

논문 2013-50-1-33

Extreme Learning Machine을 이용한 자기부상 물류이송시스템 모델링

(Modeling of Magentic Levitation Logistics Transport System Using
Extreme Learning Machine)

이 보 훈*, 조 재 훈**, 김 용 태***

(Bo-Hoon Lee, Jae-Hoon Cho, and Yong-Tae Kim)

요 약

본 논문에서는 Extreme Learning Machine(ELM)을 이용한 자기부상시스템 모델링 기법을 제안한다. 자기부상시스템의 모델링을 위하여 일반적으로 테일러 급수를 이용한 선형화 모델이 사용되어져 왔으나, 이런 수학적 기법의 경우 자기부상시스템의 비선형 반영에 한계가 있다는 단점을 가지고 있다. 이러한 단점을 극복하기 위해 본 논문에서는 학습시간이 빠른 특성을 가진 ELM을 이용한 자기부상시스템의 모델링 기법을 제안한다. 제안된 기법은 입력 가중치들과 은닉 바이어스들의 초기값을 무작위로 선택하고 출력 가중치들은 Moore-Penrose의 일반화된 역행렬 방법을 통하여 구해진다. 실험을 통하여 제안된 알고리즘이 자기부상시스템의 모델링에서 수학적 기법에 비해 우수한 성능을 보임을 알 수 있었다.

Abstract

In this paper, a new modeling method of a magnetic levitation(Maglev) system using extreme learning machine(ELM) is proposed. The linearized methods using Taylor Series expansion has been used for modeling of a Maglev system. However, the numerical method has some drawbacks when dealing with the components with high nonlinearity of a Maglev system. To overcome this problem, we propose a new modeling method of the Maglev system with electro magnetic suspension, which is based on ELM with fast learning time than conventional neural networks. In the proposed method, the initial input weights and hidden biases of the method are usually randomly chosen, and the output weights are analytically determined by using Moore-Penrose generalized inverse. matrix Experimental results show that the proposed method can achieve better performance for modeling of Maglev system than the previous numerical method.

Keywords : ELM알고리즘, 자기부상, 물류이송시스템, 선형화 모델링, PID제어기

* 정회원, 한경대학교 바이오·정보기술대학원
(Graduate School of Bio and Information Tech, Hankyong National University)

** 정회원, 한경대학교 스마트물류기술연구센터
(Smart Logistics Technology Institute, Hankyong National University)

*** 정회원, 한경대학교 전기전자제어공학과
(Department of Electrical, Electronic and Control Engineering, Hankyong National University)

※ 본 연구는 경기도의 경기도지역협력연구센터(GRRC) 사업의 일환으로 수행하였음[GRRRC 환경2012 - B01, 스마트 물류기술연구센터]

접수일자: 2012년11월12일, 수정완료일: 2013년1월4일

I. 서 론

자기부상 물류이송시스템은 비접촉 반송시스템으로서 마찰력이 없어 정밀도를 높일 수 있고, 윤활제가 필요하지 않기 때문에 반도체 및 농식품 신선물류 분야 등 분진이나 진동에 민감한 물류 이송 분야에 적합한 시스템으로 최근 다양한 개발들이 이루어지고 있다.^[1~3]

자기부상 물류이송시스템에서 부상력을 얻는 방법으로는 반발부상(Electic Dynamic System(EDS))방식과 흡인부상(Electic Magnetic System(EMS))방식으로 구분할 수 있으며, EMS방식이 EDS방식보다 구조가 간단하고 단거리 운송이 가능하여 많은 업체에서 실용화가 이루어지고 있다.^[4]

흡인부상방식은 자석의 인력을 이용하는 방법으로 자성체 아래에 전자석을 위치시켜 전자석의 흡인력에 의해 부상체가 부상하는 원리를 이용한다. 전자석이 제어시스템의 구동기로 작동할 경우 구동할 부하가 큰 인덕턴스를 가지므로 부하의 자기유도현상에 의한 시정수가 크게 나타나서 입력전압에 대한 부하에 흐르는 전류 사이에 위상지연이 발생한다. 이러한 특성들 때문에 흡인부상방식은 시스템에 불안정성을 내포하게 되어 정확한 제어를 위해서 성능이 우수하고 외란에 강인한 제어기 설계를 필요로 한다. 효과적인 제어기 설계를 위해서 우선 시스템의 정확한 비선형 모델방정식을 유도하고 선형화를 통한 선형화 모델방정식을 도출하는 것이 필요하다.^[5] 일반적으로 많이 사용되는 방법은 테일러 급수를 이용한 비선형 모델방정식의 선형화 모델을 이용하는 것이다. 이 방법은 평형점이라는 아주 작은 범위에서 선형화된 모델을 사용하기 때문에 인덕턴스, 저항 등의 주요 파라미터 비선형 요소들의 변화에 따라 제어 성능에 영향을 미치게 된다. 이러한 단점들을 극복하기 위하여 신경망을 이용한 자기부상시스템의 모델링 방법들이 제안되어 왔다.^[6]

본 논문에서는 학습시간이 빠른 ELM을 이용한 상전도 방식의 자기부상 물류이송시스템의 모델링 기법을 제안한다. 본 논문에서 제안하는 기법은 부상을 위한 입력 전류와 부상시스템의 출력을 이용하여 단일 은닉층 전방향 신경회로망을 구조로 구성되고, 학습시간이 빠른 ELM 알고리즘을 적용한 자기부상시스템을 모델링한다. 제안된 알고리즘의 성능을 평가하기 위해 시뮬레이션을 이용하였으며, 일반적인 선형화 모델링 기법

들과 비교 및 분석을 수행하였다.

본 논문의 구성은 다음과 같다. 먼저 II장에서는 흡인식 자기부상시스템의 수학적 모델링기법을 설명하고, III장에서는 ELM을 이용한 모델링 기법을 위한 구조 및 흐름도를 제안하였다. IV장에서는 제안한 모델링 기법의 성능을 검증하고, V장에서는 결론을 맺었다.

II. 흡인식 자기부상 시스템 모델링

2.1 자기부상 시스템의 수학적 모델링

본 논문에서는 제어대상으로 한 자기부상시스템은 그림 1과 같은 자기부상시스템의 수학적 모델을 사용하였다. EMS형 자기부상시스템은 레일 밑에 전자석이 있는 방식이다.^[7] 전자석에는 자기부상시스템 선형화를 위하여 자기포화 및 히스테리시스가 없다고 가정하고 수학적으로 모델링 한다.

자기부상시스템의 운동방정식은 다음 식 (1)과 식 (2)로 나타낼 수 있다.

$$m\ddot{\delta}(t) = -f(i, \delta) + f_d(t) + mg \tag{1}$$

$$f = \frac{B_\delta^2}{2\mu_0} (2A_\delta) = \frac{B_\delta^2 A_\delta}{\mu_0} = \frac{\mu_0 N^2 A_\delta}{4} \frac{i^2}{\delta^2} \tag{2}$$

부상 전자석 코일의 전압 방정식에서 입력전압과 흐르는 전류의 관계는 다음과 식과 같이 표현된다.

$$\begin{aligned} v(t) &= Ri(t) + \frac{d}{dt}[L(i, \delta)i(t)] \\ &= Ri(t) + L(i, \delta) \frac{di(t)}{dt} + i(t) \frac{dL}{d\delta(t)} \left(\frac{d\delta(t)}{dt} \right) \end{aligned} \tag{3}$$

$$L(i, \delta) = \frac{\mu_0 N^2 A_\delta}{2\delta} \tag{4}$$

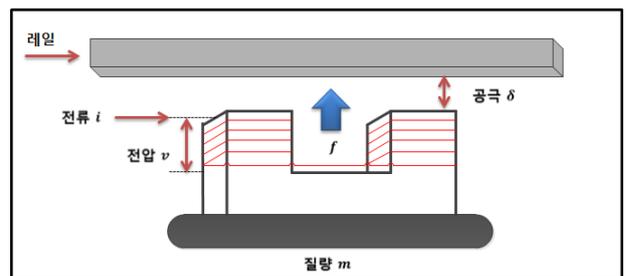


그림 1. 자기부상의 모델링
Fig. 1. Modeling of Magnetic Levitation.

식 (1)과 식 (3)의 비선형 방정식을 평형점(i_0, δ_0)에서 테일러 급수를 이용하여 선형화하면 다음과 같이 표현할 수 있다.

$$mg = f_0(i_0, \delta_0) = \frac{\mu_0 N^2 A_\delta}{4} (i_0 / \delta_0)^2 \quad (5)$$

$$m\Delta\ddot{\delta}(t) = C_\delta\Delta\delta(t) - C_i\Delta i(t) + f_d(t) \quad (6)$$

$$v_0 + \Delta v(t) \simeq Ri_0 + R\Delta i(t)$$

$$+ \frac{C_L}{\delta_0}\Delta i(t) - \frac{C_L i_0}{\delta_0^2}\Delta\delta(t) \quad (7)$$

여기서, $f_d(t)$ 는 외란, R 은 부상전자석의 저항을 나타내며, C_L , C_i , C_δ 는 아래와 같이 표현된다.

$$C_L = \frac{\mu_0 N^2 A_\delta}{2}, \quad C_i = C_L \left(\frac{i_0}{\delta_0^2} \right), \quad C_\delta = C_L \left(\frac{i_0^2}{\delta_0^3} \right) \quad (8)$$

식 (4)와 식 (8)의 계수들을 이용하면 식 (9)는 아래와 같이 나타낼 수 있다.

$$\Delta\dot{i}(t) = \frac{i_0}{\delta_0}\Delta\delta(t) - \frac{R}{L_0}\Delta i(t) + \frac{1}{L_0}\Delta v(t) \quad (9)$$

선형화된 식들에서 $\Delta\delta$, $\Delta\ddot{\delta}(t)$, $\Delta\dot{i}(t)$ 를 상태변수로 정의해서 상태방정식을 얻고 최종적으로 전달함수를 유도하면 아래의 식 (10)으로 나타낼 수 있다.

$$\frac{\Delta\delta(s)}{\Delta V(s)} = \frac{-\frac{C_i}{m}}{s^3 + \frac{R}{L_0}s^2 - \frac{RC_\delta}{mL_0}} \quad (10)$$

2.2 부상 제어기 설계

본 논문에서는 ELM 기법을 이용한 부상 제어기법을

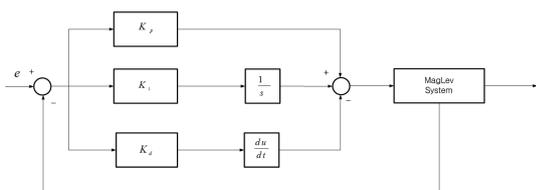


그림 2. 자기부상 제어시스템 블록선도
Fig. 2. Block diagram of control system for magnetic levitation.

표 1. 자기부상시스템의 파라미터
Table 1. Parameters of magnetic levitation system.

Parameter	Value	Dimension
코일저항 R	4.15	Ω
전자석 면적 A_δ	2200×10^{-6}	m^2
권선수 N	700	Turn
전류상수 C_i	301	N/A
공극 상수 C_δ	410000	N/m
정격 힘 f_0	500	N
정격 공극 δ_0	0.003	m
정격 전류 i_0	4.08	A
정격 인덕턴스 L_0	0.202	H
공급 전압 V_{dc}	300	V

제안하였다. 그림 2는 앞에서 언급한 자기부상시스템의 수학적 모델링된 자기부상시스템에 대한 제어기를 설계하고, 설계된 제어시스템을 시뮬레이션 하기 위해서는 자기부상시스템의 파라미터 값을 원용하여야 한다.

식 (10)과 표 1의 흡인식 자기부상시스템의 실제 설계 파라미터를 사용하며, 전달함수는 다음 식 (11)과 같이 표현된다.

$$G(s) = \frac{-6.0294}{s^3 + 2.0545s^2 - 16846} \quad (11)$$

III. Extreme Learning Machine 알고리즘

ELM은 단일 은닉층을 가지는 전방향 네트워크로 최근 Huang등에 의하여 제안되었다.^[8-9] 최근 경사법에 기반한 신경 회로망의 학습은 일반적으로 좋은 성능을 얻기 위해 많은 반복 학습을 필요로 한다. 만약 적절하지 못한 학습에 의하여 낮은 적응성을 보일 경우 종종 국부 최소해에 수렴하는 단점을 가지고 있다. ELM에서 출력 가중치들은 반복적인 학습 구조 대신에 Moore Penrose 일반화된 역행렬에 의해 분석적으로 계산된다. ELM알고리즘의 주요 장점은 반복학습을 하지 않기 때문에 다른 학습 방법들에 비하여 매우 빠른 학습이 가능하고, 경사 기반 학습 방법들은 가장 작은 출력 오차와 놈최소자승 방법을 이용하여 가장 작은 가중치들까지 구하기 때문에 변화에 우수하다. 또한 경사 기반 학습방법들이 국부 최소해, 과잉적합과 같은 문제점이 있

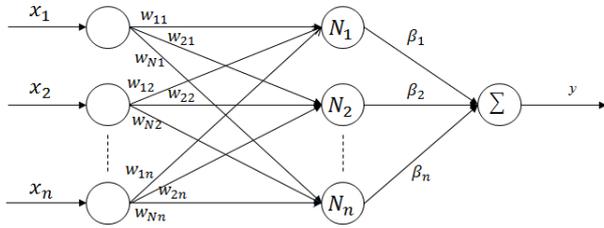


그림 3. Extreme Learning Machine의 구조
Fig. 3. Structure of Extreme Learning Machine.

는 반면에 ELM은 한 번의 학습으로 최적의 해에 직접적으로 도달하는 경향이 있다. 이러한 문제점을 극복하기 위해 그림 3과 같이 ELM의 구조를 사용한다.

ELM의 학습과정을 구현하기 위해서는 N 개의 데이터 중에서 임의의 입출력 데이터 (x_i, t_i) 를 고려하면 입력 데이터 $x_i = [x_{i1}, \dots, x_{im}]^T \in R^n$ 이고, 목표 출력 데이터 $t_i = [t_{i1}, \dots, t_{im}]^T \in R^m$ 이다. 은닉층의 뉴런의 개수는 n 개이고 활성화수가 $j(x)$ 인 단일층 은닉층을 갖는 신경회로망의 실제 출력값 y 는 다음과 식 (12)와 같다.

$$\sum_{i=1}^N \beta_i j(W_i \cdot x_n + b_i) = y, \quad n = 1, \dots, N \quad (12)$$

여기서, $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 은 입력 뉴런들과 i 번째 은닉 뉴런 사이에 연결된 가중치 벡터, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 은 출력 뉴런들과 i 번째 은닉 뉴런 사이에 연결된 가중치 벡터이며, b_i 는 i 번째 은닉 뉴런의 바이어스 값을 나타낸다. 은닉 뉴런 n 을 가지는 단일 은닉층을 갖는 신경회로망은 학습을 통하여 N 개의 모든 학습 데이터에 대하여 오차가 제로인 다음 식 (13)을 만족할 경우 식 (12)를 만족하는 β_i, W_i, b_i 가 존재한다.

$$\sum_{j=1}^N \|y - t_n\| = 0 \quad (13)$$

$$\sum_{i=1}^N \beta_i j(W_i \cdot x_n + b_i) = t_n \quad n = 1, \dots, N \quad (14)$$

N 개의 방정식으로 표현되는 식 (14)를 다음과 같이 표현할 수 있다.

$$G\beta = y \quad (15)$$

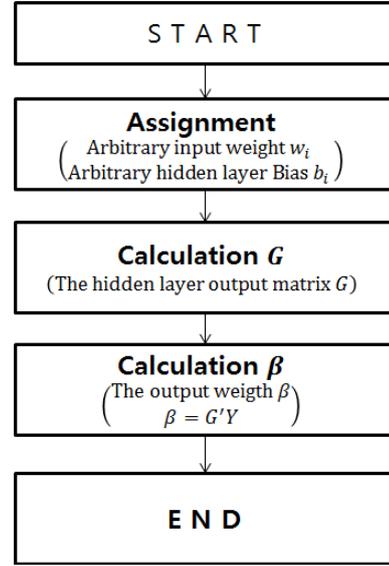


그림 4. Extreme Learning Machine의 학습과정
Fig. 4. Learning Process of Extreme Learning Machine.

여기서, G 는 신경망의 은닉층의 출력 행렬값을 나타내고, G 의 i 번째 열은 입력 x_1, x_2, \dots, x_n 의 각각에 대한 i 번째 은닉 뉴런의 출력 벡터를 나타낸다. 여기서, β 의 국소노름최소자승해 $\hat{\beta}$ 는 다음의 식 (16)과 같이 구해질 수 있다.

$$\hat{\beta} = G^+ y \quad (16)$$

여기서, G^+ 는 G 에 대한 Moore Penrose의 일반화된 역행렬을 의미한다. 위의 계산 방법과 같이 ELM 기법은 매우 빠른 학습 속도를 지니고 있다.

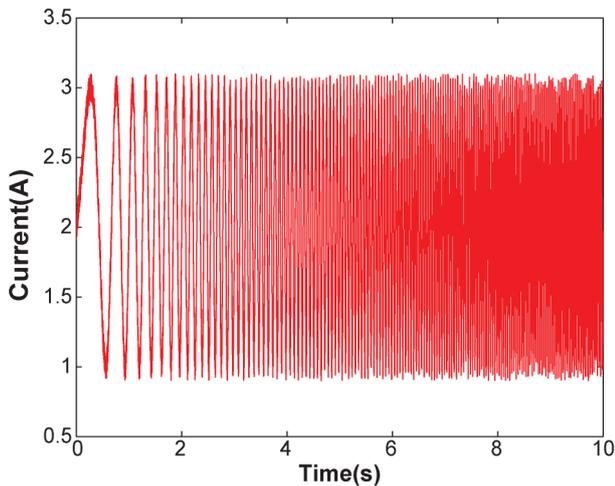
IV. 실험

본 논문에서는 ELM을 이용한 자기부상시스템 모델링의 성능 평가를 위해서 자기부상시스템의 입력 전류와 공극 변화를 각각 ELM의 입력과 출력으로 사용하였다. ELM의 효과적인 학습을 위하여 입력은 $i(t), i(t-1), i(t-2), i(t-3)$ 의 4개를 시계열 데이터로 구성하여 사용하였다. ELM의 학습데이터와 검증데이터는 각각 10,000개의 샘플을 추출하여 사용하였다. 제안된 기법의 성능평가를 위하여 성능평가지수는 다음의 식 (17)을 사용하였다.

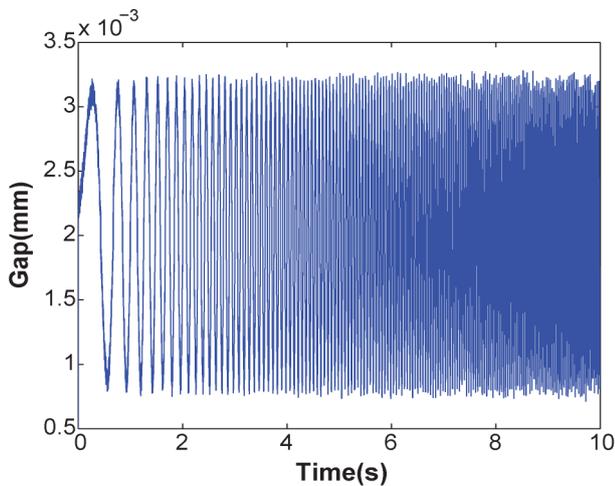
$$PI = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

표 2. 뉴런 수에 따른 ELM의 성능
Table 2. Performance of ELM according to variation of the neuron number.

뉴런 수	학습데이터 오차(10^{-5})	학습 시간 (sec)	검증데이터 오차(10^{-5})	검증 시간 (sec)
10	9.9681	0.2184	7.5776	0.1872
20	9.9061	0.2340	7.5435	0.0624
30	9.8203	0.2340	7.4797	0.0624
40	9.6309	0.2496	7.3734	0.1248
50	9.6002	0.4836	7.3542	0.1248
100	9.5407	0.6708	7.4563	0.1872
200	9.5050	1.8096	7.4254	0.3120
300	9.5000	1.8720	7.4072	0.4212
500	9.4950	4.6020	7.4526	0.5772
1000	9.4961	12.4801	7.4218	0.8268



(a) 공극 데이터



(b) 입력전류

그림 5. 입력전류에 대한 공극변화
Fig. 5. Variation of gap according to input current.

여기서, \hat{y} 는 제안된 모델의 출력, y_i 는 출력 검증 데이터, n 은 데이터의 수를 나타낸다. 또한 ELM의 성능에 큰 영향을 미치는 출력 뉴런의 수의 선정은 10~1000 개 까지 실험을 거쳐 설정하였으며, 표 2에서 알 수 있듯이 뉴런의 300개 이상일 경우 검증데이터에 대한 오차가 증가하기 때문에 본 논문에서는 뉴런의 수를 300으로 선정하여 적용하였다.

그림 5는 자기부상 실험장치의 입력전류와 공극의 변화를 나타낸다. 그림 6은 ELM의 학습데이터와 검증데이터의 결과를 나타내고 있다. 그림 6에서 알 수 있듯이 ELM의 학습이 적절히 이루어졌음을 알 수 있다. 그림 7과 그림 8은 ELM의 출력과 일반적인 선형화 모델의 시뮬레이션 결과를 나타내고 있다. 그림 7과 그림 8에서 ELM의 출력이 선형화 모델에 비해 우수한 성능을 보임을 확인할 수 있다.

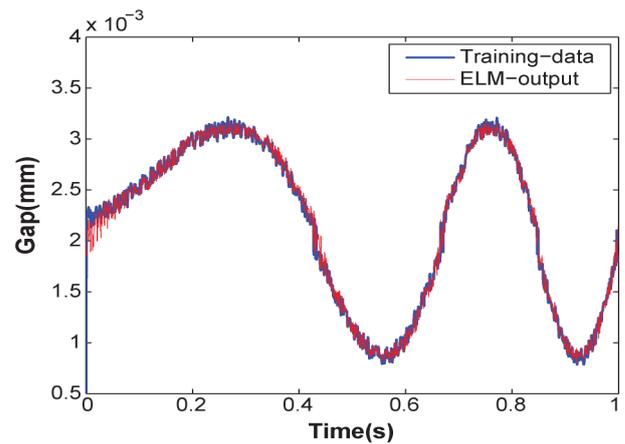


그림 6. ELM의 학습데이터 결과
Fig. 6. The results of ELM for training dataset.

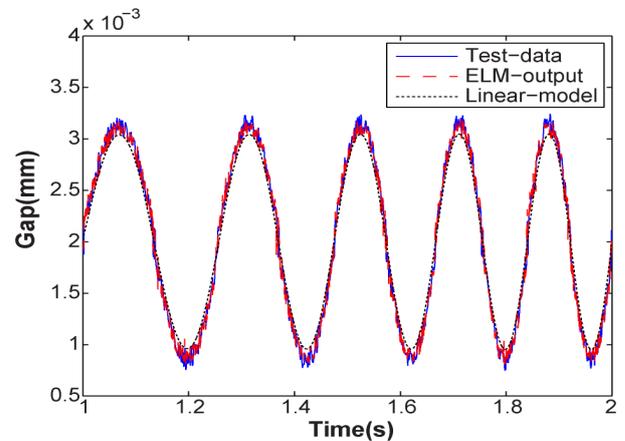
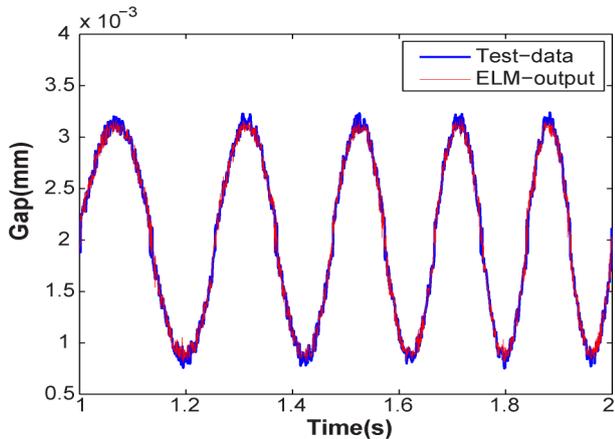
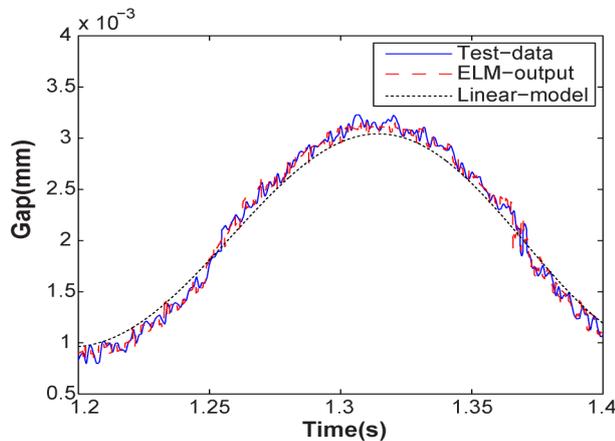


그림 7. ELM의 검증데이터 결과
Fig. 7. The results of ELM for test dataset.



(a) 샘플데이터(10,000개)



(b) (a)의 구간 확대 비교

그림 8. ELM과 일반적인 선형화 방법에 의한 성능
 Fig. 8. The performance of ELM and conventional linearized method.

V. 결 론

본 논문에서는 학습시간이 빠른 ELM을 이용한 상전도 방식의 자기부상시스템의 모델링 기법을 제안하였다. ELM의 학습데이터와 검증데이터는 실제 실험장치의 입력전류와 공극의 변화를 이용하였다. ELM의 성능을 검증하기 위하여 일반적인 선형화 모델의 시뮬레이션 출력과 비교하였으며, ELM의 성능이 더 우수함을 확인하였다. 향후 ELM 모델을 이용한 제어기의 설계를 연구하고, 특히 외란의 모델에 효과적 적용 방법을 연구할 것이다.

참 고 문 헌

- [1] 김창현, 이종민, 한형석, “영구자석 복합식 자기부상 LCD 글라스 반송장치의 제어,” *대한기계학회 2010 춘추학술대회*, pp. 1522-1527, 2010.
- [2] 고현준, 박근명, 이상용, 이상철, 김영근, “반도체 이송장치에 관한 연구.” *대한기계학회 2010 춘추학술대회*, pp. 1820-1821, 2010.
- [3] W. Wang M. Lamb, and I. J. Busch-Vishniac, “An Automated Loading and Unloading System for a Maglev Wafer Transport Path,” *IEEE Trans. semiconductor manufacturing*, Vol. 6, No. 3, pp. 276-279, 1933.
- [4] Kortum, W. and Utzt, A., 1984, “Control Law Design and Dynamic Evaluatons for a Maglev Vehicle with a ComBined Lift and Guidance Suspension Systems,” *Trans. ASME Journal of Dynamic Systems, Measurement, and Control*. vol. 106, pp. 286-292.
- [5] 조재훈, 김용태, “클론선택기반 유전자알고리즘을 이용한 자기부상 RGV의 PID 제어기 설계,” *한국지능시스템학회 논문지*, Vol. 22, No 2, pp. 239-245, 2012.
- [6] 이보훈, 조재훈, 김용태, “Extreme Learning Machine을 이용한 자기부상 물류이송시스템 모델링,” *CICS 2012 정보 및 제어 학술대회 논문집*, pp. 139-140, 2012.
- [7] 조재훈, 김용태, “지능형 최적화 기법을 이용한 자기부상 RGV를 위한 최적 부상 제어기 설계,” *한국지능시스템학회 2011년도 추계학술대회 학술발표논문집*, 제2호, pp. 41-42, 2011.
- [8] G-B Huang, H. zhou, X. Ding, R. Zhang, “Extreme learning machine for regression and multicalss classification”, *IEEE Trans. System, Man, and Cybernetics*, Vol.42, No. 2, pp. 513-529, 2012.
- [9] Mostafa Lairi and Gerard Bloch, “A Neural Network with Minimal Structure for MagLev System Modeling and Control,” *IEEE International Symposium on Intelligent Control/Inelligent System and Semiotics*, Sep.15-17, 1999. 15-17, 1999.

저 자 소 개



이 보 훈(정회원)
2010년 국립 환경대학교 정보제어
학과 졸업(공학사)
2010년~현재 동 대학원 석사과정
<주관심분야 : 지능로봇, 지능제어, 물류시스템>



김 용 태(정회원)-교신저자
1991년 연세대학교 전자공학과
졸업(공학사)
1939년 KAIST 전기및전자공학과
졸업(공학석사)
1998년 KAIST 전기및전자공학과
졸업(공학박사)
1998년~2000년 (주)삼성전자 선임연구원
2006년 Univ. of Illinois at Urbana-Champaign
방문연구
2002년~현재 국립 환경대학교 전기전자제어
공학과 교수
<주관심분야 : 지능로봇, 지능제어, 물류시스템>



조 재 훈(정회원)
2002년 국립 한밭대학교 제어계측
공학과 졸업(공학사)
2004년 국립 한밭대학교 제어계측
공학과 졸업(공학석사)
2011년 국립 충북대학교 제어계측
공학과 졸업(공학박사)
2011년~현재 국립 환경대학교 스마트물류기술
연구센터 연구교수
<주관심분야 : 지능형 최적화 알고리즘, 패턴인식, 신재생에너지, 스마트그리드, 물류시스템>