

# 도시협곡지형에서 UAV와 기지국 간의 통신을 위한 메타러닝 기반 통신경로 차단 예측

강정호\*, 반동현\*, 최진혁\*, 서효운  
 광운대학교 전자통신공학과

ttomas11@kw.ac.kr, dhban@office.kw.ac.kr, chlwlsgur801@kw.ac.kr, hywoonseo@kw.ac.kr

## Meta Learning-Based Blockage Prediction for Communication between UAV and Base Station in Urban Canyon

Jeongho Kang\*, Donghyeon Ban\*, Jinhyouk Choi\*, Hywoon Seo  
 Dept. Electronics and communication Eng., Kwangwoon Univ.

### 요약

본 논문은 통신이 불리한 도시 협곡 지형에서 UAV(Unmanned Aerial Vehicle)와 기지국 간 통신이 Sub-THz의 고주파 대역에서도 원활하게 진행할 수 있도록 하기 위한 방법에 대한 연구이다. UAV와 기지국 간의 통신경로가 건물로 인해 차단되는 상황을 메타러닝을 이용해 미리 예측할 수 있는 시스템을 구현하였다.

### I. 서론

현재 6G에서 사용 예정인 Sub-THz 주파수 대역은 90~300GHz로 매우 높은 주파수 대역에 속한다. 해당 주파수 대역에서의 통신은 빠른 통신속도가 보장되어 있다. 그러나 고주파의 특성 상 직진성이 강하고 굴절 및 회절에 취약하다는 단점도 동시에 존재한다.

6G 통신을 사용하는 주요한 응용분야에는 UAV 산업이 있다. 한편, 도시에는 수많은 고층 건축물들이 건축되고 있으며, 이들로 인해 많은 도심지역에 도시 협곡(urban canyon)이라는 인공적인 지형이 생성되고 있다. 이러한 지형을 UAV가 지나갈 때, 기지국과의 통신경로는 건축물로 인해 높은 확률로 막히게 된다.


메타러닝은 새로운 태스크를 빠르게 학습하기 위해 제시된 방법이다. 도시 협곡 지형의 형태는 무수히 많은 형태로 나타날 수 있다. 따라서 도시 협곡 지형에서의 통신 시나리오 각각을 하나의 태스크로 바라보면, 수많은 태스크가 생성될 가능성이 존재한다. 이렇듯 무작위성이 큰 상황의 예측을 원활하게 진행하기 위해서는 각 상황에 빠르게 적응하여 예측해야 할 필요가 있으며, 메타러닝은 이에 부합하는 학습기법이다

본 논문에서는 이러한 도시 협곡 지형에서 Sub-THz 대역의 고주파 신호를 이용해 UAV와 기지국 간에 통신을 할 때 건물로 인해 발생할 통신경로 차단현상을 사전에 예측하는 시스템을 메타러닝을 통해 구현하였다.

### II. 본론

본 연구의 전체적인 과정은 다음과 같다. 먼저 UAV와 기지국 간 통신 상황 시나리오를 토대로 시뮬레이션을 진행하고 이 과정에서 수신전력 데이터를 추출한다. 이후, 추출된 데이터들을 메타러닝 기법을 사용해 학습시키고 최종적으로 통신경로 차단 예측을 진행한다.

시나리오는 정해진 직사각형 구역 내부에 약 12개의 랜덤한 크기의 직육면체 건물들을 생성한다. 직육면체의 면적 및 크기는 서울특별시 건축물 정보의 확률 밀도 함수를 바탕으로 랜덤하게 추출되었다.



[그림 1] 서울특별시 건축물의 면적(좌)과 높이(우) PDF


건물 지형 주위에 랜덤한 타원 궤도를 따라 UAV가 1바퀴 이동한다. 타원 궤도 외부에 기지국을 위치하며, UAV는 기지국과 동일한 높이에서 비행한다고 가정한다. 또한 UAV와 기지국의 통신은 가시경로로만 이루어지며, 반사 및 산란된 성분은 고려하지 않는다. 만약 가시경로 상의 통신경로가 건물에 의해 막히면 통신 불능으로 판단한다. 채널의 상태는 AWGN으로 가정하며 샘플링 주기는 0.1s로 설정하였다. 그 외 시나리오에 사용된 전파, 전력 등에 관한 데이터는 아래와 같다.

내용	값
주파수 대역	100GHz
Beam Shape	Rectangular Pencil Beam
Noise Power	$N_0 = kT\Delta W$
k(Boltzmann Constant)	$1.381 \times 10^{-23}$
T(온도)	290K
$\Delta W$	10GHz
수신전력 ( $P_r$ )	$P_r = P_t \frac{G_t G_r \lambda^2}{(4\pi d)^2}$
송신전력 ( $P_t$ )	50W
수신 안테나 Gain( $G_t$ )	25dB
송신 안테나 Gain( $G_r$ )	1dB

[표 1] 시나리오 기타 세부 데이터

\* 본 논문은 세 사람이 동일한 기여를 했음을 밝힙니다.

효율적인 연산을 위해 2D 평면 상으로 정사영을 시킨 후 시뮬레이션을 진행했으며, 최종적으로 [그림 4]와 같은 수신전력 데이터를 얻을 수 있다. 아래 그림에서 적색 선이 기지국과 UAV 간의 통신경로, 타원 내부 청색 선이 건물을 의미한다.



[그림 2] 최종 시뮬레이터(좌)와 수신전력 데이터(우)

위 데이터를 활용하여 메타러닝을 진행한다. 본 논문에서 사용된 MAML(Model Agnostic Meta-Learning)은 대부분의 AI 모델에 적용가능한 메타러닝 기법으로, 태스크가 들어왔을 때, 그 태스크가 빠르게 적응해 예측을 진행할 수 있도록 가중치를 업데이트하여 파라미터의 시작점을 바꾸는 방식으로 학습 및 예측이 진행된다. 즉, MAML 은 소량의 데이터를 이용해 빠르게 학습하고, 가중치를 업데이트하여 파라미터의 위치를 변경하는 메타러닝 기법이다. 추가로 기본 모델은 LSTM 레이어의 구조를 사용했다.


```

Algorithm 1 Meta - Learning Pseudocode
1 : procedure Meta-Learning ( $D, M, T$ )
2 : Input:  $D$ : Meta-data,  $l_{meta}$ : Meta-loss,  $M_L$ : LSTM model,  $T$ : Sample batch of task
3 : Output:  $\theta_M$  - Meta-model weights,  $M_{meta}$  - Meta-model
4 : randomly initialize  $\theta, i$ 
5 : for each task  $T_i$  in  $D$  do
6 :    $D_{train}, D_{test} \leftarrow \text{SplitData}(T_i)$ 
7 :    $\theta_M^{(i)} \leftarrow \text{Train}(D_{train}, \theta_M^{(i-1)})$ 
8 :    $\theta_M^{(i)} \leftarrow \text{FineTune}(M, \theta_M^{(i)}, D_{test}^{(i)})$  ← update initial weights
9 :    $M_{meta} \leftarrow \text{Update}(\theta_M^{(i)})$ 
10 : end for
11 : return  $\theta_M, M_{meta}$ 
12 : end procedure
13 : procedure FineTune( $M, \theta, D$ )
14 :   Finetuning meta weights  $\theta_M^{(i)}$  using task specific weights and model
15 :   return Fine tuned meta weights  $\theta_M^{(i)}$ 
16 : end procedure
  
```

[그림 3] Meta-Learning Pseudo Code

시뮬레이션을 통해 약 200 개의 수신전력 태스크를 추출하고, 메타러닝을 이용해 학습을 진행한다. 임의로 선택된 태스크에서 시작점이 무작위인 10 개의 시퀀스 데이터들을 추출하고 이 데이터셋으로 학습을 진행한다. 초기 10 개의 시퀀스로 11 번째 시퀀스를 예측하고, 이후 2~11 번째의 시퀀스로 다음 12 번째 시퀀스를 예측하는, 피드백 방식을 사용하여 다음 시퀀스에 대한 예측을 진행한다.

아래 예측 결과는 MAML 을 사용한 모델과 사용하지 않은 pre-trained 모델 간의 비교이다. 50 번의 훈련 이후 20 개 데이터에 대한 예측을 진행하였다. Loss 는 유사한 형태로 감소하였지만, 정확도는 아래와 같이 차이 나는 것을 볼 수 있다.



[그림 4] MAML Model vs Pre-Trained Model


\* 본 논문은 세 사람이 동일한 기여를 했음을 밝힙니다.

실제 데이터(청색 그래프)와 각 모델을 50 번 훈련 후 예측한 그래프 간의 코사인 유사도를 계산한 결과는 MAML 을 사용했을 때 그렇지 않은 경우 보다 2 배 이상 성능이 좋게 나타남을 확인할 수 있다.

코사인 유사도	
$\cos(o, m_{k k=1,2}) = \frac{\sum_{i=1}^{20} o_i m_{ki}}{\sqrt{\sum_{i=1}^{20} o_i^2} \sqrt{\sum_{i=1}^{20} m_{ki}^2}}$	
실제 데이터: $o \in \mathbb{R}^{20}$ MAML( $m_1$ ), Pre-Trained( $m_2$ ) 모델 예측 데이터: $m_{k k=1,2} \in \mathbb{R}^{20}$	
MAML 사용 모델	Pre-trained 모델
<b>70.84%</b>	<b>35.16%</b>

[표 2] 모델 별 예측결과와 실제 결과의 유사도

최종적으로 모델을 사용하여 한 태스크에서 무작위 데이터가 주어졌을 때, 이후 10 개의 시퀀스를 아래와 같이 예측하는 것을 볼 수 있다. 녹색 영역 안에서 적색 선이 예측, 청색 선이 실제 데이터이다.



[그림 5] 10 개 sequence 에 대한 예측 결과

### III. 결론

본 논문에서는 메타러닝 기법을 활용하여 UAV 와 기지국 간 통신경로가 고층 건물로 인해 차단되는 것을 사전에 예측하는 방안을 제시하였다. 결과적으로 볼 때, 설계된 모델을 통한 예측은 잘 진행되었고, MAML 을 사용하였을 때 성능 개선이 확연하게 나타나는 것을 확인할 수 있었다. 본 논문의 통신경로 차단예측을 통해 고주파 대역의 통신에서의 신뢰성과 안정성을 보장받을 가능성이 높아질 수 있을 것으로 보인다.

### ACKNOWLEDGMENT

Put sponsor acknowledgment.

### 참 고 문 헌

- [1] Anders E. Kalør, Osvaldo Simeone, and Petar Popovski "Prediction of mmWave/THz Link Blockages through Meta-Learning and Recurrent Neural Networks", in IEEE WIRELESS COMMUNICATIONS LETTERS, VOL. 10, NO. 12, DECEMBER 2021
- [2] Tomislav Debogovic, Julien Perruisseau-Carrier, and Juraj Bartolic "Partially Reflective Surface Antenna With Dynamic Beamwidth Control", in IEEE ANTENNAS AND WIRELESS PROPAGATION LETTERS, VOL. 9, 2010