

퍼지 클러스터링기반 신경회로망 패턴 분류기의 학습 방법 비교 분석

Comparative Analysis of Learning Methods of Fuzzy Clustering-based Neural Network Pattern Classifier

김은후* · 오성권* · 김현기*

(Eun-Hu Kim · Sung-Kwun Oh · Hyun-Ki Kim)

Abstract - In this paper, we introduce a novel learning methodology of fuzzy clustering-based neural network pattern classifier. Fuzzy clustering-based neural network pattern classifier depicts the patterns of given classes using fuzzy rules and categorizes the patterns on unseen data through fuzzy rules. Least squares estimator(LSE) or weighted least squares estimator(WLSE) is typically used in order to estimate the coefficients of polynomial function, but this study proposes a novel coefficient estimate method which includes advantages of the existing methods. The premise part of fuzzy rule depicts input space as "If" clause of fuzzy rule through fuzzy c-means(FCM) clustering, while the consequent part of fuzzy rule denotes output space through polynomial function such as linear, quadratic and their coefficients are estimated by the proposed local least squares estimator(LLSE)-based learning. In order to evaluate the performance of the proposed pattern classifier, the variety of machine learning data sets are exploited in experiments and through the comparative analysis of performance, it provides that the proposed LLSE-based learning method is preferable when compared with the other learning methods conventionally used in previous literature.

Key Words : Fuzzy C-Means clustering, Weighted least squares estimator, Least squares estimator, Local least squares estimator

1. 서론

최근 인공지능의 높은 관심과 더불어 패턴인식을 이용한 많은 연구가 진행되고 있다. 그 중에서도 기계학습 방법 중 대표적인 서포트 벡터 머신(support vector machine; SVM) 및 인공 신경회로망(artificial neural network; ANN)을 이용한 패턴 분류가 많이 연구되고 있으며 최근에는 깊은 신경회로망(deep neural network; DNN) 및 컨볼루션 신경회로망(convolution neural network; CNN)이 큰 주목을 받고 있다[1-2]. 한편 퍼지 이론을 결합한 패턴 분류기도 오랫동안 연구되어 왔으며 클러스터링 및 진화 최적화 알고리즘을 적용하여 다양한 형태의 모델들이 개발되었으며 구조 및 성능 측면에서 뚜렷한 성장을 보이고 있다.

Oh와 Pedrycz 교수에 의해 퍼지 추론 시스템의 전반부 구조 설계 및 파라미터 동조를 위해 클러스터링 학습방법을 적용하였다. 클러스터링을 통해 멤버십 함수의 중심점을 결정하고 진화 최적화 연산으로 멤버십 함수의 중심점을 최적화시켜 구조 및 성능을 개선하였다. 이후에 방사형 기저 함수(radial basis function; RBF) 신경회로망[3-4]에 클러스터링을 적용하여 은닉층 활성화함수로 사용되는 가우시안 함수의 중심점 및 분포상수

를 k-평균 군집[11] 또는 Fuzzy C-means(FCM) 클러스터링[12-13]을 직간접적으로 활성화함수의 파라미터 학습에 활용하였다. 일반적인 클러스터링기반 신경회로망은 방사형 기저함수 신경회로망에 클러스터링 방법을 적용한 하이브리드 모델로서 클러스터링은 은닉층 활성화함수의 파라미터를 결정하는 역할을 한다. k-평균 군집 클러스터링의 경우 클러스터의 중심점을 활성화함수의 중심점으로 사용하였으며 각 클러스터의 중심점과 입력변수사이의 표준편차를 활성화함수의 분포상수로 사용하였다. FCM 클러스터링은 중심점 및 분포상수를 구하지 않고 직접적으로 은닉층 자체를 클러스터링으로 대체한다. 은닉층의 활성화함수를 정의하고 파라미터를 결정하는 과정을 생략하고 클러스터링을 사용하여 각 클러스터의 중심점과 입력변수간의 멤버십(소속) 값을 그대로 은닉층 출력으로 사용한다. 멤버십(소속) 값이 0 또는 1로 표현되는 k-평균 클러스터링은 적용이 쉽지 않은 반면 0과 1사이의 퍼지 수로 멤버십(소속) 값을 표현하는 FCM 클러스터링을 주로 사용한다.

퍼지추론 시스템의 후반부 다항식 및 방사형 기저 함수 신경회로망의 연결가중치는 상수항, 1차선형식, 2차식 등 입력을 포함한 다양한 형태의 다항식으로 구성된다. 다항식의 계수 추정은 일반적으로 표준 최소자승법을 사용한다.

표준 최소자승법은 방정식의 수가 미지수보다 클 때 근사식을 찾는 일반적인 방법으로 선형회귀에서 많이 사용되며 지능형 모델에서도 연결가중치 및 다항식의 파라미터 계수를 동시에 추정할 수 있는 전역 학습 방법으로 성능 측면에서도 우수하다. 하지만 데이터의 노이즈가 심하거나 구성하고자 하는 모델의 구조가

* 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 : July 18, 2016

복잡해질수록 성능저하 및 과적합이 발생한다. 또한 퍼지 규칙 모델의 경우 여러 개의 다항식 계수를 한꺼번에 추정하면 각 퍼지 규칙에 대한 특성 분석 및 해석에 어려움을 겪는다. 이와 같은 문제를 해결하기 위해 가중 최소자승법이 제안되었다. 가중 최소자승법은 다항식별로 독립적인 계수 추정을 할 수 있으며 표준 최소자승법보다 과적합 발생 가능성도 적다. 하지만 데이터 종류 및 특성에 따라 정확성이 상당히 떨어지기 때문에 표준 최소자승법의 단점을 극복했다고 보기 어렵다[16-17].

본 논문에서는 지역 최소자승법을 이용한 퍼지 클러스터링 기반 신경회로망 패턴 분류기를 제안하며 기존 방법들과 비교를 통해 제안된 학습 방법의 우수성을 보이고자 한다. 제안된 패턴 분류기는 신경 회로망의 구조로 표현되는 동시에 퍼지 규칙으로도 정의할 수 있다. 지역 최소자승법의 성능은 표준 최소자승법에 유사하지만 과적합 문제에 강인한 특성을 보이므로 가중 최소자승법과 같은 독립적 학습이 가능한 장점이 있다. 퍼지 클러스터링 기반 패턴 분류기에서 퍼지 규칙의 전반부 적합도는 fuzzy c-means(FCM) 클러스터링의 소속 값으로 정의하며 후반부 다항식 계수 추정은 지역 최소자승법을 사용한다.

본 논문의 구성은 다음과 같이 요약된다. 2장에서는 퍼지 클러스터링 기반 패턴 분류기의 구조 및 전반부와 후반부에 사용된 FCM 클러스터링 및 최소자승법, 가중 최소자승법, 그리고 제안된 지역 최소자승법의 학습방법에 대해 설명한다. 또한 제안된 퍼지 클러스터링 기반 패턴 분류기의 설계 과정 및 실험 방법에 대해 단계별로 설명하며 3장에서 각 학습 방법에 따른 패턴 분류율 및 정확성을 비교 분석하며 4장 결론으로 마무리한다.

2. 퍼지 클러스터링 기반 신경회로망 패턴 분류기의 구조 및 학습 방법

본 장에서는 퍼지 클러스터링 기반 신경회로망 패턴 분류기의 전반적인 구조 및 각 부분의 역할에 대해 자세히 설명하며 후반부 파라미터 계수 추정에 사용된 기존 학습방법 및 새롭게 제안하는 학습방법에 대해 설명한다.

2.1 퍼지 클러스터링 기반 신경회로망 패턴 분류기의 구조

퍼지 클러스터링 기반 신경회로망 패턴 분류기는 기존 방사형 기저 함수(radial basis function; RBF) 신경회로망과 같이 입력층 은닉층 출력층과 같이 세 부분으로 구성된다. 방사형 기저 함수와 구조적으로 가장 큰 차이는 은닉층에 있다. 퍼지 클러스터링 기반 신경회로망은 FCM 클러스터링의 중심점 및 소속 값(멤버쉽 값)이 은닉층을 구성한다. 따라서 입력층과 은닉층 사이의 연결가중치는 FCM 클러스터링의 중심값과 동일하며 은닉층의 출력은 FCM 클러스터링의 소속 값이 된다. 추가적으로 은닉층과 출력층 사이의 연결가중치는 상수항 또는 다항식으로 구성된다. 퍼지 클러스터링 기반 신경회로망 패턴 분류기의 구조는 아래 그림 1과 같다.

퍼지 클러스터링 기반 신경회로망은 퍼지 규칙으로 네트워크

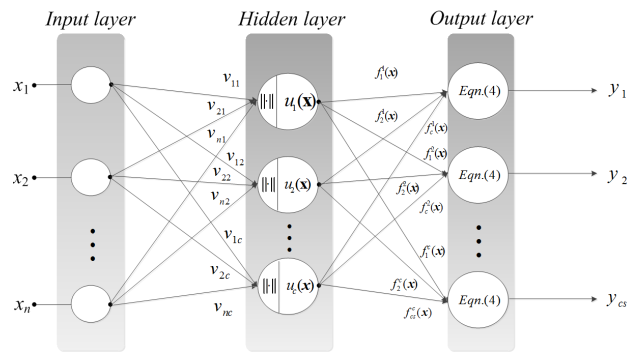


그림 1 퍼지 클러스터링 기반 신경회로망 패턴분류기의 구조
Fig. 1 Structure of fuzzy clustering-based neural network pattern classifier

구조를 표현할 수 있다. 식 (1)과 같이 입력층부터 은닉층까지를 퍼지 규칙의 전반부로 표현할 수 있으며 은닉층과 출력층사이의 연결가중치는 퍼지 규칙의 후반부로 정의할 수 있다. 또한 출력층은 퍼지 규칙의 추론부로 각 퍼지 규칙의 무게 중심법을 이용하여 최종 출력을 구하고 각 부류(class)의 출력 값을 비교하여 분류기의 최종 부류를 선택한다. 퍼지 규칙의 전반부에 해당하는 IF절은 FCM 클러스터링을 통해 형성되며 후반부의 THEN절은 상수항이외에 1차선형식 또는 2차식 및 변형된 2차식으로 표현할 수 있다.

$$R_j^i : \text{IF } x \text{ is } u_i \text{ with } v_i \text{ THEN } f_j^i(x) \quad (1)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\| \mathbf{x}_k - \mathbf{v}_i \|}{\| \mathbf{x}_k - \mathbf{v}_j \|} \right)^{2/(m-1)}} \quad (2)$$

$$f_j^i(x_1, \dots, x_n) = a_{i0}^j + \sum_{p=1}^n a_{ip}^j x_p \quad (3)$$

여기서, R_j^i ($i=1, \dots, c; j=1, \dots, cs$)는 퍼지 규칙을 나타내며 u_i 와 v_i 는 FCM 클러스터링의 소속 값 및 중심 값을 각각 의미한다. 후반부 다항식 $f_j^i(x)$ 는 1차선형식을 사용하였으며 a_{ip}^j ($p=0, \dots, n$)는 파라미터 계수를 의미한다.

후반부 다항식의 파라미터 계수 추정은 일반적으로 최소자승법 (least squares estimator; LSE)을 사용하여 제곱오차합(sum of squares error)이 최소가 되도록 학습한다. 또한 최소자승법으로 파라미터 학습 시 과적합(over-fitting)이 발생할 경우 가중 최소자승법(weighted least squares estimator; WLSE)을 통해 파라미터 계수를 추정할 수도 있다. 본 연구에서는 지역 최소자승법을 제안하며 기존 방법과 다른 변형된 비용함수(cost function)를 사용하여 계수를 추정한다.

퍼지 규칙이 정의되면 각 퍼지 규칙을 통해 분류기의 최종 출력을 구한다. 이 때 분류기의 출력은 데이터의 부류 수만큼 생성되고 각 부류에 해당하는 분류기 출력 중 가장 큰 값을 갖는 출력

이 분류기의 최종 출력이 된다.

$$\hat{y}_j = \frac{\sum_{i=1}^c u_i f_i^j(\mathbf{x})}{\sum_{i=1}^c u_i} \quad (4)$$

$$\hat{y}_i > \hat{y}_j, \quad i \neq j (i, j = 1, \dots, cs) \quad (5)$$

여기서, c 는 클러스터의 수를 의미하고 cs 는 클래스의 수를 나타낸다.

2.2 퍼지 클러스터링기반 신경회로망 패턴 분류기의 학습 방법

퍼지 클러스터링기반 패턴 분류기는 전반부 퍼지 규칙 생성하기 위해 클러스터링을 사용하였으며 그 중에서도 퍼지이론을 이용한 적합도 생성을 위해 FCM 클러스터링을 사용하였다. 또한 후반부의 1차 선형식의 파라미터 계수는 새롭게 제안된 지역 최소자승법(local least squares estimator; LLSE)을 통해 추정된다. 지역 최소자승법은 각 퍼지 규칙의 파라미터 계수를 독립적으로 구하여 각 퍼지 규칙을 부분 출력과의 오차를 최소화 하였다.

2.2.1. Fuzzy C-Means 클러스터링

퍼지 클러스터링은 소프트 클러스터링이라 불리며 이는 하드 클러스터링과 구분된다. 일반적으로 하드 클러스터링과 소프트 클러스터링의 큰 차이점은 데이터와 클러스터간의 소속개념에 있다. 하드 클러스터링의 경우, 각 데이터가 정확하게 하나의 클러스터에 속하며 이 때 가중치는 1이 되며 나머지 속하지 않은 클러스터에 대한 가중치는 0이 된다. 소프트 클러스터링의 경우, 각 데이터는 특정한 클러스터에만 속하지 않고 각 클러스터의 중심점을 기준으로 데이터가 클러스터에 얼마만큼 소속되어 있는지를 가중치로서 표현하고 이 때 가중치의 총 합은 1이 된다.

FCM 클러스터링 알고리즘은 퍼지 클러스터링 방법 중 하나로 1981년 Bezdek 교수에 의해 소개되었다. FCM 클러스터링의 목적함수는 식 (6)과 같다.

$$J(u_{ik}, \mathbf{v}_i) = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m \|\mathbf{x}_k - \mathbf{v}_i\|^2 \quad (6)$$

여기서, c 는 클러스터의 수를 의미하고 N 은 데이터(패턴)의 수를 나타낸다.

목적함수를 최소화하는 중심점 \mathbf{v}_i 와 소속 값 u_{ik} 는 반복 학습을 통해 최적의 값을 찾으며 학습 방법은 다음과 같다.

[단계 1] 클러스터의 개수 $c(2 \leq c \leq N)$ 을 정하고 퍼지화 계수 $m(1 < m < \infty)$ 을 선택한다. 초기 소속행렬 $U^{(0)}$ 을 초기화 하고 반복 횟수를 $r(r=0, 1, \dots)$ 로 표시한다.

$$U^{(r)} = \left\{ u_{ik} \in [0, 1], \sum_{i=1}^c u_{ik} = 1 \forall k, 0 < \sum_{k=1}^N u_{ik} < n \forall i \right\} \quad (7)$$

[단계 2] 식 (8)~(9)를 이용하여 FCM 클러스터 중심점 $\mathbf{v}_i^{(r)} = \{\mathbf{v}_{i1}^{(r)}, \dots, \mathbf{v}_{in}^{(r)}\}$ 및 소속 값 u_{ik} 를 계산한다.

$$\mathbf{v}_{ij}^{(r)} = \frac{\sum_{k=1}^N u_{ik}^m x_{kj}}{\sum_{k=1}^N u_{ik}^m} \quad (8)$$

여기서, u_{ik} 는 0과 1 사이의 소속을 나타내는 정도의 값으로 i 번째 클러스터에 속해져 있는 \mathbf{x}_k 의 k 번째 데이터의 소속정도를 나타낸다. \mathbf{v}_i 는 i 번째 클러스터 중심 벡터이다.

[단계 3] 다음과 같이 새로운 소속행렬 $U^{(r+1)}$ 을 계산한다.

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{2/(m-1)}}, \quad (d_{ik} = \|\mathbf{x}_k - \mathbf{v}_i\|) \quad (9)$$

여기서 $\|\cdot\|$ 은 입력변수와 각 클러스터의 중심점간의 유클리드 거리를 의미한다.

[단계 4] 다음 식 (10)을 계산해서 만일 $\Delta > \epsilon$ 이면 $r=r+1$ 로 정하고 [단계 2]로 가서 다시 알고리즘을 반복 수행하고 그렇지 않고 $\Delta \leq \epsilon$ 이면 알고리즘을 종료한다. 여기서, ϵ 는 임계값이다.

$$\Delta = \|U^{(r+1)} - U^{(r)}\| = \max_{i,k} |u_{ik}^{(r+1)} - u_{ik}^{(r)}| \quad (10)$$

2.2.2. 지역 최소 자승법

후반부 다항식의 계수를 추정하기 위해 일반적으로 표준 최소 자승법(least squares estimator; LSE)을 사용한다. 최소 자승법은 오차 제곱의 합이 최소가 되도록 계수를 추정하는 방식으로 식 (11) 같다.

$$Q = \sum_{j=1}^{cs} \sum_{k=1}^N (t_{jk} - \sum_{i=1}^c u_{ik} f_i^j(\mathbf{x}_k))^2 \quad (11)$$

여기서, $t_{jk}(j=1, \dots, cs; k=1, \dots, N)$ 는 부류 출력을 의미하며 u_{ik} 는 퍼지 규칙의 전반부 적합도 및 $f_j^i(\mathbf{x}_k)$ 는 후반부 다항식을 각각 나타낸다. 기존 최소자승법은 모든 퍼지 규칙의 후반부 다항식 계수를 동시에 추정한다. 따라서 각 퍼지 규칙의 출력보다는 전체 퍼지 규칙의 선형결합을 통한 모델 출력과 실제 출력 오차를 최소화한다. 후반부 다항식 계수 $a'_{ip}(p=0, \dots, n)$ 를 추정하기 위한 행렬식은 식 (12)와 같다.

$$A_j = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{T}_j \quad (12)$$

$$\mathbf{X} = \begin{bmatrix} u_{11} & \cdots & u_{1c} & u_{11}x_{11} & \cdots & u_{1c}x_{11} & \cdots & u_{11}x_{1n} & \cdots & u_{1c}x_{1n} \\ u_{21} & \cdots & u_{2c} & u_{21}x_{21} & \cdots & u_{2c}x_{21} & \cdots & u_{21}x_{2n} & \cdots & u_{2c}x_{2n} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ u_{N1} & \cdots & u_{Nc} & u_{N1}x_{N1} & \cdots & u_{Nc}x_{N1} & \cdots & u_{N1}x_{Nn} & \cdots & u_{Nc}x_{Nn} \end{bmatrix}$$

$$\mathbf{T}_j = \begin{bmatrix} t_{j1} \\ t_{j2} \\ \vdots \\ t_{jN} \end{bmatrix}, \mathbf{A}_j = [a_{10}^j, \dots, a_{c0}^j, a_{11}^j, \dots, a_{c1}^j, \dots, a_{1n}^j, \dots, a_{cn}^j]^T.$$

여기서, \mathbf{X} 행렬에서 입력변수와 전반부 적합도의 곱이 행렬 원소가 되며 열의 길이는 $(n+1) \times c$ 가 되며 행의 길이는 데이터의 수 N 이 된다. \mathbf{T}_j 는 데이터의 실제 출력을 1과 또는 -1로 변환한 행렬로 다음과 같이 정의된다.

$$t_{jk} = \begin{cases} +1 & \text{If } y_k = j \\ -1 & \text{otherwise} \end{cases} \quad (13)$$

가중 최소 자승법(weighted least squares estimator: WLSE)은 표준 최소자승법에 가중치 w 를 곱한 형태이다. 선형 회귀에서는 일반적으로 가중치의 값을 $0 < w \leq 1$ 사이의 값을 랜덤하게 갖는다. 하지만 퍼지 모델에서는 가중치의 값을 퍼지 적합도로 대체하며 식 (14)과 같이 정의한다.

$$Q = \sum_{j=1}^{cs} \sum_{i=1}^c \sum_{k=1}^N u_{ik} (t_{jk} - f_i^j(\mathbf{x}_k))^2 \quad (14)$$

여기서, u_{ik} 가 가중치 w 의 역할을 하며 표준 최소자승법과 다르게 각 퍼지 규칙의 후반부 다항식과 부류 출력의 오차가 제곱이 최소가 되도록 파라미터 계수를 추정한다. 또한 전체 퍼지 규칙이 아닌 각 퍼지 규칙의 다항식 계수를 구하기 때문에 퍼지 규칙 수만큼의 가중 최소자승법을 수행하여야 모델의 총 파라미터 계수를 추정할 수 있다. 미분을 통해 i 번째 퍼지 규칙에 대한 후반부 다항식의 계수 추정을 위한 행렬식은 식 (14)와 같다.

$$\mathbf{A}_i^j = (\mathbf{X}^T \mathbf{U}_i \mathbf{X})^{-1} \mathbf{X}^T \mathbf{U}_i \mathbf{T}_j \quad (15)$$

$$\mathbf{X} = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1n} \\ 1 & x_{21} & \cdots & x_{2n} \\ \vdots & \vdots & \cdots & \vdots \\ 1 & x_{N1} & \cdots & x_{Nn} \end{bmatrix} \mathbf{U}_i = \begin{bmatrix} u_{i1} & 0 & \cdots & 0 \\ 0 & u_{i2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & u_{iN} \end{bmatrix} \mathbf{T}_j = \begin{bmatrix} t_{j1} \\ t_{j2} \\ \vdots \\ t_{jN} \end{bmatrix}$$

$$\mathbf{A}_i^j = \begin{bmatrix} a_{i0}^j \\ a_{i1}^j \\ \vdots \\ a_{in}^j \end{bmatrix}$$

여기서, \mathbf{A}_i^j 는 추정하고자 하는 i 번째 퍼지 규칙의 다항식의 계수를 의미하며 \mathbf{T}_j 는 데이터의 실제 출력을 1과 또는 -1로 변환된 행렬, \mathbf{U}_i 는 i 번째 입력공간에 대한 입력 데이터들의 소속 값을 의미한다. 행렬 \mathbf{X} 는 표준 최소자승법과 다르게 입력변수로 구성된다.

제한된 지역 최소자승법(local least squares estimator: LLSE)은 최소자승법과 가중 최소자승법의 특징을 결합하여 퍼지 규칙의 파라미터 학습에 더욱 유용한 형태로 식 (16)과 같다.

$$Q = \sum_{j=1}^{cs} \sum_{i=1}^c \sum_{k=1}^N (g_{ik}^j - u_{ik} f_i^j(\mathbf{x}_k))^2 \quad (16)$$

여기서, N 은 데이터 수를 의미하며 c 는 클러스터의 수를 의미하고 cs 는 클래스의 수를 나타낸다.

$$t_{jk} = \sum_{i=1}^c g_{ik}^j = \sum_{i=1}^c u_{ik} t_{jk} \quad (17)$$

표준 최소자승법은 전체 퍼지 규칙에 대한 후반부 다항식의 파라미터 계수를 동시에 추정하기 때문에 각 퍼지 규칙의 역할에 대한 해석력이 떨어진다. 또한 가중 최소자승법의 경우 식 (14)와 같이 실제 출력과 후반부 다항식만을 고려하여 오차를 최소화하기 때문에 각 퍼지 규칙의 후반부 파라미터 계수를 독립적으로 추정할 수는 있지만 각 퍼지 규칙의 해석력보다는 후반부 THEN 절을 해석하는데 집중된다. 제한된 지역 최소자승법은 각 퍼지 규칙의 출력이 실제 출력에 전반부 적합도를 고려한 부분 출력을 기준으로 학습을 수행한다. 식 (7)과 같이 FCM의 특성상 전반부의 적합도의 합은 항상 1을 만족하므로 실제 출력에 전반부 적합도를 곱한 부분 출력들의 합은 항상 실제 출력과 같다. 결과적으로 각 퍼지 규칙은 실제 출력의 부분 출력과 오차를 최소화하여 각 퍼지 규칙의 후반부 다항식 계수를 독립적으로 추정하였으며 각 퍼지 규칙의 해석력을 향상시켰다.

미분을 통해 i 번째 퍼지 규칙에 대한 후반부 다항식의 계수 추정을 위한 행렬식은 식 (18)과 같다.

$$\mathbf{A}_i^j = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{U}_i \mathbf{T}_j \quad (18)$$

$$\mathbf{X} = \begin{bmatrix} u_{11} & \cdots & u_{1c} & u_{11}x_{11} & \cdots & u_{1c}x_{11} & \cdots & u_{11}x_{1n} & \cdots & u_{1c}x_{1n} \\ u_{21} & \cdots & u_{2c} & u_{21}x_{21} & \cdots & u_{2c}x_{21} & \cdots & u_{21}x_{2n} & \cdots & u_{2c}x_{2n} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ u_{N1} & \cdots & u_{Nc} & u_{N1}x_{N1} & \cdots & u_{Nc}x_{N1} & \cdots & u_{N1}x_{Nn} & \cdots & u_{Nc}x_{Nn} \end{bmatrix}$$

$$\mathbf{U}_i = \begin{bmatrix} u_{i1} & 0 & \cdots & 0 \\ 0 & u_{i2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & u_{iN} \end{bmatrix}, \mathbf{T}_j = \begin{bmatrix} t_{j1} \\ t_{j2} \\ \vdots \\ t_{jN} \end{bmatrix}, \mathbf{A}_i^j = \begin{bmatrix} a_{i0}^j \\ a_{i1}^j \\ \vdots \\ a_{in}^j \end{bmatrix}.$$

여기서, \mathbf{A}_i^j 는 추정하고자 하는 i 번째 퍼지 규칙의 다항식의 계수를 의미하며 \mathbf{T}_j 는 1과 -1로 변환된 출력데이터, \mathbf{U}_i 는 i 번째 입력공간에 대한 입력 데이터들의 소속 값을 의미한다. 행렬 \mathbf{X} 는 표준 최소자승법과 동일한 행렬로 구성된다.

2.3 퍼지 클러스터링기반 신경회로망 패턴 분류기의 설계 과정

본 연구에서 퍼지 클러스터링기반 신경회로망 패턴분류기는 후반부 다항식 계수 추정 방법을 세 가지로 구분하여 구조를 설계하

였으며 3장 실험결과에서 학습방법의 차이에 따른 패턴 분류율 및 정확성을 비교하였다. 퍼지 클러스터링기반 신경회로망 패턴 분류기의 설계 과정은 다음과 같다.

[단계 1] 주어진 데이터를 학습 데이터와 실험 데이터로 분할한다.

패턴 분류기를 설계하기 위해 주어진 데이터를 학습 데이터와 실험 데이터로 나눈다. 학습 데이터는 분류기의 전반적인 구조 및 파라미터를 추정하는데 사용되며 실험 데이터는 학습 데이터로 완성된 분류기의 일반화 능력을 평가하기 위해 사용된다. 본 연구에서는 5-폴드 교차 검증(5-fold cross validation; 5-fcv)을 사용하여 학습 데이터와 실험 데이터를 구성하여 성능을 평가하였다.

5-fcv	Data				
1st of 5-fcv	Training data	Training data	Training data	Training data	Testing data
2nd of 5-fcv	Training data	Training data	Training data	Testing data	Training data
3rd of 5-fcv	Training data	Training data	Testing data	Training data	Training data
4th of 5-fcv	Training data	Testing data	Training data	Training data	Training data
5th of 5-fcv	Testing data	Training data	Training data	Training data	Training data

그림 2 5-폴드 교차 검증을 통한 학습 및 실험 데이터

Fig. 2 Training and Testing data sets using 5-fold cross validation

[단계 2] FCM 클러스터링을 통해 연결가중치를 학습하고 은닉층의 출력 값을 결정한다.

(2-1) FCM 클러스터링의 클러스터 수를 설정

FCM 클러스터링의 클러스터 수는 은닉층 노드의 수와 동일하다. 일반적으로 클러스터 수는 데이터 특성 및 모델의 복잡도와 성능 등을 고려하여 선택한다. 본 실험에서는 데이터의 종류와 관계없이 2~5개 사이의 클러스터 수를 설정하였으며 퍼지화 계수는 $m=2$ 로 설정하였다.

(2-2) 입력층과 은닉층 사이의 연결가중치 v_{pi} 를 초기화 및 학습식 (19)과 같이 v_{pi} 를 초기화한다. FCM 클러스터링의 단계 2~5 학습과정을 반복하여 얻어진 v_{ip} 가 최종 연결가중치가 되며 그 때의 소속행렬 U 의 원소들이 소속 값(멤버십 값) 또는 은닉층의 최종 출력 값이 된다.

$$v_{pi} = [0,1] \times \{max(x_p) + min(x_p)\} + min(x_p) \quad (19)$$

[단계 3] 은닉층과 출력층사이의 연결가중치를 학습한다.

(3-1) 연결가중치 또는 후반부 다항식의 형태를 결정

후반부 다항식의 형태는 상수항, 1차선형, 2차식, 변형된 2차식 등이 있으며 본 연구에서는 1차선형식을 사용하였다. 상수항의 경

우 정확성 및 패턴 분류율이 나머지 다항식에 비해 현저히 떨어지며 2차식 및 변형된 2차식의 경우 앞선 상수항 및 1차선형식보다 과적합 발생확률이 매우 높다.

(3-2) 다양한 학습 방법을 이용하여 후반부 다항식의 파라미터 계수 추정

본 실험에서는 총 세 개의 서로 다른 학습 방법을 사용하여 파라미터 계수를 추정한다. 첫 번째 분류기(Classifier 1)는 표준 최소자승법을 이용하였으며 두 번째 분류기(Classifier 2)는 가중 최소자승법을 사용하였다. 마지막으로 세 번째 분류기(Classifier 3)는 제안된 지역 최소자승법을 적용하였다. 각기 다른 학습방법을 사용하여 패턴 분류율 및 평균제곱오차를 구하고 비교 및 분석을 통해 제안된 지역 최소자승법의 장점을 확인하였다.

[단계 4] 분류기 출력과 실제 부류를 비교하여 패턴 분류율 및 평균제곱오차 값을 계산한다.

[단계 2] ~ [단계 3]을 통해 분류기 설계가 완성되면 분류기의 성능평가를 위해 식 (20)~(21)을 통해 패턴 분류기의 패턴 분류율 및 평균 제곱 오차를 평가한다. 식 (20)은 실제 부류와 분류기에서 예측한 부류의 성공률 나타내며 식 (21)은 모델링 분야에서 많이 사용하는 평균제곱오차(mean squared error; MSE)를 이용하여 각 부류의 출력 값과 실제 부류의 출력 값의 차이를 비교한다.

$$PCR = \frac{1}{N} \sum_{k=1}^N I(y_k = \hat{y}_k), \quad I = \begin{cases} 1 & \text{If } y_k = \hat{y}_k \\ 0 & \text{otherwise} \end{cases} \quad (20)$$

$$MSE = \frac{1}{N} \frac{1}{cs} \sum_{k=1}^N \sum_{j=1}^{cs} (t_{jk} - \hat{t}_{jk})^2 \quad (21)$$

여기서, N 은 데이터 수를 의미하며 cs 는 클래스의 수를 나타낸다.

표 1 실험을 위해 사용된 데이터 종류

Table 1 Types of data sets used for experiment

Data	No. of inputs	No. of classes	No. of data
Balance	4	3	625
banknote	4	2	1372
BTSC	4	2	748
German	24	2	1000
Glass	9	6	214
Heart	13	2	270
Iris	4	3	150
Leaf	14	30	340
Liver	6	2	345
Pima	8	2	768
Seeds	7	3	210
Vehicle	18	4	846
WDBC	30	2	569
Wine	13	3	178

표 2 학습 방법 종류별 패턴 분류율 비교

Table 2 Comparison of pattern classification rate according to the types of learning methods

(a) 표준 최소 자승법(Classifier 1)

Data	Training		Testing	
	Mean	STD	Mean	STD
Balance	90.00	0.41	89.78	2.12
banknote	99.38	0.18	99.27	0.57
BTSC	79.45	0.66	78.47	3.63
German	82.15	0.62	76.20	2.77
Glass	78.27	1.27	63.08	10.47
Heart	86.94	0.89	81.11	5.30
Iris	98.00	1.12	98.00	1.83
Leaf	88.82	1.18	76.12	4.47
Liver	74.20	0.60	72.46	2.51
Pima	78.22	0.74	76.17	2.51
Seeds	98.45	0.53	93.81	7.26
Vehicle	89.13	1.48	82.39	2.89
WDBC	96.71	0.3	96.3	1.18
Wine	99.86	0.31	97.78	2.32

(b) 가중 최소 자승법(Classifier 2)

Data	Training		Testing	
	Mean	STD	Mean	STD
Balance	88.48	1.02	86.25	2.76
banknote	98.10	0.18	98.10	0.70
BTSC	77.64	0.36	78.34	2.81
German	80.93	0.98	77.20	1.60
Glass	72.08	1.64	61.23	9.02
Heart	86.67	1.06	83.70	2.75
Iris	97.00	1.12	97.33	4.35
Leaf	82.49	1.45	75.00	4.27
Liver	74.42	1.10	71.30	1.21
Pima	78.32	0.54	76.69	2.23
Seeds	97.38	1.00	96.19	4.94
Vehicle	85.87	0.71	81.68	3.01
WDBC	97.67	0.19	96.84	0.47
Wine	100.00	0.00	98.33	1.52

(c) 지역 최소 자승법(Classifier 3)

Data	Training		Testing	
	Mean	STD	Mean	STD
Balance	88.64	1.15	86.73	3.31
banknote	99.27	0.11	99.27	0.45
BTSC	79.21	0.64	78.47	3.17
German	82.20	0.79	76.60	2.07
Glass	72.78	2.50	63.09	7.74
Heart	87.13	1.80	83.33	2.93
Iris	98.17	0.70	98.67	2.98
Leaf	83.74	1.15	75.42	2.37
Liver	75.58	1.80	73.33	4.30
Pima	78.91	0.73	76.82	3.28
Seeds	97.26	1.23	95.71	5.93
Vehicle	86.79	0.59	82.63	2.27
WDBC	97.80	0.16	96.67	0.69
Wine	100.00	0.00	98.33	1.52

표 3 학습 방법 종류별 평균 제곱 오차 비교

Table 3 Comparison of mean squared error rate according to the types of learning methods

(a) 표준 최소 자승법(Classifier 1)


Data	Training		Testing	
	Mean	STD	Mean	STD
Balance	0.3039	0.0158	0.3359	0.0330
banknote	0.0723	0.0033	0.0753	0.0153
BTSC	0.5949	0.0081	0.6815	0.0467
German	0.5389	0.0110	0.7284	0.0408
Glass	0.2358	0.0100	0.4214	0.0821
Heart	0.4034	0.0150	0.5542	0.0788
Iris	0.0781	0.0097	0.0992	0.0430
Leaf	0.0538	0.0028	0.0843	0.0136
Liver	0.7166	0.0150	0.7868	0.0333
Pima	0.6162	0.0105	0.6559	0.0482
Seeds	0.0688	0.0149	0.1623	0.1485
Vehicle	0.2259	0.0064	0.3170	0.0286
WDBC	0.1283	0.0048	0.1747	0.0264
Wine	0.0703	0.0099	0.1557	0.0518

(b) 가중 최소 자승법(Classifier 2)


Data	Training		Testing	
	Mean	STD	Mean	STD
Balance	0.3400	0.0102	0.3538	0.0422
banknote	0.0975	0.0049	0.0995	0.0228
BTSC	0.6123	0.0085	0.6727	0.0553
German	0.5838	0.0068	0.6632	0.0318
Glass	0.2812	0.0104	0.4024	0.1092
Heart	0.4101	0.0164	0.5184	0.0804
Iris	0.1342	0.0093	0.1464	0.0405
Leaf	0.0750	0.0014	0.0833	0.0035
Liver	0.7574	0.0082	0.8188	0.0222
Pima	0.6212	0.0097	0.6476	0.0423
Seeds	0.1441	0.0168	0.1724	0.0792
Vehicle	0.2649	0.0044	0.3053	0.0208
WDBC	0.1245	0.0034	0.1813	0.0350
Wine	0.0862	0.0091	0.1545	0.0430

(c) 지역 최소 자승법(Classifier 3)


Data	Training		Testing	
	Mean	STD	Mean	STD
Balance	0.3381	0.0109	0.3528	0.0418
banknote	0.0849	0.0044	0.0870	0.0204
BTSC	0.5980	0.0080	0.6734	0.0505
German	0.5465	0.0094	0.7058	0.0721
Glass	0.2760	0.0139	0.3850	0.1100
Heart	0.4051	0.0182	0.5273	0.0945
Iris	0.0959	0.0105	0.1044	0.0452
Leaf	0.0698	0.0022	0.0800	0.0036
Liver	0.7145	0.0142	0.8020	0.0557
Pima	0.6066	0.0115	0.6696	0.0555
Seeds	0.1330	0.0168	0.1629	0.0833
Vehicle	0.2543	0.0039	0.2991	0.0212
WDBC	0.1110	0.0035	0.1844	0.0300
Wine	0.0766	0.0099	0.1379	0.0372




(a-1) 1st rule of 1st class



(a-2) 2nd rule of 1st class




(b-5) 1st rule of 3rd class




(b-6) 2nd rule of 3rd class


(b) 가중 최소자승법을 이용한 퍼지 규칙별 출력 비교




(a-3) 1st rule of 2nd class




(a-4) 2nd rule of 2nd class




(c-1) 1st rule of 1st class



(c-2) 2nd rule of 1st class




(a-5) 1st rule of 3rd class




(a-6) 2nd rule of 3rd class


(a) 표준 최소자승법을 이용한 퍼지 규칙별 출력 비교




(c-3) 1st rule of 2nd class




(c-4) 2nd rule of 2nd class




(b-1) 1st rule of 1st class



(b-2) 2nd rule of 1st class




(c-5) 1st rule of 3rd class




(c-6) 2nd rule of 3rd class

(c) 지역 최소자승법을 이용한 퍼지 규칙별 출력 비교



(b-3) 1st rule of 2nd class



(b-4) 2nd rule of 2nd class

그림 3 Iris 데이터의 학습방법에 따른 퍼지 규칙의 출력 비교

Fig. 3 Comparison of the outputs of each fuzzy according to the types of learning methods for Iris data set

3. 실험 결과

본 실험에서는 제안된 지역 최소자승법의 성능평가 및 기존 학습방법과의 비교를 위해 패턴 인식분야에서 많이 사용되고 있는 머신 러닝 데이터를 사용하였으며 표 1에 정리하였다. 실험에 사용된 데이터는 총 14개로 입력변수는 4~30개, 클래스의 수는 2~30개로 구성되며 데이터의 수는 최소 150개부터 최대 1372개로 구성된다. 5-폴드 교차 검증을 통해 학습 및 실험 데이터의 패턴 분류율 및 평균 제곱 오차 값을 평균 및 표준 편차로 정리하였다.

FCM 클러스터링의 클러스터 수는 2~5개, 반복횟수는 300번 그리고 임계값 $\epsilon=0.001$ 로 설정하였으며 퍼지 규칙의 후반부 다항식은 1차선형식을 사용하였다.

표 2와 3은 각 학습 방법 중 데이터별로 가장 우수한 실험 데이터의 패턴 분류율 및 평균 제곱 오차 값을 정리하였다.

최소 자승법으로 이용한 분류기(Classifier 1)의 경우 학습 데이터의 패턴 분류율이 가장 최소자승법 및 제안된 지역 최소 자승법보다 전반적으로 우수하다. 하지만 실험 데이터의 패턴 분류율을 비교해보면 제안된 지역 최소 자승법으로 계수를 추정한 분류기가 Banknote, Blood Transfusion Service Center(BTSC), Glass, Iris, Live, Pima, Vehicle Wine 데이터 등 총 8 종류의 데이터에서 기존 학습 방법들과 비슷하거나 더 높은 분류율을 나타낸다. 그에 비해 가장 최소자승법을 이용한 분류기(Classifier 2)의 경우 전체적으로 학습 및 실험 데이터의 패턴 분류율이 다른 학습 방법들에 비해 낮다.

표 3의 평균 제곱 오차 값을 비교해보면 표준 최소 자승법으로 파라미터 계수를 추정할 때 가장 우수함을 알 수 있다. 하지만 평균 제곱 오차의 성능향상에 비례하여 패턴 분류율의 상승으로 이어지지 않는다. 제안된 지역 최소자승법은 학습 데이터의 제곱 오차 값 및 패턴 분류율은 표준 최소 자승법보다 낮지만 실험 데이터의 패턴 분류율에서 기존 학습방법들보다 우수함을 확인할 수 있다.

그림 4는 Iris 실험 데이터의 각 부류에서 퍼지 규칙의 출력과 실제 출력의 부분출력을 비교하여 나타내었다. 그림 4(c)의 제안된 지역 최소자승법을 이용하여 후반부 파라미터 계수를 학습한 퍼지 규칙이 기존 표준 최소자승법 및 가장 최소자승법과 비교하여 부분출력과 가장 유사함을 알 수 있다. 지역 최소자승법은 실제 출력의 부분 출력에 해당하는 식 (16)과 각 퍼지 규칙의 오차를 최소화하도록 학습을 수행한다. x 축은 실험 데이터를 의미하며 1~10번째는 데이터는 첫 번째 부류를 나타내며 11~20번째는 두 번째 부류 그리고 21~30번째는 세 번째 부류를 각각 나타낸다.

표 4는 기존 분류기의 분류율 및 지역 최소자승법을 이용한 퍼지 클러스터링기반 신경회로망 패턴 분류기의 패턴 분류율을 비교하였다. KNN은 K-nearest neighbor을 나타내며 TS-KNN은 기존 KNN에 Taboo search algorithm을 결합한 분류기를 의미한다. 또한 Preprocessing-based RBFNN은 방사형 기저 함수 신경회로망 입력층 앞에 전처리층이 삽입된 분류기로 PCA 또는 LDA를 사용하였으며 최적화를 통해 전처리 알고리즘이 선택되는 분류기이다.

표 4 기존 분류기 및 제안된 분류기의 패턴 분류율 비교
Table 4 Comparison of pattern classification rate with results obtained by other classifiers

Data	Classifiers			
	KNN[18]	TS-KNN [18]	Prep.-based RBFNN[15]	Proposed classifier
Balance	84.4	89.1	92.6	86.7
banknote	-	-	-	99.3
BTSC	-	-	-	78.5
German	-	-	-	76.6
Glass	72.0	80.4	68.8	63.1
Heart	52.2	62.6	80.7	83.3
Iris	94.6	96.7	98.7	98.7
Leaf	-	-	-	75.4
Liver	62.9	73.8	70.4	73.3
Pima	70.3	77.7	76.3	76.8
Seeds	-	-	-	95.7
Vehicle	68.4	73.7	80.8	82.6
WDBC	-	-	95.8	96.7
Wine	96.7	-	98.9	98.3

4. 결 론

본 논문에서는 지역 최소자승법을 이용한 퍼지 클러스터링기반 신경회로망 패턴 분류기를 제안하였다. 퍼지 클러스터링기반 신경회로망의 전반부는 FCM 클러스터링으로 구성되며 클러스터의 중심점과 입력변수의 거리의 정도를 나타내는 소속정도를 퍼지 규칙 전반부의 적합도로 사용하고 후반부 다항식의 파라미터 계수는 새롭게 제안된 지역 최소자승법을 사용하였다. 제안된 학습 방법은 각 퍼지 규칙의 독립적인 계수 추정이 가능하며 그로 인한 퍼지 규칙의 해석력 향상시켰다. 성능 측면에서도 기존 학습방법들과 비교 분석을 통해 제안된 지역 최소자승법의 분류기가 기존 방법들보다 패턴 분류율이 개선되었으며 실험을 통해 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] R. R. Salakhutdinov and G. E. Hinton, "A better way to pretrain deep Boltzmann machines", *Advances in Neural Information Processing 25*, MIT Press, Cambridge, MA, pp. 1-9 2012.
- [2] Y. LeCun, Y. Bengio, and G. E. Hinton, "Deep learning", *Nature*, Vol. 521, pp. 436-444, 2015.
- [3] D. Broomhead, and D. Lowe, "Multivariable functional interpolation and adaptive networks", *Complex Systems*, Vol. 2, pp. 321-355, 1988.
- [4] F. Schwenker, H. A. Kestler, and G. Palm, "Three learning phases for radial-basis-function networks", *Neural Networks*, Vol. 14, pp. 439-458, 2001.
- [5] S.-K. Oh, W.-D. Kim, W. Pedrycz, and S.-C. Joo, "Design of K-means Clustering-based Polynomial Radial Basis Function Neural Networks(pRBF NNs) Realized with the Aid of Particle Swarm Optimization and Differential Evolution", *Neurocomputing*, Vol. 78, No. 1, pp. 121-132, 2012.
- [6] S.-K. Oh, W. Pedrycz, and H.-S. Park, "Multi-FNN Identification Based on HCM Clustering and Evolutionary Fuzzy Granulation", *Simulation Modelling Practice and Theory*, Vol. 11, No. 7-8, pp. 627-642, 2003.
- [7] S.-K. Oh, W. Pedrycz, and H.-S. Park, "Implicit rule-based Fuzzy-Neural Networks Using The Identification Algorithm of GA Hybrid Scheme Based on Information Granulation", *Advanced Engineering Informatics*, Vol. 16, No. 4. pp. 247-263, 2002.
- [8] S.-B. Roh, S.-K. Oh, and W. Pedrycz, "Design of Fuzzy Radial Basis Function-based Polynomial Neural Networks", *Fuzzy Sets and Systems*, Vol. 185, No. 1, pp. 15-37, 2011.
- [9] S.-K. Oh, W.-D. Kim, W. Pedrycz, and B.-J. Park, "Polynomial-based Radial Basis Function Neural Networks (P-RBFNNs) Realized with the Aid of Particle Swarm Optimization," *Fuzzy Sets and Systems*, vol. 163, No. 1, pp. 54-77, January 2011.
- [10] J.-S. R. Jang, C.-T. Sun, and E. Mizutani, *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*, Prentic-Hall, Inc, New Jersey, 1997.
- [11] S. P. Lloyd, "Least squares quantization in PCM," *IEEE Transactions on Information Theory*, Vol. 28, pp. 129-137, 1982.
- [12] J. C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.
- [13] J. C. Bezdek, and E. Robert, and F. William, "FCM: The Fuzzy C-Means Clustering Algorithm", *Computers & Geosciences* Vol. 10 No. 2-3, pp 191-203, 1984.
- [14] J.-N. Choi, S.-K. Oh, and W. Pedrycz, "Identification of Fuzzy Relation Models Using Hierarchical Fair Competition-based Parallel Genetic Algorithms and Information Granulation", *Applied Mathematical Modelling*, Vol. 33, No. 6, pp. 2791-2807, 2009.
- [15] S.-K. Oh, W.-D. Kim, and W. Pedrycz, "Design of Radial Basis Function Neural Network Classifier Realized with the Aid of Data Preprocessing Techniques: Design and Analysis", *International Journal of General Systems*, Vol. 45, No. 4, pp. 434-454, 2016.
- [16] S.-K. Oh, and W.-D. Kim, W. Pedrycz, and K.-S. 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.
- [17] S.-B. Roh, S.-K. Oh, and W. Pedrycz, "A Fuzzy Ensemble of Parallel Polynomial Neural Networks with Information Granules Formed by Fuzzy Clustering", *Knowledge-Based Systems*, Vol. 23, No. 3, pp. 121-132, 2012.
- [18] M. A. Tahir, A. Bouridane, and F. Kurugollu, "Simultaneous Feature Selection and Feature Weighting Using Hybrid Tabu Search/K-Nearest Neighbor Classifier," *Pattern Recognition Letters*, Vol. 28, No. 4, pp. 438-446, March 2007.

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, 신경 회로망, 클러스터링, 최적화 알고리즘, 컴퓨터 지능 및 지능 제어 등.
Tel : 031-222-6544
Fax : 031-220-2667
E-mail : wdKim@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, 퍼지 및 지능시스템학회 편집위원, 2013년~현재 Information Sciences 편집위원. 관심 분야는 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, 동대학원 석사(1985), 박사(1991), 1997~2010년 경기지역 산학연기술 지원단 단장, 1998~2000년 사업기술정책연구소 심의위원, 2000~2004년 사단법인 산학연 컨소시엄 전국협의회 회장. 1989~현재 수원대학교 전기

공학과 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