

ZSM/ENI 기반의 자율 네트워크 및 서비스 관리

양 우 석*, 이 재 오°

Autonomous Network and Service Management based on ZSM/ENI

Wooseok Yang*, Jaehoh Lee°

요 약

네트워크 및 서비스 운영자는 이질적이고 다양한 네트워크 장치들 간의 복잡한 상호작용 및 동적으로 변화하는 사용자 요구 사항, 비즈니스 목표 및 환경에 적용할 수 있는 지능화된(intelligent) 네트워크 및 서비스 관리에 관심을 가지고 있다. 네트워크 관리는 자체 구성 네트워크(Self Organizing Network: SON) 기반의 동적인 서비스 전개와 연관되어 자율(autonomous) 네트워크 및 서비스 관리의 연구 필요성이 대두되고 있다. 자율 관리는 다양한 AI/ML 기술을 융합 및 적용하고 있다. 따라서 이러한 AI/ML 기술을 적용할 수 있는 표준화된 자율 네트워크 및 서비스 관리 구조와 모델을 연구하는 노력도 진행 중이다.

본 논문에서는 자율 네트워크 및 서비스 관리를 위하여 사용 될 수 있는 관련 AI/ML 기술을 소개한다. 또한 자율 네트워크 및 서비스 관리 표준안을 제안하고 있는 ETSI(European Telecommunications Standards Institute)의 ZSM(Zero-touch Network and Service Management)과 ENI(Experiential Networked Intelligence) 시스템 구조에 관한 연구 동향을 살펴보고자 한다.

Key Words : Autonomous Network and Service Management, Machine Learning, Closed Loop, ZSM, ENI

ABSTRACT

Network and service operators are interested in intelligent network and service management that can be applied to complex interactions between heterogeneous and diverse network devices, dynamically changing user requirements, business goals, and environments. Network management is related to dynamic service deployment based on Self-Organizing Network (SON), and the need for autonomous network and service management is emerging for study. Autonomous management integrates and applies various AI/ML technologies. Therefore, efforts are also underway to study standardized autonomous network and service management structures and models that can use these AI/ML technologies.

In this paper, we introduce some related AI/ML technologies for autonomous network and service management. We also examine research trends on the Zero-touch Network and Service Management (ZSM) and Experiential Networked Intelligence (ENI) system architecture of the European Telecommunications Standards Institute (ETSI), which are proposing standards for autonomous network and service management.

* 이 논문은 2024년도 한국기술교육대학교 교수 교육연구진흥과제 지원에 의하여 연구되었음.

♦ First Author : Korea University of Technology and Education Department of Information Communication, oos13@koreatech.ac.kr

° Corresponding Author : Korea University of Technology and Education Department of Information Communication, jolee@koreatech.ac.kr

I. 서 론

미래 통신 및 네트워크 분야에서 인공지능/기계학습(Artificial Intelligence/Machine Learning: AI/ML) 기술은 다양한 방법으로 융합되어 중요한 역할을 하리라고 본다. 기계 학습은 복잡한 시스템의 인식 및 의사 결정 문제에 대한 솔루션을 제공하는 중요한 방법이다. 네트워크 기반의 컴퓨팅 기술과 관련된 기계 학습 기술은 네트워크 관리, 네트워크 슬라이싱(slicing), 적응성(adaptive) 자원 할당, 이동성 모델링, QoS, 보안 및 에너지 효율성을 자율화하는데 필요한 기술로서 대두되고 있다[1, 10]. 기계 학습을 적용할 수 있는 표준화된 기술의 조사 연구 및 동향은 향후 네트워크 및 네트워크 관리 기술 발전 방향을 예측하는데 도움이 된다.

자동(automation)은 사람의 개입 없이 자율적으로 작업을 실행하는 것을 말한다. 자율은 비즈니스 프로세스, 네트워크 관리, 자원 할당, 라우팅 프로토콜, 자원 최적화 등 다양한 애플리케이션에 적용될 수 있다[1, 2]. 서비스 기반 아키텍처, 인공지능 기반 기술, 프로그래밍 가능한 네트워크 및 소프트웨어 컴퓨팅 전략을 통해 자동화를 달성할 수 있다. 자율화 적용의 주요 목표는 서비스에 대한 확장성, 유연성 및 민첩성을 확보하여 다양한 주요 문제의 해결을 위한 최첨단 솔루션을 달성하는 것이다.

본 논문에서는 통신 및 네트워크 관리 분야에서 적용될 수 있는 기계 학습 방안에 관하여 조사 및 연구함으로써 미래의 네트워크 및 서비스 관리를 자율화할 수 있는 대표적인 표준 구조의 기술 내용 및 동향을 연구하려고 한다. 따라서 관련 적용 가능한 AI 기술 연구로서 기계 학습, 심층 강화 학습(deep reinforcement learning), 연합 학습(federated learning), 전이 학습(transfer learning)을 간략하게 살펴본다. 그리고 대표적인 자율 네트워크 및 서비스 관리 참조 아키텍처 및 시스템인 ETSI의 ZSM(Zero-touch Network and Service Management)과 ENI(Experiential Networked Intelligence)를 기술하려고 한다.

논문 구성은 ZSM 및 ENI 구조에서 적용 가능한 AI/ML 관련 기술로서 기계 학습 개요, 심층 강화 학습, 관리 도메인(management domain) 간의 협력 모델에 대하여 살펴본다. 그리고 대표적인 표준으로서 자율 네트워크 및 서비스 관리 구조인 ZSM 및 ENI에 관하여 기술한다. 마지막으로 ZSM/ENI 기반의 전형적인 자율 관리 시스템을 살펴보고자 한다.

II. 관련 기술 연구

본 절에서는 자율 네트워크 및 서비스 관리 분야에 적용 가능한 대표적인 AI/ML 기술을 살펴본다.

2.1. 기계 학습

기계 학습은 인공지능의 하위 집합으로 경험을 통해 자동으로 개선되는 컴퓨터 알고리즘에 대한 연구이다. 기계 학습은 데이터에서 학습하고 데이터에 대한 예측을 수행할 수 있는 알고리즘의 연구 및 구성을 탐구한다. 더 많은 데이터를 기반으로 기계 학습은 작업과 응답을 변경하여 더 효율적이고 적응 가능한 형태로 확장할 수 있다. 심층 학습은 의사 결정을 달성하기 위해 훈련 데이터에 인공 신경망을 사용한다. 신경망은 여러 계층에서 계산을 통해 미시적 계산을 수행하고 인간과 같은 작업을 처리할 수 있다[1, 3].

기계 학습은 지도(supervised) 학습, 비지도(unsupervised) 학습, 강화 학습으로 나뉜다[4]. 지도 학습 모델에서 알고리즘은 레이블이 지정된 데이터 세트에서 학습하여, 새 데이터에 대한 예상 및 예측된 응답을 생성한다. 지도 학습의 목표는 훈련(training) 데이터를 기반으로 입력과 출력 간의 매핑을 찾는 것이다. 이를 이용하여 훈련 중에는 나타나지 않는 새로운 입력에 대한 정확한 예측을 설정하고 수행한다. 지도 학습은 주로 분류(classification) 및 회귀(regression) 문제에 사용된다.

비지도 학습 모델에서 알고리즘은 레이블이 지정되지 않은 데이터 세트에서 학습하고 자체적으로 기능, 동시 발생 및 기본 패턴을 추출하여 의미를 찾으려고 한다. 훈련 데이터는 어떤 출력 값도 포함하지 않으며 학습자는 환경에서 피드백을 받지 못한다. 이는 주로 클러스터링 및 연관(association) 문제에 사용된다. 비지도 학습 유형은 클러스터링(clustering), 이상 감지(abnormal detection), 연관, 오토 인코더(auto encoder), 잠재 변수 모델(Latent Variable Model), 신경망(Neural Network) 등이 있다[1, 2].

강화 학습은 모델이 일부 작업을 수행하고 반응을 분석하여 환경에서 행동하는 방법을 배우는 일종의 기계 학습이다. 강화 학습은 특정 상황에서 긍정적인 반응을 극대화하기 위해 적절한 조치를 취한다. 강화 모델은 주어진 작업을 수행하기 위해 취해야 할 조치를 결정하므로 경험 자체에서 배워야 한다. 학습자 에이전트는 특정 작업을 실행하는 상태 정보와 함께 누적 보상(reward)의 다른 개념을 최대화하려고 노력한다

다. 학습자는 수행된 결정에 대한 피드백을 받지만 훈련 데이터는 외부 감독자에 의해 레이블이 지정되지 않는다. 결과적으로 학습자는 응답이 옳았거나 잘못되었는지 알 수 없다. 대신 반복적인 경험에서 배우고 자체적으로 최상의 정책(policy)을 발견해야 한다. 따라서 강화 학습은 보상과 처벌(punishment)에 의해 구동되는 적응성 의사 결정 문제를 모델링하기 위한 정성적 및 정량적 프레임워크를 제공한다[1, 3]. 강화 학습은 ZSM 프레임워크 아키텍처 내에서 네트워크 및 서비스 자동화를 위한 유용한 지원 도구가 될 수 있다[22]. 그림 1은 기계 학습 분류의 형태를 보여 준다.




그림 1. 기계 학습 분류
Fig. 1. Classification of Machine Learning

2.2 심층 강화 학습

심층 강화 학습은 심층 학습과 강화 학습을 결합한 기계 학습의 한 분야이다. 복잡한 시스템의 인식 및 의사 결정 문제에 대한 솔루션을 제공하기 위해 심층 학습과 강화 학습의 장점을 모두 가지고 있다[1, 2, 4, 11]. 강화 학습은 다양한 알고리즘들이 존재하며, 이들을 분류하는 방법 또한 다양하다. 환경 모델은 환경의 행동을 모방하거나 보다 일반적으로 환경이 어떻게 행동할 지에 대한 추론을 할 수 있게 해주는 것이다. 예를 들어, 상태(state)와 행동(action)이 주어졌을 때 모델은 결과적인 다음 상태와 다음 보상을 예측할 수 있다. 모델은 계획(planning)에 사용되며, 이는 실제로 경험하기 전에 가능한 미래 상황을 고려하여 행동 과정을 결정하는 모든 방법을 의미한다. 모델과 계

획을 사용하여 강화 학습 문제를 해결하는 방법을 모델 기반(model-based) 방법이라고 하며, 모델 없는(model-free) 방법은 계획이 거의 없는 것으로 간주되어 명시적으로 시행착오(trial-and-error) 기반으로 학습하는 방식이다[4]. 강화 학습의 분류 방법 중 하나는 그림 2와 같다[2].




그림 2. 강화 학습 분류
Fig. 2. Classification of Reinforcement Learning

강화 학습은 가치 기반(value-based) 방법과 정책 기반(policy-based) 방법으로 나눌 수 있다. 마찬가지로 심층 강화 학습도 같은 방식으로 나눌 수 있다. 가치 기반 심층 강화 학습은 주어진 행동 또는 주어진 상태가 에이전트에게 얼마나 좋은지를 의미한다. 보상 측면에서 주어진 상태에서 행동들의 선택에 따라서 에이전트의 수익이 증가(또는 감소)할 수 있다. 이를 미리 알면 에이전트가 예상 수익을 최대화하기 위해 어떤 상태에서 어떤 행동을 취해야 할지 결정하는 데 도움이 될 수 있습니다. 가치 기반의 대표적인 알고리즘인 심층 Q-러닝 네트워크(DQN: Deep Q-learning Network)는 정책을 훈련하기 위한 기능 엔지니어링을 피하기 위해 DNN을 사용하여 큰 상태 공간이 있는 상황을 모델링하고 이전 단계에서 학습한 정보를 계속 사용하기 위해 재생 메모리 세트를 사용할 수 있다. DQN은 특히 5G/6G와 같이 동적이며 유연성(flexibility)을 가져야 하는 ad-hoc 네트워크의 최적화 정책을 발견하는데 적용될 수 있다[1, 8, 9].

정책 기반 심층 강화 학습은 에이전트가 주어진 상태에서 주어진 행동을 취할 가능성이 얼마나 되는지,

즉 에이전트가 특정 상태에서 특정 행동을 선택할 확률을 의미한다. 정책 기반의 대표적인 방식으로 AC(Actor-Critic)가 제안되었다[8, 11, 13]. AC는 정책 기반 방법과 가치 기반 방법의 장점을 결합한 알고리즘이다. Actor는 예상 보상을 최대화하기 위해 행동을 선택하는 방법을 학습하는 정책 기반 에이전트이며, 상태를 행동 확률에 매핑하는 신경망에 의해 매개변수화 된다. Critic은 주어진 상태에서 예상되는 미래 보상을 예측하는 가치 함수를 추정하는 방법을 학습하는 가치 기반 에이전트로, 신경망에 의해 매개변수화 된다. TD(Temporal Difference) 에러는 상태 가치 함수의 추정 값과 실제 얻은 보상 간의 차이를 의미한다. 이는 예상했던 보상과 실제 얻은 보상의 차이라고 할 수 있다. 그림 3은 AC 모델을 나타낸다.




그림 3. Actor-Critic 모델
Fig. 3. Actor-Critic Model

A3C(Asynchronous, Advantage, Actor-Critic)는 단일 신경망으로 대표되는 단일 에이전트가 단일 환경과 상호 작용하는 DQN과 달리 보다 효율적으로 학습한다. A3C에는 전역(global) 네트워크와 각각 고유한 네트워크 매개변수 세트가 있는 여러 작업자 에이전트가 있다. 이것이 단일 에이전트를 사용하는 것보다 더 잘 작동하는 이유(더 많은 작업을 완료하는 속도가 빨라지는 것 이상으로)는 각 에이전트의 경험이 다른 에이전트의 경험과 독립적이기 때문이다. 이러한 방식으로 훈련에 사용할 수 있는 전반적인 경험이 더욱 다양해진다.

2.3 관리 도메인들 사이의 AI/ML 모델

표준 기계 학습 접근 방식을 사용하려면 학습 데이터를 한 기계 또는 데이터 센터에 중앙 집중화해야 한다. 그러나 통신 분야의 데이터는 일반적으로 여러

장소(locale)에 있는 고도로 분산된 네트워크를 특징으로 한다. 따라서 네트워크의 다양한 위치에서 공통 처리 위치로 데이터를 가져오는 것은 전송 자원을 소모하기 때문에 비용이 많이 든다. AI/ML 능력을 가진 관리 도메인들 사이에 공통의 문제를 해결하기 위하여 협력이 필요하다. AI/ML 능력을 가진 도메인 관리 시스템들 사이에 협력이 필요한 경우에 사용될 수 있는 대표적인 모델로서 연합 학습(federated learning)과 전이 학습(transfer learning)이 있다.

연합 학습은 학습 능력을 소유한 클라이언트 역할을 하는 다수의 관리 도메인 시스템 응용이 각각 학습하여, 중앙에 있는 관리 시스템의 전역 모델을 학습하는 기술이다[5]. 따라서 이 접근 방식은 관리 도메인의 지역 데이터를 안전하게 유지해야 할 때 사용된다. 연합 학습은 여러 도메인에서 AI/ML 관리 시스템 응용을 훈련한 다음 중앙 위치에서 집계하여 처리한다[21]. 모델 매개변수 및 훈련 정보와 같은 AI/ML 특정 정보 교환을 지원하면 운영자가 연합 학습을 기반으로 AI/ML 솔루션을 배포하고 활용할 수 있다.

전이 학습은 네트워크의 상이한 장소나 도메인 그리고 다소 유사한 상황에서 주어진 새로운 지역 상황으로 지식을 전송할 수 있게 해주기 때문에 지역 데이터의 중앙 집중화 문제를 해결할 수 있다[8, 9, 10]. 전이 학습 방법을 사용하면 사전 훈련된 AI/ML 관리 시스템 응용을 관리 도메인별 AI/ML 관리 시스템 응용을 얻기 위한 시작점으로 사용할 수 있다. 이 방법은 필요한 훈련 시간과 계산 리소스를 줄여 AI 관리 시스템 응용의 신속한 배포를 용이하게 한다[16, 21]. 따라서 전이 학습은 네트워크 및 서비스 자동화를 위한 핵심 지원 요소로, 특히 효율성을 높이고 계획, 배포 및 최적화 작업을 지원한다[22]. 일반적인 통신 연구 분야에서 전이 학습은 현재 초기 단계이지만 6G에서 훨씬 더 중요한 역할을 할 것이라고 보고 있다.

III. ZSM 및 ENI 기반 네트워크 및 서비스 관리

네트워크 및 서비스 운영자는 동적이며 복잡한 통신 및 네트워크 장치들의 문맥적 변화(contextual changes)의 감지 및 어떤 장치 및 서비스 그룹이 서로 영향을 미치는지 확인하여 서비스 수준 계약(Service Level Agreement: SLA)을 유지할 수 있는 지능화된 네트워크 및 서비스 관리를 요구하고 있다[11].

3.1. ZSM 아키텍처

ETSI에 따르면 ZSM 아키텍처는 네트워크 자율화와 관련된 디지털 서비스에 필요한 확장성, 유연성 및 민첩성을 제공하도록 설계되었다. 또한 아키텍처는 본질적으로 적응력이 있어 자율화된 기능이 새로운 기술에 대한 규정 준수 표준을 충족할 것으로 예상된다 [8, 9]. 목표는 자동화의 가장 높은 추상화를 달성하여 적응성, 인식 및 자동 특성 또는 기능의 조합을 통해 독립적으로 생각하고 행동할 수 있는 능력을 가진 자율 시스템을 개발하는 것이다 [12, 16]. 그림 4는 ZSM 프레임워크 참조 아키텍처이다 [16].




그림 4. ZSM 프레임워크 참조 아키텍처
Fig 4. ZSM Framework Reference Architecture

ZSM 프레임워크는 관리 도메인으로 조직된 분산 관리 및 데이터 서비스로 구성되며, 통합 패브릭(Integration Fabric)을 통해 합쳐진다. 모든 관리 도메인 및 종단 간(E2E) 서비스 관리 도메인은 서비스 종단의 집합을 노출 및/또는 소비하는 관리 기능(Management Function)을 통해 일련의 ZSM 서비스를 제공한다 [13, 14, 16, 17, 18]. 통합 패브릭은 관리 서비스의 등록/해제, 검색 및 호출 지원 수단과 관리 기능 간의 통신을 포함하여 관리 도메인 내부 및 외부에서 관리 기능 간의 상호 운용 및 통신을 가

능하게 한다. 제공되는 서비스 패턴은 요청-응답과 게시/구독 모델이 지원된다. 교차 도메인 간 통합 패브릭(Cross-domain Integration Fabric)은 기능 제공 및 종단 교차 도메인 접근을 용이하게 한다. 일부 서비스는 관리 도메인 내에서 로컬로만 제공되고 사용된다. 모든 관리 서비스의 논리 그룹은 관련된 기능을 갖는 서비스들을 포함한다 [18].

데이터 서비스(Data Service)는 관리 도메인 내 혹은 전체에서 관리 서비스 전반에 걸쳐 ZSM 서비스를 사용할 수 있는 인증된 ZSM 프레임워크 소비자(Framework Consumer)가 공유 관리 데이터 접근 및 지속적으로 일관된 수단을 제공한다. 관리 도메인은 자원에서 제공되는 (다양한) 인터페이스를 통해 관리 대상인 인프라 자원(infrastructure resource)을 관리한다. E2E 서비스 관리 도메인(Service Management Domain)은 다양한 관리 도메인에 걸쳐 있는 종단 간 서비스를 관리하고 오케스트레이션을 사용하여 관리 도메인 간을 조정한다 [16].

3.1.1 관리 서비스(Management Service)

본 절에서는 ZSM 프레임워크에서 정의된 기본 관리 도메인 및 E2E 서비스 관리 도메인에서 정의된 서비스들에 관하여 살펴본다 [16].

3.1.1.1 데이터 수집(Data Collection)

관리 도메인 및 종단 간 관리 도메인에서 서비스 관련 장애(fault), 성능과 같은 데이터 수집을 담당한다.

3.1.1.2 분석(Analytic)

다양한 분석 서비스는 기본 관리 도메인 및 기타 입력에서 들어오는 사건(event), 장애 및 성능과 관련된 정보를 처리하여 집계 및 분석하고 파생한다. 또한 분석 서비스에는 제공된 서비스에 고유한 종단 간 서비스 KPI(Key Performance Indicator) 및 사용자 경험(예: 비디오 정지 또는 프레임 제거)을 추적하는 기능이 있을 수 있다. 이는 기본 관리 도메인의 서비스별 관찰 체계 또는 조사를 기반으로 작동한다. 분석 서비스는 분석 결과를 제공하는 방법과 시기를 사용자가 정의하도록 구성할 수도 있다. 예를 들어 통찰이 생성되는 방식과 사용되는 알고리즘을 모두 구성할 수 있다.

실제 특정 분석 서비스는 일반 분석 서비스와 동일한 기능 세트를 갖지만 생성하는 분석 결과 유형, 수행하는 분석 및 실제 구성이 다르다. 다음은 ZSM에

서 정의한 특정 분석 서비스를 나타낸다.

- E2E 이상 탐지 서비스(E2E anomaly detection service): 이상 탐지 서비스는 기본 관리 도메인의 도메인 데이터 수집 서비스에서 제공하는 정보를 사용하여 E2E 서비스와 관련된 이상 상태를 감지하는 기능을 제공한다. 예를 들면 이러한 조건은 보안 위반/이상, 서비스 수준 사양(Service Level Specification: SLS) 위반이 감지되지 않더라도 E2E 서비스의 국지적 또는 단기적 사용 불가능 또는 서비스의 불일치로 이어지는 결함 조건일 수 있다. 이상 또는 비정상적인 동작이 감지되면 그 결과는 E2E 서비스의 지능 서비스 생산자가 적절한 결정을 내리도록 할 수 있다. 해결책이나 해결 방법을 찾거나 추가 분석을 위해 다른 분석 서비스에서 데이터를 사용할 수 있도록 하거나 도메인 간 통합 패브릭을 통해 ZSM 프레임워크 소비자에게 정보를 노출할 수 있다.
- 배포된 AI 모델 성능 평가 서비스(Deployed AI model performance evaluation service): 배포된 AI 모델 성능 평가 서비스를 통해 AI 모델의 성능 수준을 파악하고 탐지할 수 있다. 성능 저하(AI 모델은 시간이 지남에 따라 성능 저하를 겪을 수 있고 재교육이 필요한 확률 시스템), 갑작스러운 성능 저하, 불규칙한 성능 등을 배포된 AI 모델 평가 서비스에서 사용할 수 있다. 배포된 AI 모델에서 수행할 가장 적절한 작업을 결정한다.
- 근본 원인 분석 서비스(Root cause analysis service): 여러 오류에 대한 정보의 연관성 및 종속성을 식별하고 추가 통찰력 또는 지식을 사용하여 문제의 근본 원인을 결정한다.
- 영향 분석 서비스(Impact analysis service): 장애 또는 기타 문제(예: 성능 문제)가 실제 관리 서비스 성능 또는 가용성에 미치는 영향을 결정한다.
- 성능 분석 서비스(Performance analysis service): 기본 관리 도메인의 데이터 수집 서비스에서 수집한 데이터를 처리하여 높은 수준의 서비스 성능 통찰력을 수행한다. 과잉 밀집(congestion) 및 과부하 상황과 같은 서비스 저하와 관련된 KPI 및 정보이다.
- 보안 분석 서비스(Security analytics service): 보안에 영향을 줄 수 있는 특정 공격 패턴, 위협 및 의심스러운 동작을 식별하기 위해 보안 사건을 처리한다.

E2E 서비스 품질 관리 서비스를 통해 인증된 소비

자는 E2E 서비스의 서비스 수준 목표(Service Level Objective: SLO) 및 SLS를 관리하고 위반 사항을 추적할 수 있다. SLS 및 SLO는 SLA와 관련이 있다 [17]. SLS는 SLO로 구성되며 제공할 SLA에서 적용되는 서비스 품질을 정의하는 기술 매개변수를 제공한다.

3.1.1.3 서비스 오케스트레이션(Orchestration)

E2E 서비스 오케스트레이션은 도메인 간 고객 대면 서비스를 생성/수정/삭제하기 위해 여러 관리 도메인의 카탈로그(catalogue) 기반 E2E 오케스트레이션을 담당한다. 서비스 모델은 서비스의 다양한 부분이 함께 연결되고 관리 도메인에 매핑 되는 방식을 정의한다. E2E 서비스 오케스트레이션 서비스를 통해 인증된 소비자는 E2E 서비스의 생성, 수정 및 종료에 포함하여 네트워크 슬라이스와 같은 E2E 서비스를 인스턴스화하고 유지 관리할 수 있으며 해당 워크플로우를 자동화할 수 있다[12, 14]. 이 서비스는 E2E 서비스 관리 도메인에서 관리 서비스 카탈로그 관리 서비스에 의해 관리되는 E2E 서비스 모델에 적용된다. E2E 서비스 모델은 관리 도메인 및 해당 상호 연결에서 제공하는 서비스 부분 설명에 대한 참조를 포함하여 전체 E2E 서비스를 설명한다. ZSM 프레임워크 소비자는 E2E 서비스 오케스트레이션 서비스를 사용하여 E2E 서비스를 배포할 수 있습니다.

타당성 확인(Feasibility check) 서비스는 특정 매개변수화된 E2E 서비스(예: 네트워크 슬라이스)가 제안된 서비스 수준에서 배포 가능한지 확인하는 데 사용된다. 관리되는 서비스(Managed Service) 카탈로그 관리 서비스는 E2E 서비스 관리 도메인에서 관리하는 사용 가능한 E2E 서비스를 나타내는 서비스 모델의 카탈로그를 관리하고, 이 카탈로그를 ZSM 프레임워크 소비자에게 노출하는 일을 담당한다. E2E 서비스 모델은 지원되는 커버리지 영역, 관련 SLS, 서비스 템플릿 등과 같은 지원 정보를 포함할 수 있으며, 서비스 범주로 그룹화 될 수 있다. 서비스 모델에는 일반적으로 수명 주기 단계를 나타내는 상태가 있다. E2E 테스트 서비스(Testing service)를 사용하면 관련 없는 다른 네트워크 서비스에 영향을 주지 않고 중단 간 서비스 및/또는 그 일부의 능동(active) 또는 수동(passive) 테스트를 실행하여 장애 위치를 찾을 수 있다. ZSM 프레임워크 소비자에 의해 또는 자율화된 절차의 일부로 사용될 수 있다. E2E 서비스 보유 관리 서비스(E2E service inventory management service)는 사용 가능한(인스턴스화 및 활성화) E2E

서비스에 대한 정보를 유지 및 질의할 수 있는 E2E 서비스 관리 도메인 내부의 소비자에게만 제공된다. E2E 서비스 토폴로지 정보 서비스(E2E services topology information service)는 다양한 추상화 수준에서 E2E 서비스 관점의 인프라에 대한 토폴로지 정보를 제공한다.

3.1.1.4 서비스 지능(Intelligence)

E2E 서비스 지능 서비스는 최종 목표 단계인 완전 자율 관리를 통해 다양한 수준의 자동화된 의사 결정 및 인적 감독을 지원하여 E2E 서비스 관리 도메인에서 지능형 폐쇄 루프 자동화를 주도한다. 서비스 지능의 범위는 의사 결정 지원(decision support), 의사 결정(decision making), 행동 계획(action planning) 등이다. 의사 결정 지원 서비스는 AI/ML 및 지식 관리와 같은 기술을 통해 의사 결정을 가능하게 한다. E2E 서비스 관리 의사 결정은 E2E 서비스 데이터 수집, E2E 서비스 분석, E2E 서비스 관리 도메인의 도메인 데이터 서비스, 도메인 간 데이터 서비스 및 적용 가능한 기타 소스의 일부로 정의된 ZSM 서비스에서 제공하는 정보를 기반으로 한다. 후속 작업 계획은 E2E 서비스 오케스트레이션의 일부로 정의된 ZSM 서비스에서 실행할 오케스트레이션/제어 작업을 정의한다.

제공되는 서비스는 AI 모델 관리 서비스(AI Model Management Service), 배포된 AI 모델 평가 서비스(Deployed AI Model Assessment Service), AI 훈련 데이터 관리 서비스(AI Training Data Management Service), E2E 서비스 상태 문제 보고 서비스(E2E Service Health Issue Reporting Service)이다.


AI 모델 관리 서비스를 통해 AI 모델을 관리할 수 있다. 새로운 입력 데이터를 기반으로 주기적 또는 언제든지 AI 모델을 수정할 수 있다. 배포된 AI 모델의 성능은 현실의 변화로 인해 시간이 지남에 따라 저하될 수 있으며, 그 결과 모델이 현실과 정확하게 일치하지 않아 모델 수정 또는 교체가 필요할 수 있다. 배포된 AI 모델 평가 서비스를 사용하면 사용 가능한 모델 성능 정보를 기반으로 관리 기능에서 배포 및 사용하는 AI 모델에서 실행할 가장 적절한 조치를 결정할 수 있다. 이를 위해 배포된 AI 평가 서비스는 배포된 AI 모델 성능 평가 서비스의 출력을 사용할 수 있다. 배포된 AI 모델 평가 서비스에서 파생된 평가는 재교육, 재구성, 업그레이드, 교체, 일시 중지, 종료와 같이 배포된 AI 모델에서 수행할 가장 적절한 작업을 결정하는 데 사용된다. AI 훈련 데이터 관리 서비스를 통해 AI 모델을 훈련하거나 재훈련하는 데

필요한 훈련 데이터를 관리할 수 있다. 훈련 데이터는 분류, 예측 또는 기타 기계 학습 문제의 입력 특징/속성 및 실측 결과를 포함하는 레이블이 지정된 데이터일 수 있다. 학습 데이터는 학습이 데이터에 의존하는 특정 AI 모델을 의미할 수도 있고, 향후 AI 모델 개발을 위해 기존 AI 모델과 독립적으로 학습 데이터를 축적할 수도 있다. 자동화 시스템에서도 모든 서비스 상태 문제를 자동으로 복구할 수 있는 것은 아니다. 특정 문제의 경우 상위 실체(예: ZSM 프레임워크 소비자)에 보고해야 한다. 이 서비스를 통해 이러한 문제 보고서를 관리할 수 있다. E2E 서비스 상태 문제 보고 서비스는 비정상적인 서비스 상태(예: 결함, 보안 문제 등으로 인한)에 대한 정보를 제공하고 해당 정보를 사용할 수 있는 경우 이를 기본 관리 도메인의 문제와 연관시킬 수 있다. 또한 상태 문제와 심각성을 추적 및 수정하고 제공되는 정보를 구성할 수 있다.

3.1.2 폐쇄 루프(closed-loop) 기반 관리 자율화

폐쇄 루프 기반 관리 체계는 관리 작업의 자율화, 지속적인 최적화, 내부 또는 외부 조건의 변화에 대응하여 관리되는 대상 실체(entity)에 관리 동작 수행을 적용할 수 있으며, 정의된 빌딩 블록으로 구성된다. 관리 기능은 폐쇄 루프의 다른 단계를 달성하기 위해 관리 서비스 능력을 지원한다[19]. 폐쇄 루프 동작은 기본 관리 도메인 및 종단 간 서비스 관리 도메인 수준에서 발생할 수 있으며, 계층적인 관리 도메인 체계를 구성할 수 있다. 다수의 폐쇄 루프는 동시에 실행될 수 있으며 관리 서비스 및 관리 기능의 다양한 하위 집합을 사용하여 수행될 수 있다.

폐쇄 루프의 기본 모델은 OODA(Observe, Orient, Decide, Act)에 근거하고 있으며, MAPE-K(Monitoring, Analysis, Plan, Execution, Knowledge), COMPA(Control, Orchestration, Management, Policy, and Analytics) 등 다양한 유형의 폐쇄 루프를 실현할 수 있다[14]. 폐쇄 루프에는 기계 학습 기술을 적용하여 이점을 얻을 수 있는 여러 단계(step)가 있다. 기계 학습 기반 모니터링, 분석, 의사 결정 및 최적화된 조치(optimized action) 등 모든 단계에서 기계 학습을 통합할 수 있다. 폐쇄 루프는 각 단계에서 필요한 기능의 구성, 그리고 폐쇄 루프의 단계 사이에 의해 필요한 정보 또는 명령의 전송/접근을 제공해야 한다. 관리 기능은 각각의 관리 서비스 기능과 함께 그림 5에 나와 있는 것처럼 폐쇄 루프의 다양한 단계의 기능을 달성한다[16, 19].



Legend:




그림 5. 아키텍처 빌딩 블록과 폐쇄 루프 단계 사이의 지시적 매핑
Fig 5. Indicative Mapping between Architectural Building Blocks and Closed-loop Steps

폐쇄 루프는 관리 대상 실체인 관리되는 자원 및 해당 운영 문맥(context)에 대한 데이터를 지속적으로 관찰하고 수집한다. 이를 통해 루프의 관리 기능은 이러한 변경 사항을 분석하여, 동작의 진전 상황을 이해하고, 계획 및 결정을 생성한 다음, 관리 대상의 현재 관찰된 상태를 원하는 대상 상태 또는 목표에 맞게 조정하는 작업을 수행할 수 있다.

폐쇄 루프는 동작의 부분으로 다음 기능을 수행한다.

1. 관리 대상 및 기타 관련 데이터 소스에서 데이터를 관찰하고 수집한다.
2. 해당 데이터의 의미와 중요성을 적절한 맥락에서 이해할 수 있도록 이러한 데이터의 처리 방향을 지정한다.

3. 필터링, 상관관계 및 기타 메커니즘을 통해 수집된 데이터를 분석하여 과거, 현재 및 미래 상태의 모델을 정의한다.
4. 기계 학습 알고리즘을 실행하여 패턴을 학습하고 인식하며 관찰된 데이터를 예측한다.
5. 추세 추론, 근본 원인 및 순서 결정, 유사한 프로세스를 기반으로 다양한 조치를 계획한다.
6. 관리 행동의 실행 계획과 시기를 결정한다.
7. 서로 다른 목표 간의 충돌을 감지하고 해결한다.
8. 다른 제어 루프와 협업한다.

3.2 ENI(Experiential Networked Intelligence) 시스템

ETSI ISG(Industry Specification Group) ENI 시스템은 운영자 경험을 향상시키는 혁신적인 정책 기반 모델의 기능 구조이다[1]. 네트워크 자율화 외에도 ENI 시스템은 인간과 기계의 의사 결정을 지원하여 비즈니스 요구 사항을 보다 효율적으로 충족하는 인지 네트워크 관리 기능 아키텍처를 정의한다[6, 7, 17, 22]. ENI는 AI를 활용한 폐쇄 루프 네트워크 운용 및 관리를 가능하게 하는 아키텍처이다. ENI는 지능형 네트워크 운용 및 관리 권장사항(recommendations) 및/또는 명령(commands)을 피 지원 시스템(Assisted System: AS)에 제공하는 실체이다[6, 17]. AS의 운영자와 ENI 간의 신뢰도에 의존하여 권장사항과 정책 명령어 사용을 결정할 것이다. ENI 시스템은 다음 세 가지 모드 중 하나로 AS와 통신하는 외부 실체로 전개 및 배포될 수 있다. (1) AS의 운영자, 요소 관리 시스템(EMS), 네트워크 관리 시스템(NMS) 또는 오케스트레이터와 직접 통신하거나 (2) 애플리케이션 프로그래밍 인터페이스들(APIs)을 사용하거나 (3) 이들의 조합이다.

[7, 22]에서 볼 수 있듯이 AS의 인공 지능 사용 유무에 따라 세 가지 유형이 예상된다. 가장 간단한 (a) 유형의 AS는 AI가 없는 AS이다. ENI와의 상호 작용은 제한적이다. AI 기반 결정을 운용의 일부로 통합할 수 있는 기능(facility)이 없을 수 있기 때문이다. 다음 (b) 유형의 AS는 AI를 사용하지만, 운용 제어 루프의 일부로는 사용하지 않는 AS이다. 따라서 ENI와의 상호 작용은 더 강력하지만 실시간 제어 결정을 포함하지 않는다. 마지막(c)의 AS 유형은 제어 루프에서 AI를 사용하는 유형이다. 따라서 ENI는 AS가 ENI에 권한을 부여한 모든 작업에 대해 AS에 권장사항 및/또는 명령을 제공할 수 있다. AS는 상태, 정책, 명령 및 원격 측정 정보를 전달하기 위해 고유한 기

본 데이터 형식을 사용할 수 있다. API 브로커(broker)의 목적은 서로 다른 다양한 AS의 API와 ENI API 간에 변환 및 중재를 수행한다. API 브로커를 사용한 ENI의 고수준 기능 블록 다이어그램은 그림 6에 나와 있다[7]. 화살표는 12개의 외부 기준점 중 하나를 사용하여 데이터 및 정보의 방향성을 나타낸다.




그림 6. API 브로커를 사용한 ENI의 고수준 기능 아키텍처
Fig. 6. High-Level Functional Architecture of ENI when an API Broker is used

ENI 아키텍처는 내부 및 외부의 두 가지 다른 폐쇄 제어 루프(Closed Control Loop)를 제공한다. 폐쇄 제어 루프는 OODA 패러다임을 기반으로 하지만, FOCAL(FOundation, O bservation, C omparison, A ction, L earn, rEason) 아키텍처와 유사한 개선을 제공할 수 있다[7]. 이를 통해 제어 루프의 각 부분이 AI 기반의 계획 및 학습 메커니즘을 사용하여 인지적 의사 결정을 제공할 수 있다[15]. 내부 제어 루프는 실제로 OODA의 네 가지 기본 프로세스를 병렬로 실행할 수 있는 여러 개의 폐쇄형 제어 루프로 구성된다. 이러한 제어 루프는 ENI 작동 모드와 관계없이 항상 존재한다. 외부 제어 루프는 전체 OODA 프로세스가 동작을 조정하여 원하는 출력 상태를 자

동으로 유지하도록 한다[22, 23].

입력 처리(Input Processing)는 데이터 수집 및 정규화(Normalization) 기능 블록(Functional Block: FB)으로 구성된다. 모든 외부 데이터는 데이터 수집 기능 블록(Data Ingestion Functional Block)으로 모인다. 데이터 수집 FB의 목적은 여러 입력 소스에서 데이터를 수집하고, 이를 다른 ENI 기능 블록에서 추가로 처리하고 분석할 수 있도록 하는 일반적인 데이터 처리 기술이다. 정규화 기능 블록의 목적은 데이터 수집 기능 블록에서 수신한 데이터를 다른 ENI FB가 이해하고 사용할 수 있는 형식으로 처리하고 변환하는 것이다.

분석(Analysis)을 위한 지식 관리 및 처리는 지식 관리(Knowledge Management), 문맥 인식 관리(Context-Aware Management) 및 인지적 처리(Cognitive Processing) 세 가지 기능 블록으로 구성된다. 상황 기반(Situation-based) 정책 생성 기능 블록(Policy Generation Functional Block)은 상황 인식(Situation Aware), 모델 기반(Model-Driven) 엔지니어링 및 정책 관리(Policy Management) 세 가지 FB들로 구성된다. 방향설정(Orient) 부분의 구현은 지식 관리, 문맥 인식, 인지 프레임워크 및 상황 인식 FB로 함께 구성된다.

- 지식 관리 FB는 AI 처리의 기본 요소이며 모델 기반 엔지니어링 및 형식 논리를 통합한다. 모든 ENI FB에서 사용할 수 있는 데이터의 형식적 표현을 정의하여 기계 학습 및 추론을 가능하게 한다. 이는 수집된 데이터와 ENI 시스템 데이터에서 새로운 데이터와 변경된 데이터를 분석, 검증 및 추론한다.
- 문맥 인식 FB는 AS 및 해당 환경에 대한 정보를 수집하여 문맥의 변화에 따라 동작을 조정할 수 있도록 한다(예: 사용자, 장치 혹은 애플리케이션 기록 및 정보, 위치, 동작 특성 등).
- 인지적 처리 FB는 ENI에 대한 일련의 고수준 목표를 만들고 유지 관리하는 역할을 한다. 이러한 목표는 운영자가 학습 및/또는 제공한 SLA, 최적화, 효율성, 보안 등이 될 수 있다.
- 상황 인식 FB는 발생하는 사건과 잠재적 조치가 AS 및 관련 ENI 최종 목표에 어떤 영향을 미칠 수 있는지 평가하기 때문에 중요한 역할을 한다. 따라서 이 FB는 방금 일어난 사건 및 시스템 상태와 ENI에서 권장하거나 추진하는 잠재적 조치를 감안할 때 상황이 왜, 어떻게 전개될 수 있는지 이해할 수 있다.

방향설정 단계는 ENI에 제공된 목표를 기반으로 AS의 현재 상태를 원하는 상태와 비교하고 필요한 경우 선택적 조치 세트를 제안한다.

결정 기능은 모델 기반 엔지니어링 및 정책 관리 FB에서 제공한다. 모델 기반 엔지니어링 FB는 ENI의 AS 구성 내부 표현을 기반으로 제안된 변경 세트를 가져와 적절한 조치 세트로 변환한다. 그런 다음 정책 관리 FB는 이러한 조치를 재사용 가능한 정책으로 변환한다[24].

조치 부분은 역정규화(Denormalization) 및 출력 생성(Output Generation) FB로 구성된다. AS의 특성에 따라 출력은 ENI에서 지원하는 외부 형식에 맞게 적절히 역정규화 된다. 역정규화 기능 블록의 목적은 ENI 시스템의 다른 FB에서 수신한 데이터를 일련의 목표가 된 실체 집합이 이해할 수 있는 형식으로 처리하고 변환하는 것이다. 출력 생성 기능 블록의 목적은 역정규화 기능 블록에서 수신한 데이터를 AS 또는 지정된 실체가 이해할 수 있는 형식으로 변환하는 것이다. 여기에는 적절한 프로토콜 집합 정의, 데이터 인코딩 변경 및 기타 관련 기능이 포함된다. API 브로커는 네이티브 형식으로 AS에 표시되기 전에 출력을 추가로 변환할 수 있다.

산업의 모멘텀과 표준 방식으로 AI 메커니즘을 사용하는 네트워크와의 융합을 촉진하기 위해 ENI는 일련의 외부 참조 지점을 게시한다. 이러한 외부 참조 지점은 ENI 기능의 고수준 의미에 대한 표준 정의를 제공하는 데 유용하며, 수집되고 생성된 정보는 ENI 정보 모델에 저장된다.

IV. ZSM/ENI 기반 자율 관리 시스템

모든 네트워크 기능, 운용 및 애플리케이션을 서비스로 구현함으로써 6G와 같은 미래 차세대 모바일 네트워크 아키텍처는 소프트웨어화되고 지능적으로 구성될 것이다. 따라서 미래 네트워크는 매우 동적이고 복잡하게 구성 및 유지될 것이며, ZSM/ENI 표준 개념을 적용한 네트워크 및 서비스 관리 시스템의 연구 및 동향 분석은 중요한 역할을 담당하리라고 본다. 자율 관리 시스템은 지능화된 네트워크, 서비스의 관리 및 오케스트레이션의 수행을 목표로 하고 있다. 그림 7은 ZSM/ENI 기반 시스템을 통합하여 적용한 전형적인 자율 지향적 네트워크 및 서비스 관리 시스템을 구성한 것으로 전반적인 자율 관리 시스템 체제를 살펴보면 도움이 되리라고 본다.




그림 7. ZSM/ENI 기반 통합 관리 시스템들

Fig. 7. Integrated Management Systems based on ZSM/ENI

관리 대상 실체들은 도메인 기반으로 다양하고 이질적인 물리적 및 논리적 가상화된 자원들로 구성된다. 이들은 RAN, 전송, 코어, 에지 클라우드, 코어 클라우드, MANO[14]와 같은 다양한 기술적 도메인에 교차되어 관리되어질 것이다[1, 4, 11, 13, 14, 17]. 관리 대상 실체는 AS의 계층적 관리 시스템들의 최하위단인 EMS 및 ENI 시스템에 의하여 직접 관리된다. 이들은 관리 명령어를 기반으로 제어를 수행하거나 모니터링 대상이 되는 데이터를 제공받아 유지할 것이다. 관리 영역인 FCAPS(Fault, Configuration, Accounting, Performance, and Security)의 일반적인 관리 방법론은 관리 대상 실체의 상태에 대한 필요한 정보를 제공할 수 있는 정교한 데이터 모니터링 및 수집 프레임워크를 필요로 한다. AS들은 SMS, NMS, EMS로 계층적으로 구성되어있으며, 각 관리 시스템은 폐쇄 루프를 지원하거나 지원하지 않을 수 있다. 이는 기존 및 신규 관리 시스템의 구성을 가능하게 한다[6]. 계층적 관리 시스템에서 최상위 단인 E2E 서비스 관리 시스템의 폐쇄 루프는 광범위한 관점을 가지고 있으며, 비즈니스 입력을 도메인별 입력으로 변환하고 분해하는 역할을 한다. 최하위단 관리 도메인의 폐쇄 루프는 협의의 관점을 가지고 있으며 E2E 서비스의 일부를 보장 및 관리하는 역할을 수행한다. ENI 시스템은 AS의 능력에 따라서 API 브로커를 사용하여 표준화된 폐쇄 제어 루프 기능들을 제공할 수 있다.

의도 주도(intent-driven) 관리 시스템들은 ENI 시스템 혹은 기존의 AS를 지원하기 위하여 사용되어질 수 있다. 의도 주도 기반 관리로 입력 정보를 더 간단하고 사용자 친화적으로 표현할 수 있으며, 자동화의 유연성이 더 높아진다. 의도는 자동화를 증진시키고 관리를 더 단순하게 만드는 핵심 요소이다[21, 22, 25]. 의도는 분해(decomposition)가 이루어지고, 처리 기능(Handling Function)을 거쳐 AS 및 ENI에 정책의 형태로 관리 명령어들이 제공된다. 이를 효과적으로 수행하기 위하여 의도 표현 및 검증(Intent Representation and Verification), 대규모 언어 모델(LLM)과 같은 트랜스포머 모델이 사용될 수 있다[14, 15].

네트워크 및 서비스 오케스트레이션을 위한 미래 통신 및 네트워크 성능 목표를 달성하려면 자율화가 필요하다. 따라서 의도 주도 기반 관리, 폐쇄 루프 및 AI/ML과 같은 기술을 구조적으로 일관성 있게 표준화 형태로 관리 시스템을 제공하는 것은 중요할 것이다. 예를 들면 폐쇄 제어 루프는 네트워크 슬라이스 관리 및 오케스트레이션을 수행하기 위한 AI/ML 프레임워크를 제공한다. ENI 폐쇄 제어 루프들은 주로 AI/ML에 의존하며, 자체 관리(self-management), 자체 구성(self-configuration) 및 자체 적응(self-adaptation)을 달성할 수 있다[11]. 이는 AS, 오케스트레이터 및 인프라와의 향상된 협업을 통하여 자동화 수준을 높여 완전 자율화된 폐쇄 루프 제어를 목표로 설계될 것이다.

V. 결 론

6G 시스템과 같은 미래의 차세대 모바일 네트워크는 여러 기술 영역(예: 무선 접근 네트워크, 전송, 코어, 에지 클라우드 및 코어 클라우드)을 걸쳐 다수의 이질적인 네트워크 서비스 및 슬라이스를 동적이며 복잡한 형태로 제공할 것으로 예상된다. 이는 확장성과 지속성의 관점에서 고전적인 중앙 집중식 관리와 오케스트레이션 접근 방법에 대한 중요한 도전으로, 일관성 있고 표준화된 지능형 기반의 네트워크 및 서비스 관리 시스템을 필요로 한다.

이를 위하여 ZSM 및 ENI 그리고 의도 주도 기반 관리 기술의 연구 및 동향을 지속적으로 살펴보는 것은 중요하다. 자율화를 목표로 하는 이러한 기술들은 AI/ML을 기반으로 강화 학습, 연합 학습, 전이 학습을 실제 구현 및 적용하는 많은 연구가 이루어질 것으로 본다.

References

- [1] Miranda McClellan, et al., "Deep Learning at the Mobile Edge: Opportunities for 5G Networks," Applied Sciences, July 2020.
- [2] Weikang Xu, et al., "A Comprehensive Discussion on Deep Reinforcement Learning," IEEE 3rd International Conference on Communications, Information System and Computer Engineering (CISCE 2021), pp. 697-702, 2021.
- [3] Charles Ssengonzi, et al., "A Survey of Deep Reinforcement Learning Application in 5G and beyond Network Slicing and Virtualization," Elsevier Array 14, April 2022.
- [4] 조재형, 이재오, "기계 학습 기반의 스마트 팩토리 설비 장애 관리 시스템," KNOM Review, Vol. 26, No. 1, pp. 31-40, 2023.
- [5] Xiaofei Wang, et al., "In-Edge AI: Intelligentizing Mobile Edge Computing, Caching and Communication by Federated Learning," IEEE Network, Vol. 33, Issue 5, 2019.
- [6] Yue Wang, et al., "Network Management and Orchestration Using Artificial Intelligence: Overview of ETSI ENI," IEEE Communications Standards Magazine, Vol. 2, Issue 4, Dec. 2018.
- [7] Yue Wang et al., "From Design to Practice: ETSI ENI Reference Architecture and Instantiation for Network Management and Orchestration Using Artificial Intelligence," IEEE Communications Standards Magazine, pp. 38-45, Sept. Sep. 2020.
- [8] Xiaoyu Qiu, et al., "Distributed and Collective Deep Reinforcement Learning for Computation Offloading: A Practical Perspective," IEEE Transactions on Parallel and Distributed Systems, Vol. 32, No. 5, May 2021.
- [9] Hojjat Baghban, et al., "Edge-AI: IoT Request Service Provisioning in Federated Edge Computing Using Actor-Critic Reinforcement Learning," IEEE Transactions on Engineering Management, Vol. 71, pp. 11519-11528, May 2022.
- [10] Gerald M. Karam, et al., "The Evolution of Networks and Management in a 6G world: An Inventor's View," IEEE Transactions on Network and Service Management, 2022.

[11] Shalli Rani, et al., "Network Slicing for Zero-Touch Networks: A Top-Notch Technology," IEEE Network, Vol. 37, Issue 5, 2023.

[12] Ovidiu Iacoboaia, et al., "From Design to Deployment of Zero Touch Deep Reinforcement Learning WLANs," IEEE Communications Magazine, Vol. 61, Issue: 2, 2023.

[13] Sand L. Correa, et al., "Supporting MANOaaS and Heterogenous MANOaaS Deployment Within the Zero-Touch Network and Service Management Framework," IEEE Communications Standards Magazine, Vol. 8, Issue: 2, 2024.

[14] Jingwen Zang, et al., "Intent-Driven Closed Loop Control and Management Framework for 6G Open RAN," IEEE Internet of Things Journal, Vol. 11, No. 4. Feb. 2024.

[15] Ray Forbes, et al., "Transformers and Large Language Models as Used in ETSI ISG Experiential Networked Intelligence," IEEE ICC 2024 1st Workshop on The Impact of Large Language Models on 6G Networks, pp. 1250-1255, 2024.

[16] ETSI GS ZSM 002 V1.1.1 (2019-08) Zero-touch network and Service Management (ZSM); Reference Architecture.

[17] ETSI GS ZSM 003 V1.1.1 (2021-06) Zero-touch network and Service Management (ZSM); End-to-end management and orchestration of network slicing.

[18] ETSI GS ZSM 008 V1.1.1 (2022-07) Zero-touch network and Service Management (ZSM); Cross-domain E2E service lifecycle management.

[19] ETSI GS ZSM 009-1 V1.1.1 (2021-06) Zero-touch network and Service Management (ZSM); Closed-Loop Automation; Part 1: Enablers.

[20] ETSI GR ZSM 011 V1.1.1 (2023-02) Zero-touch network and Service Management (ZSM); Intent-driven autonomous networks; Generic aspects.

[21] ETSI GS ZSM 012 V1.1.1 (2022-12) Zero-touch network and Service Management (ZSM); Enablers for Artificial Intelligence-based Network and Service Automation.

[22] ETSI GS ENI 005 V3.1.1 (2023-06) Experiential Networked Intelligence (ENI); System Architecture.

[23] ETSI GR ENI 017 V2.1.1 (2021-08) Experiential Networked Intelligence (ENI); Overview of Prominent Control Loop Architectures.

[24] ETSI GS ENI 030 V4.1.1 (2024-03) Experiential Networked Intelligence (ENI); Transformer Architecture for Policy Translation.

[25] ETSI GS ZSM 016 V1.1.1 (2024-10) Zero-touch network and Service Management (ZSM); Intent-driven Closed Loops.

양 우 석 (Wooseok Yang)



2014년 8월: 한국기술교육대학교, 정보통신학과 학사

2016년 8월: 한국기술교육대학교, 전기전자통신공학 석사

2016년 9월~현재: 한국기술교육대학교, 전기전자통신공학 박사과정 수료

<관심분야> 네트워크 및 서비스 관리, NMS,, NFV/SDN, ZSM/ENI

이 재 오 (Jaeoh Lee)



1987년 2월: 광운대학교 전자계산학과 학사

1989년 2월: 광운대학교 전자계산학과 석사

1993년 8월: 광운대학교 전자계산학과 박사

2002~현재: 한국기술교육대학교

전기전자통신공학부, 교수

<관심분야> 차세대 서비스 응용, 서비스 가상화 및 네트워크 슬라이싱, AI/ML 기반 네트워크 및 서비스 관리, ZSM/ENI