

Airborne Antenna Switching Strategy Using Deep Learning on UAV Line-Of-Sight Datalink System

Se-Hyeon Jo*, Woo-Sin Lee*, Hack-Joon Kim*, So-Yeon Jin*, In-Deok Yoo*

Abstract

In the Unmanned Aerial Vehicle Line-Of-Sight datalink system, there is a possibility that the communication line is disconnected because line of sight can not be secured by one antenna due to changes in position and posture of the air vehicle. In order to prevent this, both top and bottom of air vehicle are equipped with antennas. At this time, if the signal can be transmitted and received by switching to an antenna advantageous for securing the line of sight, communication disconnection can be minimized. The legacy antenna switching method has disadvantages such that diffraction, fading due to the surface or obstacles, interference and reflection of the air vehicle are not considered, or antenna switching standard is not clear. In this paper, we propose an airborne antenna switching method for improving the performance of UAV LOS datalink system. In the antenna switching method, the performance of each of the upper and lower parts of the mounted antenna according to the position and attitude of the air vehicle is predicted by using the deep learning in an UAV LOS datalink system in which only the antenna except the receiver is duplicated. Simulation using flying test dataset shows that it is possible to switch antennas considering the position and attitude of unmanned aerial vehicle in the datalink system.

▶ Keyword: Deep learning, LOS, Datalink, Antenna, Switching, UAV

1. Introduction

최근 군사적 목적의 적진 감시, 표적 획득, 피해 평가, 적 방공망 기만, 전투 임무 수행, 공격 등의 임무 수행과 민수 목적의 해안 및 국경 감시, 국토 관리, 농업, 기상 및 해양, 방재, 관측 등 매우 다양한 분야에서 무인항공기(UAV, Unmanned Aerial Vehicle)가 활용되고 있다.[1]

무인항공기는 군사적 용도로는 전략, 전술, 특수임무 무인항공기로 구분하고, 운용고도, 체공시간, 작전반경 등에 따라 저고도, 중고도, 고고도 무인항공기 등으로 분류할 수 있으며, 무인항공기 체계는 일반적으로 비행체, 임무장비, 데이터링크, 지상통제체계(GCS, Ground Control System) 그리고 각종 전자

지원장비 등으로 구성된다.[2] 여기서 군용 무인항공기의 임무장비는 CCD, EO/IR, SAR와 같은 정찰용 센서나 타격용 무기체계 등으로 구성된다.

데이터링크는 무인항공기를 운용하기 위한 통신 시스템 전반을 일컫는 용어로서 무인항공기에 공통적으로 포함되는 필수 요소이며 용도와 운용환경에 따라 다양하게 분류된다.

데이터링크는 하향링크(Downlink)와 상향링크(Uplink)로 구분되어 지상통제체계와 무인항공기 간의 통신링크를 구성한다.[3] 무인항공기는 수집한 정보와 비행체의 상태정보를 하향링크를 통해 지상통제체계로 전송하고, 지상통제체계는 무인항

• First Author: Se-Hyeon Jo, Corresponding Author: Woo-Sin Lee

*Se-Hyeon Jo (shn.jo@hanwha.com), Hanwha Systems Co.

*Woo-Sin Lee (woosin.lee@hanwha.com), Hanwha Systems Co.

*Hack-Joon Kim (hjn.kim@hanwha.com), Hanwha Systems Co.

*So-Yeon Jin (soyeon.jin@hanwha.com), Hanwha Systems Co.

*In-Deok Yoo (indeok.yoo@hanwha.com), Hanwha Systems Co.

• Received: 2018. 10. 26, Revised: 2018. 11. 25, Accepted: 2018. 11. 27.

공기로부터 수신한 정보를 분석하여 비행체의 상태를 확인함과 동시에 비행 및 임무 수행에 관련된 명령을 상향링크를 통하여 전송한다. 이와 같이 무인항공기의 원격 통제가 데이터링크를 통해 전송되기 때문에 데이터링크는 무인항공기 시스템에 있어서 매우 중요한 부분을 차지하고 있다. 최근엔 EO/IR 및 SAR 등 임무장비의 고화질, 대용량의 동영상 및 정지영상을 지상통제체계로 전송하고 있어 데이터링크의 끊김 없는 안정적인 성능이 요구되고 있다. [4, 5, 6] 이에 따라 무인항공기에서는 지상통제체계와 무인항공기 간에 가시선을 확보하고, 추적 안테나를 사용하여 안정적인 통신을 제공하는 가시선 데이터링크를 사용하고 있다.




Fig. 1. LOS Datalink System

가시선 데이터링크 시스템은 그림1과 같이 지상체와 무인항공기가 직접 연결되는 기본 운용 모드와 통달거리 확장 또는 가시선 확보를 위한 지상중계 운용 모드로 이루어진다.

이 중 지상중계 운용 모드는 지형이나 건물 등의 이유로 인해 무인항공기가 음영지역에 진입할 경우 가시선 데이터링크의 단절 피하기 위해 사용된다. 그러나 운용 모드에 상관없이 비행체 위치 및 자세에 따라 비행체 간섭, 반사 등의 이유로 가시선이 확보되지 않아 통신 어려움이 높아지거나 데이터링크 단절이 발생한다.[7]

이러한 비행체 위치 및 자세에 따른 데이터링크 단절은 안테나 송수신 경로의 이중화를 통해 최소화할 수 있다. 비행체 상부와 하부에 각각 안테나를 장착하여 가시선 확보에 유리한 위치의 안테나로 송수신을 하는 것이다.




Fig. 2. Using airborne bottom antenna




Fig. 3. Using airborne top antenna

일반적인 경우 비행 중에 그림2와 같이 비행체 하부 안테나를 사용하는 것이 가시선 확보에 유리하다. 그러나 비행체가 선회할 경우 그림3과 같이 비행체 상부 안테나를 사용하는 것이 가시선 확보에 유리하다. 이처럼 이중화된 안테나 송수신 경로를 통해 비행체의 위치 및 자세의 변화에 따른 데이터링크 단절을 최소화할 수 있다.

최근 무인항공기는 다양한 감시, 정찰 장비들을 장착하고 있고, 그 외에도 항법, 데이터링크 및 다른 응용분야들을 위한 추가적인 안테나 장착이 요구되고 있다. 무인항공기에 탑재되는 장비들이 다양해짐에 따라 탑재 장비들의 크기, 소비전력 및 중량 감소에 대한 요구가 늘어나고 있다.

탑재 장비들의 크기, 소비전력 및 중량 감소에 대한 요구가 늘어남에 따라 상부 및 하부 안테나로 이중화된 안테나의 송수신기를 단일화하여 상황에 따라 상부 또는 하부로 스위칭함으로써 크기, 소비전력 및 중량을 감소시킬 수 있다.[8] 그러나 안테나 송수신기 스위칭은 순간적인 데이터링크의 단절을 초래하며 탑재 가시선 데이터링크 방향성 안테나의 경우, 임무영상과 전방주시영상을 지상으로 전송하는 임무와 비행조종 측면에서 중요한 요소이기 때문에 데이터링크 단절을 최소화 하는 안테나 송수신기 스위칭이 필요하다.[9]

본 논문에서는 딥러닝 모델 기반의 가시선 데이터링크시스템 탑재안테나 스위칭 방법을 제안한다. 비행체 위치 및 자세에 따른 수신품질을 예측하는 모델을 설계하고 가시선 데이터링크 시스템에 적용하는 방안을 도출한다.

2장에서는 안테나 스위칭 방법, 딥러닝 및 데이터링크와 관련된 연구에 대해 살펴본다. 3장에서는 안테나 위치에 따른 수신품질 예측 모델을 설계하고 가시선 데이터링크 시스템에 적용하기 위한 방안을 설명한다. 4장에서는 딥러닝 모델에 대한 성능 분석을 한다. 마지막으로 5장에서 결론 및 향후 계획을 논의한다.

II. Preliminaries

1. Related works

1.1 Antenna switching strategy using minimum distance calculation with virtual points

비행체의 수직 방향으로 비행체의 상부와 하부에 임의의 거리로 떨어진 가상의 점을 설정하고, 지상체와 상부의 점, 하부의 점 각각의 거리를 연산하여 둘 중 거리가 가까운 쪽 방향의 안테나를 선택하는 방법이다.




Fig. 4. Distance between GDT and virtual points

그림4와 같이 상부와 하부 가상의 점은 비행체 무게중심을 기준으로 z축 방향으로 임의의 거리만큼 떨어지도록 설정한다. 이 때 비행체의 자세(Roll, Pitch, Yaw)가 변한다면 가상의 점들도 또한 x, y, z의 모든 축으로 이동한다. 이는 회전행렬과 테이트-브라이언 각(Tait-Bryan angles)를 활용한다.

TM 좌표계로 변환한 지상체와 비행체 좌표 그리고 자세 및 회전행렬을 이용하여 가상의 점을 설정하고 피타고라스의 정리를 이용하여 간단하게 두 가상의 점과 지상체 사이의 거리를 연산할 수 있다.[10]

이 방법은 좌표의 변환, 회전행렬을 이용한 행렬 연산, 점 사이의 거리 연산 등과 같이 비교적 간단한 연산 과정만 이용하므로 알고리즘의 복잡도 낮고 따라서 구현의 편의성을 가지고 있다. 그러나 지표면 및 장애물에 의한 회절이나 페이딩 또는 비행체 기체의 간섭, 반사 등은 고려되지 않는다.

1.2 Antenna switching strategy using elevation of air vehicle for GDT

지상체에 대한 비행체의 고각을 기준으로 특정 고각 이상이면 상부 안테나를 선택하고 특정 고각 이하이면 하부 안테나를 선택하는 방법이다.

GPS 좌표는 지표면을 기준으로 하는 측지좌표계(Geodetic Coordinate System)를 사용하기 때문에 지상체와 비행체의 GPS 좌표를 지구중심고정좌표계(ECEF X, Y, Z, Earth-Centered Earth-Fixed X, Y, Z)로 변환하여 벡터를 구한 뒤 지상의 위도와 경도기준으로 회전변환하여 다시 측지좌표계로 변환하면 지상체에 대한 비행체의 고각을 구할 수 있다.[11] 그림5는 측지좌표계에서 지구중심고정좌표계로의 변환 및 비행체 기준 고각을 설명하고 있다.




Fig. 5. Concept for ECEF coordinate system transformation and air vehicle elevation

이 방법은 지상체에 대한 비행체 기준 고각의 threshold를 지정하여 안테나 스위칭을 하기 때문에 threshold 지정이 성능의 중요한 요소가 된다. threshold 값은 실험적으로 지정해야 하기 때문에 최적값 지정을 위한 장시간의 실험이 필요할 뿐만 아니라 그 값에 대한 검증이 어렵다. 또한 안테나 상부 threshold와 안테나 하부 threshold 사이의 고각에 대해 안테나 스위칭을 해야 할지 말아야 할지 에 대한 처리가 불분명한 단점이 있다.

1.3 Deep Learning

기계 학습 기술은 웹 검색에서부터 소셜 네트워크의 콘텐츠 필터링, 전자 상거래 웹 사이트의 상품 추천에 이르기까지 현대 사회의 여러 측면을 지원하며 카메라 및 스마트 폰과 같은 소비자 제품에 점점 더 많이 등장하고 있다. 기계 학습 시스템은 이미지의 대상을 식별하고, 음성을 텍스트로 복사하고, 사용자가 관심 있어 할 만한 뉴스 항목, 게시물 또는 제품을 매칭하여, 관련 검색 결과를 선택하는 데 사용된다. 최근, 이러한 응용 프로그램은 딥러닝이라는 기술을 사용하고 있다.

기존의 기계 학습 기술은 기계 학습 시스템을 구축하려면 이미지의 픽셀 값과 같은 원시 데이터(Raw Data)를 적절한 내부 표현 또는 특징 벡터로 변환하는 특징 추출기를 설계하기 위해 세밀한 엔지니어링과 상당한 도메인 전문 지식이 필요했다. 그러나 딥러닝은 도메인 전문가를 통해 특징 추출기를 설계하는 과정을 딥러닝 알고리즘을 통해 데이터로부터 스스로 학습하고 분석할 수 있도록 했다.[12]

입력데이터에 가해지는 연속한 비선형변환을 통한 특징벡터 추출 및 합성으로 기존의 얇은 모델로는 표현할 수 없는 복잡한 특징공간에 대한 모델링을 할 수 있다는 딥러닝의 강점을 통해 음성인식, 영상인식, 자연어 처리, 문자열 예측, 자율주행 등 다양한 분야에서 활용되고 있다.[13]

딥러닝은 신경망 이론을 이용한 인공 신경망 (ANN, Artificial Neural Network)의 일종으로, 계층 구조로 구성되면서 입력층(Input Layer)과 출력층(Output Layer) 사이에 하나 이상의 은닉층(Hidden Layer)을 가지고 있는 심층 신경망 (DNN, Deep Neural Network) 이다. 다음으로 다양한 딥러닝 모델에 대해 살펴본다.

1.3.1 Multilayer Neural Network

입력층과 출력층 사이에 하나 이상의 은닉층을 갖는 신경망으로서 딥러닝의 기본적인 구조이다. 입력층은 입력 데이터를 받아들이며, 입력층의 뉴런 수는 입력 데이터의 특성 개수와 일치한다. 은닉층은 입력층과 출력층 사이에 존재하는 계층으로서 은닉층의 뉴런 수는 신경망 설계자의 경험 측면에서 결정된다. 은닉층의 뉴런 수가 너무 많으면 과적합(Overfitting)이 발생하며, 너무 적으면 특징을 충분히 표현하지 못 하기 때문이다. 또한 은닉층의 개수가 많아질수록 정확도가 어느정도 높아 지지만 높아지는 정확도에 비해 연산량이 크게 증가하여 적절한 은닉층 개수를 정하는 것이 중요하다. 출력층은 해결하고자 하는 문제의 성격에 따라 뉴런 수가 정해진다.

인간의 신경망에는 시냅스(Synapse)가 있는데, 인공 신경망에는 이런 방식을 모방하여 활성화 함수(Activation Function)을 사용한다. 뉴런은 입력신호를 가중치를 고려해 합산하고 그 값을 활성화함수에 적용하여 비선형성이 추가된 출력신호로 다음 층에 전달된다. 최근에는 ReLU(Rectified Linear Unit)이 활성화 함수로 많이 사용된다. 출력층의 활성화 함수로는 확률 벡터를 얻기 위해 소프트맥스(Softmax) 함수가 자주 사용된다.

신경망에서 학습이란 뉴런 사이의 가중치를 최적화 하는 것이다. 일반적으로 지도학습은 다음과 같은 순서로 학습한다.

1. 훈련 데이터 준비
2. 신경망에 데이터를 입력하여 출력층에서의 값 확인
3. 출력층에서의 값과 출력 데이터와의 오차 계산
4. 오차가 최대한 작아지도록 가중치를 최적화

가중치를 최적화 하는 방법은 일반적으로 경사하강법(Gradient Descent Algorithm)을 이용하여 최적화하며, 오차 역전파(Back Propagation)을 이용하여 경사를 계산한다. 과적합을 방지하는 방법으로, 일정한 비율의 뉴런을 선정하여 가중치를 0으로 만드는 Dropout 방법을 이용하기도 한다.

1.3.2 Convolution Neural Network

Convolution Layer와 Pooling Layer를 포함하는 신경망으로 이미지 처리에 좋은 성능을 보인다. 가중치를 갖는 마스크를 이용하여 특징을 추출하는데, Convolution과 Pooling을 반복하여 추출한 특징을 Fully Connected 신경망에 입력하여 최종적으로 1차원 벡터 형태의 특성으로 압축한 뒤 Softmax를 통해 분류한다.

1.3.3 Recurrent Neural Network

재귀적 접속이 있는 은닉층을 사용한 신경망로 가변 길이의 데이터 취급에 많이 사용된다. 주로 시간의 흐름에 따라 변하는 시계열 데이터를 다루며 자연어 처리나 음성 인식에 주로 적용한다.

초기 RNN은 신경망이 깊어질수록 가중치가 사라져버리는 Vanishing Gradient Problem이 존재했는데, 이러한 단점을 보완하기 위해 변화를 준 LSTM 등의 다양한 RNN 모델들이 연구되고 있다.

1.3.4 Auto Encoder

오토인코더는 출력값을 입력값의 근사로 하는 함수를 학습하는 비지도 학습이다. 입력을 히든 레이어로 인코딩하고 인코딩된 히든 유닛을 디코딩해서 입력과 사이즈가 같은 출력을 한다. 이때 인코딩 과정에서 입력이 압축되는데 입력값이 압축됨으로써 입력에서 출력으로의 손실없는 완벽한 복사는 일어날 수 없으며 이러한 압축 과정의 일환으로 입력이 무작위적이지 아니라는 가정 하에 히든 유닛이 입력의 피처를 학습하게 된다. 오토 인코더의 과생형으로 Stacked Auto Encoder, Sparse Auto Encoder, Denoising Auto Encoder 등이 있다.

III. The Proposed Scheme

본 장에서는 비행체 안테나는 이중화 되어 있으나 내부의 송수신기는 단일화한 가시선 데이터링크시스템의 데이터를 딥러닝을 사용하여 학습시키고 이를 통해 수신품질을 예측하는 모델을 설계한다. 그리고 예측된 수신품질 정보를 기반으로 탑재가시선안테나를 제어하는 구조를 제안한다. 마지막으로 가시선 데이터링크에 이와 같은 구조를 적용하는 방안에 대해 논의한다.

1. Dataset analysis

비행체의 안테나의 송수신기가 단일화된 데이터링크 시스템이기 때문에 비행체의 특정 위치 및 자세에서 상부 또는 하부 한쪽의 데이터만 존재한다는 특성이 있다. 특정 위치 및 자세에서 상부 및 하부 모두의 데이터가 존재한다면, 상부 및 하부 두 개의 카테고리를 갖는 데이터셋을 만들고 비행체의 자세를 입력으로 하고 상부 및 하부 두 가지의 출력을 갖는 모델을 학습시키면 되지만 데이터 특성상 이러한 모델을 적용할 수 없었다.

데이터 항목 중 RSSI(Received Signal Strength Indicator)는 수신 신호의 세기를 나타내며 이는 비행체의 위치, 자세 및 거리에 따른 신호 손실이 반영된 값이며 비행체 상부와 하부 두 개의 안테나 성능 지표이기도 하다. 따라서 비행체의 특정 위치 및 자세에서의 상부 및 하부 안테나 각각의 RSSI를 예측할 수 있다면 두 RSSI를 비교하여 더 나은 수치를 갖는 안테나를 선택할 수 있다.

2. Multilayer Neural Network Model Design

그림6은 비행체의 위치 및 자세에 따른 탑재 안테나의 RSSI를 예측하는 모델 RPM(Rssi Prediction Model)을 나타낸다. 입력 P와 S는 각각 비행체의 위치 및 자세이며 출력 V는 예측한 RSSI 값이다. 입력층, 4개의 은닉층 및 출력층으로 이루어진 모델로서 각 계층은 10개의 뉴런으로 구성되어 있다. 학습 효율을 높이기 위해 min-max normalization을 통해 입력 데이터의 정규화를 수행했다.

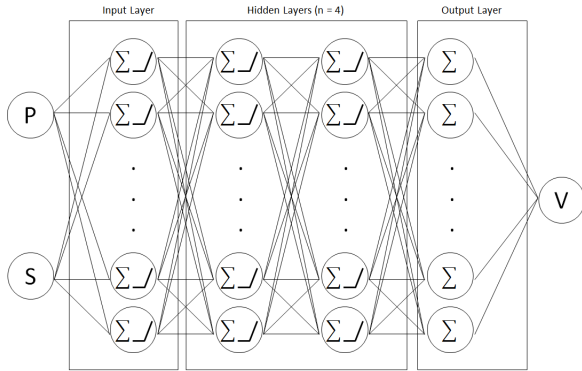


Fig. 6. RPM(Rssi Prediction Model)

Loss Function은 식(1)과 같이 RMSE(Root Mean Square Error)를 사용했으며 Loss 최적화를 위한 Optimizer는 Adam (Adaptive Moment Estimation)을 사용했다.

$$Loss = \sqrt{\sum_{i=1}^n (V_i - Y_i)^2} \quad (1)$$

각 계층에서의 활성화 함수(Activation Function)은 ReLU (Rectified Linear Unit)을 사용했으며 과적합을 피하기 위해 입력층과 은닉층엔 Dropout 기법을 적용했다. [14]에서 연구된 바와 같이 효율을 높이기 위해 입력층에서는 20%, 은닉층에서는 50%의 비율로 Dropout을 적용했다. 가중치의 초기값으로 ReLU 활성화 함수를 사용할 때 효율적인 He 초기값을 적용했다.[15]

3. Model Training

RPM의 학습은 입력값의 종류를 다르게 하여 두 가지 방법으로 진행하여 비교 분석하였다.

3.1 Input with elevation of air vehicle for GDT

1.2절에 기술한 기존 안테나 스위칭 방법은 지상체에 대한 비행체 기준 고각에 대해 경계값을 설정하여 경계값을 넘었을 때 상부 또는 하부를 선택하는 방법이다. 이 방법을 차용하여 지상체에 대한 비행체 기준 방위각, 고각 및 비행체 높이를 RPM의 입력으로 하여 학습하였다. 그림7은 해당 모델의 구성을 나타낸다.

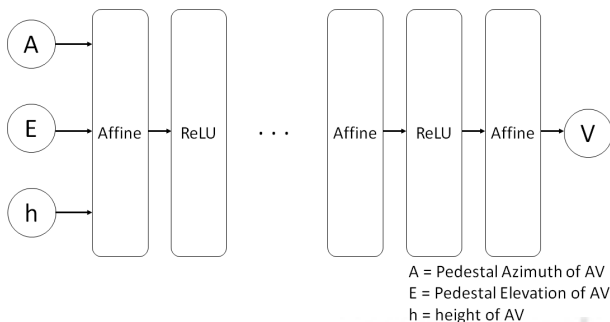


Fig. 7. RPM for three input parameters

비행체 기준 방위각과 고각을 구하는 방법은 다음과 같다. 위도를 ϕ , 경도를 θ , 높이를 h , 편평율을 e 라고 할 때 ϕ 에서의 모유선곡률반경은 식(2)로 나타낼 수 있다.

$$R_\phi = \frac{SemiMajorAxis}{\sqrt{1 - e^2 \sin^2 \phi}} \quad (2)$$

측지좌표계에서 지구중심고정좌표계로의 변환은 식(3)을 통해 이루어진다.

$$\begin{aligned} X_{ecf} &= (R_\theta + h) \cos \phi \cos \theta \\ Y_{ecf} &= (R_\theta + h) \cos \phi \sin \theta \\ Z_{ecf} &= ([1 - e^2] R_\theta + h) \sin \phi \end{aligned} \quad (3)$$

지상체에서의 지구중심고정좌표계를 X_G, Y_G, Z_G 비행체에서의 지구중심고정좌표계를 X_A, Y_A, Z_A 라고 할 때 지구중심고정좌표계의 좌표 증분은 식(4)으로 나타낼 수 있다.

$$\begin{aligned} dX &= X_G - X_A \\ dY &= Y_G - Y_A \\ dZ &= Z_G - Z_A \end{aligned} \quad (4)$$

Molodensky Transformation (3-parameter Transformation)은 지구중심고정좌표계의 좌표 증분을 위경도, 고도의 증분으로 변환하는 방식으로 5m 정도의 정확도를 갖는다. 비행체에서의 위도와 경도를 ϕ_A, θ_A 라고 할 때 Molodensky Transformation을 사용하여 위경도 및 고도의 증분은 식(5)와 같이 구할 수 있다.

$$\begin{aligned} d\phi &= -dX \sin \phi_A \cos \theta_A - dY \sin \phi_A \sin \theta_A + dZ \cos \phi_A \\ d\theta &= -dX \sin \theta_A + dY \cos \theta_A \\ dh &= -dX \cos \phi_A \cos \theta_A - dY \cos \phi_A \sin \theta_A - dZ \sin \phi_A \end{aligned} \quad (5)$$

비행체와 지상체 간 거리를 D 라고 할 때 비행체 위치의 진북 기준 지향 방위각 및 비행체 위치의 수평면 기준 지향 고각은 식(6)을 통해 나타낼 수 있다.

$$\begin{aligned} AZ_{Global} &= \arctan \frac{d\phi}{d\theta} \\ EL_{Global} &= -\arcsin \frac{dh}{D} \end{aligned} \quad (6)$$

비행체의 ROLL, PITCH, YAW를 각각 $\theta_r, \theta_p, \theta_y$ 라고 할 때 식(7)을 통해 비행체 기준 벡터로 변환할 수 있다.

$$\begin{aligned}
 CA &= \cos(AZ_{Global} - \theta_y) \\
 SA &= \sin(AZ_{Global} - \theta_y) \\
 CE &= \cos(EL_{Global}) \\
 SE &= \sin(EL_{Global}) \\
 CP &= \cos(-\theta_p) \\
 SP &= \sin(-\theta_p) \\
 CR &= \cos(-\theta_r) \\
 SR &= \sin(-\theta_r) \\
 V_{11} &= CP \times CA \times CE - SP \times SE \\
 V_{21} &= SR \times SP \times CA \times CE + CR \times SA \times CE + SR \times CP \times SE \\
 V_{31} &= SR \times SA \times CE - CR \times CA \times CE - CR \times CP \times SE
 \end{aligned}
 \tag{7}$$

비행체 기준 벡터를 통해 비행체 기준 지향 방위각 및 비행체 기준 지향 고각을 식(8)과 같이 구할 수 있다.

$$\begin{aligned}
 AZ_{Ped} &= \arctan \frac{V_{11}}{V_{21}} \\
 EL_{Ped} &= -\arcsin V_{31}
 \end{aligned}
 \tag{8}$$

3.2 Input with position and stance of air vehicle

입력값에 따른 모델의 성능을 비교하기 위해 3.1절과 같이 비행체 기준 지향 방위각 및 고각을 입력으로 사용하는 대신에 비행체의 자세(roll, pitch, yaw)와 지상체 안테나의 지향 방위각, 고각 및 비행체 높이를 입력으로 하여 학습을 수행했다. 그림8은 해당 모델의 구성을 나타낸다.

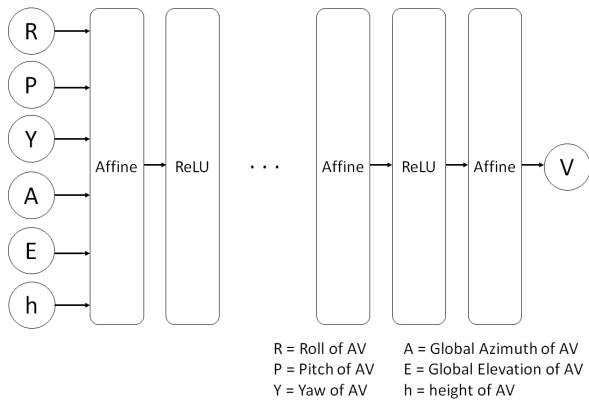


Fig. 8. RPM for six input parameters

3.3 Applying Model for Datalink

학습을 통해 생성한 안테나 RSSI 예측 모델 RPM을 데이터링크 시스템에 적용한 안테나 스위칭 절차는 그림9와 같다.

데이터링크 제어기는 항법장치로부터 비행체의 위치정보를 수신하여 모델의 입력데이터로 사용하기 위한 데이터 전처리를 수행한다. 그리고 안테나 상부 및 하부의 RSSI 예측 모델 각각에 위치정보를 입력하여 RSSI 값을 예측하고 두 예측값을 비교하여 안테나 스위칭을 수행한다.

빈번한 안테나 스위칭은 오히려 데이터링크 단절을 초래하여 데이터링크 신뢰성을 떨어뜨릴 수 있다. 이러한 현상을 방지하기 위해 동기 정보 및 FER 등의 무선환경 성능 지표를 통해 꼭 필요할 경우에만 안테나 스위칭을 수행하도록 절차를 추가할 수도 있다.

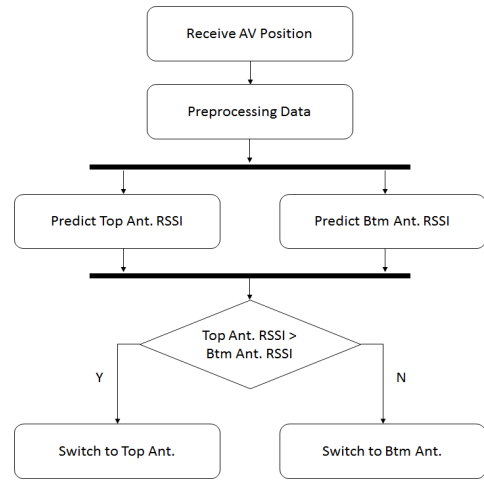


Fig. 9. Procedure of antenna switching using RSSI prediction of airborne antenna

IV. Experiment

본 장에서는 제안하는 안테나 스위칭 방법에서 사용한 RPM 모델의 학습 파라미터에 대해 설명하고 학습 및 테스트 결과를 통해 입력값에 따른 RPM 성능을 비교해본다. 이후 안테나 스위칭 시뮬레이션 실험환경 및 시뮬레이션 결과 분석을 통해 시험 결과에 대해 논의한다.




Fig. 10. Training result of each models

그림10은 입력값을 다르게 하여 학습한 RPM의 loss 변화이다. RPMT_EL은 안테나 고각을 입력값으로 하여 상부 안테나에 대한 RSSI 예측 모델이며 RPMT_EL은 안테나 고각을 입력값으로 하여 하부 안테나에 대한 RSSI 예측 모델이다. RPMT_ST 및 RPMB_ST는 비행체 자세를 입력값으로 한 RSSI 예측 모델이다. 모든 모델의 학습에 있어서 learning rate는 동일하게 0.001로 설정했으며 batch size를 128로 하여 1,000 epoch time 학습하였다. 학습 결과, 상부 안테나 RSSI

예측 모델은 두 가지 입력값에 대해 Training loss가 비슷한 값을 가지며, 하부 안테나 RSSI 예측 모델은 비행체 자세를 입력으로 하는 모델이 더 나은 Training loss를 보였다.

Table 1. Training, Validation, Test loss of each models

Model	Training loss	Validation loss	Test loss
RPMT_EL	0.109245	0.101919	0.227981
RPMT_ST	0.101122	0.092808	0.151685
RPMB_EL	0.080082	0.079494	0.198103
RPMB_ST	0.067636	0.068036	0.177674

표1은 각 모델들의 Training loss, Validation loss, Test loss를 보여준다. 데이터셋의 train:val 비율은 8:2이며 Test는 Training, Validation에 사용하지 않은 특정 비행시험의 데이터를 사용했다.

상부 안테나 RSSI 예측 모델은 고각 및 자세의 두 입력값이 거의 동일한 Training loss를 보였지만 Validation 및 Test loss는 고각을 입력으로 했을 때 더 좋은 성능을 보였고 하부 안테나 RSSI 예측 모델은 Training loss와 동일하게 비행체 자세를 입력으로 했을 때 더 좋은 성능을 보였다.

그림11과 그림12는 모델의 RSSI 예측값에 대한 히스토그램이다. 상대적으로 상부 안테나의 예측 RSSI는 넓게 분포하며 하부 안테나의 RSSI는 좁은 분포를 보인다. 이는 실제 무인항공기의 임무 수행 중 대부분의 경우 비행체 간섭이 심한 상부 안테나보다 하부 안테나가 상대적으로 더 안정적인 성능을 보이는 것과 일치한다.




Fig. 11. Histogram for RSSI prediction model of top antenna




Fig. 12. Histogram for RSSI prediction model of bottom antenna

시뮬레이션을 수행하기 위해 그림13과 같이 실험환경을 구성했다. AV Simulator에서 비행체 위치 및 자세 정보를 ADC로 송신하며 ADC는 수신한 비행체 위치 및 자세 정보를 입력으로 하여 그림9와 같은 절차를 수행한다. ADC는 안테나 스위칭 명령을 ADA를 통해 AAC로 전달하여 안테나 스위칭을 수

행한다. 안테나 스위칭 수행 결과는 그림14와 같이 Test Equipment GUI를 통해 확인 가능하며, 안테나 스위칭 결과를 파일에 기록하여 누적된 결과를 확인하였다.

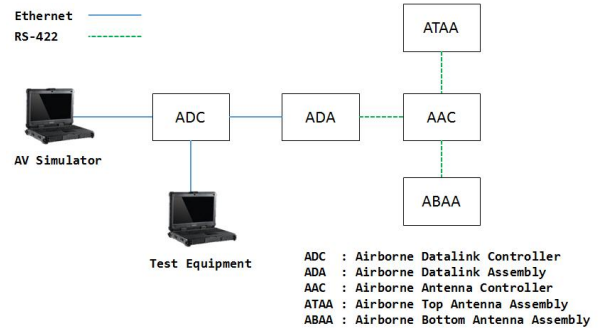


Fig. 13. Test Environment



Fig. 14. Test Equipment

시뮬레이션에는 실제 약 8시간 동안 수행한 비행시험 데이터를 사용했다. 비행체 위치 및 자세 정보, 비행체 상태정보, 지상체 상태정보 등 서로 다른 주기를 갖는 데이터를 정제하여 시뮬레이션을 구성했다. 시뮬레이션 중 총 32회의 안테나 스위칭 발생했는데 그림15와 같이 비행 초반과 후반에 안테나 스위칭이 발생했다. 안테나 스위칭 구간을 거리와 비교해본 결과, 지상체와 비행체 간 거리가 6km 이내일 때 안테나 스위칭 발생했으며 6km 이상 거리에서는 하부 안테나로 안정적인 무선 환경 유지했음을 알 수 있다.




Fig. 15. Antenna switching during simulation

V. Conclusions

본 논문에서는 무인항공기 가시선 데이터링크 시스템에서 탑재 안테나의 상부 및 하부에 대한 RSSI 예측을 통해 탑재 안테나 스위칭 방법을 제안하였다. 이를 위해 비행체 위치 및 자세에 따른 무선환경 변화 상태를 학습하여 RSSI를 예측하는 딥러닝 모델을 제안하였다.

비행체 기준 지상체에 대한 고각을 입력으로 하는 RPM_EL과 비행체 자세를 입력으로 하는 RPM_ST의 학습 결과, 충분히 낮은 loss를 보이는 것을 확인하였으며, 비행체 기준 지상체에 대한 고각을 입력으로 했을 때보다 비행체 위치 및 자세를 입력으로 하여 모델을 학습했을 때 더 좋은 성능을 보이는 것을 확인하였다.

3.1절에서 언급한 바와 같이 빈번한 안테나 스위칭은 오히려 데이터링크 신뢰성을 떨어뜨릴 수 있다. 향후에는 안테나 스위칭 시 성능지표의 변화도 학습하여 딥러닝 모델을 통해 안테나 스위칭 빈도까지 제어하는 방법에 대해 연구할 계획이다.

REFERENCES

- [1] J. W. Choi, "UAV Development Trends," Agency for Defense Technical Investigation Paper, No. 424, pp. 104-113, June 2014.
- [2] S. H. Lee, J. K. Kim, J. H. Ko, C. H. Kwon, "Dual-Redundant Design of Pilot Console of Ground Control System for Telecontrol UAV," The Korean Society for Aeronautical & Space Sciences Fall Conference, pp. 1362-1364, Jeju, Korea, Nov. 2015.
- [3] J. H. Kim, J. W. Choi, Y. M. Jeon, J. H. Cho, "Development Result of the UAS Datalink System," The Korean Society for Aeronautical & Space Sciences Spring Conference, Wonju, Korea, pp. 707-711, April 2014.
- [4] C. W. Kim, H. J. Kim, K. I. Kwon, D. J. Jeong, "An efficient Method of Antenna Placement considering EMI between equipments on UAV," Journal of The Korean Society for Aeronautical & Space Sciences, Vol. 39. No. 10, pp. 987-994, Oct. 2011.
- [5] J. W. Choi, J. H. Kim, "Ku-Band RF Transceiver System Design for UAV Line-Of-Sight Datalink," Journal of the Institute of Electronics Engineers of Korea, Vol. 51, No. 9, pp. 46-53, Sep. 2014.
- [6] S. W. Hong, Y. K. Kim, "Design of TM/TC data protocol of Military Unmanned Aerial Vehicles," Journal of The Korea Institute of Information and Communication Engineering, Vol. 22, No. 3, pp. 506-512, March 2018.
- [7] B. S. Song, H. C. Lee, S. B. Kim, "Mount Location Simulation of UHF-Band Omni-Directional Antenna for Smart UAV," The Journal of Korean Institute of Communications and Information Sciences, Vol. 38, No. 11, pp. 982-989, Nov. 2013.
- [8] K. H. Kim, S. H. Shin, Y. D. Tak, "Improved diversity antenna selection algorithm based on the real-time performance comparison," The Korean Society for Aeronautical & Space Sciences Spring Conference, Jeongseon, Korea, pp. 345-348, April 2013.
- [9] J. H. Kim, J. W. Choi, E. H. Chung, "Placement Optimization of Airborne Line-Of-Sight Datalink Directional Antenna in UAV," Journal of the Institute of Electronics and information Engineers, Vol. 51, No. 4, April 2014.
- [10] J. S. Park, "Antenna Selection Method of the Aeronautical Data-link systems for Space Diversity," Proceedings of Symposium of the Korean Institute of Communications and Information Sciences, pp. 228-229, Daejeon, Korea, Nov. 2014.
- [11] E. H. Son, C. B. Yoon, "A Study on UAV DoA Estimation Accuracy Improvement using Monopulse Tracking," Journal of Korea Institute of Electronic Communication Science, Vol. 12, No. 06, pp. 1121-1126, Dec. 2017.
- [12] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. "Deep learning," Nature, Vol. 521, No. 7553, pp. 436-444, May 2015
- [13] Yangqing Jia, et al. "Caffe: Convolutional Architecture for Fast Feature Embedding," Proceedings of the 22nd ACM international conference on Multimedia, pp. 675-678, Florida, USA, Nov. 2014
- [14] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," The Journal of Machine Learning Research, pp. 1929-1958, Vol. 15, No. 1, Jan. 2014.
- [15] K. He, X. Zhang, S. Ren, J. Sun, "Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification," The IEEE International Conference on computer vision (ICCV), pp. 1026-1034, Santiago, Chile, Feb. 2015.

Authors



Se-Hyeon Jo received the B.S. degree in Computer Science and Engineering from Hanyang University, Korea, in 2010. In 2010, he joined Hanwha Systems Co., Republic of Korea, and he is currently an engineer. He is interested in datalink and

deep learning.



Woo-Sin Lee received the B.S., M.S. and Ph.D. degrees in Computer Engineering from Kwangwoon University, Korea, in 2001, 2003 and 2007, respectively. Dr. Lee is currently a chief engineer in Hanwha Systems. He is interested in data links,

tactical networks.



Hack-Joon Kim received the B.S. degree in Computer Engineering from Hongik University, Korea, in 2004. He is currently a senior engineer in Hanwha systems and also a M.S. graduate student in Defense Fusion Engineering, Yonsei University,

Korea. He is interested in Common/Tactical data links, UAS and machine learning.



So-Yeon Jin received the B.S. degree in Computer Engineering from Chonbuk National University, Korea, in 2003. So Yeon Jin is currently a senior engineer in Hanwha systems. She is interested in data links, machine learning, military

communications, unmanned systems.



In-Deok Yoo received the B.S. degree in Computer Engineering from Kangwon University, Korea, in 2010. In Deok Yoo is currently an engineer in Hanwha Systems. He is interested in datalink, machine learning, blockchain.