

메타러닝과 3D 이미지를 활용한 도심지내 밀리미터파 경로 손실 모델링

진우빈*, 김현진*, 이혁준°

Path Loss Modeling for mmWave for Urban Scenarios Using Meta-Learning and 3D Images

Woobeen Jin*, Hyeonjin Kim*, Hyukjoon Lee°

요약

밀리미터파 통신을 위한 정확하고 효율적인 경로손실 예측 모델링 방법은 mmWave 기반의 5G 이동 통신 시스템의 도입에 중요한 역할을 한다. 기존의 방법들은 서비스 도입 현장, 특히 밀집 도심지 환경에서의 기지국 설정 최적화 요구사항에 비해 낮은 정확도와 효율성으로 인해 실제 적용시 종종 한계를 보인다. 본 논문에서는 최근에 많은 관심을 끌고 있는 딥러닝을 기반으로 하는 밀집 도심지 환경에서의 mmWave 경로손실 예측모델을 제안하고 이를 학습시키기 위한 3D 지도 데이터 기반의 입력 데이터 생성 알고리즘을 소개한다. 또한 충분한 양의 학습 데이터 확보가 어려운 경우에도 높은 예측 정확도를 확보하기 위한 메타러닝 방식의 학습 알고리즘을 제안한다. 실험 결과를 통해 제안된 모델링 방법은 기존 방법 대비 우수한 경로손실 예측 성능을 보인다.

Key Words : Millimeter Wave, Path Loss Modeling, Meta-Learning, 5G, Convolutional Neural Network

ABSTRACT

An accurate and efficient pathloss prediction modeling method for mmWave communication plays an important role in the successful introduction of mmWave-based 5G mobile communication systems. Existing methods often suffer from limitations in practical application due to low accuracy and efficiency compared to the requirements for base station settings of deployment sites, especially in dense urban environments. In this paper, we propose a mmWave pathloss modeling method for dense urban environment based on deep learning, which has attracted much attention recently, and an input image generation algorithm based on 3D map data. The proposed model training algorithm is based on meta-learning which can secure high prediction accuracy even when a sufficient amount of training data is unavailable. The experimental results show a superior performance over the CNN models trained by using 2D input images and 3D input images without meta-learning.

※ 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학 지원사업의 연구결과로 수행되었습니다(2017-0-00096).

• First Author : School of Computer and Information Engineering, Kwangwoon University, ubinjin2@naver.com, 학생회원

° Corresponding Author : School of Computer and Information Engineering, Kwangwoon University, hlee@kw.ac.kr, 종신회원

* School of Computer and Information Engineering, Kwangwoon University, zx8635@gmail.com

논문번호 : 202111-325-B-RU, Received November 26, 2021; Revised November 29, 2021; Accepted November 29, 2021

I. 서 론

밀리미터파 통신은 5G 이동 통신 시스템을 위한 핵심 기술 중 하나이다. 밀리미터파는 고 대역 통신의 특성상 더 작게 산란이 적고 회절성이 낮은 대신 LoS/NLoS여부에 의한 영향을 크게 받는다^[1]. 이로 인해 경로 손실량이 전파 환경에 의한 영향을 많이 받기 때문에 수신 강도의 예측이 쉽지 않다.

경로 손실 예측은 경로 손실 모델링을 기반으로 하는데, 기존의 대표적인 경로손실 모델링 방법으로는 경험적 방법^[2,3], 결정적 방법^[4,5] 및 머신러닝 기반 방법^[6-9]의 세 가지가 있다. 그 중 경험적 방법은 송신기(Tx)와 수신기(Rx) 사이의 거리를 기반으로 고정된 함수의 매개변수 값을 통계적으로 구하고 이를 기반으로 경로 손실 예측값을 계산한다. 경험적 모델의 매개 변수값은 특정 시나리오에서 수집된 측정 데이터를 기반으로 결정되어야 하므로 새로운 시나리오에 적용 시 예측 정확도가 감소할 수 있다.

결정적 방법으로는 3차원 광선 추적 방법이 있으며 물리적 광학 시뮬레이션을 기반으로 한다. 이 방식은 Tx-Rx의 설정값, 건물 구조의 물질에 대한 특성과 같은 자세한 전파환경을 구성하는 매질 관련 정보가 필요하다. 실제 상황에서는 이러한 정보가 거의 제공되지 않기 때문에 현장 적용 시 예측 정확도가 낮아질 수 있고 계산량 또한 과도하여 사용이 제한적이다.

머신러닝 기반의 경로손실 모델링은 실측 데이터를 기반으로 한 회귀분석 문제로 다루어진다. 그러나 머신러닝 기반의 모델링은 입력 전처리, 특징추출에 있어서 어느 정도의 도메인 지식을 요구하게 되며 처리과정에서도 많은 계산량이 요구될 수 있는 단점이 있다^[8,9].

딥러닝은 머신러닝이 한 단계 더 진화한 형태로 특징추출 자체도 학습을 통해 자동적으로 이루어지도록 한다. 일례로 논문^[10]에서는 각 Tx 및 Rx 위치 쌍에 대한 2D 지도 기반의 전파환경 정보가 인코딩된 이미지와 Convolutional Neural Network(CNN)을 이용하여 경로 손실 예측 모델을 학습시킬 수 있음을 보여 주었다.

머신러닝이나 딥러닝 기반의 경로 손실 모델이 새로운 지역에 대해서도 만족할 만한 성능(일반화 성능)을 보이기 위해서는 다양한 지역과 다양한 환경에서 실측된 데이터가 학습에 사용되어야 한다^[11]. 그러나 아직 28GHz 대역을 사용하는 기지국망이 충분히 확보되지 않아 실측 데이터 확보가 어려운 국내 도심지 환경의 경우, 기존의 학습 방법으로는 정확도가 높

은 딥러닝 기반의 경로손실 모델의 학습에 현실적인 어려움이 많다.

본 논문에서는 메타러닝을 적용한 도심지내 3D-CNN 기반 5G 밀리미터파 경로 손실 예측 모델을 제안한다. 메타러닝은 적은 데이터로 모델을 훈련하더라도 추가적인 태스크에 대해서 범용적인 일반화를 가능하게 하므로 적합한 학습 방법으로 판단 되었다^[12]. 제안하는 모델은 기존의 방법으로 학습시킨 경로 손실 예측 모델에 대해 높은 수준의 예측 성능을 달성한다. 본 논문의 구성은 다음과 같다. II절에서는 3D-CNN 기반 경로 손실 모델과 메타러닝의 관련 연구를 제공하고 III절에서는 제안하는 메타러닝 기반 경로 손실 모델 및 입력 이미지 생성 알고리즘을 설명한다. IV절에서는 실험 결과를 보이고 구체적으로 분석한다. 마지막으로 V절에서는 결론과 향후 연구 계획을 제시한다.

II. 관련 연구

2.1 CNN 기반의 경로손실 모델

논문^[10]은 교외지역에서의 밀리미터파 경로 손실 모델링을 위해 CNN 기반 경로 손실 모델과 위 모델의 학습을 위해 필요한 정보들을 제공하는 Enhanced Local Area Multi-scanning(E-LAMS) 알고리즘을 제안한다. E-LAMS 알고리즘은 건물과 도로를 포함하는 2D 구글 지도 이미지에서 각 Tx 및 Rx 위치 쌍간의 경로 손실 환경에 대한 정보를 추출한다. 이 E-LAMS 알고리즘을 통해 추출된 이미지들은 제안된 CNN 기반 경로 손실 모델의 입력값이 된다. 경로손실 모델은 기본 CNN 모델에 각 Rx당 4개의 지향성 안테나의 경로 손실 값을 예측하기 위한 4개의 서브네트워크들과 특징 공유 계층(Feature-Sharing Layer)이 추가된 형태이다.

본 논문에서는 상대적으로 건물들의 높이가 일정하지 않은 도심지에서의 경로 손실 환경에 대한 정보를 추출할 수 있도록 최적화된 3D-LAMS 알고리즘과 이를 입력값으로 사용할 수 있도록 제작된 3D-CNN 기반 경로 손실 모델을 제안한다. 자세한 설명은 섹션 III.1에서 진행한다.

2.2 다중 태스크를 활용한 메타러닝

논문^[12]는 심층신경망의 메타러닝을 위한 알고리즘을 제안한다. 이 논문에서 제안된 알고리즘은 분류, 회귀, 강화 학습 등 다양한 학습 문제에 적용 가능하다. 메타러닝의 목표는 적은 수의 학습 데이터를 사용

하면서도 다양하고 새로운 학습 태스크에 대한 문제를 해결하는 것이다. 이전의 머신러닝 학습 알고리즘이 수많은 샘플을 활용해서 오랜 기간동안 학습 시켰던 것과는 다르게 인간은 새로운 컨셉이나 기술을 더 빠르고 적은 샘플로도 효율적으로 학습할 수 있다. 이를 모사하기 위해서 메타러닝 모델의 파라미터는 적은 양의 훈련 데이터셋을 가진 새로운 태스크에 대해서 적은 학습 단계를 거치더라도 해당 태스크에 대해 우수한 일반화 성능을 가져야 한다. 그러면서도 최종적으로 여러 태스크에 대해서 민감하게 반응하며 최적의 일반화 성능을 가질 수 있어야 한다. 논문¹²⁾에서 제안하는 메타러닝 알고리즘은 기존에 연구된 알고리즘보다도 이점을 가진다. 우선 메타러닝을 위해 추가적으로 파라미터의 수를 늘릴 필요가 없기 때문에 적용이 용이하며 특정 모델 구조에 한정적이지 않다. 즉, 경사 기반 학습이 가능한 어떤 모델이든 적용이 가능하다. 또한 적은 수의 학습 데이터로도 빠른 적응이 가능하며 최대 성능을 발휘할 수 있다. 본 논문에서는 이러한 메타러닝의 이점을 활용하여 실측 데이터 확보가 어려운 국내 도심지 환경의 밀리미터파 경로 손실 모델 연구에 적용하였다.

III. 3D-CNN 경로 손실 모델

3.1 3D-LAMS 알고리즘

3D-LAMS(Local Area Multi-line Scanning)는 2D 기반의 E-LAMS, LAMS^[13], DE-LAMS^[14] 알고리즘을 3D 기반으로 확장시킨 것이다. 도심지는 교외 지역보다 건물들의 높이와 크기의 편차가 크기 때문에, 밀집 도심지 환경에서의 경로 손실 예측에 있어서 건물들의 크기와 모양, 높이에 대한 정보의 중요성이 매우 크다. 본 논문에서는 3D 지도 데이터로부터 CNN 기반 경로손실 모델의 입력 이미지 데이터를 생성하는 3D-LAMS 알고리즘을 제안한다.

3D-LAMS 알고리즘은 Tx와 Rx 사이의 공간에 다수의 가상 스캔평면을 배치하고 각 스캔평면과 3D 지도 데이터의 교차면 상의 데이터를 수집하여 2D 이미지를 생성하고 이들을 이어서 3D-LAMS 이미지를 최종적으로 생성한다. 그림 1에서와 같이 3D-LAMS 이미지는 Tx와 Rx를 연결하는 직선의 상하좌우 일정 거리 주변 공간 내에 존재하는 건물의 유무와 위치, 크기, 모양에 대한 정보를 내포하게 된다.

그림 3은 3D-LAMS 알고리즘의 의사 코드이다.




그림 1. 3D-LAMS 예시
Fig. 1. 3D-LAMS example




그림 2. 위에서 본 3D-LAMS 단면(위)과 스캔 평면(아래)
Fig. 2. 3D-LAMS viewed from above (top) & A scan plane (bottom)

Algorithm 1 3D-LAMS Algorithm

Input:

- GPS locations of Tx and Rx
- Size of a 3D-LAMS image: (w, h, d)
- Rasterized 3D map image M_R

Output:

A 3D-LAMS image

1. Divide the interval between Tx and Rx by d , P_{1-d}
 2. Determine the slope S of a straight line perpendicular to the line between Tx and Rx and parallel to the XY plane
 3. Make empty 3D-array, $A[w][h][d]$
 4. **for** $i = 1$ to d **do**
 5. Make scan plane SP_i (center: P_i , size: $w \times d$, slope: S and perpendicular to the XY plane)
 6. Copy SP_i to $A[i][i]$
 7. **end for**
 8. Save A as a 3D-LAMS image
-

그림 3. 3D-LAMS 알고리즘
Fig. 3. 3D-LAMS Algorithm

3.2 3D-CNN 모델 구조

제안하는 모델은 3D-LAMS 이미지를 입력 이미지로 사용하는 CNN 모델로서 출력값은 예측 신호 세기이다. 제안하는 CNN 모델 구조는 다수의 합성곱 계층 및 완전 연결 네트워크 계층을 포함하며, 합성곱 연산산을 통해 입력된 이미지로부터 중요한 특징이 추출되는데, 제안하는 모델에서는 이 과정에서 풀링 과정을 제외하였다. 일반적인 CNN 모델의 풀링 계층은 신경망의 파라미터 수를 줄이고 학습 시간을 단축시키며 과적합을 방지하는 효과를 제공하지만 정보의 손실을 초래할 수 있다. 3D-LAMS 이미지는 원 이미지의 단순화된 흑백 이미지로 볼 수 있으므로 추가 단축화 기능이 필요하지 않을 것으로 판단되어 제안하는 모델에서는 풀링 계층을 제외한다.

최종 합성곱 계층의 출력 이미지, 즉 3D 특징맵은 Tx-Rx 간 거리와 같은 스칼라 값과 결합(concatenate)되어 완전 연결망 계층의 입력 벡터로 주어진다. 완전 연결 망은 비선형의 경로 손실 함수를 근사화 하기 위한 2개의 은닉 계층 및 출력계층으로 구성되며, 활성화 함수로는 ReLU가 사용된다. 아래 표 1과 그림 4는 제안하는 CNN의 레이어 구조이며, 모델 파라미터는 실험적으로 가장 우수한 성능을 보이는 값으로 정한 값이다.

그림 4에서 볼 수 있듯이 3차원 입력 이미지는 세 개의 3D 합성곱 레이어를 거치게 된다. 이 과정에서 합성곱 계층은 Tx와 Rx사이의 건물의 배치와 높이와

표 1. 3D-CNN 경로 손실 모델 파라미터
Table 1. 3D-CNN Path Loss Model Parameters

Number of Convolution layer	1st	2nd	3rd
Input size	20, 20, 20	9, 9, 9	5, 5, 5
Input channel	1	80	20
Output size	9, 9, 9	5, 5, 5	4, 4, 4
Output channel	80	20	5
Kernel size	4, 4, 4	2, 2, 2	2, 2, 2
Stride size	2	2	1




그림 4. 3D-CNN 경로 손실 모델 네트워크 구조
Fig. 4. 3D-CNN Path Loss Model Network Structure

같은 전파 환경의 공간적인 특징을 추출하고, 경로 손실에 영향을 주는 특징을 파악하게 된다.

3.3 메타러닝 기반 학습

본 논문에서는 각 송신 안테나의 서로 다른 설정 값, LoS/NLoS 같은 Tx의 전파를 받은 수신한 Rx의 서로 다른 위치적인 특성들을 수용하는 범용적인 모델 일반화를 위해서 메타러닝 기반의 학습 방법을 사용하였다. 메타러닝의 장점은 새로운 환경이 주어졌을 때 이전에 비해 빠르게 학습하고 좋은 일반화 성능을 낼 수 있게 하며 적은 데이터로도 효율적인 학습을 할 수 있다는 것이다. 경로손실 모델 학습의 경우, 실측 지역(기지국), 기지국 운영 형태(morphology), Tx-Rx 거리 등을 기준으로 다수의 메타러닝 태스크들로 구성되는 메타러닝 기반 학습의 적용이 가능하다.

그림 5는 본 논문에서 제안하는 메타러닝 기반의 학습 의사 코드이다. 본 논문에서는 데이터 셋의 각 실측치가 Tx의 PCI (Physical Cell ID)에 따라 구분이 가능하므로 이를 기반으로 다수의 메타러닝 태스크로 구성이 가능하다. 특히, 각 PCI에 해당하는 기지국은 서로 다른 전파 특성을 갖고 있고 소수의 학습 데이터만을 포함하고 있어 메타러닝 기법의 적용에 적절한 것으로 분석된다.

Algorithm 2 Meta Learning with 3D Path Loss CNN

1. Separate Dataset for "Scenario 13":
 $Test[PCI1, PCI3]$,
 $Train[PCI2, PCI4, PCI5, PCI6, PCI7]$
2. Separate $Train \rightarrow tasks$ [Task1: PCI2, Task2: PCI4, ... , Task5: PCI7]
3. Initialize Meta learner M 's weights
4. Set weights array W to 0
4. for $iter$ times do
 - 5.1. Initialize task learner T 's weights to M 's weights
 - 5.2. for $task$ in $tasks$:
 - 5.2.1. Train a $task$ for $inner$ times
 - 5.2.2. $W += T$'s weights
 - 5.3. end for
 - 5.4. Update M 's weights $\leq M$'s weights + $W * Beta / len(tasks)$
6. end for
7. Meta learner M train $Train Epoch$ times

그림 5. 메타러닝 알고리즘
Fig. 5. Meta-learning Algorithm

태스크 학습을 위해 선언된 모델 T 가 각 태스크에 대한 학습을 진행하여 구한 그레디언트들은 비율 β 를 곱하여 합산된 다음 메타 러너 M 의 가중치를 업데이트 하게 된다. 위의 과정을 여러 번 수행한 M 은 태스크에 대해 일반화 성능을 높게 가지게 되며 과적합을 피할 수 있게 된다. 추가적으로 M 을 전체 데이터셋에 대하여 미세조정을 진행하면 제공받은 데이터셋 내에서의 예측 성능을 더 높일 수 있게 된다.

메타러닝 방식을 사용한다면 모델은 앞서 예를 들었던 각 메타러닝 태스크에 대해서 모두 일반화되고, 각 태스크에 대해서는 높은 성능을 가지게 된다.

IV. 실험

실측 데이터는 강남 맵 데이터 내 가로 300m, 세로 300m 이하 범위를 갖는 구역에서 7개의 5G 밀리미터파 송신기를 설치하고, 차량을 이동하며 측정된 750개의 위치 및 신호 세기(RSRP) 데이터이다. 7개의 송신기는 서로 다른 위치와 설정 값을 갖는다. 실측 데이터는 각 기지국 별로 식별자(Physical Cell ID, PCI), 경도, 위도, 안테나 높이, 방향, 다운틸트를 포함하고 있으며, 각 Rx 데이터는 측정 당시 시간과 GPS 좌표 위치, 수신 신호 세기 등을 포함한다. 그림 6는 실측 수신 신호 강도를 지도상에 표시한 것이다.

데이터셋은 학습 데이터와 테스트 데이터의 비율이 7:3에 접근하도록 PCI를 기준으로 분류할 수 있는 조합을 선정하여 총 9개의 시나리오를 생성한 후, 이 중에서도 LoS 분포 비율을 고려하여 50%에 근접한 7개의 시나리오를 표 2와 같이 최종적으로 선정했다.




그림 6. 실측 신호 세기
Fig. 6. Measured RSRP Value

표 2. 선정된 시나리오 정보
Table 2 Selected Scenarios Information

Scenario	Test PCI	Test rate(%)	Los rate(%)
S1	1, 3	25.8	55
S2	1, 4	31.3	60
S3	1, 6, 7	25.8	56

3D-CNN 모델은 III.2절에서 설명한 구조를 사용했으며 성능 비교 대상으로 2D-CNN 모델을 사용했다. 3D-LAMS 이미지를 생성하기 위해 강남 지역 맵 데이터를 이용하였으며, 지형, 도로, 건물 레이어 맵 데이터를 이용하여 지형 및 건물에 해당하는 래스터 그래픽스 형식의 3D 맵 데이터를 생성한 후 그림 3의 3D-LAMS 알고리즘을 적용했다. DE-LAMS 이미지는 3D-LAMS 알고리즘의 스캔 평면 대신 스캔 라인을 적용하여 높이 정보를 제외한 2D 데이터만을 수집하는 방식으로 생성하였으며 3D-LAMS 이미지와 DE-LAMS 이미지의 크기는 각각 20x20x20 픽셀과 40x40 픽셀이다.

성능 비교 실험은 표 2의 시나리오를 바탕으로 DE-LAMS를 적용한 2D-CNN 모델과 3D-LAMS를 적용한 3D-CNN 모델, 메타러닝과 3D-LAMS를 적용한 3D-CNN 모델을 이용하여 진행하였다.

그림 5의 Algorithm 2의 파라미터 값들은 표 4의 내용과 같다.

실험 결과 2D-CNN 경로손실 모델의 RMSE 평균

표 3. 메타러닝 파라미터 정보
Table 3. Meta-Learning Parameter Information

Hyper-parameters	Settings
Beta	0.007
Inner	60
Outer	65
Epochs	55

표 4. 3D-LAMS 이미지와 DE-LAMS 비교 실험
Table 4. Experiment by Comparing 3D-LAMS Images and DE-LAMS Image

LAMS methods	Meta-Learning	Testing Scenarios			
		S1	S2	S3	Avg
DE-LAMS	Unapplied	6.94	7.23	7.54	7.24
3D-LAMS	Unapplied	6.85	6.69	6.58	6.71
3D-LAMS	Applied	6.28	6.00	6.54	6.27

이 3D-CNN 경로손실 모델의 RMSE 평균에 비해 0.53 dBm 더 낮았으며, 이를 통해 2D-CNN 경로손실 모델보다 3D-CNN 경로손실 모델이 도심지에 더 적합하다는 것을 확인할 수 있었다. 또한 메타러닝을 적용한 모델의 RMSE 평균이 메타러닝 미적용 모델에 비해 0.44 dBm 더 낮았다. 메타러닝이 적용되고 3D 이미지를 사용한 모델의 RMSE 평균은 2D 이미지를 사용한 모델보다 0.97 dBm 더 낮은 것을 확인할 수 있다.

위 실험의 결과는 도심지에서는 메타러닝이 적용된 3D-CNN 경로 손실 모델이 기존의 CNN기반 경로 손실 모델들보다 적합함을 나타낸다. 다음은 표 4의 S2에서 진행된 실험결과를 위에서부터 C₂, C₃, C_{ME}로 정의하여 경로 손실 트렌드를 비교 분석하였다.

그림 7에서는 C_{ME}, C₃, C₂의 예측값과 실측값을 비교하였다. 각 케이스가 실측값 트렌드를 잘 따르고 있는지 그림 7과 아래 표 5를 통해 확인할 수 있다. C₃와 C₂의 10 dBm 미만 절대 오차는 85.57%로 동일하지만 4 dBm 미만 절대 오차는 47.36%와 38.14%로 9.22% 차이가 난다. 따라서 C₃가 C₂보다 더 좋은 결과를 보인다. C_{ME}의 2 dBm 미만 절대 오차는 28.35%

로 C₃보다 트렌드를 잘 따라가는 모습을 보였고 10 dBm 미만 절대 오차 역시 89.69%로 더 좋은 성능을 보였다. 이러한 예측 성능은 기존의 딥러닝 기반 모델이나 결정적 모델의 교외지역에서의 예측 성능에 비해 RMSE 기준 약 3dB 정도 떨어지는 수준이지만 밀집 도심지 전파 환경의 복잡도를 감안하면 적정수준인 것으로 판단되며, CI 모델과 같은 경험적 모델의 교외지역에서의 성능에 비해서도 월등한 수준이다^[4].

V. 결론

본 논문에서는 메타러닝을 적용한 3D-CNN 기반의 도심지내 5G 밀리미터파 경로 손실 예측 모델을 제안하였다. 실험 데이터 수가 적고 PCI 별 특성이 달랐던 실험 환경에서의 메타러닝의 적용은 기존의 학습 방법보다 더 높은 예측 성능을 이끌어 냈음을 확인할 수 있다. 또한 건물의 높이가 다양한 도심지 환경에서는 논문^[4]의 DE-LAMS의 적용 보다는 본 논문에서 제안하는 3D-LAMS 적용이 더 높은 예측 성능을 보였다. Tx와 Rx 사이 공간 내에서 건물의 유무와 위치, 크기, 모양, Tx와 Rx 사이의 거리와 같은 인자들은 도심지에서 경로 손실 값을 결정하는 데 중요한 요소임을 실험을 통해 확인할 수 있었다. 이 외에도 경로 손실 모델링에 자주 사용되었던 3차원 광선 추적 방법과 딥러닝 기반의 모델링 방법을 적절히 혼용하여 함께 사용하는 연구가 진행될 수 있을 것이다. 추후 추가적인 맵 데이터와 실측 데이터가 제공된다면 메타러닝의 장점을 활용하여 모델의 성능을 증가시킬 수 있을 것으로 기대된다.

References

- [1] F. Al-Ogaili and R. M. Shubair, "Millimeter-wave mobile communications for 5G: Challenges and opportunities," in *Proc. IEEE Int. Symp. Antennas Propag. (APSURSI)*, pp. 1003-1004, Jun. 2016.
- [2] K. Haneda, J. Zhang, L. Tan, G. Liu, Y. Zheng, H. Asplund, J. Li, Y. Wang, D. Steer, and C. Li, "5G 3GPP-like channel models for outdoor urban microcellular and macrocellular environments," in *Proc. IEEE 83rd VTC Spring*, pp. 1-7, May 2016.
- [3] J. Ko, Y.-J. Cho, S. Hur, T. Kim, J. Park, A. F. Molisch, K. Haneda, M. Peter, D.-J. Park,

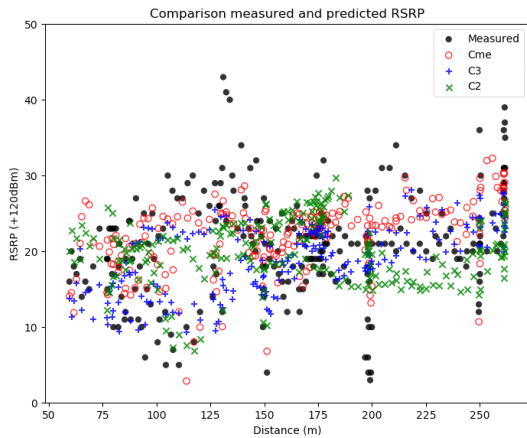


그림 7. 실측, C_{ME}, C₃, C₂, RSRP 그래프
Fig. 7. Measured, C_{ME}, C₃ and C₂ RSRP graph

표 5. 실험별 절대 오차 수치
Table 5. Absolute error values per experiment

Absolute Error	C _{ME}	C ₃	C ₂
	Rate (%)		
<2 dBm	28.35	19.07	17.52
<4 dBm	50.51	47.36	38.14
<10 dBm	89.69	85.57	85.57

- and D.-H. Cho, "Millimeter-wave channel measurements and analysis for statistical spatial channel model in in-building and urban environments at 28 GHz," *IEEE Trans. Wirel. Commun.*, vol. 16, no. 9, pp. 5853- 5868, Sep. 2017.
- [4] D. He, B. Ai, K. Guan, L.Wang, Z. Zhong, and T. Kurner, "The design and applications of high-performance ray-tracing simulation platform for 5G and beyond wireless communications: A tutorial," *IEEE Commun. Surv. Tuts.*, vol. 21, no. 1, pp. 10-27, 1st Quart., 2019.
- [5] K.-G. Lee, S.-J. Oh, J.-S. Woo, and K.-T. Lee, "Propagation characteristics of suburban environments using hybrid ray-tracing simulation," in *Proc. IEEE 84th VTC-Fall*, pp. 1-5, Sep. 2016.
- [6] S. Yang and H. Lee, "Feature extraction for neural network wave propagation loss models from eld measurements and digital elevation map," *IEICE Trans. Electron.*, vol. 82, no. 7, pp. 1260-1266, 1999.
- [7] E. Ostlin, H. Zepernick, and H. Suzuki, "Macrocell path-loss prediction using artificial neural networks," *IEEE Trans. Veh. Technol.*, vol. 59, no. 6, pp. 2735-2747, Jul. 2010.
- [8] Y. Zhang, J. Wen, G. Yang, Z. He, and J. Wang, "Path loss prediction based on machine learning: Principle, method, and data expansion," *Appl. Sci.*, vol. 9, no. 9, p. 1908, May 2019.
- [9] I. Popescu, I. Nafornita, and P. Constantinou, "Comparison of neural network models for path loss prediction," in *Proc. IEEE Int. Conf. Wirel. Mob. Comput., Netw. Commun.*, pp. 44-49, Aug. 2005.
- [10] H. Cheng, S. Ma, and H. Lee, "CNN-based mmWave path loss modeling for fixed wireless access in suburban scenarios," *IEEE Ant. Wirel. Propag. Lett.*, vol. 19, no. 10, pp. 1694-1698, Oct. 2020.
- [11] S. P. Sotiroudis, S. K. Goudos, and K. Siakavara, "Deep learning for radio propagation: Using image-driven regression to estimate path loss in urban areas," *ICT Exp.*, vol. 6, no. 3, pp. 160-165, Sep. 2020.
- [12] C. Finn, P. Abbeel, and S. Levine "Model-agnostic meta-learning for fast adaptation of deep networks," *ICML'17*, vol. 70, pp. 1126-1135, Aug. 2017.
- [13] H. Cheng and H. Lee, "A practical method for indoor path loss modelling based on CNNs," *IET Microw., Ant. & Propag.*, Jan. 2019.
- [14] H. Cheong, S. Ma, H. Lee, and M. Cho, "Millimeter wave path loss modeling for 5g communications using deep learning with dilated convolution and attention," *IEEE Access*, vol. 9, pp. 62867-62879, Apr. 2021.

진 우 빈 (Woobeen Jin)



2016년 3월~현재 : 광운대학교
컴퓨터정보공학부 학사과정
<관심분야> 유무선네트워크, 인
공지능
[ORCID:0000-0003-2013-8616]

김 현 진 (Hyeonjin Kim)



2016년 3월~현재 : 광운대학교
컴퓨터정보공학부 학사과정
<관심분야> 인공지능
[ORCID:0000-0003-3494-8839]

이 혁 준 (Hyukjoon Lee)



1987년 : 미시간대학교 컴퓨터과
학과 졸업

1989년 : 시라큐스대학교 컴퓨터
과학과 석사

1993년 : 시라큐스대학교 컴퓨터
과학과 박사

<관심분야> 유무선네트워크, 인
공지능, 머신러닝

[ORCID:0000-0001-7624-2020]