

신경회로망과 유한요소법을 이용한 편측식 선형유도전동기의 최적설계에 관한 연구

*임 달호, *박승찬, *박두진^o **장석명^o ***이철직
*한양대학교 전기공학과 **충남대학교 전기공학과 ***대림전문대학 전기공학과

Optimum Design of Single-Sided Linear Induction Motor Using the Neural Networks and Finite Element Method

*D. H. Im, *S. C. Park, *D. J. Park^o **S. M. Jang^o ***C. J. Ree
*Hanyang University **Chungnam Nat'l University ***Daelim Junior College

Abstract - A new method for the optimal design of a single-sided linear induction motor (SLIM) is presented. The method utilizes the neural networks and finite element method for optimizing the design parameters of SLIM. The finite element analysis is used to produce a variety of neural networks training data and the neural networks is used for optimizing the design parameters by sequential unconstrained minimization technique (SUMT).

As a result, it is known that the novel method is very efficient and accurate as an optimization technique.

I. 서 론

최근에는 고도의 복잡분산형 정보처리기법의 하나인 신경회로망이 비선형문제를 학습에 의하여 빠른속도로 해석할수 있다는 장점에 의해 전자, 제어분야에서 뿐만아니라 구조설계, 최적화 문제에 있어서도 응용되어지고 있다[1][2].

본 연구에서는 SLIM의 설계 변수를 신경회로망과 유한요소법 그리고 순차 비제약 최소화기법(SUMT)을 이용하여 최적화 한다. 최적 설계변수를 구하는데 있어서는 많은 반복계산을 요구하는데, 한번의 계산에 많은 시간을 필요로하는 유한요소법을 이용한 기준의 최적화 기법은 최적설계변수의 산출에 있어 상당한 시간을 소요하게된다. 그러나, 신경회로망을 이용한 최적화 기법은 네트워크의 비선형성을 이용함으로써 기존의 방법에 비해 계산시간을 많이 줄일수 있다[2][3].

본 연구에서는 신경회로망을 이용한 새로운 최적화기법을 제안하였으며, 유한요소법을 이용한 기준의 최적화기법에 의해 구한 결과값과 비교검토하였다.

II. FEM의 적용 및 최적화문제의 정식화

A. 유한요소해석

계변수가 교류 정상상태에서 시간적으로 정현적인 변화를 한다고 가정하여, 이것을 복소수로 표현하고 시간미분 $\frac{\partial}{\partial t}$ 를 $j\omega$ 로 치환하면, 그림1과 같은 SLIM의 속도를 고려한 지배방정식은 식(1)과 같다.

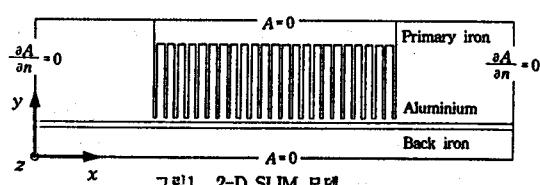


그림1. 2-D SLIM 모델

$$-\frac{\partial}{\partial x} \left(\frac{1}{\mu} \frac{\partial A}{\partial x} \right) + \frac{\partial}{\partial y} \left(\frac{1}{\mu} \frac{\partial A}{\partial y} \right) = -J + j\omega A + \sigma v_x \frac{\partial A}{\partial x} \quad (1)$$

여기서, μ 는 투자율, ω 는 전원 각주파수, σ 는 2차도체판의 도전율이다. 철심의 투자율 μ 는 선형해석일때 1차 철심의 투자율은 $3000\mu_0$, Back iron의 투자율은 $300\mu_0$ 로 하였으며, 비선형 해석일 때는 직접수렴법을 이용하였다[4].

Galerkin법을 사용하여 식(1)을 정식화한후, 전체철점의 벡터포텐셜과 각상의 전류를 미지수로 하는 행렬로 표현하면 식(2)와 같이 된다.

$$\begin{bmatrix} H_{1,1} & \dots & H_{1,n} \\ \vdots & & \vdots \\ H_{n,1} & \dots & H_{n,n} \end{bmatrix} \begin{bmatrix} A_1 \\ \vdots \\ A_n \end{bmatrix} + \begin{bmatrix} M_{1,1} & \dots & M_{1,3} \\ \vdots & & \vdots \\ M_{n,1} & \dots & M_{n,3} \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} = \begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix} \quad (2)$$

또한 전압, 전류 및 벡터포텐셜의 관계를 행렬로 나타내면 다음과 같이 된다.

$$\begin{bmatrix} Q_{1,1} & \dots & Q_{1,n} \\ \vdots & & \vdots \\ Q_{n,1} & \dots & Q_{n,n} \end{bmatrix} \begin{bmatrix} A_1 \\ \vdots \\ A_n \end{bmatrix} + \begin{bmatrix} R_a + j\omega L_a & 0 & 0 \\ 0 & R_b + j\omega L_b & 0 \\ 0 & 0 & R_c + j\omega L_c \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} = \begin{bmatrix} v_a \\ v_b \\ v_c \end{bmatrix} \quad (3)$$

여기서 R_a , R_b , R_c 는 각 상의 저항이며, L_o 는 코일 End부분의 누설인덕턴스이다.

식(2)와 식(3)으로부터 각철점의 벡터포텐셜과 각상의 전류를 미지값으로 하는 다음과 같은 계방정식을 얻을수 있다.

$$\begin{bmatrix} (H) & (M) \\ (Q) & (Z) \end{bmatrix} \begin{bmatrix} (A) \\ (I) \end{bmatrix} = \begin{bmatrix} (0) \\ (V) \end{bmatrix} \quad (4)$$

여기서, (A) 는 철점에서의 벡터포텐셜, (I) 와 (V) 는 각각 상전류, 상전압, 즉, $(A) = [A_1 \dots A_n]^T$, $(I) = [i_a \ i_b \ i_c]^T$, $(V) = [v_a \ v_b \ v_c]^T$ 이다.

적분경로 l 에 대해 작용하는 힘의 x 성분인 추력 F_x 는 Maxwell stress tensor법을 이용하여 나타내면 식(5)와 같이 된다.

$$F_x = \int_l \frac{W}{2\mu_0} ((B_x^2 - B_y^2)n_x + 2n_x B_x B_y) dl \quad [N] \quad (5)$$

여기서, W 는 1차철심의 적층폭이다.

B. 비선형최적화 문제의 정식화

일반적으로 비선형 최적화문제는 다음과 같이 주어진 제약조건하에서 목적함수의 최소화로 표현된다.

$$g_j(X) \leq 0 \quad (j=1,2,\dots,m) \text{의 조건하에서 } f(X) \text{를 최소화시키는 } X = (x_1, x_2, \dots, x_n) \text{를 구한다.} \quad (6)$$

그러나 목적함수를 최대화하기 위해서는 간단히 목적함수를 $-f(X)$ 로 하여, $\min(-f(X))$ 의 문제로 변환하여 풀다.

본 연구에서는 설계변수를 최적화하기 위하여 SUMT를 사용하였으며, 이 방법은 최적화 문제를 다른 형식으로 변환시킨 다음 일련의 순차 비제약 최소화 문제를 풀어냄으로써 해를 구한다. 이때의 변환함수는 최대화 문제인 경우 다음과 같다.

$$\phi_k = \phi(X, r_k) = -f(X) - r_k \sum_{j=1}^m 1/g_j(X) \quad (7)$$

SUMT에서의 비제약 최소화는 variable metric method를 이용하였으며, 탐색방향으로의 스텝길이는 cubic interpolation method에 의해 구하였다.

정전압(220[VI]) 구동하에서 기동주력/1차철심의 중량의 비가 최대가 되는 SLIM의 형상을 구하기 위한 목적함수는 식(8)과 같이 나타낸다.

$$f(X) = F_x/M \quad [\text{N/kg}] \quad (8)$$

여기서, F_x 는 기동주력이고 M 은 1차철심의 중량이다. 또한, 5개의 독립설계변수와 8개의 제약조건은 그림2와 표1에 표시한 것처럼 선택한다[5].

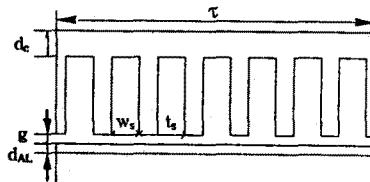


그림2. 돋립 설계 변수

표1. 돋립설계변수와 제약조건

독립설계변수	제약 조건
$X_1: k_t = w_s/t_s$ (슬롯폭/슬롯피치)	$g_1: 1\text{차철심의 최대자속}$ 밀도 $\leq 1.5 \text{ T}$
$X_2: d_{AL}$ (암부미금 두께)	$g_2: \text{back iron의 최대자속}$ 밀도 $\leq 1.1 \text{ T}$
$X_3: \tau$ (극 간격)	$g_3: 0.6 \leq k_t \leq 0.7$
$X_4: g$ (공극)	$g_4: 1.5 \text{ mm} \leq d_{AL} \leq 3.5 \text{ mm}$
$X_5: d_c$ (1차철심의 두께)	$g_5: 50 \text{ mm} \leq \tau \leq 60 \text{ mm}$ $g_6: 1.5 \text{ mm} \leq g \leq 3 \text{ mm}$ $g_7: 10 \text{ mm} \leq d_c \leq 30 \text{ mm}$ $g_8: \text{모터의 길이} \leq 22 \text{ cm}$

III. 최적화를 위한 신경회로망

A. 신경회로망 모델

신경회로망에 관한 연구는 인간의 두뇌의 신경세포모델에 대한 연구에서 시작되었다. 신경시스템은 여러층에 걸쳐 고밀도로 상호연결된 유니트로 구성되어 있는데, 그 각각의 유니트는 신경시스템에서 가장 기본적인 단위인 이상화된 뉴런으로써 동작한다[1]. 본 연구에서는 다층 Perceptron (MLP)형 신경회로망을 제안한다.

MLP형 신경회로망은 입력층과 출력층사이에 하나이상의 중간 층이 존재하는 신경회로망으로 그림3에 나타낸것과 같은 계층구조를 갖는다. 이때 입력층과 출력층사이의 중간층을 은닉층이라 부른다. 네트워크는 입력층, 은닉층, 출력층 방향으로 연결되어 있으며, 각층내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향의 네트워크이다. 일반적으로 각 층의 뉴런들은 서로 다른 연결강도를 가지고 다른층의 모든 뉴런들과 상호연결된다[2][3]. 본 연구에서는 은닉층을 3층으로 또한 각 은닉층의 뉴런수는 50개로 한 신경회로망을 사용하였으며, 여기서 입력은 5개의 돋립설계변수이고, 출력은 추력과 2개의 제약함수이다.

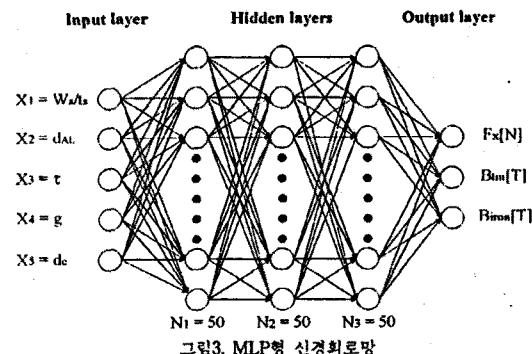


그림3. MLP형 신경회로망

$$v^{k_i} = f_{s_i}(u^{k_i}) \quad (9)$$

여기서, $u^{k_i} = \sum_j w_i^{(k-1)} j v^{(k-1)}$ 이며, $f_s(x)$ 는 시그모이드 비선형 활성함수, 즉, $(1/(1+e^{-x}))$ 이다. 그리고 j 는 $(k-1)$ 층에 있는 모든 뉴런들을 나타낸다.

본 연구에서는 신경회로망을 학습하기 위해 Backpropagation 알고리즘을 사용하였다. Backpropagation 학습 알고리즘은 최소 자승 알고리즘의 비선형적인 확장이다[1][2][6]. 이 알고리즘의 기본원리는 연결강도의 최적 근사치를 얻기 위하여, 또 주어진 입력에 대한 네트워크의 출력값을 기대값과 가능한 한 가깝게 하기 위하여 연결강도를 조정해나가는 최급강하법을 사용한다. 일반적으로 많이 사용되는 연결강도의 변화 Δw_{ij}^k 에 대한 수식은 다음과 같이 나타낸다.

$$w_i^{(k-1)} j, (n+1) = w_i^{(k-1)} j, (n) + \Delta w_{ij}^{(k-1)}, (n+1) \quad (10)$$

$$\Delta w_{ij}^{(k-1)}, (n+1) = \eta [\Delta w_i^{(k-1)}, (n+1)] - \alpha [\Delta w_i^{(k-1)}, (n)] \quad (11)$$

여기서,

$$\Delta w_i^{(k-1)} j = \Delta v_i^{k-1} f'_s(u^{k-1}) v^{(k-1)} \quad (12)$$

$$\Delta v_i^{k-1} = \epsilon (v_i^{k-1} - \hat{y}_i) \quad (k = N) \quad (13)$$

$$\Delta v_i^k = \sum_j \Delta w_{ij}^{(k-1)} f'_s(u^{k-1}) w^{(k-1)} j \quad (k = N-1, \dots, 1) \quad (14)$$

그리고 n 은 학습횟수, α 는 상수, \hat{y}_i 는 기대값, ϵ 는 작은값의 정수이며 $\Delta w_i^{(k-1)}, (n)$ 은 연결강도의 변화량으로 오차진동을 적게하여 수렴속도를 빨리하기 위하여 첨가한 모멘텀항이다.

B. 신경회로망의 학습

구성된 신경회로망은 설계변수의 변화에 대한 추력과 제약함수의 관계를 유한요소해석으로부터 구한 다음, 그 결과값을 교사데이터로하여 학습을 행한다. 이때 철심의 투자율이 선형일 때와 비선형일 때 각각에 대하여 교사데이터를 작성한다. 본 연구에서 사용된 총 교사데이터는 각각 243개이며, 이들중 몇개를 표2에 나타내었다.

표2. 신경회로망의 학습을 위한 교사데이터

NO.	입력					출력(선형)			출력(비선형)		
	X_1	X_2	X_3	X_4	X_5	F_x	B_m	B_{mm}	F_x	B_m	B_{mm}
1	0.60	1.5	50	1.50	10	65.81	1.344	1.137	67.19	1.362	1.133
2	0.65	1.5	55	1.50	20	74.57	1.251	1.241	75.65	1.260	1.239
3	0.70	2.5	60	2.25	30	77.81	1.210	1.032	79.05	1.217	1.062
4	0.60	2.5	50	2.25	10	60.59	1.384	0.860	61.74	1.407	0.878
5	0.65	3.5	55	3.00	20	63.10	1.287	0.760	64.05	1.293	0.788
6	0.70	3.5	60	3.00	30	70.22	1.211	0.828	71.25	1.218	0.853

* $X_1 \dots X_5 : [\text{mm}]$, $F_x : [\text{N}]$, $B_m B_{mm} : [\text{T}]$

유한요소해석으로 구한 표2와 같은 243개의 교사데이터를 사용하여 신경회로망을 교사데이터들의 평균 학습오차가 0.5%이내로 수렴할때까지 반복학습을 행하였다. 학습과정에서 연결강도의 초기값은 임의의 작은값으로 하였으며, 이렇게 학습된 신경회로망에 설계변수를 입력하여 구한 출력값중 몇개를 표3과 표4에 나타내었다.

표3. 철심의 투자율이 선형일때의 신경회로망의 출력

NO.	입력					출력		
	X ₁	X ₂	X ₃	X ₄	X ₅	F _x (Err.%)	B _{tm} (Err.%)	B _{loss} (Err.%)
1	0.60	1.5	50	1.50	10	67.44 (2.43)	1.334 (0.74)	1.149 (1.06)
2	0.65	1.5	55	1.50	20	74.58 (0.01)	1.266 (1.20)	1.243 (0.16)
3	0.70	2.5	60	2.25	30	77.86 (0.06)	1.204 (0.50)	1.035 (0.29)
4	0.60	2.5	50	2.25	10	60.22 (0.61)	1.371 (0.94)	0.866 (0.70)
5	0.65	3.5	55	3.00	20	62.12 (1.55)	1.296 (0.70)	0.753 (0.92)
6	0.70	3.5	60	3.00	30	70.63 (0.58)	1.204 (0.58)	0.837 (1.09)

* X₂ . . . X₅ : [mm], F_x : [N], B_{tm} B_{loss} : [T]

표4. 철심의 투자율이 비선형일때의 신경회로망의 출력

NO.	입력					출력		
	X ₁	X ₂	X ₃	X ₄	X ₅	F _x (Err.%)	B _{tm} (Err.%)	B _{loss} (Err.%)
1	0.60	1.5	50	1.50	10	67.28 (0.13)	1.371 (0.66)	1.130 (0.26)
2	0.65	1.5	55	1.50	20	75.48 (0.22)	1.271 (0.87)	1.218 (1.69)
3	0.70	2.5	60	2.25	30	78.99 (0.09)	1.195 (1.81)	1.056 (0.56)
4	0.60	2.5	50	2.25	10	62.80 (1.72)	1.372 (2.49)	0.849 (3.30)
5	0.65	3.5	55	3.00	20	64.28 (0.36)	1.282 (0.85)	0.780 (1.02)
6	0.70	3.5	60	3.00	30	71.12 (0.18)	1.210 (0.66)	0.850 (0.35)

* X₂ . . . X₅ : [mm], F_x : [N], B_{tm} B_{loss} : [T]

IV. 결과검토

표5는 유한요소법을 이용한 기존의 최적화기법과 신경회로망을 이용한 새로 제안된 최적화기법 각각으로부터 최적결과값을 구하는데 걸린 계산기의 CPU시간을 나타낸다. 또한, 표6에는 두 방법으로부터 구한 최적설계변수값과 목적함수, 제약함수값을 나타내었다.

이로부터 알수있듯이 설계변수를 최적화하는데 있어 신경회로망과 유한요소법을 이용한 새로 제안된 최적화기법을 사용함으로써 기존의 최적화기법에 비해 약 1/3 정도로 계산시간을 줄일 수 있었다. 또한 득립변수들에서는 평균오차 0.88%, 제약함수들 사이에서는 0.77%의 평균오차가 발생함으로 새로 제안된 최적화기법의 정확성을 확인할 수 있었다. 표6에서 X₂ 가 가장 많은 오차를 수반하는데, 이는 2차축 알루미늄 두께의 설계 민감도가 가장 크기 때문인것으로 사료된다.

그림4는 철심의 투자율이 선형일때와 비선형일때 각각에 대하여 신경회로망을 이용한 최적화기법으로부터 구한 최적 모델의 자속분포를 나타낸다.

표5. 기존의 최적화 방법과 신경회로망을 이용한 새로운 최적화 방법의 CPU 계산시간비교

CPU 계산시간 [sec]	기존의 최적화 방법 (투자율 선형)	새로 제안된 방법	
		투자율 선형	투자율 비선형
최적화 계산시간	109,131	40	38
학습 시간 (243개의 data)	*	26,762	76,770
교사데이터(243개) 산출 시간	*	11,907	61,464

표6. 기존의 최적화 방법과 신경회로망을 이용한 새로운 최적화 방법과의 결과값 비교

득립변수, 목적 함수 제약함수	기존의 방법(선형)	새로운 방법(선형)	오차(%)	새로운 방법(비선형)
X ₁ (w _s /t _s)	0.6996	0.6996	0.00	0.6995
X ₂ (d _{AL})	2.6089	2.5101	3.79	2.4041
X ₃ (t)	53.2789	53.4288	0.28	55.3360
X ₄ (g)	1.5005	1.5028	0.15	1.5031
X ₅ (d _c)	10.0254	10.0083	0.17	10.0089
OBJ. (F _x /M)	33.7920	33.4123	1.12	34.5258
B _{tm}	1.4997	1.4978	0.13	1.4033
B _{loss}	1.0099	1.0241	1.41	1.0909

* X₂ . . . X₅ : [mm], OBJ. (F_x/M) : [N/Kg], B_{tm} B_{loss} : [T]

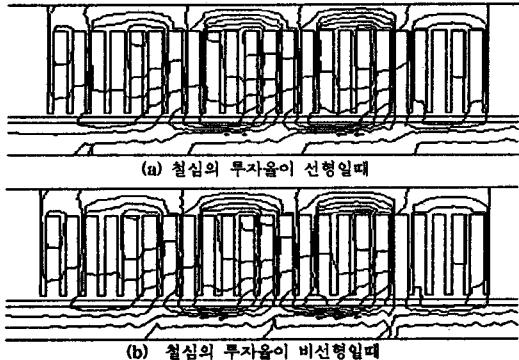


그림4. 신경회로망을 이용하여 구한 최적모델의 자속분포

V. 결론

본 연구에서는 신경회로망과 유한요소법을 이용한 편축식 선형유도전동기의 새로운 최적설계기법을 제안하였다. 제안된 최적화기법을 유한요소법을 이용한 기존의 최적화기법과 비교검토한 결과, 최적설계값들을 구하는데 있어 상당한 계산시간을 줄일 수 있었으며, 이로인해 기존의 최적화기법으로는 해석이 어려웠던 철심의 투자율이 비선형일때에 대해서도 최적설계변수를 구할 수 있었다. 또한 상대오차가 득립변수들에서는 평균 0.88%, 제약함수들에서는 평균 0.77%정도밖에 발생하지 않았으므로 제안된 최적화기법의 정확성을 확인할 수 있었다.

참고문헌

- Juhachi ODA, Takayuki MIZUKAMI and Anlin WANG : "Design of adaptive structure using neural network", Transactions of the Japan society of mechanical engineers (A), vol. 58, Sept. 1992
- O. A. Mohammed, D. C. Park, F. G. Uler, and C. Ziqiang : "Design optimization of electromagnetic devices using artificial neural networks", IEEE Trans. Mag. vol. 28, no. 5 pp. 2805-2807, Sept. 1992
- T. S. Low, Bi Chao : "The use of finite element method and neural networks for the solution of inverse electromagnetic problems", IEEE Trans. Mag., vol. 28, no. 5, pp. 2811-2813, Sept. 1992
- Philip G. Potter, Gregory K. Cambrell : "A combined finite element and loop analysis for nonlinear interacting magnetic fields and circuit", IEEE Trans. Mag. vol. 19, no. 6, pp. 2352-2355, Nov. 1983
- D. H. Im, S. C. Park, and J. W. Im : "Design of single-sided linear induction motor using the finite element method and SUMT", IEEE Trans. Mag., vol. 29, no. 3, March 1993
- Paul J. Werbos : "Backpropagation through time : what it does and how to do it", Proc. of IEEE : Special Issue on Neural Networks, vol. 78, no. 5, Sept. 1992