

## GMM과 클러스터링 기법에 의한 뉴로-폐지 시스템 모델링

### A Neuro-Fuzzy System Modeling using Gaussian Mixture Model and Clustering Method

김승석, 곽근창, 유정웅, 전명근

Sung-Suk Kim, Keun-Chang Kwak, Jeong-Woong Ryu, Myung-Geun Chun

충북대학교 전기전자공학부 컴퓨터 정보통신 연구소

Chungbuk National University School of Electrical and Electronic Engineering

#### 요약

본 논문에서는 여러 분야에서 널리 응용되고 있는 적응 뉴로-폐지 시스템(ANFIS)의 성능 개선에 있어서 전제부 파라미터를 효과적으로 초기화 시키는 방법을 제안한다. 기존의 그리드 분할을 이용한 입력공간 선택 방법은 ANFIS의 규칙 생성에 있어서 얻어진 규칙의 수가 지수적으로 증가하는 단점이 있다. 이에, 본 연구에서는 GMM에서의 최대우도추정을 이용한 EM 알고리즘을 통하여 초기치에 의하여 성능의 영향이 좌우되는 ANFIS의 입력으로 주어 제안된 클러스터링 기법에 의하여 모델의 성능을 개선하고자 한다. 제안된 방법의 클러스터링 방법은 통계적 방법에 근거하여 좋은 성능의 파라미터를 획득할 수 있어 주어진 모델에 대한 ANFIS의 성능을 개선할 수 있다. 이들 방법의 유용함을 전형적인 다변수 비선형 데이터인 자동차 연료 예측 문제와 정수장 응집제 주입 문제에 적용하여 제안된 방법이 이전의 연구보다 성능이 개선되는 것을 통하여 보였다.

#### Abstract

There have been a lot of considerations dealing with improving the performance of neuro-fuzzy system. The studies on the neuro-fuzzy modeling have largely been devoted to two approaches. First is to improve performance index of system. The other is to reduce the structure size. In spite of its satisfactory result, it should be noted that these are difficult to extend to high dimensional input or to increase the membership functions.

We propose a novel neuro-fuzzy system based on the efficient clustering method for initializing the parameters of the premise part. It is a very useful method that maintains a few number of rules and improves the performance. It combine the various algorithms to improve the performance. The Expectation-Maximization algorithm of Gaussian mixture model is an efficient estimation method for unknown parameter estimation of mixture model. The obtained parameters are used for fuzzy clustering method. The proposed method satisfies these two requirements using the Gaussian mixture model and neuro-fuzzy modeling. Experimental results indicate that the proposed method is capable of giving reliable performance.

**Key words :** Neuro-Fuzzy System, Gaussian Mixture Model, Adaptive Network-based Fuzzy Inference System, Maximum Likelihood Estimation

#### 1. 서 론

Zadeh 교수에 의하여 제안된 폐지 모델링 방법은 성능 개선을 위하여 다양한 이론들과 접목하고 있다. 그중 하나인 뉴로-폐지 시스템[1][2]의 경우 신경회로망의 역전파 알고리즘을 이용하여 반복적인 학습을 통하여 다양한 비선형 모델에 대하여 좋은 성능들을 보여왔다. 이러한 모델에 있어서 우수한 모델링 성능을 구현하기 위한 방법으로 전제부 소속 함수를 대상으로 하는 많은 연구들이 진행되고 있다. 규칙

베이스를 기반으로 하는 전제부의 경우 그리드 분할, 트리 분할, 스캐터 분할 등이 있는데, 그리드 분할[2]의 경우 소속 함수의 증가에 의한 규칙의 지수함수적인 증가[4]가 문제되어 왔다. 스캐터 분할에 의한 규칙생성으로는 데이터 자체의 수치적인 특성만을 이용하는 HCM (Hard Fuzzy C-Means), FCM (Fuzzy C-Means), Conditional Fuzzy C-Means (CFCM) [2][5] 등이 있다.

따라서, 본 논문에서는 모델의 규칙의 수를 적정하게 유지하면서도 모델의 성능을 높이기 위하여 통계적인 데이터 분류 방법중 하나인 Gaussian Mixture Model (GMM)에 대하여 Expectation Maximization (EM)[6][7] 알고리즘을 적용하여 폐지 클러스터링을 실시하고 이를 폐지 추론 시스템에 적용하여 모델의 성능을 개선하고자 한다. EM 알고리즘에 의하여 생성된 파라미터들은 기존의 HCM, FCM 등의 클러스터링 방법들과는 달리 그리드분할 등에서 생기는 규칙의

접수일자 : 2002년 9월 5일

완료일자 : 2002년 12월 8일

본 연구는 한국과학재단 목적기초연구(R01-2002-000-00315-0) 지원으로 수행되었음

지수함수적인 증가 문제를 해결 할 수 있으며 데이터의 통계적 성질[8-10]을 이용함으로써 기존의 클러스터링 방법들 보다 좋은 성능을 볼 수 있어 퍼지 추론 시스템의 성능을 개선 시킬 수 있다.

이렇게 제안된 방법을 자동차 연료 예측 문제[11][12]와 정수장 응집제 주입 문제[9]에 적용하여 이전에 연구된 방법들에 비하여 좋은 결과를 얻음을 보이고자 한다.

## 2. GMM 클러스터링과 뉴로-퍼지 시스템을 이용한 퍼지 모델링

### 2.1. GMM 클러스터링을 이용한 파라미터 추정

본 단원에서는 GMM에서 EM 알고리즘을 이용한 확률분포함수의 추정을 통하여 퍼지 추론 시스템에 사용되는 파라미터를 구하고자 한다. 신호처리에서 주로 다루어지고 있는 연구 중 하나가 확률분포함수의 파라미터 추정[7-9]은 잡음을 포함하고 있는 신호의 평균값 또는 분산 등의 추정이다. 이러한 파라미터를 추정하는데 있어서 정보의 일부가 손실되거나 불확실할 때 원하는 파라미터를 추정하는 것이 어렵다. 이때 주로 사용하는 방법이 은 어려운 문제로 남게 된다. GMM과 EM 알고리즘이다[ ]. 일반적인 가우시안 혼합모델 [13][14]에서 확률밀도함수는 다음 식에 의해 주어진다.

$$p(x|\theta) = \sum_{j=1}^c p(x|w_j, \theta)P(w_j) \quad (1)$$

여기서  $w_j$ 는 성분들이고,  $P(w_j)$ 는 그것들의 사전확률(prior probability) 혹은 혼합 파라미터들이다. 그리고  $p(x|w_j, \theta)$ 는 파라미터  $\theta$ 의 벡터가 알려졌을 때 성분의 확률 밀도이다. 샘플  $X = \{x_k\}$ 의 log 우도(likelihood)는 다음과 같다.

$$\begin{aligned} L(\theta | x) &= \sum_k \log p(x_k | \theta) \\ &= \sum_k \log \sum_j p(x_k | w_j, \theta) P(w_j) \end{aligned} \quad (2)$$

이 식은 직접적인 해를 가지지 못한다. 이러한 문제는 EM 알고리즘을 사용함으로서 해결할 수 있다. EM 알고리즘은 두 단계로 수행되는데, 간략히 그 과정을 살펴보면, 먼저 E-단계에서 사후확률 (posterior probability)을 다음과 같이 베이즈의 정리 (Bayes's Theorem)를 이용하여 계산한다.

$$P(w_j|x_k, \theta) = \frac{p(x_k|w_j, \theta)P(w_j)}{\sum_l p(x_k|w_l, \theta)P(w_l)} \equiv h_{kj} \quad (3)$$

만약 성분밀도가 d-차원 가우시안이 되도록 선택하면,  $p(x|w_j, \theta) \sim N_d(\mu_j, \Sigma_j)$ 은 다음과 같다.

$$p(x|w_j, \theta) = \frac{1}{(2\pi)^{d/2} |\Sigma_j|^{1/2}} \exp \left[ -\frac{1}{2} (x - \mu_j)^T \Sigma_j^{-1} (x - \mu_j) \right] \quad (4)$$

그러면 식(3)은 식(4)로 표현될 수 있으며 이는 가우시안 확률을 이용하는 식(5)로 표현되어질 수 있다.

$$h_{kj} = \frac{g_j |\Sigma_j|^{-1/2} \exp \left[ -\frac{1}{2} (x_k - \mu_j)^T \Sigma_j^{-1} (x_k - \mu_j) \right]}{\sum_l g_l |\Sigma_l|^{-1/2} \exp \left[ -\frac{1}{2} (x_k - \mu_l)^T \Sigma_l^{-1} (x_k - \mu_l) \right]} \quad (5)$$

단,  $g_j \equiv P(w_j)$

다음에 M-단계에서 성분 파라미터  $\theta$ 의 성분을 식(6)~(8)과 같이 갱신한다.

$$\mu_j^{t+1} = \frac{\sum_k h_{kj} x_k}{\sum_k h_{kj}} \quad (6)$$

$$\Sigma_j^{t+1} = \frac{\sum_k h_{kj} (x_k - \mu_j^{t+1}) (x_k - \mu_j^{t+1})^T}{\sum_k h_{kj}} \quad (7)$$

$$g_j^{t+1} = \frac{1}{n} \sum_k h_{kj} \quad (8)$$

여기서  $\mu_j$ ,  $\Sigma_j$ ,  $g_j$ 는 각각 EM 알고리즘에 의하여 갱신되는 가우시안 확률의 평균과 분산, 가중치로 표현할 수 있다. 또한 벡터 양자화를 위해 사용되어질 때, 평균  $\mu_j$ 은 기준 벡터(혹은 클러스터 중심)에 대응되고  $h_{kj}$ 는  $x_k$ 가 성분  $j$ 에 의해 발생되어지는 사후 확률이다.




그림 1. EM 알고리즘  
Fig 1. EM algorithm

이를 정리하면 그림 1과 같이 초기값을 선택한 후 Expectation 단계와 Maximization 단계를 파라미터의 값이 수렴할 때까지 반복 수행하면서 파라미터의 값을 ML함수가 최대화 될 때까지 추정하는 것을 알 수 있다. 이때 대부분의 반복 알고리즘과 마찬가지로 파라미터의 수렴성은 보장되지만 수렴이 전역적 최대값에 대한 보장은 할 수 없으며 단지 초기 시작점  $\theta^0$ 에 의존하는 지역적 최대값으로 수렴함으로 알려져 있다[15]

### 2.2. 뉴로-퍼지 시스템의 파라미터 동정

뉴로 퍼지시스템의 구조식별은 GMM에서의 EM 알고리

즘을 이용하여 추정할 수 있다. 이러한 ML 방법에 의한 클러스터의 패턴 분류는 주어진 데이터에 대하여 통계적 방법에 의하여 실시하므로 데이터의 특성을 잘 표현한다. 구조식별에서의 초기치 결정은 뉴로-퍼지 모델의 학습 속도와 수렴에 크게 영향을 준다.

구조식별과정이 끝나면 여기서 추정된 파라미터를 이용하여 Jang[2]의 방법과 같이 최소자승법(Least Square Estimate)과 역전파 알고리즘(Back Propagation)을 이용한 하이브리드 학습에 의해 이루어지게 된다. 여기서 ANFIS 모델은 언어적 입력 형태의 전제부와 1차 선형 방정식 형태의 결론부를 가지는 Takagi-Sugeno-Kang(TSK) 퍼지 모델이다. 아래와 같은 두 개의 TSK 형태의 퍼지 규칙을 갖는 추론시스템의 구성은 다음과 같다.

$$\begin{aligned} R^1 : \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1x + q_1y + r_1 \\ R^2 : \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f_2 = p_2x + q_2y + r_2 \end{aligned} \quad (9)$$

여기서  $x$ 와  $y$ 는 입력이고  $A_i, B_i$ 는 언어적 변수이며  $\{p_i, q_i, r_i\}$ 는 결론부 파라미터이다.

위와 같은 ANFIS에 대하여 학습절차는 다음과 같다. 먼저, 제안된 방법에서는 전제부 소속함수로 다음과 같은 가우시안 소속함수를 이용하였고 이 소속함수는 다음 식(10)과 같이 표현한다.

$$\mu_{A_i}(x) = \exp \left\{ - \left( \frac{x - c_i}{\sigma_i} \right)^2 \right\} \quad (10)$$

여기서  $\{\sigma_i, c_i\}$ 는 전제부 파라미터이며,  $\sigma_i$ 는 소속함수의 폭이고  $c_i$ 는 소속함수의 중심이다. 전제부 파라미터  $c_i$ 는 EM 알고리즘에 의하여 추정되며 이를 이용하여 소속함수의 폭  $\sigma_i$ 를 구한다. 여기서 전방향 추정은 최소자승법으로 구하며 역방향 추정은 역전파 알고리즘을 이용하여 학습을 한다.

정리하면, 전방향 경로에서는 최소자승법으로 후방향 경로에서는 역전파 알고리즘으로 전제부 및 결론부 파라미터를




그림 2. 제안된 알고리즘  
Fig. 2 Proposed algorithm

조정하여 실제 데이터 출력과 퍼지모델 출력사이의 오차를 최소화하는 것이다.

제안된 방법은 그림 2에서와 같이 EM 알고리즘에서 추정된 확률밀도함수의 중심값을 통하여 퍼지 소속함수의 폭을 추정한 후 이를 ANFIS의 초기 소속함수로 초기화하고 학습을 진행한다. EM 알고리즘에서 추정된 파라미터는 확률밀도 함수의 파라미터이므로 실제의 소속함수의 파라미터로의 직접적으로 적용이 어렵다. 따라서 추정된 중심값을 이용하여 퍼지 소속함수의 폭을 다음 식과 같이 구할 수 있다.

$$\sigma_i^2 = \frac{1}{n} \sum_{k=1}^n (x_k - c_i)^2 \quad (11)$$

ANFIS의 학습 성능은 초기 파라미터의 결정에 의하여 크게 달라질 수 있으므로 초기 파라미터의 값을 결정하는데 EM 알고리즘을 적용하였다.

### 3. 시뮬레이션 및 결과

본 논문에서 제안된 GMM과 클러스터링 기법을 이용한 ANFIS를 이용하여 자동차 연료 예측 문제[11]와 정수장 응집제 주입 문제[12]에 적용하여 이전에 연구된 방법들에 비하여 보다 나은 결과를 얻을 수 있음을 보이고자 한다.

#### 3.1. 자동차 연료 예측 문제

자동차 연료 예측 문제는 신경회로망이나 퍼지 시스템과 같이 지능 시스템을 이용하여 모델링을 할 수 있는 비선형 문제의 한 예라고 할 수 있다. 데이터의 구성은 다음과 같다. 입력으로는 실린더의 수, 배기량, 마력, 무게, 가속, 모델 연식이고 출력으로는 자동차 연비이다.

위와 같이 각각의 데이터 쌍은 6개의 입력과 1개의 출력을 가지면 총 392개의 데이터 쌍을 가진다. 이를 학습 데이터와 검증 데이터로 나누어 시뮬레이션 하였다. 이전의 연구들의 경우 다음과 같은 특징을 가질 수 있다. 먼저 그 리드 분할의 경우 각각의 소속함수의 수를 3개으로 하여도 규칙은  $3^6 = 729$ 로 증가하는 문제점을 가지고 있다. 즉 퍼지 추론 시스템의 크기가 커지는 문제를 가지고 있었다. 또한 Jang의 입력 선택 방법에 의한 입력수의 제한도 주어진 데이터를 효과적으로 이용할 수 없다는 문제를 가지고 있었다.

먼저 GMM 모델에 6개 입력 모두를 대상으로 각각의 파라미터를 추정한다. 각각의 파라미터는 중심과 분산, 가중치로 구성되어 있으며 이들 중 중심 값을 이용하여 ANFIS에서 사용되는 Gaussian 소속함수의 분산을 추정한다. 추정된 파라미터를 이용한 파라미터 동정은 Jang[2]의 방법과 같이 하이브리드 학습에 의해 추정된다.

그림 3과 4에서 볼 수 있듯이 실제 출력과 모델 출력이 근사하게 일치함을 볼 수 있다.

이를 정리하면 표1과 같이 제안된 알고리즘이 기존의 방법들 보다 우수한 성능을 보임을 알 수 있다. 즉 소속함수의 수 및 입력의 증가와는 무관하게 규칙의 수는 클러스터의 수와 일치하여 제안된 뉴로-퍼지 모델을 규칙의 지수함수적 증가에 대한 문제를 해결하였다.




그림 3. 학습 데이터와 모델 출력과의 비교  
Fig. 3 Training data and model output




그림 4. 검증데이터와 모델 출력과의 비교  
Fig. 4 Checking data and model output

표 1. RMSE와 규칙 수의 비교

Table 1. The comparison of RMSE and rule numbers  
(\* 신경회로망의 파라미터 수는 연결 가중치의 갯수)

	입력 수	규칙 수	파라미터 수	Trn_RMSE	Chk_RMSE
RBFN(Pedrycz) [11]	6	.		5.67	6.70
ANFIS(Jang) [2]	2	4	28	2.60	3.00
	2	9	54	2.46	2.99
제안된 방법	6	3	57	2.37	2.88

### 3.2. 정수장 응집제 주입 문제

본 연구에서 모델링하고자 하는 응집제 주입공정의 필드 데이터는 하루 1,320,000 톤의 정수처리 능력을 가지고 있는 서울시 암사 정수장에서 얻어진 데이터이다. 사용된 데이터는 암사 정수장에서 Jar 실험에서 합격된 약 346개 샘플 데이터를 사용하였다. 이를 토대로 기존의 연구들과 제안된 방법에 의한 퍼지시스템과 비교하고자 한다.

제안된 방법에서의 입력 변수로 원수의 탁도, 온도, PH, 알칼리도를 삼았다. 왜냐하면 응집과 침전 반응에 대한 다양

한 분석을 통해서 위의 변수들이 수질에 가장 많은 영향을 미치고 있으며 jar실험할 때에도 검사하는 수질 인자들이기 때문이다[12].

한편, ANFIS의 출력이 학습 데이터에 편중되지 않고 새로운 데이터에 대해서도 타당한 결과를 내는 모델인가를 평가하기 위해 데이터 집합을 학습 데이터와 검증 데이터로 나누었다. 이런 이유로 앞서 얻어진 346개의 중 173개 데이터는 모델 형성에 학습 데이터로 사용하였고 나머지 173개의 데이터는 모델 검증에 검증 데이터로 사용하였다.

TSK 퍼지모델을 이용한 퍼지 규칙의 형태는 다음과 같다.

$$R^i: \text{If } x_1 \text{ is } A_i \text{ and } x_2 \text{ is } B_i \text{ and } x_3 \text{ is } C_i \text{ and } x_4 \text{ is } D_i \text{ then } f_i = p_i x_1 + q_i x_2 + r_i x_3 + s_i x_4 + t_i$$

( $x_1$  : 원수의 탁도,  $x_2$  : 온도,  $x_3$  : PH,  $x_4$  : 알칼리도)

그림 5를 보면 클러스터의 수를 변화시키면서 제안된 모델의 성능을 평가한 결과 클러스터의 수가 11개일 때 학습데이터에 의한 오차가 1.513, 검증데이터에 대한 오차가 1.81로 성능이 가장 좋은 것을 알 수 있다. 또한 그림 6에서는 실제 출력과 모델의 출력을 비교하였으며 그림에서 볼 수 있듯이 제안된 방법에 의한 모델의 출력이 실제 출력과 근사하게 일치함을 볼 수 있다.




그림 5. 클러스터 수에 의한 성능 평가  
Fig. 5 Performance estimation by the number of clusters




그림 6. 실제데이터와 모델 출력과의 비교  
Fig. 6 Actual data and model output




그림 7. 모델의 성능 비교  
Fig. 7 Performance of the models

그림 7과 같이 본 논문에서 제안된 방법과 앞서 제시되었던 방법들과의 비교를 위하여 앞에 설명된 ANFIS와 다른 방법에 의해서 주어진 원수의 탁도에 대한 PAC주입률을 구했을 때의 RMSE를 각 탁도에 대하여 나타내었다. 그래프로부터 알 수 있듯이 본 논문에서 제안된 방법이 전체 탁도 구간에 걸쳐서 우수한 성능을 보이고 있음을 알 수 있다.

표 2는 지금까지의 결과로 학습데이터와 검증데이터의 RMSE 비교와 각 모델에 대한 규칙 수, 추정하고자 하는 파라미터 수를 비교한 결과이며 제안된 방법의 알고리즘이 학습데이터와 검증데이터의 오차와 규칙의 수가 다른 모델에 비해 모두 적음을 알 수 있다.

표 2. RMSE와 규칙 수의 비교  
Table 2. The comparison of RMSE and rule numbers  
(\* 신경회로망의 파라미터 수는 연결 가중치의 갯수)

	규칙 수	파라미터 수	Trn_RMSE	Chk_RMSE
선형회귀분석	.	5	3.12	3.60
신경회로망[12]	.	106	2.94	2.98
ANFIS(일차선형식)	81	441	0.67	7.95
ANFIS(상수)	81	117	1.66	1.97
제안된 방법	11	143	1.51	1.81

#### 4. 결 론

퍼지 추론 시스템을 구성하는 문제에 있어서 시스템의 크기 및 성능에 대한 다양한 연구들이 이루어져 왔다. 본 논문에서는 GMM 클러스터링에 의한 퍼지 추론 시스템의 규칙 생성과 초기 파라미터 추정을 통하여 모델의 성능을 개선하는 방법을 제안하였다. 제안된 방법은 그리드 분할 방법일 경우 입력공간이 증가함에 따라 퍼지 규칙의 수가 지수적으로 증가하는 문제와 다변수 입력에서 입력공간의 차원을 제한하는 문제점들을 GMM을 이용한 클러스터링을 이용하여 개선하였다. 또한 데이터의 통계적 성질을 이용함으로서 주어진 데이터를 좀 더 잘 모델링 할 수 있는 퍼지 추론 시스템을 구성할 수 있었다.

이때, 전제부 구조 동정은 ANFIS의 초기 파라미터 추정

문제를 EM 알고리즘을 통하여 주어진 데이터의 통계적 성질을 이용, 성능을 개선할 수 있었으며, 효율적인 퍼지규칙을 생성할 수 있었다. 시뮬레이션으로 정수장 응집제 주입 결정 모델링과 자동차 연료 예측 문제에 적용하여 이전의 연구방법에 비하여 좋은 성능을 보임을 알 수 있었다. 따라서, 제안된 방법은 다변수 입력을 가진 퍼지 추론 시스템의 성능을 만족하도록 하는 다양한 분야에 유용하게 적용될 수 있으리라 생각된다.

본 논문의 GMM에서, 초기치에 의한 국부적 최적화 수렴은 뉴로-퍼지 시스템 모델의 성능 개선에도 영향을 미치고 있다. 이는 모델의 오차가 특정치 이하로 감소할 수 없는 결정적인 원인이 된다. 또한 적절한 퍼지 규칙 선택에 대하여 정형화된 방법이 아닌 경험적 또는 시행착오법에 의존하고 있다. 이러한 문제점들에 대하여 해석적이면서 타당한 결과를 유도할 수 있는 연구가 뒤따라야 할 것이다.

#### 참 고 문 헌

- C. T. Lin, C. S. G. Lee, "Neural fuzzy Systems : A Neuro-Fuzzy Synergism to Intelligent Systems", *Prentice Hall*, 1996.
- J. S. R. Jang, C. T. Sun, E. Mizutani, "Neuro-Fuzzy and Soft Computing : A Computational Approach to Learning and Machine Intelligence", *Prentice Hall*, 1997.
- K. S. Leung, W. Lam, "Fuzzy Concepts in Expert Systems", *IEEE Trans. Computer*, Vol. 21, Issue. 9, pp. 43-56, 1988
- J. S. R. Jang, "ANFIS : Adaptive-Networks-based Fuzzy Inference System", *IEEE Trans. on System, Man, and Cybern.*, Vol. 23, No. 3, pp. 665-685, 1993.
- W. Pedrycz, "Conditional fuzzy c-means", *Pattern Recognition Letter*, Vol. 17, pp. 625-632, 1996.
- Todd K. Moon, "The Expectation-Maximization Algorithm", *IEEE Signal Processing*, Vol. 13, pp. 47-60, 1996.
- Richard O. Duda, Peter E. Hart, David G. Stork, "Pattern Classification", *John Wiley & Sons Inc*, 2001.
- Mario A. T. Figureiredo, Anil K. Jain, "Unsupervised Learning of Finite Mixture Models", *IEEE Trans. Pattern Analysis and Machine Intelligencer*, Vol. 24, No. 3, pp. 381-396, 2002
- Xiangyu Yang, Jun Liu, "Unsupervised Learning of Finite Mixture Models", *Pattern Recognition Letters*, Vol. 23, Issue 5, Pages 501-512, 2002
- Guorong Xuan, Wei Zhang, Peiqi Chai, "EM algorithm of Gaussian Mixture Model and Hidden Harkov Model", *Image Processing, Proceedings, International Conference on*, Vol. 1, pp. 145-148, 2001.
- W. Pedrycz, "Conditional fuzzy clustering in the design of radial basis function neural networks", *IEEE Trans. on Neural Networks*, Vol. 9, No. 4, pp. 601-612, 1998.

- [12] 한태환, 전명근, 유정웅 “정수장의 응집제 주입공정 자동화를 위한 신경회로망의 응용과 구현”, 대한전기학회논문지, Vol. 46, No. 9, pp. 1395-1401, 1997.
- [13] Ethem Alpayd, "Soft vector quantization and the EM algorithm", *Neural Networks*, Vol. 11, pp. 467-477, Issue 3, 1998.
- [14] Roy L. Streit, Tod E. Luginbuhl, " Maximum Likelihood training of Probabilistic Neural Networks", *IEEE Trans on Neural Networks*, Vol. 5, No. 5, pp. 764-782, 1994
- [15] Ross L. Finney, Maurice D. Weir, Frank R. Giordano, "Thomas' Calculus", Addison-Wesley Publishing Company, 2001.

## 저자 소개

### 김승식

1998. 2 충주대학교 전기공학과(공학사)  
2002. 2 충북대학교 전기공학과(공학석사)  
2002. 3-현재 충북대학교 전기공학과  
박사과정

주관심분야 : 퍼지시스템, 신경회로망,  
지능제어

E-mail : powerkim@vod.chungbuk.ac.kr



### 곽근창

1996. 2 충북대학교 전기공학과(공학사)  
1998. 2 충북대학교 전기공학과(공학석사)  
2002. 2 충북대학교 전기공학과(공학박사)  
2002. 3-현재 충북대학교 BK사업단  
박사후연구원



주관심분야 : 계산지능, 패턴분류, 생체인식  
E-mail : kkc@vod.chungbuk.ac.kr

### 유정웅

1965. 2 한양대학교 전기공학과(공학사)  
1976. 2 단국대학교 전자공학과(공학석사)  
1987. 2 단국대학교 전자공학과(공학박사)  
1979. 3-현재 충북대학교 전기공학과 교수



주관심분야 : 가변구조제어, 지능제어, QFT  
E-mail : jwryu@vod.chungbuk.ac.kr

### 전명근

1987. 2 부산대학교 전자공학과(공학사)  
1989. 2 KAIST 전기 및 전자공학과  
(공학석사)  
1993. 2 KAIST 전기 및 전자공학과  
(공학박사)  
1993-1996 삼성전자 자동화연구소  
선임연구원

2000-2001 University of Alberta 방문교수  
1996-현재 충북대학교 제어계측공학과 부교수

주관심분야 : 생체인식, 감정인식, 지능제어  
E-mail : mgchun@cbucc.chungbuk.ac.kr