

확률기하와 기계학습을 통한 셀룰러 네트워크 순방향 성능 근사화

박한결*, 엄중선*,
박승근**, 권태수*

Downlink Performance Approximation of Cellular Networks via Stochastic Geometry and Machine Learning

Han-Kyul Park*, Jungsun Um*,
Seungkeun Park**, Taesoo Kwon*

요 약

확률기하는 동작변수간 상관관계 파악에 용이하지
 만, 실제 네트워크 동작의 단순화된 모델링에 의해
 제한적 환경에 대해서만 적용가능하다는 한계가 있다.
 반면, 시뮬레이션은 다양한 환경에 대해 성능 분석이
 가능하지만, 동작변수간 상관관계 파악이 어렵다는 한
 계가 있다. 본 논문은 확률기하와 기계학습을 통해,
 셀룰러 네트워크의 순방향 성능을 매개변수화하고, 경
 로감쇄지수, 음영, 열잡음에 따른 성능을 학습하기 위
 한 방안을 제시한다. 또한, 제안 방안이 기지국 밀도
 및 송신 전력의 설계에 응용될 수 있음을 보인다.

Key Words : Downlink SINR performance,
 stochastic geometry, machine
 learning

ABSTRACT

Stochastic geometry facilitates to comprehend
 correlations between operation variables, but has a

limit that it is applicable only to limited environment
 because of simplified modeling of real network
 operation. On the other hand, simulation can analyze
 performance in various environments, but it is
 difficult to comprehend correlation between operation
 variables. This paper parameterizes the downlink
 SINR (Signal to Interference plus Noise Ratio)
 performance of cellular networks, and proposes the
 method to learn the performance according to path
 loss exponent, shadowing, and thermal noise, via
 stochastic geometry and machine learning. In
 addition, it is demonstrated that the proposed
 performance can be applied to the design of base
 station (BS) density and transmit power.

I. 서 론

확률기하는 동작변수간 상관관계 파악이 용이하여
 무선 네트워크의 정량적 성능 분석 툴로서 널리 이용
 되어 왔지만^[1-3], 제한적 환경에 대해서만 정량적 성능
 분석이 가능하다는 한계점이 있다. 반면에 시뮬레이션
 은 다양한 환경에 대해 성능 분석이 가능하지만, 동작
 변수간 상관관계 파악이 쉽지 않아 네트워크 설계에
 응용하기 어렵다. 최근 통신 분야에서 기계학습을 활
 용한 연구가 진행되고 있으며, [3]에서는 순방향 네트
 워크의 SINR(Signal to Interference plus Noise
 Ratio) 분포가 Sigmoid 함수와 유사한 형태를 갖기 때
 문에 해당 함수의 형태를 추측하고 기계학습을 통해
 해당 함수의 계수들을 도출하였다. 또한, 인공지능망
 을 활용하여 경로감쇄지수 등의 네트워크 환경변수에
 따른 함수의 계수 값들을 학습시키고 이를 통해 임의
 무선 네트워크의 SINR 분포를 예측하였다. 하지만
 [3]의 제안방안은 설계 변수간 상관관계를 표현하지
 않았기 때문에, 기지국 밀도 및 송신 전력과 같은 네
 트워크 설계에 응용하기 어렵다는 한계가 있다.

본 논문에서는 확률기하 기반 접근방식에 기계학습
 을 결합하여 셀룰러 네트워크의 순방향 SINR 분포를

※ 이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원(2019-0-00964-001, 스펙트럼 쉐어링을 통한
 기존 무선국 보호 및 주파수 공유기술 개발)과 2020년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된
 연구임(No. NRF-2019R1F1A1062870).

• First Author : (ORCID:0000-0002-9066-784X) SK telecom, hk.p@sk.com, 정희원

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

* (ORCID:0000-0003-1514-0500) Electronics and Telecommunications Research Institute, korses@etri.re.kr; 정희원

** (ORCID:0000-0003-4956-8775) Electronics and Telecommunications Research Institute, seungkp@etri.re.kr, 정희원

논문번호 : 201911-307-A-LU, Received November 22, 2019; Revised December 13, 2019; Accepted December 14, 2019

매개변수화한다. 또한, 인공지능망을 활용하여 해당 식의 계수들을 학습시키고, 이를 통해 다양한 네트워크의 성능을 예측한다. 더 나아가, 제안한 수학적 식이 네트워크의 요구 성능에 따른 기지국 밀도 및 송신 전력 설계에 응용될 수 있음을 확인한다.

II. 시스템 및 성능 모델

본 논문에서는 그림 1의 2가지 기지국 배치 방식을 따르는 네트워크를 고려한다. 그림 1-(a)는 기지국이 PPP(Poisson Point Process)에 따라 분포된 네트워크(이하 PPP 네트워크)이며, 그림 1-(b)는 기지국이 육각셀 기반 배치에 따라 균일하게 분포된 네트워크(이하 육각셀 네트워크)이다. 단말은 PPP에 따라 분포되며, 가장 가까운 기지국으로부터 서비스를 받는 순방향 네트워크를 가정한다. 전송된 신호는 $Ad^{-\alpha}$ 의 경로 감쇄를 겪으며, A 는 단위 거리당 경로감쇄, d 는 링크 간 거리, α 는 경로감쇄지수이다. 따라서, PPP 네트워크에서 기지국으로부터 서비스를 받는 단말이 ξ 이상의 SINR을 갖는 신호를 수신할 확률은 다음과 같이 표현할 수 있다⁴⁾.


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

위의 식에서 $\chi \triangleq \exp\left(\frac{1}{2}\left(\frac{\log 10}{5}\frac{\bar{\chi}}{\alpha}\right)^2\right)$, $\Theta \triangleq \frac{1}{\xi^{2/\alpha}\zeta(\xi, \alpha)}$, $\zeta(\xi, \alpha) \triangleq \int_{\xi^{-\frac{2}{\alpha}}}^\infty \frac{du}{1+u^{\alpha/2}}$, $\sigma^2 \triangleq \bar{\sigma}^2/A$, λ 는 기지국 밀도, p 는 기지국 송신 전력, $\bar{\chi}$ 는 음영 표준편차, 그리고 $\bar{\sigma}^2$ 은 열잡음을 의미한다.

또한 (1)은 다음과 같이 근사화할 수 있다⁴⁾.

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

(2)는 네트워크의 핵심 설계 변수인 λ 와 p 의 상관 관계를 잘 표현하고 있기 때문에 네트워크 설계에 적합한 형태이지만, 간섭 영향이 큰 환경에서는 정확한 성능을 나타내는 반면 잡음 영향이 큰 환경에서는 간섭 영향이 큰 환경에 비해 비교적 부정확한 성능을 나타낸다. 따라서, PPP 네트워크의 성능은 (2)의 형태를



(a) PPP 기반 배치 (b) 육각셀 기반 배치

그림 1. 기지국 배치 시나리오

Fig. 1. Base station deployment scenarios

잘 따를 것이라 추측하고, (2)를 응용하여 다음과 같은 근사식을 제안한다.

$$\Pr\{\text{SINR} > \xi\} \approx \beta_1 \exp(-\beta_2/(\lambda^{\alpha/2}p)) \quad (3)$$

(3)에서 $\beta \triangleq (\beta_1, \beta_2)$ 는 λ 및 p 와 무관하며, 네트워크 환경 변수인 α , $\bar{\chi}$ 및 σ^2 에 따라 다양한 값을 가질 것이라 추측하고, 추후 그림 2의 결과를 통해 (3)의 성능을 확인한다. β 는 주어진 네트워크 환경에서 $\lambda^{\alpha/2}p$ 에 대해 비선형 최소자승법(non-linear least square)을 활용하는 curve-fitting 함수를 활용하여 얻을 수 있다. 또한, repulsive한 기지국 토폴로지에 기반한 네트워크의 성능은 PPP 네트워크의 성능을 활용하여 표현 가능하기 때문에⁵⁾, (3)의 성능은 육각셀 네트워크의 성능 또한 잘 표현할 수 있을 것이다.

그림 2는 PPP 네트워크 및 육각셀 네트워크의 SINR 분포를 나타낸다. PPP 네트워크는 (1) 기반의 성능을 활용하였으며, 주어진 α , $\bar{\chi}$ 및 σ^2 에 대해 SINR 분포가 $\lambda^{\alpha/2}p$ 의 관계를 따름을 알 수 있다. 육각셀 네트워크는 시뮬레이션 결과를 활용하였으며, 주어진 환경변수에 대해 SINR 분포가 $\lambda^{\alpha/2}p$ 의 관계를 따름을 알 수 있다. 따라서, $\lambda = 1 \text{ km}^{-2}$ 인 경우에 한해 PPP 네트워크와 육각셀 네트워크의 curve-fitting 성능을 나타내었다. PPP 네트워크의 경우, (3) 기반 성능이 (2) 기반 성능보다 뛰어난 정확도를 나타내고 있으며, (3) 기반 성능은 육각셀 네트워크의 성능 또




그림 2. Curve-fitting을 활용한 SINR 성능 분석

Fig. 2. SINR performance analysis using curve-fitting

한 잘 따르기 때문에 네트워크의 환경에 따라 β 를 얻는다면, (3)을 활용하여 네트워크의 성능을 쉽게 구할 수 있을 것이다.

III. 인공신경망 설계 및 데이터셋

그림 3은 네트워크의 환경 변수에 따른 β 를 얻기 위한 인공신경망이다. 제안 인공신경망은 α , $\bar{\chi}$ 및 σ^2 을 입력 벡터로 활용하여 $\beta_p (= \beta_1$ 또는 $\beta_2)$ 를 도출한다. 제안 인공신경망은 3개의 hidden layer로 구성되며, hidden layer의 첫 번째, 두 번째 및 세 번째 layer는 각각 8, 6 및 3개의 뉴런으로 구성된다. 제안 인공신경망의 hidden layer 및 뉴런의 개수를 증가시키더라도 정확도가 더 이상 향상되지 않기 때문에, 인공신경망의 빠른 학습을 위해 제안 인공신경망을 활용하였다. 각 뉴런의 활성화 함수로는 leaky Relu 함수를 사용하였으며, 비용 함수로는 MSE(Mean Square Error)를 사용하였으며, 비용함수는 다음과 같이 표현할 수 있다.

$$\text{Cost function (MSE)} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

(4)에서 n 은 데이터의 개수, y 는 실제 관측값, 그리고 \hat{y} 는 예측값을 의미한다.

표 1은 제안 인공신경망 학습을 위한 데이터셋이며, PPP 네트워크와 육각셀 네트워크에서 각각




그림 3. β 학습을 위한 인공신경망
Fig. 3. Artificial Neural Network for learning β

표 1. 네트워크 파라미터
Table 1. Network parameters

Notations	Descriptions	Values
α	Path loss exponent	[2.1:0.1:6]
$\bar{\chi}$	Shadowing Standard Deviation (dB)	[0:1:10]
σ^2	$\bar{\sigma}^2/A$ (dBm)	[20:0.1:28]

35,640개의 데이터를 활용하였다. PPP 네트워크의 경우, (1) 기반 성능을 활용하여 데이터를 확보하였으며, 육각셀 네트워크의 경우, 시뮬레이션 결과를 통해 데이터를 확보하였다. 해당 데이터들은 실제 네트워크의 성능과 완벽하게 일치하지는 않지만, 실제 네트워크 성능의 경향을 잘 반영하고 있으며[6], 이러한 방식을 통해 얻은 네트워크의 성능과 수학적 프레임워크를 활용하여 네트워크 설계에 대한 방향성을 제안할 수 있을 것이다. 각 네트워크에서, 데이터셋의 80%는 학습 데이터셋으로 활용하였으며, 나머지 20%는 테스트 데이터셋으로 활용하였다. 제안 인공신경망 학습의 결과로, 학습 데이터셋 및 테스트 데이터셋의 β_1 에 대해 약 0.00002의 MSE, β_2 에 대해 약 0.002의 MSE가 나타났다으며, 또한 β_1 및 β_2 에 대해 각각 0.98 이상의 R-square 성능이 나타남을 확인하였다. R-square는 다음과 같이 정의된다.

$$R^2 = 1 - \left(\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \right) \quad (5)$$

(5)에서 \bar{y} 는 데이터의 평균값이며, R-square 값이 1에 가까울수록 높은 신뢰도를 나타낸다.

IV. 성능 평가 및 응용

그림 4는 PPP 네트워크의 요구 성능에 따른 λ 및 p 를 나타낸다. 각 시나리오는 테스트 데이터셋에서 임의로 선정하였으며, 모든 시나리오에서 제안된 인공신경망을 통해 얻은 β 와 (3)을 활용한 성능이 (2) 기반 성능에 비해 훨씬 정확한 성능을 나타내고 있다. 또한 학습된 인공신경망을 활용하면 β 를 손쉽게 도출할 수 있기 때문에, (3)은 PPP 네트워크에서의 λ 와 p 와 같은 핵심 네트워크 변수의 설계에 있어 응용할 수 있을 것이다.




그림 4. PPP 네트워크의 요구 성능에 따른 λ 및 p 설계
Fig. 4. Design of λ and p according to required performance for PPP network




그림 5. 육각셀 네트워크의 요구 성능에 따른 λ 및 p 설계
 Fig. 5. Design of λ and p according to required performance hexagonal-cell network

그림 5는 육각셀 네트워크의 요구 성능에 따른 λ 및 p 를 나타낸다. 그림 4와 마찬가지로 각 시나리오는 테스트 데이터셋에서 임의로 선정하였으며, 모든 시나리오에서 인공지능망을 통해 얻은 β 와 (3)을 활용한 성능이 시뮬레이션 기반 성능과 유사함을 알 수 있다. 따라서, 제안한 인공지능망을 통해 육각셀 네트워크에서의 β 를 손쉽게 도출할 수 있기 때문에, (3)은 육각셀 네트워크에서의 λ 와 p 와 같은 네트워크 동작변수 설계에 응용할 수 있을 것이다.

V. 결론

본 논문에서는 확률기하 및 기계학습을 응용하여 다양한 네트워크 환경에 따른 SINR 분포를 매개변수화하였다. 또한 제안 방안은 네트워크의 요구 성능에 따른 기지국의 밀도와 송신 전력과 같은 네트워크 핵심 변수의 설계에 있어 응용될 수 있음을 확인하였다. 향후, 보다 실제적인 기지국 배치를 갖는 환경의 성능 분석에 대한 연구로 확장할 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, M. N. Kulkarni, A. Ghosh, and J. G. Andrews, "Tractable model for rate in self-backhauled millimeter wave cellular networks," *IEEE Wireless Commun. Lett.*, vol. 6, no. 4, pp. 438-441, Aug. 2017.
- [3] H. El Hammouti, M. Ghogho, and S. Ali Raza Zaidi, "A machine learning approach to predicting coverage in random wireless networks," in *Proc. IEEE Globecom*, pp. 1-6, Dec. 2018.
- [4] T. Kwon, S. W. Choi, and Y. 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] Y. Takahashi, Y. Chen, T. Kobayashi, and N. Miyoshi, "Simple and fast PPP-Based approximation of SIR distributions in downlink cellular networks," *IEEE Wireless Commun. Lett.*, vol. 7, no. 6, pp. 898-901, Dec. 2018.
- [6] 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.