

SDN 환경에서 머신러닝 기반 비디오 서비스를 위한 최적 AP 선택기법

이동규[○], 홍충선^{*}
경희대학교 컴퓨터공학과
{lidoobil, cshong}@khu.ac.kr

Machine Learning Based Optimal AP Selection Technique for Video Service in SDN Environment

Dongkyu Lee[○], ChoongSeon Hong^{*}
Department of Computer Science and Engineering, Kyung Hee University

요 약

무선 네트워크 환경에서 모바일 디바이스가 AP(Access Point)를 선택할 때, 수신 신호 강도(RSSI: Received Signal Strength Indication)가 가장 높은 AP를 선택한다. 이를 해결하기 위해 QoS(Quality of Service)를 보장하기 위한 AP selection 연구들이 많이 진행되었지만, 간단한 파라미터만 고려하기 때문에 효율적인 서비스 제공이 어려웠다. 따라서 본 논문은 SDN 기반의 Wifi 네트워크 환경에서 모바일 디바이스의 효율적인 비디오 서비스를 제공하기 위해 Access Point selection을 제안한다. 제안하는 알고리즘은 비디오 서비스의 재생 시간을 고려할 뿐만 아니라, 기계학습 알고리즘인 RNN을 통한 AP들의 트래픽을 예측하여 최적의 AP를 선택한다. 이를 통해 모바일 디바이스에게 최적의 비디오 서비스를 제공할 뿐만 아니라 AP들의 부하를 분산시킴으로써 망의 효율성 또한 늘릴 수 있다.

1. 서 론

모바일 디바이스가 서비스를 제공하기 위해 AP(Access Point)와 Wi-Fi(Wireless Fidelity) 연결이 필요할 때, 먼저 주변 AP를 탐색하고 그들 중 하나를 선택하여 연결을 진행한다. 이 때, IEEE 802.11 표준에 의하면 수신 신호 강도(RSSI: Received Signal Strength Indication)가 가장 높은 AP를 선택한다. 그러나 RSSI 기반 선택 방식은 신호 세기만 고려하기 때문에, 해당 AP의 네트워크 상태를 고려하지 않아 서비스에 알맞은 네트워크 환경을 제공하기 어렵다. 따라서 이를 해결하기 위해 QoS를 고려한 AP selection에 대한 많은 연구가 진행되어 왔다. 하지만 대부분의 연구는 QoS를 고려하기 위한 파라미터가 모바일 디바이스와 AP사이의 Downlink bitrate로 한정되어 있어 서비스의 다양한 요구사항을 충족시키지 못한다는 단점이 있다.[1] 뿐만 아니라 모바일 디바이스의 서비스들이 점점 다양하고 거대해짐에 따라 모바일 트래픽을 통한 구체적인 서비스를 분류하고 해당 서비스의 요구사항 분석이 어렵다는 문제점도 있다. 따라서 본 논문은 다양한 모바일 서비스 중에서 가장 활용 빈도가 높은 Youtube에 초점을 두고, 효율적인 비디오 서비스를 위한 AP Selection 연구를 진행하였다. 특히, 비디오 서비스의 재생시간과 Request를 요구한 시간을 주변 AP들의 트래픽 예측한 결과값과 비교하여 가장 핸드오버의 가능성이 적고 QoS를 만족하면서 안정된 서비스를 제공할 수 있는 AP를 선택할 수 있

도록 한다. 또한 이 때, AP와 모바일 디바이스 사이의 Downlink 정보뿐만 아니라 AP와 라우터를 연결하는 Backhaul link의 정보를 파라미터로 추가한다. 왜냐하면 Downlink의 상태만 고려하였을 때 QoS를 만족하는 AP들이 많을 경우, 해당 AP들의 Backhaul link의 상태 또한 고려한다면 특정 AP에 부하가 일어나는 상황을 막을 수 있기 때문이다. 따라서 모바일 디바이스의 주변 AP들에 대한 네트워크 정보들을 수집하기 위해 Software Defined Network(SDN)을 적용했다. SDN은 Wi-Fi 네트워크에서 네트워크 상태를 모니터링 하거나 망의 부하 분산을 위해 효과적이다. 그리고 비디오 서비스의 재생 시간과 디바이스 주변의 AP List를 SDN 컨트롤러에 전달하기 위해 모바일 어플리케이션을 구현하고, 컨트롤러에는 트래픽을 예측하기 위한 어플리케이션을 구현한다. 본 논문은 트래픽을 예측하기 위해서 기계학습 중 딥러닝 알고리즘인 RNN을 사용하여 정확성을 높였다.

2. 관련 연구

2.1 RNN with LSTM

순환 신경망(Recurrent Neural Networks; RNN)은 루프가 들어있고, 과거의 데이터가 미래에 영향을 줄 수 있는 구조를 가진 딥러닝 알고리즘의 하나이다. RNN은 특히 시계열(Time-Series) 데이터를 분석하는 데 많이 쓰인다. 하지만 기존의 RNN은 gradient가 소실되거나(Vanishing) 발산하는(Exploding)하는 문제점이 있다.[2] 그리고 이 문제를 해결하기 위한 고안된 RNNs의 변형인 LSTM(Long Short-Term Memory)의 구조는 그림 1과 같다. LSTM에서 하나의 셀은 Cell State와 Input gate, Out gate, Forget gate 총 3가지의 게이트로 구성되어

본 연구는 과학기술정보통신부 및 정보통신기술진흥센터의 대학 ICT연구센터육성 지원사업의 연구결과로 수행되었음(IITP-2017-2013-0-00717) *Dr. CS Hong is the corresponding author

있다. 각각의 게이트는 가지고 있는 정보들 중에 무엇을 입력할 것인지, 출력할 건지, 잊을 건지를 정한다. 이를 통해 LSTM은 강제적으로 기울기 값을 유지하도록 하여 이러한 문제를 해결하고 오랜 시간의 연관성도 학습할 수 있는 장점이 있다.[3]




그림 1. LSTM의 구조

3. 본론

3.1 기존 연구의 문제점 및 제안 사항

기존의 연구들은 RSSI값으로 AP Selection이 이루어졌을 때, 발생하는 문제를 해결하기 위해 bit rate나 AP의 부하를 고려하여 QoS를 보장하는 알고리즘들을 제안했다.[4] 그러나 단순한 파라미터로는 서비스의 다양한 요구사항을 만족시킬 수 없고, 현재 상황만을 고려하여 AP Selection을 결정했을 때, Connection 이후에 지속적인 QoS를 보장하기 힘들다는 문제점이 있다. 따라서 본 논문은 모바일 디바이스에서 특히 Youtube를 통한 비디오 서비스를 실행할 때, 비디오의 재생시간과 주변 AP들의 네트워크 현재 상태와 기계학습을 통한 미래의 상태를 예측하여 가장 최적의 AP를 선택하는 알고리즘을 제안한다.

3.2 제안 알고리즘

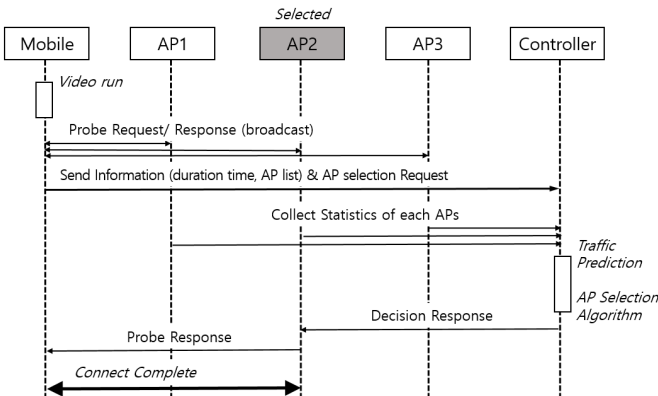


그림 2. 제안하는 기법의 시퀀스 다이어그램

제안하는 기법의 시퀀스 다이어그램은 그림 2와 같다. 먼저 모바일 디바이스에서 Youtube 비디오를 실행할 경우, 어플리케이션을 통해 해당 비디오의 총 재생시간과

주변 AP List 정보를 컨트롤러에게 전달한다. 컨트롤러는 어플리케이션으로부터 받은 정보들을 이용하여 RNN 모델을 통해 주변 AP들의 트래픽을 예측한다. 그리고 예측한 결과와 주변 AP의 Downlink 와 Backhaul link의 상태 정보를 통해, 재생시간동안 QoS를 보장할 수 있는 최적의 AP를 결정한다. 마지막으로 모바일 디바이스는 컨트롤러에서 결정한 AP와 연결을 한다.

3.2.1 RNN 알고리즘을 통한 트래픽 예측

RNN은 시계열 데이터를 분석하는 다른 딥러닝보다 훈련시간이 짧고 정확도 또한 높다.[5] 특히 LSTM의 구조를 가진 RNN은 더욱 강한 학습능력을 갖고 있기 때문에, 본 논문에서는 Keras 라이브러리를 통해 LSTM을 이용한 트래픽 예측 모델을 구현하였다.[6] 먼저 각 AP들의 시간당 트래픽을 입력으로 트래픽을 예측하는 모델을 학습한다. 그리고 이를 통해 어플리케이션에서는 주어진 시간에 대한 각 AP의 예측되는 트래픽을 얻는다.

3.2.2 AP selection 알고리즘

Algorithm 1 : Access Point Selection

Input: S_{AP_req} (Set of Aps), video_durationTime

Output: O_{AP_req} (Optimized AP)

1. set R_{req} based video service with duration time
2. **Predict** bit rate of S_{AP_req}
2. **AP selection for QoS requirement**
3. **for** ap $\in S_{AP_req}$ **do**
4. R_{AP_req} = get predicted **DownLink** bit rate of ap
5. **if** $R_{AP_req} > R_{req}$ **then**
6. Append(L_{AP} , ap)
7. **end if**
8. **end for**
9. **AP selection for Load balancing**
10. **for** ap $\in L_{AP}$ **do**
11. Thr_{AP} = get **Backhaul link** current Throughput of ap
12. Append(L_{Back_AP} , Thr_{AP})
13. **end for**
14. Sort(L_{Back_AP})
15. $O_{AP} = AP$ with L_{Back_AP} .get(0)

그림 3. 제안하는 알고리즘의 의사코드

그림 3은 SDN 컨트롤러에서 이루어지는 AP selection 알고리즘을 의사코드로 나타낸 것이다. 컨트롤러는 Request의 주변 AP List와 요청하는 비디오 서비스의 재생시간을 입력으로 받는다. 그리고 이를 통해 주변 AP들의 현재 네트워크 상태와 미래의 네트워크 상태를 구한다. 먼저 비디오 서비스에 대한 QoS를 보장할 수 있는 bit rate 값인 R_{req} 와 주변 AP들의 LSTM을 통해 예측한 bit rate 값을 비교하여 재생시간동안 QoS를 보장할 수 있는 AP들을 먼저 선별한다. 다음으로 리스트 L_{AP} 에 저장된 선별된 AP들은 자신과 라우터 사이를 연결하는 Backhaul link의 Throughput의 비교한다. 그리고 그 중에서 현재 가장

Backhaul link의 부하가 적은 O_{AP} 를 최적의 AP로 결정한다.

4. 성능 평가

4.1 시나리오

제안한 AP selection 알고리즘을 평가하기 위해, 모바일 디바이스에서 각각 재생시간이 1시간인 비디오 서비스(Service1, s1)와 30분인 비디오 서비스(Service2, s2)를 실행한다. 이 때, 기존의 AP selection은 재생시간과 QoS를 고려하지 않고 신호세기로 AP를 선택하기 때문에 두 개의 서비스 모두 상대적으로 AP2보다 신호세기가 강한 AP1과 연결된다. 그리고 서비스를 이용한 지 30분이 지난 후 AP1에 부하가 생길 경우, 기존의 알고리즘은 QoS를 보장하지 못한다. 그러나 제안한 알고리즘은 SDN 컨트롤러가 주변 AP들의 네트워크 정보를 수집하고, 재생시간에 따른 트래픽 상황을 예측하여 알맞은 AP를 결정하기 때문에 QoS를 지속적으로 보장할 수 있다.

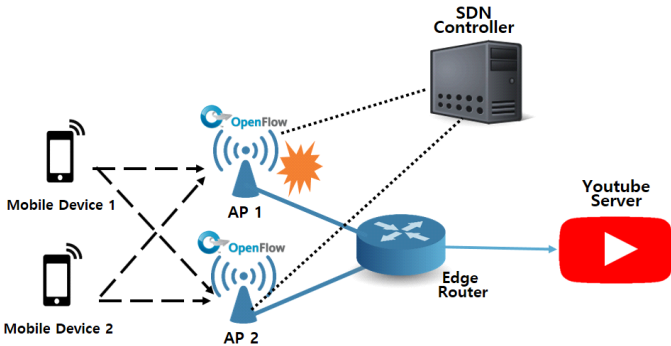


그림 4. 시나리오 토폴로지

모바일 어플리케이션은 Youtube Data API[7]를 통해 구현하였다. 모바일 어플리케이션의 Request Message 안에는 시청하고자 하는 비디오의 재생 시간 값과 스캔한 주변 AP들의 SSID, BSSID, RSSI 값들이 포함되어 있다. 컨트롤러는 미리 학습된 RNN 모델을 통해 각 AP들의 트래픽을 예측한다.

4.2 성능평가

기존의 AP selection은 신호세기로만 AP를 선택하기 때문에 그림 5의 위 그래프처럼 두 개의 서비스 모두 QoS를 만족하지 못할 뿐만 아니라, 안정된 네트워크 상황을 보장할 수 없다. 그러나 제안한 알고리즘은 그림 5의 아래 그래프에서 볼 수 있듯이 두 개의 비디오 서비스 모두 QoS를 보정한 AP와 연결이 가능하다. 뿐만 아니라 신호세기가 강한 AP1에 연결이 집중되는 현상을 막고, AP들의 부하를 분산시켜 전체 네트워크 망의 효율성을 높일 수 있다.

5. 결론

본 논문은 모바일 서비스들 중 Youtube를 통한 비디오 서비스를 대상으로 하여 최적의 AP selection을 제안한다. 특히 SDN 컨트롤러와 딥러닝 알고리즘 RNN을 활용하여 트래픽을 예측하여 비디오 서비스에 알맞은 최적의 AP를 결정한다. 그리고 시나리오 결과, 이를 통해 재

생시간에 따라 비디오 서비스들에 맞는 최적의 AP를 결정하기 때문에 지속적으로 QoS를 보장할 수 있었고 AP들의 분하도 분산시킴으로써 망의 효율성도 높일 수 있었다. 향후에는 사용자 히스토리를 기반으로 서비스의 재생시간을 다 유지하지 않을 경우를 추가로 고려하고, LSTM 모델의 정확성을 더욱 높일 계획이다.

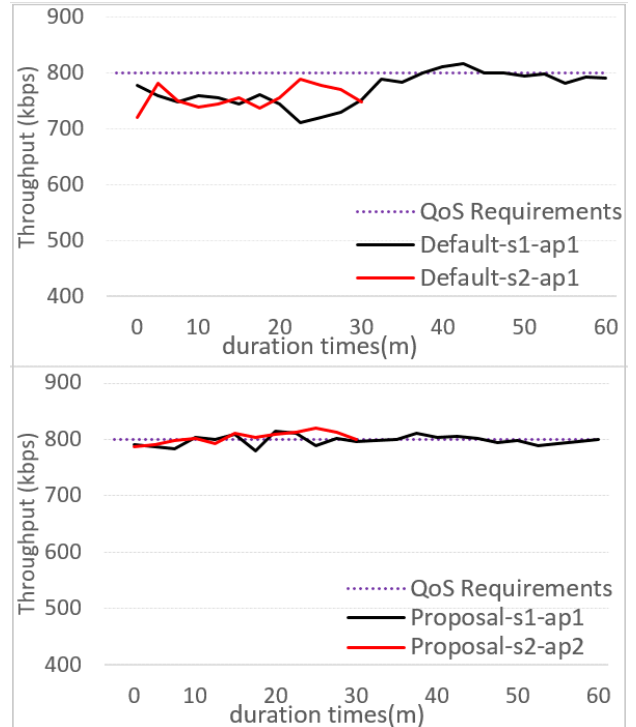


그림 5. 시나리오 결과

참고 문헌

- [1] Tomotaka Kimura, Kouji Hirata, et al., "A Centralized Framework for Smart Access Point Selection based on the Fittingness Factor" International Conference on Telecommunications (ICT), pp. 1-5, May 2016.
- [2] Tjeng Wawan Cenggoro, Ida Siahaan, "Dynamic Bandwidth Management Based on Traffic Prediction Using Deep Long Short Term Memory" International Conference on Science in Information Technology (ICSITech), pp.318-323, Oct 2016.
- [3] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural Computation, vol. 9, no. 8, pp. 1735-1780, Nov 1997.
- [4] Keshav Sood, et al., "Dynamic Access Point Association Using Software Defined Networking" International Telecommunication Networks and Applications Conference (ITNAC) pp. 226-231, Nov 2015.
- [5] Tiago Prado Oliveira, Jamil Salem Barbar, et al., "Computer network traffic prediction: a comparison between traditional and deep learning neural networks" International Journal of Big Data Intelligence, vol. 3, no. 1, pp. 28-37, 2016.
- [6] <https://keras.io/>
- [7] <https://developers.google.com/youtube/v3/>