

## 조도 적응 알고리즘 기반 지능형 White LED Dimming System의 최적화 설계

임승준\*, 정대형\*\*, 김현기\*\*\*, 오성권\*\*\*\*  
수원대학교 전기공학과

### Optimized Design of Intelligent White LED Dimming System Based on Illumination-Adaptive Algorithm

Sung-Joon Lim\*, Dae-Hyung Jung\*\*, Hyun-Ki Kim\*\*\*, Sung-Kwon Oh\*\*\*\*  
Department of Electrical Engineering, The Suwon University

**Abstract** - 본 연구는 White LED를 이용하여 주변 밝기 변화에 빠르게 적응하는 퍼지 뉴로 Dimming Control System을 설계한다. 본 논문에서는 방사형기저함수 신경회로망(Radial Basis Function Neural Network: RBFNN)을 설계하여 실제 White LED Dimming Control System에 적용시켜 모델의 근사화 및 일반화 성능을 평가한다. 제안한 모델에서의 은닉층은 방사형기저함수를 사용하여 적합도를 구현하였고, 후반부의 연결가중치는 경사하강법을 사용한다. 이때 멤버쉽 함수의 중심점은 HCM 클러스터링(Hard C-Means Clustering)을 적용하여 결정한다. 연결가중치는 4가지 형태의 다항식을 대입하여 출력을 평가하였다. 최종 출력의 최적화를 위하여 PSO(Particle Swarm Optimization)을 이용하여 은닉층 노드수 및 다항식 형태를 결정한다. 본 논문에서 제안한 LED Dimming Control System은 Atmega8535를 사용하여 PWM 제어 방식을 사용하고, 조도계(Cds)를 이용하여 LED의 밝기에 따른 주변의 밝기를 감지하여 조명에 적응시키는 방법을 적용하였다.

광원으로부터의 빛의 세기가 강해지면 전압이 낮아지는 Cds의 특징을 이용하여 Cds 전압 데이터를 획득하였다.

#### 2.2 RBFNN의 설계

White LED의 Dimming Control을 위한 방법으로는 광원으로부터의 빛 밝기에 의해 얻어지는 Cds 2개의 전압값을 입력으로 받아 그림2에 표현되는 RBFNN의 구조를 설계한다. 은닉층의 노드수와 중심점은 HCM 클러스터링 방법을 사용하여 결정하였고 RBF의 활성함수는 식1의 Gaussian 활성함수를 적용하였다. 은닉층과 출력층 사이의 다항식 파라미터는 오류역전파 알고리즘을 이용하였고, 네트워크의 연결가중치는 경사하강법의 학습방법을 통해 결정하였다. 후반부의 다항식은 표 1에서와 같이 4가지 형태의 구조를 갖는다.

$$R_j(X) = e^{-\frac{\|x - v_j\|^2}{2(\sigma)^2}} \quad (1)$$

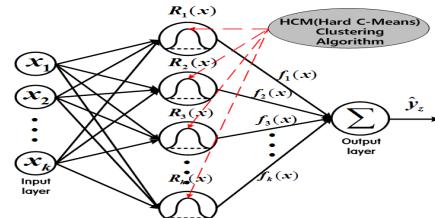


그림 2) 제안한 RBFNN의 구조

#### 표 1) 다항식 형태

상수항(Constant)	$f_j = a_{j0}$
1차 다항식(Linear)	$f_j(x_1, \dots, x_n) = \sum_{i=0}^n a_{ji}x_i$
2차다항식(Quadratic)	$f_j(x_1, \dots, x_n) = \sum_{i=0}^n a_{ji}x_i + \sum_{i=1}^n a_{j(n+i)}x_i^2 + a_{(2n+1)}x_1x_2$
변형된 2차 다항식(Modified Quadratic)	$f_j(x_1, \dots, x_n) = \sum_{i=0}^n a_{ji}x_i + a_{(2n+1)}x_1x_2$

#### 2.2.1 HCM 클러스터링 방법

본 논문에서는 클러스터링 알고리즘 중 데이터들간의 거리를 기준으로 근접한 정도를 측정하고, 이를 바탕으로 데이터를 특성별로 분류하는 HCM 클러스터링을 이용하여 그 특성을 파악한다. 주어진 데이터 분류는 먼저 HCM 클러스터링에 의해 학습 데이터를 분류하고, 분류된 학습 데이터의 중심에 의해 테스트 데이터를 분류한다.[2]

HCM클러스터링에 의한 학습 데이터 분류는 다음과 같다.

[단계 1] 클러스터의 개수결정( $2 \leq c < n$ ), 소속행렬  $U$ 를  $U^{(0)} \in M_c$ 로 초기화

$$M_c = \left\{ U \mid u_{ij} \in \{0,1\}, \sum_{i=1}^c u_{ij} = 1, 0 < \sum_{j=1}^m u_{ij} < m \right\} \quad (2)$$

여기서,  $u_{ij}$ 는 소속행렬의 파라미터.

[단계 2] 각 클러스터에 대한 중심벡터를 구함

$$v_i = \{v_{i1}, v_{i2}, \dots, v_{ij}, \dots, v_{im}\} \quad v_{ij} = \frac{\sum_{k=1}^n u_{ik} \cdot x_{kj}}{\sum_{k=1}^n u_{ik}} \quad (3)$$

여기서,  $i$ 는  $i$ 번째 클러스터,  $j$ 는  $j$ 번째 입력 변수( $j=1, \dots, m$ ),  $n$ 은 data 수.

## 2. 본 론

### 2.1 LED의 조도에 따른 Cds 출력값 분석

연구에 사용된 LED 광원으로는 FC Semiconductor사의 NLWH5603B3 제품을 사용하였고, 사용된 광원으로부터 서로 설치된 거리가 다른 Cds 2개를 설치하고, PWM 신호를 0~255구간에서 증가시키면서 그에 따른 Cds 각각에 걸리는 전압을 측정하여 255개의 데이터를 획득하였다.

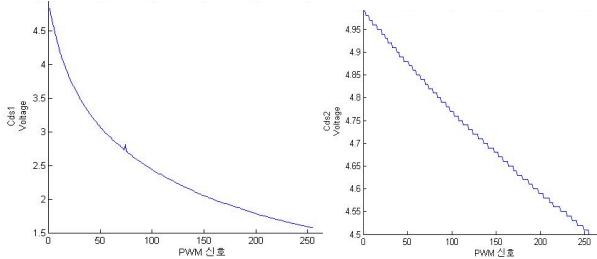


그림 1) PWM 신호에 따른 Cds 전압

[단계 3] 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬  $U^{(r)}$ 을 생성한다.

$$d_{ik} = d(x_k - v_i) = \|x_k - v_i\| = \left[ \sum_{j=1}^m (x_k - v_i)^2 \right]^{1/2} \quad (4)$$

$$u_{ik}^{(r)} = \begin{cases} 1 & d_{ik}^{(r)} = \min \{d_{ik}^{(r)}\} \text{ for all } j \in c \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

여기서,  $d_{ik}$ 는 k번째 데이터 sample  $x_k$ 와 I번째 클러스터 중심  $V_i$ 의 기하학적 거리.

[단계 4] 아래의 식을 만족하면 종료, 아니면  $r=r+1$ 으로 놓고 [단계 2]로 돌아가 아래식이 만족할 때까지 이 과정을 반복

$$\|U^{(r+1)} - U^{(r)}\| \leq \epsilon \quad (\text{tolerance level}) \quad (6)$$

### 2.2.2 PSO 알고리즘(Particle Swarm Optimization Algorithm)

J.Kennedy와 R.Eberhart에 의해 1995년 제안된 PSO[2]는 진화형 계산기법의 일종으로, 종래의 새떼나 물고기떼의 움직임에 관한 연구로부터 유도되었다. PSO는 이론의 간결성, 구현의 용이성, 연산의 효율성과 같은 특징을 보이며 다른 확률적 방법과 비교하여 보다 안정적인 수렴 특성을 가지고 유전자 알고리즘에 비해 계산속도의 유리함을 가지고 있다.[3]

PSO 알고리즘은 다음과 같다.

[Step 1] Initialization - n개의 particle을 탐색 공간 내에서 랜덤하게 생성한다. 이들은 초기 swarm이 된다. 마찬가지로 초기 particle velocity를  $[-v_{\max}, v_{\max}]$ 내에서 랜덤하게 생성한다. 초기 swarm의 각 particle은 목적함수를 이용하여 평가되고, 이를 모두는 pbest로 설정한다. 초기 particle 중 최적의 값은 다시 gbest로 설정된다.

[Step 2] Inertia weight & velocity updating - 관성하중 값을 계산하고, 식(7)을 이용하여 j번째 particle velocity를 계산한다. 제한조건  $[-v_{\max}, v_{\max}]$ 을 확인한다.

$$w(t) = w_{\max} - \frac{w_{\max} - w_{\min}}{er_{\max}} \times t \quad (7)$$

[Step 3] Position updating - 식(8)에 의해 particle의 위치정보는 조절된다.

$$x_{jk}(t) = v_{jk}(t) + x_{jk}(t-1) \quad (8)$$

[Step 4] Individual & global best updating - 새로운 위치정보를 가진 particle들은 목적함수에 의해 평가된다. 각 particle의 적합도는 이전 pbest의 적합도와 비교되며 pbest를 재설정한다. pbest의 particle 중 최적해를 가지는 particle의 적합도와 이전 gbest의 적합도를 비교하여 최적 위치정보를 가진 particle을 gbest로 재설정한다.

[Step 5] Stopping criteria - 종료조건을 만족하면 탐색과정을 종료하고, 그렇지 않으면 [Step 2]부터 반복한다.

[Step 6] Optimal parameter - 최종적으로 생성된 gbest는 최적의 위치정보를 가진다.

### 2.2.3 Simulation

PSO의 초기 파라미터 및 탐색범위는 표 2에 나타내었다.

#### 표 2 PSO 파라미터 및 탐색범위

Parameters	Value
Number of generations	300
Number of swarms	100
Vmax	탐색 공간의 20%
[Wmin Wmax]	[ 0.4 0.9 ]
C1, C2	2.0
The range of Search space	Polynomial Type [1~4] 분포상수 [0.2~2.8]

시뮬레이션 결과 표현되는 RBF의 노드수는 6개이며 Linear 형태의 다항식으로 결정되었고 성능지수는 식(9)의 MSE를 사용한 결과 PI=0.5477, EPI=0.3790의 결과를 보였다.

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (9)$$

### 2.3 RBF 뉴럴 네트워크를 적용한 지능형 Dimming 제어방식

일반적인 제어방식의 응답속도를 개선하기 위해 지능형 알고리즘을 적용한 Dimming제어 방식은 그림 3과 같이 표현된다.

초기 광원의 소등상태에서 원하는 조도값을 설정하고 조도센서를 통해 읽어들인 값과 비교하여 오차가 있으면 RBFNN 모델식을 이용하여 PWM신호를 하나씩 증가시키는 것이 아닌 최적화 된 값을 적용시킴으

로, 기존의 PWM 신호를 1씩 증가시켜주는 것보다 빠른 응답속도를 가지는 장점이 있다. 신호 차이가 없을 시에는 PWM신호를 유지시키고 조도센서를 가지고 설정조도와의 오차를 feed-back 하기 때문에 유지시 사용되는 전력도 절감할 수 있는 장점이 있다.

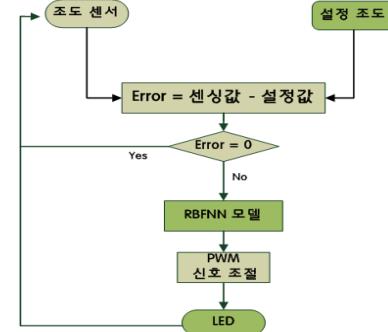


그림 3) RBFNN을 적용한 제어방식

### 3. 결 론

본 논문에서는 클러스터링 방법중의 하나인 HCM 클러스터링 방법과 최적화 알고리즘인 입자 군집 최적화(PSO) 알고리즘을 이용한 RBF Neural Network를 설계하고 실제 LED Dimming Control System에 적용하였다. 조명을 설치하는 환경, 설치장소의 공간넓이에 잘 적용될 수 있도록 조도계(Cds)를 2개 설치하여 거리나 공간에 구애받지 않고 알맞은 밝기를 표현하는 LED control system을 개발하고자 하였다. RBF Neural Network를 사용하여 LED를 제어하여 보다 빠른 응답특성을 가지고, 일반적으로 설치된 LED dimming control system과 비교했을 때 비슷한 정상상태 오차를 가졌다. 또 PWM 신호를 계속적으로 제어를 하지 않고 설정 조도와 관측 조도와의 차이가 생기면 RBFNN 제어를 통한 적합한 PWM 신호를 조정하므로써 주변환경에 적응하는 LED 조도를 자동적으로 제어할 수 있는 system을 개발하였다. 현재 시판되고 있는 조명장치의 조도 컨트롤 방식은 조광기를 사용하여 사용자가 의의로 밝기를 조절하는 방식과 단계별로 설정된 밝기를 유지하는 방식이 사용되고 있다. 이는 자연채광에 의한 효과를 보기 위해서는 사용자가 일일이 조작을 해야하는 번거로움이 있다. 이에 본 연구를 통하여 지능형 알고리즘을 접목한 자동 조도 컨트롤 시스템을 설계함으로써 자연채광의 효과를 극대화함은 물론 불필요한 에너지 소비를 방지함으로써 에너지 낭비 문제에 대해 효과적인 대처 방법으로 적합함을 증명하였다.

### 감사의 글

본 연구는 중소기업청에서 지원하는 2011년도 산학연 공동 기술개발사업(No. 00047478)의 연구수행으로 인한 결과물을 밝힙니다 그리고 이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2009-0074928)

### 참 고 문 헌

- [1] Fabio A. Guerra "Multi-step agead nonlinear identification of lorenz's chaotic system using radial basis neural network with learning by clustering and particle swarm optimization." Chaos, Solitons & Fractals, Volume35, Issue 5, pp.967-979 ,March 2008.
- [2] 오성권, "프로그램에 의한 컴퓨터지능", pp481~485, 내하출판사, 2002.8.
- [3] 박병준, 오성권, 김용수, 안태천, "PSO의 특징과 차원성에 관한 비교 연구", 제어 자동화 시스템 공학 논문지, Vol 12(4), pp. 328~338, 2006.