

# 머신러닝을 활용한 2D 루프 코일 기반 자기장 집속(MFC) 기법

김원구, 김민승, 이은수  
 한양대학교 ERICA 전자공학부

Machine Learning-Based Magnetic-Field FoCusing with 2D Loop Coils

Wongu Kim, Minseung Kim, Eunsoo Lee  
 Hanyang University ERICA, Electrical Engineering

## ABSTRACT

본 논문에서는 머신러닝을 활용하여  $B=AI$  수식의 A Matrix를 학습함으로써 특정 지점에 자기장을 집속할 수 있는 머신러닝 기반 Magnetic-Field FoCusing(MFC) 기술을 제안한다. 기존의 Biot-Savart 법칙에 기반한 방법은 복잡한 수식 해석과 계산을 요구하며, 특히 자기장 집속 포인트 및 코일 개수의 증가, 3차원 확장 시 행렬 차수와 변수의 급증으로 인해 계산 시간이 크게 증가하는 단점이 있다. 이를 해결하기 위해 본 연구에서는 수식 계산 대신 머신러닝의 지도학습 알고리즘을 활용하여, 2D coil array 조건에서 A Matrix를 학습하는 두 가지 방법을 제안한다. Matrix 곱을 통한 학습과 Neural Network를 통한 학습 두 가지 방법으로 자기장 집속이 가능함을 제시하고, 시뮬레이션을 통해 제안된 MFC 기술이 2D 2x2 배열에서 자기장을 성공적으로 집속할 수 있음을 검증하였다. 또한, 두 가지 A Matrix 학습 방법에 따른 성능 차이를 비교 분석하였다.

## 1. 서론

무선 충전은 최근 몇 년간 다양한 전자기기 및 산업 분야에서 필수적인 기술로 자리 잡고 있다. 최근 사용자의 편의성 증대 목적을 넘어 전기차 혹은 웨어러블 기기와 같은 전자기기 디바이스들의 이동성과 연속적인 사용을 가능하게 하는 점, 그리고 새로운 애플리케이션의 요구에 대응할 수 있는 유연성을 장점으로 하는 무선 충전에 대한 요구가 더욱 증대되고 있다. 기존의 무선 전력 시스템으로는 다수의 모바일 기기를 동시에 충전할 수 있는 Wi-Power Zone과 같은 솔루션이 있다. 이 기술은 고주파 자기장을 이용하여 근거리 전송을 구현하였지만, 근거리에서 발생하는 전자기파에 의한 인체 안전 문제가 있다. 또한 송수신 코일 간 거리에 따라 전송 효율이 급격하게 떨어지는 문제점, 그리고 충분한 자속밀도를 제공하지 못해 충전 효율이 떨어지는 단점이 존재한다. 이와 같은 자기장 균등 생성 방식과는 달리 [1]-[2], 자기장을 특정 위치에 집중시켜 충전 효율을 높이는 새로운 방식이 제안되기도 했다 [3]. 하지만 이 기술은 2D 평면 코일 배열만으로도 매우 복잡한 수학적 모델링을 필요로 하며, 집속 위치와 코일 수의 증가에 따라 Matrix equation의 차원이 급격히 커져 계산의 복잡성과 시간이 크게 늘어나는 문제점이 있다. 또한 Biot-Savart 법칙을 기반으로 한 단순한 수식만으로는 구현하고자 하는 3차원 공간에서의 자기장 집속에 한계가 존재한다.

이와 같은 전자기 유도(Electromagnetic Induction)를 통한 무선전력전송(WPT)이 인체 안전 문제를 지니고 있음에 반해, Radio Frequency(RF) 무선전력전송(WPT)는 Beam-forming 기술을 통해 원하는 지점에 집중하여 전력을 전송하여 이 문제

를 해결할 수 있다는 장점을 지니고 있다 [4]-[5]. 그러나, RF WPT 시스템은 여전히 고출력 증폭기와 안테나의 효율 저하 문제를 가지며, 변환 손실로 인한 전송 효율이 30% 이하로 낮은 점은 여전히 해결해야 하는 과제이다.

본 논문에서는 기존의 복잡한 계산을 통한 자기장 집속 기술을 개선하기 위해 머신러닝 기반의 지도학습을 활용한 새로운 방식을 제안한다. 기존 방식은 Biot-Savart 법칙에 따라 복잡한 수식을 사용해 A Matrix와 전류 방정식을 도출해야 했으나, 제안된 방법은 지도학습을 통한 Matrix 곱과 Neural Network의 학습 방법으로 이를 간소화한다. 이를 통해 특정 위치로의 자기장 집속을 직관적이고 효율적으로 수행할 수 있으며, 시뮬레이션 결과를 통해 그 성능을 입증하고 학습 방법에 따라 비교하였다.[1]

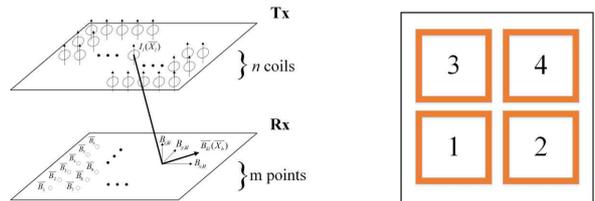


그림 1. 2D coil array 기반 Magnetic-Field FoCusing (MFC) 개념(좌) 및 본 논문에서 적용된 2x2 coil array(우)

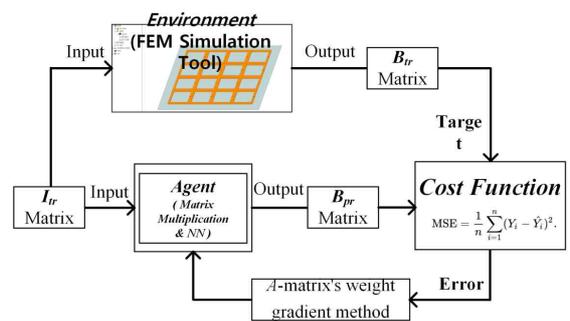


그림 2. 제안하는 MFC 머신러닝 알고리즘

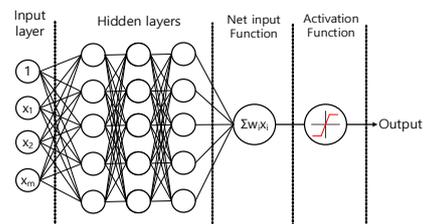


그림 3. Neural Network의 구성

## 2. 제안하는 Machine Learning 기반 Magnetic-Field FoCusing (MFC) 기술

본 논문에서 제안하는 MFC 시스템은 그림 1과 같이 다중 평면 코일 및 이와 동일한 차원을 갖는 집속 포인트로 나타낼 수 있다. 이 시스템은 여러 코일로 구성된 2D 송수신 coil array를 포함하며, 각 코일은 상이한 크기와 위상을 갖는다. 그림 1(좌)의  $n$  coils는 자기장 집속이 가능한 지점을 나타내며, 이는 송신 코일을 의미하는  $m$  points와 동일한 개수를 갖는다. 1D coil array로 구성된 경우 Biot-Savart 법칙을 통해 전류와 자기장 간의 관계를 표현할 수 있으며, 이를 통해 자기장을 목표하는 위치로 집속시킬 수 있다.

$$\vec{B}_k = \sum_{l=1}^n \vec{B}_{kl} = \vec{x}_0 \sum_{l=1}^n B_{x,kl} + \vec{y}_0 \sum_{l=1}^n B_{y,kl} \quad (1a)$$

$$\begin{bmatrix} B_{x,1} \\ B_{x,2} \\ \vdots \\ B_{x,m} \end{bmatrix} = \begin{bmatrix} a_{11x} & a_{12x} & \cdots & a_{1nx} \\ a_{21x} & a_{22x} & \cdots & a_{2nx} \\ \vdots & \vdots & & \vdots \\ a_{m1x} & a_{m2x} & \cdots & a_{mnx} \end{bmatrix} \begin{bmatrix} I_1 \\ I_2 \\ \vdots \\ I_n \end{bmatrix} \Leftrightarrow \mathbf{B}_x = \mathbf{A}_x \mathbf{I}$$

$$\begin{bmatrix} B_{y,1} \\ B_{y,2} \\ \vdots \\ B_{y,m} \end{bmatrix} = \begin{bmatrix} a_{11y} & a_{12y} & \cdots & a_{1ny} \\ a_{21y} & a_{22y} & \cdots & a_{2ny} \\ \vdots & \vdots & & \vdots \\ a_{m1y} & a_{m2y} & \cdots & a_{mny} \end{bmatrix} \begin{bmatrix} I_1 \\ I_2 \\ \vdots \\ I_n \end{bmatrix} \Leftrightarrow \mathbf{B}_y = \mathbf{A}_y \mathbf{I} \quad (1b)$$

위 (1) 수식을 통해 아래 (2) 수식과 같이 자기장과 전류의 관계를 간단히 정리할 수 있다.

$$\mathbf{B} = \mathbf{A} \mathbf{I} \rightarrow \mathbf{I} = \mathbf{A}^T (\mathbf{A} \mathbf{A}^T)^{-1} \mathbf{B} \quad (2a)$$

$$\text{where } \mathbf{A} \equiv \begin{bmatrix} \mathbf{A}_x \\ \mathbf{A}_y \end{bmatrix}, \mathbf{B} \equiv \begin{bmatrix} \mathbf{B}_x \\ \mathbf{B}_y \end{bmatrix} \quad (n \geq 2m) \quad (2)$$

수식 (1a)의 경우 1D 시스템에서는  $\vec{x}_0$  벡터만을 고려하며, 이때 총 두 개의  $m \times n$  형태 A Matrix로 표현할 수 있다. 그러나 코일의 개수와 집속 지점이 증가하고, 1D 및 2D를 넘어 3D로 확장될 경우, A Matrix의 복잡성은 기하급수적으로 증가한다. 이로 인해 단순 계산만으로 특정 지점에 자기장을 집속하기 위한 전류 해를 도출하는 것이 현실적으로 매우 어렵다.

표 1.  $2 \times 2$  coil array test set

	$P_1$	$P_2$	$P_3$	$P_4$	$P_1$	$P_2$	$P_3$	$P_4$
$I_{tr}$ [A]	9.0	2.0	0.0	4.0	9.0	2.0	0.0	4.0
$B_{tr}$ [ $\mu$ T]	67.0	19.8	15.9	28.4	67.0	19.8	15.9	28.4
<b>Training</b>	After training Matrix 곱 for A Matrix				After training NN for A Matrix			
$I_{pr}$ [A]	94.8	68.8	-51.1	65.2	8.3	-3.2	-3.92	3.4
$B_{pr}$ [ $\mu$ T]	726.4	479.5	372.8	441.2	62.1	29.4	31.4	25.6

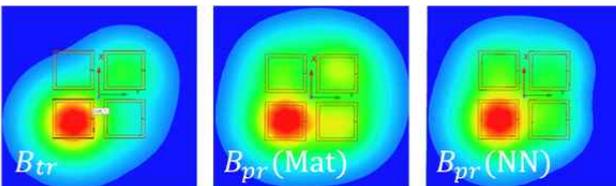


그림 4.  $B_{tr}$  와  $B_{pr}(\text{Mat})$  &  $B_{pr}(\text{NN})$  비교

이에 대한 개선된 시스템으로 본 논문에서는 그림 2와 같이 정해진 전류 조합들을 Simulation Program(Ansys)로 들여 보낸다. 전류입력에 따른  $B_{tr}$  값들이 I-B pair를 이룬다. Neural Network를 통한 학습방식은 시뮬레이션으로 전류 조합들이 들어가면, 이와 동일한 전류 조합들이 A Matrix의 Input으로 들어간다. 이때 출력되는 자기장 값을  $B_{pr}$ 라고 가정하고, Cost function에  $B_{tr}$ 와 출력된  $B_{pr}$ 를 넣어 자기장에 대한 MSE(Mean Square Error)를 각각 구하고 평균을 낸다. 이를 기반으로 전체적인 오차에 대한 평가를 하고, 이 평가를 기반으로 각 코일별 Gradient를 주어 A Matrix를 업데이트한다. Matrix 곱을 통한 학습 방법은  $\mathbf{B} = \mathbf{A} \mathbf{I}$ 의 수식을 A Matrix 행렬곱 모델을 통해 Neural Network와 유사한 역할을 하도록 Cost function과 Weight gradient 모델을 각각 설계하여 알고리즘을 구성하였다.

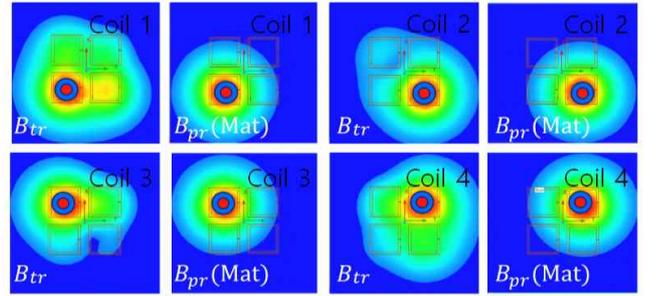


그림 5. Matrix 곱 기반 자기장 집속 결과

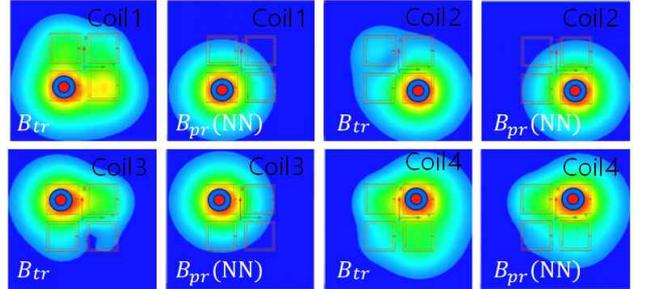


그림 6. Neural Network 기반 자기장 집속 결과

## 3. 시뮬레이션을 통한 검증

본 논문에서 제안한 머신러닝을 기반으로 한 MFC 성능을 검증하고, Matrix 곱과 Neural Network 두 가지 학습 방법에 따른 성능 차이를 비교 분석하기 위해 그림 2와 같이 시뮬레이션 모델링을 구성하였다. 본 논문에서는 그림 1(우)과 같이  $2 \times 2$  coil array의 4개(1, 2, 3, 4)번 코일의 자기장 집속 지점을 두고 Matrix 곱을 통해 학습한 결과와 Neural Network를 60개의 임의 설정한  $I_{tr}$ 값과 이를 통해 도출된 자기장 값인  $B_{tr}$ 를 통해 학습시키고, 일부 test set을 통해 검증한 결과를 표 1에 나타내었다.

그림 2의 제안하는 머신러닝 알고리즘을 통해 수식(2)의 A Matrix가 학습되었고, reverse A Matrix인  $A^{-1}$ 를 통해 목표하는  $B_{tr}$ 를 생성하는 전류의 해  $I_{pr(Mat)}$  &  $I_{pr(NN)}$ 을 표 1과 같이 도출할 수 있다. 결국 머신러닝을 통해 학습된  $A^{-1}$ 로  $I_{pr}$ 를 도출하였고, 이 값으로  $B_{pr}$ 를 확인할 경우  $B_{tr}$ 와 동일해야 하며, 이는 그림 4의 B-Plot을 통해 확인할 수 있다. 제안하는 머신러닝 알고리즘을 통해 도출된  $A^{-1}$ 를  $2 \times 2$  coil array에 학습 방법별로 MFC를 적용한 결과를 그림 5, 그림 6에 나타내었

다. 시뮬레이션 결과, Matrix 곱을 통해 학습시킨 시뮬레이션의 정답률은 53.8% (35/60), Neural Network를 통해 학습시킨 시뮬레이션의 정답률이 71.6% (43/60)로 더 높았다. 자기장 집속 정답의 판단은 집속되는 자기장 크기 순서별 집속 경향성을 기준으로 판단하였다. 이를 통해 머신러닝 알고리즘을 이용하여 목표하는 지점에 자기장을 집속시킬 수 있음을 확인하였으며, 이를 통한 두가지 A Matrix 학습 방법에 따른 머신러닝 알고리즘을 통한 무선전력전송이 가능함을 시뮬레이션을 통해 검증하였다.

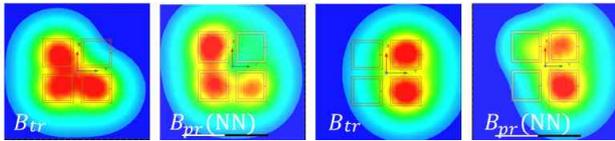


그림 7. [3 Layer - 100 Node] MFC 시뮬레이션 정답 B-Plot

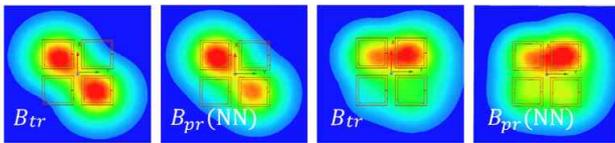


그림 8. [2 Layer - 50 Node] MFC 시뮬레이션 정답 B-Plot

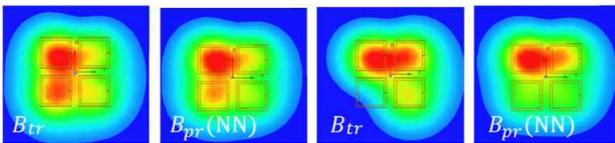


그림 9. [2 Layer - 10 Node] MFC 시뮬레이션 정답 B-Plot

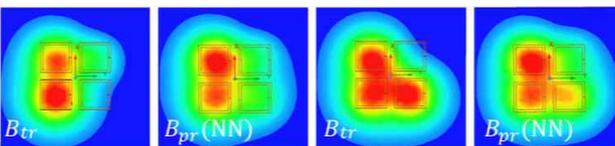


그림 10. [2 Layer - 5 Node] MFC 시뮬레이션 정답 B-Plot

표 2. Hyper parameter에 따른 시뮬레이션 정답률 비교

	3L-100N	2L-50N	2L-10N	2L-5N
Accuracy (%)	30.0	50.0	71.6	31.7
Correct Ans / Total Data	18 / 60	30 / 60	43 / 60	19 / 60

Neural Network 학습 프로세스에서 Hyper parameter에 따른 시뮬레이션 결과를 비교하였다. 본 논문에서는 Neural Network의 Hyper parameter로 Layer와 Node 개수를 설정하였고, [3 Layer - 100 Node], [2 Layer - 50 Node], [2 Layer - 10 Node], [2 Layer - 5 Node]의 시뮬레이션 결과를 비교하였다. 그림 7은 [3 Layer - 100 Node] Hyper parameter의 MFC 시뮬레이션 정답 B-Plot을 나타낸 것으로, 30%(18/60)의 정답률을 보였다. 그림 8에서는 [2 Layer - 50 Node]의 Hyper parameter 값을 가진 Neural Network에서의 학습된 결과 B-Plot이며, 50%(30/60)의 정답률을 가졌다. 그림 9에서는 [2 Layer - 10 Node]의 시뮬레이션 정답 B-Plot을 보인다. 이때의 정답률은 71.6%(43/60)로 진행한 네 가지 조합의 Hyper parameter 값에 따른 시뮬레이션 결과 중 가장 높은 정답률을 보였다. 그림 10은 [2 Layer - 5 Node]의 정답 B-Plot으로 31.7%(19/60)의 정답률을 보였다. 본 알고리즘 학습 모델에 적합한 Layer와 Node 개수로 71.6%의 정답률을 보인 [2 Layer

- 10 Node]를 시뮬레이션 결과에 따라 선택하였고, 이는 가장 낮은 30%의 정답률을 보인 [3 Layer - 100 Node] 대비 71.6%로 약 2.39배 정답률이 증가했음을 보인다. Hyper parameter와 더불어 본 논문에서 머신러닝 모델의 Parameter로 Weight와 Bias를 갖는다. Weight의 경우 Weight Gradient 모델에 따라 A Matrix를 최적화시킨다. 그러나 Bias는 본 논문의 머신러닝 알고리즘에서 시뮬레이션 결과 큰 영향을 미치지 않는 것으로 확인되어, 시뮬레이션에서 변수로 고려하지 않았다.

#### 4. 결 론

본 논문에서는 기존의 Biot-Savart 법칙을 통한 복잡한 A Matrix 계산 대신, 머신러닝 기반의 Matrix 곱을 이용한 학습과 Neural Network 학습을 통한 자기장 집속(Magnetic-Field FoCusing) 기술을 제안하였다. 시뮬레이션을 통해 Neural Network 학습 방법이 Matrix 곱을 통한 학습 방법보다 높은 정답률을 가져 더 효과적인 학습 모델임을 검증하였고, Neural Network 학습 방법의 Hyper parameter 값에 따른 시뮬레이션 B-Plot 정답률 비교를 통해, 본 논문에서 제안하는 알고리즘 학습 모델에 적합한 Hyper parameter 값을 정답률이 71.6%로 가장 높았던 [2 Layer - 10 Node]로 설정하였다.

이를 통해 본 논문에서 제안하는 Neural Network 학습 방법의 경우 기존 복잡한 수학적 모델을 대체하여 coil array의 수가 많아지거나 시스템이 3D로 확장되더라도 목표하는 시스템의 효율적 구현이 가능함을 제시하였다. 이후 진행될 연구에서는 지도학습과 강화학습의 결합을 통한 자기장 집속 정확도를 높이는 방법을 추가하고, 2x2 coil array에서 3x3, 4x4 coil array의 MFC까지 진행할 예정이다. 궁극적으로는 자기장의 크기뿐만 아니라 자기장 집속의 위상까지 알고리즘 상에 도입하여 3D coil array의 Magnetic-Field FoCusing(MFC)을 목표로 한다.

#### 참 고 문 헌

- [1] Eun S. Lee *et al.*, "A Modularized IPT with Magnetic Shielding for a Wide-range Ubiquitous Wi-Power Zone," *IEEE Trans. Power Electron.*, vol. 33, no. 11, pp. 9669-9690, Nov. 2018.
- [2] Eun S. Lee *et al.*, "Six Degrees of Freedom Wide-range Ubiquitous IPT for IoT by DQ Magnetic Field," *IEEE Trans. Power Electron.*, vol. 32, no. 11, pp. 8258-8276, Nov. 2017.
- [3] Ji H. Kim, Bo H. Choi, Hoi R. Kim, and Chun T. Rim, "2-D Synthesized Magnetic Field Focusing Technology With Loop Coils Distributed in a Rectangular Formation," *IEEE Trans. on Ind. Electron.*, vol. 10, no. 4, pp. 3216-3333, Apr. 2017.
- [4] Md. Ullah, *et al.*, "A Review on Antenna Technologies for Ambient RF Energy Harvesting and Wireless Power Transfer: Designs, Challenges and Applications," *IEEE Access*, vol. 10, no. 4, pp. 17231-17267, Feb. 2022.
- [5] Silver, D., Huang, A., Maddison, C. *et al.*, "Mastering the Game of Go with Deep Neural Networks and Tree Search," *Nature*, 529, 484-489 (2016)