로 비정상 비행 상태로 정의된 실속(stall)으로 인한 upset 상황이 발생하는 시나리오를 설정하였다.



(a)



(b)


Fig. 7 Simulation result. (a)  $V_T$  &  $V_C$  and (b)  $\alpha$

이러한 비정상 비행 시나리오를 구현하기 위해 시뮬레이션 상에서 무인항공기 임무 수행 중 인위적으로  $V_C$ 값을  $V_{stall}$ 이하의 값으로 부여하여 실속 상태를 유발하고 점진적으로 upset 상태에 빠져드는 상황을 모사하였다. Figure 5는 실속 속도 이하의 명령을 부여한 경우 시뮬레이터에서의 무인항공기의  $V_T$ 과  $\alpha$ 값의 변화를 보여준다.

정의된 비정상 비행 상태 시나리오에 기초하여 학습 데이터(training data)를 생성하기 위해 초기 조건과 명령 값을 다양하게 조합하여 여러 번 시뮬레이션을 수행하였다. Table 1은 실험 데이터 생성을 위해 사용된 조건들을 보여준다. 정상 비행의 경우에는

Table 1 Conditions for generating upset flight data

Case	Initial V ( $V_0$ ) [m/s]	Cmd V ( $V_C$ ) [m/s]	Cmd Phi( $\phi_C$ ) [deg]	비행상황
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	19	7	35	Stall



**Fig. 6** The trajectory of UAV. (a) normal flight and (b) upset flight.

Figure 6의 (a)와 같이 원형 궤적을 보이지만 실속 속도 이하로 내려간 경우에는 (b)와 같이 원형 궤적을 벗어나 upset 상황에 빠지는 것을 확인할 수 있었다. 한편 모델의 예측 능력과 일반화 능력을 확인하기 위하여 학습 데이터 생성에 이용되지 않은 초기 조건( $H_0=300\text{m}$ ,  $V_0=19\text{m/s}$ ,  $\phi_0=0\text{deg}$ )과 제어 명령( $V_c=7\text{m/s}$ ,  $\phi_c=35\text{deg}$ )에 의하여 생성된 비행 데이터를 테스트 데이터(test data)로 사용하였다.

비정상 비행상태 모사 시뮬레이션을 통해 생성된 비행 데이터들 가운데서 upset 상황과 밀접한 연관성을 가지는 종축 비행 상태변수  $\alpha, q, \theta, \delta e_{out}, V_T, H$ 를 입력 데이터로 선정하였다. 원본 데이터들의 경우 상태변수들의 단위가 상이하기 때문에 원본 값을 인공신경망 모델의 입력으로 사용할 경우 값이 큰 상태변수에 의해 편향된 결과가 야기될 수 있기 때문에 각 상태변수들을 정규화하는 과정이 요구된다. 본 논문에서는 Eq. 1과 같이 min-max값을 사용하여 각 상태변수들을 0~1사이 값으로 정규화하였다.

$$\text{MinMax Normalize} = \frac{(x - \min(x))}{(\max(x) - \min(x))} \quad (1)$$

본 논문에서는 정규화된 데이터들을 CNN-LSTM 혼합모델의 입력으로 사용하기 위하여 window sliding 기법을 활용하여 정규화된 데이터들을 50x6 크기의 계조 영상들로 분할하였다. 이러한 과정에 의하여 총 23,190개의 계조 영상들이 생성되었으며 이중 무작위로 80% 데이터를 학습 데이터로 나머지 20%를 검증 데이터(validation data)로 선별하였다.

## 4.2 모델 학습 조건

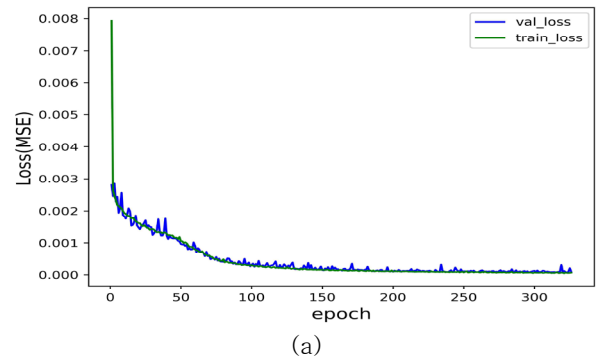
본 논문에서는 제안하는 혼합 모델의 성능을 확인하기 위하여 NARX 모델, CNN 모델, 그리고 CNN-LSTM 모델을 각각 학습한 후 테스트 데이터를 이용하여 예측 결과를 비교하였다. 실험에 사용된 3가지 모델은 현재 시점  $t_c$ 에서  $t_c-0.98\text{sec}$ 까지 총 50 time step의  $\alpha, q, \theta, \delta e_{out}, V_T, H$  데이터를 사용하여  $t_c + 0.2\text{sec}$  시점의  $\alpha, q, \theta$ 를 예측하도록 학습이 수행되었다. Table 2는 학습에 사용된 파라미터들로서 NARX 모델, CNN 모델, 그리고 CNN-LSTM 혼합 모델에 동일하게 적용되었다. 그리고 각 모델들의 최적 학습 상태를 구하기 위해 early stoping 기법이 학습에 사용되었다. 이 기법은 학습 중 일정 epoch 동안 모델의 검증 손실이 개선되지 않을 경우 과적합을 방지하기 위해 학습을 중단하는 방식으로서 적절한 반복 학습 횟수를 알지 못할 경우 모델의 과적합 및 과소적합을 방지하고 최적의 학습 상태를 구하는 데 효과적이다.

**Table 2** Training parameter.

Optimizer	Learning rate	Loss function	Max epoch	Patience
Adam	0.0001	MSE	500	30

## 4.3 학습 결과

Figure 7은 3가지 인공신경망 모델들에서 얻어진 학습 결과로서 epoch 별 학습 데이터와 검증 데이터에 대한 손실 값 추이를 보여준다. 그리고 Table 3은 인공신경망 모델별 학습 시간과 최적화된 모델들의 검증 손실 값을 보여준다. 모델 구조의 복잡도가 가장 높은 CNN-LSTM 혼합모델의 학습 시간이 가장 길지만 검증 손실 값은 가장 작음을 알 수 있다.






Fig. 7 Training and validation loss. (a) NARX, (b) CNN, (c) CNN-LSTM

Table 3 Training result

	학습 시간(sec)	best epoch	val loss
NARX	4,440	296	0.00006864
CNN	5,649	269	0.00002732
CNN-LSTM	8,176	292	0.00001887

#### 4.4 예측 결과

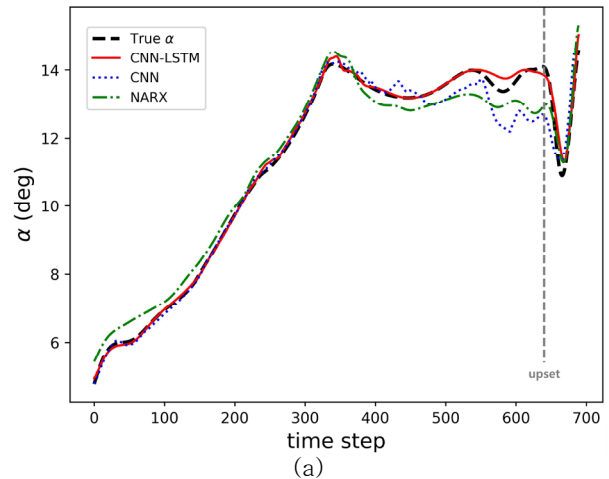
Table 4는 동일한 테스트 데이터에 대한 인공지능 경망 모델들의 비행 상태변수별 예측 결과를 RMSE로 나타낸 것이다. RMSE를 비교한 결과 본 논문에서 제안하는 CNN-LSTM 혼합모델의 예측 결과가 모든 비행 상태변수에서 가장 우수함을 확인할 수 있다. 그리고 공통적으로 비행 상태변수들 가운데  $q$ 에 대한 예측 오차가 가장 높음을 알 수 있다.

Table 4 RMSE for predictions performed by neural network model

	$\alpha$ (deg)	$q$ (deg/sec)	$\theta$ (deg)
NARX	0.4783	4.5982	0.4780
CNN	0.4335	5.2610	0.2391
CNN-LSTM	0.1464	1.3773	0.2331

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (p_i - y_i)^2}{n}} \quad (2)$$

Figure 8은 NARX모델, CNN모델, 그리고 CNN-LSTM 혼합모델에서 얻어진  $\alpha, q, \theta$ 에 대한 예측 결과들을 함께 도시한 그래프이다. 회색의 수직 점선은 upset이 발생한 시점을 표시한 것이며 각 모델의 예측 결과를 실제 값과 시점을 맞춰 동일선상에 나타내었다.  $\alpha$ 와  $q$ 의 경우 비행 초기의 정상 상태에서는 모든 모델들에서 예측 오차가 비교적 크게 발생하지 않았지만 upset이 발생하기 100 time step 전부터 NARX 모델과 CNN 모델의 예측이 크게 벗어남을 알 수 있다. 반면에 CNN-LSTM 혼합모델의 경우 정상 상태는 물론 upset이 발생하기 직전과 직후에 대한 예측이 다른 두 모델에 비해 정확함을 확인할 수 있다. 그리고  $\theta$ 의 경우에는 CNN 모델과 CNN-LSTM 혼합모델이 NARX모델보다 안정적인 예측을 수행하였으며 비슷한 예측 성능을 보이고 있음을 알 수 있다.



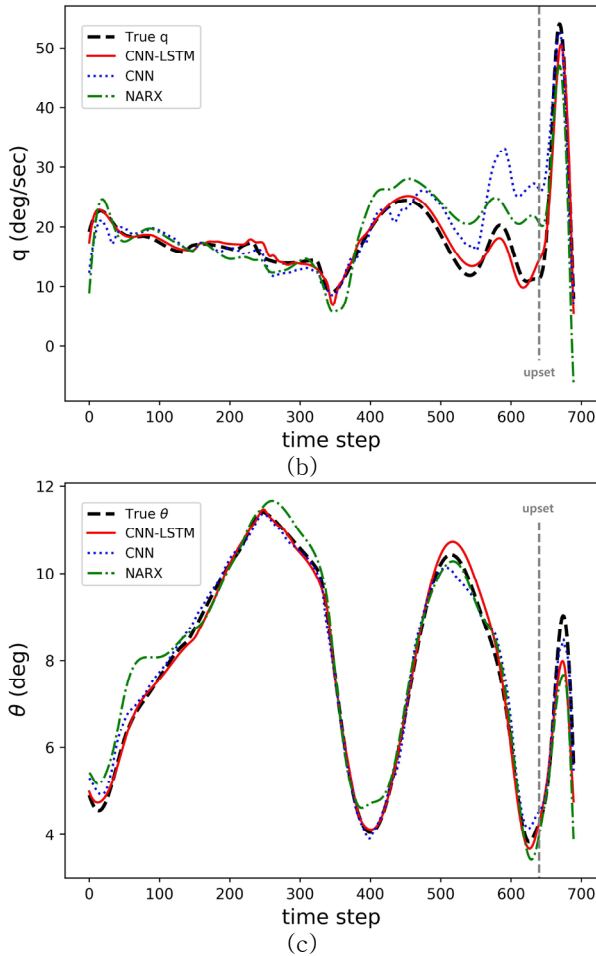


Fig. 9 Comparison prediction results. (a)  $\alpha$ , (b)  $q$ , (c)  $\theta$

## 5. 결론

본 논문에서는 CNN-LSTM 혼합모델을 이용하여 무인항공기의 비정상 비행상태를 예측하는 기법을 제안하였다. 제안하는 혼합모델은 CNN부에서 합성곱 연산을 통해 입력되는 비행 데이터들간의 시,공간적 특징들을 추출하고, LSTM부에서는 추출된 특징들의 단,장기적인 시계열 특성들을 추출한다. 그리고 전연결부에서 추출된 시계열 특성을 이용하여 특정 시점의 비행 상태변수들을 예측한다. 제안하는 CNN-LSTM 혼합모델의 예측 성능을 확인하기 위하여 기존 NARX 모델과 CNN모델에 기반한 예측 기법들과 성능 비교를 수행하였다. 모의 실험 결과를 통하여 제안하는 기법이 기존 기법들에 비하여 우수한 예측 성능을 보인다

는 사실을 확인하였다. 특히 변화가 큰  $q$ 에 대해서 CNN-LSTM 혼합모델이 기존 기법들보다 정확한 예측을 수행하였으며 예측 오차가 상대적으로 크게 발생하는 upset 발생 직전에도 제안하는 혼합모델은 높은 예측 성능을 보였다.

## 후 기

본 연구는 국토교통부 연구개발사업의 연구비 지원(22ACTO-B151661-04)에 의해 수행되었습니다.

## References

- [1] SeungJong Song and Byung-ok Gil, "A Study on the History and Strategic Implications of Military Drones Development," *Institute for Military History(MND)*, no. 97, pp. 263-308, Dec. 2015.
- [2] Choong Hyun Choi, "[KISTEP Technology trend brief] Personal Air Vehicle(PAV)," *Korea Institute of Science & Technology Evaluation and Planning*, no. 5, Apr 2015.
- [3] Jeong-ho Yang, "Personal Aircraft (PAV) Technology Market Trends and Industrial Environment Analysis Report," *Korea Aerospace Research Institute*, May 2019.
- [4] On Park, "Aircraft Upset Detection Algorithm using Neural Networks," *Master's thesis. Chungnam National University*. Chungnam. Korea, 2016.
- [5] Junjie He, Junliang Wang, Lu Dai, Jie Zhang, Jingsong Bao, "An Adaptive Interval Forecast CNN Model for Fault Detection Method," *2019 IEEE 15th International Conference on Automation Science and Engineering (CASE)*, Sep. 2019.
- [6] Yunfei Ma, Xisheng Jia, Huajun Bai, Guozeng Liu, Guanglong Wang, Chiming Guo, Shuangchuan Wang, "A new fault diagnosis method based on convolutional neural network and compressive sensing," *Journal of Mechanical Science and Technology*, vol. 33, no. 11, pp. 5177-5188, Nov 2019.

- [7] Kang Wang, Kenli Li, Liqian Zhou, Yikun Hu, Zhongyao Cheng, Jing Liu, Cen Chen, "Multiple convolutional neural networks for multivariate time series prediction," *Neurocomputing*, vol. 360, no. 30, pp. 107-119, Sep. 2019.
- [8] Aslam Muhammad, Jae Myoung Lee, Sug Won Hong, Seung Jae Lee, Eui Hyang Lee, "Deep Learning Application in Power System with a Case Study on Solar Irradiation Forecasting," *2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, pp. 275-279, 2019.
- [9] Benjamin Lindemann, Benjamin Maschler, Nada Sahlab, Michael Weyrich, "A survey on anomaly detection for technical systems using LSTM networks," *Computers in Industry*, vol. 131, 2021.
- [10] Jun Yang, Jingbin Qu, Qiang Mi, Qing Li, "A CNN-LSTM Model for Tailings Dam Risk Prediction," *IEEE Access*, vol. 8, pp. 206491-206502, Nov. 2020.
- [11] Musaed Alhussein, Khursheed Aurangzeb, Syed Irtaza Haider, "Hybrid CNN-LSTM Model for Short-Term Individual Household Load Forecasting". *IEEE Access*, vol. 8, pp. 2169-3536, Oct. 2020.
- [12] Haifeng Zheng, Feng Lin, Xinxin Feng, YouJia Chen, "A Hybrid Deep Learning Model With Attention-Based Conv-LSTM Networks for Short-Term Traffic Flow Prediction", *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, no. 11, pp. 6910-6920, Nov. 2021.

## 기호 설명

$t_c$	: 현재 시점
$V_T$	: 진대기속도(True Airspeed)
$V_C$	: 속도 제어 명령
$V_{stall}$	: 실속 속도
$\alpha$	: 받음각
$q$	: $\theta$ 각속도
$\theta$	: 피치각
$\phi$	: 롤각
$\delta e_{out}$	: 엘리베이터 출력
$H$	: 고도