

영상복원을 위한 유전자기반 시스템 모델링 : 러프-퍼지엔트로피

System Modeling based on Genetic Algorithms for Image Restoration
: Rough-Fuzzy Entropy

박 인 규*, 황 상 문**, 진 달 복***
I.K. Park, S.M. Hwang, D.B. Jin

요약 효율적이고 체계적인 퍼지제어를 위해 조작자의 제어동작을 모델링하거나 공정을 모델링하는 기법이 필요하고, 또한 퍼지 추론시에 조건부의 기여도(contribution factor)의 결정과 동작부의 제어량의 결정이 추론의 결과에 중요하다. 본 논문에서는 추론시 조건부의 기여도와 동작부의 제어량이 퍼지 엔트로피의 개념하에서 수행되는 적응 퍼지 추론시스템을 제시한다. 제시된 시스템은 전방향 신경회로망의 토대위에서 구현되며 조건부의 기여도가 퍼지 엔트로피에 의하여 구해지고, 동작부의 제어량은 확장된 퍼지 엔트로피에 의하여 구해진다. 이를 위한 학습 알고리즘으로는 역전파 알고리즘을 이용하여 조건부의 파라미터의 동정을 하고 동작부 파라미터의 동정에는 국부해에 보다 강인한 유전자 알고리즘을 이용한다. 이러한 모델링 기법을 임펄스 잡음과 가우시안 잡음이 첨가된 영상에 적용하여 본 결과, 영상복원시에 발생되는 여러 가지의 경우에 대한 적응성이 보다 양호하게 유지되었고, 전체영상의 20%의 데이터만으로도 객관적 화질에 있어서 기존의 추론 방법에 비해 향상을 보였다.

I. 서 론

1965년 L. A. Zadeh¹⁾ 교수가 퍼지집합 이론을 발표한 이래 상당한 이론적 발전과 더불어 다양한 분야에의 적용이 이루어져 왔다. 기존의 신경회로망에 대한 퍼지논리의 적용으로 인하여 역전파 학습알고리즘이 상당한 보편성을 가지게 됨에 따라 퍼지추론 시스템은 전문가로부터 언어적정보를 취할 수 있을 뿐만 아니라, 입/출력 데이터를 이용한 적응성을 가지므로써 보다 나은 결과를 가져올 수 있었다. 또한 퍼지논리의 규칙베이스의 다양성과 신경회로망의 학습능력을 비롯하여 유전자 알고리즘의 강인한 탐색능력을

상호 유기적으로 결합하여 여러 분야에 대한 새로운 가능성을 제시하는 방향으로의 연구가 매우 활발히 진행되어 왔다.²⁾

퍼지 논리 제어기의 핵심은 퍼지추론 방식과 이에 관련된 언어 제어규칙으로서 제어규칙은 조건부와 동작부로 구성된 퍼지 조건문들로 이루어진다^{3~4)}. 이러한 추론에 적용될 퍼지 제어규칙이 성공적으로 구현된다면 많은 시간이 소요되는 모델구축이 불필요하게 되는데, 퍼지 제어규칙을 얻는 방법으로는 다음과 같은 방법들이 있다. 첫째 제어대상 공정의 특성을 분석하여 제어목적이 이루어지도록 제어규칙을 유도하는 경험적인 방법, 둘째 Mamdani가 제안한 자기 구성 제어기를 통하여 구현하는 방법⁵⁾, 셋째 퍼지관계 방정식에서 시스템의 입출력 데이터로부터 퍼지 관계행렬을 결정하는 방법⁶⁾, 넷째 '퍼지동정'이라는 개념에서 출발한 방법⁷⁾으로 공정 조작자의 제어조작

* 중부대학교 자연과학대학 전자계산학과
Tel : (0412)750-6755

E-mail : ikpark@joongbu.ac.kr

** 원광대학교 공과대학 전자공학과

*** 원광대학교 공과대학 전자공학과

이 성공적인 경우 제어조작에 따른 입출력 데이터로부터 제어동작을 모델링하여 제어규칙을 얻거나 조작자 이상의 제어효과가 필요한 경우 공정의 퍼지모델에 기초하여 퍼지 제어규칙을 얻는방법. 다섯째 신경회로망의 학습기능을 이용하여 퍼지 제어규칙을 동정하려는 뉴로퍼지(접근법8)이 있다. 또한 퍼지논리제어기 자체에 학습기능을 부여하기 위한 방법은 교사데이터로부터 학습에 의해 제어전략을 유도하는 것과 같고 있지만 신경회로망의 학습률, 중간층 수와 중간층 노드수와 같은 부수적인 파라미터의 결정을 수반하는 등등의 문제점을 안고 있다. 따라서 전문가의 지식이나 경험을 규칙 베이스나 데이터 베이스로 구축하기 위한 표준적인 방법이 존재하지 않고 시스템의 출력 오차를 최소화함으로써 시스템의 성능을 향상시키기 위한 멤버쉽 함수의 미세조정에 대한 효과적인 방법이 없다.

본 논문에서는 이러한 문제를 퍼지집합에서의 소속정도만을 가지고 기여도 및 제어량을 결정하기보다는 퍼지 엔트로피 개념하에서 기여도 및 제어량을 고려하여 결정한다. 퍼지추론의 조건부의 기여도를 퍼지 엔트로피를 이용하여 결정하여 기여도 결정을 위한 기준의 min방법이나 product방법의 단점이 개선된다. 또한 확장된 퍼지 엔트로피를 비퍼지화의 파라미터로 사용하여 각각의 제어규칙에 대한 조건부의 기여도에 따라 결정된 동작부의 제어량에 대해 최종 출력을 결정하여 기준의 비퍼지화기의 성능이 향상시키고자 한다.

II. 퍼지논리와 퍼지 엔트로피

1. 퍼지 집합

기준의 집합은 집합의 원소가 주어진 조건에 만족하면 집합에 속하고, 그렇지 않으면 집합에 속하지 않는데 반해, 퍼지집합은 “집합에 속하는 정도”에서부터 “집합에 속하지 않는 정도”까지의 변화가 완만한 집합으로 집합에 속하는 원소를 확실히 구분할 수 없는 집합을 나타낸다. 이러한 집합에 속하는 정도의 완만성은 멤버쉽 함수(membership function)에 해당하며 “물이 따듯하다”, “온도가 높다”와 같은 언어적 표현을 기술하는데 많은 융통성을 부여하게 된다.

2. 샤논 엔트로피

샤논 엔트로피는 불확실성이거나 정보의 양을 측정하는 척도로 많이 이용되고 있으며, 정보이론 분야의

가장 기본이 되는 이론으로 인식되고 있다. 이 척도는 확률이론에 기초하여 식 (1)과 같이 표현된다.

$$H(X) = - \sum_{x \in X} p(x) \ln p(x), \quad \forall x \in X. \quad (1)$$

3. 퍼지 엔트로피

퍼지 엔트로피는 샤논 엔트로피와 달리 확률이론에 기초하지 않기 때문에, $\sum p(x) \neq 1$ 로써 퍼지 엔트로피는 식 (2)와 같이 구해진다.¹⁰⁾

$$H(\bar{A}) = \sum_{x \in \bar{A}} (\mu_{\bar{A}}(x) \ln \mu_{\bar{A}}(x) + (1 - \mu_{\bar{A}}(x)) \ln (1 - \mu_{\bar{A}}(x))) \quad (2)$$

이는 $\mu_{\bar{A}}(x)$ 로 정의되는 퍼지집합 \bar{A} 와 $(1 - \mu_{\bar{A}}(x))$ 로 정의되는 퍼지집합의 보집합 \bar{A}' 의 불확실성을 합한것으로 결국 퍼지 엔트로피는 하나의 퍼지집합에 대한 애매함의 정도를 나타내는 퍼지척도이다. 여기서 퍼지척도란 한 원소가 퍼지집합에 속하는지, 속하지 않는지에 대한 애매함의 평균적인 양을 나타낸다. 따라서 De Luca 와 Termini는 n개의 원소를 갖는 퍼지집합 \bar{A} 에 대한 퍼지 엔트로피를 식 (3)과 같이 제안하였다.

$$H(\bar{A}) = \frac{1}{n \ln 2} \sum_{i=1}^n (S_n(\mu_{\bar{A}}(x_i))) \quad (3)$$

여기서

$$S_n(\mu_{\bar{A}}(x_i)) = \mu_{\bar{A}}(x_i) \ln \mu_{\bar{A}}(x_i) + (1 - \mu_{\bar{A}}(x_i)) \ln (1 - \mu_{\bar{A}}(x_i))$$

이 퍼지 엔트로피 함수는 퍼지집합에 대한 퍼지정도를 나타내며 그림 1과 같이 $[0, 0.5]$ 에서는 단조적으로 증가하고 $[0.5, 1]$ 에서는 단조적으로 감소하며 멤버쉽 함수값이 0.5일 경우에 가장 큰 값(가장 큰 불확실성)을 가진다

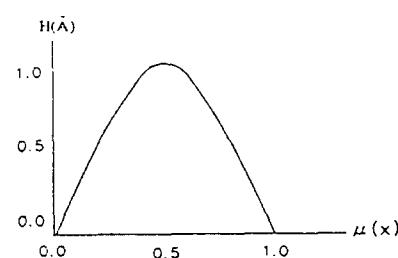


Fig. 1 Entropy function

4. 확장된 퍼지 엔트로피

확장된 퍼지엔트로피는 퍼지집합에 의해서 발생되는 퍼지정도를 최적화하기 위해 퍼지집합의 애매함(fuzziness)을 나타내는 퍼지정도의 척도와 퍼지집합에 상응하는 보통집합의 애매함에 의한 불규칙성(randomness)의 척도를 결합한 것이다. 그럼 2와 같이 퍼지집합을 구성하는 원소들의 애매함으로 인한 불확실성의 정보를 이에 상응하는 보통집합의 불규칙성으로 인한 확률적 정보를 고려할 수 있다.

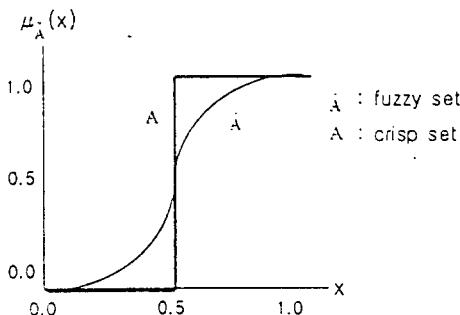


Fig. 2 The mapping of fuzzy set to ordinary set

퍼지집합 \bar{A} 를 보통집합 A 로 사상시키기 위하여 그림 2의 멤버쉽 함수를 이용한다. \bar{A} 의 원소 x_i 의 멤버쉽 함수 $\mu_{\bar{A}}(x_i) > 0.5$ 이면 x_i 는 A 의 원소가 된다. 이것을 모든 x_i 에 대하여 기술하면 식 (4)와 같다.

$$A = \{x_i \mid \mu_{\bar{A}}(x_i) > 0.5\} \quad (4)$$

\bar{A} 의 원소가 A 의 원소가 될 확률 $P(A)$ 는 식 (5)와 같이 정의할 수 있다.

$$P(A) = \frac{m+0.5r}{n} \quad (5)$$

\bar{A} 의 원소가 A 의 원소가 되지 않을 확률 $P(A^c)$ 은 $1 - P(A)$ 이다. 따라서 보통집합 A 의 퍼지 엔트로피 $H(\bar{A})$ 는 식 (6)과 같다.

$$H(\bar{A}) = -P(A) \ln P(A) - (1 - P(A)) \ln (1 - P(A)) \quad (6)$$

따라서 퍼지집합이 가지는 전체적인 엔트로피 $H(\bar{A})$ 는 식(7)과 같다.

$$H(\bar{A}) = H(A) + \frac{1}{n \ln 2} \sum_{i=1}^n \{S_n(\mu_{\bar{A}}(x_i))\} \quad (7)$$

여기서

$$S_n(\mu_{\bar{A}}(x_i)) = \mu_{\bar{A}}(x_i) \ln \mu_{\bar{A}}(x_i) + (1 - \mu_{\bar{A}}(x_i)) \ln (1 - \mu_{\bar{A}}(x_i))$$

5. 러프-퍼지 엔트로피에 의한 입력공간의 분할

퍼지추론 시스템의 성공 여부는 입력공간에 대한 분할을 얼마나 잘 구축하느냐에 달려 있다고 해도 과언이 아니다. 이러한 입력공간의 분할을 위해 본 논문에서 제안한 확장된 러프-퍼지 엔트로피를 이용하여 입력공간을 분할하였다. 결국 색상함수로 표현된 퍼지집합에 그 퍼지집합의 가장 가까운 퍼지 성분이 배제된 보통집합의 확률정보를 결합시킴으로써 임의의 한 입력변수의 공간분할을 보다 세분화 하였다. 즉, 경계영역이 인접 영역들과의 불확실성의 정도를 보다 세밀하게 구분할 수 있다. 결국 퍼지집합에 근접한 보통집합의 불확실한 정보를 고려한 러프-퍼지 엔트로피즉, 식(7)을 이용한 공간 분할의 알고리즘은 다음과 같다.

- 1) 영상 X 의 애매함을 측정하는 멤버쉽 μ_X 를 정의한다.

for($x_i = L_{min}; x_i \leq L_{max}; x_i++$)

for($x_i = L_{min} + \Delta b; x_i \leq L_{max} - \Delta b; x_i++$)

$$\mu_i(x_i; a, x_j, c) = S(x_i; a, x_j, c)$$

- 2) 영상 X 의 히스토그램 $h(x)$ 를 구한다.

- 3) 교차점 $b = x_i(L_{min} + \Delta b \leq x_i \leq L_{max} - \Delta b)$ 에 의해서 엔트로피를 구한다.

for($x_i = L_{min} + \Delta b; x_i \leq L_{max} - \Delta b; x_i++$)

$$H_T(X) |_{t_i} = -\text{Prob1} \ln \text{Prob1} - \text{Prob0} \ln \text{Prob0}$$

$$+ \frac{1}{MN \ln 2} \sum_{i=1}^{MN} \{(\mu_i(x_i; a, x_j, c) - \mu_c(x_i; a, x_j, c))\} h(x_i)$$

- 4) 각각의 경계에 따른 lower approximation과 upper approximation을 구한다.

$$LOWER(R(F_c) \text{ of } X) = \min\{\mu F_c(x) \mid x \in X_c\}$$

$$UPPER(R(F_c) \text{ of } X) = \max\{\mu F_c(x) \mid x \in X_c\}$$

- 5) 각각의 경계를 클러스터에 속하는 boundary region을 구한다.

$$BND(x) = UPPER((F_c) \text{ of } X) - LOWER((F_c) \text{ of } X)$$

- 6) ($L_{min} + \Delta b, L_{max} - \Delta b$)의 구간에서 아래

의 식을 만족하는 $BND(X) \mid_{x_i}$ 에 해당하는 국부적 최대치의 $x_i = b_k$ 를 구한다.

$$BND(X) \mid_{x_i} \rightarrow BND(X) \mid_{x_i} < BND(X) \mid_{x_{i+1}}, \quad 1 \leq k \leq Lme$$

Lme 는 국부적 최대치 엔트로피의 수이며, 클러스터의 수 C 는 $Lme + 1$ 개로 구성되어, 결국 영상은 $Lme + 1$ 개의 영역으로 분할이 된다. 국부적 최대치 엔트로피에 상당하는 계조도값들이 클러스터간의 경계에 해당하기 때문에 국부적 최대치 엔트로피의 수 Lme 와 클러스터의 수 C 는 퍼지 영역 폭과 아주 밀접한 관계가 있다. 따라서 퍼지 영역 폭이 넓어지면 넓어질수록 국부적 최대치 엔트로피의 수가 줄어들게 됨으로서 영상의 클러스터의 수가 줄게 되며, 퍼지 영역 폭이 줄어들게 되면 국부적 최대치 엔트로피의 수가 많아지게 된다.

위에서 언급한 내용에 기초하여 퍼지추론과정의 조건부의 최종 출력에 대한 기여도와 동작부의 제어량에 대한 결정에 확장된 퍼지엔트로피의 개념을 고려한 적용 퍼지추론 시스템은 그림 4과 같이 구성될 수 있다. 여기서 P 는 조건부의 멤버쉽함수, C 는 동작부의 멤버쉽함수, E 는 퍼지 엔트로피, H 는 확장된 퍼지 엔트로피, N 은 정규화이며, Π 와 Σ 는 각각 곱과 합연산이다.

퍼지추론시 동작부의 제어량의 결정을 위한 조건부의 기여도를 기준의 min-max방법의 최소값으로 구하기 보다는 입력을 구성하는 원소들만에

의하여 결정되도록 하기 위하여 이를 퍼지 엔트로피 개념하에서 구하면 식 (8)과 같다. 여기서 a 는 입력이고, $E(a)$ 는 입력의 퍼지 엔트로피이다.

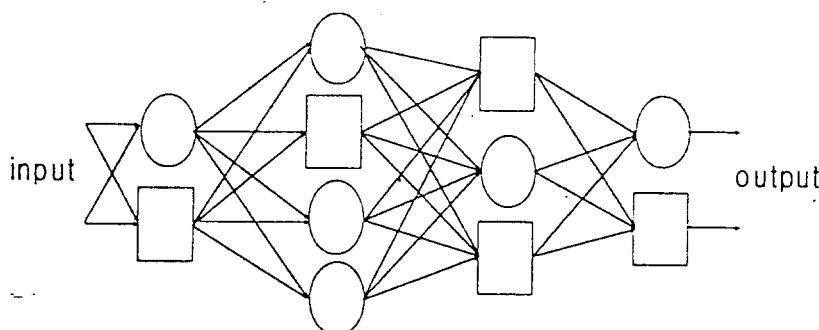


Fig. 3 An adaptive network

III. 뉴로퍼지 모델링

1. 적용 퍼지추론 시스템

퍼지추론 시스템의 구성은 제어 목적에 부합되는 퍼지 제어 규칙을 포함하는 규칙베이스와 퍼지 규칙에서 사용되는 퍼지집합들의 멤버쉽 함수를 정의하는 데이터베이스로 구성된다. 그리고 이들에 기초하여 추론합성 연산자에 의해 인간의 추론과정을 묘사하는 출력부에 해당하는 추론 엔진에 의해 퍼지 제어규칙으로부터 제어동작을 추론한다. 또한 입력을 퍼지영역의 전체집합으로 변환하는 퍼지화기와 퍼지 추론의 결과를 실제 제어입력의 전체집합으로 변환하는 비퍼지화기로 구성되는 일련의 퍼지추론의 과정을 다층 신경회로망에 구현하여 추론을 적응적으로 수행하도록 한다.

$$\text{기여도} = \frac{\sum_{i=1}^n a_i \cdot E(a_i)}{\sum_{i=1}^n E(a_i)} \quad (8)$$

또한 식 (8)에 의해 구해진 조건부의 기여도를 이용하여 동작부의 퍼지집합에 대해 α 수준집합을 발생시킨다. 이때 발생된 α 수준집합에 대해 보다 정확한 제어량을 결정하기 위하여 α 수준집합에 포함된 원소들만이 최종 출력을 계산하기 위한 비퍼지화 과정에 참여할 수 있도록 하고, 이에 따라 결정된 동작부의 각각의 제어량에 대해 확장된 퍼지 엔트로피를 비퍼지화 과정의 파라미터로 고려하여 식 (9)와 같이 최종 출력을 구한다. 여기서 w_i 는 α 수준집합의 적합도이고 $H(A')$ 는 α 수준집합의 확장된 퍼지 엔트로피이다.

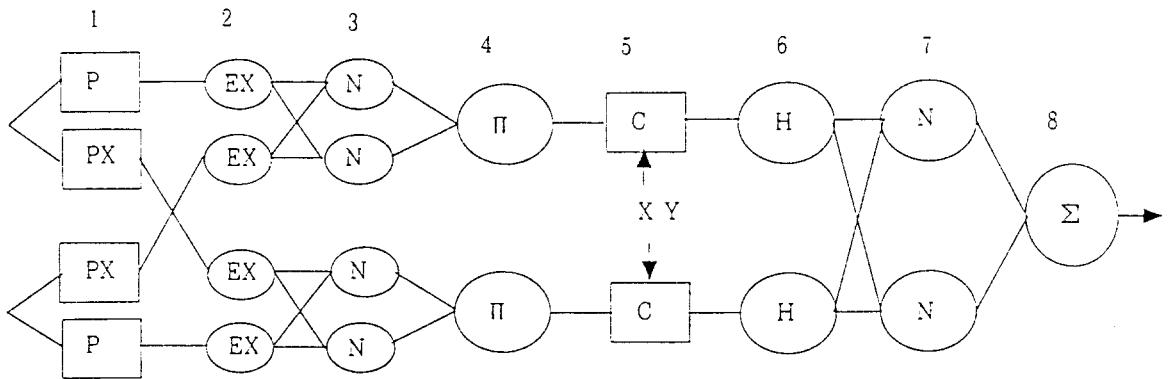


Fig. 4 The proposed adaptive fuzzy inference system

$$\text{출력} = \frac{\sum_{i=1}^n w_i \cdot H(A^{(i)})}{\sum_{i=1}^n H(A^{(i)})} \quad (9)$$

적용 퍼지추론 시스템의 전체적인 추론 과정은 다음과 같다.

[제1층] 멤버쉽 함수의 파라미터를 포함하는 적응 노드로 다음의 노드함수에 의하여 계산한다.

$$O_i^{(1)} = \mu_{A_i}(x)$$

[제2층] 입력에 대한 퍼지 엔트로피 $E(x)$ 를 구한다.

$$E(\mu_{A_i}(x_i)) = \frac{1}{\ln 2} (-\mu_{A_i}(x_i) \ln \mu_{A_i}(x_i))$$

$$-(1 - \mu_{A_i}(x_i)) \ln (1 - \mu_{A_i}(x_i))$$

[제3층] 각 노드는 전체 퍼지엔트로피에 대한 해당노드의 퍼지 엔트로피의 비율을 계산한다.

$$E_i^{(2)} = \frac{E_i}{E_1 + E_2}, \quad i = 1, 2.$$

[제4층] 노드에 입력되는 신호의 곱을 출력한다.

$$w_i = \mu_{A_i}(x_i) * \mu_{A_i}(x_i), \quad i = 1, 2.$$

[제5층] 동작부 파라미터를 조건부의 적합도에 의해 α 수준집합을 발생시킨다.

[제6층] 5층에서 발생된 α 수준집합에 대한 확장된 퍼지 엔트로피를 계산한다.[12]

$$H_1 = H(C_1^{(2)}) - \frac{1}{n \ln 2} \sum_{i=1}^n (\mu_{c_i}(x_i) \ln \mu_{c_i}(x_i))$$

$$+ (1 - \mu_{c_i}(x_i)) \ln (1 - \mu_{c_i}(x_i))$$

$$H_2 = H(C_2^{(2)}) - \frac{1}{n \ln 2} \sum_{i=1}^n (\mu_{c_i}(x_i) \ln \mu_{c_i}(x_i))$$

$$+ (1 - \mu_{c_i}(x_i)) \ln (1 - \mu_{c_i}(x_i))$$

여기서, n 는 퍼지집합의 원소의 수
[제7층] 확장된 퍼지 엔트로피에 대한 해당노드의 확장된 퍼지 엔트로피의 비율을 계산한다.

$$H_i = \frac{H_i}{H_1 + H_2}, \quad i = 1, 2.$$

[제8층] 하나의 노드로 구성되며 노드에 입력되는 모든 신호의 합을 추론의 결과로 출력한다.

$$\text{OUTPUT} = \sum_{i=1}^n w_i \cdot H_i$$

2. 학습 알고리즘

제안된 학습 알고리즘의 한 기(Epoch)는 전방향과 역방향의 각각 한 번씩의 수행으로 구성된다. 먼저 전방향의 진행에서는 네트워크의 제1층에 있는 조건부의 퍼지집합의 멤버쉽 함수를 정의하는 파라미터가 고정된 상태에서 입력 패턴이 입력되면 각 층마다 전방향으로 각 노드함수에 의해서 진행해서 전체 학습 패턴의 전방향 계산이 완료되면, 최종 출력에 대한 오차를 최대치 문제로 변환하여 유전 알고리즘에 의해 최적의 동작부 파라미터가 찾아진다. 다음 역방향의 진행에서는 제5층에 있는 동작부의 퍼지집합의 멤버쉽 함수를 정의하는 파라미터가 고정된 상태에서 다시 전체 학습 패턴을 학습시킨 다음, 발생된 오차에 대해서 역전파 알고리즘을 이용하여 오차에 대한 조건부의 파라미터를 수정하고 다시 전방향의 계산에 의해 최적의 퍼지규칙의 파라미터의 동정을 적응적으로 수행한다. 이에 대한 전체적인 학습알고리즘에 의한 파라미터 동정절차는 각각 그림 5와 표 1과 같다.

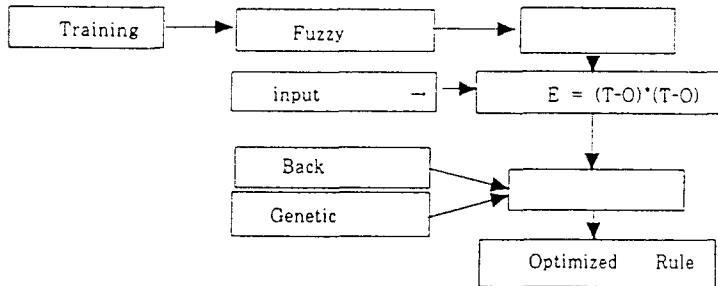


Fig. 5 Procedure of the identification of parameters by BP and GA

Table I Sequence of training algorithm

Parameter \ Epoch	Forward Feed	Backward Feed
Premise Parameter	Fixed	Back Propagation
Consequent Parameter	Genetic Algorithm	Fixed
Signal	Node Output	Error Rate

파라미터 동정은 식 (10)의 목적함수 E 를 최소화시키는 조건부 멤버쉽 함수 파라미터와 동작부를 구성하는 파라미터를 동정하는 일이다. 유전 알고리즘에서는 적합도에 따라 재생 연산자에 의해 문자열이 복제되는데, 이는 적합도가 큰 문자열이 이후의 세대로 더 많이 복제되는 것을 의미한다. 따라서 적합도 함수를 최대화시키도록 진화가 이루어지므로 최소화 문제를 최대화 문제로 변경하여야 한다. 이들의 이중성이 이미 널리 알려져 있듯이 최소화 문제를 유전 알고리즘에 맞도록 최대화 문제로 쉽게 변환할 수 있다. 그 변환 방법에는 여러 가지가 있지만 본 논문에서는 식 (11)과 같이 목적함수의 역수를 적합도 함수 f 로 결정한다.

$$E = \frac{1.0}{n} \sum_{i=1}^n \frac{|y_i^0 - y_i^*|}{y_i^0} 100(\%) \quad (10)$$

$$f = 1.0 / E \quad (11)$$

여기서 N 은 데이터 수, y_i^0 는 교사 데이터 출력이고, y_i^* 는 동정된 퍼지 규칙으로부터 추론된 값이다.

IV. 결과 및 고찰

제시된 모델링 기법의 성능 평가를 위해서 Lenna 영상 (256계조도의 256*256크기의 영상)을 사용한다. 본 논문에서 제시된 퍼지추론 모델링 기법을 이용하여 영상복원을 수행하기 위하여 구성한 시스템은 그림 6과 같다. 실험에 사용된 영상은 추론시스템의 퍼지화 도입부를 위하여 [0, 1]의 퍼지 단일값 (singleton)으로 변환하여 퍼지 추론 시스템의 입력을 구성하였다. 사용된 멤버쉽 함수 형태로는 그림 6과 같이 밝음, 어둠과 중간의 세 가지의 증형의 멤버쉽 함수를 사용하였다.

퍼지 추론시스템의 입력의 한 패턴을 구성하기 위하여 그림 8과 같이 가장 일반적인 3*3 윈도우를 이용하여 총 9개의 화소로 구성하였다. 한 개의 패턴을 구성하는 원소의 수는 윈도우의 크기에 따라 달라지며 윈도우의 크기가 커질수록 주위의 인접정보를 이용하여 추론 결과의 향상을 도모할 수 있지만 반면에 계산량의 증가를 고려하여 일반적인 3*3으로 구성하였다. 또한 영상복원에서 사용될 제어규칙의 수에 있어서는 각 언어 변수에 멤버쉽 함수를 각각 한개씩 정의하여 세 개의 제어규칙을 사용하였다.

또한 퍼지 제어규칙의 조건부의 멤버쉽 함수를 정의하는 밝음(a,b,c), 중간(a,b,c), 어둠(a,b,c)파라미터는 역전파 알고리즘에 의해 학습되며, 동작부의

밝음(a,b,c), 중간(a,b,c), 어둠(a,b,c)의 파라미터 동정은 유전 알고리즘에 의해서 동정된다. 이중 동작부 파라미터의 유전 탐색을 위한 부호화된 문자열을 표 2에 나타냈다. 9개의 파라미터는 총 108개의 0과 1로 이루어진 문자열로 변환되며(파라미터 하나의 코드길이는 12비트) 각각 최소값과 최대값을 나타낸다.

그림 9에 원 영상과 임펄스 잡음 영상을 나타낸다. 10%, 30%의 임펄스 잡음 영상에 대해 적응 퍼지필

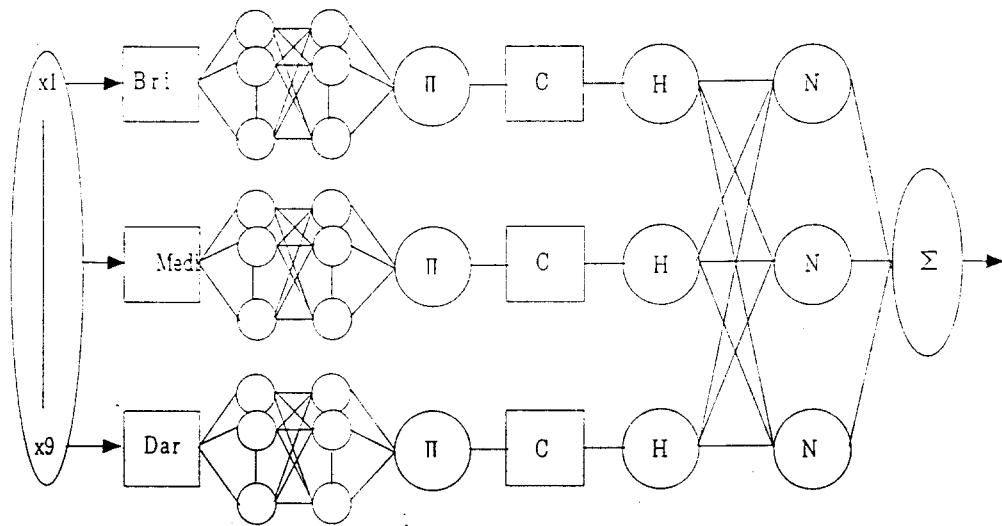


Fig. 6 The proposed adaptive fuzzy inference system

Table. 2 Coding for consequent parameter identification

Consequent Parameter								
a ₁	b ₁	c ₁	a ₂	b ₂	c ₂	a ₃	b ₃	c ₃

101001000110	101000100010	100001110111
Code Length for each Parameter (12bit)			
Length of total string (108bit)			

터, 기존의 추론방법과 제안된 방법과의 결과가 각각 그림 10, 그림 11에 보여진다. 이 결과를 통하여 전체적으로 잡음이 증가함에 따라서 영상의 화질이 떨어짐을 알 수 있었다. 적응 퍼지필터의 경우는 규칙 베이스를 구성하는 멤버쉽 함수의 각 파라미터를 공정의 모델에 기초하여 어둠, 중간과 밝음의 파라미터를 고정시킨 경우로서 최종출력에 대한 보다 정확한 정보를 제공하는데 문제가 있음을 알 수 있었고, 기

존의 추론 방법(sugeno-type)과 제안된 방법의 경우 역전파 알고리즘과 유전 알고리즘을 결합하여 규칙 베이스의 멤버쉽 함수의 동정을 수행하였다. 기존 방법의 경우는 각각의 조건부의 언어 변수에 대한 입력 변수의 소속정도(membership)에 대해 곱(product) 연산을 수행하여 퍼지 제어규칙의 조건부의 적합도를 결정하였고, 동작부의 최종출력에 대한 비퍼지화 방법은 무게중심법을 사용하였다. 제안된 방법에서는

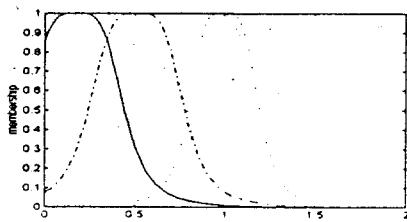


Fig. 7 Bell's membership function

P(x-1,y-1)	P(x,y-1)	P(x+1,y-1)
P(x-1,y)	P(x,y)	P(x+1,y)
P(x-1,y+1)	P(x,y+1)	P(x+1,y+1)

Fig. 8 3*3 input window

잡음으로 인한 영상의 입력공간이 비선형적(입출력 구조가 애매함)인 특성을 고려하기 위해 퍼지 엔트로피를 이용하여 입력변수가 가지는 소속정도에 대해 조건부의 적합도를 결정하므로써, 소속정도만을 파라미터로 한 기존의 곱연산에 의한 방법보다는 조건부의 적합도가 보다 정확한 것으로 분석된다. 동작부의 각각의 제어량에 대한 비퍼지화기로는 무게중심법을 사용하고 확장된

퍼지 엔트로피를 무게중심법의 파라미터로 이용하여 기존의 소속정도에 의한 경우보다 최종출력을 보다 잘 나타낼 수 있었다. 복원된 영상의 화질을 평가하기 위하여 각 방법에 따른 평균자승 오차를 표 3에

나타냈으며 식(12)과 같이 정의되는 MSE(mean square error)와 PSNR을 이용하였다.

$$MSE = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M [x(i,j) - \bar{x}]^2 / \sum_{i=1}^N \sum_{j=1}^M [x(i,j)]^2,$$

$$PSNR = 10 \log_{10} \frac{255^2}{MSE} \quad (12)$$

그림 12에 초기의 멤버쉽 함수와 학습후의 동정된 멤버쉽 함수를 나타냈다. 그림 13에는 30% 임펄스 잡음이 섞여 있는 영상에 대한 복원된 영상을 3차원의 히스토그램으로 나타내었다. 복원된 영상의 화질을 평가하기 위하여 각 방법에 따른 평균자승 오차를

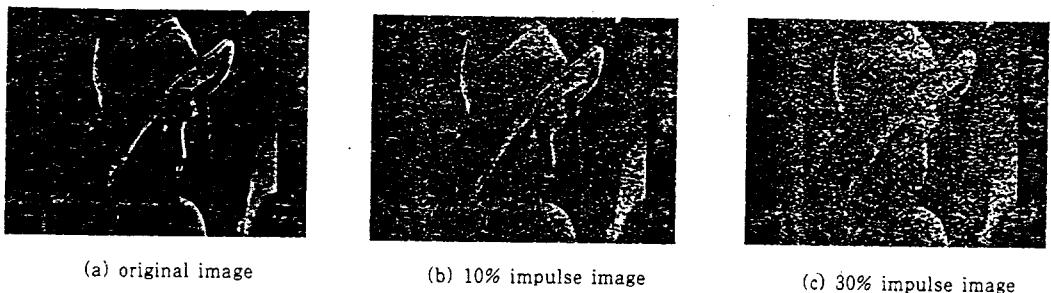


Fig. 9 Original and noise images by corrupted by impulse noises

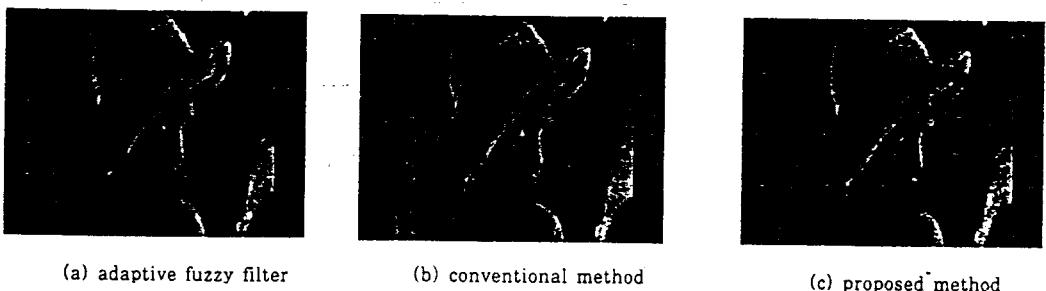


Fig. 10 Restored images of lenna corrupted by 10% impulse

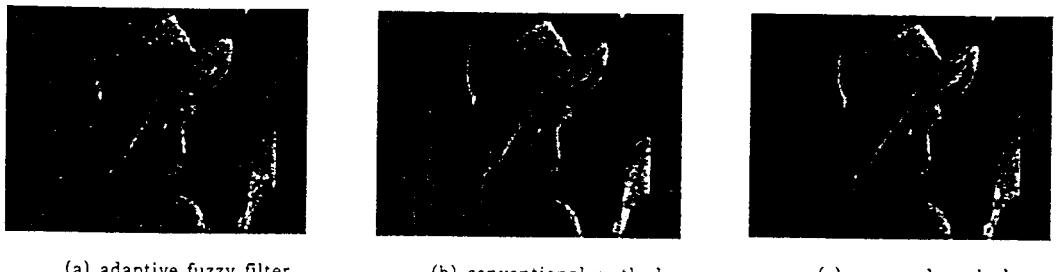


Fig. 11 Restored images of lenna corrupted by 30% impulse

표 3에 나타냈다.

Table 3 Mean square error of restored lenna

	NR = 10%	NR = 30%
Adaptive Fuzzy Filter	19	56
Conventional Fuzzy Method	17	29
Proposed Method	15	19

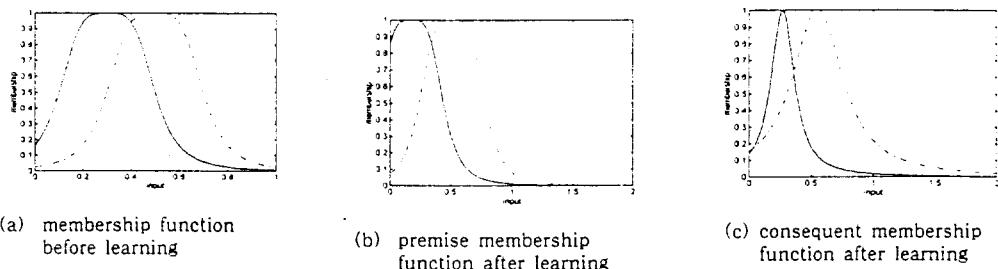


Fig. 12 Membership functions of 50% noise image

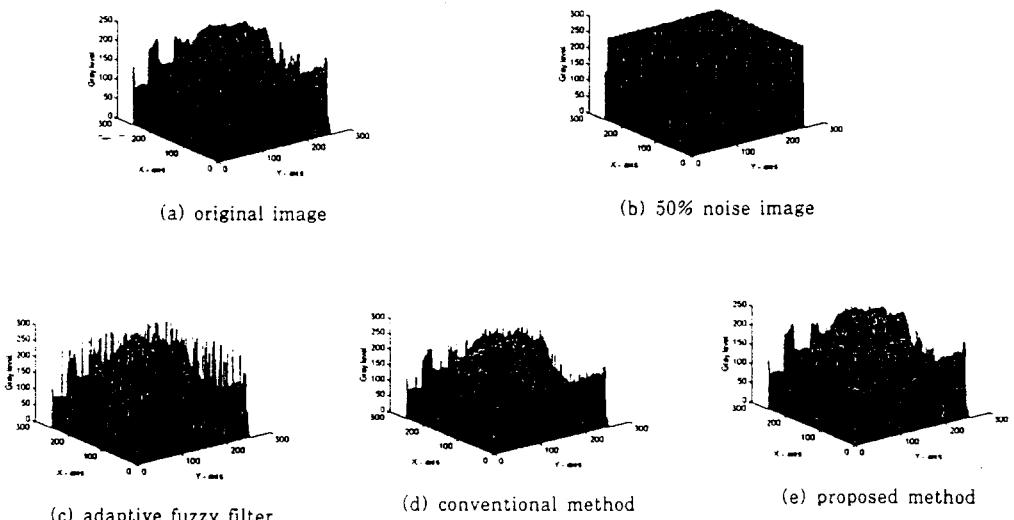


Fig. 13 Histograms of original, noise and restored images

이상에서 살펴 본 바와 같이 본 논문에서는 퍼지 추론시에 IF-THEN 제어규칙의 조건부의 동작부에 대한 기여도를 퍼지 엔트로피에 의해서 구하고, 이를 토대로 결정된 동작부의 제어량에 대한 확장된 퍼지 엔트로피를 구하여 최종 출력을 결정하는 적응 퍼지 추론 시스템을 제안하였다. 제안한 방법은 제어규칙

의 조건부를 구성하는 퍼셉트론에 대해 입력이 가지는 퍼지 엔트로피를 가지고 기여도를 결정하기 때문에 입력이 조건부의 기여도 결정에 기준의 min-max 방법의 min값에 의한 방법보다 잘 반영됨을 알 수 있었다. 또한 동작부의 각 제어규칙의 각 제어량에 대한 확장된 퍼지 엔트로피를 이용하여 비퍼지화를 수

행하므로써 역시 기존의 소속정도만에 의한 방법보다는 각 제어규칙들이 최종출력에 미치는 영향을 보다 잘 고려한 것으로 분석된다. 제안된 시스템의 모델링 기법의 타당성을 검토하기 위해 영상복원을 통해 기존의 적용 퍼지필터에 의한 방법과 기존의 Sugeno 추론방법과의 비교를 통해 알아 본 결과, 임펄스 잡음의 경우에 다른 방법보다 제안된 방법이 10%잡음의 경우에 객관적인 화질(PSNR)이 0.48~1.02dB 향상을 보였고 30%잡음과 50% 잡음의 경우에 각각 9.6 7~11.51dB와 15.25~17.53dB의 향상을 보였다.

V. 요 약

효율적이고 체계적인 퍼지제어를 위해 조작자의 제어동작을 모델링하거나 공정을 모델링하는 기법이 필요하고, 또한 퍼지 추론시에 조건부의 기여도 (contribution factor)의 결정과 동작부의 제어량의 결정이 추론의 결과에 중요하다. 이와 같은 목적을 달성하기 위해서는 입력공간의 분할이 중요하다. 따라서 확장된 퍼지 엔트로피에 의한 클러스터링 기법을 이용하여 입력공간을 분할하였다. 본 논문에서는 추론시 조건부의 기여도와 동작부의 제어량이 퍼지 엔트로피의 개념하에서 수행되는 적용 퍼지 추론시스템을 제시한다. 제시된 시스템은 전방향 신경회로망의 토대위에서 구현되며 조건부의 기여도가 퍼지 엔트로피에 의하여 구해지고, 동작부의 제어량은 확장된 퍼지 엔트로피에 의하여 구해진다. 이를 위한 학습 알고리즘으로는 역전파 알고리즘을 이용하여 조건부의 파라미터의 동정을 하고 동작부 파라미터의 동정에는 국부해에 보다 강인한 유전자 알고리즘을 이용한다. 이러한 모델링 기법을 임펄스 잡음이 첨가된 영상에 적용하여 본 결과, 영상복원시에 발생되는 여러 가지의 경우에 대한 적응성이 보다 양호하게 유지되었고, 전체영상의 20%의 데이터만으로도 객관적 화질에 있어서 기존의 추론 방법에 비해 향상을 보였다.

참고문헌

- [1] A. Deluca and Termini, "A Definition for non-probabilistic entropy in the setting of fuzzy set theory", *Information and Control*, vol.20, pp.301-312, 1972.
- [2] C. C. Lee, "Fuzzy logic in control systems: fuzzy logic controller-part1", *IEEE Trans. SMC.*, Vol. SMC-20, pp.404-418, Mar/Apr. 1990
- [3] C. C. Lee, "Fuzzy logic in control systems: fuzzy logic controller-part2", *IEEE Trans. SMC.*, Vol. SMC-20, pp.419-435, Mar/Apr. 1990
- [4] E. Czogala and W. Pedrycz, "On identification in fuzzy systems and its applications in control problems", *FSS*, vol. 6, no.1, pp. 73-83, 1981
- [5] H.-J. Zimmermann, "Fuzzy set theory and its applications", *Kluwer Academic Publishers*, 1991.
- [6] J. M. Keller and D. J. Hunter, "Incorporating fuzzy membership function into the perceptron algorithm", *IEEE Trans. PAMI.*, vol. PAMI-7, no.6, pp.693-669, 1985
- [7] Jyh-Shing Roger Jang, "ANFIS: Adaptive-network-based fuzzy inference system", *IEEE Trans. on SMC*, vol. 23, no. 3, pp. 665-685, 1993
- [8] L. A. Zadeh, "Fuzzy sets, information control", vol. 8, pp.338-353, 1965
- [9] L. H. Tsoukalas and R. E. Uhrig, "Fuzzy and neural approaches in engineering", *Wiley Interscience*, 1997
- [10] M. Sugeno and G. T. Kang, "Structure identification of fuzzy model", *FSS*, vol.28, no.1, pp.15-33, 1988
- [11] T. J. Procyk and E. H. Mamdani, "A linguistic self-organizing process controller", *Automat.*, vol. 15, no. 1, pp.15-30, 1979
- [16] 박인규, 진달복, "확장된 퍼지 엔트로피를 이용한 영상분할 알고리즘", *한국통신학회 논문지*, 21권 6호 pp. 1390-1397, 1996년 6월.

System Modeling based on Genetic Algorithms for Image Restoration : Rough-Fuzzy Entropy

I.K. Park*, S.M. Hwang**, D.B. Jin**

(*Joongbu University, **Wonkwang University)

Abstract An efficient and systematic fuzzy control requires a technique to model operator's control action or process, and in fuzzy inference it plays an important role in its result to determine the contribution factor of premise part and the output of consequent part. It is a prerequisite for that goal and so partition of input space is performed using clustering method based on extended rough-fuzzy entropy. This paper presents an adaptive fuzzy inference system that the approximate reasoning is carried out based on the concept of rough-fuzzy entropy. BP(backpropagation) algorithm is applied to the identification of premise parameters of fuzzy IF-THEN rule base and the identification of consequent parameters is investigated by GA(genetic algorithms) which are robust to local minima and thus have the advantage of optimal search. The utility of this neuro-fuzzy modeling was investigated through the model identification of image corrupted by impulse noises. Through a lot of results of simulation, a high degree of adaptability was reached by means of a set of fuzzy control rules which approximated a desired data set. The proposed shows the improvement in the objective image quality with only 20% training data of the entire image.