

적응 퍼지 시스템을 이용한 칼라패턴 감성 평가 모델에 관한 연구

A Study on the Emotional Evaluation Model of Color Pattern Based on Adaptive Fuzzy System

두성한 · 엄경배* · 이준환

Sunghan Doo, Kyoungbae Eum* and Joonwhoan Lee

전북대학교 전자공학과, *군산대학교 컴퓨터과학과

요 약

본 논문에서는 칼라패턴의 물리적 속성을 감성속성으로 변환시켜 주는 적응퍼지시스템을 기반으로 한 감성평가모델을 제안하였다. 감성평가모델은 칼라패턴의 물리적 속성인 평균색상, 평균채도, 평균명도, 주파수 성분이 서로 상반되는 의미를 갖는 형용사 쌍으로 표현되는 감성속성에 영향을 준다는 Soen의 심리학적 실험을 기초로 하였다. 제안된 모델은 두 개의 적응퍼지시스템과 이 시스템으로부터 얻어지는 감성평가치를 융합하기 위한 퍼지 집합 연산자인 γ 모델로 구성되었다. 실험결과 본 논문에서 제안한 모델이 비선형 모델을 근사화하는 신경회로망 모델과는 근접한 결과를 제공하였고, 훈련된 결과로부터 얻어진 해석이 용이함을 보였다. 제안된 모델에 의한 감성평가결과는 감성을 기반으로 하는 칼라패턴의 검색에 이용될 수 있을 것으로 기대된다.

ABSTRACT

In the paper, we propose an evaluation model based the adaptive fuzzy systems, which can transform the physical features of a color pattern to the emotional features. The model is motivated by the Soen's psychological experiments, in which he found the physical features such as average hue, saturation, intensity and the dynamic components of the color patterns affects to the emotional features represented by a pair of adjective words having the opposite meanings. Our proposed model consists of two adaptive fuzzy rule-bases and the γ -model, a fuzzy set operator, to fuze the evaluation values produced by them. The model shows comparable performances to the neural network for the approximation of the nonlinear transforms, and it has the advantage to obtain the linguistic interpretation from the trained results. We believe the evaluated results of a color pattern can be used to the emotion-based color image retrievals.

1. 서 론

색채 환경은 그것을 보고 느끼는 인간의 감성에 많은 영향을 주고 있으며, 특히 패션이나 상품의 디자인 등의 분야에서 제품의 경쟁성을 위해 감성에 알맞은 색채의 선택적인 사용은 대단히 중요하다. 이러한 이유 때문에 일찍부터 색채가 인간의 감성에 어떠한 영향을 미치는가 하는 것은 색채 심리학 분야에서 매우 중요한 연구 분야가 되어왔다[1-3].

이 색채 심리학의 연구 분야 중에 하나가 다양한 색을 가진 옷감이나 벽지와 같은 칼라 패턴에 대한 인간의 감정을 객관적으로 평가하고, 이러한 평가치를 얻어적인 이미지 스케일에 표현하려는 시도이다. 예로써 일본의 색채 심리학자 Soen 등은 다양한 랜덤 칼라패턴을 제작하여 설문조사를 통하여 피험자가 느끼는 감성을 13가지의 서로 반대되는 이미지 스케일 상에 나타내도록 하는 심리학적 실험을 수행하였다[4].

이들은 랜덤 칼라패턴의 색상 및 채도와 Fourier 주파수 영역에서의 에너지 분포가 감성과의 밀접한 관계가 있음을 실험결과를 통하여 입증하였고, 이러한 칼라패턴의 속성과 13개의 이미지 스케일 값들 사이의 변환 관계를 다중회귀 분석 방법을 이용한 모델로 규정할 수 있음을 보고하였다[5]. (이하, 본 논문에서는 칼라패턴으로부터 얻어지는 평균 색상, 평균 채도, Fourier 주파수 영역에서의 에너지 분포를 물리적 속성이라고 명명하며, 이속성들이 모델을 통하여 변환된 13개의 이미지 스케일 상의 값을 감성 속성이라 명명함)[6].

이러한 Soen등의 실험결과에 대한 모델은 칼라패턴을 분석하여 이를 보고 느끼는 평균적인 인간의 감성을 기계로 하여금 평가하는데 이용될 수 있을 뿐만 아니라, 얻어진 감성 평가치는 새로운 속성으로 감성을 기반으로 하는 칼라패턴의 분류 및 검색에 이용될 수 있다. 그러나, 칼라 패턴의 Soen 등의 다중회귀

방법을 이용한 비선형 모델은 근사화 능력이 떨어져서 피험자의 평가치와 잘 일치하지 않았다. 따라서 Lee 등은 비선형 함수의 근사화 능력이 우수한 신경회로망 모델을 제안하였고 Soen의 비선형 모델에 비해 상관관계 및 실제 칼라패턴 적용시 인간의 평가치와의 근접성 측면에서 우수함을 입증하였다[6].

그러나, 모델의 우수성을 평가하는 척도는 근사화 성능 뿐만 아니라, 학습 등의 근사화 과정을 통하여 얻어진 외부적인 결과가 내부적으로 어떠한 의미를 갖는지를 알아내는 것도 중요하다. 신경회로망 모델은 학습결과가 여러 노드에 분산되어 나타나는 형태이기 때문에 훈련 결과를 언어적인 규칙등으로 해석하는 데 어려움이 있다. 따라서, 본 논문에서는 신경회로망의 grandmother cell(망의 각 노드에 의미를 부여할 수 있는 네트워크의 노드를 의미함)의 개념을 부여할 수 있는 적용 퍼지시스템과 의사결정에 기여하는 부시스템의 평가치를 융합하는 네트워크로 표현된 새로운 평가 모델을 제안하였다.

본 논문의 모델은 Soen 등이 자신들의 심리학적인 실험결과의 언어적 근사화를 수행한 결과에 영향을 받았으며, 실험결과 근사화 능력에 있어서는 신경 회로망과 유사한 능력을 가질 수 있으며, 추가적으로 훈련 결과에 대한 Soen등의 언어적인 해석과도 관련이 있음을 실험적으로 확인하였다.

본 논문의 구성은 2절에서 Soen 등의 심리학적인 실험 결과와 디중회귀 분석에 의한 비선형 모델, 근사화 능력을 개선한 신경회로망 모델 및 제안된 적용 퍼지 시스템 모델을 소개하였으며, 3절에서는 이를 평가 모델의 성능을 실험을 통해 비교하였으며, 제안된 적용 퍼지 시스템을 이용한 모델의 장점을 검토하였고, 끝으로 4절에서는 본 논문의 목적과 제안한 모델의 의미와 향후 연구방향을 서술하였다.

2. 칼라패턴의 감성평가모델

칼라패턴을 감성적으로 평가하는 시스템을 구현하기 위해서는, 심리학적인 실험을 통하여 실제로 사람들이 칼라패턴을 보고 느끼는 감성에는 어떠한 종류가 있으며, 칼라패턴을 보고 이를 감성척도에 사람들이 평균적으로 어떠한 감성 평가치를 제공하는가에 대한 데이터가 필요하다. 일본의 심리학자 Soen 등은 피실험자들로 하여금 칼라패턴을 보고 느끼는 감정의 정도를 13개의 상반된 의미의 형용사로 기술되는 이미지 스케일상에 표시하게 하고 그 결과를 분석하여 칼라패턴의 물리적인 속성과 감성 평가치 사이의 관계를 비선형 모델로 규정할 수 있다고 보고하였다[3,4].

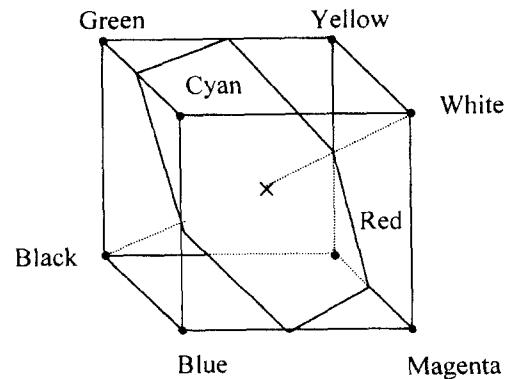


그림 1. RGB 색좌표계

본 절에서는 Soen 등의 심리학적인 실험 내용을 요약하고, 그들의 디중회귀분석에 의한 비선형 모델 및 Lee 등에 의해 제안된 신경회로망 모델에 대해 언급하고 언어적 규칙을 학습결과로부터 추출할 수 있는 적용 퍼지 시스템을 이용하는 새로운 모델을 제안한다.

2.1 Soen의 심리학적 실험 및 기준의 감성 평가 모델

2.1.1 Soen의 심리학적 실험

Soen 등이 감성평가에 이용한 랜덤 칼라패턴은 모두 30개로 칼라패턴의 크기가 256×256 로, 도트크기가 4×4 이며 평균명도가 같고 색조가 다른 18개의 패턴과 4개씩의 2×2 , 4×4 , 8×8 의 도트크기를 갖는 평균색조가 동일하고 평균명도가 다른 패턴 12개로 구성된다.

생성된 30개의 랜덤 칼라패턴의 분포는 그림 1에서와 같이 RGB 색좌표계의 칼라 정육면체에 나타낼 수 있는데, 여기서 평균명도가 같고 색조가 다른 랜덤 칼라패턴 18개는 정육면체 내의 육각형 평면에 분포하며, 평균색조가 동일하고 평균명도와 도트크기가 다른 랜덤 칼라패턴 12개는 Black과 White를 잇는 직선상에 나타나게 된다. 이는 칼라패턴의 색조(색상과 채도) 분포에 대한 피실험자들의 반응과 명도 분포에 대한 반응을 실험할 수 있게 구성한 것이다[4].

Soen 등은 이렇게 구성된 30가지의 랜덤 칼라패턴을 스크린에 투사하고 패턴을 보고 느끼는 감정의 정도를 13가지로 이루어진 이미지 스케일 상에 7~1의 값으로 표시하게 하였다. 실험에 사용된 13가지의 이미지 스케일은 ‘like-dislike’, ‘beautiful-ugly’, ‘natural-unnatural’, ‘dynamic-static’, ‘warm-cold’, ‘gay-sober’, ‘cheerful-dismal’, ‘unstable-stable’, ‘light-dark’, ‘strong-weak’, ‘gaudy-plain’, ‘hard-soft’, ‘heavy-light’ 등이다.

또한 이들은 실험으로부터 얻은 데이터의 분석결과를 그림 2와 그림 3과 같이 요약하였다. 동일명도의 랜덤 칼라 패턴에 대한 실험결과는 그림 2와 같으며, 그림에서 원의 중심은 랜덤 칼라패턴의 육각형 평면상의 위치이며, 반경은 실험결과 값으로 반경이 큰 부분은 큰 영향을 주는 것을 의미하고 작은 원은 반대의

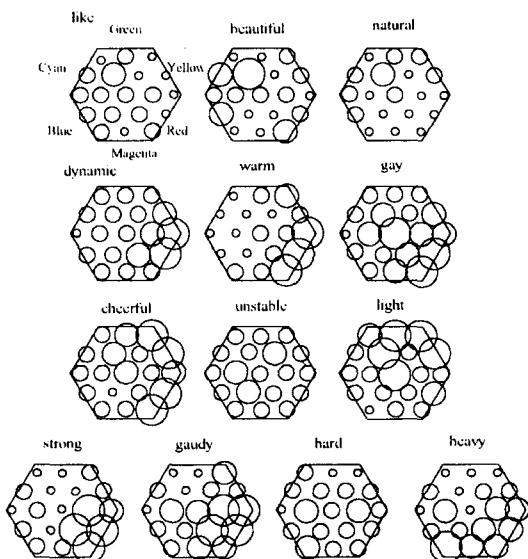


그림 2. 그림 1의 육각형 평면에 나타나는 칼라패턴의 감성 평가치

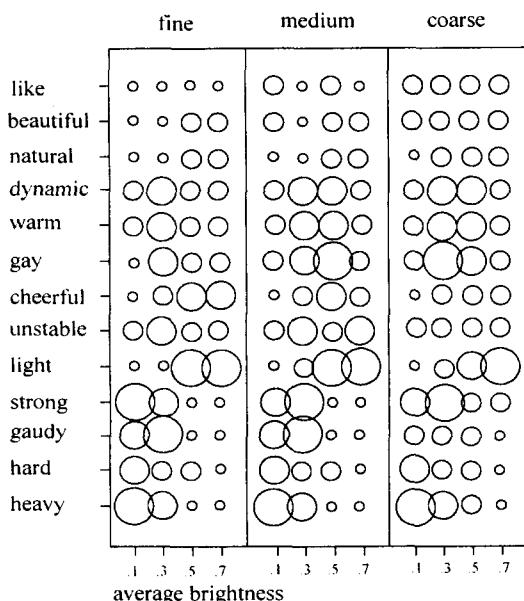


그림 3. 그림 1의 gray line을 따라 나타나는 칼라패턴의 감성 평가치

의미에 큰 영향을 줌을 의미한다. 평균색조가 동일하고 평균명도와 도트크기가 다른 랜덤 칼라패턴에 대한 실험결과는 그림 3과 같으며, 원의 중심은 랜덤 칼라패턴의 평균밝기를 나타내고, 원의 크기는 실험결과 값의 그림 2와 동일한 의미를 가진다. 예를 들어 warm-cold 이미지 스케일의 경우 채도가 높은 붉은 색상의 경우 매우 따듯한 느낌을 주고, 붉은 색의 보색 계통인 푸른색 계통은 채도와 상관없이 차가운 느낌을 준다는 결과이며, 명도가 낮을 경우 도트크기를 나타내는 질감성분과 무관하게 무거운 느낌을 준다는 것이다. 이상의 실험 결과는 칼라패턴을 보고 느끼는 감성은 평균 색상 및 채도, 평균 밝기, Fourier 변환시 저주파, 중간 주파, 고주파 성분 등의 물리적인 속성에 의해 영향을 받는다는 것을 의미한다.

Soen은 이러한 실험결과를 바탕으로 칼라패턴으로부터의 물리적 속성을 입력하였을 때 13가지의 이미지 스케일에 대한 등급을 출력하는 감성 평가시스템을 제안하였다. 사용된 칼라패턴의 물리적 속성은 시감의 등보성이 유지되는 CIE-LUV 좌표계의 평균칼라 성분인 L^* , u^* , v^* 와 주파수 성분인 D_L , D_M , D_H 의 6가지 속성이다. 이 물리적 속성 추출과정은 그림 4와 같다.

이 물리적 속성을 감각언어의 칼라패턴의 심리적 척도에 대응하는 감성속성을 추출하기 위하여

$$\begin{aligned} P_i = & c_{i_1} + c_{i_2} \bar{u}^* + c_{i_3} \bar{v}^* + c_{i_4} \bar{L}^* + c_{i_5} \bar{u}^{*2} + c_{i_6} \bar{u}^* \bar{v}^* \\ & + c_{i_7} \bar{v}^{*2} + c_{i_8} \bar{v}^{*3} + c_{i_9} \bar{u}^{*2} \bar{v}^* + c_{i_{10}} \bar{u}^* \bar{v}^{*2} \\ & + c_{i_{11}} \bar{v}^{*3} + c_{i_{12}} D_L + c_{i_{13}} D_M + c_{i_{14}} D_H \end{aligned} \quad (1)$$

과 같은 모델을 제안하고 다중회귀분석(multiple regression analysis)방법을 이용하여 계수들을 구하였다[2]. 여기서 P_i 는 13개의 이미지 스케일 중 i 번째 스케일의 심리적인 척도값을 나타낸다.

2.1.2 신경회로망을 이용한 칼라패턴의 감성 평가 모델

전 항에서 언급된 식 (1)에 의한 비선형 평가 모델은 비선형함수의 근사화 능력에 있어서 심리학적인 실험 데이터와의 정합정도가 뛰어난 성능을 발휘하지 못

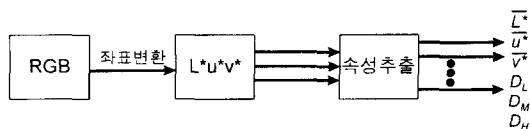


그림 4. 칼라패턴의 물리적 속성 추출

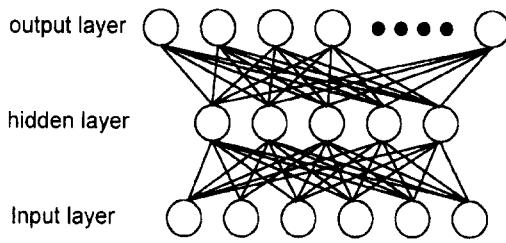


그림 5. 신경회로망 구조

하였다. 따라서 Lee 등은 보다 정확한 근사화를 위해서 다층 신경회로망을 이용한 감성 평가 모델을 제안하고 오류 역전파 학습에 의해 근사화를 시도하였다. Lee 등의 신경회로망 모델을 이용한 평가 시스템에서는 Soen등의 평가 시스템과의 비교를 위해서 Soen등이 사용한 \bar{L}^* , \bar{u}^* , \bar{v}^* , D_L , D_M , D_H 의 6가지의 물리적 속성을 그대로 사용하였다[6]. 그 결과 신경회로망의 경우 경우는 은닉층(hidden layer)을 거치면서 6가지 입력들이 서로 비선형 조합되므로 6가지 특성의 독립적인 특성뿐만 아니라, 각 항들의 곱해지는 항들에 의해 포괄적인 비선형 특성이 고려되기 때문에 더욱 심리학적인 실험 데이터에 근접한 정합특성을 얻었다. Lee 등이 제안한 신경회로망 구조는 그림 5와 같다. 그림 5에서 입력은 6개의 물리적인 속성을 의미하고, 출력은 정규화된 13개의 이미지 스케일에서의 감성 속성들을 의미한다.

2.2 적응퍼지 시스템을 이용한 감성평가 모델

본 논문에서 제안하는 감성평가 모델은 그림 2와 그림 3의 심리학적인 실험 결과로 부터 유래된다. 그림의 내용을 언어적으로 분석해 보면 칼라패턴의 색조가 red에 가까우면 ‘warm’한 느낌을 강하게 받으며 ‘green’이나 ‘yellow’에 가까우면 ‘light’한 감성을 받을 수 있음을 알 수 있다. 또 명도가 높아질수록 ‘light’한 느낌을 받음을 알 수 있다. 이러한 불명료한 규칙과 그림 2와 그림 3의 내용을 조합할 수 있는 도구의 필요성 때문에 본 논문에서는 칼라패턴의 감성적 평가를 위한 적응 퍼지 시스템 모델을 제안하였다.

2.2.1 칼라패턴의 물리적 속성추출

본 논문에서 제안한 감성평가 모델에서는 물리적 속성을 Soen 등의 감성평가 시스템과는 다르게 설정하였다. 그 이유는 Soen 등의 심리적 실험의 원시 데이터는 그림 2와 그림 3에서 볼 수 있듯이 평균 색상과 평균 채도, 평균 명도와 칼라패턴의 질감 성분에 해당하는 공간 영역에서 도트크기의 밀하고 소한 정

도이기 때문에 Fourier 변환 영역의 저주파, 중간 주파 고주파 대역의 에너지를 사용한 것 보다 더 실험 내용에 가까울 수 있다는 판단 때문이었다.

즉 그림 2에 따른 평균색조와 심리적 평가치에 대하여 다음과 같은 언어적 규칙들을 가정할 수 있다.

‘평균 색조가 red 부근이면 ‘warm’한 느낌을 받는다.’ ①

‘평균 색조가 blue 부근이면 ‘like’한 느낌을 받는다.’ ②

마찬가지로 그림 3에서는 평균명도와 도트크기에 대하여 다음과 같은 규칙의 예들을 가정할 수 있다.

‘평균 밝기가 높으면 ‘light’의 느낌을 받는다.’ ③

‘도트크기가 coarse이면 ‘like’의 성향이 커진다.’ ④

이러한 언어적 규칙에서 알 수 있듯이 감성평가 모델의 입력은 그림 2와 그림 3을 모델링할 경우 평균색조, 평균 명도, 도트크기이다. 그러나 칼라패턴의 색조를 RGB 공간상에서는 표현할 수 없기 때문에 칼라 패턴의 red, green, blue 각각의 평균값을 색상, 명도, 채도로 나타내는 HSI 칼라공간으로 변환하였다. 따라서, HSI 공간의 HS 평면은 그림 2의 색조를 나타내는 육각형에 해당한다. 그런데, HS 평면은 각도와 크기로 표시되는 극좌표계가 나타나므로 그림 2의 내용을 쉽게 모델링하기 위해 HS 평면을 V_a , V_b 로 표현되는 각각 좌표계로 변환하여 색조를 표시하였다.

$$V_a = S \cdot \cos H \quad (2)$$

$$V_b = S \cdot \sin H \quad (3)$$

여기서 $0^\circ \leq H \leq 360^\circ$ 이고, $0 \leq S \leq 1$ 이므로 $0 \leq \sqrt{V_a^2 + V_b^2} \leq 1$ 이 된다. 평균 명도는 HSI 좌표 변환 후 R 값을 그대로 사용하였다.

도트의 크기에 대해서는 Soen 등의 모델에서 Fourier 주파수 대역의 에너지를 이용한 것과 다른 속성을 이용하였다. 랜덤 칼라패턴의 도트 크기는 Fourier 영역보다는 공간 영역에서 영상의 질감이 밀하고 소한 정도를 나타낼 수 있다. 따라서 ④의 논리를

‘영상이 소하면 ‘like’의 성향이 커진다.’ ⑤

로 바꾸어 가정할 수 있다. 따라서 제안된 모델에서

사용한 질감 특성은 공간영역의 영상의 밀하고 소한 정도를 잘 표현하는 영상의 GLRLM(Gray Level Run Length Matrix)을 이용하여 구하였다. GLRLM은

$$GLRLM(m, n) = \text{Card}[\{(i, j) \in \Delta_{MN} \mid I(i, j) = m, \pi(M, \theta) = n\}] \quad (4)$$

로 표현된다. 여기서 Δ_{MN} 은 $M \times N$ 의 격자이고 $I(i, j)$ 는 격자내 (i, j) 위치의 화소 값이다. $I(m, \theta)$ 는 θ 방향의 화소값 m 의 run-length에 해당하며 Card는 집합의 원소개수(cardinality)이다. GLRLM의 방향특성을 없애기 위해 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 에 대한 GLRLM 값을 산술평균 하였고 GLRLM의 모든 run-length의 합이 1이 되도록 정규화하였다. 최종적으로 제안된 모델에서 이용한 질감특성 C 는 GLRLM의 스칼라 척도인 SRE(Short Run Emphasis)로 구하였다[7].

$$SRE = \sum_m \sum_n GLRLM(m, n)/n^2 \quad (5)$$

식 (5)에서 run-length가 평균적으로 짧아서 GLRLM (m, n) 행렬의 작은 m 값의 범위에 큰 값을 가지면 SRE 값은 커지고, 반대의 경우에는 작아진다. 즉 밀한 영상에서는 SRE가 커지고 소한 영상에서는 작아지는 특성이 있다. 그림 6은 R, G, B 칼라 패턴으로부터 제안된 모델에 사용하는 물리적 속성의 추출과정을 나타낸다.

2.2.2 칼라패턴의 감성속성 추출

그림 2와 3의 Soen등의 실험결과는 새로 정의된 4 가지 물리적 속성과 심리적 평가치 사이의 변환을 위해 퍼지 IF-THEN 규칙 즉, 언어적 규칙을 설정할 수 있다. 그림 2에서 1번쨰 이미지 스케일에서 V_a, V_b 에 대한 퍼지 규칙 기반은

$$R^i : \text{IF } V_a \text{ is } \begin{bmatrix} \text{positive} \\ \text{zero} \\ \text{negative} \end{bmatrix} \text{ and } V_b \text{ is } \begin{bmatrix} \text{positive} \\ \text{zero} \\ \text{negative} \end{bmatrix}, \text{ THEN } EV_1 \text{ is } \begin{bmatrix} \text{High} \\ \text{Middle} \\ \text{Low} \end{bmatrix} \quad (6)$$

이고, 그림 3의 I와 C에 대하여서도

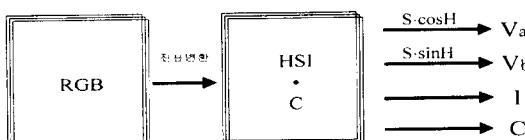


그림 6. 제안된 모델에서 사용되는 물리적 속성 추출

$$R^i : \text{IF } I \text{ is } \begin{bmatrix} \text{High} \\ \text{Middle} \\ \text{Low} \end{bmatrix} \text{ and } C \text{ is } \begin{bmatrix} \text{fine} \\ \text{medium} \\ \text{coarse} \end{bmatrix}, \text{ THEN } EV_2 \text{ is } \begin{bmatrix} \text{High} \\ \text{Middle} \\ \text{Low} \end{bmatrix} \quad (7)$$

와 같이 설정할 수 있다. 여기서 EV_1^i, EV_2^i 는 13개의 척도중 1번쨰 이미지 스케일에 대한 평가치이다.

따라서 제안한 평가모델은 위 두 가지 퍼지 규칙기반에 해당하는 V_a, V_b 가 입력인 적응 퍼지 시스템과 I, C 가 입력인 적응 퍼지 시스템으로 구성되며, 두 시스템으로부터의 평가치를 융합하기 위해 퍼지 접속연산자의 일종인 γ -모델을 이용하였다.

2.2.3 제안된 감성평가 시스템의 구조

제안된 평가 시스템의 전체 블록 다이어그램은 그림 7과 같다. 그림에서 알 수 있듯이 제안된 모델은 V_a, V_b 를 입력으로 하는 그림 2에 해당하는 적응퍼지 시스템과 I, C 를 입력으로 하는 그림 3에 해당되는 적응퍼지 시스템 및 이들로부터의 평가치를 정규화하여 0과 1사이의 평가치를 만드는 정규화 부분, 또한 정규화된 두 개의 평가치를 μ 모델에 의해 조합하는 융합부분으로 구성된다.

2.2.3.1 적응 퍼지 시스템

퍼지 규칙기반은 언어적 퍼지 변수와 불명료한 용어들로 구성된 변수의 값들로 구성되어진 IF-THEN 형태의 일련의 규칙들을 의미한다. 이들 변수들의 값들은 일반적으로 불명료하기 때문에 임의적인 값으로 표현되기보다는 개념상의 공간에 정의된 소속함수로 표현된다.

퍼지규칙기반 제어 등에 이용되는 적응 퍼지 시스템을 product inference rule, singleton fuzzifier, center average defuzzifier를 채택할 경우 적응 퍼지

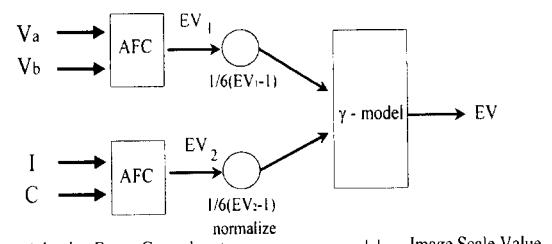


그림 7. 적응퍼지시스템과 γ -모델을 이용하는 제안된 평가 모델

시스템의 출력은

$$f(x) = \frac{\sum_{l=1}^M \bar{y}^l \left(\prod_{i=1}^n \mu_{F_i^l}(x_i) \right)}{\sum_{l=1}^M \left(\prod_{i=1}^n \mu_{F_i^l}(x_i) \right)} \quad (8)$$

과 같이 표현할 수 있다. 여기에서 \bar{y}^l 은 $\mu_{F_i^l}$ 이 최대가 되는 값으로 $\mu_{F_i^l}(\bar{y}^l) = 1$ 을 가정한다. 이와 같은 퍼지 논리 시스템을 학습 알고리즘을 이용하여 개발하기 위해서 소속 함수 $\mu_{F_i^l}$ 을 함수의 형태로 명시할 필요가 있다. 소속함수를 Gaussian 함수를 이용하면

$$\mu_{F_i^l}(x_i) = a_i^l \exp \left[- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right] \quad (9)$$

와 같다. 식 (9)를 식 (12)에 대입하면 규칙기반 시스템의 출력은

$$f(x) = \frac{\sum_{l=1}^M \bar{y}^l \left[\prod_{i=1}^n a_i^l \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \right]}{\sum_{l=1}^M \left[\prod_{i=1}^n a_i^l \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \right]} \quad (10)$$

과 같다. 여기서 $f = a/b$, $a = \sum_{l=1}^M (\bar{y}^l z^l)$, $b = \sum_{l=1}^M z^l$, $a_i^l = 1$, $z^l = \prod_{i=1}^n \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right)$ 으로 한다[8]. 이와 같

은 퍼지 논리 시스템은 함수의 근사화 관점에서 볼 때, 비선형 시스템을 모델링하는데 사용될 수 있으며, 제안된 모델에서 적용 퍼지시스템은

$$EV_1 = f(V_a, V_b) \quad (11)$$

에 의해 동일 명도 평면상의 평균 색상과 채도의 함수로서 이미지 스케일의 감성 평가치를 구하는 부분과

$$EV_2 = f(I, C) \quad (12)$$

에 의해 white-black 축상의 평균 명도와 패턴의 질감의 밀하고 소한 정도를 나타내는 부분으로 구성되며 평가치 EV_1 과 EV_2 는 1부터 7까지의 이미지 스케일 상의 값을 의미한다. 또한 적용퍼지 시스템에서 심리학적 실험 데이터와 정합을 위해 조정되어야 할 파라미터들은 a_i^l , \bar{x}_i^l , σ_i^l , \bar{y}^l 이다.

2.2.3.1 정규화 과정

전술한 바와 같이 적용 퍼지 시스템 출력 EV_1 과 EV_2 는 1부터 7까지의 이미지 스케일 상의 값으로 두

시스템의 융합을 위해 사용한 퍼지 접속 연산자 γ -모델의 입력으로는 부적합하다. 따라서 정규화 과정에서는

$$V_i = \frac{1}{6}(EV_i - 1), i = 1, 2 \quad (13)$$

선형적으로 평가치를 [0, 1]로 스케일링하였다.

2.2.3.2 γ -모델

γ -모델은 Zimmermann과 Zysno에 의해 고안된 퍼지 접속연산자로 교연산과 합연산의 혼합연산자의 형태로

$$y = \left(\prod_{i=1}^n x_i^{\delta_i} \right)^{1-\gamma} \cdot \left(1 - \prod_{i=1}^n (1-x_i)^{\delta_i} \right)^\gamma, \quad (14)$$

$$\text{여기서 } \begin{cases} \sum_{i=1}^M \delta_i = n \\ 0 \leq \gamma \leq 1 \\ \prod_{i=1}^n x_i^{\delta_i} : \cap operator \\ 1 - \prod_{i=1}^n (1-x_i)^{\delta_i} : \cup operator \end{cases} \text{이다.}$$

과 같이 정의된다. x_i 는 [0, 1]의 값을 가지는 의사결정 입력을 의미하고, δ_i 는 입력값 x_i 에 가해지는 가중치를 나타낸다. 그리고, γ 는 합 연산과 교 연산부분 사이에서 보상정도를 나타내는 파라미터이다.

γ -모델은 x_i , γ 에 대하여 단조증가 함수로 $(x_{\min})^\gamma \leq y \leq 1 - (1-x_{\max})^\gamma$ 의 값을 가진다. 여기서 x_{\min} 은 $\min(x_1, \dots, x_n)$ 이고 x_{\max} 은 $\max(x_1, \dots, x_n)$ 이다[9]. 따라서 γ -모델은 γ 값에 따라 합 연산자 또는 교 연산자 또는 보상 연산자로서 작용함으로써 인간의 의사 결정과 매우 유사한 특징을 보이고 있다.

본 논문에서 γ -모델은 두 개의 적용 퍼지 시스템으로부터 제공되는 감성 평가치의 가중치 δ 를 결정하고 융합하는데 사용되는 연산자의 형태 γ 를 결정하는데 사용된다.

2.2.4 학습 알고리즘 및 데이터

제안된 감성평가 모델에서 적용퍼지 시스템의 식 (10)의 파라미터 a_i^l , \bar{x}_i^l , σ_i^l , \bar{y}^l 과 γ -모델의 식 (14)의 파라미터 γ , δ 들은 학습에 의해 결정되어야 한다. 본 논문의 평가시스템의 학습은 Soen의 랜덤 칼라패턴의 심리학적 실험에서 얻어진 13개의 이미지 스케일 상의 감성 평가치와 평가 모델로부터 계산된 평가치 사

o)의 squared sum 에러를

$$E = \sum_{k=1}^N (f_k - Y_k)^2, \quad \begin{cases} k : \text{input pattern number} \\ N : \text{total pattern number} \\ f_k : \text{aggregation function} \\ Y_k : \text{desired output} \end{cases} \quad (15)$$

과 같이 정의하고, 이 에러를 최소로 하는 Steepest Gradient Descent 방법에 의한 학습을 시도하였다 [9,10]. γ -모델은 γ 와 δ 에 대하여 연속함수이며 미분 가능 함수이므로 γ 와 δ 의 제약조건을 없애기 위해 다음과 같이 설정할 수 있다.

$$\gamma = \frac{a^2}{a^2 + b^2}, \quad \delta_j = \frac{nd_j^2}{\sum_{k=1}^N d_k^2}, \quad j = 1, 2 \quad (16)$$

그래서, γ -모델은 a, b, d_j 을 학습시킴으로써 γ 와 δ 를 대신하며, 그 학습알고리즘은

$$a(n) = a(n-1) - \eta \frac{\partial E}{\partial a} = a(n-1)$$

$$-2\eta \left(\sum_{k=0}^N (f_k - Y_k) \frac{\partial f_k}{\partial a} \right) \quad (17)$$

$$b(n) = b(n-1) - \eta \frac{\partial E}{\partial b} = b(n-1)$$

$$-2\eta \left(\sum_{k=0}^N (f_k - Y_k) \frac{\partial f_k}{\partial b} \right) \quad (18)$$

$$d_j(n) = d_j(n-1) - \eta \frac{\partial E}{\partial d_j} = d_j(n-1)$$

$$-2\eta \left(\sum_{k=0}^N (f_k - Y_k) \frac{\partial f_k}{\partial d_j} \right) \quad (19)$$

과 같이 구성하였으며, 적응 퍼지 시스템의 학습알고리즘은 식 (10), (14)과 chain rule로부터

$$\overline{V_a^l}(n) = \overline{V_a^l}(n-1) - \eta \frac{\partial E}{\partial \overline{V_a^l}} = \overline{V_a^l}(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_1} \frac{\partial f_1}{\partial z_1^l} \frac{\partial z_1^l}{\partial \overline{V_a^l}} \quad (20)$$

$$\overline{V_b^l}(n) = \overline{V_b^l}(n-1) - \eta \frac{\partial E}{\partial \overline{V_b^l}} = \overline{V_b^l}(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_1} \frac{\partial f_1}{\partial z_1^l} \frac{\partial z_1^l}{\partial \overline{V_b^l}} \quad (21)$$

$$\overline{I^l}(n) = \overline{I^l}(n-1) - \eta \frac{\partial E}{\partial \overline{I^l}} = \overline{I^l}(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_2} \frac{\partial x_2}{\partial f_2} \frac{\partial f_2}{\partial z_2^l} \frac{\partial z_2^l}{\partial \overline{I^l}} \quad (22)$$

$$\overline{C^l}(n) = \overline{C^l}(n-1) - \eta \frac{\partial E}{\partial \overline{C^l}} = \overline{C^l}(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_2} \frac{\partial x_2}{\partial f_2} \frac{\partial f_2}{\partial z_2^l} \frac{\partial z_2^l}{\partial \overline{C^l}} \quad (23)$$

$$\sigma_{V_a^l}^l(n) = \sigma_{V_a^l}^l(n-1) - \eta \frac{\partial E}{\partial \sigma_{V_a^l}^l} = \sigma_{V_a^l}^l(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_1} \frac{\partial f_1}{\partial \sigma_{V_a^l}^l} \quad (24)$$

$$\sigma_{V_b^l}^l(n) = \sigma_{V_b^l}^l(n-1) - \eta \frac{\partial E}{\partial \sigma_{V_b^l}^l} = \sigma_{V_b^l}^l(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_1} \frac{\partial f_1}{\partial \sigma_{V_b^l}^l} \quad (25)$$

$$\sigma_I^l(n) = \sigma_I^l(n-1) - \eta \frac{\partial E}{\partial \sigma_I^l} = \sigma_I^l(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_2} \frac{\partial f_2}{\partial \sigma_I^l} \quad (26)$$

$$\sigma_C^l(n) = \sigma_C^l(n-1) - \eta \frac{\partial E}{\partial \sigma_C^l} = \sigma_C^l(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_2} \frac{\partial f_2}{\partial \sigma_C^l} \quad (27)$$

$$\overline{y^l}_{V_a V_b}(n) = \overline{y^l}_{V_a V_b}(n-1) - \eta \frac{\partial E}{\partial \overline{y^l}_{V_a V_b}} = \overline{y^l}_{V_a V_b}(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_1} \frac{\partial f_1}{\partial a_1} \frac{\partial a_1}{\partial \overline{y^l}_{V_a V_b}} = \overline{y^l}_{V_a V_b}(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_1} \frac{\partial f_1}{\partial a_1} \frac{\partial a_1}{\partial \overline{y^l}_{V_a V_b}} = \overline{y^l}_{V_a V_b}(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_1} \frac{\partial f_1}{\partial b_1} z_1^l \quad (28)$$

$$\overline{y^l}_{IC}(n) = \overline{y^l}_{IC}(n-1) - \eta \frac{\partial E}{\partial \overline{y^l}_{IC}} = \overline{y^l}_{IC}(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_2} \frac{\partial f_2}{\partial a_2} \frac{\partial a_2}{\partial \overline{y^l}_{IC}} = \overline{y^l}_{IC}(n-1) - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_1} \frac{\partial x_1}{\partial f_2} \frac{\partial f_2}{\partial b_2} z_2^l \quad (29)$$

과 같이 구성하였다. 단 적응 퍼지 시스템의 입력 퍼지변수의 소속함수식인 식 (9)의 $a_i^l = 1$ 로 고정하였다.

그리고 f_i 는 그림 7에서 V_a , V_b 와 I , C 입력에 해당하는 적응퍼지 시스템의 평가치이고, a_i , b_i , z_i 는 각 i 시스템 즉, V_a , V_b , I , C 를 입력으로 하는 적응퍼지시스템에서의 치환된 값이며, x_i 는 이 적응퍼지 시스템으로부터의 평가치를 정규화 하여 얻어진 결과 값이며 γ -모델의 입력 값을 나타낸다.

또한 적응 퍼지 시스템의 규칙의 개수는 분할된 입력공간의 개수와 같은데, V_a , V_b 를 입력으로 하는 첫 번째 적응 퍼지 시스템에서는 그림 2의 육각형으로 나타난 6개의 색조와 그레이를 고려해서 규칙의 개수를 7개로 하였고, I , C 입력으로 하는 두 번째 적응 퍼지 시스템에서도 규칙의 개수를 7개로 하였으며, 각 파라미터의 초기치는 감마모델에서 $a=b=d=0.5$ 즉, $\gamma=0.5$, $\delta=1.0$ 로 하고 적응퍼지시스템에서 \bar{V}_a , \bar{V}_b , \bar{I} , \bar{C} , $\bar{y_{VaVb}}$, $\bar{y_{IC}}$ 는 각 학습데이터의 분포를 고려해서 정하였으며 σ_{Va} , σ_{Vb} , σ_I , σ_C 는 학습데이터의 최대값과 최소값의 범위를 rule의 개수로 나눈 값으로 정하였다. 훈련시의 학습율은 [0.00001 0.1]의 범위에서 패턴의 오차가 더 이상 줄어들지 않을 때까지 변화를 주었다.

3. 실험 및 결과

본 논문에서는 제안된 감성 평가 모델과 Soen등이 제안한 감성 평가 모델, 그리고 신경회로망을 이용한 감성 평가 모델을 서로 비교하였다. 성능의 비교는 학습후 평가 모델의 30개의 랜덤 칼라 패턴의 감성과 심리학적인 실험에 의한 평가치와 얼마나 근접해 있는가에 대한 근사화 능력과 실제로 사용되는 칼라패턴 데이터에 대한 인간의 평가치와 모델의 평가치가 얼마나 유사한가의 비교를 통해서 이루어졌다.

표 1. 평가모델의 출력치와 실험 데이터 사이의 상관관계

Image Scale	Soen's System	Neural Network System	Adaptive Fuzzy System
like - dislike	0.812	0.825	0.985
beautiful - ugly	0.728	0.727	0.980
natural - unnatural	0.786	0.897	0.998
dynamic - static	0.946	0.942	0.999
warm - cool	0.917	0.923	0.998
gay - sober	0.925	0.903	0.999
cheerful - dismal	0.934	0.932	0.985
unstable - stable	0.836	0.866	0.967
light - dark	0.908	0.945	0.999
strong - weak	0.910	0.959	0.981
gaudy - plain	0.911	0.912	0.996
hard - soft	0.924	0.884	0.998
heavy - light	0.940	0.967	0.996

3.1 감성 평가 모델의 상관관계 비교

본 논문에서 제안된 적응퍼지 시스템 모델에서 30개의 랜덤 칼라패턴들의 물리적 속성으로부터 얻어진 감성 평가치와 Soen의 심리학적 실험에서 제공된 감성 평가치의 평균 값들과의 상관관계

$$\rho_i = \frac{\text{cov}(x_i, y_i)}{\sigma_{x_i} \sigma_{y_i}} \quad (30)$$

를 이용하여 각 모델의 성능을 비교하였다.식 (30)에서 σ 가 1에 가까울수록 모델이 정확한 것임을 의미한다[6]. 여기서 x 는 1번재 스케일이고 y 는 30개 랜덤 칼라패턴에 대한 피험자들의 감성속성 값이고, ρ 는 모델의 출력 값이다. 표 1은 2절에서 언급된 세 모델의 상관관계 비교를 보여주고 있는데 본 논문에서 제안한 적응 퍼지 시스템을 이용한 모델이 Soen등의 모델이나 신경회로망 모델보다 상관계수가 월등함을 보여주고 있다. 따라서 인간이 랜덤 칼라패턴을 보고 느끼는 감정의 심리학적 실험치를 적응 퍼지 시스템을 이용한 모델이 가장 잘 모델링 할 수 있음을 알 수 있다.

3.2 실제 칼라 패턴에 대한 감성 평가 결과

Soen등은 그들의 모델을 실제 5개의 칼라패턴에 적용하여 평가 실험을 수행하였다. 그들은 5장의 칼라패턴을 사람들에게 보여주고 각 이미지 스케일에 평가치를 주게 하였으며, 이를 이미지 스케일 당 평가치들을 평균하고 분산을 구한 후 자신들의 모델로부터의 평가치가 평균값으로부터 얼마나 떨어져 있는 가를 구하였다. 즉 모델의 성능이 좋을 경우에는 평균적인 인간의 감성과 유사하게 작은 분산거리를 가질 것이고, 그렇지 않을 경우에는 큰 분산거리에 위치하게

표 2. 0.3, 0.5, 0.7, 1 σ 안에 든 테스트 패턴의 개수

Image Scale	Soen's System				Neural Network System				Adaptive Fuzzy System			
	0.3 σ	0.5 σ	0.7 σ	1 σ	0.3 σ	0.5 σ	0.7 σ	1 σ	0.3 σ	0.5 σ	0.7 σ	1 σ
like - dislike	1	3	3	5	2	3	4	5	1	2	4	5
beautiful - ugly	2	2	2	3	2	2	4	5	2	2	3	3
natural - unnatural	1	3	3	5	0	3	4	5	1	2	3	4
dynamic - static	0	0	0	0	1	1	2	3	1	2	3	3
warm - cool	0	1	1	1	1	2	2	2	0	0	0	1
gay - sober	0	1	2	3	0	1	4	4	0	0	3	3
cheerful - dismal	1	1	1	2	1	1	1	1	0	1	1	2
unstable - stable	1	2	4	4	4	4	4	4	2	2	5	5
light - dark	0	1	2	2	1	2	2	2	0	0	0	1
strong - weak	0	0	1	2	2	4	4	4	4	4	4	4
gaudy - plan	0	0	0	1	1	2	2	3	1	3	4	5
hard - soft	1	1	3	4	1	2	4	5	1	1	4	5
heavy - light	1	1	1	2	0	0	1	3	0	0	2	4

표 3. 표 2에 대한 스칼라 척도값

	Soen's System	Neural Network System	Adaptive Fuzzy System
S	0.640	0.918	0.899

될 것이다.

본 논문에서도 동일한 칼라 패턴에 대한 신경회로망과 제안된 평가모델의 평가치를 평균적인 인간의 감성 평가치와의 분산거리를 통하여 비교하여 보았다. 표 2는 이러한 실험결과를 요약한 것으로, 표의 수치는 주어진 분산 거리 내에 5장의 칼라패턴에 대한 모델의 평가치가 몇 개 들어 있는가를 표현한다. 예로써 “hard-soft”的 경우는 Soen의 평가 모델은 인간의 평가치의 평균으로부터 1 σ 이내에 4장의 평가 결과가 위치한다는 것을 의미한다.

표 2에서 알 수 있듯이 실제 칼라 패턴에 대하여도 적응 퍼지시스템을 이용한 모델이 ‘warm-cold’, ‘light-dark’의 두 이미지 스케일에서만 성능이 떨어졌으나 신경회로망 모델과 같이 비교할 만한 성능을 나타낸 것으로 나타났다. 본 논문에서는 표 2를 기반으로 모델 성능을 비교할 수 있는 스칼라 척도

졌다.

$$w_j = \frac{\frac{1}{\sqrt{2\pi}} \text{Exp} \left[-\frac{\sigma_j^2}{2} \right]}{\sum_{j=1}^4 \frac{1}{\sqrt{2\pi}} \text{Exp} \left[-\frac{\sigma_j^2}{2} \right]} \quad (32)$$

표 2에서 $\sigma = \{0.3, 0.5, 0.7, 1\}$ 이므로 $w = \{0.3, 0.27, 0.24, 0.19\}$ 이다. S의 최대치는 첫 번째 표준편차 오차에 패턴의 개수 5가 들어있는 경우로 값이 1.5이다. 표 3에는 3가지의 모델에 대한 스칼라 척도를 나타내었으며, 이에 따라서 Soen 등의 모델보다 제안된 모델이 보다 더 인간에 의한 평가와 가까워졌음을 알 수 있으며, 신경회로망 모델보다는 성능이 약간 떨어지는 것으로 나타났다.

3.3 칼라 패턴에 대한 감성 평가 모델의 언어적 근사화 능력 평가

본 실험에서는 V_a , V_b 와 I , C 의 입력 공간에서 제안된 평가모델이 그림 2와 3의 결과와 얼마나 근사한 접근을 하는지를 살펴보았다. 이를 위하여 학습이 끝난 평가모델에 입력 값들을 바꾸어 가며 모델의 13개의 이미지 스케일 상의 최종 평가치가 어떠한 값을 가지는지를 MathLab으로 구하고 이를 그림으로 나타내 보았다. 그러나, 평가 모델의 입력인 물리적 속성이 4개인 관계로 3차원 공간상에 표시할 수 없으므

을 제안하였다. 여기서 i 는 i 번째 이미지 스케일, j 는 각 0~0.3, 0.3~0.5, 0.5~0.7, 0.7~1 사이의 표준편차 오차를 나타내는 인덱스이다. N_{ij} 는 i 번째 이미지 스케일의 j 번째 표준편차 오차 내에 해당하는 패턴의 개수이고, w_j 는 j 번째 표준편차 오차에 해당하는 패턴의 개수에 대한 가중치이고 다음과 같이 정해

$$S = \frac{\sum_{i=1}^{13} \sum_{j=1}^4 w_j N_{ij}}{13} \quad (31)$$

로, I , C 값이 고정된 상태에서의 V_a , V_b 의 변화에 따른 평가치와 $V_a V_b$ 값을 고정시키고 I , C 값의 변화에 따른 평가치를 그래프로 표현하였다. 각 경우의 고정 값은 그림 2와 그림 3과의 비교를 위해서 I , C 값은 그림 2에서와 같이 I 는 0.5로 설정하고, C 값은 도트 크기가 4×4 인 경우의 값(0.2)으로 설정한 후 V_a , V_b 값의 변화에 따른 평가치의 변화를 구하였으며, V_a , V_b 의 고정치는 그림 3의 경우와 비교를 위해 각각 0으로 설정하고(무채색) I , C 값에 따른 변화를

관찰하였다.

그림 8과 그림 9는 13개의 이미지 스케일 중에 “heavy-light”, “gaudy-plain”의 결과를 예로서 도시한 것으로, 그림 2와 그림 3의 원에 크기에 의한 균사화된 결과와 유사한 모습을 보이는 것을 확인할 수 있다. 즉 “heavy-light”的 경우 그림 8에서 알 수 있듯이 보라색 및 청색 계통에서 무거운 느낌을 크게 갖는 것이 일치하며, 패턴의 밀하고 소한 정도 보다는 명도가 낮은 값에서 무거운 느낌을 갖는 결과와 일치

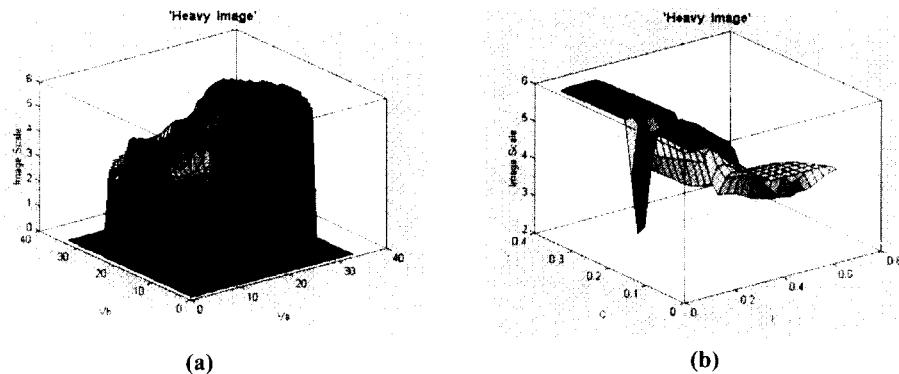


그림 8. a: Heavy-Light V_a , V_b , b: Heavy-Light I-C

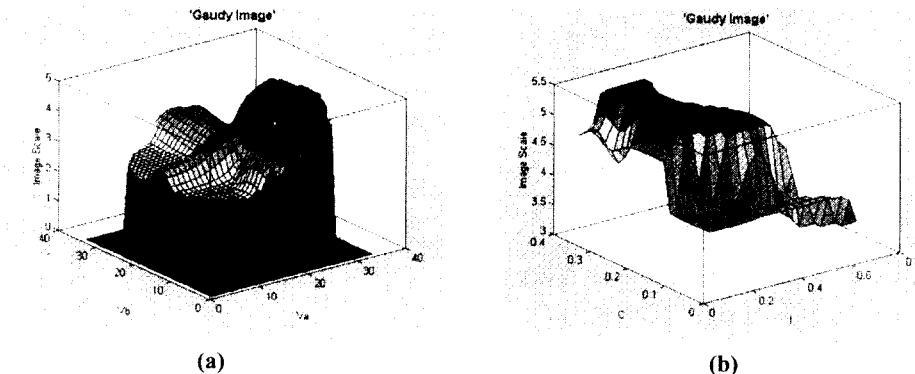


그림 9. a: Gaudy-Plain V_a , V_b , b: Gaudy-Plain I-C

표 4. 학습후 13개 이미지 스케일에서 γ -모델의 파라미터
($\delta_{V_a} V_b \delta_C$ 는 V_a , V_b , I , C 를 입력으로 하는 적응퍼지시스템의 parameter)

parameter	like-dislike	beautiful-ugly	natural-unnatural	dynamic-static	warm-cold	gay-sober	cheerful-dismal
γ	0.64	0.62	0.54	0.48	0.64	0.37	0.50
$\delta_{V_a} V_b$	1.03	1.31	1.13	1.16	1.11	1.04	1.15
δ_C	0.97	0.69	0.87	0.84	0.89	0.96	0.85
parameter	unstable-stable	light-dark	strong-weak	gaudy-plain	hard-soft	heavy-light	-
γ	0.54	0.33	0.81	0.46	0.79	0.74	-
$\delta_{V_a} V_b$	0.98	0.92	0.94	0.96	0.94	0.86	-
δ_C	1.02	1.08	1.06	1.04	1.06	1.14	-

함을 확인할 수 있다. 이러한 결과는 “gaudy-plain” 이미지 스케일 및 제시되지 않은 다른 이미지 스케일에서도 유사한 해석을 부여할 수 있었다.

3.4 γ -모델의 학습결과 분석

제안된 평가 모델에서 두 개의 적응 퍼지 시스템의 평가치는 γ -모델에 의해 융합된다. 표 4는 학습이 끝난 후의 γ -모델의 파라미터인 γ 값과 δ 값을 보여주고 있다. 표 4에서 γ 값이 0.334 - 0.807 사이의 값으로 보아 물리적인 속성 V_a , V_b 에 의한 평가치와 I, C제안된 평가 모델에서 두 개의 적응 퍼지 시스템의 평가치는 γ -모델에 의해 융합된다. 표 4는 학습이 끝난 후의 γ -모델의 파라미터인 γ 값과 δ 값을 보여주고 있다. 표 4에서 γ 값이 0.334 - 0.807 사이의 값으로 보아 물리적인 속성 V_a , V_b 에 의한 평가치와 I, C에 의한 평가치의 보상 연산이 이루어 진 것을 확인할 수 있으며, “beautiful-ugly”, “dynamic-static”, “warm-cool”, “cheerful-dismal” 등의 경우는 평균 색조에 의한 영향이 평균명도나 패턴의 질감보다 조금 더 큰 영향을 주는 것으로 해석할 수 있으며, “heavy-light”, “light-dark” 등은 그 반대로 평균 색조보다는 평균 명도나 질감에 의한 영향이 더 큰 것으로 나타났다. 이러한 결과 역시 색채 심리학에서의 통상적인 사실과 유사하게 일치하는 것을 알 수 있다.

4. 결 론

본 논문에서는 Soen 등의 칼라 패턴의 감성평가를 위한 색채 심리학적인 실험 결과를 모델링하기 위한 적응 퍼지 시스템을 이용한 감성 평가 모델을 제안하였다. 제안된 모델은 입력으로 평균적인 색조를 입력으로 하는 적응 퍼지 시스템과 평균 명도와 칼라패턴의 질감을 입력으로 하는 적응퍼지 시스템으로 구성되고 13개의 상반된 의미를 갖는 형용사로 표현된 이미지 스케일에서의 최종적인 평가치는 두 시스템의 평가치를 퍼지 연산자인 γ -모델에 의해 융합하여 얻어낸다.

제안된 모델은 실험결과의 심리학적인 데이터를 근사화 하는 능력에서는 Soen 등이 제안한 다중회귀분석에 의한 비선형 모델보다는 우수하고, 기준에 발표

된 신경회로망 모델과는 근접한 결과를 제공할 수 있음을 확인할 수 있었다. 또한 제안된 모델의 특징은 신경 회로망이나 비선형 다중회귀 분석에 의한 모델에 비해 학습결과를 언어적으로 해석하기가 용이하다는 장점이 있다. 즉 학습된 정보가 노드나 연결강도의 형태로 분산되어 나타나는 신경회로망에 비해 보다 뚜렷한 의미를 부여할 수 있는 규칙들을 제공하기 때문에 적용 퍼지 시스템의 경우 학습 결과에 대한 언어적인 해석이 보다 용이하다는 것이다.

제안된 모델은 칼라 디자인의 기계에 의한 감성 평가와 인간의 감성을 기반으로 하는 칼라패턴의 검색 등에 사용되어 사용자가 원하는 분위기의 칼라패턴을 검색하는데 이용할 수 있을 것으로 기대된다. 또한 본 논문에서 사용된 연구 방법론은 심리학 등의 실험 데이터와 이에 대한 해당 학문분야의 부정확한 언어적 서술을 바탕으로 기계에 이식할 수 있는 언어적인 모델을 개발하는데 적용할 수 있을 것으로 기대된다.

참고문헌

- [1] Gobayashi, Color Image Scale, Kohdansha, 1990.
- [2] 엄진섭, 유원영, 이준환, “퍼지이론을 이용한 색채 계획 시스템에 관한 연구”, Proceeding of JCEANF'96, pp. 112-116, 1996.
- [3] S. W. Hsiao, “A Systematic Method for Color Planning int Product Design”, *Color Res. Appl.*, Vol. 20, pp. 191-205, 1995.
- [4] T. Soen, T. Shimada and M. Akita, “Objective Evaluation of Color Design”, *Color Res. Appl.*, Vol. 12, pp. 187-194, 1987.
- [5] N. Kawamoto and T. Soen, “Objective Evaluation of Color Design II”, *Color Res., Appl.*, Vol. 18, pp. 260-266, 1996.
- [6] 엄진섭, 이준환, “감각언어를 이용한 칼라패턴 검색”, 한국퍼지 및 시스템학회 논문지, Vol. 9, No. 1, 1999.
- [7] 김준철, 속성 벡터를 이용한 효율적인 질감 영상 분별, 전북대 박사 학위 논문, 1995.
- [8] Wang, Li-Xi., Adaptive Fuzzy Systems And Control, PTR Prentice Hall, 1994.
- [9] Krishnapuram, R., Lee, J., “Fuzzy-Set-Based Hierarchical Networks for Information Fusion in Computer Vision”, *Neural Networks*, Vol. 5, pp. 335-350, 1992.
- [10] Hagan, Demuth, Beale, Neural Network Design, PWS Publishing Company, 1996.



두 성 한 (Sung-Han Doo)

1993년 3월~1997년 2월 : 전북대학교
물리학과(학사)
1997년 3월 ~현재 : 전북대학교 전자
공학과 석사과정 재학중



엄 경 배 (Kyoung-Bae Eum)

1990년 : 전북대학교 대학원 전자공
학과 (박사)
1995년 : 캐나다 토론토대학교 전기
및 컴퓨터 공학과 박사후
연구원
1999년 : 일본 동경대학 생산기술연
구소 객원 연구원
1989년 ~현재 : 군산대학교 컴퓨터
과학과 부교수



이 준 환 (Joon-Whaon Lee)

1976년 3월~1980년 2월 : 한양대학교
전자공학과(학사)
1980년 3월~1982년 2월 : 한국과학기
술원 산업전자(석사)
1980년 8월~1990년 8월 : Univ. of
Missouri in Columbia ECE(
박사)
1985년 4월 ~현재 : 전북대학교 전자
공학과 교수