

OFDM 시스템에서 LS 채널 추정 한계를 극복하기 위한 딥러닝 기반 Neural Receiver 설계

박준우, 이호원

아주대학교 전자공학과

pspp15@ajou.ac.kr, howon@ajou.ac.kr

Design of a Deep Learning-Based Neural Receiver to Overcome the Limitations of LS Channel Estimation in OFDM Systems

JunWoo Park, Howon Lee

Ajou Univ.

Abstract

기존 Orthogonal Frequency Division Multiplexing(OFDM) 시스템에서 널리 사용되는 Least Squares(LS) 채널 추정 기반 수신기는 파일럿 심볼에 의존하여 채널을 추정하지만, 실제 채널 상태나 잡음 간섭, 특히 Multiple Input Multiple Output(MIMO) 환경에서의 스트림 간 간섭까지 반영하지 못하는 한계가 있다. 본 연구에서는 이러한 문제를 해결하기 위해 Convolutional Neural Network(CNN)과 Long Short-Term Memory(LSTM)을 결합한 딥러닝 기반 Neural Receiver를 설계하고, NVIDIA Sionna 프레임워크를 통해 그 성능을 검증한다. 시뮬레이션을 통해, 딥러닝 기반 Neural Receiver가 LS 채널 추정 방안 대비 낮은 Signal-to-Noise_Ratio(SNR) 환경에서도 향상된 Bit Error Rate(BER) 성능을 가짐을 보인다.

I. Introduction

6G 시대에서는 높은 신뢰성과 빠른 통신을 실현하기 위해, 수신기 설계와 채널 추정 등 통신 시스템에서 인공지능 기반 접근 방식이 활발히 연구되고 있다[1]. 반면, 기존 시스템 구조는 복잡한 채널 환경에서 정확도가 떨어진다는 한계를 지닌다. 대표적으로 Orthogonal Frequency Division Multiplexing(OFDM) 시스템에서 널리 사용되는 Least Squares(LS) 기반 채널 추정 방식은 주기적으로 전송하는 파일럿 심볼을 단순히 나누는 방식을 통해 채널을 추정한다. 이 방식은 구현이 간단하다는 장점이 있으나, 채널의 구조적 특성을 고려하지 않기 때문에 노이즈가 추정값에 직접 더해지고, 이에 따라 낮은 Signal-to-Noise-Ratio(SNR) 영역에서 채널 추정 성능이 크게 떨어지게 된다. 그림 1은 Perfect CSI (Channel State Information)과 LS 채널 추정의 성능 차이를 보여준다[2].




그림 1. BER Performance Comparison of LS estimation and Perfect CSI Receivers

또한 Multiple Input Multiple Output(MIMO) 4x4 환경에서는 송신 스트림 간 간섭이 발생하며, 기존 LS 채널 추정 방식은 이를 충분히 반영하지 못한다. 그림 2는 스트림 간 간섭의 심각성을 보여주며, Bit Error Rate(BER) 성능 역시 Perfect CSI 대비 큰 차이를 보인다. 이로 인해 각 수신기에서 정확한 데이터 복원이 어려운 문제가 발생한다[3].

본 논문에서는 이러한 LS 채널 추정 기반 수신기의 한계를 극복하기 위해, 업링크 및 기지국 간 통신 시나리오를 가정한 OFDM 시스템에서 Long Short-Term Memory(LSTM)과 Convolutional Neural Network(CNN)을 결합한 딥러닝 기반 Neural Receiver를 설계한다. 본 수신기는 채널 상태와 노이즈를 보다 정밀하게 반영하며, 스트림 간 간섭을 분리하는 구조로 설계되어 향후 MIMO 환경으로의 확장도 가능하다.

본 논문에서 시뮬레이션은 NVIDIA에서 제공하는 TensorFlow 기반 오픈 소스 라이브러리인 Sionna를 활용하여 수행하였다. Sionna는 무선 및 광통신 시스템의 물리 계층과 다양한 채널 모델, Ray Tracing 기반 전파 모델링을 지원하는 통합 시뮬레이션 도구이다. 본 논문에서는 Sionna를 통해 OFDM 시스템의 전체 물리 계층을 구성하고, LS 채널 추정기 및

Neural Receiver를 구현하였다. 이를 바탕으로 기존 LS 채널 추정 방식 대비 BER 성능을 비교·분석하였다.




그림 2. BER performance comparison between LS estimation and Perfect CSI receivers (left), and interference power histogram for Stream 0 (right).

II. 딥러닝 기반 Neural Receivers

본 논문에서는 CNN과 LSTM을 결합한 두 가지 Neural Receiver 모델을 설계하고 구현하였다. CNN은 시간 및 주파수 축에서 발생하는 간섭, 페이딩, 노이즈의 분포를 효과적으로 학습할 수 있어 채널 상태 및 스트림 파악에 적합하며, LSTM은 시계열 상의 연속성을 활용하여 심볼 간 상관성과 노이즈 패턴을 학습함으로써, 노이즈 및 간섭 제거에 유리하다.

A. CNN-LSTM




그림 3. Overall architecture of the proposed CNN-LSTM Neural Receiver (top) and detailed structure of the CNN (bottom)

CNN-LSTM 모델은 그림 3의 상단 구조를 따른다. CNN은 수신 신호로부터 채널 상태 및 심볼의 스트림 관련 정보를 추출하며, LSTM은 이를 이용해 수신 신호 내 노이즈와 간섭을 제거하고 soft Log-Likelihood Ratio(LLR)을 추정한다. CNN은 그림 3 하단 구조에 따라 Conv2D와 Layer Normalization으로 구성되며, Conv2D는 채널 흐름에 대한 심볼 특징을 추출하고, Layer Normalization은 공간 및 채널 차원에서 출력을 정규화하여 학습 안정성을 높인다. LSTM은 Bidirectional 구조로 구현되어 앞뒤 시간 흐름을 모두 반영함으로써 시간-주파수 도메인상의 연관성을 효과적으로 학습할 수 있다.

B. LSTM-CNN

LSTM-CNN 모델은 그림 4의 상단 구조를 따른다. CNN-LSTM과 유사하게 LSTM은 노이즈 및 간섭을 제거하고, CNN은 채널 상태 및 스트림

관련 정보를 추출하지만, 본 구조에서는 LSTM이 먼저 soft LLR을 추정하고, 이후 CNN이 이를 보정하는 방식으로 처리 순서에 차이가 있다. LSTM은 이전 모델과 동일하게 Bidirectional 구조로 구성되었으나, 채널 정보 없이 LLR을 추정해야 하므로 입력 전에 각각 dense layer로 구성된 두 개의 encoder를 통해 주요 정보를 정제한다. CNN은 보정 기능을 수행하기 위해 NVIDIA Sionna의 예시 모델을 기반으로 그림 4의 중간 구조처럼 설계되었으며, 내부에 Residual Block을 포함한다[4]. 해당 Block은 그림 4 하단 구조를 따르며, 입력 정보를 유지하면서 필요한 보정 정보를 추가적으로 학습하도록 설계되었다. 최종적으로 CNN은 채널 상태를 반영하여 각 스트림별 LLR을 보정한다.

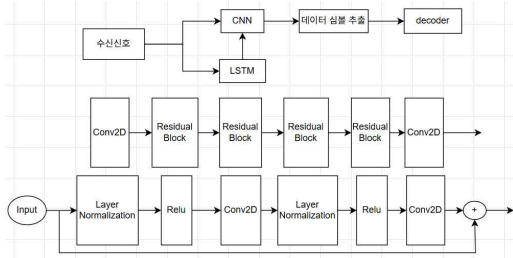


그림 4. Overall architecture of the proposed LSTM-CNN Neural Receiver (top), detailed structure of the CNN (middle), and internal configuration of the residual block (bottom).

III. Simulation Results

A. 시뮬레이션 환경

표 1. Simulation Parameters

Delay spread	100ns	SNR Range	-3dB ~ 5dB
Number of UT, BS	1	Number of OFDM symbols	14
Carrier frequency	2.6 GHz	FFT size	76
Coderate	0.5	CP length	6
UT speed	10m/s	Channel Model	3GPP CDL-C
Direction	Uplink	채널 적용 방식	Frequency domain
서브캐리어간격	30 kHz	변조 방식 및 채널 코딩	QPSK, LDPC

시뮬레이션은 송신 안테나 1개, 수신 안테나 2개로 구성된 1×2 환경에서 진행되었으며, 모든 실험은 NVIDIA의 Sionna 프레임워크를 기반으로 구현되었다. 본 연구에서는 Sionna에서 제공하는 Quadrature Phase Shift Keying(QPSK) 변복조, Low Density Parity Check(LDPC) 채널 코딩, OFDM 리소스 그리드 및 심볼 매핑/디매핑 등을 활용하여 송수신 물리 계층 전반을 구성하였고, 비트 생성부터 BER 측정까지 Sionna의 함수들을 이용해 시뮬레이션 전 과정을 통합적으로 구현하였다. 채널 모델은 3rd Generation Partnership Project(3GPP) Clustered Delay Line(CDL)-C를 적용하여 가우시안 잡음과 다중경로 페이딩이 반영된 실제 환경을 구성하였으며, Neural Receiver는 이 구조에 맞게 설계되었다. 주요 파라미터는 표 1에 정리하였다.

B. 시뮬레이션 결과

그림 5는 CNN-LSTM 및 LSTM-CNN 모델의 BER 성능을 Perfect CSI 및 기존 LS 채널 추정 기반 수신기와 비교한 결과를 나타낸다. 두 모델 모두 전 SNR 범위에서 LS 채널 추정 기반 수신기보다 우수한 BER 성능을 보였으며, 특히 LS 채널 추정 기반 수신기가 $E_b/N_0 = 2.5$ dB 이하에서 BER이 10^{-1} 수준을 벗어나지 못한 반면, 딥러닝 기반 모델들은 1.6 dB부터 사실상 BER이 0에 수렴하는 성능을 나타낸다. 또한 두 모델의 BER 곡선은 Perfect CSI 수신기와 유사한 경향을 보이며, 기존 LS 채널

추정기의 한계를 효과적으로 극복한 것을 볼 수 있다.

일부 SNR 구간에서 BER이 일시적으로 상승하는 현상이 관찰되었으나, 이는 시뮬레이션 과정에서 해당 구간에 무작위로 생성된 비트가 상대적으로 어렵게 구성된 결과로 보이며, 이러한 편차는 모델의 구조적 문제라기 보다는 반복 시뮬레이션 특성상 발생할 수 있는 확률적 오차로 판단된다. 종합적으로, 딥러닝 기반 Neural Receiver는 채널 상태를 보다 정확히 반영하고 노이즈를 효과적으로 제거함으로써, 기존 LS 채널 추정 기반 수신기 대비 우수한 성능을 보였으며, Perfect CSI 수신기에 근접한 비트 복원 능력을 달성하였다.




그림 5. BER performance comparison of LS Estimation, Perfect CSI, and proposed Neural Receivers under a 1×2 scenario.

IV. Conclusion

본 논문에서는 1×2 환경에서 딥러닝 기반 Neural Receiver가 기존 LS 채널 추정 방식에 비해 채널 상태를 더 정확히 반영하고, 노이즈를 효과적으로 제거하여 정확한 비트 복원이 가능한지를 BER 성능을 통해 비교·분석하였다. 실험 결과, CNN-LSTM과 LSTM-CNN 모두 LS 채널 추정 기반 수신기에 비해 채널 상태를 보다 정밀하게 반영하고 노이즈를 효과적으로 제거함으로써, 전반적인 BER 성능 향상을 달성하였으며 Perfect CSI 수신기와 유사한 수준의 성능을 보였다. 또한, 향후 MIMO 환경에서의 시뮬레이션을 염두에 두고 스트림 분리 기능을 포함한 구조로 설계하였기 때문에, 다양한 다중 안테나 환경으로의 확장이 가능하다. 다만, 모델의 복잡도와 연산량 증가로 인해 상대적으로 높은 지연시간이 발생하는 점은 향후 관련 추가 연구가 필요하다.

ACKNOWLEDGMENT

이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원(No. RS-2024-00396992, 저궤도 위성통신 핵심 기술 기반 큐브 위성 개발)과 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원(No. 2022-0-00704, 초공간 이동체 지원을 위한 3D-NET 핵심 기술 개발)과 2025년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(RS-2025-00563401, 3차원 공간에서 에너지 효율적 멀티레벨 AI-RAN 구현을 위한 AI-for/and-RAN 핵심 원천기술 연구)을 받아 수행된 연구임.

참고 문헌

- [1] H. Lee et al., "Towards 6G hyper-connectivity: Vision, challenges, and key enabling technologies," in Journal of Communications and Networks, vol. 25, no. 3, pp. 344-354, June 2023.
- [2] NVIDIA, "Part 3: Advanced Link-level Simulations", Mar. 2025, (https://nvlabs.github.io/sionna/phy/tutorials/Sionna_tutorial_part3.html)
- [3] NVIDIA, "MIMO OFDM Transmissions over the CDL Channel Model", Mar. 2025, (https://nvlabs.github.io/sionna/phy/tutorials/MIMO_OFDM_Transmissions_over_CDL.html).
- [4] NVIDIA, "Part 4: Toward Learned Receivers", May. 10. 2025, (https://nvlabs.github.io/sionna/phy/tutorials/Sionna_tutorial_part4.html).