

# SISO 브로드캐스트 채널에서 QoS를 고려한 기계학습 기반 전력 할당 기법

권형준\*, 이정훈<sup>o</sup>

## Machine Learning-Based QoS Aware Power Allocation in SISO Broadcast Channels

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

### 요 약

최근 다양한 스마트 기기의 보급으로 모바일 트래픽이 폭증하고 있다. 그로 인해 발생하는 서비스 품질(QoS: Quality of service) 저하는 차세대 무선통신에서 중요한 이슈로 떠오르고 있다. 본 레터에서는 간단한 SISO(single-input and single-output) 브로드캐스트 채널에서 QoS를 고려한 기계학습 기반 전력 할당 기법을 제안한다. 제안하는 기계학습 모델은 주어진 최대 전력과 채널 이득에 대해 QoS가 가장 낮은 사용자의 전송률을 최대화하는 최선의 전력 할당을 수행한다. 성능 평가를 통하여 제안하는 기법이 높은 복잡도를 가지는 다른 전력 할당 기법과 동일한 성능을 얻는 것을 보인다.

**Key Words** : Machine learning, deep learning, SISO broadcast channels, deep neural network, power allocation, QoS

### ABSTRACT

In recent years, mobile traffic is exploding as various smart devices emerge. As a result, QoS(quality of service) becomes a more important measure in the next generation of wireless

communications. In this letter, we propose machine learning-based power allocation considering QoS in simple SISO broadcast channels. Our proposed machine learning model finds the best power allocation considering the QoS of all users for given maximum power budget and channel gains. The numerical results show that our proposed scheme achieves the same performance as the target power allocation scheme, which requires high computational complexity.

### 1. 서 론

SISO(single-input and single-output) 브로드캐스트 채널에서는 단일 안테나를 가진 하나의 송신단이 다수의 사용자를 서비스한다. SISO 브로드캐스트 채널에서 평균 합-전송률 용량(sum-rate capacity)은 신호 대 잡음 비(SNR: Signal to noise ratio)가 가장 큰 사용자에게 전력을 할당하는 기회주의적 스케줄링(opportunistic scheduling)에 의해 얻어진다<sup>1)</sup>. 그러나 실제 시스템에서 사용자들은 서로 다른 페이딩 특성(fading statistics)을 갖기 때문에 단순히 sum-rate를 극대화하는 스케줄링은 특정 사용자의 서비스 품질(QoS: Quality of service) 저하를 초래할 수 있다. 이러한 문제는 IPTV, VoIP, VTC 등 안정적인 QoS가 요구되는 서비스에서 특히 중요하다. 이를 해결하기 위해 QoS를 고려한 다양한 스케줄링 알고리즘과 전력 할당 기법이 제안되는 등 연구가 활발하게 진행되고 있다<sup>1-3)</sup>.

최근에는 이러한 통신 환경 개선을 위해 기계학습이 다양하게 활용되고 있다. 기계학습은 NOMA(non-orthogonal multiple access), Massive MIMO(multiple-input and multiple-output), mmWave 등 차세대 무선통신 기술에서 성능향상 및 복잡도 개선을 위한 핵심요소로 부각되고 있다<sup>4,5)</sup>. 본 레터에서는 SISO 브로드캐스트 채널에서 QoS를 고려한 기계학습 기반 전력 할당 기법을 제안하고, 성능 분석을 통해 전력 할당 문제에 대한 기계학습의 응용 가능성을 확인한다.

※ This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. NRF-2021R1H1A1010858) and by Hankuk University of Foreign Studies Research Fund of 2020.

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

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

논문번호 : 202102-026-A-LU, Received January 29, 2021; Revised February 25, 2021; Accepted March 2, 2021

## II. 시스템 모델

본 논문에서는 간단한 SISO 브로드캐스트 채널을 고려한다. 송신단은 사용자들에게 전송할 데이터 신호를 중첩하여  $K$ 명의 사용자에게 전송하며, 모든 사용자로부터 채널 정보를 완벽하게 얻는다고 가정한다. 이와 같은 경우  $k$ 번째 사용자가 수신하는 신호는 다음과 같이 표현된다.

$$y_k = h_k \sum_{i=1}^K s_i + n_k, \quad (1)$$

여기서  $h_k \in C^{1 \times 1}$ 는 송신단으로부터  $k$ 번째 사용자까지의 채널,  $n_k \in C^{1 \times 1}$ 는 평균이 0 분산이  $\sigma^2$ 인 백색 가우시안 노이즈, 그리고  $s_i \in C^{1 \times 1}$ 는 송신단이  $i$ 번째 사용자에게 보내는 데이터 심볼로  $E[|s_i|^2] \leq P_i$ 를 만족한다. 이때  $k$ 번째 사용자가 얻는 데이터 전송률은 다음과 같이 주어진다.

$$R_k = \log_2(1 + \text{SINR}(P_k)), \quad (2)$$

여기서  $\text{SINR}(P_k)$ 는  $k$ 번째 사용자의 신호 대 간섭-잡음 비(SINR: Signal to interference-plus-noise ratio) 함수로 다음과 같이 정의한다<sup>6)</sup>.

$$\text{SINR}(P_k) := \frac{|h_k|^2 P_k}{|h_k|^2 (P_{\max} - P_k) + \sigma^2}. \quad (3)$$

최대 전송 전력이  $P_{\max}$  일 때,  $K$ 명의 사용자 중 QoS가 가장 낮은 사용자의 전송률을 최대화하는 최선의 전력 할당 벡터  $\mathbf{P} = [P_1, \dots, P_K]$ 는 다음과 같이 얻을 수 있다<sup>6)</sup>.

$$\max_{\mathbf{P}} \min_{1 \leq k \leq K} R_k \quad \text{s.t.} \quad \sum_{k=1}^K P_k = P_{\max}. \quad (4)$$

## III. 여러가지 전력 할당 기법

식 (4)의 최적해는  $\text{SINR}(P_1) = \text{SINR}(P_2) = \dots = \text{SINR}(P_K) = \gamma$  일 때,  $\sum_{k=1}^K P_k = P_{\max}$ 가 만족될 때까지  $\gamma$ 를 증가시키는 반복적 알고리즘을 통해 구할 수 있다<sup>6)</sup>. 그러나 이는 반복적인 높은 연산량이 요구되기 때

문에 실제 시스템에 적용하기 힘들다.

낮은 SNR 영역과 높은 SNR 영역에서는 식 (4)의 근사해를 구할 수 있다. 낮은 SNR 영역에서  $R_k$ 와 이를 이용한 근사해는 다음과 같이 얻어진다.

$$\lim_{P_{\max} \rightarrow 0} R_k \approx \frac{1}{\ln 2} \frac{|h_k|^2}{\sigma^2} P_k, \quad (5)$$

$$P_k = \frac{1/|h_k|^2}{\sum_{i=1}^K 1/|h_i|^2} P_{\max}, \quad k = 1, \dots, K.$$

한편 높은 SNR 영역에서  $R_k$ 와 이를 이용한 근사해는 다음과 같이 얻어진다.

$$\lim_{P_{\max} \rightarrow \infty} R_k \approx \log_2 \left( 1 + \frac{P_k}{P_{\max} - P_k} \right), \quad (6)$$

$$P_k = P_{\max} / K, \quad k = 1, \dots, K.$$

다른 전력 할당 기법으로는 식 (4)를 다음과 같이 변형하여 연산량을 줄일 수 있다.

$$\max_{\mathbf{P} \in S_N} \min_{1 \leq k \leq K} R_k \quad \text{s.t.} \quad \sum_{k=1}^K P_k = P_{\max} \quad (7)$$

여기서  $S_N$ 은  $\mathbf{P}$ 의 해집합으로 다음과 같이 정의한다.

$$S_N = \{ \mathbf{P} \mid P_1, \dots, P_K \in \{ \frac{0}{N-1} P_{\max}, \dots, \frac{N-1}{N-1} P_{\max} \} \}. \quad (8)$$

식 (7)의 최적해는 식 (4)의 부분최적해(suboptimal solution)가 되며,  $N \rightarrow \infty$  일 때, 최적해가 된다. 본 연구에서는 이 방식을  $N$ -level 전력 할당 기법이라 칭하며, 사용자가 3명일 경우에는  $N(N+1)/2$  가지 해 중 하나를 선택하기 때문에 비교적 간단하지만,  $N$ 과 사용자 수가 큰 경우에는 실제 시스템에 적용하기 어렵다.

## IV. 제안하는 기계학습 기반 전력 할당 기법

본 연구에서는 식 (7)의 연산량을 줄이기 위해 기계학습을 이용한다. 그림 1은 사용자가 3명일 때 기계학습 모델의 구조를 나타낸 것이다. 기계학습 모델은 최대 전력( $P_{\max}$ )과 채널 이득( $|h_1|^2, \dots, |h_K|^2$ )이 입력으

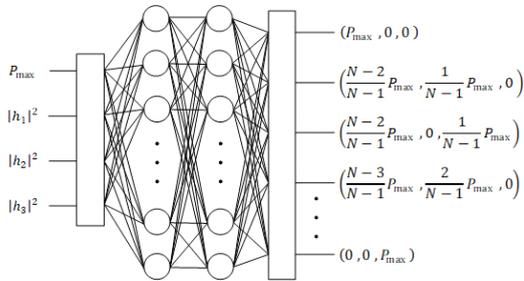


그림 1. 사용자가 3명일 때, 기계학습 모델 구조  
Fig. 1. Machine learning model structure in 3-user case

로 주어졌을 때 식 (7)의  $N(N+1)/2$  가지 해 중 하나를 선택한다.  $N$ -level 전력 할당 기법은 최선의 전력 할당을 위해  $N(N+1)/2$  가지 전력 할당 방법에 대한 결과를 모두 비교해야 한다. 즉,  $O(N^2)$ 만큼의 전력 할당 비교가 필요하다. 반면, 기계학습 모델은  $O(N^2)$ 만큼의 곱셈 연산으로 결과를 얻을 수 있으며, 기계학습 모델의 구조적 특성으로 유한한 클럭수 후에 모든 연산이 완료된다.

심층 신경망(DNN: Deep neural network) 기반의 기계학습 모델은 각각 100개의 은닉노드를 가진 2개의 은닉층으로 구성된다. 활성화 함수로 ELU(exponential linear unit), 목적 함수로 cross entropy를 사용하고 (Adam)adaptive moment 알고리즘을 이용하여 기계학습 모델을 학습시킨다.

제안하는 기법의 성능 분석을 위해 MATLAB 환경에서 컴퓨터 시뮬레이션을 수행하였다. 사용자는 3명으로 설정하였고, 기계학습 모델은 Tensorflow 프레임워크를 이용하여 학습하였다. 성능 척도는 QoS가 가장

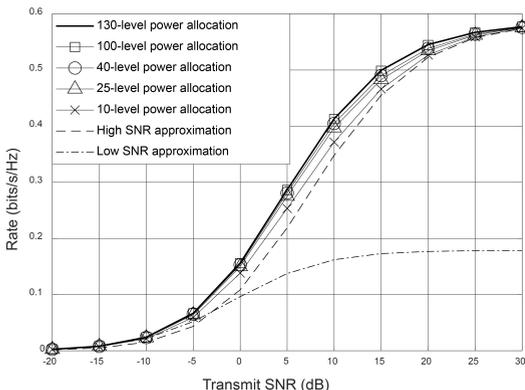


그림 2.  $N$ -level 전력 할당 기법, 낮은 SNR과 높은 SNR 영역에서 근사해의 성능  
Fig. 2. The performance of  $N$ -level power allocation, the approximation in low and high SNR

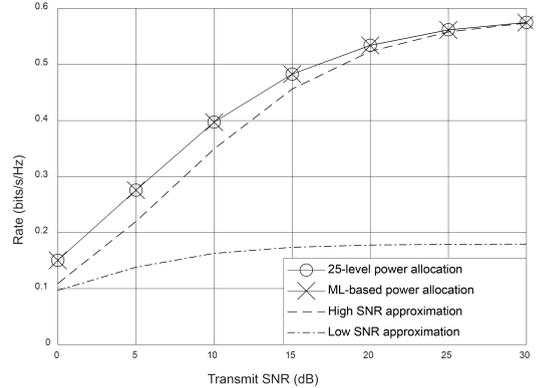


그림 3. 25-level 전력 할당 기법과 기계학습 기반 전력 할당 기법의 성능 비교  
Fig. 3. Comparison between 25-level power allocation and machine learning-based power allocation

낮은 사용자의 데이터 전송률이다. 그림 2는  $N$ -level 전력 할당 기법, 낮은 SNR과 높은 SNR 영역에서 근사해의 성능을 보여준다. 낮은 SNR과 높은 SNR 영역에서  $N$ -level 전력 할당 기법이 각각의 근사해와 동일한 성능을 가지는 것을 알 수 있다.  $N$ 이 증가할수록 성능이 향상되지만  $N=25$  이상부터는 성능에 큰 차이가 없다. 따라서 25-level 전력 할당 기법에 대하여 기계학습을 적용하였고, 그림 3에 그 성능을 나타내었다. 이 결과로부터 기계학습을 이용하여 25-level 전력 할당 기법과 동일한 성능을 얻을 수 있음을 확인할 수 있다.

### V. 결론

본 연구에서는 SISO 브로드캐스트 채널에서 QoS를 고려한 기계학습 기반 전력 할당 기법을 제안하였다. 성능 평가를 통해 기계학습을 이용하여 높은 복잡도를 가지는  $N$ -level 전력 할당 기법과 동일한 성능을 얻는 것을 확인하였다. 이러한 결과는 QoS를 고려한 전력 할당을 위한 기계학습의 다양한 응용 가능성을 보여준다. 다만 실제 시스템에서 기계학습을 활용하기 위해서는 보다 복잡한 시스템에서의 성능 분석이 요구된다. 따라서  $N$ 과 사용자 수에 따른 성능 분석, 기존 기법과의 연산량 비교 등 몇 가지 후속 연구가 필요하다.

### References

[1] P. Viswanath, D. N. C. Tse, and R. Laroia, "Opportunistic beamforming using dumb

- antennas,” *IEEE Trans. Inf. Theory*, vol. 48, no. 6, pp. 1277-1294, Jun. 2002.
- [2] A. Bayesteh, M. A. Sadrabadi, and A. K. Khandani, “Throughput and fairness maximization in wireless networks,” in *Proc. CWT*, pp. 168-171, Edmonton, Canada, Jun. 2007.
- [3] C. Wang, J. Chen, and Y. Chen, “Power allocation for a downlink non-orthogonal multiple access system,” *IEEE Wireless Commun. Lett.*, vol. 5, no. 5, pp. 532-535, Oct. 2016.
- [4] H. Huang, S. Guo, G. Gui, Z. Yang, J. Zhang, H. Sari, and F. Adachi “Deep learning for physical-layer 5G wireless techniques: Opportunities, challenges and solutions,” *IEEE Wireless Commun.*, vol. 27, no. 1, pp. 214-222, Feb. 2020.
- [5] H. J. Kwon, J. H. Lee, and W. Choi, “Machine learning-based beamforming in two-user MISO interference channels,” *J. KICS*, vol. 44, no. 3, pp. 461-469, Mar. 2019.
- [6] W. Yang and G. Xu, “Optimal downlink power assignment for smart antenna systems,” in *Proc. IEEE ICASSP*, pp. 3337-3340, Seattle, USA, May 1998.