

## 칼라 매저링/매칭용 지능형 전문가 시스템의 구현

### Implementation of Intelligent Expert System for Color Measuring/Matching

안 태 천, 장 경 원, 오 성 권  
(Tae-Chon Ahn, Kyung-Won Jang and Sung-Kwun Oh)

**Abstract** : The color measuring/matching expert system is implemented with a new color measuring method that combines intelligent algorithms with image processing techniques. Color measuring part of the proposed system preprocesses the scanned original color input images to eliminate their distorted components by means of the image histogram technique of image pixels, and then extracts RGB(Red, Green, Blue) data among color information from preprocessed color input images. If the extracted RGB color data does not exist on the matching recipe database, we can measure the colors for the user who want to implement the model that can search the rules for the color mixing information, using the intelligent modeling techniques such as fuzzy inference system and adaptive neuro-fuzzy inference system. Color matching part can easily choose images close to the original color for the user by comparing information of preprocessed color real input images with data-based measuring recipe information of the expert, from the viewpoint of the delta E formula used in practical process.

**Keywords** : image processing, image histogram, color measuring, color matching, intelligent algorithms

#### I. 서론

생산성 위주의 대량 생산 체제인 염색 산업은 소비자의 다양한 요구에 맞춰 다종품 소량 생산, 고급 브랜드화, 품질의 표준화 및 고급화에 모든 역량을 집중하여 고부가가치 산업으로 탈바꿈하기 위한 노력을 계속하고 있다. 특히 염색 산업에 있어서 섬세하고 다양한 색상의 표현은 고부가가치 상품 개발의 기본이 되고 있으며, 의뢰인의 요구에 부합하는 색상을 만들기 위해서 방대한 양의 색상 정보를 생성 및 저장하고 대용량의 데이터베이스로부터 한정된 시간 내에 원하는 색상 정보에 대한 정확하고 빠른 검색을 통한 제품 생산이 중요한 요소로 작용하고 있다. 그러나 복잡하고 비선형 특성이 강한 칼라의 모델을 구축하거나 정밀 제어를 수행할 경우에 분석상의 어려움이 많아 지금도 많은 연구자들의 관심을 끌고 있다[8]-[10][17][18]. 한편, 지능형 이론과 모델링 방법은 컴퓨터의 발전과 더불어 구현상의 어려움을 극복하여 산업 전반에 걸쳐 그 응용의 폭을 넓혀 가고 있다[1]-[6]. 지금은 복잡하고 비선형성이 강한 화학 공정이나 조제 공정 시스템의 모델 구축에 활용되고 있으나, 칼라 생산공정의 자동화에 그 예가 드문 편이다.

본 논문에서는 지능형 모델링 알고리즘과 이미지 프로세싱 기술을 결합한 칼라 매저링/매칭 전문가 시스템을 구현한다. 제안된 시스템은 스캐너로 입력된 원본 칼라 이미지의 왜곡요소를 이미지 픽셀의 히스토그램을 이용하여 전 처리한 후, 처리된 칼라 이미지에서 RGB 데이터를 추출하여 원본 이미지의 칼라를 측정하고, 칼라 매칭을 위한 데이터로 이용한다. 이 RGB 데이터가 기존의 데이터 베이스에 존재

하지 않을 때, 지능형 모델링 기법을 이용하여, 이 데이터 상 호간에 존재하는 일정한 색상 배합 정보에 관한 규칙을 찾아내는 모델을 구축함으로써 사용자가 원하는 칼라를 용이하게 조절할 수 있게 한다. 조절된 칼라의 매칭은 원본의 RGB 데이터와 조절된 염료의 RGB 데이터를 색상 비교를 위해 실제 공정에서 사용하는 델타 E의 허용 범위 안에서 비교 매칭하여 원본 이미지에 가까운 칼라 염료를 얻게 한다.

#### II. 칼라 공간과 이미지 프로세싱

##### 1. RGB 칼라 공간

칼라를 인지하는데 사용되어지는 세 가지 시각 변수로는 색상(Hue), 채도(Saturation), 명도(Brightness)가 있는데, 일반적으로 종이나 섬유에 염색된 염료도 색상, 채도, 명도의 조합으로 만들어지므로, 일반적인 칼라공간과 같다. 칼라 공간은 칼라들 사이의 관계를 표현하는 방법으로 RGB(Red, Green, Blue), CMY(Cyan, Magenta, yellow), HSV(Hue, Saturation, Value), HSI(Hue, Saturation, Intensity)등 다양한 종류가 있는데, 칼라 공간들은 목적에 따라 선택하여 사용할 수 있다. 컴퓨터의 컬러 CRT 모니터나 컴퓨터 그래픽 시스템들은 RGB 공간을 이용하고 있다[14].

RGB 공간은 빨강(Red), 초록(Green) 및 파랑(Blue)의 삼원색을 조합하여 색상 공간을 만든다. 세 가지 색은 각각 256단계(0~255)의 값을 가지고 있어 이들을 혼합하여 만들 수 있는 색상의 숫자는  $256 \times 256 \times 256 = 16,777,216$ (24bit 칼라)을 표현할 수 있다.

RGB 공간 모형은 그림 1과 같이 각 축의 모서리가 빨강, 초록 그리고 파랑인 3차원 입방체로 표현되는데 검은색은 원점이고 흰색은 입방체의 반대 끝 쪽이다. 명암은 검은색에서 흰색으로 이어지는 선을 따라서 표현된다. 빨간색은 (255,0,0)의 좌표로 칼라 입방체 상에서는 (1,0,0) 좌표이다. 본 논문에서는 컬러모니터 상에서 RGB 데이터를 가지고 우

논문접수 : 2001. 8. 20., 채택확정 : 2002. 3. 28.

안태천, 장경원, 오성권 : 원광대학교 전기전자 및 정보공학부(tcahn@wonkwang.ac.kr/jaang@wonkwang.ac.kr/skoh@wonkwang.ac.kr)

\* 이 논문은 2001년도 원광대학교 교비 지원에 의해서 수행됨.

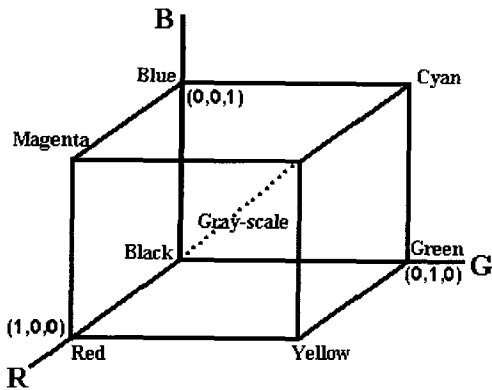


그림 1. RGB 공간 칼라 입방체.  
Fig. 1. RGB space color hexahedrons.

리가 인식할 수 있는 실제 칼라를 구현하고자 하기 때문에 RGB 칼라공간이 사용된다.

2. 이미지 히스토그램(Image histogram)

천이나 종이에 염색된 원본 샘플을 가지고 칼라를 측정하기 위해서 스캐너를 통해 컴퓨터 칼라 이미지를 얻는데, 이때 섬유와 종이의 특성 그리고 조명으로 인한 원본과 다른 이미지를 얻게 되므로 정확한 색상 정보를 얻기 위해 약간의 이미지가공이 필요하고, 이 과정에서 빼 놓을 수 없는 것이 바로 칼라 이미지 처리이다[11][12][14]. 이미지 프로세싱 기법 중에 한 방법인 히스토그램은 이미지가 가진 중요한 정보를 저장하고 있는 것으로 히스토그램은 샘플 이미지가 주어졌을 때 이미지에서 화소(pixel)의 밝기를 표현하는 막대 그래프로 나타낸다. 즉 초기 칼라 이미지가 입력되면 그 이미지를 단색으로 처리한 후 그 단색에 대해 256 명암 단계를 보여주는 것이다[12][13].

히스토그램 방법은 이미지의 평활화에 이용되고 있다. 이것은 명암을 재 분포시키는 것으로서, 이를 위해서 우선 이미지에 대해 히스토그램을 생성해야 한다. 그리고 나서 히스토그램의 정규화된 합을 계산하고 입력 이미지를 변형하여 결과 이미지를 생성하게 되는 것이다. 히스토그램 평활화는 축적 히스토그램을 그레이 스케일 매핑 함수를 이용하여 구현하는데 축적 히스토그램은 (1)에 의해 정규화 된다[13].

$$k_i = \frac{g_{\max}}{n_i} H(i) \tag{1}$$

여기서,  $n_i$ 는 영상에서의 픽셀의 총 개수(가로 256×세로 256 영상을 사용하였을 때, 픽셀의 총 수 256×256)이고,  $g_{\max}$ 는 명도의 최대 값이며(여기서, Gray-level로 256 단계)  $H(i)$ 는 축적 히스토그램이다.  $k_i$ 는 정규화된 값 즉, 변환된 이미지 값이다.

실제 샘플을 스캔하면 빛 또는 섬유나 종이의 재질 특성이 처음 샘플칼라가 아닌 다른 칼라로 나타나게 된다. 따라서 본 논문에서는 불필요한 화소를 처리하기 위해 이미지 히스토그램을 이용하여 가장 많은 색의 분포를 가진 부분을 가지고 칼라를 측정한다.




그림 2. 스캐너의 샘플 이미지.  
Fig. 2. Scanner's sample image.




그림 3. 히스토그램 분석 프로그램.  
Fig. 3. Histogram analysis program.

그림 2와 그림 3은 입력된 이미지의 일부분을 선택했을 때 선택 영역에 대한 칼라 분포를 히스토그램화 하여 보여주는 프로그램으로, 이와 같은 전처리 과정을 통해서 빛에 의한 섬유나 종이의 특성에 의해 나타나는 왜곡 색에 대해 선택적으로 제거하여 보다 정확한 칼라를 측정할 수 있게 한다.

III. 칼라 RGB 모델 구현을 위한 지능형 알고리즘

본 논문에서는 정확한 칼라 모델을 구축하기 위해 회귀 다항식 시스템, 선형 퍼지 추론 시스템, 적응 뉴로 퍼지 추론 시스템을 이용하여 RGB 칼라를 모델링한 후 그 성능을 비교한다[7][15][16].

RGB 칼라의 모델링은 첫째 시스템 구조를 결정하고, 둘째 구조에 대한 파라미터를 계산하며, 셋째 시스템 모델의 타당성을 평가하는 식을 비교함으로써 이루어진다.

1. 회귀 다항식 시스템

주어진  $n$ 개의 점인  $(x_1, y_1), \dots, (x_n, y_n)$ 을 만족하는 특성곡선을 추정할 때  $f(x_j) \approx y_j, j = 1, \dots, n$ 을 만족하는 함수  $f(x)$ 를 결정한다. 이렇게 얻은 함수는 저 차수부터 고 차수에 이르는 회귀 다항식이 된다.

주어진 점에서  $f(x_1) = y_1, \dots, f(x_n) = y_n$ 가 성립하게 하려면, 충분히 높은 차수의 회귀 다항식과 보간법을 연계시켜 사용하면 가능하다. 그러나 만약 데이터 값이 실험과정에서 발생하는 오차를 수반한 값이고 또한 이 실험의 성질로 보아 낮은 차수의 함수 관계가 추측된다면 주어진 점을 가까이 지나는 낮은 차수의 직선(혹은 곡선)을 가우스의 최소자승법으로 선택하는 것이 더 용이할 것이다.

가우스의 최소자승법(Gauss's method of least square)은 설명하기 위하여 (2)를 고려한다[15].

$$y = a + bx \tag{2}$$

이 방법은 (2)의 형태로 주어진 점  $(x_1, y_1), \dots, (x_n, y_n)$ 을 지나는 직선(혹은 곡선)을 추정하도록, 점으로부터 직선(혹은 곡선)까지의  $y$ 축상 거리의 자승이 최소가 되도록 매개변수  $a, b$ 를 결정하는 것이다. 직선상의 점의  $x$ 좌표가  $x_j$ 인 것은  $y$ 좌표가  $a + bx_j$ 이 되고, 점  $(x_j, y_j)$ 로부터 직선까지의  $y$ 축상 거리는  $|y_j - a - bx_j|$  이 되며, 합은 (3)이 된다.

$$q = \sum_{j=1}^n (y_j - a - bx_j)^2 \tag{3}$$

$q$ 는  $a$ 와  $b$ 의 종속 함수로써  $q$ 가 최소가 되기 위한 필요충분조건은 (4)가 된다.

$$\begin{aligned} \frac{\partial q}{\partial a} &= -2 \sum (y_j - a - bx_j) = 0 \\ \frac{\partial q}{\partial b} &= -2 \sum x_j (y_j - a - bx_j) = 0 \end{aligned} \tag{4}$$

(4)를 정리하면 (5)와 같은 정칙 방정식이 된다.

$$\begin{aligned} an + b \sum x_j &= \sum y_j \\ a \sum x_j + b \sum x_j^2 &= \sum x_j y_j \end{aligned} \tag{5}$$

고차의 회귀다항식은 (2)의 차수를 높여 줌으로써 얻을 수 있고, 이 다항식의 최적 매개변수는 (3)에서 (5)의 과정을 거쳐 계산할 수 있다[15].

2. 선형 퍼지 추론 시스템

선형 퍼지 추론 시스템은 입출력 데이터가 비선형적인 관계에 있을 경우에 매우 효율적으로 모델을 추정할 수 있다 [2]. 선형 퍼지 추론 모델의 일반적인 퍼지 규칙은 (6)과 같다 [15].

$$\text{If } x_1 \text{ is } A \text{ and } x_2 \text{ is } B \text{ Then } y = f(x_1, x_2) \tag{6}$$

여기서,  $A$ 와  $B$ 는 전반부의 소속 함수이고,  $y = f(x_1, x_2)$ 는 후반부의 함수 식이다.

선형 퍼지 추론모델은 각 입력 변수의 공간을 퍼지 부분 공간으로 분할하여 각 부분 공간의 입·출력 관계를 1차 선형식으로 나타내고 가중치를 고려한 이들의 합에 의해 비선형 시스템의 입·출력 관계를 나타내며, 선형 퍼지 추론 시스템은 (7)의 형태를 가지는 규칙들로 구성된다[15].

$$\begin{aligned} R^1: & \text{If } x_1 \text{ is } A_{11} \dots x_k \text{ is } A_{1k} , \\ & \quad \quad \quad \vdots \\ & \quad \quad \quad \text{Then } y = a_{10} + \dots + a_{1k}x_k \\ & \quad \quad \quad \vdots \\ R^j: & \text{If } x_1 \text{ is } A_{j1} \dots x_k \text{ is } A_{jk} , \\ & \quad \quad \quad \vdots \\ & \quad \quad \quad \text{Then } y = a_{j0} + \dots + a_{jk}x_k \\ & \quad \quad \quad \vdots \\ R^n: & \text{If } x_1 \text{ is } A_{n1} \dots x_k \text{ is } A_{nk} , \\ & \quad \quad \quad \text{Then } y = a_{n0} + \dots + a_{nk}x_k \end{aligned} \tag{7}$$

여기서,  $k$ 는 입력변수의 수이고,  $j$ 는 규칙번호이며,  $n$ 은 규칙 수이다. 또한  $R^j$ 는  $j (j=1, \dots, n)$ 번째 규칙이고,  $x_l (l=1, \dots, k)$ 는 입력변수이며,  $A_{jl}$ 는 퍼지 집합의 소속함수이고,  $a_{jp} (j=1, \dots, n; p=0, \dots, k)$ 는 후반부의 파라미터이다. 추론된 값  $y^*$ 는 (8)과 같이 얻어진다.

$$\begin{aligned} y^* &= \frac{\sum_{j=1}^n w_{ji} y_j}{\sum_{j=1}^n w_{ji}} \\ &= \frac{\sum_{j=1}^n w_{ji} (a_{j0} + a_{j1}x + \dots + a_{jk}x^k)}{\sum_{j=1}^n w_{ji}} \end{aligned} \tag{8}$$

여기서,  $i$ 는  $i (i=1, \dots, m)$ 번째 데이터이고,  $w_{ji}$ 는 적합도이다.

퍼지 추론 시스템의 전반부 구조동정은 입력 변수의 선택이 여기에 해당되고 후반부 구조동정은 출력 파라미터를 동정하는 것이다 파라미터 동정도 마찬가지로 전반부 및 후반부 파라미터 동정이 있다. 전반부 파라미터 동정은 주어진 성능지수를 최소로 하는 후반부 파라미터를 결정할 것이고, 후반부 파라미터 동정은 전반부 입력변수 및 파라미터가 주어지면, 성능 평가지수 PI( Performance index)를 최소화하는 최적 후반부 파라미터  $a_{ji}$ 를 결정하는 것이다. 성능평가지수 PI는 (9)로 정의된다.

$$PI = \frac{1}{m} \sum (y - y^*)^2 \tag{9}$$

여기서,  $m$ 은 데이터 수이고,  $y$ 는 실험 값이며,  $y^*$ 는 모델 출력 값이다.

퍼지 If-Then 규칙의 후반부 파라미터는 입·출력 데이터가 주어졌을 때 최소자승법에 의해 구해진다. 선형 퍼지 추론모델에서 파라미터 추정은 평가함수 (10)을 사용하여 계산된다.

$$\begin{aligned}
 V(a, m) &= \frac{1}{2} \sum_{i=1}^m (y_i - y_i^*)^2 \\
 &= \frac{1}{2} \sum_{i=1}^m [y_i - \sum_{j=1}^n a_{ji} w_{ji}]^2 \quad (10) \\
 &= \frac{1}{2} \sum_{i=1}^m [y_i - x_i^T a]^2 \\
 &= \frac{1}{2} \cdot \|E\|^2
 \end{aligned}$$

여기서,

$$w_{ji} = \frac{(A_{j1}(x_{1i}) \wedge \dots \wedge A_{jk}(x_{ki}))}{\sum_{l=1}^k (A_{j1}(x_{1i}) \wedge \dots \wedge A_{jk}(x_{ki}))}$$

이다. 그리고,

$$\begin{aligned}
 x_i^T &= [w_{1i}, \dots, w_{ni}, x_{1i}w_{1i}, \dots, x_{ni}w_{1i}, \dots, \\
 &\quad x_{ki}w_{1i}, \dots, x_{ki}w_{ni}] \\
 a^T &= [a_{10}, \dots, a_{n0}, a_{11}, \dots, a_{n1}, a_{1k}, \dots, a_{nk}] \\
 Y &= [y_1, y_2, \dots, y_m]^T \\
 X &= [x_1, x_2, \dots, x_m]^T
 \end{aligned}$$

이다.

(10)에서  $E = Y - Xa$ 의 관계가 있으므로 최소자승법에 의해 후반부 파라미터를 구하면 (11)과 같게 된다.

$$\hat{a} = (X^T X)^{-1} X^T Y \quad (11)$$

### 3. 적응 뉴로 퍼지 추론 시스템 (ANFIS)

퍼지 추론 시스템에 신경망의 네트워크 개념을 도입하고 학습 알고리즘을 부가한 ANFIS는 함수적으로 퍼지 추론 시스템과 동가이며 이를 신경망의 구조처럼 표현할 수 있다. 또한 이 시스템은 오류 역전파 알고리즘과 최소자승법을 사용하는 하이브리드 학습 알고리즘으로 동정한다[16].

#### 3.1 ANFIS 네트워크 구조

2입력 1출력을 가지고 각 입력변수에 대하여 2개의 소속 함수를 사용하는 간단한 ANFIS의 구조는 그림 4와 같다.

여기서, 입력은  $x, y$  이고 출력은  $z$ 이고, 포함된 퍼지 규칙은 (12)와 같은 선형 추론형태의 2개의 규칙을 가진다.

$$\begin{aligned}
 R^1: & \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1, \text{ then } f_1 = p_1x + q_1y + r_1 \\
 R^2: & \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2, \text{ then } f_2 = p_2x + q_2y + r_2
 \end{aligned} \quad (12)$$

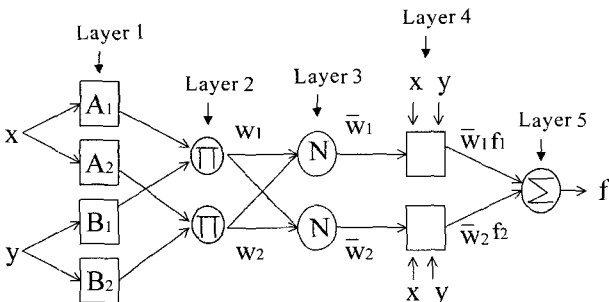


그림 4. ANFIS 네트워크의 구조.  
Fig. 4. Architecture of ANFIS.

ANFIS는  $L$ 개의 층을 가지며,  $k$ 번째 층은  $\#(k)$ 개의 마디를 가졌다고 하면  $k$ 번째 층의  $i$ 번째 마디의 출력은  $O_i^k$ 로 표시된다. 이 출력값은 이전 층에서 들어오는 입력 신호와 각 마디가 가지는 파라미터에 의해 계산된다. 즉,

$$O_i^k = F(O_i^{k-1}, \dots, O_{\#(k-1)}^{k-1}, a, b, c, \dots) \quad (13)$$

여기서,  $a, b, c, \dots$ 는 각 마디에 속하는 파라미터들이다.

ANFIS에서 사용한 소속함수는 최소값이 0이고 최대값이 1인 (14)로 표현되는 종 모양의 소속함수를 사용하는데 그림 5와 같다.

$$\mu_{A_i}(x) = \frac{1}{1 + \left[ \left( \frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (14)$$

여기서,  $\{a_i, b_i, c_i\}$ 는 파라미터의 집합으로 이 파라미터들을 조정함으로써 소속 함수의 모양을 변경할 수 있다. 이 파라미터가 동정되어야 할 전반부 파라미터이다. 파라미터  $a$ 는 너비의 절반을 의미하고,  $b$ 는  $a$ 와 함께 소속함수 값이 0.5가 되는 점의 기울기이며,  $c$ 는 소속함수의 중심 값을 결정하는 물리적 의미를 가진다.

#### 3.2 ANFIS의 학습 알고리즘

ANFIS는 각 파라미터들을 동정하기 위해, 경사 하강법에 기초한 오류 역전파 알고리즘과 최소자승법을 합성하여 사용한다. 이러한 하이브리드 학습 알고리즘은 전방향 경로에서 각 마디의 출력 신호는 4층까지 계산되고 전반부 변수가 고정된 상태에서 후반부 변수가 최소자승법에 의해 동정된다. 후방향 경로에서는 오차율이 출력마디에서 입력 마디까지 역으로 전달되고 전반부 변수가 경사하강법에 의해 조정된다[16].

ANFIS에서 주어진 데이터 집합이  $P$ 엔트리를 가지고 있을 경우,  $p$ 번째 엔트리의 예러는 다음과 같이 정의할 수 있다.

$$E_p = \sum_{m=1}^{\#(L)} (T_{m,p} - O_{m,p}^L)^2 \quad (1 \leq p \leq P) \quad (15)$$

여기서,  $T_{m,p}$ 는  $p$ 번째 목표 출력의  $m$ 번째 요소이며,  $O_{m,p}^L$ 는 실제 출력의  $m$ 번째 요소이다. 따라서 전체 예러는 (16)과 같다.




그림 5. 종 모양 소속함수.  
Fig. 5. Bell membership function.

$$E = \sum_{p=1}^k E_p \quad (16)$$

전반부 변수의 동정을 위한 오류 역전과 알고리즘은 (17)과 같이 에러 값을 편 미분하여 퍼지 규칙의 전반부 파라미터를 동정한다

$$\Delta\alpha = -\eta \frac{\partial E}{\partial \alpha} \quad (17)$$

여기서,  $\eta$ 는 학습율이며 (18)과 같이 계산된다.

$$\eta = \frac{k}{\sqrt{\sum_a \left(\frac{\partial E}{\partial \alpha}\right)^2}} \quad (18)$$

새로운 파라미터  $\alpha$ 는 (19)과 같이 갱신된다.

$$\alpha_{n+1} = \alpha_n + \Delta\alpha \quad (19)$$

여기서,  $\alpha$ 는 (14)의  $\{a_i, b_i, c_i\}$  파라미터 집합을 의미한다.

#### IV. 칼라 RGB 특성곡선 모델링

##### 1. 칼라 RGB 데이터

본 연구에서는 실제 칼라 조제 공정에서 사용하는 표 1의 RGB 데이터를 이용한다. RGB 각각은 0에서 255까지의 값을 갖는데, 이는 컴퓨터 그래픽 상에서 다루고 있는 칼라는 24비트 칼라로 RGB값이 각각 8비트에 해당하는 값을 가지게 된다. 따라서 각 색은  $2^8 = 256$  단계의 명도 값을 가지는 색으로 표현되는 것이다. 표 1에서 Yellow 5GN, Yellow RXL, Red 10B, Red B, Red F-3GL, Blue G, Blue 5GM, Blue 6B로 표시된 가로축은 실제 공정에서 사용되는 칼라의 명칭이며, 세로축은 각 칼라의 농도에 따른 RGB 데이터를 나타내고 있다. 표 1에서 알 수 있는 것은 농도의 변화가 0~2.5% 까지이고, 데이터의 수가 8개이다. 여기서 농도는 물 100g에 대한 염료의 첨가량(g)을 나타낸다.

그림 6은 RGB 데이터를 가지고 직접 모니터 상에서 작업하기 위해 델파이(Delphi)로 구현한 RGB 분석 및 생성 프로그램이다. 즉, 측정된 칼라의 RGB 각 값을 입력하면 그 데이터에 대한 칼라의 명칭과 고유 칼라를 함께 보여주는 프로그램으로 RGB 값의 구성 비율과 대응되는 칼라를 바로 확인할 수 있다.

##### 2. 칼라 RGB 특성 곡선 모델링

본 절에서는 8가지의 다른 농도를 가진 임의의 칼라에 대한 RGB 데이터로부터 그 칼라의 특성 곡선을 모델링 한다. 추정된 특성 곡선을 가지고 8가지 외의 농도에 대한 칼라 RGB 데이터를 구함으로써 칼라 조제 정보를 얻을 수 있다. 표 1의 RGB 데이터는 8개의 1출력 1출력 데이터임으로, 성능 평가를 위해서 농도 0.01~2.5% 사이를 균일하게 분할하여 테스트를 하였다. 그리고 출력 오차의 제곱의 평균인 성능지수 PI가 최소화되도록 모델을 찾아 선택한다.

표 1. 칼라 RGB 데이터.

Table 1. RGB data of colors.

| No (%)   | Color | Yellow 5GN | Yellow RXL | Red 10B | Red B | Red F-3 GL | Blue G | Blue 5GM | Blue 6B |
|----------|-------|------------|------------|---------|-------|------------|--------|----------|---------|
| 1 (0.01) | R     | 254        | 251        | 251     | 253   | 254        | 191    | 209      | 202     |
|          | G     | 253        | 240        | 234     | 221   | 225        | 224    | 240      | 212     |
|          | B     | 220        | 212        | 231     | 228   | 221        | 239    | 245      | 242     |
| 2 (0.05) | R     | 255        | 253        | 243     | 252   | 254        | 117    | 158      | 146     |
|          | G     | 254        | 240        | 194     | 170   | 181        | 175    | 215      | 159     |
|          | B     | 183        | 172        | 226     | 205   | 174        | 236    | 243      | 241     |
| 3 (0.1)  | R     | 255        | 254        | 240     | 251   | 254        | 83     | 130      | 120     |
|          | G     | 254        | 233        | 166     | 140   | 159        | 148    | 195      | 129     |
|          | B     | 150        | 131        | 218     | 186   | 148        | 226    | 235      | 235     |
| 4 (0.2)  | R     | 255        | 254        | 231     | 250   | 255        | 42     | 100      | 90      |
|          | G     | 254        | 218        | 129     | 116   | 138        | 123    | 171      | 97      |
|          | B     | 118        | 93         | 198     | 167   | 119        | 214    | 226      | 220     |
| 5 (0.5)  | R     | 255        | 254        | 214     | 243   | 254        | 1      | 38       | 35      |
|          | G     | 254        | 202        | 89      | 64    | 112        | 73     | 131      | 34      |
|          | B     | 40         | 40         | 167     | 128   | 59         | 180    | 201      | 192     |
| 6 (1.0)  | R     | 255        | 253        | 198     | 236   | 255        | 0      | 18       | 17      |
|          | G     | 253        | 181        | 43      | 33    | 92         | 46     | 107      | 8       |
|          | B     | 0          | 7          | 142     | 105   | 18         | 157    | 179      | 168     |
| 7 (1.5)  | R     | 255        | 251        | 188     | 231   | 254        | 1      | 14       | 13      |
|          | G     | 252        | 164        | 26      | 22    | 81         | 39     | 92       | 4       |
|          | B     | 0          | 0          | 128     | 91    | 8          | 144    | 166      | 155     |
| 8 (2.5)  | R     | 255        | 248        | 174     | 226   | 253        | 7      | 16       | 15      |
|          | G     | 249        | 147        | 8       | 14    | 68         | 29     | 75       | 4       |
|          | B     | 0          | 0          | 108     | 77    | 7          | 123    | 149      | 137     |

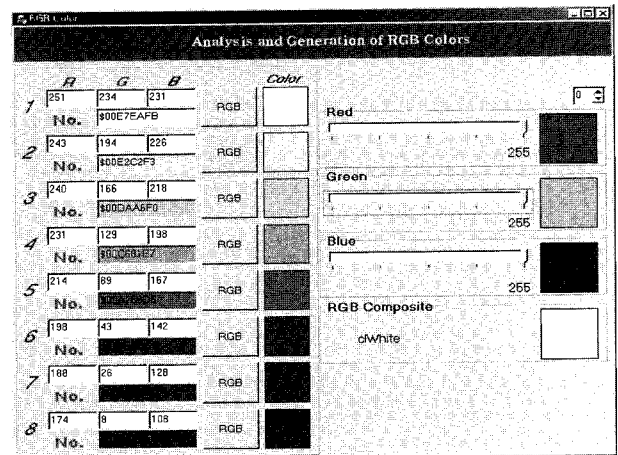


그림 6. RGB 칼라의 분석과 생성 프로그램.

Fig. 6. Analysis and generation program of RGB colors.

$$PI = \frac{1}{m} \sum (y - \hat{y})^2 \quad (20)$$

여기서,  $m$ 은 데이터 수이고,  $y$ 는 실험 값이며,  $\hat{y}$ 는 모델 출력 값이다.

추정된 특성곡선의 결과는  $x$ 축 데이터의 분포가 0~2.5%로 한정되어 있을 뿐 아니라, 0~0.5% 사이에 너무 밀집되어 있기 때문에 이를 보다 가시적으로 쉽게 볼 수 있도록,  $x$ 축에 로그(log)를 취하여 상대적인 대수함수로 나타내었다.

##### 2.1 칼라의 RGB에 대한 회귀다항식 모델링

표 1에서 주어진 RGB 데이터를 최소자승법을 이용하여

(21)의 회귀다항식(1, 2, 3, 4차식)으로 모델링 하였다. 농도 0.01~2.5% 사이를 0.005간격으로 균일하게 분할하여 테스트를 하였다.

$$\begin{aligned}
 &1차 : a_0 + a_1 \times x \\
 &2차 : a_0 + a_1 \times x + a_2 \times x^2 \\
 &3차 : a_0 + a_1 \times x + a_2 \times x^2 + a_3 \times x^3 \\
 &4차 : a_0 + a_1 \times x + a_2 \times x^2 + a_3 \times x^3 + a_4 \times x^4
 \end{aligned}
 \tag{21}$$

Yellow 5GN에 대한 결과의 예로 그림 7과 같은 특성 곡선을 얻는다.

Yellow 5GN에 대한 모델링 결과로 표 2와 같은 성능지수를 얻는다.

2.2 칼라의 RGB에 대한 선형 퍼지 추론 모델링

선형 퍼지 추론 시스템은 입출력 데이터가 비 선형적인 관계에 있을 경우에 매우 효율적으로 적용할 수 있다. 특히 RGB 데이터는 선형이 아니기 때문에 미분방정식이 아닌 퍼지를 이용하여 모델링하는 것이 더 정확할 수 있다. 농도 0.01~2.5% 사이를 0.005간격으로 균일하게 분할하여 테스트를 하였고, 성능평가는 (20)을 사용하였다.

우선 선형 퍼지 추론 시스템의 퍼지규칙을 (6)과 같이 만들고, 규칙에 대한 소속 함수를 정의하여 시스템을 모델링 하였다.

표 2. Yellow5GN에 대한 회귀 다항식 모델 성능 지수.  
Table 2. Performance index of yellow 5GN in regression polynomial model.

| Yellow 5GN | 1차       | 2차       | 3차        | 4차         |
|------------|----------|----------|-----------|------------|
| R          | 0.056205 | 0.011533 | 0.0015296 | 0.00013044 |
| G          | 1.7516   | 0.41738  | 0.092567  | 0.0045467  |
| B          | 329.06   | 294.68   | 52.772    | 19.267     |

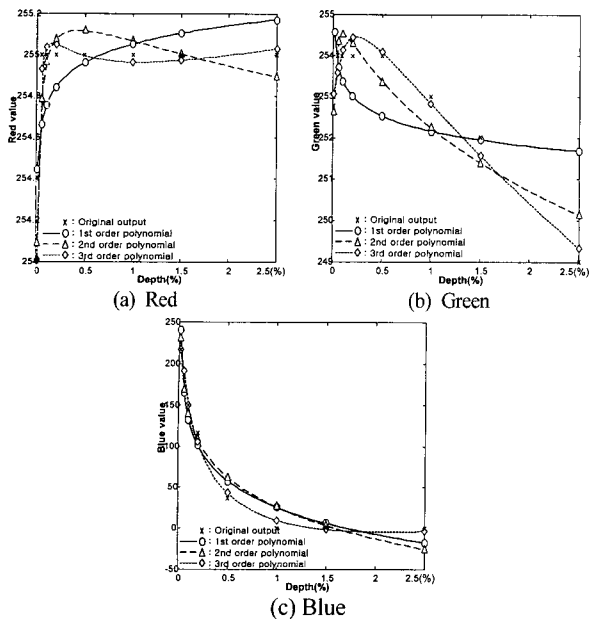


그림 7. Yellow 5GN의 회귀 다항식 모델의 결과.  
Fig. 7. Result of yellow 5GN in regression polynomial model.

본 논문에서는, 전반부의 소속함수는 농도 0~2.5% 사이의 범위를 갖고, 크기는 1을 가진 규칙 2개와 3개의 삼각형 및 가우시안 소속함수를 사용하며, 모양은 그림 8과 같다. 후반부 함수는 (21)과 같은 회귀 다항식을 이용한다.

주어진 RGB 데이터는 농도 0~2.5%까지의 변화를 전반부 입력 범위로 설정하였으며, 퍼지 규칙에서의 0과 1사이의 값으로 그 크기를 정의했다. 그리고 출력값은 0에서 255사이의 RGB 데이터가 될 것이며, 이는 후반부 추론의 결과 값 y가 된다.

선형 퍼지 추론에 의한 모델링 결과 중 Yellow 5GN의 결과를 그림 8과 표 3에 나타내었다.

그림 9와 표 3의 결과는 선형 퍼지 추론 모델의 결과 중 가장 좋은 결과만을 나타내었다. 그림 9에서 (a)는 전반부를 가

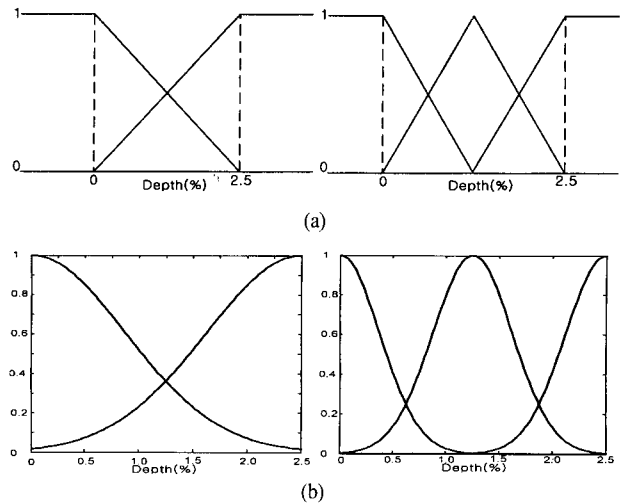


그림 8. (a) 규칙 2, 3개의 삼각형 소속함수.  
(b) 규칙 2, 3개의 가우시안 소속함수.  
Fig. 8. (a) Triangular MFs with 2 or 3 rules.  
(b) Gaussian MFs with 2 or 3 rules.

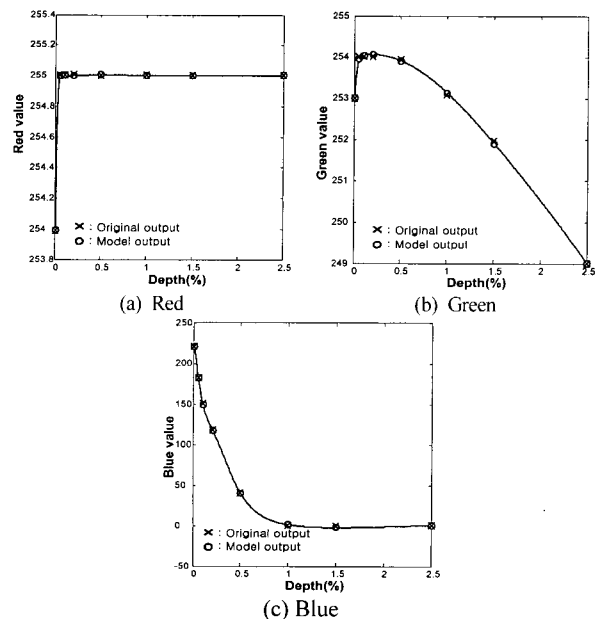


그림 9. Yellow 5GN의 퍼지 모델 결과.  
Fig. 9. Result of yellow 5GN in fuzzy model.

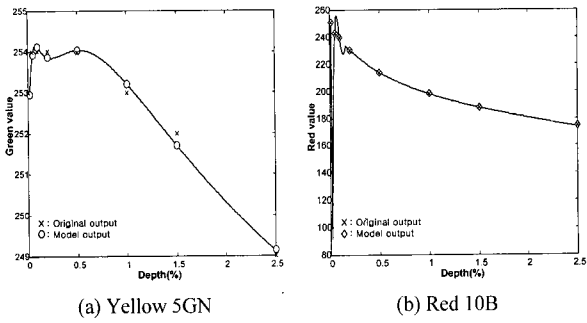


그림 10. 퍼지 모델의 좋지 않은 결과의 예.  
Fig. 10. Bad result examples of fuzzy model.

표 3. Yellow5GN에 대한 퍼지 모델의 성능 지수.  
Table 3. Performance index of yellow 5GN in fuzzy model.

| Yellow 5GN | Performance Index(PI) |
|------------|-----------------------|
| R          | 9.5666e-016           |
| G          | 3.5994e-003           |
| B          | 1.9317e-007           |

우시안 소속 함수의 규칙 2개로 구성하고 후반부를 회귀 다항식 3차 모델링한 경우이고, (b)는 전반부를 삼각형 소속 함수의 규칙 2개로 구성하고 후반부를 회귀 다항식 4차 모델링한 경우이며, (c)는 전반부를 가우시안 소속 함수의 규칙 2개로 구성하고 후반부를 회귀 다항식 3차 모델로 모델링한 경우이다. 그림 10은 선형 퍼지 추론 모델의 결과 중 좋지 않은 성능을 보이는 것의 예이다. (a)는 Yellow 5GN의 G 값의 결과로 전반부 가우시안 소속 함수 3개 후반부 1차 선형식을 사용한 경우이고, (b)는 Red 10B의 R값에 대한 결과로 전반부에 삼각형 소속 함수 규칙 3개를 사용하고, 후반부에는 3차식을 사용한 결과이다. 퍼지 모델링의 경우 농도 0~0.5% 사이에서 큰 진동이 나타나는 것을 볼 수가 있다.

2.3 칼라의 RGB에 대한 ANFIS 모델링

선형 퍼지 추론 방법으로 비선형 특성을 갖는 RGB 데이터를 모델링한 결과, 입력 데이터의 전반부에서 그림 10과 같은 큰 진동이 나타남을 볼 수 있다. 이를 보정하고자 신경망 개념을 도입한 ANFIS를 이용한다[16]. 주어진 조건은 선형 퍼지 추론과 같고, (22)와 같은 2개의 규칙을 사용하며, 전반부 소속 함수는 벨 모양을, 후반부는 1차 다항식  $a_0 + a_1x$ 를 이용한다. 그리고 학습 횟수는 500번으로 하였다.

$$R^1 : \text{If } x \text{ is } A_1, \text{ Then } Y = a_{01} + a_{11}x \quad (22)$$

$$R^2 : \text{If } x \text{ is } A_2, \text{ Then } Y = a_{02} + a_{12}x$$

Yellow 5GN에 대해 ANFIS를 이용하여 모델링한 결과로 그림 11과 같은 특성 곡선을 얻는다.

그림 12는 Yellow 5GN에 대한 ANFIS 모델의 RMSE(Root mean squared error) 곡선과 최적화된 소속 함수의 결과를 나타내었다. Yellow 5GN에 대한 ANFIS 모델의 성능지수는 표 4와 같다.

ANFIS 모델의 경우 선형 퍼지 추론 모델에서 농도 0.5% 이전에서 나타나는 진동 현상이 보정이 되어 좋은 결과를 얻을 수 있었다.

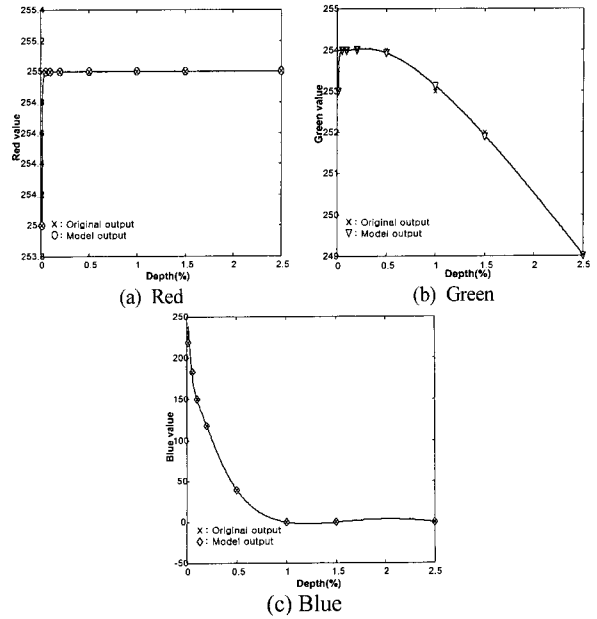


그림 11. Yellow 5GN의 ANFIS 모델 결과.  
Fig. 11. Result of yellow 5GN in ANFIS model.

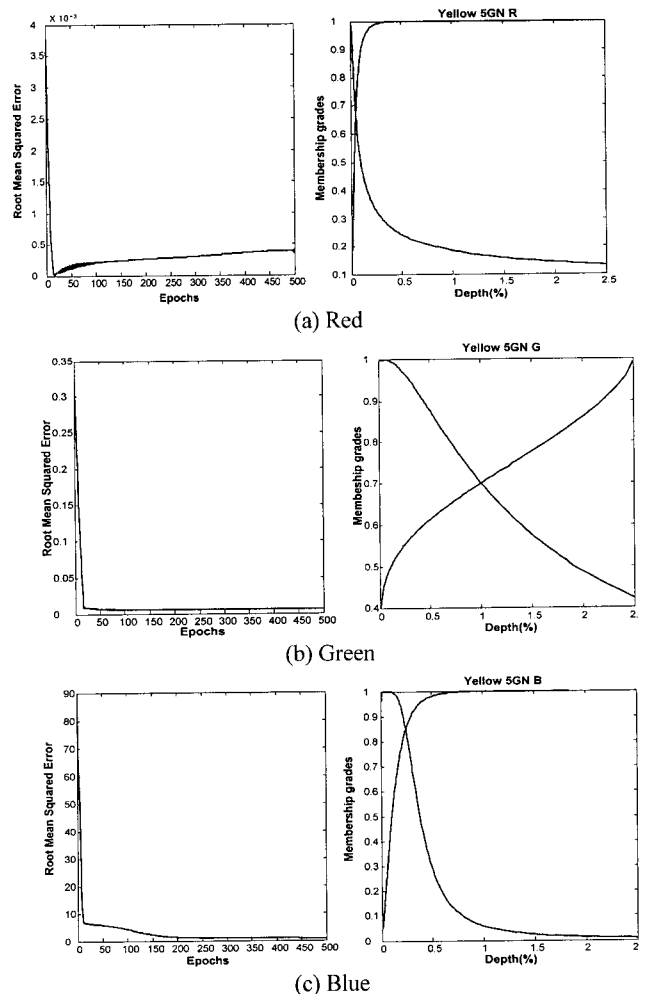


그림 12. Yello 5GN에 대한 ANFIS 모델의 RMSE 곡선 및 최적화된 소속 함수.  
Fig. 12. RMSE curves and optimized membership functions of yellow 5GN in ANFIS model.

3. 시뮬레이션 결과

표 1에 주어진 RGB 데이터를 회귀 다항식, 선형 퍼지 추론 시스템 및 ANFIS를 이용하여 칼라의 RGB 모델을 추정하였다. 표 5는 각 모델에 대한 성능평가를 비교한 것으로, 회귀다항식 모델의 경우는 차수를 고려하지 않고 성능지수가 가장 좋은 결과 값을 나타내었고, 퍼지 모델의 경우는 전반부 소속함수와 후반부 다항식을 고려하지 않고 성능지수가 가장 좋은 결과만을 나타내었으며, ANFIS 모델의 경우는 입력 층에 2개의 소속함수와 후반부에 1차의 다항식을 사용하여 나타낸 결과이다. 표 5의 결과에서는 퍼지 모델이 ANFIS 모델에 비해 성능이 우수한 것으로 보인다. 그러나 규칙의 수와 후반부 선형식의 차수를 고려할 때, ANFIS 모델은 퍼지 모델에서 나타나는 진동을 보정할 수 있으며, 규칙의 수를 증가시켜 보다 나은 결과를 얻을 수 있다.

또한, 칼라 식별의 관점에서 두 칼라의 차이가 0.1 이하이면 육안으로 칼라의 차이를 식별할 수 없는 범위이므로 구현된 ANFIS 모델의 성능만으로도 칼라 모델을 실제 적용하는데 충분하다. 나머지 색에 대해서도 같은 방법으로 모델링하여 비슷한 결과를 얻을 수 있었다. 특히 Blue G 염료는 ANFIS 모델에서만 정확한 모델을 추정할 수 있었다.

V. 칼라 전문가 시스템의 구현

1. 칼라 매저링/매칭 전문가 시스템

본 논문에서는, 칼라의 이미지 처리기법과 지능형 모델링 기법을 이용하여, 샘플 칼라의 RGB 데이터를 분석하고 그 샘플 칼라와 같은 색을 정확히 구현하는 칼라 매저링/매칭 전문가 시스템을 구현하였다. 그림 13은 제안한 시스템의 전체 구성도를 나타내고 있다.

칼라 매저링/매칭 전문가 시스템을 구현하기 위해서는 많은 공정이 요구되는데 이 중에서 중요한 공정 중 하나가 컴퓨터를 이용한 칼라의 측정과 매칭공정 부분이다. 컴퓨터는 스캐너를 통해 얻어진 컴퓨터 이미지를 전 처리하는데 사용하는 것뿐만 아니라, 칼라 모델을 기반으로 한 염료 조제 데이터베이스의 구축과 관리를 위해 이용된다. 이러한 모델 기반의 컴퓨터 시스템을 그림 14에 나타내었다.

표 4. Yellow 5GN에 대한 ANFIS 모델의 성능지수.  
Table 4. Performance index of yellow 5GN in ANFIS model.

|   | Performance Index(PI) |
|---|-----------------------|
| R | 5.4756e-006           |
| G | 0.005847              |
| B | 0.039966              |

표 5. 각 모델의 성능 비교.  
Table 5. Performance comparisons for each model.

|            | Yellow 5GN | Red 10B      | Blue G      |              |
|------------|------------|--------------|-------------|--------------|
| 회귀 다항식 모델링 | R          | 1.3044e-004  | 2.1687e-001 | 10.1520e-000 |
|            | G          | 4.5467e-003  | 7.3292e-000 | 4.9002e-000  |
|            | B          | 19.2671e-000 | 1.2158e-000 | 2.5164e-000  |
| 퍼지 모델링     | R          | 9.5666e-016  | 9.0702e-021 | 1.3789e-000  |
|            | G          | 3.5994e-003  | 8.5436e-016 | 3.7606e-000  |
|            | B          | 1.9317e-007  | 1.4920e-021 | 1.6885e-000  |
| ANFIS 모델링  | R          | 5.4756e-006  | 5.4593e-003 | 1.4942e-001  |
|            | G          | 5.8470e-003  | 1.9329e-006 | 1.1719e-001  |
|            | B          | 3.9966e-002  | 5.7917e-002 | 8.0340e-006  |

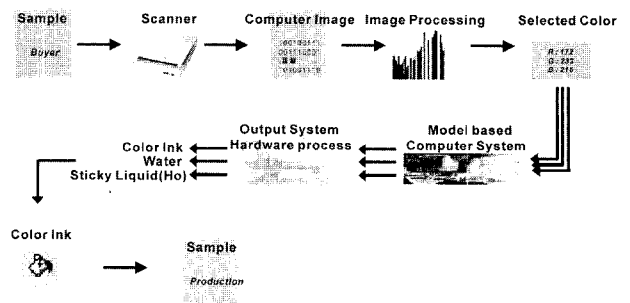


그림 13. 칼라 매저링/매칭 전문가 시스템의 전체 구성도.  
Fig. 13. Overall scheme of color measuring/ matching expert system.

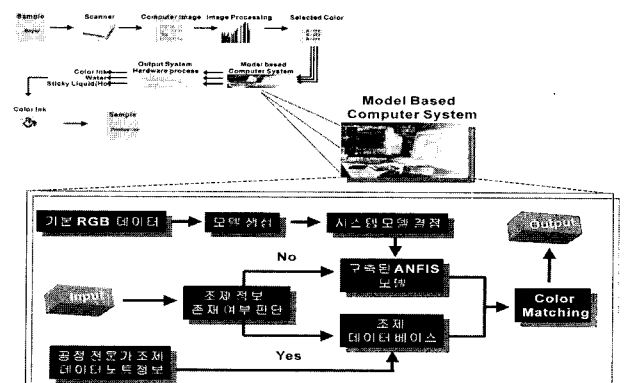


그림 14. 모델 기반 컴퓨터 시스템.  
Fig. 14. Model based computer system.

모델 기반의 컴퓨터 시스템은 크게 두 부분으로 되어 있다. 첫째는 컴퓨터 시스템이 이미 저장하고 있는 전문가의 노트 정보 데이터베이스를 이용하여 임의의 입력 데이터를 비교 매칭하는 기능이다. 둘째는, 만약 입력 데이터가 데이터베이스에 존재하지 않으면, 지능형 알고리즘으로 구현된 칼라 모델을 통해 칼라를 측정하고 매칭한다. 구현된 칼라의 매칭은 칼라의 차이를 나타내는 델타 E(Delta E)를 가지고 원본의 RGB 데이터와 비교하는 방법으로 실행된다.

2. 칼라 매칭

이미지 히스토그램 분석을 통하여 얻은 원본 칼라 이미지의 RGB 데이터와 조제 정보 데이터 베이스 또는 ANFIS로 구현된 칼라 모델의 RGB 데이터를 가지고 구현한 칼라의 차이를 (23)의 델타 E를 이용하여 비교한다. 이 방법은 실제 공정에서 사용하는 방법으로 두 데이터간의 칼라 차이(color difference)와 인식 범위를 이용하고 있다. 칼라 매칭은 (23)의 허용 범위 안에서 이루어진다. 두 색의 차이가 0.0~0.1일 경우 색의 차이를 육안으로 식별이 불가능하며, 0.2~0.4일 경우 전문가에 의해 색의 차이를 식별할 수 있다. 그 외 0.4~0.8일 경우 일반인이 식별 가능한 범위이며 그 차이가 12.0이면 별도의 색 계통임을 의미한다[10].

$$\Delta E = \sqrt{(R_o - R_t)^2 + (G_o - G_t)^2 + (B_o - B_t)^2} \quad (23)$$

여기서,  $R_o, G_o, B_o$ 는 원본 샘플 이미지에 대한 R, G, B 값이고  $R_t, G_t, B_t$ 는 조제 데이터베이스 또는 ANFIS로 구



현한 칼라 모델을 통해 구현한 칼라의 가R, G, B값으로 원본 이미지와 매칭될 칼라의 R, G, B값이다.

3. 컴퓨터 칼라 매칭 프로그램의 구현

칼라 매칭 프로그램은 칼라 샘플을 컴퓨터 이미지로 변환하는 스캐너 제어 프로그램, 히스토그램 기법을 이용한 이미지 프로세싱, 델타 E 비교 프로그램, 데이터 베이스 프로그램뿐만 아니라 매칭의 결과로 나온 RGB 데이터를 기반으로 그에 해당하는 조제 데이터를 데이터 베이스에서 찾아 기계로 신호를 넘겨주는 기계제어 프로그램도 포함하고 있다.

그림 15는 델파이로 구현한 컴퓨터 칼라 매칭 프로그램의 GUI들이다. (a)는 매칭(Matching) 창의 GUI로 입력 이미지를 관리하면서 데이터 베이스 안의 데이터와 입력된 이미지간의 델타 E의 값을 비교하면서 매칭하는 기능을 한다. (b)는 저장(Storage) 창의 GUI로 스캐너를 제어하며 직접 샘플 이미지를 컴퓨터 이미지로 변환하여 저장하고 이미지 히스토그램을 이용하여 왜곡 요소를 처리하고 칼라를 측정한 후 매칭 부분으로 넘겨주는 화면으로 매칭 이전 단계의 역할을 한다. (c)는 조제(Recipe) 창의 GUI로 직접 데이터 베이스와 연계되어 있고 새로운 조제 샘플 데이터에 대한 입력을 관리하는 화면이다. 각 공정마다 칼라 염료 탱크 수에 따라 관리할 수 있으며 물과 동시에 접착 염료(호, ho) 탱크의 상태를 직접 보여주고 있다. (d)는 조제 정보 데이터베이스의 데이터를 직접 염료 조제 기계로 넘겨주는 창의 GUI로 (a)의 매칭이 확인되면, 각 탱크에 대한 수치 정보와 Recipe 창의 데이터를 그대로 읽어들이어 RS232 통신을 통해 하드웨어로 넘겨주는 화면이다. 그밖에, 컴퓨터 칼라 매칭 GUI로 직접 데이터 베이스 데이터 수치를 넘겨 줄뿐 아니라 배합될 염료의 무게를 측정하는 기계 저울에 대한 데이터를 받을 수 있는 화면도 설계하였다.

VI. 결론

본 논문에서는 지능형 알고리즘과 이미지 프로세싱 기술을 결합한 새로운 칼라 매저링 방법을 가진 칼라 매저링/매

칭 전문가 시스템을 구현하였다. 칼라 매저링 방법은 입력 이미지의 왜곡 요소를 제거하기 위해, 이미지 픽셀의 히스토그램을 이용하여 전 처리한 후 칼라의 RGB 데이터를 추출하여 정확한 칼라를 측정하고, 입력된 원본 칼라의 정보가 데이터 베이스에 없을 경우, 지능형 모델링 기법인 적응 퍼지 뉴로 추론 방법으로 찾아냄으로서 사용자가 원하는 칼라를 용이하게 조제할 수 있게 하였다. 칼라 매칭은 전 처리된 칼라의 데이터와 조제된 칼라를 실제 공정에서 사용하는 델타 E의 오차 범위에서 비교함으로써 사용자가 원하는 칼라를 용이하게 선택할 수 있게 하였다.

본 논문의 연구 결과를 요약하면 다음과 같다.

첫째, 실제 염색된 천을 직접 스캐너를 통해 컴퓨터 이미지로 변환하고 왜곡 요소를 이미지 히스토그램으로 분석하여 원본 칼라의 RGB를 추출하는 프로그램을 구현하였다.

둘째, 적은 수의 입력력 데이터에도 불구하고, 지능형 모델인 ANFIS를 이용하여 우수한 칼라 추정 성능을 얻을 수 있었다.

셋째, 칼라의 매저링, 매칭 및 염료 제조 공정에 필요한 통합 운영프로그램 및 GUI(Graphical user interface)를 구현하였다.

끝으로, 본 연구의 결과는 단색의 위주의 칼라 이미지에 대해서는 우수한 매저링 및 매칭 성능을 보이나, 각기 다른 2가지 이상의 칼라를 가진 이미지의 경우 왜곡 요소를 제거하는 과정에서 한 색상 영역의 왜곡 요소의 제거가 다른 색상에 영향을 미치는 경우가 있으므로, 전체 이미지를 동시에 처리하지 못하고 각 영역을 선택하여 순차적으로 처리하도록 하였다. 차후의 연구에는 원본 이미지의 모든 칼라를 동시에 처리하고, 칼라의 RGB 데이터와 실제 염료의 배합 비율을 동시에 구할 수 있는 모델에 대한 연구가 계속되어야 할 것이다.

참고문헌

- [1] M. Sugeno and G. T. Kang "Structure identification of fuzzy model," *Fuzzy Set and Systems*, vol. 28, pp. 15-33, 1988.
- [2] G. T. Kang and M. Sugeno, "Fuzzy modeling," *Transactions. of the Society of Instrument and Control Engineers*, vol. 23, no. 6, pp. 106-108, 1987.
- [3] R. M. Tong, "Synthesis of fuzzy models for industrial processes," *Int. J. Gen. Systems*, vol. 4, pp. 143-162, 1978.
- [4] T. C. Ahn and S. M. Ryu, "Fuzzy PNN algorithm and its application to nonlinear processes," *Int. J. Gen. Systems*, vol. 30, no. 4, pp. 463-478, Aug. 2001.
- [5] W. Pedrycz, "An identification algorithm in fuzzy relational system," *Fuzzy Sets and Systems*, vol. 13, pp. 153-167, 1984.
- [6] R. R. Yager, "Fuzzy modeling for intelligent decision making under uncertainty," *IEEE Transactions on Systems, Part B: Man and Cybernetics*, vol.30, no.1, pp. 60-70, 2000.
- [7] M. Sugeno and T. Yasukawa, "A fuzzy-logic-based approach to qualitative modeling," *IEEE Trans. on Fuzzy System*, vol. 1. no. 1, pp. 7-31, Feb., 1993.

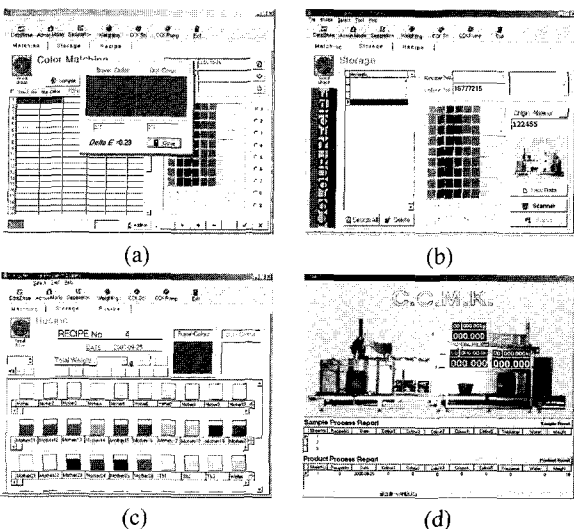



그림 15. 칼라 비교 컴퓨터 프로그램.  
Fig. 15. Computer color matching program.

- [8] M. J. Swin, "Interactive indexing into image databases," *SPIE Proceedings : Storage and Retrieval for Image and Video Databases*, vol. 1980, pp. 95-103, Feb., 1993.
- [9] A. Petland, R. W. Picard, and S. Sclaroff, "Photobook : Tools for content-based manipulation of image database," *SPIE Proceedings: Storage and Retrieval for Image and Video Databases II*, vol. 2185, pp. 34-47, Feb., 1994.
- [10] C. Connolly and T. Fliess, "A study of efficiency and accuracy in the transformation from RGB to CIELAB color space," *IEEE Trans. on Image Processing*, vol.6 no.7, pp. 1046-1048, 1997.
- [11] S. H. Boyle, "Image processing, analysis, and machine vision," *Second Edition*, PWS, Boston, 1998.
- [12] J. R. Parker, "Algorithms for image processing and computer vision," Wiley, N. Y., 1996.
- [13] P. Bosdogianni, "Image processing : The fundamentals," Wiley, N. Y., 1999.
- [14] R. Crane, "A simplified approach to image processing : Classical and modern techniques in C," Prentice Hall, N. J., 1999.
- [15] 오성권, "C-프로그래밍에 의한 퍼지 모델 및 제어 시스템" 내하출판사, 2000.
- [16] J. R. Jang, "ANFIS : Adaptive-network-based fuzzy inference system," *IEEE trans. on System, Man and Cybernetics*, vol. 23, no. 3, pp. 665-685, 1994.
- [17] 류상문, 한일석, 박병준, 안태천, "퍼지 모델링 기법을 이용한 새로운 칼라 조제 방법," 대한전기학회 하계학술대회, vol. D, pp. 2395-2397, Jul., 2000.
- [18] T. Muraoka and N. Nakashima, "New color matching system for color reproduction," *Proc. of 11th KACC*, Oct, 1996.



안 태 천

1955년 10월 11일생. 1978년 연세대 전기공학과 졸업. 동대학원 석사(1980), 동대학원 공학박사(1986). 1981년~현재 원광대학교 전기전자 및 정보공학부 교수. 관심분야는 지능형 모델링 및 제어응용, 디지털 신호처리, 지능 정보 제어, Image processing.



오 성 권

1957년 2월 13일생. 1981년 연세대 전기공학과 졸업. 동대학원 석사(1983), 금성 산전 연구소 선임 연구원(1983~1989), 연세대학교 대학원 공학 박사(1993). 1993년~현재 원광대학교 전기전자 및 정보공학부 부교수. 2002년 현재 대한전기학회 및 제어·자동화·시스템공학회 편집위원. 관심분야는 시스템 자동화, 퍼지 이론 및 신경회로망 응용, 계산지능 및 소프트웨어 컴퓨팅.



장 경 원

1974년 9월 30일생. 2001년 원광대 제어계측공학과 졸업. 2001~현재 원광대 전기전자 및 정보공학부 석사과정. 관심분야는 지능형 모델링 및 제어, Image processing, Machine vision.