

U-Net을 이용한 무인항공기 비정상 비행 탐지 기법 연구

송명재¹ · 최은주² · 김병수¹ · 문용호^{1,†}¹경상국립대학교 일반대학원 기계항공우주공학부²한국항공우주연구원 항공연구소

Abnormal Flight Detection Technique of UAV based on U-Net

Myeong Jae Song¹, Eun Ju Choi², Byoung Soo Kim¹ and Yong Ho Moon^{1,†}¹School of Mechanical and Aerospace Engineering, Gyeongsang National University²Korea Aerospace Research Institute

Abstract

Recently, as the practical application and commercialization of unmanned aerial vehicles (UAVs) is pursued, interest in ensuring the safety of the UAV is increasing. Because UAV accidents can result in property damage and loss of life, it is important to develop technology to prevent accidents. For this reason, a technique to detect the abnormal flight state of UAVs has been developed based on the AutoEncoder model. However, the existing detection technique is limited in terms of performance and real-time processing. In this paper, we propose a U-Net based abnormal flight detection technique. In the proposed technique, abnormal flight is detected based on the increasing rate of Mahalanobis distance for the reconstruction error obtained from the U-Net model. Through simulation experiments, it can be shown that the proposed detection technique has superior detection performance compared to the existing detection technique, and can operate in real-time in an on-board environment.

초 록

최근에 무인항공기의 실용화 및 사업화가 추진됨에 따라 무인항공기의 안전성 확보에 관한 관심이 증가하고 있다. 무인항공기의 사고는 재산 및 인명 피해를 발생시키기 때문에 사고를 예방할 수 있는 기술의 개발은 중요하다. 이러한 이유로 AutoEncoder 모델을 이용한 비정상 비행 상태 탐지 기법이 개발되었다. 그러나 기존 탐지 기법은 성능과 실시간 처리 측면에서 한계를 지닌다. 본 논문에서는 U-Net 기반 비정상 비행 탐지 기법을 제안한다. 제안하는 기법에서는 U-Net 모델에서 얻어지는 재구성 오차에 대한 마할라노비스 거리 증가량에 기반하여 비정상 비행이 탐지된다. 모의실험을 통해 제안 탐지 기법이 기존 탐지 기법에 비해 탐지 성능이 우수하며 온보드 환경에서 실시간으로 구동될 수 있음을 알 수 있다.

Key Words : UAV(무인항공기), Abnormal Flight(비정상 비행), UAM(도심형 항공 교통 체계), Deep Learning Model(딥러닝 모델), Mahalanobis Distance(마할라노비스 거리)

1. 서 론

20세기 초기부터 군사적 용도로 발전하기 시작한 무

인항공기는 산업 및 민간용 시장으로 빠르게 확산되어 물류 및 배송, 촬영, 농업 관리 등 다양한 분야에서 개발, 활용되고 있다[1]. 그러나 무인항공기의 활용 범위가 확대됨에 따라 무인항공기 관련 사고 발생 가능성 또한 증가하고 있다[2]. 무인항공기 관련 사고들은 재산 피해뿐만 아니라 인명 피해를 초래할 가능성이 매우 높다. 특히 UAM(Urban Air Mobility)이 지상 교통

수단의 대안으로 주목받기 시작하면서 인구가 밀집된 대도시에서의 무인항공기 추락 사고는 매우 심각한 피해를 발생시킬 것으로 예상된다[3]. 따라서 무인항공기의 비정상적인 비행을 식별하여 사고 발생을 예방하기 위해서는 추락 사고의 주요 원인 중 하나인 비정상 비행 진입을 탐지할 수 있는 기술 개발은 매우 중요한 상황이다.

최근 무인항공기 비정상 비행 상태 식별을 위하여 DBSCAN(Density-Based Spatial Clustering of Applications with Noise), Naive Bayes Classification과 같은 머신러닝 기반의 기법들이 개발되고 있다[4,5]. 그러나 머신러닝은 항공기 센서 기술의 발전으로 점점 고차원, 대용량화되는 비행 데이터에 대해 확장성 및 성능 면에서 한계를 드러내고 있다[6]. 이러한 한계를 극복하기 위해 AutoEncoder 또는 LSTM(Long Short Term Memory)과 같은 딥러닝 모델을 활용하여 비정상 비행을 식별하는 연구가 수행되고 있다[7]. 또한 딥러닝과 머신러닝을 결합한 하이브리드 모델을 활용한 연구도 활발하게 진행되고 있다[8,9]. 그러나 이러한 연구들은 비정상 비행 식별을 목표로 하기 때문에 비정상 비행 진입 시점을 제공하지 못하는 한계를 지닌다.

무인항공기의 사고를 예방하기 위해서는 무엇보다도 무인항공기가 비정상 비행으로 진입하는 시점을 정확하게 탐지하는 것이 중요하다. 최근에 비정상 비행 진입 시점을 파악하기 위하여 AutoEncoder 모델을 활용한 탐지 기법이 개발되었다[10]. AutoEncoder 모델 기반 탐지 기법에서는 모델에서 얻어지는 재구성 오류에 대한 마할라노비스 거리를 계산하여 임계값을 초과할 경우 비정상 비행으로 진입했다고 판단한다. 그러나 기존 탐지 기법은 AutoEncoder 모델의 높은 복잡도로 인해 실시간 처리에 한계가 존재한다. 또한 마할라노비스 거리의 최대값을 임계값으로 설정하기 때문에 마할라노비스 거리가 상대적으로 낮은 비행의 경우 탐지 지연으로 인한 탐지 성능 저하가 발생된다.

본 논문에서는 U-Net 모델에 기반한 비정상 비행 탐지 기법을 제안한다. 탐지 기법의 실시간 처리 성능 개선을 위하여 복잡도가 높은 AutoEncoder 모델 대신 복잡도가 낮은 U-Net 모델을 이용한다. 또한 탐지 성능 개선을 위하여 비정상 비행 진입 시점에서 마할라노비스 거리가 급증하는 현상에 기초하여 마할라노비

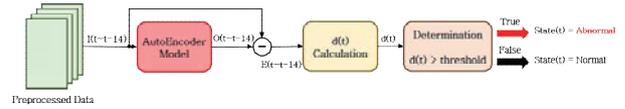


Fig. 1 Abnormal Flight Detection Procedure of Existing Detection Technique

스 거리 증가량을 기반으로 한 새로운 비정상 비행 판별 방식을 제시한다. 모의실험은 제안하는 탐지 기법이 기존 탐지 기법보다 우수한 탐지 성능을 지닌다는 것을 보인다. 또한 온보드 환경에서의 실험을 통하여 제안 기법이 실시간 구동이 가능함을 확인할 수 있다.

2. 기존 딥러닝 기반 비정상 비행 탐지 기법

Figure 1은 기존 탐지 기법의 세부 과정을 도식화한 것이다. 일반적으로 AutoEncoder 모델은 입력 데이터와 동일한 데이터가 출력되도록 학습된다. 이러한 사실에 기초하여 기존 탐지 기법에서는 정상 비행에서 얻어진 받은값 α , 피치각속도 q , 그리고 피치각 θ 데이터를 이용하여 AutoEncoder 모델을 학습한다. 따라서 정상 비행에서 얻어진 데이터가 입력될 경우에는 작은 재구성 오차가 출력되는 반면에 비정상 비행으로 인한 입력 데이터는 큰 재구성 오차를 발생시킨다.

기존 탐지 기법에서는 AutoEncoder 모델을 통하여 얻어진 재구성 오차가 비정상 비행에서 생성된 것인지를 판별하기 위하여 마할라노비스 거리를 계산한다. 비정상 비행의 경우 재구성 오차가 데이터 분포로부터 멀리 벗어나기 때문에 마할라노비스 거리가 특정 임계값보다 크면 비정상 비행으로 판별할 수 있다. 기존 기법에서는 Fig. 2와 같이 정상 비행 상태에서 얻어진 마할라노비스 거리값들 가운데 가장 큰 값을 임계값으로 설정한다.

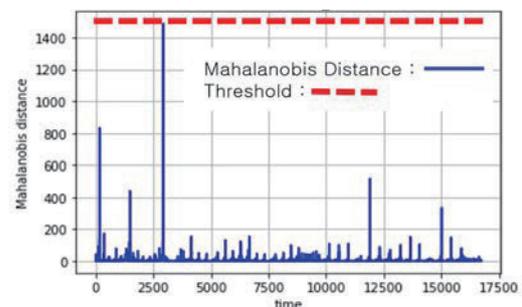


Fig. 2 Threshold Selection in Existing Technique

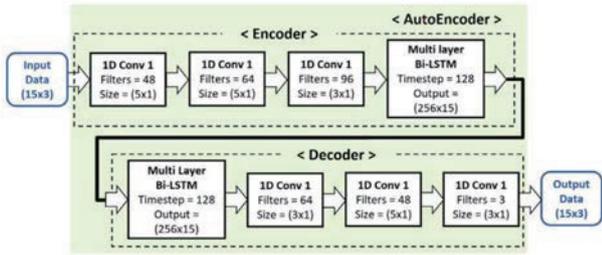


Fig. 3 AutoEncoder Structure of Existing Technique

그러나 이러한 임계값 설정 방식은 효과적이지 않다. Fig. 2에서 알 수 있듯이 임계값에 비해 대부분의 정상 비행 시나리오에서 생성되는 마할라노비스 거리는 매우 작은 값을 지닌다. 이것은 다수의 비행 시나리오에서 탐지 지연으로 인한 탐지 성능 저하가 야기될 수 있음을 암시한다. 또한, Fig. 3에 제시된 바와 같이 기존 기법의 AutoEncoder 모델 구조는 계산 복잡도로 인해 실시간 구동에 한계를 지닌다. 특히, Multi-layer Bi-LSTM 모듈은 복잡한 시계열 패턴을 효과적으로 분석하는 우수한 성능을 지니고 있지만 상당한 계산 복잡도를 수반하기 때문에 실시간 처리에 적합하지 않다.

3. 제안하는 비정상 비행 탐지 기법

3.1 제안 탐지 기법에서의 U-Net 모델 구조

본 논문에서는 기존 탐지 기법에서 사용되는 AutoEncoder 모델의 계산 복잡도 문제를 해결하기 위해 U-Net 모델을 활용한다. U-Net 모델은 AutoEncoder 모델의 구조를 확장한 형태로 스킵 연결(Skip Connections)이 추가된다[11]. 스킵 연결은 인코더에서 추출한 특징을 디코더로 직접 전달하여 디코더가 더 정확한 재구성성을 할 수 있도록 한다. 이는 AutoEncoder 모델 인코더의 데이터 축소 과정에서 발생하는 정보 손실을 방지한다.

Figure 5는 제안하는 탐지 기법에서 사용된 U-Net

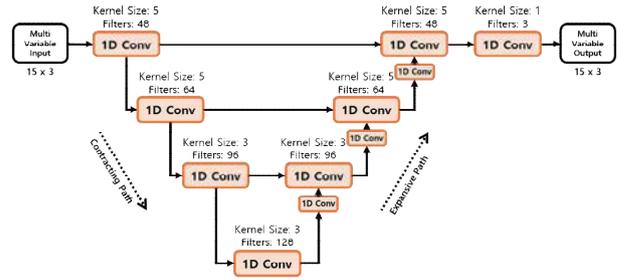


Fig. 5 Proposed U-Net Model Structure

모델 구조를 나타낸 것이다. AutoEncoder 모델에서 복잡도가 높은 Multi-layer Bi-LSTM 모듈을 하나의 CNN(Convolution Neural Network)으로 대체하고 스킵 연결을 추가하였다. 이는 U-Net 모델이 AutoEncoder 모델의 성능을 유지면서 낮은 계산 복잡도로 인하여 실시간 처리를 효과적으로 할 수 있게 한다.

3.2 제안하는 탐지 방식

본 논문에서는 기존 탐지 기법을 개선하기 위해 새로운 탐지 방식을 제안한다. Fig. 4는 제안하는 탐지 기법에서의 세부 과정을 도식화한 것이다.

기존 탐지 기법과 마찬가지로 Fig. 5의 U-Net 모델은 정상 비행 데이터만을 이용하여 학습된다. 학습된 U-Net 모델에 대하여 기존 탐지 기법과 동일하게 테스트할 비행 데이터를 입력하여 재구성 오차 $E(t \sim t-14)$ 와 마할라노비스 거리 $d(t)$ 를 구한다. 그리고 명확한 $d(t)$ 의 추세 파악을 위해 $d(t)$ 부터 $d(t-14)$ 까지의 값을 평균하는 이동 평균(Moving Average)을 수행하여 $c(t)$ 를 생성한다. 이 과정은 이상치의 영향을 제거하고 $d(t)$ 의 변동성을 평활화하는 기능을 수행한다.

제안하는 탐지 기법에서는 비정상 비행으로 진입할 때 $c(t)$ 가 급격하게 증가하는 현상에 기초하여 아래와 같이 비행 상태를 최종 판별한다.

$$\delta(t) = c(t) - c(t-1) \tag{1}$$

$$s(t) = \begin{cases} 1 & \text{for } \delta(t) > Th \\ 0 & \text{others} \end{cases} \tag{2}$$

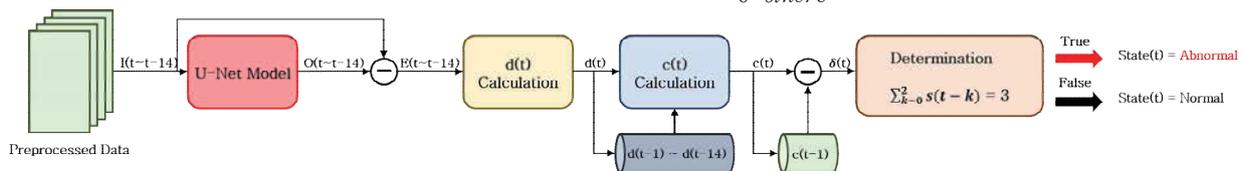


Fig. 4 Abnormal Flight Detection Procedure of Proposed Detection Technique

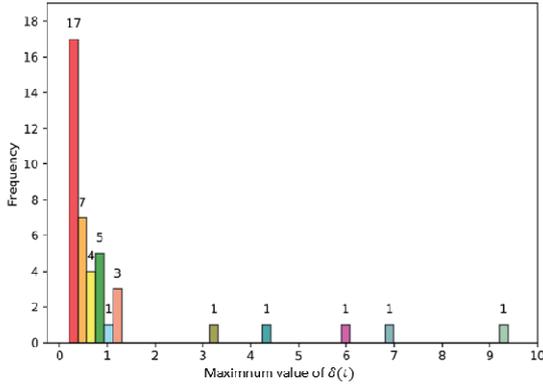


Fig. 6 Histogram of Maximum $\delta(t)$ for Scenarios

$$\begin{aligned} \text{State}(t) &= \text{abnormal} \quad \text{when} \quad \sum_{k=0}^2 s(t-k) = 3 \\ &= \text{normal} \quad \text{others} \end{aligned} \quad (3)$$

학습에 사용된 비행 시나리오들에 대하여 $\delta(t)$ 의 최대값에 대한 빈도를 조사하였다. Fig. 6은 이를 히스토그램으로 나타낸 것이다. 대부분의 비행 시나리오에서 $\delta(t)$ 의 최대값이 2보다 작음을 알 수 있다. 이러한 이유로 본 논문에서는 임계값(Th)을 2로 설정하였다.

4. 실험 및 결과

4.1 실험 데이터 생성

본 논문에서는 Table 1에 나열된 UL-1부터 UL-9까지의 비행 생성 조건에 기초하여 61,010개의 Training Data와 15,291개의 Validation Data로 구성된 학습 데이터를 생성하였다[10]. UT-2와 UT-3은

Table 1 Conditions for Generating Flight Data

Case	Initial V [m/s]	Cmd V [m/s]	Cmd Phi [deg]	Flight Situation
UL-1	21	15	-45 ~ +45	Normal
UL-2	21	10	-45 ~ +45	Abnormal
UL-3	21	5	-45 ~ +45	Abnormal
UL-4	18	15	-45 ~ +45	Normal
UL-5	18	10	-45 ~ +45	Abnormal
UL-6	18	5	-45 ~ +45	Abnormal
UL-7	15	15	-45 ~ +45	Normal
UL-8	15	10	-45 ~ +45	Abnormal
UL-9	15	5	-45 ~ +45	Abnormal
UT-2	19	7	35	Abnormal
UT-3	20	11	32	Abnormal

Table 2 Specification of PC

CPU	Intel(R) Core(TM) i5-3570 @ 3.40 GHz
GPU	Nvidia GeForce GTX 970
RAM	16 GB
OS	Window 10 Pro

Table 3 Training Parameters

Optimizer	Loss Function	Learning Rate	Batch Size	Max Epoch
Adam	MAE	0.00008	16	500

제안하는 탐지 기법의 테스트를 위해 사용되었다.

4.2 U-Net 모델 학습

Table 2는 U-Net 모델의 학습 및 테스트를 위해 구축된 PC 환경을 나타낸 것이다. 그리고 Table 3은 U-Net 모델의 학습에 사용된 학습 파라미터를 보여준다. U-Net 모델의 초기 가중치와 학습률은 다양한 실험을 통하여 선정하였다.

일반적으로 딥러닝 모델이 정상적으로 학습이 완료되었는지는 Epoch에 따른 Train Loss와 Validation Loss의 추세를 통해 확인할 수 있다. Train Loss와 Validation Loss는 모델이 학습 데이터의 패턴을 얼마나 잘 숙지하는지와 모델의 일반화 능력을 각각 나타낸다. Fig. 7은 U-Net 모델의 학습 과정에서 생성된 Train Loss와 Validation Loss에 대한 그래프들을 보여준다. Fig. 7에서 각각의 그래프들이 0으로 수렴하고 있기 때문에 U-Net 모델이 정상적으로 학습되었다는 것을 알 수 있다.

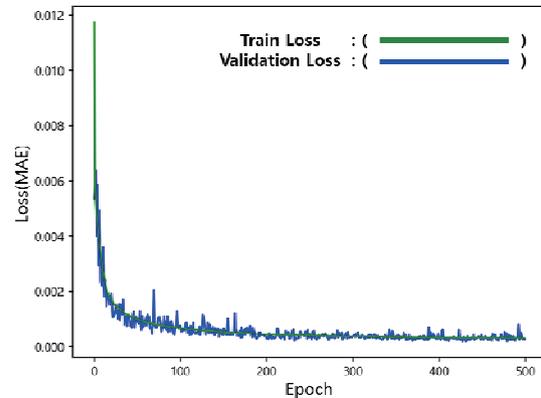


Fig. 7 Train and Validation Loss Graphs

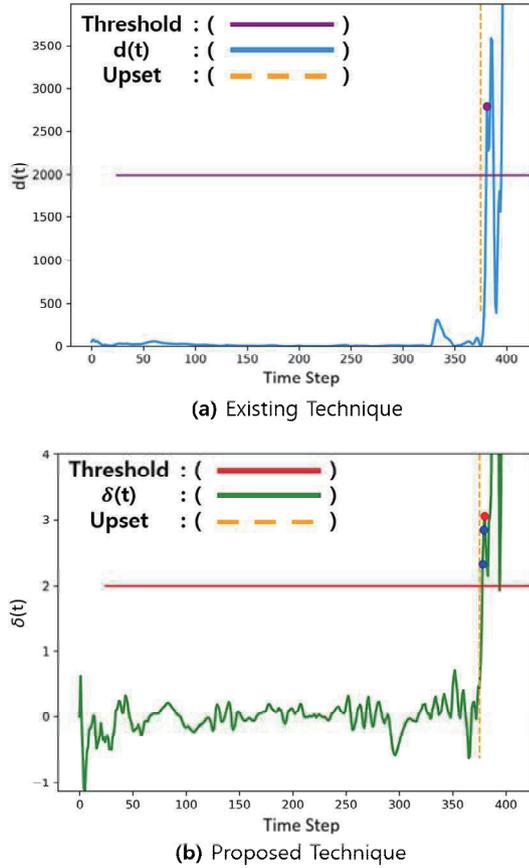


Fig. 8 Example of Abnormal Flight Detection with Existing and Proposed Techniques

4.3 탐지 성능 비교

Figure 8은 UT-3 테스트 데이터에 대하여 기존 기법과 제안 기법에서의 탐지 결과를 보여준다. 여기서 노란색 점선은 실제로 비정상 비행이 시작되는 시점을 의미한다. 기존 기법과 제안 기법에서는 마할라노리비스 거리 기반의 임계값과 식(3)의 판별 방식에 기반하여 비정상 비행 진입 시점을 각각 탐지한다.

Table 4는 42개 비정상 비행 시나리오를 통해 얻어진 데이터에 대하여 기존 기법과 제안 기법에서의 탐지 지연 시간을 정리한 것이다. Table 4에서 제안 기법이 기존 기법에 비하여 평균 3.6 Time Step 빠르게 비정상 비행 진입을 탐지하는 것을 알 수 있다. 특히, 제안 기법은 4개 시나리오에 대하여 탐지 지연 시간이 기존 기법과 동일하지만 38개의 시나리오에서는 기존 기법에 비하여 탐지 지연 시간이 감소한다. 더구나 기존 기법에서 탐지되지 못하는 시나리오도 제안 기법에서 탐지가 이루어지는 것을 알 수 있다.

Table 4 Comparisons of Detection Delay Time for Various Flight Scenarios

Scenario Condition			Existing Technique (Time Step)	Proposed technique (Time Step)
initV	cmdV	cmdPhi		
15	5	-45	4	4
		-30	5	3
		-15	15	3
		0	19	6
		15	16	4
		30	5	3
		45	5	4
	10	-45	-	27
		-30	14	4
		-15	21	15
		0	28	21
		15	25	15
		30	69	59
		45	0	0
18	5	-45	6	3
		-30	6	3
		-15	5	3
		0	4	2
		15	5	3
		30	7	4
		45	6	3
	10	-45	7	4
		-30	13	5
		-15	6	4
		0	6	3
		15	7	4
		30	13	5
		45	7	4
21	5	-45	6	3
		-30	5	5
		-15	2	1
		0	11	7
		15	2	1
		30	5	5
		45	6	3
	10	-45	7	2
		-30	5	4
		-15	3	1
		0	27	20
		15	3	1
		30	5	4
		45	7	2
Average			10.19	6.59

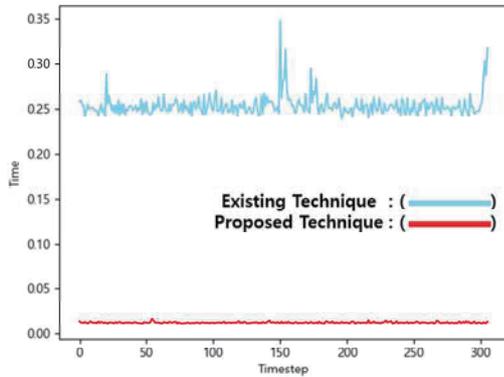
4.4 딥러닝 모델 복잡도 비교

일반적으로 딥러닝 모델의 복잡도는 모델 내 가중치와 편향의 총합을 의미하는 파라미터 개수와 부동 소수점 연산(Floating Point Operations, FLOPs)의 총 횟수로 표시된다. 총 FLOPs 횟수는 입력부터 출력까지 필요한 연산 횟수를 의미한다.

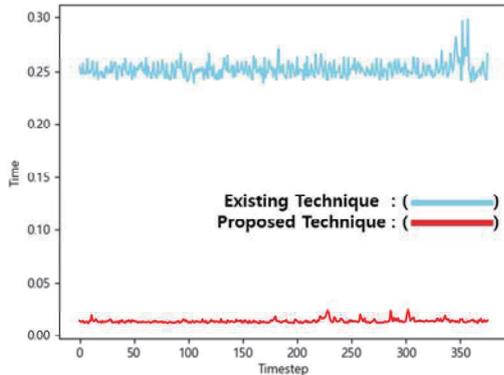
Table 5는 각 탐지 기법에 사용된 딥러닝 모델의 복잡도를 측정된 결과이다. U-Net 모델의 복잡도가 AutoEncoder 모델의 복잡도 보다 95 % 이상 감소한

Table 5 Complexity Comparisons for AutoEncoder and U-Net Models

	Number of Parameters	Number of FLOPs
AutoEncoder	5,596,899	83,948,640
U-Net	213,075	3,184,800



(a) Example 1



(b) Example 2

Fig. 9 Comparisons of Execution Time for Two Flight Scenarios

것을 알 수 있다.

4.5 실시간 구동 비교

모의실험에 사용된 비행 데이터는 30 Hz의 주파수로 생성되기 때문에 입력 데이터로부터 비정상 비행 여부를 실시간으로 판별하기 위해서는 0.0333 sec 이내에 탐지가 수행되어야 한다. Fig. 9는 2개의 비행 시나리오에 대하여 기존 탐지 기법과 제안하는 탐지 기법에서 소요된 탐지 시간을 보여준다. Fig. 9로부터

Table 6 Execution Time for All Scenarios on PC

	Average	Min	Max
Existing Technique	0.3179	0.3008	0.5337
Proposed Technique	0.0129	0.0118	0.0475

Table 7 Average Execution Time for Onboard Environment

	UT-2	UT-3
Existing Technique	0.601	0.609
Proposed Technique	0.031	0.030

기존 기법에 비해 제안 기법이 고속으로 동작하는 것을 알 수 있다. Table 6은 모든 비행 시나리오에 대하여 수행된 실행 시간을 요약한 것이다. Table 6은 제안 기법이 PC환경에서 30 Hz 데이터에 대해 실시간 탐지를 수행할 수 있음을 보여준다.

본 논문에서는 NVIDIA사에서 개발한 임베디드 AI 컴퓨팅 장치로 알려진 Jetson TX2를 기반으로 하여 온보드 환경을 구축하고 기존 기법과 제안 기법의 실시간 처리 성능을 비교하였다. Table 7은 UT-2와 UT-3에 대한 평균 탐지 시간을 보여준다. 기존 기법과 제안 기법 모두 PC 환경 대비 온보드 환경에서의 실행 시간이 증가하였다. 그리고 기존 기법에서는 탐지를 수행하는 데 평균 약 0.6 sec가 소요되었지만 제안 기법에서는 평균 0.033 sec 이내에 탐지가 수행되었다. 이러한 사실은 제안 기법이 온보드 환경에서 30 Hz 데이터에 대해 실시간 탐지를 수행할 수 있다는 것을 의미한다.

5. 결 론

본 논문에서는 U-Net 모델 기반 무인항공기 비정상 비행 탐지 기법을 제안하였다. 기존 탐지 기법은 AutoEncoder 모델의 높은 복잡도로 인하여 실시간 구동에 한계를 지니고 있으며 비효율적인 임계값 설정에 따른 탐지 성능 저하가 발생하는 문제를 지닌다. 이를 극복하기 위하여 본 논문에서는 AutoEncoder 모델 대신에 U-Net 모델을 도입함으로써 모델의 복잡도를 감소시켰다. 또한 비정상 상태 진입시 마할라노비스 거

리가 급증하는 추세를 보인다는 사실에 기반하여 마할라노비스 거리 증가량을 이용한 비정상 비행 판별 방식을 제시하였다. 모의실험을 통하여 제안 탐지 기법의 탐지 성능과 실시간 구동 성능이 기존 탐지 기법에 비하여 우수함을 확인하였다. 또한 온보드 환경에서의 실험을 통하여 제안하는 탐지 기법이 온보드 환경에서 30 Hz 데이터에 대하여 실시간으로 구동할 수 있음을 확인하였다.

후 기

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

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] Junhyeong Sim, Euicheon Hwang, Changgeun Son, Yoonseung Ryu, "Anti-Drone Countermeasures According to Drone Accident Cases and Technology Trend," *Journal of the Korea Academia-Industrial cooperation Society*, Vol. 24, No. 2, pp. 651-659, Feb. 2023
- [3] Areum Hong, Anseon Park, Minseon Kim, "Policy and Industry Trends in Urban Air Mobility," *National Strategic Technology Policy and Industry Trends in the Era of Technological Hegemony Competition*, Vol. 38, No. 4, pp. 36-46, Aug. 2023.
- [4] Lishuai Li, Maxime Gariel, R. John Hansman, Rafael Palacios, "Anomaly detection in onboard-recorded flight data using cluster analysis," *IEEE/AIAA 30th Digital Avionics Systems Conference*, Dec. 2011
- [5] Murtaja Salah, Tareef Kamil Mustafa, "Anomaly Detection in Flight Data Using the Naive Bayes Classifier," *7th International Conference on Contemporary Information Technology and Mathematics (ICCITM)*, Jan. 2022
- [6] Nosam Park, "Research Trends on Deep Learning for Anomaly Detection of Aviation Safety." *Electronics and Telecommunications Trends*, Vol. 36, No. 5, pp. 82-91, Oct. 2021
- [7] Zhiqiang Que, Yanyang Liu, Ce Guo, Xinyu Niu, Yongxin Zhu, Wayne Luk, "Real-Time Anomaly Detection for Flight Testing Using AutoEncoder and LSTM," *2019 International Conference on Field-Programmable Technology (ICFPT)*, Feb. 2020
- [8] Qihan Sun, Ruipeng Ji, "Flight anomaly detection model based on QAR data autoencoder and DBscan algorithm," *IEEE 3rd International Conference on Civil Aviation Safety and Information Technology (ICCASIT)*, Dec. 2021
- [9] Qixin Wang, Kun Qin, Binbin Lu, "Flight Anomaly Detection Based on Deep Hybrid Model" *IEEE 2nd International Conference on Civil Aviation Safety and Information Technology (ICCASIT)*, Mar. 2021
- [10] MinJae Song, EunJu Choi, YongHo Moon, ByoungSo Kim, "A Study on the Domain Knowledge-Based Data Normalization Method in the Utilization of AI Model for the Detection of Abnormal Flight of Small UAVs," *Journal of the Korean Society for Aeronautical and Space Sciences*, Vol. 52, No. 1, pp. 57-64, Jan. 2024
- [11] Olaf Ronneberger, Philipp Fischer, Thomas Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," *Computer Vision and Pattern Recognition*, May 2015