

Development of an AI-Based Velocity Control Learning Pipeline for Autonomous Drone Navigation

Woon-Yong Kim*

*Professor, Dept. of Drone Convergence Technology, Gangwon State University, Gangneung, Korea

[Abstract]

In this paper, we propose an AI-based learning pipeline for velocity-based autonomous drone navigation. The proposed method utilizes a supervised learning approach that integrates the drone's current state information (velocity and orientation) with future path data to predict velocity commands in real-time. The hybrid LSTM-based model classifies diverse flight patterns such as hovering, straight flight, turning, ascending/descending, obstacle avoidance, and takeoff/landing, generating adaptive velocity commands suitable for different flight scenarios. Consequently, this method enables smooth and efficient path following in complex and dynamic environments. Evaluated within ROS 2 and PX4 simulation environments, the proposed model demonstrates excellent performance metrics, including RMSE of 0.0347, MAE of 0.0225, and an R^2 of 98.67%. By recognizing various drone flight modes and dynamically calculating appropriate velocities based on current position and speed, the method ensures natural trajectory control and responsive maneuverability.

▶ **Key words:** Autonomous drone, velocity-based control, AI controller, learning-based model, path tracking, ROS 2, PX4

[요 약]

본 논문에서는 속도 기반의 자율 드론 비행을 위한 AI 학습 파이프라인을 제안한다. 제안하는 방법은 지도학습 기반 모델을 활용하여 드론의 현재 상태 정보(속도 및 방향)와 미래의 경로 정보를 결합하여 실시간으로 속도 명령을 예측하는 구조를 가진다. LSTM 기반의 하이브리드 모델을 통해 호버링, 직선비행, 선회, 상승/하강, 장애물 회피, 이착륙과 같은 다양한 비행 패턴을 분류하고, 이를 바탕으로 비행 상황에 유연하게 반응할 수 있는 속도 명령을 생성하는 구조를 가진다. 이를 통해 복잡하고 동적인 환경에서 자연스럽게 효율적인 경로 추종을 이끌어 낼 수 있을 것이다. 모델 구조는 ROS 2 및 PX4 기반의 실시간 자율비행 환경에 적용가능한 모델로 평가 결과 RMSE 0.0347, MAE 0.0225, R^2 98.67%의 성능을 보여주고 있다. 다양한 드론 비행 모드를 인식하고 현재의 드론의 위치와 속도를 기반으로 이동할 경로에 대한 속도를 계산하고 운행하는 구조로 드론의 자연스러운 흐름제어를 바탕으로 경로에 유연하게 반응하는 제어 명령을 생성할 수 있을 것이다.

▶ **주제어:** 자율비행 드론, 속도 기반 제어, 인공지능 제어기, 학습 기반 모델, 경로 추종, ROS 2, PX4

- First Author: Woon-Yong Kim, Corresponding Author: Woon-Yong Kim
- Woon-Yong Kim (wykim@gw.ac.kr), Dept. of Drone Convergence Technology, Gangwon State University
- Received: 2025. 05. 08, Revised: 2025. 06. 10, Accepted: 2025. 06. 17.

I. Introduction

1. Research Background

자율주행 시스템은 드론, 자율주행차, 모바일 로봇 등 다양한 분야에서 핵심 기술로 자리잡고 있으며, 이들의 공통적인 구조는 크게 인식(Perception), 위치 추정(Localization), 경로 계획(Planning), 제어(Control), 실행(Actuation)의 단계로 구성된다[1,2]. 먼저, 자율주행 시스템은 카메라, LiDAR, IMU, GPS 등 다양한 센서를 활용하여 주변 환경과 드론 자체의 상태를 실시간으로 인식한다. 이 과정에서는 객체 탐지, 장애물 인식, 3차원 지도 생성 등의 기능이 수행된다. 이후 위치 추정 단계에서는 센서 융합과 SLAM 기반 기법을 통해 로봇의 현재 위치와 자세를 정확하게 계산할 수 있다. 경로 계획 단계는 전역(Global) 또는 지역(Local) 수준에서 주행 경로를 생성하며, 주변 장애물이나 경로상의 제약을 반영하여 최적의 경로를 선택한다. 생성된 경로를 따라 움직이기 위해 제어(Control) 단계에서는 PID, MPC 또는 AI 기반 제어를 활용하여 속도 및 자세 명령을 생성하며, 마지막으로 생성된 제어 명령은 모터나 서보 등을 제어하는 하드웨어 계층에 전달되어 실제 동작이 수행되는 구조를 가진다[3,4]. 이 중 제어 단계는 전체 시스템의 성능과 안전성에 결정적인 영향을 미치며, 특히 복잡한 환경에서의 즉각적인 대응이 요구된다. 전통적인 드론 제어 방식은 경로점 기반(Position-based control)으로, 사전에 정의된 좌표 경로를 따라가도록 설계된다. 이는 구현이 간단하고 신뢰성이 높은 장점이 있으나, 급격한 장애물 회피, 실시간 경로 수정, 동적 환경 대응 등에서는 유연성이 부족하다는 한계를 갖는다. 이에 비해 속도기반 제어(Velocity-based control)는 매 순간 드론의 상태와 환경 정보를 반영하여 연속적인 속도 벡터를 생성함으로써 보다 유연하고 부드러운 경로 추종이 가능하다. 그러나 이러한 제어 방식을 수동으로 설계하거나 규칙 기반으로 구성할 경우, 다양한 비행 상황에 대한 일반화가 어렵고 튜닝에 많은 비용이 발생할 수 있다. 이에 본 논문에서는 자율주행 구조를 바탕으로 속도 기반 제어(Velocity-based control)를 위한 AI 모델 설계 방법을 제시한다. 이는 전통적인 경로점 기반 제어방식의 한계를 극복하고, 동적 환경에서 더욱 유연하고 실시간적인 자율 비행을 구현할 수 있을 것이다.

2. Objectives and Methods

속도 기반 드론 자율비행 제어의 효율성과 일반화를 달성하기 위해, 지도학습 기반 인공지능 모델을 활용한 속도

제어기 설계 및 학습 파이프라인을 구축하고자한다. 이를 위해 드론의 현재 상태(x, y, z, vx, vy, vz, yaw)와 경로(local path)를 바탕으로 실시간 속도 명령(vx, vy, vz, yaw_rate)을 출력하는 학습 기반 제어 모델을 구축하기 위해 다양한 비행 유형(hover, straight, turn, ascend/descend, avoid)에 적응 가능한 다중 모드 예측 및 실제 시뮬레이션 및 비행 로그 기반의 데이터셋을 구축을 통한 학습 및 추론이 가능한 통합 파이프라인을 제시한다. 연구 방법으로 속도기반 자율비행 제어 모델을 위한 입력 구조 및 출력 정의를 체계화하고, 경로 기반 시계열 데이터를 반영한 학습 포맷을 제안한다. 또한 다양한 비행 유형을 고려한 비행모드(패턴) 분류 및 속도 추론 연계 모델 구조를 설계하여 복잡한 비행 상황에 대응 가능한 AI 제어기를 구현하고자 한다. 구현 환경은 ROS 2 및 PX4 기반 시뮬레이션 환경[5]에서 데이터 전처리, 모델 학습, 추론, ROS 연동 등 전체 제어 흐름을 포함하는 자동화된 학습 파이프라인을 구축하고 평가한다.

II. Preliminaries

1. Related works

자율비행 드론 시스템은 일반적으로 인식(Perception), 위치 추정(Localization), 경로 계획(Planning), 제어(Control), 실행(Actuation)의 다섯 단계로 구성된다. 인식단계는(Perception) 카메라, LiDAR, IMU 등 센서를 통해 주변 환경 및 비행체 상태 정보를 수집하고, 위치 추정(Localization)단계는 GPS, 비전 기반 SLAM, IMU 융합을 통해 드론의 현재 위치와 자세를 추정한다. 또한 경로 계획(Planning)은 시작점에서 목표 지점까지의 전체 경로 계산하는 Global Planner와 장애물을 회피하며 현재 위치 기준으로 단기 경로 생성하는 Local Planner로구성되며, A*, DWA, MPC등의 알고리즘으로 구현될 수 있다. 제어(Control)단계는 경로를 따라 움직이기 위해 필요한 이동 위치(x, y, z)나 속도(vx, vy, vz, yaw_rate) 명령을 생성하고 그결과를 실행(Actuation)으로 전달한다. 마지막으로 생성된 명령은 PX4와 같은 Flight Controller에 전달되어 실제 비행을 수행하는 과정을 거친다. 이러한 자율비행 시스템 블록 구성되는 그림 1과 같이 표현될 수 있다. 그중 제어 단계는 센서 정보와 경로 계획 결과를 기반으로 실제 드론의 움직임을 결정하는 핵심 요소로, 전체 자율 비행의 품질을 좌우할 수 있다.

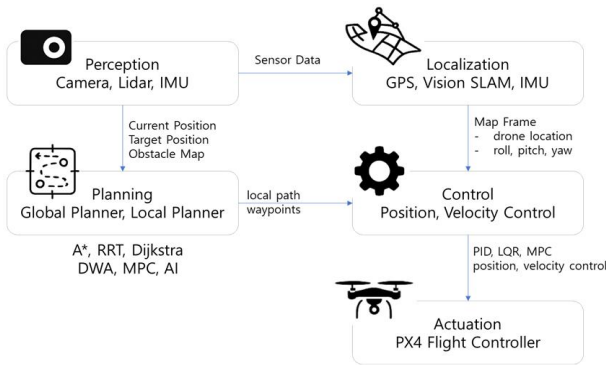


Fig. 1. Autonomous Drone System Architecture

기존 제어 방식은 대부분 PID나 MPC와 같은 수학적 모델에 기반한 전통 제어기로, 안정성과 예측 가능성 측면에서는 우수하지만, 다양한 비행 시나리오나 예기치 않은 외란에 대한 적응성은 부족하다. 이러한 한계를 극복하고자 최근에는 강화학습 및 지도학습을 활용한 인공지능 기반 제어 전략이 활발히 연구되고 있다. Sadeghi & Levine [6]은 CAD 모델 기반의 시뮬레이션 이미지를 활용해 실제 이미지를 사용하지 않고도 강화학습을 수행하는 'CAD2RL'을 제안하였다. 이는 도메인 랜덤화를 통해 시뮬레이션-현실 간 간극(Sim2Real gap)을 줄이고, 단일 이미지 기반 제어를 가능하게 하였다. Kaufmann et al.[7]은 고난도 곡예 비행을 가능하게 하는 강화학습 기반 모델을 통해 드론의 민첩성과 정확성을 극대화하였다. 시뮬레이션에서 학습한 정책을 실제 드론에 적용하여 고속 비행을 성공적으로 수행하였다. Loquercio et al.[8]은 실제 환경에서 수집한 이미지 시퀀스를 입력으로 하여 속도 명령을 직접 출력하는 end-to-end 딥러닝 기반 제어기를 제안하였다. 이 연구는 고속 자율비행의 실현 가능성을 실 환경에서 입증하고 있다. Huang et al. [9]은 모델 예측 제어(MPC)에 딥러닝 기반 상태 예측을 결합한 학습 기반 MPC 구조를 통해 안전한 경로 계획과 제어를 통합하였으며 이는 특히 미지의 환경 탐색에서 유용한 방식으로 인식되고 있다. 김도형 [10]은 DQN, PPO 기반의 강화학습 제어기를 설계하고, PX4 시뮬레이션 환경에서 다양한 비행 시나리오에 대한 성능을 비교 분석하였으며 강화학습 기반 제어기의 실제 활용 가능성을 평가한 실용적 연구로 인식되고 있다. 이러한 대부분의 기존 연구는 이미지 또는 상태 기반 입력에 집중한 반면, 본 연구는 경로(local path) 정보를 포함한 복합 입력 구조를 통해 더욱 정밀한 경로 추종 방법을 제시한다. 강화학습 중심의 기존 연구들과 달리, 지도학습 기반의 회귀 모델(LSTM)을 통해 학습 안정성과 추론 속도를 확보하고 ROS 2와 PX4 기반의 시

뮬레이션 환경에 통합하여, 실시간 제어 노드와의 연동이 가능한 구조를 이끌어 내기위한 다양한 비행 유형을 통합적으로 학습하고, 실시간 속도 명령을 생성한다. 이러한 방식을 통해 기존의 경로점 기반 제어가 가지는 문제인 장애물 회피나 곡선 경로 추종과 같은 동작 상황의 부자연스러운 진행 및 과도한 진동등의 문제를 극복하고 현재 상태를 기반으로 지속적인 속도 명령 생성을 통한 자연스러운 경로 및 비행 방향과 속도 변화량을 직접 제어할 수 있는 구조를 제시한다.

III. The Proposed Scheme

1. AI Control Model and Learning Pipeline

이장에서는 드론의 속도기반 자율 제어를 위한 지도학습 기반 AI모델의 구체적인 구조와 학습을 위한 데이터 구성 및 학습 및 추론 파이프라인 구성 방법을 제시한다. 운영환경은 PX4기반의 시뮬레이션 환경과 ROS2 기반의 구조로 구성하여 실행과 테스트를 진행한다. 먼저 구축하고자 하는 AI제어 모델 추론을 위한 전체 흐름은 그림 2와 같은 과정을 거친다.

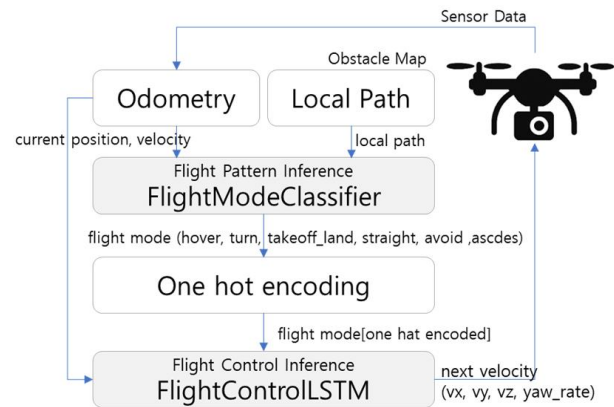


Fig. 2. AI Inference Flow for Velocity-Based Control

실시간 추론 모델 구조는 현재 속도 ($v_x, v_y, v_z, \text{yaw}$)와 경로 시퀀스 (dx, dy, dz) 입력 데이터는 FlightModeClassifier를 이용해 mode를 추론한다. (ex. hover, straight, turn 등) 이 예측된 mode는 one-hot 벡터로 변환하여 현재속도, 경로시퀀스 데이터와 함께 FlightControlLSTM의 입력을 통해 다음 속도 상대 정보인 $\Delta v_x, \Delta v_y, \Delta v_z, \Delta \text{yaw_rate}$ 를 예측하여 속도기반 비행 제어에 활용하는 구조를 가진다. 이러한 구조를 달성하기 위해 본 논문에서는 학습데이터 구성 방법, 비행 패턴

의 정의, 학습데이터 수집 방법 그리고 비행 패턴 및 비행 제어에 대한 AI 학습모델을 바탕으로 ROS2환경에서 PX4 기체의 비행 제어를 수행한다.

2. Construction of Training Data

드론의 주어진 상태정보 (x, y, z, vx, vy, vz, yaw)와 미래 경로(local_path 형태의 여러 waypoint들)를 입력으로 받아 다음 이동을 위한 속도 조종 명령 (vx, vy, vz, yaw_rate)을 예측하는 지도학습 기반 모델로 데이터의 일반화를 통해 다양한 환경에서 적용 가능한 모델을 구성할 필요가 있다. 추론을 위한 학습데이터 입력과 출력구조로 입력 데이터는 드론의 x, y, z, vx, vy, vz, yaw와 앞으로 따라야 할 경로 좌표 $[[dx_1, dy_1, dz_1], \dots, [dx_N, dy_N, dz_N]]$ 좌표로 표현할 수 있다. 여기에서 드론의 현재 좌표 x,y,z는 특정 환경에 필요한 요소이므로 일반화에서 제거하여 정의한다.

$$X = [vx, vy, vz, yaw, dx_1, dy_1, dz_1, dx_2, dy_2, dz_2, \dots, dx_N, dy_N, dz_N] \text{ 총 } 4 + 3*N \text{ 차원의 데이터 구조}$$

$$Y = [next_vx, next_vy, next_vz, next_yaw_rate]$$

3. Data Collection Methodology

학습데이터 수집 방법으로는 정의된 경로 기반 학습 데이터 수집 및 자유 비행을 통한 방식으로 수집할 수 있으며 기존의 PID 제어기로 드론을 따라가게 만든 경로 데이터를 이용해서 지도학습 모델을 학습한다. PID를 Ground Truth로 간주하고, 나중에 그 역할을 신경망 모델이 대신하게 되는 방식으로 구성된다. 학습을 위해 사용되는 경로 좌표의 waypoint수(N)는 예측하고자 하는 조종 명령의 시간적 간격과 경로 곡률 변화량에 따라 달라질 수 있다. 또한 조종 명령 유효 시간은 일반적으로 0.5~1.0초 정도의 행동을 유도하기 위해 사용된다. 즉 vx,vy,vz,yaw_rate는 약 1초 이내의 경로 모양에 영향을 받을 수 있다. 대부분의 드론은 20~50Hz 주기로 제어되며 반응 시간은 0.1~0.3초이므로 너무 먼 경로 고려시 예측과 반응 사이의 불균형이 발생할 수 있다. 경로점이 많이 지면 모델이 복잡해지고 overfitting 위험이 증가할 수 있고 너무 적은 경우 경로 구조 반응이 부족할 수 있다. 또한 비행 방식(패턴)에 따라 학습데이터 구분이 중요하며 실제 모델 성능 향상에 직결될 수 있다. 일반적으로 유용한 경로점 개수는 정적인 직선 경로일 경우 2~4개 커브 및 회피 경로는 5~8개 그리고 급회전 및 고속 회피 경로일 경우 10~12개의 경로점을 고려할 수 있다. 본 논문에서 사용되는 경로점 개수 및 주기 및 경로 길이는 다음과 같이 정의한다.

Table 1. Configuration of Waypoint Interval and Path Length

Item	Value	Description
Interval	0.2 sec	Time interval between consecutive points
Duration	2.0 sec	Total time range covered by the input
N	10	Number of path points included

비행유형에 따라 최적 경로 주기/길이는 다르지만 통합 학습을 위해서는 최소 0.2초 주기로 2초 이상을 커버하는 경로(N=10 이상) 구성하여 선회, 회피 같은 민감한 동작도 포함 가능하면서 직선/호버링에서도 무리 없는 구조를 제공하기 위해 설정하였다. 본 논문에서 학습데이터 수집방법은 자유 비행 기반 로그를 기반으로 수집하였다. 경로점은 과거 로그 기반으로 추출한 경로를 활용하고 실제 비행 행동 패턴을 학습할 수 있다는 관점에서 다 자연스러운 다양한 데이터 수집이 가능하다는 장점을 가진다.

4. Categorization of Drone Flight Patterns

드론의 비행 유형(행동패턴)에 따라 조종 명령의 특성이 다르기 때문에, 학습 데이터 구성 시 유형별로 균형 있게 포함시키는 것이 중요하며, 가능하다면 레이블링 및 분리 학습등의 방법을 통해 데이터를 수집할 필요가 존재한다. 유형별로 비행 특성을 잘 드러내는 데이터 선별하고 다양한 환경과 조건에서 데이터를 확보하여 일반화를 강화할 수 있도록 본 논문에서는 다음과 같은 비행 패턴을 정의하여 학습데이터를 구축하고자 한다.

Table 2. Definition of Drone Flight Patterns

Pattern	Features
Hover	Nearly stationary data Very slight velocity variations
Straight Flight	Stable straight-line data Maintains constant velocity
Turn	Varying curvature Changes in curve center point
Ascend/Descend	Altitude change data Maintains steady asc/des speed
Obstacle Avoidance	Rapid changes and responsive behavior Proximity data near obstacles
Takeoff/Landing	Rapid altitude change Precise speed control data

비행패턴 - 호버링 (hover)

특정고도를 유지하는 명령으로 속도(vx,vy,vz)가 0에 가깝고 위치(x,y,z)의 변화가 미세한 특징을 가진다. 다양한 위치 및 고도에서 최소 10초 이상의 호버링을 통해 데이터를 수집할 필요가 존재한다. 본 논문에서는 비행로그 데이

터틀 기반 호버링 판단 기준은 다음조건으로 설정하여 데이터를 확보하였다. 최근 2초간(10개 데이터, 0.2초 간격)의 평균 속도 ($\sqrt{v_x^2+v_y^2+v_z^2}$) < 0.1m/s 위치 변화가 발생하고 yaw의 변화가 0.01이하의 조건을 가진다.

비행패턴 - 직선비행 (straight)

직선비행은 직선 경로 웨이포인트가 일정 고도를 유지하며 vx,vy가 일정하게 유지되는 특징과 yaw 변화가 최소화된 형태를 가진다. 다양한 속도와 거리를 설정한 다양한 데이터가 필요하다. 직선 비행 데이터는 위치 데이터의 직선성(Linearity)이 높고 속도의 변화가 작고 일정할때를 기준으로 선택하였다. 즉 드론이 거의 일정한 속도로 방향을 바꾸지 않고 직선 형태로 이동하고 있을 때 이를 직선 비행인식하도록 구성하였다. 직선성 분석은 PCA(주성분 분석)를 활용하여 최근 10개(2초 간격 0.2초)의 3D 위치 데이터를 가져와 PCA 분석을 수행하였다. PCA 결과에서 첫 번째 주성분이 설명하는 분산 비율이 전체의 98% 이상이면 직선으로 판단하여 직선 비행 유형으로 분류하였다.

Table 3. Criteria for Determining Straight Flight

Item	Threshold Condition
Linearity (PCA)	explained variance > 0.98
Velocity Variation	speed_change < 0.2 m/s
Horizontal Displacement	displacement ≥ 1.0 m

비행패턴 - 선회비행 (turn)

선회비행은 원형 및 S자형인 곡선 구조의 웨이 포인트로 구성되며 yaw의 지속적인 변화와 곡률이 명확히 나타난다. x,y가 곡선 구조를 가지면 일정한 속도를 유지하는 특징을 가진다. 다양한 반경, 곡률, 선회속도를 바탕으로 데이터 확보가 필요하다. 선회비행은 최근 2초간 (10개 데이터, 0.2초 간격)의 Yaw 각도가 꾸준히 변화하고 드론이 일정 반경 이상 수평 이동(최소 1m 이상 이동)이 이루어지고 일정 이상의 곡률 유지가 발생하는 조건으로 분류한다. yaw의 변화는 연속적인 각도 값 변화의 변화량을 계산하여 최소 5도이상의 yaw변화가 존재할 경우 선회 비행으로 판단하였다.

비행패턴 - 상승/하강비행 (ascdes)

상승 및 하강비행은 x,y의 좌표가 일정하게 유지되며 고도(z)의 변화만 발생하는 구조로 z값은 명확하기 증가하거나 감소하는 특징을 가진다. 속도 vz는 일정하게 유지된다. 다양한 속도 및 다양한 상승 고도 범위에서 데이터의

확보가 필요하다. 상승/하강조건은 최근 2초(10개 데이터) 동안 z축 고도가 일정하게 증가 또는 감소하고 vz (z축 속도)의 평균 절대값이 일정 이상 변화가 이루어지며 수평 이동 거리값을 고려하여 평가되었다.

Table 4. Conditions for Ascend/Descend Flight

Item	Threshold Condition
Altitude Change	≥ 0.5m
Mean Vertical Speed	≥ 0.2 m/s
Horizontal Movement Distance Limit	≥ 0.5m

비행패턴 - 장애물회피 (avoid)

장애물회피 비행은 장애물 인식에 따른 급격한 속도(vx, vy)의 변화가 발생가능하여 방향(yaw)의 변화가 발생될 수 있다. 단기간의 높은 반응성 데이터로 다양한 거리, 각도에서 접근하고 회피 행동을 통해 데이터 확보가 필요하다. 장애물 회피는 짧은 시간 동안 급격한 속도 변화(vx, vy, yaw)가 발생하고 기체가 급격하게 방향을 바꾸거나 속도 벡터를 변경하는 특징을 가진다.

Table 5. Criteria for Obstacle Avoidance Behavior

Item	Threshold Condition
Velocity Change	$\Delta v = v(t_n) - v(t_0)$, 1.0 m/s
Yaw Change	$\Delta yaw \geq 20^\circ$ (≈ 0.35 rad)
Duration	2-second interval (10 points)

비행패턴 - 이륙/착륙 (takeoff_land)

이륙과 착륙은 정지 상태에서 이륙 또는 공중에서 착륙까지의 과정으로 고도(z)의 명확한 변화 및 초기 및 최종 고도 근처에서의 낮은 속도 변화의 특징을 가진다. 빠른 이륙 및 느린 착륙 방식을 통해 데이터의 확보가 필요하다. 이륙과 착륙 구조는 거의 제자리에서 상승과 하강이 이루어지며 고도 변화량과 평균 z 속도 그리고 수평 이동 < 0.5m 이하일 때를 고려하였다. 거리값을 고려하여 평가되었다.

Table 6. Conditions for Takeoff and Landing

Item	Threshold Condition
Altitude Change	≥ 0.5m
Mean Vertical Speed	≥ 0.2 m/s
Horizontal Movement Distance Limit	< 0.5m

5. AI Model for Flight Pattern Recognition

드론의 비행 유형(행동패턴)에 따라 조종 명령의 특성이 다르기 때문에 정밀한 비행제어 예측을 위해 경로의 연속성 및 패턴을 이용한 학습 모델의 개발이 필요하다. 현재 상태와 주어진 경로를 기반으로 비행 모드를 정확히 분류하여 각 비행 모드에 필요한 속도 제어를 달성하기 위해 비행 패턴 AI모델은 LSTM(Long Short-Term Memory)과 Feedforward 신경망을 결합하여 시계열 경로 정보와 현재 속도 정보를 동시에 학습할 수 있는 구조로 그 특징들을 반영한 비행모드(hover, straight, turn, ascdes, avoid, takeoff_land)를 예측하는 모델을 그림 3과 같이 구성하였다.

입력 데이터 : 드론의 현재 속도 및 방향, 경로점
 $[vx, vy, vz, yaw, dx1, dy1, dz1, \dots, dxN, dyN, dzN]$
 출력 데이터 : [flight_mode]
 hover, straight, turn, ascdes, avoid, takeoff_land
 현재 속도와 경로 시퀀스를 바탕으로 비행 패턴(모드)를 예측하는 구조로 이 예측 데이터는 one hot encoding 되어 속도제어 모델의 입력 값으로 활용된다.

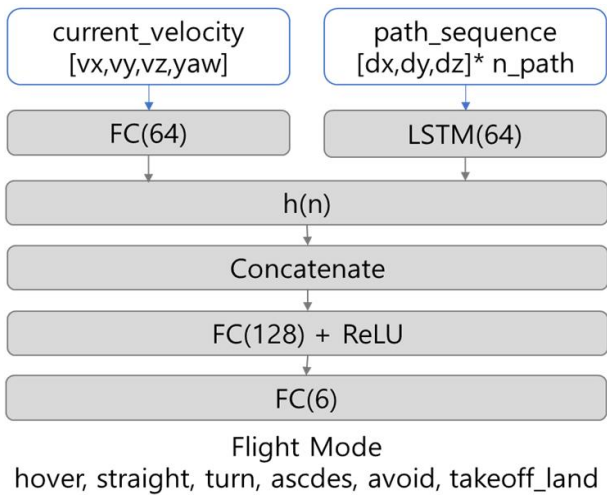


Fig. 3. AI Model for Flight Pattern Recognition

6. AI for Velocity Control in Drone Flight

모드 추론은 현재 상태에 맞는 비행 모드를 판단하고 해당 모드는 one-hot 인코딩되어 비행 상황을 속도 제어 모델에 제공하는 역할을 수행한다. FlightControlLSTM 모델은 드론의 현재 상태와 경로 그리고 모드 정보를 바탕으로 다음속도 명령을 예측할 수 있다. 비행 제어 학습모델 구조는 그림 4와 같이 구성된다. 이 모델은 시계열 기반 경로 정보(LSTM), 현재 상태(FC), 비행 모드(FC)를 결합한 하이브리드 구조로, 복잡한 드론의 제어 패턴을 정밀하

게 회귀 예측하기 위해 구성하였다. 입력구조는 드론의 현재 상태 (vx,vy,vz,yaw) 는 Fully Connected(FC) 128차원 feature로 변환하고 경로시퀀스(path_inputs)는 10개의 경로점 시퀀스 $(dx,dy,dz) * N$ 로 2-layer LSTM으로 hidden size 는 128로 구성한다. 또한 비행 모드 정보(mode_inputs)는 6차원 One-Hot Encoding하여 FC Layer에서 128차원 feature로 변환하여 구성하였다.

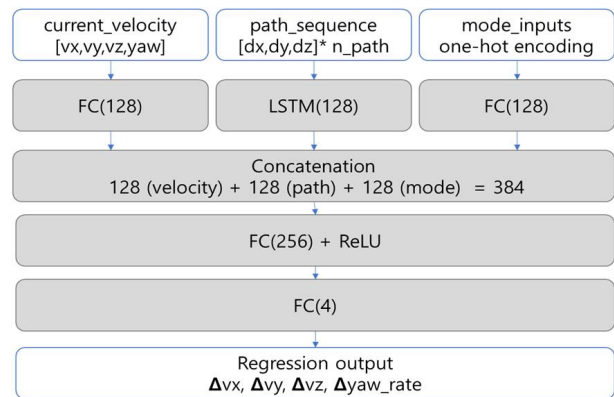


Fig. 4. AI for Velocity Control in Drone Flight

두 모델을 활용해 실시간 추론 모델의 흐름 구조는 다음과 같은 과정을 따른다.

Table 7. Inference Pipeline of the Velocity Model

No	Model Flows for Velocity Control
1	Input current velocity (vx, vy, vz, yaw) and path sequence (dx, dy, dz)
2	Predict flight mode using the FlightModeClassifier
3	Convert the predicted mode to a one-hot vector (6 classes)
4	Input current velocity, path sequence, and one-hot encoded mode into FlightControlLSTM
5	FlightControlLSTM predicts $\Delta vx, \Delta vy, \Delta vz,$ and Δyaw_rate

IV. Experiment and analysis

1. Experimental environment

실험 환경은 PX4 SITL과 ROS 2 Humble, MAVROS 환경에서 Gazebo Harmonic 기반으로 gz_x500_depth (Depth Camera) 드론 모델을 활용하여 ROS2 환경에서 실행되는 PyTorch 기반 추론 모델로 구성하였다. 관련 실험 조건 및 평가지표는 다음과 같다.

Table 8. Evaluation criteria and conditions

Evaluations	Conditions
Path Types	Hover, Straight, Curve, Obstacle Avoidance, Turning Flight, Takeoff/Landing
Path Data	[dx, dy, dz] * N_path (N = 10)
Interval	0.2 sec (0.2 * 10 = 2 sec)
RMSE	Difference between predicted and actual velocities
MAE	Mean Absolute Error
R ² Score	Regression performance indicator

2. Analysis of the FlightModeClassifier Inference

드론의 현재 속도(vx, vy, vz, yaw) 및 경로(relative path)의 시계열 정보(dx₁, dy₁, dz₁, ..., dx₁₀, dy₁₀, dz₁₀)를 입력으로 받아, 드론의 비행 패턴(flight mode)을 분류하는 LSTM 기반의 분류 모델을 설계하였다. 해당 모델은 현재 속도와 경로의 공간적·시간적 특성을 함께 고려하여, 드론의 비행 유형(정지비행, 직선비행, 회전, 상승/하강, 회피 등)을 효과적으로 추론한다. 학습 과정에서는 입력 데이터를 사전 정규화한 후, CrossEntropyLoss를 손실 함수로, Adam Optimizer를 최적화 기법으로 사용하였다. 모델은 비행 패턴 인식에 특화된 LSTM 구조에 속도 정보를 결합한 하이브리드 형태로 구성되었으며, 시계열 경로의 연속성과 현재 상태의 물리적 특성이 함께 반영되도록 설계되었다. 모델의 성능 평가는 Confusion Matrix를 기반으로 수행하였으며, 각 비행 유형별 분류 정확도 및 오분류 패턴을 시각적으로 비교하였다.

분석 결과 클래스 분류모델은 90%수준으로 안정적 구조를 제시하고 있으며 각 클래스별 분석에서 상승/하강 및 직선 및 이착륙 판단 능력이 우수하고 선회 및 회피 판단은 양호한 수준을 가지는 것으로 분석되었다.

Table 9. Training and Validation Result

Flight Pattern	Precision	Recall	F1-Score
ascdes	0.9934	0.9676	0.9803
avoid	0.8396	0.8039	0.8000
hover	0.8235	0.9432	0.8615
straight	0.8707	0.9032	0.8914
takeoff_land	0.9671	0.9932	0.9800
turn	0.8739	0.8472	0.8604

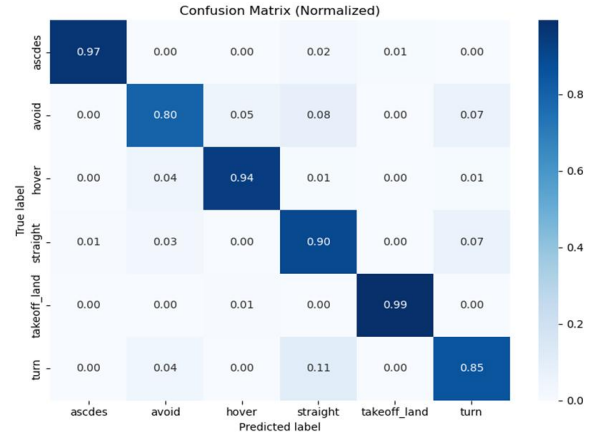


Fig. 5. Confusion Matrix of the Flight Pattern

3. Analysis of the Velocity-Based Control Model

속도 기반 통합 제어 학습 모델은 현재의 속도정보와 경로의 시간 흐름 (이동 방향 변화, 속도 변화)을 학습하는 구조로 vx, vy, vz, yaw 와 경로 경보 그리고 LSTM으로 추출한 비행 패턴을 결합해 제어가능한 속도를 얻기위한 구조를 가지며 학습 결과는 다음과 같다.

Table 10. Analysis of Training Performance

Evaluations	Values
RMSE	0.0347
MAE	0.0225
R ²	0.9867
Accuracy(10%)	94.34%
Precision(5%)	72.05%

RMSE 0.034값으로 예측값과 실제값 사이의 평균제곱 오차가 낮고 비행 제어 명령(Δvx, Δvy, Δvz, Δyaw_rate) 오차범위가 0.03정도를 만들고 있으며, MAE 0.0225는 절대값 기준 평균오차가 2.25% 수준으로 5%이내 정밀 제어를 목표로 했을 때 이상적인 수준을 유지하고 있다. R²값은 데이터 분산이 98.67%로 우수한 결과를 이끌어 내고 있다. 또한 예측값이 실제값 대비 10%이내 오차 Accuracy가 94.34%로 드론 비행 제어의 일정 수준 허용 오차가 존재하는 구조에서 적절한 결과를 만들고 있으며 Precision(5%) 값이 72% 수준으로 정밀 제어 가능성을 보여주고 있다.

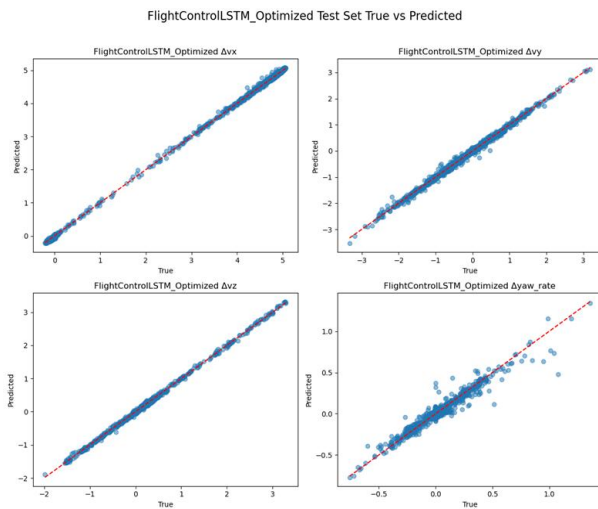


Fig. 6. Prediction Accuracy of the Velocity Model

V. Conclusions

본 논문에서는 기존의 경로점 기반 제어 방식의 한계를 극복하고, 더욱 유연하고 정밀한 자율 비행을 실현하기 위해 속도기반의 인공지능 학습 제어 모델을 설계하고 평가하였다. 특히, 드론의 현재 상태와 경로 정보를 입력으로 받아 실시간으로 속도 명령을 출력하는 지도학습 기반 AI 제어기를 제안하고, ROS 2 및 PX4 시뮬레이션 환경에서 성능을 검증하였다. 드론의 실시간 상태와 경로를 기반으로 속도 명령을 예측하기 위해 비행 패턴을 정의하고 이를 바탕으로 비행 패턴 예측과 속도 제어 AI 모델을 경로간의 상관성을 표현하기 위해 LSTM 방식과 혼합된 하이브리드 형태의 모델을 구현하였다. 학습된 AI 제어기는 기존 PID 기반 경로점 제어방식에 비해 경로 추종 및 속도 명령에 따른 부드러운 제어 환경을 제공할 수 있다. 또한 전체 제어 흐름을 ROS 2 기반 시스템으로 통합함으로써, 실시간 추론 및 제어가 가능한 구조를 제시하였다. 이를 통해 다양한 비행 시나리오에서 유연하고 효율적인 제어가 가능하며, 자율비행 드론 시스템의 적응성과 안정성을 향상시킬 수 있을 것이다.

REFERENCES

- [1] Zhou, Xin, et al. "Ego-planner: An esdf-free gradient-based local planner for quadrotors.", *IEEE Robotics and Automation Letters*, Vol. 6, No. 2, Dec 2020. DOI: 10.1109/LRA.2020.3047728
- [2] Liu, Xu, et al. "Large-scale autonomous flight with real-time

semantic slam under dense forest canopy.", *IEEE Robotics and Automation Letters*, Vol. 7, No. 2, Feb 2022. DOI: 10.1109/LRA.2022.3154047

- [3] Zhou, Boyu, et al. "Robust and efficient quadrotor trajectory generation for fast autonomous flight.", *IEEE Robotics and Automation Letters*, Vol. 4, No. 4, Oct 2019. DOI: 10.1109/LRA.2019.2934217 ??
- [4] Devo, Alessandro, et al. "Autonomous single-image drone exploration with deep reinforcement learning and mixed reality.", *IEEE Robotics and Automation Letters*, Vol. 7, No. 2, Apr 2022. DOI: 10.1109/LRA.2022.3154019
- [5] Moon, S.T., Lee, D.G., Kim, D.Y., "Analysis of PX4-ROS2 System For The Swarm Reconnaissance System.", *Spring Conference of The Korean Society for Aeronautical and Space Sciences*, 2020.
- [6] Sadeghi, F., Levine, S. "CAD2RL: Real Single-Image Flight without a Single Real Image.", *arXiv preprint arXiv:1611.04201*, Nov 2016. arXiv DOI: 10.48550/arXiv.1611.04201
- [7] Kaufmann, E., Loquercio, A., Ranftl, R., Dosovitskiy, A., Koltun, V., & Scaramuzza, D. "Deep Drone Acrobatics." *arXiv preprint arXiv:2006.05768*, June 2020 arXiv DOI: 10.48550/arXiv.2006.05768
- [8] Loquercio, A., Kaufmann, E., & Scaramuzza, D., "Learning High-Speed Flight in the Wild", *Science Robotics*, Vol. 6, No. 59, Oct 2021.
- [9] Huang, Y., Faust, A., & Murphy, K., "Learning-based Model Predictive Control for Safe Exploration", *arXiv preprint arXiv:2109.07044*, Sep 2021. DOI: 10.48550/arXiv.2109.07044
- [10] Kim, D.-H., Lee, J.-H., & Kim, Y.-J., "Design and Performance Evaluation of a Reinforcement Learning-Based Autonomous Drone Controller", *Journal of the Institute of Electronics and Information Engineers*, Vol. 59, No. 4, pp.404-412., 2022.

Authors



Woon-Yong Kim received the M.S. and Ph.D. degrees in Computer Science from KwangWoon University, Korea, in 1999, 2006, respectively. Dr. Kim joined the faculty of the Department of Computer Application

at Gangwon State University, Gangneung city, Gangwon-do, Korea, in 2006. He is currently a Professor in the Department of Drone Convergence Technology, Gangwon State University. He is interested in parallel computing, mobile computing, embedded computing and artificial intelligent.