

기계학습 기반 다중셀 네트워크 역방향 성능 근사화

권진우*, 권태수^o

Uplink Performance Approximation of Multicell Networks Based on Machine Learning

Jinwoo Kwon*, Taesoo Kwon^o

요약

역방향 다중셀 네트워크에서 FPC(Fractional Power Control)는 역방향 동작의 핵심 특징이며, 역방향 시스템 레벨 성능 분석을 위해 FPC 동작이 기지국 밀도, 무선채널과 함께 고려되어야 한다. 따라서, 본 논문은 역방향 SINR 분포를 신속히 제공할 수 있는 기계학습 기반 성능 분석 방안을 제안한다. 또한, 제안 방안은 사용자 경험 SINR 값을 손쉽게 도출하기 위해 사용될 수 있고, 시뮬레이션 결과는 제안 방안의 정확도를 입증한다.

Key Words : Uplink SINR, system level performance, power control, machine learning

ABSTRACT

In uplink multicell networks, the fractional power control (FPC) is a key feature of uplink operations and the FPC operation has to be considered in conjunction with the base station distribution and wireless channel for the uplink system level performance evaluation. Hence, this paper proposes the machine learning based performance evaluation method that can quickly provide the uplink SINR distribution. Also, the proposed method can be used

for readily deriving the user experience SINR value and the simulation results demonstrate their accuracy.

I. 서론

최근 5G 이동통신의 구축과 함께, 다중셀 네트워크의 체계적 성능 분석이 더욱 중요해 지고 있다. 기존 성능 분석은 주로 시스템 레벨 시뮬레이션에 기반되고^[1], 이러한 방식은 다양한 환경의 고려가 가능하지만 동작변수들이 성능에 미치는 영향을 일반화하기 어렵고 구현이 복잡하며 긴 시뮬레이션 시간을 필요로 한다. 한편, 확률기하이론에 기반한 다중셀 네트워크의 수학적 성능 분석 연구가^[2] 활발해지면서 동작변수 영향의 정량적 분석이 더욱 용이해졌지만, 여전히 비교적 단순한 네트워크 환경에 한해서만 유용한 수학적 표현이 가능하다.

최근 이러한 기존 성능 분석 방식의 한계를 극복하기 위해 [3]-[4]에서는 기계학습을 활용한 순방향 네트워크 성능 분석 방안을 제안하였지만, 역방향 다중셀 네트워크는, 단말들의 서빙(serving) 기지국 선택에 따른 송신 단말 위치간 상호 연관성과 역방향 송신전력 제어의 적용으로 인해 순방향 다중셀 대비 성능 분석이 더욱 복잡해지고^[2], 또한 기계학습을 적용한 성능 분석이 지금까지 역방향 네트워크에는 적용되지 않았다. 따라서 본 논문은 [3]과 같이, Sigmoid-like 함수 기반 Curve-fitting을 통해 확보한 데이터셋을 활용하여 인공신경망(ANN, Artificial Neural Network)을 학습시켜 SINR(Signal to Interference plus noise ratio) 확률분포를 근사화하고, 역방향 송신전력제어 지수에 따른 사용자 경험 SINR 값을 도출할 수 있는 응용방안을 함께 제안한다.

II. 시스템 및 성능 모델

그림 1은 단말과 기지국 간 경로감쇄를 보정하는 역방향 송신전력제어를 적용하고 있는 역방향 다중셀 네트워크 모델을 보여준다. 단위면적당 평균 λ 개의 기지국들이 균일 프이송점과정(HPPP, Homogeneous Poisson Point Process) 혹은 육각셀 형태로 분포하며,

* 본 연구는 서울과학기술대학교 교내연구비의 지원으로 수행되었습니다.

• First Author : (ORCID:0000-0003-3626-0501)Seoul National Univ. of Science and Technology, Dept. of CSE, wlsdn110@seoultech.ac.kr, 학생(학사과정), 학생회원

o Corresponding Author : (ORCID:0000-0002-6624-4863)Seoul National Univ. of Science and Technology, Dept. of CSE, tskwon@seoultech.ac.kr, 부교수, 종신회원

논문번호:202008-187-A-LU, Received August 6, 2020; Revised September 9, 2020; Accepted September 10, 2020

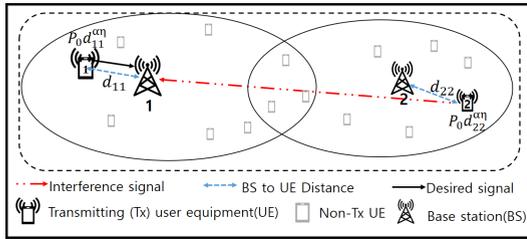


그림 1. 역방향 다중셀 네트워크 모델
Fig. 1. Uplink multicell network model

단말은 HPPP에 따라 분포한다고 가정한다. 단말과 기지국 모두 단말 안테나를 사용한다. 단말은 가장 가까운 기지국으로부터 서비스를 받고, 라운드로빈(Round Robin) 스케줄링에 의해 기지국별 역방향 송신 단말이 결정된다. 따라서 송신 단말간 위치분포는 항상 상호 연관된다(correlated).

d_{xy} 를 x 번 기지국과 y 번 단말의 거리, A 를 단위 거리에서의 경로감쇄이득, α 를 경로감쇄지수라 할 때, 역방향 신호는 $Ad_{xy}^{-\alpha}$ 의 경로감쇄 이득과 평균 1의 Rayleigh 페이딩 이득 g 를 겪고, 음영효과는 고려되지 않는다. 각 단말 송신전력 P 는, 기준 송신전력 P_0 와 최대송신전력 P_{max} 에 대해, $P = \min(P_{max}, P_0 \times d_{xy}^{-\eta})$ 의 FPC(Fractional Power Control) 방식에 의해 결정된다. FPC 동작변수 $0 \leq \eta \leq 1$ 는 경로감쇄를 얼마나 보정할지 결정한다.

따라서, 기지국의 역방향 수신 SINR은 $\frac{Agd_{xy}^{-\alpha}P}{\sigma^2 + I}$ 로 표현된다. 이 때, I 는 모든 간섭의 합을 나타낸다. 또한, Sigmoid-like 함수에 의해 순방향 SINR cdf (complementary cumulative distribution)가 잘 표현된다는 [3]의 결과에 착안하여, τ_{dB} 를 dB 단위의 SINR이라 할 때, 본 연구에서도 역방향 SINR cdf를 다음과 같이 근사화한다.

$$\Pr \{SINR > \tau_{dB}\} \approx \frac{1}{1 + \exp(-\beta_2 \tau_{dB}^2 - \beta_1 \tau_{dB} - \beta_0)} \quad (1)$$

이 때, $\beta \triangleq (\beta_0, \beta_1, \beta_2)$ 는 SINR cdf를 (1)과 같이 표현하기 위한 매개변수로서, (1)의 수학적식과 시뮬레이션 결과의 비선형 최소자승법(Non-linear least square) 기반 Curve-fitting을 통해 그 값을 얻을 수 있다. (1)의 수학적식에서 (β_0, β_1) , 즉 2개의 매개변수만을 사용하는 경우, 그림 2의 PPP 환경에서 τ_{dB} 값이

-14dB일 때 $\Pr \{SINR > \tau_{dB}\}$ 을 시뮬레이션을 통해 구한 값과 Curve-fitting을 통해 도출한 값이 약 2%의 차이가 발생하였다. 반면 $(\beta_0, \beta_1, \beta_2)$ 모두, 즉 3개의 매개변수를 사용하는 경우 1% 이하의 차이가 관찰되었고, 그 이상으로 매개변수개수를 증가시키더라도 그 오차가 유의미하게 감소하지는 않았다. 따라서, 빠른 인공지능망의 학습을 위해 3개의 매개변수로 구성된 β 를 사용하는 (1)의 수학적식을 활용하였다. 수학적식 (1)을 이용한 근사화는 IV장에서 그 정확도가 검증될 것이다. 다음 장에서는 이러한 속성을 이용해 $\alpha, \lambda, \eta, P_0$ 와 같은 FPC 적용 역방향 환경변수와 수학적식 (1)의 β 간의 관계를 지도학습을 통해 학습시키는 방안을 제안한다.

III. 인공지능망 구성 및 데이터셋

본 장에서는 α, λ, η 및 P_0 의 값을 입력으로 하여 β 를 도출하기 위한 ANN을 구성한다. 이러한 ANN을 이용하여 역방향 환경변수로부터 SINR cdf를 수학적식 (1)의 형태로 손쉽게 표현할 수 있다. ANN은 7개 hidden layer로 구성되고 각각은 16개, 16개, 8개, 8개, 8개, 3개 및 2개의 뉴런으로 이루어진다. 활성화함수는 Leaky ReLu를 이용하고, 비용함수는 $\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$ 의 MSE(Mean Squared Error)를 사용한다. n 은 전체 학습 데이터의 수, y_i 는 Curve-fitting을 통해서 얻어낸 β 의 값, \hat{y}_i 값은 ANN을 통해 도출한 β 의 값을 나타낸다. 표 1의 네트워크 환경에서 ANN이 학습되며, HPPP와 육각셀 모델 각각 데이터셋 12474개를 시뮬레이션과 수학적식 (1)에 기반한 Curve-fitting을 통해 확보하였다. 데이터셋의 80%는

표 1. 역방향 다중셀 네트워크 환경
Table 1. Uplink Multicell Network Environments

Notation, Description	변수범위
λ : Base station density	[0.2:0.1:1] km ²
α : Path loss exponent	[2:0.2:6]
η : FPC operation parameter	[0:0.1:1]
P_0 : Reference transmit power	[13:2:23] dBm
P_{max} : Maximum transmit power	23 dBm
B : Bandwidth	0.125 Mhz
σ^2/B : Noise power per hertz	-174 dBm/Hz
A : Path loss at a unit distance ^[5]	-141.33dB

학습 데이터로, 20%는 테스트셋으로 사용한다. 구성된 인공신경망은 도출된 $\beta_1, \beta_2, \beta_3$ 에 대해 각각 약 $2 \times 10^{-7}, 4 \times 10^{-5}, 3 \times 10^{-3}$ 의 MSE가 관찰되었다. 이와 같이 학습된 역방향 환경변수 간의 관계를 통해 역방향 SINR 분포를 신속히 도출할 수 있다. 한편, 구성된 인공신경망의 hidden layer 및 뉴런 개수의 영향을 살펴보기 위해 5개와 7개의 hidden layer에 대해 MSE를 관찰한 결과, 5개 대비 7개는 약 1/10 수준의 MSE 감소가, 7개 대비 9개는 약 1/2 수준의 MSE 감소를 관찰할 수 있었다. 또한 7개의 경우 이미 10^{-3} 수준의 MSE를 제공하므로, 본 논문은 7개의 hidden layer를 사용하여 결과를 도출한다.

이와 같이 학습된 역방향 환경변수와 β 간의 관계를 통해 역방향 SINR 분포를 신속히 도출할 수 있다. 이는 환경별 별도의 시뮬레이션을 수행하는 기존 시뮬레이션 기반 방식 대비 분석 시간을 크게 줄일 수 있고, 시뮬레이션과 Curve-fitting 후 Look-up table¹⁾만을 기반으로 SINR분포를 도출하고자 하는 경우에 대해서도 학습되지 않은 환경에서 SINR분포를 예측하거나 입력변수의 수가 증가할 경우 ANN 기반 방식이 보다 낮은 복잡도로 동작할 것으로 기대된다.

IV. 성능 평가 및 응용

성능평가는 표 1의 환경에서 수행된다. 표 1에서, [a:b:c]는 a에서 c까지 b씩 증가시킴을 의미한다.

그림 2는 역방향 다중셀 시뮬레이션 결과와 제안된 ANN 학습 결과가 거의 일치함을 보여준다. ANN 성능은 $R^2 \triangleq 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$ 와 같은 R-square 값을 통해 평가될 수 있는데, \bar{y} 값은 Curve-fitting을 통해 얻은 β 값들의 평균값이며, 값이 1에 가까울수록 높은 신뢰도를 나타낸다. 이때, 0.98 이상의 R-square 성능이 관찰되었고, 이를 통해 제안한 기계학습 기반 역방향 성능 근사화의 효용성을 확인할 수 있었다. 한편, 제안한 기계학습 기반 역방향 성능 분석 방안은 하위 25% 사용자 SINR 성능과 같은 특정 순위 사용자 성능을 손쉽게 도출하기 위해 응용가능하다. 즉, 역방향 다중셀 네트워크 환경이 $(\lambda, \alpha, \eta, P_0)$ 로 주어질 때, III장에서 구성한 ANN을

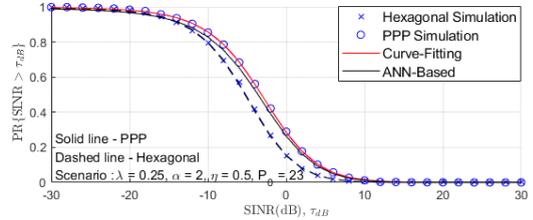


그림 2. 기계학습을 적용한 다중셀 역방향 네트워크 성능
Fig. 2. Multi-cell Uplink Network Performance Using Machine Learning

통해 해당 환경에서 수학적 (1)로 표현되는 SINR 분포의 β 값을 신속히 도출할 수 있다. β 값을 알고 있다면, $\varphi \triangleq \Pr\{SINR > \tau_{dB}\}$ 일 때, 예를 들어 하위 25% 사용자 SINR 성능은 $\varphi = 0.25$ 와 수학적 (2)로부터 다음과 같이 표현될 수 있다.

$$\tau_{dB} = \frac{-\beta_1 \pm \sqrt{\beta_1^2 - 4\beta_2(\beta_0 + 1/\log \varphi)}}{2\beta_2} \quad (2)$$

그림 3은 기지국이 HPPP 및 육각셀에 따라 배치될 때, III장에서 구성된 ANN과 수학적 (2)를 이용하여 도출된 FPC 동작변수에 따른 하위 25%와 75% 사용자의 SINR 성능을 보여준다. 해당 성능은 테스트셋 시나리오 중 하나인 $\alpha = 5.3, \lambda = 0.45, P_0 = 23$ 을 고려하였다. 이 결과에서, 제안 방안에서 도출된 사용자 SINR 성능이 시뮬레이션 기반의 성능과 거의 일치함을 확인할 수 있다. 또한, 기지국 배치에 따라 특정 순위 사용자 성능을 최대화할 수 있는 최적 η 값이 달라짐을 보이고 있다. 예를 들어, HPPP와 육각셀 배치에 대해 η 가 약 0.5와 0.2일 때 각각 하위 25% 사용자 성능이 최대가 된다.

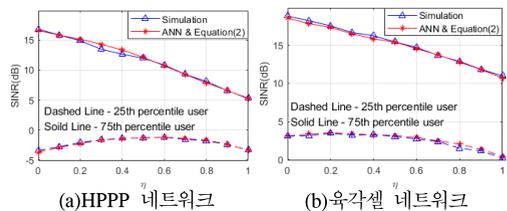


그림 3. FPC 동작변수에 따른 사용자들의 SINR 성능
Fig. 3. SINR Performance according to FPC operation parameter

1) [6]에서 Tic-Tac-Toe게임을 1000게임 동안 원하는 결과를 얻기 위해서 ANN과 Look-Up table을 이용한 방식을 비교하였는데, ANN을 이용한 방식은 108초가 걸리는 반면 Look-Up table을 이용한 방식은 262초가 소요되었다.

V. 결 론

본 논문은 기지국 분포, 경로감쇄지수, FPC 동작변수에 따른 역방향 SINR 확률분포를 Sigmoid-like 함수 형태로 표현하고 기계학습을 통해 SINR 확률분포를 신속히 도출하는 방안을 제안하였다. 또한, 제안 방안이 하위 $x\%$ 사용자 SINR 값을 손쉽게 표현하기 위해 응용될 수 있음을 보였다. 향후, 계층셀 등의 환경에서 기계학습을 통해 성능 근사화를 단순화하고 응용하는 연구로 확장해갈 것이다.

References

- [1] J. G. Andrews, F. Baccelli, and R. K. Ganti, "A tractable approach to coverage and rate in cellular networks," *IEEE Trans. Commun.*, vol. 59, no. 11, pp. 3122-3134, Nov. 2011.
- [2] S. Singh, X. Zhang, and J. G. Andrews, "Joint rate and SINR coverage analysis for decoupled uplink-downlink biased cell associations in HetNets," *IEEE Trans. Wirel. Commun.*, vol. 14, no. 10, pp. 5360-5373, Oct. 2015.
- [3] H. E. Hammouti, M. Ghogho, and S. A. R. Zaidi, "A machine learning approach to predicting coverage in random wireless networks," in *Proc. IEEE Globecom'18*, Abu Dhabi, Dec. 2018.
- [4] H.-K. Park, J. Um, S. Park, and T. Kwon, "Downlink performance approximation of cellular networks via stochastic geometry and machine learning," *J. KICS*, vol. 45, no. 03, pp. 492-495, Mar. 2020.
- [5] T. Kwon, "Green random access for wireless peer discovery," *IEEE Commun. Lett.*, vol. 18, no. 09, pp. 183-186, Feb. 2015.
- [6] S. Siegel, "Training an artificial neural network to play tic-tac-toe," Technical report, University of Wisconsin-Madison, 2001, from <https://users.auth.gr/~kehagiat/Research/GameTheory/12CombBiblio/TicTacToe.pdf>.