

RBF 뉴럴네트워크를 이용한 리니어형 초전도 전원장치의 비선형적 충전전류특성 해석

Nonlinear Characteristic Analysis of Charging Current for Linear Type Magnetic Flux Pump Using RBFNN

정윤도 · 박호성 · 김현기 · 오성권*

Yoon-Do Chung, Ho-Sung Park, Hyun-Ki Kim and Sung-Kwun Oh*

수원대학교 전기공학과

요 약

본 연구에서는 초전도 전원장치의 비선형적인 충전특성을 이론적으로 해석하기 위해서 Radial Basis Function 뉴럴 네트워크를 적용하였으며 이를 바탕으로 초전도 부하 마그넷에 따른 충전특성의 경향을 해석하였다. 본 논문에서는 안정적인 충전전류를 발생시키고 충전전류를 쉽게 제어할 수 있는 리니어형 초전도 전원장치를 개발하였고, 극저온 시스템에서 충전전류 특성을 실험적으로 수행하였다. 이를 통해 초전도 전원장치는 초전도 선재(초전도 Nb 박막)를 사용하기 때문에 비선형적인 충전전류 특성을 가짐을 알 수 있었다. 일반적으로, 극저온에서의 실질적인 실험에 있어서 주변 환경에 따른 냉각 비용 문제 등이 대두되기 때문에 다양한 실험을 수행하는데 연구의 어려움이 있다. 따라서 본 논문에서는 개발된 초전도 전원장치의 주파수에 대한 비선형적인 충전 특성을 기반으로 지능형 알고리즘인 RBF 뉴럴 네트워크를 통해서 그 결과를 예측하고 이에 대해서 지능 모델을 구현하였다. 본 논문에서 사용된 RBF 뉴럴 네트워크에서는 효율적인 데이터 처리를 위해서 은닉층에 FCM 클러스터링 알고리즘을 사용하였으며, 클러스터의 수가 모델의 은닉층에서의 노드의 수가 되도록 설계하였다.

키워드 : 초전도 전원장치, RBF 뉴럴 네트워크, FCM 클러스터링

Abstract

In this work, to theoretically analyze the nonlinear charging characteristic, a Radial Basis Function Neural Network (RBFNN) is adopted. Based on the RBFNN, an charging characteristic tendency of a Linear Type Magnetic Flux Pump (LTMFP) is analyzed. In the paper, we developed the LTMFP that generates stable and controllable charging current and also experimentally investigated its charging characteristic in the cryogenic system. From these experimental results, the charging current of the LTMFP was also found to be frequency dependent with nonlinear quality due to the nonlinear magnetic behaviour of superconducting Nb foil. On the whole, in the case of essentially cryogenic experiment, since cooling costs loomed large in the cryogenic environment, it is difficult to carry out various experiments. Consequently, in this paper, we estimated the nonlinear characteristic of charging current as well as realized the intelligent model via the design of RBFNN based on the experimental data. In this paper, we view RBF neural networks as predominantly data driven constructs whose processing is based upon an effective usage of experimental data through a prudent process of Fuzzy C-Means clustering method. Also, the receptive fields of the proposed RBF neural network are formed by the FCM clustering.

Key Words : Superconducting flux pump, RBF neural network. FCM clustering method

1. 서 론

기존의 구리선을 이용하여 고자장을 발생시키는 방식은 오래전에 한계점에 이르렀고, 현재는 저온 초전도 선재를 사용한 고자장 마그넷을 응용한 산업기기가 개발되었으나, 저온 초전도 선재는 냉각을 위해 액체헬륨을 사용하기 때문에 냉각비용이 비싸고 무엇보다 자기장의 크기가 커질수록 초전도체로 흘릴 수 있는 전류의 크기가 제한된다는 임계전류 특성으로 인하여 기존 저온초전도 마그넷의 경우 초고자장 응용이 불가능하다 [1].

접수일자 : 2009년 4월 20일

완료일자 : 2009년 12월 31일

본 논문은 본 학회 2009년도 춘계학술대회 에서 선정된 우수논문입니다 (18권6호(2009년 12월 25일 발행)에 논문지 게재요청 드림)

+교신저자

이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2009-0074928) 그리고 본 연구는 경기도지역협력연구센터사업의 일환으로 수행하였음 [GRRC 수원2009-B2, U-city 보안감시 기술협력센터].

이와 같은 문제를 해결하기 위해 고온 초전도 선재를 사용한 마그넷을 저온 마그넷에 삽입하는 방식만이 유일한 해결방법으로 여겨지고 있어 고온 초전도 선재를 사용한 마그넷의 관한 기반기술의 전 세계적으로 중요한 연구 과제로 진행되고 있다. 그러나 고자장의 영구모드에서 전류 감쇄가 크기 때문에 전류 감쇄를 보상해주어 안정적인 전류 stability를 유지하는 초전도 전원장치가 반드시 필요하다. 따라서 고온 초전도 선재를 이용한 고자장 마그넷 개발과 함께 초전도 전원장치의 개발은 중요한 핵심 기술로 전 세계적으로 많은 연구가 진행되고 있다 [2].

고자장용 마그넷의 전원장치로서 우리는 새로운 형태의 리니어형 초전도 전원장을 개발하였고 기본적인 충전 특성을 실험적으로 수행하였다 [3]. 개발된 초전도 전원장치를 다양한 부하에 따른 충전전류 특성 실험을 함에 있어 주변 환경에 따른 비용 문제 등이 대두됨에 따라 지능형 알고리즘을 통해 그 결과를 예측하고 이론적 해석을 하고자 한다.

본 논문에서는 개발된 초전도 전원장치의 원리와 비선형적인 충전전류 실험결과를 소개하고 실험을 통해 구축된 데이터를 기반으로 지능형 알고리즘인 RBF 뉴럴 네트워크 [4-6]를 통해서 그 결과를 예측하고 이에 대해서 이론적으로 해석하였다. 사용된 RBF 뉴럴 네트워크에서는 효율적인 데이터 처리를 위해서 은닉층에 FCM 클러스터링 알고리즘 [7]을 사용하였으며, 클러스터의 수가 모델의 은닉층에서의 노드의 수가 되도록 설계하였다.

2. 리니어형 전원장치

2.1 동작원리 및 구조

초전도 전원장치의 원리는 그림 1과 같이 초전도 Nb 박막에 이동하는 자속을 증가하면 증가하는 자속의 방향을 방해하는 방향으로 맴돌이 전류가 발생한다. 초전도 Nb 박막은 저항 값이 거의 0 이므로 에너지 소모가 거의 없다. 따라서 연속적으로 이동자속이 증가되면 전류가 발생하는데 이와 같은 전류를 충전 전류라 한다. 이것이 회전형 초전도 전원장치의 충전 메커니즘이다. 발생된 충전전류는 연결된 초전도 부하마그넷에 충전된다. 이와 같은 원리를 근거로 리니어형 초전도 전원장치를 제작하였다.

그림 2-(a)는 개발된 리니어형 초전도 전원장치의 구조이다. 리니어 철심 코어는 리니어 유도 전동기의 구조와 흡사하다. 3상 armature 코일을 중앙 슬롯에 감아 전류를 흘리면 공극에서 이동자속이 발생한다. 공극에 Nb 박막을 설치하면 발생된 이동자속이 박막에 침투되어 충전전류를 발생시키며 충전전류는 그림 2-(b)에서 보이듯이 부하 마그넷에 충전된다.




그림 1. 초전도 전원장치의 원리.

Fig. 1. The mechanism of the superconducting flux pump




그림 2. 리니어형 전원장치.

Fig. 2. Linear type magnetic flux pump.

2.2 실험 장치 및 측정 결과

개발된 LTMFP의 동작특성을 조사하기위해 1.3mH 과 543mH의 부하코일과 각각 연결하여 충전전류특성을 조사되었다. 그림 3은 LTMFP와 부하 코일의 연결도이다. 부하 코일과 초전도 Nb 박막은 영구전류폐회로 (Loop 1)를 형성하고 있다. LTMFP의 교류 코일에 PWM 인버터에 의해 3상 전류가 인가된다.




그림 3. LTMFP와 부하 마그넷의 연결도.

Fig. 3. The connection diagram between LTMFP and load magnet.

그림 3은 실험을 위해 설치된 리니어형 전원장치 시스템의 연결도이다. 공극과 부하코일에 홀센서를 설치하여 인가 자속의 세기와 충전전류를 각각 측정한다.




그림 4. 연결된 리니어형 초전도 전원장치 시스템.

Fig. 4. Fabricated linear type superconducting power supply.

그림 4는 LTMFP와 인덕턴스 크기가 543 mH인 부하 마그넷 (실제 NMR 마그넷의 약 1/20 크기)이 연결된 제작된 리니어 전원장치 시스템의 사진이다.

그림 5는 리액터가 있을 때와 없을 때의 공극에서의 동극의 교류자속의 세기를 보여준다. 입력 전류는 직류 전류 10 A 와 교류전류 6 A_{peak} 의 주파수 7 Hz의 값을 갖는다. 발생한 교류 자속의 세기는 -20 mT에서 200 mT의 측정값을 얻었다. 발생한 교류 자속은 공극에 설치된 초전도 Nb sheet에 인가하여 normal spot의 계속적인 진행을 발생시켜 펌핑 전류를 부하코일에 충전시킨다. 그림 5-(a)는 인덕터가 설치 안했을 경우 발생한 교류 자속의 크기를 보여주고 있고 이 경우, 주파수 왜곡이 크게 발생하여 펌핑 전류의 노이즈가 많이 포함되어 측정되었다. 반면에, 그림 5-(b)와 같이 인덕터가 설치된 경우는 발생한 교류 자속의 주파수왜곡이 크게 감소되었음이 측정되었다. 그와 같은 이유로 안정적인 펌핑 전류가 발생함이 실험적으로 측정되었다.

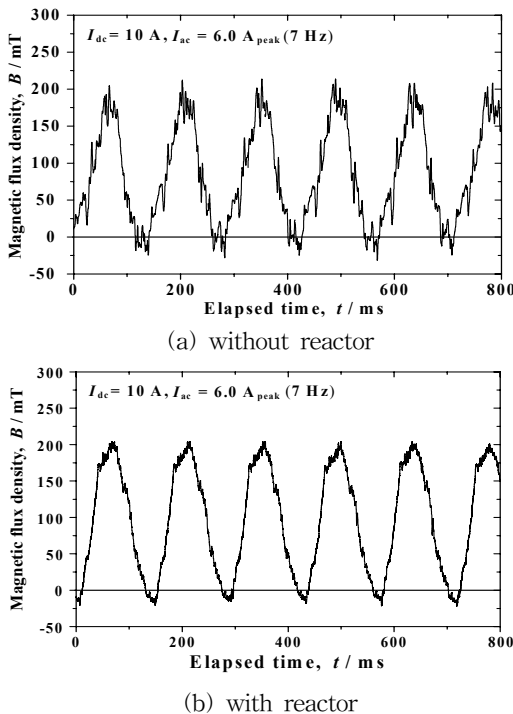


그림 5. 리액터를 연결했을 경우와 설치하지 않은 경우 DC 10 A AC 6 A_{peak} (7 Hz)의 조건에서 공극에서의 자장분포 측정 값.

Fig. 5. Temporal variations of the magnetic flux density at the central part in the air gap with DC bias current at 10 A and AC current 6 A_{peak} (7 Hz) with reactor and without reactor.

그림 6은 DC 10 A AC 6A_{peak} 조건에서 주파수 변화에 따른 충전전류 특성값을 나타낸다. 이때 동작시간 400초이며 각각의 주파수 7, 9, 15 Hz에서 충전 전류의 값은 동작 시간 100초 이후부터 포화되기 시작했고 각 주파수에 따라 발생한 충전전류 값은 각각 22.7, 25.3, 29.8 A이다. 충전전류가 주파수의 증가에 따라 증가하는 현상을 조사하였다. 3상 인버터를 전원으로 사용하여 고조파에 의한 영향으로 충전전류에 노이즈가 많이 발생하였다. 이 같은 노이즈를 줄이기 위해 리액터를 설치한 후 543mH 부하마그넷에서 충전전류 특성을 조사하였다.




그림 6. 부하마그넷 L=1.3mH일 때 충전전류 실험 결과.
Fig. 6. Measured results for charging current with load magnet 1.3mH.

그림 7은 부하코일의 크기 543 mH하에서 주파수 변화에 따른 충전 전류의 변화를 보여준다. 이때 동작시간 18분 동안 주파수 변화에 따른 충전전류의 변화를 보여준다. 각각의 주파수 10, 15, 20, 50, 60 Hz에서 충전 전류의 값은 5.0, 7.3, 10.2, 3.0, 1.3 A가 측정되었다. 주파수가 20 Hz 까지는 주파수가 증가할 때 충전 전류가 증가함을 실험적으로 측정하였다. 이때 20Hz 이상의 주파수에서는 충전전류가 급격히 감소함을 실험적으로 측정하였다. 즉, 충전전류가 주파수의 크기에 따라 비선형적인 특성을 갖게 됨을 실험적으로 조사하였다. 결국, 리니어형 초전도 전원장치의 최적의 동작조건은 20 Hz 미만임을 실험적으로 확인하였다.

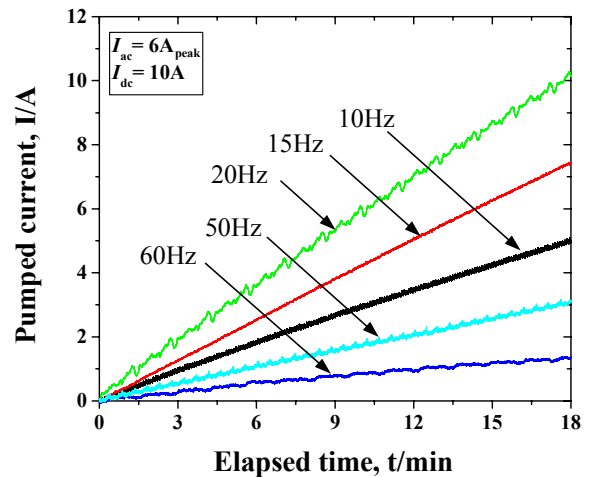


그림 7. 부하마그넷 L=543 mH일 때 충전전류 실험 결과.
Fig. 7. Measured results for charging current with load magnet 543mH.

표 1과 표 2는 서로 다른 부하 마그넷의 크기에 따라 주파수를 변화시켰을 때 발생한 충전전류비율(mA/s) 값을 나타낸다.

표 1. 부하마그넷 L=1.3mH에서 충전전류비율.
Table 1. Pumping current rate with load magnet 1.3 mH.

L(mH)	I _{dc} (A)	I _{ac} (A _{peak})	f(Hz)	펌핑전류 (mA/s)
1.3	10	5.5	6	198
			8	223
			20	284
		6	7	227
			9	253
			15	298

표 2. 부하마그넷 L=543mH에서 충전전류비율.
Table 2. Pumping current rate with load magnet 543 mH.

L(mH)	I _{dc} (A)	I _{ac} (A _{peak})	f(Hz)	펌핑전류 (mA/s)
543	10	6	7	3.4
			8	3.9
			9	4.2
			10	4.7
			12.5	5.8
			15	6.9
			17.5	8.3
			20	9.5
			25	8.4
			30	7.5
			35	6.2
			40	4.7
			50	2.8
			60	1.2

개발된 LTMFP는 주파수의 증가에 따라 충전전류가 증가하나, 임계주파수(20 Hz) 이상에서는 충전전류가 급격히 감소하는 비선형적인 동작특성이 발생하였다.

부하 마그넷의 크기에 따라 다양한 주파수에 따른 충전전류값을 정리하면 표 1과 표 2와 같다. 표 1은 부하 마그넷의 인덕턴스 값이 1.3mH인 경우의 AC 전류의 크기에 따라 초당 충전전류 (mA/s)의 실험값을 나타내고, 표 2는 부하 마그넷의 크기가 실제 NMR 마그넷의 약 1/20 크기인 0.543 H의 부하 마그넷에서의 AC 전류의 크기에 따른 초당 충전전류(mA/s)의 실험값을 나타낸다.

3. RBF 뉴럴 네트워크 설계

3.1 Fuzzy C-Means clustering method

본 논문에서는 일반적으로 데이터 전처리에 넓게 사용되어진 fuzzy c-means 방법(FCM)[7]을 이용하여 주어진 출력데이터를 분류하였다.

FCM은 주어진 데이터의 특징을 해석하여 파악된 데이터의 정보를 기반으로 입력 데이터를 분할함으로써 기존의 데이터 전처리 방법들보다 더 효율적이고 유기적으로 주어진 데이터의 특성을 파악하는 장점을 가지고 있다. 이러한 장점을 이용하여 본 논문에서는 FCM 알고리즘을 RBF 뉴럴네트워크를 구축하는데 사용하였다. 단계별 FCM 알고리

즘의 수행과정은 다음과 같다.

[단계 1] 클러스터의 개수를 결정하고, 소속행렬 U를 다음과 같이 초기화한다.

$$U = \left\{ u_{ik} \in [0, 1], \sum_{i=1}^c u_{ik} = 1 \forall k, 0 < \sum_{k=1}^N u_{ik} < N \forall i \right\} \quad (1)$$

[단계 2] [단계 1]로부터 얻어진 u_{ik} 값을 기반으로 각각의 클러스터에 대한 중심값과 소속 함수의 값을 구한다.

$$v_i = \{v_{i1}, v_{i2}\}, v_{ij} = \left(\frac{\sum_{k=1}^n (u_{ik})^m \cdot x}{\sum_{k=1}^n (u_{ik})^m} \right) \quad (2)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_k - v_i\|}{\|x_k - v_j\|} \right)^{2/(m-1)}} \quad (3)$$

[단계 3] 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬을 생성한다.

$$d_{ik} = d(x_k - v_i) = \left[\sum_{j=1}^l (x_{kj} - v_{ij})^2 \right]^{1/2} \quad (4)$$

[단계 4] 만일 식 (5)를 만족한다면 종료하고, 그렇지 않으면 r=r+1로 놓고 [단계 2]로 간다.

$$\|U^{(r+1)} - U^{(r)}\| \leq \epsilon (\text{tolerance level}) \quad (5)$$

3.2 제안된 RBF 뉴럴 네트워크

본 논문을 위해서 설계된 RBF 뉴럴 네트워크는 은닉층에서의 커널함수로써 주어진 데이터의 정보 입자화 특성을 파악하기 위하여 FCM clustering을 이용하였으며, 후반부 계수 동정에 있어서는 최소자승법을 이용하였다.

그림 8은 본 논문의 목적인 초전도 전원장치의 비선형적인 충전특성을 이론적으로 해석하기 위한 은닉층의 활성화함수로써 FCM 클러스터링 방법을 사용한 RBF 뉴럴 네트워크의 구조를 보여준다.

그림 8에서도 알 수 있듯이, 본 연구에서 사용된 은닉층에서의 노드의 수는 FCM 클러스터링에 의해서 분할된 클러스터의 수와 같으며, 본 연구에서는 은닉층에서의 노드의 수 즉, 클러스터를 2개에서 4개까지 세분화하여 그 특성을 파악하였다.




그림 8. 제안된 RBF 뉴럴 네트워크.

Fig. 8. The proposed RBF neural networks.

제안된 RBF 뉴럴 네트워크에서 후반부 다항식은 식 (6)에서 보이듯이 선형식을 이용하여 비선형 관계식을 형성하였다.

$$f_i = a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n = \sum_{k=1}^n a_{ik}x_k \quad (6)$$

여기서, i 는 은닉층에서의 노드의 번호($i=1, 2, \dots, h$)이고 k 는 입력변수의 수($k=1, 2, \dots, n$)를 의미한다.

후반부 선형식과 은닉층의 활성화함수를 통해서 얻어진 소속함수 u_i 의 결합으로 모델의 local model을 다음 식 (7)과 같이 구축한다.

$$\begin{aligned} \hat{y}_i &= u_i \times f_i \\ &= u_i \times \{a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n\} \\ &= \sum_{k=1}^n u_i \times (a_{ik}x_k) \end{aligned} \quad (7)$$

최종 모델식은 식 (8)과 같이 표현된다.

$$\begin{aligned} \hat{y} &= \sum_{i=1}^h \hat{y}_i = \sum_{i=1}^h (u_i \times f_i) \\ &= \sum_{i=1}^h \{u_i \times (a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n)\} \\ &= \sum_{i=1}^h \sum_{k=1}^n \{u_i \times (a_{ik}x_k)\} \end{aligned} \quad (8)$$

본 연구에서는 식 (9)를 최소로 하기 위해서 식 (8)의 후반부 계수를 최소자승법(Least square method)을 이용하여 계수를 최적화하였다.

모델의 출력에 대한 성능 지수식으로는 널리 사용되어진 식 (9)과 같이 Mean Square Error(MSE)를 사용하여 모델을 평가하였다.

4. 시뮬레이션 및 결과 고찰

본 논문에서 사용된 학습데이터는 표 2에서 보여준 것과 같이 실제 실험 장치를 통해서 얻은 수치 데이터를 이용하였다. 또한 객관적인 모델 성능의 평가를 위해서 10-fold cross-validation을 수행하였다.

표 3에서도 알 수 있듯이, 은닉층에서의 노드의 수가 3개인 경우가 다른 경우에 비해서 근사화 능력이 우수함을 알 수 있다.

표 3. 학습 데이터의 성능지수.

Table 3. Performance index of training data.

No. of nodes in the hidden layer		
2	3	4
0.4315±2.61e-6	0.0570±7.90e-7	0.1039±3.94e-5

또한 더 나아가 본 논문에서는 모델의 일반화 능력을 평가하기 위하여 표 4에서 보인 것과 같이 임의의 테스트 데이터를 생성하여 제안된 모델에 적용하였으며 그에 대한 결과를 그림 9에 표현하였다. 즉, 은닉층에서의 노드의 수가 3개인 경우 학습 데이터에 대한 성능이 0.0570인 모델을 선택하여 임의의 테스트 데이터에 대한 모델의 일반화 능력을 평가하였다.

그림 9에서도 알 수 있듯이, 제안된 모델을 사용한 경우 실제 실험을 통해서 얻은 결과값에 근사한 능력 및 미지의

입력값에 대한 일반화된 값을 실험을 통해서 얻은 결과값과 비슷하게 유추할 수 있음을 알 수 있었다.

표 4. 실험 장치를 통해 얻어진 데이터 집합.

Table 4. Data set obtained by experiment equipment.

Input				Output	
L(mH)	I _{dc} (A)	I _{ac} (A _{peak})	Training data	Testing data	C _{pr} (mA/s)
			f(Hz)		
543	10	6	7	7.5	3.4
			8	8.5	3.9
			9	9.5	4.2
			10	10.5	4.7
			12.5	14.5	5.8
			15	17	6.9
			17.5	19.5	8.3
			20	22	9.5
			25	28	8.4
			30	31	7.5
			35	37	6.2
			40	42	4.7
			50	53	2.8
			60	57	1.2

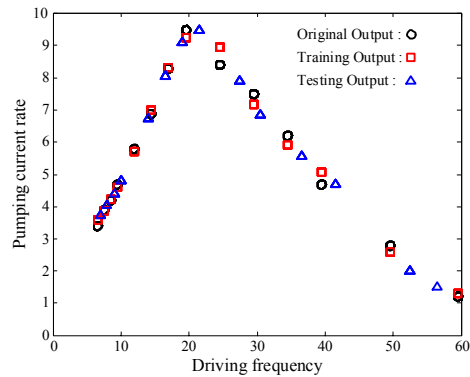


그림 9. 제안된 모델의 근사화 및 일반화 능력.

Fig. 9. Approximation and generalization abilities of the proposed model.

5. 결 론

본 연구에서는 초전도 전원장치의 비선형적인 충전특성을 이론적으로 해석하기 위해서 FCM 클러스터링 방법을 적용한 새로운 형태의 Radial Basis Function 뉴럴 네트워크를 제안하였으며 이를 바탕으로 초전도 부하 마그넷에 따른 충전특성의 경향을 해석하였다. 본 논문에서는 실질적인 실험에 있어서 주변 환경에 따른 비용 문제 등이 대두됨에 따라 개발된 초전도 전원장치를 통해 구축된 데이터를 기반으로 지능형 알고리즘인 RBF 뉴럴 네트워크를 통해서 그 결과를 예측하고 이에 대해서 이론적으로 해석하였다. 시뮬레이션에서도 보이듯이 제안된 RBF 뉴럴 네트워크는 초전도 전원장치의 비선형적인 충전 특성을 해석하는 효과적임을 알 수 있었으며 또한 더 나아가 실질적인 실험을 통해서가 아니어도 그에 대한 예상되는 충전 특성의 경향을 해석하는데도 우수함을 알 수 있었다.

참 고 문 헌

- [1] Markiewicz WD, Miller JR, Schwartz J, Trociewitz UP, Weijers HW, "Prospective on a superconducting 30 T/1.3 GHz NMR spectrometer magnet," *IEEE Transactions on Applied Superconductivity*, vol. 16, no. 2, pp. 1523-1526, 2006.
- [2] Y. Iwasa, "Microampere flux pump for superconducting NMR magnets Part1: basic concept and microtesla flux measurement," *Cryogenics*, vol. 41, pp. 385-391, 2001.
- [3] Yoondo Chung, Itsuya Muta, Tsutomu Hoshino, Taketsune Nakamura and M.H. Sohn, "Design and performance of compensator for decremental persistent current in HTS magnets using linear type magnetic flux pump," *Cryogenics*, vol. 44, no. 11, pp. 839-844, Nov. 2004.
- [4] M. Han and J. Xi, "Efficient clustering of radial basis perceptron neural network for pattern recognition," *Pattern Recognition*, vol. 37, pp. 2059-2067, 2004.
- [5] J. M. Vilaplana, J. L. P. Molina, and J. L. Coronado, "Hyper RBF model for accurate reaching in redundant robotic systems," *Neurocomputing*, vol. 61, pp. 495-501, 2004.
- [6] M. Wallace, N. Tsapatsoulis, and S. Kollias, "Intelligent initialization of resource allocating RBF networks," *Neural Networks*, vol. 18, pp. 117-122, 2005.
- [7] H.-S. Park, W. Pedrycz and S.-K. Oh, "Granular Neural Networks and Their Development Through Context-Based Clustering and Adjustable Dimensionality of Receptive Fields", *IEEE Trans. on Neural Networks*, vol. 20, no. 10, pp. 1604-1616, 2009.

저 자 소 개



정윤도(Yoondo Chung)

1999년 : 건국대학교 전기공학과 졸업(학사)
 2001년 : 연세대학교 전기전자공학과 졸업
 (공학석사)
 2007년 : 京都(Kyoto)대학교 전기공학과
 졸업(공학박사)
 2008년~현재 : 수원대학교 전기공학과
 겸임교수

관심분야 : 초전도 전력기기 개발, 초고자장용 NMR 마그넷
 설계 및 초전도 전원장치 개발

Phone : 031-229-8169

Fax : 031-220-2667

E-mail : ydchung@suwon.ac.kr



박호성(Hosung Park)

1999년 : 원광대학교 제어계측공학과 졸업
 (학사)
 2001년 : 원광대학교 제어계측공학과 졸업
 (공학석사)
 2005년 : 원광대학교 제어계측공학과 졸업
 (공학박사)
 2008년~현재 : 수원대학교 산업기술
 연구소 연구교수

관심분야 : Granular computing, Neuro-fuzzy computing,
 Evolutionary computing

Phone : 031-222-6544

Fax : 031-220-2667

E-mail : parkhs@suwon.ac.kr



김현기(Hyunki Kim)

1977년 : 연세대학교 전기공학과 졸업
 (학사)
 1985년 : 연세대학교 전기공학과 졸업
 (공학석사)
 1991년 : 연세대학교 전기공학과 졸업
 (공학박사)
 1989년~현재 : 수원대학교 전기공학과 교수

관심분야 : 시스템자동화 및 감시제어, 지능형 모델링 및
 제어등

Phone : 031-220-2666

Fax : 031-220-2667

E-mail : hkkim@suwon.ac.kr



오성권(Sungkwun Oh)

1981년 : 연세대학교 전기공학과 졸업
 (학사)
 1983년 : 연세대학교 전기공학과 졸업
 (공학석사)
 1993년 : 연세대학교 전기공학과 졸업
 (공학박사)

1983년~2004년 : 원광대학교 전기전자 및
 정보공학부 교수

2005년~현재 : 수원대학교 전기공학과 교수

관심분야 : 퍼지 시스템, 퍼지-뉴럴 네트워크, 고급
 computational intelligence, 자동화 시스템,
 지능 제어등

Phone : 031-229-8162

Fax : 031-220-2667

E-mail : ohsk@suwon.ac.kr