

전술 애드혹 네트워크에서 실시간 서비스의 성능 향상을 위한 AI 기반 라우팅 경로 신뢰성 판단 기술

이철웅*, 이동근*, 최정욱*, 박수범*, 이민*, 장재원**, 김대영**, 이성형***

AI-Based Routing Path Reliability Assessment Scheme for Performance Enhancement of Real-Time Service in Tactical Ad-Hoc Networks

Cheol-woong Lee*, Dongkeun Lee*, Jungwook Choi*, Soo Beom Park*, Min Lee*,
 Jae-Won Jang**, Dae-Young Kim**, Sung-Hyung Lee***

요약

정보통신 기술의 발전에 따라, 현대전에서는 무기체계들을 하나의 네트워크로 연결하고 감시정찰, 의사결정 및 정밀타격 과정에 소요되는 시간을 단축하는 것이 중요해졌다. 그러나, 기간망의 지원을 받기 어려운 전장환경에서 전술 애드혹 네트워크를 구성할 경우, 주파수 특성 및 토폴로지의 변화로 인해 음성 또는 영상과 같은 종단 간 실시간 전술 서비스를 안정적인 성능으로 제공하기 어려운 문제가 있다. AI 및 ML 기술을 활용하여 네트워크에 요구되는 다양한 요소들을 프로토콜 동작에 반영하고자 하는 연구들이 진행되고 있으나, 전술 애드혹 환경에서 실시간 서비스의 품질을 고려하는 네트워크 기술은 제안되지 않았다. 본 논문에서는 전술 애드혹 단말에 적용 가능한 AI 기반의 실시간 트래픽 송신 경로 신뢰성 판단 기술을 제안한다. 본 논문에서는 실험결과를 통해 AI 모델을 기반으로 트래픽 송신 경로의 신뢰성을 판단하고 선제적으로 라우팅 경로를 전환할 경우, 실시간 서비스 제공 성능이 향상됨을 보인다.

Key Words : Tactical Ad-hoc Network, Real-time Service, Ad-hoc Routing, Artificial Intelligence, Machine Learning, Path Reliability Assessment

ABSTRACT

With the advancement of information and communication technology, it has become important in modern warfare to connect weapon systems into a single network and shorten the time required for surveillance, reconnaissance, decision-making, and precision strike processes. However, when configuring a Tactical Ad-hoc Network in a battlefield where it is difficult to receive support from a backbone network, there is a problem in that it is difficult to provide end-to-end real-time tactical services such as voice or video with stable performance due to changes in frequency characteristics and topology. Researches are being conducted to

※ This work was supported by Korea Research Institute for Defense Technology Planning and Advancement-Grant funded by the Defense Acquisition Program Administration (DAPA) (KRIT-CT-21-030).

* First and Corresponding Author : LIG Nex1 Co. Ltd., cheolwoong.lee@lignex1.com, 정회원

* LIG Nex1 Co. Ltd., {dklee27, jungwook.choi}@lignex1.com; sbpark93@lignex1.com, 정회원; min.lee@lignex1.com, 정회원

** Soonchunhyang University, fnd148@sch.ac.kr; dyoung.kim@sch.ac.kr, 중신회원

*** SOLVIT System Co. Ltd., shlee@solvitsystem.co.kr

논문번호 : 202506-140-B-RN, Received June 17, 2025; Revised August 5, 2025; Accepted August 14, 2025

reflect various elements required for networking into protocol operations by utilizing AI and ML technologies, but no networking technology has been proposed that considers the quality of real-time services in a tactical ad-hoc environment. In this paper, we propose an AI-based real-time traffic transmission path reliability assessment technology applicable to tactical ad-hoc terminals. In this paper, it is demonstrated through experimental results that performance of real-time service is improved when the reliability assessment of traffic transmission paths based on an AI model is applied and the routing paths are proactively switched.

I. 서 론

정보통신 기술의 발전에 따라, 주요 선진국들은 전술 데이터의 효율적인 교환을 통해 정보우위를 달성하고자 현대전의 특징을 네트워크 중심전(NCW: Network Centric Warfare)로 정의했다. 이에 따라, 감시정찰, 의사결정 및 정밀타격 과정에 소요되는 시간을 단축하기 위해 모든 무기체계를 하나의 네트워크로 연결하는 것이 중요해졌다^{1,2}.

적의 공격 등에 의해 기간망의 지원을 받기 어려운 전장 환경에서의 통신을 위해, 다수의 단말을 기반으로 전술 애드혹 네트워크를 구성해야 한다^{3,4}. 그러나, 전술환경에서는 지형지물 및 전파방해 등으로 인해 주파수 특성을 예측하기 어려우며, 단말의 이동에 의해 토폴로지 변화 또한 빈번하다^{5,6}. 따라서, 음성 또는 영상과 같이 성능의 안정성이 중요한 중단 간 실시간 전술 서비스 제공을 위한 네트워킹 기술이 요구된다.

한편, 컴퓨터의 연산 능력의 발전으로 인공지능(AI: Artificial Intelligence) 또는 기계학습(ML: Machine Learning)을 결합한 다양한 네트워킹 기술들이 제안되고 있다¹⁰⁻¹⁷. 그러나, 다수의 연구들은 전술 또는 애드혹 환경보다는 기간망의 지원을 받는 상황을 고려한 기술들을 제안한다¹¹⁻¹². 이동 애드혹 네트워크(MANET: Mobile Ad-hoc Network)에서 적용 가능한 AI 기반 네트워킹 기술들도 제안되었으나, 이 중 일부만이 실시간 전술 서비스의 제공 성능 향상을 목표로 한다¹³⁻¹⁷. 기계학습 기반 클러스터링 연구들은 네트워크의 성능을 향상시키기 위한 기술을 제안한다^{13,14}. 그러나, 1~2홉 간 클러스터링 방식은 중단 간 실시간 전술 서비스의 성능에 직접적으로 영향을 주기 어렵다. 기계학습 기반 무선자원 할당 및 송신세기 조절 기술은 트래픽의 중단 간 지연시간을 감소시키기 위해 제안되었다¹⁵. 그러나, 단말의 이동 등으로 인해 토폴로지가 변화하는 상황에서 무선자원 할당 방식만으로는 실시간 전술 서비스를 효과적으로 제공하기 어려울 수 있으며, 트래픽 전송을 안정적으로 수행할 수 있는 경로의 확보 기술이 추가적으로 요구된다. 기계학습 기반 라우팅 경로설정 연구는

에너지 소모, 데이터 손실, 라우팅 오버헤드 및 패킷 전달 성능 측면에서 향상된 성능을 보여주나¹⁶, 실시간 트래픽의 서비스 품질(QoS: Quality of Service)을 고려하지 않는다. 그래프 학습 기반 트래픽 정체 완화 연구는 트래픽 발생량에 의한 정체를 완화하는 라우팅 기술을 제안한다¹⁷. 해당 연구의 제안 기술은 실시간 서비스 품질을 고려했다고 평가할 수 있다. 하지만, AI 모델이 링크 품질까지 고려하지 못해서 신호의 감쇠가 있는 상황에서 기존 라우팅보다 낮은 성능을 보인다.

본 논문에서는 전술 애드혹 환경에서 동작하는 라우팅 프로토콜에 적용 가능한 AI 기반 라우팅 경로 신뢰성 판단 기술을 제안한다. 제안 기술은 라우팅 경로의 신뢰성을 판단하고 선제적인 트래픽 송신 경로 전환을 지원한다. 또한, 모델링 및 시뮬레이션 (M&S: Modeling and Simulation) 결과를 통해 제안 기술이 중단 간 실시간 전술 서비스의 성능을 향상시킬 수 있음을 보인다.

본 논문의 구성은 다음과 같다. 2장에서는 AI 및 ML 기반 무선 네트워킹의 개요에 대해 설명하며, AI 및 ML을 적용한 네트워킹 기술 연구에 대해 설명한다. 3장에서는 라우팅 경로 신뢰성 판단을 위한 AI 모델 학습 방법과 신뢰성 판단 정보 수집을 위한 계층 간 정보 전달 구조에 대해 설명하며, AI 모델의 판단 결과를 기반으로 라우팅 경로 전환 여부를 결정하는 기술에 대해 설명한다. 4장에서는 제안방법의 M&S를 위해 구성한 환경과 이를 이용하여 얻은 실험결과에 대해 설명한다. 5장에서는 제안방법을 기반으로 진행될 수 있는 추후 연구에 대해 설명한 후, 본 논문의 결론을 맺는다.

II. 배경 및 관련연구

2.1 전술 애드혹 네트워크 개요

전술 애드혹 네트워크는 전시 혹은 재난과 같이 기간망 지원을 받기 어려운 상황에서, 전파가 직접적으로 닿지 않는 위치에 정보를 전달하거나 다수 단말 간 효율적인 통신 지원을 위해 구성하는 이동 애드혹 네트워크(MANET: Mobile Ad-hoc Network)의 일종이다^{5,6}.

전파 특성상, 주파수 대역을 넓게 사용하는 광대역 통신의 경우 전송속도가 높고 전파의 통달거리가 짧다. 반면, 대역을 좁게 사용하는 협대역 통신의 경우 전송속도가 낮고 전파의 통달거리가 길다⁷. 통신에 사용 가능한 주파수 자원에는 한계가 있다. 따라서, 전술 애드혹 네트워크에서는 네트워크 구성 단말의 수, 지원하고자 하는 전술 서비스 종류 등의 요구조건을 반영한 광대역 및 협대역 네트워크 기술을 사용한다^{8,9}. 광대역 네트워크 기술은 제어 패킷의 주기적 및 비주기적 송수신을 모두 지원 가능하며, 제어 패킷에 포함된 정보를 프로토콜 동작에 반영한다. 반면, 협대역 네트워크 기술은 주기적으로 송수신하는 제어 패킷에 최대한 많은 정보를 포함하고 이를 활용한다.

2.2 AI 및 ML 기반 무선 네트워크 개요

인공지능(AI: Artificial Intelligence)은 컴퓨터가 주어진 정보를 바탕으로 추론, 문제해결 및 의사결정 등을 수행할 수 있도록 하는 정보통신 기술이다. 이때, 다수의 입력 정보를 바탕으로 컴퓨터가 스스로 학습하도록 하는 기술이 기계학습(ML: Machine Learning)이다.

컴퓨터의 연산 능력이 향상되면서, 수 많은 인공지능망 계층적으로 연결한 심층신경망 구조를 적용한 기술들의 성능이 비약적으로 증가하였다. 또한, 심층신경망 구조를 적용할 경우, 학습 결과를 저장하기 위한 공간에 대한 문제를 해결할 수 있다¹⁸. 이로 인해 최근에는 대다수의 AI 기술들이 심층학습(DNN: Deep Neural Network) 구조 기반의 학습 방식을 채용한다¹⁹.

MAC, 라우팅 등 네트워크 계층에 적용되는 심층학습 기반의 기술들은 대부분 Convolutional Neural Network(CNN), Recurrent Neural Network(RNN) 등 총 7가지 DNN의 세부 모델들 중 하나를 활용하며²⁰, 각 모델 별로 장단점이 있어, 해결하고자 하는 문제의 종류에 따라 적합한 모델의 선정 및 조합이 중요하다.

2.3 AI 및 ML 기반 애드혹 네트워크 기술

주파수 특성의 비예측성, 단말의 이동으로 인한 토폴로지 변화 등으로 인해, 무선 통신 환경에서 전술 애드혹 네트워크를 구성하기 위해서는 많은 요소를 고려한 복잡한 형태의 네트워크 기술이 요구된다.

AI 및 ML 기술은 컴퓨터가 주어진 정보를 바탕으로 학습 및 의사결정을 수행하여, 복잡한 동작 방식을 취하지 않고 네트워크 기술의 성능을 향상시킬 수 있다. 이에 AI 및 ML을 기반으로 하는 애드혹 네트워크 기술들이 제안되고 있다. 그러나, 일부 연구들만이 실시간 전술 서비스의 제공 성능 향상을 목표로 하며, 전술 애

드혹 환경에 대해 완벽히 고려하지 못한다¹³⁻¹⁷.

기계학습 기반 클러스터링 연구들은 네트워크의 성능을 전반적으로 향상시키기 위한 기술을 제안한다^{13,14}. 각 연구들은 제안 기술이 데이터 전달 성공률, 지연시간 및 패킷 손실 측면에서 네트워크 성능을 향상시킬 수 있음을 보인다. 하지만, 1~2홉 노드 간에 이루어지는 클러스터링 기법으로는 3홉 이상 거리에서 수행 가능한 중단 간 실시간 전술 서비스의 성능에 직접적인 영향을 주기 어렵다. 기계학습 기반 무선자원 할당 및 송신세기 조절 기술 연구는 MANET에서 멀티 홉 트래픽의 중단간 지연시간을 감소시키기 위한 기술을 제안한다¹⁵. 해당 연구는 제안 기술이 단대단 지연시간 및 트래픽 전달을 위해 사용되는 슬롯 수 측면에서의 뛰어난 성능을 보였다. 그러나, 단말의 이동으로 인해 토폴로지의 변화가 빈번하게 발생하는 전술 애드혹 네트워크에서 실시간 전술 서비스를 효과적으로 제공하기 위해서는 안정적인 경로를 확보하는 것이 무선자원 할당 방식보다 중요하다. 기계학습 기반 라우팅 경로설정 연구는 에너지 소모, 데이터 손실, 라우팅 오버헤드 및 패킷 전달 성능을 고려한 라우팅 기술을 제안한다¹⁶. 하지만, 실시간 트래픽의 서비스 품질(QoS: Quality of Service)을 고려하지 않기 때문에, 다수의 이종 트래픽이 발생할 경우 실시간 전술 서비스의 성능을 보장하기 어렵다. 그래프 학습 기반 트래픽 정체 완화 연구는 트래픽 발생량에 의한 정체를 완화하는 라우팅 기술을 제안한다¹⁷. 해당 연구는 실시간 서비스의 품질을 고려하는 방식으로, 신호 감쇠가 없는 상황에서는 기존 라우팅보다 높은 성능을 보인다. 하지만, 학습된 모델이 신호의 수준을 완벽히 고려하지 못해, 감쇠가 있는 상황에서는 기존 라우팅보다 낮은 성능을 보인다.

본 논문에서는 네트워크 구성 정보와 실시간 서비스 제공 성능을 고려하여 라우팅 경로 신뢰성 판단 및 선제적 경로 전환을 수행하는 네트워크 기술을 제안한다.

III. AI 기반 라우팅 경로 신뢰성 판단 기술

3.1 경로 신뢰성 판단을 위한 AI 모델 구현

라우팅 경로 신뢰성 판단을 위해, Long Short Term Memory(LSTM)을 기반으로 AI 모델을 구성한다. LSTM은 과거의 정보를 저장하고 필요에 따라 업데이트하는 셀 상태와 셀 상태에 어떤 정보를 저장할지 결정하는 게이트 구조를 적용하여, 입력 정보의 길이가 긴 경우에 과거 학습 내용을 잊어버려 예측에 반영하지 못하는 RNN의 장기 의존성 문제를 극복했다²¹. LSTM은 순차적으로 들어오는 시계열 정보를 바탕으로 향후

발생 상황을 예측하는데 주요하게 사용된다.

경로 신뢰성 판단 AI 모델은 크게 LSTM, Dropout, Linear 및 Sigmoid 계층으로 이루어진다. Dropout은 모델의 과적합을 방지하기 위해 일정 확률로 뉴런 중 일부를 제거하고 특정 요소만을 학습하기 위해 사용되며, Linear는 입력 데이터의 차원 변환을 위해 사용된다. Sigmoid는 라우팅 경로 신뢰성 판단을 위한 활성화 함수이다.

AI 모델이 실시간 트래픽 송신 경로의 신뢰성을 판단하기 위해 입력받는 정보는 광대역 및 협대역 네트워크 기술의 설계내용에 따라 달라질 수 있다. 본 논문에서는 AI 모델의 입력하는 네트워크 메트릭을 1~2홉(광대역) 또는 1~3홉(협대역) 링크 품질에 대한 지표와 실시간 트래픽의 성공률, 지연 및 지터로 한다.

광대역 및 협대역 네트워크에서의 학습 정보 수집 시나리오는 각각 그림 1과 그림 2에 나타낸다. 광대역 네트워크에서는 5홉 실시간 트래픽을 송신하며, 송신 노드 기준 1홉 및 2홉 노드가 차례대로 경로 단절까지 이동 후 복귀한다. 협대역 네트워크에서는 3홉 실시간 트래픽을 송신하며, 송신 노드 기준 1홉, 2홉 및 3홉 노드가 차례대로 경로 단절까지 이동 후 복귀한다. 광대




그림 1. 광대역 네트워크의 5홉 실시간 트래픽 경로 신뢰성 판단을 위한 네트워크 메트릭 수집 시나리오
Fig. 1. Network Metric Collecting Scenario for 5hop Real-time Traffic Path Reliability Assessment in a Wideband Network




그림 2. 협대역 네트워크의 3홉 실시간 트래픽 경로 신뢰성 판단을 위한 네트워크 메트릭 수집 시나리오
Fig. 2. Network Metric Collecting Scenario for 3hop Real-time Traffic Path Reliability Assessment in a Narrowband Network

역 및 협대역 네트워크 메트릭 수집 시나리오는 모델링 및 시뮬레이션 (M&S: Modeling and Simulation)에 적용되며, 수집된 메트릭은 AI 모델의 학습 정보 생성을 위해 사용된다.

AI 모델의 학습 정보는 M&S를 통해 수집된 정보에 실시간 트래픽 경로에 대한 신뢰성 평가 결과를 종합하여 생성한다. 광대역 및 협대역 네트워크에서 발생한 실시간 트래픽의 성공률, 지연 및 지터가 QoS 요구 조건을 만족할 경우 경로를 신뢰할 수 있는 것으로, 반대의 경우 신뢰할 수 없는 것으로 평가 결과를 기록하여 네트워크 메트릭에 따라 경로 신뢰성을 예측할 수 있도록 AI 모델을 학습시킨다.

AI 모델의 학습을 위한 파라미터는 표 1과 같다. 광대역 네트워크 학습 데이터는 676개이고, 협대역 학습 데이터는 471개이다. 이 중 80%를 학습용으로, 20%를 AI 모델 성능 확인 및 검증을 위해 사용한다. 데이터의 길이는 8로, 광대역 및 협대역 네트워크 메트릭의 수

표 1. 라우팅 경로 신뢰성 판단 AI 모델의 학습 설정
Table 1. Learning Settings of AI Model for Routing Path Reliability Assessment

Parameter		Value
The Number of Data	Wideband	676
	Narrowband	471
Data Usage	Learning	80%
	Validation	20%
Sequence Length		8
Batch Size		16
Epoch Length		300
Loss Function		Mean Squared Error
Optimization Function		Adam (Learning Rate : 0.001)



그림 3. 광대역 네트워크 메트릭 및 라우팅 경로 신뢰성 학습에 의한 학습 손실 측정 결과
Fig. 3. Training Loss Measurement Result based on Wideband Network Metrics and Routing Path Reliability Learning

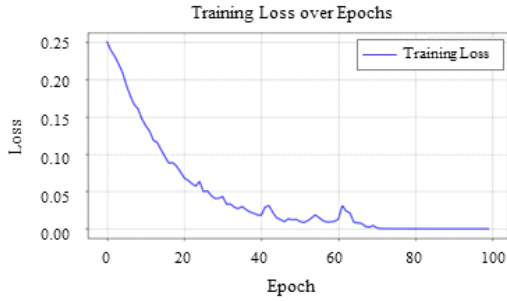


그림 4. 협대역 네트워크 메트릭 및 라우팅 경로 신뢰성 학습에 의한 학습 손실 측정 결과
 Fig. 4. Training Loss Measurement Result based on Narrowband Network Metrics and Routing Path Reliability Learning

보다 크게 설정한다. 16개씩의 데이터로 학습 1회를 수행하며, 전체 데이터를 총 300회 학습한다. 손실 함수는 Mean Squared Error이며, 최적화 함수는 Adam이다. 그림 3과 그림 4는 각각 광대역 및 협대역 네트워크 메트릭과 라우팅 경로 신뢰성을 학습하면서 얻은 학습 손실 측정 결과를 나타낸다. 두 그림 모두 학습 진행 과정에서 손실이 점차 감소하는 양상을 확인할 수 있다. 이는 LSTM 기반의 AI 모델이 데이터를 안정적으로 학습하였음을 나타낸다.

3.2 경로 신뢰성 판단을 위한 정보 수집 및 전달 구조

본 논문의 제안 기술에 적용되는 AI 모델은 네트워크 메트릭을 입력으로 해서, 연산 이후 경로 신뢰성에 대한 판단 결과를 출력한다. 따라서, MAC, 라우팅 및 전송 계층은 AI에 전달할 정보를 수집한다.

AI 모델에 라우팅 경로 신뢰성 판단 정보를 전달하기 위한 네트워킹 계층별 정보 수집 및 전달 구조를 그림 5에 나타낸다. 전송 계층은 AI 모델과 연동하고 실시간 트래픽 송신 경로의 전환 여부를 결정한다. 따라서, MAC 계층과 라우팅 계층 간, 그리고 라우팅 계층과 전송 계층 간에 정보 전달을 위한 인터페이스를 구성한다. MAC 계층은 최대 2홉까지 노드 간 연결링크에 대한 품질 정보를 수집 및 관리하고 이를 MAC-라우팅 인터페이스를 통해 라우팅 계층으로 전달한다. 광대역 라우팅은 최대 2홉까지, 협대역 라우팅은 최대 3홉까지의 링크 품질 정보를 수집 및 관리하고 트래픽 송신 경로에 대한 링크 품질 정보를 라우팅-전송 인터페이스를 통해 전송 계층으로 전달한다. 전송 계층은 필요 정보를 트래픽 목적지 단말로부터 수집하며, 주기적으로 MAC, 라우팅 및 전송 계층에서 수집한 정보를 AI 모델

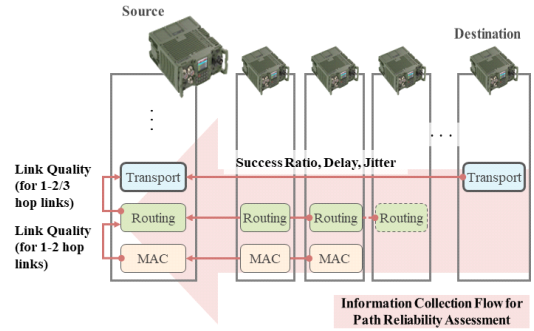


그림 5. 라우팅 경로 신뢰성 판단을 위한 네트워킹 계층별 정보 수집 및 전달 구조
 Fig. 5. Network Layer-wise Information Collecting and Forwarding Structure for Routing Path Reliability Assessment

에 전달 할 수 있도록 관리한다.

3.3 경로 신뢰성 판단 기반 라우팅 경로 전환 기술

전송 계층은 AI 모델과 연동하여 트래픽 송신을 위한 주 경로에 대해 신뢰성 평가 결과를 얻으며, 신뢰성이 임계값 이하인 경우 트래픽 송신 경로를 대체 경로로 전환한다. 라우팅 경로 전환을 위한 연동 구조는 그림 6과 같다. 3.2절에 설명한 바와 같이, 소스 노드의 전송 계층은 트래픽 송신 경로와 관련된 네트워크 메트릭을 수집한다. 주기적으로 AI 모델에 경로 신뢰성 판단을 요청할 때 수집된 메트릭이 함께 전달된다. AI 모델은 전송 계층의 요청에 대해 네트워크 메트릭 기반의 경로

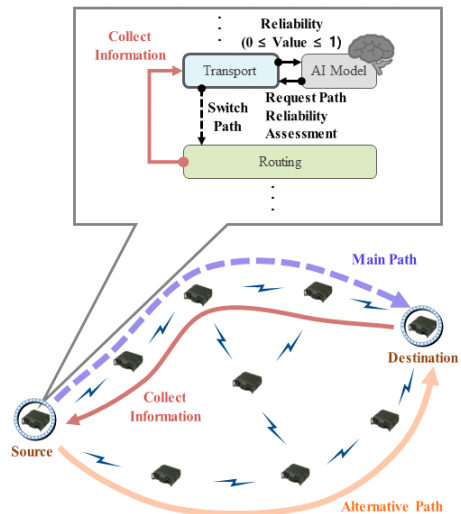


그림 6. 경로 신뢰성 판단 결과 기반 트래픽 경로 전환을 위한 AI 모델, 전송 및 라우팅 연동 구조
 Fig. 6. Integration Structure of AI Model, Transport and Routing for Path Reliability Assessment based Traffic Path Switching

신뢰성 평가 결과로 응답한다. 신뢰성 평가 결과는 0 이상 1 이하의 값이며, 이 값이 임계값 이하일 경우 전송 계층이 라우팅 계층으로 트래픽 송신경로 전환을 요청한다.

IV. 모의실험

4.1 AI 모델 연동 모의실험 환경

AI 모델 연동 및 모의실험을 위한 테스트베드 아키텍처는 그림 7과 같다. Riverbed Modeler(구 OPNET Modeler) 18.6 버전을 설치한 PC와 경로 신뢰성 판단을 위한 AI 모델이 탑재된 NVIDIA Jetson Nano 보드를 이더넷으로 연결하여 테스트베드를 구축한다. Riverbed Modeler의 노드 모델에는 응용 트래픽 특성을 반영한 응용계층과 트래픽 전송을 제어하는 전송 계층 프로토콜을 포함하여, 광대역/협대역 통신을 위해 개발한 MAC 및 라우팅 프로토콜이 적용된다. 전송 계층은 AI 모델과 외부 인터페이스를 통해 연동된다. 모의실험 시나리오는 AI 기반 라우팅 경로 신뢰성 판단 기술의 효과를 확인하기 위해 구성되었으며, 실험 결과는 4.2절에서 상세히 설명한다.

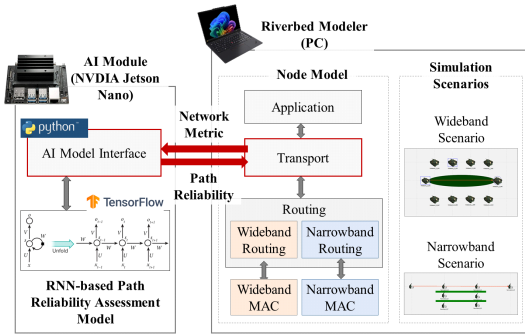


그림 7. AI 모델 연동 및 모의실험 수행을 위한 테스트베드 아키텍처
Fig. 7. Testbed Architecture for Integrating AI Model and Conducting Simulation

4.2 모의실험 결과

전송 애드혹 네트워크에서 노드들은 그룹 단위로 이동하며, 이동 중에 그룹들이 동일 지역으로 집결하고 서로 다른 지역으로 전개하는 과정을 반복한다. 또한, 지형으로 인해 링크가 단절되는 상황도 발생할 수 있다. 이와 같은 전송 애드혹 네트워크의 특징을 반영하여 광대역 및 협대역 네트워크 기반 모의실험 시나리오를 구성한다.

광대역 환경을 대상으로 제안 기술의 효과성을 확인하기 위한 모의실험 파라미터 및 토폴로지를 각각 그림 8과 표 2에 나타낸다. 5홉 실시간 트래픽 송수신을 위한 주 경로 및 대체 경로를 형성할 수 있도록 10개 노드를

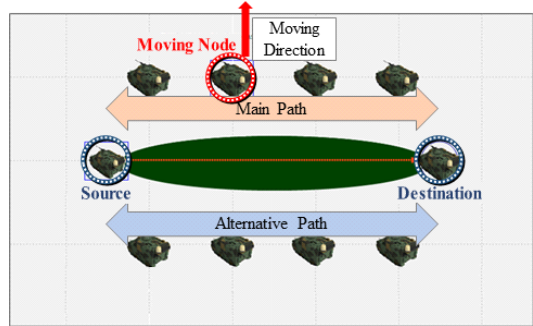


그림 8. 광대역 네트워크에서의 라우팅 경로 신뢰성 판단 기술 모의실험 토폴로지
Fig. 8. Simulation Topology for Evaluating Routing Path Reliability Assessment Scheme in Wideband Network

표 2. 광대역 네트워크에서의 라우팅 경로 신뢰성 판단 기술 모의실험 파라미터
Table 2. Simulation Parameters for Evaluating Routing Path Reliability Assessment Scheme in Wideband Network

Configurations		Value
Topology	The Number of Nodes	10
	The Number of Paths	2 (Main and Alternative Paths)
	Mobility	<ul style="list-style-type: none"> • Moving Node : One of the nodes located on the main path • Moving Time : During Traffic Generation Time • Topology Restoration : During Traffic Pause Time
Traffic Characteristics		<ul style="list-style-type: none"> • Traffic Generation Time : 10 min • Traffic Pause Time : 10 min • The Number of Repeat (Generation/Pause) : 8 • Packet Size : 800 bytes • Packet Generation Rate : 10 packets/sec
Signal Attenuation		<ul style="list-style-type: none"> • Path Loss • Random Attenuation : 0~1 dB
Criterion to Switching Routing Path		<ul style="list-style-type: none"> • Existing Scheme : Upon route error message is received • Proposed Scheme : When path reliability is below 0.2 (Moving Average Window Size : 3)

배치한다. 트래픽 전달 중에 주 경로의 신뢰성이 저하되는 상황을 만들기 위해, 주 경로에 위치한 하나의 노드가 경로 단절 상황까지 이동하도록 시나리오를 구성한다. 트래픽은 10분 발생 및 10분 휴식을 8회 반복하도록 설정한다. 주파수 특성의 임의성을 반영하고자, 거리에 따른 신호 감쇠 뿐만 아니라 0~1dB 사이의 임의 감쇠를 적용한다. 다음의 내용에서, AI 기반 라우팅 경로 신뢰성 판단 기술 적용 여부에 따른 광대역 네트워크 성능 분석 결과를 제시한다.

광대역 환경에서 라우팅 경로 신뢰성 판단을 위한 AI 모델을 적용하지 않았을 때 Min-Max 정규화된 링크 품질 값, 라우팅의 주 경로 데이터 전달량 및 MAC 계층 재전송량 측정 결과를 그림 9에 나타낸다. 광대역 환경에서 링크 품질이 약 0.4 이하일 경우 경로 단절이




그림 9. 광대역 네트워크에서 라우팅 경로 신뢰성 판단 기술 미적용시 링크 품질, 라우팅 계층에 의한 주 경로 데이터 전달량 및 MAC 계층 재전송 성능 측정 결과
Fig. 9. Results of Link Quality, Data Forwarded to Main Path by Routing Layer, and MAC Layer Retransmission Performance Measurements When Routing Path Reliability Assessment Scheme is Not Applied in Wideband Network

발생하며, 이에 의해 경로 오류 메시지가 발생한다. 경로 오류를 인지하고 새로운 송신 경로로 트래픽 전달을 결정하기까지 시간이 소요되어, 라우팅 계층에서는 일정 시간 동안 기존 경로로 트래픽을 전달한다. 따라서, MAC 계층에서는 링크 품질이 낮고 새로운 트래픽 송신 경로가 결정되기까지 재전송이 발생하게 된다.

광대역 환경에서 AI 모델 기반 라우팅 경로 신뢰성 판단 기술을 적용했을 때 Min-Max 정규화된 링크 품질, 라우팅의 주 경로 데이터 전달량 및 MAC 계층 재전송량 측정 결과를 그림 10에 나타낸다. 제안 방법 미 적용 상황과 동일하게 링크 품질이 약 0.4 이하일 경우 경로 단절이 발생하지만, 경로 신뢰성 판단에 의해 트래픽 송신 경로 변경이 주 경로 단절 이전에 발생한다.

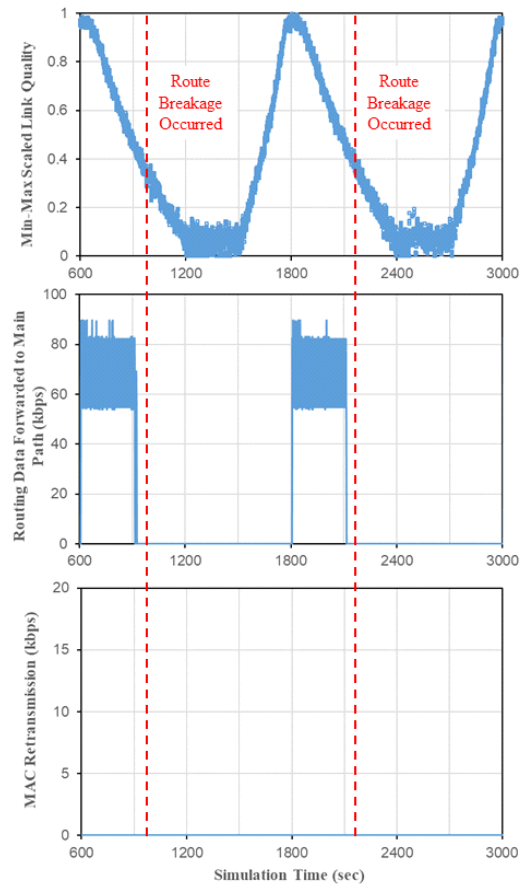


그림 10. 광대역 네트워크에서 라우팅 경로 신뢰성 판단 기술 적용시 링크 품질, 라우팅 계층에 의한 주 경로 데이터 전달량 및 MAC 계층 재전송 성능 측정 결과
Fig. 10. Results of Link Quality, Data Forwarded to Main Path by Routing Layer, and MAC Layer Retransmission Performance Measurements When Routing Path Reliability Assessment Scheme is Applied in Wideband Network

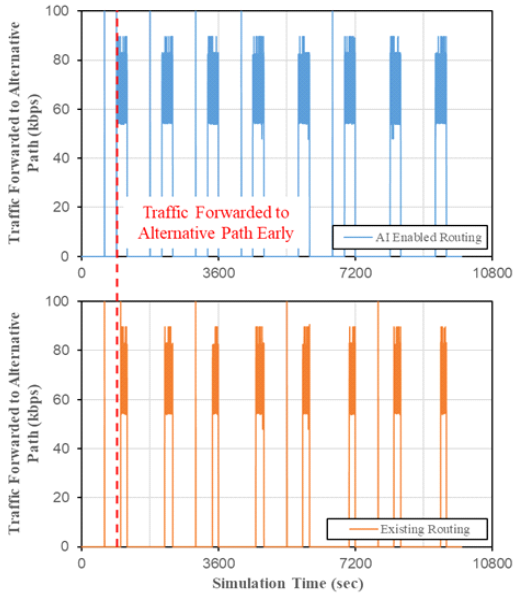


그림 11. 광대역 네트워크에서 라우팅 경로 신뢰성 판단 기술 적용 여부에 따른 대체 경로 트래픽 송신량 비교 결과
Fig. 11. Comparison of Traffic Volume for Alternative Path According to The Application of Routing Path Reliability Assessment Scheme in Wideband Network

따라서, MAC 계층에서도 재전송이 발생하지 않는다.

그림 11은 제안 방법 적용 여부에 따른 대체 경로 트래픽 송신량 측정 결과를 나타낸다. 그림의 붉은 점선을 통해, 제안 방법을 적용하면 상기 설명과 같은 이유로 트래픽 송신 경로 전환이 더 빠르게 일어나는 결과를 확인할 수 있다.

표 3은 4번의 모의실험을 반복 수행하여 얻은 AI 모델 적용 여부에 따른 네트워크 성능지표 평균을 보인다. 측정 지표는 경로 단절 대응 시간, 전송 성공률 및 평균 중단 간 지연시간이다. 경로 단절 대응 시간은 경로 단절 시점부터 트래픽 송신 경로 전환이 일어나기까지의 소요 시간을 의미하며, 0보다 작은 경우에는 경로 전환이 단절보다 이전에 발생했음을 나타낸다. 제안 방

표 3. 광대역 네트워크에서의 라우팅 경로 신뢰성 판단 기술 모의실험 파라미터
Table 3. Simulation Parameters for Evaluating Routing Path Reliability Assessment Scheme in Wideband Network

Routing Scheme	Response Time for Route Breakage (sec)	Packet Delivery Ratio (%)	Average E2E Delay (sec)
AI Enabled Routing	-26.588	100.0	1.963
Existing Routing	82.665	99.83	2.136

법을 사용할 경우, AI의 라우팅 경로 신뢰성 판단 결과를 바탕으로 선제적인 트래픽 송신 경로 전환이 발생한다. 따라서, 링크 단절이 발생한 경로로 트래픽을 송신하지 않아 기존 방식보다 높은 패킷 전달 성공률 및 낮은 중단 간 지연시간을 보인다.

협대역 환경을 대상으로 제안 기술의 효과성을 확인하기 위한 모의실험 파라미터 및 토폴로지를 각각 그림 12와 표 4에 나타낸다. 3홉 실시간 트래픽 송수신을 위한 주 경로 및 2개의 대체 경로를 형성할 수 있도록 8개 노드를 배치한다. 트래픽 전달 중에 주 경로의 신뢰성이 저하되는 상황을 만들기 위해, 주 경로에 위치한 하나의 노드가 경로 단절 상황까지 이동하도록 시나리오를 구성한다. 트래픽은 17분 발생 및 3분 휴식을 7회 반복하도록 설정한다. 주파수 특성의 임의성을 반영하고자, 거리에 따른 신호 감쇠 뿐만 아니라 0~1dB 사이의 임의 감쇠를 적용한다. 트래픽 송신 경로를 전환해야 하는 경우, 협대역 라우팅은 경로 홉 수, 링크 품질 등을 고려하여 대체경로 중 하나를 주 경로로 선택한다. 다음

표 4. 협대역 네트워크에서의 라우팅 경로 신뢰성 판단 기술 모의실험 파라미터
Table 4. Simulation Parameters for Evaluating Routing Path Reliability Assessment Scheme in Narrow Network

Configurations		Value
Topology	The Number of Nodes	8
	The Number of Paths	3 (Main and Two Alternative Paths)
	Mobility	<ul style="list-style-type: none"> • Moving Node : One of the nodes located on the main path • Moving Time : During Traffic Generation Time • Topology Restoration : During Traffic Pause Time
Traffic Characteristics		<ul style="list-style-type: none"> • Traffic Generation Time : 17 min • Traffic Pause Time : 3 min • The Number of Repeat (Generation/Pause) : 7 • Packet Size : 500 bytes • Packet Generation Rate : 2 packets/sec
Signal Attenuation		<ul style="list-style-type: none"> • Path Loss • Random Attenuation : 0~1 dB
Criterion to Switching Routing Path		<ul style="list-style-type: none"> • Existing Scheme : Minimum link quality of routing path is below threshold • Proposed Scheme : When path reliability is below 0.3




그림 12. 협대역 네트워크에서의 라우팅 경로 신뢰성 판단 기술 모의실험 토폴로지
 Fig. 12. Simulation Topology for Evaluating Routing Path Reliability Assessment Scheme in Narrowband Network

의 내용에서, AI 기반 라우팅 경로 신뢰성 판단 기술 적용 여부에 따른 협대역 네트워크 성능 분석 결과를 제시한다.

협대역 네트워크는 광대역 네트워크와 달리, 전송할 수 있는 정보의 양이 극히 적다. 따라서, 협대역 라우팅

은 주기적으로 송신하는 Hello 메시지에 이웃 노드와의 링크 품질 정보를 포함하여, 경로 단절에 대응한다. 따라서, 기존 라우팅 방식에 대해 경로 단절 대응을 위한 링크 품질 임계값을 파라미터로 설정한다.

그림 13과 그림 14는 각각 제안 방법 적용 여부에 따른 주 경로 및 대체 경로 트래픽 송신량 측정 결과를 나타낸다. 실험 결과의 붉은색 점선을 통해, 기존 라우팅 방식에서 링크 품질 임계값을 높게 설정할수록 주 경로를 통한 트래픽 전달 중단과 대체 경로를 통한 트래픽 전달 시작이 빠르게 일어나는 결과를 확인할 수 있다. 이는 트래픽 송신 경로의 전환이 빠르게 일어나는 것을 의미한다. 또한, AI 기반의 라우팅 경로 전환 기술을 적용하는 경우, 링크 품질 임계값을 비교적 높게 설정한 경우보다도 빠르게 경로 신뢰성 저하에 대응할 수 있음을 확인할 수 있다. 이와 같은 결과를 얻은 이유는

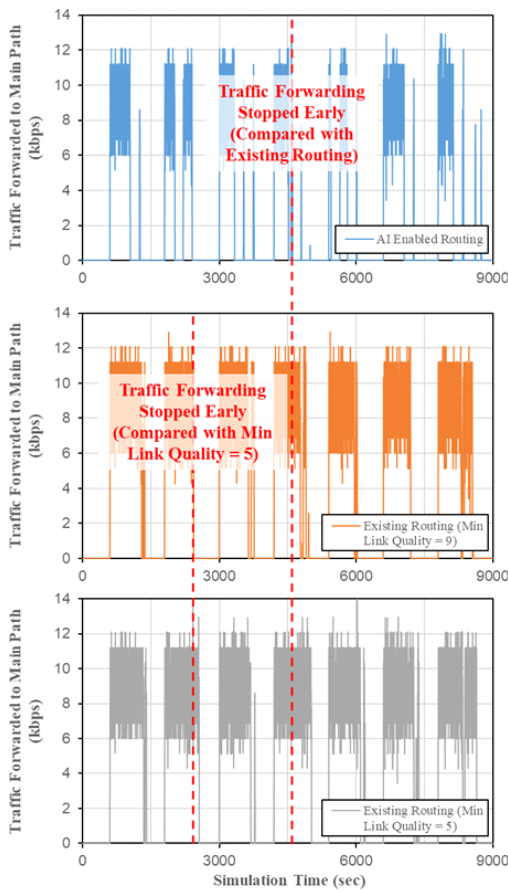


그림 13. 협대역 네트워크에서 라우팅 경로 신뢰성 판단 기술 적용 여부에 따른 주 경로 트래픽 송신량 비교 결과
 Fig. 13. Comparison of Traffic Volume for Main Path According to The Application of Routing Path Reliability Assessment Scheme in Narrowband Network

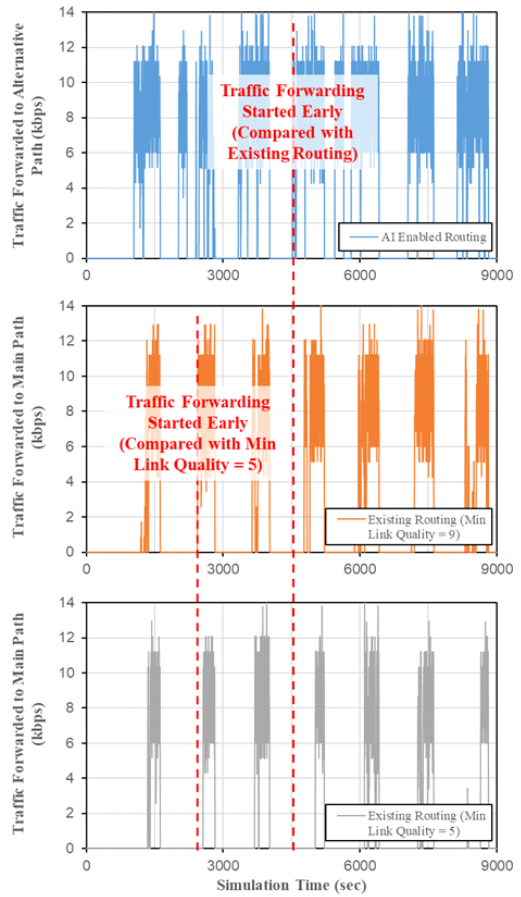


그림 14. 협대역 네트워크에서 라우팅 경로 신뢰성 판단 기술 적용 여부에 따른 대체 경로 트래픽 송신량 비교 결과
 Fig. 14. Comparison of Traffic Volume for Alternative Path According to The Application of Routing Path Reliability Assessment Scheme in Narrowband Network

표 5. 협대역 네트워크에서 AI 모델 적용 여부에 따른 경로 단절 대응 시간, 전송 성공률 및 평균 종단 간 지연 비교 결과

Table 5. Comparison of Route Breakage Response Time, Packet Delivery Ratio, and Average E2E Delay According to The Application of AI Models in Narrowband Network

Routing Scheme	Route Breakage Response Time (sec)	Packet Delivery Ratio (%)	Average E2E Delay (sec)
AI Enabled Routing	-221.11	97.45	3.778
Existing Routing (Min Link Quality = Mid)	-10.54	97.00	3.765
Existing Routing (Min Link Quality = Low)	142.57	93.60	3.885

AI 학습 시 링크 품질 뿐만 아니라 전송 계층에서의 성능지표 또한 학습 정보로 주었기 때문이다. 네트워크 성능이 감소할 경우 경로 신뢰성 저하를 인지하여, AI 모듈이 더 빠르게 경로 단절에 대응할 수 있음을 확인할 수 있다.

표 5는 4번의 모의실험을 반복 수행하여 얻은 AI 모델 적용 여부에 따른 네트워크 성능지표 평균을 보인다. 제안 방법을 사용할 경우, AI의 라우팅 경로 신뢰성 판단 결과를 바탕으로 선제적인 트래픽 송신 경로 전환이 발생한다. 따라서, 전송 성공률이 링크 품질의 임계값을 중간 또는 낮은 값으로 했을 때 보다 높은 결과를 보인다. 종단간 지연시간은 품질 임계값이 중간일 때 보다 높은 결과를 확인할 수 있다. 이는 전송 성공률이 높아 지연이 큰 패킷도 도달하기 때문이다.

V. 결론 및 향후연구

본 논문에서는 종단 간 실시간 서비스를 안정적인 성능으로 제공하기 위해 AI 모델을 기반으로 라우팅 경로의 신뢰성을 판단하는 기술을 제안한다. 주 경로와 대체 경로가 모두 존재하는 광대역/협대역 전송 환경에서 모의실험을 수행한 결과, 제안 방법을 적용한 경우 주경로의 신뢰성이 감소하는 것을 신속하게 판단하고 선제적으로 트래픽을 대체경로를 통해 송신할 수 있음을 확인하였다. 따라서, 제안 방법을 적용하면 적용하지 않은 경우보다 트래픽 전송 성공률이 증가하고 평균 종단간 지연이 감소하여 실시간 서비스를 더욱 안정적인 성능으로 제공할 수 있다.

향후연구에서는 라우팅 경로 신뢰성 감소에 대한 오

탐지율을 최소화 할 수 있도록 AI 모델을 최적화하는 연구를 수행하고자 한다. 또한, 다양한 특성의 트래픽을 적용하고 노드 이동성 모델 및 실 지형 기반의 신호 감쇠 모델을 적용하는 등 보다 실제적인 전송네트워크 운용 시나리오에서 AI 모델 적용 네트워크 기술의 모의 실험을 수행하여 제안방법의 성능을 평가하고자 한다.

References

- [1] H. Li, G. Yan, X. Zhao, J. Zhang, and M. Lyu, "Tactical mission event logic graph construction for network-centric warfare," *Alexandria Eng. J.*, vol. 61, no. 11, pp. 9161-9173, Nov. 2022. (<https://doi.org/10.1016/j.aej.2022.02.055>)
- [2] K. J. Seo, "A study on the application of optical wireless communication in network centric warfare," *J. Korea Academia-Industrial Cooperation Soc.*, vol. 25, no. 7, pp. 554-562, Jul. 2024. (<https://doi.org/10.5762/KAIS.2024.25.7.554>)
- [3] A. Lie, J. E. Håkegård, T. Ulversøy, V. L. Nir, U. Sterner, A. Hansson, J. Krygier, et al., "Dynamic spectrum management and routing solutions for multi-radio mobile ad hoc networks," *IEEE Trans. Cognitive Commun. and Netw.*, vol. 10, no. 2, pp. 580-593, Nov. 2023. (<https://doi.org/10.1109/TCCN.2023.3335350>)
- [4] S. Al Ajrawi and B. Tran, "Mobile wireless ad-hoc network routing protocols comparison for real-time military application," *Spatial Inf. Res.*, vol. 32, no. 1, pp. 119-129, Sep. 2024. (<https://doi.org/10.1007/s41324-023-00535-z>)
- [5] D. Ramphull, A. Mungur, S. Armoogum, and S. Pudaruth, "A review of mobile ad hoc NETWORK (MANET) protocols and their applications," in *2021 5th ICICCS*, pp. 204-211, May 2021. (<https://doi.org/10.1109/ICICCS51141.2021.9432258>)
- [6] Z. A. Younis, A. M. Abdulazeez, S. R. Zeebaree, R. R. Zebari, and D. Q. Zeebaree, "Mobile ad hoc network in disaster area network scenario: A review on routing

- protocols,” *Int. J. Online & Biomedical Eng.*, vol. 17, no. 3, pp. 49-75, Mar. 2021.
(<https://doi.org/10.3991/ijoe.v17i03.16039>)
- [7] K. Shahzad, M. U. Farooq, M. Zeeshan, and S. A. Khan, “Adaptive multi-input medium access control (AMI-MAC) design using physical layer cognition for tactical SDR networks,” *IEEE Access*, vol. 9, pp. 58364-58377, Apr. 2021.
(<https://doi.org/10.1109/ACCESS.2021.3073030>)
- [8] N. Jansen, M. Manso, A. Toth, K. S. Chan, T. H. Bloebaum, and F. T. Johnsen, “NATO core services profiling for hybrid tactical networks –results and recommendations,” in *2021 ICMCIS*, pp. 1-8, May 2021.
(<https://doi.org/10.1109/ICMCIS52405.2021.9486415>)
- [9] Riyanto, S. H. Supangkat, and Iskandar, “Survey on MAC protocol of mobile ad hoc network for tactical data link system,” in *2022 ICITSI*, pp. 134-137, Nov. 2022.
(<https://doi.org/10.1109/ICITSI56531.2022.9971025>)
- [10] M. R. Mahmood, M. A. Matin, P. Sarigiannidis, and S. K. Goudos, “A comprehensive review on artificial intelligence/machine learning algorithms for empowering the future IoT toward 6G era,” *IEEE Access*, vol. 10, pp. 87535-87562, Aug. 2022.
(<https://doi.org/10.1109/ACCESS.2022.3199689>)
- [11] T. Bilen, B. Canberk, V. Sharma, M. Fahim, and T. Q. Duong, “AI-driven aeronautical ad hoc networks for 6G wireless: Challenges, opportunities, and the road ahead,” *Sensors*, vol. 22, no. 10, pp. 1-18, May 2022.
(<https://doi.org/10.3390/s22103731>)
- [12] L. Song, X. Hu, G. Zhang, P. Spachos, K. N. Plataniotis, and H. Wu, “Networking systems of AI: On the convergence of computing and communications,” *IEEE Internet of Things J.*, vol. 9, no. 20, pp. 20352-20381, May 2022.
(<https://doi.org/10.1109/JIOT.2022.3172270>)
- [13] A. A. Ali, M. K. Hussein, M. A. Subhi, “A Classifier-driven deep learning clustering approach to enhance data collection in MANETs,” *Mesopotamian J. CyberSecurity*, vol. 4, no. 3, pp. 36-45, Sep. 2024.
(<https://doi.org/10.58496/MJCS/2024/014>)
- [14] V. S. N. Reddy, and J. Mungara, “Machine learning-based efficient clustering and improve quality of service in manet,” *Indian J. Computer Sci. and Eng.*, vol. 12, no. 5, pp. 1392-1399, Sep. 2021.
(<https://doi.org/10.21817/indjcse/2021/v12i5/211205072>)
- [15] K. Danilchenko, R. Azoulay, S. Reches, and Y. Haddad, “Deep learning method for delay minimization in MANET,” *ICT Express*, vol. 8, no. 1, pp. 7-10, Mar. 2022.
(<https://doi.org/10.1016/j.icte.2022.01.004>)
- [16] K. Chandravanshi, G. Soni, J. Ahmed, C. Gautam, and K. Khan, “Machine learning technique for mobility and signal strength-based route selection in MANET,” in *2024 First Int. Conf. Software, Syst. and Inf. Technol. (SSITCON)*, pp. 1-7, Oct. 2024.
(<https://doi.org/10.1109/SSITCON62437.2024.10796596>)
- [17] Y. Maret, M. Raza, F. Legendre, J. Wang, N. Bessis, and J. F. Wagen, “Investigation of a GNN approach to mitigate congestion in a realistic MANET scenario,” *Procedia Computer Sci.*, vol. 205, pp. 127-136, Sep. 2022.
(<https://doi.org/10.1016/j.procs.2022.09.014>)
- [18] V. Mnih, K. Kavukcuoglu, D. Silver, A. Graves, I. Antonoglou, D. Wierstra, and M. Riedmiller, “Playing atari with deep reinforcement learning,” *arXiv preprint arXiv:1312.5602*, Dec. 2013.
(<https://doi.org/10.48550/arXiv.1312.5602>)
- [19] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu, and M. S. Lew, “Deep learning for visual understanding: A review,” *Neurocomputing*, vol. 187, pp. 27-48, Apr. 2016.
(<https://doi.org/10.1016/j.neucom.2015.09.116>)
- [20] C. Zhang, P. Patras, and H. Haddadi “Deep learning in mobile and wireless networking: A survey,” *IEEE Commun. Surv. & Tuts.*, vol.

21, no. 3, pp. 2224-2287, Mar 2019.

(<https://doi.org/10.1109/COMST.2019.2904897>)

[21] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735-1780, Nov. 1997.

(<https://doi.org/10.1162/neco.1997.9.8.1735>)

이 철 응 (Cheol-woong Lee)



2015년 2월 : 아주대학교 정보 컴퓨터공학과 학사

2017년 2월 : 아주대학교 컴퓨터공학과 석사

2023년 8월 : 아주대학교 AI융합네트워크학과 박사

2023년 2월~현재 : LIG 넥스원 재직

<관심분야> 전송네트워크 아키텍처, 전송 애드혹 네트워크, 지능형 네트워킹, 네트워크 M&S

[ORCID: 0000-0001-9287-7034]

이 동 근 (Dongkeun Lee)



1999년 2월 : 건국대학교 컴퓨터공학과 학사

2001년 2월 : 건국대학교 컴퓨터공학과 석사

2006년 8월 : 건국대학교 컴퓨터공학과 박사

2007년 10월~현재 : LIG 넥스원 재직

<관심분야> 전송네트워크 아키텍처, 전송 애드혹 네트워크, 지능형 네트워킹

최 정 옥 (Jungwook Choi)



2009년 2월 : 광운대학교 컴퓨터공학과 학사

2011년 2월 : 광운대학교 컴퓨터공학과 석사

2011년 1월~현재 : LIG 넥스원 재직

<관심분야> 전송네트워크 아키텍처, 전송 애드혹 네트워크, 지능형 네트워킹, 네트워크 M&S

박 수 범 (Soo Beom Park)



2001년 8월 : 한국과학기술원 전기및전자공학과 학사

2006년 2월 : 한양대학교 미디어통신공학전공 석사

2007년 10월~현재 : LIG 넥스원 재직

<관심분야> 전송 애드혹 네트워크, 전송 데이터링크, 네트워크 M&S, 딥러닝

이 민 (Min Lee)



2006년 8월 : 아주대학교 전자공학부 학사

2014년 8월 : 아주대학교 전자공학부 박사

2014년 11월~현재 : LIG 넥스원 재직

<관심분야> 무선 MAC 프로토콜, 국방 전송네트워크, 군집무인기 네트워크 등

[ORCID:0000-0001-9202-1658]

장 재 원 (Jae-Won Jang)



2023년 2월 : 대구가톨릭대학교 모바일 소프트웨어 전공 학사

2024년 3월~현재 : 순천향대학교 소프트웨어 융합학과 석사과정

<관심분야> 딥러닝, 시계열, 네트워크 시스템

김 대 영 (Dae-Young Kim)



2015년 9월~2017년 8월: 창신
대학교 컴퓨터소프트웨어 공
학과 조교수

2017년 2월~2021년 2월: 대구
가톨릭대학교 컴퓨터소프트
웨어학부 조교수

2021년 3월~현재: 순천향대학
교 컴퓨터소프트웨어공학과 조교수

<관심분야> 인텔트 기반 지능형 시스템, 네트워크
시스템 AI, IoT 시스템

이 성 형 (Sung-Hyung Lee)



2007년 2월: 아주대학교 전자
공학부 학사

2009년 2월: 아주대학교 전자
공학과 석사

2017년 8월: 아주대학교 전자
공학과 박사

2018년 3월~현재: 솔빛시스템
재직

<관심분야> 네트워크 M&S, 디지털트윈