

# 기계학습 기반 Slotted-ALOHA 백오프 기법

권형준\*, 이정훈\*, 정동근<sup>o</sup>

## Machine Learning Based Backoff Scheme for Slotted-ALOHA

Hyung Jun Kwon\*, Jung Hoon Lee\*,  
Dong Geun Jeong<sup>o</sup>

### 요약

본 레터에서는 Slotted-ALOHA 시스템의 성능을 높이기 위해 기계학습을 이용하는 전송 백오프(backoff) 기법을 제안한다. 제안하는 기법에서는 기존의 지수 백오프 방식과 기계학습을 이용하여 구한 최적의 경쟁 윈도우 크기를 고정적으로 사용하는 방식이 유기적으로 결합되어 사용된다. 또한 최적 경쟁 윈도우 크기를 결정하는 기능을 하나의 제어기에 집중시킴으로써, ALOHA의 장점인 단순함을 훼손하지 않는다. 레터에서는 시뮬레이션을 이용하여 제안하는 기법이 시스템의 성능을 현저히 향상시킴을 보인다.

**Key Words** : slotted-ALOHA, collision resolution, backoff window size, IoT, machine learning

### ABSTRACT

In this letter, we propose a machine learning-based backoff scheme for slotted-ALOHA systems. The proposed scheme combines the conventional binary exponential backoff technique and the technique using a constant optimal contention window size, obtained with machine learning. Since a specific controller

carries out the window size decision, the proposed scheme maintains the simplicity of ALOHA. We show that the proposed scheme improves the system performance remarkably by using simulation.

### I. 서론

ALOHA 및 그 변형 프로토콜은 군사용, 상업용 무선 통신시스템에 다양하게 응용되어 왔다. WiFi와 같은 근거리 무선통신의 채널 액세스는 물론이고, 4G/5G와 같은 셀룰러통신 시스템의 제어채널 액세스 프로토콜도 ALOHA의 변형인 Slotted-ALOHA (S-ALOHA)가 근저를 이룬다.

ALOHA 또는 S-ALOHA의 장점은 그 액세스 기법의 단순함이고, 그 결과 프로토콜 구현 비용이 적고 동작시 소모되는 에너지가 작다. 이 특성은 최근 폭발적으로 보급되고 있는 사물인터넷(IoT: Internet of Things)의 저비용, 저에너지 소모라는 일반적 요구 조건에 잘 부합된다. 이에 따라, Zigbee, BLE (Bluetooth Low Energy), UWB(Ultra-Wideband) 등과 같은 단거리 IoT 시스템이나 LoRa(Long-Range)와 같은 중장거리 IoT 시스템을 막론하고 S-ALOHA나 그 변형을 기본 액세스 프로토콜로 사용함으로써, ALOHA의 중요성이 더욱 커지고 있다.

ALOHA 프로토콜에서 둘 이상의 사용자가 동시에 전송을 시도하면 트래픽 충돌(collision)이 발생한다. 이러한 충돌 상황을 해소하기 위해 각 사용자가 서로 다른 시간만큼 인위적으로 전송을 양보하는 백오프(backoff) 기법이 사용된다. ALOHA의 성능은 백오프 기법에 결정적으로 좌우되므로, 전통적인 S-ALOHA를 위한 향상된 백오프 기법 설계는 물론이고<sup>[1]</sup>, 특정한 통신시스템의 ALOHA에 관한 백오프 기법에 관해서도 다양한 연구가 진행되어 왔다<sup>[2]</sup>.

한편 지난 수년간 컴퓨팅 파워의 가격 대비 성능이 획기적으로 신장됨에 따라, 기계학습이 많은 분야에서 응용되고 있다. 통신 분야에서도 동작 성능을 극대화하기 위한 각종 파라미터 값의 결정에 있어서 기계학습

\* This work was supported by Hankuk University of Foreign Studies Research Fund of 2019 and by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. 2016R1C1B2010281 and 2019R1F1A1062597).

• First Author : (ORCID:0000-0001-9007-5871)Department of Electronics Engineering and Applied Communications Research Center, Hankuk University of Foreign Studies, hjkwon91@hufs.ac.kr, 학생회원

◦ Corresponding Author : (ORCID:0000-0001-7515-7422)Department of Electronics Engineering and Applied Communications Research Center, Hankuk University of Foreign Studies, dgjeong@hufs.ac.kr, 종신회원

\* (ORCID:0000-0002-7875-2398)Department of Electronics Engineering and Applied Communications Research Center, Hankuk University of Foreign Studies, tantheta@hufs.ac.kr, 정회원

논문번호 : 201912-337-A-LU, Received December 15, 2019; Revised December 19, 2019; Accepted December 19, 2019

을 이용하는 연구가 진행되고 있다<sup>13-15</sup>.

본 레터에서는 S-ALOHA 시스템에서, 주어진 트래픽 패턴에 대해 기계학습을 이용하여 최적의 경쟁 윈도우 크기(CWS: Contention Window Size)를 결정하는 방법을 제안하고, 그 성능을 평가한다. 제안하는 기법의 목표는 각 사용자 입장에서 S-ALOHA의 단순함을 훼손하지 않으면서도 통신시스템의 성능을 현저히 높이는 것이다.

## II. 시스템 모델

본 레터에서 고려하는 시스템은  $N$  개의 사용자로 구성된다. 설명의 편의를 위해, 사용자 중 하나는 특별한 중앙제어기(예컨대, 셀룰러시스템의 기지국, WiFi의 액세스포인트, LoRa의 게이트웨이, 또는 센서 네트워크의 수집기 등)라 가정한다. 중앙제어기는 하나의 사용자로 동작하는 동시에, 단독으로 혹은 엣지(edge) 컴퓨팅을 통해, 다음 절에서 설명할 기계학습을 수행하여 결정된 CWS 값을 다른 사용자에게 통보하는 추가적 역할을 수행한다.

각 사용자는 S-ALOHA 기법에 따라 일정한 속도로 트래픽을 전송한다. 한 슬롯 동안 하나의 일정 크기 패킷이 전송된다고 하자. 전송 실패는 충돌에 의해서만 발생한다고 가정한다. 각 슬롯에서의 전송 상황에 따라 슬롯 상태를 전송 성공(S: Success), 충돌(C: Collision), 휴면(I: Idle)으로 분류할 수 있는 바, 각각 전송 사용자가 하나일 때, 둘 이상일 때, 아무도 없을 때에 상응한다. 각 상태의 슬롯을 각각 S-슬롯, C-슬롯, I-슬롯이라 부르기로 한다.

한 사용자가 패킷을 생성하면 그 패킷은 해당 사용자의 송신큐(queue)로 들어간다. 송신큐에는 전송되지 못한 다수의 패킷이 대기하고 있을 수도 있다. 전송할 패킷을 가진 사용자는  $[0, CWS-1]$  구간에서 균일(uniform) 분포에 따라 발생된 백오프 슬롯 수만큼 기다린 후 패킷을 전송한다. 전송에 실패한 패킷에 대해서는 동일한 백오프 방법을 적용하여 (단, 다음 절에서 설명할 방법에 따라 그 사용자의 CWS 값은 변경되었을 수 있다) 재전송을 시도한다. 각 사용자는 한 패킷에 대해 최대 재전송 시도 횟수의 제한을 가지며, 이를 초과하면 패킷을 폐기한다.

## III. 제안하는 기법

### 3.1 경쟁 윈도우 크기(CWS) 결정

기존의 S-ALOHA는 통상 이진 지수 백오프(BEB:

Binary Exponential Backoff) 방식으로 동작한다. 본 연구의 BEB에서는, 각 사용자의 CWS는 자신의 전송 결과, 충돌이 일어날 때마다 2 배로 증가하고, 성공하면 최솟값( $CWS_{min}$ )으로 감소(재설정)된다.

제안하는 기법에서는 BEB와 함께 고정된 값의 CWS를 사용하는 (C-CWS: Constant CWS) 방식도 사용된다. 제안하는 기법은 (명목상의) 프레임 기반으로 동작하며, 그림 1과 같이 하나의 프레임은 BEB 구간(BEB phase), 방송슬롯(broadcast slot), C-CWS 구간(C-CWS phase)으로 구성된다.

BEB 구간에서 각 사용자는 앞서 말한 BEB 방식으로 동작한다. 이에 덧붙여, 중앙제어기는 이 구간 동안 트래픽 패턴을 대표하는 S-슬롯, C-슬롯, I-슬롯 각각의 비율을 파악한다. 또 BEB 구간이 끝나면, (독자적으로 혹은 엣지컴퓨팅을 통해) 미리 학습된 기계학습 모델을 이용하여 C-CWS 구간에서 사용할 최적의 CWS 값을 구한다. 중앙제어기는 독점적 방송슬롯을 경쟁없이 사용하여 모든 사용자에게 새로운 최적 CWS 값을 방송한다. C-CWS 구간에서 각 사용자는 방송된 CWS를 고정 값으로 사용한다.




그림 1. 제안하는 기법의 프레임 구성  
Fig. 1. Frame structure of proposed scheme

### 3.2 기계학습

기계학습 모델은 BEB 구간 동안의 S-슬롯, C-슬롯, I-슬롯 각각의 비율을 입력으로 C-CWS 구간 동안 사용할 최적의 CWS 값을 도출한다. 이를 위한 사전 오프라인 학습과정은 다음과 같다.

- (1) 특정 시스템부하에서 충분한 시간 동안 BEB 방식을 사용하였을 때, S-슬롯, C-슬롯, I-슬롯 각각의 비율을 측정한다.
- (2) (1)과 동일한 시스템부하에서 충분한 시간 동안 각 CWS 값을 고정적으로 사용하였을 때, 가장 좋은 성능을 나타내는 CWS 값을 찾는다.
- (3) (1)에서 측정된 S-슬롯, C-슬롯, I-슬롯의 비율들과 (2)에서 찾은 최적의 CWS 값을 연결하여 하나의 데이터 샘플을 만든다.

(4) (1) ~ (3) 과정을 다양한 시스템부하에서 시행하여 충분한 수의 훈련 데이터를 확보하고 기계학습 모델을 학습시킨다.

#### IV. 성능 평가

본 연구에서 사용한 기계학습 모델은 각각 100 개의 은닉노드를 가진 3 개의 은닉층으로 구성된 DNN(deep neural network)이고, Tensorflow 프레임워크를 이용하여 학습하였다. 활성화 함수로 ReLU (Rectified linear unit)을, 목적 함수로 교차 엔트로피 함수를, 학습 알고리즘으로 Adam(Adaptive moment) 알고리즘을 사용하였다. 학습과정에서는  $CWS_{min} = 4$  일 때, BEB 방식으로 최대 6회 재전송할 동안 사용하는 모든 CWS 값을 고려하였다. 즉,  $CWS \in \{4, 8, 16, 32, 64, 128, 256\}$ 이다.

기계학습은 일반적으로 블랙박스과 같아서 결과에 대한 분석이 어렵다. 그러나 그 동작을 시각화함으로써 부분적인 분석이 가능하다. 그림 2는  $N=100$  일 때, 훈련 데이터 5,000 개를 이용하여 학습시킨 기계학습 모델의 입력 공간에서 결정 지역을 나타낸 것이다. 결정 지역은 S-슬롯, C-슬롯, I-슬롯 비율의 총합이 1이라는 조건을 만족하는 2차원 평면으로 나타난다. 그림에서 보듯이 I-슬롯 비율이 낮을수록, C-슬롯과 S-슬롯 비율이 높을수록 큰 CWS 값을 반환하는 것을 알 수 있다.

제안하는 기법의 성능 분석을 위해 MATLAB을 이용한 시뮬레이터를 구현하고, 이를 사용해 컴퓨터 시뮬레이션을 수행하였다. 시스템부하가  $\lambda$ (생성패킷/슬롯), 전체 사용자 수가  $N$ 일 때, 각 사용자는 발생률이  $\lambda/N$

인 지수분포에 따라 패킷을 생성한다. 또 한 패킷에 대한 재전송은 6회로 제한하며,  $CWS_{min} = 4$ 로 설정하였다. 프레임 길이를 250,000 슬롯시간으로 하고 BEB 구간과 C-CWS 구간을 각각 125,000 슬롯시간으로 설정하였다. 그림 3과 4에서 시뮬레이션 결과를 나타낸 각 동작점은 1,250,000 슬롯시간 동안 시뮬레이션을 수행한 결과이다.

그림 3에서는 기존의 BEB 방식과 제안하는 방식의 충돌 확률을 비교하였고, 그림 4에서는 시스템 처리량을 비교하였다. 특징적 결과로서, 시스템 부하가 클 때 제안하는 방식이 기존 BEB 방식보다 충돌 확률은 더 낮고 시스템 처리량은 더 높은 것을 확인할 수 있다. 그 이유는 과부하 상황에서 기존의 방식은 가끔 전송이 성공할 때마다 CWS를  $CWS_{min}$ 으로 급격히 낮춤으로서 격렬한 후속 충돌을 야기하는 반면, 제안하는 기




그림 3. 충돌 확률  
Fig. 3. Collision probability

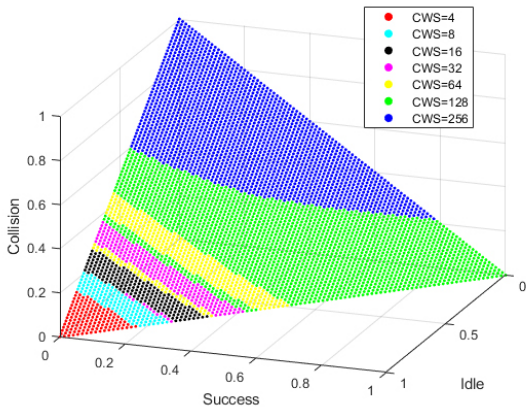


그림 2. 기계학습 모델의 결정 지역  
Fig. 2. Decision region of machine learning model




그림 4. 시스템 처리량  
Fig. 4. System throughput

법은 C-CWS 구간에서 최적의 CWS 값을 고정하여 사용하기 때문에 이러한 현상을 완화하기 때문이다.

제안하는 기법의 과부하 상황에서의 현저한 성능향상은 순간적으로 또는 일정 기간 트래픽이 폭증하는 특정한 IoT 응용에서 아주 유용하다. 예를 들면, IoT를 이용한 스마트검침(smart metering) 등에서는 검침이 시작되면 주변 검침기의 트래픽이 일시에 몰려 한동안 과부하 상황이 연출될 수 있기 때문이다.

## V. 결 론

본 레터에서는 기계학습을 이용하여 최적의 CWS를 결정하는 새로운 백오프 기법을 제안하였다. 성능평가를 통해, 제안된 기법이 특히 과부하 상황에서 S-ALOHA의 성능을 현저히 향상시킬 수 있음을 보였다. 후속 연구로서, BEB 구간과 C-CWS 구간의 적정 비율을 구하는 문제 등 몇 가지 심화 연구가 필요하다. 또한 제안된 개념을 CSMA(carrier-sense multiple access)나 CSMA/CA(collision avoidance) 등으로 확장 적용하여, 더욱 다양한 유무선 시스템에 응용하는 연구도 중요하다.

## References

- [1] D. G. Jeong and W. S. Jeon, "Performance of an exponential backoff scheme for slotted-ALOHA protocol in local wireless environment," *IEEE Trans. Veh. Tech.*, vol. 44, no. 3, pp. 470-479, Aug. 1995.
- [2] W. S. Jeon and D. G. Jeong, "Combined channel access and sensing in cognitive radio slotted-ALOHA networks," *IEEE Trans. Veh. Tech.*, vol. 64, no. 5, pp. 2128-2133, May 2015.
- [3] M. Wang, Y. Cui, X. Wang, S. Xiao, and J. Jiang, "Machine learning for networking: Workflow, advances and opportunities," *IEEE Netw.*, vol. 32, no. 2, pp. 92-99, Apr. 2018.
- [4] D. Lim, "Performance improvement of fast time-varying OFDM channel estimation by machine learning," *J. KICS*, vol. 44, no. 2, pp. 281-284, Feb. 2019.
- [5] C. Zhang, P. Patras, and H. Haddadi, "Deep learning in mobile and wireless networking: A survey," *IEEE Commun. Surv. & Tuts.*, vol. 21, no. 3, pp. 2224-2287, Mar. 2019.