

기계학습 기반 상향링크 랜덤 접속 네트워크 성능 근사화

현 찬 수*

Machine Learning-Based Performance Approximation in the Uplink Random Access Network

Can-shou Xuan*

요 약

확률 기하 기반한 성능 분석은 동작 변수가 성능에 미치는 영향을 정량적으로 파악할 수 있지만 제한된 네트워크 환경에서 성능 분석이 가능하다. 따라서 본 논문은 확률 기하 기반 기계학습을 역방향 성능 근사화에 적용하는 방안을 제안한다. 제안 방안으로는 송신전력 제어 변수가 성능에 미치는 영향을 근사화하고 기타 네트워크 환경에도 응용 가능성을 보여 준다.

Key Words : Uplink SINR performance, power control, stochastic geometry, machine learning

ABSTRACT

The stochastic geometry-based analysis is possible to understand the effect of operating variables on network performance. But it is possible in a limited environment. Thus, this paper proposed a method that applies stochastic geometry-based machine learning to uplink performance approximation. The proposed method can approximate the effect of the power control variable on the uplink performance. In addition, the proposed method can apply to other network environments.

I. 서 론

SINR(Signal to Interference plus Noise Ratio) 분포는 시뮬레이션 방식으로 분석할 수 있지만 복잡한 네트워크 환경에서는 긴 시간이 필요하다. 확률 기하 기반 성능 분석은 제한된 네트워크 환경에서 가능하지만 복잡한 수식은 동작 변수가 성능에 미치는 영향을 분석하는 데 응용의 어려움이 있다^{3, 4}. 최근에는 기계학습을 성능 분석에 적용한 연구^{1, 2}가 진행되었다. [1]에서는 sigmoid-like function과 인공신경망을 SINR CCDF 성능 근사화에 적용한 연구가 진행되었다. sigmoid-like function은 target SINR 값과 계수들로 구성된 수식으로서 네트워크 환경변수가 성능에 미치는 영향을 직접 반영할 수 없는 한계가 있다. 따라서 송신 전력 제어 변수가 적용된 환경에서 기지국 밀도가 성능에 미치는 영향을 반영하는 데는 그 응용의 한계가 있다. [2]에서는 확률 기하 수식의 근사식에서 제안 방안에 적용할 근사식을 도출하고 경로 감쇄, 잡음 등 네트워크 환경변수를 입력 특징으로 하는 인공신경망을 제안하였다. 하지만 순방향 네트워크에서 확률 기하 동작 변수와 네트워크 환경변수가 일치한 상황만 고려하였다. 따라서 역방향 네트워크에서 확률 기하 동작 변수는 아니지만, 네트워크 환경변수인 송신 전력 제어 변수가 있는 상황에서는 제안 방안의 응용은 어려운 한계가 있다.

따라서 본 논문은 역방향 확률 기하 수식⁴과 기계학습을 결합한 근사식을 제안하고 제한한 근사식을 인공신경망에 적용하는 방안을 제안한다. 제안한 방안을 활용하여 송신 전력 제어 변수가 성능에 미치는 영향을 근사화하고 서로 다른 네트워크 환경에서의 응용 가능성과 제안 근사식을 송신 전력 제어 변수에 따른 최댓값을 도출하는데 응용 가능성을 보여 준다.

II. 시스템 및 성능 모델

본 논문은 기존 연구³에서 기지국 분포를 HPPP(homogeneous poisson point process)와 육각 셀 배치를 성능 분석에 적용하였던 점을 참고하여 그림 1과 같은 기지국 배치로 진행하였다. 그림 1-(a)는 기지국이 HPPP를 따른 배치를 보여 주고 그림 1-(b)는 기지국이 육각 셀 배치를 따르는 것을 보여 주고

* First Author : (ORCID:0000-0003-2300-5288)Seoul National Univ. of Science and Technology, Dept. of CSE, shou19@seoultech.ac.kr, 학생(석사), 학생회원
논문번호 : 202103-065-A-LU, Received March 22, 2021; Revised April 19, 2021; Accepted April 22, 2021

있다. 단말은 단위면적당 v 개를 갖는 균일 푸아송 분포에서 랜덤 접속 네트워크 환경을 고려하여 송신 확률 v 에 따라 단위면적당 uv 개 분포한다. 단말은 가장 가까운 기지국과 송신하고 송신 여부는 송신 확률을 따른다. 단말과 기지국은 모두 단일 안테나를 사용한다. 송신과정은 $A d^{-\alpha}$ 의 경로 감쇄 영향을 받고 A 는 단위 거리당 경로 감쇄, d 는 단말과 기지국 간 거리, α 는 경로 감쇄 지수를 의미한다. Rayleigh 페이딩 환경으로 가정하고 음영효과는 고려하지 않았다. 역방향 랜덤 접속 네트워크 환경에서 기지국이 ξ 이상의 SINR 신호를 수신할 확률을 아래 수식(1)과 같이 표현할 수 있다⁴⁾.

$$\Pr[SINR > \xi] = 2\pi\chi \int_0^{\infty} r \exp(-\frac{\pi\chi\lambda}{\Theta(\lambda)}r^2 - \frac{\xi\sigma^2}{p}r^\alpha)dr \quad (1)$$

수식 (1)에서 $\chi \doteq \exp(\frac{1}{2}(\frac{\log_{10} \bar{\chi}}{5} \frac{\bar{\chi}}{\alpha})^2)$ 는 음영효과, r 은 단말과 기지국 간 거리, p 는 사용자의 송신전력, $\Theta(\lambda) \doteq \lambda / \{\lambda + \mu \xi^{2/\alpha} \zeta(\alpha)\}$, $\zeta(\alpha) \doteq \frac{2\pi/\alpha}{\sin(2\pi/\alpha)}$ 을 보여 주고 있다. 또한 수식 (1)은 아래와 같이 근사화 가능하다⁴⁾.

$$\Pr[SINR > \xi] > \Theta(\lambda)(1 - (\frac{\Theta(1)}{\pi\chi})^{\frac{\alpha}{2}} \frac{\xi\sigma^2 \Gamma(1+\alpha/2)}{\lambda^{\alpha/2} p}) \quad (2)$$

역방향 랜덤 접속 네트워크 환경에 송신전력 제어 방안을 적용 시 각 단말의 송신전력은 $p_{tx} = \min\{p_{max}, p_0 \cdot p^{\epsilon}\}$ 와 같이 결정된다⁵⁾. p_{max} 는 최대 송신전력, p_0 는 참조 전력, p 는 경로 감쇄 영향을 보여 준다. ϵ 가 0부터 1 사이값으로 설정 시 송신 전력 제어 방안을 FPC(Fractional Power Control)라고도 부른다. 그림 2는 송신 전력 제어 방안을 적용한 역방향 랜덤 접속 네트워크의 SINR CCDF(complementary cumulative distribution)을 시

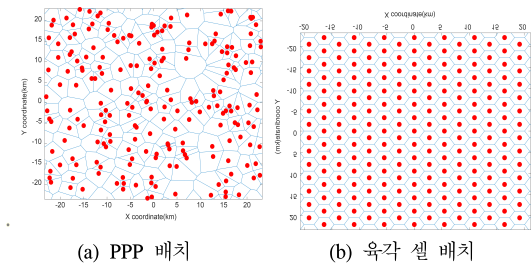


그림 1. 기지국 배치 종류
Fig. 1. Base station deployment type

물레이션 방식으로 도출한 결과이다. FPC가 0에서 1로 설정 시 높은 SINR 값을 갖는 UE는 감소하는 반면 간섭의 영향이 적어진 것을 확인할 수 있고 수식 (1)의 결과는 FPC=0인 성능을 잘 반영할 수 있는 점을 확인할 수 있다. 비록 FPC가 0부터 1 사이값 일 시 수식으로는 SINR CCDF를 직접 도출할 수 없지만 송신 전력 제어 방안을 적용한 SINR CCDF 데이터를 통해 기지국 밀도에 따른 target SINR 값 보다 큰 확률값 데이터를 확보할 수 있고 확보한 데이터를 curve-fitting 방식을 통해서 데이터의 경향을 반영하는 곡선을 도출하는 데 사용할 수 있다. 따라서 아래와 같은 근사식을 제안한다.

$$\Pr[SINR > \xi] \approx \beta_1 \exp(1 - \beta_2/\lambda) \quad (3)$$

수식 (2)가 수식 (1)의 성능을 잘 따른 점⁴⁾과 수식 (2)에서 $1/(\lambda^{(\alpha/2)p})$ 부분을 $1/(\lambda \lambda^{(\alpha/2-1)p})$ 로 표현할 수 있는 점을 고려하여 제안하였다. 네트워크 환경 변수인 기지국 밀도만 남기고 시물레이션 결과를 통한 비선형 최소자승법(non-linear least square)방식의 curve-fitting을 통해 ϵ 가 성능에 미치는 영향을 $\beta \doteq (\beta_1, \beta_2)$ 들을 통해 반영한다. 기지국 밀도가 성능에 미치는 영향을 반영한 데이터 셋을 다항식 곡선 피팅 방식으로도 접근할 수 있다. 하지만 다항식의 차수를 5차까지 설정해야 경향을 반영한다는 점과 다항식 본신은 기지국 밀도에 대한 높은 차수의 다항식으로 성능에 미치는 영향을 정량적으로 분석하기에는 한계가 있다. 반면 제안 근사식은 네트워크 환경변수 값에 따라 β 값들은 서로 다르지만, 인공지능망에 적용하면 두 개의 예측값만 도출하면 된다.

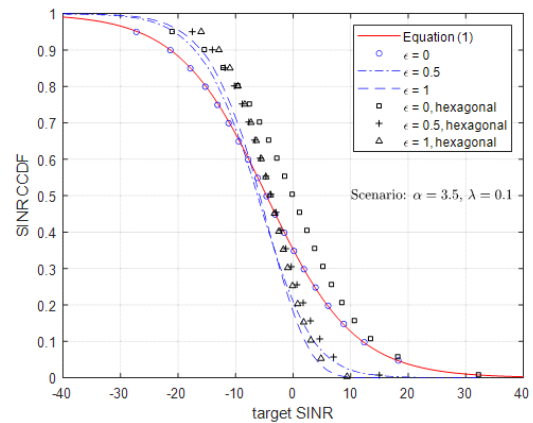


그림 2. 역방향 SINR CCDF
Fig. 2. Uplink SINR CCDF

III. 인공신경망 및 데이터 셋

본 장에서는 네트워크 환경변수인 $\nu, \alpha, P_0, \epsilon$ 을 입력 특징으로 하여 curve-fitting을 통해 도출한 $\beta \equiv (\beta_1, \beta_2)$ 중 하나를 출력하는 인공신경망을 제안한다. 제안한 인공신경망과 수식(3)을 사용하여 FPC가 서로 다른 값을 적용 시 신속히 기지국 밀도가 성능에 미치는 영향을 분석할 수 있다. 인공신경망은 각각 입력층은 4개 뉴런, 출력층은 하나의 뉴런으로 구성하였다. 4개의 은닉층은 각각 13개, 9개, 5개, 3개의 뉴런으로 구성되었다. 은닉층을 추가하여 총 뉴런 수가 증가 시 비용함수에 주는 영향을 관찰하였지만 5개의 은닉층 구성 시 비용함수는 4개의 은닉층보다 1/10수준 더 감소하지만 4층으로 구성하여도 10^{-3} 수준까지 비용함수가 감소함으로 위와 같은 은닉층으로 인공신경망을 구성하였다. 은닉층 사이마다 Leaky ReLU층을 사용하고 비용함수는 MSE(Mean Square Error)을 사용한다. MSE는 $\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$ 로 표현할 수 있고 n 는 전체 학습 데이터 개수, y_i 는 curve-fitting을 통해 도출한 β 값, \hat{y}_i 는 인공신경망을 통해 도출한 β 값이다.

표 1의 네트워크 환경변수 범위에서 인공신경망에 학습할 데이터를 확보하였다. 표에서 [A, B]는 A 값 또는 B값으로 환경변수를 설정하고 진행하였음을 의미하고 [A:B:C]는 A부터 C까지의 값 범위에서 B씩 증가하는 것을 의미한다. PPP 배치와 육각 셀 배치 네트워크 환경에서 시뮬레이션에 기반한 curve-fitting을 통해 각각 88,000개 데이터를 확보하였다. 각각의 데이터셋에서 80%는 학습 데이터, 20%는 테스트 셋으로 활용하였다. 인공신경망을 학습 데이터로 학습 시 β_1, β_2 는 각각 $2 \times 10^{-5}, 1 \times 10^{-3}$ 의 MSE를 보여 주었다.

표 1. 역방향 랜덤 접속 네트워크 환경
Table 1. Uplink random access network environment

Notation : Description	Values
μ : UE(user equipment) density	100 km ⁻²
ν : UE transmit probability	[0.001, 0.01]
α : Path loss exponent	[2.1:0.1:6]
P_0 : Reference power	[13:0.1:23]dBm
ϵ : FPC parameter	[0:0.1:1]
P_{max} : Maximum transmit power	23 dBm

IV. 성능 평가 및 응용

그림 3은 임의의 테스트 셋 HPPP배치 네트워크 환경에서 서로 다른 송신전력제어변수가 성능에 미치는 영향을 기지국 밀도에 따라 보여 주고 있다. 인공신경망의 정확도는 $R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$ 인 R-squared 값으로 평가할 수 있다. 위 수식에서 y_i 는 실제값, \hat{y}_i 는 예측값, \bar{y}_i 는 평균값으로서 1에 가까울수록 예측값과 실제값이 같아지는 것을 의미한다. 그림에서 3가지 마크는 네트워크 시뮬레이션을 통해 도출한 결과이다. 하나의 송신전력제어변수가 성능에 미치는 영향을 도출 시 47초가 필요하지만 학습된 인공신경망에서는 0.98 이상의 R-squared 성능을 나타내는 β_1, β_2 을 신속히 도출할 수 있고 수식 (3)을 통해서 제안 방안이 시뮬레이션 결과의 경향을 잘 반영하는 것을 그림을 통해 확인할 수 있다.

그림 4는 육각 셀 배치의 테스트 셋에서 임의로 정한 네트워크 환경에서 서로 다른 송신전력제어 변수가 성능에 미치는 영향을 기지국 밀도에 따라 보여 주고 있다. 시뮬레이션 결과의 경향을 잘 반영하는 것을 통해서 제안 방안으로 서로 다른 기지국 배치하에서도 응용 가능함을 확인할 수 있다. 제안 방안으로는 송신전력제어 변수가 성능에 미치는 영향의 최대치를 구할 수 있다. 그림 4의 FPC=1인 상황에서 기지국 밀도가 0에서 시작 시 일정한 선형적인 증가가 있지만, 기지국 밀도가 커지면서 증가 폭은 크게 줄어드는 것을 확인할 수 있다. 따라서 FPC가 1인 상황에서 성능에 미치는 최대 영향은 수식(3)에서 기지국 밀도를 일정하게 큰 값을 취할 수 있는 것으로 그림을 통해 직




그림 3. 제안 방안을 활용한 성능 분석 1
Fig. 3. Performance analysis 1 using proposed method

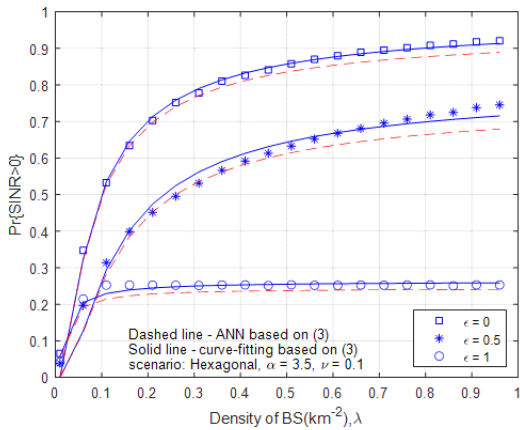


그림 4. 제안 방안을 활용한 성능 분석 2
 Fig. 4. Performance analysis 2 using proposed method

관적으로 확인할 수 있다.

V. 결 론

본 논문에서는 네트워크 환경변수와 확률 기하 동작 변수가 일치하지 않는 상황의 성능 근사화에 적용 가능한 방안을 제안하였다. 제안 방안으로는 송신전력이 성능에 미치는 영향을 근사화할 수 있음을 보여 주었다. 향후, 간섭이 SINR에 미치는 영향을 확률 기하 기반 기계학습으로 분석하는 응용으로 확장할 것이다.

References

[1] 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*, pp. 1-6, Abu Dhabi, United Arab Emirates, Dec. 2018.

[2] 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. 3, pp. 492-495, Mar. 2020.

[3] 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.

[4] T. Kwon, S.-W. Choi, and Y.-H. Shin, "A comprehensive design framework for

network-wide cost reduction in random access-based wireless IoT networks," *IEEE Commun. Lett.*, vol. 23, no. 9, pp. 1576-1580, Sep. 2019.

[5] C. U. Castellanos, et al., "Performance of uplink fractional power control in UTRAN LTE," in *Proc. IEEE VTC Spring 2008*, pp. 2517-2521, Marina Bay, Singapore, May 2008.