

802.11p V2X 통신에서 LSTM 기반 고성능 Link Adaptation 메커니즘

권상원*, 김수현*, 임재한^o

High-Quality Link Adaptation Mechanism Based on LSTM in 802.11p V2X Communication

Sang-Won Kwon*, Su-Hyun Kim*, Jea-Han Lim^o

요약

최근 머신 러닝은 V2X(Vehicle to Everything) 통신에서 급변하는 채널 환경 및 보상 값 예측 성능을 크게 향상시켰다. 그러나 기존의 수신 신호 기반 예측 구조는 송신단의 전송 방식 선택을 통한 성능 안정화가 고려되지 않았다. 이에 본 연구에서는 송신단에서 시행하는 Link Adaptation 시, Long Short Term Memory (LSTM)을 통해 예측한 최적의 전송방식을 채택하는 메커니즘을 제안한다. 또한 Throughput 향상을 위한 트래픽 속도 증가 시 발생하는 버퍼 오버플로우에 대해 LSTM 기반의 오버플로우 예측 및 최저속도제한 알고리즘을 제안한다. Modulation and Code Scheme (MCS) 예측 알고리즘의 적용 시, 지연된 MCS 예측 값을 이용하는 기존의 방식에 비해 평균 10% Throughput 향상되었고, 차량의 속도 증가 및 전송 간격 감소 시 MCS 예측 성능이 더욱 향상되었다. 또한 최저 속도 제한 알고리즘 사용 시, 오버플로우가 발생했던 기존 결과에 비해 2.5배 Throughput이 향상되었고, 5dB~10dB의 SNR에서 Packet Error Rate (PER)이 감소하였다.

키워드 : LSTM, 802.11p, 차량 이동 통신, 링크 적응, 버퍼 오버플로우, PER, throughput

Key Words : LSTM, 802.11p, V2X communication, link adaptation, buffer overflow, PER, throughput

ABSTRACT

Recently, machine learning has improved prediction performance of rapidly changing channel environments and compensations in V2X communication. However, conventional prediction system based on received signals did not consider performance stabilization by deciding the sending method of a transmitter. Thus, we propose a mechanism that adopts optimal sending method derived from Long Short-Term Memory (LSTM) during link adaptation of the transmitter. For increasing throughput, we also propose minimum speed limiting and overflow prediction algorithm to address buffer overflow caused by high traffic speed. When applying the Modulation and Code Scheme (MCS) prediction algorithm, throughput increases by an average of 10% compared to the current method using delayed MCS prediction results. Moreover, MCS prediction performance improves when the vehicle becomes faster, and transmission interval decrease. Through using the proposed scheme, throughput increases by 2.5 times than the current method using minimum speed limitation algorithm, which has overflow problem, and Packet Error Rate (PER) decreases in the range of 5dB to 10dB SNR.

* 본 연구는 광운대학교 우수연구자 지원 사업 2022와 한국연구재단 신소지원기술개발사업 (grant no. NRF-2021M3F3A2A01037962), 한국연구재단 기본연구사업 (grant no. RS-2023-00241628)의 지원을 받아 수행된 연구입니다.

• First Author : Kwangwoon University Department of Software, kwonsw812@gmail.com, 학생회원

◦ Corresponding Author : Kwangwoon University Department of Software, ljhar@kw.ac.kr, 정회원

* Kwangwoon University Department of electronic engineering, rkawns5909@naver.com, 학생회원

논문번호 : 202310-121-A-RN, Received October 30, 2023; Revised January 24, 2024; Accepted February 7, 2024

I. 서 론

최근 인공 신경망의 발달에 따라 다양한 분야에서 인공지능이 이용되고 있다. 기존에 많이 쓰이는 이미지 분야를 뛰어 넘어 이동통신 분야에서도 인공지능을 사용한 기술들이 많이 개발되고 있다^{1,2}. 특히 속도에 따라 채널 환경이 빠르게 변화하는 Vehicle to Everything(V2X) 분야에서 인공지능을 이용한 예측 기반의 알고리즘은 채널 예측 및 보정을 포함한 많은 분야에서 높은 성능 향상을 보여왔다^{3,4}.

기존의 많은 V2X 연구에서 수신 신호의 채널 예측에 인공지능을 이용해 보상 정확도를 높이는 방식을 이용하였다^{3,4}. 그러나 이는 수신단 외에 송신단에서 선택될 수 있는 전송 방식 등을 고려하지 않았다는 점에서 한정적으로 인공지능을 사용한 구조라는 한계가 있다.

V2X 시 시스템에서 송신단은 측정된 채널 환경에 맞추어 전송 방식을 설정하는 Link Adaptation을 기본으로 작동한다. 이 때, 실제보다 낮게 측정된 Signal-to-Noise Rate(SNR)은 안정적인 통신을 위한 송신방식의 선택으로 인해 주파수 및 전력 효율을 떨어뜨린다. 또한 높게 측정된 SNR은 더 빠르고 불안정한 전송 방식의 선택으로 인해 Packet Error Rate (PER)을 증가시키며, 심할 경우 복원이 불가능할 정도로 신호를 손상시킨다⁵⁻⁸.

빠른 속도로 이동하는 차량에서의 위치 및 주변 지형 변동은 신호의 SNR을 포함한 채널 환경을 급격하게 변화시킨다. 따라서 채널환경을 즉각적으로 반영하여 전송 방식을 선택하기 어려운 기존의 방식에서는 주파수 및 전력 효율과 PER 면에서 성능이 떨어진다는 문제점이 존재한다.

따라서 본 논문에서는 송신단에서 Link Adaptation 시에 고려되는 채널 환경을 LSTM(Long Short Term Memory)을 통해 예측하고, 전송 시점을 기준으로 최적의 전송방식을 채택하기 위한 메커니즘을 제안한다.

제안하는 메커니즘을 통해 BS(Base Station)는 LSTM을 이용해 통신 상황에서 과거의 SNR 값을 통해 미래의 SNR 값을 정확하게 예측하고 이를 바탕으로 BS는 최적의 신호 전송 방식을 선택할 수 있게 된다. 또한 본 연구는 시뮬레이션 환경에서 다양한 실험을 통해 기존 방식에 비해 Throughput이 상승하고 PER이 감소하였음을 확인했다.

또한, 시스템의 전송 속도 및 데이터 사이즈에 의해 변화하는 전송 시간에 대하여, 전송 간격과 트래픽 발생 시간 사이에서 발생하는 버퍼 오버플로우가 존재한다. 본 논문에서는 시스템의 Modulation and Code

Scheme(MCS) 예측을 통해 예측된 전송 속도를 바탕으로 버퍼 오버플로우가 발생하지 않는 빠른 속도로의 MCS 할당을 추가로 진행하는 알고리즘을 제안한다.

II. 배경 지식

2.1 무선 통신 환경

본 연구는 V2X 환경의 Wireless LAN(WLAN) 시스템 모델을 고려하며, 차량 이동 통신 시에 사용되는 IEEE 802.11p의 기본 구조를 따른다^{9,10}. 802.11의 전송은 기본적으로 채널의 SNR에 따른 MCS 변경 알고리즘을 기반으로 이루어진다.

BS는 일정한 전송간격을 두고 802.11p 파형을 전송한다. 이 때, 안정적인 전송을 위해 수신단은 전송 성공 시 Ack(Acknowledgement code)을 전송하고, 전송 실패로 판단 시에는 정보를 재전송한다. 최대 재전송 횟수를 초과할 경우 패킷 에러를 증가시킨다⁸.

<그림 1>은 Ack와 트래픽 사이의 작동을 나타내며, 전송이 성공했을 경우 전송 간격 T_I 이후에 새로운 데이터를 전송한다.

<그림 2>는 데이터의 전송 실패를 나타내며, 일정 시간 이후로 Ack가 도착하지 않으므로, 전송간격 T_I 이후에 동일한 데이터를 재전송한다.

<그림 3>은 데이터가 전송 성공했지만 Ack가 전송 실패했을 경우를 나타내며, 이 때도 동일하게 전송 실패로 간주하고 T_I 이후에 동일한 데이터를 재전송한다.

<그림 2>, <그림 3>의 전송 실패로 인해 재전송이 계속될 경우 통신 환경이 좋지 않은 상황에서는 동일한




그림 1. 성공적인 데이터와 Ack전송
Fig. 1. Successful data and Ack transfer




그림 2. 데이터의 전송 실패
Fig. 2. Data transmit failure




그림 3. Ack의 전송 실패
Fig. 3. ACK transmit failure




그림 4. 최대 재전송 횟수 초과
Fig. 4. Maximum retransmissions count exceeded

데이터만이 계속해서 전송된다. 따라서 최대 재전송 횟수를 지정하여 재전송이 최대 횟수를 초과하면 다음 데이터를 전송할 수 있도록 한다. <그림 4>는 최대 재전송 횟수를 초과했을 때의 상황을 나타내며, 전송 대기 시간 T_{re} 동안 최대 재전송 횟수 M_{re} 를 초과하면 다음 데이터를 전송한다.

802.11p의 MCS 규정은 <표 1>과 같으며, 기본 MCS는 0으로 설정되어 있다^[2]. 전송속도가 느리고 모듈레이션의 복잡도가 감소하면 PER이 감소하므로^[5,6] 낮은 MCS를 채택하는 것이 전송 성공 측면에서 합리적이다. 그러나 ^[2]에서 볼 수 있듯이 MCS 채택은 주파수 효율 측면과 높은 연관성을 갖고 있다^[7]. 주파수 효율을 높이는 것은 전송률을 증가시키고, 한정된 자원인 주파수를 이용함에 있어 많은 이점이 있으므로 통신 시스템에 있어 필수적으로 고려되어야 하는 지수이다.

표 1. 802.11P MCS에 따른 PHY 모드
Table 1. PHY Mode according to 802.11P MCS

| MCS | 부호율 | 모듈레이션 | 전송속도 |
|-----|-----|--------|----------|
| 0 | 1/2 | BPSK | 3 Mbps |
| 1 | 3/4 | BPSK | 4.5 Mbps |
| 2 | 1/2 | QPSK | 6 Mbps |
| 3 | 3/4 | QPSK | 9 Mbps |
| 4 | 1/2 | 16 QAM | 12 Mbps |
| 5 | 3/4 | 16 QAM | 18 Mbps |
| 6 | 2/3 | 64 QAM | 24 Mbps |
| 7 | 3/4 | 64 QAM | 27 Mbps |

2.2 차량 이동 모델

2.2.1 나카가미 페이딩 채널

본 논문에서는 차량의 이동으로 인한 경로 변화를 나카가미 페이딩 모델을 이용하여 시뮬레이션 한다^[12]. 나카가미 페이딩에서 랜덤한 채널 상황은 다양한 경로의 산란 및 비산란 신호를 포함하는 신호 모델로 나타낼 수 있으며^[13,14], 페이딩 정도를 나타내는 변수 m 을 통해 확률밀도함수를 다음과 같이 나타낼 수 있다.

$$f(x; m, \Omega) = \frac{2m^m}{\Gamma(m)\Omega^m} x^{2m-1} \exp\left(-\frac{m}{\Omega} x^2\right) \quad (1)$$

이 때 $m = 0$ 이면, 나카가미 페이딩은 레일리 페이딩에서의 특성을 나타내며^[16], m 이 ∞ 로 수렴하면, 가우시안 채널과 동일해진다. x 는 송신 신호, $\Gamma(m)$ 은 감마 함수이며, 수신 전력 Ω 은 거리 d 에 의해 감쇄하는 함수로 나타낼 수 있다.

$$\Omega = \frac{P_t G_t G_r h_t^2 h_r^2}{d^\theta L} \quad (2)$$

P_t 는 송신 전력, G_t 및 G_r 은 송신기와 수신기의 안테나 이득이며, h_t 및 h_r 은 안테나의 높이, L 은 시스템 손실, θ 는 경로 손실 지수이다^[15].

2.2.2 도플러 효과에 의한 시변 채널

이동통신 시스템에서 송수신기가 이동하면 기기의 속도가 전송 파형의 주파수 자체에 영향을 끼치는 도플러 효과가 발생한다. 주파수 축에서 발생한 도플러 효과는 시간 축에서 신호의 속도를 지연시키거나 확산시키는 등 신호에 영향을 끼치기 때문에 이를 미리 파악하고 보정 또는 예방하는 것이 필요하다^[20]. 도플러 효과가 발생할 때, 주파수는 두 송수신기가 가까워질 때 높아지고 멀어질 때 낮아진다.

$$f = f_0 \left[\frac{v+v_r}{v+v_s} \right] \quad (3)$$

f 는 관측된 주파수, f_0 는 파원의 주파수, v 는 파동속도, v_r 은 관측자 속도, v_s 는 파원 속도이다. 이 때, 시간에 따라 변하는 주파수에 따라 시간 축의 수신 파형을 아래와 같이 나타낼 수 있다.

$$r(t) = \sum_{n=0}^N x_n e^{-j2\pi f(t+\phi_n)} \quad (4)$$

$r(t)$ 는 수신 신호이며, x_n 은 도플러 효과가 발생하기 전까지의 신호, ϕ_n 는 n 번째 신호의 주파수 천이에 따른 위상 변화이다²¹⁾.

2.3 LSTM (Long Short Term Memory)

Recurrent Neural Network(RNN)은 일정한 시간에 따라 값이 변하는 시계열 데이터를 사용하는 인공 신경망이다. RNN의 변형 중 하나인 LSTM은 시계열 분석에서 기존의 RNN보다 더 우수한 성능을 보여준다¹⁷⁾.

<그림 5>는 LSTM의 구조이다.

LSTM에서 Cell State는 입력과 이전의 Hidden State의 영향을 직접적으로 받지 않기 때문에 유닛 내에서의 정보 변화가 비교적 적다. 이는 긴 지연시간에도 정확도를 유지할 수 있게 도와준다. Forget Gate에서는 이전 Hidden State와 현재의 입력을 받아 Sigmoid 함수를 거친다. Sigmoid 함수의 결과는 1에서 0 사이의 값이 출력된다. 1과 가까울 수록 이전 상태의 값을 유지하고 0과 가까울 수록 이전 상태의 값을 폐기한다. 따라서 Forget Gate에서 Sigmoid 함수는 들어온 정보에서 값을 얼마나 보존할지 결정한다. Input Gate에서는 Forget Gate와 마찬가지로 이전의 Hidden State와 현재의 입력이 Sigmoid 함수에 들어간다. Input Gate에서는 입력된 두 값이 Hyperbolic Tangent 함수를 거쳐 -1과 1 사이의 값으로 출력된다. 이 두 값을 Hadamard product를 통해 State에 반영할 값을 결정한다. 이렇게 Forget Gate와 Input Gate를 통과한 값들은 Cell State에 Hadamard product와 Summation을 통해 Cell State의 값을 갱신한다. Output Gate는 앞서 계산된 Cell State와 이전의 Hidden State, 현재의 입력을 다음 유닛에 Hidden State로 전달한다. 유닛에서 계산된 Cell State는 Hyperbolic Tangent 함수를 거친다. 이 둘을 Element-wise Product를 하여 현재 유닛의 Hidden State를 결정하고, 이를 내보낸다¹⁹⁾.

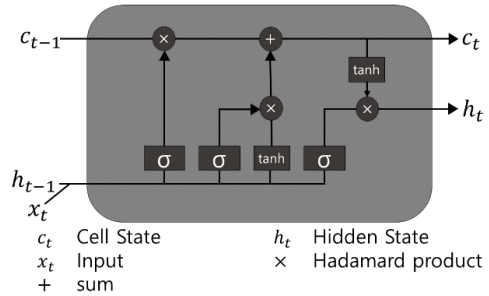


그림 5. LSTM의 구조
Fig. 5. LSTM structure

III. 제안 메커니즘

<그림 6>과 같이 BS에서 일정한 간격으로 전송된 신호는 다양한 채널을 통과한 후 차량에서 수신된다. 본 연구에서는 BS-차량 간 일대일 통신 상황에서 수신 SNR을 측정하고, 이에 따른 LSTM 예측 기반의 MCS 값을 비콘으로 전송하는 메커니즘을 제안한다.

따라서 본 연구에서는, 채널 상황이 양호할 경우 높은 MCS를 채택하여 채널 주파수 효율을 증가시킬 수 있는 Link adaptation 알고리즘을 채택한 무선 통신 환경을 기본으로 한다. 이 때, 채널 상황에 따른 MCS 채택은 SNR을 기준으로 한다. 채널 상황이 나카가미 페이딩을 이용해 적용하며 차량 이동에 의한 도플러 주파수 편이는 차량 속도에 따라 적용한다. 본 연구에서는 등속도 상황에서 도플러 효과에 의한 편이가 동일하게 작동하므로, 이에 따른 왜곡은 완전하게 복원되었다고 가정한다.

수신된 신호의 SNR을 바탕으로 차량은 MCS를 예측하고 BS로 전송한다. LSTM을 이용하여 차량 내부에서 예측이 이루어지며, 현재까지의 SNR 10개로 다음 SNR을 예측한다.

802.11p V2X 통신에서 차량은 일정한 간격으로 BS

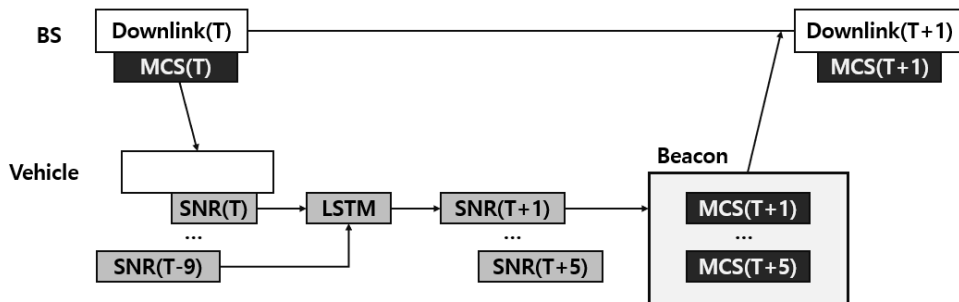


그림 6. T초에서 LSTM을 이용한 MCS 할당 구조
Fig. 6. MCS allocation structure using LSTM at T seconds

에 비콘을 전송하며^[3], 본 논문에서는 LSTM을 통해 예측한 MCS 값을 비콘에 실어 보낸다. 마지막으로, BS는 다음 트래픽 전송 시에 예측된 MCS를 적용하여 전송한다.

이 때, 전송 실패 또는 전송 간격에 따른 딜레이를 해결하기 위해 총 5개의 MCS 값을 전송하며, BS는 전송 시점에 맞는 인덱스 값을 가진 MCS를 채택한다.

<그림 7>은 BS가 차량에게 패킷을 전송하지 못했을 때의 구조이며, 이전에 받은 MCS 중 해당 시간에 적합한 MCS를 채택한다.

<그림 8>은 BS가 트래픽을 전송하는 간격이 비콘의 MCS 전송 간격보다 짧을 때의 구조이며, 차량은 가장 최근의 SNR 값을 기준으로 예측된 MCS를 전송한다. 이 때 전송 실패 구조와 마찬가지로 T+1초의 MCS는 이전 비콘에서 예측한 값을 바탕으로 채택한다.

<그림 9>는 트래픽 전송 간격이 LSTM이 예측시간보다 짧을 때의 구조이며, 차량이 T초에서 예측한 값을




그림 7. 데이터 전송 실패 시 MCS 할당 구조
Fig. 7. MCS allocation structure when data transfer failure




그림 8. 비콘 전송 간격에 따른 MCS 할당 구조
Fig. 8. MCS allocation structure according to beacon transfer interval

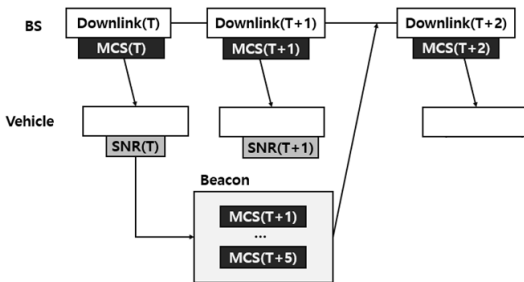


그림 9. LSTM 예측 시간에 따른 MCS 할당 구조
Fig. 9. MCS allocation structure according to LSTM prediction time




그림 10. 기존의 MCS 할당 구조
Fig. 10. Existing MCS allocation structure

T+2초에 수신한다. 이 때 T+1초의 MCS는 이전 비콘에서 예측한 값을 바탕으로 채택하며, T+2초에서는 T초에서 예측한 값을 기반으로 MCS를 채택한다. 이 때, LSTM 예측 시간과 비콘 전송 간격을 고려하여 트래픽 전송 간격 또는 전송 MCS 개수가 조정 가능하다.

그러나 <그림 10>와 같은 기존의 방식에서는 T초에서 측정된 SNR을 기반으로 T+1초의 MCS를 채택한다. 따라서 속도가 빠르게 이동하는 V2X 통신에서는 부적합하며, 전송 실패 및 딜레이 발생 시 새로운 채널 정보를 획득하기 힘들다는 단점이 존재한다.

3.1 LSTM 알고리즘

정확한 MCS 예측을 위해 본 연구에서는 SLTM 신경망이 SNR의 변화를 학습하고 MCS를 예측하도록 하였다. 학습을 위해 SNR 데이터의 전처리 과정에서 데이터의 길이를 패딩을 통해 통일했다.

빠르게 다음 SNR 값을 예측해야 하는 자동차의 특성상 자동차의 속도를 판별하는 시간을 줄이고자 길이를 통일한 데이터들을 모두 이어 붙여 하나의 모델을 통해 학습을 진행하였다.

100ms의 시간 간격에서 t-9시점부터 현재 시점 t까지 10개의 SNR값을 인풋으로 가지고 t+1부터 t+5 시점까지 5개의 SNR값을 예측한다. 따라서 일시적으로 SNR 송신이 실패하더라도 미리 예측한 5개의 SNR값을 이용하여 적절한 MCS를 설정함으로써 이를 대응할 수 있다.

보다 정확한 예측을 위해 LSTM의 학습 Feature로 SNR뿐만 아니라 Distance를 추가적으로 채택하였다^[18]. Distance를 Feature로 채택하게 되면 SNR값이 언제까지 오르고 언제부터 감소할지를 학습할 수 있다. 이와 같이 Multivariate LSTM을 사용하여 높은 정확도를 얻을 수 있다.

3.2 LSTM 기반의 최저 속도 제한 알고리즘

기존 구조보다 향상된 성능을 제공하기 위해서는 시나리오에서 전송 패킷 당 비트 수와 패킷 전송 간격을

조절할 수 있어야 한다⁸⁾. 이 경우 패킷이 빠져나가는 시간보다, 새로운 트래픽이 발생하는 간격이 빠를 경우, 버퍼 오버플로우가 발생한다. 802.11p의 MCS에 따른 패킷 전송 시간은 전송 속도 $v(mcs)$ 로 나타낼 수 있으며 다음과 같다.

$$T = B_p * \frac{c(mcs)}{v(mcs)} \quad (5)$$

제한하는 메커니즘을 통해 LSTM 예측을 이용하여 다음 시점의 MCS를 알 수 있으므로, 패킷 전송 시간 또한 예측 가능하다. 이는, 사용자가 지정한 전송 간격에 대하여 다음 시점에서의 버퍼 오버플로우 발생 여부를 예측 가능하도록 한다.

따라서 이를 바탕으로 본 논문에서는 다음 전송 시 충돌 여부를 예측하고, 충돌이 예상될 때 미리 예측된 MCS를 1 증가시키도록 하는 최저속도제한 알고리즘을 제안한다. MCS의 증가는 패킷의 전송속도를 증가시키므로 이상 패킷의 전송 시 버퍼 오버 플로우가 발생하지 않게 되며, 버퍼 사이즈 충돌로 인해 발생하는 데이터 손실을 방지할 수 있다.

IV. 실험 및 결과 분석

4.1 LSTM 데이터셋 생성 및 SNR 예측

제안 메커니즘의 구현을 위해 LSTM의 학습에 필요한 데이터셋을 생성한다. <표 2>는 V2X 환경에서 차량 한 대의 SNR을 측정하기 위한 환경 파라미터이다. 차량은 같은 방향으로 등속도로 이동하며, 10km/h에서 100km/h까지 10km/h 간격으로 바뀌가며 데이터셋을

생성한다. 차량의 위치는 BS으로부터 100m 떨어진 지점에서 출발하여, 100m 떨어진 지점으로 떨어질 때까지 측정한다.

차량과 BS간 거리가 d_m 떨어져 있을 때, BS에서는 802.11p의 파형 W 를 생성한다. 신호는 d 와 식 (1)~(2)를 반영하여 나카가미 페이딩 채널 H 를 생성하고, 컨볼루션을 통해 채널을 통과한다. 수신기에서의 생성되는 열 잡음은 N 로 나타내며, 아래와 같이 구할 수 있다.

$$N = 10 \log \left(\frac{kBT}{1mW} \right) \quad (6)$$

이 때, T 는 절대온도, B 는 대역폭, k 는 볼츠만 상수이며 밑이 10인 로그를 사용한다. 열 잡음 N 은 신호에 덧셈을 통해 구할 수 있으며, 따라서 차량에서 수신한 신호 R_x 는 아래와 같다.

$$R_x = H * W + N \quad (7)$$

R_x 의 신호 파워를 N 으로 나눈 값을 통해 구한 SNR 값을 거리 및 속도에 따라 측정하고, 1000개의 서로 다른 데이터셋을 생성하여 LSTM을 학습한다.

본 연구에서는 컴퓨팅 파워가 약한 차량에서 LSTM을 원활하게 구동하기 위해 모델을 경량화하는 것이 중요하다. 빠르게 다가오는 차량의 SNR을 예측하기 위해서 LSTM 레이어 2개만을 사용하였으며, 각 유닛의 개수도 적게 사용하였다. 출력 시퀀스의 길이를 5로 설정하였다. 이 때, 나카가미 페이딩에 의한 영향으로, 무작위로 SNR이 급격하게 변하는 지점에서 측정 오류가 발생하였다. 따라서 본 연구에서는 신호를 기준으로 이전 값 2개, 이후 값 2개로 총 5개의 SNR 중 중앙값을 선택해 LSTM을 학습하였다. <그림 11>는 중앙값을 선택한 SNR 데이터셋과 LSTM 예측값을 비교한 그래프이며, 이에 따른 에러는 <그림 12>와 같다.

표 2. SNR 데이터셋 생성 파라미터
Table 2. Parameter for SNR data set generation

| 심볼 | 의미 | 값 |
|----------|------------------|------------------------------------|
| d | 차량 거리 | -100m to 100m |
| v | 차량 속도 | 10/20/30/40/50/60/70/80/90/100km/h |
| s | 패킷 당 비트 | 2000octects |
| M | MCS of 802.11p | 0 |
| T_f | 전송 간격 | 100ms |
| F_s | Sampling rate | 10MHz |
| f_c | Center Frequency | 2.4GHz |
| B | Bandwidth | 10MHz |
| θ | 경로 손실 지수 | 2 |
| k | 볼츠만 상수 | $1.38064852 \times 10^{-23} J/K$ |
| m | 나카가미 페이딩 | 2 |

표 3. LSTM 파라미터
Table 3. LSTM parameter

| LSTM 파라미터 | 값 |
|---------------|-------------------------|
| LSTM layer 1 | 64 units |
| LSTM layer 2 | 32 units |
| Dense layer | 5 units |
| Learning rate | 0.001 |
| Epochs | 20 |
| Batch size | 64 |
| Loss function | MSE (Mean Square Error) |
| Optimizer | Adam |

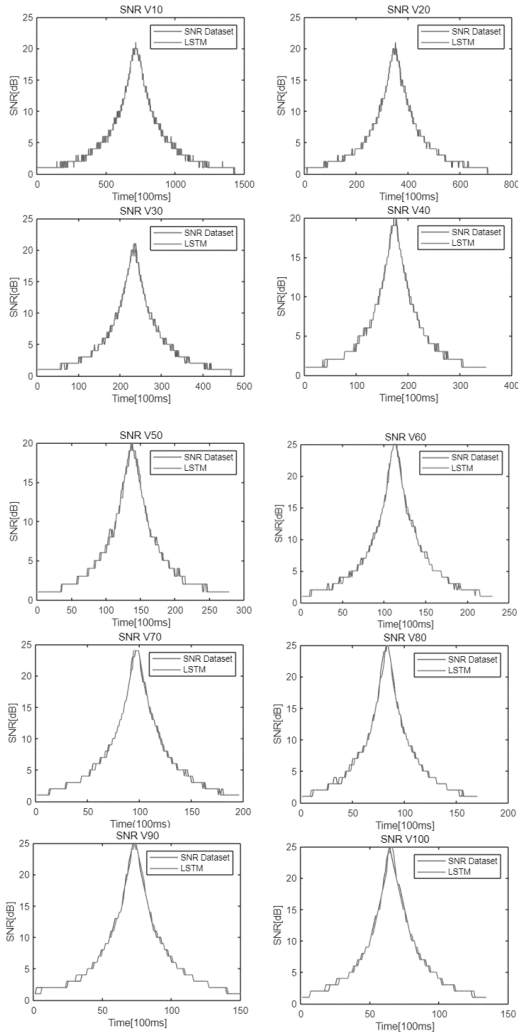


그림 11. 400m 이동 시 표준화된 SNR과 LSTM 예측 SNR
Fig. 11. Standardized SNR and LSTM prediction SNR for 400m movement

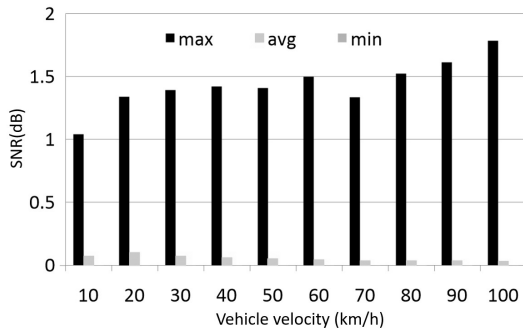


그림 12. 각 속도에 대한 LSTM 예측의 최대, 평균, 최소 에러
Fig. 12. Maximum, average, minimum error in the LSTM prediction for each speed

<그림 12>는 각 속도에서 LSTM의 예측 최대, 평균, 최소 에러이다. 이 때 각 테스트셋에서 최대 오차는 2dB를 넘지 않고 평균 0.2dB의 오차를 보였다. 최소 오차는 0에 수렴하였다. 0으로 패딩 된 데이터셋에서는 0에서 실제 데이터가 시작되는 부분에서 최대 오차가 나타났다.

다음 <그림 13>은 LSTM을 이용하여 SNR을 예측한 결과이다. <그림 13>에서 진한 선은 데이터셋에서 학습되지 않은 테스트셋의 SNR, 연한 선은 LSTM이 예측한 SNR이다. 길이가 최대인 테스트셋에서는 <그림 13>과 같이 LSTM이 예측하기 위해 맨 처음 10개의 데이터를 받기까지 기다리면서 최대 오차가 나타났다. 하지만 이는 LSTM이 예측을 위해 필수적으로 필요한 것이다. SNR값이 최고에 오르는 지점에서는 평균에 비해 오차가 컸지만 2dB를 넘지진 않았다.

<그림 14>는 실제 측정된 SNR과 LSTM 예측 값을 비교한 그래프이다. 실제 Throughput 측정 시에는 동일한 실험을 100번 이상 반복하여 평균값을 사용한다.

<그림 15>는 예측한 SNR 값에 따라 최적의 MCS를 선택한다. 802.11의 MCS를 고정시키고 Throughput이 0에서 급격하게 증가하는 체크한다. 같은 시행을 100번 이상 반복하며 MCS에 따라 안정적으로 전송 가능한 부분을 기준으로, SNR에 따른 최적의 MCS를 채택한 다⁸⁾. 송신단은 수신단에게서 전달받은 SNR을 기반으로 채널상황을 판단하고, 다음 전송 시의 MCS를 변경 시킨다⁸⁾.

<그림 16>은 앞서 학습시킨 모델로 학습되지 않은 속도의 경우를 SNR의 중앙값을 선택해 예측한 결과이다. <그림 17>은 이 경우의 각 속도에서의 최대, 평균, 최소 에러이다.

학습시킨 데이터에 비해서 에러가 더 큰 모습을 보인다. 각 속도에 대해 평균적으로 최대값이 2dB가 넘고, 평균값은 0.5dB정도이다. 최소값은 0.1 dB를 넘지 않았다.




그림 13. 60km/h에서 200m 동안LSTM으로 예측한 SNR 그래프
Fig. 13. SNR predicted by LSTM for 200m at 60km/h

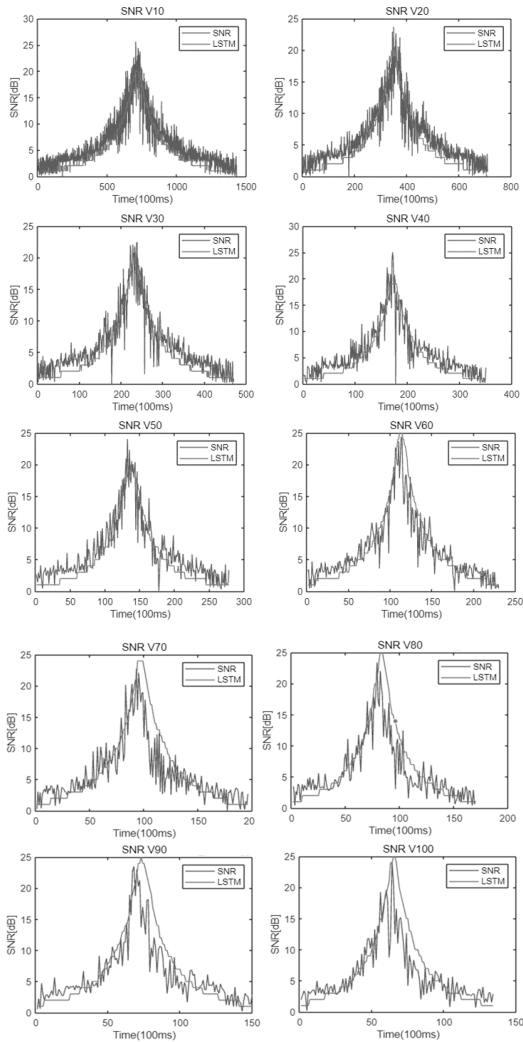


그림 14. 400m 이동 시 차량의 SNR과 LSTM 예측 SNR
Fig. 14. SNR of LSTM prediction and vehicle at 400m movement




그림 15. SNR에 따른 최적의MCS
Fig. 15. Optimal MCS according to SNR

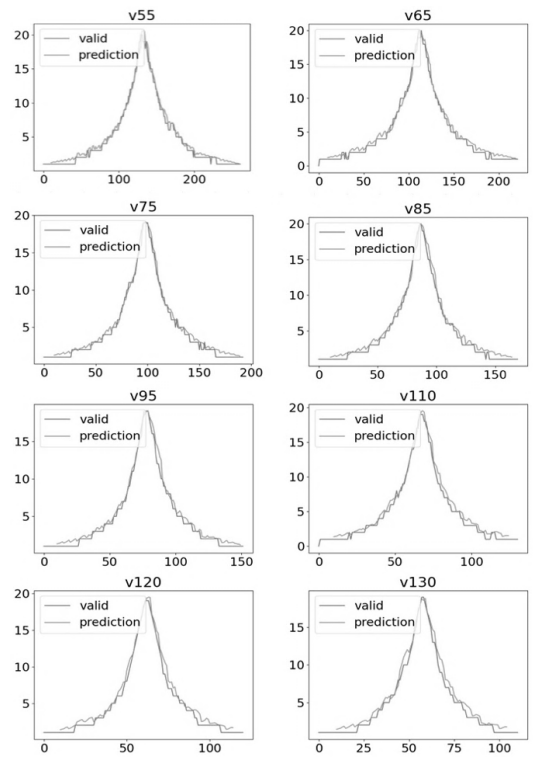


그림 16. 학습하지 않은 속도의 SNR에 대한 LSTM 예측
Fig. 16. LSTM prediction for SNR at untrained velocities




그림 17. 학습하지 않은 속도에 대한 LSTM 예측 오류
Fig. 17. LSTM prediction error for untrained velocities

4.2 LSTM 기반의 Link Adaptation

Throughput과 PER(Packet Error Rate)를 기반으로 분석하였으며, 시스템의 속도, 전송 간격에 따라 실험하였다. MCS 예측 메커니즘과 기존의 방식을 비교하고, 버퍼 오버플로우 발생 시에는 오버플로우 발생 상황과 본 논문에서 제안한 최저 속도 제한 알고리즘을 비교하였다. 느린 전송 간격, 빠른 차량 속도에서는 제안 메커니즘 중 LSTM 기반의 MCS 예측 기술이 큰 이득을 보이며, 빠른 전송 간격에서는 최저 속도 제한 알고리즘이 큰 이득을 보인다.

4.2.1 Throughput

Throughput은 전송 시간 내에 성공적으로 전송된 데이터의 수를 의미하며, 시스템의 성능을 나타내는 지표로 사용된다^{8,18)}.

$$Throughput = \frac{D_{succ}}{T} \quad (8)$$

식(8)에서 T 는 전송 시간, D_{succ} 는 성공적으로 전송된 데이터를 의미한다. 링크 레이어에서 D_{succ} 는 전송 성공한 패킷 수와 패킷 당 비트 수의 곱으로 나타낼 수 있다.

$$D_{succ} = P_{succ} * B_p * c(mcs) \quad (9)$$

식(9)에서 P_{succ} 는 성공적으로 전송된 패킷 수, B_p 는 패킷 당 전송 비트 수, $c(mcs)$ 는 802.11p의 부호율이다.

4.2.2 LSTM 기반의 MCS 예측

본 논문에서는 시스템의 성능 비교를 위해 전송 간격을 5ms, 10ms, 50ms, 100ms, 500ms로 구분하여 전송하고, 전송 간격이 5ms 일 때는 특수하게 재전송 대기 시간을 5ms로 단축하였다. 또한 <그림 15>에서 Throughput이 의미 있는 값을 가지는 구간만을 채택하기 위해 측정 구간을 -100m~100m로 제한한다.

<그림 18>은 전송 간격이 100, 500ms일 때 LSTM으로 인해 상승된 Throughput의 퍼센트 비율 그래프이다. 패킷 전송 간격이 짧을 경우 기존의 방식과 큰 차이를 보이지 않지만, 100ms 이상의 경우에는 제안 메커니즘이 평균 10% 정도의 Throughput 상승 효과를 보였다. 이는 짧은 전송 간격에서는 차량 이동거리 변화량이 줄어들면서 MCS 변화량이 유사하지만, 전송 간격이 증가할수록 차량 이동거리 변화량이 증가하고 MCS도 차이가 커지기 때문에 나타나는 결과이다.

또한 차량의 속도가 증가할수록 패킷 간 차량이 이동한 거리가 증가하므로, 제안 메커니즘의 성능이 저속 주행에 비하여 5배 정도 상승하는 것을 확인할 수 있다.

표 4. MCS 예측 파라미터
Table 4. MCS prediction parameter

| 심볼 | 의미 | 값 |
|----------|------------------|------------------------------|
| T_{re} | 재전송 대기 시간 | 5ms, 10ms |
| T_f | 전송 간격 | 5ms, 10ms, 50ms, 100ms 500ms |
| M_{re} | 최대 재전송 횟수 | 8 |
| T_b | 비콘 전송 간격 | 100ms |
| | Throughput 측정 구간 | -100m ~ 100m |

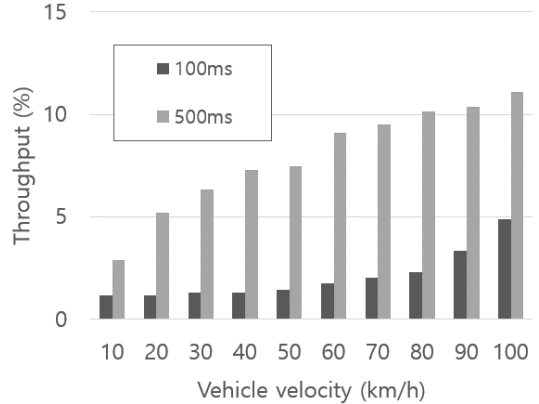


그림 18. 전송 간격에 따른 LSTM의 Throughput 상승률 비교
Fig. 18. Comparison of LSTM throughput increase rate over transmission interval

4.2.3 LSTM 기반의 최저 속도 제한 알고리즘

Throughput 평균치를 높이기 위해 5ms의 전송 간격에서 실험을 진행하였다. 트래픽 전송 간격이 작기 때문에 차량 속도로 인한 성능 차이는 거의 나타나지 않고, MCS 예측 메커니즘으로 인한 성능 차이도 뚜렷하지 않다. 반면 패킷이 빠져나가는 시간에 비해 전송 간격이 짧아 발생하게 되는 버퍼 오버플로우에 의해, 전송 속도가 느린 10dB 미만의 구간에서는 버퍼 오버플로우가 발생하게 되고 패킷 에러로 이어지게 된다.

<그림 19>는 5ms에서 오버플로우가 발생하는 상황과 본 논문에서 제안한 LSTM 기반의 최저 속도 제한 알고리즘 적용시의 PER을 비교한 그래프이다. 제안 알고리즘 적용 시 MCS가 증가되며, 5dB~10dB 사이에서 발생하는 버퍼 오버플로우에 의한 영향이 크게 줄어드는 것을 확인할 수 있다.

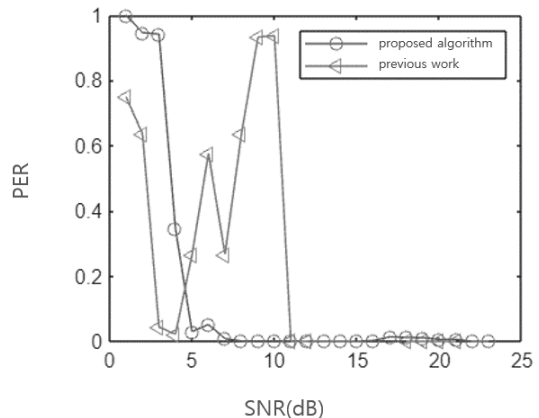


그림 19. 5ms 전송 시 SNR에 따른 PER
Fig. 19. PER according to SNR at 5ms transmission

<그림 20>는 제안 메커니즘의 Throughput을 비교한 값이며, 약 2Mbps의 성능 향상을 보이고 Throughput 평균 또한 2.5Mbps 이상으로 측정된다. 이 때, Throughput 향상을 위해 전송 간격 및 재전송 간격을 5ms 이내로 감소시키면서, 5dB 이하에서 패킷 에러가 증가하기 때문에 시스템의 PER과 Throughput 사이에서 tradeoff를 고려하여 적절하게 선택하는 것이 필요하다.

<그림 21>은 LSTM 기반의 Link adaptation과 버퍼 오버플로우 제거를 위한 전송 속도 제한 알고리즘이 모두 고려된 후의 평균 Throughput 그래프이다. 그래프에서 볼 수 있듯이 패킷 데이터 수가 같을 때, 전송 간격의 감소는 Throughput 상승으로 이어진다. 전송 간격이 100ms 이상으로 요구되는 시스템의 경우, 본 논문에서 제시한 LSTM 기반의 MCS 예측 알고리즘은 빠른 속도의 차량에서 더욱 좋은 성능을 보인다. 또한, 5dB 이상으로 채널 환경이 양호할 때, 1Mbps 이상의 높은

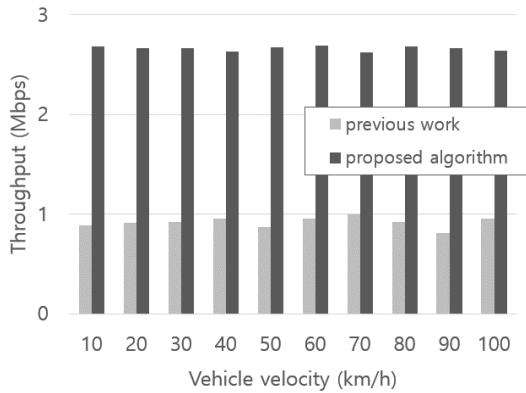


그림 20. 전송간격 5ms에서 버퍼 오버플로우 제거를 위한 알고리즘 적용 시 성능 분석
Fig. 20. Analysis of performance when applying algorithms for buffer overflow removal at 5ms transfer interval




그림 21. 전송 간격에 따른 평균 Throughput
Fig. 21. Average throughput according to transmission interval

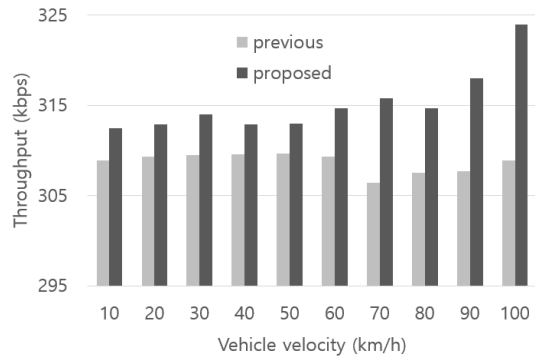


그림 22. 100ms 전송 시 Throughput
Fig. 22. Throughput for 100ms transmission

Throughput을 요구한다면 5ms 전송간격과 최저 속도 제한 기술을 적용하는 것이 적절하다.

<그림 22>에서 100ms의 간격으로 전송한 경우, 100km/h에서 최대 0.3Mbps의 성능을 낼 수 있다. 본 연구에서는 기존의 방식과 비교한 성능 향상에 집중하였지만, 패킷 사이즈를 증가와 다양한 모뮬레이션 및 다중 전송을 접목시키면 더욱 다양한 상황에서의 적용이 가능할 것으로 예측된다.

V. 결 론

본 연구에서는 IEEE 802.11p를 이용한 차량 이동 통신 시 발생할 수 있는 통신 채널의 에러를 LSTM을 이용하여 제거하는 메커니즘을 제안한다. LSTM을 이용한 SNR의 예측은 평균 0.2dB의 오차를 나타내며 평균 10% 정도의 Throughput 상승을 보였다. 이는 제안하는 메커니즘이 기존의 방식보다 매우 높은 성능을 가짐을 의미한다. 또한 차량의 속도, 패킷 전송 간격이 증가할수록 Throughput 상승률이 증가하는 것을 확인하였다. 또한 Throughput의 상승이 요구되는 시스템에서 발생가능한 버퍼 오버플로우 문제에 대해서, 본 논문에서 제시한 알고리즘은 평균 2.5배의 Throughput 상승을 보였다.

본 논문에서 제안한 메커니즘은 Throughput, PER 면에서 성능 향상을 보였으며, 이는 나아가 빠르게 이동하는 V2X 통신에서의 통신 속도 및 정확도, 주파수 효율 면에 있어 큰 이익이 있을 것으로 예상된다. 본 연구에서는 단일 차량과 BS 간의 통신만을 고려하고, 2000 octet의 단일 패킷 전송을 가정하였다. 따라서 패킷의 사이즈를 늘리고, 다양한 통신 방식을 적용한다면 본 연구에서 도출된 것에 비해 더 큰 Throughput을 보일 수 있을 것으로 예측된다. 또한, 많은 차량이 존재하는

실제 환경에서 차량에 도착하는 정보의 간격 및 채널 환경은 더 다양하게 달라질 수 있으므로, 본 논문에서 제안한 메커니즘의 적용은 다양한 간격 및 환경에 따른 최적의 전송 방식을 제안했다는 점에서 의의가 있다. 다수 차량 모델링을 통한 메커니즘의 적용은 향후 연구 주제로 남겨둔다.

또한 본 논문에서는 도플러 효과로 인한 시변 채널에 대해 등속도 운동을 가정하고 완벽하게 보정 가능한 상황에 대해 시뮬레이션 하였다. 그러나 실제 상황에서 도플러 효과를 보정하기 위해서는 OFDM 신호의 앞 뒤 간격을 조정하거나, 새로운 알고리즘 등을 적용하는 방식이 제안되고 있다^[21]. 본 논문에서 제안한 SNR의 변화 추이 기반 LSTM 예측은 속도와 방향에 따른 값을 포함하고 있다. 따라서 시간에 따라 변화하는 속도를 예측하고 보정하는 방식의 적용이 가능하다.

최근에는 802.11p의 문제점으로 인해 이를 해결할 수 있는 802.11bd가 등장하였다. 802.11bd는 기존 802.11p에 비해 높은 전송 속도와 안정성을 자랑하며 본 연구에서 제시한 알고리즘을 802.11bd에 적용하면 더 개선된 성능을 보일 것으로 예상된다.

References

[1] J. Hou, H. Liu, Y. Zhang, W. Wang, and J. Wang, "GRU-based deep learning channel estimation scheme for the IEEE 802.11p standard," in *IEEE Wireless Commun. Lett.*, vol. 12, no. 5, pp. 764-768, May 2022.

[2] A. Burbano-Abril, B. McCarthy, M. Lopez-Guerrero, V. Rangel, and A. O'Driscoll, "MCS adaptation within the cellular V2X sidelink," *2021 IEEE CSCN*, pp. 111-117, Thessaloniki, Greece, Dec. 2021.

[3] D. Jeong, "Modeling of the distributed broadcasting in IEEE 802.11p MAC based vehicular networks," *J. KICS*, vol. 38, no. 11, pp. 924-933, Nov. 2013.

[4] H. Kim, A. Lee, D. Kang, K. Park, and W. Oh, "Decision-directed channel estimation for IEEE 802.11p based V2X communications," *J. KICS*, vol. 42, no. 8, pp. 1513-1520, Aug. 2017.

[5] C. Yao, Z. Guo, G. Long, and H. Zhang, "Performance comparison among ASK, FSK and DPSK in visible light communication,"

Optics and Photonics J., vol. 6, no. 8B, pp. 150-154, Aug. 2016.

[6] A. Farzamnia, M. Mariappan, E. Mount, and R. Thangasalvam, "Control engineering in robotics and industrial automation," *Springer Cham*, pp. 257-266, 2022.

[7] M. Kalil, A. Shami, and A. Al-Dweik, "QoS-aware power-efficient scheduler for LTE uplink," in *IEEE Trans. Mobile Comput.*, vol. 14, no. 8, pp. 1672-1685, Aug. 2015.

[8] D. Qiao, S. Choi, and K. G. Shin, "Goodput analysis and link adaptation for IEEE 802.11a wireless LANs," in *IEEE Trans. Mobile Comput.*, vol. 1, no. 4, pp. 278-292, Oct.-Dec. 2002.

[9] IEEE Standard for Information technology, "Local and metropolitan area networks--Specific requirements-- Part 11: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications Amendment 6: Wireless Access in Vehicular Environments," in IEEE Std 802.11p-2010 (Amendment to IEEE Std 802.11-2007 as amended by IEEE Std 802.11k-2008, IEEE Std 802.11r-2008, IEEE Std 802.11y-2008, IEEE Std 802.11n-2009, and IEEE Std 802.11w-2009), vol., no., pp. 1-51, Jul. 2010.

[10] IEEE Standard for Information Technology, "Telecommunications and Information Exchange between Systems Local and Metropolitan Area Networks--Specific Requirements Part 11: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications Amendment 5: Enhancements for Next Generation V2X," in IEEE Std 802.11bd-2022 (Amendment to IEEE Std 802.11-2020 as amended by IEEE Std 802.11ax-2021, IEEE Std 802.11ay-2021, IEEE Std 802.11ba-2021, IEEE Std 802.11-2020/Cor 1-2022, and IEEE Std 802.11az-2022), vol., no., pp. 1-144, Mar. 2023.

[11] M. K. Simon and M.-S. Alouini, "Digital communication over fading channels: A unified approach to performance analysis,"

- John Wiley & Sons, pp. 17-27, 2000.
- [12] D. P. Thinh, J. S. Wang, J. B. Park, and Y. H. Kim, "Symbol error probability of a physical layer network coded system in nakagami fading channels," *J. KICS*, vol. 37, no. 8C, pp. 645-654, Aug. 2012.
- [13] H. Suzuki, "A statistical model for urban radio propagation," *IEEE Trans. Commun.*, vol. 25, no. 7, pp. 673-680, Jul. 1977.
- [14] J. Yoo, B. S. C. Choi, and M. Gerla, "An opportunistic relay protocol for vehicular road-side access with fading channels," *The 18th IEEE Int. Conf. Net. Protocols*, pp. 233-242, Kyoto, Japan, Oct. 2010.
- [15] M. A. Khan and A. U. H. Sheikh, "Equivalence between Nakagami channels and Rayleigh channels with diversity," in *Proc. 2008 Mosharaka Int. Conf. Commun., Signals and Coding*, pp. 83-88, Amman, Jordan, Oct. 2008.
- [16] C. Aydogdu and E. Karasan, "Goodput and throughput comparison of single-hop and multi-hop routing for IEEE 802.11 DCF-based wireless networks under hidden terminal existence," *Wireless Commun. and Mobile Comput.*, vol. 16, no. 9, pp. 1078-1094. Jun. 2016.
(<https://onlinelibrary.wiley.com/doi/epdf/10.1002/wcm.2588>)
- [17] Y. D. Prabowo, H. L. H. S. Warnars, W. Budiharto, A. I. Kistijantoro, Y. Heryadi, and Lukas, "Lstm and simple Rnn comparison in the problem of sequence to sequence on conversation data using bahasa Indonesia," *2018 INAPR*, pp. 51-56, Jakarta, Indonesia, 2018.
- [18] D. Miller and J.-M Kim, "Univariate and multivariate machine learning forecasting models on the price returns of cryptocurrencies," *J. Risk Financial Manag.*, vol. 14, no. 10, p. 486, 2021.
(<https://doi.org/10.3390/jrfm14100486>)
- [19] K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A search space odyssey," in *IEEE Trans. Neural Netw. and Learn. Syst.*, vol. 28, no. 10, pp. 2222-2232, Oct. 2017.
- [20] D. H. N. Nguyen and R. W. Heath, "Delay and doppler processing for multi-target detection with IEEE 802.11 OFDM signaling," *2017 IEEE ICASSP*, pp. 3414-3418, New Orleans, LA, USA, 2017.
- [21] A. Waqas, G. Lechner, K. Nguyen, and T. Chan, "Particle filter for joint carrier phase, doppler shift and doppler rate estimation and data detection," *2021 IEEE LATINCOM*, pp. 1-6, Santo Domingo, Dominican Republic, 2021.

권 상 원 (Sang-Won Kwon)



2028년 2월: 광운대학교 소프트웨어 학부 졸업 예정
<관심 분야> 기계 학습, 자율주행

김 수 현 (Su-Hyun Kim)



2024년 2월: 광운대학교 전자공학과 졸업 예정
<관심 분야> 이동통신시스템, OFDM, V2X

임 재 한 (Jae-Han Lim)



2004년 2월 : 서울대학교 전기
공학부 공학사

2006년 2월 : 서울대학교 전기컴
퓨터공학부 공학석사

2014년 12월 : UCLA Electrical
Engineering 공학박사

한국전자통신연구원 선임연구원

현재 : 광운대학교 소프트웨어학부 부교수

<관심분야> 스피이킹 뉴럴 네트워크, 차량용 네트
워크, 자율주행, 모바일 컴퓨팅, 기계학습, 백스캐
터 통신