

DDPG 및 연합학습 기반 5G 네트워크 자원 할당과 트래픽 예측

(5G Network Resource Allocation and Traffic Prediction based on DDPG and Federated Learning)

박석우*, 이오성*, 나인호**

(Seok-Woo Park, Oh-Sung Lee, In-Ho Ra)

요약

향상된 모바일 광대역(eMBB), 초저지연 및 고신뢰 통신(URLLC), 대규모 기계형 통신(mMTC) 등의 특징을 가진 5G의 등장으로 인해 효율적인 네트워크 관리와 서비스 제공을 위해 증가하는 네트워크 트래픽과 복잡성 해결이 시급한 상황이다. 본 논문에서는 기계학습(Machine Learning, ML) 및 딥러닝(Deep Learning, DL) 기술을 활용하여 5G 네트워크의 초고속, 초저지연, 초연결성이라는 주요 과제를 해결하면서 네트워크 슬라이싱 및 자원 할당을 동적으로 최적화하는 새로운 접근 방식을 제시한다. 제안된 기법에서는 네트워크 트래픽 및 자원 할당에 대한 예측 모델, 네트워크 대역폭 및 지연 시간을 최적화하면서 동시에 개인 정보와 보안을 향상시키기 위한 연합 학습(FL) 기법을 사용한다. 특히, 본 논문에서는 랜덤 포레스트와 LSTM 등 다양한 알고리즘과 모델의 구현 방법에 대해 자세히 다루며, 이를 통해 5G 네트워크 운영의 자동화와 지능화를 위한 방법론을 제시한다. 마지막으로 제안된 기법을 통해 5G 네트워크에 ML 및 DL을 적용하여 얻을 수 있는 성능 향상 효과를 성능평가 및 분석을 통해 검증하고 다양한 산업 응용 분야에서 네트워크 슬라이싱 및 자원 관리 최적화를 위한 솔루션을 제시한다.

■ 중심어 : 5G 네트워크 ; 네트워크 슬라이싱 ; 자원 할당 ; 기계 학습 ; 연합 학습

Abstract

With the advent of 5G, characterized by Enhanced Mobile Broadband (eMBB), Ultra-Reliable Low Latency Communications (URLLC), and Massive Machine Type Communications (mMTC), efficient network management and service provision are becoming increasingly critical. This paper proposes a novel approach to address key challenges of 5G networks, namely ultra-high speed, ultra-low latency, and ultra-reliability, while dynamically optimizing network slicing and resource allocation using machine learning (ML) and deep learning (DL) techniques. The proposed methodology utilizes prediction models for network traffic and resource allocation, and employs Federated Learning (FL) techniques to simultaneously optimize network bandwidth, latency, and enhance privacy and security. Specifically, this paper extensively covers the implementation methods of various algorithms and models such as Random Forest and LSTM, thereby presenting methodologies for the automation and intelligence of 5G network operations. Finally, the performance enhancement effects achievable by applying ML and DL to 5G networks are validated through performance evaluation and analysis, and solutions for network slicing and resource management optimization are proposed for various industrial applications.

■ keywords : 5G Networks ; Network Slicing ; Resource Allocation ; Machine Learning ; Federated Learning

I. 서론

5세대(5th Generation, 5G) 네트워크는 향상된 모바일 광대역(enhanced Mobile BroadBand,

* 정회원, 군산대학교 전자정보공학부

** 정회원, 군산대학교 컴퓨터소프트웨어학부

이 논문은 2023년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2021R1A2C2014333).

접수일자 : 2024년 04월 22일

게재확정일 : 2024년 04월 26일

교신저자 : 나인호 e-mail : ihra@kunsan.ac.kr

eMBB), 고신뢰·저지연(ultra-Reliable and Low Latency Communications, uRLLC), 대용량(massive Machine-Type Communications, mMTC) 지원 특성을 기반으로 산업과 일상생활에서 디지털 시대 전환 가속화와 초연결사회 구현을 주도하고 있다[1]. 4G/LTE 세대를 초월하는 향상된 성능을 제공하는 5G는 스마트팩토리, 자율주행 자동차, 원격의료, 무인 자동화, 사물인터넷(Internet of Things, IoT), 홀로그램 등과 같은 다양한 산업 분야에서 폭넓게 활용되고 있으며[2-5], 이로 인하여 5G 네트워크 트래픽이 급격히 증가하고 있다. 또한, 5G 네트워크 기능 고도화와 사용자 수요 증가로 인하여 네트워크 관리의 복잡성 또한 증가하고 있으며, 이로 인한 네트워크 지연 및 데이터 손실 증가, 보안성 취약 등의 문제가 발생하고 있다[6]. 네트워크 복잡성 증가로 발생하는 문제는 사용자 경험 대한 부정적인 영향을 미칠 수 있으며, 이를 해결하기 위해 네트워크 자동화와 인공지능(Artificial Intelligence, AI), 기계학습(Machine Learning, ML)을 적용한 기술의 필요성이 중요시되고 있다. AI 및 ML을 이용하여 네트워크 트래픽을 실시간으로 분석하고 최적화함으로써 네트워크 관리의 효율성을 향상시키며, 승인 제어[7], 자원 할당[8], 자원 오케스트레이션[9], 자원 스케줄링[10] 등과 같은 고도화된 기능을 자동화하여 오류를 감소하기 위한 연구가 지속적으로 수행되고 있다.

그러나, 기술적인 진보에도 불구하고 대규모 네트워크에서 중앙집중식 처리 방식인 AI는 다양한 문제에 직면하고 있다. 특히, 중앙집중식 처리 방식은 지연 시간과 대역폭 소비를 증가시키고 개인정보 보호 및 보안 문제를 일으킬 우려가 있다. 이에 대한 대응책으로 연합학습(Federated Learning, FL)이라는 혁신적인 접근 방식이 제안되고 있다[11, 12]. FL은 사용자 장치(User Equipment, UE)의 데이터를 로컬 영역에서 처리하고 모델 학습을 통해 중앙 서버로 불필요한

데이터 전송을 감소시킨다. 이에 따라, 네트워크의 대역폭 효율성 향상 및 모델의 효율성을 개선하고 개인정보 보호 및 보안을 강화하는 잇점을 제공하며, 분산된 네트워크 환경에서 AI 및 ML의 적용 가능성을 확장할 수 있다. 이에 따라 FL은 5G 네트워크의 효율적인 운영과 지속 가능한 성장을 위한 핵심 요소로 자리 잡고 있다.

본 논문에서는 지능형 5G 네트워크 환경에서 효율적인 자원 관리를 위한 새로운 기법을 제안한다. 이를 위해, UE의 다양한 요구 사항을 효율적으로 분류하고 관리하기 위한 랜덤 포레스트(Random Forest, RF) 기반 슬라이스 분류 기법을 제시하고 실제 네트워크 환경에 적용하기 위한 최적의 결정 트리[13]를 결정하며, 최적의 결정 트리 수를 통해 다양한 요구 사항에 따른 네트워크 트래픽을 효율적으로 관리할 수 있는 기법을 제안한다. 또한, FL 기반 장단기 메모리(Long Short-Term Memory, LSTM) 모델을 활용하여 네트워크 슬라이스의 트래픽을 예측하고자 하며, 이것은 각각의 슬라이스 트래픽 예측을 통해 네트워크 자원 할당 및 관리를 정확하게 수행하기 위해 필요하다[14]. 이와 함께, 심층 결정 정책 그래디언트(Deep Deterministic Policy Gradient, DDPG) 기반의 자원 할당 기법과 GraphSAGE 모델을 이용하여 복잡한 네트워크 구조를 파악함으로써 5G 코어망에서 최적의 자원 할당을 수행하고 관리하는 기법을 제시한다[15, 16].

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구에 대해 기술하고 3장에서는 본 논문에서 제안하는 시스템 모델에 대해 상세히 기술한다. 4장에서는 5G RAN에서 슬라이스 분류 및 슬라이스 트래픽 예측 기법, 5G 코어망에서 최적의 가상 네트워크 기능(Virtual Network Functions, VNFs) 배치를 위한 DDPG 모델에 대해 기술한다. 5장에서는 제안된 기법의 성능 검증을 수행하며, 마지막으로 6장에서는 결론을 맺는다.

II. 관련 연구

1. ML 및 RL을 적용한 5G 네트워크 슬라이싱

5G 네트워크 환경에서 네트워크 슬라이싱을 구현하는 ML과 RL 기반 프레임워크의 효율성 증진과 최적화에 대한 연구는 네트워크 슬라이스의 생성, 배치, 관리, 자원 할당, 트래픽 조정, 네트워크 기능 배포 등으로 구성되며, 이에 관련된 연구는 표 1에 요약되어 있다.

DeepSlice 모델은 DL을 활용하여 네트워크 부하를 효율적으로 관리하고 가용성을 보장하며, 네트워크 장애 발생 시 문제 해결형 슬라이싱 결정을 수행한다[17]. DeepSlice는 슬라이스 선택, 예측 정확성, 트래픽 기반 자원 할당에 중점을 두고 있다.

RAN 슬라이싱 기반의 동적 가상 자원 할당 기법은 외부 환경과의 상호 작용에 적응하여 자원을 동적으로 조정한다[18]. 또한, 전력 제어와 하위 채널 할당을 최적화하고 동적 프로그래밍과 분산 온라인 학습을 통합한다. 5G 데이터 센터 네트워크에서는 효율적 네트워크 슬라이싱과 자원 할당이 센터 운영 측면에서 매우 중요한 역할을 담당한다. 이 기법은 동일한 네트워크 토폴로지 내에서 자원을 공유하면서 다양한 슬라이스

에 대해 효율적인 라우팅이 이루어질 수 있도록 지원한다.

HA-DRL 접근 방식은 네트워크 슬라이스 배치 최적화를 위해 A2C와 GCN을 결합하였으며, P2C 기반 휴리스틱 기법으로 DRL 프로세스를 강화하였다[19]. 이 외에도 SDN 및 NFV에 기초하여 VNF-P 문제를 해결하기 위한 하이브리드 휴리스틱-메타휴리스틱 모델이 제안된 바 있으며, 이 기법은 실시간 VNF 배치 및 최적화를 위해 다수의 프리미티브 휴리스틱 기법과 GA를 활용하여 하이퍼 파라미터를 조정한다[20].

2. FL 기반 네트워크 슬라이싱

최근 들어 FL(Federated Learning)을 활용한 5G 네트워크 최적화 연구가 활발히 진행되고 있다. 표 2는 5G 네트워크에서 FL을 활용한 네트워크 슬라이싱 기법에 관련된 최근 연구의 특징을 나타낸 것이다.

Zhao[12] 등은 5G 네트워크의 두 가지 대표적인 응용 사례인 엣지 컴퓨팅(Edge Computing)과 산업용 사물 인터넷(Industrial IoT, IIoT)을 위한 에너지 효율적 자원 할당 기법을 제안한 바 있다. 이 기법은 기지국과 사용자 간의 연결 관계와 기지국이 할당한 전송 전력을 결정 변수로

표 1. ML 및 DL 기반 네트워크 슬라이스 및 자원 할당 요약

Objective	Key Features	Results/Performance
To efficiently manage network slicing in 5G networks using a deep learning neural network[17]	Selects appropriate network slices for user devices; predicts traffic based on various KPIs.	Demonstrates efficient and reliable network slicing.
To propose a dynamic virtual resource allocation scheme for 5G and beyond network slicing[18]	Involves power control and subchannel allocation; uses online stochastic learning algorithm.	Improves user transmission rate and meets delay requirements.
To address the challenge of network slice placement in 5G networks using a Deep Reinforcement Learning (DRL) approach[19]	Combines Advantage Actor Critic and Graph Convolutional Network (GCN); uses Power of Two Choices based heuristic.	Shows promise in simulations for effectively placing network slices.
To address the challenge of Virtual Network Function Placement (VNF-P) in SDN and NFV environments using a hybrid heuristic-metaheuristic learning model[20]	Combines multi-criteria heuristic for online VNF placement and Genetic Algorithm for learning hyperparameters.	Minimizes total power consumption in NFV infrastructure.

표 2. ML 및 DL 기반 네트워크 슬라이스 및 자원 할당 요약

Objective	Key Features	Results/Performance
Propose an energy-efficient resource allocation method for edge computing and IIoT in 5G networks[21]	Utilize the relationship between base stations and users, and the transmission power allocated by base stations as decision variables for energy efficiency.	Minimize overall energy efficiency while ensuring QoS for mobile users.
Predict service-oriented KPIs of network slices in 5G networks to achieve Zero Touch Management (ZSM) using Federated Learning (FL)[22]	Train local models for each network slice's data and aggregate using FedAvg algorithm to predict KPIs while considering privacy constraints.	Enable scalable management of network slices and optimal performance within privacy constraints.
Use FL for dynamic scaling of VNF resources across multiple domains in 5G-and-beyond networks[23]	Apply deep learning models like LSTM and GRU for VNF scaling and use GANs to generate synthetic data in each domain.	Use FL for training without data sharing, ensuring privacy and efficient resource allocation.

활용하는 방법을 통해 전체 에너지 소모량을 최소화하는 동시에 모바일 사용자를 위한 서비스 품질(Quality of Service, QoS)을 보장하는 것을 목표로 한다.

한편, Brik[22] 등은 네트워크 슬라이스의 성능, 특히 FL을 이용하여 KPI를 모니터링 및 예측하여 5G 네트워크 슬라이스의 제로 터치 네트워크 서비스 관리(Zero-touch Network and Service Management, ZSM)를 수행하기 위한 서비스 중심 KPI 예측 기법을 제안한 바 있다[22]. 이 기법은 각 네트워크 지역 데이터에 대한 로컬 모델을 훈련하고 이것들을 FedAvg 알고리즘을 이용하여 통합함으로써 글로벌 모델 학습 효과를 획득하는 특징을 지닌다. 이 방식은 네트워크 슬라이스의 확장 가능한 관리가 가능하며, 개인 정보 보호 제약 조건하에서도 일정 수준의 성능 향상을 보장한다.

Verma[23] 등은 네트워크 슬라이싱 기반 5G 통신망에서 다양한 사용자 요구를 지원하고 자원을 효율적으로 활용하기 위한 방법으로 FL 모델을 기반으로 다중 도메인 VNF 자원을 동적으로 확장하는 기법을 제안하였다. 이 기법은 훈련 데이터를 각 도메인 내부에 유지하도록 하고 공유 모델을 통해 로컬에서 계산된 업데이트를 집계하여 학습하는 FL 방식을 활용하였으며, LSTM 및 게이트 순환 유닛(Gate Recurrent

Unit, GRU)과 같은 DL 모델을 VNF 스케일링에 적용하였다. 또한, 생산적 적대 신경망(Generative Adversarial Networks, GAN)을 사용하여 여러 도메인으로부터 합성 데이터를 생성하여 예측 결과를 개선한 바 있다.

III. 시스템 모델

1. RAN 네트워크

본 논문에서는 그림 1에 나타난 것과 같은 RAN 네트워크 모델을 사용하며, UE(User Equipment, UE), 기지국(Base Station, BS), 모바일 엣지 컴퓨팅 (Mobile Edge Computing, MEC) 장비로 구성된다. UE로부터 발생한 데이터는 BS를 경유하여 MEC로 전달 및 처리된다. 이때 RAN에서 수행하는 주요 작업은 다음과 같다. 먼저, 다양한 요구사항을 가진 UE를 기반으로 슬라이스를 분류하며, 이것은 각 슬라이스의 KPIs를 통해 이루어진다. 다음, 중앙집중식 ML 및 DL 모델의 한계를 극복하기 위해 FL을 사용하여 각 슬라이스의 트래픽을 분류한다.

RAN 네트워크의 BS는 클라우드에서 제공하는 글로벌 모델을 바탕으로 로컬 학습을 수행한다. 또한, 다수의 BS들은 물리 네트워크 인프라를 공유하며, 이를 통해 다중 슬라이싱이 가능해




그림 1. RAN 네트워크 아키텍처

진다. UE는 여러 기지국에 연결될 수 있다. 각 기지국은 트래픽 데이터를 수집하여 각 슬라이스의 트래픽을 예측하고, 이를 기반으로 로컬 모델을 훈련시킨다. 훈련된 로컬 모델의 매개변수는 클라우드로 전송되며, 클라우드는 이러한 매개변수들을 통합하여 글로벌 모델을 업데이트한다.

본 논문에서는 BS를 $B = \{b_k \mid k = 1, 2, \dots, K\}$ 로 정의하며, 네트워크 슬라이스는 $S = \{s_i \mid i = 1, 2, \dots, S\}$ 로, 각 슬라이스의 트래픽 용량은 $L_i = \{l_1^i, l_2^i, \dots, l_K^i\}$ 로 표현한다. 그리고, 각 BS에서 수집된 시계열 데이터는 $l_k^i(t) = \{x_t, x_{t-1}, \dots, x_{t-T+1}\}$ 로 나타낸다.

2. Core 네트워크

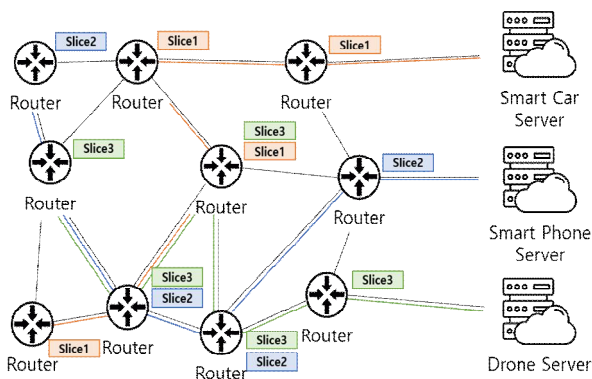


그림 2. 코어 네트워크 아키텍처

본 논문에서 제시하는 코어 네트워크는 그림 2와 같이 물리적 네트워크를 무방향 그래프 $G = (V, E, M)$ 로 모델링 된다. 그래프 G 에서 V 는 물리 노드들의 집합을 나타내고, E 는 임의의 노드 v 와 u 를 연결하는 링크들의 집합을 의미한다. 또한, M 은 VNF 인스턴스를 나타낸다. 각 노드 v 는 $v \in V$ 이고 각 링크 e 는 $e \in E$ 이며, VNF 인스턴스는 방화벽, 라우터, 로드 밸런서, 침입 탐지 시스템(Intrusion Detection System, IDS) 등 슬라이스들이 필요한 기능들을 포함한다. 각 물리 노드의 자원은 CPU, 메모리 및 에너지로 구분되고, 링크의 자원은 대역폭, 지연으로 정의된다.

반면, 요청된 SFC의 요구사항은 방향 그래프인 $G' = (V', E')$ 로 나타낸다. 이 그래프에서 V' 는 가상 노드들의 집합을 나타내고, E' 는 가상 링크들의 집합을 나타낸다. SFC가 요구하는 자원에는 CPU가 rsc_f^{cpu} , 메모리가 rsc_f^{mem} , 대역폭이 rsc_f^{bw} 로 표현된다. 요청된 각 SFC의 트래픽 흐름은 f 로 표시되며, 특정 시간 t 에서의 흐름 집합은 F_t 로 표현된다.

IV. 제안된 모델

1. RF 기반 네트워크 슬라이스 분류

본 논문에서는 네트워크 슬라이스 분류를 위해 RF 기법을 사용한다. RF는 여러 결정 트리의 앙상블로 구성되어 있어 예측 정확도가 높으며, 데이터를 부트스트랩(Bootstrap) 방식으로 샘플링하여 각 트리를 구성하고 최종 예측은 각 트리 결과의 평균으로 결정한다. 이것은 데이터 노이즈의 영향을 최소화할 수 있으며, 특성 중요도 평가에 활용할 수 있어 네트워크 슬라이스 분류 과정에서 다양한 이점을 제공한다. 그림 3은 결정 트리 기반 ML 모델을 나타내며, 다양한 데이터로 훈련된 여러 트리의 결과로 예측한다. 입력 데이터는 훈련과 테스트 비중은 80:20으로 분할

하여 모델의 정확성을 평가한다.

(3)




그림 3. RF 기반 네트워크 슬라이스 분류

2. FL-LSTM 기반 네트워크 트래픽 예측

본 논문은 FL과 LSTM을 결합하여 네트워크 트래픽 예측을 수행한다. LSTM은 시간적 데이터 종속성을 파악하는 데 탁월한 모델이며, 특히 5G 네트워크에서의 트래픽 패턴 예측에 적합하다. LSTM을 통한 트래픽 예측은 식 (1)과 같다.

$$\hat{y}_{k,t+1}^i = LSTM(l_k^i(t), \omega_{k,t}^i) = l_k^i(t+1) \quad (1)$$

여기서, $LSTM(\cdot)$ 은 모델을 나타내며, $\omega_{k,t}^i$ 는 모델의 가중치이다. 이를 통해 각 BS의 트래픽을 예측할 수 있다. 각 BS는 네트워크 슬라이스를 지원하고, FL 참여 여부는 $\delta_{k,i} \in \{0, 1\}$ 로 표현되며, 참여하는 경우는 $\delta_{k,i} = 1$ 이고, 참여하지 않는 경우는 $\delta_{k,i} = 0$ 이다.

글로벌 모델은 참여하는 각 BS의 훈련된 매개변수를 집계하여 갱신되며, 각 네트워크 슬라이스에 대한 글로벌 모델 업데이트는 식(2)로 표현될 수 있다.

$$g_i(t) = \frac{1}{D_T^i} \sum_{k=1}^K \delta_{k,i} D_{k,T}^i \omega_{k,t}^i \quad (2)$$

여기서, $D_{k,T}^i$ 는 BS의 데이터 양을 나타내고 $\sum_{k=1}^K D_{k,T}^i$ 는 i 번째 슬라이스의 총 데이터 양을 의미한다. 이 데이터를 기반으로 각 BS의 매개변수를 수집하여 글로벌 모델을 업데이트하며, 이는 식(3)으로 표현된다.

$$\omega_{k,t+1}^i = g_i(t)$$

$$- \lambda \sum_{k=1}^K \frac{1}{D_{k,T}^i} \delta_{k,i} \nabla L(LSTM(l_k^i(t), \omega), y_{k,t+1}^i)$$

여기서, λ 는 학습률을 나타내며, $\nabla L(\cdot)$ 은 ω_i 의 기울기를 나타내고, $y_{k,t+1}^i$ 는 다음 시간 단계의 실제 값이다. FL 기반 트래픽 예측의 목표는 오차 최소화과 예측 정확도를 최대화하는 것이며, 오차 계산은 식 (4)로 나타낼 수 있다. 최종적으로 FL-LSTM 훈련 과정은 알고리즘 1과 같다.

$$\min_{\omega} \frac{1}{K} \sum_{k=1}^K \sum_{t=1}^T L(LSTM(l_k^i(t), \omega_{k,t}^i), y_{k,t+1}^i) \quad (4)$$

Algorithm 1. FL-LSTM based Traffic Prediction

```

1: Input : Number of Clients(K)
2: Output : Final global model parameters vectors
   ( $\omega_{eMBB}, b_{eMBB}, \omega_{URLLC}, b_{URLLC}, \omega_{mMTC}, b_{mMTC}$  )
3: Server side:
4: Initialize global LSTM model parameters
   ( $\omega_{eMBB}, b_{eMBB}, \omega_{URLLC}, b_{URLLC}, \omega_{mMTC}, b_{mMTC}$  )
5: While True:
6:    $N \leftarrow$  Check participating clients(K)
7:   for  $k = 1, 2, \dots, K$  do
8:     if  $b_k \in N$  then
9:       Send global model parameter to client( $b_k$ )
10:    end if
11:  end for
12:  for  $k = 1, 2, \dots, K$  do
13:    if  $b_k \in N$  then
14:       $eMBB\_w_i \leftarrow$  trained client eMBB weight
15:       $URLLC\_w_i \leftarrow$  trained client URLLC weight
16:       $mMTC\_w_i \leftarrow$  trained client mMTC weight
17:       $i \leftarrow i+1$ 
18:    end if
19:     $\omega_{eMBB}, b_{eMBB} \leftarrow$  FedAvg( $eMBB\_w_i$ )
20:     $\omega_{URLLC}, b_{URLLC} \leftarrow$  FedAvg( $URLLC\_w_i$ )
21:     $\omega_{mMTC}, b_{mMTC} \leftarrow$  FedAvg( $mMTC\_w_i$ )
22:  end While
23: Client side:
24: Receive global parameters( $\omega_{eMBB}, b_{eMBB}, \omega_{URLLC}, b_{URLLC}, \omega_{mMTC}, b_{mMTC}$ ) and Initialize local LSTM models
25: For each slice type[eMBB, URLLC, mMTC] do
26:    $LSTM(\omega_{type}, b_{type}) \leftarrow \sum_{(x,y) \in b} lstm(\omega_{type}, x, y)$ 
27: end for

```

3. DDPG 기반 VNF 배치 및 관리 기법

가. 제약 사항

5G CN의 높은 대역폭, 낮은 지연 시간, 대규모 연결성을 제공하기 위해 VNF 배치 시 CPU, 메모리, 대역폭 등의 제약 조건을 고려해야 한다. 이러한 조건은 식 (5)부터 식 (7)까지 표현된다.

$$\sum_{m \in M} \sum_{f \in F_t} rsc_{f,m}^{cpu} \delta_{f,m}^v \leq C_v^{cpu} \omega_v^{cpu} \quad (5)$$

$$\sum_{f \in F_t} rsc_f^{mem} \delta_f^v \leq C_v^{mem} \omega_v^{mem} \quad (6)$$

$$\sum_{f \in F_t} rsc_f^{bw} \delta_f^e \leq C_e^{bw} \omega_e^{bw} \quad (7)$$

여기서, $\delta_{f,m}^v$, δ_f^v , δ_f^e 는 SFC의 물리적 네트워크 매핑을 나타내는 이진 변수이며, $rsc_{f,m}^{cpu}$, rsc_f^{mem} , rsc_f^{bw} 는 요구되는 CPU, 메모리, 대역폭 자원을 나타낸다. C_v^{cpu} , C_v^{mem} , C_e^{bw} 는 노드 및 링크의 최대 용량을 의미하고, ω_v^{cpu} , ω_v^{mem} , ω_e^{bw} 는 자원의 사용 비율을 나타낸다. 여러 VNF 인스턴스를 하나의 노드에 배치하는 CPU 제약은 식 (8)로 표현할 수 있다.

$$\sum_{f \in F_t} rsc_{f,m}^{cpu} \delta_{f,m}^v \leq C_m^{cpu} \omega_m^{cpu} \quad (8)$$

물리적 노드의 에너지 소비는 VNF 인스턴스 처리 여부에 따라 구분되며, 이는 식 (9)로 정의된다.

$$\begin{cases} \sum_{f \in F_t} (e_v^{cpu} + e_v^{send} + e_v^{rec}) \delta_{f,m}^v \leq C_v^{energy} \omega_v^{energy} \\ \sum_{f \in F_t} (e_v^{send} + e_v^{rec}) \delta_{f,m}^v \leq C_v^{energy} \omega_v^{energy} \end{cases} \quad (9)$$

여기서 e_v^{cpu} , e_v^{send} , e_v^{rec} 는 노드에서의 처리, 전송, 수신 에너지를 나타내며, 각 노드의 에너지 사용량은 최소 잔여 에너지 임계값 이상이어야 한다.

네트워크의 E2E 지연 시간은 SFC의 서비스 마감 시간 요구사항을 만족하며, 이는 식 (10)로 정의된다.

$$\sum_t \sum_{f \in F_t} (t + \frac{VNF_{load}}{Proc_v} - 1) \delta_{f,m}^v \leq Delay_f \quad (10)$$

여기서, t 는 VNF 실행 시간을 나타내고, 이는 VNF의 부하(VNF_{load})와 노드 처리 속도($Proc_v$)를 통해 계산할 수 있다. $Delay_f$ 는 SFC의 마감

시간을 의미한다.

나. 최적화 목적

본 논문에서는 인터넷 서비스 제공자(Internet Service Provider, ISP)의 수익과 비용, 네트워크 슬라이싱 제공을 통한 SFC 수용률, VNF 배치 및 운영 비용, 에너지 소비를 고려하여 최적의 VNF 배치를 결정한다. 수익은 ISP가 가상 네트워크 요청을 수락함으로써 발생하며, 사용한 자원의 양과 시간에 따라 변한다. 이 수익은 식 (11)을 통해 계산된다.

$$R = \sum_{v' \in V'} [CPU(v') + Mem(v')] + \sum_{e' \in E'} BW(e') \quad (11)$$

여기서, $CPU(v')$ 와 $Mem(v')$, $BW(e')$ 는 각각 가상 노드와 링크에 필요한 컴퓨팅 지원, 메모리, 대역폭을 의미한다. 자원 요구량이 높을수록 ISP의 수익이 증가함을 알 수 있다.

5G 네트워크의 VNF 배치 비용 함수는 배치 결정의 효율성 측정 및 최적화에 필수적이다. 이 함수는 가상 요청 수락 시 발생하는 비용을 계산하며, 식 (12)로 나타낼 수 있다.

$$C = D + F \quad (12)$$

비용 함수는 SFC 매핑 시 노드와 링크의 대역폭 사용량을 계산하는 데 사용된다.

SFC 수용률은 식 (13)으로 정의된다.

$$U = \sum_{f \in F_t} c^{penalty} (1 - I(\sum_{v \in V} n_f^v > 0)) \quad (13)$$

여기서, $c^{penalty}$ 는 요청된 SFC가 거부될 경우 부과되는 패널티를 나타낸다.

VNF 배치 비용은 특정 시점의 자원 요구사항, 자원 가용성, 경로의 대역폭과 지연 시간을 기반으로 계산되며, 식 (14)와 같이 표현될 수 있다.

$$D = c^{place} \sum_{v \in V_m \in M} \max\{\delta_{f,m}^v, 0\} \quad (14)$$

여기서, c^{place} 는 VNF 배치에 소요되는 비용을

나타낸다.

VNF 운영 비용은 실행 및 관리에 사용되는 총 비용으로, 자원 사용과 라이선스 비용을 포함하며, 식(15)로 표현된다.

$$F = \Delta t \sum_{v \in V_m \in M} \delta_{f,m}^v \quad (15)$$

서버, 스토리지, 네트워크 장비에서의 VNF 전력 소비는 각 노드의 VNF 배치에 따라 달라지며, 에너지 소비는 식 (16)으로 표현된다.

$$E = c^{energy} \sum_{f \in F_t} \sum_{v \in V_m \in M} \max\{n_{f,m}^v, 0\} \quad (16)$$

여기서, c^{energy} 는 에너지 소비와 관련된 비용을 의미한다.

따라서, 본 논문에서 최적의 VNF 배치를 위한 최적화 문제는 식(17)으로 정의된다.

$$\underset{\delta_f^v, \delta_p^v, \delta_{f,m}^v}{\text{Minimize}} (\eta_1 U + \eta_2 D + \eta_3 F + \eta_4 E) - \eta_5 R \quad (17)$$

여기서, $\eta_1, \eta_2, \eta_3, \eta_4$ 는 가중된 비용을 나타내며, 이를 최소화하는 것이 최적화의 목표이다.

다. DDPG 및 GraphSAGE 모델

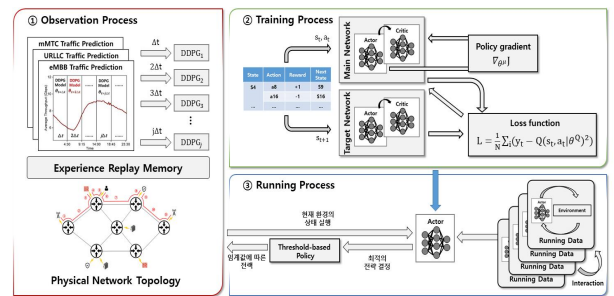


그림 4. DDPG 기반 최적의 VNF 배치 기법

본 논문에서는 DDPG 모델을 사용하여 최적의 VNF 배치를 제안한다. DDPG는 실시간 의사 결정, 확장성, 적응성을 갖추고 대규모 네트워크에서 네트워크 성능과 자원 할당을 최적화한다. 즉, 서비스 요구사항 충족, 자원 효율성 극대화, 네트워크 처리량 증가 및 지연 시간 감소를 목표로 운영 비용 및 에너지 소비를 최고화한다.

DDPG 모델을 구현하기 위해, 본 논문에서는 마르코프 결정 과정(Markov Decision Process, MDP)을 사용하며. 상태 공간 S 는 $\{s_1, s_2, \dots, s_T\}$ 로 표현되고 행동 공간 A 는 물리적 네트워크 내의 노드를 선택하는 $a \in A$ 로 나타낸다. 보상 R 은 서비스 요구 사항을 충족하는 최적의 VNF 배치를 위해 정의된다. 또한, 그림 4와 같이 Actor-Critic 아키텍처를 활용하여 상태와 행동의 쌍을 기반으로 네트워크를 구성하며, 두 개의 은닉층을 사용한다.

GraphSAGE[24]는 대규모 그래프에서 네트워크 토폴로지를 분석하여 노드 임베딩을 생성하는 알고리즘으로서 이웃 노드 샘플링과 집계를 통해 보이지 않는 노드에 대한 임베딩을 수행한다.

GraphSAGE에서는 알고리즘 2와 같이 5G 코어 네트워크 그래프(G)와 노드의 특징 행렬 X_t 가 입력으로 사용되며, 최종적으로 노드 임베딩 결과로 Z_t 가 출력된다. GraphSAGE는 이웃 노드 정보를 활용하여 각 노드의 임베딩을 업데이트하기 위해 이웃 노드 샘플링을 수행하며, 이러한 과정은 다음 식 (18)과 같이 나타낸다.

$$N(v_i) = \begin{cases} v_i, & k = 0 \\ \Phi(v_i), & k = 1, 2, \dots, K \end{cases} \quad (18)$$

여기서, n_i 는 i 번째 노드를 의미하며, $\Phi(\cdot)$ 는 이웃 노드의 집합을 의미한다.

샘플링된 이웃 노드 $N(v_i)$ 는 집계 함수를 통해, k 번째 계층에서 해당 노드의 이웃 노드들의 특징을 집계하며, 다음 식 (19)와 같다.

$$h_{N(v_i)}^k = A(h_{u_j}^{k-1} \mid \forall u_j \in N(v_i)) \quad (19)$$

여기서, A 는 집계 함수를 의미하며, 집계 함수는 식(20)과 같이 정의된다.

$$h_{N(v_i)}^k = \frac{1}{N(v_i)} \sum_{v_j \in N(v_i)} P_{drop}^\rho(h_j^{k-1}) \quad (20)$$

이후, 식 (21)과 같이 집계된 정보를 통해 각 노

드의 임베딩을 업데이트한다. 마지막으로, 식 (22)와 같이 업데이트된 임베딩을 정규화하여 최종적인 임베딩 결과를 구한다.

$$h_{v_i}^k = \sigma(W^k \cdot \text{CONCAT}(h_{v_i}^{k-1}, h_{N(v_i)}^k)) \quad (21)$$

$$h_v^k \leftarrow \frac{h_v^k}{\|h_v^k\|_2} \quad (22)$$

여기서, W_k 는 학습 가중치 행렬이고, σ 는 비선형 활성화 함수를 의미한다. CONCAT은 h_v^{k-1} 와 $h_{N(v_i)}^k$ 간의 관계 함수이다.

Algorithm 3 DDPG Training & Running Procedure

Training :	
1:	Randomly initialize critic network $Q(s, a; \theta^Q)$ and actor $\mu(s; \theta^\mu)$ with weights θ^Q and θ^μ
2:	Initialize target network Q' and μ' with $\theta^{Q'}$, $\theta^{\mu'}$
3:	Initialize replay buffer R
4:	for $episode = 0, 1, \dots, M$ do
5:	Initialize a random process N for action exploration
6:	Receive initial observation state s_1
7:	for $t = 0, 1, \dots, T$ do
8:	Select action $a_t = \mu(s_t; \theta^\mu) + N_t$ according to the current policy θ^μ and exploration noise N_t
9:	Execute action a_t and observe reward r_t and observe new state s_{t+1}
10:	Store a random mini-batch of N transitions (s_t, a_t, r_t, s_{t+1}) from D
11:	Set $y_t = r_t + \gamma Q'(s_{t+1}, \mu'(s_{t+1}) \mid \theta^{\mu'}) \mid \theta^{Q'}$
12:	Update critic by minimizing the loss: $L = \frac{1}{B} \sum_t (y_t - Q(s_t, a_t; \theta^Q))^2$
13:	Update the actor policy using the sampled gradient: $\nabla_{\theta^\mu} J \approx \frac{1}{B} \sum \nabla_a Q(s_t, a_t; \theta^Q) \nabla_{\theta^\mu} \mu(s; \theta^\mu) \mid_{s_t}$
14:	Update the target network: $\theta^{Q'} \leftarrow \tau \theta^{Q'} + (1 - \tau) \theta^Q$ $\theta^{\mu'} \leftarrow \tau \theta^{\mu'} + (1 - \tau) \theta^\mu$
15:	end for
16:	end for
Running :	
18:	$a^* \leftarrow$ Get the best action with the highest reward from A:
19:	Conduct a^* in physical network \rightarrow Function 1

본 논문에서는 알고리즘 3과 같이 DDPG 및 GraphSAGE 모델을 활용하여 최적의 VNF 배치를 수행한다. DDPG 모델은 훈련된 후 현재 상태를 기반으로 장기적 누적 보상을 평가하며, 최적의 보상을 제공하는 전략을 기반으로 물리적 네트워크에 VNF를 배치한다. 이 배치는 특정 임계

Algorithm 4 Threshold-Based Policy

```

1: for n=1, 2, ..., N do
2:   if a* needs to optimize the VNF placement in network
   then
3:     for s ∈ S do
4:       for type ∈ Each VNF type do
5:          $\zeta_{type,n}^{cpu} \leftarrow \sum_{u \in V_m \in M_n} \omega_m^{cpu} C_m^{cpu} \delta_{f,m}^v m_{type}^s$ 
6:         if predicted traffic > real traffic then
7:           if  $\zeta_{type,n}^{cpu} < \sigma_{down}^{place}$  then
8:             Place a new instance of VNF
             type;
9:           else if  $\zeta_{type,n}^{cpu} \geq \sigma_{down}^{release}$  then
10:            Sort the list of VNF instance
            types for that placed slice
11:            Release least utilized VNF
            instance
12:          end if
13:        else
14:          if  $\zeta_{type,n}^{cpu} < \sigma_{up}^{place}$  then
15:            Place a new instance of VNF
            type p
16:          else if  $\zeta_{type,n}^{cpu} \geq \sigma_{up}^{release}$  then
17:            Sort the list of VNF instance
            types for that placed slice
18:            Release least utilized VNF
            instance
19:          end if
20:        end if
21:      end for
22:    end for
23:  end if
24: end for

```

값을 기준으로 한 정책에 따라 최적화되며, 이 정책은 각 VNF 유형에 할당할 CPU 자원의 양을 결정한다. 네트워크 부하가 감소하면 VNF 배치는 알고리즘 4에 의해 최적화된다.

알고리즘 4에서는 CPU 임계값을 사용하여 과부하 상태의 VNF를 식별하고, 이를 기반으로 VNF의 수를 최적화하는 임계값 기반 정책을 채택한다. 3~5행에서는 각 VNF 인스턴스의 용량을 측정하고, 6행에서는 예측된 트래픽 양과 이전에 배치된 트래픽 양을 비교하여 VNF의 최적화를 수행한다. 각 네트워크 슬라이스별로 할당할 수 있는 VNF 인스턴스 유형의 CPU 용량은 식 (21)과 같다.

$$\zeta_{type,n}^{cpu} \leftarrow \sum_{v \in V_m \in M} \omega_m^{cpu} C_m^{cpu} \delta_{f,m}^v m_{type}^s \quad (21)$$

여기서, m_{type}^s 는 각 네트워크 슬라이스에 할당된

VNF 유형을 나타내며, 네트워크 트래픽 부하에 따라 VNF의 배치와 해제를 관리하는 데 사용된다.

V. 성능 분석

1. RF 기반 네트워크 슬라이스 분류

RF 기반 네트워크 슬라이스 분류 모델의 성능을 분석하기 위하여 Ubuntu 20.04 환경에서 성능 분석을 수행하고 ML 모델의 구현 및 평가를 위해 Python의 Scikit-learn 라이브러리를 사용한다. UE의 네트워크 슬라이스 분류 요구사항은 표 3과 같으며, 슬라이스의 성능지표는 국제전기통신연합(International Telecommunication Union, ITU)에서 정의한 성능 지표와 동일하다. 제안된 RF 기반 네트워크 슬라이스 분류 기법을 KNN(K-Nearest Neighbor), NB(Naive Bayes), SVM(Support Vector Machine)과 비교분석한다. 성능 평가를 위해 IE 데이터를 생성하고 라벨링한 후, 학습과 테스트 세트를 80:20으로 분할하여 각 모델의 성능을 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1 점수(F1-score) 등 네 가지 주요 지표를 사용하여 평가한다.

표 3. UE의 요구사항

Parameter	Value
User Device Type	Smartphone, IoT device
Duration(s)	600, 800
Packet Loss Rate	0.01, 1.00e-05
Packet Delay Budget(PDB)	7, 22
Bandwidth(GHz)	29, 60
Delay Rate(Mbps)	900, 10500
Speed(Mbps)	864, 1082
Jitter(ps)	4.30e07, 1.90e07
Modulation Type	FBMC, UPMC

5G 네트워크의 UE를 다양한 네트워크 슬라이스로 분류하기 위한 RF 모델의 최적 트리 수는 데이터 분할 비율에 따라 달라질 수 있다. 표 4의

분석 결과를 통해 알 수 있듯이 80:20의 데이터 분할 비율에서는 트리 수가 70일 때 모든 성능 지표에서 100%를 달성하였다. 이것은 제안된 모델이 슬라이스 분류 작업에 있어 뛰어난 성능을 발휘하여 상대적으로 빠른 실행 시간과 효율적인 메모리 사용량을 제공하는 것을 의미한다.

트리 수를 줄이면 성능 지표가 다소 하락하지만, 실행 시간과 메모리 사용량도 감소한다. 특히, 트리 수가 5인 경우에도 높은 성능을 유지하면서 실행 시간과 메모리 사용량을 현격히 절감할 수 있음을 알 수 있다. 따라서 RF 모델의 정확도와 계산 효율성을 높이기 위해서는 적정 트리 수를 결정해야 하며, 이 경우에는 70 이하로 설정할 때 가장 우수한 성능을 보이고 있다.

표 4. RF 모델의 성능 분석(80:20)

결정 트리	정확도	정밀도	재현률	F1 점수	Run time	Current Memory	Peek Memory
100	99.75	99.59	99.75	99.67	0.34	1.04	1.2
70	100	100	100	100	0.26	1.02	1.18
50	99.75	99.59	99.75	99.67	0.19	1.01	1.16
20	99.5	99.2	99.5	99.34	0.9	0.99	1.14
10	99.75	99.59	99.75	99.67	0.6	0.98	1.13
5	99.75	99.59	99.75	99.67	0.04	0.97	1.12
1	98	98.06	99.75	99.67	0.06	0.98	1.13

표 5. RF 모델의 교차 검증(80:20)

결정 트리	정확도	정밀도	재현률	F1-점수
100	99.9	99.88	99.89	99.89
70	99.9	99.88	99.89	99.89
50	99.9	99.88	99.89	99.89
20	99.85	99.8	99.84	99.82
10	99.85	99.8	99.84	99.82
5	99.75	99.66	99.75	99.7
1	99.25	99.28	99.28	99.28

표 5는 교차 검증 결과를 나타낸 것으로 결정 트리 수가 적더라도 높은 성능을 획득할 수 있다는 것을 보여 주고 있으며, 특히 20개와 10개일 때 실행 시간과 메모리 사용량이 비교적 낮게 유지되어 제안된 모델의 효율성과 성능 사이에 좋

은 균형을 보인다.

2. FL-LSTM 기반 네트워크 트래픽 예측


본 논문에서는 FL-LSTM 기반 네트워크 트래픽 예측 성능을 평가하기 위해 Flower 프레임워크를 사용한다. 또한, ELBORN, LESCORTS, PRBLESEC 트래픽 데이터를 성능 평가에 사용한다. 각 데이터의 특성은 표 6과 같으며, 성능 평가에 사용되는 파라미터는 표 7과 같다.

표 6. 네트워크 트래픽 데이터 세트


ELBORN	18.03.28 ~ 04.04까지 2분 단위 수집된 5421개의 데이터
LESCORTS	19.01.12 ~ 24까지 2분 단위 수집된 8615개의 데이터
PRBLESEC	18.02.05 ~ 03.05까지 2분 단위 수집된 19909개의 데이터

표 7. FL-LSTM 성능 평가 파라미터

Parameter	Value
Number of Clients	6
Round	5
Epochs	50
Time_step	5
LSTM	(16, 8, 8, 1)




a) FL-LSTM vs. Centralized LSTM Loss




b) FL-LSTM vs. Centralized LSTM MAE

그림 5. FL-LSTM과 중앙집중식 LSTM 모델 비교



a) 각 라운드에 따른 Loss 분석



b) 각 라운드에 따른 MAE 분석

그림 6. 각 라운드에 따른 클라이언트 1의 성능 분석

그림 5는 중앙집중식 LSTM과 FL-LSTM 모델의 성능을 비교한 것으로써 FL-LSTM의 평균 손실값이 중앙집중식 LSTM에 비해 약 50% 낮고 평균 MAE도 약 12% 감소하여 더 정밀한 예측이 이루어지는 것을 보여준다. 이것은 FL-LSTM이 다수의 클라이언트로부터 얻은 다양한 데이터를 학습함으로써 얻어진 결과로서 제안된 모델이 데이터의 다변성을 반영하고 복잡한 패턴을 이해하는데 훨씬 효과적임을 보여준다.

그림 6은 클라이언트 1의 성능 분석 결과로서 라운드가 거듭될수록 손실값과 MAE가 지속적으로 감소하여 모델이 개선됨을 보여주며, 라운

드 1에서 가장 높은 손실값과 MAE를 보이다가 라운드가 진행될수록 감소하며, 큰 폭으로 개선되다가 이후에는 개선 폭이 점차 줄어든다.

3. DDPG 기반 최적의 VNF 배치 및 관리

DDPG 기반 최적의 VNF 배치 및 관리 기법의 성능 분석을 위해 PyTorch 라이브러리를 사용하고 NetworkX 라이브러리를 통해 생성된 Waxman 네트워크를 활용한다. 주요 파라미터는 표 8에 요약되어 있으며, 하이퍼파라미터는 표 9와 같다.

표 8. 하이퍼파라미터

Parameter	Value
Number of episodes	2,000
Learning rate	0.1, 0.01, 0.001
Buffer size	10,000
Hidden layer	2
Hidden nodes	64, 128
Discounted factor	0.8

먼저, 각 모델의 성능 분석을 위해 장기 평균 수익과 장기 비용 대 수익 비율을 사용하여 비교를 수행한다. 5G 네트워크의 VNF 배치를 위해 각 모델의 성능 수용률에 대한 비교 결과는 그림 7과 같다. 여기서, DDPG 모델은 손실률이 낮을수록 높은 수용률을 달성하는 경향을 보인다. 특히, 손실률이 0.001인 DDPG 모델은 약 70.61%의 가장 높은 수용률을 보이며, 이것은 DDPG 모델이 손실률 변화에 민감하게 반응하며, 손실률이 낮은 환경에서 효율적으로 VNF를 배치할 수 있음을 보여준다. 반면에, A3C 모델은 약

표 9. DDPG 성능 평가 파라미터

Parameter	Value
Number of Node	500
Resource capacity of Physical Node	[1, 100]
Bandwidth of Physical Link	[50, 100]
Delay of Physical Link	[0., 1.]
Number of SFCR	Prediction Value
Resource capacity of VNF	[0, 50]

58.86%의 수용률로 DDPG 모델보다 상대적으로 낮은 성능을 나타내고 있으며, RF-VNE 모델은 가장 낮은 수용률인 57.62%을 보인다.

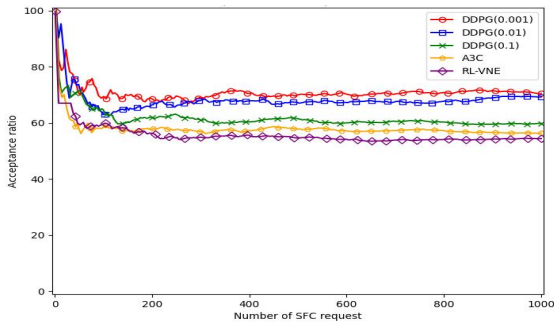


그림 7. 각 모델에 대한 수용률 비교

그림 8은 5G 네트워크 환경에서 VNF 배치와 관련된 평균 비용을 분석한 결과이다. 분석에 따르면, DDPG 모델은 손실률이 0.001일 때 평균 비용이 0.09761로 가장 낮으며, 이는 DDPG 모델이 낮은 손실률 환경에서 VNF 배치를 효율적으로 수행할 수 있다는 것을 의미한다. 반면, A3C 모델은 DDPG 모델에 비해 약 5.97% 높은 비용을 보이며, RF-VNE 모델은 약 6.17% 더 높은 비용을 필요로 한다.

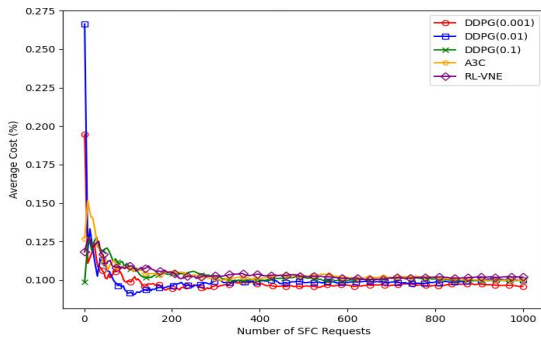


그림 8. 각 모델에 대한 평균 비용 비교

그림 9은 각 모델의 평균 수익을 분석한 결과이다. 손실률이 0.001인 DDPG 모델의 평균 수익은 418.32이며, 이는 손실률이 0.01인 경우에 비해 2.48% 낮으며, 손실률이 0.1인 경우에는 6.61% 낮은 수익을 갖는다. 반면, A3C 모델은 평균 수익이 425.7로, 손실률이 0.001인 DDPG 모델보다 약 1.76% 높은 수익률을 보이며, RF-VNE 모델은 약 5.86% 더 높은 수익을 보인다.

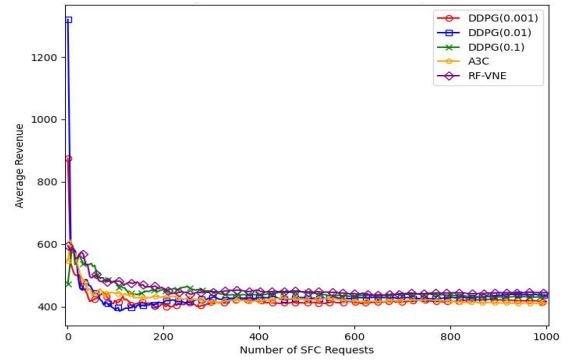


그림 9. 각 모델에 대한 평균 수익 비교

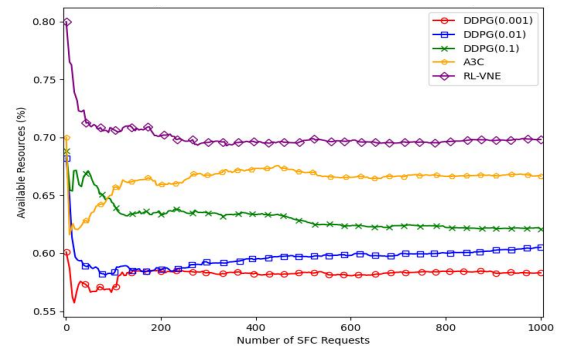


그림 10. 각 모델에 대한 장기 비용 대 수익 비교

그림 10은 5G 네트워크의 VNF 배치에 대한 각 모델의 장기 비용 대 수익 비율을 분석한 결과이다. 손실률이 0.001인 DDPG 모델이 0.5819의 비율로 가장 효율적인 성과를 보이며, 이것은 손실률이 0.01과 0.1인 경우에 비해 각각 약 2.4%와 7.7% 비용 대 수익 비율이 감소한 것이다. 반면, A3C 모델은 0.6639의 비율로 손실률이 0.1인 DDPG 모델보다 약 5.2% 높은 비용 대 수익 비율을 나타내며, RF-VNE 모델은 0.6997의 비율로 가장 높은 비용 대 수익 비율을 보인다.

VI. 결론

5G 네트워크는 다양한 산업 분야에서 활용되며, 네트워크 관리의 복잡성으로 인해 데이터 지연, 손실, 보안 문제 등이 발생한다. 이를 해결하기 위해 AI 및 ML 기반의 네트워크 자동화 기술이 연구되고 있으며, 연합학습 기법에 대한 관심도 증가하고 있다.

본 논문에서는 5G 네트워크의 자원 관리를 위

해 RF 기반의 슬라이스 분류 기법, FL 기반 LSTM 모델, DDPG 모델과 GraphSAGE 모델을 이용한 최적의 자원 할당 방안을 제안하였다. 성능 분석 결과, 제안된 기법들은 KNN, NB, SVM 모델보다 정확도, 정밀도, 재현율, F1-점수 모두 99% 이상의 높은 성능을 보였으며, 중앙집중식 LSTM 모델 보다 평균 손실률과 MAE에서 각각 약 50%와 12% 향상되었다. 마지막으로 제안된 DDPG 모델은 A3C 모델과 비교하여 손실률 0.001에서 70.61%의 높은 수용율을 달성하였다.

REFERENCES

- [1] Noohani M. Z., Magsi K. U., "A Review of 5G Technology: Architecture, Security and Wide Applications", *International Research Journal of Engineering and Technology(IRJET)*, vol. 7, no. 5, pp. 3440-3471, May 2020.
- [2] Hakak S., Gadekallu T. R., Maddikunta P. K. R., Ramu S. P., Parimala M., De Alwis C., Liyanage M., "Autonomous Vehicles in 5G and beyond: A Survey", *Vehicular Communications*, vol. 39, Feb. 2022.
- [3] Alenoghena C. O., Ohize H. O., Adejo A. O., Onumanyi A. J., Ohihoin E. E., Balarabe A. I., Okoh S. A., Kolo E., Alenoghena B., "Telemedicine: A Survey of Telecommunication Technologies, Developments, and Challenges", *Journal of Sensor and Actuator Networks*, vol. 12, no. 2, Mar. 2023.
- [4] Khujamatov K., Khasanov D., Reypnazarov E., Akhmedov N., "Existing Technologies and Solutions in 5G-Enabled IoT for Industrial Automation", *Blockchain for 5G-Enabled IoT*, pp. 181-221, Apr. 2021.
- [5] Li S., Da Xu L., Zhao S., "5G Internet of Things: A survey", *Journal of Industrial Information Integration*, vol. 10, Jun. 2018.
- [6] Shayea I., Ergen M., Azmi M. H., Çolak S. A., Nordin R., Daradkeh Y. I., "Key Challenges, Drivers and Solutions for Mobility Management in 5G Networks: A Survey", *IEEE Access*, vol. 8, pp. 172534-172552, Sep. 2020.
- [7] Ojijo M. O., Falowo O. E., "A Survey on Slice Admission Control Strategies and Optimization Schemes in 5G Network", *IEEE Access*, vol. 8, pp. 14977-14990, Jan. 2020.
- [8] Xu Y., Gui G., Gacanin H., Adachi F., "A Survey on Resource Allocation for 5G Heterogeneous Networks: Current Research, Future Trends, and Challenges", *IEEE Communications Surveys & Tutorials*, vol. 23, no. 2, pp. 668-695, Feb. 2021.
- [9] Salhab N., Langar R., Rahim R., "5G Network Slices Resource Orchestration Using Machine Learning Techniques", *Computer Networks*, vol. 188, Apr. 2021.
- [10] Yan M., Feng G., Zhou J., Sun Y., Liang Y. C., "Intelligent Resource Scheduling for 5G Radio Access Network Slicing", *IEEE Transactions on Vehicular Technology*, vol. 68, no. 8, pp. 7691-7703, Jun. 2019.
- [11] Zhang C., Xie Y., Bai H., Yu B., Li W., Gao Y., "A Survey on Federated Learning", *Knowledge-Based Systems*, vol. 216, Mar. 2021.
- [12] Li Q., Wen Z., Wu Z., Hu S., Wang N., Li Y., Liu X., He B., "A Survey on Federated Learning Systems: Vision, Hype and Reality for Data Privacy and Protection", *IEEE Transactions on Knowledge and Data Engineering*, vol. 35, no. 4, pp. 3347-3366, Apr. 2023.
- [13] Breiman L., "Random Forests", *Machine learning*, vol. 45, pp. 5-32, 2001.
- [14] Hochreiter S., Schmidhuber J., "Long Short-Term Memory", *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, Nov. 1997.
- [15] Lillicrap T. P., Hunt J. J., Pritzel A., Heess N., Erez T., Tassa Y., Silver D., Wierstra D., "Continuous Control with Deep Reinforcement Learning", arXiv, Sep. 2015.
- [16] Hamilton W., Ying Z., Leskovec J., "Inductive Representation Learning on Large Graphs", *Advances in Neural Information Processing Systems*, 2017.
- [17] Thantharate A., Paropkari R., Walunj V., Beard C., "DeepSlice: A Deep Learning Approach Towards an Efficient and Reliable Network Slicing in 5G Networks", *Annual Ubiquitous Computing, Electronics & Mobile Communication Conference(UEMCON)*, pp. 762-767, Feb. 2020.
- [18] Song F., Li J., Ma C., Zhang Y., Shi L., Jayakody D. N. K., "Dynamic Virtual Resource Allocation for 5G and Beyond Network Slicing", *IEEE Open Journal of Vehicular Technology*, vol. 1, pp. 215- 226, Apr. 2020.
- [19] Esteves J. J. A., Boubendir A., Guillemin F., Sens P., "A Heuristically assisted Deep Reinforcement Learning Approach for Network Slice Placement", *IEEE Transactions on Network and Service Management*, vol. 19, no. 4, pp. 4794-4806, Dec. 2022.
- [20] Zahedi S. R., Jamali S., Bayat P., "A

Power-Efficient and Performance-aware Online Virtual Network Function Placement in SDN/NFV-enabled Networks”, *Computer Networks*, vol. 205, Mar. 2022.

- [21] Zhao S., “Energy Efficient Resource Allocation Method for 5G Access Network Based on Reinforcement Learning Algorithm”, *Sustainable Energy Technologies and Assessments*, vol. 56, Mar. 2023.
- [22] Brik B., Ksentini A., “On Predicting Service-Oriented Network Slices Performances in 5G: A Federated Learning Approach”, *Local Computer Networks(LCN)*, pp. 164-171, Nov. 2020.
- [23] Verma R., Sivalingam K. M., “Federated Learning Approach for Auto-Scaling of Virtual Network Function Resource Allocation in 5G-and-Beyond Networks”, *Cloud Networking(CloudNet)*, pp. 242-246, Nov. 2022.
- [24] Hamilton W., Ying Z., Leskovec J., “Inductive Representation Learning on Large Graphs”, *Advances in Neural Information Processing Systems*, 2017.

— 저 자 소 개 —



박석우(정회원)

2017년 군산대학교 정보통신공학과 학사 졸업.

2019년 군산대학교 정보통신전과공학 석사 졸업

2024년 군산대학교 정보통신전과공학 박사 졸업

<주관심분야 : 무선 센서 네트워크, IoT, 클라우드 컴퓨팅, 기계학습, 딥러닝>



이오성(정회원)

2008년 한양대학교 전자전기공학과 학사 졸업.

2018년 전북대학교 경영학과 석사 졸업

2024년 군산대학교 정보통신전과공학 박사과정

<주관심분야 : 무선 센서 네트워크, IoT, 클라우드 컴퓨팅, 기계학습, 딥러닝>



나인호(정회원)

1988년 울산대학교 전자계산학과 학사 졸업.

1991년 중앙대학교 전자계산학과 석사 졸업.

1995년 중앙대학교 전자계산학과 박사 졸업.

1995년 ~ 현재 군산대학교 소프트웨어 학부 교수

<주관심분야 : 무선 센서 & 에드혹 네트워크, IoT, 클라우드 컴퓨팅, 블록체인>