

# DNN 구조 최적화에 따른 Multipath 채널 환경에서의 PRACH 검출 성능 개선 연구

김수빈, 김주엽

숙명여자대학교

[2315391@sookmyung.ac.kr](mailto:2315391@sookmyung.ac.kr), [jykim@sookmyung.ac.kr](mailto:jykim@sookmyung.ac.kr)

## PRACH Detection Performance Improvement in Multipath Channel Environments via DNN Structural Optimization

Soobin Kim, Juyeop Kim

Sookmyung Women's University

### 요약

본 논문은 DNN 모델 구조와 파라미터의 확장 및 최적화를 통해 PRACH 검출 성능을 효과적으로 향상시키는 기법을 제안한다. 기존 기법에서는 경량화된 DNN 모델을 기반으로 PRACH 검출 실험을 수행하였으나, Multipath 채널 환경에서 발생하는 PDP Spreading 특성으로 PRACH 검출 성능이 저하되는 한계가 있었다. 이에 본 논문의 제안 기법으로 실시간 학습을 수행함으로써 Multipath 채널 환경에서의 PRACH 검출 성능 열화를 보상한다.

## I. 서론

오늘날의 5G 및 LTE 무선 통신에서 Random Access(RA)는 단말(UE)이 기지국(gNB)에 초기 접속을 수행하기 위한 핵심 과정이다 [1], [2]. 기지국은 RA를 사용함으로써 단말의 ID, 접속 순서에 관계 없이 임의의 시간에 단말에 접근할 수 있다. RA 절차의 초기 접근 단계에서 사용되는 물리 채널인 Physical Random Access CHannel(PRACH)은 단말이 RA preamble을 전송하기 위해 사용된다. 단말이 전송한 PRACH preamble에 대한 검출 성능은 RA 절차 전반에서 핵심적인 성능 지표로 작용한다 [3].

그러나 PRACH 신호를 검출하는 과정에서 AWGN(Additive White Gaussian Noise)이나 Multipath 환경에 의해 검출 성능이 저하되는 문제가 발생한다. 이를 보완하기 위해 Machine Learning(ML)을 이용해 RA 절차를 지능화하려는 연구가 진행되고 있다 [1], [4], [5]. 기존 지능화 연구에서 경량화된 DNN(Deep Neural Network, 심층 신경망) 모델로 실시간 학습(Real-time Channel Learning)을 수행하였을 때, AWGN 환경과 달리 Multipath fading 특성을 갖는 Tapped Delay Line(TDL) 환경에서는 PRACH 검출 성능이 향상되지 않았다 [1]. 따라서, 본 논문에서는 기존 방식보다 더 복잡한 DNN 구조를 이용한 실험으로 Multipath 환경에서의 PRACH 검출 성능 개선을 확인하고자 한다.

## II. 본론

### 1. 문제 정의

선행 연구에서 제안한 검출기는 AWGN 환경에 최적화된 검출기이다. 하지만 AWGN 환경과 달리, Multipath 환경은 반사 및 회절로 인해 서로 다른 지연 시간  $\tau_k$ 를 갖는 신호가 수신된다. 각 경로  $k$ 는 신호를 시간적으로 지연시킬 뿐만 아니라, 식 (1)로 표현되는 복소 경로 이득(Complex Path Gain)에 의해 신호의 크기와 위상을 함께 변화시킨다. 이때 Channel Impulse

Response(CIR)는  $N_{RX}$ 개의 경로 성분을 가질 때, 식 (2)와 같이 시간 지연과 크기·위상 변화를 반영한  $N_{RX}$ 개 delta 함수의 합으로 표현된다.

$$a_k = |a_k|e^{j\phi_k} \quad (1)$$

$$h(t, \tau) = \sum_{k=0}^{N_{RX}-1} a_k \delta(\tau - \tau_k) \quad (2)$$

$$P(\tau) = E[|h(t, \tau)|^2] \quad (3)$$

Power Delay Profile(PDP)은 식 (3)과 같이 CIR의 제곱을 평균한 값으로, 각 지연에 따른 수신 전력 분포를 나타낸다. 시간이 지연된 Multipath 성분이 존재하는 경우, PRACH 신호의 수신 전력이 시간 축 전반에 분산되어 PDP peak의 최댓값이 감소한다. 또한 약전계 환경에서 noise 전력이 상대적으로 커지며 PDP peak와 배경 noise 간의 구분이 어려워진다. 즉, PDP peak의 분산에 따라 PRACH 신호를 검출하는 성능이 열화된다 [1].

### 2. 제안 기법

본 논문은 DNN 구조를 확장하면서, DNN 모델의 파라미터에 대한 최적화 기법을 제안한다. 이는 Multipath 환경에서 발생하는 PDP spreading 특성을 충분히 학습하기 위해, 보다 복잡한 DNN을 사용하는 접근이다.

$$CCLM_{FC}^i = D_{in}^i \times D_{out}^i \quad (4)$$

$$CCLM_{DNN} = RTT \times RMS \times \sum_{i=1}^L CCLM_{FC}^i \quad (5)$$

Bias 항을 제외한 Fully Connected Layer의 파라미터 수는 식 (4)와 같이 입력 노드와 출력 노드의 곱으로 정의된다. 단순한 weight 개수만으로는 Multipath 채널 환경의 학습 복잡도를 충분히 반영하기 어렵기 때문에, Relative Training time(RTT)와 Relative Memory Space(RMS)를 함께 고려한 계산 복잡도 지표를 도입한다. RTT와 RMS를 포함한 계산 복잡

도는 식 (5)와 같이 Computational Complexity of Learning Model(CCLM)로 산출된다 [1].

Param.	Exposition	Prior Value	Proposed Value
$L$	The no. of layers	4	6
$L_{hid}$	The no. of hidden layers	2	4
$D_{hid}$	The no. of hidden nodes	30	256
$D_{in}$	The no. of input nodes	150	256
$N_E$	Training epochs	10	50
$N_{bsize}$	Batch Size	32	128
$L_{out}$	The no. of output layers	1	1

표 1. DNN parameter

표 1에 제시된 바와 같이, 본 연구에서는 선행 연구 대비  $L$ ,  $L_{hid}$ ,  $D_{hid}$ ,  $D_{in}$ 을 증가시켰다. 식 (5)로 계산한 CCLM은 선행 연구 대비 약 21.9배 증가하였다. 또한 확장된 DNN 구조에 대해 epoch 수를 확대하여 TDL 환경의 복잡한 채널 특성을 충분히 학습하고, Batch size를 증대시켜 안정적인 수렴 특성을 가지며 학습해 검출 성능 향상을 기대할 수 있다.

### 3. 성능 분석

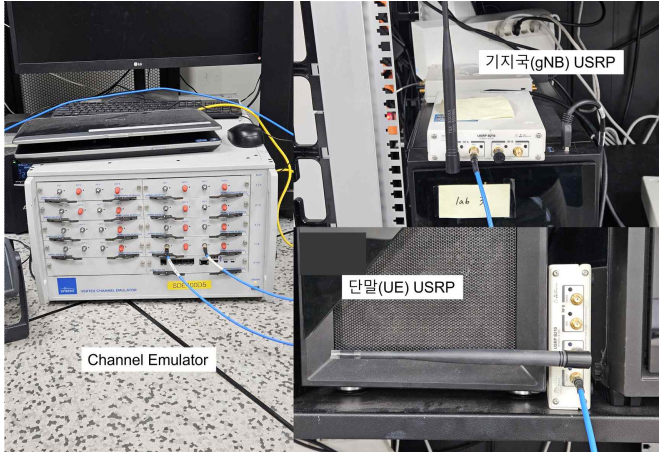


Fig 1. 실험 환경

PRACH 검출 성능 분석을 위해 Fig 1과 같은 실험 환경을 구성하였다. Multipath 환경 구현을 위해 기지국 및 단말 역할의 USRP와 Spirent Vertex Emulator에 각각 연결해 실험을 수행하였다. Emulator에는 실외 차량 속도를 가정한 환경 정도의 Multipath fading 채널 모델인 LTE EVA 70km/h를 적용하였다.

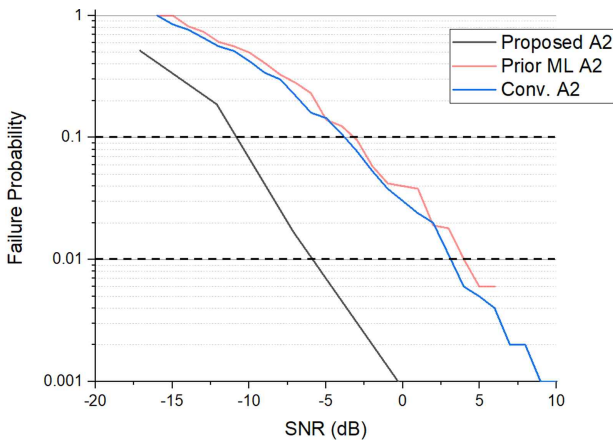


Fig 2. SNR-Failure Probability 그래프

Fig 2는 SNR에 따른 PRACH 검출 정도를 나타낸 SNR-Failure Probability 그래프이다. 모든 곡선은 Water-falling 특성을 보이며, 곡선이 좌측으로 이동할수록 동일한 실패 확률에서 우수한 SNR 성능을 가진다.

선행 연구에서 제시한 검출기는 TDL 환경에서 유의미한 SNR 이득을 확보하지 못한 반면, 본 연구에서 제시한 검출기는 10%의 실패 확률에서 8dB, 1%의 실패 확률에서 9dB의 SNR 성능 개선을 보인다. 이러한 성능 향상은 DNN 모델의 구조적 차이에 기인한다. 선행 연구의 DNN 모델은 Multipath 환경에서 낮은 peak의 PRACH 신호와 noise를 구분하지 못하였다. 이로 인해 PRACH 신호가 noise로, 혹은 noise가 PRACH 신호로 오인되어 DNN 모델이 잘못 라벨링된 데이터로 학습되는 문제가 있었다. 반면, 본 연구는 확장된 DNN 구조와 파라미터를 적용하고 PDP spreading 특성을 고려한 학습을 수행함으로써 성능을 크게 향상시켰다.

이러한 결과는 확장된 DNN 구조가 Multipath 환경에서 PRACH 검출 성능 열화를 효과적으로 보상할 수 있음을 시사한다.

### III. 결론

본 논문은 Multipath 채널 환경에 최적화된 DNN 파라미터를 확장된 DNN 구조에 적용하여, 기존 DNN 모델과의 PRACH 검출 성능을 비교·분석하였다. 실험을 통해 DNN 구조를 확장함에 따라 동일한 실패 확률에서 검출 성능이 유의미하게 향상되었음을 확인하였다. 이러한 결과는 Multipath 환경과 같이 채널 특성이 복잡한 상황에서도 확장된 DNN 모델을 활용함으로써 PRACH 검출 성능을 유의미한 수준으로 유지할 수 있음을 시사한다.

### ACKNOWLEDGMENT

이 논문은 2025년도 정부(과학기술정보통신부) 재원으로 정보통신기획평가원의 지원(No.2021-0-00165, 5G+ 지능형 기지국 소프트웨어 모델 개발)을 받아 수행된 연구임.

### 참고 문헌

- [1] Kim B., Kang S., Song Y. T., Lee S., Lee T., Kim J., Jo O., and Choi S. W., "On the Intelligentization of Softwarized Modem: From Algorithmic Design to Realization of Real-Time Channel-Learning Random Access", IEEE Internet of Things Journal, vol. 11, no. 24, Dec. 2024.
- [2] R. Fang, H. Chen, and W. Liu, "Deep learning-based PRACH detection algorithm design and simulation", Proc. 2nd Int. Conf. Frontiers of Electronics, Information and Computation Technologies (ICFEICT), pp. 505 - 511, 2022.
- [3] N.-K. Kwon, Y. Lee, and J. Kim, "Multipath 채널 환경에서의 딥러닝 기반 PRACH 검출 성능 개선 기법", 대한전자공학회 하계학술대회 논문집, pp. 883 - 885, 2023.
- [4] Yang X. and Fapojuwo A. O., "Enhanced Preamble Detection for PRACH in LTE", in Proc. IEEE Wireless Communications and Networking Conference (WCNC), 2013, pp. 3306 - 3311.
- [5] D. Y. Du, S. Lee, and S. W. Choi, "Machine learning-based PRACH preamble detection: Efficient structured design perspective", IEEE Access, vol. 13, pp. 193160 - 193169, 2025.