

퍼지 보상 연산자를 이용한 정보융합 방법 및 응용

正會員 李 俊 煥* 正會員 金 贊 星* 正會員 嚴 景 培**

A Fuzzy-Compensative-Operator Based Information Fusion Method and Its Applications

Joon Whoan Lee*, Chan Seong Kim*, Kyoung Bae Eum** *Regular Members*

要 約

본 논문에서는 퍼지 보상(compensative) 연산자를 이용하는 정보융합(information fusion) 방법을 제안하였다. 제안된 정보융합 방법에서는 보상적인 성질을 갖는 퍼지 총체화(aggregation) 연산자를 역오류전파(back-propagation) 신경회로망의 활성화함수(activation function)로 간주하고, 이들 연산자에 수반된 파라미터들을 학습에 의해 결정한다. 결정된 연산자의 파라미터들은 학습자료에 나타난 의사 결정에 수반된 보상도를 표현할 수 있으며, 평가에 불필요한 정보원을 제거하는 성질도 가지고 있다. 제안된 정보융합 구조는 평가지수(criterion)들의 계층적 망으로 구성되며, 평가지수들은 평가에 수반되는 부평가지수(sub-criterion)들의 만족도를 입력으로 학습에 의해 결정된 보상연산자에 의해 총체화된 만족도를 제공한다. 제안된 방법은 패턴 인식 문제와 칼라영상의 분할과 인식등 컴퓨터비전 문제에 적용하여 그 정당성을 입증하였다.

ABSTRACT

A methodology based on fuzzy compensative operators to achieve information fusion is proposed. The proposed scheme may be treated as a neural network in which fuzzy compensative aggregation functions are used as activation functions. The scheme involves generating degrees of satisfaction (memberships) of various decision criteria and aggregating the memberships in a hierarchical network. The parameters associated with the aggregation operators are learned through back-propagation training procedures. These training techniques also provide a mechanism for selecting powerful features via the detection of redundancies. Selected examples about computer vision problems including classification, segmentation and labelling of color images based on this method are presented to verify the proposed scheme.

*全北大學校 電子工學科
**群山大學校 컴퓨터科學科
論文番號 : 93-128

I. 서 론

의사 결정을 위한 불확실한 정보융합 방법은, 불충분한 정보들을 이용하는 의사 결정시, 애매모호성을 감소시키기 위한 목적으로 이용되어 왔다^{[1][12]}. 불확실한 정보융합을 위해서는 반드시 총체화를 위한 연산자를 필요로 하며, 사용되는 연산자는 정의된 방법론에 따라, 확률을 기본으로 하는 방법^[16], Dempster-Shafer의 믿음이론(belief theory)을 기본으로 하는 방법^{[1][5][12]}, 퍼지이론을 이용하는 방법들로 구분될 수 있다. 확률을 기본으로 하는 경우에는 Bayes 규칙이 융합을 위한 연산자로 사용되고, 믿음이론을 기본으로 하는 경우에는 Dempster의 규칙이 융합을 위한 연산자로 사용되고 있다. 그러나, Bayes 규칙이나, Dempster의 규칙을 적용하는 데는 확률론이나 믿음이론이 정의된 공리에 의해 융합 연산자 적용에 몇가지 제약 요건이 가해진다. 예를 들면, Bayes 규칙의 *apriori* 확률이나, Dempster 규칙의 non-interactiveness 등이 그것이다.

퍼지 이론을 이용하는 정보융합 방법에는 퍼지 수(fuzzy number)를 이용하는 방법^[6], 퍼지 적분을 이용하는 방법^[19], 퍼지 접속 연산자를 이용하는 방법^{[8][9][10][11]} 등 몇 가지 형태가 발표되었다. 퍼지 수를 이용하는 방법은 각각의 정보원에 신뢰도에 따라 퍼지 집합 형태의 가중치를 부여하고, 정보원으로 부터 제공되는 정보를 퍼지 집합 형태로 모형화 하여, 이를 확장원리(extension principle) 등의 퍼지 수 연산을 이용하여 융합하고, 그 결과는 퍼지 집합이다. 퍼지 적분을 이용한 방법^[19]은 Sugeno의 g-measure를 이용하여 정보원 또는 평가기준의 중요성을 표현하고, 평가 기준에 대한 평가치들을 계층적인 의사 결정 모형에서 퍼지 적분을 이용하여 총체화하는 방법을 이용하고 있다. 이들 퍼지이론을 이용하는 두 방법에서는 확률론이나, 믿음이론의 경우에서와 같이 융합시 연산자 적용의 제약 요건이 없는 장점이 있으나, 정보원의 중요성을 부여하는 가중치들은 확률이론 적용시의 *apriori* 확률과 같이 미리 결정되어야 하는 단점이 있다. 반면 퍼지 접속 연산자를 이용하는 정보 융합 방법에서는 t-norm, co-norm, 보상연산자 등 퍼지 총체화 연산자들을 기본으로^{[2][3][7][14][15]}, 정보의 총체화시 정책에 따라 다양한 연산자를 선택할 수 있을 뿐 아니라, 연산자 적용에 따르는 제약요건이 없는 장점이 있다. 또한 이러한 방법에서는 학습을 통하여 총체화에 필요한 연산자와 연산자에 부가된

정보원의 중요성을 표현하는 파라미터등을 자동적으로 결정하기 때문에 가중치 결정에 선지식등을 필요로 하지 않는다.

본 논문에서는 이러한 퍼지 접속 연산자를 이용하는 방법에 있어서 보상적인 성질을 갖는 정보융합 방법과 그 응용에 대하여 논하려한다. 일반적으로 교(intersection) 연산자나 합(union) 연산자의 경우 정보 융합시 너무 비관적이거나 낙관적이어서 정보의 손실이 크며, 서로 다른 성질의 정보를 융합하는데는 보상연산자가 적합하다고 보고되고 있다^{[3][23]}. 특별히 일반화된 평균(generalized mean)이나 γ -모델 등의 보상 연산자는 융합시 극단적인 성향을 피할 수 있고, 입력 정보원의 중요성을 표현하는 가중치를 가지고 있으며, γ -모델의 경우는 교연산이나 합연산의 영역도 부분적으로 포함하여 효율적인 정보융합이 가능하다.

본 논문에서 제안된 정보융합 방법에서는 평가지수들의 계층성에 따라 계층적인 신경회로망과 유사한 구조를 갖고, 신경회로망의 각 단(unit)들은 하나의 평가지수 또는 총체화에 필요한 보상 연산자에 해당 된다. 여기서 각 단에서의 평가지수들의 만족도는 보상 연산자들을 이용하여 $[0, 1]$ 의 값인 하위 계층에서 제공되는 만족도들을 이용하여 융합한다. 이때 융합에 사용되는 보상 연산자와 부가된 파라미터들은 이들 연산자를 신경회로망의 활성화 함수^[20]로 가정하고 학습 데이터를 이용하여 역전파 학습에 의해 미리 구해진다. 학습후 연산자에 부수된 가중치들은 불필요한 평가지수를 제공하는 하위계층의 부평가지수를 제거하는 성질을 갖고, 일반화된 평균의 β 와 γ -모델의 γ 값은 보상의 정도를 표현할 수 있다.

제안한 방법과 기존 신경 회로망과의 차이점은 기존 신경회로망에서는 정보가 각 연산 요소들에 분포되어, 각 단의 의미(semantics)를 분명하게 부여하기 어려운 반면, 제안된 망에서는 symbolic 모델에서와 유사하게 각 단의 의미가 망 설계자에 의해 평가지수로 분명하게 부여된다.


본 논문의 제 2절에서는 퍼지 접속 연산자와 보상 연산자의 성질을 요약하고, 제 3절에서는 정보 융합의 성향을 결정하는 파라미터를 찾아 내기 위한 학습 방법과, 제 4절에서는 패턴 인식과 갈라 영상의 분할과 인식에 적용된 모의실험 결과와 제 5장에서는 결론을 맺고자 한다.

II. 퍼지 보상 연산자


퍼지 집합 이론에는 소속 함수 값을 총체화하는 수많은 접속 연산자가 정의되어 있다. 이들 접속 연산자들은 총체화의 성향(attitude) 또는 영역(range)에 따라 합 연산자, 교 연산자와 보상 접속 연산자들의 세가지 종류로 구별되고, 보상 연산자는 평균(mean) 연산과 혼합(hybrid) 연산자들로 구분될 수 있다. 그림 1에는 이들 연산자들의 영역을 표시하였다. 그림 1에서 $i_{\min}(x_1, x_2)$ 과 $u_{\max}(x_1, x_2)$ 연산자는 각각 다음과 같이 정의되는 가장 비관적이고 낙관적인 연산자이다^[7].

$$i_{\min}(x_1, x_2) = \begin{cases} 0 & (x_1 \neq 1 \text{ 이고 } x_2 \neq 1 \text{ 일 경우}) \\ x_1 & (x_2 = 1 \text{ 일 경우}) \\ x_2 & (x_1 = 1 \text{ 일 경우}) \end{cases} \quad (1)$$

$$u_{\max}(x_1, x_2) = \begin{cases} 1 & (x_1 \neq 0 \text{ 이고 } x_2 \neq 0 \text{ 일 경우}) \\ x_1 & (x_2 = 0 \text{ 일 경우}) \\ x_2 & (x_1 = 0 \text{ 일 경우}) \end{cases} \quad (2)$$



(a) 합, 교 및 평균 연산자의 영역



(b) 혼합 연산자의 영역

그림 1. 접속 연산자의 영역

Fig. 1. The Ranges of Fuzzy Connectives

합 접속 연산자는 연산 결과가 연산자의 입력중 값이 가장 큰것 보다 작지 않은 성질을 갖는 연산자로서, 영역은 $[max(x_1, x_2), u_{\max}(x_1, x_2)]$ 의 범위를 갖고, 정보융합시 낙관적인 성향을 나타내는 연산자이며, co-norm의 정의와 동일하기 때문에 발생함수(generating function)에 따라 무수히 많은 합 연산자의 정

의가 가능하다. 반면에 교 접속 연산자는 총체화된 값이 모든 입력중 가장 작은 입력보다 크지 않은 비관적인 성질을 갖는 연산자로서, $[i_{\min}(x_1, x_2), \min(x_1, x_2)]$ 의 영역을 갖는다. 따라서, 정보 융합시 비관적인 성향을 나타내는 연산자라 볼 수 있고, t-norm의 정의와 동일 하기 때문에 co-norm과의 쌍대성(duality)를 이용하면 무수히 많은 연산자를 정의 할 수 있다^[3].

많은 의사결정 문제에 있어서는 합이나 교 연산자들의 극단적인 연산자 보다는 보상 연산자를 이용하는 경우가 많으며, 특히 서로 다른 개념(multifactoral)으로 부터 제공되는 정보의 융합에는 보상 연산자가 적합하다는 사실이 입증된 바 있다^{[3][23]}. 퍼지 접속 연산자에는 무수히 많은 종류의 보상 연산자들이 있으며, 이들은 정의되는 형태에 따라 평균 연산자와 혼합 연산자의 두가지로 분류될 수 있으며, 평균 연산자의 경우는 일련의 공리를 근거로 정의되고 혼합 연산자는 일반적인 합이나 교 접속 연산자의 산술 또는 기하 평균으로 정의 된다.

정의 1: 평균 연산자 m은

- i) $m(a, b) \geq m(c, d)$ if $a \geq c$ and $b \geq d$
{ 단조증가 }
- ii) $\min(a, b) \leq m(a, b) \leq \max(a, b)$.

의 성질을 만족하는 $m: [0, 1] \times [0, 1] \rightarrow [0, 1]$ 의 사상(mapping)으로 정의된다.

이러한 성질을 만족하는 평균 연산자에는 산술 평균(arithmetic mean), 조화 평균(harmonic mean), 기하 평균(geometric mean), 파라미터를 이용하는 일반화된 평균(generalized mean)등이 있다. 또한 입력 정보원의 가중치를 부여하고, 파라미터 값에 따라 다양한 평균 연산자를 갖게 하는 일반화된 평균 연산자가 Dyckhoff and Pedrycz에 의해^[1] 제안되었는데 이는

$$g(x_1, x_2, \dots, x_n; p; w_1, w_2, \dots, w_n) = \left(\sum_{i=1}^n w_i x_i^p \right)^{\frac{1}{p}} \quad (3)$$

와 같이 정의 되고, 여기서 x_i 는 i 번째 입력을 의미하며 w_i 는 i 번째 입력의 가중치로

$$w_1 + w_2 + \dots + w_n = 1, \text{ 모든 } w_i \geq 0 \quad (4)$$

이며, 파라미터 p 값은 $+\infty$ 와 $-\infty$ 사이의 값이다. 일반화된 평균의 p 값에 대한 편미분은

$$\frac{\partial g}{\partial p} = p^{-2} g^{1-p} \left\{ \sum_{i=1}^n w_i x_i^p \ln x_i^p - g^p \ln g^p \right\} \quad (5)$$

로 주어지고, 식 (5)는 주어진 p 값의 범위에서 항상 0보다 크므로 단조 증가함수이며^[1], min 과 max 사이의 값을 갖는다. 또한 각 입력의 값에 따른 편미분은

$$\frac{\partial g}{\partial x_i} = g^{1-p} w_i x_i^{p-1} \quad (6)$$

이며, 항상 0 이상이므로 x_i 에 따라 단조증가하며, 그 증가율은 입력에 부가된 가중치 w_i 값의 증가에 따라 증가한다. 따라서, 일반화된 평균 연산에 있어서 w_i 들은 각 정보원의 중요성을 표시하는 가중치로 생각할 수 있으며, p 값은 융합시 min 과 max 사이의 보상의 정도를 표시할 수 있다. 그림 2에는 p 값에 따른 일반화된 평균의 출력을 도시하였다.




그림 2. 일반화된 평균 연산자의 예 ($x_1 = 0.1, x_2 = 0.9, w_1 = w_2 = 0.5$ 일 경우)

Fig. 2. Behavior of a Generalized Mean Operator

혼합 연산자는 일반적으로 합과 교 연산자의 산술 또는 기하 평균으로 정의된다. 따라서, 무수히 많은 합과 교 연산자의 조합을 생각할 수 있으며, 영역은 혼합 연산자 정의에 사용된 교 연산자 값에서 합 연산자 값사이의 범위를 가지고, 보상적인 성질을 갖게 된다. Zimmermann과 Zysno에 의해 제안된 γ -모델은 이러한 연산자의 일종으로 식(7)과 같이 정의 된다.^{[21][23][24]}

$$h(x_1, x_2, \dots, x_n; \gamma; \delta_1, \delta_2, \dots, \delta_n) = \left(\prod_{i=1}^n x_i^{\delta_i} \right)^{1-\gamma} \left(1 - \prod_{i=1}^n (1-x_i)^{\delta_i} \right)^\gamma \quad (7)$$

여기서 $\delta_i \geq 0$ 이며 $\sum_{i=1}^n \delta_i = n$ 이고, $0 \leq \gamma \leq 1$ 이다.

식 (7)에서 정의된 γ -모델은 교 연산자의 일종인 대수적 곱(algebraic product) 연산과 합 연산자의 일종인 대수적 합(algebraic sum) 연산 두 부분으로 되어 있고, δ_i 는 x_i 의 가중치이며, γ 는 보상의 정도를 표현하는 파라미터 이다. 식 (7)에서 γ 값이 0 이면,

$$h_1(x_1, x_2, \dots, x_n) = \prod_{i=1}^n x_i^{\delta_i} \quad (8)$$

입력이 가중된 대수적 곱 연산과 같고, 1 이면

$$h_2(x_1, x_2, \dots, x_n) = \prod_{i=1}^n (1-x_i)^{\delta_i} \quad (9)$$

가중된 대수적 합과 같다.

정리 1: γ -모델은 γ 값에 따라 단조 증가하고 영역은 대수적 곱으로부터 대수적 합에 이르는 범위를 갖는다.

증명: γ -모델의 γ 값에 따른 편미분은

$$\frac{\partial h}{\partial \gamma} = h \cdot \ln \left(\frac{h_2}{h_1} \right) \quad (10)$$

과 같다. 식 (10)에서 h_1 과 h_2 는 식 (8)과 (9)와 같고, 동일한 입력에 대해 $h_2 > h_1$ 이면, h 가 항상 0 이상이기 때문에, 식 (10)은 항상 0 이상이고 h 는 γ 에 따라 단조 증가한다. 식 (7)에서 δ_i 는 항상 0보다 작지 않아야 하기 때문에 $\delta_i = \alpha_i^2$ 라 치환할 수 있다. $p = h_2 - h_1$ 이라 놓고, p 의 최소값을 결정하기 위해 Lagrange Multiplier를 도입하여,

$$Y = p + \lambda \cdot \left(\sum \alpha_i^2 - n \right) \quad (11)$$

라 놓자. 식 (11)을 모든 α_i 에 대하여 편미분하면, 식 (12)와 같은 형태의 n 개의 방정식을 얻는다.

$$-2\alpha_i \cdot ((1-h_2) \cdot \ln(1-x_i) + h_1 \cdot \ln(x_i)) + 2\alpha_i \lambda = 0 \quad (12)$$

식 (12)의 n 개의 방정식은

$$\alpha_i = 0 \text{ 또는 } -((1-h_2) \cdot \ln(1-x_i) - h_1 \cdot \ln(x_i)) + \lambda = 0 \quad (13)$$

일 경우에 만족된다. 만약 α_i 가 모두 0이 아니라면, x_i 값들은 서로 다르기 때문에 유일한 λ 값을 가질 수 없다. 따라서, 식 (12)의 방정식을 만족시키는 경우는 오직 하나의 α_i 값만 0이 아닐때 유일한 λ 값을 가질 수 있다. 만약 $\alpha_k \neq 0$ 이고 $i = k$ 를 제외한 모든 $\alpha_i = 0$ 라면, $\delta_k = \alpha_k^2 = n$ 이 되고,

$$p = 1 - (1-x_k)^n - x_k^n \quad (14)$$

이다. 식 (14)에서 p 는 $n=1$ 일 경우 0이고, $n > 1$ 에서 p 의 n 에 대한 편미분은 항상 양이기 때문에

$$p = h_2 - h_1 \geq 0$$

이다.

정리 1의 결과는 γ -모델 연산자의 성질이 극단적인 대수적 함으로 부터 대수적 곱에 이르며 γ 값의 크기에 따라 보상의 정도를 표현할 수 있음을 보여 준다. 또한 γ -모델에서 입력의 가중치 δ_i 의 의미는 다음과 같이 설명되어 진다. 식 (8)에서 $x_i \in [0, 1]$ 일 경우 δ_i 가 증가하면 $x_i^{\delta_i}$ 는 감소하고, 교 연산인 h_1 값은 x_i 값에 더욱 민감하게 되며, 식 (9)에서 역시 δ_i 가 증가하면 $(1-x_i)^{\delta_i}$ 는 감소하며 합 연산인 h_2 값은 x_i 값에 더욱 민감하게 된다. γ -모델의 입력 x_i 에 대한 편미분은

$$\frac{\partial h}{\partial x_i} = h \left\{ \frac{(1-\gamma)\delta_i}{x_i} + \gamma \frac{\delta_i h_1}{h_2(1-x_i)} \right\} \quad (15)$$




그림 3. γ -model의 예 ($x_1 = 0.1, x_2 = 0.9, \delta_1 = \delta_2 = 1$)

Fig. 3. Behavior of a γ -model

과 같으며, 식 (15)는 항상 0 보다 크기 때문에 x_i 의 증가에 따라 h 값은 증가하며, 그 증가율은 δ_i 에 비례한다. 그림 3은 γ 값에 따른 γ -모델의 출력을 보여 주고 있다.

III. 학습 방법

평가 지수들이 계층적 체계로 구성된 정보 융합방에서 각 평가지수의 부평가지수들로부터의 부분적인 만족도의 융합은 구체적인 망의 형태와 각 단계에서 사용되는 접속 연산을 알고 있다면 가능하다. 그러나, 종종 망의 개략적인 형태만을 알고, 구체적인 접속 연산자는 알 수 없을 경우가 많다. 본 논문에서는 이러한 가정에서 출발하여, 망의 구체적인 구조와 각 단계에 필요한 연산자를 학습에 의해 구하는 방법을 제안하고자 한다.

본 논문에서 학습을 위해 필요한 데이터는 최 하위 계층의 각 평가지수에 대한 만족도들과 이러한 만족도들이 입력되었을 때의 최 상위 계층의 총체화된 평가 지수로 가정한다. 이러한 평가지수의 만족도들로 구성된 학습 데이터를 이용하여, 각 단의 일반화된 평균이나 γ -모델의 파라미터들은 이들 연산자를 계층적 신경회로망의 활성화함수라 가정하고, 역오류전파 학습과 같은 gradient descent 방법을 이용하여 결정한다.

만약, 어떤 단계에 n 개의 입력이 가해진다 하고, N 가지의 학습 데이터 $\{x_{1k}, \dots, x_{nk}; d_k\}$ 가 주어졌다고 가정하자. 여기서 $k=1, \dots, N$ 이고, d_k 는 k 번째 입력에 대한 원하는 출력이다. 학습을 통하여 해결하려는 문제는 실제 총체화된 값과 원하는 출력과의 불일치가 가장 작아 진다는 관점에서 최적의 연산자와 파라미터 값을 결정하는 것이다. 여기서, 불일치 정도는

$$E = \sum_{k=1}^N (f_k - d_k)^2 \quad (16)$$

로 정의하고, 식 (16)에서 f_k 는 입력 $\{x_{1k}, \dots, x_{nk}\}$ 에 대한 접속 연산자의 총체화된 값으로 f_k 는 망에서 일반화된 평균 또는 γ -모델 연산을 통하여 구해진 k 번째 학습 데이터에 대한 융합 결과이다.

학습 방법은 식 (16)에서, E 의 연산자 f_k 의 각 파라미터에 대한 negative gradient를 체인룰을 이용하여 구하고, 이를 작은 양의 실수 값(learning constant)과 곱하여, 현재의 파라미터 값에 더하여 개선하며, 식 (16)의 불일치가 더 이상 개선되지 않거나 망

의 모든 파라미터값이 더 이상 변화 하지 않을 때 까지 반복 수행하는 역오류전파 학습방법을 이용한다. 학습된 결과는 학습 데이터에 표현된 보상적인 성향과 입력 정보원의 중요성을 찾아내며, 결정된 망 구조와 연산자들은 학습 이후 불충분한 정보들을 융합하는데 이용된다.

3.1 일반화된 평균 연산자의 경우

이 경우는 망의 각 단에서 연산자의 형태를 모두 일반화된 평균이라고 가정하고 역전파 학습에 의해 식 (16)을 최소화 하도록 파라미터 p 와 w_i 값을 찾는다. 학습결과 p 값이 매우 크다면 집속 연산자는 근사적으로 max 연산과 같고 p 값이 매우 작다면 min 연산으로 근사화 될 수 있다.

그러나 일반화된 평균 경우 식 (4)에서 알 수 있듯이 입력의 가중치 w_i 에는 제약요인이 있기 때문에 일반적인 신경회로망의 제약요인이 없는 망의 강도(network strength)를 구하는 방식으로 입력의 가중치 w_i 들을 구할 수 없다. 본 논문에서는 이러한 제약조건을 우회 시키는 다음과 같은 방법을 고안하였다. 식 (3)와 (4)에서, 함수 g 는 식 (17)과 같은 방법으로 고쳐 쓸 수 있다.

$$g = \left(\frac{w_1^{*2}}{\sum w_i^{*2}} \cdot x_1^p + \dots + \frac{w_n^{*2}}{\sum w_i^{*2}} \cdot x_n^p \right)^{\frac{1}{p}} \quad (17)$$

식 (17)에서 w_i^* 들은 식 (4)의 가중치와는 다르게 제약이 없고, 식 (17)에서 새로운 가중치를

$$w_i = \frac{w_i^{*2}}{\sum w_i^{*2}} \quad (18)$$

로 정의하면 식 (4)의 제약조건을 만족시키게 된다. 즉 알고리즘에서 식 (17)의 w_i^* 를 제약없이 개선하여 수렴시키고 수렴된 값에서 w_i 를 찾아내면 가중치의 제약을 우회하여, 계층적 망의 파라미터를 찾아 내는데 역전파 학습법을 이용할 수 있다. 실제 알고리즘의 구현에 있어서 p 의 값이 무한히 증가할 수는 없기 때문에, $-15 < p < 15$ 로 제한하였고, 학습 시작시 모든 가중치는 $w_i = 1/n$ 으로 하고 $p = 1$ 즉 산술평균에서 시작하였다.

3.2 γ -모델의 경우

이 경우 집속 가능한 연산자의 형태를 모두 γ -모델로 가정한다. 실제 γ -모델의 영역은 대수적 교 연산자와 합 연산자 사이의 값을 갖기 때문에 그림 1-(b)에

서와 같이 하한이 모든 입력들 중 최소치 보다 작고, 상한은 최대치 보다 크다. 즉, γ -모델의 영역이 합 이나 교 연산 영역 까지 침투되어 있기 때문에 γ -모델만으로도 거의 모든 $[0, 1]$ 의 의사결정 영역을 포함시킬 수 있다. 또한 γ -모델은 γ 값에 따라 단조 증가하기 때문에 학습결과 γ 값이 0에 가깝다면 바람직한 연산은 교 연산이고, γ 값이 1에 가깝다면 합 연산이며, γ 값이 0.5 근방이라면 보상 접속 연산자라는 것을 알 수 있다. 학습 시작시 γ 는 0.5로 하고, δ_i 값들은 모두 1로 동일하게 놓는다.

그러나, 식 (7)에서 보는 바와 같이 γ -모델의 γ 값과 δ_i 값들에는 제약이 있기 때문에, 역오류전파 학습에 의해 파라미터를 개선해 가는데 어려운 점이 있다. 본 논문에서는 이러한 제약 조건을 다음과 같이 우회한다. 식 (7)에서 γ 와 δ_i 를 각각

$$\gamma = \frac{a^2}{a^2 + b^2} \quad \text{와} \quad \delta_i = \frac{n\delta_i^{*2}}{\sum \delta_k^{*2}} \quad (19)$$

로 치환 하자. 식 (19)에서, a 와 b 또는 δ_i^* 에는 아무런 제약이 없고 이러한 a 와 b 또는 δ_i^* 에 의해 구한 γ 와 δ_i 는 식 (7)의 제약 조건을 만족 시키기 때문에 학습시 a , b 와 δ_i^* 에 대한 불일치의 정도 E 의 편미분을 체인 룰을 이용하여 계산하고 개선해 나가며, 실제의 γ -모델의 파라미터들은 식 (19)를 이용하여 구할 수 있다.

IV. 모의 실험

본 절에서는 3 절에서 제시된 알고리즘 들을 이용한 모의 실험의 결과를 제시한다. 퍼지 접속 연산자를 이용한 AND나 OR, EXOR 문제등의 간단한 논리 연산등을 학습할 경우 성공적인 결과를 얻어 내었고, 가상적인 규칙 기반 컴퓨터 비전 문제의 경우 응용 가능성이 입증되었다^{[8][9][10]}. 따라서, 본 논문에서는 패턴 인식에 있어서 클래스 분류 문제와 칼라 영상의 분할 문제등에 적용하여 제안된 방법의 적용 가능성을 보였다.


4.1 패턴 분할 문제

본 실험에서는 4 개의 속성을 갖는 두개의 클래스의 데이터를 분할(classification)하는 문제를 고려하였다. 여기서 각 클래스의 속성들은 다변수 정규 분포(multivariate gaussian distribution)로 부터, 4개 중 처음 두개의 속성은 첫번째 클래스와 두번째 클래스의 평균과 분산이 동일하며, 각 클래스당 121 개씩

242 개의 데이터로 구성되었다. 각 클래스의 만족도 들을 융합하기 위해서는 그림 4(a)의 단층 구조의 망을 가정하였다. 그림 4에서 m_{ij} 는 속성 i 의 클래스 j 에 대한 만족도로

$$m_{ij} = \frac{\exp(-(x_i - \mu_{ij})^2)}{2 \cdot \sigma_{ij}^2} \quad (20)$$

과 같이 계산하였다. 여기서 μ_{ij} 와 σ_{ij}^2 는 학습 데이터의 i 번째 데이터의 j 번째 클래스의 평균값과 분산이고, x_i 는 i 번째 속성의 데이터 값이다. 실험에서 242 개의 데이터중 약 90%를 학습에 사용하고 나머지 10%를 검증하며, 학습 데이터와 검증에 사용될 데이터를 중복되지 않게 10번 교환하는 jack-knife 절차를 이용하였다. 여기서 학습 데이터는 하나의 속성당 2개 즉 8개의 만족도로 구성되며, 요구되는 출력의 총체화된 만족도는 해당 클래스에 대해서는 1, 해당되지 않는 클래스에서는 0의 값을 할당하였다. 각 단의 연산자는 일반화된 평균 연산자 또는 γ -모델을 가정하였는데, 학습의 결과 평균과 분산이 같은 속성 1과 2로 부터 제공되는 만족도에 해당되는 입력의 가중치들은 모두 0으로 수렴하였고, 속성 3과 4의 만족도에 해당하는 입력의 가중치만 남아 그림 4(b)와 같이 단순화됨을 알 수 있었다. 또한 검증 데이터에 대해서는 학습데이터로 부터 얻은 평균과 분산값을 이용하여 식 (20)으로 부터 검증 데이터의 만족도를 구하고, 학습 결과로 부터 얻은 연산자를 이용하여 만족도를 총체화하고 만족도가 큰 쪽으로 분류하였다. 표 1에는 10회 학습중의 한 학습으로 부터 얻어진 대표적인 학습 결과와 10회 학습에 대한 전체 검증 결과를 보였다. 학습시 학습률(learning constant)를 0.01로 하고 종료 조건(stopping criterion)을 식 (16)에 표현된 불일치정도의 변화가 4×10^{-1} 으로 설정할 경우, 수백회 정도의 반복 회수를 보였다.



(a) 학습전의 망구조 (b) 학습후의 망구조

그림 4. 두개의 클래스 분할을 위한 망구조
Fig. 4. Network Structures for Two-Class Problem

표 1. 패턴 분할 문제의 실험 결과

Table 1. Results of Two-Class Problem

일반화된 평균의 경우 :

node 1 $p = 0.163$ $w_1 = 0.69$ $w_2 = 0.31$

node 2 $p = 0.574$ $w_1 = 0.59$ $w_2 = 0.41$

γ -모델의 경우 :

node 1 $\gamma = 0.922$ $\delta_1 = 4.66$ $\delta_2 = 3.34$

node 2 $\gamma = 0.923$ $\delta_1 = 4.64$ $\delta_2 = 2.36$

10회 수행의 confusion matrix :

일반화된 평균의 경우

classes	1	2
1	102	19
2	6	115

γ -모델의 경우

classes	1	2
1	110	11
2	9	112

본 실험에서 평균치와 분산이 동일하여 클래스 분류에 불필요한 속성 1과 2로 제공되는 입력의 가중치들은 0으로 수렴되어, 학습 알고리즘은 불필요한 속성들을 제거할 수 있음을 알 수 있었으며, 표 1의 일반화된 평균의 경우 p 값이 0과 1 사이의 기하평균과 산술평균 영역에 수렴되어 보상적인 연산자를 이용하는 의사결정이 타당할 수 있음을 보였다.

4.2 칼라 영상의 분할과 인식

본 실험에서는 칼라 영상에서 얻어진 정보를 융합하여, “하늘(sky)”, “숲(vegetation)”, “도로(road)” 등 유사한 객체(object)들을 포함하는 256×256 크기의 영상을 분할하고 인식하는데 이용하였다. 본 실험에서는 칼라속성, 질감속성(texture) 및 객체의 위치 속성등을 이용하였다. 본 실험에서 사용한 칼라속성은 Ohta에 의해 칼라영상의 분할에 사용되었던 $(r + g + b)/3$ 의 인텐시티(intensity), $b - r$, $2g - r - b$ 등의 세가지였고^[16], 질감속성은 co-occurrence 행렬을 이용하는 국부 동질성(local homogeneity)

$$H(\delta, d) = \frac{L-1}{L} \sum_{i=0}^{L-1} \frac{L-1}{L} \sum_{j=0}^{L-1} \frac{1}{1 + (i + j)^2} S(i, j, \delta, d) \quad (21)$$

과 엔트로피(entropy)

$$E(\delta, d) = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} S(i, j, \delta, d) \cdot \log(S(i, j, \delta, d)) \quad (22)$$

등을 이용하였다. 식 (21)과 식 (22)에서 L 은 그레이 레벨수이고, co-occurrence 행렬 $S(i, j, \delta, d)$ 는 $T \times T$

원도우 내에서 δ 방향으로 d 만큼 떨어져 있는 부분의 그레이 레벨이 i 에서 j 로 천이되는 빈도를 표시한다. 본 실험에서 식 (21)와 (22)의 질감속성은 $2g-r-b$ 칼라속성 영상에서 계산하였고, $L=16$, $T=15$, $d=3$, δ 는 수직, 수평, 45° , -45° 의 4 방향을 co-occurrence 행렬을 계산하여 평균을 취하였다. 또한 질감 속성은 행과 열방향으로 세줄당 하나씩 계산하였고 계산되지 않은 부분은 보간하였다. 또한 영상에서 객체가 점유하는 위치를 속성으로 이용하였는데, 이는 객체가 점유하는 부분의 행 번호에 해당된다.

각 속성들로부터 객체를 지원하는 만족도는 칼라 속성과 질감속성의 경우 해당 객체부분의 전형적인 데이터를 채취하여 히스토그램을 얻어 내어 구하였다. 이 방법은

$$m_{ij} = h_{ij}(x_i) \quad (23)$$

과 같이 표현할 수 있으며, 여기서 $h_{ij}()$ 는 속성 i 의 객체 j 에 대한 속성데이터로부터 얻는 히스토그램으로서, 여기서 모든 객체들에 대해 각 속성값은 0와 255 사이에서 정규화되고, $h_{ij}()$ 의 최대값은 각각의 객체 j 에 대해 최대값이 1이 되도록 정규화하였다. 또한 위치 만족도를 얻기 위해서는 그림 5와 같은 사다리꼴함수를 이용하였다. 그림 6에서 실험에서 사용한 a, b, c, d 값은 각각 20, 30, 150과 230이었다.






그림 5. 위치의 만족도를 얻기 위한 소속함수
Fig. 5. Membership Functions for Positions

학습데이터는 히스토그램을 얻기 위해 채취한 데이터중 각 객체당 60개의 데이터를 임의로 선택하여 이들의 속성값으로부터 각 객체의 만족도를 구한 후 해당 객체의 요구된 만족도는 0.99, 그렇지 않은 객체는 0.01로 하여 전체 180개의 데이터를 이용하였다. 학습은 일반화된 평균과 γ -모델을 가정하였고, 학습

율은 10^{-3} 로 설정하고, 모든 파라미터 값의 변화가 10^{-3} 이하 이면 학습을 종료하였다. 학습시 사용한 망구조는 그림 6(a)와 그림 6(b)와 같다. 그림 6(a)의 경우 학습후의 파라미터들은 일반화된 평균을 적용하였을 경우 모든 단의 융합 연산자가 보상적인 성향이였으며 ($-2 < p < 2$), γ -모델의 경우는 γ 값이 0.9 이상으로 다소 합 연산자와 같은 성질을 나타내었다. 그림 6(a)의 학습의 종료까지 일반화된 평균의 경우 반복 횟수는 86회, γ -모델의 경우는 356회 이었다. 또한 학습후의 가중치로부터 위치와 질감 속성은 “도로”를 인식하는데 다소 무관한 성질을 나타냄을 알 수 있었고, “숲” 영역의 경우 국부동질성 질감속성이 강하게 작용함을 알 수 있었다. 또한 그림 6(b)의 망구조를 이용하였을 경우 일반화된 평균연산자의 경우 822회, γ -모델의 경우 482회의 반복후 학습이 종료하였으며, 질감속성들이 “하늘”과 “도로”의 구별에 적합하지 않고, “숲”을 구별하는 데는 우수한 특성임을 나타내었다.



(a) 망 구조 1



(b) 망 구조 2


그림 6. 영상 분할 및 인식에 사용한 망 구조
Fig. 6. Network Structures for Image Segmentation

학습후 구해진 연산자들은 학습 영상과 검증 영상의 분할과 인식에 이용하였다. 분할과 인식 과정에서는 각 화소의 속성을 추출하고 학습 데이터를 구성한

동일한 히스토그램 및 사다리꼴 함수로부터 각 객체에 대한 만족도를 구하고, 이를 망에 전파시켜 총체화된 만족도가 가장 큰 객체로 인식하였다. 그림 7에는 학습 데이터를 채취한 영상과 검증 영상의 인텐시티 속성을 보였고, 그림 8에는 그림 6(a)의 망구조에 일반화된 평균 연산을 이용할 경우의 학습 영상과 검증 영상의 분할 및 인식 결과를 그림 9에는 그림 6(b)의 망 구조에 γ -모델을 이용할 경우의 분할과 인식 결과를 보였다. (그림 6(a) 망구조에 γ -모델을 이용할 경우의 학습 영상과 검증 영상의 분할 및 인식 결과와 그림 7(b) 망 구조에 일반화된 평균 연산을 이용할 경우의 분할과 인식 결과는 유사하여 생략함)




(a) 학습 영상



(b) 검증 영상

그림 7. 학습 영상과 검증 영상의 인텐시티 속성
Fig. 7. Intensity Features for Training and Test Images




(b) 검증 영상의 경우

그림 8. 분할되어 인식된 영상(그림 6(a)의 구조와 일반화된 평균 연산자)

Fig. 8. Results of Segmentation and Labelling (Fig. 6(a) with Generalized Mean)




(a) 학습 영상의 경우



(b) 검증 영상의 경우

그림 9. 분할되어 인식된 영상(그림 6(b)의 구조와 γ -모델)
Fig. 9. Results of Segmented and Labeled Images (Fig. 6(b) with γ model)



(a) 학습 영상의 경우

V. 결 론

본 논문에서는 퍼지 보상 연산자를 이용하는 정보 융합 방법을 제안 하였다. 제안된 방법에서는 평가지수들의 계층적 체계를 이용하여 [0, 1]의 평가지수의 만족도들을 일반화된 평균 연산자와 Zimmermann의 γ -모델로 융합하여 전파할 수 있는 망을 구성하였다. 이를 융합에 필요한 연산자들은 역오류전과 학습 방법에 의해 학습 데이터로부터 추출된 파라미터 값을 조정하므로써 결정되는데, 학습 결과는 학습 데이터

에 나타난 정보원의 중요성이나 보상정도를 표현할 수 있다. 따라서, 퍼지 적분이나 퍼지 수등을 이용하는 정보 융합 방법들에 있어서 임기응변적으로 가중치를 부가하는 단점이 없으며, Bayes 규칙을 이용하는 방법이나, 믿음 이론의 Dempster의 규칙 적용에서 같은 제약이 없게 된다.

한편, 패턴 분류 문제에서 보았듯이 제안된 학습 방법은 불필요한 정보원에 부가된 가중치를 작게 만들어 의사 결정에 반영 시키지 않는 특성이 있다. 즉 정보원들이 패턴 인식에 있어서 속성들이라면 속성의 수를 감소(feature reduction) 시키는 성질도 가지고 있다고 말할 수 있다. 여기서 불필요한 정보원의 제거란 redundancy를 증가 시켜서 의사결정의 강인성을 증가시키는 정보원을 포함 시키지는 않는다. 또한 칼라 영상 분할과 인식실험을 통하여 제안된 방법이 영상의 객체 인식에도 적용 가능함을 보였다. 칼라 영상 분할 및 인식 실험에서 사용했던 방법은 Riseman^[24] 등이 이용한 방법과 유사하나 가중치등을 임기응변적으로 부가하지 않고 학습에 의해 자동적으로 구해질 수 있다는 점이 장점이다.

또한, 본 논문에서는 Zimmermann의 γ -모델이 γ 값에 따라 단조 증가 함수라는 사실을 증명하였고, 식 (15)와 (16)에서와 같이 가중치등의 제약 조건있는 최적화 문제를 계층적 망에서 해결하는 간단한 방법을 제시하였다. 제안된 방법의 문제점으로는 일반적인 gradient를 이용하는 역전파 학습으로 인한 국부 최소치 문제와 느린 수렴속도등을 들 수 있다. 본 논문에서 사용한 활성화 함수는 logistic 함수들과는 다르기 때문에 현재 제작되는 신경회로망의 하드웨어로는 구현이 불가능하며, 이를 가능하게 하기 위해서는 비선형 아나로그회로의 개발이 필요하다.

참 고 문 헌

1. Andress, K. M., and Kak, A. C., "Evidence Accumulation and Flow of Control in a Hierarchical Spatial Reasoning System," *Artificial Intelligence Magazine*, pp.75-94, Summer 1988.
2. Dubois, D., and Prade, H., "A Class of Fuzzy Measures Based on Triangular Norms," *International Journal of General Systems*, vol.8, No.1, pp. 43-61, 1982.
3. Dubois, D., and Prade, H., "A Review of Fuzzy Set Aggregation Connectives," *Information Sciences*, vol.36, No.1&2, pp.85-121, 1985.
4. Dyckhoff, H., and Pedrycz, W., "Generalized Means as a Model of Compensation Connectives," *Fuzzy Sets and Systems*, vol.14, No.2, pp. 143-154, 1984.
5. Gordon, J., and Shortliffe, H., "A Method for Managing Evidential Reasoning in a Hierarchical Hypothesis Space," *Artificial Intelligence*, vol.26, pp.323-357, 1985.
6. Keller, J., Hobson, G., Wotton, J., Nafarieh, A., and Luetkemeyer, K., "Fuzzy Confidence Measures in Midlevel Vision," *IEEE Trans. on SMC*, vol.17, No.4, pp.676-683, 1987.
7. Klir, G. J., and Folger, T. A., *Fuzzy Sets, Uncertainty and Information*, Prentice Hall, Englewood Cliffs, NJ, 1988.
8. Krishnapuram, R., and Lee, J., "Fuzzy-Connective-Based Hierarchical Aggregation Networks for Decision Making," *Fuzzy Sets and Systems*, vol.46, no.3, 1992.
9. Krishnapuram, R., and Lee, J., "Propagation of Uncertainty in Neural Networks," *Proceedings of the SPIE Conference on Intelligent Robots and Computer Vision*, Cambridge MA, pp.377-383, November, 1988.
10. Krishnapuram, R., and Lee, J., "Determinating the Structure of Uncertainty Management Networks," *Proceedings of the SPIE Conference on Robotics and Computer Vision*, Philadelphia, 1989.
11. Lee, J., *Fuzzy-Connective-Based Information Fusion Networks and Their Application to Computer Vision*, Ph. D. Dissertation, Dept. of Electrical and Computer Engineering, University of Missouri in Columbia, Aug 1990.
12. Li, Z., "Uncertainty Management in a Pyramid Vision System," *International Journal of Approximate Reasoning*, vol.3, No.1, pp.59-85, 1989.
13. Mitiche, A., and Aggarwal, J. K., "Multiple Sensor Integration/Fusion through Image Processing: A review," *Optical Engineering*, vol.25, No.3, pp.380-386, 1986.

14. Mizumoto, M., "Pictorial Representations of Fuzzy Connectives, Part I : Cases of t-norms, t-conorms, and Averaging Operators," *Fuzzy Sets and Systems*, vol.31, pp.217-242, 1989.
15. Mizumoto, M., "Pictorial Representations of Fuzzy Connectives. Part II : Cases of Comensatory Operators, and Self-Dual Operators," *Fuzzy Sets and Systems*, vol.32, pp.45-79, 1989.
16. Ohta, Y., *Knowledge-based interpretation of outdoor natural color scenes*, Boston, MA : Pitman Advanced Publishing Inc, 1985.
17. Pearl, J., "Fusion, Propagation, and Structuring in Belief Networks," *Artificial Intelligence*, vol.29, No.3, pp.241-288, 1986.
18. Riseman, E. M, & Hanson, A. R., A methodology for the development of general knowledge-based vision systems in M. A. Arbib (Ed.), *Vision Systems and Cooperative Computation*(pp.285-313), Cambridge, MA : MIT Press.
19. Tahani H. & Keller J. M., "Information Fusion in Computer Vision Using the Fuzzy Integral," *IEEE Trans. on SMC*, vol.20, No.3, May/June 1990.
20. Rumelhart, D. E., McClelland, J. M., and the PDP Research Group, *Parallel Distributed Processing*, Chapter 8, vol.1, MIT Press, 1986.
21. Thole, U., and Zimmermann, H.-J., "On the Suitability of Minimum and Product Operations for the Intersection of Fuzzy Sets." *Fuzzy Sets and Systems*, vol.2, pp.167-180, 1979.
22. Yager, R. P., "On a General Class of Fuzzy Connectives," *Fuzzy Sets and Systems*, vol.4, pp.235-242, 1980.
23. Zimmermann, H.-J., and Zysno, P., "Latent Connectives in Human Decision Making," *Fuzzy Sets and Systems*, vol.4, No.1, pp.37-51, 1980.
24. Zimmermann, H.-J., and Zysno, P., "Decisions and Evaluations by Hierarchical Aggregation of Information," *Fuzzy Sets and Systems*, vol.10, No.3, pp.243-260, 1983.

이 논문은 1991년도 교육부 지원 한국 학술진흥 재단의 자유공모(지방대학육성) 과제 학술연구 조성비에 의하여 연구되었음.

李俊煥(Joon Whoan Lee)

정회원

1980년 2월 : 한양대학교 전자공학과(공학사)
 1982년 2월 : 한국과학원 전기 및 전자공학과 졸업(공학석사)
 1990년 8월 : 미국 미주리대학교 전기 및 컴퓨터공학과 졸업(공학박사)
 1985년 : 전북대학교 전자공학과 전임강사
 1990년 : 전북대학교 전자공학과 조교수
 ※주관심분야: 인공지능, 영상처리 및 인식, 퍼지이론 및 신경회로망



金贊星(Chan Seong Kim) 정회원

1992년 2월 : 전북대학교 정보통신공학과(공학사)
 1992년 3월 ~ 현재 : 전북대학교 전자공학과 석사과정
 ※주관심분야: 영상처리 및 인식, 인공지능



嚴景培(Kyoung Bae Eum) 정회원

1984년 2월 : 전북대학교 전자공학과(공학사)
 1986년 2월 : 전북대학교 대학원 전자공학과(공학석사)
 1990년 8월 : 전북대학교 대학원 전자공학과(공학박사)
 1989년 3월 ~ 1991년 2월 : 군산대학교 전산통계학과 전임강사

1991년 3월 ~ 현재 : 군산대학교 컴퓨터과학과 조교수
 ※주관심분야: 영상처리 및 방렬처리, 퍼지이론 및 신경회로망