

# 저지연 및 고출력을 위한 전이 학습과 GNN 기반 UAV 네트워크 라우팅 최적화

이 승 현\*, 박 창 민\*, 김 황 남<sup>o</sup>

## Optimizing UAV Network Routing with GNNs and Transfer Learning for Low Latency and High Throughput

Seunghyeon Lee\*, Changmin Park\*, Hwangnam Kim<sup>o</sup>

### 요 약

무인 항공기(UAV) 네트워크는 높은 이동성과 직선 시야 통신과 같은 장점에도 불구하고 높은 지연과 불안정한 연결성이라는 문제에 직면해 있다. 이를 해결하기 위해 본 논문은 지연과 네트워크 출력을 고려하여 경로를 최적화하는 전이 학습 기반 그래프 신경망(GNN) 라우팅 방식을 제안한다. 실험 결과, 제안된 방식은 대규모 네트워크에서 다익스트라 기반 라우팅보다 더 빠른 추론 속도와 높은 정확도를 달성하였으며, UAV 네트워크에서 저지연 및 고출력 솔루션으로서의 가능성을 입증하였다.

**키워드** : UAV 네트워크, 그래프 신경망, 라우팅 최적화, 전이 학습, 저지연 통신

**Key Words** : UAV networks, Graph Neural Network, Routing optimization, Transfer Learning, Low-latency communication

### ABSTRACT

Unmanned Aerial Vehicle (UAV) networks, while offering benefits like high mobility and line-of-sight communication, face significant challenges such as high latency and unreliable connectivity. To overcome these issues, this paper introduces a Graph Neural Network (GNN)-based routing approach leveraging transfer learning to optimize path prediction with a focus on both latency and throughput. Experimental results indicate that the proposed method outperforms Dijkstra-based routing in terms of inference speed and accuracy, especially in large-scale networks, highlighting its potential as an effective low-latency, high-throughput solution for UAV networks.

### I. 서 론

최근 드론 연구는 개별 드론에 대한 제어뿐만 아니라, 여러 드론이 유기적으로 협업하여 군집으로 임무를

수행하는 방향으로 변화하고 있다<sup>[1-4]</sup>. 군집 드론은 단순히 편대를 유지하는 작업에서 나아가, 정찰, 수색 및 구조, 물자 운송 등 고도의 협력이 요구되는 복잡한 임무를 수행하게 되었다<sup>[5-8]</sup>. 이러한 발전은 각 드론이

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

♦ First Author : Korea University Dept. of Electrical Engineering, lsh981225@korea.ac.kr, 학생회원

° Corresponding Author : Korea University Dept. of Electrical Engineering, hnkim@korea.ac.kr, 종신회원

\* Korea University Dept. of Electrical Engineering, minpark0120@korea.ac.kr

논문번호 : 202501-018-C-RE, Received January 17, 2025; Revised March 7, 2025; Accepted March 28, 2025

군집의 정보를 즉각적으로 공유하고 활용할 수 있는 네트워크 기술들이 제안되고 있다<sup>9)</sup>.

현재 드론 네트워크는 분산 라우팅 프로토콜이 주로 사용되고 있다<sup>10,11)</sup>. 그러나 군집에 참여하는 드론의 수가 증가함에 따라 분산 라우팅 프로토콜에는 다음과 같은 한계가 존재한다.

첫째, 네트워크 규모가 커질수록 오버헤드가 증가하고 네트워크 출력이 저하된다<sup>12)</sup>. 둘째, 경로 설정 시 메시지의 교환으로 추가적인 지연이 발생할 수 있다<sup>13)</sup>. 셋째, 높은 이동성과 링크의 불안정성으로 인해 라우팅의 신뢰성이 저하될 수 있다<sup>14)</sup>. 특히, 군집 드론이 GPS 위치 정보와 같은 단순한 벡터 값이 아니라 카메라 영상 등 고용량 데이터를 주고받아야 하는 상황에서는, 분산 라우팅으로는 저지연과 고용량 전송을 동시에 만족시키는 데 한계가 있다<sup>15,16)</sup>.

따라서 드론 네트워크의 각 드론인 저지연 및 고용량의 최적 경로를 찾기 위해서 중앙제어형 GCS-Routing 방식을 고려할 수 있다<sup>17)</sup>. GCS 라우팅 아키텍처는 각 드론의 경로를 제어하는 GCS에서 각 드론 간의 라우팅도 담당하는 방식이다. 중앙제어형 GCS-Routing은 네트워크 장애나 오류 발생 시 빠른 복구가 가능하며, 분산형 라우팅에 비해 더 높은 안정성과 신뢰성을 제공한다는 장점이 있다. GCS는 Dijkstra 알고리즘을 기반으로 라우팅 테이블을 생성한 다음 각 UAV에 라우팅 테이블을 배포한다.

본 논문에서는 그래프 신경망 (GNN, Graph Neural Network)을 활용한 GCS 라우팅 방식을 개선하는 방안을 제안한다. GNN은 네트워크의 구조를 효과적으로 모델링하고, 동적 특성을 학습하여 라우팅 결정을 내릴 수 있는 강력한 도구로 주목받고 있다<sup>18-20)</sup>. 또한, 전이 학습 (Transfer Learning)을 활용하여 GNN 모델의 학습 속도와 정확도를 향상시켰다<sup>21)</sup>. 전이 학습을 통해 사전에 학습된 모델을 기반으로 새로운 네트워크 환경에 빠르게 적응하여 드론 군집 네트워크 환경에서 라우팅 테이블 생성 속도를 향상시키고, 적용 규모를 증가시키는 결과를 얻을 수 있다.

따라서 본 논문에서는 드론 네트워크에 사용되는 기존 중앙제어형 라우팅 프로토콜들의 한계를 극복하고, 대규모 군집 드론 운용에서 요구되는 저지연과 고용량 데이터 전송을 동시에 만족시키는 라우팅 방안을 제안한다.

본 논문의 구성은 다음과 같다. 제2장에서는 GNN 기반 라우팅 테이블 생성 방식을 소개하고, GNN의 그래프 입력 데이터 전처리와 학습 과정을 설명한다. 제3장에서는 중앙제어형 라우팅 알고리즘인 GCS Routing

기법에 대해 GNN을 통한 개선 방안을 기존 다익스트라 알고리즘에 기반한 기법과 성능을 비교하고, 전이 학습을 통해 GNN 학습 성능을 향상시키는 실험 결과를 제시한다<sup>22)</sup>. 제4장에서는 본 논문의 결론과 함께 향후 연구 방향을 논의한다.

## II. GNN 기반 라우팅 테이블

### 2.1 GNN 모델 개념 및 드론 네트워크 환경 적 합성

GNN은 그래프 구조 데이터를 학습하고 처리하기 위한 딥러닝 모델이다. 통신 네트워크는 그래프 구조를 가진 네트워크로, 본 논문에서 노드는 드론, 엣지는 드론 간의 통신 링크를 의미한다. FANET 등으로 대표되는 드론 네트워크는 높은 이동성과 동적 토폴로지를 가지며, 이러한 환경에서 GNN은 다음과 같은 이유로 적합하다.

첫째, GNN은 그림 1과 같이 네트워크에 속한 각 노드와 엣지의 속성을 특징 행렬(Feature Matrix)로 학습하여 네트워크 상태(예: 네트워크 출력, 지연 시간, 연결 상태 등)를 효과적으로 모델링할 수 있다. 또한, 빠른 추론 시간으로 네트워크 속성이 변화하더라도 저지연으로 대응이 가능하다는 장점이 있다.

둘째, GNN은 네트워크 토폴로지가 변화하더라도 인접 행렬(Adjacency Matrix)을 업데이트함으로써 새로운 환경에 적응할 수 있다. 인접 행렬은 그래프의 구조를 수학적으로 표현한 것으로, 노드 간 연결 상태를 나타낸다. 드론 네트워크 환경에서는 드론의 이동으로 인해 네트워크 토폴로지가 동적으로 변화하는데, GNN은 이러한 변화를 동적으로 처리할 수 있다.

셋째, GNN은 인접 노드뿐만 아니라 그래프 전체의 전역적 정보를 학습할 수 있어, 네트워크 전체를 고려하여 최적의 라우팅 경로를 생성할 수 있다. 이때, GNN이 “네트워크 전체를 고려한다”는 의미는, 단순히 인접 노




그림 1. GNN 및 인접 행렬과 특징행렬  
Fig. 1. GNN, Adjacency matrix and Feature matrix

드 간의 정보 교환에 의존하지 않고, 네트워크의 병목 상태, 혼잡도, 네트워크 출력 분배 등 전반적인 정보를 반영하여 라우팅 결정을 내릴 수 있다는 점을 나타낸다. 이는 드론 네트워크와 같은 동적이고 복잡한 네트워크 환경에서 특히 유리한 특성으로, 네트워크 효율성을 극대화하고 데이터 전송의 안정성을 높이는 데 기여할 수 있다.

드론 네트워크에서의 라우팅은 단순히 최단 경로 탐색을 넘어, 저지연성과 고출력을 동시에 고려해야 하는 복합적인 문제다. GNN은 이러한 다중 목표를 통합적으로 최적화할 수 있는 잠재력을 제공한다.

## 2.2 GNN 기반 라우팅 테이블 생성 프로세스

드론 네트워크에서 라우팅 테이블을 생성하기 위해 GNN은 다음과 같은 과정을 거친다.

### 2.2.1 그래프 입력 데이터 전처리

‘GNN을 통해 라우팅 테이블을 생성하기 위해서는 네트워크 그래프를 학습 가능한 데이터로 변환하는 전처리 과정이 필요하다. 각 드론은 GPS 위치, 남은 배터리, 처리 가능한 데이터, 네트워크 출력과 같은 상태 정보를 포함하는 특징 벡터로 표현된다. 드론 간 링크는 네트워크 출력, 지연 시간, 패킷 손실률과 같은 정보를 포함하여 정의된다.

### 2.2.2 GNN 학습

GNN은 학습 과정을 통해 그래프 데이터를 처리하는데, 이때의 핵심은 메시지 전달(Message Passing) 메커니즘이다. 메시지 전달 과정에서 각 노드는 이웃 노드와 정보를 교환하며, 이를 통해 자신의 상태 벡터를 업데이트한다. 이러한 과정이 반복되면 노드와 엣지는 네트워크 내 위치와 관계를 반영한 고차원 임베딩을 생성하게 된다. 이 임베딩은 네트워크의 현재 상태를 반영하며, 라우팅 경로를 예측하는 데 사용된다.

### 2.2.3 라우팅 테이블 생성

학습된 GNN 모델은 라우팅 테이블을 다음과 같은 방식으로 생성한다. 출발지 노드에서 목적지 노드로 데이터를 전송할 최적 경로를 예측한 후, 네트워크 출력과 지연 시간 같은 비용을 기준으로 경로를 선택한다. 그 결과, 각 노드에서 나머지 모든 노드에 대한 다음 홉 정보가 포함된 라우팅 테이블이 생성된다.

아래 그림 2는 전체적인 흐름을 나타낸 프레임워크로, UAV 배치와 이를 그래프로 나타내고 올바른 라우팅 테이블을 형성한 후 GNN으로 학습하는 전 과정을 그린다.

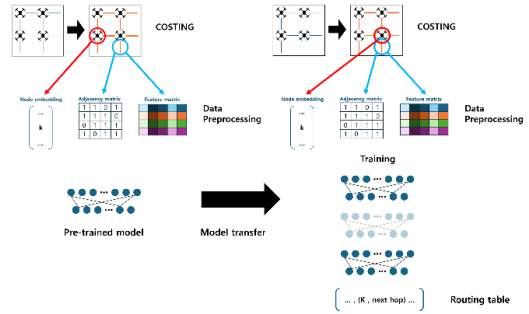


그림 2. GNN기반 라우팅 테이블 전체 프레임워크  
Fig. 2. Routing table based GNN Framework

## III. 성능평가

### 3.1 실험 목적

본 실험은 드론 네트워크 환경에서 GNN 기반 라우팅 방식과 기존의 다익스트라 알고리즘 기반 라우팅 방식을 비교하여, 두 방식의 효율성과 성능을 평가하는데 목적이 있다. 구체적으로, GNN 방식이 다익스트라 알고리즘과 비교하여 경로 예측의 정확성과 추론 속도에서 얼마나 우수한지 확인한다. 또한, 전이 학습을 도입하여 GNN의 학습 시간을 단축하고 성능을 개선하는 효과를 실증하고자 한다.

또한, GNN은 라우팅 테이블을 생성하는 추론 단계에서 다익스트라 보다 빠른 속도를 보였으나, 학습 시간이 오래 걸리는 단점이 있다. 이를 해결하기 위해 전이 학습을 적용하여 학습 시간을 단축하고 경로 예측의 정확도를 높이는 추가 실험도 진행한다. 전이 학습 적용의 효과를 입증하기 위해 학습 시간의 감소율과 다음 홉 예측의 정확성을 비교 분석한다.

### 3.2 실험 환경

실험은 Python의 NetworkX 라이브러리를 사용하여 네트워크 토폴로지를 시뮬레이션 하였다. 실험 환경에서 드론은 10×10 영역 내에 무작위로 배치되며, 임의의 개수의 노드로 구성된다. 각 노드는 가까운 순서대로 최대 4개의 노드와 연결되며, 연결 가능 범위는 유클리드 거리로 계산된다. 임계값 내에 연결 가능한 노드가 없을 경우, 가장 가까운 노드 하나와 강제로 연결하여 네트워크의 강건성을 유지하여 그림 3과 같은 토폴로지를 구성한다.

각 노드 간의 연결은 지연 시간(delay)과 네트워크 출력(throughput)을 주요 특성으로 가지며, 각각 20ms에서 50ms과 50Mbps에서 100Mbps 사이의 랜덤 값으로 설정된다. 다익스트라 알고리즘은 이 두 특성을 결합




그림 3. 노드 생성 및 그래프 연결 결과  
Fig. 3. Node creation and graph connection results

한 비용 함수를 사용하여 최적 경로를 계산하며, 이를 기준으로 초저지연 및 고용량 경로를 찾는 학습을 수행한다.

비용 함수는 다음과 같은 형태로 정의된다.

$$score = c_1 \cdot \frac{throughput}{throughput_{dijkstra}} + c_2 \cdot \frac{delay}{delay_{dijkstra}} \quad (1)$$

식(1)에서  $c_1$ 과  $c_2$ 는 throughput과 delay 간의 상대적 중요도를 조정하는 가중치이며,  $throughput_{dijkstra}$ 와  $delay_{dijkstra}$ 는 다익스트라 알고리즘을 통해 계산된 기준 값이다. 이 수식은 특정 경로의 throughput 유지 정도와 delay 감소 정도를 정량화하며, score 값이 가장 높은 경로가 초저지연 및 고용량을 동시에 만족하는 최적 경로로 평가된다.

다익스트라 알고리즘과 위 제약조건으로 계산된 경로를 기반으로 각 노드의 라우팅 테이블을 생성하고, 이를 GNN 학습의 지도 데이터(Label)로 사용하였다.

GNN 학습은 PyTorch Geometric(PyG)을 활용하여 수행되었다. 입력 데이터로는 대상이 되는 각 노드의 위치(x, y 좌표)와 연결 정보가 사용되었으며, 출력은 각 노드를 시작점으로 나머지 노드를 목적으로 하는 경로에 대해 다음 홉(Next Hop)을 예측하는 방식으로 설계되었다. 학습 방법은 주어진 그래프에 대하여 다익스트라 알고리즘과 제약조건을 만족하도록 모든 노드에 대해 나머지 노드에 대한 라우팅 테이블을 생성한 후, 이를 학습하는 방식으로 진행하였다.

### 3.3 실험 과정

첫 번째 실험에서는 GNN 방식과 다익스트라 알고리즘 기반 라우팅의 성능을 비교하였다. 이를 위해 25대 노드부터 400대 노드를 10\*10 환경에서 각각 두 방식의 라우팅 테이블 생성 속도를 측정하여 비교하였다.

그 결과, 표 1에서 25개의 노드로 구성된 소규모 네트워크에서는 다익스트라 알고리즘이 CPU 기반으로

표 1. 다익스트라와 GNN라우팅 테이블 생성시간

Table 1. Dijkstra and GNN based routing table creation time.

# of nodes	Dijkstra (s)	GNN (s)
25	0.0000316	0.0001112
49	0.0000614	0.0001143
81	0.0000975	0.0002044
121	0.0001593	0.0001541
169	0.0002165	0.0001605
225	0.0003062	0.0001848
400	0.0006153	0.0002751

더 빠르게 작동하여 GNN보다 우월한 성능을 보였다. 이는 다익스트라 알고리즘이 단일 프로세스 연산에 최적화되어 있고, 소규모 네트워크에서는 복잡한 병렬 연산의 이점이 드러나지 않기 때문이다.

반면, 100개 이상의 노드로 구성된 대규모 네트워크 환경에서는 GNN이 GPU 기반 병렬 연산의 이점을 통해 더 나은 효율성을 발휘하였다. 특히 400개의 노드 환경에서 GNN은 다익스트라 알고리즘 대비 약 2.2배 더 빠른 추론 속도를 보이며, 대규모 네트워크에서의 실시간 경로 계산 및 예측에 더 적합한 방법임을 증명하였다.

이러한 결과는 기존 알고리즘 기반 라우팅과 GNN 기반 라우팅의 근본적인 차이에서 기인한다. 다익스트라 알고리즘은 단일 최적 경로를 결정하는 데 최적화된 방식이며, 계산 복잡도는  $O(N \log M)$ 으로 노드 수가 증가할수록 연산 비용이 선형적으로 증가한다. 반면, GNN 기반 라우팅은 사전 학습된 모델을 활용하여 여러 경로의 비용을 동시에 추론하는 방식이므로, 일정 규모 이상의 네트워크에서는 GPU 기반 병렬 연산을 통해 다익스트라 알고리즘보다 빠른 속도로 최적 경로를 탐색할 수 있다.

또한, 본 연구에서는 학습 시간과 추론 시간을 분리하여 평가하였으며, Table 1에서 비교한 라우팅 속도는 학습을 완료한 후 추론 단계에서의 속도만 반영한 결과이다. GNN 기반 라우팅은 초기 학습이 필요하지만, 한번 학습이 완료되면 새로운 네트워크 토폴로지나 변화된 트래픽 조건에서도 빠르게 최적의 라우팅을 생성할 수 있는 장점을 가진다<sup>23)</sup>.

두 번째 실험에서는 GNN의 학습 속도와 성능향상 정도를 측정하기 위해 전이 학습을 적용하였다. 초기 실험에서는 49대 노드의 네트워크 환경에서 중심이 되는 노드를 기준으로 GNN 모델을 학습하여 사전 학습된 모델(pre-trained model)을 생성하였다. 이후, 주변 노드를 입력으로 하여 100회의 추가 학습(fine-tuning)을 수행하였다. 전이 학습을 적용한 경우와 처음부터

학습을 시작한 경우의 학습 시간과 경로 예측 정확성을 비교하여 전이 학습의 효과를 평가하였다. 이 때, 경로 예측 정확성은 GNN 모델로 생성된 결과와 다익스트라 알고리즘으로 생성된 결과의 유사도로 모델의 예측 정확성이다.

그림 4는 전이 학습을 적용하였을 때의 학습 속도와 성능이 향상된 결과를 보여준다. 여기서 노드 25와 노드 18은 GNN 학습에서 노드 임베딩에 의해 할당된 번호를 의미한다. 노드 임베딩은 노드의  $x, y$  좌표 값을 기준으로 정렬하여 번호를 매긴 방식으로, 값이 작은 노드부터 순서대로 번호를 부여한다. 노드 25와 노드 18은 물리적으로 서로 근접한 노드로 선정하였다.

첫 번째 그래프는 노드 25에서 사전 학습을 수행한 후, 노드 18에서 미세 조정을 진행한 결과를 보여준다. 이 과정에서 학습 속도가 빨라졌으며, 더 높은 정확도 상한에 도달하였다. 미세 조정 과정에서는 학습 초기 단계부터 성능이 빠르게 개선되었고, 최종적으로 더 높은 정확도를 달성하였다. 이는 사전 학습을 통해 GNN이 네트워크의 구조적 특성을 잘 학습하였고, 새로운 환경에서도 빠르게 적응할 수 있었음을 보여준다.

두 번째 그래프는 노드 18에서 사전 학습을 수행하고, 같은 노드에서 미세 조정을 진행한 결과를 나타낸다. 이 경우에도 미세 조정을 통해 학습 속도가 빨라졌

으며, 최종적으로 더 높은 성능을 기록하였다. 이러한 결과는 전이 학습이 새로운 노드나 환경에서 빠르게 적응하고 성능을 높이는 데 효과적인 방법임을 증명한다. 특히 노드 25에서의 사전 학습이 근접한 노드인 노드 18에서의 학습 효율과 최종 성능을 크게 향상시켰음을 보여준다.

이는 사전 학습 모델 생성에 사용된 GNN 모델인 GCN(Graph Convolution Network)의 특성으로 인해 전이 학습 모델에서 정확도 개선이 이루어졌다. GCN은 한 번의 학습이 수행될 때마다 이웃한 노드의 특성을 집합하여 학습하는 구조를 가진다. 이러한 특성을 바탕으로 노드 25와 노드 18은 인접한 노드이므로, 노드 25를 학습한 뒤 노드 18을 추가 학습하면 한 홉을 더 깊이 있게 학습할 수 있기 때문에 사전 학습한 모델이 보다 풍부한 정보를 가진 초기 표현을 바탕으로 학습할 수 있어 성능이 향상되었다.

## IV. 결 론

본 논문에서는 UAV 네트워크에서 발생하는 라우팅 문제를 해결하기 위해 GNN 기반 라우팅 방식을 제안하였다. GNN은 네트워크의 그래프 구조를 활용하여 각 노드 간의 최적 경로를 예측하고, 지연 시간과 네트워크 출력을 고려하여 다중 목표 최적화를 가능하게 한다. 특히, 전이 학습을 적용하여 GNN 모델의 학습 시간을 단축하고 새로운 환경에 빠르게 적응할 수 있도록 하였다.

실험 결과, GNN은 대규모 네트워크 환경에서 다익스트라 알고리즘 대비 더 빠른 추론 속도를 보였으며, 전이 학습을 통해 초기 학습 시간 단축과 경로 예측 정확도를 효과적으로 개선하였다. 이러한 결과는 GNN 기반 라우팅 방식이 다중 UAV 네트워크와 같은 동적이고 복잡한 환경에서 저지연성과 고용량 데이터 전송을 동시에 만족하는 데 유용함을 입증한다.

향후 연구에서는 UAV 네트워크에서 발생할 수 있는 실시간 장애 복구와 에너지 효율성 문제를 해결하기 위해 GNN 모델의 확장성과 적응성을 더욱 개선할 필요가 있다. 또한, 실제 네트워크 환경에서의 실시간 라우팅 성능 평가를 통해 본 연구에서 제안한 방식의 실용성을 검증하는 것이 필요하다.

## References

- [1] W. Chen, J. Liu, H. Guo, and N. Kato, "Toward robust and intelligent drone swarm:

그림 4. 전이 학습을 통한 정확성과 학습속도증가  
Fig. 4. Increased accuracy and learning speed through transfer learning

- Challenges and future directions,” in *IEEE Netw.*, vol. 34, no. 4, pp. 278-283, Jul.-Aug. 2020.  
(<https://doi.org/10.1109/MNET.001.1900521>)
- [2] Y. Zhou, B. Rao, and W. Wang, “UAV swarm intelligence: Recent advances and future trends,” *IEEE Access*, vol. 8, pp. 183856-183878, 2020.  
(<https://doi.org/10.1109/ACCESS.2020.3028865>)
- [3] G. Asaamoning, P. Mendes, D. Rosário, and E. Cerqueira, “Drone swarms as networked control systems by integration of networking and computing,” *Sensors*, vol. 21, no. 8, p. 2642, 2021.  
(<https://doi.org/10.3390/s21082642>)
- [4] W. Jung, C. Park, S. Lee, and H. Kim, “Enhancing UAV swarm tactics with edge AI: Adaptive decision making in changing environments,” *Drones*, vol. 8, no. 10, p. 582, 2024.  
(<https://doi.org/10.3390/drones8100582>)
- [5] A. Restas, “Drone applications for supporting disaster management,” *World J. Eng. and Technol.*, vol. 3, no. 3, pp. 316-321, 2015.  
(<http://doi.org/10.4236/wjet.2015.33C047>)
- [6] S. Ahirwar, et al., “Application of drone in agriculture,” *Int. J. Current Microbiology and Applied Sci.*, vol. 8, no. 1, pp. 2500-2505, 2019.  
(<https://doi.org/10.20546/ijcmas.2019.801.264>)
- [7] H. W. Choi, H. J. Kim, S. K. Kim, and W. S. Na, “An overview of drone applications in the construction industry,” *Drones*, vol. 7, no. 8, p. 515, 2023.  
(<https://doi.org/10.3390/drones7080515>)
- [8] D. Cvitanić, “Drone applications in transportation,” *2020 5th Int. Conf. Smart and Sustainable Technol. (SpliTech)*, pp. 1-4, Split, Croatia, 2020.  
(<https://doi.org/10.23919/SpliTech49282.2020.9243807>)
- [9] H. Shim, H. Joo, K. Kim, S. Park, and H. Kim, “Provisioning high-precision clock synchronization between UAVs for low latency networks,” *IEEE Access*, vol. 12, pp. 190025-190038, 2024.  
(<https://doi.org/10.1109/ACCESS.2024.3516856>)
- [10] A. Chriki, H. Touati, H. Snoussi, and F. Kamoun, “FANET: Communication, mobility models and security issues,” *Computer Networks*, vol. 163, no. 106877, 2019.  
(<https://doi.org/10.1016/j.comnet.2019.106877>)
- [11] K. Kumari, B. Sah, and S. Maakar, “A survey: Different mobility model for FANET,” *Int. J. Advanced Research in Computer Sci. and Software Eng.*, vol. 5, no. 6, 2015.
- [12] M. G. Zapata and N. Asokan, “Securing ad hoc routing protocols,” in *Proc. 1st ACM Wkshp. WISE '02*, pp. 1-10, New York, NY, USA, 2002.  
(<https://doi.org/10.1145/570681.570682>)
- [13] E. Kulla, et al., “Investigation of AODV throughput considering RREQ, RREP and RERR packets,” *2013 IEEE 27th Int. Conf. AINA*, pp. 169-174, Barcelona, Spain, 2013.  
(<https://doi.org/10.1109/AINA.2013.135>)
- [14] M. Das, B. K. Panda, and B. Sahu, “Analysis of effect of mobility on performance of AODV in mobile ad hoc network,” *2012 Int. Conf. Computer Commun. and Inf.*, Coimbatore, India, 2012.  
(<https://doi.org/10.1109/ICCCI.2012.6158871>)
- [15] S. Zafar, H. Tariq, and K. Manzoor, “Throughput and delay analysis of AODV, DSDV and DSR routing protocols in mobile ad hoc networks,” *Int. J. Computer Netw. and Appl. (IJCNA)*, vol. 3, no. 2, pp. 1-7, 2016.
- [16] A. Lanjewar and N. Gupta, “Optimizing cost, delay, packet loss and network load in AODV routing protocol,” *arXiv preprint arXiv:1304.6486*, 2013.  
(<https://doi.org/10.48550/arXiv.1304.6486>)
- [17] J. Lee, et al., “Constructing a reliable and fast recoverable network for drones,” *2016 IEEE ICC*, pp. 1-6, Kuala Lumpur, Malaysia, 2016.  
(<https://doi.org/10.1109/ICC.2016.7511317>)
- [18] A. Singh, S. Sharma, A. Gumaste, and J. Wang, “Grafnet: Using graph neural networks



to create table-less routers,” in *IEEE Trans. Netw. Sci. and Eng.*, vol. 9, no. 2, pp. 740-754, Mar.-Apr. 2022.

(<https://doi.org/10.1109/TNSE.2021.3132070>)

- [19] H. G. Kim, S. Lange, D. Y. Lee, J. H. Yoo, and J. W. K. Hong, “A Study on the network management using GNN,” in *Proc. Symp. KICS*, pp. 406-407, Gangwon, Korea, 2020.
- [20] O. Hope and E. Yoneki, “GDDR: GNN-based data-driven routing,” *2021 IEEE 41st ICDCS*, pp. 517-527, DC, USA, 2021.  
(<https://doi.org/10.1109/ICDCS51616.2021.00056>)
- [21] E. W. Dijkstra, “A note on two problems in connexion with graphs,” *Numerische Mathematik*, vol.1, no 1 pp. 269-271, 1959.  
(<https://doi.org/10.1007/BF01386390>)
- [22] K. Rusek, et al., “Unveiling the potential of graph neural networks for network modeling and optimization in SDN,” in *Proc. 2019 ACM Symp. SDN Research*, 2019.  
(<https://doi.org/10.1145/3314148.3314357>)

#### 이 승 현 (Seunghyeon Lee)



2024년 2월 : 고려대학교 전기  
전자공학부 졸업  
2024년 3월~현재 : 고려대학교  
전기전자공학과 석사과정  
<관심분야> UAV 네트워크,  
소프트웨어 정의 네트워크  
[ORCID:0009-0009-8676-3909]

#### 박 창 민 (Changmin Park)



2021년 2월 : 광운대학교 전자  
공학과 졸업  
2021년 3월~현재 : 고려대학교  
전기전자공학과 석박사 통합  
과정  
<관심분야> 강화 학습, 군집  
드론, 자율 주행

[ORCID:0009-0000-0554-7740]

#### 김 황 남 (Hwangnam Kim)



1992년 2월 : 부산대학교 컴퓨  
터공학과 (공학사)  
1994년 2월 : 서울대학교 컴퓨  
터공학과 (공학석사)  
2004년 2월 : 미국 Urbana-  
Champaign 소재 Illinois  
주립대학 컴퓨터공학과 (공  
학박사)

1994년~1999년 : LG전자 주임연구원

2004년~2005년 : 미국 Urbana-Champaign 소재  
Illinois 주립 대학 Post Doctorate Fellow

2005년~2006년 : 삼성전자 책임연구원

2012년~2012년 : 미국 LA 소재 California 주립대학  
방문연구원

2006~현재 : 고려대학교 전기전자공학과 교수

<관심분야> 모바일컴퓨팅, 블록체인플랫폼, 무인이  
동체, 군집 지능

[ORCID:0000-0003-4322-8518]