

원색 재현을 위한 스캐너의 신경회로망 모델링

김흥기, 강병호, 윤창락, 김진서, 한규서, 조맹섭
시스템공학연구소 감성공학연구부
hkimrock@seri.re.kr

Neural Network Modeling for Color Reproduction on Scanner

Hong-Kee Kim, Byung-Ho Kang, Chang-Rak Yoon, Jin-Seo Kim,
Kyu-Seo Han and Maeng-Sub Cho
Human Computer Interface Department
Systems Engineering Research Institute
hkimrock@seri.re.kr

요 약

1. 서 론

본 논문에서는 신경회로망에서 가장 널리 쓰이고 있는 오차 역 전파 알고리즘(Error Back-Propagation)을 사용하여 스캐너를 모델링함으로써 스캐너의 원색 재현을 위한 방법을 제시하였다. 이것은 스캐너의 하드웨어적 특성을 고려, 입력된 영상의 원색과 출력물의 색과 일치시키는 방법이다. 우선, 오차 역 전파 알고리즘에 대하여 학습 규칙을 살펴보고 학습을 위한 데이터를 추출하기 위해 고르게 분포된 색 샘플들을 계측기로 측정하여 칼라 공간에서의 X,Y,Z 값을 얻어낸다. 그 중에서 표본 샘플을 추출한다. 그리고 이를 스캐너로 스캐닝하여 얻은 R,G,B값을 오차 역 전파 알고리즘의 입력값으로, 목표값은 X,Y,Z 값을 사용하여 학습시킨다. 학습하는 동안 샘플 색상의 수와 중간층의 수, 노드의 수를 변화시킴으로써 최적의 결과를 얻도록 실험하였다. 결론에서는 서로간의 결과를 분석한다.

칼라 스캐너, 칼라 프린터, 디지털 카메라 등 서로 다른 칼라 입출력 장비들간의 칼라 불일치 문제는 칼라정보를 이용하는 전자 상거래, 전자 출판, 원격 진료등 여러 응용분야에서 칼라 조절(Color Control) 및 칼라 예측(Color Prediction)등의 기술적 관심을 불러 일으키고 있다[1]. 이와 같은 색의 왜곡현상은 칼라 영상 입출력 장치의 구성 요소들의 비선형적 특성에 기인한다. 예를 들어 칼라 스캐너에서 사용된 CCD소자들의 여러 파장에 대한 감도(sensitivity)의 비선형적 특성이 존재하고 칼라 프린터의 경우 종이, 염료, 기계적 장치들의 특성이 대부분 비선형이기 때문이다. 이러한 칼라 불일치 문제를 해결하는 방법 중에는 칼라 입출력 장비들에 대한 장비 특성화(Devices Characterization) 기법이 있다. 장비 특성화 기법은 칼라 입출력 장비가 가지는 장비 의존적 칼라공간(Device Dependent Color Space)을 장비 독립적인 칼라

공간(Device Independent Color Space)으로 변환시켜 서로 다른 칼라 입출력 장비들간의 칼라 불일치를 해결하고자 하는 방법이다. 여기서는 칼라 이미지 스캐너에 대해 장비 특성화 기법으로 통계학적 접근 보다는 신경회로망의 오차 역 전파 알고리즘을 이용한 접근으로 모델링하여 칼라 불일치를 해결하고 그 성능을 분석하였다.

칼라 이미지 스캐너는 하드웨어 특성에 따라 Red, Green, Blue의 세 가지 색으로 칼라 정보를 표현한다. 본 논문에서는 칼라 이미지 스캐너의 RGB 칼라공간을 장비 독립적 칼라공간인 XYZ 칼라공간으로 변환하는데 신경회로망 기법인 오차 역 전파 알고리즘을 이용하였다. 개발된 칼라 영상 일치 시스템의 성능을 평가하기 위해 균등 칼라공간(Uniform Color Space)인 CIE L*a*b* 칼라공간에서 칼라정보의 일치도를 평가한다.

2. 오차 역 전파 알고리즘

오차 역 전파 알고리즘은 신경회로망에서 가장 널리 사용되고 있으며 학습시간에 대해 효율 좋은 알고리즘으로 알려져 있다. 이 알고리즘은 입력 신호와 교정 신호를 받아서 학습을 하게 되며 학습한 내용은 노드와 노드 사이의 가중치에 저장된다. 하나의 노드에서 출력값은 다음과 같다.

$$O = f(\sum W \cdot O_i), \quad f(x) = 1/(1 + e^{-x}) \quad \dots[\text{식 1}]$$

학습을 하기 위한 에너지 함수는 다음 [식 2]와 같이 출력층에서의 출력값과 목표값과의 차이로서 구한다.

$$E = \frac{1}{2} \sum_j (T_j - O_j)^2 \quad \dots[\text{식 2}]$$

출력층에서 에러는 내부층과 입력층의 노드에 각각 전파되며 이 때 노드는 전파된 에러를 이용하여 노드 사이의 가중치를 [식 3]에 의해서 수정한다.

$$\Delta W = -\eta \cdot \frac{\partial E}{\partial W} \quad \dots[\text{식 3}]$$

[식 3]은 에너지 함수와 노드사이의 가중치에 대한 기울기(Gradient)를 계산하여 강하(descent)시키는 방법이다. 에너지가 작아지도록 가중치의 값을 변화시키는 개념이 점진강하(Gradient descent)이다. 즉 기울기가 음수가 되면 가중치를 증가 시켜 주고, 양수가 되면 가중치를 감소 시킨다. [식 3]을 풀면 출력층과 내부층의 두 가지 경우로 나뉘어 값이 나오게 된다. 이 값에 의해 노드 사이의 가중치의 값을 변동시킨 후 다시 새로운 입력 패턴에 대하여 학습을 하게 된다. 출력층에서는 내부층에서 올라온 값과 목표값을 가지고 [식 2]에 의해 에너지를 계산하게 되며 원하는 에너지 값이 나오도록 이와 같은 작업을 반복 학습한다.

3. 시스템의 구조

칼라 스캐너의 장비 의존적인 칼라공간을 장비 독립적인 칼라공간으로 변환하는 모델을 개발하기 위해서는 임의의 칼라 샘플들에 대하여 칼라 이미지 스캐너에 의해 획득한 칼라정보와 칼라 계측장비에 의해 계측된 칼라 정보가 필요하다.

$$V_{XYZ} = EBP_{model}(V_{RGB}) \quad \dots \quad [\text{식 4}]$$

[식 4]은 오차 역 전파 알고리즘을 적용하여 장비 독립적인 칼라공간으로 변환하는 방법이다. 이를 위해 입력이 되는 샘플 색상의 V_{RGB} 를 결정해야 한다. 여기서는 샘플 색상의 모집단을 1000여개의 칼라 샘플로 하였다. 그리고 계측장비를 사용, 이 칼라 샘플을 측정하여 계측값 X, Y, Z 값을 얻어 냈다. 그러나 XYZ좌표계는 인간의 시각을 가장 잘 표현한 칼라 공간임에도 불구하고 균등 칼라 공간이 아니다. 그래서 모집단에서 대표성을 지닌 표본 색 샘플을 잘 추출하기 위해서 아래의 [식 5]에 의해 균등 칼라 공간인 CIE $L^*a^*b^*$ 으로 전환한다.

$$\begin{aligned} L^* &= 116(Y/Y_0)^{1/3} - 16 \quad \text{for } Y/Y_0 > 0.008856 \\ L^* &= 903(Y/Y_0) \quad \text{for } Y/Y_0 \leq 0.008856 \\ a^* &= 500[(X/X_0)^{1/3} - (Y/Y_0)^{1/3}] \\ b^* &= 200[(Y/Y_0)^{1/3} - (Z/Z_0)^{1/3}] \quad \dots \quad [\text{식 5}] \end{aligned}$$

위 식에서 X_0, Y_0, Z_0 는 계측된 칼라 샘플들중 흰색의 X, Y, Z 값이다. 이렇게 전환된 값은 균등 칼라 공간을 형성한다. 다음은 표본 샘플을 추출해야 한다. 그러기 위해서 L^*, a^*, b^* 축을 각각 원하는 만큼 구간으로 나누고, 이때 생기는 공간의 중앙점에 가장 가까이 위치한 색 샘플을 선택함으로써 색 샘플을 추출한다. 그리고 선택된 색 샘플들을 스캐너로 스캐닝 작업을 하여 각각의 샘플에 대해서 X, Y, Z 값과 R, G, B 값을 동시에 얻는다. 이때 X, Y, Z 값은 실제 색상을 계측장비로 측정된 것이기 때문에 정확한 값이 되어 오차 역전파 알고리즘의 목표값이 되는 것이다. 스캐너로 얻은 R, G, B 값은 [식 4]의 입력값이 되

고 EBP_{model} 의 가중치에 의해 XYZ칼라 공간으로 V_{XYZ} 값이 나오고 이 값과 목표값과의 차이가 원하는 만큼 줄어들 때까지 가중치를 변화시키며 학습을 계속하는 것이다. 성능 측정을 위해서는 모델에 의해 나온 V_{XYZ} 를 [식 5]를 이용하여 CIE $L^*a^*b^*$ 칼라 공간으로 변형한다. 그리고 칼라 샘플들을 계측장비로 측정한 XYZ값을 CIE $L^*a^*b^*$ 로 변형한 값과의 차이로써 성능을 측정한다. [식 6]은 성능 측정을 위한 식이다.


$$\begin{aligned} \Delta E^*_{ab} &= \text{SQRT}((L^*_i - L^*_j)^2 + (a^*_i - a^*_j)^2 + \\ &\quad (b^*_i - b^*_j)^2) \quad \dots \quad [\text{식 6}] \end{aligned}$$

이와 같은 작업을 위해서 오차 역 전파 알고리즘의 구조를 초기에, 노드 3개씩의 입·출력 층을, 노드 10개씩의 중간층 2개를 쌓았다. 입력값은 칼라 샘플들을 스캐너로 스캐닝한 후에 나온 RGB값을 가지고 하였고, 출력으로 나온 값과 칼라 샘플들의 계측기로 측정한 값과의 차이가 원하는 만큼 줄어들었을 때까지 학습을 반복시킨다. 학습 방법은 앞 절의 설명과 같이 점진 강화 기법을 사용하였다.

4. 실험 및 결과


오차 역 전파 알고리즘을 학습하기 전에 학습률(Learning Rate)는 초기값이 0.9로 시작하여 샘플당 100,000번 반복 학습할 때마다 그 값의 1%씩을 감소시키고, 중간 층은 2개로 각각 10개의 노드로 구성하였다. 적절한 샘플의 수를 결정하기 위해 L^*, a^*, b^* 축을 각각 7단계의 구간으로 나누어 표본을 추출하

여 7개의 그룹으로 이루어진 칼라 샘플군을 얻었다. 아래의 [그림 1]은 이 7개 데이터군에 대하여 측정을 한 결과이다.



[그림 1] 샘플수 vs. ΔE^*ab

[그림 1]을 보면 샘플 수가 78개일 때 가장 좋은 결과를 냈다. 다음이 이 데이터를 가지고 학습을 하되 최적의 학습을 위한 신경 회로망의 구조를 찾아 내기 위하여 우선 중간층의 수를 변동시켜 실험하였다. 그 결과인 [그림 2]를 보면 중간층의 개수가 2일 때 가장 에너지가 낮았다.



[그림 2] 중간층 수 vs. ΔE^*ab

그래서 중간층을 2개로 고정하고 다음은 각각의 중간층 노드의 개수를 결정하는 실험으로, 2개의 층에 대한 노드의 수가 다양한 조합이 존재하므로 여기서는 각층이 동일 수의 노드를 갖도록 하여 실험 하였다. 다음의 [표 1]은 그 결과이다.

(중간층1, 중간층2)	ΔE^*ab
(5, 5)	5.921231
(6, 6)	5.164319
(7, 7)	4.689452
(8, 8)	3.838215
(9, 9)	4.103118
(10,10)	3.883183
(11,11)	3.650229
(12,12)	3.979066
(13,13)	3.988388
(14,14)	309.991405

[표 1] 노드 수 변동 실험(샘플 78개)

표처럼 (11,11)일 때 가장 좋은 결과를 얻었으므로 다음은 중간층2의 노드의 수를 11로 고정시키고 중간층1의 노드를 변동시키며 실험하였다

(중간층1, 중간층2)	ΔE^*ab
(2, 11)	28.493167
(3, 11)	6.557182
(4, 11)	4.502714
(5, 11)	4.269569
(6, 11)	3.768913
(7, 11)	3.743253
(8, 11)	3.950316

(9,11)	4.360416
(10,11)	3.868859
(11,11)	3.650229
(12,11)	4.345745
(13,11)	3.921554
(14,11)	4.125726
(15,11)	163.078765

[표 2] 중간층 1의 노드 수 변동 실험

중간층2의 노드를 고정시킨 후 중간층1의 노드의 개수가 11일 때 가장 좋은 결과를 내었다. 그래서 중간층1의 노드를 11로 고정시키고, 중간층2의 노드를 변동시켜 실험하였다.

(중간층1, 중간층2)	ΔE^*_{ab}
(11,3)	5.203277
(11,4)	4.520217
(11,5)	4.733371
(11,6)	4.002870
(11,7)	4.051576
(11,8)	4.258393
(11,9)	4.058340
(11,10)	3.743164
(11,11)	3.650229
(11,12)	3.832801
(11,13)	3.867773
(11,14)	3.552269
(11,15)	163.078774
(11,16)	3.462382
(11,17)	163.078773

[표 3] 중간층 2의 노드 수 변동 실험

위 결과와 같이 중간층2의 노드의 갯수가

16일 때 ΔE^*_{ab} 값이 3.462382인 결과를 얻었다.

5. 결 론

본 논문에서는 신경회로망의 오차 역 전파 알고리즘을 이용하여 칼라 이미지 스캐너의 장비 의존적인 칼라공간을 장비 독립적인 칼라공간으로 변환하는 스캐너 모델링 시스템을 구현하였다. 기존에는 통계학적 방법으로 얻은 매트릭스를 이용하여 RGB값에서 XYZ값으로 변환하였다. 그러나 이 방법은 매트릭스를 얻기 위해 많은 실험과 복잡한 계산이 필요하였다. 본 논문에서는 이 부분을 블랙박스로 놓고서 신경회로망 기법인 오차 역 전파 알고리즘으로 간단히 구현하였다. 이 둘의 성능을 비교해보면 통계적기법으로는 ΔE^*_{ab} 값이 2.741[7]이 나온 반면 본 논문에서는 3.46정도여서 개선의 여지가 남아 있다. 신경회로망은 학습하는 도중 로컬 해(local optima)에 빠지거나 학습 시간이 오래 걸리는 것이 문제점이다. 보다 나은 실험을 위해서는 본 실험도 로컬 해에 빠졌다고 판단될 때 빠져 나오는 방법을 더 연구해야 하며 최적의 학습 데이터를 추출하기 위한 별도의 샘플링 방법도 연구할 계획이다.

참고 문헌

[1] M. S. Cho, Biological Object Representation for Identification, Ph. D. Thesis, Loughborough University of Technology, 1992.

- [2] R. W. G. Hunt, *Measuring Colour*, Second Ed., Ellis Horwood, 1992.
- [3] D. E. Rumelhart, J. L. McClelland and the PDP Research Group, *Parallel Distributed Processing*, MIT Press, 1986.
- [4] S. Tominaga, Color notation conversion by neural Networks, *Color Research and Application*, 18: 253-259, 1993.
- [5] Y. Arai, Y. Nakano, T. Iga, and S. Usui, A Method Of Transformation from CIE $L^*a^*b^*$ to CMY Value by A Three-Layered Neural Network, *IS&T and SID's Color Imaging Conference: Transforms and Transport-ability of Color*, 41-44, 1993.
- [6] G. Marcu, and K. Iwata, RGB-YMCK Color Conversion by Application of the Neural Networks, *IS&T and SID's Color Imaging Conference: Transforms and Transportability of Color*, 27-32, 1993.
- [7] 김진서, 강병호, 윤창락, 조맹섭, 칼라 이미지 스캐너와 칼라 모니터 특성화를 이용한 WYSIWYG 칼라 재생 시스템, *한국 정보처리학회 춘계 학술 대회 4:1*, 1119-1122, 1997.
- [8] S. Tominaga, Color control using neural network and its application, *SPIE Conference on Color Imaging. Vol. 2658*, 253-260, 1996.