

## 머신러닝을 이용한 꺾인 모노폴 안테나 설계

## Design of a Bent Wire Monopole Antenna Using Machine Learning

박재윤 · 안인범 · 주재율

Jae Yoon Park · In Beom Ahn · Jaeyul Choo

## 요 약

본 논문에서는 950~1,050 MHz 대역에서 동작하고, 목표 방향( $\varphi=180^\circ$ ,  $40^\circ<\theta<50^\circ$ )에서 지향성을 갖는 꺾인 모노폴 안테나를 제안하였다. 제안된 안테나는 임피던스와 방사패턴의 조정이 용이한 3개의 꺾인 부분선로로 구성되며, 목표 성능값에 부합하는 부분선로의 최적설계값을 도출하기 위해서 DNN(deep neural network) 구조의 기계학습 모델을 활용하였다. 기계학습 모델은 안테나 구조 변수 및 성능 평가값으로 구성된 학습데이터를 이용하여 훈련되었으며, 성능 평가값은 상용 시뮬레이션 결과로부터 동작 주파수 대역의 반사손실과 목표 방향의 방사이득을 고려하여 도출하였다. 기계학습 모델의 훈련 성숙도를 나타내는 지표를 통해서 기계학습 모델이 충분히 훈련되었음을 확인한 후, 훈련된 기계학습 모델과 상용 시뮬레이터가 예측한 표본 안테나의 성능 평가값을 비교하여 훈련된 기계학습 모델을 검증하였다. 그 후, 검증된 기계학습 모델에 격자 탐색 방법을 적용하여 설계 목표에 부합하는 최적 안테나 구조를 도출하고, 성능확인을 위해서 제작하였다. 제작된 안테나의 반사손실 및 안테나 방사이득을 측정된 결과, 제작된 안테나는 시뮬레이션값과 유사하게 983.5 MHz~1,037.5 MHz의 반사손실 대역폭과 목표 방향에서 약 4.1 dBi의 방사이득을 가졌다. 따라서 제안된 기계학습을 이용한 안테나 설계기법이 안테나 설계를 위해서 충분히 활용될 수 있다는 것을 확인하였다.

## Abstract

This study proposes a bent wire monopole antenna to achieve impedance matching in the frequency range of 950–1,050 MHz and a directive radiation pattern in the target direction ( $\varphi=180^\circ$ ,  $40^\circ<\theta<50^\circ$ ). A machine learning technique based on a deep neural network is applied to obtain an optimal antenna design that is bent at three points to adjust the impedance and radiation pattern. The machine learning model is trained using a dataset that includes the antenna geometry and cost, evaluated on how well the antenna performance satisfies the target bandwidth and radiation pattern. After verifying that the machine learning model is trained using the figure of merit, the machine learning model is validated by comparing the cost estimated by the model with that estimated by a commercial electromagnetic simulator. Next, we obtain the optimal antenna design from the result of a grid search and fabricate it to verify its performance. The results show that the manufactured antenna has a matching bandwidth from 983.5 to 1,037.5 MHz and a radiation gain of approximately 4 dBi in the target direction. These results are in good agreement with the simulated performance of the antenna. Thus, we conclude that the antenna design obtained using the machine learning technique is valid for designing the proposed antenna.

Key words: Bent Monopole Antenna, Deep Neural Network, Directive Radiation Pattern, Impedance Matching, Machine Learning Technique

「이 논문은 2021학년도 안동대학교 학술연구조성비에 의하여 연구되었음」.

안동대학교 전자공학과(Department of Electronic Engineering, Andong National University)

· Manuscript received April 10, 2022 ; Revised April 24, 2022 ; Accepted June 7, 2022. (ID No. 20220410-036)

· Corresponding Author: Jaeyul Choo (e-mail: jychoo@anu.ac.kr)

## I. 서 론

안테나는 무선 통신 시스템의 입단부와 종단부에서 데이터가 포함된 전파를 송·수신하는 역할을 한다. 무선 통신에 적용되는 안테나의 경우, 범용적인 사용을 위한 일반적 구조의 안테나(예, 모노폴 안테나, 패치 안테나)와 특수 목적을 위해 설계된 복잡한 구조의 안테나(예, crooked wire antenna)가 활용된다<sup>[1]~[3]</sup>. 다양한 무선통신용 안테나 중 복잡한 구조를 가진 안테나를 설계하기 위해서는 적용 분야에서 요구하는 안테나 성능이 구현되도록 안테나 구조를 최적화해야 한다.

안테나 설계를 위한 구조식이 정립된 경우(예, 일반적 마이크로스트립 패치 안테나), 해당 구조식을 통해 최적화된 안테나를 설계할 수 있다. 그러나 안테나 구조가 복잡한 경우, 구조식 활용이 어려워져 안테나 구조에 따른 성능을 예측하는 데는 한계가 있으며, 이를 해결하기 위해서는 최적화 설계기법이 요구된다<sup>[4]~[6]</sup>. 일반적인 최적화 설계기법으로는 시행착오법(trial and error)이 있으며, 이 최적화 설계기법에서는 안테나 설계 엔지니어의 판단에 근거하여 최적 설계가 진행된다. 그러나 안테나 성능에 민감하게 영향을 주는 설계변수가 많을 경우, 시행착오법만을 사용해서는 안테나 구조를 최적화하기 어렵다. 이러한 시행착오법의 제약점을 극복하기 위해서 유전자 알고리즘(genetic algorithm: GA)과 입자 군집 최적화 기법(particle swarm optimization: PSO) 등과 같은 최적화 기법이 소개되었다<sup>[7]~[9]</sup>. 그러나 유전자 알고리즘을 활용한 최적화 기법이나 입자군집 최적화 기법을 안테나 최적설계에 활용할 경우, 안테나의 성능을 확인하기 위한 수치해석이 수반되기 때문에 많은 시간적, 비용적 노력이 요구된다.

최근 안테나 최적설계를 위해서 기계학습 기법을 활용한 연구들이 보고되고 있다. 보고된 연구에서는 수치해석에 의한 안테나 성능해석을 대신하기 위해서, 다양한 기계학습 기법들이 활용되었다<sup>[10],[11]</sup>. 참고문헌 [10]에서는 기존에 설계된 평판형 다중대역 모노폴 안테나에 기계학습을 적용하여 안테나 구조를 최적화하였다. 또한, 해당 논문에서는 다양한 기계학습 기법을 분석하여, 제안된 안테나 구조를 최적화하는 데 적합한 기계학습 기법을 선

별하였다. 그 외, 참고논문 [11]에서는 기계학습 기법을 활용하여 장시간 소요되는 안테나 성능해석 시간을 효과적으로 줄인 연구 결과가 보고되었다. 그러나 앞서 설명한 선행연구의 경우, 안테나의 임피던스 정합 특성에만 국한하여, 기계학습을 활용했다는 제약점을 갖고 있기 때문에 다른 안테나 성능(예, 방사패턴)을 대상으로 기계학습을 활용한 확장연구가 필요하다. 따라서 본 연구에서는 기계학습을 활용하여 다수의 부분선로로 구성된 모노폴 안테나 구조가 양질의 임피던스 정합 특성과 특정 방향에서의 지향성 방사패턴을 갖도록 최적설계하였다.

## II. 안테나 구조

그림 1은 3개의 부분선로(지름: 1 mm, 재질: 구리)로 구성된 꺾인 모노폴 안테나의 구조를 보여준다. 제안된 안테나는 무한 접지면( $x$ - $y$  평면) 위에 구축되며, 50  $\Omega$  특성 임피던스를 갖는 동축 케이블로부터 급전된다고 가정하였다. 전체 안테나 선로는 길이( $l_1, l_2, l_3$ )와 꺾인각( $\theta_1, \theta_2, \theta_3$ )을 갖는 3개의 부분선로로 구성되며, 표 1에서는 선로 시작점( $P_0$ ), 부분선로 연결점( $P_1, P_2, P_3$ ), 선로 끝점( $P_4$ )에 대한 좌표가 제시되었다. 안테나 설계변수가 안테나 특성에 미치는 영향을 살펴보면, 안테나 부분선로의 길이는 안테나 임피던스에 영향을 미치며, 선로의 꺾인 위치와 각도는 안테나 방사패턴에 영향을 미친다. 따라서 제안된




그림 1. 꺾인 모노폴 안테나 구조

Fig. 1. Geometry of the bent wire monopole antenna.

안테나가 양질의 임피던스 정합특성을 가지며, 목표 방향에서 지향성 방사패턴을 갖기 위해서는 설명한 안테나 설계변수에 대한 최적화가 필요하다.

본 연구에서는 제안된 안테나가 950~1,050 MHz 주파수 범위에서 양질의 임피던스 정합특성을 갖고,  $\varphi=180^\circ$ ,  $40^\circ \leq \theta \leq 50^\circ$ 의 공간에서 지향성 방사특성을 갖도록 설계변수를 최적화하였다. 최적화된 설계변수를 도출하기 위해서 DNN(deep neural network) 구조 기반의 기계학습 모델을 활용하였으며, 해당 기계학습 모델을 통해 다양한 설계변수에 따른 안테나 성능을 짧은 시간에 예측하였다.

### Ⅲ. 기계학습 데이터 생성 및 훈련

본 연구에서 수행된 기계학습 훈련 및 검증은 기계학습 데이터 생성 및 전처리, 기계학습 수행 및 학습모델 도출, 훈련된 기계학습 모델 검증으로 구성된다. 본 절에서는 기계학습 데이터를 생성하고 이로부터 기계학습 모델을 훈련하는 과정에 관해서 설명하였다.

#### 3-1 기계학습 데이터 생성 및 전처리

안테나 성능을 예측하는 기계학습 모델을 생성하기 위해서는 다양한 구조의 안테나에 대한 학습데이터가 필요하며, 각 학습데이터는 안테나 구조 정보(설계변수)와 성능값을 포함해야 한다. 따라서 본 연구에서는 안테나 구조에 따른 안테나 성능을 비교적 짧은 시간에 예측할 수 있는 NEC(numerical electromagnetic code)를 이용하여 학습데이터를 생성하였다<sup>[1]</sup>. 생성된 학습데이터는 부분선로

의 길이( $l_1, l_2, l_3$ )와 꺾인각( $\theta_1, \theta_2, \theta_3$ )에 대한 설계변수 정보와 해당 설계변수에 따른 안테나 성능(정합특성과 방사특성) 평가값( $Cost$ )으로 구성된다.

표 2는 학습데이터 생성 시 고려된 해석조건(목표 주파수 범위, 목표 방향)과 설계변수(부분선로의 길이와 꺾인각)의 범위와 분할 개수(number of points)를 보여준다. 표 2에 따르면 총 729,000개 표본 안테나(sample antenna)에 대한 학습데이터를 구성할 수 있다. 또한, 각 표본 안테나의 성능 평가값을 식 (1)로 표현된 평가함수( $Cost$  function)를 이용하여 도출하였다.

$$Cost = 1 - Average(P_r(f)) \quad (1)$$

여기서  $P_r(f) = (1 - (\Gamma(f))^2) \frac{G_{avr}(f)}{\max(G_{mono})}$  이며,  $Average(P_r(f))$ 는 목표 주파수 대역인 950~1,050 MHz에서  $P_r(f)$ 를 평균한 값을 의미한다. 또한,  $\Gamma(f)$ 와  $G_{avr}(f)$ 는 각각 주파수( $f$ )에서의 표본 안테나 반사손실,  $\varphi = 180^\circ$ ,  $40^\circ \leq \theta \leq 50^\circ$  방향에서의 평균이득을 의미한다. 또한,  $\max(G_{mono})$ 는 모노폴 안테나의 최대 이득인 5.15 dBi로 설정하였다. 식 (1)에 따르면 표본 안테나는 목표 주파수 대역에서 임피던스 정합과 목표 방향에서의 이득이 동시에 평균적으로 고려되게 된다. 예를 들어, 표본 안테나가 목표 주파수 대역에서 완벽히 임피던스 정합을 이루고, 이때 목표 방향에서의 평균이득이 5.15 dBi이면  $Cost$ 는 0의 값을 갖게 된다.

#### 3-2 기계학습 수행 및 학습모델 도출

본 연구의 기계학습 모델은 NEC 해석으로 도출된 학습데이터를 이용하여 훈련되었다. 일반적으로 기계학습

표 1. 제안된 모노폴 안테나의 꺾인점 위치

Table 1. Locations of the bending points of the proposed monopole antenna.

Bending point	Location		
	$x$ (m)	$y$ (m)	$z$ (m)
$P_0$	$x_0 = 0$	0	0
$P_1$	$x_1 = 0$	0	$z_1 = 0.007$
$P_2$	$x_2 = x_1 + l_1 \cos \theta_1$	0	$z_2 = z_1 + l_1 \sin \theta_1$
$P_3$	$x_3 = x_2 + l_2 \cos \theta_2$	0	$z_3 = z_2 + l_2 \sin \theta_2$
$P_4$	$x_4 = x_3 + l_3 \cos \theta_3$	0	$z_4 = z_3 + l_3 \sin \theta_3$

표 2. 학습데이터 생성을 위한 주파수 및 설계 조건

Table 2. Conditions of design parameters and interesting frequency for training data acquisition.

Parameter	Range	Number of points
Target frequency	950~1,050 MHz ( $f_0=1$ GHz)	5
Target direction	$\varphi=180^\circ$ , $40^\circ \leq \theta \leq 50^\circ$	11
Sub-wire length	$0.03 \lambda_0 \sim 0.18 \lambda_0$ ( $9 \sim 54$ mm)	15
Bending angle	$10^\circ \sim 90^\circ$	6

에서 학습데이터는 훈련데이터, 검증데이터, 시험데이터로 나누어지며, 각각의 데이터는 학습모델의 훈련, 학습이 완료된 학습모델의 검증, 훈련과 검증이 완료된 학습모델의 평가를 위해서 사용된다. 본 연구에서는 학습데이터의 70 %, 15 %, 15 %를 각각 훈련데이터, 검증데이터, 시험데이터로 활용하였다<sup>[12]</sup>.

본 연구에서는 학습데이터로부터 훈련된 기계학습 모델을 생성하기 위해서 인간 신경망을 모사한 DNN 구조를 사용하였다<sup>[13]</sup>. 그림 2는 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성된 DNN 모델의 전체 구조를 보여준다. 입력층은 안테나의 구조에 대한 모든 가지적 정보를 포함하고 있으며, 은닉층은 여러 입력 노드로부터 가중합을 계산하고, 이 값을 활성화 함수(예, Relu, linear, sigmoid 함수 등)에 적용하여 다음 은닉층 또는 출력층에 전달하는 역할을 한다. 표 3에서는 본 연구에서 적용된 DNN 구조의 입력층, 은닉층, 출력층의 노드 개수와 활성화 함수를 보여준다<sup>[14]</sup>. 표 3의 DNN 구조는 Adam(adaptive moment) 최적기법을 사용하여 128의 배치 크기(batch size)와 0.001의 학습속도(learning rate)로 훈련되었다.

제안된 기계학습 모델의 훈련 성숙도를 평가하기 위해서 평균 제곱 오차(mean squared error: MSE)와 결정계수(R-squared score( $R^2$ ))를 평가지표로 활용하였다<sup>[15],[16]</sup>. MSE의 경우, 식 (2)와 같이  $Cost$ 에 대한 편차(예측값과 실제값 차이)의 제곱을 평균한 값으로서 MSE가 0에 가까운 값을 가질수록 기계학습 모델이 성숙했다는 것을 의미한다. 특히 MSE는 학습모델의 성숙도 평가뿐만 아니라, 학습과




그림 2. DNN 구조의 예

Fig. 2. Example of DNN structure.

표 3. DNN 구조 구성 및 활성화 함수

Table 3. DNN structure and activation functions.

Layer type		Number of node	Activation function
Input layer		6	-
Hidden layers	1	512	Relu
	2	256	
	3	128	
	4	64	
	5	32	
	6	16	
	7	8	
Output layer		1	Linear

정 중의 손실함수로도 사용된다. 또한,  $R^2$ 은 식 (3)과 같이  $Cost$ 의 총변동합(실제값-평균값)에 대한 변동합(실제값-예측값)의 비를 의미하며,  $R^2$ 이 1에 가까울수록 기계학습 모델이 성숙했음을 의미한다.

$$MSE = \frac{1}{n} \sum_{k=1}^n (Y_k - \hat{Y}_k)^2 \quad (2)$$


$$R^2 = 1 - \frac{\sum_{k=1}^n (Y_k - \hat{Y}_k)^2}{\sum_{k=1}^n (Y_k - \bar{Y}_k)^2} \quad (3)$$

그림 3은 적용된 기계학습 모델의 훈련이 진행됨에 따라 변화되는 MSE와  $R^2$ 을 보여준다. 그림 3(a)에서 제시된 것처럼 MSE는 훈련의 반복을 의미하는 epoch가 증가함에 따라 값이 급격히 감소하여 0으로 수렴하였다. 반면에  $R^2$ 의 경우, 그림 3(b)에 제시된 것과 같이 epoch가 증가함에 따라 값이 급격히 증가하여 1로 수렴하였다. 따라서 조사된 MSE와  $R^2$ 의 변화로부터 적용된 기계학습 모델은 훈련단계 초기부터 빠른 속도로 성숙해진다는 것을 확인하였다. 본 연구에서는 약 400 epoch의 반복 훈련을 진행하였으며, 이를 통해서 DNN 구조의 성숙한 기계학습 모델을 도출하였다.

### 3-3 훈련된 기계학습 모델 검증


훈련된 기계학습 모델이 제안된 안테나의 성능을 정확





(a) 훈련 반복에 따른 MSE

(a) MSE corresponding to the number of epoch

(b) 훈련 반복에 따른  $R^2$ (b)  $R^2$  corresponding to the number of epoch그림 3. 훈련 반복에 따른 MSE와  $R^2$ Fig. 3. MSE and  $R^2$  corresponding to the number of epoch.

히 예측할 수 있는지를 검증하기 위해서, 기계학습 모델로부터 예측된  $Cost$ 가 0.6, 0.7, 0.8, 0.9인 안테나 모델을

선별하였고, 해당 안테나의 예측된  $Cost$ 를 NEC 시뮬레이션으로부터 계산한  $Cost$ 와 비교하였다. 표 4는 기계학습 모델 검증에 위해서 선별된 안테나의 구조정보와 기계학습 모델 및 NEC로부터 예측한  $Cost$ 를 보여준다. 표 4로부터 기계학습 모델이 예측한 4개 선별 안테나의  $Cost$ 는 NEC 시뮬레이션으로 도출한  $Cost$ 와 약 1 % 이내의 작은 오차를 보인다는 것을 확인하였다. 따라서 표 4의 결과는 안테나 설계변수가 제공되었을 때 훈련된 기계학습 모델이 안테나의 성능을 정확하게 예측할 수 있다는 것을 의미한다.

#### IV. 최적화 안테나 도출 및 검증

검증된 기계학습 모델을 이용하여 성능이 우수한 안테나 구조를 추출하기 위해서 격자 탐색(grid search)을 활용하였다<sup>[17]</sup>. 기계학습을 활용한 격자 탐색에서는 훈련된 기계학습 모델을 이용하여 총 46,656,000개(표 1의 분할개수를 2배 적용) 안테나의  $Cost$ 를 도출하였다. 표 5는 격자 탐색 결과로부터 최적성능을 갖는 10개 안테나의 구조정보와  $Cost$ 를 보여준다. 표 5에 제시된 최적 안테나의 구조를 검토한 결과, 최적 안테나는 반사손실 없이 목표 방향( $\varphi=180^\circ$ ,  $40^\circ < \theta < 50^\circ$ )에서 지향성 방사패턴을 갖도록, 두 번째와 세 번째 부분선로의 길이와 각도가 최적화된 것으로 확인되었다. 또한, 표 5에 제시된 것과 같이 NEC 시뮬레이션으로 도출한  $Cost$ 와 비교한 결과, 기계학습 모델로 도출한 최적 안테나의  $Cost$ 가 비교적 정확하게 예측(오차율<0.2 %)되었음을 확인하였다.

기계학습 모델로부터 도출한 최적화 안테나의 성능을 보다 실질적으로 검증하기 위해서 표 5의 Rank 3 안테나

표 4. 기계학습 모델과 NEC 시뮬레이션으로 도출한 표본 안테나의 성능 평가값

Table 4. Evaluated Cost of sample antennas by the machine learning model and NEC simulation.

No	Sub-wire length (mm)			Bending angle (degree)			Evaluated Cost		Error (%)
	$l_1$	$l_2$	$l_3$	$\theta_1$	$\theta_2$	$\theta_3$	Machine learning	NEC simulation	
1	15.2	19.9	30.7	82	46	24	0.6	0.5997	0.05
2	36.9	21.4	16.8	60	46	10	0.7	0.6979	0.3
3	36.9	32.3	15.2	68	39	17	0.8	0.7984	0.2
4	9	32.3	13.7	53	10	10	0.9	0.9040	0.44

표 5. 기계학습 모델로 도출한 최적 안테나의 구조와 성능 평가값

Table 5. Design parameters and evaluated Costs of ranked antenna models.

Rank	Sub-wire length (mm)			Bending angle (degree)			Evaluated Cost		Error (%)
	$l_1$	$l_2$	$l_3$	$\theta_1$	$\theta_2$	$\theta_3$	Machine learning	NEC simulation	
1	15.2	26.0	24.5	90	46	17	0.5983	0.5990	0.11
2	15.2	27.6	22.9	90	46	10	0.5984	0.5994	0.16
3	15.2	19.8	30.7	82	60	17	0.5984	0.5979	0.08
4	15.2	27.6	22.9	90	46	17	0.5984	0.5987	0.05
5	15.2	24.5	26.0	90	46	17	0.5984	0.5991	0.11
6	15.2	21.4	29.1	90	53	17	0.5985	0.5984	0.01
7	15.2	18.3	32.2	82	60	17	0.5985	0.5984	0.01
8	15.2	22.9	27.6	90	46	17	0.5985	0.5997	0.20
9	15.2	19.8	30.7	90	53	17	0.5985	0.5989	0.06
10	15.2	29.1	21.4	90	46	10	0.5986	0.5991	0.08

를 그림 4와 같이 제작하고 성능을 측정하였다. 최적 안테나는 지름 1 mm의 두께인 구리선이 도출된 부분선로 길이와 꺾인각을 갖도록 유한 접지면(0.25 m×0.25 m) 위에 제작되었다. 제작된 안테나의 성능을 검증하기 위해서, 벡터회로망 분석기와 전자파 무반사 챔버를 이용하여 50 Ω 동축선으로부터 급전된 안테나의 반사손실과 방사 패턴을 측정하였다.

그림 5는 제작된 안테나의 측정된 반사손실을 시뮬레이션값과 비교하여 보여준다. 그림 5에 제시된 시뮬레이션 결과의 경우, 무한 접지면과 유한 접지면 위의 안테나를 NEC와 HFSS 시뮬레이션 툴로 각각 해석하여 도출하였다<sup>[18]</sup>. 반사손실 대역폭은 -10 dB의 반사손실값을 기준

으로 5.4 % (983.5~1,037.5 MHz)로 측정되어, NEC와 HFSS 시뮬레이션 결과인 3.4 % (981~1,015 MHz)와 7.3 % (959~1,032 MHz) 유사하게 측정되었다. 또한, 그림 5의 측정값과 시뮬레이션값의 비교를 통해, 제작된 안테나의 반사손실 대역폭이 낮은 주파수 대역에서 높은 주파수 대역으로 다소 이동하였음을 확인하였다. 측정된 반사손실값이 시뮬레이션값과 차이가 나는 이유는 제작상의 오차로 발생하였다고 판단한다.

그림 6은  $\varphi=180^\circ$ 일 경우,  $\theta$  방향에 따라 측정된 안테




그림 4. 제작된 안테나 및 측정환경

Fig. 4. Configuration and measurement of the fabricated antenna.




그림 5. 제작된 안테나의 반사손실

Fig. 5. Reflection coefficient of the fabricated antenna.




그림 6.  $x$ - $z$  평면에서의 제작 안테나 총이득  
Fig. 6. Total gain of the fabricated antenna on  $x$ - $z$  plane.

나의 총 방사이득( $x$ - $z$  평면 방사패턴)을 상용 시뮬레이션 결과와 비교하여 보여준다. 그림 6으로부터 제작된 안테나는 다른 방향보다 목표 방향( $\varphi=180^\circ$ ,  $40^\circ<\theta<50^\circ$ )에서 향상된 방사이득 특성을 가지며, 측정된 방사패턴은 유한 접지면 조건을 고려한 상용 시뮬레이션 결과와 유사하였다. 제작된 안테나의 지향성 방사특성을 보다 명확하게 확인하기 위해서 표 6에 목표 방향의 방사이득을 정리하였다. 표 6으로부터 제작된 안테나는 목표 방향에서 약 4.1 dBi의 방사이득을 가져, 이상적인 모노폴 안테나보다 약 1 dB 높은 방사이득을 갖는다는 것을 확인하였다. 그러므로 제안된 안테나는 목표 방향에서 지향성 방사패턴을 갖도록 설계되었으며, 이는 제안된 기계학습을 통한 안테나 설계기법이 유효하다는 것을 의미한다.

## V. 결 론

본 논문에서는 950~1,050 MHz 대역에서 동작하고, 목표 방향( $\varphi=180^\circ$ ,  $40^\circ<\theta<50^\circ$ )에서 지향성을 갖는 꺾인 모노폴 안테나를 제안하였다. 목표 주파수 대역에서 안테나가 양질의 임피던스 정합 특성과 목표 방향에서의 지향성 방사특성을 가질 수 있도록, 안테나 구조를 3개의 꺾인 부분선로로 구성하였다. 목표 성능에 부합하는 최적 안테나 구조를 도출하기 위해서 DNN 구조의 기계학습 모델을 활용하여 안테나 성능을 예측하였다. 기계학습 모델은 안테나 설계변수와 성능 평가값으로 구성된 학습데

표 6. 목표 방향으로부터의 예측된 총이득  
Table 6. Estimated total gain in the target direction.

Direction ( $\varphi=180^\circ$ )	Ideal molopole (dBi)	Gain of resulting antenna (dBi)	
		HFSS	Measurement
$\theta=40^\circ$	2.9965	4.1288	3.8020
$\theta=41^\circ$	3.0393	4.1373	3.9090
$\theta=42^\circ$	3.0735	4.1383	3.9130
$\theta=43^\circ$	3.0993	4.1318	4.1080
$\theta=44^\circ$	3.1172	4.1183	3.8890
$\theta=45^\circ$	3.1276	4.0979	3.9950
$\theta=46^\circ$	3.1308	4.0908	4.1910
$\theta=47^\circ$	3.1272	4.0374	3.9580
$\theta=48^\circ$	3.1171	3.9979	3.9950
$\theta=49^\circ$	3.1009	3.9524	4.0750
$\theta=50^\circ$	3.0789	3.9013	4.1200

이터로 훈련되었으며, 성능 평가값의 경우, 동작 주파수 대역의 반사손실과 목표 방향의 방사이득이 고려된 평가 함수로 계산하였다. 또한, 기계학습 모델 훈련 과정 중, 기계학습 모델의 훈련 성숙도는 다양한 지표값(MSE와  $R^2$ )을 이용하여 확인하였으며, 훈련된 기계학습 모델과 상용 시뮬레이터로 예측한 표본 안테나의 성능 평가값을 비교하여, 기계학습 모델의 안테나 성능 예측 능력을 검증하였다.

검증된 기계학습 모델에 격자 탐색 방법을 적용하여 설계 목표에 부합하는 최적 안테나 구조를 도출하였으며, 최적 안테나의 제작과 측정을 통해 기계학습 모델의 유효성을 재검증하였다. 제작된 안테나의 반사손실과 방사패턴 측정값을 상용 시뮬레이션 결과값과 비교한 결과, 제작된 안테나는 983.5~1,037.5 MHz의 반사손실 대역폭과 목표 방향에서 약 4.1 dBi의 방사이득을 가져 시뮬레이션 결과값과 유사한 특성값이 도출되었음을 확인하였다. 따라서 본 연구에서 제안한 기계학습을 활용한 안테나 설계기법은 안테나 설계 시 안테나의 성능을 예측하는데 활용될 수 있다고 판단한다.

## References

- [1] C. A. Balanis, *Antenna Theory: Analysis and Design*, 4th

- ed. Hoboken, NJ, John Wiley and Sons, 2016.
- [2] J. Y. Choo, H. S. Choo, I. M. Park, and Y. S. Oh, "Design of crooked wire antennas for UHF band RFID reader," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 32, no. 12, pp. 471-481, May 2005.
- [3] D. Kim, C. Y. Park, Y. Kim, H. Kim, and Y. J. Yoon, "Ultra-wideband cavity-backed four-arm sinuous antenna with low height and uniform gain characteristics," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 32, no. 8, pp. 699-707, Aug. 2021.
- [4] J. Choo, H. Choo, I. Park, and Y. Oh, "On the design of multi-layered polygonal helix antennas," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 17, no. 3, pp. 249-258, Mar. 2006.
- [5] J. G. Park, Y. S. Chung, W. J. Kang, J. W. Shin, J. H. So, and C. Cheon, "Optimal shape design of dual reflector antenna based on genetic algorithm," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 26, no. 5, pp. 445-454, May 2015.
- [6] C. M. Seong, O. H. Kwon, and D. C. Park, "Pattern synthesis of rotated-type conformal array antenna using enhanced adaptive genetic algorithm," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 26, no. 8, pp. 758-764, Aug. 2015.
- [7] Y. Rahmat Samii, E. Michielssen, *Electromagnetic Optimization by Genetic Algorithms*, New York, NY, John Wiley & Sons, 1999.
- [8] J. Robinson, Y. Rahmat-Samii, "Particle swarm optimization in electromagnetics," *IEEE Transactions on Antennas and Propagation*, vol. 52, no. 2, pp. 397-407, Feb. 2004.
- [9] T. H. Lim, D. Jang, S. G. Park, and H. Choo, "Optimization of a 36-element broadband direction-finding antenna array using printed vivaldi array elements with extended flares," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 31, no. 8, pp. 655-662, Aug. 2020.
- [10] Y. Sharma, H. H. Zhang, and H. Xin, "Machine learning techniques for optimizing design of double T-shaped monopole antenna," *IEEE Transactions on Antennas and Propagation*, vol. 68, no. 7, pp. 5658-5663, Jul. 2020.
- [11] J. Choo, T. H. A. Pho, and Y. H. Kim, "Machine learning technique to improve an impedance matching characteristic of a bent monopole antenna," *Applied Sciences*, vol. 11, no. 22, p. 10829, Nov. 2021.
- [12] A. Rácz, D. Bajusz, and K. Héberger, "Effect of dataset size and train/test split ratios in QSAR/QSPR multiclass classification," *Molecules*, vol. 26, no. 4, p. 1111, Feb. 2021.
- [13] V. Sze, Y. H. Chen, T. J. Yang, and J. S. Emer, "Efficient processing of deep neural networks: A tutorial and survey," *Proceedings of the IEEE*, vol. 105, no. 12, pp. 2295-2329, Dec. 2017.
- [14] D. P. Kingma, J. Ba, "Adam: A method for stochastic optimization," in *The 3rd International Conference for Learning Representations*, San Diego, CA, May 2015.
- [15] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Computer Science*, vol. 7, p. e623, Jul. 2021.
- [16] A. Botchkarev, "A new typology design of performance metrics to measure errors in machine learning regression algorithms," *Interdisciplinary Journal of Information, Knowledge, and Management*, vol. 14, pp. 45-76, 2019.
- [17] P. Liashchynskyi, P. Liashchynskyi, "Grid search, random search, genetic algorithm: A big comparison for NAS," 2019. Available: <http://arxiv.org/abs/1912.06059>
- [18] ANSYS, Available: <http://www.ansys.com>

박 재 윤 [국립안동대학교 전자공학과/학부생]

<https://orcid.org/0000-0002-1155-5939>



2017년 3월~현재: 국립안동대학교 전자  
공학과 학부생  
[주 관심분야] 안테나 이론 및 기술

주 재 율 [국립안동대학교/교수]

<https://orcid.org/0000-0002-5804-858X>



2004년 2월: 홍익대학교 전기전자공학부  
(공학사)  
2006년 2월: 홍익대학교 전파통신공학과  
(공학석사)  
2014년 2월: 한국과학기술원 전기 및 전자  
공학과 (공학박사)  
2020년 9월~현재: 국립안동대학교 전자

공학과 교수  
[주 관심분야] Antenna 설계 및 EMC 등

안 인 범 [국립안동대학교 전자공학과/학부생]

<http://orcid.org/0000-0002-7236-8782>



2022년 3월~현재: 국립안동대학교 전자  
공학과 학부생  
[주 관심분야] 안테나 이론 및 기술