

2020 IT 21


Global Conference

Digital New Deal
Technology Essentials
디지털 뉴딜 기술 핵심

Session 6-4

엣지 기반 분산 클라우드 기술 동향

윤주상 교수 (동의대학교)



[요약문]

본 강연에서는 엣지 기반 분산 클라우드 구현을 위해 개발 중인 지능형 분산-협업 엣지컴퓨팅 협업 모델 및 관련 기술 개발 현황을 소개한다. 특히, 클라우드-엣지 및 엣지 간 지능형 협업 모델의 개발 방향 및 요소 기술에 대해서 논의한다.

최근 지능형 분산-협업 엣지컴퓨팅 기술 개발 방향은 컴퓨팅 오프로딩 및 서비스 이동 제공 시 클라우드-엣지 및 엣지 간 협업 및 연계 운영이 가능한 딥러닝 기반 지능형 기술을 개발 중이다. 본 강연에서는 이와 관련된 다양한 기술 개발 사례를 중심으로 관련 기술을 소개 하며 주로 딥러닝 기술이 엣지 컴퓨팅 협업 모델에 어떻게 적용되는지를 소개한다. 또한, 클라우드-엣지 및 엣지 간 협업 모델에 대해서는 분산-협업 시 필요한 엣지컴퓨팅 협업 요소 기술을 정의하고 관련 기능을 소개한다.

[발표자 약력]

1999년 고려대 전기전자전파공학사
2008년 고려대학교 전자컴퓨터공학 박사
2002년 ETRI 연구원
2012년~현재 TTA 국제표준전문가
2015년~현재 TTA 사물인터넷 네트워킹 그룹 부의장
관심분야 : 지능형 사물인터넷, 클라우드 컴퓨팅, 포그/엣지 컴퓨팅, 5G 등



엣지 기반 분산 클라우드 기술 동향

동의대학교

윤주상

joosang.youn@gmail.com

2020.09.25

내용

- 엣지 컴퓨팅 소개
- 엣지 컴퓨팅 도입 배경 및 필요성
- 엣지 기반 분산 클라우드 기술
- 지능형 분산 협업 기술 동향
- 결론

Computing 기술의 변화

Cloud
(2000 – 2015)



Edge / Fog
(2016 – ?)



배경

- 사물인터넷 서비스 증가로 인한 폭발적인 데이터 증가
 - 데이터 활용을 위한 컴퓨팅 서비스 요구 증가
- 인터넷 기반 응용 서비스 환경 변화
 - 컴퓨팅 기반 응용 서비스 증가
 - 자연에 민감한 이동 응용 서비스 증가
 - 자원 제약적 모바일 디바이스 (IoT 디바이스)의 컴퓨팅 요구 사항 증가
 - Computation offloading
 - Service migration
 - Network Control & Resource Allocation
 - → Reduces energy consumption for local processing and prolongs battery life

엣지 컴퓨팅 도입의 필요성

- Cloud computing(CC)
 - Easy-to-use platform
 - 사물인터넷 디바이스는 데이터 저장 및 프로세징을 위한 CC에 의존적임
- 하지만, 최근 CC 사용에 있어 한계점이 발견됨
 - Real-time, low latency, mobile applications 서비스 제공에 있어 자연 발생
- 엣지 컴퓨팅 장점
 - 초지연 서비스 제공 가능
 - 네트워크 자원 사용률 감소

클라우드-엣지 컴퓨팅 협업 기술

- 솔루션 구분

구분	분류	특징	배포 방식	지원 Platform
MS, Azure IoT Edge	Computing	클라우드에서 ML 모델 학습 후 배포 머신 러닝, 스트림 데이터 질의 / 필터링 클라우드 기반 Edge 기기 관리	Microservice	Linux, Mac, Windows
AWS, Greengrass	Computing	AWS 기능(Lambda, Shadow)을 Edge에서 실행 클라우드에서 ML 모델 학습 후 배포	Proprietary (MQTT 통신)	Linux, RPi
Google IoT Edge, Apple 등	Computing	클라우드에서 ML 모델 학습 후 배포, 딥러닝 기반 AI 서비스 지향, H/W(NPU, GPU, 전용 AI Processor 등) 활용	SDK	Android iOS,macOS, tvOS
ARM, MBed Edge	Collecting	Edge와 연결된 기기의 Protocol Translation	Microservice	Linux, RPi


엣지 컴퓨팅 기술의 변화

- Edge computing Power 증가
- Intelligent Service in Edge 요구
- 5G 융합서비스 개발 촉진
 - 초저지연 서비스 증가
 - Local cache 서비스 증가
- Finding insights in data

→Where? Cloud --> Edge


- 현재 클라우드-엣지 간 협업 시나리오 및 기술은 존재하나 엣지 간 협업 기술 개발은 진행형
- 엣지-클라우드 및 엣지 간 협업 기술 요구
- 이를 통해 분산 클라우드 인프라 구축

분산-엣지 협업 서비스




협업이 필요한 분산-엣지 서비스 시나리오

- COS, DCS, DSS 가 필요한 서비스 시나리오 정의



용합 서비스 관점에서 엣지-클라우드 간 협업 서비스 (예)

- Edge-cloud 연계 비디오 분석 운영 시나리오
 - Latency-sensitive Applications over Edge-Cloud Computing



비디오 분석을 위한 협업 운영 솔루션 (기존)


• 기존 솔루션

Research	Proposed solutions	Edge devices	Edge nodes	Offloading granularity	What's to be offloaded
VideoEdge [158]	A hierarchical framework for video analytics and large-scale video query	IoT cameras	Private clusters	Full	The pipeline of computer vision components, such as video decoder, object detector, and associator
GigaSight [73]	A 3-tier architecture for first-person video storage, sharing, and content searching with privacy removing	Head-up displays, like Google Glass	Cloudlets	Tasks-Components	Video privacy removing, video tagging and indexing, and content searching
Wang <i>et al.</i> [159]	A privacy-aware and scalable live video analytics for face recognition	Devices with cameras, e.g., mobile phones	Cloudlets	Tasks-Components	Video privacy removing, the execution of analytics algorithms, e.g., DNN-based feature extraction and classification
Wang <i>et al.</i> [160]	A bandwidth-efficient drone video analytics framework employing adaptive policies to reduce video transmission	Drones	Cloudlets	Tasks-Components	The execution of computer vision algorithms
LAVEA [161]	A latency-aware 3-tier video analytics architecture enabling offloading tasks inter-edge collaboration	Smartphones and wearable devices	Container-based cloudlets	Tasks-Components	The execution of computer vision algorithms


지능형 요소 개발 (딥러닝을 활용한 솔루션 도출)

서비스 연동 지능형 운영 방안

- 예)



Workflows of cloud gaming with the types of video streaming




Hybrid Architecture,
to reduce latency and network traffic

서비스 결정 필요 → 지능형 요소 설계

Distributed AI Service

- 인공지능 서비스에서 고민 중
 - 엣지 추론 – 클라우드 학습 (일반적인 모델)
 - 엣지 추론+**학습** – 클라우드 학습 (제안하는 모델)
 - Multi-task 상황에서 추론 서비스 지연 발생.. 등
 - 5G 융합서비스 중 고민 중
- 서비스 시나리오 발굴 및 정의 후 Edge-Edge(E-E), Edge-Cloud(E-C) 간 서비스 연동을 위한 지능형 운영 방안 제안

엣지 간 협업 모델



엣지 서버 간 협업 기술의 중요성

- 엣지 컴퓨팅 서버 기반 응용 개발 중
 - 드론 응용, cyber-physical-social systems (CPSSs)
 - Traffic violation tracking cameras
 - Drone services for delivery
- 클라우드-엣지 간 역할 분담이 이루어지고 있음
 - 지능형 서비스
 - 클라우드-학습, 엣지-추론, 학습
 - 실시간 서비스 및 결정 서비스 등 엣지 서버 역할로 다운 중
- 클라우드 단절 서비스 제공을 위한 엣지 역할
- 엣지 기술은 분산 방식으로 개발이 용이함

엣지 기술 관련 이슈

- 실시간 이동 응용 서비스 경우 여전히 자연 및 에너지 컴퓨팅 이슈가 존재함
 - 엣지 네트워크 내 자원의 동적 특성으로 실행 시간이 불안정함
 - 엣지 컴퓨팅 서버의 효율적 오프로딩 서비스 제공 방법 필요
- 오프로딩 서비스 제공시 오프로딩 수준 정의
- 협업 관련 이슈
 - 협업이 가능한 분산 엣지 네트워킹 기술 부족
 - 엣지 간 정보 전달을 위한 인터페이스 및 프로토콜 부재
 - 오프로딩 수준에 따른 협업 모델 필요
 - 협업을 위한 엣지 서버 탐색 방법 부재
 - 협업 목적에 따른 협업 방법 및 정책 부족
 - 이외에도 다양한 협업 이슈가 존재함

지능형 분산-엣지 컴퓨팅 서비스 연구

- 기존 연구


- 인접한 엣지 서버와 협업이 없음
- 자원 할당 및 관리를 위한 policy-based reinforcement learning techniques 기술 적용
 - 현재 상태가 반영되지 않는 모델 적용
 - 일반적인 오프로딩 시나리오 적용

- 고려 사항


- 분산 엣지 네트워크 환경 고려
- 자연과 에너지 측면을 동시 고려
- 현재 상태가 반영되는 심층 강화 학습 모델 적용
- 협업 엣지 디스커버리 및 선택

→ 분산 엣지 네트워크 환경에서 DRL 기반 자원 할당 및 관리 기술

지능형 분산-엣지 협업 모델 (간단한)



협업 모델 개발 시나리오



협업이 필요한 컴퓨팅 서비스 정의

- 클라우드-분산 엣지 간 컴퓨팅 서비스 (엣지 기반 융합 서비스 아님)
 - Computing Resource Provisioning
 - Computing Offloading Service (COS)
 - Decentralized/Distributed Cache/Storage Service (DCS, DSS)
 - Service Migration (SM)
 - Distributed AI service
 - Task offloading service와 유사
 - Network Resource Provisioning
 - 이동 디바이스의 서비스 품질 보장을 위해 엣지 서버간 네트워크 자원 보장 등을 협의 할 수 있는 협업 기술 필요

Computation Offloading & Granularity




Fig. 4. *Granularity of computation offloading. Generally, mobile devices can offload computation at (a) full offloading, (b) task/component, and (c) method/thread levels.*

- 협업 시 Granularity 설정이 필요

협업 서비스 수준 정의

- <컴퓨팅 오프로딩 제공 방법 별로 협업 서비스 수준 정의>
- Computation Offloading (CO-X)
 - **Application Partitioning**
 - Partitioning for multi-offloading in distributed edge node
 - Tasks can distribute edge-cloud or between edges
 - Partitioning granularity
 - **Task Allocation**
 - The runtime decision of task placement and scheduling associated with the resource management
 - if considering multiuser scenarios, multi-edge node collaborated resource allocations and load balancing are two challenges
 - **Task Execution**
 - VM-based Execution, Container-based Execution
 - Serverless architecture
 - Process-level isolation


Application Partitioning
Task Allocation
Task Execution



협업 요청 시 고려사항 (협업 수준)


협업 모델 도출

- COS, DCS/DSS 협업 시나리오 가정




엣지 내 협업 요소 기술 도출

- COS, DCS/DSS 협업 시나리오 가정
- 요소 기술 안
 - Policy for collaborative triggering
 - Task scheduling in distributed computing manner
 - Collaborative computation resource allocation
 - Intelligent RA based DRL algorithm for optimal offloading action with distributed edge node or cloud
 - Training element & process
 - Learning based Action Prediction Method
 - Adaptive Allocation Strategy
 - Optimal resource allocation scheme




지능형 분산-협업 모델



협업 지원 지능형 컴퓨팅 오프로딩 연구 동향

- High-level overview of computation offloading in MEC model
 - Communication Model
 - Task & Offloading Model
 - Computation Model
 - Edge Processing Time
 - Local Processing Time
 - Edge Processing Time
 - Processing Time of Adjacent Edge Server
 - Remote Processing Time (Cloud Server)



Problem Formulation

- The minimized cost is denoted by Q_{min}
 - Our objective to minimize the processing and transmission delay and reduce the power consumption
 - DQN based Offloading Decision Method

Algorithm 1 OD-SARSA

```
1: Input: Number of MDs  $N$  and task size  $D_n$ 
2: Output: efficient offloading decision, cost reduction
   and bandwidth allocation
3: Initialize the network parameters with upload and
   download bandwidth, and processing cycle number
4: Initialize the number of iterations (episodes), let  $I =$ 
   100
5: for iteration  $I < 1, 2, 3, \dots, I$  do
6: Select "Action" randomly.
7: Compute "Current State" according to formula No. 3
8: if "Current state"  $< (S_t + 1)$  then
9: Set  $r_t = 1$ 
10: else if  $S_t > S_{t+1}$  then
11: Set  $r_t = -1$ 
12: else
13: Set  $r_t = 0$ 
14: end if
15: Obtain reward  $r_t$  and next state  $S_{t+1}$  after execution
   of  $a_t$ .
16: Set this as  $(S_t, a_t, r_t, S_{t+1})$ .
17: Compute the Q-value  $y_t$  from the target deep QL  $y_t =$ 
    $r_{t+1} + \gamma Q(S_{t+1}, a_{t+1})$ 
18: Execute the algorithm of gradient descent to reduce
    $(y_t - q(s_{t+1}, a_{t+1}); \alpha)^2$ 
19: Update q-value:  $q^*(s, a) = (1 - \alpha) q(s, a) +$ 
    $\alpha(R_{t+1} + \gamma q(s_{t+1}, a_{t+1}))$ 
20: end for
```

협업 지원 지능형 오프로딩 연구 동향

- 심층강화학습 기반 지능형 협업 엣지 기술 1





Fig. 2. MDP representation of different methods. (a) Single time slot decision. (b) Deep Q-learning. (c) Deep MCTS.

iRAF: A Deep Reinforcement Learning Approach for Collaborative Mobile Edge Computing IoT Networks, IEEE INTERNET OF THINGS JOURNAL, VOL. 6, NO. 4, AUGUST 2019

협업 지원 지능형 오프로딩 연구 동향

- Blockchain-empowered mobile edge computing 모델 구축
 - Deep reinforcement learning-based online computation offloading






Fig. 1. Multi-hop blockchain-empowered mobile edge computing.

Online Deep Reinforcement Learning for Computation Offloading in Blockchain-Empowered Mobile Edge Computing, IEEE TRANSACTIONS ON VEHICULAR TECHNOLOGY, VOL. 68, NO. 8, AUGUST 2019

강화학습 기반 고속 서비스 이동 기술



Conclusion

- 인터넷 기반 응용 서비스 환경 변화
 - 클라우드-분산 엣지 간 협업 모델 개발에 대한 필요성 대두
 - 이를 통해 분산 클라우드 인프라 구축을 추진 중임
- 분산 클라우딩을 위해 클라우드-엣지 간 컴퓨팅 지원 및 네트워크 자원 관리를 위한 분산-협업 기술 개발 중
 - 딥러닝 기반 분산-협업 지원 기술 개발 중