

O-RAN RIC 구조에서 효율적 네트워크 슬라이스 분류를 위한 KPI 특성 분석

최다영, 박시연, 박형곤

이화여자대학교 전자전기공학과

{dayoung.choi, siyoun0116, hyunggon.park}@ewha.ac.kr

KPI Feature Analysis for Efficient Network Slice Classification in O-RAN RIC

Dayoung Choi, Siyoun Park, Hyunggon Park

Department of Electronic and Electrical Engineering, Ewha Womans University

요약

본 논문에서는 Open Radio Access Network (O-RAN) 환경에서의 효율적인 네트워크 슬라이스 분류를 위해, Colosseum 기반 Key Performance Indicator (KPI) 데이터의 구조를 분석하였다. 상호정보량과 generalized Dunn's Index를 활용하여 KPI 간 종속성과 클래스 간 분리도를 정량적으로 측정하였다. 데이터 분석 결과, KPI 데이터는 소수의 주요 특징이 네트워크 슬라이스 분류 성능을 결정하는 단순한 구조를 가지며, 이러한 희소성은 고차원 표현 학습 없이도 정확한 슬라이스 구분이 가능함을 확인하였다. 분석 결과를 고려하여 네트워크 슬라이스 분류가 수행되는 O-RAN의 RAN Intelligent Controller 구조를 설계한다면, 효율적인 분류기 업데이트와 인터페이스 간 교환되는 정보량의 최소화를 통해 전체 RAN 시스템의 운영 효율을 향상시킬 수 있을 것으로 기대된다.

I. 서론

무선 접속 네트워크(Radio Access Network, RAN)는 기지국과 사용자 단말(user equipments, UEs) 간의 무선 통신을 담당하며, 트래픽 부하, 사용자 이동성, 채널 품질, 서비스 품질 요구사항 등이 시시각각 변화하는 동적 환경을 갖는다. 이러한 환경에서 최적의 네트워크 성능을 유지하기 위해서는, 실시간으로 변하는 네트워크 상태를 감지하고 이에 따라 자원을 효율적으로 재배하는 데이터 기반의 지능형 의사결정이 필수적이다. 이러한 요구를 충족하기 위해 제안된 Open Radio Access Network (O-RAN)은 표준화된 개방형 인터페이스를 통해, 인공지능 및 머신러닝(AI/ML) 기술을 실제 네트워크 운영에 통합할 수 있는 유연한 아키텍처를 제공한다[1]. O-RAN은 전통적인 단일 폐루프 RAN 제어 구조와 달리, AI/ML을 지원하는 비실시간(non-real-time, non-RT) RIC과 근실시간(near-real-time, near-RT) RIC으로 구성된 분산형 지능 제어 구조를 채택하고 있다. 이러한 분산형 구조에서는 모델의 주기적인 학습 및 업데이트 주기의 효율성에 따라 전체 RAN 시스템 성능이 크게 좌우된다. 특히, 데이터의 양이 방대해지고 모델의 복잡도와 학습 비용이 증가할 경우, RIC 전체의 응답성과 효율이 저하되는 문제 가 발생한다. 따라서, 짧은 학습 시간과 낮은 복잡도를 갖는 경량 기법이 실시간 RAN 제어에서 중요해지고 있다.

O-RAN의 핵심 기능 중 하나인 네트워크 슬라이싱(network slicing)은 물리적 인프라를 논리적 슬라이스로 분리하여, 서로 다른 서비스 요구사항을 동시에 충족시킨다. 이때, 각 트래픽 흐름을 올바른 슬라이스로 분류하는 슬라이스 분류(slice classification) 과정은 RIC 내 자원 스케줄링, 서비스 수준 협약(SLA) 관리, 정책 실행의 출발점이 된다[2]. 빈번한 모델 업데이트가 요구되는 RIC 환경에서는 효율적인 운영을 위해서는, 데이터의 복잡도와 모델의 표현 능력(capacity)을 고려하여 AI 모델을 선택하는 것이 중요하기 때문에, 데이터의 특성과 구조를 파악할 수 있는 분석 연구가 선행되어야 한다.

본 연구에서는 O-RAN의 Key Performance Indicator (KPI) 데이터를 대상으로 분석을 수행한다. 상호정보량(mutual information)과 generalized Dunn's Index를 이용해 KPI 데이터의 구조적 단순성과 희소성(sparsity)을 검증함으로써, 효율적인 네트워크 슬라이스 분류가 가능함을 확인하였다.

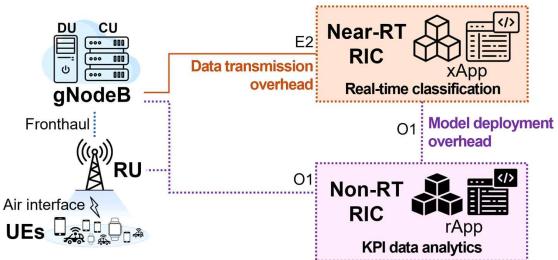


그림 1. O-RAN 아키텍쳐에서의 KPI 데이터 수집·전송·분석 과정

II. 본론

A. O-RAN에서의 KPI 데이터 흐름 및 RIC 구조

그림 1은 O-RAN 아키텍쳐 내에서 KPI 데이터 수집·전송되어 RIC의 두 계층으로 분산되는 과정을 나타낸다. UE는 eMBB (enhanced mobile broadband), URLLC (ultra-reliable and low-latency communications), mMTC (massive machine type communications)와 같은 서비스 유형에 따라 트래픽을 발생시키며, 이 트래픽은 무선부(Radio Unit, RU)를 거쳐 분배부(Distributed Unit, DU)와 중앙부(Central Unit, CU)로 전달된다. RU에서는 물리계층 및 MAC 계층에서 발생하는 다양한 KPI를 주기적으로 측정한다. KPI 특성은 T 시점 동안 수집된 n 개의 벡터 $\mathbf{k}_i \in \mathbb{R}^T$ ($i = 1, 2, \dots, n$) 형태로, 한 시점마다 수집되는 서비스 유형 벡터는 $\mathbf{y} \in \mathbb{R}^T$ 형태이다. non-RT RIC에서는 장기간의 KPI 데이터를 기반으로 데이터 분석과 슬라이스 분류기 학습을 수행하고, near-RT RIC에서는 전달받은 분류기 모델을 이용해 실시간 분류와 자원 제어를 수행한다. 이때, DU에서 RIC으로 데이터 전달 시에 데이터 전송 오버헤드가, non-RT RIC에서 near-RT RIC으로 배포 시에 모델 배포 오버헤드가 발생한다. 따라서, KPI 특성 분석 결과를 기반으로 핵심 KPI만을 선별할 수 있다면, 데이터 전송량을 줄이고 차원이 축소된 데이터로 모델을 학습함으로써 모델 업데이트 부담을 최소화할 수 있다.

본 연구에서는 두 가지 KPI 데이터셋인 COMMAG[4]와 ColO-RAN[5]을

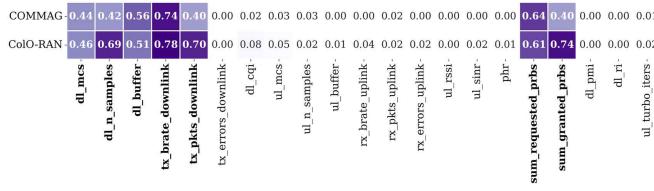


그림 2. KPI 특성별 상호정보량 값(λ_i)

고려한다. 슬라이스 유형은 eMBB, URLLC, mMTC이며, 총 21개($n = 21$)의 KPI로 이루어진다.

B. 상호정보량 기반 KPI 특성 중요도 분석

상호정보량[6]은 두 확률변수 간의 종속성을 나타내는 지표로, 두 확률변수가 공유하고 있는 정보량을 수치화한 값이다. 따라서, $p(\cdot, \cdot)$ 가 두 변수 간 결합 확률 질량 함수, $p(\cdot)$ 가 주변 확률 질량 함수일 때, i 번째 특성 k_i 가 슬라이스 유형 y 에 대해 제공하는 정보량 λ_i 은 다음과 같다.

$$\lambda_i = \sum_{y \in \mathcal{Y}} \sum_{k_i \in \mathcal{K}_i} p(k_i, y) \log \left(\frac{p(k_i, y)}{p(k_i)p(y)} \right) \quad (1)$$

그림 2는 데이터셋에 따른 KPI 특성별 λ_i 를 시각화한 것으로, 대부분의 KPI는 λ_i 가 0.08 이하로 낮았다. 특히, 두 데이터셋이 서로 다른 환경에서 수집되었음에도 불구하고, 단 7개의 KPI만이 0.40 이상의 높은 정보량을 제공하고 있는 것을 확인할 수 있다. 즉, KPI 데이터의 구조가 희소(sparse)하며, 슬라이스 구분에 기여하는 정보는 소수의 특성에만 집중되어 있다는 것을 의미한다. 이는 복잡한 고차원 표현 학습 없이도 슬라이스 간 분리를 달성할 수 있음을 내포한다. 또한, 7개의 핵심 특성은 주로 하향링크(downlink) 차원 및 전송률 관련 지표로, 슬라이스 유형 구분이 주로 하향 전송 차원 사용 패턴에서 비롯되었음을 알 수 있다. 이는 네트워크의 비대칭적 트래픽 구조인 하향 전송 편향(donwlink-heavy) 성격이 KPI 중요도에 반영된 것으로 해석할 수 있다. 구체적으로, 고해상도 영상, 스트리밍의 eMBB, 낮은 지연과 높은 신뢰도를 위한 하향링크 중심 스케줄링의 URLLC 등 실제 5G/6G 슬라이스 서비스의 특성과도 일치한다.

C. generalized Dunn's Index 기반 슬라이스 유형 분리도 분석

상호정보량 분석을 통해 슬라이스 유형 클래스와 강한 종속성을 보이는 핵심 KPI가 실제로 유형 간 분리도를 향상시키는지 검증하기 위해 generalized Dunn's Index[7] ϵ 를 다음과 같이 계산한다.

$$\epsilon = \frac{\min_{1 \leq g < h \leq m} \delta(C_g, C_h)}{\max_{1 \leq l \leq m} \Delta(C_l)} \quad (2)$$

ϵ 은 유형 간 거리 $\delta(\cdot, \cdot)$ 에 대한 유형 내 응집도 $\Delta(\cdot)$ 의 비율로 정의되며, 값이 높을수록 유형 간 분리도가 높음을 의미한다. m 은 슬라이스 유형의 개수이고, $\delta(\cdot, \cdot)$ 은 각 유형의 중심 벡터 간의 마할라노비스 거리로, $\Delta(\cdot)$ 은 유형 내 샘플과 중심 간의 평균 거리를 이용해 산출된다.

표 1은 λ_i 를 내림차순으로 정렬한 후 특성을 하나씩 추가하며 특성 개수에 따른 ϵ 을 나타낸 것이다. COMMAG과 ColO-RAN 두 데이터셋 모두에서, $n = 7$ 개의 KPI만 사용했을 때의 ϵ 이 전체 21개 KPI를 사용했을 때보다 향상되었다. 구체적으로, COMMAG에서는 약 17.06%, ColO-RAN에서는 53.39%로 분리도가 상승하였다. 그러나 n 이 증가함에 따라, 정보량이 적은 KPI가 포함되면 분리도가 점차 감소하는 경향을 보였다. COMMAG에서는 $n = 2$, ColO-RAN에서는 $n = 3$ 일 때 ϵ 이 최대값을 기록하였는데, 이는 슬라이스 유형 간 경계를 결정하는 데 필요한 정보가 매우 소수의 KPI에 집중되어 있음을 의미한다. 즉, 슬라이스 분류를 위한

		generalized Dunn's Index (ϵ)
	COMMAG	ColO-RAN
Number of KPI features (n)	$n = 21$	0.0834
	$n = 7$	0.0977
	$n = 3$	0.1474
	$n = 2$	0.4556
	$n = 1$	0.0569
		0.0780

표 1. KPI 특성 개수(n)에 따른 generalized Dunn's Index 값(ϵ)
KPI 공간은 본질적으로 저차원적이고 희소하며, 추가적인 고차원 특징은 오히려 특성 공간의 잡음을 증가시켜 분리도를 약화시킨다. 결과적으로 generalized Dunn's Index 분석 결과 역시 KPI 데이터가 고차원적 표현 학습을 필요로 하지 않는다는 점을 실증적으로 보여준다.

IV. 결론

본 논문에서는 O-RAN에서 네트워크 슬라이스 분류를 효율적으로 하기 위해 KPI 데이터의 구조적 특성을 상호정보량과 generalized Dunn's Index를 활용하여 분석하였다. 상호정보량을 통해 슬라이스 유형과 공유하고 있는 정보량을 정량적으로 파악하고, generalized Dunn's Index를 통해 슬라이스 유형 간 분리도를 평가함으로써 소수의 핵심 KPI 특성만으로도 높은 구분 성능을 확보할 수 있음을 확인하였다. 이러한 결과는 데이터 차원 축소, 데이터 전송량 절감, 경량 모델 설계로 직접 확장될 수 있으며, O-RAN의 RIC 구조에서 효율적이고 실용적인 슬라이스 분류 시스템을 구현하기 위한 기초적인 근거로 활용될 수 있을 것으로 기대된다.

ACKNOWLEDGMENT

이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원(No. 2021-0-00739, 분산/협력AI 기반 5G+ 네트워크 데이터 분석 기능 및 제어 기술 개발)과 한국연구재단의 지원(No.RS-2025-16066913, No.RS-2025-25431268)을 받아 수행된 연구임.

참 고 문 헌

- [1] O-RAN Alliance, "Towards an Open and Smart RAN," O-RAN Alliance, White Paper, Oct. 2018.
- [2] J. Groen, et al., "TRACTOR: Traffic Analysis and Classification Tool for Open RAN," in *ICC 2024 - IEEE International Conference on Communications*, 2024, pp. 4894 - 4899.
- [3] L. Bonati, et al., "Colosseum: Large Scale Wireless Experimentation Through Hardware-in-the-Loop Network Emulation," in *2021 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*, 2021, pp. 105 - 113.
- [4] L. Bonati, et al., "Intelligence and Learning in O-RAN for Data-driven NextG Cellular Networks," *IEEE Communications Magazine*, vol. 59, no. 10, pp. 21 - 27, October 2021.
- [5] M. Polese, et al., "ColO-RAN: Developing Machine Learning- Based xApps for Open RAN Closed-Loop Control on Programmable Experimental Platforms," *IEEE Transactions on Mobile Computing*, vol. 22, no. 10, pp. 5787 - 5800, 2023.
- [6] Shannon, C. E., "A Mathematical Theory of Communication," *The Bell System Technical Journal*, vol. 27, no. 3, pp. 379-423, 1948.
- [7] J. Bezdek and N. Pal, "Cluster validation with generalized dunn's indices," in *1995 Second New Zealand International Two-Stream Conference on Artificial Neural Networks and Expert Systems*, 1995, pp. 190 - 193.