

# 개선된 수업-학습기반 최적화 알고리즘을 이용한 자기부상 제어기의 최적 설계

## Optimal Design of Magnetic Levitation Controller Using Advanced Teaching-Learning Based Optimization

조재훈\* · 김용태†  
(Jae-Hoon Cho · Yong-Tae Kim)

**Abstract** - In this paper, an advanced teaching-learning based optimization(TLBO) method for the magnetic levitation controller of Maglev transportation system is proposed to optimize the control performances. An attraction-type levitation system is intrinsically unstable and requires a delicate control. It is difficult to completely satisfy the desired performance through the methods using conventional methods and intelligent optimizations. In the paper, we use TLBO and clonal selection algorithm to choose the optimal control parameters for the magnetic levitation controller. To verify the proposed algorithm, we compare control performances of the proposed method with the genetic algorithm and the particle swarm optimization. The simulation results show that the proposed method is more effective than conventional methods.

**Key Words** : Teaching-learning based optimization(TLBO), Clonal selection, Magnetic levitation controller, Maglev system, Intelligent optimization methods

### 1. 서론

자기부상 기술은 자력의 인력과 척력을 이용하여 물체를 부상시키는 기술로서 현재 자기부상열차와 산업용 액츄에이터, 자기 베어링과 같은 다양한 분야에서 상용화되어 적용되어지고 있다. 특히 분진에 민감한 반도체 이송분야에서 상용화를 위한 연구가 활발히 이루어지고 있다[1-3].

자기부상시스템은 부상방식에 따라 유도식 자기부상방식과(Electro-Dynamic Suspension)과 흡인식 자기부상방식(Electro-Magnetic Suspension)으로 구분된다. 유도식 자기부상방식은 부상체에 설치된 초전도 자석과 레일에 설치된 코일 사이의 반발력을 이용하여 부상하는 방식으로 자기적으로 안정한 시스템이고, 제어에 용이하다는 장점이 있으나 시스템의 개발 비용이 비싸다는 단점이 있다[4]. 흡인식 자기부상방식은 자석의 인력을 이용하는 방법으로 자석체 아래 부분에 전자석을 위치시켜 전자석의 흡인력에 의해 부상체가 부상하는 원리를 이용한다. 흡인식자기부상방식은 일반적으로 불안정 시스템이기 때문에 제어기의 높은 제어능력이 요구된다. 그러나 반발식에 비해 기술적으

로 용이하고 정지시와 저속에서도 자력에 의한 부상이 가능하여 많은 응용분야에 적용되고 있다. 흡인식 자기부상시스템의 제어를 위해서 보편적으로 PID제어기와 상태궤환제어기가 많이 사용되어지고 있다. 상태궤환제어기는 PID제어기에 비해 시스템의 상태 정보를 더 많이 필요로 하기 때문에 더 많은 센서들이 요구되고 이는 제어연산량과 시스템 개발 비용이 일반적인 PID를 사용했을 때 보다 증가하는 단점을 가진다. 반면 PID 제어기는 강인성, 설비 구조의 단순성, 응용성, 제어의 용이성 등의 많은 장점들 때문에 현재 자기부상제어에 적용되고 있다. 그러나 PID 제어기의 우수한 성능을 위해서는 시스템의 특성을 고려한 PID제어기의 파라미터 설계가 중요하다. 최근에는 고전적 파라미터 선정 기법들의 한계를 극복하기 위하여 지능형 최적화 알고리즘을 이용한 다양한 PID제어기 최적 파라미터 설계 기법들이 연구되어지고 있다[5, 6].

대표적인 지능형 최적화 알고리즘으로는 자연의 생존경쟁을 모방한 유전자알고리즘(Genetic Algorithm, GA), 새 또는 벌과 같은 군집의 행동 특성을 모방한 입자군집 최적화 알고리즘(Particle Swarm Optimization, PSO), 인간의 면역체계를 모방한 면역알고리즘(Immune Algorithm, IA)과 면역체계 내에서의 세포들의 분화를 모방한 클론선택기법(Clonal Selection, CS), 개미의 집단행동을 모방한 개미집단최적화(Ant Colony Optimization, ACO)기법 등이 있다. 이러한 알고리즘들은 최적해를 찾는 많은 분야에서 성공적인 적용과 성능의 우수함이 입증되어져 왔다[7, 8]. 그러나 지능형 최적화 기법의 가장 큰 문제점은 각 고유의 알고리즘에서 설계자 또는 사용자가 임의로 선택 되어지는 제어

† Corresponding Author : Department of Electrical, Electronic and Control Engineering, Hankyong National University, Korea.  
E-mail : ytkim@hknu.ac.kr

\* Smart Logistics Technology Institute, Hankyong National University, Korea.

Received : December 01, 2014; Accepted : December 19, 2014

파라미터들에 따라 성능의 차이가 크다는 것이다. 이러한 문제점을 해결하기 위해서 다양한 알고리즘의 융합 및 개선들이 이루어지고 있으며 현재까지도 지능형 최적화 알고리즘의 가장 큰 단점으로 인식되어지고 있다[9].

최근에 Rao 등은 최적화 문제를 위한 수업-학습기반 최적화 기법(TLBO)이라고 불리는 효과적인 최적화 기법을 제안하였다 [10]. TLBO 방법은 다른 최적화 알고리즘이 자연현상을 모방한 것과 비슷하게 교사와 학생 간의 지식 전달 과정을 모사한 최적화 알고리즘이다. TLBO 기법의 특징은 지능형 최적화 기법에서 사용되어지는 교배율, 돌연변이율, 관성 가중치 등과 같이 설계자가 임의로 선택해야 하는 알고리즘의 제어 변수들이 없기 때문에 다른 기법들에 비해 더 일관성을 보이는 장점을 가지고 있다.

본 논문에서는 자기부상제어의 최적설계를 위하여 개선된 TLBO알고리즘을 제안한다. 제안된 알고리즘은TLBO와 CS가 융합된 형태로서 각 세대에서 TLBO에 의해 선택된 가장 우수한 개체를 클론선택기법의 항체로 선정하여 더 우수한 최적해를 탐색한다. 제안된 알고리즘의 성능을 평가하기 위하여 Matlab/Simulink를 이용하여 자기부상시스템을 모델링하고, GA와 PSO와의 성능을 비교 및 분석하였다.

## 2. 흡인식 자기부상시스템의 모델링

흡인식 자기부상시스템은 그림 1과 같이 레일의 아래에서 전자석의 흡인력을 이용하여 부상하는 시스템으로 비선형 특성을 가진다. 흡인식 자기부상시스템을 수학적으로 모델링하기 위하여 전자석에는 자기부상시스템 선형화를 위하여 자기포화 및 히스테리시스가 없다고 가정한다[11].




그림 1 흡인식 자기 부상시스템  
Fig. 1 Attraction type magnetic levitation system

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

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

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

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

$$v(t) = Ri(t) + \frac{d}{dt}[L(i, \delta)i(t)] \quad (3)$$

$$= Ri(t) + L(i, \delta)\frac{di(t)}{dt} + i(t)\frac{dL}{d\delta(t)}\left(\frac{d\delta(t)}{dt}\right)$$

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

식(1)과 식(3)의 비선형 방정식을 평형점( $i_0, \delta_0$ )에서 테일러 급수를 이용하여 선형화 하면 다음과 같이 표현할 수 있다.

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

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

$$v_0 + \Delta v(t) \approx Ri_0 + R\Delta i(t) + \frac{C_L}{\delta_0}\Delta i(t) - \frac{C_L i_0}{\delta_0^2}\Delta\delta(t) \quad (7)$$

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

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

식(4)와 식(8)의 계수들을 이용하면 식(7)은 아래와 같이 나타낼 수 있다.

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

선형화된 식들에서  $\Delta\delta, \Delta\dot{\delta}(t), \Delta\ddot{\delta}(t)$ 를 상태변수로 정의해

표 1 자기부상시스템의 파라미터

Table 1 Parameters of magnetic levitation system

Parameter	Value	Dimension
코일저항 $R$	4.18	$\Omega$
전자석 면적 $A_\delta$	$2200 \times 10^{-6}$	$m^2$
권선수 $N$	700	Turn
전류상수 $C_i$	236.44	N/A
공극 상수 $C_\delta$	252212	N/m
정격 힘 $f_0$	500	N
정격 공극 $\delta_0$	0.003	m
정격 전류 $i_0$	4.08	A
정격 인덕턴스 $L_0$	0.202	H
공급 전압 $V_{dc}$	300	V

서 상태방정식을 얻고 최종적으로 전달함수를 유도하면 아래의 식(10)으로 나타낼 수 있다. 표 1은 본 논문에서 자기 부상시스템을 모델링하기 위한 파라미터들을 나타낸다.

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

### 3. 지능형 최적화 알고리즘

#### 3.1 집단 기반 지능형 최적화 알고리즘

다양한 최적화 문제를 해결하기 위하여 자연 현상들을 모방한 지능형 최적화 기법들이 19060년대부터 꾸준히 연구되어지고 있다. 지능형 최적화 기법의 장점은 일반적인 최적화 기법에서 요구되는 연속성, 미분가능성, 단봉성과 같은 탐색공간의 제약조건들에 대해 큰 제약을 받지 않는다는 것이다. 지능형 최적화 기법의 대표적인 것들로는 자연의 생존경쟁을 모방한 유전자알고리즘, 새 또는 벌과 같은 군집의 행동 특성을 모방한 입자군집 최적화 알고리즘(PSO), 인간의 면역체계를 모방한 면역알고리즘(IA)과 면역체계 내에서의 세포들의 분화를 모방한 클론선택기법(CS), 개미의 집단행동을 모방한 개미집단(ACO)최적화 기법 등이 있다. 이러한 기법들은 많은 연구에서 전통적인 기법에 비해 우수한 성능들을 가지는 것이 입증되어져 왔으며 계속해서 성능 개선을 위한 융합과 개선된 알고리즘들에 대한 연구가 이루어지고 있다. 그러나 앞서 언급한 지능형 최적화 기법들의 가장 큰 단점은 각 알고리즘의 고유한 제어 파라미터들을 주어진 문제에 맞게 설계자가 선정해야 된다는 것이다. 예로 GA의 돌연변이율 및 교배율 또는 PSO의 속도벡터 및 관성가중치와 같은 파라미터들을 어떤 값으로 선정하느냐에 따라 탐색 성능도 큰 차이점을 보인다. 이러한 변수들은 선정은 다른 지능형 최적화 기법들에 대해서도 비슷하게 작용하며 이런 문제점을 극복하기 위한 많은 연구가 수행되어지고 있다.

#### 3.2 수업-학습기반 최적화 알고리즘(TLBO)

Rao 등은 최적화 문제를 위한 수업-학습기반이라고 불리는 효과적인 최적화 기법을 제안하였다[10, 12]. TLBO 방법은 다른 최적화 알고리즘이 자연현상을 모방한 것과 비슷하게 교사와 학생 간의 지식 전달 과정을 모사한 최적화 알고리즘이다. TLBO 기법의 특징은 일반적인 집단 기반 최적화 알고리즘에서 사용되는 제어 파라미터들이 없다는 것이다. 집단 기반 최적화 알고리즘들의 제어변수들은 사용자에게 의해 임의로 선정되거나 다른 기법들을 이용하여 제어 파라미터들을 선정하여야 한다. 따라서 설계자의 경험이나 추가적인 연산이 필요하다는 단점들이 있다. 그러나 TLBO기법은 설계자가 임의로 선택해야 하는 알고리즘의 제어 변수들이 없기 때문에 다른 기법들에 비해 더 일관성을 보이는 장점을 가지고 있다. TLBO 기법에서는 각 학급별 집단과 학생 그룹별 집단이 사용되며 최적화 절차는 수업 단계(Teaching phase)와 학습 단계(Learning phase)의 두 부분으로

나누어진다. 교사 단계는 교사가 학생을 지도하는 과정이며 학생 단계는 학생들 간의 상호 지식교류를 통해 지식을 습득하는 과정을 의미한다. TLBO와 일반적인 최적화 기법을 비교하여 설명하면 TLBO의 클래스는 GA의 집단 또는 PSO의 군집, 학생은 GA의 각 개체 또는 PSO의 입자(Particles), 학생들이 가진 과목별 점수는 GA의 염색체 또는 PSO의 위치벡터(최적화 문제의 변수)와 대응되며, 과목 수는 최적화 문제에서 변수의 차원과 동일한 의미를 지닌다.

#### 3.2.1 수업 단계

현실적으로 교사는 학생들을 지도하여 더 우수한 지식들을 습득할 수 있도록 노력한다. 이런 노력들의 가장 이상적인 결과는 학생들이 교사 자신의 지식수준이나 그 이상까지 도달하도록 하는 것이며 TLBO 기법의 교사 단계(Teaching phase)에서는 이런 교사들의 노력을 모사하여 최적해를 탐색하도록 한다.  $M_i$ 를 임의의  $i$  번째 지도 단계에서의 학급별 과목에 대한 평균으로 가정하면,  $i$  번째 지도 단계에서 교사는  $i$  단계에서 가장 우수한 학생이 교사로 선정된다. 교사는 학생들의 평균을 자신의 수준까지 도달할 수 있도록 지도하고 이런 현상들은 아래의 수식으로 표현된다. 여기서,  $M_{new}$ 은 교사 자신의 평균이 된다.

$$diff - mean_i = r_i (M_{new} - T_F M_i) \quad (11)$$

여기서  $T_F$ 는 변경되는 평균값을 결정하기 위한 학습요소이고  $r_i$ 는 0~1 사이의 임의의 값이다.  $T_F$ 값은 1또는 2로 선정될 수 있다. 위 식에서 구해진 평균의 차이를 이용하여 각각의 후보해(학생들의 각 과목에 대한 평균 점수)들을 아래의 식(12)를 이용하여 변경한다.

$$X_{new,i} = X_i + diff - mean_i \quad (12)$$

식(12)에 의해 새롭게 형성된 후보해(학생의 상향 또는 하향된 각 과목의 평균 점수)는 목적함수의 평가를 통하여 이전 보다 목적함수 값이 우수하면 교체가 되며 그렇지 않을 경우 이전값을 유지한다.

#### 3.2.2 학습 단계

학습 단계는 학생들이 교사의 지도와는 별도로 다른 학생들의 상호 정보교류를 통하여 자신들의 지식을 향상 시키는 행동들을 모사하였다. 학생들은 무작위 적으로 다른 학생과 함께 그룹 토의, 발표 또는 일반적인 대화 등을 통하여 상호교류를 통하여 지식을 받아들이며 특히 자신 보다 우수한 지식 능력을 가진 다른 학생들로부터 더 우수한 지식을 습득할 기회가 커진다. 이런 행동들을 최적해 문제에 적용하기 위하여 아래와 같이 표현될 수 있다.

$$\text{for } i = 1: P_n \\ \text{임의의 다른 학습자 } x_j \text{를 선택.}$$

```

if  $f(X_i) < f(X_j)$ 
 $X_{new,i} = X_{old,i} + r_i(X_i - X_j)$ 
else
 $X_{new,i} = X_{old,i} + r_i(X_j - X_i)$ 
end
    
```

학습자 단계에서는 새롭게 형성된 지식 또는 점수(후보해)가 교사 단계에서와 동일하게 목적함수의 평가를 통하여 이전 값에 비해 우수할 경우에만 교체된다.

### 3.3 클론 선택 기법

클론선택이론은 생체 면역계의 항원자극에 대한 면역계통의 반응 체계를 모방한 최적화 알고리즘이다[13]. 생체 면역계에서 항체를 생산하는 B세포들은 항원이 침입 하였을 경우 각각 다른 항체들을 생산한다. 각각의 B세포들이 생산한 항체들 중 항원에 적합한 항체가 인식되었을 경우 그 항체들을 생산한 B세포들은 자기와 동일한 클론들을 생산하고 더 많은 항체들을 생산하여 항원에 대항한다. 이 과정에서 더욱 더 적합한 항체들의 생산을 위해서 돌연변이 과정을 거치게 되고 이것은 클론들이 항원에 대하여 더 좋은 면역반응을 보일 수 있게 한다. 이런 면역계통의 항체 생성 체계를 모방한 최적화 기법이 클론선택 기법이다. 클론 선택 기법의 동작 순서를 간단히 표현하면 아래와 같다.

- [Step 1] 초기항체의 생성: 사용자에게 의해 정의된 수의 항체를 생성(초기 후보해를 생성)
- [Step 2] 초기항체들의 적합도를 평가한 후 클론 생성을 위한 우수한 항체를 저장
- [Step 3] 클론 생성 : 우수한 항체들을 이용하여 사용자에게 의해 정의된 클론 수만큼 클론을 생성(분화)
- [Step 4] 정해진 돌연변이율을 기반으로 클론들의 돌연변이 과정을 진행
- [Step 5] 돌연변이 된 클론들의 적합도 평가
- [Step 6] 종료조건이 만족되면 종료하고 그렇지 않을 경우 Step 2로 이동

### 4. 수업-학습기반 최적화 알고리즘과 클론선택 알고리즘을 이용한 지능형 최적화 기법

본 논문에서는 TLBO 알고리즘과 클론선택 기법을 융합한 개선된 TLBO-CS 최적화 알고리즘을 제안한다. TLBO알고리즘에서 제일 우수한 개체는 교사의 역할을 하며 다른 학생(교사를 제외한 개체들)의 성능향상에 영향을 준다. 제안된 알고리즘에서 교사는 클론 선택을 위한 항체로 선정되어 분화되고 교사의 클론이 돌연변이 되어 더 우수한 해를 탐색하도록 동작한다. 제안된 알고리즘에서 TLBO는 전체의 탐색공간에 대해 전역탐색을 수행하는 기능을 가지며 클론선택은 우수한 개체들의 주변을 탐색하는 지역탐색의 기능을 수행하여 최적에 해를 선택하도록 설계되었다. CS기법은 최적해를 찾기 위하여 클론들의 수와 분화율에 따

라 연산량이 크게 증가될 수 있으나 제안된 알고리즘에서는 TLBO기법에서 탐색된 최적해를 가지고 지역탐색만을 수행하기 때문에 클론수를 적게 선택하여 연산속도를 높일 수 있도록 하였다. 따라서 제안된 알고리즘은 전역탐색과 지역탐색의 균형적인 탐색 성능을 가지므로써 더 우수한 최적해 탐색성과 빠른 최적해 수렴의 장점을 가지도록 동작한다. 그림 2는 제안된 TLBO-CS의 알고리즘의 전체 동작 순서도이며 단계별로의 동작은 아래와 같이 진행된다.

- [Step 1] 초기 파라미터들의 선정(학생, 과목 및 반복 횟수)
- [Step 2] 초기 학생들의 목적함수 계산: (제일 우수한 학생을 클론선택을 위한 항체로 선정)
- [Step 3] 클론선택 알고리즘
  - [CS-step 1] 항체를 이용한 클론 생성 (분화율에 따른 클론 생성)
  - [CS-step 2] 클론들의 돌연변이
  - [CS-step 3] 돌연변이 된 클론들의 적합도 평가
- [Step 4] 초기학생들과 클론선택을 수행한 후의 클론들 중에서 가장 우수한 학생 또는 클론을 교사로 선정
- [Step 5] 식(11)와 (12)을 이용하여 과목별 새로운 점수를 계산
- [Step 6] 이전 값에 비해 목적함수 값이 더 우수하면 새로운 값으로 교체하고 그렇지 않으면 기존값을 유지한다.

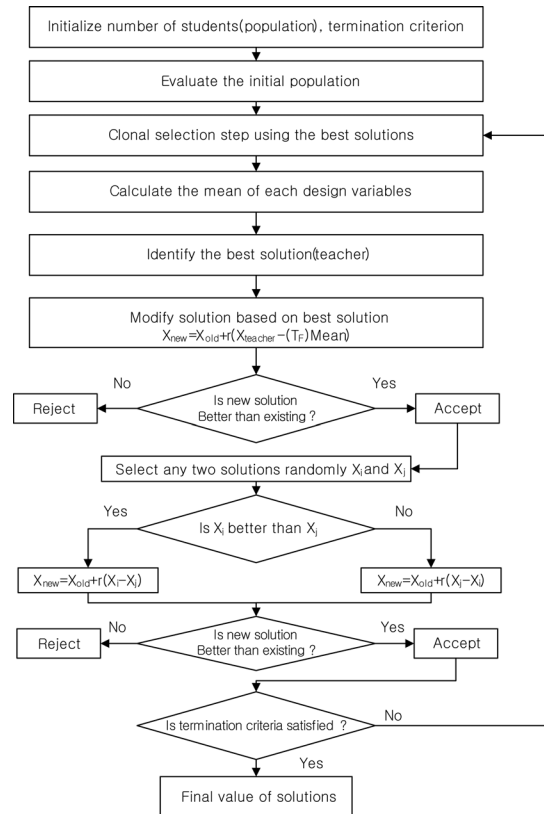


그림 2 제안된 TLBO-CS의 전체 순서도  
Fig. 2 The flowchart of the proposed TLBO-CS

[Step 7] 종료 조건에 만족을 하면 전체 계산과정을 종료하며, 그렇지 못하면 3단계로 가서 반복 수행

### 5. 시뮬레이션 및 결과 고찰

자기부상시스템에 대한 제안된 알고리즘의 성능을 평가하기 위하여 Matlab/Simulink를 이용하여 시뮬레이션을 수행하였다. 표 2는 시뮬레이션을 위한 각 알고리즘들의 초기 파라미터를 나타낸다. 각 알고리즘들에 대한 성능의 공정성 및 반복재현성을 위하여 세대수와 반복횟수는 동일하게 선택하였으며, 난수 생성함수의 시드(seed)값도 동일한 값으로 선정하여 각 알고리즘들의 초기 집단들도 동일한 초기집단에서 탐색을 시작하도록 하였다. 자기부상을 위한 PID제어기는 주파수영역에서 설계하기 쉽도록 식(13)과 같은 형태로 변경이 가능하며, 각 알고리즘들은 제어기의 3개의 변수(K, z1, z2)들의 최적값을 탐색한다. 또한 목적함수는 일반적으로 알려진 PID제어기의 성능지수(Performance index, PI) 함수인 적분제곱오차(Integrated Square Error, ISE), 적분절대오차(Integrated Absolute Error, IAE), 적분시간제곱오차(Integrated Time Square Error, ITSE), 적분시간절대오차(Integrated Time Absolute Error, ITAE)을 사용하였으며, 자기부상시스템의 큰 오버슈트를 피하기 위하여 식(14)와 같은 기준값 필터(set-point filter)를 적용하였으며 큰 오버슈트를 피하기 위하여 오버슈트 값을 목적함수에 벌점함수 항으로 추가하였다. 식(15)와 식(16)은 두 성능지수가 결합된 형태의 목적함수를 나타내며 각 알고리즘들은 이 목적함수를 최소로 하는 파라미터를

표 2 시뮬레이션을 위한 초기 파라미터들

Table 2 Initial simulation parameters

Algorithm	parameters	Values
PSO	Generation size	100
	Swarm size	100
	Vmax	20% of search space
	[Wmin Wmax]	[0.4 0.9]
	c1, c2	2.0
	Seed of random function	488
GA	Generation size	100
	Population size	100
	Mutation rate	0.05
	Crossover rate	0.65
	Seed of random function	488
Clonal selection	Clone size	3
	Differentiation rate	0.7
	Mutation rate	0.2
	Seed of random function	488
TLBO	Iteration	100
	Number of Student	100
	Seed of random function	488

탐색하게 된다.

$$K(s) = \frac{K(s+z_1)(s+z_2)}{s} \tag{13}$$

$$G_{setpoint} = \frac{20}{s+20} \tag{14}$$

$$object\ function = PI + penalty\ value \tag{15}$$

$$penalty\ value = e^{(-Mo)} + Th \begin{cases} Th = Mo & 0 \leq Mo \leq 0.6 \\ Th = 100 & Mo > 0.6 \end{cases} \tag{16}$$

식(15)~(16)에서 PI 성능지수함수 값, Mo는 오버슈트 값을 나타낸다. Th는 오버슈트 값에 따른 문턱값(threshold values)을 나타내며, 오버슈트가 0.6이상일 경우 100으로 선택되어 큰 목적함수 값을 가지도록 설계 하였다. 목적함수를 최소화하는 최소값 문제에서는 큰 목적함수를 가진 개체들은 다음 세대에서 선택되어지지 않을 확률이 높다. 목적함수에 오버슈트값을 벌점값으로 적용함으로써 큰 오버슈트를 유발하는 값들을 선택하지 않도록 하였다.

표 3은 각 알고리즘들에 의해 최적해로 선택된 제어기의 파라미터들과 목적함수 값이다. 표 3에서 GA를 제외한 PSO, TLBO 및 제안된 TLBO-CS 알고리즘들은 최적해로서 거의 비슷한 값들을 선택한 것을 알 수 있다. 그러나 그림 3에서 알 수 있듯이 PSO의 경우 속도벡터를 생성하는 할 때 범위 값으로 사용되는 속도벡터 최대값(Vmax) 같은 PSO 고유의 제어파라미터 값 변화에 따라 탐색성능에 큰 차이를 보이는 것을 알 수 있다. 따라서 일반적으로 알려진 GA와 PSO 같은 집단 기반 최적화 기법들은 항상 우수한 탐색성능을 위하여 각 알고리즘들에서 고유한 제어 파라미터들을 설계자의 경험이나 다른 최적기법을 이용하여 우수한 성능을 보장하는 최적 제어파라미터들을 선정해야 되는 단점이 있다. 그림 4와 5는 TLBO와 TLBO-CS의 랜덤변수와 클론분화를 파라미터 변화에 따른 탐색성능을 나타낸다. 그림에서 볼 수 있듯이 알고리즘의 주요 제어 파라미터 변화에 대해 큰 변화 없이 최적해를 탐색하는 것을 알 수 있다. 따라서 GA이나 PSO에 비해 TLBO와 제안된 TLBO-CS가 알고리즘의 제어 파라미터들에 큰 영향을 받지 않으면서 최적해를 탐색하는 능력이 우수하고 신뢰성과 반복재현성 면에서 우수함을 알 수 있다. PSO의 경우 TLBO와 제안된 알고리즘에 비해 약 최적해 탐색 능력이 20세대 정도 늦는 것을 볼 수 있다.

그림 8과 9에서는 제안된 알고리즘이 TLBO와 비교했을 때 비해 최적해에 수렴하는 속도 면에서 우수함을 알 수 있다. 그림 10~13은 각각의 성능지수함수를 목적함수로 적용하여 탐색된 최적해의 단위계단응답을 나타낸다. 앞서 설명된 표 3에서 GA를 제외한 알고리즘들의 최적해가 거의 비슷하기 때문에 PSO, TLBO 및 제안된 TLBO-CS의 단위계단응답은 거의 비슷한 출력을 가진다. 그림 10~13에서 자기부상시스템의 출력이 오버슈트가 크지 않으면서 적절한 출력특성을 가지는 최적해가 선택되었음을 알 수 있다. 그림 8과 9 그리고 표 3의 ITAE항의 목적함수 값을 비교해 보면 제안된 알고리즘이 다른 알고리즘들에 비해 최적해에 수렴하는 속도에서는 크게 우수함을 알 수 있었으며 최적해 탐색 능력에서도 PSO와 TLBO에 비교하면 동일하거나 더 우수한 성능이 있음을 알 수 있다.

표 3 각 알고리즘들에 의해 선택된 PID 파라미터에 대한 시뮬레이션 결과

Table 3 The simulation results of PID parameters selected by each algorithm

PI	Methods	Object function	$K'$	$z_1$	$z_2$
ISE	GA	0.144	257.259	3.243	$7.271 \times 10^5$
	PSO	0.0092	19.903	$2.738 \times 10^4$	$5.024 \times 10^5$
	TLBO	0.0092	19.903	$2.738 \times 10^4$	$5.024 \times 10^5$
	TLBO-CS	0.0092	19.903	$2.738 \times 10^4$	$5.024 \times 10^5$
IAE	GA	0.0237	210.230	$4.009 \times 10^4$	$7.572 \times 10^5$
	PSO	0.0131	31.7524	$2.7493 \times 10^4$	$5.3672 \times 10^5$
	TLBO	0.0131	31.7552	$2.7493 \times 10^4$	$5.3674 \times 10^5$
	TLBO-CS	0.0131	31.7552	$2.7493 \times 10^4$	$5.3674 \times 10^5$
ITSE	GA	$2.758 \times 10^{-4}$	900.242	$5.733 \times 10^4$	$9.9542 \times 10^5$
	PSO	$4.737 \times 10^{-5}$	25.5305	$2.724 \times 10^4$	$5.196 \times 10^5$
	TLBO	$4.737 \times 10^{-5}$	25.5308	$2.724 \times 10^4$	$5.196 \times 10^5$
	TLBO-CS	$4.737 \times 10^{-5}$	25.5308	$2.724 \times 10^4$	$5.196 \times 10^5$
ITAE	GA	$5.9294 \times 10^{-4}$	365.649	$5.129 \times 10^4$	$8.915 \times 10^5$
	PSO	$1.0659 \times 10^{-4}$	37.999	$2.7778 \times 10^4$	$5.4035 \times 10^5$
	TLBO	$1.0646 \times 10^{-5}$	37.904	$2.7841 \times 10^4$	$5.4166 \times 10^5$
	TLBO-CS	$1.0645 \times 10^{-4}$	37.994	$2.7842 \times 10^4$	$5.4162 \times 10^5$

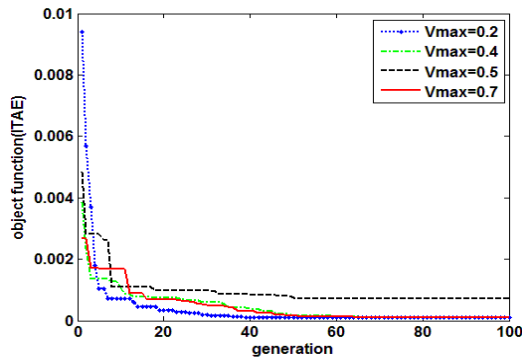


그림 3 PSO의 최대속도변화(Vmax)값 변화에 따른 최적해 탐색 성능

Fig. 3 Performance of PSO according to the variation of the maximum velocity




그림 5 제안된 TLBO-CS의 클론 분화율 변화에 따른 탐색성능  
Fig. 5 Performance of TLBO-CS according to the variation of the Differentiation rate

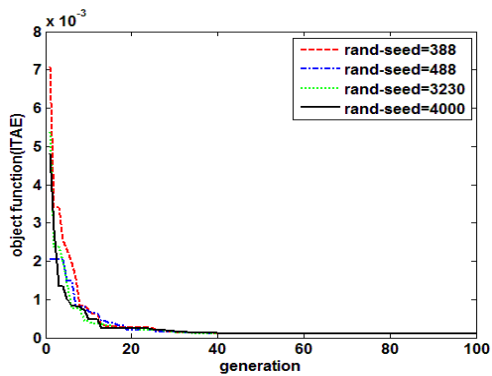


그림 4 TLBO의 난수생성을 위한 시드값 변화에 따른 최적해 탐색 성능

Fig. 4 Performance of TLBO according to the variation of the seed values for random number generation

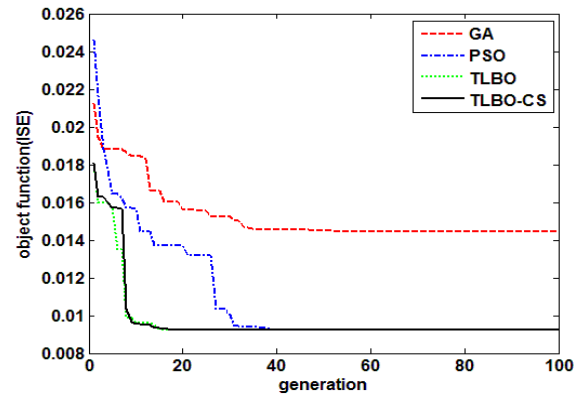


그림 6 목적함수 ISE에 대한 각 알고리즘들의 최적해 탐색성능  
Fig. 6 Performance of each algorithm with object function ISE




그림 7 목적함수 ITSE에 대한 각 알고리즘들의 최적해 탐색성능  
 Fig. 7 Performance of each algorithm with object function ITSE




그림 10 목적함수 ISE를 이용한 자기부상시스템의 단위계단 응답  
 Fig. 10 Step response of the maglev system with PID parameters selected by object function ISE

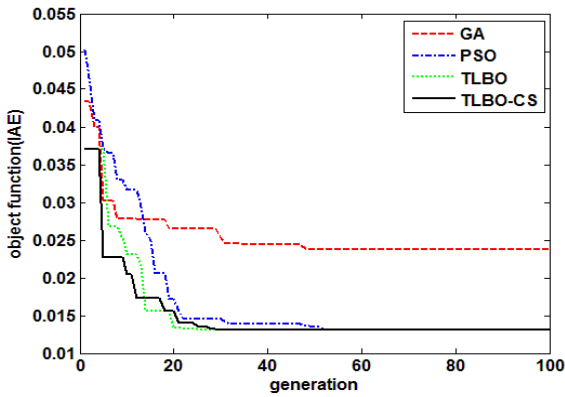


그림 8 목적함수 IAE에 대한 각 알고리즘들의 최적해 탐색성능  
 Fig. 8 Performance of each algorithm with object function IAE




그림 11 목적함수 IAE를 이용한 자기부상시스템의 단위계단 응답  
 Fig. 11 Step response of the maglev system with PID parameters selected by object function IAE

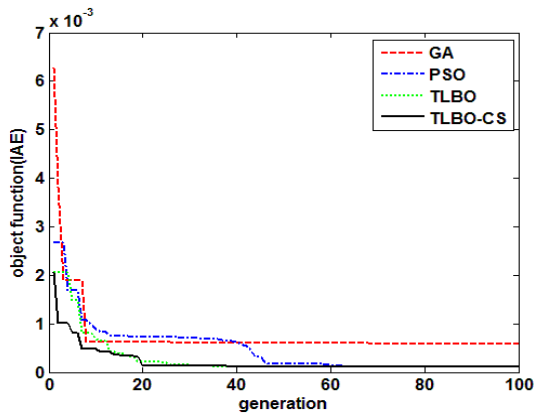


그림 9 목적함수 ITAE에 대한 각 알고리즘들의 최적해 탐색성능  
 Fig. 9 Performance of each algorithm with object function ITAE

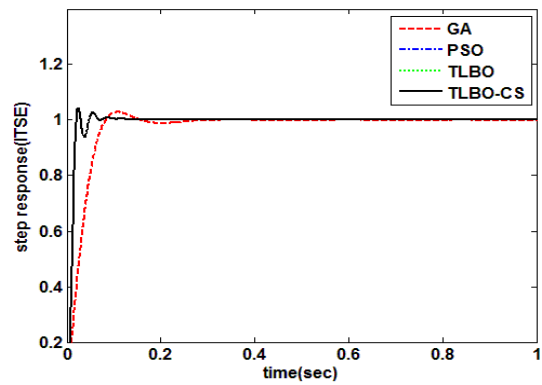


그림 12 목적함수 ITSE를 이용한 자기부상시스템의 단위계단 응답  
 Fig. 12 Step response of the maglev system with PID parameters selected by object function ITSE




그림 13 목적함수 ITAE를 이용한 자기부상시스템의 단위계단 응답  
**Fig. 13** Step response of the maglev system with PID parameters selected by object function ITAE

## 6. 결 론

본 논문에서는 개선된 TLBO알고리즘을 이용하여 자기 부상시스템의 부상제어기의 최적 파라미터를 선정하는 기법을 제안하였다. 제안된 알고리즘은 TLBO와 CS의 융합된 형태로서 TLBO가 탐색공간에서의 전역 탐색을 담당하고, CS는 TLBO에서 선택된 우수한 해를 이용하여 최적해 주변의 지역탐색을 담당하도록 하여 균형적인 탐색능력을 가지도록 설계하였다. 제안된 시스템의 성능을 평가하기 위하여 Matlab/Simulink로 시뮬레이션을 수행하였으며 제안된 알고리즘이 다른 알고리즘들에 비해 최적해에 수렴하는 속도에서는 크게 우수함을 알 수 있었으며, 최적해 탐색 능력에서도 PSO와 TLBO에 비교하면 동일하거나 더 우수한 성능이 있음을 확인하였다. 향후 제안된 알고리즘으로 탐색된 제어기의 값들을 실제 시스템에 적용하여 성능을 평가하고 그 유효성을 검증하고자 한다.

### 감사의 글

본 연구는 경기도의 경기도지역협력연구센터 (GRRC) 사업의 일환으로 수행하였음. [GRRC 환경 2012-B01, 스마트 물류기술연구센터]

### References

- [1] Jae-Hoon Cho, Yong-Tae Kim, "Design of PID Controller for Magnetic Levitation RGV Using Genetic Algorithm Based on Clonal Selection", Journal of Korean Institute of Intelligent Systems, vol. 22, no. 2, pp. 239-245, 2012.
- [2] Jae-Hoon Cho, Yong-Tae Kim, "Design of Levitation Controller with Optimal Fuzzy PID Controller for Magnetic Levitation System", Journal of Korean Institute of Intelligent Systems, vol. 24, no. 3, pp. 279-284, 2014.
- [3] El Hajjaji, Ahmed, and M. Ouladsine., "Modeling and nonlinear control of magnetic levitation systems", IEEE Transactions on Industrial Electronics, vol.48, no. 4, pp. 831-838, 2001.
- [4] Hyung-Woo Lee, Ki-Chan Kim, and Ju Lee., "Review of maglev train technologies", IEEE Transactions on Magnetics, vol. 42, no. 7, pp. 1917-1925, 2006.
- [5] S. Kusagawa, J. Baba, E. Masada, "Weighty Reduction of EMS-Type Maglev Vehicle with a Novel Hybrid Control Scheme for Magnets", IEEE Transactions on Magnetics, vol. 40, no. 4, pp. 3066-3068, 2004.
- [6] Rong-Jong Wai, Jeng-Dao Lee, and Kun-Lun Chuang., "Real-time PID control strategy for maglev transportation system via particle swarm optimization", IEEE Transactions on Industrial Electronics, vol. 58, no. 2, pp. 629-646, 2011.
- [7] K. Chandrasekar and N. V. Ramana., "Performance Comparison of GA, DE, PSO and SA Approaches in Enhancement of Total Transfer Capability using FACTS Devices", Journal of Electrical Engineering & Technology, vol. 7, no. 4, pp. 493-500, 2012.
- [8] K. Lakshmi and S. Vasantharathna., "Hybrid Artificial Immune System Approach for Profit Based Unit Commitment Problem", Journal of Electrical Engineering & Technology, vol. 8, no. 5, pp. 959-968, 2013.
- [9] R. V. Rao, V. J. Savsani, and D. P. Vakharia., "Teaching - learning-based optimization: an optimization method for continuous non-linear large scale problems", Information Sciences, vol. 183, no. 1, pp. 1-15, 2012.
- [10] R. V. Rao, V. J. Savsani, and D. P. Vakharia., "Teaching - learning-based optimization: A novel method for constrained mechanical design optimization problems", Computer-Aided Design, vol. 43, pp. 303-315, 2011.
- [11] E. Alvarez-Sanchez, J. Alvarez-Gallegos, R. Castro-Linares, "Modeling and controller design of a magnetic levitation system", IEEE International Conference on Electrical and Electronics Engineering, pp. 330-334, 2005.
- [12] R. V. Rao and Vivek Patel., "Multi-objective optimization of heat exchangers using a modified teaching-learning-based optimization algorithm", Applied Mathematical Modelling, vol. 37, no. 3, pp. 1147-1162, 2013.
- [13] L. N. de Castro and Fernando J. Von Zuben, "Learning and Optimization Using the Clonal Selection Principle", IEEE Trans. Evolutionary Computation, vol. 6, no. 3, pp. 239-251, 2002.



## 저 자 소 개



### 김 용 태(Jae-Hoon Cho)

1991년 : 연세대학교 전자공학과 졸업(공학사)  
1993년 : 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 한경대학교 전기전자제어공학과 교수  
관심분야 : 지능로봇, 지능시스템, 지능제어, 기계학습, 물류시스템  
E-mail : ytkim@hknu.ac.kr



### 조 재 훈(Yong-Tae Kim)

2002년 : 국립 한밭대학교 제어계측공학과 졸업(공학사)  
2004년 : 국립 한밭대학교 제어계측공학과 졸업(공학석사)  
2011년: 국립 충북대학교 제어계측공학과 졸업(공학박사)

2011년-현재: 국립한경대학교 스마트물류기술연구센터 연구교수

관심분야 : 지능제어, 신재생에너지, 물류시스템  
E-mail : jhcho@hknu.ac.kr