

지형 및 환경 패치 기반 다중입력 모델을 활용한 경로손실 예측

Multi-Input Model-Based Path Loss Prediction with Terrain and Environment Patches

이 동 엽

Dong-Yeob Lee

요 약

본 논문에서는 디지털 고도 지도와 토지피복도로부터 추출한 지형 및 환경 정보를 통합하여 경로손실을 예측하는 다중입력 합성곱 신경망 모델을 제안한다. 전파에 큰 영향을 미치는 지형적 요인과 환경적 요인을 동시에 반영하기 위해, 송신기와 수신기를 중심으로 한 64×64 픽셀의 2차원 공간 정사각형 패치를 생성하고, 전파경로가 패치의 0° 방향을 향하도록 회전 정렬 후, 채널 방향으로 결합하였다. 결합된 패치들은 거리, 주파수, 안테나 높이 등의 시스템 파라미터와 함께 모델의 입력으로 사용되었다. 제안하는 모델은 충청남도 홍성군에서 측정한 3.4 GHz 대역의 전파 환경 데이터를 이용하여 학습하였으며, 시험 데이터셋 기준 5.8044 dB의 RMSE(root mean squared error)를 달성하였다.

Abstract

This paper proposes a multi-input convolutional neural network model for path loss prediction that integrates terrain and environmental information extracted from digital elevation and land-cover maps. To simultaneously account for the terrain and environmental factors that strongly influence radio propagation, two-dimensional spatial square patches of 64×64 pixels centered at both the transmitter and receiver were generated and rotated such that the propagation path corresponded to the 0° direction and concatenated along the channel dimension. The concatenated patches were then combined with system parameters such as distance, frequency, and antenna height to form the inputs to the model. The proposed model was trained using 3.4 GHz propagation measurement data collected in Hongseong, Chungcheongnam-do, South Korea, and achieved a root mean squared error of 5.8044 dB on the test dataset.

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

I. 서 론

최근 드론 운용의 확산과 자율주행 시장의 급격한 성장, 그리고 5G 이동통신망의 고도화로 인해 민간 영역의 주파수 수요가 빠르게 증가하고 있다. 그러나 주파수 자

원은 한정되어 있으며, 이러한 상황은 군에서도 예외가 아니다. 민과 군은 동일한 주파수 대역을 시간적 및 공간적으로 분리하여 운용함으로써 상호 간섭을 최소화하고 있으나, 실제 전파환경에서는 지형과 인접 송·수신체계 등 복합적인 요인들로 인해 전파 간섭을 완전히 피하기

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

· Manuscript received November 10, 2025 ; Revised December 16, 2025 ; Accepted February 3, 2026. (ID No. 20251110-140)

· Corresponding Author: Dong-Yeob Lee (e-mail: f3483168@gmail.com)

는 어렵다. 이러한 간섭을 효율적으로 관리하기 위해서는 전파 특성을 정밀하게 예측할 수 있는 모델이 필요하며, 특히 경로손실의 정확한 예측은 전장 통신망의 설계와 주파수 자원 운용의 핵심 요소라 할 수 있다^{[1][2]}. 경로손실 예측을 위해 경험적 접근을 기반으로 제안된 전파모델들도 존재하나, 이는 특정 환경에 최적화되어 있다. 예를 들어 Okumura 및 Hata 모델은 도시 혹은 교외환경에서는 높은 신뢰도를 보이지만, 산악지형 및 해안지형에서는 낮은 신뢰도를 갖는다^{[3][4]}. 따라서, 지형기복, 식생분포, 인공구조물과 같은 요소가 전파의 회절, 산란, 차폐에 미치는 영향을 반영할 필요가 있다.

이러한 문제를 해결하기 위해 최근에는 인공지능(AI, artificial intelligence)을 이용하여 지형 정보와 환경 정보를 학습하는 시도가 활발히 이루어지고 있다. 예를 들어, 시스템 파라미터와 전파경로 정보를 기반으로 앙상블 모델인 랜덤 포레스트(RF, random forest) 또는 서포트 벡터 머신(SVM, support vector machine)을 이용하여 경로손실을 예측한다^{[5][6]}. 뿐만 아니라 환경 정보를 반영하기 위해 위성영상과 합성곱 신경망(CNN, convolutional neural network)을 활용하여 경로손실을 예측하기도 한다^{[7][8]}. 또한, 경로 프로파일이나 고도 지도를 이용하여 지형 정보를 일부 반영하기도 한다^{[9][10]}. 그러나, 경로 프로파일을 기반으로 하는 경우는 수신기(Tx)와 송신기(Rx) 주변의 지형 정보를 동시에 반영하기 어려우며, 지형 정보뿐만 아니라 환경 정보의 반영이 필요하다.

본 연구에서는 지형 정보와 환경 정보의 반영을 위해 Tx와 Rx 주변의 지형 및 환경 정보를 포함하는 2차원 패치를 학습하는 CNN 기반 경로손실 예측 모델을 제안한다. 제안하는 모델은 디지털 고도 지도(DEM, digital elevation map)와 토지피복도(LCM, land cover map)로부터 각각 64×64 픽셀의 정사각형 패치를 생성하며, 패치의 한 변은 실제 거리로 약 500 m다. 또한, 패치는 각각 Rx와 Tx를 중심으로 하며, 전파경로가 0° 방향을 향하도록 회전 정렬하여 전파 진행 방향에 대한 일관성을 확보하였다. 지형 정보 패치는 1개의 채널, 환경 정보 패치는 3개의 채널로 구성되며, Rx 중심과 Tx 중심인 두 패치를 채널 방향으로 결합한다. 2채널의 지형 정보 패치와 및 6채널의 환경 정보 패치는 CNN 블록들을 통해 특징을 추출

한 후, Tx와 Rx 간 거리, 주파수, 안테나 높이 등 시스템 파라미터와 결합되어 경로손실을 학습한다. 또한, 제안하는 모델의 예측 성능은 위성영상 기반 CNN 모델 및 환경 특성 이미지 기반 모델과 같은 기존 AI 기반 경로손실 예측 연구에서 보고된 성능과 비교하여 분석하였다^{[7][11]}. 제안하는 모델은 Tx와 Rx 주변의 국지적 지형 변화와 환경적 분포를 동시에 인식하며, 전파의 회절, 차폐, 반사와 같은 효과를 효과적으로 학습하도록 설계되었다.

II. 지형 및 환경 정보 기반 경로손실 예측

본 연구에서는 Tx와 Rx 간 경로손실을 예측하기 위해, 그림 1과 같이 시스템 파라미터와 함께 지형 및 환경 정보를 동시에 입력으로 받는 다중입력 CNN 모델을 제안

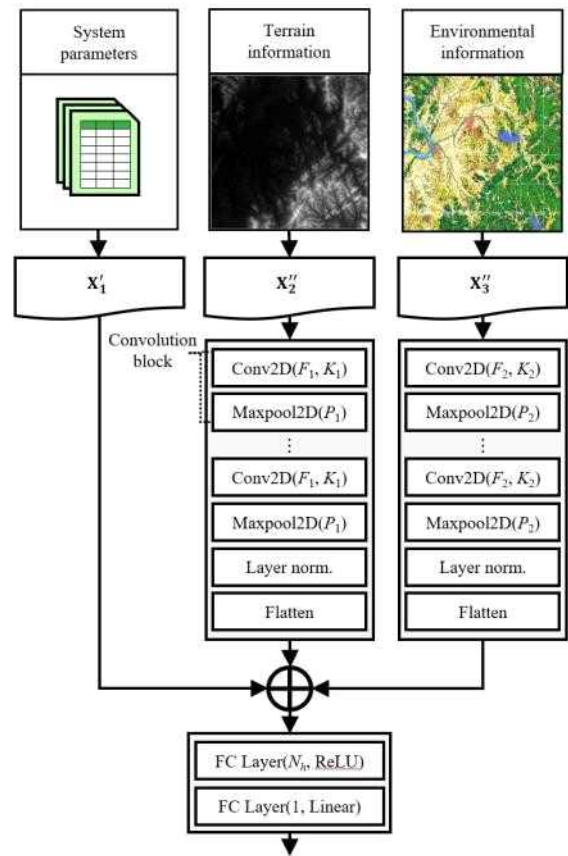


그림 1. 제안하는 모델의 구조
Fig. 1. Architecture of the proposed model.

한다. 입력은 거리, 주파수, 안테나 높이 등으로 구성되는 시스템 파라미터, DEM으로부터 생성한 지형 정보 패치, 환경부의 LCM으로부터 생성한 환경 정보 패치로 구성된다. 세 데이터는 각기 다른 특성을 가지므로, CNN과 정규화 과정을 통해 특징을 추출한 후 결합하여 학습된다.

2.1 시스템 파라미터

시스템 파라미터 X_1 는 식 (1)과 같다.

$$X_1 = [x_1^{(1)}, \dots, x_1^{(N)}]^T \in \mathbb{R}^{N \times 5} \quad (1)$$

여기서 N 은 전체 샘플 수를 나타낸다. n 번째 시스템 파라미터 벡터 $x_1^{(n)}$ 은 식 (2)와 같이 5가지 특징으로 구성된다.

$$x_1^{(n)} = [x_{1,1}^{(n)}, x_{1,2}^{(n)}, x_{1,3}^{(n)}, x_{1,4}^{(n)}, x_{1,5}^{(n)}]^T \quad (2)$$

여기서 $x_{1,1}^{(n)}$ 는 그림 2에 나왔듯이 Tx와 Rx 간 수평거리(m), $x_{1,2}^{(n)}$ 는 Rx의 해발고(m), $x_{1,3}^{(n)}$ 은 Tx와 Rx의 해발고 차이(m), $x_{1,4}^{(n)}$ 와 $x_{1,5}^{(n)}$ 은 Tx와 Rx의 안테나 이득(dBi)이다. 각 특징 열(column)별로 식 (3)과 같이 최소-최대 정규화를 수행하여 [0, 1] 범위로 스케일링된다.

$$x'_{1,k} = \frac{x_{1,k}^{(n)} - \min(x_{1,k})}{\max(x_{1,k}) - \min(x_{1,k})} \quad (3)$$

여기서 $x_{1,k}$ 는 $[x_{1,k}^{(1)}, \dots, x_{1,k}^{(N)}]^T$ 로, k 번째 특징을 나타내며, 시스템 파라미터에 대한 전체 샘플의 특징 열에 해당하는 열벡터를 의미한다. 이 과정을 통해 스케일링된 시




그림 2. 학습에 사용된 시스템 파라미터의 구성 예시
Fig. 2. Example of system parameters used for model training.

스템 파라미터 벡터 $x_1^{(n)}$ 을 얻을 수 있으며, 모델에 입력되는 시스템 파라미터 데이터셋 X'_1 은 식 (4)와 같이 표현된다.

$$X'_1 = [x_1'^{(1)}, \dots, x_1'^{(N)}]^T \in \mathbb{R}^{N \times 5} \quad (4)$$

이 과정을 통해 각 입력 변수는 동일한 스케일로 정규화되어, 지형 정보 및 환경 정보와 안정적으로 결합된다.

2.2 지형 정보 패치

Tx와 Rx 주변의 지형 정보를 반영하기 위해 시스템 파라미터 데이터셋 X'_1 과 동일한 샘플 인덱스를 갖는 지형 정보 패치 데이터셋을 생성한다. 지형 정보 패치는 30 m 해상도를 갖는 NASA의 SRTM(shuttle radar topography mission) DEM으로부터 생성된다^[12]. 지형 정보 패치는 그림 3(a)와 같이 64×64 픽셀을 가지며, 한 변이 500 m인 정사각형 영역으로 정의된다. 해당 패치들은 다음과 같이 각 Tx 또는 Rx가 중심으로 설정되며, 지형 정보 패치의 위치 좌표는 식 (5)와 같다.

$$P = [p^{(1)}, \dots, p^{(N)}]^T \in \mathbb{R}^{N \times 64 \times 64} \quad (5)$$

여기서 $p^{(n)}$ 은 n 번째 패치의 위치 좌표로 식 (6)과 같다.


$$p^{(n)} = \begin{bmatrix} (p_x^{(0)}, p_y^{(0)}) & \dots & (p_x^{(63)}, p_y^{(0)}) \\ \vdots & \ddots & \vdots \\ (p_x^{(0)}, p_y^{(63)}) & \dots & (p_x^{(63)}, p_y^{(63)}) \end{bmatrix} \in \mathbb{R}^{64 \times 64} \quad (6)$$

여기서 $(p_x^{(i)}, p_y^{(j)})$ 는 각 픽셀에 해당하는 로컬 좌표로 식 (7) 및 식 (8)과 같다.

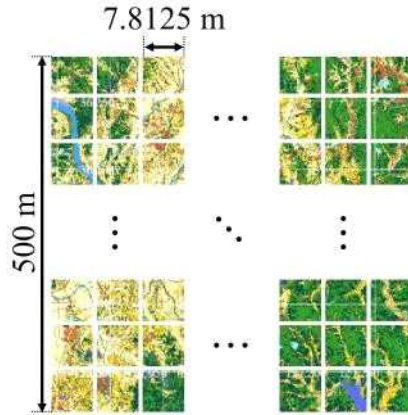
$$p_x^{(i)} = -\frac{L}{2} + \left(i + \frac{1}{2}\right) \Delta L \quad (7)$$

$$p_y^{(j)} = \frac{L}{2} - \left(j + \frac{1}{2}\right) \Delta L \quad (8)$$

여기서 i 와 j 는 각각 패치 내 픽셀의 가로 및 세로 방향 인덱스를 나타내며, 0부터 시작하여 63까지 총 64개의 이산적인 값을 갖는다. L 은 패치 한 변의 실제 거리(m)이며, ΔL 은 $L/64$ 이다. 로컬 좌표의 가로 및 세로 방향의 좌표 성분은 식 (9) 및 식 (10)과 같이 벡터로 표현할 수 있다.



(a) 지형 정보 패치
(a) Terrain information patch



(b) 환경 정보 패치
(b) Environmental information patch

그림 3. 패치 예시
Fig. 3. Examples of patches.

$$p_x = [p_x^{(0)}, \dots, p_x^{(63)}]^T \quad (9)$$

$$p_y = [p_y^{(0)}, \dots, p_y^{(63)}]^T \quad (10)$$

일관성을 위해 전체 좌표는 Tx과 Rx 간의 전파경로가 각 패치의 0° 방향을 향하도록 식 (11)과 같이 회전된다.

$$\begin{bmatrix} p'_x \\ p'_y \end{bmatrix} = \begin{bmatrix} \cos \alpha & \sin \alpha \\ -\sin \alpha & \cos \alpha \end{bmatrix} \begin{bmatrix} p_x \\ p_y \end{bmatrix} \quad (11)$$

여기서 α 는 그림 4에 나왔듯이 Tx와 Rx 간 전파경로의 방위각이다. p'_x , p'_y 를 각각 경도, 위도로 변환하기 위해 패치의 중심점 (p_x^c, p_y^c) 으로부터의 그림 5와 같이 각 좌




그림 4. Tx-Rx 전파 경로 방향에 따른 패치 회전 정렬
Fig. 4. Rotation alignment of patches according to the Tx-Rx propagation direction.




그림 5. 패치 내 픽셀 좌표
Fig. 5. Pixel coordinates within a patch.

표의 거리 $r^{(i,j)}$ 와 방위각 $\beta^{(i,j)}$ 을 식 (12) 및 식 (13)을 사용하여 계산한다.

$$r^{(i,j)} = \sqrt{(p_x^{(i)} - p_x^c)^2 + (p_y^{(j)} - p_y^c)^2} \quad (12)$$

$$\beta^{(i,j)} = \text{atan2}((p_y^{(j)} - p_y^c), (p_x^{(i)} - p_x^c)) \quad (13)$$

여기서 패치의 중심점 (p_x^c, p_y^c) 는 실제 계산에서는 (0, 0)으로 설정된다. 각 픽셀의 로컬 좌표는 계산된 방위각과 거리를 이용하여 빈센티 공식(Vincenty's formulae)을 통해 식 (14)와 같이 경도, 위도 좌표로 변환된다^[13].

$$p^{(n)} = \begin{bmatrix} (p_{lon}^{(0)}, p_{lat}^{(0)}) & \dots & (p_{lon}^{(63)}, p_{lat}^{(0)}) \\ \vdots & \ddots & \vdots \\ (p_{lon}^{(0)}, p_{lat}^{(63)}) & \dots & (p_{lon}^{(63)}, p_{lat}^{(63)}) \end{bmatrix} \quad (14)$$

DEM으로부터 $p^{(n)}$ 에 해당하는 좌표의 고도를 얻는다. 이때, $(p_{lon}^{(i)}, p_{lat}^{(j)})$ 가 DEM의 데이터 격자의 경도, 위도와 일치한다면 해당 고도를 그대로 사용이 가능하나, 일치하지 않을 경우는 근접한 4개의 데이터 격자의 고도에 대해 이중 선형 보간을 수행하여 각 픽셀의 고도 $z^{(i,j)}$ 을 계산한다^[14]. n 번째 패치의 고도 행렬 $Z^{(n)}$ 을 식 (15)와 같이 구성한다.

$$Z^{(n)} = \begin{bmatrix} z^{(0,0)} & \dots & z^{(63,0)} \\ \vdots & \ddots & \vdots \\ z^{(0,63)} & \dots & z^{(63,63)} \end{bmatrix} \in \mathbb{R}^{64 \times 64} \quad (15)$$

고도 행렬 Z 는 패치 내부의 상대적인 고도 분포를 유지하면서, 서로 다른 위치에서 추출된 패치 간의 스케일 차이를 완화하고, 패치 내부의 상대적인 고도 분포를 일관된 범위로 표현하기 위해 다음과 같이 최솟값 -10 과 최댓값 150 을 사용하여 식 (16)과 같이 정규화를 수행한다.

$$Z^{(n)} = \frac{Z^{(n)} - (-10)}{150 - (-10)} \quad (16)$$

이후 255배 스케일링 및 8비트 정수형 변환을 거쳐 시각화된 Tx 중심의 지형 정보 패치 $Z_t^{(n)}$, Rx 중심의 지형정보 패치 $Z_r^{(n)}$ 로 저장된다. 저장된 지형 정보 패치들을 불러온 후 두 패치는 채널 방향으로 식 (17)과 같이 결합된다.

$$x_2^{(n)} = [Z_t^{(n)}; Z_r^{(n)}] \in \mathbb{R}^{64 \times 64 \times 2} \quad (17)$$

픽셀 값은 저장을 위해 $[0, 255]$ 의 범위로 스케일링된 상태이기 때문에 학습의 안정성을 위해 식 (18)과 같이 최솟값 0 , 최댓값 255 을 사용하여 정규화를 수행한다.

$$x_2^{(n)} = \frac{x_2^{(n)}}{255} \quad (18)$$

최종적으로, 지형 정보 데이터셋 X_2 는 식 (19)와 같이 N 개의 샘플로 구성된다.

$$X_2 = [x_2^{(1)}, \dots, x_2^{(N)}]^T \in \mathbb{R}^{N \times 64 \times 64 \times 2} \quad (19)$$

2-3 환경 정보 패치

Tx와 Rx 주변의 환경 정보 또한 반영하기 위해 시스템

파라미터 데이터셋 X_1 과 동일한 샘플 인덱스를 갖는 지형 정보 패치 데이터셋을 생성한다. 환경 정보 패치 또한 그림 3(b)와 같이 64×64 픽셀을 가지며, 한 변이 500 m인 정사각형 영역으로 정의된다. 환경 정보 패치는 환경부의 30 m 해상도를 갖는 토지피복도로부터 생성된다^[15]. 토지 피복도는 환경부의 토지피복 분류체계에 따라 대분류, 중분류, 세분류로 구성된다. 각 분류마다 분류코드가 존재한다. 분류코드는 세 자리 정수형 코드로 계층적으로 표현되며, 41종류가 존재한다. 대분류는 시가지(100), 농업지역(200), 산림지역(300), 초지(400), 습지(500), 나지(600), 수역(700)으로 구분되며, 각 대분류는 중분류, 세분류로 세분화된다. 예를 들어, 농업지역 대분류에는 논(210), 밭(220) 등의 중분류가 존재하며, 논(210)의 세분류는 경지정리가 된 논(211)과 경지정리가 안 된 논(212)이 존재한다. 이와 같이, 토지피복도는 DEM과 달리 연속적인 실수형 값이 아닌 이산적인 범주형 값으로 구성되므로, 이중 선형 보간 대신 각 픽셀의 좌표에서 가장 가까운 격자에 존재하는 분류코드를 샘플링한다. DEM과 동일한 해상도로 보간된 좌표 $p^{(n)}$ 에 대응되는 각 픽셀의 분류코드 $c^{(i,j)}$ 를 샘플링하여, n 번째 패치의 분류코드 행렬 $c^{(n)}$ 을 식 (20)과 같이 구성하였다.

$$c^{(n)} = \begin{bmatrix} c^{(0,0)} & \dots & c^{(63,0)} \\ \vdots & \ddots & \vdots \\ c^{(0,63)} & \dots & c^{(63,63)} \end{bmatrix} \in \mathbb{R}^{64 \times 64} \quad (20)$$

환경 정보 데이터셋에 대응되는 전체 N 개의 분류코드 데이터셋 C 는 식 (21)과 같이 구성된다.

$$C = [c^{(1)}, \dots, c^{(N)}]^T \in \mathbb{R}^{N \times 64 \times 64} \quad (21)$$

여기서 분류코드 행렬 c 는 N 개가 존재하며 각 패치와 대응된다. 각 분류코드 $c^{(i,j)}$ 는 토지피복 분류체계에 따라 RGB 색상으로 대응되어 범주 정보를 시각적으로 표현된다. 예를 들어, 경작정리가 된 논(211)은 $[255, 255, 191]$ 의 RGB 색상으로, 경작정리가 안 된 논(212)은 $[244, 230, 168]$ 의 RGB 색상으로 표현된다. 이러한 색상 정보를 각 픽셀 단위로 구성하면, 픽셀별 RGB 벡터 $m^{(i,j)}$ 는 식 (22)와 같이 표현할 수 있다.

$$m^{(i,j)} = [r^{(i,j)}, g^{(i,j)}, b^{(i,j)}] \quad (22)$$

또한, $m^{(i,j)}$ 를 요소로 갖는 패치의 RGB 행렬 $M^{(n)}$ 은 식 (23)과 같이 정의할 수 있다.

$$M^{(n)} = \begin{bmatrix} m^{(0,0)} & \dots & m^{(63,0)} \\ \vdots & \ddots & \vdots \\ m^{(0,63)} & \dots & m^{(63,63)} \end{bmatrix} \in \mathbb{R}^{64 \times 64 \times 3} \quad (23)$$

환경 정보 패치 또한 지형 정보 패치와 동일하게 Tx와 Rx 간 전파경로가 패치의 0° 방향에 정렬되도록 패치들을 회전 정렬한 후에 저장된다. 저장된 환경 정보 패치들로부터 n 번째 샘플의 Tx 중심 패치와 Rx 중심 패치를 각각 $M_t^{(n)}$, $M_r^{(n)}$ 으로 불러오며, 두 행렬은 채널 방향으로 결합되어 식 (24)와 같이 표현된다.

$$x_3^{(n)} = [M_t^{(n)}; M_r^{(n)}] \in \mathbb{R}^{64 \times 64 \times 6} \quad (24)$$

RGB 색상값은 $[0, 255]$ 범위를 가지므로, 식 (25)와 같이 정규화하여 $[0, 1]$ 범위로 스케일링된다.

$$x_3'^{(n)} = \frac{x_3^{(n)}}{255} \quad (25)$$

최종적으로, 환경 정보 데이터셋 X'_3 는 식 (26)과 같이 N 개의 샘플로 구성된다.

$$X'_3 = [x_3'^{(1)}, \dots, x_3'^{(N)}]^T \in \mathbb{R}^{N \times 64 \times 64 \times 6} \quad (26)$$

2.4 학습 구조 및 모델 설계

제안하는 모델은 지형 정보 패치, 환경 정보 패치, 그리고 시스템 파라미터의 세 가지 입력을 동시에 학습하는 다중입력 CNN 구조로 구성된다. 그림 1과 같이 지형 정보 패치와 환경 정보 패치는 각각 개별 합성곱 블록을 통해 특징이 추출되며, 정규화된 시스템 파라미터와 결합된다. 각 합성곱 블록은 합성곱 레이어(Conv2D)와 맥스풀링(MaxPooling2D) 레이어로 구성되며, 활성화 함수로는 ReLU를 사용한다. 합성곱 레이어는 입력 패치에 대해 필터 개수 F 와 커널 크기 $K \times K$ 를 적용하여 공간적 특징을 추출하고, 풀링 크기 $P \times P$ 를 갖는 맥스풀링 레이어를 사용해 특징을 점진적으로 압축한다. 지형 정보 패치는 (F_1, K_1, P_1) 의 파라미터를 사용한 L_1 개의 합성곱 블록으로, 환경 정보 패치는 (F_2, K_2, P_2) 의 파라미터를 사용

한 L_2 개의 합성곱 블록으로 특징을 추출하며, 마지막 합성곱 블록의 출력은 레이어 정규화(layer normalization)를 통해 추출된 특징의 스케일을 정규화한다. 정규화된 각각의 출력들은 평탄화(flatten) 과정을 거쳐 일차원 벡터 X''_2 , X''_3 로 구성된다. 지형 정보 패치로부터 추출된 특징 벡터 X''_2 는 $N \times d_2$ 의 크기를 가지며, 환경 정보 패치로부터 추출된 특징 벡터 X''_3 는 $N \times d_3$ 의 크기를 갖는다. 여기서 d_2 , d_3 는 각각 평탄화된 1차원 벡터의 길이이다. 두 특징 벡터는 시스템 파라미터 $X'_1 \in \mathbb{R}^{N \times 5}$ 와 결합되어 하나의 통합 입력 벡터를 형성하며, 이는 식 (27)과 같이 표현된다.

$$X = [X'_1, X''_2, X''_3]^T \in \mathbb{R}^{N \times (5 + d_2 + d_3)} \quad (27)$$

X 는 ReLU(rectified linear unit) 활성화 함수를 사용하는 완전 연결 레이어(Full Connected Layer)를 통해 결합된 특징과 경로손실 사이의 비선형적 관계를 학습한다. 완전 연결 레이어의 노드 수는 N_h 이며, 출력 레이어는 1개의 노드와 선형(linear) 활성화 함수를 사용하여 경로손실 y 를 예측한다. 결과적으로, 제안된 모델은 지형, 환경, 그리고 시스템 특성을 통합적으로 학습한다.

III. 실험 구성 및 결과

3.1 측정 환경 및 데이터 획득

학습 데이터는 충청남도 홍성군에서 측정한 3.4 GHz의 전파 환경 데이터를 기반으로 구성하였다. Tx는 고정된 위치(36.5414° N, 126.4718° E)에 설치하였으며, 송신 안테나 높이는 건물 높이를 포함하여 약 24.5 m이다. 송신 신호는 40 dBm 출력의 CW(continuous wave) 신호로 방사되었으며, Rx는 차량에 탑재하여, 그림 6과 같이 Tx로부터 약 0.1 km에서 16 km 떨어진 거리까지 Rx를 이동하며 연속적으로 수신하였다. 수신 안테나의 높이는 2 m이며, 측정의 안정성을 위해 차량은 30 km/h 이하로 이동하였다. 수신 신호는 GPS 수신기로부터 획득한 위도 및 경도와 수신 신호 세기가 함께 저장되었다. 총 측정 데이터 수는 10,000개다.

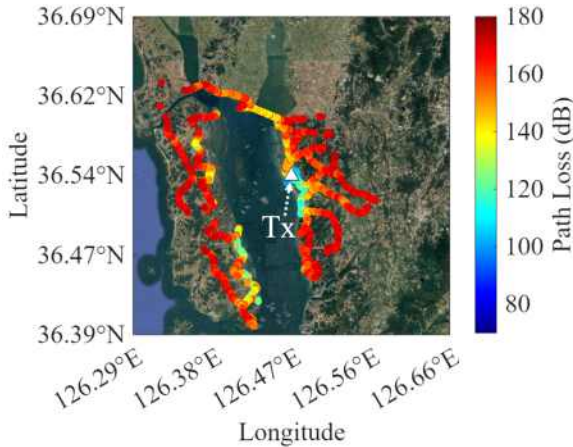


그림 6. 측정 경로 및 측정된 경로손실
Fig. 6. Measurement routes and measured path loss.

3-2 학습 설정 및 하이퍼파라미터 탐색

모델의 학습은 Python 3.8.6의 TensorFlow 2.9.0 기반의 Keras를 이용하여 수행하였다. 전체 데이터셋은 학습 데이터 60%, 검증 데이터 20%, 시험 데이터 20%으로 분할하였다. 옵티마이저는 Adam을 사용하였고, 학습률은 l_r , 배치 크기는 128, 최대 학습 에포크 수는 1,000으로 설정하였으며, 검증 손실이 5회 연속 개선되지 않을 경우 학습을 조기 종료(early stopping)하였다. 손실 함수는 평균 제곱 오차(MSE, mean squared error)를 사용하였다. 하이퍼파라미터 최적화는 Optuna의 TPE(tree-structured Parzen estimator) 알고리즘을 이용한 베이지안 최적화를 사용하여 검증 데이터의 MSE를 최소화하는 방향으로 수행하였다. 탐색은 총 100회 수행하였으며, 하이퍼파라미터의 탐색 범위와 최적값은 표 1에 요약하였다.

3-3 입력 구성별 비교

제안하는 모델의 입력 구성에 따른 성능 차이를 검증하기 위해, 시스템 파라미터, 지형 정보 패치, 환경 정보 패치의 조합을 달리하여 세 가지 모델을 구성하였으며, 각 모델의 성능을 비교하였다. 모든 비교 모델은 제안하는 모델과 동일한 CNN 구조 및 하이퍼파라미터를 사용한다. 모델 1은 시스템 파라미터와 지형 정보 패치만을 입력으로 사용한다. 이 모델은 지형적 요인이 전파 감쇠

표 1. 하이퍼파라미터 탐색 범위 및 최적값

Table 1. Hyperparameter search ranges and optimal values.

Hyperparameter	Search range	Optimal value
L_1	{1, 2, 3, 4, 5}	4
F_1	{2, 4, 8, 16, 32, 64, 128, 256, 512}	256
K_1	{3, 5}	3
P_1	{2}	2
L_2	{1, 2, 3, 4, 5}	5
F_2	{2, 4, 8, 16, 32, 64, 128, 256, 512}	256
K_2	{3, 5}	3
P_2	{2}	2
N_h	{2, 4, 8, 16, 32, 64, 128, 256, 512}	64
l_r	$[10^{-4}, 10^{-2}]$	0.00098

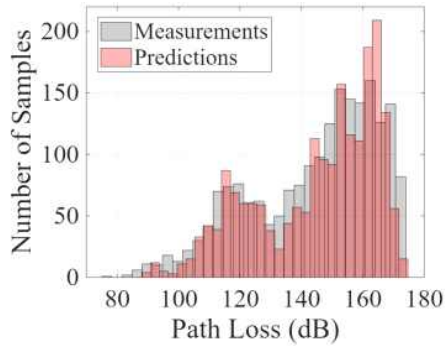
에 미치는 영향을 반영할 수 있으나, 환경적 요소는 고려하지 않는다. 모델 2는 시스템 파라미터와 환경 정보 패치를 입력으로 하며, 환경적 요소만을 반영한다. 마지막으로, 제안하는 모델인 모델 3은 시스템 파라미터, 지형 정보 패치, 환경 정보 패치를 입력으로 하며, 지형과 환경의 복합적인 특성을 동시에 학습한다. 모든 모델은 동일한 인덱스를 갖는 학습 데이터셋을 갖고 동일한 학습 절차로 학습되었으며, 시험 데이터셋에서의 평균 절대 오차(MAE, mean absolute error), MSE, 평균 제곱근 오차(RMSE, root mean square error), 결정계수(R^2)를 비교하였으며, 결과는 표 2에 요약하였다.

시스템 파라미터와 지형 정보가 결합된 모델 1은 회절 및 차폐 효과를 부분적으로 학습하여 약 6.4571 dB의 RMSE를 보였다. 시스템 파라미터와 환경 정보를 결합한 모델 2는 환경 정보를 반영함으로써 모델 1에 비해 RMSE 약 0.5 dB 낮았다. 세 정보를 모두 결합하여 학습


표 2. 입력 구성별 성능 비교(단위: dB)

Table 2. Performance comparison according to input configuration (unit: dB).


Model	MAE	MSE	RMSE	R^2
1	4.7144	41.6946	6.4571	0.9034
2	4.4081	35.2905	5.9406	0.9178
3	4.3851	33.6915	5.8044	0.9215



(a) 모델 1
(a) Model 1



(b) 모델 2
(b) Model 2



(c) 모델 3
(c) Model 3

그림 7. 실측 및 예측 경로손실 분포 비교
Fig. 7. Comparison of measured and predicted path-loss distributions.

한 모델 3은 RMSE가 5.8044 dB로 가장 우수한 예측 성능을 보였다. 또한, 그림 7은 실측값과 예측값의 경로손실

분포를 비교한 결과로, 제안하는 모델이 실측 분포와 가장 유사한 형태를 보임을 시각적으로 확인할 수 있다. 결과적으로, 본 연구에서 제안한 다중 입력 데이터를 학습한 모델은 시스템 파라미터와 지형 정보만을 학습한 모델보다 예측 정확도가 약 10 % 향상되었다.

3-4 성능 비교 및 논의

그림 8은 측정된 경로손실과 제안하는 모델 및 경험적(empirical) 경로손실 모델인 CI(close-in) 모델의 예측 경로손실 PL^{CI} 을 함께 비교하여 보여준다. 이때 실선은 CI 모델로부터 얻은 예측 경로손실로 식 (28)과 같이 정의된다¹⁶⁾.

$$PL^{CI}(f,d) = FSPL(f,1m) + 10n \log_{10}(d) + \chi_{\sigma}^{CI} \quad (28)$$

여기서, f 는 주파수(GHz), d 는 거리(m), FSPL은 주파수 f 에서 1 m 거리의 자유 공간 경로손실, n 은 경로 손실 지수, χ_{σ}^{CI} 는 쉐도잉을 나타낸다. CI 모델은 훈련 데이터셋에 대해 피팅되었으며, 표 3에 관련 경로손실 예측

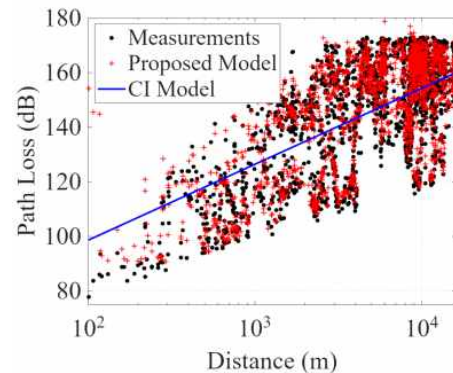


그림 8. Tx-Rx 거리에 따른 측정 및 예측 경로손실 비교
Fig. 8. Comparison of measured and predicted path loss as a function of Tx-Rx distance.

표 3. 관련 경로손실 예측 모델과의 RMSE 비교
Table 3. RMSE comparison with related path loss prediction models.

Model	RMSE (dB)
Proposed Model	5.8044
[7]	6.645
[11]	7.61
CI Model	14.8232

연구에서 보고된 RMSE와 함께 RMSE를 제시하였다. CI 모델은 측정값 기반의 거리 감쇠의 평균적인 경향을 반영하나, 지형 및 환경 요인에 의해 발생하는 변동성을 직접적으로 설명하기 어려워 표 3에 제시된 결과 중 가장 낮은 14.8232 dB의 RMSE를 기록하였다. 제안하는 모델은 시스템 파라미터뿐만 아니라 지형 및 환경 패치를 함께 학습함으로써 위성영상 기반 CNN 모델, 환경 특성 이미지 기반 CNN 모델을 사용한 모델인 참고문헌 [7] 및 참고문헌 [11] 대비 0.84 dB, 1.8056 dB 낮은 RMSE를 보였다. 따라서 제안하는 모델은 지형 및 환경 정보 패치를 통해 지형의 고도 변화와 환경적 특성을 동시에 반영함으로써 기존 모델 대비 오차를 낮출 수 있음을 확인하였다.

IV. 결 론

본 연구에서는 Tx와 Rx 주변의 지형 및 환경 정보를 64×64 크기의 패치 형태로 구성하고, 시스템 파라미터와 함께 다중입력 CNN 모델로 통합 학습하는 경로손실 예측 모델을 제안하였다. 각 입력에 대해 개별 합성곱 블록을 사용하여 특징을 추출하고, 채널 결합을 통해 전파 환경과 시스템 특성이 통합적으로 반영되도록 설계하였다. 동일한 하이퍼파라미터 조건에서 수행한 비교 결과, 제안된 모델은 가장 낮은 예측 오차를 보였다. 시험 데이터셋 기준 RMSE 5.8044 dB의 성능을 달성하였으며, 시스템 파라미터와 지형 정보 패치만을 입력으로 하는 모델 대비 약 10 % 이상의 정확도 향상을 보였다. 이는 제안한 다중입력 모델이 거리 감쇠뿐만 아니라 회절, 차폐, 반사 등의 현상을 효과적으로 학습하여, 실제 지형 및 환경 조건에서의 경로손실 예측 정확도를 향상시킬 수 있음을 의미한다. 또한, 관련 경로손실 예측 연구에서 보고된 RMSE와 비교했을 때, 제안하는 모델은 고도 변화와 환경적 특성을 동시에 반영함으로써 오차를 낮출 수 있음을 확인하였다. 제안하는 모델은 단일 지역에서 측정된 데이터를 기반으로 하였다. 후속 연구는 다양한 지형 및 환경 조건을 포함하는 지역에서 추가적인 측정을 통해 지형 유형별 성능을 분석할 예정이다.

References

- [1] S. H. Moon, K. I. Kim, H. J. Choi, and K. T. Kim, "Simulation of ground clutter received signals on rough surfaces in an electronic warfare environment," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 36, no. 1, pp. 95-105, Jan. 2025.
- [2] I. Lee, "Suitability of the P.617 and P.2001 models for troposcatter loss prediction in Korea," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 36, no. 8, pp. 758-765, Aug. 2025.
- [3] Y. Okumura, E. Ohmori, T. Kawano, and K. Fukuda, "Field strength and its variability in VHF and UHF land-mobile service," *Review of the Electrical Communication Laboratory*, vol. 16, no. 9-10, pp. 825-873, Sep.-Oct. 1968.
- [4] M. Hata, "Empirical formula for propagation loss in land mobile radio services," *IEEE Transactions on Vehicular Technology*, vol. 29, no. 3, pp. 317-325, Aug. 1980.
- [5] Y. Sun, J. Zhang, Y. Zhang, L. Yu, Z. Yuan, and G. Liu, et al., "Environment features-based model for path loss prediction," *IEEE Wireless Communications Letters*, vol. 11, no. 9, pp. 2010-2014, Sep. 2022.
- [6] S. P. Sotiroudis, A. D. Boursianis, S. K. Goudos, and K. Siakavara, "From spatial urban site data to path loss prediction: An ensemble learning approach," *IEEE Transactions on Antennas and Propagation*, vol. 70, no. 7, pp. 6101-6105, Dec. 2021.
- [7] Z. Qiu, R. He, M. Yang, S. Zhou, L. Yu, and C. Wang, "CNN-based path loss prediction with enhanced satellite images," *IEEE Antennas and Wireless Propagation Letters*, vol. 23, no. 1, pp. 189-193, Oct. 2023.
- [8] 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.
- [9] R. T. Juang, "Explainable deep-learning-based path loss prediction from path profiles in urban environments," *Applied Sciences*, vol. 11, no. 15, Jul. 2021.
- [10] Y. Chen, T. Xiang, and X. Zhang, "An efficient wireless propagation loss prediction model based on 3-D terrain

- features extracted by deep learning," *IEEE Antennas and Wireless Propagation Letters*, vol. 22, no. 5, pp. 1055-1058, Dec. 2022.
- [11] L. Wu, D. He, B. Ai, J. Wang, D. Liu, and F. Zhu, "Enhanced path loss model by image-based environmental characterization," *IEEE Antennas and Wireless Propagation Letters*, vol. 21, no. 5, pp. 903-907, Feb. 2022.
- [12] NASA JPL, "NASA shuttle radar topography mission global 1 arc second, NASA EOSDIS land processes DAAC," 2013. Available: <https://doi.org/10.5067/MEaSUREs/SRTM/SRTMGL1.003>
- [13] C. M. Thomas, W. E. Featherstone, "Validation of Vincenty's formulas for the geodesic using a new fourthorder extension of Kivioja's formula," *Journal of Surveying Engineering*, vol. 131, no. 1, pp. 20-26, Feb. 2005.
- [14] W. Shi, B. Wang, and Y. Tian, "Accuracy analysis of digital elevation model relating to spatial resolution and terrain slope by bilinear interpolation," *Mathematical Geosciences*, vol. 46, no. 4, pp. 445-481, Jan. 2014.
- [15] Ministry of Environment, Republic of Korea, "National land cover map of Korea," 1998. Available: <http://egis.me.go.kr/intro/land.do>
- [16] Ministry of Environment, Republic of Korea, "National land cover map of Korea," 1998. Available: <http://egis.me.go.kr/intro/land.do>

이 동엽 [국방과학연구소/연구원]

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



2021년 2월: 한국해양대학교 전과공학과 (공학사)

2023년 2월: 한국해양대학교 전과공학과 (공학석사)

2023년 4월 ~ 현재: 국방과학연구소 연구원

[주 관심분야] AI, 전파모델링, 전자장수

치해석 등