

논문 2010-47CI-3-10

# 정보 입자에 근거한 개선된 언어적인 모델의 설계

## ( A Design of an Improved Linguistic Model based on Information Granules )

한 윤희\*, 꺾 근 창\*\*

( Yun-Hee Han and Keun-Chang Kwak )

### 요 약

본 논문은 수치적인 입출력데이터로부터 언어적인 규칙을 생성시키기 위한 체계적인 접근방법으로써 정보입자(information granules)에 근거한 언어적인 모델(LM: Linguistic Model)을 발전시킨다. Pedrycz에 의해 소개된 언어적인 모델은 컨텍스트 기반 퍼지 클러스터링(CFC: Context-based Fuzzy Clustering)으로부터 얻어지는 퍼지 정보입자에 의해 수행되어지며, 이는 입력과 출력공간과 연관된 클러스터 된 데이터들의 동질성을 보존하도록 클러스터를 추정한다. 언어적인 모델의 효능성은 이전 연구에서 이미 증명되었음에도 불구하고 성능 측면에서 개선시킬 필요성이 있다. 따라서, 본 논문에서는 기존 언어적인 모델의 근사화와 일반화 성능을 모두 향상시키기 위해 언어적인 컨텍스트의 자동적인 생성, 바이어스항의 추가, 결론부 파라미터의 변형된 구조를 통해 이루어진다. 실험결과는 자동차 연료소비량 예측문제와 보스턴 housing 데이터를 통해 제안된 방법이 언어적인 모델뿐만 아니라 기존 방법들보다 우수함을 증명한다.

### Abstract

In this paper, we develop Linguistic Model (LM) based on information granules as a systematic approach to generating fuzzy if-then rules from a given input-output data. The LM introduced by Pedrycz is performed by fuzzy information granulation obtained from Context-based Fuzzy Clustering(CFC). This clustering estimates clusters by preserving the homogeneity of the clustered patterns associated with the input and output data. Although the effectiveness of LM has been demonstrated in the previous works, it needs to improve in the sense of performance. Therefore, we focus on the automatic generation of linguistic contexts, addition of bias term, and the transformed form of consequent parameter to improve both approximation and generalization capability of the conventional LM. The experimental results revealed that the improved LM yielded a better performance in comparison with LM and the conventional works for automobile MPG (miles per gallon) predication and Boston housing data.

**Keywords :** linguistic model, information granules, context-based fuzzy clustering, linguistic contexts

### I. 서 론

일반적으로 퍼지 모델링(fuzzy modeling)의 본질은 퍼지 집합 혹은 퍼지 관계로 고려되는 정보 입자들 (information granules) 사이의 관계를 발전하는데 있다.

기존 문헌에서 연구되어진 퍼지 모델은 다양한 방법론, 구조 및 알고리즘의 측면에서 잘 정리되어져 있다. 모델의 정확성과 명백함은 퍼지 모델에 있어서 필수적인 요소이며 중요한 척도이다<sup>[1]</sup>. 정확성은 많은 방법에서 이미 다루어져 있는 반면, 명백함과 해석능력은 여전히 연구되어져야 할 부분이다. 해석능력은 기본적인 정보 입자의 성질을 만족함을 의미한다. 해석능력과 정확성 요구조건을 만족하는 모델은 자연스럽게 발전되어질 수 있다. 특히, 퍼지 클러스터링은 퍼지 모델의 설계에서 중요한 역할을 차지한다. Kim<sup>[2]</sup>은 TSK(Takagi-Sugeno-Kang)모델을 구축하기 위해서 기본적인 정보

\* 학생회원, 조선대학교 제어계측공학과 (Dept. of Control and Instrumentation, Chosun University)  
\*\* 평생회원, 조선대학교 제어계측로봇공학과 (Dept. of Control, Instrumentation, and Robot Engineering, Chosun University)  
접수일자: 2009년9월17일, 수정완료일: 2010년5월7일

입자로서 고려되는 초평면 클러스터의 위상기하학이 논의되어졌다. 이 모델의 성능은 클러스터들의 초평면 기하학과 비교하여 개선되어졌다. 소위 더블 클러스터링의 아이디어는 두 단계의 퍼지 클러스터링 프로세스를 통한 퍼지 모델링의 설계에 목적을 두고 있다. 먼저 클러스터링은 초평면과 같은 클러스터들을 추정하도록 사용되어지고 그런 다음 파라미터 공간에서 세밀한 클러스터링을 수행한다<sup>[3]</sup>. Hadjuli<sup>[4]</sup>는 출력공간에서 존재하는 데이터의 구조를 고려할 필요성을 증명하였다. 그러나, 조건적인 클러스터링의 아이디어를 따르는 대신에 가장 관련된 입력변수의 선택에 초점을 두고 있다. 또한, Abonyi<sup>[5]</sup>는 수정된 Gath-Geva 클러스터링을 이용하여 퍼지 모델링에 적용하였다. 본질적으로 이러한 클러스터링기법들은 입력공간에서 형성되어진 퍼지 클러스터들의 기하학을 다루는 연구들이었다.

기존 논문들<sup>[2-5, 11]</sup>은 입력공간에 의해 클러스터링이 수행되어지는 반면, Pedrycz는 새로운 형태의 컨텍스트 기반 퍼지 클러스터링(CFC: Context-based Fuzzy Clustering)<sup>[10]</sup>을 제안하여 입력과 출력공간과 연관된 클러스터 된 데이터들의 동질성을 보존하도록 클러스터링을 수행한다. 또한, 이 클러스터링을 근거로 해서 새로운 형태의 언어적인 모델(LM: Linguistic Model)<sup>[1]</sup>, 방사기저함수 (RBFN: Radial Basis Function Networks)<sup>[6]</sup>, 점진적인 모델(incremental models)<sup>[7]</sup> 등을 발전시키고 효능성을 입증하였다. 이들 모델들은 정보입자의 기본 성질을 만족시키는 언어적인 해석능력을 보이고 추론된 출력 값은 퍼지 수(fuzzy number)에 의해 불확실성을 내포하는 특성을 가지고 있다. 그러나, 기존의 LM은 구조적인 문제로 인해 근사화와 일반화 성능이 저하되는 문제점을 가지고 있었다. 즉, 출력공간에서 균등한 간격에 의해 언어적인 컨텍스트가 생성되기 때문에 출력 데이터의 분포가 편향된 경우에는 그 영역에서 클러스터링을 수행하지 못하는 문제점이 있다. 또한, 모델의 출력이 한쪽방향으로 치우친 결과로 인해 좀 더 큰 오차가 발생되어진다. 따라서 본 논문에서는 이러한 문제점을 해결하기 위해 1)출력공간에서 확률적인 분포에 근거한 언어적인 컨텍스트의 자동적인 생성 2) 바이어스항의 추가 3) 결론부 파라미터의 변형된 구조를 사용하여 개선된 언어적인 모델(ILM: Improved Linguistic Model)을 제안한다.

실험적인 결과는 대표적인 비선형 회귀문제인 자동차 연료소비량 예측문제와 Boston housing 데이터<sup>[7]</sup>를

고려하였으며, 실험을 통해 제안된 모델이 기존의 LM 뿐만 아니라 다른 지능적인 모델에 비해 우수한 특성을 나타냄을 증명한다. 본 논문은 학술대회 논문<sup>[8]</sup>을 기초로 해서 작성되어졌다.

## II. 언어적인 모델(LM)

각 언어적인 모델(LM: Linguistic Model)은 Pedrycz<sup>[1]</sup>에 의해 소개되었으며, 전반적인 모델의 구축은 컨텍스트 기반 퍼지 클러스터링(CFC: Context-based Fuzzy Clustering)<sup>[10]</sup>에 의해 수행되어진다. 먼저 CFC에 관해 간략히 설명하면 다음과 같다. 출력공간의 퍼지 집합에 대해서 다음과 같이 정의한다.

$$T: D \rightarrow [0, 1] \quad (1)$$

여기서 D는 출력변수의 전체집합이며, 주어진 데이터에 대해 컨텍스트의 값이 이용가능하다고 가정한다.  $f_k = T(d_k)$ 는 출력공간에서 생성된 임의의 퍼지 집합에서 k번째 데이터의 포함정도를 표현한다. 여기서  $f_k$ 의 값은 0과 1사이의 소속 값을 나타낸다. 이러한 특성에 의해 소속 행렬의 요구조건을 수정하면 다음과 같다.

$$U(f) = \left\{ \begin{array}{l} u_{ik} \in [0, 1] \mid \sum_{i=1}^c u_{ik} = f_k \forall k \\ \text{and } 0 < \sum_{k=1}^N u_{ik} < N \end{array} \right\} \quad (2)$$

수정된 소속행렬은 U는 다음과 같이 표현되어진다.

$$u_{ik} = \frac{f_k}{\sum_{j=1}^c \left( \frac{\|x_k - c_i\|}{\|x_k - c_j\|} \right)^{\frac{2}{m-1}}} \quad (3)$$

여기서 m은 가중치 지수이며 일반적으로 m=2를 사용한다. 언어적인 컨텍스트는 연속적인 퍼지 집합 사이의 1/2 겹침과 출력공간에서 균등히 분포된 삼각형 혹은 사다리꼴 소속함수에 의해 발생되어진다. 본 논문에서는 삼각형 소속함수가 사용되어졌다. CFC 알고리즘의 수행순서는 다음과 같다.

[단계 1] 언어적인 컨텍스트의 수와 각 컨텍스트에서 발생되어질 클러스터의 수를 선택한다. 0과 1사이의 임의의 값을 가진 소속행렬 U를 초기화한다. 간소성을 위해 각 컨텍스트에서 클러스터의 수는 동일하다고 가정한다.

[단계 2] 출력공간에서 균등하게 분포된 삼각형 소속함수에 의해 언어적인 컨텍스트를 생성시킨다.

[단계 3] 각 컨텍스트에서 클러스터 중심을 다음 식과 같이 계산한다.

$$c_i = \frac{\sum_{k=1}^N u_{ik}^m x_k}{\sum_{k=1}^N u_{ik}^m} \quad (4)$$

여기서 소속 값  $u_{ik}$ 는 식(3)에 의해서 구해진다.

[단계4] 목적함수는 다음 식과 같이 계산되며, 만약 이전 반복을 통해 얻어진 개선정도가 어떤 임계치보다 적은 값이라면 멈춘다.

$$J = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m d_{ik}^2 \quad (5)$$

$$|J^t - J^{t-1}| \leq \epsilon \quad (6)$$

여기서  $d_{ik}$ 는  $i$ 번째 클러스터 중심과  $k$ 번째 데이터 포인트 사이의 유클리디안 거리를 나타내며  $t$ 는 반복 횟수를 나타낸다.

[단계 5] 식(3)에 의해 새로운 소속행렬  $U$ 를 계산하고, [단계 3]으로 간다.

그림 1은 CFC의 개념도를 보여주고 있다. 그림에서 보는 바와 같이 언어적인 컨텍스트의 수와 각 컨텍스트




그림 1. 컨텍스트 기반 퍼지 클러스터링의 개념도.  
Fig. 1. Concept of context-based fuzzy clustering.

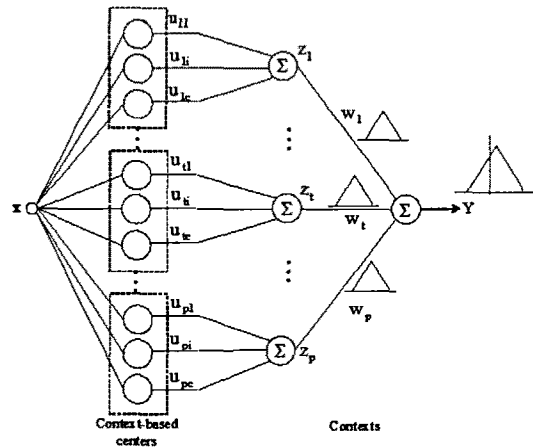


그림 2. 언어적인 모델(LM)의 구조.

Fig. 2. Architecture of linguistic model.

에서 클러스터의 수는 각각  $p=3$ 와  $c=2$ 을 나타낸다.

그림 2는 Pedrycz가 소개한 LM의 구조를 보여주고 있다. 전제부의 파라미터는 컨텍스트 기반 클러스터링에 의해 얻어진 클러스터 중심에 의해 얻어진다. 출력 공간에서 생성된 언어적인 컨텍스트는 그림에서 보는 바와 같이 결론부의 파라미터가 된다.

결과적인 모델의 추론 값  $Y$ 는 다음과 같이 퍼지 수 (fuzzy number)에 의해 계산되어진다.


$$Y = \sum_{\oplus} W_i \otimes z_i \quad (7)$$

여기서 일반화된 덧셈과 곱셈의 기호( $\oplus, \otimes$ )는 정보입자를 강조하기 위해 사용되어진다.


### III. 개선된 언어적인 모델(ILM)

#### 1. 언어적인 컨텍스트의 자동적인 생성 (Case1)

기존의 LM에서는 임의의 컨텍스트에 포함된 적은 데이터로 인해 데이터 부족 문제를 보일 수 있다. 이런 문제는 결과적으로 CFC로부터 클러스터 중심과 퍼지 규칙을 얻기 어려워진다. 그러므로 본 논문에서는 출력 데이터의 확실적인 분포에 의해 자동적으로 언어적인 컨텍스트를 생성하여 데이터 부족문제를 해결할 수 있다. 여기서 생성되는 언어적인 컨텍스트는 각각의 규칙 즉, 퍼지집합의 경계를 의미 하고, 출력 공간에서의 확실적인 분포정보를 이용하여 균등하게 분포된 삼각소속함수에 의해 언어적인 컨텍스트가 자동적으로 생성된다<sup>[8]</sup>. 그림 3은 확실적인 분포에 의한 언어적인 컨텍스트의 자동적인 생성을 보여주고 있다. 그림 3(a)는 데이터



(a)



(b)

그림 3. 언어적인 컨텍스트의 생성.  
Fig. 3. Generation of Linguistic contexts.

의 출력공간에서의 히스토그램을 나타내고 있으며, 그림 3(b)는 출력 공간에서의 확률적인 분포에 근거한 삼각소속 함수에 의해 생성된 언어적인 컨텍스트를 나타내고 있다. 여기서 확률적인 분포는 확률밀도함수와 조건밀도함수를 이용해서 쉽게 얻어질 수 있다.

2. 바이어스항의 추가(Case2)

수치적인 바이어스 항  $w_0$ 을 그림 4와 같이 출력층의




그림 4. 언어적인 모델에 바이어스항 추가  
Fig. 4. Augmentation of bias term.

노드에 연결함으로써 쉽게 오차를 줄일 수 있다. 이렇게 함으로써 모델의 편향된 출력 값을 조절할 수 있다. 바이어스 항은 다음 식과 같이 계산되어진다.

$$w_0 = \frac{1}{N} \sum_{k=1}^N (d_k - y_k) \tag{8}$$

여기서,  $d_k$ 는 데이터의 k번째 출력을 나타내고,  $y_k$ 는 LM에 의해서 예측되어진 데이터의 k번째 출력을 나타낸다.

불확실성을 갖는 출력 경계는 다음과 같이 계산되어진다.

- 하한경계(lower bound):  $y_- = \sum_{t=1}^p z_t w_{t-} + w_0$

- 중심 값(modal value):  $y = \sum_{t=1}^p z_t w_t + w_0$

- 상한경계(upper bound):  $y_+ = \sum_{t=1}^p z_t w_{t+} + w_0$

3. 결론부의 변형된 형태(Case3)

그림 2에서 보는 바와 같이 결론부의 파라미터의 수와 언어적인 컨텍스트의 수는 같다. 이 경우는 전제부와 결론부가 퍼지집합의 형태이기 때문에 Mamdani 모델<sup>[9]</sup>과 유사하다. 그러나, 이러한 모델은 비선형성이 강한 경우에는 좋지 않은 성능을 보일 수가 있다. 따라서, 본 논문에서는 결론부 파라미터를 간략화 된 상수로 표현되며, 다음과 같이 CLSE (Constrained Least Square Estimate)에 의해 추정되어진다.

$$\min \| U\theta - D \| \tag{9}$$

subject to  $\min(D) \leq \theta \leq \max(D)$

여기서 U와 D는 그림 2에서 활성화함수의 값과 실제 출력 값을 의미한다. 추정되고자 하는 파라미터  $\theta$ 는 간략화 된 TSK 모델의 상수가 된다.

IV. 시뮬레이션 및 결과 고찰

1. 비선형 회귀문제

본 절에서는 대표적인 비선형 회귀문제인 자동차 연료 소비량 예측문제를 다룬다. 이 예제에서 6개의 입력이 사용되며 이는 실린더 수, 배기량, 마력, 무게, 가속력, 모델년도로 구성되어진다. 이들 입력에 의해 예측되




그림 5. 퍼지 수에 의해 얻어진 모델의 출력  
Fig. 5. Model output obtained by fuzzy number.

고자 하는 출력변수는 자동차 연료소비량인 MPG (Miles Per Gallon)이다. 데이터 집합은 392개의 서로 다른 자동차로부터 얻어졌다. 학습데이터와 검증데이터는 0과 1사이로 정규화 되어졌으며, 각각 60%-40%로 임의로 나누어 10번씩 반복적으로 실험하였다. 여기서 학습 데이터는 언어적인 모델을 구축하기 위해 사용되어지며, 검증 데이터는 구축된 모델이 타당한지 살펴보는 모델검증과 관련되어진다. 이렇게 함으로써 결과적인 모델이 학습데이터에 편향되지 않고 새로운 데이터에 대해 좋은 일반화 능력을 가질 수 있다.

그림 5는 일부 검증데이터에 대해서 실제 출력과 퍼지 수에 얻어진 모델 출력 및 불확실성을 포함한 경계값을 보여주고 있다.

그림 6은 P(컨텍스트의 수)와 C(클러스터의 수)는 2에서 6까지 증가해가면서 실험하였다. 그림 6(a)는 학습데이터의 RMSE 성능비교 값을 나타내고 있으며, 그림 6(b)는 검증 데이터의 성능비교 값을 나타내고 있다. 표 1은 제안된 ILM과 Pedrycz에 의해 소개된 LM 및 RBFN과의 RMSE (root mean square error) 성능을 비교하고 있다. LM의 경우에는 10번 반복 중 일부는 앞에서 언급한 균등한 컨텍스트 분포로 인한 데이터 부족 문제가 야기되어졌다. 표 1에서 보는 바와 같이 제안된 ILM은 기존 방법들에 의해 우수한 특성을 보이고 있으며, 특히 Case의 수가 증가함에 따라 더 좋은 성능을 나타냄을 알 수 있었다. 그림 6에서 보이는 바와 같이 가장 좋은 성능을 보인 p=6과 c=6을 각각 선택하였다. 여기서 Case1, 2, 3은 3절에서 설명한 세 가지 개선사항을 모두 고려한 결과를 나타낸다.





그림 6. 컨텍스트와 클러스터의 수에 따른 RMSE의 성능 비교

Fig. 6. Performance comparison of RMSE by the number of contexts and cluster.

표 1. RMSE의 성능비교

Table 1. Performance comparison of RMSE. (mean error of 10 iterations)

		학습오차	검증오차
LM <sup>[1]</sup>		3.78	4.22
RBFN <sup>[6]</sup>		3.24	3.72
개선된 LM	Case1	3.14	3.60
	Case1,2	2.80	3.31
	Case1,2,3	2.34	3.17

2. 보스턴 housing 데이터

본 절에서는 보스턴 housing 데이터를 사용하여 부동산 가격 예측문제를 다룬다. 이 예제에서는 13개의 입력 변수 중 본 논문에서는 12개의 입력을 사용한다.


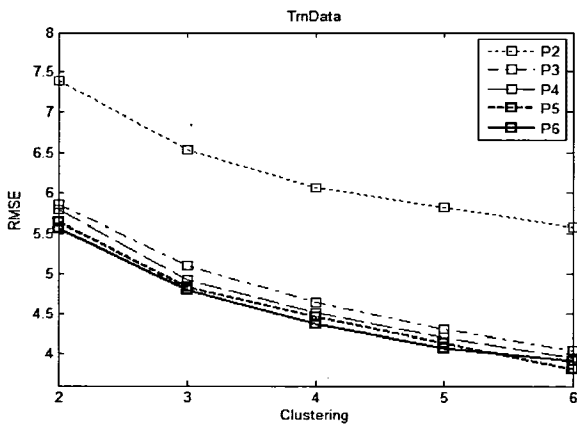
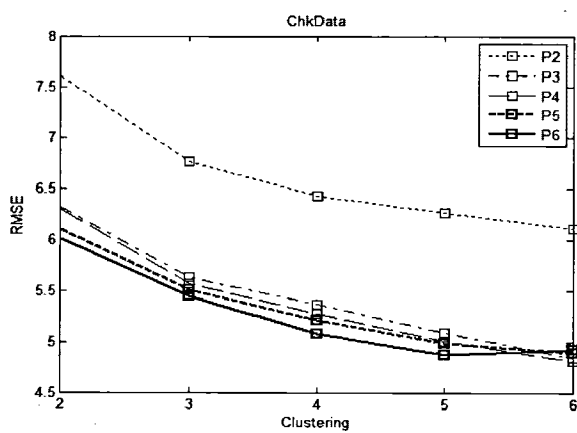


그림 7. 퍼지 수에 의해 얻어진 모델의 출력  
Fig. 7. Model output obtained by fuzzy number.



(a)



(b)

그림 8. 컨텍스트와 클러스터의 수에 따른 RMSE의 성능 비교

Fig. 8. Performance comparison of RMSE by the number of contexts and cluster.

12개의 입력 변수로는 CRIM: 각 도시에서의 1인당 범죄 비율, ZN: 25,000 sq.ft 이상의 거주 지역 비율, INDUS: 도시 당 비 소매상업 비율, NOX: 일산화질소의 집중도,

표 2. RMSE의 성능비교

Table 2. Performance comparison of RMSE. (mean error of 10 iterations)

		학습오차	검증오차
LM <sup>[1]</sup>		5.21	6.14
RBFN <sup>[6]</sup>		5.52	6.91
개선된 LM	Case1	4.82	5.78
	Case1,2	4.52	5.49
	Case1,2,3	3.89	4.89

RM: 주거 당 평균 방의 수, AGE: 1940년 이전에 지어진 집의 비율, DIS: 다섯 개의 보스턴 고용 중심지까지의 가중 거리, RAD: 고속도로까지의 접근 지표, TAX: 만 달러당 재산세, PTRATIO: 학생과 선생님 비율, B:  $1000(Bk-0.63)^2$ , 여기서 Bk는 도시 당 흑인의 비율을 의미한다. LSTAT: 저소득층 비율로 구성되어진다. 이들 입력에 의해 예측하고자 하는 출력 변수는 보스턴 외곽지역의 집의 가격(MEDV)이다. 데이터 집합은 보스턴 외곽의 506개 지역을 대상으로 조사하여 얻어졌다. 학습데이터와 검증데이터는 0과 1사이로 정규화 되어졌으며, 각각 60%-40%로 임의로 나누어 10번씩 반복적으로 실험하였다. 여기서 학습 데이터는 언어적인 모델을 구축하기 위해 사용되어지며, 검증 데이터는 구축된 모델이 타당한지 살펴보는 모델검증과 관련되어진다. 그림 7은 일부 검증데이터에 대해서 실제 출력과 퍼지 수에 얻어진 모델 출력 및 불확실성을 포함한 경계 값을 보여주고 있다. 그림 8은 P(컨텍스트의 수)와 C(클러스터의 수)는 2에서 6까지 증가해가면서 실험하였다. 그림 8(a)는 학습데이터의 RMSE 성능비교 값을 나타내고 있으며, 그림 8(b)는 검증 데이터의 성능비교 값을 나타내고 있다. 표 2는 제안된 방법과 이전 방법들과의 RMSE 성능을 보여주고 있다. 그림 8에서 보이는 바와 같이 가장 좋은 성능을 보인 P=5와 C=6을 각각 선택하였다.

참고 문헌

[1] W. Pedrycz and A. V. Vasilakos, "Linguistic models and linguistic modeling," IEEE Trans. on Systems, Man, and Cybernetics, vol. 29, no. 6, pp. 745-757, Dec 1999.

- [2] E. Kim, M. Park, S. Kim, and M. Park, "A transformed input-domain approach to fuzzy modeling," *IEEE Trans. on Fuzzy Systems*, vol. 6, no. 4, pp. 596-604, Nov 1998.
- [3] E. Kim, H. Lee, M. Park, and M. Park, "A simply identified Sugeno-type fuzzy model via double clustering," *Information Sciences*, vol. 110, no. 1-2, pp. 25-39, Sep 1998.
- [4] M. L. Hadjuli and V. Wertz, "Takagi-Sugeno fuzzy modeling incorporating input variables selection," *IEEE Trans. on Fuzzy Systems*, vol. 10, no. 6, pp. 728-742, Dec 2002.
- [5] J. Abonyi, R. Babuska, and F. Szeifert, "Modified Gath-Geva fuzzy clustering for identification of Takagi-Sugeno fuzzy models," *IEEE Trans. on Systems, Man, and Cybernetics-Part B*, vol. 32, no. 5, pp. 612-621, Oct 2002.
- [6] 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, July 1998.
- [7] W. Pedrycz and K. C. Kwak, "The development of incremental models," *IEEE Trans. on Fuzzy Systems*, vol. 15, no. 3, pp. 507-518, June 2007.
- [8] 한윤희, 김승석, 광근창, "퍼지 정보입자에 근거한 언어적인 모델의 개선에 관한 연구", 한국지능시스템학회 추계학술대회, pp. 350-353, 진주대학교, 한국, Nov 2008.
- [9] E. H. Mamdani and S. Assilian, "An experiment in linguistic synthesis with a fuzzy logic controller," *International Journal of Man-Machine Studies*, vol. 7, no. 1, pp.1-13, Jan 1975.
- [10] W. Pedrycz, "Conditional fuzzy C-Means," *Pattern Recognition Letters*, vol. 17, pp. 745-757, May 1999.
- [11] 김경중, 김은태, 박민용, "함수 근사화를 위한 강인한 TSK 퍼지 모델링", 대한전자공학회 논문지 CI, 제 42권, 제 3호, pp. 59-65, Jan 2005.

---

 저 자 소 개
 

---



한 윤희(학생회원)

2009년 조선대학교 제어계측로봇  
공학과 학사 졸업.

2009년~현재 조선대학교 제어계  
측공학과 석사과정

<주관심분야 : 인간-로봇상호작용,  
계산지능, 영상처리>



광 근 창(정회원)

1998년 충북대학교 전기공학과 석  
사 졸업.

2002년 충북대학교 전기공학과 박  
사 졸업.

2003년~2005년 캐나다 Alberta  
대학교 전기 및 컴퓨터공  
학과, 박사후과정

2005년~2007년 한국전자통신연구원 지능형로봇  
연구단 선임연구원

2007년~현재 조선대학교 제어계측로봇공학과  
교수

<주관심분야 : 인간-로봇상호작용, 계산지능, 바  
이오인식>