

UAV 네트워크 라우팅 최적화를 위한 전이학습 기반 SDN 프레임워크 연구

이승현, 유경현, 정우용, 박창민, 김황남

고려대학교 전기전자공학과

{lsh981225, seven1705, jy17347, minpark0120, hnkim}@korea.ac.kr

Transfer Learning-Based SDN Framework for Routing Optimization in UAV Networks

Seunghyeon Lee, Kyeonghyun Yoo, WooYong Jung, Changmin Park, Hwangnam Kim

School of Electrical Engineering, Korea University

요약

무선 드론 네트워크는 LOS 확보, 노드의 이동성 등의 네트워크로서의 장점을 갖췄으나 무선 연결의 높은 지연과 불안정한 연결성으로 인해 주요 네트워크로서의 쓰임을 다하지 못하고 있다. 이를 극복하기 위해 지연을 최소화하는 것을 목적으로 하는 라우팅 알고리즘을 적용한 SDN인 무인 비행체 소프트웨어 정의 네트워크(Unmanned Aircraft Software Defined Network, UASDN)를 제안한다. 이를 위해 그래프를 기반으로 경로를 분석하는 전이 학습(Transfer Learning) 모델을 준비한다. 이를 Fine-Tuning한 모델을 사용하여 탐색한 경로를 기존 알고리즘인 OSPF와 비교해 지연 개선을 비교하며 모델을 적용하지 않고 무작위 탐색을 한 경우와 시간적 효율성을 검토한다.

I. 서론

무인항공기(Unmanned Aerial Vehicle, UAV)를 이용한 무인기 통신 네트워크(Unmanned Aircraft Area Network, UAAN) 구축 기술은 지상과 공중을 긴밀하게 연결하고, 사용자와 기지국 간의 가시선(Line of Sight, LOS)을 확보하고, 트래픽 변화에 유연하게 적응할 수 있는 이동성을 제공한다. 이는 무선 연결의 특성으로 UAV가 통신재난지역 네트워크 복구, 6G 통신의 중층 네트워크 구성[1] 등 다양한 응용 분야에서 유용하게 활용될 수 있게 한다. 그러나 유선 네트워크와 달리 무선 네트워크는 더 높은 지연(Delay)과 지터(Jitter)를 겪으며, 대역폭의 변화가 잦기 때문에 라우팅 과정을 복잡하게 만들기 때문에 네트워크 성능과 안정성을 유지하기 위해 지연과 지터를 줄이며 대역폭을 유지하는 경로를 빠르게 찾을 필요가 있다.[2],[3]

이 문제를 해결하기 위해, 본 논문에서는 UAV 기반 네트워크에 적합한 UASDN을 제안한다. 이 SDN은 대역폭을 기준으로 하는 라우팅 프로토콜인 OSPF와 달리 전송 지연(Transmission Delay)를 고려하여 라우팅한다. 또한, 전이 학습(Transfer Learning)을 활용하여 라우팅 결정을 최적화하며, 실시간으로 빠르게 변화하는 무선 네트워크의 상태에 맞춰 동적 라우팅을 할 수 있게 한다.

본 논문은 전송 지연을 고려해 패킷 전달 속도와 SDN 컨트롤러의 경로 계산 속도를 향상시켜, UAV 네트워크의 본질적인 단점을 극복하고 전반적인 네트워크 성능을 개선하는 데 기여할 것이다.

II. 전이학습 기반 SDN 프레임워크

본 절에서는 다음 목표를 기반으로 UAV 네트워크에서 라우팅을 최적화하기 위한 전이학습 기반 SDN 프레임워크를 제안한다.

첫째, OSPF를 이용한 경로와 UASDN을 이용한 경로를 비교하여 지연의 개선을 확인한다. 이 때, UASDN의 경로는 노드 간 간선의 지연 값을 최소화 하고 대역폭의 손실을 방지하기 위해 기존 OSPF 경로의 최소 대역폭 이상이 되도록 한다.


둘째, SDN이 받은 링크 상태 정보를 Transfer Learning을 이용한 라우팅 속도와 상기 조건과 일치하는 경로 탐색의 속도를 비교하여 Transfer Learning의 시간적 효율성을 입증한다.

2.1 드론 네트워크 구성

통신장에 복구용 드론 네트워크와 같이 소규모부터 UAM 통신망 등 대규모 네트워크까지 다루는 UASDN을 테스트하기 위해 네트워크에 참여하는 UAV의 개수는 9,49,100으로 다양화한다. 보다 현실적인 네트워크 지표를 반영하기 위해 iperf를 사용해[4] Wi-Fi (802.11 ac)의 네트워크 성능을 측정하였고 이 값과 이론상의 값[5] 실험에 대역폭, 지연, 지터를 반영하였다.

2.2 전이 학습 모델 훈련 및 적용

3X3부터 10X10까지의 그래프를 10개에서 50개를 사용하여 총 600개의 그래프를 학습하여 Routing table을 출력하는 Pre-trained model을 구성한다. GNN(Graph Neural Network)을 사용하여 3X3의 그래프에서 경로를 추출하였고 4X4부터 추가된 노드를 탐색하기 위해 [그림 1]의 붉은 영역과 같이 GCN(Graph Convolution Network)을 추가하는 Fine-Tuning을 실행한다. CNN과 비슷하게 GCN은 늘어난 그래프의 범위를 탐색하기 위한 역할을 하는 네트워크 레이어로써 사용한다.



[그림 1] 전이 학습을 이용한 UASDN

Require: Graph sizes $S = \{3, 4, 5, 6, 7, 8, 9, 10\}$, Cost range $C = (n, m)$

- 1: **Training Phase**
- 2: **for all size $s \in S$ do**
- 3: Create grid graph $G_s = (V_s, E_s)$ of size $s \times s$
- 4: **for all edge $(u, v) \in E_s$ do**
- 5: Assign random cost $c_{uv} \in C$ to edge (u, v)
- 6: **end for**
- 7: Convert G_s to node features X_s and edge indices E_s
- 8: Store (X_s, E_s, C_s) in training dataset
- 9: **end for**
- 10: Train GCN model on the training dataset to output routing tables
- 11: **Transfer Learning Phase**
- 12: Given a new graph $G_{new} = (V_{new}, E_{new})$ with costs C_{new} , convert to node features X_{new} and edge indices E_{new}
- 13: Fine-tune the pre-trained GCN model on the new graph data $(X_{new}, E_{new}, C_{new})$
- 14: **Fine-Tuning Procedure**
- 15: **for each epoch e do**
- 16: **for each batch (X, E, C) in new dataset do**
- 17: Zero the gradients
- 18: Forward pass through GCN1: $H_1 = ReLU(GCN1(X, E))$
- 19: Compute edge embeddings: $H_e = edge_mlp(C)$
- 20: Combine node features with edge embeddings: $H = H_1 + H_e$
- 21: Forward pass through GCN2: $O = GCN2(H, E)$
- 22: Compute loss: $loss = CrossEntropyLoss(O, labels)$
- 23: Backpropagate loss
- 24: Update model parameters using optimizer
- 25: **end for**
- 26: **end for**
- 27: **Output Phase**
- 28: Evaluate the fine-tuned GCN model on the new graph to generate the routing table

[그림 2] 주어진 그래프에서 라우팅 테이블을 생성하는 Fine-Tuning

2.3 네트워크 지연 개선도 평가


[그림 3]에서는 네트워크 참여 노드가 각각 9, 49, 100일 때 각 노드의 조합마다 OSPF의 경로에 비해 지연이 얼마나 개선되었는지를 10회의 반복을 통해 확인하였다. 아래 그래프는 OSPF의 경로와 비교했을 때의 평균 개선도, 최고 개선도를 비교하였다. 이미 지연 값이 최소라던가 시작 노드와 종료 노드가 직접 연결된 경우는 더 개선할 점이 없어 지연 값의 개선도가 0이므로 최저 개선도는 표기하지 않았다. 참여 노드가 많아질수록 평균 개선도는 작아지고, 최고 개선도는 커지는 경향성을 확인하였다. 이는 노드가 많아질수록 이미 최적화된 경로나 직접적으로 연결되는 노드가 증가하여 개선도가 0인 조합이 늘어남에 따른 결과이다.

2.4 전이 학습 모델의 시간적 효율성 입증

알고리즘에서 볼 수 있듯이 대역폭을 제한하고 지연을 최소화하는 경로를 찾는 과정은 주어진 시작과 종료 노드의 조합에 따라 OSPF 경로를 한번 계산하고 그에 따라 일정 대역폭 미만의 간선을 가지치기하는 과정을 포함한다. 참여 노드가 많아질수록 가지치기를 한 이후에도 탐색 경로가 많아 경로 탐색에 걸리는 시간이 전이 학습을 적용한 것보다 더 큰 차이가 나는 것을 확인할 수 있다.

III. 결론

본 논문에서는 네트워크 지연 감소를 초점에 맞춘 그래프 기반 라우팅 모델을 Fine-Tuning 하여 전이 학습을 통해 라우팅을 하는 UASDN을 제안하였다. 제한한 UASDN의 라우팅 경로와 가장 보편적이라 할 수 있는 라우팅 방식인 OSPF와의 경로 비교를 통해 네트워크 지연 개선도를 평가하였다. 또한, 네트워크 규모를 달리해가면서 소규모 네트워크보다 대규모 네트워크에서 효율적으로 적용할 수 있음을 보였다. 그리고 UASDN과 무작위 경로 탐색을 비교해 시간적으로 효율적임을 확인할 수 있었다. 이 SDN 기법은 향후 UAV 네트워크에서 기계 간에 보다 더 빠르고 정확하게 데이터를 교환하게 하고 변화하는 환경에 빠르게 반응하여 통신망의 안정성을 향상시킬 것으로 기대된다.



[그림 3] 참여노드(N) 수에 따른 Delay 개선 값의 최고, 평균 효율

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터지원사업의 연구결과로 수행되었음 (IITP-2024-2021-0-01835) 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2020R1A2C1012389).

참고 문헌

- [1] D. Mishra, A. M. Vegni, V. Loscrí and E. Natalizio, "Drone Networking in the 6G Era: A Technology Overview," in IEEE Communications Standards Magazine, vol. 5, no. 4, pp. 88-95, December 2021
- [2] W. Xu, H. A. Omar, W. Zhuang and X. S. Shen, "Delay Analysis of In-Vehicle Internet Access Via On-Road WiFi Access Points," in IEEE Access, vol. 5, pp. 2736-2746, 2017
- [3] H. Joo, S. Lee, S. Lee and H. Kim, "Optimizing Time-Sensitive Software-Defined Wireless Networks With Reinforcement Learning," in IEEE Access, vol. 10, pp. 119496-119505
- [4] S. S. Kolahi, S. Narayan, D. D. T. Nguyen and Y. Sunarto, "Performance Monitoring of Various Network Traffic Generators," 2011 UkSim 13th International Conference on Computer Modelling and Simulation, Cambridge, UK, 2011, pp. 501-506
- [5] Huawei Technologies Co., Ltd. *HCIA-WLAN V2.0 Training Materials*. Huawei Technologies Co., Ltd, 2017.