

목표색상 재현을 위한 페인트 안료 배합비율의 예측

박창원 · 황규석[†]

부산대학교 화학공학과
(2008년 7월 25일 접수 ; 2008년 10월 1일 채택)

Recipe Prediction of Colorant Proportion for Target Color Reproduction

Chang-Won Park · Kyu-Suk Hwang[†]

Dept. of Chemical Eng., Pusan National University
(Received July 25, 2008 ; Accepted October 1, 2008)

Abstract : For recipe prediction of colorant proportion showing nonlinear behavior, we modeled the effects of colorant proportion of basic colors on the target colors and predicted colorant proportion necessary for making target colors. First, colorant proportion of basic colors and color information indicated by the instrument was applied by a linear model and a multi-layer perceptrons model with back-propagation learning method. However, satisfactory results were not obtained because of nonlinear property of colors. Thus, in this study the neuro-fuzzy model with merit of artificial neural networks and fuzzy systems was presented. The proposed model was trained with test data and colorant proportion was predicted. The effectiveness of the proposed model was verified by evaluation of color difference(ΔE).

Key Words : Colorant, Recipe Prediction, Neuro-fuzzy System, Back-propagation, Color Difference

1. 서론

다양한 공업제품의 색상을 나타내기 위한 안료 배합 기술은 현재 외국산 컬러 컴퓨터를 사용하여 이루어지고 있다. 외국산 컬러 컴퓨터가 제시하는 배합 비율은 특정한 외국의 안료를 기준으로 하여 만들어 졌기 때문에 국내의 컬러 처리기술을 개발하지 않으면 국내에서 안료를 정밀하게 제조할 수 있는 능력이 있을지라도 외국 회사의 안료를 사용할 수 밖에 없다.

이러한 안료 배합 기술은 페인트 제조, 플라스틱 산업 등 안료를 배합하여 필요한 색상을 정밀하게 제조하는 조색 공정에 있어 가장 중요한 공정으로 간주되고 있다[1].

목적으로 하는 색의 제조에 필요한 안료의 배합 비율을 예측하는 것은 안료와 색상의 다변수적인 특성과 비선형성의 특성으로 인해 지금까지도 방대한 데이터를 이용한 조색자의 시각적인 감각에 의해서 배합되고 있는 실정이다 [2]. 또한 각각의 조색자는 다른 색감각을 가지고 있을 수 있고 주위환경에 따라 조색자가 결정하는 배합 비율이 변할 수가 있다. 이러한

[†] 주저자 (E-mail: kshwang@pusan.ac.kr)

이유로 안료 배합 비율을 예측하기 위하여 인공 신경망을 사용한 컴퓨터 자동 배색 시스템(CCM:computer color matching system) 개발에 관한 연구가 진행되고 있다[3-6,14-20]. 인공 신경망의 단점을 보완하고자 Bishop은 시스템의 구조 설계 시 유전자 알고리즘을 사용하였으며[4], 또한 여러 가지 컬러 데이터를 사용하여 예측시스템을 학습시키는 연구가 활발히 진행되고 있으나[5], Westland는 학습 정지 조건을 학습 반복횟수(epochs) 55,000회를 사용하였으며 매우 느린 학습 속도를 나타내었다[6].

본 연구에서는 인공 신경망 모델의 단점을 극복한 뉴로-퍼지(neuro-fuzzy) 모델을 개발하여 기본 안료가 최종색상에 미치는 영향을 모델링하고 최종색상의 제조에 필요한 안료의 배합 비율을 예측하는 것을 그 목적으로 한다.

2. 이론

2.1. 색의 3속성

색의 3속성은 밝고 어두움을 판단하는 명도(Lightness), 무채색으로부터 벗어난 정도를 나타내는 채도(Chroma), 유색을 나타내는 색상(Hue)으로 이루어지며, CIE(commission international de l'eclairage)에서는 색의 객관적 표현이 가능하도록 표준을 설정하였다[1]. 광원은 텅스텐 전구를 대표하는 A형, 태양 직사광선을 대표하는 B형, 한 낮의 하늘로부터 들어오는 빛을 대표하는 C형, 하루 동안의 태양광선을 평균한 D형 광원으로 분류할 수 있다. 또한, CIE에서는 색을 지각하는 눈은 사람마다 다르기 때문에 컬러 매칭 함수(color matching function) (\bar{x} , \bar{y} , \bar{z})이라는 CIE 표준 관측자를 제시하였다(Fig. 1). 본 연구에서는 공업적으로 널리 사용되며, 광원 B, C에 부족한 자외선을 보충한 D형 광원의 2도(2°)시야에서의 컬러 매칭 함수를 사용하였다.

물체색은 광원의 가시영역 파장 범위에서 물체의 반사율에 의한 상대 분광 분포 에너지와 컬러 매칭 함수(color matching function)의 값에 의해서 색상이 결정된다. 시세포는 물체의 색을 적(R), 녹(G), 청(B)의 혼합으로 색을 인식하게 되고, 따라서 적(R), 녹(G), 청(B)의 3원색 광을 적당히 가법 혼합하면 임의의 색을 얻

을 수 있다. 이들 3원색 광은 태양광의 가시광선 파장 영역 700nm, 546.1nm, 435.8nm에 해당한다.

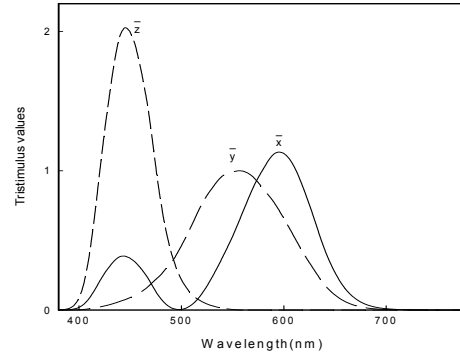


Fig. 1. Color matching functions.

2.2. 반사에 의한 3자극치

XYZ 표색계에서 반사에 따른 물체색의 3자극치 XYZ는 다음 식에 따라 구한다[1].

$$X = K \int_{380}^{780} S(\lambda) \bar{x}(\lambda) R(\lambda) d\lambda$$

$$Y = K \int_{380}^{780} S(\lambda) \bar{y}(\lambda) R(\lambda) d\lambda$$

$$Z = K \int_{380}^{780} S(\lambda) \bar{z}(\lambda) R(\lambda) d\lambda$$

$$K = \frac{100}{\int_{380}^{780} S(\lambda) \bar{y}(\lambda) d\lambda}$$

여기서,

$S(\lambda)$: 색의 표시에 사용되는 표준광의 분광 분포

$\bar{x}(\lambda)$, $\bar{y}(\lambda)$, $\bar{z}(\lambda)$: XYZ 표색계에서의 등색함수

$R(\lambda)$: 분광입사각 반사율

2.3. CIEL*a*b* 표색계

산업 현장에서 가장 널리 사용되고 있는 CIEL*a*b* 표색계는 a*(red-green), b*(yellow-blue)라는 보색 이론에 바탕을 두고 있으며, 명도를 가지는 L*축의 영향으로 3차원으로 표현

된다. CIEL*a*b* 표색계는 3자극치의 XYZ를 사용하여 다음과 같이 구한다.

$$L^* = 116 (Y / Y_n)^{1/3} - 16$$

$$a^* = 500 [(X / X_n)^{1/3} - (Y / Y_n)^{1/3}]$$

$$Y / Y_n > 0.008856$$

$$b^* = 200 [(Y / Y_n)^{1/3} - (Z / Z_n)^{1/3}]$$

$$L^* = 903.29 (Y / Y_n)$$

$$a^* = 500 \times 7.787 [(X / X_n) - (Y / Y_n)]$$

$$Y / Y_n \leq 0.008856$$

$$b^* = 200 \times 7.787 [(Y / Y_n) - (Z / Z_n)]$$

위의 X_n, Y_n, Z_n 은 표준광의 3자극치이며, 본 연구에서 사용된 D형 광원, 2°의 3자극치의 값은 $X_n=95.045, Y_n=100, Z_n=108.892$ 를 가진다.

2.4. 색차의 표시

$L^* a^* b^*$ 표색계에 의한 색차는 다음과 같다. 색의 속성을 대표하는 명도(L^*), 색상(H), 채도(C)는 다음과 같이 구해질 수 있다.

Color difference :

$$\Delta E^* = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2}$$

Lightness(L^*) : L^*

Hue(H) : $\arctan(b^* / a^*)$

Chroma(C) : $\sqrt{(a^*)^2 + (b^*)^2}$

3. 안료 배합 비율에 의한 색상 변화 실험

실험을 간단히 하기 위하여 우선 다른 2종류의 청색 안료(blue)와 백색 안료(white)를 비율을 달리하면서 교반기를 사용하여 교반시킨다. 지지체인 수지는 유성 우레탄(D-ALE 117, 동성화학)을 사용하였으며, 각 샘플은 건조기를 통해서 충분히 건조시킨다. 각각의 서로 다른 조색 비율로 만들어진 샘플을 색차계(SP-80, Tokyo Denshoku Tech.)로 분석하여 샘플에 대

한 3자극치와 CIEL*a*b* 표색계의 L^*, a^*, b^* 값을 구하고, 뉴로-퍼지 모델에 입력시켜 조색비율과 색상 데이터 간의 상관관계를 충분히 학습시킨다. 다음에, 목표로 하는 색의 L_t^*, a_t^*, b_t^* 을 측정하여, 이미 학습이 이루어진 뉴로-퍼지 모델에 대입하여 조색비율(colorant proportion)을 예측한 후 조색 비율대로 컬러를 만들어 낸다. 이 제작된 컬러에서의 L^*, a^*, b^* 와 우리가 목표로 하는 색의 L_t^*, a_t^*, b_t^* 와의 색차가 허용 오차 범위를 가질 때 안료의 배합비율을 예측할 수 있게 되는 것이다(Fig. 2).

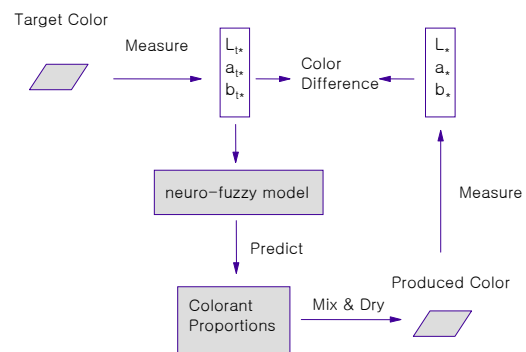


Fig. 2. Color paint manufacturing process.

청색 안료(Blue)에 백색 안료(white)를 첨가함에 따른 3자극치의 값 X, Y, Z (Fig. 3) 와 L^*, a^*, b^* (Fig. 4)의 변화량을 표시하였다. Fig. 3에서는 백색 안료를 첨가함에 따라 X, Y, Z 의 값이 비선형적으로 증가함을 볼 수 있었고, Fig. 4에서는 L^*, a^*, b^* 의 값 중 L^* 과 b^* 의 값이 증가함을 알 수 있었다. 3차원 공간에서 L^*, a^*, b^* 값의 변화 과정을 보면(Fig. 5), L^* 는 명도로서 원추형으로 지면위로 솟아오른 형태를 가지며, 백색 안료가 증가함에 따라서(W+) L^* 의 값은 증가함을 보여주고 있다. Fig. 6에서는 배합비율 중 백색 안료의 양이 많을수록 백색을 나타내는 CIEL*a*b* 표색계의 중심으로 데이터가 이동하는 것을 알 수 있다. CIEL*a*b* 표색계의 적색(red)과 녹색(green)의 축에서 적색쪽으로 가면 a^* 가 (+)값을 갖게 되며, 황색(yellow)과 청색(blue)축에서는 황색쪽으로 가면 b^* 가 (+)값을 갖는다. a^*-b^* 평면에서 a^* 축의 변화량보다 b^* 축으로의 변화량이 큰 이유는 한 가지 유색 안료만을 포함하고 있기 때문이다.




Fig. 3. Effect of white colorant fraction (X, Y, Z).




Fig. 4. Effect of white colorant fraction (L^* , a^* , b^*).




Fig. 5. Sample plot in CIEL^{*}a^{*}b^{*} color space(1).




Fig. 6. Sample plot in CIEL^{*}a^{*}b^{*} color space(2).

4. 결과 및 고찰

인공 신경망을 이용한 모델링 기법은 대상 모델에 대한 학습능력을 갖추고 있기 때문에 학습정도에 따라 정확한 모델을 구축할 수 있다는 장점을 가지고 있다[4]. 그러나, 인공 신경망의 성능은 학습이 이루어진 데이터의 정확도에 의존하므로 제한된 범위 내에서만 적용 가능하다는 단점이 있다. 퍼지 모델링 기법은 퍼지 논리 자체의 비선형적인 특성을 이용하기 때문에 시스템의 비선형적인 특성을 모델링하는데 매우 효과적이다[7-13]. 따라서, 인공 신경망과 퍼지 모델링의 장점을 이용하여 안료 배합 비율을 예측할 수 있는 뉴로-퍼지 모델을 개발하였다.

4.1. 안료 배합 비율 예측 시스템의 구조

본 연구에서는 노드(node)층이 입력층, 출력층, 은닉층(hidden layer)의 3개층(Layers)인 인공 신경망과 퍼지 시스템을 사용하여 학습을 시킨다. 여기서, 인공 신경망은 입력층 노드 8개(2색의 3자극치, 조색비율 x 와 $1-x$), 중간 은닉층 노드 8개 및 출력층 노드 3개(혼합 결과물의 3자극치)를 가지는 3층의 인공 신경망이며, 입력층과 출력층의 직접적인 연결이 없는 다층 신경망(MLP, multi-layer perceptrons) 모델이다. 학습 과정 중 사용한 학습율은 0.6으로 하고, 학습 회수는 12,000회, 비선형 함수는 s자형(sigmoid) 함수(식 (1))를 사용했다.

$$Sigmoid\ Function = \frac{1}{1 + \exp(-\sum)} \quad (1)$$

학습 방법으로는 현재 주어진 연결 강도로 생성되는 오차를 감소시키는 방향으로 연결해 나가는 후방전파(BP, back propagation) 알고리즘을 사용하였다. 후방전파는 학습의 속도가 매우 느리며, 지역적 최소점에 도달하면 빠져 나오기 힘들다는 단점을 지니고 있다. 그래서, 본 연구에서는 기존의 후방전파 알고리즘에 퍼지 시스템을 포함시켜 속도를 향상시켰다.

퍼지 시스템에 적용되는 규칙은 Fig. 7과 같은 "IF-THEN"형식으로 구성되어 19개의 규칙을 가지며, 여기서 PB, PM, PS, ZO, NS, NM 등은 크기를 나타내는 용어이며, e_1, e_2, \dots, e_n 은 오차이고, ce_1, ce_2, \dots, ce_n 은 오차의 변화량이고, co_1, co_2, \dots, co_n 은 퍼지 출력값이다.

<p>Rule(1) : IF e_1 is PB and ce_1 is NS THEN co_1 is PM.</p> <p>Rule(2) : IF e_2 is PB and ce_2 is ZO THEN co_2 is PB.</p> <p style="text-align: center;">⋮</p> <p>Rule(19) : IF e_{19} is NB and ce_{19} is PS THEN co_{19} is NM.</p>

Fig. 7. Fuzzy rules description.

퍼지화된 값을 처리하는 퍼지 추론방법은 직접법인 Mamdani의 최대-최소(max-min) 방식을 사용했으며, 또한 퍼지 추론에서 나온 값을 비퍼지화 시키는 방법으로 멤버십 함수(membership function)의 값을 갖는 모든 요소들의 무게 중심을 취하는 방법인 무게 중심법을 사용했다(식 (2)).

$$co = \frac{\sum[(value\ of\ member)(membership\ of\ member)]}{\sum(memberships)} \quad (2)$$

본 연구에서 사용되어진 뉴로-퍼지 모델에 대한 구조는 아래의 Fig. 8과 같으며, 퍼지 시스템은 인공 신경망의 연결 강도에 관여하게 된다. 인공 신경망의 학습 과정 중, 실험에서 구한 값인 목표 데이터에서 나오는 목표값 y_d 와 인공 신경망을 통해 나오는 출력값 y 의 오

차(e)와 퍼지 추론엔진(fuzzy inference engine)을 이용해서, 각각의 규칙에 대한 적합도를 고려하여 신경망의 연결 강도 수정을 행한다.

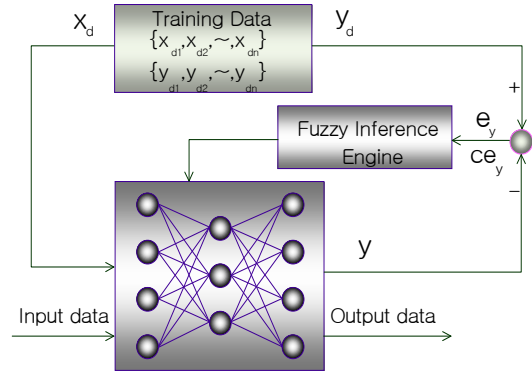


Fig. 8. The architecture of neuro-fuzzy model.

4.2. 학습의 결과

뉴로-퍼지 모델을 사용하여 학습을 시킨 결과 오차의 수렴정도를 Fig. 9에 나타내었다. 수렴정도는 다음의 식으로 평가되었다.

$$Error = \sum_p \sqrt{(O_{p,1} - t_{p,1})^2 + (O_{p,2} - t_{p,2})^2 + (O_{p,3} - t_{p,3})^2} \quad (3)$$

여기서, p 는 패턴의 수, O 는 인공 신경망의 출력값, t 는 목표값을 나타낸다. 학습횟수 약 5,000회에서는 0.1102, 약 12,000회에서는 0.0307의 오차를 가짐을 볼 수 있었다.




Fig. 9. Convergence of the learning.

4.3. 색차(ΔE)의 평가

언어진 배합 비율은 CIEL*a*b* 표색계에서 목표색과 재현색 간의 유클리드 거리를 나타내는 색차에 의해서 평가되며(2.4절참조), ΔE의 값에 따른 사람의 색차 지각 정도는 Table 1에 나타내었다. ΔE가 0.5이하의 값을 가질 때, 사람은 목표색과 재현색의 색 차이를 느끼지 못하므로 두 색은 일치하게 된다. 본 연구에서 얻은 결과를 볼 때(Fig. 12), 백색안료/청색안료의 비율이 0.1 미만인 영역을 제외하고는 ΔE 값이 만족함을 검증할 수 있었다.

Table 1. Degree of human perception

Color difference	Degree of human perception
ΔE = 0.0 ~ 0.5	Almost equal
ΔE = 0.5 ~ 1.5	Some difference
ΔE = 1.5 ~ 3.0	Possible perception
ΔE > 3.0	One can generally differ

4.4. 안료 배합 비율 예측 결과

4.4.1. 선형 모델

Fig. 4에서 얻어진 CIEL*a*b* data 를 사용하여 선형 회귀 분석을 이용한 선형모델을 구하였다 (식 (4)). 선형모델을 이용하여 구한 목표색의 색차는 최대 20의 큰 오차를 보였다(Fig. 10).




Fig. 10. Result of color matching by linear model.

$$L^* : f(x) = 58.04x + 31.99$$

$$a^* : f(x) = -33.69x + 19.78 \quad (4)$$

$$b^* : f(x) = 95.76x - 88.97$$

4.4.2. 신경망 모델과 뉴로-퍼지 모델

퍼지 추론엔진이 생략된 기존의 인공 신경망 모델(MLP 모델)을 사용하여 안료 배합 비율을 예측해 보았다. 학습 반복 횟수 30,000회, 학습율 0.6을 사용하여 목표색의 색차를 평가한 결과(Fig. 11), 평균 3.0의 색차를 보임에 따라 선형모델 보다는 조금 나아졌지만, 여전히 만족할 만한 결과를 얻지 못했다. 뉴로-퍼지 모델에서는 인공 신경망 모델에 사용된 같은 학습율을 사용하였으며, 학습 반복 횟수를 12,000회 사용한 결과 ΔE의 값이 대부분 0.5 이내에 도달하는 결과를 나타내었다(Fig. 12). 목표값과 출력값의 오차를 이용한 퍼지 이론의 도입으로 학습 반복 횟수를 줄였을 뿐만 아니라, 목표색의 색차를 만족할 만한 수준으로 줄일 수 있었다.




Fig. 11. Result of color matching by neural networks model.




Fig. 12. Result of color matching by neuro-fuzzy model.

5. 결론

본 연구에서는 목적으로 하는 컬러샘플을 제조하기 위한 페인트 안료의 배합 비율을 예측하는 시스템을 뉴로-퍼지 모델을 사용하여 구축하였다. 기존의 신경망 모델에 퍼지 이론을 접목시킨 뉴로-퍼지 시스템을 사용하여 시스템의 학습 속도 향상과 더불어 목표색의 색차를 획기적으로 줄일 수 있었다. 샘플컬러의 L^* , a^* , b^* 값과 안료의 배합 비율을 사용하여 선형화시킨 선형모델, 인공 신경망(MLP) 모델, 뉴로-퍼지 모델을 사용하여 목표색의 색차(ΔE)를 구하여 평가한 결과 뉴로-퍼지 모델이 가장 우수하였다.

본 연구에서 좀 더 정확한 안료 배합 비율을 예측하기 위해서는 여러 가지 안료에 대한 방대한 컬러 데이터 베이스의 구축과 고 정밀도의 색차 측정 장치에 의한 입력 데이터의 신뢰성 확보가 필요하다고 생각된다.

감사의 글

본 연구는 두뇌한국 21(BK21) 사업의 지원과 부산대학교 자유과제 학술 연구비(2년)에 의하여 연구되었음.

참고문헌

1. F. W. Billmeyer and M. Saltzman, "Principle of Color Technology", John Wiley & Sons (1981).
2. S. M. Courtney, L. H. Finkel, and Gershon. Buchsbaum, A multistage Neural Network for Color Constancy and Color Induction, *IEEE Transactions on Neural Networks*, **6(4)**, 972 (1995).
3. J. Spehl and M. Wolker, Application of Back-propagation Nets for Color Recipe Prediction as a Nonlinear Approximation Problem, *IEEE*, 60 (1994).
4. J. M. Bishop and M. J. Bushnell, Genetic optimisation of Neural Network Architectures for Colour Recipe Prediction, *Proc. Int. Conf. Neural Networks and Genetic Algorithms*, 726 (1993).
5. J. J. Warren and T. K. Eva, Using Neural Networks to Predict Dye Concentrations in Multi-Dye Mixtures, *Textile Res. J.*, **63(9)**, 545 (1993).
6. J. M. Bishop, M. J. Bushnell, and S. Westland, "Application of neural networks to Computer Recipe Prediction", John Wiley & Sons, New York, NY(1991).
7. V. Venkatasubramanian, R. Vaidyanathan, and Y. Yamamoto, Process Fault Detection and Diagnosis Using Neural Networks-I. Steady-State Processes, *Comp. chem. Eng.*, **14(7)**, 699 (1990).
8. D. H. Brainard and B. Wandell, Analysis of The Retinex Theory of Color Vision, *J. Optical Soc. Amer.*, **3**, 1651 (1986).
9. J. C. Hoskins and D. M. Himmelblau, Artificial Neural Network Models of Knowledge Representation in Chemical Engineering, *Comput. chem. Engng.*, **12**, 881 (1988).
10. W. Y. Huang and R. P. Lippmann, Comparisons between Neural Net and Conventional Classifiers, *Proc. IEEE First Int. Conf. on Neural Networks*, **4**, 485 (1987).
11. S. B. Chen, L. Wu, and Q. L. Wang, Self-Learning Fuzzy Neural Network for Control of Uncertain Systems With Time Delays, *IEEE Trans. S.M.C.*, **27**, 1 (1997).
12. C. W. Anderson, Learning to Control An Inverted Pendulum Using Neural Networks, *IEEE Control Syst. Mag.*, **9**, 31 (1989).
13. D. J. Burr, Experiments on Neural Net Recognition of Spoken and Written Text, *IEEE Trans. Acoust., Speech, Signal Processing*, **36(7)**, 1162 (1988).
14. S. Abdulkadir, Wavelet transform and adaptive neuro-fuzzy inference system for color texture classification, *Expert Systems with Applications*, **34**, 2120 (2008).
15. M. E. Yuksel, A. Basturk, and E. Besdok, Detail-Preserving Restoration of Impulse

- Noise Corrupted Images by a Switching Median Filter Guided by a Simple Neuro-Fuzzy Network, *EURASIP Journal on Applied Signal Processing*, **16**, 2451 (2004).
16. S. G. Kandi and M. A. Tehran, Color recipe prediction by Genetic Algorithm, *Dyes and Pigments*, **74**, 677 (2007).
 17. B. Xu and S. Lin, Automatic color identification in printed fabric images by a fuzzy-neural network, *AATCC Review*, **2(9)**, 42 (2002).
 18. E. Mizutani and K. Nishio, Multi-Illuminant Color Reproduction for Electronic Cameras Via CANFIS Neuro-Fuzzy Modular Network Device Characterization, *IEEE TRANSACTIONS ON NEURAL NETWORKS*, **13(4)**, 1009 (2002).
 19. J. S. Wang and C. S. George Lee, Self-Adaptive Neuro-Fuzzy Inference Systems for Classification Applications, *IEEE TRANSACTIONS ON FUZZY SYSTEMS*, **10(6)**, 790 (2002).
 20. W. Stephen, I. Laura, and M. B. John, Kubelka-Munk or Neural Networks for Computer Colorant Formulation, *9th Congress of the International Color Association, Proceedings of SPIE*, **4421**, 745 (2002).