

리니어형 초전도 전원장치 모델링을 위한 입자화 기반 Neurocomputing 네트워크 설계

논문
59-7-23

Design of Granular-based Neurocomputing Networks for Modeling of Linear-Type Superconducting Power Supply

박호성* · 정윤도** · 김현기*** · 오성권†
(Ho-Sung Park · Yoon-Do Chung · Hyun-Ki Kim · Sung-Kwun Oh)

Abstract - In this paper, we develop a design methodology of granular-based neurocomputing networks realized with the aid of the clustering techniques. The objective of this paper is modeling and evaluation of approximation and generalization capability of the Linear-Type Superconducting Power Supply (LTSPS). In contrast with the plethora of existing approaches, here we promote a development strategy in which a topology of the network is predominantly based upon a collection of information granules formed on a basis of available experimental data. The underlying design tool guiding the development of the granular-based neurocomputing networks revolves around the Fuzzy C-Means (FCM) clustering method and the Radial Basis Function (RBF) neural network. In contrast to "standard" Radial Basis Function neural networks, the output neuron of the network exhibits a certain functional nature as its connections are realized as local linear whose location is determined by the membership values of the input space with the aid of FCM clustering. To modeling and evaluation of performance of the linear-type superconducting power supply using the proposed network, we describe a detailed characteristic of the proposed model using a well-known NASA software project data.

Key Words : Granular-based neurocomputing network, Linear-type superconducting power supply, Fuzzy c-means clustering method, Radial basis function neural networks, Local models, Receptive fields, Information granules

1. 서론

고자장 마그넷을 구현하기 위한 가장 효과적인 방법은 초전도 마그넷을 사용하는 것이다. Nuclear Magnetic Resonance (NMR)와 Magnetic Resonance Image (MRI)는 이와 같은 초전도 마그넷을 이용하여 상용화 되었다. 또한 초전도 전원장치 시스템 응용기술은 고자장 마그넷 기술 개발과 병행하여 마그넷의 안정적인 운전을 보장할 수 있는 핵심기술이다[1-2]. 그와 같은 필요성으로부터 우리는 리니어형 초전도 전원장치를 개발하였고 기본적인 동작특성을 다양한 조건에서 실험적으로 조사하였다.

본 논문에서는 개발된 초전도 전원장치는 대한 기본적인 동작 특성을 기반으로 다양한 부하에 따른 충전전류 특성 해석을 효과적으로 예측함은 물론 극저온 환경에서의 실험 비용 문제 등에 효율적으로 대처하고자 비선형성이 강한 실공정의 모델링 및 예측에 뛰어난 성능을 가진 Computational Intelligence (CI)[3-4]를 통해 리니어형 초전도 전원장치를

수학적으로 모델링하여 일반화하고자 한다.

CI 기술 중에서 중요한 연구 분야중의 하나로 자리매김하고 있는 방사형 기저 함수(Radial Basis Function : RBF) 신경 회로망은 뉴로 컴퓨팅분야에서 많은 관심과 더불어 이에 대한 다수의 비교적인 연구와 다양한 적용이 이루어지고 있다[5-7].

본 논문에서는 이러한 CI기술인 FCM 클러스터링 방법[8]과 RBF 신경 회로망을 접목한 neurocomputing 네트워크를 제안하여 리니어형 초전도 전원장치를 모델링하고자 한다. 즉, RBF 신경 회로망의 활성화함수로서 방사형 기저 함수의 형태를 가지고 있는 FCM 클러스터링 방법을 이용하여 주어진 정보 입자화의 효율적인 처리를 통한 실험적 데이터의 효과적인 사용을 기반으로 입자화 기반 neurocomputing 네트워크를 제안한다. 본 논문에서의 궁극적인 목적은 (a) 퍼지 클러스터링 알고리즘을 통한 주어진 실험적 데이터의 퍼지 입자화 사용, (b) 리니어형 초전도 전원장치의 모델링을 위한 모델의 근사화 능력과 LOOCV(Leave-One-Out Cross-Validation)[9-10]를 통한 모델의 일반화 능력 평가, (c) 네트워크의 출력층에서 표현된 뉴론의 함수적 연결의 표현과 같은 포괄적인 설계 방법론을 제안하는 것이다.

본 논문에서는 제안된 구조의 장점과 한계를 정량화하기 위하여 NASA software project 데이터[11-12]를 실험적 데이터로 이용하였다.

* 정 회 원 : 수원대 산업기술연구소 학술연구교수 · 공박

** 정 회 원 : 수원대 산업기술연구소 학술연구교수 · 공박

*** 정 회 원 : 수원대 공대 전기공학과 교수 · 공박

† 교신저자, 시니어회원 : 수원대 공대 전기공학과 교수 · 공박

E-mail : ohsk@suwon.ac.kr

접수일자 : 2009년 10월 9일

최종완료 : 2010년 4월 20일

2. 리니어형 초전도 전원장치

2.1 동작원리 및 구조

초전도 전원장치의 기본원리는 그림 1에 기초하여 설명되어진다. 두께 20 μ m 초전도 Nb 박막을 Nb-Ti부하 마그넷과 연결하여 초전도 페루프를 형성하고, 초전도 Nb 박막과 부하 마그넷을 액체 헬륨(4.2K)으로 냉각하여 초전도 상태를 유지시켜 초전도 영구전류상태를 유지시킨다. 그 상태에서 이동자계를 초전도 Nb박막에 인가시키면 침투된 영역을 상전도 영역이라 한다.

2.2 실험 장치 및 측정 결과

개발된 리니어형 초전도 전원장치의 동작특성을 조사하기 위해 1.3mH 과 543mH의 부하코일과 각각 연결하여 충전전류특성을 조사하였다. 그림 1은 Linear-Type Magnetic Flux Pump(LTMFP)와 부하 코일의 연결도이다.




그림 1 LTMFP와 부하 마그넷의 연결도
Fig. 1 The connection diagram between LTMFP and load magnet

그림 2는 DC 10A AC 6Apeak 조건에서 주파수 변화에 따른 충전전류 특성값을 나타낸다.




그림 2 부하마그넷 L=1.3mH일 때 충전전류 실험 결과
Fig. 2 Measured results for charging current with load magnet 1.3mH

본 논문에서는 제안된 입자화 기반 neurocomputing 네트워크를 그림 2와 그림 3에서 보여준 각각의 부하에서 주파수의 변화에 따른 충전전류율의 변화에 대한 실험치 데이터를 이용하여 리니어형 초전도 전원장치의 모델링 및 일반화를 평가하였으며, 이에 대한 결과는 '6장 시뮬레이션 및 결과과고찰'에서 자세하게 서술하였다. 즉, 본 장에서 언급한 고가의 실험 장치 및 고비용의 실험재료들을 새로이 사용하지

않고 이미 실험을 통해서 얻어진 데이터를 기반으로 입자화 기반 neurocomputing 네트워크를 통해서 효율적인 리니어형 초전도 전원장치를 모델링 하고자 한다.

그림 3은 부하코일의 크기 543mH하에서 주파수 변화에 따른 충전 전류의 변화를 보여준다.




그림 3 부하마그넷 L=543mH일 때 충전전류 실험 결과
Fig. 3 Measured results for charging current with load magnet 543mH

3. 일반적인 방사형 기저 함수 기반 신경 회로망

3.1 RBF 신경 회로망의 형태

RBF 신경 회로망[5-7]은 3개의 층을 가진 신경 회로망으로써 n 차원의 입력 벡터 $\mathbf{x}=[x_1, x_2, \dots, x_n]^T$ 는 은닉층을 통해서 비선형식으로 변환된다. 일반적으로 널리 사용되어진 가우시안 기저 함수의 형태는 다음과 같은 형태로 표현된다.

$$\Phi_i(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x}-\mathbf{v}_i\|^2}{2\sigma_i^2}\right) \quad (1)$$

여기서, $\Phi_i(\mathbf{x})$ 와 \mathbf{v}_i 그리고 σ_i 는 i번째 은닉층 노드에서의 출력 그리고 가우시안 기저 함수의 중심값과 폭을 의미한다. 네트워크의 출력 $y(\mathbf{x})$ 는 각각의 활성화 레벨의 선형 조합으로써 다음과 같이 계산된다.

$$y(\mathbf{x}) = \sum_{i=1}^K w_i \Phi_i(\mathbf{x}) \quad (2)$$

여기서, w_i 는 i번째 은닉층 출력과 출력층 사이의 연결 가중치를 의미한다.

3.2 RBF 신경 회로망의 설계

RBF 신경 회로망에 적용된 구조로서 모든 RBF 신경 회로망의 설계는 (a) 은닉층에서의 개발과 (b) 네트워크의 출력층에서의 뉴론들의 연결값의 최적화로 구성될 수 있다. 그러나 표준적으로 네트워크의 출력층에서 뉴론들의 연결값의 최적화 임무보다 더욱 중요한 것은 은닉층에서의 개발에 대한 네트워크의 효율적인 기능이다. 즉, 은닉층에서의 개발이 결정적인 RBF 신경 회로망 설계에 있어서 중요한 특징

으로 부각되기 때문이다.

기존의 논문들에서는 이와 같은 중요한 설계 이슈들을 다루기 위해서 여러 가지 방법을 시도하였다[13-15].

4. 정보 유사성 기반 차원성 축소

본 논문에서 제안한 입자화 기반 neurocomputing 네트워크 설계에 있어서 주축의 역할을 하는 FCM 클러스터링 방법[8]에 대해서 초점을 맞춘다. 즉, FCM 클러스터링 방법을 이용하여 제안한 입자화 기반 neurocomputing 네트워크의 활성화함수로 사용하여 주어진 데이터를 처리하였다.

U라 표시되는 partition matrix를 구하기 위한 FCM 클러스터링 방법의 알고리즘은 다음과 같다.

[단계 1] 클러스터의 개수를 결정하고, 소속행렬 $U^{(r)}$ 를 다음과 같이 초기화한다.

$$U^{(r)} = \left\{ u_{ik} \in [0,1], \sum_{i=1}^c u_{ik} = 1 \forall k, 0 < \sum_{k=1}^N u_{ik} < N \forall i \right\} \quad (3)$$

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

$$v_i^{(r)} = \{v_{i1}^{(r)}, \dots, v_{ic}^{(r)}\}, v_{ij}^{(r)} = \left(\frac{\sum_{k=1}^N (u_{ik})^m \cdot x_k}{\sum_{k=1}^N (u_{ik})^m} \right) \quad (4)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_k - v_j^{(r)}\|}{\|x_k - v_i^{(r)}\|} \right)^{2/(m-1)}} \quad (5)$$

여기서, $m > 1$ 은 퍼지화 계수를 나타내고, $v_i^{(r)}$ 는 입력 변수들의 중심값을 의미한다. 본 논문에서는 퍼지화 계수(m)의 범위를 1.8~3.4로 주어 다양한 퍼지화 계수를 모델에 적용하였다.

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

$$d_{ik} = d(x_k - v_i^{(r)}) = \left[\sum_{j=1}^n (x_{kj} - v_{ij}^{(r)})^2 \right]^{1/2} \quad (6)$$

[단계 4] 만일 식 (7)을 만족한다면 종료하고, 그렇지 않으면 $r=r+1$ 로 놓고 [단계 2]로 간다.

$$\|U^{(r+1)} - U^{(r)}\| \leq \epsilon (\text{tolerance level}) \quad (7)$$

식 (5)에서 생성된 partition matrix가 제안한 입자화 기반 neurocomputing 네트워크에서의 은닉층 출력으로 사용되어진다.

5. 입자화 기반 Neurocomputing network 설계

3장과 4장에서 언급되어진 알고리즘 및 구조를 기반으로 본 논문에서 제안한 입자화 기반 neurocomputing 네트워크는 그림 4에서 보인 것처럼 RBF 기반 네트워크 형태를 가진다.

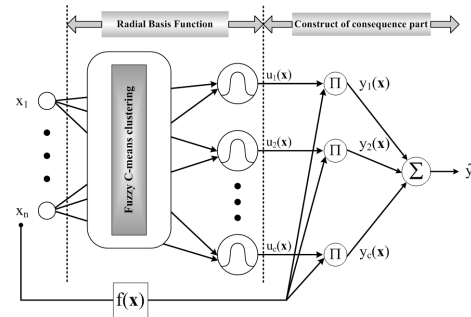


그림 4 제안된 neurocomputing network의 전체 구조

Fig. 4 The overall structure of the neurocomputing network

제안된 neurocomputing 네트워크는 주어진 데이터의 효율적인 처리를 위해서 은닉층의 활성화함수로써 FCM 클러스터링 방법을 이용하였다. FCM 클러스터링 방법을 이용한 경우 은닉층의 출력은 다음 식 (5)에서 나타나듯이 주어진 입력변수들의 소속정도가 된다.

그림 4에서 보여준 후반부 다항식 $f(x)$ 는 다음과 같은 선형식을 이루고 있다.

$$f_i(x) = a_{i0}x_0 + a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n \quad (8)$$

$$= \sum_{k=0}^n a_{ik}x_k$$

식 (5)와 식 (8)의 결합을 통해서 모델의 지역 모델이 다음 식 (9)에서 보인 것과 같이 이루어진다. 여기서, x_0 는 1의 값을 가진 입력이다.

$$y_i(x) = u_i(x) \times f_i(x) \quad (9)$$

$$= u_i(x) \times (a_{i0}x_0 + a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n)$$

$$\hat{y}(x) = \sum_{i=1}^c y_i = \sum_{i=1}^c \{u_i(x) \times f_i(x)\} \quad (10)$$

$$= \sum_{i=1}^c \{u_i(x) \times (a_{i0}x_0 + a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n)\}$$

$$= \sum_{i=1}^c \sum_{k=0}^n \{u_i(x) \times f_{ik}(x)\}$$

제안된 모델의 전체 출력은 식 (10)과 같이 모두 클러스터의 개수의 지역 모델의 가중된 평균에 의해서 계산된다.

본 논문에서는 기존의 논문들과의 비교 및 모델의 평가를 위해서 사용된 데이터에 따라서 식 (11)과 식 (12)에서 같이 2가지의 성능 지수식을 이용하여 제안된 모델의 성능을 평가하였다.

$$E_{MSE} = \frac{1}{N} \sum_{t=1}^N (y(x_t) - \hat{y}(x_t))^2 \quad (11)$$

$$E_{MMRE} = \frac{1}{N} \sum_{t=1}^N \frac{|y(x_t) - \hat{y}(x_t)|}{y(x_t)} \quad (12)$$

여기서, $y(x)$ 는 주어진 실제 출력 데이터이고 $\hat{y}(x)$ 는 모델의 출력 데이터를 의미한다.

6. 시뮬레이션 및 결과고찰


제안된 모델의 성능을 평가하기 위해서 주어진 데이터를 학습 데이터와 테스트 데이터로 구분하였으며, 학습 데이터에 대한 성능지수(PI)는 전체 데이터를 이용하여 구하였으며, 테스트 데이터에 대한 성능지수(EPI)는 모델의 일반화 평가에 널리 사용되어지고 있는 LOOCV 방법을 이용하였다 [9-10]. 또한 객관적이고 신뢰 가능한 결과를 얻기 위하여 시뮬레이션 각각의 경우 10번 반복을 하여 평균과 표준오차로 모델의 성능을 표현하였다.

6.1 NASA software project data


NASA software project 데이터는 2입력 (Developed Lines (DL), Methodology (ME)) 1출력 (Effort (E)) 구조를 가지는 데이터 집합이다[11-12]. NASA software project 데이터의 성능 지수식으로는 기존의 논문들과의 비교 및 평가를 위해서 식 (12)에서 보여준 MMRE(Mean Magnitude of Relative Error) 방법을 이용하여 모델의 일반화 능력을 평가한다. 표 1은 NASA software project 데이터를 이용한 neurocomputing 네트워크의 성능지수 값을 나타낸다.

표 1에서 볼 수 있듯이, 첫 번째 입력(DL)만을 사용한 경우, 가장 좋은 성능을 갖는 경우는 퍼지화 계수가 3.0이고 은닉층에서의 클러스터의 수가 5개인 경우로 PI=0.1047±0.0208, EPI=0.1529±0.0101인 값을 얻을 수 있었다. 모든 입력을 사용한 경우에 있어서 최고의 성능은 퍼지화 계수가 3.4인 경우로써, PI=0.0862±2.07e-7, EPI=0.1494±4.10e-6인 성능을 얻을 수 있었다.

그림 5는 표 1에서 보여준 제안된 모델의 성능 중에서 퍼지화 계수에 상관없이 은닉층에서의 노드 수의 증가에 따른 가장 우수한 성능을 가지고 있는 모델의 학습 및 테스트 데이터에 대한 평균과 표준오차에 대한 성능 값을 표시한 것



(a) Input variable : DL



(b) Input variable : DL and ME

그림 5 클러스터 수에 따른 성능지수

Fig. 5 Performance index treated as the number of clusters

이다. 표 2는 기존의 NASA software project 데이터를 이용한 지능형 모델들의 성능들을 나타낸 것이다.

표 2 선택된 모델의 성능과의 비교 분석

Table 2 Comparative analysis of the performance of selected model

Model	Input variables	MMRE		
		PI	EPI	
Linear regression[12]	DL	0.2110	0.2330	
	DL, ME	0.2110	0.2330	
RBF NN[11]	DL $\delta=0.1\%, \sigma=0.25, m=6$	0.1450	0.1881	
	DL $\delta=2\%, \sigma=0.75, m=4$	0.1470	0.2474	
	ME $\delta=0.1\%, \sigma=0.85, m=7$	0.0870	0.1907	
SVR Linear [12]	DL C=100, $\epsilon=10^{-4}$	0.1650	0.1790	
	DL C=10, $\epsilon=10^{-4}$	0.1480	0.1650	
	ME C=100, $\epsilon=10^{-4}$	0.1480	0.1740	
SVR RBF[12]	DL C=100, $\epsilon=10^{-3}, \gamma=10^{-2}$	0.1650	0.1890	
	DL C=100, $\epsilon=10^{-4}, \gamma=10^{-2}$	0.1370	0.1790	
	ME C=10, $\epsilon=10^{-4}, \gamma=10^{-1}$	0.1200	0.1800	
Gaussian process regression[17]	DL	0.2138	0.2453	
	DL, ME	0.1424	0.1940	
Proposed model	DL	m=2.0, c=3	0.132±8.4e ⁻⁸	0.173±1.2e ⁻⁶
		m=3.0, c=5	0.104±0.020	0.152±0.010
		m=3.2, c=5	0.101±0.019	0.169±0.014
	ME	m=2.0, c=3	0.104±1.7e ⁻⁸	0.221±6.9e ⁻⁷
		m=3.2, c=3	0.085±2.4e ⁻⁷	0.151±2.0e ⁻⁶
		m=3.4 c=3	0.086±2.0e ⁻⁷	0.149±4.1e ⁻⁶

6.2 리니어형 초전도 전원장치

본 논문의 주요 목적은 neurocomputing 네트워크를 통한 리니어형 초전도 전원장치의 모델링 개발에 있다.

본 장에서는 표 3에서 나타낸 것과 같이 리니어형 초전도 전원장치 입출력 데이터를 기반으로 모델링을 하고자한다.

표 3에서 보이듯이 리니어형 초전도 전원장치의 구체적인 성능을 평가하기 위하여 5가지 형태 (V1, V2, V3, V4, V5)

표 3 리니어형 초전도 전원장치 입출력 dataset

Table 3 Input-Output dataset of LTMFP

L(mH)	Input			Output		Index							
	IDC(A)	IAC (Apeak)	f(Hz)	Pumping current (mA/s)									
1.3	10	5.5	6.0	49.5	V1								
			8.0	55.8									
			20.0	71.0									
			7.0	56.8									
			9.0	63.3									
		6.0	15.0	74.5									
			543	10				5.5	7.0	2.6	V2		
									8.0	3.0			
									9.0	3.5			
									1.0	4.1			
15.0	5.7												
6.0	20.0	8.2			V5								
	7.0	3.4											
	8.0	3.9											
	9.0	4.2											
	10.0	4.7											
	V4	12.5	5.8	V3									
		15.0	6.9										
		17.5	8.3										
		20.0	9.5										
		25.0	8.4										
		30.0	7.5										
		35.0	6.2										
		40.0	4.7										
		50.0	2.8										
		60.0	1.2										

표 1 모델의 성능지수

Table 1 Value of the performance index for the NASA software project data

(a) Input variable : DL


m	No. of nodes in the hidden layer (c)									
	2		3		4		5		6	
	PI	EPI	PI	EPI	PI	EPI	PI	EPI	PI	EPI
1.8	0.176±3.7e-7	0.223±3.2e-7	0.134±3.4e-7	0.184±6.3e-7	0.128±0.001	0.183±0.007	0.106±0.011	0.540±0.160	0.088±0.007	5.475±1.454
2.0	0.188±3.7e-7	0.236±2.5e-7	0.132±8.4e-8	0.173±1.2e-6	0.133±0.001	0.206±0.013	0.104±0.016	0.268±0.051	0.080±0.006	1.664±0.240
2.2	0.195±3.5e-7	0.242±2.2e-7	0.131±2.6e-8	0.169±5.0e-7	0.141±0.002	0.214±0.006	0.116±0.018	0.202±0.012	0.080±0.001	0.739±0.115
2.4	0.197±3.6e-7	0.243±2.7e-7	0.133±1.6e-8	0.171±1.7e-6	0.149±6.9e-5	0.209±0.014	0.114±0.017	0.211±0.015	0.086±0.002	0.567±0.190
2.6	0.197±4.3e-7	0.241±1.9e-7	0.135±2.9e-8	0.173±1.5e-6	0.142±0.013	0.209±0.016	0.114±0.018	0.171±0.009	0.088±0.009	0.324±0.047
2.8	0.195±6.9e-7	0.238±4.6e-7	0.136±6.5e-8	0.177±4.2e-6	0.136±0.012	0.204±0.017	0.105±0.018	0.169±0.007	0.091±0.007	0.423±0.106
3.0	0.191±7.6e-7	0.233±4.5e-7	0.136±1.8e-7	0.179±3.2e-6	0.124±0.016	0.189±0.013	0.104±0.020	0.152±0.010	0.085±0.019	0.391±0.253
3.2	0.186±9.5e-7	0.228±5.0e-7	0.137±1.2e-7	0.181±1.2e-5	0.126±0.011	0.197±0.010	0.101±0.019	0.169±0.014	0.103±0.025	0.497±0.184
3.4	0.181±1.0e-6	0.223±7.9e-7	0.137±5.9e-8	0.183±1.4e-5	0.118±0.016	0.183±0.012	0.100±0.016	0.172±0.010	0.106±0.025	0.470±0.115

(b) Input variables : DL and ME


m	No. of nodes in the hidden layer (c)									
	2		3		4		5		6	
	PI	EPI	PI	EPI	PI	EPI	PI	EPI	PI	EPI
1.8	0.150±2.7e-7	0.232±1.6e-7	0.105±5.9e-7	0.256±1.9e-6	0.114±0.015	0.828±0.126	0.058±0.001	0.823±0.055	0.010±0.022	43.96±10.72
2.0	0.153±2.4e-7	0.234±1.7e-7	0.104±1.7e-8	0.221±6.9e-7	0.120±0.014	0.726±0.163	0.064±0.011	0.765±0.105	0.019±0.024	7.969±1.024
2.2	0.155±2.9e-7	0.235±1.8e-7	0.100±1.6e-7	0.205±9.7e-7	0.123±0.011	0.692±0.139	0.068±0.018	1.448±0.341	0.004±0.013	5.565±1.095
2.4	0.156±1.3e-7	0.236±2.6e-7	0.095±7.9e-7	0.185±2.2e-7	0.124±0.008	0.523±0.056	0.062±0.019	0.761±0.147	0.012±0.020	4.192±0.582
2.6	0.157±1.6e-7	0.237±2.4e-7	0.091±3.9e-7	0.174±8.7e-7	0.127±0.008	0.449±0.035	0.061±0.021	1.291±0.364	5.3e-7±1.1e-6	2.872±0.308
2.8	0.158±2.1e-7	0.238±4.1e-7	0.087±4.8e-7	0.165±6.5e-7	0.114±0.016	0.350±0.064	0.056±0.019	0.653±0.097	1.7e-8±2.7e-8	2.631±0.755
3.0	0.158±2.5e-7	0.239±4.0e-7	0.085±2.7e-7	0.156±5.3e-7	0.123±0.014	0.374±0.072	0.060±0.027	0.641±0.140	0.006±0.014	3.040±0.499
3.2	0.159±2.8e-7	0.239±4.8e-7	0.085±2.4e-7	0.151±2.0e-6	0.119±0.008	0.375±0.035	0.078±0.032	0.575±0.126	1.5e-6±3.6e-6	2.268±0.605
3.4	0.160±1.8e-7	0.240±7.4e-7	0.086±2.0e-7	0.149±4.1e-6	0.112±0.013	0.334±0.040	0.056±0.031	0.503±0.210	4.0e-7±1.0e-6	1.444±0.264

로 데이터로 분류하여 세밀하게 리니어형 초전도 전원장치를 모델링하였으며, 식 (12)에서 보여준 MSE(Mean Square Error) 방법을 이용하여 모델의 성능을 평가하였다.


표 4는 표 3에서 주어진 데이터를 기반으로 본 논문에서 제안한 알고리즘을 통해서 구한 성능 중에서 가장 우수한 모델들의 평균과 표준오차로 나타낸 것이다. 전체 데이터를 사용한 경우에 있어서의 PI=0.0244, EPI=0.2625로써 기존의 논문들[1-2]에서의 실험치에 비교해서 아주 근접할 정도의 오차를 가지고 있으며, 이로 인하여 직접 실험하지 않고도 리니어형 초전도 전원장치의 예상 값을 쉽게 구할 수 있다.




(c-1) Training data(L=1.3mH) (c-2) Testing data(L=1.3mH)



(a-1) Training data (a-2) Testing data
(a) V1, m=1.8, c=2, PI=8.6999e-21, EPI=12.9592



(c-3) Training data(L=543mH) (c-4) Testing data(L=543mH)
(c) V5, m=2.0, c=4, PI=0.0244, EPI=0.2625



(b-1) Training data (b-2) Testing data
(b) V4, m=2.2, c=3, PI=0.0488, EPI=0.3144

그림 6 제안된 모델에서의 각각의 데이터 그룹에 따른 데이터 출력과 모델의 출력

Fig. 6 Output of the proposed model and actual output for each data group

그림 6은 표 4에서 보여준 각각의 데이터 그룹들 중에서 V1, V4 그리고 V5에 대한 가장 우수한 능력을 가진 모델들에 대한 주어진 데이터의 출력과 모델의 출력과의 비교를 나타낸 것이다.

표 4 제안된 모델의 성능지수

Table 4 Performance index of the proposed model

Index	V1			V2			V3			V4			V5		
	m	c	EPI	c	PI	EPI	c	PI	EPI	c	PI	EPI	c	PI	EPI
1.8	2	1.75e-20 ±2.38e-20	12.9593 ±2.28e-5	4	3.26e-26 ±3.30e-26	0.0726 ±0.0011	3	0.0415 ±1.03e-6	1.2530 ±5.43e-5	2	0.2387 ±1.83e-6	1.4527 ±3.17e-5	4	0.4611 ±0.3345	5.8097 ±1.7510
2.0	2	5.13e-21 ±5.51e-21	16.7107 ±6.46e-5	4	4.92e-26 ±5.99e-26	0.0897 ±0.0091	3	0.0570 ±4.94e-6	0.5929 ±0.0001	3	0.0316 ±4.71e-7	0.4991 ±4.53e-5	4	0.0610 ±0.0379	0.5218 ±0.2402
2.2	2	8.85e-22 ±1.47e-21	21.6626 ±0.0001	3	3.71e-21 ±5.32e-21	0.0914 ±2.95e-5	3	0.0751 ±6.51e-7	0.4372 ±0.0003	3	0.0488 ±1.01e-5	0.3147 ±1.19e-4	3	0.0976 ±0.0004	1.0892 ±0.0099
2.4	2	9.22e-22 ±1.23e-21	25.4070 ±0.0006	3	3.08e-21 ±5.30e-21	0.0922 ±0.0007	3	0.0971 ±1.89e-5	0.4007 ±0.0004	3	0.0786 ±2.33e-6	0.3446 ±0.0004	3	0.1057 ±0.0433	2.0338 ±0.0414
2.6	2	2.38e-22 ±2.40e-22	28.3937 ±0.0011	3	3.49e-21 ±5.87e-21	0.0941 ±0.0003	3	0.1249 ±4.90e-5	0.4241 ±0.0072	3	0.1221 ±3.24e-6	0.4584 ±0.0002	2	0.1234 ±6.13e-9	2.5533 ±1.85e-6
2.8	2	1.83e-22 ±2.49e-22	30.8600 ±0.0019	3	8.83e-20 ±1.16e-19	0.0976 ±0.0005	3	0.1606 ±0.0001	0.4337 ±0.0080	3	0.1646 ±3.54e-6	0.5571 ±0.0014	4	0.0930 ±0.0446	3.0992 ±0.2726
3.0	2	7.61e-23 ±8.56e-23	32.9385 ±0.0020	3	1.50e-17 ±4.44e-17	0.1041 ±0.0014	3	0.2073 ±0.0002	0.4835 ±0.0048	3	0.2056 ±3.23e-5	0.6430 ±0.0066	2	0.2947 ±3.08e-7	3.5982 ±5.70e-7
3.2	2	2.67e-22 ±3.30e-22	34.7223 ±0.0035	3	1.23e-15 ±3.06e-15	0.1139 ±0.0024	3	0.2691 ±2.66e-5	0.5712 ±0.0047	3	0.2455 ±2.09e-5	0.7453 ±0.0104	2	0.4992 ±2.59e-7	4.0767 ±3.41e-7
3.4	2	1.32e-22 ±1.54e-22	36.2910 ±0.0046	3	3.26e-18 ±7.33e-18	0.1372 ±0.0058	3	0.3485 ±0.0001	0.6957 ±0.0332	3	0.2909 ±0.0026	0.8510 ±0.0148	2	0.7459 ±9.27e-7	4.5150 ±1.83e-6

표 5 선택된 모델의 성능과의 비교 분석

Table 5 Comparative analysis of the performance of selected model

Model	Index	No. of nodes in the hidden layer	MSE	
			PI	EPI
Linear regression	V1		3.548	26.56
	V2		0.024	0.075
	V3		4.726	6.859
	V4		4.636	6.991
	V5		20.36	33.90
RBF NN using MATLAB[18]	V1	c=4	0.112	56.02
	V2	c=3	0.147	2.702
	V3	c=4	1.818	6.869
	V4	c=5	1.698	4.872
	V5	c=6	3.884	464.5
Gaussian process regression[17]	V1		0.017	3.820
	V2		0.024	1.541
	V3		0.075	0.183
	V4		0.002	0.552
	V5		0.063	0.859
Proposed model	V1	m=1.8, c=2	1.758e-20±2.38e-20	12.95±2.28e-5
		m=2.0, c=2	5.130e-21±5.51e-21	16.71±6.46e-5
	V2	m=1.8, c=4	3.262e-26±3.30e-26	0.072±0.0011
		m=2.0, c=4	4.921e-26±5.99e-26	0.089±0.0091
	V3	m=2.2, c=3	0.075±6.51e-7	0.432±0.0003
		m=2.4, c=3	0.097±1.89e-5	0.400±0.0004
	V4	m=2.2, c=3	0.048±1.01e-5	0.314±1.19e-4
		m=2.4, c=3	0.078±2.33e-6	0.344±0.0004
	V5	m=2.0, c=4	0.061±0.0379	0.521±0.2402
		m=2.2, c=3	0.097±0.0004	1.089±0.0099

7. 결론

본 논문에서는 기존의 개발된 리니어형 초전도 전원장치를 통해서 부하에 따른 충전전류 특성 실험을 함에 있어서 주변 환경에 따른 비용 문제와 고가의 실험재료비 부담등이 대두됨에 따라 이러한 문제점을 해결하고 리니어형 초전도 전원장치를 수학적으로 모델링하고 일반화하고자 입자화 기반 neurocomputing 네트워크를 제안하였다. 즉, FCM 클러스터링을 이용하여 정보 입자화의 세심한 공정을 통해 실험적 데이터의 효과적인 사용을 기반으로 한 입자화 기반의 RBF 신경 회로망의 새로운 구조를 제안하였다.

본 연구에서는 먼저 리니어형 초전도 전원장치의 모델링 및 성능을 평가하기에 앞서 포괄적인 실험적 예제를 위해서 NASA software project 데이터를 사용하여 제안한 모델의 성능을 평가 및 입증하였으며, 이를 기반으로 리니어형 초전도 전원장치의 모델링 및 근사화와 일반화 능력을 평가하였다. 결과에서도 알 수 있듯이 이전에 연구되어진 기본적인 RBF 신경 회로망의 구조에서 얻어진 결과보다 본 논문에서 제안한 알고리즘에서의 근사화 및 일반화 능력이 우수함을 알 수 있었으며, 다양한 클러스터 수 사용에 대한 효과적인 메카니즘은 정보 입자화의 중요한 분배에 있어서 효과적인 설계 매체라고 간주되어짐을 알 수 있었다.

감사의 글

본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음 [GRRC 수원2009-B2, U-city 보안감시 기술협력센터] 그리고 본 연구는 중소기업청에서 지원하는 2008년도 산학연공동기술개발사업(산학 08-06-01-08)의 연구수행으로 인한 결과물임을 밝힙니다.

참고 문헌

- [1] Y. D. Chung, I. Muta, T. Hoshino, and T. Nakamura, "Characteristics of a Persistent Current Compensator for Superconducting NMR Magnets Using Linear Type Magnetic Flux Pump," IEEE Trans. Applied Superconductivity, Vol. 15, No. 2, pp. 1338-1341, 2006.
- [2] Y. D. Chung, T. Hoshino, and T. Nakamura, "Current Pumping Performance of Linear-Type Magnetic Flux Pump With Use of Feedback Control Circuit System," IEEE Trans. Applied Superconductivity, Vol. 16, No. 2, pp. 1638-1641, 2006.
- [3] W. Pedrycz and A. T. Vasilakos, "Computational Intelligence in Telecommunications Networks," CRC Press, 2000.
- [4] D. Srinivasan, C. W. Chan, and P. G. Balaji, "Computational intelligence-based congestion prediction for a dynamic urban street network," Neurocomputing, Vol. 72 pp. 2710-2716, 2009.
- [5] G. A. Montazer, R. Sabzevari, H. G. Khatir,

“Improvement of learning algorithms for RBF neural networks in a helicopter sound identification system,” Neurocomputing, Vol. 71, pp. 167-173, 2007.

[6] J. S. Lee, R. Sankar, “Theoretical derivation of minimum mean square error of RBF based equalizer,” Signal Processing, Vol. 87, pp. 1613-1625, 2007.

[7] K. B. Kim and S. S. Kim, “A passport recognition and face verification using enhanced fuzzy ART based RBF network and PCA algorithm,” Neurocomputing, Vol. 71, pp. 3202-3210, 2008.

[8] J. C. Bezdek, Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press, New York, 1981.

[9] I. Myrvtveit, E. Stensrud, and M. Shepperd, “Reliability and validity in comparative studies of software prediction models,” IEEE Trans. on Software Engineering, Vol. 31, No. 5, pp. 380-391, 2005.

[10] I. Witten and E. Frank, Data mining: Practical machine learning tools and techniques (2nd ed.), Morgan Kaufmann, San Francisco (2005).

[11] M. Shin and A. Goel, “Empirical data modeling in software engineering using radial basis functions,” IEEE Trans. Software Engineering, Vol. 26, No. 6, pp. 567-576, 2000.

[12] A. Oliveira, “Estimation of software project effort with support vector regression,” Neurocomputing, Vol. 69, pp. 1749-1753, 2006.

[13] P. Singla, K. Subbarao, and J. L. Junkins, “Direction-dependent learning approach for radial basis function networks,” IEEE Trans. Neural Networks, Vol. 18, No. 1, pp. 203-222, 2007.

[14] A. Alexandridis, H. Sarimveis, and G. Bafas, “A new algorithm for online structure and parameter adaptation of RBF networks,” Neural Networks, Vol. 16, pp. 1003-1017, 2003.

[15] X. Hong, “A fast identification algorithm for Box - Cox transformation based radial basis function neural network,” IEEE Trans. Neural Networks, Vol. 17, No.4, pp. 1064-1069, 2006.

[16] C. E. Rasmussen and C. K. I. Williams, Gaussian Processes for Machine Learning, MIT Press, 2006.

[17] <http://www.mathworks.com/access/helpdesk/help/toolbox/nnet>.

저 자 소 개



박 호 성 (朴 浩 成)

1999년 원광대학교 제어계측공학과 졸업. 동 대학원 석사(2001), 박사(2005). 2005-2006년 원광대학교 전기전자 및 정보공학부 전임강사, 2006-2007년 캐나다 Alberta 대학 전기 및 컴퓨터공학과 Post-Doc. 2008~현재 수원대학교 산업기술연구소 학술연구교수. 관심분야는 퍼지추론시스템, 신경 회로망, 퍼지-신경 회로망, 진화론적 최적화 알고리즘, 입자화컴퓨팅, 뉴로퍼지 컴퓨팅, 진화 컴퓨팅.

Tel : 031-222-6544
 Fax : 031-220-2667
 E-mail : parkhs@suwon.ac.kr



정 윤 도 (鄭 允 道)

1999년 건국대학교 전기공학과 졸업. 2001년 연세대학교 전기전자공학과 졸업(공학석사). 2007년 京都(Kyoto)대학교 전기공학과 졸업(공학박사). 2008년~현재 : 수원대학교 전기공학과 겸임교수. 2009~현재 수원대학교 산업기술연구소 학술연구교수. 관심분야는 초전도 전력기기 개발, 초고자장용 NMR 마그넷 설계 및 초전도 전원장치 개발등.

Tel : 031-229-8169
 Fax : 031-220-2667
 E-mail : ydchung@suwon.ac.kr



김 현 기 (金 賢 起)

1977년 연세대학교 전기공학과 졸업, 동 대학원 석사(1985), 박사(1991). 1997~현재 경기지역 산학연 기술지원단 단장, 1998~현재 산업기술정책연구소 심의위원, 2000~현재 사단법인 산학연 컨소시엄 전국협의회 회장, 1989~현재 수원대학교 전기공학과 교수, 관심분야는 시스템 자동화 및 감시제어, 지능형 모델링 및 제어등.

Tel : 031-220-2666
 Fax : 031-220-2667
 E-mail : hkkim@suwon.ac.kr



오 성 권 (吳 聖 權)

1981년 연세대학교 전기공학과 졸업, 동 대학원 석사(1983), 박사(1993). 1983-1989년 금성산전연구소(선임연구원). 1996-1997년 캐나다 Manitoba 대학 전기 및 컴퓨터공학과 Post-Doc. 1993-2004년 원광대학교 전기전자 및 정보공학부 교수. 2005~현재 수원대학교 전기공학과 교수, 2002~현재 대한전기학회, 제어로봇시스템학회, 퍼지및지능시스템학회 편집위원. 관심분야는 퍼지 시스템, 퍼지-신경 회로망, 자동화 시스템, 고급 컴퓨터지능, 지능 제어등.

Tel : 031-229-8162
 Fax : 031-220-2667
 E-mail : ohsk@suwon.ac.kr