

1. はじめに

色を表示する表色系としてすでに多くのシステムが提案され実用化されている。一般に表色系はマンセルやNCSといった心理知覚量で定義される系とCIE表色系で代表される心理物理量で定義される系に分けることができる。後者のグループでは表色系間で3変量の変換公式が存在する。しかし前者の心理知覚量による表色系と後者の表色系間には変換式が存在せず、対応関係を指定する換算テーブルが与えられているだけである(例えば文献1-5参照)。このような表色系間の変換には与えられた換算テーブルを補間することにより座標変換が実施されてきた⁶⁻⁹⁾。

さて大量の色彩情報を処理する場合、表色系の変換に高速性や簡便さが要求される。例えば、カラー画像では各画素ごと変換を行うので処理は膨大である。このため筆者らは以前、マンセル表色系とCIE-XYZ表色系間の表色変換に対して、補間法に代わるニューラルネットワークを用いる変換法を提案した¹⁰⁻¹¹⁾。

ニューラルネットワークは多数の非線形素子(ニューロン)の結合したものからなる。これを用いて2つの色空間の間の変換(写像)を適応学習し、その知識をネットワーク構造の中に保持することができる。ニューラルネットワークによる写像は従来からの補間法と異なり、対応関係を示す換算テーブルを保持する必要がない。ネットワーク構造は非線形素子を並列的で多層に結合された単純なもので、しかもコンパクトなプログラムで写像が可能であることがわかった。

その後、筆者らはニューラルネットワークによる変換方式の実用化に向けて改善を続けてきた。このたび変換処理の効率化及び変換精度において良好な結果が得られたので報告する。

本論文では、マンセル表色系とCIE-L*a*b*表色系間の変換に対して、効率的なニューラルネットワーク法のアルゴリズムを述べる。本手法の特徴は、マンセルとCIE-XYZ表色系間でなく、マンセルとCIE-L*a*b*表色系間の直接的な対応関係をニューラルネットワークで実現することである。つまりC光下でのマンセルHVC値とL*a*b*値を互いに変換させる。三刺激値XYZが必要な場合はL*a*b*より公式を用いて算出する。

一般に変換の精度や能率は色空間の記述の仕方に依存する。マンセル色空間は直交座標系と円筒座標系の2通りの表現が可能で、ここではそれぞれの表現法についてニューラルネットワークを構築する。そして変

換アルゴリズムの性能を実験的に調べる。

以下では、まず§2でニューラルネットワークによる色座標変換の原理を簡潔に述べる。§3では具体的な変換法を展開する。マンセル表色値からL*a*b*表色値への変換、及び逆のL*a*b*表色値からマンセル表色値への変換アルゴリズムを示す。§4は計算機実験である。ネットワークの学習と試験を行い、変換の精度を詳細に調べる。§5では従来法との比較を行う。§6はまとめである。

2. ニューラルネットワークによる色座標変換の原理

ニューラルネットワークは多数の非線形素子の集合体であるが、本研究ではこのようなネットワークを色座標を変換するための非線形変換器とみなしている。この変換器は、対応関係の数学的記述が難しい2つの色空間の間の写像を適応学習することができ、その知識をネットワーク構造にパラメータとして保持する。

本研究で使用するネットワークの構造は、階層型のフィードフォワード型ネットワークである。図1にこのネットワークの概念図を示す。図ではネットワーク構造と色信号の流れを示している。使用するネットワークは入力層、3層の中間層、そして出力層からなる。変換したい一方の表色値を、入力信号として入力層に与える。ただし入力信号の大きさは適当なスケールで正規化しておく。出力層からは他方の表色系での対応する色座標値が出力される。各ユニットは自分自身より下の層からの出力を受け取り、上の層に出力を送り出す。つまり色信号は常に上層方向に伝播される。

各ユニットの演算は次のようである(図2参照)。いま、下層のユニット*i*の出力値を o_i 、ユニット*i*から自身の層のユニット*j*への結合の重み係数を w_{ji} 、そして自身のユニット*j*のバイアス項を b で表す。このときユニット*j*への入力値は下層の出力値の重み付き和

$$\text{net} = \sum_i w_{ji} o_i + b \quad (1)$$

で与えられ、ユニット*j*の非線形出力は

$$o = f(\text{net}) \quad (2)$$

である。ただし関数 f をシグモイド関数とする。

$$f(\text{net}) = 1 / (1 + \exp(-\alpha \text{net})) \quad (3)$$

ユニットの出力値は常に区間[0, 1]の実数値を取り、正定数 α は $\text{net}=0$ における関数 f の傾きを表わす。 α の値は経験的に定めており、本研究では後述のように0.2~0.6の値としている。

ネットワークのサイズは計算機実験に基づいて決定した。図1のように、3つの中間層で各層10個のユニットもつネットワーク構造がマンセルとCIE-XYZ間の変換のみならず、CIE-L*a*b*間の変換でも効率的である。一般に、ユニット数を増大させれば変換精度は向上するものの、学習に要する時間が大幅に増大する。ユニット数を可変にして実験的に調べたところ、ユニット数10の場合が最も効率的であった¹³⁾。

このネットワーク構造では結合の重み係数が260個、バイアス項が33個となり、合計293個の未知パラメータを有する。これらの未知パラメータは表データを用いた適応学習によって決定される。

次に適応学習について簡単にまとめる。重み係数とバイアスを決定するために誤差逆伝播（バックプロパゲーション）法の学習則を用いる。ネットワークの学習データとして、元の表色系の座標値と目標とする表色系の座標値との換算テーブルを用いる。いまこのデータ表において、 p 番目の元表色系の座標値と目標表色系の座標値を、3次元ベクトル i_p 、 t_p と書くことにする。 $i_p = [i_{p1}, i_{p2}, i_{p3}]$ 、 $t_p = [t_{p1}, t_{p2}, t_{p3}]$ 。この i_p がニューラルネットワークへの入力信号で、 t_p が学習のための教師信号となる。またネットワークの出力信号ベクトルを $o_p = [o_{p1}, o_{p2}, o_{p3}]$ と書く。このとき図1のように、目標値 t_p と実際のネットワーク出力値 o_p との誤差 $(t_p - o_p)$ を求める。

学習アルゴリズムは(4)式のようにこれの2乗誤差 E_p を最小にするように重み係数を変化させる。

$$E_p = \frac{1}{2} \sum_{j=1}^3 (t_{pj} - o_{pj})^2 \quad (4)$$

計算は次の手順で行われる。まず、重み係数の初期値を定め、出力を計算する。そしてこの計算された出力値と目標値を用いて、重み係数を次式によって修正する。

$$\Delta_p W_{ij} = \eta (-\partial E_p / \partial W_{ij}) = \eta \delta_{pj} O_{pi} \quad (5)$$

ここで、 η は学習係数で、 δ_{pj} は目標値と実際の出力値の j 番目の誤差項である。この誤差は次の2式によって上層から下層に向かって逐次計算される。

$$\delta_{pj} = 4\alpha (t_{pj} - o_{pj}) O_{pj} (1 - O_{pj}) : \text{出力層に対して} \quad (6)$$

$$\delta_{pj} = 4\alpha O_{pj} (1 - O_{pj}) \sum_k \delta_{pk} W_{kj} : \text{中間層に対して} \quad (7)$$

なおバイアス項 b は(1)式で出力値が常に1となるようなユニットからの結合の重み係数とみなすことができる。

ネットワークの重み係数とバイアスを修正するための反復計算式は次のような形で与えられる。

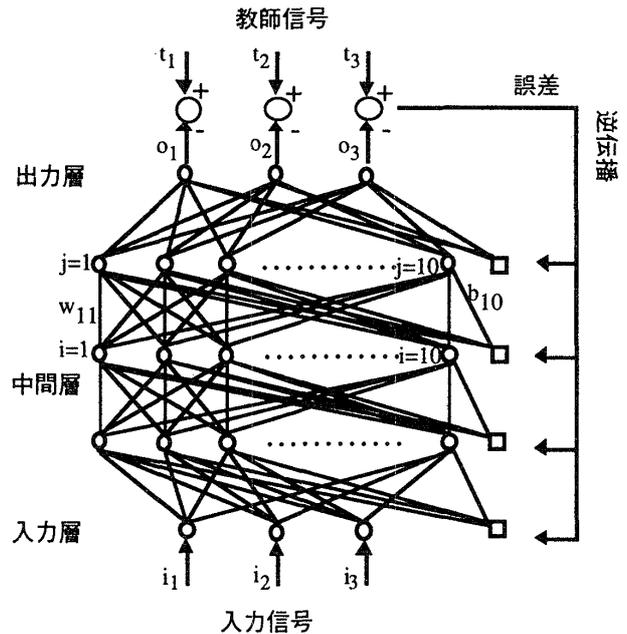


図1 ニューラルネットワークの概念図

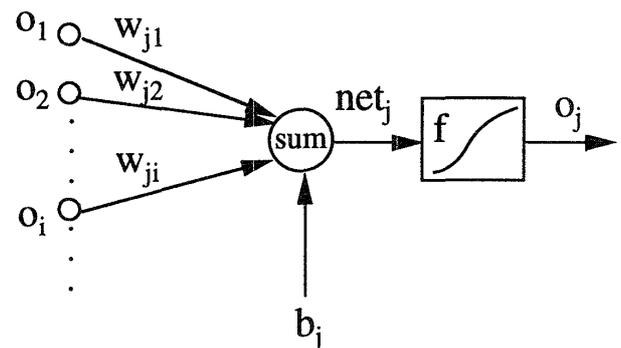


図2 各ユニットにおける処理

$$\Delta W_{ji}(n+1) = \eta \delta_{pj} O_{pi} + \beta \Delta W_{ji}(n) \quad (8)$$

$$\Delta b(n+1) = \eta' \delta_{pj} + \beta' \Delta b(n) \quad (9)$$

(8)–(9)式で右辺の第1項は(5)式に基づくが、第2項は振動を防いで、収束をスムーズにするための慣性項である。 n は反復計算の回数で、 β は慣性定数と呼ばれる係数である。なお実際の計算では $\eta' = \eta$ 、 $\beta' = \beta$ としている。 η と β の定め方は計算機実験に基づいて適切に定めている（文献11参照）。

3. 具体的な変換アルゴリズム

マンセル表色系とCIE表色系の対応関係はNickerson¹⁾やJIS¹²⁾による表データとして与えられている。これらはマンセル表色値に等価なCIEの色度座標値 (Y, x, y) を定めている。筆者らが以前提案した手法¹⁰⁻¹¹⁾は、このような表データを用いてマンセルとCIE-XYZ表色系間の変換をニューラルネットワークで実施した。実際、マンセル色空間を直交

座標系で表した (V, A, B) と三刺激値を変型した $(X^{1/3}, Y^{1/3}, Z^{1/3})$ の3変量間の対応関係を求めるものであった。

一般に色座標変換の精度は対応関係を求める表色系の空間構造に大きく影響される。筆者らは変換法の改善を検討する過程でマンセル表色系とCIE- $L^*a^*b^*$ 表色系の対応に注目した。前者は色相, 明度, 彩度の三属性で定義される知覚的に等歩度な表色系であり, 後者は3量 $L^*a^*b^*$ で定義されるが, 知覚的にほぼ等歩度な表色系である。これら2つの色空間の構造は類似しているので, XYZ表色系よりも $L^*a^*b^*$ 表色系の方が直接的な対応関係を求めやすいはずである。

そこで本研究では, まず表データの (Y, x, y) を公式に従って (L^*, a^*, b^*) に変換し, マンセル表色値に等価な $L^*a^*b^*$ 値を定める換算表を作成した。そしてこの表データを用いてマンセル- $L^*a^*b^*$ 表色系間の直接的な写像を構築した。なお三刺激値が必要な場合は, 得られた $L^*a^*b^*$ 値から, 公式を逆に用いて対応するXYZ値を求める。

以下では, マンセルから $L^*a^*b^*$ 表色系への変換及びその逆方向変換の具体的な手続きを述べる。マンセル色空間については直交座標系と円筒座標系の2通りで記述する。変換に使用するネットワーク本体は共通で, 構造及び学習の仕方は§2で述べたものと基本的に同じである。

3.1. マンセル→CIE- $L^*a^*b^*$ 変換

(A) $(V, A, B) \rightarrow (L^*a^*b^*)$ 変換

まず, マンセル表色系を直交座標系で記述する。本来, マンセル色空間の色座標はマンセル色相 (H), マンセル明度 (V), マンセル彩度 (C) の三属性からなる円筒座標系 (H, V, C) で記述されるが, これを直交座標系 (V, A, B) で記述する。

$$V=V, A=C\cos\left(\frac{2\pi H}{100}\right), B=C\sin\left(\frac{2\pi H}{100}\right) \quad (10)$$

ただし, 色相Hは5Rを0とする実数で, $0 \leq H \leq 100$ の値をとるものとする。 (V, A, B) の値は換算表のデータに上式を適用して決まるが, 3量の取る区間は $[-1, 1]$ に正規化する。すなわち, 全データについてV, A, Bの最小値が-1に最大値が+1になるように設定している。ニューラルネットワークには常にこのような正規化した色座標値を入力する。

ネットワークの出力は (L^*, a^*, b^*) の直交座標系に対応している。ただしこれらの3量は, それぞれ,

区間 $[0, 1]$ に正規化されているので, 適当なスケール変換により実際の (L^*, a^*, b^*) 推定値を得る。

(B) $(H, V, C) \rightarrow (L^*a^*b^*)$ 変換

マンセル表色系を三属性の (H, V, C) 円筒座標系で記述し, 円筒座標系から (L^*, a^*, b^*) 直交座標系への変換を試みた。この方式は(10)式のような三角関数による変換が不要で, 表色系間の非線形写像を三角関数を含めて1つのニューラルネットワークで実現しようとするものである。したがって変換方式として最も単純で能率的な方式といえる。ネットワークの入出力の正規化は (A) と同様である。

3.2. CIE- $L^*a^*b^*$ →マンセル変換

(A) $(L^*a^*b^*) \rightarrow (V, A, B)$ 変換

この変換方式では, (L^*, a^*, b^*) の直交座標値がニューラルネットワークに入力される。ただしこれらの3量は区間 $[-1, 1]$ に正規化している。一方ネットワーク出力として, $[0, 1]$ に正規化した (V, A, B) の直交座標値を得る。これらを元のスケールになおして式(10)の逆変換をすれば, 円筒座標系でのマンセル表色値 (H, V, C) が推定できる。

(B) $(L^*a^*b^*) \rightarrow (H, V, C)$ 変換

この方式では直交座標系 (L^*, a^*, b^*) から円筒座標系 (H, V, C) への直接変換を試みている。この場合円筒座標系への写像となるためニューラルネットワークの評価関数が通常とは違ってことに注意すべきである。筆者らは誤差関数として, ユークリッド距離による色差ではなく, Godloveの色差式を用いた。この色差式では2つの色座標点 (H_1, V_1, C_1) と (H_2, V_2, C_2) 間の色差は次式で定義される¹³⁾。

$$\Delta E_{GM} = \left[2C_1C_2 \left[1 - \cos\left(\frac{2\pi}{100}(H_1 - H_2)\right) \right] + (C_1 - C_2)^2 + 16(V_1 - V_2)^2 \right]^{1/2} \quad (11)$$

ニューラルネットワークの学習アルゴリズムは(4)式のような2乗誤差 E_p を最小にするように決められる。Godlove色差式を適用すれば, 目標値 t_p と出力値 o_p との間の2乗誤差は次のように書き改められる。

$$E_p = \frac{1}{2} (\Delta E_{GM})^2 \\ = \frac{1}{2} \left[2t_{p3}o_{p3} \left\{ 1 - \cos\left(\frac{2\pi}{100}(t_{p1} - o_{p1})\right) \right\} + (t_{p3} - o_{p3})^2 + 16(t_{p1} - o_{p1})^2 \right]$$

$$O_{p3})^2 + 16(t_{p2} - O_{p2})^2 \quad (12)$$

ここで (O_{p1}, O_{p2}, O_{p3}) はネットワークの出力で (H, V, C) の推定値に対応し, (t_{p1}, t_{p2}, t_{p3}) は (H, V, C) の目標値に対応する。(A) の $(L^*a^*b^*) \rightarrow (V, A, B)$ においても, 出力値を円筒座標に直して誤差評価には(12)式を適用すれば, (A) と (B) の両方の精度が比較できる。

さて, 重み係数の修正量は(5)式から算出される。評価関数 E_p の変数が(4)式と異なるので誤差項及び修正量を新たに算出する必要がある。(12)式に対して(5)式の微分計算を行なったところ, 出力層に対する誤差項 δ_{pj} ($j=1, \dots, 3$) は次のように求まった。

$$\begin{aligned} \delta_{p1} &= 2t_{p3}O_{p3} \left(\frac{2\pi}{100} \right) \sin \left\{ \frac{2\pi}{100} (t_{p1} - O_{p1}) \right\} \\ \delta_{p2} &= 32(t_{p2} - O_{p2}) \\ \delta_{p3} &= -2t_{p3} \left[1 - \cos \left\{ \frac{2\pi}{100} (t_{p1} - O_{p1}) \right\} \right] + 2(t_{p3} - O_{p3}) \end{aligned} \quad (13)$$

ここで $(\delta_{p1}, \delta_{p2}, \delta_{p3})$ は (H, V, C) のそれぞれの要素に対応した誤差項である。なお中間層に対する誤差項は(7)式に一致する。以上をまとめれば, まず出力値に対して(13)式, 続いて中間層に対して(7)式を逐次を用いることによって誤差が逆伝播できる。

$(L^*a^*b^*) \rightarrow (H, V, C)$ の方式では, ネットワークの出力に対して三角関数の変換が不要となり, マンセルの三属性をネットワーク出力から簡単に求めようとするものである。

4. 計算機実験と変換精度

4.1. 使用データ

マンセル色の表データとして筆者らは JIS Z 8721 の換算表を使用した¹²⁾。有彩色の数は3176である。色相の40色相, V の $V=1, 2, \dots, 9$, C の $C=1, 2, 3, 4, 6, 8, 10 \dots$ の点で等価な (Y, x, y) が与えられている。無彩色は $V=0 \sim 10$ で 0.01おきに与えられている。

筆者らは有彩色の表から $C=36$ までのデータをすべて取り出し, さらに無彩色の表から全データを取り出した。これらの合計4177色を実験の原データとした。次に原データから学習データを選択した。マンセル空間の構造を能率よく学習させるには, 学習データを空間内で一様に分散させればよい。そこで原データの表から有彩色と無彩色を1つおきに取り出した。学習データの総数は2089色である。各色について $(Y, x,$

$y)$ 値から三刺激値 (X, Y, Z) , さらに (L^*, a^*, b^*) に変換した。ただし $(X_0, Y_0, Z_0) = (98.074, 100.0, 118.32)$ 。

また変換精度を調べるテストデータとして, 学習データを取り除いた原データの中から選択した。彩度は実用的な観点から $C \leq 14$ の色見本に限定した。実際, ほとんどのマンセル色見本はこの範囲にあり, また $C > 14$ になるとカラーモニタでの色再現が困難になることが多い。テストデータの総数は1769色である。

4.2. ネットワーク学習

ネットワーク学習のためにマンセルと $L^*a^*b^*$ の対データをネットワークの入出力に提示する。このデータ提示の仕方はランダムに行なった。ただし前報¹⁰⁻¹¹⁾ のように乱数を用いてランダムにデータを取り出せば, 乱数の統計的性質に依存して均一に提示できないことがある。そこで, ここではデータ番号を1次的配列に並べ, 1次元データの順番をランダムにソートした。すなわちデータの提示する順序がランダムになり, しかも全学習データが一通りもれなく学習に使用される。

ネットワークのパラメータである重み係数とバイアスは(8)–(9)式の形で反復学習される。これの初期値は乱数で決めた。学習の収束判定は全学習データに対する2乗誤差 E_p の和 (システムエラーと呼ぶ) の減少状態に基づいて決めた。収束を迅速に行うために学習係数 η , 慣性係数 β の値は学習が進行するにつれて, 段階的に減少させればよいことがわかっている。学習回数 n が40000回程度でシステムエラーが十分小さくなることがわかった。例えば, 図3に3.1 (b) に対応した $(H, V, C) \rightarrow (L^*, a^*, b^*)$ 変換における学習特性を示す。図ではシステムエラーと反復回数との関係が両対数グラフで示されており, 誤差が単調に減少していることがわかる。実際40000回でおおよそ0.015程度になり, ほぼ収束していることがわかる。また図4に3.2 (a) に対応した $(L^*, a^*, b^*) \rightarrow (V, A, B)$ 変換における学習特性を示す。同様に40000回でシステムエラーが0.02に収束している。すなわち, 全学習データを40000回程度繰り返して学習すれば誤差が十分小さくなることがわかった。

4.3. 変換精度

(A) 評価式

変換精度の評価を行なうために, $L^*a^*b^*$ 表色値に対してはユークリッド色差 ΔE_{ab} を使用し, マンセル

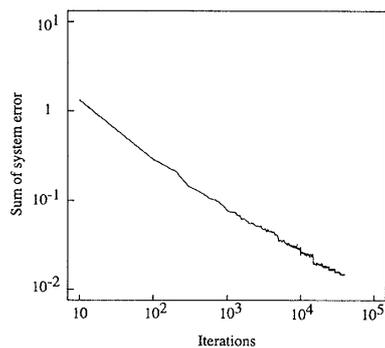


図3 (H,V,C)→(L*,a*,b*)変換の学習特性

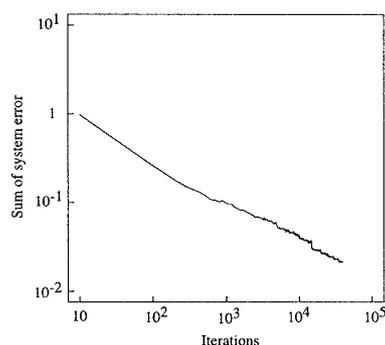


図4 (L*,a*,b*)→(V,A,B)変換の学習特性

表1 マンセル→L*a*b*の変換誤差

変換方式	N	α	β/η	最大 ΔE_{ab}	平均 ΔE_{ab}
(V,A,B)→(L*,a*,b*)	293	0.585	1.0	3.50	0.86
(H,V,C)→(L*,a*,b*)	293	0.399	1.0	3.47	0.71

N: パラメータ数

表2 L*a*b*→マンセルの変換誤差

	N	α	β/η	最大 ΔE_{GM}	平均 ΔE_{GM}
(L*,a*,b*)→(V,A,B)	293	0.465	1.0	0.80	0.18
(L*,a*,b*)→(H,V,C)	293	0.200	0.5	2.45	0.20

N: パラメータ数

表色系に対してはGodlove色差 ΔE_{GM} を用いる。まず、マンセルからL*a*b*表色系への変換の場合、

$$\Delta E_{ab} = \{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2\}^{1/2} \quad (14)$$

で評価する。テストデータのマンセル値をニューラルネットワークに入力し、出力から推定値 (\hat{L}^* , \hat{a}^* , \hat{b}^*) を得る。この推定値と換算表の目標値 (L^* , a^* , b^*) との誤差 $\Delta L^* = L^* - \hat{L}^*$, $\Delta a^* = a^* - \hat{a}^*$, $\Delta b^* = b^* - \hat{b}^*$ を(14)式に代入して色差 ΔE_{ab} を算出する。次に、L*a*b*からマンセル表色系への変換の場合、同様に(14)式を用いる。

(B) 効率的な係数設定

シグモイド関数の傾きや学習係数等を、区間 [0, 1] の中心0.5を基点に等間隔に変えて、学習とテストを繰り返した。マンセルからL*a*b*表色系への順方向及びL*a*b*からマンセル表色系への逆方向のそれぞれについて、§3の(A)と(B)2種類の変換方式を調べた。各方式について最も効率的な実験結果を表1と表2に示す。各表でNは重み係数とバイアスを合わせた未知パラメータの総数を示し、3-10-10-10-3タイプのネットワークにおいてN=293である。次に、 α の欄はシグモイド関数の傾き α の良好な値を示している。また反復学習(8)-(9)式における学習係数 η と慣性係数 β については、これらの係数比が最終的な精度に影響を与えることがわかった。 $\beta/\eta=1.0$ とは両係数を常に同じ値に設定すればよいことを意味している。反復学習では、最初は $\eta=0.1$, $\beta=0.1$ で回数が増大するにつれて段階的に減少させた。

(C) 精度

マンセル→L*a*b*変換の場合：

まず表1からマンセルからL*a*b*表色系の変換は(H, V, C) → (L*, a*, b*) の方式のほうが優れていることがわかる。この精度の差は計算機実験で再現性があり、有意であった。この方式は三角関数の変換をもニューラルネットワークに負担させるため、全体として最も効率的なものである。図5はL*a*b*空間での全テストデータに対する誤差の分布を示している。各線分はマンセル色の推定座標と正しい目標座標を結ぶ色差ベクトルを表している。図5(a)と(b)は色差分布を(a*, b*)と(L*, a*)平面に投影している。色差の分布は均一化していることがわかる。なお、全テストデータで最良の推定値を与えたのは(H, V, C)=(5.0G, 7, 3)に対してで、このとき色差は0.031であり、逆に最も色差が大きいののは(H, V, C)=(5.0GY, 9, 8)で、色差は3.47であった。さらに色差の傾向を理解するために、図6に色差ヒストグラムを示す。横軸は色差を表わし、縦軸はその色差に対するデータ数(頻度)を表す。図からも明らかのように大部分のテストデータに対して色差は $\Delta E_{ab} \leq 1.0$ を満たしている。

L*a*b*→マンセル変換の場合：

表2から(L*, a*, b*) → (V, A, B)の方式が(L*, a*, b*) → (H, V, C)よりも優れてい

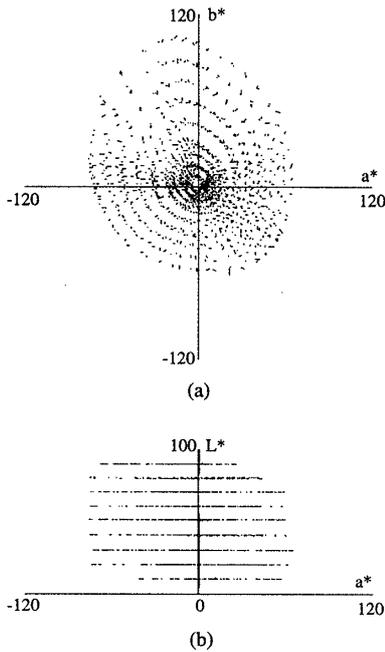


図5 (H,V,C)→(L*,a*,b*)変換における色差分布
(a)(a*,b*)平面への投影,
(b)(L*,a*)平面への投影

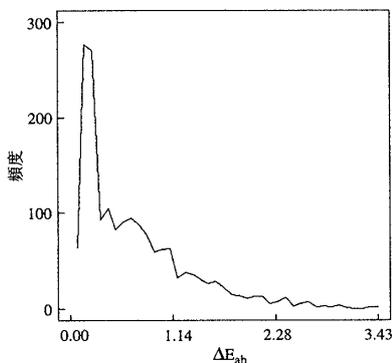


図6 (H,V,C)→(L*,a*,b*)変換における色差ヒストグラム

る。これは平均誤差からみれば、一方の変換と同程度であるが、最大誤差の点で優れているからである。図7はマンセル空間で全テストデータに対する色差分布を描く。図7(a)と(b)は(a*, b*)と(L*, a*)平面への投影である。色差は小さく、分布は均一化している。このとき最小色差は(H, V, C)=(10.0Y, 3, 3)に対して $\Delta E_{GM}=0.0013$ であり、最大色差は(H, V, C)=(5.0P, 2, 14)に対して $\Delta E_{GM}=0.80$ であった。図8は色差ヒストグラムを示す。横軸がGodlove色差である。大部分のテストデータに対して $\Delta E_{GM} \leq 0.25$ を満たしている。

ところで、表2より(L*, a*, b*)→(H, V,

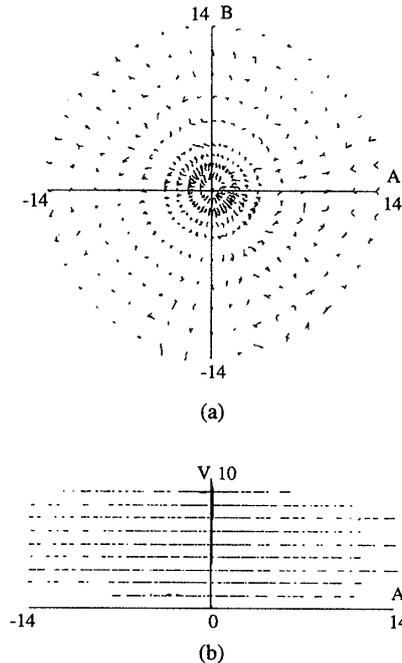


図7 (L*,a*,b*)→(V,A,B)変換における色差分布
(a)(A,B)平面への投影,
(b)(V,A)平面への投影

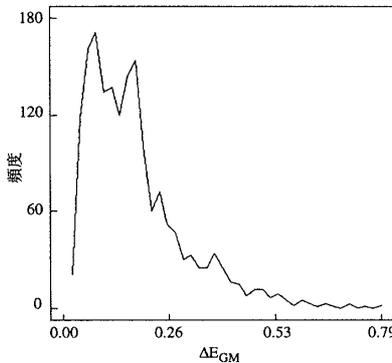


図8 (L*,a*,b*)→(V,A,B)変換における色差ヒストグラム

した。順方向の変換において平均誤差は $\Delta E_{ab}=1.35$ であった。また逆変換において平均色差は $\Delta E_{GM}=0.27$ であった。今回提案したアルゴリズムでは、表1と表2に示されるように $\Delta E_{ab}=0.71$ と $\Delta E_{GM}=0.18$ であるので、大幅に精度が改善したことになる。マンセル表色系とL*a*b*表色系の直接的な対応関係を求めることが精度の向上につながったといえる。

(B) 3次元補間法

3次元補間法のアルゴリズムとして文献14のものを採用した。3次元補間は本来目標点を囲む8つの座標点から目標値を補間するが、実際には輝度・明度の関係は明度関数を用いている。文献14ではVからYへの

C) 変換の最大色差は大変大きい。実際、計算機実験の結果を詳細に調べたところ、一定の色相Hにおいて大きな誤差が残ることがわかった。この原因は明らかでないが、3.2(b)の円筒座標系による最小化アルゴリズムが三角関数を含んでいるため、収束が容易でないと考えている。

5. 比較検討

順方向の変換には(H, V, C)→(L*, a*, b*)の方式が優れ、逆方向変換には(L*, a*, b*)→(V, A, B)の方式が優れていることがわかった。そこで本章では、従来のニューラルネットワーク法および3次元補間法との比較を行なう。

(A) 従来のニューラルネットワーク法

前報¹⁰⁻¹¹⁾ではマンセル表色系とCIE-XYZ表色系間の対応関係をニューラルネットワークで求めた。そこで上述の学習データとテストデータに対して、前報と同様の手順で変換を実施

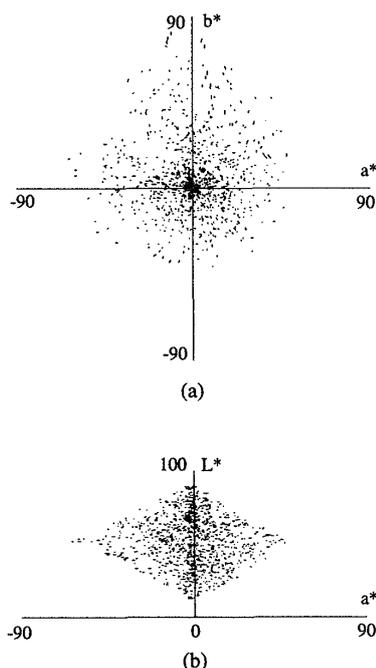


図9 (H,V,C)→(L*,a*,b*)変換における提案法と補間法間の色差分布
(a)(a*,b*)平面への投影,
(b)(L*,a*)平面への投影

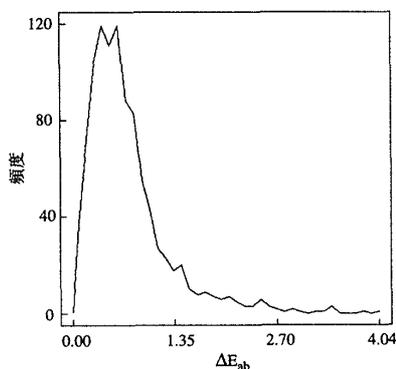


図11 (H,V,C)→(L*,a*,b*)変換における提案法と補間法間の色差ヒストグラム

変換には5次式の明度関数を、YからVへの逆変換にはニュートン法を用いて解を求めている。必要な補間はxy平面上での2次元補間である。

補間アルゴリズムでは、変換すべき入力値が換算表として与えられたデータと一致すれば、補間の必要性がなくなる。そこで我々は補間法と提案法を比較するためにテストデータを新たに1000色作成した。これらは乱数に基づいてランダムに選択した実数データで、換算表のデータと完全に一致する可能性は非常に少ない。作成したテストデータの範囲は、マンセルからL*a*b*表色系への変換の場合は

$$0.0 \leq H < 100.0, 1.0 \leq V \leq 9.0, 0.0 \leq C \leq 12.0 \quad (15)$$

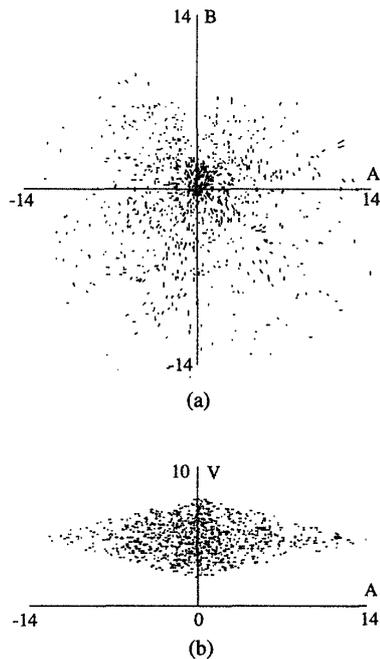


図10 (L*,a*,b*)→(V,A,B)変換における提案法と補間法間の色差分布
(a)(A,B)平面への投影,
(b)(V,A)平面への投影

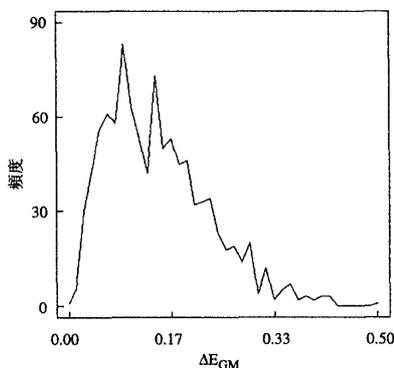


図12 (L*,a*,b*)→(V,A,B)変換における提案法と補間法間の色差ヒストグラム

推定した座標点と補間法で推定した座標点の色差の分布を描いている。順方向変換によるL*a*b*空間での色差分布が図9に示されており、各線分は2つの変換アルゴリズムによる色座標の差異ベクトルを表す。同様に逆方向変換によるマンセル空間での色差分布を図10に示す。さらに図11と図12は、それぞれ、図9と図10の色差分布のヒストグラムを描く。順方向は最大値 $\Delta E_{ab} = 4.11$ 、最小値 $\Delta E_{ab} = 0.02$ で、大部分は1.0以内である。一方逆方向は最大値 $\Delta E_{GM} = 0.51$ 、最小値 $\Delta E_{GM} = 0.00$ で、分布はやや広がっているが、0.25以内が多いといえる。

で、L*a*b*からマンセル表色系への変換の場合は

$$\begin{aligned} 20.0 &\leq L^* < 80.0, \\ -70.0 &\leq a^* \leq 70.0, \\ -70.0 &\leq b^* \leq 70.0 \end{aligned} \quad (16)$$

とした。

まず変換速度をSUN SPARC station 10上で調べた。ニューラルネットワーク法では、順方向に対して表1の(H, V, C) → (L*, a*, b*)方式を、逆方向変換に対しては表2の(L*, a*, b*) → (V, A, B)方式を用いた。補間法ではマンセル値から(Y, x, y)を求め、これよりL*a*b*を計算式で求めた。

全テストデータに対する変換速度は、順方向においてニューラルネットワークでは1.8秒、補間法では2.0秒であった。一方、逆方向において、それぞれ、1.8秒と4.3秒であった。このように順方向ではほぼ同程度の変換時間であったが、逆方向では提案手法が高速であることがわかった。

次に変換結果を比較した。

図9と図10は、提案手法で

6. おわりに

本論文では、ニューラルネットワークを用いて、マンセル表色系とCIE-L*a*b*表色系間の色座標を変換するためのアルゴリズムを述べた。使用したネットワークは多層フィードフォワード型ネットワークで、2つの表色系の対応を例示する表データを学習させた。このとき対応関係の知識はネットワークの重み係数とバイアスといったパラメータに保持される。

筆者らはマンセル表色系からCIE-L*a*b*表色系への順方向変換、及びこれの逆方向変換に対して効率的なニューラルネットワーク変換法を提示した。特にマンセル色空間を直交座標系と円筒座標系の2通りで記述することにより、各方向で2種類のアルゴリズムを開発した。結果として、マンセルからL*a*b*表色系への変換には(H, V, C) → (L*, a*, b*)方式が良く、また逆方向の変換には(L*, a*, b*) → (V, A, B)方式が良いことがわかった。

従来のマンセルとCIE-XYZ表色系間のニューラルネットワーク法と比較したが、提案手法は変換精度を大幅に改善した。これはマンセル表色系とL*a*b*表色系といった知覚的に等歩度な空間同士の対応関係を求めたことが改善につながったと考えられる。また、補間法との速度比較において、特にL*a*b*空間からマンセル空間への変換が高速であることがわかった。

本手法のもう一つの利点はデータ数の減少である。マンセル-CIE対応関係を表す換算表では約3000色のデータが与えられている。対応関係は2つの3次元データの対、すなわち(H, V, C)と(Y, x, y)からなるので、計算機の数値データとして合計 $3000 \times 6 = 18000$ 個の実数データとなる。これらのデータをコンパクトにしたものとして、久下らはC光ならば3000色について色度座標(x, y)だけでよく、合計 $3000 \times 2 = 6000$ 個の実数データですむ手法を提案している¹⁵⁻¹⁶⁾。本論文で提案したニューラルネットワークのアルゴリズムでは、260個の重み係数と33個のバイアスの合計293個の実数データのみが必要である。すなわち多量の実数データが、293個の実数データをいう小さい集合へと、大幅にデータ圧縮できたことになる。

本論文で述べたニューラルネットワークによる変換法の原理は一般性を持つので、NCS表色系等の他の表色系への変換にも適用できるものと考えている。

最後に、補間法のアルゴリズムをご教示いただいた京都工芸繊維大学の佐藤哲也先生に謝意を表します。

文献

- 1) S. M. Newhall, D. Nickerson, and D. B. Judd: Final report of the OSA subcommittee on spacing of the Munsell colors, J. Opt. Soc. Am., 33 (1943) 385-418.
- 2) D. B. Judd and G. Wyszecki: Extension of the Munsell notation system to very dark colors, J. Opt. Soc. Am., 46 (1956) 281-284.
- 3) G. Wyszecki and W. S. Stiles: Color Science, 2nd ed., John Wiley & Sons (1992) 831-861.
- 4) The Swedish Standards Institution: Swedish Standard SS 01 91 00E, Color notation system (1990).
- 5) The Swedish Standards Institution: Swedish Standard SS 01 91 03, CIE tristimulus values and chromaticity coordinates for the colour samples in SS 01 91 02 (1982).
- 6) W. C. Rheinboldt and J. P. Menard: Mechanized conversion of colorimetric data to Munsell notations, J. Opt. Soc. Am., 50 (1960) 802-807.
- 7) 久下靖征: 三次補間によるマンセル表色系からXYZ表色系への座標変換とその逆変換の方法, 日本色彩学会誌, 11 (1987) 121-125.
- 8) N. S. Smith, T. W. A. Whitfield, and T. J. Wiltshire: A colour notation conversion program, Color Research and Application, 15 (1990) 338-343.
- 9) 久下靖征, 他: XYZ表色系からNCS表記への座標変換プログラム, 日本色彩学会誌, 17 (1996) 203-208.
- 10) 富永昌治: ニューラルネットワークを用いたマンセルとCIE表色系間の表色変換, テレビジョン学会誌, 47 (1993) 881-888.
- 11) S. Tominaga: Color notation conversion by Neural Networks, Color Research and Application, 18 (1993) 253-259.
- 12) 日本規格協会編: JISハンドブック 色彩, 日本規格協会 (1990) 129-167.

- 13) 富永昌治：ニューラルネットワークによるマンセル-CIE間の表色変換（第2報），日本色彩学会誌（第25回全国大会特集号），18（1994）28-29。
- 14) 青柳太陽：パーソナルコンピュータによる三刺激値よりマンセル表色系への変換，染色研究，25（1981）125-129。
- 15) 久下靖征，他：XYZ表色系からマンセル表色系への座標変換プログラムの比較評価，日本色彩学会誌，12（1988）107-116。
- 16) 久下靖征：マンセル基準データを効率よく配列に格納する方法，日本色彩学会誌，13（1989）237-239。

（受付日：1997年9月17日）

著者紹介



とみながし ようじ
富永 昌治

昭和22年4月12日生

昭和50年大阪大学大学院基礎工学
研究科物理系博士課程修了，工学
博士

現在，大阪電気通信大学情報工学
部教授

日本色彩学会，電子情報通信学会，情報処理学会，映像メディア学会，IEEE，OSA等の会員



いりたまにただひさ
入谷 忠久

昭和46年9月13日生

平成7年大阪電気通信大学工学部
精密工学科卒業

現在，大阪電気通信大学大学院工
学研究科博士前期課程学生

日本色彩学会，電子情報通信学会

の会員