

NOMA 시스템에서 SINR 정보 피드백을 이용한 딥러닝 기반 송신 전력 제어의 성능 분석

김동현¹ · 이인호^{2*}

Performance Analysis of Deep Learning Based Transmit Power Control Using SINR Information Feedback in NOMA Systems

Donghyeon Kim¹ · In-Ho Lee^{2*}

¹Graduate Student, School of Electronic and Electrical Engineering, Hankyong National University, Anseong, 17579 Korea

^{2*}Professor, School of Electronic and Electrical Engineering, Hankyong National University, Anseong, 17579 Korea

요약

본 논문에서는 하향링크 비직교 다중 접속 시스템에서 최소 데이터 전송률을 만족하며 데이터 전송률의 총합을 최대화할 수 있는 딥러닝 기반의 송신 전력 제어 기법을 제안한다. 하향링크 비직교 다중 접속 시스템에서 사용자가 위치한 셀 이외의 기지국으로부터 발생할 수 있는 동일 채널 간섭을 고려하고, 시스템 피드백 오버헤드를 줄이기 위하여 사용자는 채널 상태 정보 대신에 신호 대 간섭 및 잡음비 정보를 피드백 한다. 따라서 기지국은 신호 대 간섭 및 잡음비 정보만을 이용하여 송신 전력을 제어한다. 함축적 신호 대 간섭 및 잡음비 정보의 이용은 정보 차원을 감소시키는 장점은 있지만 데이터 전송률을 감소시킬 수 있는 단점이 있다. 본 논문에서는 딥러닝 기반의 학습 방식으로 이 문제를 해결하고, 딥러닝 입력의 차원을 효과적으로 축소할 경우 학습의 성능을 향상시킬 수 있음을 보여준다. 시뮬레이션을 통해서 제안된 딥러닝 기반의 송신 전력 제어 기법이 최소 데이터 전송률을 만족하며 데이터 전송률의 총합을 향상시킬 수 있음을 입증한다.

ABSTRACT

In this paper, we propose a deep learning-based transmit power control scheme to maximize the sum-rates while satisfying the minimum data-rate in downlink non-orthogonal multiple access (NOMA) systems. In downlink NOMA, we consider the co-channel interference that occurs from a base station other than the cell where the user is located, and the user feeds back the signal-to-interference plus noise power ratio (SINR) information instead of channel state information to reduce system feedback overhead. Therefore, the base station controls transmit power using only SINR information. The use of implicit SINR information has the advantage of decreasing the information dimension, but has disadvantage of reducing the data-rate. In this paper, we resolve this problem with deep learning-based training methods and show that the performance of training can be improved if the dimension of deep learning inputs is effectively reduced. Through simulation, we verify that the proposed deep learning-based power control scheme improves the sum-rate while satisfying the minimum data-rate.

키워드 : 딥러닝, 송신 전력 제어, 비직교 다중 접속, 채널 피드백

Keywords : Deep learning, Transmit power control, Non-orthogonal multiple access, Channel feedback

Received 11 March 2021, Revised 26 March 2021, Accepted 29 March 2021

* Corresponding Author In-Ho Lee (E-mail: ihlee@hknu.ac.kr, Tel:+82-31-670-5197)

Professor, School of Electronic and Electrical Engineering, Hankyong National University, Anseong, 17579 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.5.685>

print ISSN: 2234-4772 online ISSN: 2288-4165

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

최근 무선 통신 시스템에서 딥러닝을 통한 송신 전력 제어가 활발하게 이루어지고 있다[1-5]. [1]의 연구에서는 주파수 효율과 에너지 효율을 손실 함수로 사용해 각각의 성능 지표를 향상시키는 기법을 제안했다. 또한, [2]의 연구는 [1]의 연구에서 발생한 지역 최소화 문제를 [3]의 배치 정규화 기법을 통해서 성능을 개선했고, 주파수 효율과 데이터 전송률의 공정성을 동시에 향상시키는 기법을 제안했다. [4]의 연구에서는 단말 대 단말 시스템에서 주파수 효율을 향상시키는 동시에 셀룰러 사용자에게 발생시키는 간섭을 제한할 수 있는 딥러닝의 비지도 학습 기반 손실 함수를 제안했다. 또한 [5]의 연구는 하향링크 비직교 다중 접속 (Non-Orthogonal Multiple Access, NOMA) 시스템에서 각 사용자가 최소 데이터 전송률을 만족하면서 데이터 전송률의 합을 최대화하기 위해 [6]의 내부점법 기법을 딥러닝의 지도 학습 기반으로 학습한 기법을 제안했다. 표 1과 같이 NOMA는 시분할 다중 접속 (time division multiple access, TDMA), 주파수 분할 다중 접속 (frequency division multiple access, FDMA), 부호 분할 다중 접속 (code division multiple access, CDMA) 기법들과 다르게 전력 차원에서 다중 접속을 수행한다.

본 연구는 하향링크 NOMA 시스템에서 사용자가 위치한 셀 이외의 기지국이 동일 채널 간섭을 발생시키는 것을 고려하고, [5]의 연구와 같이 각 사용자의 최소 데이터 전송률이 있으며 데이터 전송률의 합을 최대화하는 기법을 제안한다. 또한, 딥러닝의 손실 함수는 [4]의 연구와 같이 설계해서 비지도 학습 기반으로 학습해서 지도 학습의 정답 데이터를 생성하는 과정을 생략이 가능하다. 그리고 사용자가 많아질수록 각 사용자들의 채널 상태 정보 (Channel State Information, CSI)를 피드백하는 시스템 오버헤드가 증가하는 문제를 신호 대 간섭 및 잡음비 (Signal to Interference and Noise Ratio, SINR) 정보를 피드백 하는 것으로 해결한다. 즉, 제안한 기법은 기지국이 모든 CSI가 아닌 함축적인 SINR 정보

Table. 1 Comparison of multiple access techniques

Multiple access	TDMA	FDMA	CDMA	NOMA
Division domain	Time	Frequency	Code	Power

만으로 송신 전력을 제어하는 것이 가능하다.

SINR과 같은 정보량 축소 데이터는 딥러닝 학습 시 데이터의 차원이 높을 때 사용된다. [7]의 연구에서는 딥러닝 기반의 얼굴 인식 학습 시 주 성분 분석 기법[8]을 통한 높은 차원을 갖는 데이터의 차원 축소로 높은 정확도의 얼굴 인식 성능을 보였다. 본 논문에서는 딥러닝의 입력을 사용자들의 CSI를 함축한 SINR 정보로 사용하며, 효과적으로 입력의 차원을 줄인 SINR 정보를 사용하여 딥러닝의 학습 성능을 향상시킬 수 있음을 보여준다.

II. 시스템 모델

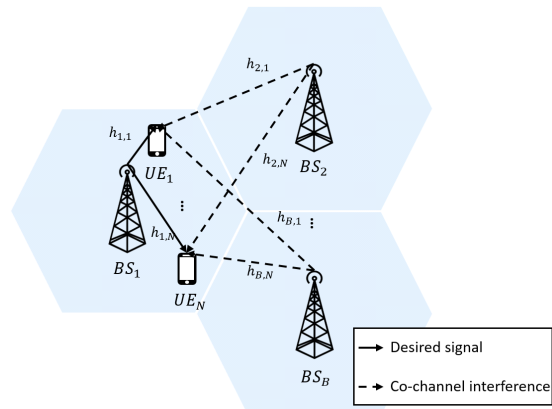


Fig. 1 System model for transmit power control.

본 연구에서는 그림 1과 같이 직경이 D 이고 B 개의 기지국과 N 명의 사용자가 있는 하향링크 NOMA 시스템에서 동일채널 간섭이 존재하는 환경을 고려한다. 여기서 기지국과 모든 단말기는 하나의 송수신 안테나를 이용한다. 하향링크 NOMA 시스템에서 각 단말기는 자신의 하향 링크 SINR 정보를 보고하며, 기지국은 보고된 SINR 정보를 기반으로 데이터 신호의 전력 할당 계수를 결정하고, 결정된 전력 계수가 적용된 데이터 신호를 합하여 전체 단말기로 전송한다. 여기서, 채널 추정 오차는 없다고 가정하고, 시간지연에 다른 채널 변화는 없다고 가정한다.

기지국과 사용자 사이의 채널은 경로 손실과 레일리 페이딩으로 구성되며 기지국 i 와 사용자 j 사이의 채널은 다음과 같이 표현된다.

$$h_{i,j} = |g_{i,j}|^2 d_{i,j}^{-\alpha}, \quad (1)$$

여기서, $g_{i,j}$ 는 평균이 0이고 분산이 1인 레일레이 채널의 복소 계수이며, α 와 $d_{i,j}$ 는 각각 경로 손실 지수와 기지국 i 와 사용자 j 사이의 거리이다. 그림 1과 같이 1번 기지국의 셀에 사용자들이 위치할 때, 사용자 j 는 식 (1)을 통한 기지국 1과 사용자 j 사이의 채널 그리고 동일 채널 간섭을 포함한 SINR 정보를 피드백하고 다음과 같이 표현된다.

$$SINR_j = \frac{h_{1,j} \rho_{\max}}{\sum_{k=2}^B h_{k,j} \rho_{\max} + 1}, \quad (2)$$

여기서, ρ_{\max} 는 기지국의 송신 신호 대 잡음 비 (Signal to Noise Ratio, SNR)이며 기지국의 송신 전력 P_{\max} 와 각 단말기의 잡음 전력 σ^2 으로 이뤄진다. 각 단말기의 잡음 전력은 같다고 가정하고, $\rho_{\max} = P_{\max}/\sigma^2$ 이다.

본 논문에서 고려하는 NOMA 전송의 단말기별 전력 할당을 위해 $SINR_1 > SINR_2 > \dots > SINR_N$ 을 가정한다. 하향링크 NOMA 시스템에서 기지국은 각 단말기의 데이터 신호에 상이한 전력 할당 계수를 적용한 후 합하여 전송한다. 여기서, 사용자 j 의 전력 할당 계수는 a_j 이며, $0 < a_j < 1$, $\sum_{j=1}^N a_j = 1$ 의 조건을 따른다. 또한, 각 단말기에서 중첩된 신호를 연속적인 간섭 제거 기법을 이용해서 자신의 신호를 획득할 때, $a_1 < a_2 < \dots < a_N$ 와 같은 전력 할당 계수의 조건을 만족해야 한다. 간섭 제거 기법에 의해 얻어진 사용자 j 의 데이터 전송률은 다음과 같이 얻을 수 있다.

$$R_j = \log_2 \left(1 + \frac{h_{1,j} a_j \rho_{\max}}{\sum_{k=1}^{j-1} h_{1,k} a_k \rho_{\max} + \sum_{k=2}^B h_{k,j} \rho_{\max} + 1} \right). \quad (3)$$

본 논문에서는 식 (3)을 통해서 얻어진 각 사용자의 데이터 전송률이 최소 데이터 전송률 R_{thr} 을 충족하면서 총 데이터 전송률을 최대화 하는 하향링크 NOMA 송신 전력 제어의 최적화 문제는 다음과 같이 표현된다.

$$\max \sum_{j=1}^N R_j, \quad (4)$$

$$\text{s.t. } \sum_{j=1}^N a_j = 1, \quad (5)$$

$$a_1 < a_2 < \dots < a_N, \quad (6)$$

$$R_j \geq R_{thr}, \quad (7)$$

여기서, 식 (7)의 제약조건 $R_j \geq R_{thr}$ 을 사용자 j 가 만족하지 못해 아웃티지가 발생할 경우 $R_j = 0$ 이 된다.

III. 심층신경망 구조 및 학습과정




Fig. 2 Proposed DNN model.

본 연구는 그림 2와 같은 심층 신경망 (deep neural network, DNN)을 기반으로 송신 전력을 도출한다. 신경망의 입력은 각 단말로부터 보고받은 식 (2) 기반의 SINR 정보를 dB 단위로 변화 후 정규화 한 것을 사용하고 다음과 같다.

$$\widehat{SINR}_j = \frac{\log_{10} SINR_j - E[\log_{10} SINR_j]}{\sqrt{E[(\log_{10} SINR_j - E[\log_{10} SINR_j])^2]}}, \quad (8)$$

그 이후, 각 층에서 $F(X) = WX + b$ 연산을 수행한다. 여기서, W 와 b 는 각 층의 가중치와 기준값이다. 이때 각각의 층은 512개의 출력을 갖고, 배치 정규화 [3] 과정을 수행하고, 활성화 함수는 rectified linear unit (ReLU) 함수를 사용한다. 여기서, 배치 정규화는 각각 배치 데이터의 평균과 표준편차를 통해서 각 층마다 정규화 과정을 수행하는 과정이며, ReLU는 각 층의 음의 값을 제한하여 심층 신경망에 비선형성을 제공하는 것이 가능하다. 각각의 신경망은 가중치 연산과 ReLU 및 배치 정규화를 수행하고 마지막 4번째 층의 출력은 제안한 송신 전력과 동일한 N 개가 되도록 가중치를 설정한다.

4번째 층의 연산이 끝난 이후 Softmax 연산을 수행하고 다음과 같다.

$$Y_j = \frac{e^{X_j}}{\sum_{k=1}^N e^{X_k}}, \quad (9)$$

여기서, X_j 는 4번째 층의 j 번째 출력이며 Softmax 함수의 특성상 $\sum_{j=1}^N Y_j = 1$ 을 만족한다. 즉, 식 (5)의 첫 번째 제약조건을 충족하고, 두 번째 제약조건을 만족하기 위해 Y_j 원소들의 벡터 \mathbf{Y} 를 오름차순으로 정렬하고, 정렬된 출력은 제한된 전력 할당 계수의 벡터 \mathbf{a} 이다. 그러므로, 제한된 DNN 구조는 SINR 정보를 기반으로 해서 전력 할당 계수를 도출하는 것이 가능하다.

식 (8)과 (9)를 기반으로 얻어진 \mathbf{a} 를 통해서 식 (3)의 데이터 전송률을 도출하는 것이 가능하다. 본 논문은 주어진 심층신경망에서 Adam 최적화 방안을 통해서 학습을 진행한다 [9]. Adam 최적화 방안은 딥러닝의 손실 함수를 감소시키는 방향으로 학습을 진행하고, 식 (4)부터 (7) 까지의 최적화 문제를 해결하기 위한 손실 함수 L 은 다음과 같다.

$$L = \sum_{j=1}^N (-\lambda R_j + \tanh([R_{thr} - R_j]^+)), \quad (10)$$

여기서, $[\cdot]^+$ 는 음의값을 제한하는 ReLU 함수를 의미하고, \tanh 함수는 $\tanh(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$ 연산을 수행하고, λ 는 가중치이며 사용자들의 아웃티지를 감소시키는 것과 데이터 전송률의 총합을 향상시키는 것의 비중을 결정할 수 있다. 본 논문에서는 아웃티지 확률을 최소화 한 상태에서 데이터 전송률을 최대화 하는 송신 전력 제어 기법을 제안하므로 이 조건을 만족하는 최적의 λ 를 통해서 송신 전력을 제어한다.

식 (10) 기반의 딥러닝 학습과정은 오프라인에서 진행되며 그림 3에서 자세히 설명된다. 제한된 송신 전력은 SINR 정보로부터 계산이 되며, 함축적인 피드백 정보 때문에 데이터 전송률의 손실을 발생시킬 수 있다. 본 논문에서는 오프라인에서 모든 CSI를 수집할 수 있다고 가정하고 딥러닝의 학습 방식으로 이 문제를 해결한다. 딥러닝의 학습은 각 층의 W 와 b 가 손실 함수를 통

해서 학습이 되며, 학습이 수렴되면 W 와 b 는 고정되며 손실 함수는 사용이 안 된다. 이 점을 이용해서 오프라인에서 손실 함수에 사용되는 데이터 전송률은 식 (3)과 같이 모든 CSI를 기반으로 사용해 데이터 전송률의 감소를 없도록 학습한다. 이와 같은 학습방식은 실질적인 통신 시스템에서 모든 CSI가 없이 SINR 정보만으로 높은 성능의 송신 전력 제어가 가능하다.

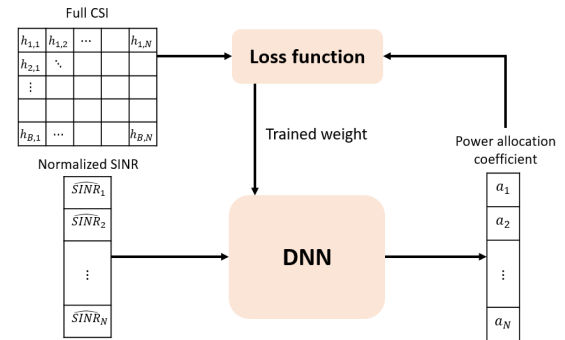


Fig. 3 Proposed training process.

IV. 수치적 결과

본 장에서는 제안한 딥러닝 기반의 송신 전력 제어 기법의 성능을 분석한다. 여기서, D 는 40이고 α 는 3이며 ρ_{max} 는 45dBm이고. 학습 데이터 및 테스트 데이터는 각각 100000, 10000개를 각각 생성하고, 배치 데이터 및 학습률은 각각 10000, 0.0001 이다. 여기서, 학습 데이터 및 테스트 데이터는 식 (1)의 채널을 이용하고, 학습 데이터와 테스트 데이터는 독립적이고, 시뮬레이션은 테스트 데이터를 통해서 보여준다. 또한, 시뮬레이션을 통해 아웃티지 확률을 최적화 하면서 데이터 전송률을 최대화 할 수 있는 최적의 λ 가 0.001인 것을 찾아냈다.

제한된 SINR 피드백 기법 (SINR feedback)과 성능을 비교하기 위해서 모든 채널을 피드백한 기법 (Full CSI feedback) 과 입력 차원이 동일한 기법인 간섭을 제외한 사용자 본인의 신호만 피드백한 기법 (Desired CSI feedback) 들을 통해서 성능을 분석한다. 그림 4와 5는 각각 $B=2$ 이며 $R_{thr}=0.1$ 일 때 사용자의 수에 따른 데이터 전송률의 총합과 아웃티지 확률의 성능 비교이다. SINR feedback 기법이 다른 기법에 비해서 데이터 전송

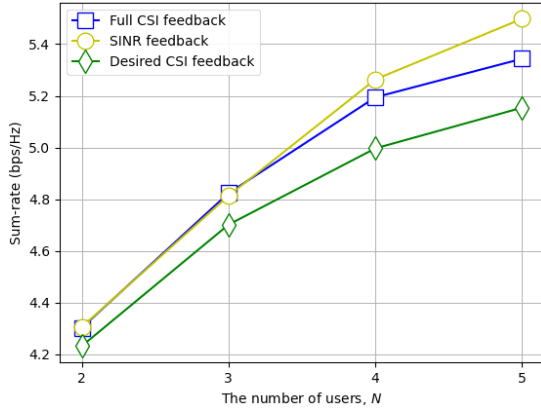


Fig. 4 Sum-rate of deep learning schemes with B=2.

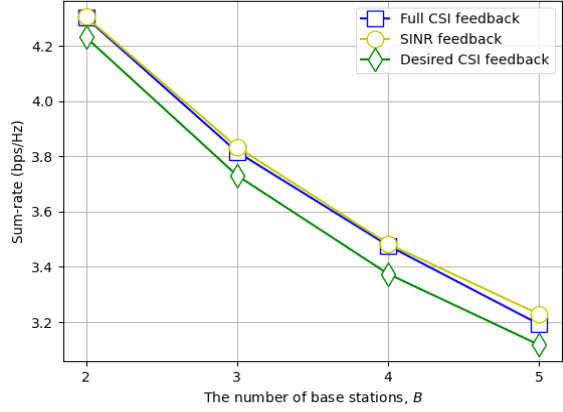


Fig. 6 Sum-rate of deep learning schemes with N=2.

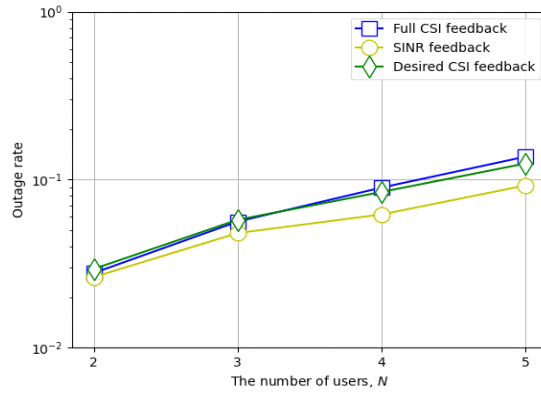


Fig. 5 Outage rate of deep learning schemes with B=2.

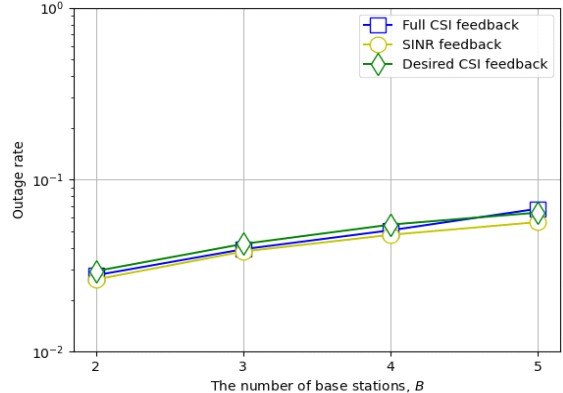


Fig. 7 Outage rate of deep learning schemes with N=2.

률의 성능은 가장 높으며 아웃티지 확률은 가장 낮은 것을 확인할 수 있다.

그림 6과 7은 $N=2$ 이며 $R_{thr}=0.1$ 일 때 기지국 수에 따른 데이터 전송률의 총합과 아웃티지 확률의 성능의 비교이며, 그림 8과 9는 $N=3, B=3$ 일 때 R_{thr} 값 변화에 따른 데이터 전송률의 총합과 아웃티지 확률의 성능의 비교이다. 각각 그림들을 통해서 SINR feedback 기법이 가장 우수한 성능을 제공하는 것을 알 수 있다. 여기서, Full CSI feedback 기법은 딥러닝의 입력 차원이 높아 계산의 복잡성이 증가되고, Desired CSI feedback 기법은 정보량의 부족 때문에 SINR feedback 기법에 비해서 성능이 떨어진다. 각 그림들을 통해서 제안된 SINR feedback 기법이 효과적으로 차원을 축소하며 학습 성능을 향상시킬 수 있음을 보여준다.

V. 결론

본 연구에서는 하향링크 NOMA 시스템에서 SINR 정보를 이용해 피드백 주파수 자원의 효율을 향상한 딥러닝 기반 송신 전력 제어 기법을 제안했다. 제안된 기법은 아웃티지 확률을 최소화 하고 데이터 전송률의 총합은 최대화하는 딥러닝의 손실 함수를 통해서 학습을 했다. 학습 모델은 SINR 정보를 입력으로 받으며 손실 함수에서는 모든 CSI 정보를 얻을 수 있다고 가정하여 학습을 진행하고 함축된 채널 정보만으로 우수한 성능을 제공할 수 있다. 또한 딥러닝의 입력 차원의 감소는 학습의 성능을 향상시킬 수 있으며, 시뮬레이션을 통해서 모든 채널을 피드백 하는 기법과 간섭을 제외한 사용자 본인의 신호만 피드백한 기법들과의 비교를 통해서 제안된 기법이 가장 우수한 성능을 제공함을 보여준다.

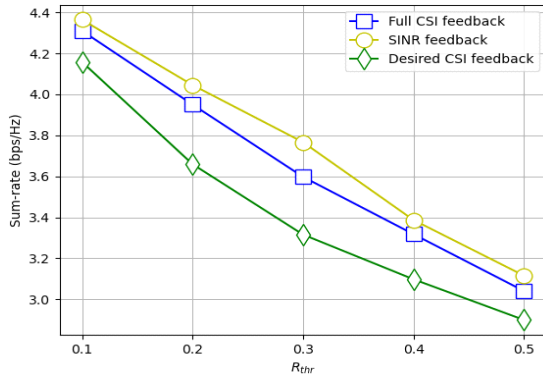


Fig. 8 Sum-rate of deep learning schemes with N=3, B=3.

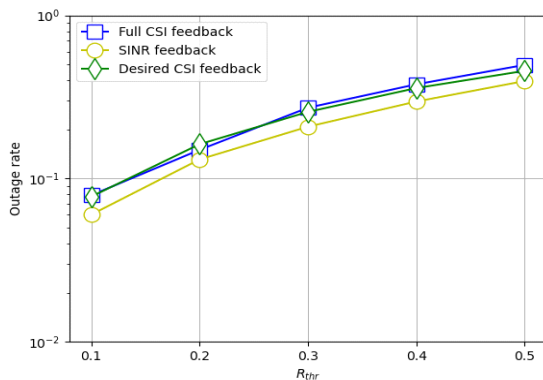


Fig. 9 Outage rate of deep learning schemes with N=3, B=3.

ACKNOWLEDGEMENT

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education (Grant number: NRF-2018R1D1A1B 07042499).

References

[1] W. Lee, M. Kim, and D. Cho, "Deep power control: transmit power control scheme based on convolutional neural network," *IEEE Communications Letters*, vol. 22, no. 6, pp. 1276-1279, Jun. 2018.

[2] D. Kim and I. H. Lee, "Deep learning-based power control scheme for perfect fairness in device-to-device communication

systems," *Electronics*, vol. 9, no. 10, pp. 1606, Oct. 2020.

[3] S. Ioffe and C. Szegedy, "Batch normalization: accelerating deep network training by reducing internal covariate shift," *Proceedings of the 32nd International Conference on Machine Learning*, Lille: France, pp. 448-456, 2015.

[4] W. Lee, M. Kim, and D. Cho, "Transmit power control using deep neural network for underlay device-to-device communication," *IEEE Wireless Communication Letters*, vol. 8, no. 1, pp. 141-144, Feb. 2019.

[5] N. Yang, H. Zhang, K. Long, H. Hsieh, and J. Liu, "Deep neural network for resource management in NOMA networks," *IEEE Transactions Vehicular Technology*, vol. 69, no. 1, pp. 876-886, Jan. 2020.

[6] W. Lu, M. Liu, S. Lin, and L. Li, "Fully decentralized optimal power flow of multi-area interconnected power systems based on distributed interior point method," *IEEE Transactions Power Systems*, vol. 33, no. 1, pp. 901-910, Jan. 2018.

[7] L. Tian, C. Fan, Y. Ming, and Y. Jin, "Stacked PCA Network (SPCANet): An effective deep learning for face recognition," *Proceedings of the IEEE International Conference on Digital Signal Processing*, Singapore, pp. 1039-1043, 2015.


[8] J. Shlens. (2014) "A tutorial on principal component analysis," [Internet]. Available: <https://arxiv.org/abs/1404.1100>.

[9] D. P. Kingma and J. Ba. (2014) "Adam: A method for stochastic optimization," [Internet]. Available: <https://arxiv.org/abs/1412.6980>.



김동현(Donghyeon Kim)

2020년 2월 : 국립한경대학교 전자전자공학학과 학사
 2020년 3월 ~ 현재 : 국립한경대학교 전자전자공학부 석사과정
 ※관심분야: 무선 통신 시스템, 딥러닝, 송신 전력 제어



이인호(In-Ho Lee)

2003년 2월 : 한양대학교 전자컴퓨터공학부 학사
 2005년 2월 : 한양대학교 전자전자계측공학과 공학석사
 2008년 8월 : 한양대학교 전자전자계측공학과 공학박사
 2008년 9월 ~ 2010년 4월 : 삼성전자 DMC 연구소 책임연구원
 2010년 4월 ~ 2011년 3월 : 한양대학교 ERICA 부설연구소 공학기술연구소 박사후과정
 2011년 3월 ~ 현재 : 국립한경대학교 전자전자공학부 교수
 ※관심분야: 무선 협력 통신 시스템, MIMO 전송 기술, 무선자원관리 기술, 비구조적 다중 접속 기술