

AI 기반 실시간 UAV Motor Error Detection 시스템

윤희창, 김상현, 유승호*

국립부경대학교 컴퓨터공학과

{yhc122833, shkim1615}@pukyong.ac.kr, shyoo@pknu.ac.kr

AI-based Real-time UAV Motor Error Detection System

HuichangYun, Sanghyun Kim, Seungho Yoo*

Department of Computer Engineering, Pukyong National Univ.

요약

무인항공기(UAV)는 물류, 감시, 재난 대응 등 다양한 분야에서 활용도가 증가하고 있다. UAV는 안정적인 비행, 신속한 장애 대응이 필수적이다. 특히 UAV의 핵심 부품인 모터는 비행 안전성과 직결되며, 모터의 고장은 UAV의 비정상적인 비행을 야기하며 이는 심각한 사고로 이어질 수 있다. 이러한 사고를 막기 위해 정상 비행 여부를 판단하는 Failure Detection 기법들이 존재하지만, 기존의 대부분의 기법들은 Rule-Based 기법에 기반하고 있기 때문에 모터 오류 감지 같은 복합적인 기체 이상 진단에 어려움이 있다. 이러한 문제를 해결하기 위해 본 연구에서는 AI를 적용한 Motor Error Detection 시스템을 제안한다. Gazebo 시뮬레이션을 사용하여 모터 고장 시나리오를 구현해 데이터를 확보하였으며, 해당 데이터로 GRU 기반의 Motor Error Detection Model을 학습시키고 필터를 적용하여 신뢰성 높은 모터 오류 감지 시스템을 구현하였다. 평가 결과 제안된 시스템은 Motor Error 현상이 일어난 후 평균 0.87초 이내에 오류를 감지할 수 있었으며, 이러한 경량화된 시스템은 엣지 단에서의 실시간 적용 가능성을 보여준다.

I. 서론

무인항공기(UAV)는 물류, 감시, 재난 대응[1, 2] 등 다양한 분야에서 활용되고 있으며, 중요도가 계속해서 증가하고 있다. UAV 운용에 있어서 안정적인 비행과 신속한 장애 대응이 필수적이다. 특히 UAV의 핵심 부품인 모터는 비행 안전성과 직결되며, 모터 고장은 UAV의 비정상적인 비행을 일으키고 심각한 사고로 이어질 수 있다. 하지만 기존의 Rule-Based 고장 여부 판단 기법[1]은 특정 조건에서 효과적일 수 있으나, 모터 오류 감지와 같은 복합적인 기체 이상 진단에 어려움이 있다.

이러한 문제를 해결하기 위해, 본 연구에서는 무인기 비행 데이터를 활용한 AI 기반의 모터 고장을 감지하는 시스템을 제안한다. 실시간으로 정확한 모터 이상 감지를 하는 것이 제안하는 시스템의 목표이며, 이를 통해 본 연구에서는 다음의 내용들을 제안하고 확인하였다.

- 현실에서 얻기 어려운 비행 중 모터 고장 데이터를 시뮬레이션으로 구현하여 모델 학습데이터로 활용함.
- 시뮬레이션에서 생성된 데이터를 바탕으로 GRU 모델을 학습시켜 Motor Error Detection Model을 구현함.
- GRU 모델 단독으로 오류 예측을 수행하였을 때 발생하는 예측 노이즈를 해결하기 위한 후처리 필터를 적용하여 시스템의 신뢰성을 향상 시킴.

II. 데이터 생성 및 수집

본 논문에서 제안하는 시스템을 구현하고 검증하기 위하여 UAV 비행 중 모터의 고장이 일어나는 상황에 대한 데이터가 필요하였다. 하지만 현실에서 실제 UAV를 통해 이러한 데이터를 확보하는 것은 어려움이 있기에 시뮬레이션을 활용하여 해당 데이터를 수집하였다. 시뮬레이션은 Gazebo와 PX4 SITL을 사용하였고, 시뮬레이션 상에서 UAV 비행 중 모터 에러를 의도적으로 발생시켜 고장 시나리오를 구현하였다.

UAV Flight Controller인 PX4에서는 다양한 비행 관련 데이터[3]가 존재하는데, 그중 드론 기체 정보 (roll, pitch, yaw 등), 비행 목표 정보 (target_x, target_y, target_z 등), 및 모터 정보를 사용하였다.

MAVLink를 통해 0.2초 간격으로 업데이트되는 UAV 실시간 비행 데이터를 수집하였다. 무인기의 이동과 모터 오류 발생에 대해 무작위적으로 이루어지도록 시뮬레이션을 구성하고, 해당 환경에서 약 15만 개의 데이터를 확보하였으며, 이를 오류 검출 모델의 학습데이터로 사용하였다.

III. 시스템 구성




그림 1. UAV Motor Error Detection System Design

본 논문에서 제안하는 Motor Error Detection 시스템의 시스템 구성도를 그림 1에 나타내었다. 먼저, UAV의 실시간 비행 데이터를 정해진 윈도우의 크기만큼 이전 비행 데이터와 묶어 하나의 시퀀스 데이터를 생성한다. 이 시퀀스 데이터는 비행 데이터가 업데이트될 때마다 생성되며, 생성될 때마다 Motor Error Detection Model에 넘겨진다. Motor Error Detection Model은 받은 시퀀스 데이터를 기반으로 Motor Error 확률을 계산하여 Raw Predict Result를 생성하고 이를 후처리 필터에 전달한다. 필터는 Raw Predict Result에서 예측 노이즈를 제거하고, 최종적으로 Motor Error가 발생했는지를 결정한다.

3.1 GRU(Gated Recurrent Unit) 기반 Motor Error Detection Model

본 연구에서는 GRU 기반의 분류 모델을 사용하였다. GRU는 LSTM과 유사하게, 이전 시점의 정보를 고려하여 시계열 데이터의 시간적 패턴을 학습할 수 있으며 LSTM에 비해 구조가 단순하고 파라미터 수가 적다는 장점[4]이 있다. 대신에 LSTM에 비해 긴 시퀀스의 학습에서 약한 모습을

보이지만, 본 연구에서는 긴 시퀀스 분석은 필요로 하지 않고 오히려 실시간성이 필요로 하였기에 학습 모델로서 GRU를 선택하였다.

모델 학습에 활용된 입력 feature는 섹션 2에서 서술한 드론 기체 정보, 비행 목표 정보, 모터 정보를 사용하였고, 슬라이딩 윈도우 방식으로 데이터를 시퀀스로 변환하였다. 윈도우 크기는 30으로 설정하였으며, 각 시퀀스 데이터들은 시계열 상으로 가장 최근에 업데이트된 데이터가 정상 혹은 고장인지에 대해 라벨링하여 학습에 활용하였다.

3.2 후처리 필터

GRU 모델을 단독으로 사용하여 모터 오류 예측을 하면, 예측값이 순간적으로 튀는 예측 노이즈가 발생한다. 예를 들어 UAV가 정상 비행 중임에도 바람이 불거나 급격한 방향 전환 등의 이유로 기체가 순간적으로 흔들리는 것을 모터 에러로 착각하는 현상이 발생하는데, 이러한 오탐(False Positive)을 줄이기 위해 후처리 필터(post-processing filter)를 적용하였다. 후처리 필터 기법 중 Majority Voting, EMA(Exponential Moving Average)[4], Debounce, Kalman Filter[5]를 각각 적용하여 결과를 비교해보았고, 그 결과를 표 1에 나타내었다.

IV. 연구 결과

본 연구에서 사용한 GRU모델 및 후처리 필터 기법은 슬라이딩 윈도우를 기반으로 데이터가 업데이트된다. 따라서 모델이 모터 오류를 탐지하기 위해서는 데이터가 윈도우에 누적될 필요가 있으며, 이는 고장 상황 후 기체 데이터가 누적되는 과정(step)이 필요하다는 것을 말한다. 표 1의 Missed Detection은 테스트 중 모델이 모터 오류를 놓친 수를 나타내는데, GRU만을 썼을 때와 필터를 적용시켰을 때 모두 0인 것을 확인할 수 있다. 이는 실제 오류 탐지 자체는 모두 성공적으로 수행되었으며, 성능 차이로는 윈도우 누적 지연 및 노이즈만이 존재함을 의미한다.

따라서 성능은 다음 두 가지 항목으로 평가된다. 첫째, 실제 오류가 발생한 시점 t_e 와 에러가 탐지된 탐지 시점 t_d 사이의 탐지 지연($D = t_d - t_e$, 단위: step)의 평균인 Average Delay. 두 번째, 필터 성능을 평가하기 위한 오탐률(False Positive Rate, $FPR = FP / (FP + TN)$)이다. 여기서 FP는 정상 상태를 오류로 잘못 판단한 횟수, TN은 정상 상태를 올바르게 판단한 횟수이다. 테스트 데이터는 섹션 2에서 생성하였던 데이터와 동일한 방식으로 생성되었고, 약 3천 개의 데이터를 생성해 테스트하였다.

4.1 GRU 및 후처리 필터 적용 결과

각 필터는 Average Delay가 5 step(0.2초 업데이트 기준 1초)을 넘기지 않는 기준으로 가장 정확도가 높았던 파라미터를 적용시켜 테스트하였고, 그 결과는 표 1과 같다. 필터를 사용하면 GRU모델 단독으로 사용했을 경우보다 오탐을 확실히 줄여주는 모습을 보여준다. 그중 Majority Voting 방식이 필터를 적용한 결과 중 가장 Average Delay가 낮고, FPR 또한 가장 성능이 좋은 Debounce와 비슷하게 좋은 성능을 보여주었기에 본 연구에서는 GRU + Majority Voting을 사용하였다.

표 1. GRU 및 후처리 필터 적용 결과

	Missed Detection	Average Delay(step)	FPR
GRU Only	0	2.0	0.064
Majority Voting	0	4.36	0.006
EMA	0	4.43	0.018
Debounce	0	4.5	0.004
Kalman Filter	0	4.8	0.017




그림 2. 오류 검출 소요 시간에 대한 PDF, CDF

4.2 Inference Time

그림 2는 시퀀스 데이터가 GRU + Majority Voting을 거쳐 Motor Error Detection Output을 생성할 때까지, 하나의 step에 대한 Inference Time을 나타낸다. 90%의 경우 추론이 0.2ms 이내로 끝나며, 0.35ms 이내에 거의 모든 추론이 끝나는 것을 확인할 수 있다. 따라서 GRU + Majority Voting의 Average Delay가 4.36 step이므로 평균적으로 Motor Error 현상이 일어난 후 대부분은 0.87초 이내에 감지되는 것을 의미하며, 이를 통해 제안된 시스템이 매우 경량화되어 있음을 확인할 수 있다.

V. 결론

본 논문에서는 UAV 비행 데이터를 사용하여 실시간으로 UAV Motor Error Detection을 수행하는 시스템을 제안한다. 시뮬레이션 환경에서 UAV의 모터 고장 시나리오를 생성하여 약 15만 개의 학습데이터를 확보하였으며, 이를 기반으로 GRU 모델을 학습시켰다. 또한 필터 적용을 통해 예측 노이즈 문제를 줄여 시스템의 신뢰성을 높였고 Average Delay, Inference Time 평가 결과, Motor Error 발생 후 대부분의 경우 0.87초 이내에 오류를 감지할 수 있음을 확인하였다.

향후 연구에서는 제안된 경량화된 시스템을 실제 UAV 기체에 탑재하여 HITL 실험을 수행함으로써 엣지 단에서 실시간 탐지 성능을 검증할 계획이다. 또한 GRU 이외의 모델과 다양한 필터 기법의 조합을 탐색하거나 UAV 비행 데이터 업데이트 주기를 빠르게 하여 더욱 정확하고 신속한 시스템을 설계할 수 있을 것으로 기대된다.

ACKNOWLEDGMENT

이 논문은 2025년 정부(방위사업청)의 재원으로 국방기술진흥연구소의 지원을 받아 수행된 연구임 (KRIT-CT-23-041)

참 고 문 헌

- [1] H. Shraim, A. Awada and R. Youness, "A survey on quadrotors: Configurations, modeling and identification, control, collision avoidance, fault diagnosis and tolerant control," in IEEE Aerospace and Electronic Systems Magazine, vol. 33, no. 7, pp. 14-33, 2018.
- [2] 차용준 외, "국방 분야 인공지능 기술의 적용 사례 연구," 한국통신학회 인공지능 학술대회 논문집, pp. 258-260, Sept. 2024.
- [3] "uORB Message Reference | PX4 Guide (main)." Accessed: Aug. 25, 2025. [Online]. Available: https://docs.px4.io/main/ko/msg_docs/
- [4] S. Mahjoub, L. Chrifi-Alaoui, B. Marhic and L. Delahoché, "Predicting Energy Consumption Using LSTM, Multi-Layer GRU and Drop-GRU Neural Networks," Sensors, vol. 22, no. 11, p. 4062, 2022.
- [5] J. D. Borrero and J. Mariscal, "Predicting Time Series Using an Automatic New Algorithm of the Kalman Filter," Mathematics, vol. 10, no. 16, p. 2915, Jan. 2022.