

기계학습을 이용한 SDN 기반 모바일 서비스를 위한

최적 엣지노드 선택 메커니즘

김기태^o 홍충선*
 경희대학교 컴퓨터공학과
 {glideslope^o, cshong*}@khu.ac.kr

Optimal Edge Node Selection Mechanism for SDN based Mobile Service Using Machine Learning

Kitae Kim^o Choong Seon Hong*
 Department of Computer Science and Engineering, Kyung Hee University

요 약

최근 등장한 다양한 고성능 모바일기기와 통신기술의 발전으로 이전에는 볼 수 없었던 가상/증강 현실이나 각종 IoT(Internet of Things)와 같이 고 대역폭과 실시간 처리를 요하는 어플리케이션이 등장하였으며 이로 인하여 네트워크 트래픽의 양은 계속 폭증하고 있다. 이러한 추세에서 기존의 중앙 집중형 클라우드는 네트워크 지연이나 대역폭 문제로 앞선 서비스를 제대로 제공할 수 없다. 이러한 문제를 해결하기 위해 기지국이나 AP사용자와의 가까운 위치에 클라우드 서버를 설치해 유저와 가까운 위치에서 서비스를 제공하는 엣지 컴퓨팅 기법이 각광받고 있다. 하지만 이러한 엣지 노드 중 가장 가까운 노드가 최적의 서비스를 제공하지 않는다. 따라서 본 논문에서는 기계학습과 SDN 컨트롤러를 이용해 유저에게 최적의 서비스를 제공할 수 있는 노드 선택 기법을 제안한다.

1. 서 론

다양한 고성능 모바일 기기의 보급과 5G의 상용화로 인한 다양한 어플리케이션으로 인해 전 세계의 모바일 트래픽이 2023년에는 현재의 8배에 이르는 100EB(ExaBytes)가 될 것으로 예측하고 되며 이러한 데이터 중 대부분은 고화질 동영상이나 VR(Virtual Reality) AR(Augment Reality)이나 IoT 기기의 센싱 데이터와 같이 지연에 고 대역폭과 지연에 민감한 트래픽으로 조사되었다.[1] 이러한 서비스 요구를 만족시키기 위해서는 기존의 중앙 집중형 방식의 클라우드 구조는 한계가 있다. 따라서 이러한 문제를 해결하기 엣지 컴퓨팅 개념이 등장하였으며 네트워크 가장자리에 위치한 클라우드 서버로부터 다양한 모바일 기기들 뿐 만 아니라 자율주행 자동차 등이 다양한 서비스를 좀 더 빠르게 제공받을 수 있게 되었으며 네트워크 혼잡 또한 완화된다. 하지만 다양한 모바일 유저들의 다양한 서비스 요청을 고려해야하는 분산 클라우드 구조에서 항상 유저와 가까운 엣지 노드가 최적의 서비스를 제공할 수 있는 노드가 아닐 수 있다. 따라서 본 논문에서는 이러한 분산 클라우드 구조에 SDN(Software Defined Network) 컨트롤러를 연동 후

신러닝 기법인 추천시스템과 강화학습을 이용하여 서비스 유형별로 엣지 노드 중 가장 최적의 서비스를 제공할 수 있는 노드를 선택하는 기법을 제안한다.

2. 관련연구

2.1 추천시스템(Recommendation System)

추천시스템이란 사용자가 선호할만한 아이템을 추천함으로써 여러 가지 항목 중 사용자에게 적합한 특정 항목을 선택(Information Filtering)하여 제공하는 시스템을 일컫는다.[2] 주로 Netflix나 Youtube 같은 멀티미디어 콘텐츠 제공 사업자나 쇼핑업계에서 사용자들의 구입내역이나 선호도 등의 개별 데이터를 이용해 사용자 간의 유사성 등을 측정하여 개인에게 콘텐츠나 제품을 추천하기 위해 사용 된다. 본 논문에서는 대표적인 추천 알고리즘인 협업 필터링(Collaborative Filtering)을 사용하여 해당 기법을 제안한다.

2.2 Q-Learning

Q-Learning은 강화학습(Reinforcement Learning)의 대표적인 알고리즘으로 상태의 유한집합 S 그리고 각 상태 $s \in S$ 에서 취할 수 있는 행동의 집합 $A_s \subseteq A$ 로 구성된다. 어떤 상태 s 에서 행동 $a \in A_s$ 를 취하면 에이전트는 이러한 행동에 따른 보상을 받으며 에이전트의 행동은 행동이 끝났을 때 받은 보상의 합을 최대화 시키는 것이

이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임(No.2015-0-00567, 유무선 통합 네트워크에서 접속 방식에 독립적인 차세대 네트워킹 기술 개발). 또한 본 연구는 과학기술정보통신부 및 정보통신기술진흥센터의 대학 ICT연구센터 육성 지원사업의 연구결과로 수행되었음(IITP-2018-2013-1-00717) *Dr. CS Hong is the corresponding author

목표이며 현재의 상태에서 최대의 보상을 획득하는 최적의 정책을 학습한다. 여기서 Q함수는 최적의 규칙을 따라 행동을 할 때 예상되는 보상의 최댓값이며 즉 최적의 규칙을 정의하는 함수이며 아래와 같은 수식으로 Q함수를 업데이트 한다.

$$Q(s_t, a_t) = (1 - \alpha) \cdot Q(s_t, a_t) + \alpha [r + \gamma \max_a Q(s_{t+1}, a)]$$

수식 1. Q 함수

α 는 0과 1사이 값인 Learning Rate이며 γ 는 Discount Factor로서 현재 받는 보상과 미래에 받는 보상과 비교해 현재 받는 보상의 가치를 나타내는 값이다.

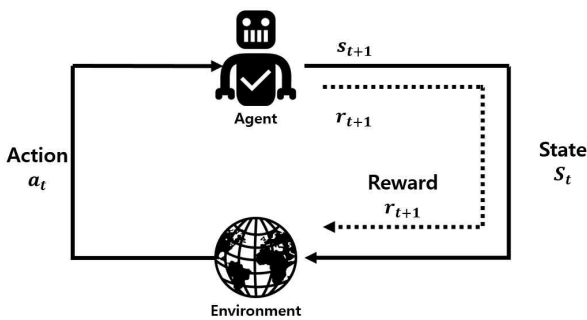


그림 1 . 강화학습(Reinforcement Learning)

3. 제안사항

3.1 추천시스템과 강화학습을 이용한 엣지 노드 선택

앞서 언급하였듯 추천시스템은 사용자가 관심 있어할 만한 콘텐츠나 아이템을 사용자의 개별데이터를 분석해 사용자간의 유사도를 측정하여 추천하는 방법이다. 본 논문에서는 이 점에 착안해 유저에게 서비스를 제공할 수 있는 엣지 클라우드를 추천할 수 있는 아이템으로 사용자를 각 요구사항이 각기 다른 Application으로 간주하고 연구를 진행하였다. 즉, 각기 다른Application들의 특성에 따라 가장 최적의 서비스를 제공할 수 있는 엣지 클라우드를 추천하는 시스템이다. 본 논문에서는 대표적인 사용자 행동 기반 추천 알고리즘인 협업적 필터링(Collaborative Filtering)을 사용한다.

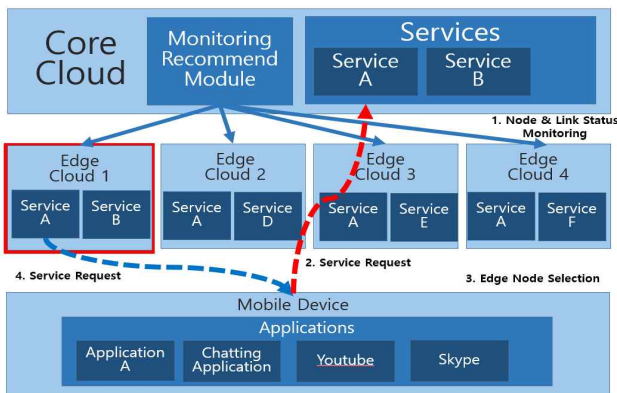


그림 2 . 제안하는 시스템의 구조 및 시나리오
위 그림은 전반적인 시스템의 구조를 나타내며 각 엣지

클라우드들은 SDN 컨트롤러에 연결되어 노드의 현재 혼잡 상태나 주변 링크들의 상태가 모니터링 된다.

본 논문에서 추천을 위해 고려되는 Application의 특성은 아래 표와 같으며 Youtube와 Skype, HTTP 패킷 데이터셋을 고려하였다.[3] 각 Application의 Feature 추출과 카테고리는 기 제안한 논문의 방법에 따라 나뉘어진다.[4]

Application	Category	Requirement (Feature)
Youtube	Video(1)	High Bandwidth
Skype	VoiP(2)	Low Latency
HTTP	Text(3)	Default

표 1 . Application의 Category와 특성

알고리즘1. Machine Learning based Edge Node Selection

- 1: **Request** : Service Request From User
- 2: **selected Node** : Selected Node
- 3: **State** : Have to Select Edge Node
- 4: **Action** : Select Node
- 5: **Reward** : Reward (0,1)
- 6: **Q(S,A)** : Initialize Q Function
- 7: **Measure** : Link Bandwidth/Latency Value
- 8: From Selected Node to User
- 9: **Request from User**
- 10: **Category = classification**(Request)
- 11: **Switch**(Category)
- 12: **Case 1:**
- 13: Selected Node = C_Filtering(Request)
- 14: **Return** Selected Node
- 15: **Case 2:**
- 16: Selected Node = C_Filtering(Request)
- 17: **Return** Selected Node
- 18: **Default :**
- 19: Selected Node = C_Filtering(Request)
- 20: **Return** Selected Node
- 21: **service_Provide**(Selected Node .Request)
- 22: **Measure = measure_Reward**(Selected Node. Request)
- 23: **If**(measure > requirement)
- 24: **Reward = 1;**
- 25: **Else**
- 26: **Reward = 0;**
- 27: **Update Q Function Q(S,A)**

표 2. 머신러닝을 이용한 엣지노드 선택 알고리즘

위 표는 엣지 노드 선택을 위한 대략적인 알고리즘을 나타내며 위 알고리즘에 따른 시나리오는 아래와 같다

시스템 시나리오

1. 모바일 유저의 서비스 요청
2. 서비스 어플리케이션의 카테고리 분류
3. Collaborative Filtering 알고리즘을 통해 노드 추천
4. 모니터링 된 링크정보를 통해 서비스가 되는 경로의 링크지연 / 대역폭 측정(Q러닝의 보상을 위함)
5. 보상 값을 통해 어플리케이션 별 요구사항에 부응하는 서비스를 제공한 경우 시스템에 보상을
6. 추천시스템은 어플리케이션 특성과 최대 보상을 고려하여 노드 추천

보상 결정을 위한 서비스 경로의 링크 지연 / 대역폭 측정은 아래의 식2와 같이 계산 된다.

$$Measure = \begin{cases} \frac{1}{transmissiondelay} + linkspeed, & category = 2 \\ throughput + bandwidth, & category = 1 \end{cases}$$

수식 2. Reward 결정을 위한 Function

Low Latency 서비스를 위해서 링크의 Transmission Delay와 linkspeed가 측정되었고 High Bandwidth 서비스를 위해 노드의 throughput과 bandwidth가 측정된다.

4. 시뮬레이션

4.1 시뮬레이션 방법 및 토폴로지

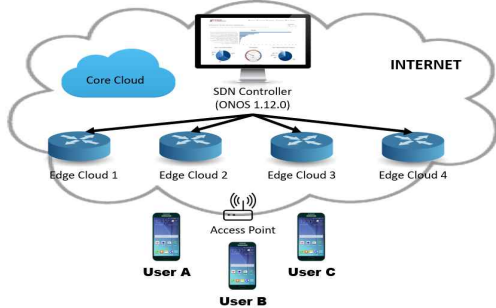


그림 3. 시뮬레이션 토폴로지

시뮬레이션을 위해 그림3과 같이 라즈베리파이 4개로 엣지 클라우드를 구축하였으며 두 대의 모바일 기기를 통해 시뮬레이션을 진행하였다. 성능 검증을 위해 각 유저는 Youtube 패킷을 전송해 비디오 스트리밍 서비스를 요청하며 Edge Cloud 1,2,3에는 고의적인 트래픽 발생을 통해 혼잡상황을 발생 시켜 User A는 제안한 방법을 통하여 서비스를 제공받고 User B는 가장 가까운 노드에서 User C는 코어 클라우드에서 서비스를 받도록 하여 같은 시간 동안 받은 데이터의 양을 측정한다.

4.2 시뮬레이션 결과

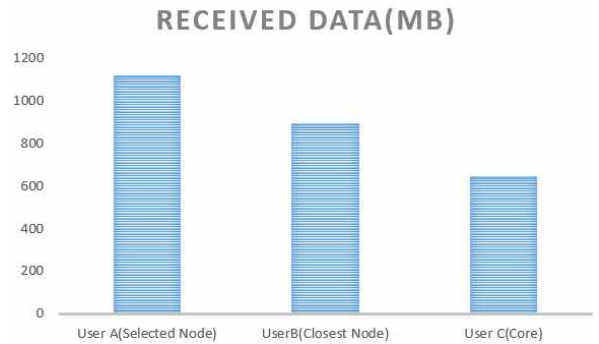


그림 4. 시뮬레이션 결과

해당 시나리오로 시뮬레이션 결과 제안하는 방법을 통한 노드로 서비스를 받는 것이 같은 시간동안 더 많은 데이터를 수신한다는 것을 확인 할 수 있다.

5. 결론 및 향후연구

본 논문에서는 머신러닝을 이용하여 어플리케이션 별로 최적의 서비스를 제공 할 수 있는 엣지 노드 선택 기법을 제안하였으며 추천시스템이 항상 정확하지는 않으므로 추천 성능을 향상시키기 위해 강화학습을 이용하였다. 시스템을 개선시키기 위해 어플리케이션 뿐 만 아닌 노드들의 현재 특성이나 다양한 변수들을 고려해야 할 필요가 있으며 이에 대한 연구를 진행할 예정이다. 또한 다양한 시뮬레이션 시나리오와 많은 수의 노드를 이용해 시스템 및 강화학습의 성능을 검증 및 개선 예정이다.

6. 참고문헌

- [1] Erricson “Mobile Data Traffic Growth Outlook”, Mobility Report 2017, Nov 2017
- [2] 서봉원, “콘텐츠 추천 알고리즘의 진화”, 한국 콘텐츠 진흥원 방송&트렌드 인사이트, Vol 05 ,No4, 2016
- [3] Satadal Sengupa, Harshit Gupta, Nioly Ganguly, Bivas Mitra, Pradipta De, Sandip Charkraborty, CRAWDAD dataset iitkgp/apprtraffic(v. 2015-11-26), traceset : apptraffictraces, downloaded from <http://crawdad.org/iitkgp/apprtraffic/20151126/apptraffictraces>, <http://doi.org/10.15783/C77S3W>, NOV 2015
- [4] 김기태, 홍충선 “SDN환경에서 효율적인 트래픽 분류를 위한 Feature Selection 기반 Multi Classification 기법 연구” 2017 한국 컴퓨터 종합 학술대회(KCC 2017)