

측정 데이터를 활용한 딥러닝 기반 전파 환경 예측 시뮬레이터

Deep Learning-Based Simulator for Radio Propagation Environment Prediction Using Measurement Data

노연수, 이동엽, 박용우, 조정호

Eonsu Noh · Dongyeob Lee · Yongwoo Park · Jungho Cho

요약

본 논문에서는 딥러닝 기반의 전파 환경 예측 시뮬레이터를 제안한다. 시뮬레이터는 측정된 경로 손실값을 레이블로 사용하여 심층 신경망(deep neural network: DNN) 모델을 학습할 수 있다. 학습을 위해 디지털 고도 모델과 토지피복도로부터 입력 특징들을 추출하였으며, 여러 지역에서 측정된 약 640만 개의 수신신호세기 데이터를 사용하였다. 학습된 DNN 모델은 시뮬레이터 내에서 전파 환경 예측 및 분석에 사용될 수 있다. 학습에 사용되지 않은 새로운 환경에서도, DNN 모델은 ITU-R 모델(P.525+P.526)보다 정확한 전파 환경 예측 성능을 보였다.

Abstract

This study proposed a deep learning-based simulator for radio propagation environment prediction. The simulator enabled the training of a deep neural network (DNN) model using the measured path loss values as labels. Input features were extracted from a digital elevation model and land cover map to train the DNN model, and approximately 6.4 million received signal strength measurements collected across diverse geographic regions were used. The trained DNN model could be used to predict and analyze the radio propagation environment within the simulator. The DNN model outperformed the International Telecommunication Union radiocommunications model (ITU-R P.525+P.526) in predicting radio propagation, even in previously unseen environments.

Key words: Deep Neural Network, Path Loss, Radio Propagation Environment, Simulator

I. 서론

전파 환경을 예측하는 것은 무선 통신망의 물리 계층 설계에 있어 중요한 과정이다. 이를 위해서는 주어진 환경에 적합한 전파모델을 사용하여 경로 손실을 정확하게 계산할 필요가 있다. 전파모델은 일반적으로 두 가지 유

형으로 분류된다^[1]. 첫 번째는 실측 데이터를 바탕으로 통계적인 경향을 모델링한 경험적 모델(empirical model)이며, 두 번째는 맥스웰 방정식을 기반으로 전파의 전파 메커니즘을 수치적으로 계산하는 결정론적 모델(deterministic model)이다. 경험적 모델을 활용하는 상용 시뮬레이터로는 ATDI사의 HTZ Warfare가 있으며, 결정론적 모

「본 연구는 대한민국 정부(국방부 및 방위사업청) 재원으로 민군협력진흥원에서 수행하는 민군협력기술사업의 연구비 지원으로 수행되었습니다(22-CM-TN-39).
국방과학연구소(Agency for Defense Development)

· Manuscript received July 1, 2025 ; Revised July 26, 2025 ; Accepted August 28, 2025. (ID No. 20250701-015S)

· Corresponding Author: Eonsu Noh (e-mail: eonsu.noh@gmail.com)

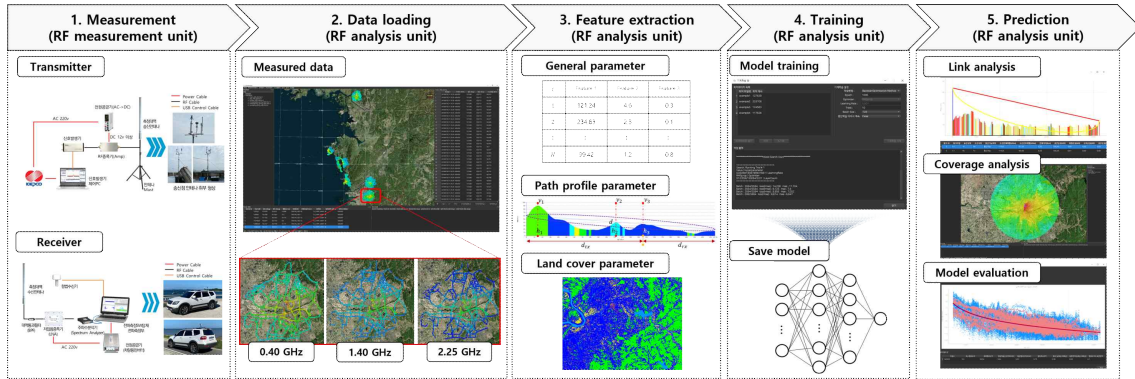


그림 1. 제안된 시뮬레이터의 운용 개념도
Fig. 1. System operation diagram of the proposed simulator.

델을 활용하는 시뮬레이터로는 REMCOM사의 Wireless InSite, Altair사의 WinProp 등이 있다.

최근 경로 손실 예측 정확도를 높이기 위해 딥러닝 기반 전파모델들이 활발히 연구되고 있다^{[2]-[5]}. 참고문헌 [2] 및 참고문헌 [3]에서는 거리, 주파수, 안테나 높이, 지형 고도 등의 입력 특징들을 활용하여 경로 손실을 예측하기 위해 심층 신경망(DNN, deep neural network) 모델을 학습하였다. 참고문헌 [4]에서는 해상 환경에서 음영 페이딩을 예측하기 위해서 해수면 높이, 풍속 등과 같은 특징들을 활용하여 DNN 모델을 학습하였다. 참고문헌 [5]에서는 위성 이미지로부터 추출된 특징을 활용하여 DNN 모델을 학습하였다. 이처럼 DNN은 다음과 같은 장점들로 인해 경로 손실 예측에 자주 활용되고 있다. 첫째, 측정 환경의 복잡한 특성을 반영하기 위해 멀티모달 특징들을 모델의 입력으로 활용할 수 있다. 둘째, 특징과 경로 손실의 관계를 비선형적으로 모델링할 수 있기 때문에 기존의 전파모델보다 정확하다.

본 논문에서는 딥러닝 기반 전파 환경 예측 시뮬레이터를 제안한다. 시뮬레이터는 DNN 모델을 학습하기 위해서 디지털 고도 모델과 토지피복도로부터 입력 특징을 추출하고, 측정된 경로 손실값을 레이블로 사용한다. 학습된 DNN 모델은 시뮬레이터 내에서 전파 환경의 예측 및 분석에 직접적으로 활용된다.

II. 딥러닝 기반 전파 환경 예측 시뮬레이터

그림 1은 제안한 시뮬레이터(이하 전파분석부)의 운용

개념도를 보여준다. 전파분석부는 전파측정부로부터 수집된 데이터들을 활용해 아래의 기능들을 수행한다.

- 데이터 입력(data loading): 측정된 수신전력 데이터 불러오기 및 가시화
- 특징 추출(feature extraction): 장비 제원, 디지털 고도 모델, 토지피복도 등으로부터 특징 추출
- 모델 학습(model training): 추출된 특징들을 활용한 DNN 모델 학습 및 저장
- 전파 환경 예측(prediction): 학습된 DNN 모델 기반 전파 환경 예측 및 분석 수행
 - 링크 분석(link analysis): 송신기와 수신기간 1:1 링크 성능 분석
 - 영역 분석(coverage analysis): 송신기 주위 수신신호세기 분석
 - 모델 평가(model evaluation): 모델의 전파 환경 예측 성능 평가

전파측정부는 송신부(Tx)와 수신부(Rx)로 구성된다. Tx는 신호 발생기와 무지향성 안테나로 구성되고, Rx는 스펙트럼 분석기, 저잡음 증폭기, 무지향성 안테나, GPS 안테나로 구성된다.

본 논문에서는 0.40, 1.40, 2.25 GHz 대역에서 교외 및 해안지역의 전파 환경들을 측정하였다. 표 1은 지역별 측정 환경을 보여준다. Tx 안테나는 각 지역의 지정된 좌표에, 표에 제시된 높이만큼 지면으로부터 떨어져 설치하였다.

표 1. 지역별 측정 환경

Table 1. Measurement environments by region.

Region	Tx coordinates (latitude, longitude)	Tx antenna height (m)	Season
Iksan	(35.9101, 127.0757)	30	Spring/Summer/ Winter
Nonsan	(36.1502, 127.1034)	10	Spring/Summer/ Winter
Paju	(37.7587, 126.7879)	7	Spring/Summer/ Winter
Hongseong	(36.5414, 126.4718)	22	Spring/Summer/ Winter
Taeon	(36.7756, 126.1374)	12	Spring/Summer/ Winter
Seocheon	(36.1724, 126.5267)	23	Spring/Summer/ Winter
Jeongeup	(35.6908, 126.8831)	12	Autumn

Rx는 차량에 탑재되었으며, Tx로부터 1~15 km 떨어진 거리 내에서 이동하며 수신전력(P_r)을 측정하였다. 경로 손실(PL)은 측정된 P_r 에 의해 식 (1)과 같이 계산된다.

$$PL = P_t + G_t + G_r + G_{LNA} - L - P_r \quad (1)$$

이때 P_t 는 송신 출력(dBm), G_t 는 송신 안테나 이득(dBi), G_r 는 수신 안테나 이득(dBi), G_{LNA} 는 LNA 이득(dB), L 은 회로 손실(dB)이다. 본 논문에서 사용된 값들은 $P_t=36$ dBm, G_t 및 $G_r=0$ dBi(0.40 GHz), 2 dBi(1.40, 2.25 GHz), $G_{LNA}=40$ dB(0.40, 1.40, 2.25 GHz), $L=4.61$ dB(0.40 GHz), 9.19 dB(1.40 GHz), 13.13 dB(2.25 GHz)이다.

그림 2는 DNN 모델의 학습 절차를 보여준다. 학습을 위해 익산, 논산, 파주, 홍성, 태안, 서천 지역에서 측정된 PL 값(6,391,624개)이 레이블로 사용되었다. 입력 특징들은 데이터 전처리(data preprocessing) 과정에서 추출되며, 추출된 파라미터는 다음과 같다^[6].

- 일반 파라미터(general parameter): $[\log(f/0.40), \log(d), \log(h_t/26.69), \log(h_r/4), |h_t - h_r|, \theta_t, \theta_r]$
- 지형 파라미터(path profile parameter): $[\nu_1, \nu_2, \dots, \nu_{10}]$

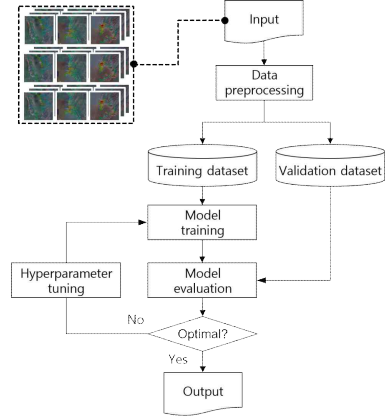


그림 2. DNN 모델 학습 절차

Fig. 2. Training procedure of DNN model.

- 토지피복 파라미터(land cover parameter): $[r_1, r_2, \dots, r_7]$

이때 f 는 주파수(GHz), d 는 Tx와 Rx 간 전파 거리(km), h_t 는 Tx 안테나 높이(m), h_r 은 Rx 안테나 높이(m), θ_t 는 Tx 클리어런스 각도($^\circ$), θ_r 는 Rx 클리어런스 각도($^\circ$)이다. ν_i 는 i 번째 장애점의 회절 파라미터이며 식 (2)와 같다.

$$\nu_i = h_i \sqrt{\frac{2}{\lambda} \left(\frac{1}{d_{t,i}} + \frac{1}{d_{r,i}} \right)} \quad (2)$$

이때 h_i 는 i 번째 장애점으로부터 Tx와 Rx를 잇는 직선까지의 최소 거리(m), λ 는 파장(m), $d_{t,i}$ 는 Tx와 i 번째 장애점까지의 거리(m), $d_{r,i}$ 는 Rx와 i 번째 장애점까지의 거리(m)이다. 만약 Tx와 Rx 좌표 사이의 지형 프로파일 이 K 개로 샘플링될 경우 r_j 는 식 (3)과 같다.

$$r_j = N_j / K, \quad j \in \{1, 2, \dots, 7\} \quad (3)$$

이때 N_j 는 경로 프로파일 샘플 중 토지피복 타입이 j 에 해당하는 샘플 수이다. $j=1$ 은 고층 빌딩 지역, $j=2$ 는 중층 빌딩 지역, $j=3$ 은 저층 빌딩 지역, $j=4$ 기타 빌딩 지역, $j=5$ 는 숲, $j=6$ 는 평지, $j=7$ 은 물을 의미한다.

데이터 전처리 이후 데이터의 80 %는 학습 데이터 세트(training dataset), 20 %는 검증 데이터 세트(validation

dataset)로 나뉜다. 학습 데이터 세트는 DNN 모델 학습(model training)에 사용되고, 검증 데이터 세트는 학습 중 모델 평가(model evaluation)에 사용된다. 모델 평가 이후 최적의 모델을 도출하기 위해서, 베이지안 최적화를 통해 하이퍼파라미터들을 튜닝한다.

본 논문에서 DNN 모델의 은닉층 개수는 {1, 2, 3, 4, 5, 6, 7}, 노드 개수는 {8, 16, 32, 64, 128, 256, 512}, 옵티마이저(optimizer)는 {SGD, Adagrad, RMSProp, Adam, Adamax}, 학습률은 $10^{-4} \sim 10^{-1}$ 범위 내에서 최적화되었다. 표 2는 학습에 사용된 컴퓨팅 리소스를 보여주며, 표 3은 최적화된 DNN 모델의 하이퍼파라미터를 보여준다.

표 2. DNN 모델 학습에 사용된 컴퓨팅 리소스
Table 2. Computing resource used to train the DNN model.

Parameter	Configuration
CPU	Intel Core i7-9700F
GPU	NVIDIA Geforce RTX 2060
RAM	32 GB DDR4
Language	Python 3.8.6
Deep learning framework	TensorFlow 2.8.0

표 3. 최적화된 DNN 모델의 하이퍼파라미터
Table 3. Hyperparameters of optimized DNN model.

Parameter	Value
Batch size	256
Activation function	ReLU
Number of hidden layers	3
Number of nodes	{512, 256, 128}
Optimizer	RMSProp
Learning rate	0.00027

표 4. ITU-R 모델 및 DNN 모델의 RMSE
Table 4. RMSE of ITU-R and DNN models.

Frequency	Number of samples	ITU-R P.525+P.526	DNN
0.40 GHz	111,956	10.21 dB	6.27 dB
1.40 GHz	68,042	17.21 dB	5.58 dB
2.25 GHz	60,273	16.72 dB	5.71 dB

다. 입력 특징의 표준화 여부, 학습 및 검증 데이터 세트의 분할 비율, 파라미터 탐색 범위 등은 사용자의 설정에 따라 자유롭게 변경될 수 있다.

표 4는 전파모델들의 예측값과 테스트 데이터(정읍 지역의 측정값)의 평균제곱근오차(root mean squared error: RMSE)를 나타낸다. ITU-R P.525와 P.526 모델에 의한 경로 손실은 다음과 같이 계산된다^{[7],[8]}.

$$L = 20 \log \left(\frac{4\pi d}{\lambda} \right) + L_{ba} + \max \{ L_{sph} - L_{bs}, 0 \} \quad (4)$$

이때 L_{ba} 는 actual path에 대한 bullington 회절 손실, L_{bs} smooth path에 대한 bullington 회절 손실, L_{sph} 는 spherical-earth path 회절 손실이다^[8]. DNN 모델은 학습에 사용되지 않은 새로운 환경에서도 ITU-R 모델보다 낮은 RMSE를 도출하여, 전파 환경 예측 성능이 우수한 것을 확인하였다.

III. 결 론

본 논문에서는 측정 데이터를 활용한 딥러닝 기반 전파 환경 예측 시뮬레이터를 제안하였다. 새로운 전파 환경에서도 DNN 모델의 예측 성능이 ITU-R 모델 대비 우수한 것을 확인하였다. 향후 본 시뮬레이터는 주파수 자원 사용의 효율화를 위한 기술 개발에 활용될 수 있을 것이다.

References

- [1] A. Sertetis, C. D. Sarris, "An overview of machine learning techniques for radiowave propagation modeling," *IEEE Transactions on Antennas and Propagation*, vol. 70, no. 6, pp. 3970-3985, Jun. 2022.
- [2] M. Ayadi, A. B. Zineb, and S. Tabbane, "A UHF path loss model using learning machine for heterogeneous networks," *IEEE Transactions on Antennas and Propagation*, vol. 65, no. 7, pp. 3675-3683, Jul. 2017.
- [3] C. A. Oroza, Z. Zhang, T. Watteyne, and S. D. Glaser, "A machine-learning-based connectivity model for complex terrain large-scale low-power wireless deployments," *IEEE Transactions on Cognitive Communications*

and Networking, vol. 3, no. 4, pp. 576-584, Dec. 2017.

- [4] E. Noh, J. Park, "A two-stage model for enhanced prediction of received signal strength in maritime environments," *IEEE Antennas and Wireless Propagation Letters*, vol. 23, no. 8, pp. 2531-2535, Aug. 2024.
- [5] J. Thrane, D. Zibar, and H. L. Christiansen, "Model-aided deep learning method for path loss prediction in mobile communication systems at 2.6 GHz," *IEEE Access*, vol.

8, pp. 7925-7936, Jan. 2020.

- [6] B. Kwon, H. Lim, J. Park, and E. Noh, "Machine learning-based path loss prediction with novel diffraction and morphology features," *IEEE Antennas and Wireless Propagation Letters*, vol. 24, no. 7, pp. 2004-2008, Jul. 2025.
- [7] *Calculation of Free-Space Attenuation*, ITU-R P. 525-5, Nov. 2024.
- [8] *Propagation by Diffraction*, ITU-R P. 526-15, Oct. 2019.

노 언 수 [국방과학연구소/선임연구원]

<https://orcid.org/0000-0001-9172-1070>



2014년 2월: 인하대학교 전자공학과 (공학사)
 2016년 2월: 광주과학기술원 기전공학과 (공학석사)
 2020년 2월: 광주과학기술원 기전공학과 (공학박사)
 2019년 12월~현재: 국방과학연구소 선임

연구원

[주 관심분야] 인공지능 기반 채널 모델링, 전자기 스펙트럼 관리, 전자기 센싱 및 이미징 등

박 용 우 [국방과학연구소/선임기술원]

<https://orcid.org/0000-0001-5726-8268>



2005년 2월: 우송대학교 컴퓨터디자인학과 (학사)
 2016년 2월: 충남대학교 산업공학과 (공학석사)
 2012년 10월~현재: 국방과학연구소 선임

기술원

[주 관심분야] 안테나, 전자파 측정 등

이 동 엽 [국방과학연구소/연구원]

<https://orcid.org/0000-0001-5560-9225>



2021년 2월: 한국해양대학교 전파공학과 (공학사)
 2023년 2월: 한국해양대학교 전파공학과 (공학석사)
 2023년 4월~현재: 국방과학연구소 연구원

[주 관심분야] AI, 전파 모델링, 전자기장 수치해석 등

조 정 호 [국방과학연구소/책임연구원]

<https://orcid.org/0009-0000-1582-9522>



2004년 2월: 고려대학교 전기전자전파공학부 (공학사)
 2006년 2월: 고려대학교 전파공학과 (공학석사)
 2020년 2월: 아주대학교 NCW학과 (공학박사)
 2006년 1월~현재: 국방과학연구소 책임

연구원

[주 관심분야] 국방 무기체계 주파수 획득 및 보호, 전파전파모델 연구개발 등