

최적화된 Interval Type-2 FCM based RBFNN 구조 설계 : 모델링과 패턴분류기를 중심으로

Structural design of Optimized Interval Type-2 FCM Based RBFNN : Focused on Modeling and Pattern Classifier

김 은 후* · 송 찬 석* · 오 성 권* · 김 현 기*
(Eun-Hu Kim · Chan-Seok Song · Sung-Kwun Oh · Hyun-Ki Kim)

Abstract - In this paper, we propose the structural design of Interval Type-2 FCM based RBFNN. Proposed model consists of three modules such as condition, conclusion and inference parts. In the condition part, Interval Type-2 FCM clustering which is extended from FCM clustering is used. In the conclusion part, the parameter coefficients of the consequence part are estimated through LSE(Least Square Estimation) and WLSE(Weighted Least Square Estimation). In the inference part, final model outputs are acquired by fuzzy inference method from linear combination of both polynomial and activation level obtained through Interval Type-2 FCM and acquired activation level through Interval Type-2 FCM. Additionally, The several parameters for the proposed model are identified by using differential evolution. Final model outputs obtained through benchmark data are shown and also compared with other already studied models' performance. The proposed algorithm is performed by using Iris and Vehicle data for pattern classification. For the validation of regression problem modeling performance, modeling experiments are carried out by using MPG and Boston Housing data.

Key Words : Interval type-2 FCM clustering, principal component algorithm, Linear discriminant analysis, Least square estimation, Weighted least square estimation, Differential evolution

1. 서 론

1965년 Zadeh에 의해 창안된 “퍼지 집합” 이론은 비선형적이고 잡한 실 시스템의 특성을 해석하는데 적용함으로써 수학적 모델보다 좋은 결과를 가져왔다[1]. 현재는 퍼지 집합을 이용한 퍼지 추론 시스템과 더불어 퍼지 뉴럴 네트워크, 그리고 퍼지 다항식 뉴럴 네트워크 등의 다양한 구조가 여러 분야에 적용되고 있다. 또한 데이터의 효율적인 처리를 위하여 정보 입자화 알고리즘과 최적화 알고리즘, 그리고 다양한 빅 데이터 처리기법을 결합시켜 모델의 구조 및 성능을 개선시키거나 새로운 모델을 구축하는 방향으로 연구가 진행되고 있다. Type-1 퍼지 집합의 확장인 Type-2 퍼지 집합은 Zadeh에 의해 소개 되었으며, Mizumoto와 Tanaka는 Type-2 퍼지 집합의 이론적인 연산 및 멤버십 함수의 특성에 대해 연구하였다. 또한 Mendel과 Karnik은 퍼지 “if-then” 규칙으로 표현되는 Type-2 퍼지 논리 시스템에 대해 연구하였다[2]. 하지만 기존의 퍼지 추론 시스템을 이용할 경우 일반적으로 규칙을 형성하는데 있어서 멤버십 함수에 따

른 차원의 수가 증가하면 규칙수가 지수적으로 증가하는 문제를 가지고 있다. 본 연구에서는, 이러한 문제를 해결하기 위하여 FCM(Fuzzy C-Means) 클러스터링 알고리즘을 확장시킨 interval type-2 FCM 클러스터링에 기반한 RBFNN 모델을 설계한다. interval Type-2 FCM 기반 RBFNN은 클러스터의 수만큼의 공간 분할이 이루어지며 각각의 분할된 부분 공간이 하나의 퍼지 규칙을 형성한다. 이러한 특성 때문에 차원의 저주로부터 벗어날 수 있으며 퍼지 규칙의 구현 한계성을 극복하게 된다.[3,4] 또한 전처리 알고리즘인 PCA와 LDA를 사용하여 입력차원의 정보 손실을 최소화한 저차원의 특징 데이터를 생성한다. 결론부의 다항식 계수는 LSE와 WLSE를 통해 추정되며 두 학습 알고리즘을 비교 분석한다. 본 논문은 다음과 같은 구성으로 이루어진다. 2장에서는 선형 특징추출 기법에 대해 설명하며 3장에서는 제안한 interval type-2 FCM based RBFNN의 구조 및 4장에서 최적화를 위한 차분진화 알고리즘에 대해 설명한다. 5장에서는 Machine Learning 데이터를 이용한 제안된 모델의 실험 결과를 보여주며, 6장에서는 결론으로 마무리한다.

† Corresponding Author : Dept. of Electrical Engineering, The University of Suwon, Korea
E-mail: ohsk@suwon.ac.kr

* Dept. of Electrical Engineering, The University of Suwon, Korea.

Received : March 2, 2016; Accepted : February 21, 2017

2. 선형 특징추출 기법을 이용한 데이터 전처리

본 장에서는 데이터 전처리 과정으로 데이터의 차원축소를 진행하기 위한 PCA와 LDA에 대하여 서술하도록 한다. 선형 변환

에 의한 특징 추출 방법의 가장 큰 목적중 하나는 차원 축소인데, 고차원의 데이터의 경우 계산량이 급격히 증가할 뿐만 아니라 차원이 늘어남에 따라 데이터 처리에 많은 비용이 들어 추정 의 정확도도 저하가 발생한다. 이와 더불어 원래 주어진 입력 데이터를 그대로 활용하는 경우에는 인식에 불필요한 정보까지도 함께 사용하게 되어 결과적으로 인식을 저하의 원인이 되기도 한다[5].

2.1 주성분 분석법

주성분 분석법은 대표적인 선형변화에 의한 특징 추출 방법으로, 얻어진 특징데이터의 차원 m 이 입력데이터의 차원 n 보다 작은 값이 되어 저차원의 특징을 추출하는 것을 기본 전제로 한다. 또한 주성분 분석법의 가장 큰 목적은 변환 전의 데이터 X 가 가지고 있는 정보를 차원 축소 후에도 최대한 유지하도록 하는 것이다. PCA 변환을 통해 입력 벡터의 차원을 감소하고 노이즈를 제거하여 저차원의 고유특성을 보이지만, 집단 간에 관계를 고려하지 않고 전체 데이터에 대한 분산을 최대화 하는 방향으로만 투영하기 때문에 데이터 간에 겹침 현상이 발생하는 단점을 가진다. 주성분 분석법 알고리즘은 다음과 같다.

[Step 1] 입력데이터 집합 X 의 평균 μ_x , 공분산 Σ_x 를 계산한다.

$$\mu_x = \frac{1}{N} \sum_{i=1}^M x_i, \quad \Sigma_x = \frac{1}{N} (X - M_x)(X - M_x)^T \quad (1)$$

[Step 2] 고유치 분석을 통해 공분산 Σ_x 의 고유치 행렬 Λ 과 고유벡터 행렬 U 를 계산한다.

$$\Sigma_x = U \Lambda U^T = [u_1, u_2, \dots, u_n] \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & 0 & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_n \end{bmatrix} [u_1, u_2, \dots, u_n]^T \quad (2)$$

[Step 3] 고유값이 큰 순서로 k 개를 선택하여 대응되는 고유벡터를 변환 행렬 $W = [w_1, w_2, \dots, w_k]$ 로 저장한다.

[Step 4] 특징 데이터 Y 를 구한다.

$$W^T X = Y \quad (3)$$

2.2 선형 판별 분석법

선형 판별 분석법은 클래스간 분산과 클래스내 분산의 비율을 최대화하는 방식의 특징 추출을 목적으로 한다. 이는 데이터에 대해 평균 근처에서 집중 발생하고, 평균 근처에서부터 주위로 감소되는 밀도를 가진다는 특정한 가정하에 집단의 타당한 분리를 보증하는 방법이다. 이 변환 방법은 집단간의 편차는 최대로 해주면서, 집단 내 편차를 최소로 하여, 데이터를 쉽게 나눌 수 있고, 집단 또한 쉽게 분리 할 수 있도록 한다. PCA 변환이 입력데이터를 다른 공간으로 변환할 때, 입력데이터의 모양과 위치

가 변화하고, 집단 간의 겹침이 발생하는 단점을 가지는 반면, LDA 변환은 입력데이터의 위치가 변하는 것이 아니라, 주어진 클래스가 확실히 구별 될 수 있도록 판별 선을 그려주기 때문에 집단간의 겹침이 발생하는 것을 막아줄 수 있다.

[Step 1] 전체 분산 S_T 와 클래스 내 분산 S_W 를 구한다.

$$S_T = \frac{1}{N-1} \sum_{i=1}^N (y_i - \mu)(y_i - \mu)^T, \\ S_W = \sum_{j=1}^{class} \left\{ \frac{1}{N_c - 1} \sum_{i=1}^{N_c} (y_i - \mu_j)(y_i - \mu_j)^T \right\} \quad (4)$$

여기서 μ 는 전체 데이터의 평균을 나타내며, μ_j 는 각 클래스의 평균을 나타낸다.

[Step 2] 아래식의 비율을 최대로 하는 변환행렬 W 를 구한다.

$$J(W) = \operatorname{argmax} \left| \frac{W^T S_T W}{W^T S_W W} \right| \quad (5)$$

여기서, W 는 $S_W^{-1} S_T$ 의 고유 벡터를 열벡터로 가지는 행렬로 다음과 같이 식 (2)와 같은 고유치 분석을 통해 구할 수 있다. 이후 단계는 주성분 분석법의 [Step 3]과 [Step 4]의 단계가 동일하다. 주성분 분석법과 선형 판별 분석을 통해 차원이 축소된 특징 데이터를 가지고 다항식 방사형 기저 함수 신경회로망 패턴분류기의 입력으로 사용된다.

3. Interval Type-2 FCM based RBFNN의 구조

3.1 Interval Type-2 Fuzzy Sets

Type-2 퍼지 집합 멤버쉽 함수란 Type-1 퍼지 집합 멤버쉽 함수의 확장된 형태이다. 일반적으로 General 형태와 Interval 형태로 나눌 수 있다. Type-2 퍼지 집합 멤버쉽 함수는 두 개의 멤버쉽 함수가 겹쳐진 형태로 멤버쉽 함수의 적합도는 $[\underline{\mu}_A(x), \overline{\mu}_A(x)]$ 와 같이 Upper와 Lower로 각각 나타난다. 기존의 Type-1 멤버쉽 함수와 달리 Type-2 멤버쉽 함수는 Footprint Of Uncertain(FOU)라 불리는 영역이 존재한다. FOU는 Upper와 Lower 사이의 영역을 말하며 영역의 위쪽 경계선이 적합도의 Upper 부분이 되고, 아래쪽 경계선이 적합도의 Lower 부분이 된다. General type-2 멤버쉽 함수와 Interval type-2 멤버쉽 함수의 개념은 동일하지만, 연산의 복잡성에 차이가 있으며, Type-2 멤버쉽 함수의 적합도를 나타내는 식은 다음과 같다[2].

$$\tilde{A} = \int_{x \in X} \mu_{\tilde{A}}(x)/x = \int_{x \in X} \left[\int_{u \in [\underline{\mu}_{\tilde{A}}, \overline{\mu}_{\tilde{A}}]} f_x(u)/x \right] / x \quad (6)$$

식 (6)에서, secondary 멤버쉽 함수의 영역은 x 에 대한

primary 멤버십 함수이며, J_x 는 x 에 대한 primary 멤버십 함수이다. $f_x(u)$ 는 secondary 멤버십 함수의 크기이다. $f_x(u)/u=1, \forall u \in J_x \subseteq [0,1]$ 인 경우에는 secondary 멤버십 함수는 Interval이며, $\mu_{\tilde{A}}(x)$ 는 Interval Type-2 멤버십 함수이다. 따라서, \tilde{A} 는 다음과 같이 표현된다.

$$\tilde{A} = \int_{x \in X} \mu_{\tilde{A}}(x)/x = \int_{x \in X} \left[\int_{u \in J_x} 1/u \right] / x, J_x \subseteq [0,1] \quad (7)$$

primary 멤버십 값에 대한 불확실성은 Footprint of uncertainty (FOU)라 불리는 경계구간을 갖는 Type-2 퍼지 집합으로 표현된다.

$$FOU(\tilde{A}) = U_{x \in X} J_x \quad (8)$$

FOU에 대한 예는 그림 2에서 보여준다. FOU는 type-2 퍼지 집합의 Interval 특성을 강조하기 위하여 균일 되게 표현된다. 불확실성은 임의의 범위 내에서 정점을 기준으로 멤버십비함수의 값을 표현한다. 여기서, a, b, c는 멤버십 파라미터이며 σ_a 와 σ_c 는 a와 c의 불확실성을 의미한다.




그림 1 Interval Type-2 퍼지 집합
Fig. 1 Interval Type-2 Fuzzy Sets

Interval type-2 퍼지 집합의 FOU에 대한 경계는 상위 경계와 하위 경계의 두 개의 Type-1 멤버십 함수를 가진다. 상위 멤버십 함수 $\overline{\mu_{\tilde{A}}}(x)$ 는 $FOU(\tilde{A})$ 의 상위 경계를 나타내며 하위 멤버십 함수 $\underline{\mu_{\tilde{A}}}(x)$ 는 $FOU(\tilde{A})$ 의 하위 경계를 의미한다. 퍼지 공간은 각 입력에 대해 적은 수의 멤버십 함수가 필요한데, 고차원으로 갈수록 규칙의 수가 지수적으로 증가하는 문제를 해결하기 위해 본 논문에서는 분산(퍼지) 형태의 지역 퍼지 공간을 분할하기 위하여 interval type-2 FCM 클러스터링 알고리즘을 이용하여 입력 공간으로 분할한다. 각 분할된 퍼지 공간은 퍼지 규칙을 형성하게 되며, 퍼지 규칙 수는 클러스터의 수가 된다. Type-2 FCM 클러스터링은 불확실성을 표현하기 위하여 FCM 클러스터링의 퍼지화 계수를 조절하여 상위 소속 정도와 하위 소속 정도를 표현한다. 각 클러스터는 각 클러스터의 최대 소속 정도를 갖는 데이터의 표준편차에 의해 서로 다른 불확실성을 갖는다[2,6].

3.2 Interval Type-2 FCM based RBFNN의 구조

제안된 interval type-2 FCM based RBFNN은 입력층, 은닉층, 출력층으로 구성된 일반적인 신경회로망 구조와 동일하다. 그러나 기존 기법들과는 다르게 데이터의 특성을 반영하기 위해 가우시안 활성 함수를 대신하여 Type-2 퍼지 집합을 가지는 type-2 FCM 클러스터링을 사용하여 입력 공간을 분할한다. 또한 비선형 특성의 판정 경계를 위해 상수항 연결가중치를 다항식 연결가중치로 확장하여 이용한다. 제안된 모델은 식 (9)와 같이 If-then의 퍼지 규칙을 사용한다.

$$R: \text{If } x_1, x_2 \dots \text{ and } x_n \text{ are } \tilde{u}_i, \text{ Then } y = f_{ji}(x) \quad (9)$$

여기서 x 는 입력데이터, \tilde{u}_i 는 FCM 클러스터링에 의한 i 번째 그룹의 소속 함수, $f_{ji}(x)$ 는 j 번째 출력에 대한 i 번째 퍼지 규칙의 다항식이다.

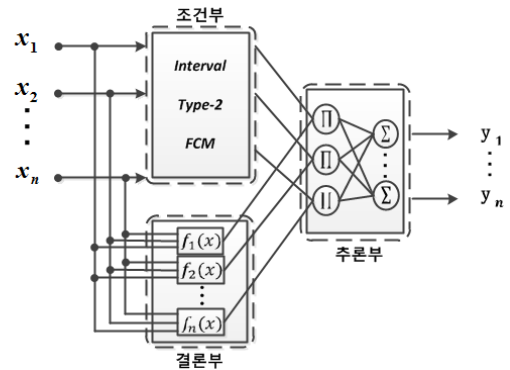


그림 2 Interval Type-2 FCM based RBFNN의 구조
Fig. 2 Structure of Interval Type-2 FCM based RBFNN

식 (9)에서 나타난 “Then” 이전의 조건부는 클러스터에 대한 각 데이터의 거리를 기준으로 소속정도를 측정하여 데이터들의 특성을 분류하는 FCM 클러스터링을 확장한 Type-2 FCM을 사용하였다. 은닉층 활성함수의 중심점 및 분포상수를 정의하기 위해 쓰였으며 각 데이터의 소속정도는 각 규칙에 대한 적합도로서 사용된다[9][10]. 입력 데이터는 은닉층의 노드 수만큼 클러스터링하여 입력 공간을 분할하고, 클러스터링으로 나온 중심점을 활성함수의 중심점으로 사용하였으며 활성함수의 분포상수는 주어진 입력 데이터와 클러스터 중심점간의 표준편차를 구해 적용하였다. 다음은 FCM 클러스터링의 절차이다[10].

본 연구에서는 전체 입력 공간을 분산(퍼지) 형태로 분할하는 interval type-2 FCM으로 각각의 분할된 퍼지 공간으로 퍼지 규칙을 형성하게 되며, 퍼지 규칙 수는 클러스터의 수가 된다. 클러스터들의 부피가 비슷하거나 같을 경우에는 퍼지화 계수 m 값에 따라 좋은 성능을 기대할 수 있지만, 아래 그림과 같이 클러스터들의 부피가 다를 경우에는 하나의 m 으로는 좋은 성능을 보일 수 없다.

Type-1 FCM의 소속행렬은 패턴 인식에서 패턴의 불확실성을

나타나는데 사용되어져 왔다. 하지만 type-1 FCM 으로 좋은 결과를 나타낼 수 없는 경우에는 interval type-2 기반 퍼지 집합을 사용함으로써 더 나은 결과를 나타낼 수 있다. Interval type-2 FCM 기반 RBFNN으로 type-1 FCM 기반 RBFNN 보다 패턴인식의 불확실성을 더 다양하게 제어할 수 있기 때문이다. 본 논문에서는 m 은 퍼지화 계수로 클러스터의 퍼지화 정도를 결정한다. m 에 따른 Upper and Lower 멤버십 함수는 다음과 같이 구성할 수 있다.

$$\bar{u}_{ik} = \begin{cases} \frac{1}{\sum_{k=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m_1-1}}}, & \text{if } \frac{1}{\sum_{k=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)} < \frac{1}{c} \\ 1, & \text{otherwise} \end{cases}$$

$$\underline{u}_{ik} = \begin{cases} \frac{1}{\sum_{k=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m_2-1}}}, & \text{if } \frac{1}{\sum_{k=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)} \geq \frac{1}{c} \\ 1, & \text{otherwise} \end{cases} \quad (10)$$

여기서 m_1 은 upper 퍼지화 계수이고, m_2 는 lower 퍼지화 계수, c 는 클러스터 수이다. 입력패턴들이 각 클러스터에 대한 Upper and lower 멤버십 값을 구하고 나면 각 클러스터들의 중심 값을 갱신해야한다. 중심값 갱신을 위해 Type reduction이 필요하다. Type reduction을 수행하는 알고리즘은 KM(Karnik and Mendel) 알고리즘을 사용한다. KM 알고리즘은 가장 작은 값과 가장 큰 값을 구한다. 이 두 개의 값의 평균으로 제안된 모델의 최종 소속행렬을 구할 수 있다.[9]

[Step 1] 클러스터의 수 c 를 정하고 퍼지화 계수 $\bar{m}_i, \underline{m}_i$ 를 선택한다. 소속행렬 U 와 클러스터 중심 v 의 계산은 일반적인 FCM 클러스터링 절차와 동일하다.

(여기서 \bar{m}_i 는 i 번째 클러스터에 대한 상위 퍼지화 계수이며, \underline{m}_i 는 i 번째 클러스터에 대한 하위 퍼지화 계수이다.)

[Step 2] 상위 적합도와 하위 적합도의 평균을 이용하여 v_r 과 v_l 을 계산한다.

$$\dot{v}_{ij}^r = \frac{\sum_{k=1}^n u_{ik}^{\frac{2}{m_1-1}} \times x_{kj}}{\sum_{k=1}^n u_{ik}^{\frac{2}{m_1-1}}} \quad (11)$$

[Step 3] 다음 식을 만족하는 스위칭 포인트를 찾고 스위칭 포인트를 기준으로 적합도 위치를 서로 바꿔준다.

$$v_r^p \leq \dot{v}_{ij}^r \leq v_r^{p+1}, \quad p(1 \leq p < h-1) \quad (12)$$

여기서 $x_{kj} - \dot{v}_{ij}^r < 0$ 이면 lower 적합도 선택하고, $x_{kj} - \dot{v}_{ij}^r > 0$ 이면 Upper 적합도 선택한다.

[Step 4] 식 (11)과 식 (12)이 같으면 ($\dot{v}^r = \ddot{v}^r$), \ddot{v}^r 이 최종출력이 되고 알고리즘을 종료한다. 아니면 [Step 5]으로 이동한다.

[Step 5] $\dot{v}^r = \ddot{v}^r$ 을 놓고 [Step 3]로 이동하여 알고리즘 반복 수행한다. (\dot{v}^l 도 [Step 2]부터 같은 방법으로 수행한다)

[Step 6] $v = (\dot{v}^r + \dot{v}^l)/2$ 로 클러스터 중심을 구하고, 클러스터 중심과 데이터 사이의 거리로 소속행렬 U 를 구한다.

RBFNN의 결론부는 “Then” 이후 비선형 특성의 판정 경계를 위해 네트워크의 연결가중치를 다항식으로 구성하였으며, 퍼지 규칙의 로컬 모델로 동작된다. 후반부 다항식 구조는 상수항, 1차 선형식 및 변형된 2차식으로 나타내며 다항식 연결가중치의 파라미터 계수(a)를 동정하기 위해 최소자승법(LSE) 및 가중최소자승법(WLSE)을 두 가지 학습 방법을 사용하여 각각의 모델을 설계하며 성능을 비교 분석한다.

LSE(Least Square Estimation)

$$A = (X^T X)^{-1} X^T Y \quad (13)$$

WLSE(Weighted Least Square Estimation)

$$A_j = (X^T U_j X)^{-1} X^T U_j Y \quad (14)$$

LSE는 오차제곱의 합이 최소가 되도록 계수를 추정하지만, WLSE는 오차제곱에 가중치가 곱해진다는 차이가 있다. LSE는 후반부 다항식들의 계수를 한 번에 구하기 때문에 전역 모델의 학습을 수행하게 되고, 입력변수와 멤버십 함수의 수가 많아지면 퍼지 규칙수가 기하급수적으로 늘어나기도 하므로, 컴퓨터 연산을 수행하지 못하는 경우가 발생하기도 한다. 따라서 각 퍼지 규칙에 대한 해석력이 사라지는 경향이 있다. 반면에 WLSE는 각 규칙의 후반부 다항식의 계수를 퍼지 규칙마다 독립적으로 구하며 로컬 학습을 수행한다. 또한 분할된 입력공간에 적합한 로컬 모델을 형성함으로써 각 로컬영역에 대한 해석력을 향상시킬 수 있는 장점이 있다. 마지막으로 WLSE는 컴퓨터의 계산량의 부하를 줄일 수 있으며, 각각의 로컬 모델이 서로 다른 형태의 다항식으로 표현 될 수 있다.[8]

LSE에서의 성능평가 함수 Q_L 을 행렬로 표현하면 다음과 같다

$$Q_L = (Y - XA)^T (Y - XA) \quad (15)$$

여기서, A 는 후반부 다항식의 파라미터 계수, Y 는 출력 데이터, X 는 FCM의 소속행렬이 곱해진 입력데이터의 행렬을 의미한다. 후반부 구조가 선형식일 경우 X, Y, A 행렬은 다음과 같이 표현

할 수 있다.

$$X = \begin{bmatrix} u_{11} & \dots & u_{c1} & x_{11}u_{11} & \dots & x_{11}u_{c1} & \dots & x_{k1}u_{11} & \dots & x_{k1}u_{c1} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \dots & \vdots & \ddots & \vdots \\ u_{1m} & \dots & u_{cm} & x_{1m}u_{1m} & \dots & x_{1m}u_{cm} & \dots & x_{km}u_{1m} & \dots & x_{km}u_{cm} \end{bmatrix}, Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix}$$

$$A = [a_{10}, a_{11}, \dots, a_{1k}, \dots, a_{c0}, a_{c1}, \dots, a_{ck}]^T$$

여기서 m 은 데이터의 수이며, k 는 입력변수의 수, c 는 규칙 수 (클러스터 수)가 된다. 전역 모델에 대한 후반부 다항식의 계수 A 는 식 (13)에 의해 구해진다.

다음은 LSE의 가중치가 곱해진 WLSE에서의 성능평가 함수 Q_w 를 행렬 형식으로 표현하면 식 (16)과 같다.

$$Q_w = \sum_{j=1}^c (Y - XA_j)^T U_j (Y - XA_j) \tag{16}$$

여기서, a_j 는 추정하고자 하는 j 번째 다항식의 계수, Y 는 출력데이터, U_j 는 j 번째 입력공간에 대한 입력 데이터들의 소속 값을 의미한다. X_j 는 j 번째 로컬모델의 계수를 추정하기 위한 입력데이터 행렬을 의미하며, 로컬모델이 선형일 경우 다음처럼 정의된다.

$$X_j = \begin{bmatrix} 1 & x_{11} & \dots & x_{1k} \\ 1 & x_{21} & \dots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{m1} & \dots & x_{mk} \end{bmatrix}, U_j = \begin{bmatrix} u_{j1} & 0 & \dots & 0 \\ 0 & u_{j2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & u_{jm} \end{bmatrix}$$

여기서 m 은 데이터의 수이다. j 번째 규칙에 대한 로컬모델인 다항식의 계수는 식 (14)에 의해 구해진다.

모델의 최종 출력은 식 (17)와 같이 표현한다.

$$y = \frac{\sum_{i=1}^c u_i(x) f_i(x)}{\sum_{i=1}^c u_i(x)} = \sum_{i=1}^c \hat{u}_i(x) f_{ji}(x) \tag{17}$$

여기서, c 는 은닉층의 노드 수를 나타낸다.

4. 차분진화(DE) 알고리즘을 이용한 최적화

4.1 차분진화 알고리즘

차분진화 알고리즘(Differential Evolution: DE)은 Price와 Storn에 의해 벡터 차분(Vector Differential)을 사용하여 chebychev 다항곡선의 내삽 문제(Polynomial fitting problem)를 해결하는 과정에서 개발되었다[11]. 차분 진화 알고리즘은 통계적임의 탐색법인 유전 알고리즘(Genetic Algorithm: GA)와 유사한 알고리즘으로, DE와 GA는 초기 개체군을 이루는 개체를 샘플링하고 교배(Crossover), 변이(Mutation), 선택(Selection) 과정을 거쳐 새로운 개체들을 추출해 낸다는 공통점이 있다. 그러나 DE

에서는 초기 개체군을 이루는 모든 개체들을 벡터로 표현하며 이들을 파라미터 벡터라고 표현하여, GA알고리즘의 경우 개체들의 표현을 유전형인 0 또는 1로 바꾸는 코딩이 필요한 반면에 차분진화 알고리즘은 코딩 과정이 필요 없음을 뿐만 아니라 유전알고리즘의 단점인 복잡한 구조와 연산대신 개체를 간단하고 합리적인 구조의 벡터 방식으로 표현하기 때문에 이 벡터들의 산술적 연산을 통한 새로운 개체를 생성한다는 이점이 있다. 또한 GA의 단점이었던 복잡한 구조와 연산과정에 비하여 간단하고 합리적인 구조와 연산속도가 빠르다는 장점이 있다. 차분진화의 실행 단계를 정리하면 다음과 같다.

[Step 1] 초기 집단 구성(임의의 값으로 μ 개의 개체를 초기화. $t = 0$.)

$$P(t) = a_1(t), a_2(t), \dots, a_\mu(t), a_k = x_{ik}, \dots, x_{nk} \tag{18}$$

[Step 2] 집단내의 모든 개체의 목적함수(Φ) 평가

$$\Phi(t) = \Phi(a_1(t)), \dots, \Phi(a_\mu(t)), \Phi(a_k(t)) = func(x_{1k}, \dots, x_{nk}) \tag{19}$$

[Step 3] 모든 개체에 대하여 차분 변화를 위한 개체 a_{r_1}, a_{r_2} 와 a_{r_3} 를 선택하여 교배용 벡터를 만들고 이를 교배 대상 벡터와 교배함

$$v_i(t) = a_{r_1}(t) + F \cdot (a_{r_2}(t) - a_{r_3}(t)): \text{교배용 벡터} \tag{20}$$

$$x'_i(t) = v_i(t) * a_i(t) : \text{교배} \tag{21}$$

[Step 4] 모든 개체의 목적함수 평가

$$\Phi(t) = \Phi(x'_1(t)), \dots, \Phi(x'_\mu(t)) \tag{22}$$

$$\text{if } (\Phi(x'_i(t)) < \Phi(a_i(t))) a_i(t) = x'_i(t) \tag{23}$$

[Step 5] 종료조건을 확인하고 종료 조건이 만족되지 않으면 $t = t + 1$ 로 하고 [Step 3]으로 복귀

표 1 차분 진화의 파라미터의 구성

Table 1 Parameter composition of differential evolution

Parameters	Value
No. of generations	300
Vector size	100
Crossover rate	0.8
F-weight	0.5

5. 실험 결과

본 장에서는 제안된 모델의 성능을 평가한다. 실험은 모델링 및 패턴분류로 나누어 수행하였으며 각 실험의 파라미터 설정은 표 2와 같다.

표 2 제안된 모델의 파라미터 설정

Table 2 Parameter setting of the proposed model

	Parameter	Search Space
Modeling	Fuzzification coefficient	[1.1~3.0]
	Polynomial type	[0~2]
Classification	Fuzzification coefficient	[1.1~3.0]
	No. of rules	[4~10]
	No. of vectors	[2~Max input]
	Polynomial type	[0~2]

※Polynomial Type(0:Constant, 1:Linear, 2:Modified quadratic)

표 3 MPG 데이터의 LSE와 WLSE 성능비교

Table 3 Comparative performance between LSE and WLSE on MPG data

	R	m ₁ , m ₂	PI	VPI	EPI
I	4	1.78	2.53±0.12	3.29±0.30	3.09±0.29
	6	1.83	2.38±0.12	3.52±0.06	3.65±0.51
	8	1.83	2.37±0.13	3.54±0.39	3.53±0.52
	10	1.83	2.35±0.13	4.17±0.54	5.07±2.48
II	4	1.37	2.62±0.14	3.12±0.28	2.77±0.40
	6	1.25	2.55±0.16	3.17±0.29	2.80±0.45
	8	1.37	2.44±0.13	3.24±0.29	2.89±0.44
	10	1.42	2.33±0.14	3.32±0.25	2.97±0.42
III	4	1.7,3.0	2.49±0.09	3.19±0.26	2.87±0.24
	6	1.3,2.8	2.23±0.06	3.40±0.40	3.38±0.63
	8	1.3,2.8	2.02±0.10	3.72±0.39	3.80±0.75
	10	1.4,2.8	1.85±0.18	4.06±0.98	4.34±1.49
IV	4	1.4,2.0	2.60±0.11	3.08±0.27	2.75±0.36
	6	1.8,2.0	2.40±0.11	3.08±0.31	2.77±0.36
	8	1.8,2.0	2.27±0.17	3.09±0.35	2.74±0.40
	10	1.6,2.0	2.23±0.18	3.08±0.33	2.75±0.37

I: Type-1 FCM based RBFNN(LSE)
 II: Type-1 FCM based RBFNN(WLSE)
 III: Interval Type-2 FCM based RBFNN(LSE)
 IV: Interval Type-2 FCM based RBFNN(WLSE)

5.1 모델링 데이터

모델링에 사용한 Machine Learning 데이터는 MPG 데이터와 Boston housing 데이터를 사용하였다. 규칙수를 4, 6, 8, 10개 고정하여 실험을 수행하였다. 데이터 분할은 최적화를 적용하기 위해 3개로 나누어 전체 데이터에서 50%는 학습데이터로 사용하며, 30%는 검증데이터, 20%는 테스트 데이터로 사용된다.

5.1.1 Automobile Miles per Gallon(MPG) 데이터

Automobile Miles per Gallon 데이터는 시스템 모델링에 흔히 사용되는 비선형 데이터 중 하나이다. 데이터는 총 7입력-1출력의 형태로 총 392개이며, 차량의 고유한 정보 대한 기준용량(1 Gallon)의 연료로 차량이 주행한 거리(Miles)의 출력 값으로 나타난다.

표 3에서 보는 것과 같이 LSE와 WLSE 모두 규칙 수가 증가됨에 따라 학습 데이터의 성능지수인 근사지수(PI)는 감소하고

표 4 기존 모델과의 성능 비교

Table 4 Comparison of performance with other models

Model	N	Performance accuracy		
		PI	EPI	
Pedrycz's RBFNN [12]	36	3.24±0.24	3.62±0.31	
Pedrycz's RBFNN with context-free [12]	36	3.21±0.21	3.51±0.27	
Pedrycz's Linguistic modeling [12]	without Optimization	36	3.78±1.52	4.22±1.22
	One-loop Optimization	36	2.90±0.32	3.17±1.01
	Multi-step Optimization	36	2.86±0.83	3.14±1.01
Roh's Single PNN [13]	N/A	2.56±0.14	2.94±0.34	
Roh' MARS [13]	N/A	2.72±0.10	3.05±0.21	
Proposed model	10	2.23±0.18	2.75±0.37	

표 5 BH 데이터의 LSE와 WLSE 성능비교

Table 5 Comparative performance between LSE and WLSE on BH data

	R	m ₁ , m ₂	PI	VPI	EPI
I	4	1.95	3.06±0.13	3.98±0.28	6.88±0.54
	6	1.98	2.77±0.09	4.97±1.11	12.60±5.37
	8	1.95	3.42±0.19	4.56±0.63	8.20±8.73
	10	1.96	2.84±0.22	7.16±3.97	14.55±9.61
II	4	1.23	3.59±0.10	3.82±0.20	3.67±0.39
	6	1.25	3.12±0.23	3.85±0.31	3.61±0.44
	8	1.28	3.00±0.22	3.77±0.17	3.58±0.35
	10	1.25	2.73±0.28	3.99±0.44	3.75±0.31
III	4	1.5,2.7	3.31±0.10	4.15±0.26	4.18±0.52
	6	1.8,2.1	2.86±0.17	4.42±0.57	4.66±0.44
	8	1.4,3.0	2.49±0.23	6.14±1.93	5.55±0.46
	10	1.1,2.5	2.20±0.17	13.62±9.78	8.47±2.12
IV	4	1.5,2.0	3.24±0.12	3.58±0.11	3.54±0.25
	6	1.5,2.0	3.12±0.11	3.57±0.11	3.53±0.25
	8	1.3,2.0	3.03±0.11	3.54±0.12	3.46±0.27
	10	1.5,2.0	2.90±0.06	3.60±0.14	3.56±0.24

I: Type-1 FCM based RBFNN(LSE)
 II: Type-1 FCM based RBFNN(WLSE)
 III: Interval Type-2 FCM based RBFNN(LSE)
 IV: Interval Type-2 FCM based RBFNN(WLSE)

있다. 하지만 LSE를 이용하여 후반부 파라미터 계수를 추정할 시에는 Type-1모델과 Type-2모델 모두 테스트 성능 지수인 일반화 지수(EPI)는 규칙 수가 증가함에 따라 점점 커지는 경향이 있다. 이에 반해 WLSE를 이용하여 후반부 파라미터 계수를 추정할 시에는 규칙수가 증가됨에 따라 근사지수는 감소하고 있는데도 불구하고 일반화지수의 범위는 비슷하게 나타냄을 확인할 수 있었다. Type-1 모델과 Type-2 모델의 성능을 비교 할 경우에 Type-1모델과 Type-2모델의 근사화 지수는 비교적 비슷한 성능을 보이고 있으며, 일반화 지수는 전체적으로 Type-2 모델의 일반화 지수가 약간 개선된 성능을 보이고 있다. 표 4는 기존 알고리즘에서 MPG 데이터를 사용하여 나타낸 성능을 기록한 표이다.

표 6 기존 모델과의 성능 비교

Table 6 Comparison of performance with other models

Model		N	Performance accuracy	
			PI	EPI
Pedrycz's RBFNN [12]		25	6.36±0.24	6.94±0.31
Pedrycz's RBFNN with context-free [12]		5	5.52±0.25	6.91±0.45
Linguistic modeling [12]	without Optimization	25	5.21±0.12	6.14±0.28
	One-loop Optimization	25	4.80±0.52	5.22±0.58
	Multi-step Optimization	25	4.12±0.24	5.32±0.96
Roh's Single PNN [13]		N/A	3.72±0.35	5.54±3.46
Roh' MARS [13]		N/A	3.25±0.10	4.19±0.32
Proposed model		10	2.90±0.06	3.56±0.24

5.1.2 Boston Housing(BH) 데이터

Boston Housing 데이터는 보스턴 지역의 집값을 나타내는 데이터이다. 집값에 영향을 미치는 요소들인 주변 환경 및 시설 등을 파악하여 선별하고 수치로 환산하여 집값을 책정한 데이터이다. 데이터는 총 13입력-1출력으로 구성되었으며, 506개의 데이터로 구성되어 있다. 실험을 위하여 MPG 데이터와 동일하게 데이터를 분할하여 구성한다. 또한 동일하게 5-fold cross validation을 사용하여 성능지수를 평균과 표준편차로 나타내었다.

표 5와 같이, MPG데이터와 동일하게 LSE와 WLSE 모두 규칙 수가 증가함에 따라 근사지수(PI)는 감소하고 있는 경향을 보이고 있다. 또한 LSE를 이용하여 후반부 파라미터 계수를 추정할 시에는 Type-1모델과 Type-2모델 모두 테스트 성능 지수인 일반화 지수(EPI)는 규칙수가 증가함에 따라 점점 커지는 경향도 동일하게 나타나고 있다. 이에 반해 WLSE는 규칙수가 증가하여도 LSE에 비하여 비교적 안정적인 성능을 나타내고 있다. 표 6은 기존 모델과 성능을 비교한 결과를 나타내고 있다.

5.2 패턴 분류 데이터

패턴 분류실험에 사용한 데이터 또한 Machine Learning 데이터를 사용하였다. 또한, 제안한 알고리즘에 전처리 과정인 차원 축소 알고리즘 PCA와 LDA를 통하여 차원 축소를 하여 실험을 하였다.

5.2.1 Iris 데이터

Iris 데이터는 Iris꽃을 종류별로 분류하여 기록한 데이터다. 패턴 분류 분야에서 가장 많이 사용하는 데이터로 이 데이터는 총 3개의 클래스로 분류되며, 총 4입력으로 구성된다. 총 데이터 수는 150개로 각 클래스별 균등하게 50개 데이터로 이루어져 있다. 성능은 5-fold cross-validation(5fcv)를 사용하여 성능을 평균과 표준편차로 패턴 인식률을 나타내었다. Iris 데이터를 차원축소를 통하여 가장 좋은 성능을 보이는 차원의 특징을 파악하여 실험하였다. 특징을 파악한 데이터는 Type-1과 Typ-2의 성능 비교를

표 7 Iris 데이터의 Type-1 모델과 Type-2 모델의 성능비교

Table 7 Comparative performance between type-1 model and type-2 model on Iris data

Model	Selected parameters				Classification rate		
I-1	6	1.4	-	-	98.16±1.4	97.57±1.3	97.33±2.7
I-2	5	1.5	3	-	98.85±0.8	97.36±2.5	97.33±2.0
I-3	5	1.3	3	3	98.93±1.1	97.33±1.5	98.67±2.0
II-1	6	1.7, 2.8	-	-	99.46±0.7	97.33±2.4	98.00±1.8
II-2	5	1.3, 2.3	4	-	99.46±0.7	97.33±2.4	98.00±1.6
II-3	6	1.3, 2.1	3	3	99.46±0.7	98.20±1.8	98.67±1.8

표 8 기존 모델과의 성능지수 비교

Table 8 Comparison of performance with other models

Model	Classification rate [%]
Adamczak's FSM [14]	98.30
Abbass'sMPANN [15]	98.10
Anagnostopoulos's DigaNN [16]	97.90
Tipping's RVM [17]	97.20
Vapnik's SVM [18]	96.68
Duda's MLP [19]	85.92
Zheng's RBF2 [10]	97.13
Jensen's Bayes Net [10]	95.81
Proposed model	98.67

위하여 각각의 패턴 분류율을 나타내었다.

패턴 분류는 Type-1과 Type-2의 비교를 진행하며 각각의 PCA와 LDA를 이용하여 입력데이터를 차원 축소하여 진행하여 비교하였다. 또한 차분진화 알고리즘을 통하여 각 모델에서의 우수한 파라미터(규칙 수, 퍼지화 계수, 다항식 종류, 고유벡터 수)를 탐색하여 성능을 나타내었다. Iris 데이터는 모델의 성능들이 97% 이상의 성능을 나타내고 있다. Type-1 모델과 Type-2 모델을 비교 하였을 경우 서로 Testing 성능의 경우 Type-1 모델과 Type-2 모델의 경우 비슷한 성능을 보인다. Type-2 모델의 경우 전처리를 사용하지 않은 경우와, 전처리를 하였을 경우 거의 비슷한 테스트 성능을 보이지만 근소하게 차원축소를 사용한 경우 성능이 약간 개선된 결과를 나타내었다.

5.2.2 Vehicle Silhouettes 데이터

Vehicle Silhouettes 데이터는 차량을 다양한 각도에서 보여주는 실루엣 이미지를 특징 추출하여 4가지 종류의 차량으로 분류하는 데이터이다. 입력변수는 18개로 실험에 사용한 데이터 중 가장 고차원의 데이터이며, 데이터 수는 946개이며 총 4가지 클래스로 구성되어 있다.

Vehicle 데이터는 모델의 성능들이 80~90% 정도의 성능을 나타내고 있다. 성능이 가장 낮은 Type-1 FCM모델에서 차원축소를 진행하지 않은 경우에 79.05%로 가장 낮게 나왔으며, 성능이 가장 좋은 모델은 Type-2 FCM모델에서 PCA와 LDA를 사용한 경우 82.01%로 이 둘의 성능 차이가 가장 크다. Vehicle 데이터 또한 외란이 첨가된 데이터에 강인한 Type-2 FCM의 경우 Type-1 데이터 보다 더 좋은 성능을 보였으며 차원 축소를 진행

표 9 Vehicle Silhouettes 데이터의 Type-1 모델과 Type-2 모델의 성능비교

Table 9 Comparative performance between type-1 and type-2 model on vehicle silhouettes data

Model	Selected Parameters				Classification rate		
I-1	6	1.7	-	-	90.00±1.3	81.33±3.4	79.05±2.6
I-2	5	1.9	17	-	90.42±1.4	83.07±2.1	80.23±1.9
I-3	6	1.8	16	15	90.38±2.1	83.46±2.3	80.47±2.0
II-1	5	1.7, 2.8	-	-	91.96±1.1	81.73±1.0	81.18±1.8
II-2	5	1.7, 2.9	16	-	92.15±1.3	82.04±1.6	81.64±1.8
II-3	6	1.8, 2.3	16	15	92.43±1.3	82.04±1.6	82.01±2.0

표 10 기존 모델과의 성능지수 비교

Table 10 Comparison of performance with other models

Model	Classification Rate [%]
V.Sindhwani's Multi SVM [21]	80.00
Rajesh Parekh's CNN [21]	79.70
G.Cohen's Parzen [22]	65.21
H.Zuo's MOG [22]	65.79
B.scholkopf's OCSVM [22]	69.33
D.M.J's SVDD [22]	70.06
M.Galar's C4.5 [22]	75.15
Proposed model	82.01

할 경우 데이터의 고유 특징점을 입력데이터로 사용하여 우수한 성능을 보임을 확인할 수 있었다.

6. 결 론

본 논문에서는 Interval Type-2 FCM을 기반으로 한 RBFNN 모델을 제안하였다. 제안한 모델은 Type-2 FCM 클러스터링을 통해 클러스터의 수만큼의 공간 분할이 이루어지며 분할된 각각의 공간이 하나의 퍼지 규칙을 형성하여 차원의 저주로부터 벗어남과 동시에 퍼지 규칙의 구현 한계성을 극복하며, 또한 Type-1 FCM에 비해 비선형성이 강인한 특징을 보여, 외란 및 잡음이 섞인 데이터에 좋은 성능을 얻는 것이 장점이다. 또한 차분 진화 알고리즘을 통하여 최적의 성능을 보이는 퍼지화 계수 및 규칙 수, 고유벡터수를 추정하여 향상된 성능을 얻었다. RBFNN의 결론부에서는 다항식 구조를 1차선형식으로 표현하였으며, 모델링의 경우 파라미터 계수 추정 시에는 LSE와 WLSE를 적용하여 성능을 비교 하였다. 실험 결과를 통하여 각 데이터를 모두 LSE로 파라미터 추정 시에는 overfitting됨을 확인할 수 있었으며, 이에 반해 WLSE의 경우 규칙 수가 증가됨에도 학습데이터의 성능지수(PI)와 테스트 데이터의 성능지수(E_PI)가 비교적 안정적임을 확인할 수 있다. 패턴 분류의 경우 Type-1과 Type-2를 비교 분석하였으며, 각 모델에서 PCA와 LDA를 사용하여 데이터의 고유 특징점을 이용해 실험하였다. 차원 축소를 통해 패턴 분류율이 개선되었음을 확인하였다.

감사의 글

This work was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Science, ICT and Future Planning [grant number: NRF-2015R1A2A1A15055365] and also supported by the GRRC program of Gyeonggi province [grant number: GRRC Suwon 2016-B2, Centre for U-city Security & Surveillance Technology].

References

- [1] L.A. Zadeh, "Fuzzy sets," Inform. and Control, Vol. 8, pp. 338 - 353, 1965.
- [2] J.M. Mendel, Uncertain Rule-based Fuzzy Logic System: Introduction and New Direction, Prentice-Hall, NJ, 2001.
- [3] K. J. Park, Yong, K. Kim. S. K. Oh, "Design of Type-2 FCM-based Fuzzy Inference Systems and Its Optimization," Korean Institute of Electrical engineers, Vol. 60, No. 11, pp. 2157-2164, 2011.
- [4] B.-I. Choi, F. C.-H. Rhee, "Interval type-2 fuzzy membership function generation methods for pattern recognition," Information Sciences, Vol. 179, No. 13, pp. 2102-2122, 2009.
- [5] S.-H. Yoo, S.-K. Oh, W. Pedrycz, "Optimized face recognition algorithm using radial basis function neural networks and its practical applications," Neural Networks, Vol. 69, pp. 111-125, 2015
- [6] P. Melin, O. Castillo "A Review on the Applications of Type-2 Fuzzy Logic in Classification and Pattern Recognition," Expert Systems with Applications, Vol. 40, No. 13, pp. 5413-5423, October 2013.
- [7] S.-K. Oh, W.-D. Kim, W. Pedrycz, K. Seo, "Fuzzy Radial Basis Function Neural Networks with information granulation and its parallel genetic optimization," Fuzzy Sets and Systems, Vol. 237, pp. 96-117, 2014.
- [8] W.-D. Kim, S.-K. Oh, H.-K. Kim, "Structural Design of FCM-based Fuzzy Inference System: A Comparative Study of WLSE and LSE" Korean Institute of Electrical engineers, Vol. 59, pp. 981-989, 2010.
- [9] H. H. Kim, "Interval Type-2 Fuzzy Approach to Gradient Based FCM," Han Yang University, Graduate master's thesis, 2009.
- [10] W. D. Kim, "Optimized Type-1/Type-2 pRBF Neural Networks Architecture: Comparative Analysis & Methodological Design," The University of Suwon, Graduate master's thesis, 2011.
- [11] R. Storm, and K. Price, "Differential Evolution - A Simple

and Efficient Heuristic for Global Optimization over Continuous Spaces,” Journal of Global Optimization, Vol. 11, pp. 341 – 359, 1997.

- [12] W. Pedrycz, K. C. Kwak, “Linguistic models as a Framework of User-centric System Modeling,” IEEE Trans. Syst. Man Cybern. A, Vol. 36, pp. 727-745, 2006.
- [13] S. B. Roh, S. K. Oh, W. pedrycz, "A Fuzzy Ensemble of Parallel Polynomial Neural Networks with Information Granules formed by Fuzzy Clustering", Knowledge-Based Syst., Vol. 23, pp. 202-219, 2010.
- [14] R. Adamczak, W. Duda, and N. Jankowski “New Developments in the Feature Space Applications,” 3rd Conference on Neural Networks, Kule, pp. 65-70, 1997.
- [15] H. A. Abbass, “An Evolutionary Artificial Neural Networks Approach for Breast Cancer Diagnosis,” Artif Intell Med, Vol. 25, No. 3, pp. 265-281, 2002.
- [16] I. Anagnostopoulos, I. Maglogiannis, “Neural network-based Diagnostic and Prognostic Estimations in Breast Cancer Microscopic Instances,” Medical & Biological Engineering & Computing Springer Publishers to appea Sep, Vol. 44, No. 9, pp. 773-784, 2006.
- [17] M. E. Tipping, "The Relevance Vector Machine," Adv. Neural Inf. Pocess. Syst., Vol. 12, pp. 652-658, 2000.
- [18] V. Vapnik, "The Nature of Statistical Learning Theory," New York: Springer-Verlag, 1995.
- [19] R. O. Duda and P. E. Hart, "Pattern Classification and Science Analysis," New York : Wiley, 2002.
- [20] S. Haykin, "Neural Networks- A comprehensive Foundation", Engluood Cliffs, NJ: Prentice-Hall, 1999.
- [21] R. Parekh, J. H. Y and V. Honavar, “Constructive Neural-Network Learning Algorithms for Pattern Classification,” IEEE, Vol. 11, No. 2, pp. 436-451, 2000.
- [22] B. Krawczyk, M. Wozniak, and F. Herrera, “On the Usefulness of One-class Classifier Ensembles for Decomposition of Multi-class Problems,” Pattern Recognition, Vol. 48, pp. 3969-3982, 2015.

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



송 찬 석 (Chan-Seok Song)

2013년 수원대학교 전기공학과 공학사, 동 대학원 석사(2015). 관심분야는 퍼지 추론 시스템, 신경회로망, 패턴인식, 얼굴인식, 진화 최적화 등.

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



오 성 권 (Sung-Kwun Oh)

1981년 연세대학교 전기공학과 공학사, 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, 퍼지및지능시스템학회 편집위원, 2013년~현재 Information Sciences 편집위원. 관심분야는 퍼지 시스템, 퍼지-뉴럴 네트워크, 자동화 시스템, 고급 computational intelligence, 지능 제어 등.

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



김 현 기 (Hyun-Ki Kim)

1977년 연세대학교 전기공학과 공학사, 동 대학원 석사(1985), 박사(1991), 1997~2010년 경기지역 산학연기술 지원단 단장, 1998~2000년 사업기술정책연구소 심의위원, 2000~2004년 사단법인 산학연 컨소시엄 전국협의회 회장. 1989~현재 수원대학교 전기공학과 교수. 관심분야는 Automatic System and Control, Intelligent Modeling and Control 등.

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

저 자 소 개



김 은 후 (Eun-Hu Kim)

2009년 수원대학교 전기공학과 공학사, 동 대학원 석사(2011), 박사(2016), 2016~현재 수원대학교 전기공학과 Post-Doc. 관심분야는 퍼지 이론, 신경회로망, 클러스터링, 최적화 알고리즘, 컴퓨터 지능 및 지능 제어 등.