

# 기계학습 기반의 임의접속 프리앰블 검출기법

장 한 승\*, 이 훈°, 윤 문 섭\*, 김 대 익°

## Machine Learning-Based Detection Mechanism of Random Access Preambles

Han Seung Jang\*, Hoon Lee°,  
Munseop Yun\*, Daeik Kim°

### 요 약

본 논문에서는 셀룰러 임의접속과정에서의 프리앰블 검출성능을 향상시키기 위한 기계학습 기반의 임의접속 프리앰블 검출기법을 제안한다. 수신 프리앰블 신호를 효과적으로 처리하기 위해 합성곱 신경망 구조를 고안한다. 제안한 기술은 기존 임계값 기반의 검출 성능과 동일한 허위 검출 경보 확률을 갖는 상황에서 3dB 향상된 프리앰블 검출 성능을 보인다.

**Key Words** : random access, preamble, machine learning, deep learning, convolutional neural network

### ABSTRACT

In this paper, we propose a machine learning-based random access preamble detection method to improve the preamble detection performance in the cellular random access procedure. A convolutional neural network is developed for processing received preamble signals efficiently. The proposed technique shows a 3dB performance gain

over conventional schemes given the same false detection alarm probability.

### I. 서 론

사물인터넷(IoT) 및 사물지능통신(MTC) 서비스를 지원하기 위한 차세대 이동통신의 핵심 요구 조건은 극다수 단말을 수용하기 위한 초연결성(massive connectivity)이다<sup>[1]</sup>. 이를 위해서는 단말들이 이동통신 네트워크에 접속하기 위한 초기화 단계인 임의접속(random access) 과정이 필수적이다. 임의접속 과정을 수행하기 위해 단말들은 신원확인을 위한 프리앰블 신호를 무작위적으로 선택한다. 임의접속 과정의 첫 번째 단계에서 단말기는 자신의 프리앰블을 기지국에게 전송한다. 기지국은 수신신호를 활용하여 프리앰블을 검출하고, 검출된 프리앰블 인덱스 정보를 포함하여 무선 자원 할당을 임의접속 두 번째 단계에서 수행한다.

현재 LTE/LTE-A 및 5세대 통신 시스템에서는 프리앰블 검출을 위해 단순한 임계값(threshold) 기반의 이진 판단 전략을 활용한다. 프리앰블의 수신 신호가 주어진 임계값을 초과할 경우 기지국은 특정 프리앰블이 검출되었다고 판단하고, 해당 프리앰블을 사용하는 단말을 위한 임의접속 과정을 수행한다. 기존 기술은 단말의 수가 많지 않을 경우 비교적 잘 동작하지만, 극다수 단말의 접속을 지원해야 하는 차세대 통신 네트워크 환경에서는 정확도가 크게 하락한다. 따라서, 극다수 단말이 존재하는 초연결 시스템을 위한 새로운 개념의 임의접속 프리앰블 검출 기법 개발이 필수적이다.

본 논문에서는 기존 임계값 기반의 프리앰블 검출 성능보다 더욱 뛰어난 기계학습 기술을 이용한 프리앰블 검출 방법을 새롭게 제안한다. 최근 기계학습을 이용한 이동통신의 성능 향상기법들의 연구가 활발히 진행되고 있으나<sup>[2]</sup>, 대부분 송수신기 설계 및 물리계층 신호처리 최적화에 초점을 두어 임의접속을 위한

\* 이 논문은 부경대학교 자율창의기술연구비(2019년)에 의하여 연구되었음.

• First Author : Chonnam National University School of Electrical, Electronic Communication, and Computer Engineering, hsjang@jnu.ac.kr, 조교수, 정회원

° Corresponding Author : Pukyong National University Department of Information and Communications Engineering, hlee@pknu.ac.kr, 조교수, 정회원

°° Corresponding Author : Chonnam National University School of Electrical, Electronic Communication, and Computer Engineering, daeik@jnu.ac.kr, 정교수, 중신회원

\* Chonnam National University School of Electrical, Electronic Communication, and Computer Engineering, ungl72726@gmail.com, 학생(학석통합과정), 학생회원

논문번호 : 202012-321-LU, Received December 23, 2020; Revised January 5, 2021; Accepted January 6, 2021

기계학습 연구는 부족하다. 기지국에서 수신된 프리엠블 신호를 효과적으로 처리하기 위해 합성곱 신경망 구조를 설계하고, 프리엠블 검출을 위한 훈련 과정을 고안한다. 제안된 방식을 이용할 경우 기존 방식보다 약 3dB의 성능 향상을 보이는 것을 관찰하였다. 제안하는 기계학습 기반의 임의접속 프리엠블 검출기법을 활용하면 5세대 및 6세대 이동통신 시스템에서 추구하는 초연결성 지원의 토대가 될 것으로 예상된다.

## II. 임계값 기반의 프리엠블 검출 방법

경쟁 또는 비경쟁 셀룰러 임의접속 기술은 초기 네트워크 접속을 희망하는 익명의 단말들이 데이터 전송을 위한 자원 요청을 위해 활용된다. 각 단말들은 Zadoff-Chu (ZC) 시퀀스를 순환 이동하는 방식을 통해 아래 수식과 같은 프리엠블을 생성한다<sup>3,4</sup>.

$$z_{r,i}[n] = z_r[(n + iN_{cs}) \bmod N_{zc}], n = 0, \dots, N_{zc} - 1,$$

여기서  $z_r[n]$ 은 루트 인덱스  $r$ 을 갖는 ZC 시퀀스이며  $N_{cs}$ 는 기준 순환 이동 크기,  $N_{zc}$ 는 ZC 시퀀스의 길이(839)를 의미한다. 따라서  $z_{r,i}[n]$ 는 순환 이동을  $i$ 번 수행한  $i$ 번째 프리엠블을 의미한다. 생성된 프리엠블은 32768길이의 역 푸리에변환과 두 단계의 다운 샘플링 그리고 순환접두사(cyclic prefix: CP)를 붙여 1920의 길이로 물리적임의접속채널(PRACH)을 통해 기지국에게로 전송 된다. 기지국은 PRACH에 수신된 프리엠블 신호의 CP를 제거한 후 1536길이의 푸리에 변환을 수행한다. 다음으로 푸리에 변환이 된 루트 ZC 시퀀스( $Z_{r,0}[k]$ )와의 상관 값을 아래의 식으로 계산한다.

$$|c_j[n]|^2 = \left| \text{IFFT} \left\{ Y_j[k] Z_{r,0}^*[k] \right\}_n \right|^2, n = 0, \dots, \hat{N}_{zc} - 1,$$

여기서  $|c_j[n]|$ 은 위치  $n$ 에서의  $j$ 번째 안테나에서 계산한 상관 값의 크기,  $Y_j[k]$ 는  $j$ 번째 안테나에 수신된 푸리에 변환된 신호,  $\hat{N}_{zc}$ 는 수신된 프리엠블의 총 길이 1536를 의미한다. 총  $J$ 개의 안테나로부터 계산된 상관 값의 평균을 아래와 같이 구한다.

$$\chi[n] = \frac{1}{J} \sum_{j=1}^J |c_j[n]|^2, n = 0, \dots, \hat{N}_{zc} - 1.$$

$i$ 번째 프리엠블 검출영역에서의 평균 상관 값 집합

을 아래와 같이 정의한다.

$$D_i = \{ \chi[n] | i\hat{N}_{cs} \leq n < (i+1)\hat{N}_{cs} \},$$

여기서  $\hat{N}_{cs}$ 는 검출영역 크기를 의미한다. 임계값  $\gamma_{p_{false}}$ 을 기준으로 아래 기준을 만족할 경우 기지국은  $i$ 번째 프리엠블이 검출 되었다고 판단한다.

$$\max(D_i) \geq \gamma_{p_{false}},$$

여기서 임계값  $\gamma_{p_{false}}$ 은 허위 검출 경보(false alarm, 프리엠블 전송이 되지 않은 상황에 검출이 되었다고 판단) 확률이  $p_{false}$ 를 갖도록 하는 임계값이다.

## III. 기계학습 기반의 프리엠블 검출 방법

본 논문에서는 기계학습의 분류(classification)개념을 활용하는 새로운 프리엠블 검출 방식을 제안한다. 기계학습을 위한 입력 데이터로는 기지국에서 계산된 프리엠블 상관 값 데이터  $\chi[n]$ 를 사용하고 미리 알려진 프리엠블의 전송 여부 (0: 비 전송, 1: 전송)을 출력 데이터(클래스)로 사용한다. 따라서, 학습 데이터는 상관 값 데이터와 그에 해당하는 레이블(프리엠블 전송 여부)로 구성된다. 학습에 이용될 기계학습 모델로는 합성곱 신경망(convolutional neural network)을 이용한다. 합성곱 신경망은 영상과 같이 입력 데이터 내부의 공간적인 상관 관계를 다루는데 효과적인 구조로 잘 알려져 있다. 최근에는 합성곱 신경망을 1차원으로 구현하여 채널 출력 및 필터링 된 1차원 신호의 처리에도 널리 활용된다<sup>5</sup>. 프리엠블 검출을 위해서는 다중경로 채널을 통해 얻은 상관 값  $\chi[n]$ 를 활용해야 하므로 합성곱 신경망을 적절한 구조로 판단하였다.

그림 1에 제안하는 합성곱 신경망 구조를 도시하였다. 입력 데이터로  $i$ 번째 프리엠블 검출영역에서의 평균 상관 값 집합  $D_i$ 를 이용하고 세 개의 컨볼루션 층과 두 개의 완전 연결 층(fully connected layer)을 거친다. 마지막 완전 연결층 2에서의 출력은 softmax 활성화함수를 이용해 두 개의 클래스 0과 1에 대한 판별 확률값을 출력하도록 구성하였다. 이와 같은 모델을 제시하게 된 이유는 그림 2에서 보여주는 것처럼 모델의 층의 수에 따른 학습 시간과 검출 능력에 있다. 층의 수가 증가 됨에 따라 학습 시간은 선형적으로 증가 되지만 SNR 2dB 기준 검출 성능은 5층 이상에서의 한계를 보여 5개를 최적의 층의 수로 결정하였다.




그림 1. 합성곱 신경망을 이용한 학습 구조  
Fig. 1. Convolutional neural network architecture




그림 2. 레이어 수에 따른 검출 성능 및 학습 시간  
Fig. 2. Detection performance and learning time for the varying number of layers

학습에 이용될 데이터의 선별과정에서 프리앰블 수신 SNR 값의 범위 지정에 주의가 필요하다. 너무 낮은 SNR 값의 범위 데이터를 학습에 이용할 경우 검출 확률(1→1)은 매우 높게 나타나지만 허위 검출 확률(0→1) 또한 높게 나타나도록 학습될 수 있다. 또한 학습과정에서 과적합(overfitting)을 방지<sup>[5]</sup>하기 위한 검증 데이터 집합(validation set)을 설정하여 실제 시험(test)과정에서의 성능을 보장하기 위한 정교한 모델 학습이 필요하다.

#### IV. 실험 결과

본 논문에서 고려한 실험 환경을 표 1로 정리한다.

표 1. 실험 파라미터 및 값  
Table 1. Simulation parameters and values

| Item                             | Value                                     |
|----------------------------------|---|
| 프리앰블 검출 영역 크기 ( $\hat{N}_{cs}$ ) | 24  |
| 학습 데이터 SNR 범위                    | -31dB ~ -1 dB                             |
| 학습(training) 데이터 갯수              | Class 0: 1,000,000<br>Class 1: 70,000/SNR |
| 검증(validation) 데이터 갯수            | Class 0: 1,000,000<br>Class 1: 10,000/SNR |
| 시험(test) 데이터 갯수                  | Class 0: 100,000<br>Class 1: 20,000/SNR   |
| 허위 검출 확률 ( $P_{false}$ )         | 0.001                                     |
| 채널 환경                            | Extended Pedestrian A (EPA)               |

MATLAB을 이용한 프리앰블 검출 실험을 진행하여 많은 수의 데이터를 확보할 수 있지만 학습 시간을 고려한 학습, 검증, 시험에 적절한 데이터의 양을 정리하고 있다. Class 0의 경우는 기존 임계값 기반의 검출에서의 허위 검출 경보 확률 0.001과 동일한 성능에 대한 학습과 검증을 위해 각각 1,000,000개의 데이터를 가지고 실험하였고 시험 데이터에서도 0.001의 허위 검출 경보확률을 보이는지에 대한 확실한 시험을 위해 Class 1에 비해 더 많은 양의 데이터를 사용하였다. 이와 반대로, Class 1의 경우는 신호의 SNR 값에 따라 검출 성능이 상이하므로 SNR당 데이터를 따로 생성하고 학습, 검증, 그리고 시험을 위해 전체 데이터를 7:1:2의 비율로 나눠 사용하였다. 프리앰블 검출 영역의 크기는 24로써 이는 합성곱 신경망 입력층의 크기를 의미한다. Extended Pedestrian A (EPA) 채널 모델을 상정하여 데이터를 생성한다. 수신 SNR을 -31dB~-1dB 구간으로 나누어 학습하였다. 예를 들어 -15dB부터 -1dB 수신 SNR 크기를 갖는 데이터 집합은 (-15dB~-1dB)로 표기하였다. 최종 시험과정에서는 전체 수신 SNR 영역에서의 프리앰블 검출 여부를 확인하였다.

그림 3와 4에 각각 기지국에서 단일 및 두 개의 수신 안테나를 사용하는 상황에 대한 프리앰블 검출(1→1) 확률을 수신 SNR에 따라 도시하였다. 단일 안테나 상황에서는 학습에 사용된 SNR의 범위가 (-9db~-1dB)일 때 기존 임계값 기반의 기술과 동일한 0.001의 허위 검출 확률을 보인다. 제안하는 기술은 기존 기법 대비 약 3dB의 성능 향상을 보인다. 두 개의 기지국 안테나를 사용하는 환경에서도 비슷한 결과를 도출할 수 있다. 실험 결과를 통해 제안하는 기




그림 3. 단일 수신 안테나 상황에서의 프리앰블 검출 성능  
Fig. 3. Performance of preamble detection with a single receive antenna




그림 4. 두 개의 수신 안테나를 활용한 프리앰블 검출 성능  
Fig. 4. Performance of preamble detection with two receive antennas

기계학습 기반 프리앰블 검출 기술이 기존 기법 대비 효과적임을 확인할 수 있다.

### V. 결론

본 논문에서는 기존 임계값 기반의 프리앰블 검출 성능을 개선하기 위한 머신러닝 기반의 프리앰블 검출 방식을 제안하였다. 제안된 기술은 기지국 측에서 계산한 수신 상간값 데이터를 기반으로 검출 모델을 학습하고 기존 기술과 동일한 허위 검출 확률을 갖도록 학습하였다. 모의실험을 통해 제안하는 기술의 성능을 검증하였다.

### References

- [1] C. Bockelmann, N. Pratas, H. Nikopour, K. Au, T. Svensson, C. Stefanovic, P. Popovski, and A. Dekorsy, "Massive machine-type communications in 5G: Physical and MAC-layer solutions," *IEEE Commun. Mag.*, vol. 54, no. 9, pp. 59-65, Sep. 2016.
- [2] J. Kwon and T. Kwon, "Uplink performance approximation of multicell networks based on machine learning," *J. KICS*, vol. 45, no. 11, pp. 1855-1858, Nov. 2020.
- [3] S. Sesia, I. Toufik, and M. Baker, *LTE - The UMTS Long Term Evolution From Theory to Practice*, John Wiley & Sons Ltd., 2009.
- [4] D. Chu, "Polyphase codes with good periodic correlation properties," *IEEE Trans. Inf. Theory*, vol. 18, no. 4, pp. 531-532, Jul. 1972.
- [5] T. O'Shea and J. Hoydis, "An introduction to deep learning for the physical layer," *IEEE Trans. Cog. Commun. Netw.*, vol. 3, no. 4, pp. 563-575, Dec. 2017.