

# 인지 라디오 시스템용 협업 기계학습기반 무선접속 식별 기술

윤 장 혁\*, 손 웅\*, 정 방 철<sup>o</sup>

## A Radio Access Technology Identification Based on Collaborative Machine Learning for Cognitive Radio Networks

Janghyuk Yoon\*, Woong Son\*,  
 Bang Chul Jung<sup>o</sup>

### 요 약

본 논문은 기지국과 다수의 주 사용자들로 이루어진 주 네트워크와 주변에 다수의 부 사용자들이 존재하는 인지라디오 환경에서 주 네트워크의 무선접속 방식을 식별하기 위한 협업 기계학습 기반 기술을 제안한다. 특히, 주 네트워크의 무선접속 방식을 식별하는 것은 무선자원 이용효율을 향상시키고, 주 사용자들과 부 사용자들의 간섭을 최소화하기 위해 인지라디오 사용자들이 전송 파라미터를 조절하기 위해 사용될 수 있다. 제안하는 기술은 부 사용자들이 주 네트워크의 신호들을 감지하고 전력값을 기록하여 융합 제어기로 전력 데이터를 전달한다. 최종적으로 융합제어기에서는 주 네트워크의 무선접속 방식을 기계학습을 통해 식별한다. 컴퓨터 모의실험을 통해 기존에 제안된 단일 부 사용자를 이용한 기술보다 제안하는 기술이 동일시간 대비 식별 정확도가 우수함을 확인하였다.

**Key Words** : Radio Access Technology (RAT),  
 Cognitive Radio (CR), Collaborative

Sensing, Machine Learning (ML),  
 Support Vector Machine (SVM)

### ABSTRACT

In this letter, we propose a radio access technology (RAT) identification based on collaborative machine learning for cognitive radio (CR) networks consisting of multiple primary users, a base station and multiple secondary users. In particular, a RAT identification technique can be exploited for improving radio resource utilization as well as minimizing interference between primary and secondary users through adaptively change transmission parameters at CR users. During the training period, each secondary user senses the wireless channel and records the received signal power. After the training period, all of secondary users feedback the recorded data to the fusion center. The fusion center identifies the RAT in the primary network. Via simulations, the proposed technique outperforms the conventional technique in terms of identification accuracy during the same time.

### 1. 서 론

최근 기계학습 분야의 비약적인 발전으로 기계학습 기술을 무선통신 네트워크에 적용하는 다양한 접근이 제시되고 있다<sup>[1]</sup>. 또한, 인지라디오 네트워크에서 기계학습기술을 활용하여 성능을 개선시키는 연구가 활발히 진행되고 있다<sup>[2]</sup>. 인지 라디오 환경에서 주 네트워크에서 사용하는 무선접속 프로토콜을 부 네트워크에서 식별하는 것은 부 네트워크가 보다 효율적으로 주파수 자원을 공유하기 위해 매우 중요한 기술적 과제로 알려져 있다. 최근 기계 학습 기술 중 SVM (Support Vector Machine) 기법을 활용하여 주 네트워크에서 사용하는 무선접속 프로토콜을 식별하는 기술이 제안되었다<sup>[3-5]</sup>. 특히, 기존 연구를 통하여 다양

※ 본 연구는 방위사업청과 국방과학연구소가 지원하는 미래전투체계 네트워크기술 특화 연구센터 사업의 일환으로 수행 되었습니다 (UD160070BD).

• First Author : (ORCID:0000-0002-7486-8270)Department of Electronics Engineering, Chungnam National University, jhyoon@o.cnu.ac.kr, 학생회원

◦ Corresponding Author : (ORCID:0000-0002-4485-9592)Department of Electronics Engineering, Chungnam National University, bcjung@cnu.ac.kr, 중신회원

\* (ORCID:0000-0001-9332-2102)Department of Electronics Engineering, Chungnam National University, woongson@cnu.ac.kr, 학생회원  
 논문번호 : 201908-145-A-LU, Received August 1, 2019; Revised August 13, 2019; Accepted August 14, 2019

한 무선 접속 프로토콜 중 TDMA (Time-Division Multiple Access)와 s-ALOHA (Slotted-ALOHA)는 동작 방식이 매우 유사하여 TDMA와 s-ALOHA 프로토콜을 식별하는 것은 매우 도전적인 과제로 알려져 있다<sup>[5]</sup>. 기존 연구에서는 단일 부 사용자에서 기계 학습 알고리즘을 이용하여 무선접속 방식을 식별 기술들이 제안되었으며, 높은 식별 정확도를 달성하기 위해서 긴 학습시간이 요구되는 것으로 알려져 있다<sup>[3-5]</sup>.

본 논문에서는 주 네트워크에 대한 사전 정보 없이 수신 신호의 전력 및 시간적 특징만을 이용하여 짧은 학습시간으로 높은 식별 정확도를 얻을 수 있는 다중 부 사용자들이 협업하여 주 네트워크에서 사용되는 무선접속 프로토콜을 식별하는 기법 제안한다.

## II. 시스템 모델

주 네트워크는  $N$ 개의 주 사용자들과 단일 기지국으로 구성되고, 인접된 부 네트워크는  $M$ 개의 부 사용자들과 이들을 제어하는 융합제어기가 존재한다. 부 사용자들은 기존에 설치된 주 네트워크의 전송 성능 열화를 최소화하기 위해 주 네트워크의 무선접속 방식을 식별하여 무선자원을 접근한다. 본 논문에서는 주 네트워크는 TDMA와 s-ALOHA 무선접속 방식 중 하나를 사용하고, 동일한 길이의 시간슬롯을 사용한다고 가정한다. TDMA와 s-ALOHA 뿐 아니라 다양한 무선접속 프로토콜의 식별이 가능하나 본 논문에서는 기존 연구에서 가장 어렵다고 알려져 있는 TDMA와 s-ALOHA 프로토콜간의 식별에 집중한다<sup>[5]</sup>. 주 사용자들로부터 전송되는 신호들을 부 사용자들이 감지할 수 있다. 또한 모든 통신 기기들간 채널은 독립적이고 균등한 분포를 갖고 전송중 채널이 변하지 않다고 가정한다.

## III. 협업 기계학습기반 무선접속 방식 식별 기술

부 사용자는 무선 채널을 감지할 때마다 수신신호의 전력값만을 획득할 수 있으며, 획득한 전력값을 융합제어기로 전송하고, 융합제어기는 기계학습을 수행하여 주 네트워크의 무선접속 방식을 식별한다.

기계학습을 하기 전에 융합제어기는 부 사용자들로부터 수집한 수신신호 전력값 데이터의 평균을 계산하여 하나의 데이터로 종합한다. 그리고 일정 학습구간 동안의 데이터를 종합하여 수신신호 전력 평균/분산, 최대/중간/최소 신호존재시간과 신호부재시간, 총

8개의 특징을 추출한다. 여기서 신호존재시간이란 주 사용자가 신호를 전송하여 감지된 신호가 있는 시간슬롯의 길이를 의미하며, 신호부재시간이란 어떠한 주 사용자도 신호를 전송하지 않아 감지된 신호가 없는 시간슬롯의 길이를 의미한다.

선형 SVM은 추출한 8차원의 특징 데이터를 두 개로 구분할 수 있는 초평면을 학습한다. 데이터 집합은  $\mathbf{x}_i, \mathbf{y}_i$ 이며,  $\mathbf{x}_i$ 는 분류할 전체  $n$ 개의 데이터 중  $i$ 번째 데이터를,  $\mathbf{y}_i \in \{-1, 1\}$ 는  $\mathbf{x}_i$ 의 분류를 나타낸다. 데이터를 분류하는 초평면은 다음과 같다.

$$\mathbf{w} \cdot \mathbf{x}_i + b = 0 \tag{1}$$

이때,  $\mathbf{w}$ 와  $b$ 는 초평면의 법선 벡터와 더해지는 편향 값을 의미한다.  $\mathbf{y}_i = 1$ 과  $\mathbf{y}_i = -1$ 에 대응하는  $\mathbf{x}_i$  중 (1)의 초평면과 가장 가까운  $\mathbf{x}_i$ 들을 각각  $\mathbf{x}^+, \mathbf{x}^-$ 라 하면  $\mathbf{x}^+, \mathbf{x}^-$ 을 지나며 (1)과 같은 법선벡터를 갖는 초평면을 다음과 같이 나타낼 수 있다.

$$\begin{aligned} \mathbf{w} \cdot \mathbf{x}^+ + b &= +1, \\ \mathbf{w} \cdot \mathbf{x}^- + b &= -1. \end{aligned} \tag{2}$$

(2)는 (1)의 초평면과 가장 가까운 데이터를 지나는 초평면을 나타내기 때문에  $\mathbf{x}^+$ 가 아닌  $\mathbf{y}_i = 1$ 에 대응하는  $\mathbf{x}_i$ 는  $\mathbf{w} \cdot \mathbf{x}_i + b \geq +1$ 가 성립하며,  $\mathbf{x}^-$ 가 아닌  $\mathbf{y}_i = -1$ 에 대응하는  $\mathbf{x}_i$ 는  $\mathbf{w} \cdot \mathbf{x}_i + b \leq -1$ 이 성립한다. SVM 기법의 목표는 (2)의 두 초평면의 마진 (margin) 을 최대화하는 최적화 문제로 표현되며, 다음과 같은 식으로 쓸 수 있다.

$$(\mathbf{w}^*, b^*) = \underset{(\mathbf{w}, b)}{\operatorname{argmin}} \frac{1}{2} \|\mathbf{w}\|^2, \tag{3}$$

이때,  $1 \leq i \leq n$ 일 경우에  $\mathbf{y}_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1$ 이다.

## IV. 모의실험 결과

단일 부 사용자 단말에서 수집한 수신 전력 데이터를 이용한 선형 SVM기반의 기존 무선접속 방식 식별 기술<sup>[5]</sup>과 제안하는 다수의 부 사용자 단말들에서 수집한 수신 전력 데이터를 이용하여 융합센터에서 선형 SVM기반으로 무선접속 방식을 식별하는 기술을 비교하였다. 주 사용자와 부 사용자는 10개가 존재하며

( $N=M=10$ ), 융합제어기는 1,000개의 수신 전력 데이터마다 하나의 특징 데이터를 추출하고, 이 과정을 1,000번 수행하여 총 1,000개의 추출된 데이터에 대한 기계학습을 수행하였다.

그림 1은 융합제어기에서 학습에 사용하는 평균 수신 신호 전력의 존재 및 부재시간 분포를 보여준다. 트래픽 부하 (Traffic Load) 는 전체 시간슬롯 중 주 사용자가 전송한 신호가 존재하는 시간슬롯의 비율을 의미한다. 트래픽 부하는 0.5로, TDMA의 경우, 주 사용자는 할당된 시간슬롯마다 0.5의 확률로 데이터 신호를 전송하며, s-ALOHA의 경우, 모든 시간슬롯마다 0.05의 확률로 데이터 신호를 전송한다. 그림 1을 살펴보면, 기존 기술뿐만 아니라 제안하는 기술도 신호 및 부재시간을 이용해서 TDMA와 s-ALOHA를 식별하기는 어렵다.

그림 2는 융합제어기에서 학습에 사용하는 평균 수신 신호 전력의 평균 및 분산 분포를 보여준다. 제안하는 기술의 분포가 기존 기술보다 밀집도가 높아 선형 초평면을 이용하는 선형 SVM으로도 충분히 높은 식별 정확도를 달성할 수 있다.




그림 1. 신호존재 및 부재시간 분포  
Fig. 1. Busy and idle state duration distribution




그림 2. 수신 전력 평균 및 분산 분포  
Fig. 2. Mean and variance distribution




그림 3. ROC 성능 비교  
Fig. 3. Comparison of ROC curve

그림 3은 제안하는 기술과 기존 기술에 대한 식별 정확도를 비교한다. 무선접속 방식 식별은 1,000개의 시간슬롯을 감지 후 얻은 수신 전력 데이터를 이용하며, 총 1,000번 실시하였다. 기존 기술은 선형 SVM, 제안하는 기법은 선형 및 가우시안 SVM을 고려하였다. 주 네트워크의 트래픽 부하는 0에서 1사이의 균일한 확률 분포에 따라 정해지며, 한번의 무선접속 방식 식별이 이루어지는 동안 변하지 않는다. 제안하는 기술이 잘못 식별한 비율인 거짓양성률이 작을 때, 정확히 식별한 비율인 참양성률이 더 높기 때문에 기존 기술 대비 식별 정확도가 더욱 우수하다. 또한, 제안하는 기술과 같은 환경에서 가우시안 SVM을 사용한 경우보다도 우수한 성능을 달성하는 것을 확인할 수 있다.

### V. 결론

본 논문은 SVM기반의 주 네트워크의 무선접속 방식 식별 기술을 제안하였다. 다수의 부 사용자들이 수신 신호 전력값을 융합제어기로 전달하고 최종적으로 융합제어기에서 무선접속 방식을 식별한다. 단일 사용자에서의 무선접속 방식을 식별하는 기존 기술대비 다수의 협업 사용자와 융합제어기를 이용하는 제안하는 기술이 식별 정확도가 우수한 것을 확인하였다. 또한 선형 SVM이 가우시안 SVM을 사용했을 때 보다 성능이 더 우수한 것을 확인하였다.

### References

[1] Y. Sun, M. Peng, Y. Zhou, Y. Huang, and S. Mao, "Application of machine learning in wireless networks: Key techniques and open

- issues,” *IEEE Commun. Surv. & Tuts.*, to appear, 2019.
- [2] M. Bkassiny, T. Li, and S. K. Jayaweera, “A survey on machine-learning techniques in cognitive radios,” *IEEE Commun. Surv. & Tuts.*, vol. 15, no. 3, pp. 1136-1159, Third Quarter, 2013.
- [3] Z. Yang, Y.-D. Yao, S. Chen, H. He, and D. Zheng, “MAC protocol classification in a cognitive radio network,” in *Proc. 19th Annu. WOCC*, Shanghai, China, May 2010.
- [4] S. Hu, Y.-D. Yao, and Z. Yang “MAC protocol identification approach for implement smart cognitive radio,” in *Proc. IEEE ICC*, Ottawa, ON, Canada, Jun. 2012.
- [5] S. Hu, Y.-D. Yao, and Z. Yang, “MAC protocol identification using support vector machines for cognitive radio networks,” *IEEE Wireless Commun.*, vol. 21, no. 1, pp. 52-60, Feb. 2014.