

# 자율주행 자동차 서비스를 위한 강화학습 기반 서비스 체이닝 오프로딩 결정 방안

이민경<sup>0</sup>, 홍충선\*  
 경희대학교 컴퓨터공학과  
 {minkyung0110, cshong}@khu.ac.kr

## Offloading Decision for Service Chaining Based on Reinforcement Learning in Autonomous Vehicle Services

Minkyung Lee<sup>0</sup>, Choong Seon Hong\*  
 Department of Computer Science and Engineering, Kyung Hee University

### 요약

5G 네트워크 상용화에 따라 스마트 공장, 자율주행 자동차 등 초저지연 실시간 통신 서비스를 요구하는 미션 크리티컬 기기들이 발전하는 추세이다. 이와 함께 기기들과 근접한 곳에 위치하여 기존의 집중형 클라우드 시스템보다 처리 속도가 빠른 분산형 클라우드 시스템이 급증하는 추세이다. 그 중 자율주행 자동차의 경우 카메라 인식을 통한 경로 계획 과정에서 10ms 이내의 처리 속도를 요구한다. 따라서 카메라 인식 기반 경로 계획을 실행할 때, 자율주행 자동차와 엣지 서버 간에 서비스 체이닝 오프로딩이 요구된다. 본 논문은 저 소비 에너지 및 저 지연의 경로 계획 제공을 위해 자율주행 자동차와 엣지 서버 간 Actor Critic 기반 서비스 체이닝 오프로딩 결정 방안을 제안하고자 한다.

### 1. 서론 및 관련 연구

5G 네트워크가 상용화 되면서 초저 지연 고 신뢰도 서비스가 제공 가능한 시대가 도래함에 따라 분산형 클라우드 모델을 통해 사용자 기기들 가까이에서 각 기기들의 요구사항을 처리해주는 기술이 도입되는 추세이다. 그중 스마트 공장, 스마트 시티, 자율주행 자동차 등 미션 크리티컬 기기들의 경우 저 에너지 기반 초저 지연 및 고 신뢰도 서비스를 요구한다[1][2]. 특히 자율주행 자동차의 경우 비디오 스트리밍, 음성, 텍스트부터 객체 인식, 주행 거리 판단, 로드뷰, 경로 계획 등에 이르는 방대한 양의 데이터를 실시간으로 처리해야 한다. 이때 발생하는 지연 시간 및 정보 신뢰도 문제를 해결하기 위해 다양한 오프로딩 방안들이 연구되고 있다. 우선 논문 [3]의 경우, 효율적인 작업 오프로딩을 위해 계산 작업을 분할하여 최적의 자원 효율을 얻는 동시에 자동차의 이동을 예측하여 오프로딩 지연을 줄여주는 포그 네트워크 기반 자동차 오프로딩을 연구하고 있다. 이때 자동차의 이동 예측을 통한 오프로딩 지연시간 감소를 위해 모델 기반의 강화학습 알고리즘을 적용하였다. 논문 [4]의 경우, 자동차와 모바일 엣지 컴퓨팅 간 발생하는 하위 작업의 유동적인 관리를 위한 동적 작업 오프로딩 결정 방안을 제안한다. 또한 모바일 엣지 컴퓨팅의 계산 자원 할당 최적화를 제안하여 각 차량의 전송 큐와 계산 밀집도를 분산하는 방안을 제안한다.[1]

그러나 논문[3][4]의 경우, 자율주행 자동차에서 엣지 서버로 오프로딩 되는 데이터 수집, 전처리, 객체 탐지와 같이 각각의 구성 블록(Component Block, CB)들의 요구사항을 고려하지 않는다. 따라

서 본 논문은 각각의 구성블록들의 네트워크 자원 및 에너지에 따라 차량 또는 엣지 서버로의 오프로딩 할당되는 방안을 제안한다.

### 2. 제안 사항

#### 2.1 시스템 모델

본 논문은 카메라 인식 기반 경로 계획 서비스를 제공하는 자율주행 자동차와 엣지 서버 간 요구되는 높은 신뢰도 및 저 지연을 제공하기 위해 강화학습 기반 서비스 체이닝 오프로딩 결정 방안을 제안한다.

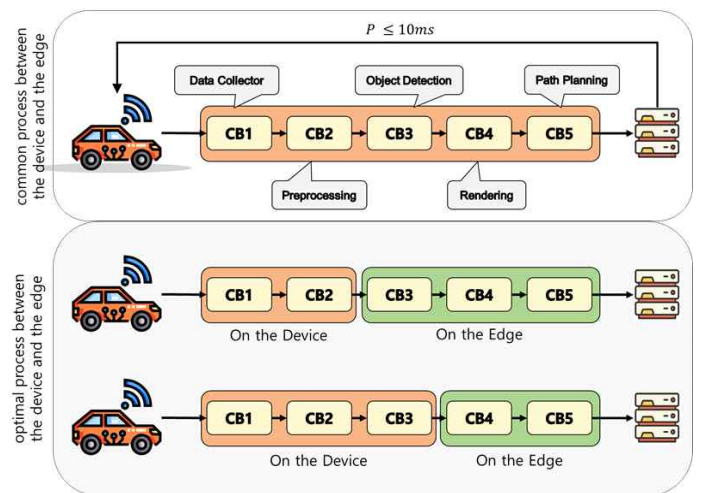


그림 1. optimal process for the device and the edge

그림 1과 같이 자율주행 자동차는 최적의 경로 계획을 위해 실시간으로 주변 데이터 수집 및 전처리 후 이를 통해 객체를 탐지하여 렌더링 작업을 거친 후 최적의 경로 계획 방안을 탐색

이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2019-0-01287, 분산 엣지를 위한 진화형 딥러닝 모델 생성 플랫폼) \*Dr. CS Hong is the corresponding author

한다. 각각의 과정은 CB 모델 안에서 수행되며 다음 CB로 전달되어 다음 과정을 진행한다. 이때 모든 CB 과정을 자율주행 자동차에서 수행할 경우, 경로 계획 외에 비디오 스트리밍, 전화, 라이더 센서 등 자율주행을 위해 요구되는 다른 서비스들의 지연시간이 증가하게 되고 자율주행 자동차의 신뢰도 역시 감소하게 된다. 따라서 최적의 경로 계획 서비스를 제공하는 자율주행자동차와 엣지 서버 간 강화학습 기반 서비스 체이닝 오프로딩 결정을 제안함으로써 저 에너지 및 저 지연 서비스를 제공하는 방안을 연구한다.

## 2.2 네트워크 모델 및 문제 정의

자율주행 자동차와 엣지 서버의 서비스 체이닝 오프로딩 결정을 위하여 전송 및 계산 지연시간 및 에너지소비가 필요하다[5][6].

**1) Local Computing:** 자동차 서비스 체이닝 수  $k$ 에서 엣지 서버  $e$ 로의 데이터 비율은  $r_k$ 이고, 전송된 데이터 사이즈 비율은  $\beta$ 이며, 비트 내 전체 작업을 위한 입력 데이터 크기는  $I$ 이다. 이를 바탕으로 자율주행 자동차에서 엣지 서버로의 오프로딩을 위한 전송 지연 시간은 다음 수식 (1)이다. 이때 본 논문은 오프로딩이 항상 발생한다고 가정한다.

$$L_{k \rightarrow c}^{Tran} = \frac{\beta I_k}{r_k} \quad (1)$$

자율주행 자동차의 한 CPU cycle의 에너지 소비량은  $\varphi_k$ 이고, 작업을 처리하기 위해 사용되는 CPU cycle은  $C_k$ 로, 자동차에서 시행되는 작업의 에너지 소비량은 수식 (2)와 같다.

$$P_k^{Local} = C_k \cdot \varphi_k \quad (2)$$

**2) Offloading Computing:** 엣지 서버로 오프로딩 하는 계산 전송 시간은 업링크 전송과 다운링크 전송으로 구분할 수 있다. 본 논문에서 다운링크 전송의 경우 오프로딩 결정 방안만을 전달하기에 데이터 크기가 작아 업링크 전송만을 고려한다. 따라서 업링크 전송만을 고려한 지연시간은 수식 (3)으로 나타낸다.

$$L_{k \rightarrow c}^{Comp} = \frac{\alpha I_k}{f_k}, \forall k \in K \quad (3)$$

자동차 서비스 체이닝 수  $k$ 의 전송 에너지는  $p_k$ 이고, 자동차의 업링크 전송 데이터율은  $r_k^u$ 로, 엣지 서버에서 계산 오프로딩 시 발생하는 전체 에너지 소비량은 수식 (4)이다.

$$P_k^{Edge} = \rho_k \cdot I_k / r_k^u \quad (4)$$

수식 (1)과 (2)에 자동차 서비스 체이닝 가중치  $w_k$  및 엣지 가중치  $w_c$ 를 더하여 수식 (5)와 같이 자동차에서 시행되는 전체 작업 소비량  $T^{Local}$ 을 구할 수 있다.

$$T^{Local} = \omega_k \cdot L_{k \rightarrow c}^{Tran} + \omega_c \cdot P_k^{Local} \quad (5)$$

비슷한 방법으로 수식 (3)과 (4)에 각각의 가중치들을 더하여

수식 (6)과 같이 계산 오프로딩의 전체 소비량을 나타낼 수 있다.

$$T^{Edge} = \omega_k \cdot L_{k \rightarrow c}^{Comp} + \omega_c \cdot P_k^{Edge} \quad (6)$$

**3) Problem Formulation:** 수식 (5)와 (6)을 통해 본 논문에서 구하고자 하는 저 소비 에너지 및 저 지연 시간 오프로딩 결정 방안 연구를 구할 수 있다.

$$\begin{aligned} & \text{minimize } T^{Local} + T^{Edge} \\ & \text{s.t. } \omega_k + \omega_c = 1 \end{aligned} \quad (7)$$

## 2.3 강화학습 기반 서비스 체이닝 오프로딩 결정 방안

본 논문은 수식 (7)을 바탕으로 자율주행 자동차 및 엣지 서버의 계산 에너지 상태에 따라 서비스 체이닝 오프로딩을 결정하는 방안을 Actor Critic 강화학습 모델 기반으로 제안한다.

**1) 상태( $S_t$ ):** 자율주행 자동차의 이용 가능한 계산 에너지량  $A_k$  및 엣지 서버의 사용할 수 있는 계산 에너지량  $E_c$ 를 고려하여 상태  $s = (A_k, E_c)$ 이다.

**2) 행동( $\alpha_t$ ):** 본 논문이 구하고자 하는 값으로 주어진  $\alpha$ 에 따라 변하는 상태  $s$ 값의  $R$ 이 최소일 때가 최적의  $\alpha$ 값이다. 즉, 자동차와 엣지 간 서비스 체이닝 오프로딩을 각각 얼마만큼 할당받는지 결정하는 값이  $\alpha$ 로  $\pi_\theta(\alpha_t | S_t)$ 이다.

**3) 보상( $R_t$ ):**  $R$ 은 수식 (7)로서 여러 에피소드에서 주어지는  $\alpha$ 에 대해  $R$ 이 가장 최소인 경우가 최적의  $R$ 값이다.

### Algorithm 1 Process of Service Chaining Offloading Decision

**Input:**  $k, e, r_k, I, \beta, \varphi_k, C_k, r_k^u, w_k, w_c$   
**Output:** optimal service chaining offloading decision  $\pi_\theta(\alpha_t | S_t)^*$   
**Initialization:**  $S_t, \alpha_t, R_t, S_{t+1}$ , Actor Critic  
1: **For Until:** optimal  $\pi_\theta(\alpha_t | S_t)^*$  **do**  
2: **for**  $\forall k \in K$  **do**  
3: **Action:**  $\alpha_t \sim \pi_\theta(\alpha_t | S_t)$   
4: **Get:**  $o_t = \langle S_t, \alpha_t, R_t, S_{t+1} \rangle$   
5: **Assess:**  $\alpha(\theta_k)$  using eq. (7)  
6: **Policy:**  $\theta \leftarrow \theta + \alpha_\theta Q_w(s, a) \nabla_\theta \ln \pi_\theta(a | s)$  (policy gradient)  
7: **Update:**  $\theta_k = \theta_k + \text{Policy}$   
8: **ActionValue:**  $\delta_t \leftarrow r_t + \gamma Q_w(s, a) \nabla_\theta \ln \pi_\theta(a | s)$   
9: **Update:**  $\delta_t = \delta_t + \text{ActionValue}$   
10: **end for**  
11: **Update:**  $a \leftarrow a_{t+1}$  and  $s \leftarrow s_{t+1}$   
12: **Append:**  $o_t \in O$   
13: **return**  $\pi_\theta(\alpha_t | S_t)^*, O$

알고리즘 1은 Actor Critic 알고리즘을 적용하여 본 논문이 구하고자 하는 자동차 및 엣지 서버 간 최적의 서비스 체이닝 오프로딩 할당 결정 방안의 과정을 보여주며, 얻어지는 최적

의 오프로딩 결정 값은  $\pi_{\theta}(\alpha_t|S_t)^*$  에 해당한다.

### 3. 성능 평가

본 연구에서 제안한 방안의 성능평가를 위한 환경 구성은 5대의 자율주행 자동차와 한 대당 5개의 서비스 체이닝 구성블록으로 이루어져 있고, 도커 가상머신 위에 올린 5개의 쿠버네티스로 엷지 서버 환경을 설정하였다. 이 때 각각의 자동차와 엷지 서버의 사용 가능한 계산 에너지 소비량 입력값으로 균등분포 난수발생으로 구축한 데이터 값을 활용하였다. 각각의 서비스 체이닝 구성블록 모델들이 차지하는 에너지 소비량 값은 난수발생으로 구축한 값을 사용하였다.




그림 2. 제안하는 알고리즘 동작 여부 확인을 위한 총 60번의 에피소드 별 보상 값 출력 그래프

그림 2는 제안하는 알고리즘이 주어진 환경에서 잘 작동하는 지 여부를 확인하기 위해 총 60번의 에피소드 진행을 통해 알고리즘 동작 여부를 확인한 그래프이다. 그래프 별로 오차 지점은 -3에서 +3으로 존재하지만 해당 오차의 평균값들이 에피소드별 보상값이 최솟점을 나타내주는 것을 확인할 수 있다.




그림 3. Actor Critic 알고리즘 오프로딩(AC) vs 순수 오프로딩(None)의 보상값 비교 그래프




그림 4. AC vs None 평균 보상값 비교 그래프

그림 3은 서비스 체이닝 오프로딩 결정 시 Actor Critic 알고리즘이 적용된 것과 일반적인 오프로딩 결정 방안을 적용했을 시 에피소드별 보상값을 나타낸다. 또한 그림 3의 결과값에 기반한 그림 4의 평균 보상값 비교를 통하여 Actor Critic 알고리즘을

적용하였을 때 나타나는 보상값이 대체적으로 낮은 것을 확인할 수 있다. 즉 본 논문이 제안한 알고리즘을 적용하였을 때 수식 (7)에 만족하는 저 소비 에너지 및 저 지연의 오프로딩 결정 방안이 구현 되는 것을 확인할 수 있다.

### 4. 결론

본 연구에서는 Actor Critic 알고리즘을 기반으로 자율주행 자동차와 엷지 서버 간 최적의 서비스 체이닝 오프로딩 결정 방안을 연구하였다. 성능평가를 통해 최소 보상값의 지점에서 본 연구가 구하고자 하는 수식(7)의 결과값이 형성된다는 것을 확인할 수 있었다. 그러나 서비스 체이닝 모델은 카메라 센서를 통한 경로 계획 애플리케이션의 모델만을 고려한 부분이 한정적이었고, 네트워크 모델 고려 시, 전송 대기 지연 시간을 고려하지 않았다는 한계가 존재한다. 또한 항상 오프로딩이 발생하는 상황임을 가정하여 진행했다는 한계가 존재한다.

따라서 향후 연구에서는 다양한 애플리케이션을 고려한 여러 대의 자율주행 자동차와 다수의 엷지 서버를 고려하여 이기종 엷지 서버 환경에서 최적의 서비스 체이닝 오프로딩 결정 방안을 연구할 계획이다. 더불어 단순히 오프로딩 결정 방안만을 연구하는 것이 아닌 각각의 서비스 체이닝 구성블록별 모델 압축 알고리즘을 고안하여 자율주행 자동차 애플리케이션 별 최소 지연 시간을 제공하는 프레임워크를 연구할 계획이다.

### 참고 문헌

- [1] Aidin Ferdowsi, Ursula Challita, Walid Saad, "Deep Learning for Reliable Mobile Edge Analytics in Intelligent Transportation Systems: An Overview", IEEE Vehicular Technology Magazine, vol. 14, p.p 62- 70, Issue. 1, March 2019
- [2] Anselme Ndikumana, Nguyen H. Tran, Tai Manh Ho, Walid Saad, Dusit Niyato, Choong Seon Hong, "Joint Communication, Computation, Caching, and Control in Big Data Multi access Edge Computing", IEEE Transactions on Mobile Computing, p.p.1-1, March 2019
- [3] Sheng Zhou, Yuxuan Sun, Zhiyuan Jiang, Zhisheng Niu, "Exploiting Moving Intelligence: Delay-Optimized Computation Offloading in Vehicular Fog Networks", IEEE Communication Magazine, vol. 57, p.p.49-55, Issue. 5, May 2019
- [4] Xiaoge Huang, Ke Xu, Chenbin Lai, Qianbin Chen, Jie Zhang, "Energy-efficient offloading decision-making for mobile edge computing in vehicular networks", EURASIP Journal on Wireless Communications and Networking, 2020
- [5] Jianhui Liu, Qi Zhang, "Offloading Schemes in Mobile Edge Computing for Ultra-Reliable Low Latency Communications", IEEE Access, vol. 6, p.p 1285-12837, 2018
- [6] Ke Zhang, Yuming Mao, Supeng Leng, Sabita maharjan, Yan Zhang, "Optimal delay constrained offloading for vehicular edge computing networks", IEEE International Conference on Communications(ICC), May 2017