

밀리미터파 셀룰러 네트워크를 위한 기계학습 기반의 성능 근사화

김 조 은*, 권 태 수^o

Machine Learning Based Performance Approximation for Millimeter-Wave Cellular Networks

Joeun Kim*, Taesoo Kwon^o

요 약

밀리미터파 다중셀 네트워크는 방해물, 심한 전파 손실, 빔포밍과 같은 고유 속성들로 인해 일반적으로 복잡한 수학적 분석이나 긴 시뮬레이션 시간을 필요로 한다. 이에 따라, 본 논문은 다항식 로지스틱 함수와 인공신경망을 활용한 SINR 분포의 근사화 방안을 제안하고, 제안 방안은 신속하면서도 상대적으로 정확한 성능을 제공함을 컴퓨터 시뮬레이션을 통해 입증한다.

Key Words : Millimeter wave, cellular network, SINR, machine learning, 5G

ABSTRACT

Millimeter-wave multicell networks require a complex mathematical analysis or a long simulation time due to such intrinsic properties as blockage, harsh propagation loss, and beamforming. In this regard, this paper proposes the approximation method of signal-to-interference-plus-noise-ratio (SINR) distributions using polynomial logistic functions and artificial neural networks, and it demonstrates that the proposed method provides a quick yet

considerably accurate performance via computer simulations.

I. 서 론

5G 이동통신은 가상현실, 클라우드 게임 등 다양한 초고속 데이터 서비스에 활용되고 있다. 특히, 28GHz와 같은 밀리미터파 대역은 6GHz 이하 대역보다 더 넓은 대역폭을 사용함에 따라 더욱 높은 데이터 전송률을 지원할 수 있다.

[1],[2]에서는 밀리미터파 대역 셀룰러 네트워크의 성능을 확률기하 기반으로 수학적 분석하였다. 하지만 주변 전파 방해물들과 빔포밍의 영향으로 인해 분석이 매우 복잡하여 주로 HPPP(Homogeneous Poisson Point Process) 환경에서 분석되었다. 이러한 한계로, 여전히 시스템 레벨 시뮬레이션을 통한 성능 분석이 주를 이루지만 소요 시간이 짧지 않고 미리 설계한 환경 변수값들에 한정하여 분석이 가능하다는 문제점을 갖는다.

한편, [3]-[5]에서는 수학적 분석과 시뮬레이션 기반 분석의 한계점을 극복하기 위해 기계학습을 이용한 SINR(Signal to Interference plus Noise Ratio) 확률분포 분석 방안을 제안하였다. 이것은 네트워크 환경이 일부 변하더라도 시뮬레이션을 다시 하지 않고 신속하게 SINR 확률 분포를 도출할 수 있다는 장점을 갖는다. 하지만, 이들 연구결과는 6GHz 이하 대역으로 한정된다.

본 논문에서는, 6GHz 이하 대역과 달리 방해물들의 전파전달 영향과 빔포밍의 영향으로 인해 더욱 복잡한 기술적 요소를 고려해야 하는 밀리미터파 대역에서 다항식 로지스틱 함수를 통해 기계학습 기반의 성능 근사화가 가능함을 시뮬레이션을 통해 검증한다. 또한 본 방안의 응용 예로 전송 성공 확률을 최대화하는 기지국 밀도 도출 방안을 제시한다.

II. 시스템 모델

기지국은 밀도가 λ 인 HPPP 또는 육각셀 형태로 분포하며 단말은 HPPP에 따라 분포한다. 그리고 기

* 본 연구는 서울과학기술대학교 교내연구비의 지원으로 수행되었습니다.

• First Author : (ORCID:0000-0002-7719-5032)Seoul National Univ. of Science and Technology, Dept. of CSE, worth3910@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 : 202110-285-A-LU, Received October 14, 2021; Revised November 12, 2021; Accepted November 20, 2021

지국은 항상 하나 이상의 단말에 연결된다. 밀리미터파 대역에서는 주변 방해물들의 영향에 따라 LoS(Line of Sight)와 NLoS(Non Line of Sight) 채널을 겪는데, 기지국과 단말간 거리가 R 일 때, LoS와 NLoS 채널이 될 확률은 각각 $e^{-\mu R}$ 과 $1 - e^{-\mu R}$ 로 설정되며^[1] μ 는 환경변수로 주어진다. 경로감쇄이득 $L(R)$ 은 LoS와 NLoS 확률에 따라 $KR^{-\alpha_L}$ 혹은 $KR^{-\alpha_N}$ 이 된다. 또한 나카가미- m 페이딩 이득 h 가 고려되며, m 은 LoS와 NLoS 확률에 따라 m_L 혹은 m_N 이 된다. 밀리미터파 대역은 큰 경로감쇄손실을 보상하기 위해 빔포밍을 적용하는데 이를 색터화된 빔포밍 모델로 근사화하고^[1], G 는 메인 로브 이득, g 는 사이드 로브 이득, θ 는 빔폭을 나타낸다. 이때, G, g, θ 에 대해 송신빔과 수신빔은 각각 아래첨자 t 와 r 로 표기된다. 수신 단말은 경로감쇄가 최소인 기지국과 연결되고, 순방향 데이터 전송 시 단말은 빔포밍 이득으로 서빙 기지국과는 $G_t G_r$ 을, 인접 기지국과는 위치관계에 따라 G_t, g_t 와 G_r, g_r 의 조합을 가진다. 그림 1은 이러한 모델들을 보여준다.

따라서 송신전력이 P , 잡음전력이 σ^2 일 때 단말에서 수신 SINR은 $\frac{hG_t G_r L(R)}{\sigma^2 + I}$ 로 표현된다. 여기서 I 는 단말이 받는 모든 간섭의 합을 의미한다.




그림 1. 밀리미터파 대역 순방향 네트워크
Fig. 1. Millimeter-wave Downlink Network

III. 인공신경망 구성

인공신경망(ANN, Artificial Neural Network)을 활용하면 학습하는 시간을 필요로 하지만 오프라인 학습이므로 학습 후 사용할 때에는 시뮬레이션으로 구하는 것보다 빠르게 SINR 분포 도출이 가능하다. 뿐만 아니라 시뮬레이션 값이 없는 부분이 어떤 성향을 보이는지 예측할 수 있다. 따라서 기계학습을 활용하여 여러 네트워크 환경변수와 곡선 적합의 매개변수 간 관계를 학습하는 방안을 제안하고자 한다.

표 1. 밀리미터파 다중셀 네트워크 시스템 매개변수
Table 1. System Parameters for Millimeter-wave Multicell Networks

Parameters	Value
$\log \lambda$: log value of density of base stations	$[\log(10^{-6}):0.005: \log(2 \times 10^{-4})] m^{-2}$
μ : LoS distance	141.4, 50 m
α_L, α_N : path loss exponent for LoS, NLoS	[2:0.1:2.5], [3.5:0.1:4.5]
m_L, m_N : parameter of Nakagami fading	3, 2
G_t, g_t, θ_t : transmit antenna parameters	18 dB, -2 dB, 10 degrees
G_r, g_r, θ_r : receive antenna parameters	0 dB, 0 dB, 360 degrees
P : transmit power	30 dBm
W : bandwidth	100 MHz
σ^2 : noise power	-114 dBm
K : path loss gain at 1 m	-61.38 dB

[3]에서는 6GHz 이하 대역 네트워크에서의 SINR CCDF(Complementary Cumulative Distribution Function)를 수학적 (1)과 같은 다항식 로지스틱 함수로 표현하였다.

$$P(\tau_{dB}) \approx \frac{1}{1 + \exp(-\beta_n \tau_{dB}^n - \dots - \beta_1 \tau_{dB} - \beta_0)} \quad (1)$$

6GHz 이하 대역에서는 다항식 로지스틱 함수의 차수가 2차면 충분했지만 밀리미터파 대역에서는 방해물과 빔포밍의 영향으로 그래프의 굴곡이 더 커지므로 2차로는 정확도가 떨어져 더 높은 차수가 필요할 수 있다. 이에 대해서는 IV장에서 논의한다.

본 논문에서는 환경변수 $\lambda, \alpha_L, \alpha_N$ 를 입력하여 β 를 도출하는 인공신경망을 구성한다. 이때, β 는 시뮬레이션 결과를 다항식 로지스틱 함수로 비선형 최소자승법(Non-linear Least Square)의 곡선 적합을 하여 얻을 수 있다. 데이터 세트로는 입력 파라미터 값들의 모든 조합을 사용하였으며 값의 범위는 데이터 생성 시간 대비 인공신경망 성능 향상이 유의미하지 않은 수준까지 증가시킨 것이다. 이에 따라 HPPP와 육각셀 각각 총 30,426개의 데이터를 가지고 이것을 랜덤하게 섞은 것의 80%를 훈련 세트로 사용했다. 시뮬레이션 매개변수는 표 1과 같다. 표 1에서 [a:b:c]는 a부터 c까지 b 간격의 값들을 나타낸다.

인공신경망은 총 7개의 히든 레이어(Hidden Layer)

로 구성되고 각각 20개, 16개, 8개, 8개, 5개, 3개, 2개의 뉴런들을 가진다. 활성화 함수로는 Leaky ReLU를, 비용함수로는 MSE(Mean Squared Error)인 $\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$ 를 사용한다. n 은 전체 데이터 수, y_i 는 곡선 적합의 β 값, 그리고 \hat{y}_i 는 인공지능망의 β 값이다.

IV. 성능 분석 및 응용

앞에서 설명했듯이 밀리미터파 대역에서는 SINR 분포의 굴곡이 심하여 높은 다항식 로지스틱 함수의 차수가 필요함을 볼 수 있었다. 그림 2의 (a)에서 μ 가 50m일 때 차수가 2차라면 최대 약 14%의 오차율이 발생했지만 3차이면 최대 약 1%로 낮아졌다. 차수가 4차일 때는 3차일 때와 거의 차이가 나지 않아 그래프에서 잘 나타나지 않는다. 따라서 3차 이상으로 차수를 증가시켰을 때 SINR 분포를 상당히 잘 표현하므로 본 논문에서는 3차 다항식 로지스틱 함수를 사용한다. 또한 (a)와 (b) 모두 인공지능망이 시뮬레이션과 거의 일치함을 확인할 수 있다. 인공지능망은 $R^2 \triangleq 1 - \left(\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \right)$ 인 R-square로 평가될 수 있는데, 이는 1에 가까운 값일수록 인공지능망이 높은 신뢰도를 가짐을 의미한다. 여기서 \bar{y} 는 곡선 적합의 평균 β 값이다. 이전 장에서 제안한 인공지능망의 MSE 값들은 10^{-3} 수준이고 R-square 값들은 0.9 이상이므로 이를 신뢰할 수 있음을 알 수 있다.

그림 3은 기지국 밀도에 따라 그림 2와 같은 학습된 인공지능망을 통해 얻은 수신 SINR이 20 dB 이상일 확률을 나타낸 그래프이다. 즉, 기지국 밀도에 따

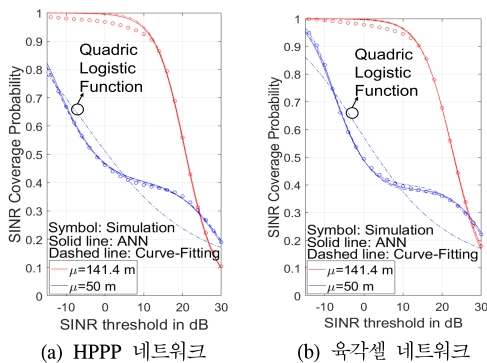


그림 2. SINR CCDF 성능
Fig. 2. SINR CCDF Performances




그림 3. 기지국 밀도에 따른 성공확률
Fig. 3. Success Probability vs. BS Density

른 성공확률(Success Probability)을 나타낸다. 밀리미터파 대역에서는 기지국간 거리가 가까워지면 LoS 채널로 간섭 영향을 받을 확률이 증가하여 오히려 성공확률이 낮아질 수도 있다. 따라서 최적의 기지국 밀도 값 도출이 필요할 수 있고, 기계학습 기반 성능분석을 통해 동작 변수들이 학습한 변수 범위 정도에서 변화하는 네트워크 환경들에서는 신속하게 그 값을 도출해 낼 수 있다. 여기서 최적의 기지국 밀도는 그래프에서의 모든 값들을 비교하여 최적의 기지국 밀도 $\lambda_{opt} = 2.3 \times 10^{-5}$ 을 도출할 수 있고, 단일 변수이므로 그 복잡도가 크지 않다. 뿐만 아니라 성공확률은 다항식으로 곡선 적합을 할 수 있는데, 7차 다항식이 그래프를 잘 표현함을 확인할 수 있다. 이러한 7차 다항식으로 그래프 자체를 또한 학습시킬 수 있을 것이다.

V. 결론

본 논문에서는 기존 6GHz 이하 대역처럼 밀리미터파 대역에서도 기계학습 기반 성능 분석이 가능함을 보였다. 하지만 밀리미터파 대역은 방해물들의 영향, 빔포밍 등 6GHz 이하 대역에 비해 더욱 복잡한 네트워크 환경을 고려해야하므로 더 높은 차수의 다항식 로지스틱 함수를 필요로 했다. 따라서 논문에서 제안한 기계학습을 이용해 신속하게 SINR 분포를 구하고, 그 응용 예로 성공확률을 최대화하는 기지국 밀도 도출에 적용될 수 있음을 보였다. 향후 매크로 셀과 소형 셀이 공존하는 이중 네트워크 환경으로 연구를 확장해갈 것이다.

References

[1] T. Bai and R. W. Heath, "Coverage and rate analysis for millimeter-wave cellular networks," *IEEE Trans. Commun.*, vol. 14, no. 2, pp. 11100-11114, Feb. 2015.

- [2] C. Madapatha, B. Makki, C. Fang, O. Teyeb, E. Dahlman, M. S. Alouini, and T. Svensson, "On intergrated access and backhaul networks: current status and potentials," *IEEE Open J. Commun. Soc.*, vol. 1, pp. 1374-1389, Sep. 2020.
- [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] J. Kwon and T. Kwon, "Uplink performance approximation of multicell networks based on machine learning," *J. KICS*, vol. 45, no. 11, pp. 1855-1858, Sep. 2020.
- [5] H. 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.