

# 무선 네트워크 환경에서 UAV-BS를 활용한

## 딥러닝 기반의 콘텐츠 캐싱 프레임워크

강석원<sup>0</sup>, 홍충선\*  
 경희대학교 컴퓨터공학과  
 {dudntdud, cshong}@khu.ac.kr

### Deep Learning based Content Caching

### Framework Structure Using UAV-BS in Wireless Network

SeokWon Kang<sup>0</sup>, Choong Seon Hong\*

Department of Computer Science and Engineering, Kyung Hee University

#### 요약

스마트 디바이스 수의 증가와 함께 데이터 트래픽 또한 급증하고 있다. 이에 따라 스마트 디바이스들의 연결에 필요한 기지국의 수요가 증가하고 있으나 갑작스럽게 인구가 증가하는 콘서트장, 놀이공원과 같은 장소마다 기지국을 설치하는 것은 경제적인 해결 방안이 아니다. 이러한 상황에서 설치가 쉽고 보다 저렴한 UAV (Unmanned Air Vehicle)는 좋은 해결방안이 될 수 있다. 본 논문에서는 백본 네트워크로 향하는 데이터 트래픽의 부하를 줄이고 사용자에게 더욱 빠른 시간내에 서비스를 제공하기 위하여 스마트 디바이스를 거리에 따라 K-means 알고리즘을 활용해 클러스터링하고, 서비스 사용 트래픽 데이터셋을 딥러닝의 Long Short Term Memory를 통하여 분석하고 가장 수요가 높은 콘텐츠를 UAV에 캐싱하는 프레임워크를 제안한다. 이는 기존의 콘텐츠 서버에서 서비스를 제공받는 상황보다 더욱 빠른 서비스 응답 시간을 제공 할 수 있으며, 높은 hit rate를 제공 할 수 있음을 보인다.

#### 1. 서론

Cisco 전망에 따르면 2020년까지 인터넷에 연결된 스마트 디바이스가 500억개까지 증가할 것으로 예측하고 있다[1]. 이렇게 급증하는 스마트 디바이스에 따라 온라인 비디오 스트리밍과 같은 데이터 트래픽 또한 함께 증가하고 있으며 스마트 디바이스의 서비스 요청과 데이터를 처리하기 위해 더 많은 기지국 혹은 스몰셀 기지국 설치 필요한 상황이다. 그러나 놀이공원, 콘서트장과 같이 갑작스럽게 데이터 사용자가 증가하는 곳마다 기지국을 새로 설치하는 것은 시간과 비용적으로 한계가 있다. 여기서 UAV (Unmanned Air Vehicle)는 설치가 간편하고 기존의 기지국을 설치하는 것 보다 저렴하기 때문에 경제적인 해결방안이 될 수 있다.

현재 UAV는 최적 배치 문제, 에너지 효율 문제 등 다양한 분야에서 연구가 진행되고 있으나, UAV의 기지국에 콘텐츠를 캐싱하는 연구는 아직까지 많지 않다. 그렇기 때문에 본 논문에서는 UAV-BS에 콘텐츠를 캐싱하여 연결된 사용자들에게 기존의 콘텐츠 서버에서 제공 하는 것 보다 더욱 빠른 시간 내에 서비스를 제공할 수 있는 프레임워크를 제안하고자 한다.

이에 따라 본 논문의 2장에서 UAV의 배치문제와 관련된 연구들을 살펴보고 3장에서는 첫째로 UAV를 기지국으로 활용하기 위해 K-means 알고리즘을 통하여 UAV의 수에 따라 사용자의 구역을 클러스터링하고, 각 UAV에 사용자의 서비스 사용 트래픽 정보 데이터셋[2]을 딥러닝을 통해 분석하여 수요가 많은 콘텐츠를 UAV-BS에 캐싱하여 사용자의 서비스 요청을 빠른 시간 내에 처리하는 프레임워크를 제안한다. 4장에서는 본 논문에서 제안한 프레임워크를 통해 콘텐츠를 예측하고, 캐싱하여 기존의 콘텐츠 서버에서 서비스를 제공받는 방법과의 서비스 처리 속도를 비교

하기 위한 시뮬레이션을 진행하며, 5장에서 결론 및 향후 방안을 제시한다.

#### 2. 관련 연구

논문 [3], [4]은 강화학습 Q-learning을 활용하여 UAV를 배치하는 문제를 해결하고자 하였다. 하지만 단순히 스마트 디바이스의 연결을 위한 기지국으로 활용하고 있으며, 논문 [5]는 분산된 UAV 포트를 관리하고 각 UAV의 에너지 소비를 최소화하기 위한 알고리즘 제안한다. 현재 UAV 배치 문제와 관련하여 다양한 연구들이 진행되고 있으나 UAV-BS와 관련하여 콘텐츠 캐싱에 대한 연구는 부족한 상황이다. 본 논문에서는 UAV를 K-means 알고리즘을 통해 클러스터링하고, 연결된 사용자의 트래픽을 딥러닝을 통해 분석하여 가장 적합한 콘텐츠를 캐싱하며, 이러한 시스템을 모듈화한 프레임워크를 제안하고자 한다.

#### 3. 제안사항

그림 1은 본 논문에서 제안하는 시스템 구성도이며, 다음과 같

이 논문은 2019년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임 (No.2015-0-00557, IoT 기기의 물리적 속성, 관계, 역할 기반 Resilient/Fault-Tolerant 자율 네트워크 기술 연구) 또한 이 논문은 2019년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2019-0-01287, 분산 엣지를 위한 진화형 딥러닝 모델생성 플랫폼).

\*Dr. CS Hong is the corresponding author

이 콘텐츠 서버, UAV 기반 기지국 그리고 유저의 스마트 디바이스 (UE) 로 나눈다. 여기서 UE는  $U = \{1, 2, 3, \dots, u\}$  으로 나타낼 수 있으며, 모든 비디오 콘텐츠는  $W = \{1, 2, 3, \dots, w\}$  으로, UAV-BS는  $B = \{1, 2, 3, \dots, b\}$  로 나타낸다.

### 3.1 UAV Allocation and Network Model

본 논문에서 UE를 클러스터링하고 각 UAV를 구역별로 할당하기 위해 K-means 클러스터링을 활용했다. 이렇게 클러스터링된 각 구역의 중심  $c_u$ 에 UAV-BS  $b$ 가 위치한다. 그림 2는 UAV-BS 할당을 위해 필요한 변수를 나타내며,  $d$ 는 UAV-BS와 UE간의 거리,  $R$ 은 UAV의 커버리지 거리,  $H$ 는 UAV의 높이이며  $u$ 는 UAV의  $(x, y)$  좌표이다. 또한  $u$ 와 UE 사이의 거리  $r_{ij}$ 는 다음과 같이 나타낼 수 있다.

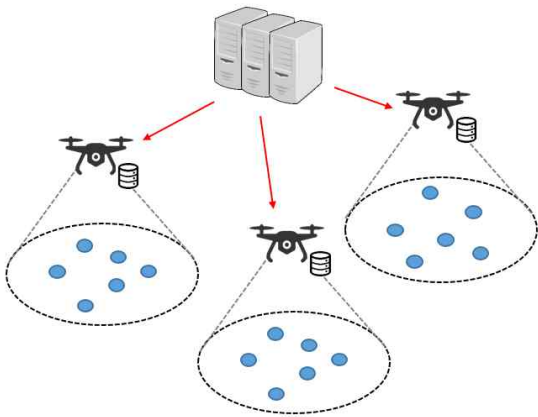


그림 1. 시스템 모델

$$r_{ij} = \| U - u_{ij} \| = \sqrt{(x - x_{ij})^2 + (y - y_{ij})^2}, \quad (1)$$

또한 [6]에 따라, UE의 Line of sight (LoS) 및 Non-Line of Sight (NLoS)의 확률을 구하기 위해 본 논문은 Air-To-Ground (ATG) 채널 모델을 따르며 다음과 같이 나타낸다.

$$P_{LoS}(H, r_i) = \frac{1}{1 + a \exp(-b(\frac{180}{\pi} \tan^{-1}(\frac{H}{r_{ij}}) - a))}, \quad (2)$$

$$P_{NLoS}(H, r_i) = 1 - P_{LoS}(H, r_i), \quad (3)$$

$$PL(dB) = 20 \log_{10}(\frac{4\pi d f}{c}) + P_{LoS}(H, r_i) + P_{NLoS}(H, r_i), \quad (4)$$

신호 감쇄 효과를 계산하기 위하여 UAV-BS와 UE 사이의 거리인  $d$ 를 인자로 사용하였으며, 여기서  $c$ 는 빛의 속도를 의미한다. 식 (1), (2), (3)과 (4)를 사용하여 신호 대비 잡음비 (SNR)과 신호 세기를 다음과 같이 나타낼 수 있다.

$$P_r(d) = P_t + G_t - PL - G_r - L, \quad (5)$$

$$SNR = \frac{\text{signal power}}{\text{noise power}} = \frac{P_r(d)}{N}, \quad (6)$$

Shannon-Hartley 공식에 따라, UAV-BS  $b$ 와 UE  $u$  사이의 데이터 전송속도는 다음과 같이 나타낼 수 있다.

$$c_{ij}^{UAV} = B_{UAV} \log_2(1 + SNR_{ij}^{UAV}), \quad (7)$$

마찬가지로 UAV-BS  $b$ 와 콘텐츠 서버  $i$  사이의 데이터 전송 속도는 다음과 같이 나타낼 수 있다.

$$t_{bi}^{Server} = B_{Server} \log_2(1 + SNR_{bi}^{Server}), \quad (8)$$

$$t_{bu}^{UAV} = \frac{a_{bu}}{c_{bu}^{UAV}}, \quad t_{ij}^{Server} = \frac{a_{bu}}{c_{bu}^{Server}} \quad (9), (10)$$

여기서  $a_{bu}$ 는 UAV-BS와 UE 사이의 전송되는 콘텐츠 크기를 나타낸다. 식 (7), (8), (9)와 (10)을 통하여 각 UE가 콘텐츠를 받기 위해 걸리는 다운로드 딜레이는 다음과 같이 나타낼 수 있다.

$$t_u^w = t_{ub}^w + t_{bi}^w(1 - x_b^w) \quad (11)$$




그림 2. UAV-BS 할당 모델

$x_b^w \in \{0, 1\}$ 은 만약 UE  $w$ 가 요청한 콘텐츠가 해당 UAV-BS  $b$ 에 존재할 경우에  $x_b^w = 1$ 이며 그렇지 않을 경우 0으로 나타낸다.

### 3.2 System Module and Problem Formulation

각 UE  $w$ 가 콘텐츠를 제공받는 딜레이를 최소화시키기 위한 공식은 다음과 같이 나타낼 수 있다.

$$\begin{aligned} \min \sum_{u=1}^U \sum_{w=1}^W t_u^w \\ \text{s.t.} \quad \sum_{w=1}^W x_b^w \leq s_b, \quad S = \sum_{b=1}^B S_b, \\ x_b^w \in \{0, 1\} \end{aligned}$$

여기서 첫 번째 제한사항은 UAV-BS의 캐싱 수용량에 대한 것이며, 두 번째는 모든 UAV-BS의 캐싱 수용량이다. 위의 공식에서  $x_b^w \in \{0, 1\}$ 은 콘텐츠  $w$ 의 popularity에 기반한다.

그림 3은 본 논문에서 제안하는 UAV-BS와 콘텐츠 서버의 모듈에 대한 설명이다. Service Routing Module은 현재 UAV-BS에 캐싱되어 있는 콘텐츠의 정보를 담고 있으며, 사용자가 요청한 콘텐츠를 UAV 내에서 제공이 가능할 경우, 트래픽을 Service Provider Module에서 제공하는 해당 서비스에 넘기며 제공이 가능하지 않을 경우에는 콘텐츠 서버로 해당 서비스를 요청한다. 이때 사용자가 요청한 데이터 수요를 예측하기 위해 해당 콘텐츠 IP, 요청한 사용자의 IP, 콘텐츠의 크기 및 타임 스탬프 정보를 Traffic Database에 저장하며, UAV-BS는 주기적으로 콘텐츠 서버에 데이터를 전송한다. 여기서 Service Provider Module은 Docker를 활용하여 만들었으며, 콘텐츠 서버가 캐싱을 위해 콘텐츠를 보내면 해당 콘텐츠를 Service Provider Module 위에 배치한다.

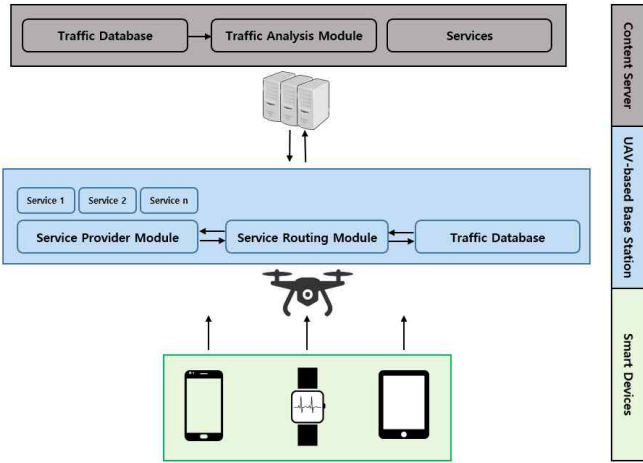


그림 3. 시스템 모듈 도면

컨텐츠 서버는 일정 주기마다 각 UAV-BS의 Traffic Database 정보를 받아 데이터셋을 구축하며, Traffic Analysis Module은 이렇게 모인 데이터셋을 LSTM을 통해 분석, 예측하고 각 UAV-BS에 가장 수요가 높은 컨텐츠를 전송한다.

#### 4. 성능평가

본 논문에서 제안된 프레임워크의 성능을 평가하기 위해 기존에 컨텐츠 서버에서 사용자들이 컨텐츠를 제공받은 상황과 랜덤으로 캐싱된 상황, 그리고 컨텐츠의 크기의 순서대로 캐싱된 Round Robin 방식과 비교한다. 데이터셋은 [2]를 사용하였으며, UE는 Poisson Point Process에 따라 랜덤하게 위치를 배정하였다. K-means 클러스터링에 따라 그림 4와 같이 UAV-BS가 위치한다.




그림 4. K-means 클러스터링을 통한 UAV 배치

또한 데이터셋을 통해 예측한 시간대별 컨텐츠 사용률과 실제 데이터의 차이는 그림 5와 같다. 또한 각 알고리즘별 총 컨텐츠 응답 시간은 그림 6과 같다.

#### 5. 결론

본 논문에서는 UAV-BS 기반 컨텐츠 캐싱을 위한 딥러닝을 활용한 프레임워크를 제안하였다. 각 디바이스는 거리에 따라 클러스터링되며 LSTM을 통해 컨텐츠 Popularity를 예측하고 가장 수요가 많은 컨텐츠를 캐싱하였으며 이를 통해 컨텐츠를 제공받는 시간을 줄임으로서 사용자의 QoE를 증가시켰다. 그러나 본 논문은




그림 5. LSTM을 활용한 컨텐츠 사용 예측 그래프

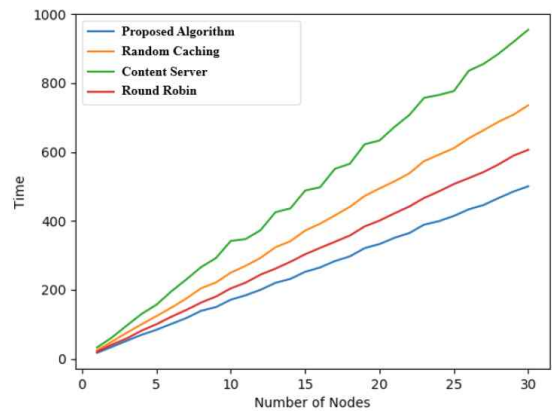


그림 6. 각 알고리즘별 총 컨텐츠 응답 시간

현재 UAV의 이동성과 에너지 효율이 고려되어있지 않은 상황이며 향후 제안한 프레임워크에 적용할 예정이다.

#### 6. 참고문헌

- [1] P. Zhang, J. K. Liu, F. R. Yu, M. Sookhak, M. H. Au and X. Luo, "A Survey on Access Control in Fog Computing," in IEEE Communications Magazine, vol. 56, no. 2, pp. 144-149, Feb. 2018.
- [2] Juan Sebastian Rojas Melendez, Alvaro Rendon, Juan Carlos Corrales, "Personalized Service Degradation Policies on OTT Applications Based on the Consumption Behavior of Users", International Conference on Computational Science and Its Applications 2018, pp. 543-557, July 2018
- [3] Liu, Xiao. Yuanwei Liu, and Yue Chen, "Reinforcement Learning in Multiple-UAV Networks: Deployment and Movement Design.", arXiv preprint arXiv:1904.05242(2019)
- [4] Yumin Park, Minkyung Lee and Choong Seon Hong. "Multi-UAVs Collaboration System based on Machine Learning for Throughput Maximization", The 20th Asia-Pacific Network Operations and Management Symposium(APNOMS), Sep. 18-20, 2019, Matsue, Japan
- [5] Nan Zhao, F. Richard Yu, Lisheng Fan, Yunfei Chen, Jie Tang, Arumugam Nallanathan and Victor C.M. Leung, "Caching Unmanned Aerial Vehicle-Enabled Small-Cell Networks: Employing Energy-Efficient Methods That Store and Retrieve Popular Content
- [6] Chuan-Chi Lai, Chun-Ting Chen and Li-Chun Wang, "On-Demand Density-Aware UAV Base Station 3D Placement for Arbitrarily Distributed Users With Guaranteed Data Rates," IEEE Wireless Communications Letter, Vol.8, Issue.3, pp. 913-916, Feb 2019