

# カラー画像の色分類と分割†

富永昌治‡

本論文では、カラー画像を知覚的に一様な色領域の集合に分割するための色分類法を述べている。高分解能のカラー画像平面を、少數の一様な色領域に分割することは、画像分割や画像表現の基礎的問題からの応用問題まで有用である。画像平面上で知覚的に一様な色領域は色空間の中で稠密なクラスタを成す。したがって色分類は知覚的に均等な色空間でクラスタを検出することによって実施することができる。そこでまず計測画像を均等色空間に写像して表色する。色分類の過程として、(1)色データのクラスタを逐次検出する基本分類と、(2)抽出したクラスタの代表色を距離で分類する再分類、の2段階による方法を提案する。基本分類におけるクラスタ検出は反復的な1次元ヒストグラムの分析に基づいている。検出効率を向上させるために、色データ分布の主成分軸上で常にヒストグラムを分析する。クラスタの自動抽出アルゴリズムや、色領域の決定の具体的な手法を示す。次に、再分類の段階では、色差や色相差といった色知覚の距離尺度を使用する。ユークリッド距離によるクラスタリングのアルゴリズムが抽出した色の分類に適用できることを示す。最後に、実測データを用いた実験で提案した色分類法の有用性を確認する。

## 1. はじめに

本論文では、カラー画像を知覚的に一様な色領域の集合に分割するための色分類法を述べている。すなわち、高分解能のカラー画像を受け取って、これを平面的に分割し、各領域が1つの色で記述されるような新しい画像表現を求める。その際、平面的に一様な色領域に分割された出力画像で使用する色数は、もとの画像で使用した色数に比べて当然極めて少ない。このように、カラー画像を、少數の一様な色領域に分割することは、画像分割や画像表現の基礎的問題から応用問題まで有用である<sup>1)~7)</sup>。これまで画像の色を正確に分類しようとする研究は少ない。むしろ画像の領域処理が主目的<sup>2), 3)</sup>、色の分析は厳密とはいえないかった。ここでは色の分析に主眼をおき、カラー画像を配色によって分割しようとしている。

カラー画像の色情報は3次元色空間の中に集約されている(図1参照)。画像平面上で知覚的に一様な色領域は色空間の中でクラスタを成す。例えば、同色の画素の大きな領域が画像に存在すれば、それらは色空間で稠密なクラスタになる。したがって色分類は色空間でクラスタを検出することによって行うことができる。色空間でクラスタが順次抽出できれば、画像平面内で対応する均等な色領域が順次検出できる。図1では色空間に3つのクラスタが存在し、これらは画像平面を背景と3つの部分領域に分割している。長方形と

三角形の領域は同一クラスタで抽出され、同じ色領域と判定される。クラスタの形や配置は使用する色空間によって定まるので、色分類の問題において色空間の選択は重要である。当然、知覚的に均等な色空間を使用すべきである。均等色知覚空間(均等色空間)として、例えば CIE- $L^*a^*b^*$  表色系や CIE- $L^*u^*v^*$  表色系が知られている。

さて均等色空間でのクラスタ検出に基づいた色の分類を基本分類と呼ぶ。クラスタを検出するためには色分布のヒストグラムを分析すればよい。実際1次元ヒストグラムを反復的に使用することにより、クラスタの自動的検出が可能である。この手法は従来の領域分割の手法とも関係している。しかし従来の手法では、検出の性能がクラスタの空間配置に依存し、クラスタを分離検出することが困難な場合があった。本論文では、ヒストグラム分析に、固定した座標系や色特徴を用いずに、均等色空間における色分布の主成分ベクトルの座標系を使用する。常に主成分軸上でヒストグラムを求め、これを厳密に分析する。このような処理によって画像を構成する異なる色の基本集合と対応する色領域が決定できる。

基本色は均等空間でのクラスタの形状から抽出されたもので、色知覚の尺度を基準にしたものではない。色の相互の関係を調べるために色差や色相差といった尺度が有効な場合も多い。そのような場合は色知覚の距離尺度を基準にした分類を、基本分類に追加すればよい。すなわち分類の過程を2段階にして、色クラスタ検出による基本分類と色知覚の尺度による再分類を組み合わせることによって、安定で柔軟な色分類が実現できるものと期待できる。

† Color Classification and Segmentation of Color Images by SHOJI TOMINAGA (Department of Precision Engineering, Faculty of Engineering, Osaka Electro-Communication University).

‡ 大阪電気通信大学工学部精密工学科

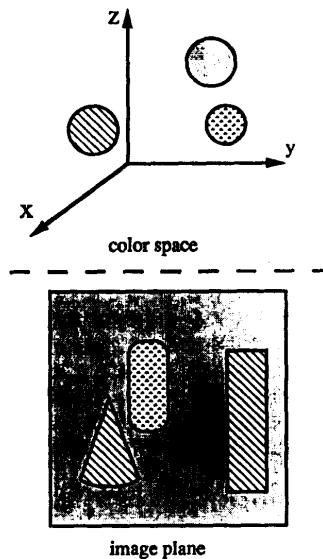


図 1 色クラスタと画像の分割  
Fig. 1 Color clusters and image partition.

以下、第2章で均等色空間について簡単に説明する。第3章で色分類の全過程を概説する。第4章で基本分類の手法と具体的なアルゴリズムを示す。第5章で再分類を述べる。第6章は実験結果で、提案した色分類法の有用性を示す。

## 2. 均等色空間での表色

計測した  $RGB$  の画像を知覚的に均等な色空間へ写像するには、一般に計測データの非線形変換が伴う。本論文では均等色空間として CIE- $L^*a^*b^*$  表色系を使用する。

CIE が提案した  $L^*a^*b^*$  表色系は三刺激値  $X$ ,  $Y$ ,  $Z$  の項で均等色空間を形成する。この空間は3量  $L^*$ ,  $a^*$ ,  $b^*$  の直交座標系で次のように定義される。

$$L^* = 116(Y/Y_0)^{1/3} - 16 \quad (1)$$

$$a^* = 500[(X/X_0)^{1/3} - (Y/Y_0)^{1/3}] \quad (2)$$

$$b^* = 200[(Y/Y_0)^{1/3} - (Z/Z_0)^{1/3}] \quad (3)$$

ただし、 $X_0$ ,  $Y_0$ ,  $Z_0$  は標準白色物体に対する三刺激値である。また上式では極度に暗い物体色は表現できないことになっている。 $L^*$  は明度を表し、また2次元座標  $(a^*, b^*)$  で色相と彩度の色度平面を表す。 $L^*a^*b^*$  空間は色座標の距離空間で、色差はユークリッド距離で表される。さて実際に  $L^*a^*b^*$  座標で色値を得るには、観測した  $RGB$  値を三刺激値に変換する必要がある。この変換はマトリックス演算で行うことができる。まず  $RGB$  の実効反射率  $(\rho_R, \rho_G, \rho_B)$

を計測する。実効反射率は、画像計測装置で観測した  $RGB$  の各値を白色物体に対する観測値によって基準化したものである。このとき色信号を3次元ベクトル

$$\mathbf{s} = [\rho_R, \rho_G, \rho_B]^t \quad (4)$$

で表し、三刺激値を3次元ベクトル

$$\mathbf{p} = [X, Y, Z]^t \quad (5)$$

で表現する。ただしベクトルはすべて縦ベクトルで、その転置を  $t$  で記す。通常  $RGB$  の実効反射率と三刺激値の間に線形な関係を仮定することができるので、変換は  $\mathbf{p} = \mathbf{T}\mathbf{s}$  と書ける。行列  $\mathbf{T}$  は  $3 \times 3$  変換行列で色見本の実測データを用いて定める（詳細は、例ええば文献 8) 参照）。

## 3. 色分類過程の概要

色分類の全過程の概要を図 2 のフローチャートに示す。分類の過程は、色空間でのクラスタの逐次検出に基づく基本分類と、抽出した代表色の再分類の段階に分かれる。

基本分類では、均等色空間におけるクラスタがヒストグラム分析によって逐次検出される。そして画像平面上の対応する一様な色領域を抽出して、それらにラベルを付ける。一度、1つの色クラスタが決定されれ

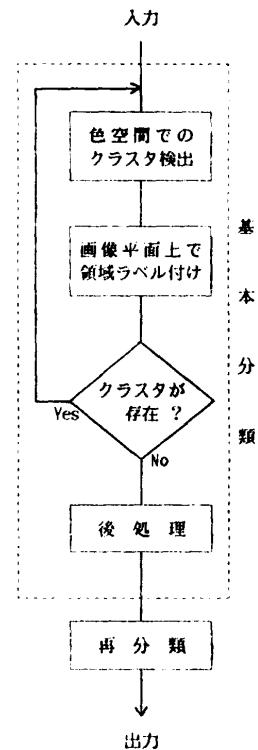


図 2 色分類過程の概要  
Fig. 2 Outline of color classification process.

ば、その色データをもとのデータ集合から取り除き、クラスタ検出を残りのデータに対して繰り返す。この反復過程は色空間にクラスタがなくなった時点で終了する。終了条件として2つの場合が考えられる。1つは、3種類のヒストグラムがすべて单一ピークをもつようになった場合で、色データは1つのクラスタをなすものとして、ラベルを付けて終了する。他方として、もしヒストグラムが明瞭なピークをもたなくなれば、色空間でデータ数が少なくなって分布が疎らになつたと判断できる。そこで、残った画素を雑音みなして終了する。後処理でこれらを、色ラベルをもつ隣接領域に併合する。

基本分類の後処理部では、まず残った画素の処理やスムージング処理を実施する。これらは一種の領域併合の処理である。スムージングは領域サイズが小さくて近隣との色差も小さい領域を併合することによって、全体としてなめらかな画像分割を得る。次に、分類した色ラベルに対して代表色を決定する。このようにして原画像を構成する色の基本集合が求まり、かつ基本色の一様な領域に分割された画像を得る。

基本分類の過程ではヒストグラム分析によってクラスタを検出しておらず、色知覚の距離尺度に基づいていない。一般に色差や色相差などは重要な知覚測度で、再分類では先に抽出した基本色の集合をこれらの尺度で整理する。このためのアルゴリズムとしては、ユーリッド距離に基づく3次元パターンの分類アルゴリズムを応用する。

#### 4. 基本分類

##### 4.1 色クラスタ検出のための座標変換

色クラスタを検出するのに、固定した色特徴の座標系を使用すれば、検出の性能は色空間における色データ分布とクラスタの位置関係に大きく依存する。もし複数のクラスタが球形に近い形で、互いにあまり重なり合っていないならば、固定した座標系でクラスタの抽出が可能である。しかし、図3のような直交座標系で、対角線に平行に複数のクラスタがあれば、それらをx, y, z軸に射影した像はすべてについて重なってしまう。したがって各座標軸上で1次元的なしきい値処理によって区別することは困難である。そこで色分布の主成分座標を使用することにする。このような主成分の利用は画像量子化の問題でも提案されている<sup>9)</sup>。

主成分座標は色データベクトルの共分散行列の固有

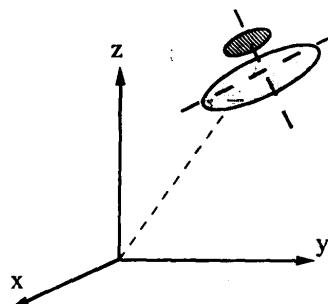


図3 色クラスタと座標系  
Fig. 3 Color clusters and coordinate system.

値と固有ベクトルから求まる。このとき色データの平均ベクトルと固有ベクトルがクラスタの位置と方向を記述することになる。いま3次元縦ベクトル  $\mathbf{m}$  と  $3 \times 3$  行列  $\mathbf{R}$  を、それぞれ  $L^*a^*b^*$  直交座標系 ( $a^*$ ,  $b^*$ ,  $L^*$ ) における色ベクトル  $\mathbf{c}$  の平均値と共分散行列と定義する。

$$\mathbf{m} = E[\mathbf{c}], \quad \mathbf{R} = E[(\mathbf{c} - \mathbf{m})(\mathbf{c} - \mathbf{m})^t]. \quad (6)$$

期待値  $E$  は対象とする画像領域の色データについて計算する。 $\mathbf{R}$  の固有値および対応する固有ベクトルをそれぞれ  $\lambda_1, \lambda_2, \lambda_3 (\lambda_i \geq \lambda_{i+1})$  と  $\mathbf{u}_1, \mathbf{u}_2, \mathbf{u}_3$  と置く。これらの固有ベクトルは与えられたデータ集合の主成分軸の単位ベクトルとなる。したがって、色ベクトル  $\mathbf{c}$  をもとの座標系 ( $a^*, b^*, L^*$ ) から、主成分軸による新しい座標系での色ベクトル  $\mathbf{c}'$  に変換する線形変換を得る。この変換は次式で記述される。

$$\mathbf{c}' = \mathbf{U}'(\mathbf{c} - \mathbf{m}). \quad (7)$$

ただし  $\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \mathbf{u}_3]$ 。ベクトル  $\mathbf{c}'$  の要素として定義される新しい色特徴  $c'_1, c'_2, c'_3$  は平均値0で、分散はそれぞれ  $\lambda_1, \lambda_2, \lambda_3$  をもつ。

これらの色特徴のうちで、第1成分  $c'_1$  は、クラスタを検出するために最も重要な成分といえる。すなはち第1成分は色データの分布の方向を表すので、ほとんどすべての場合第1成分ベクトルのみで複数のクラスタを能率よく分離することができる。しかしまれではあるが、第1成分に直交する成分まで使用しなければならない場合もある。

図4に2つの特別な場合を示す。いずれの場合もクラスタ全体の広がりは第1成分軸にそって最大であるが、この軸だけでは分離できない。また、第1成分軸が  $L^*a^*b^*$  空間の対角線方向にあれば、もとの  $L^*a^*b^*$  軸でも分離できない。変換した座標系の第2成分軸によってクラスタの分離が可能となる。このような理由で、クラスタを抽出するために、第1成分のみなら

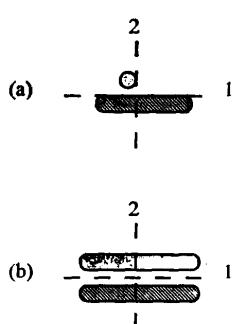


図 4 クラスタと主成分の特別な関係  
Fig. 4 Special cases of relationship between clusters and principal components.

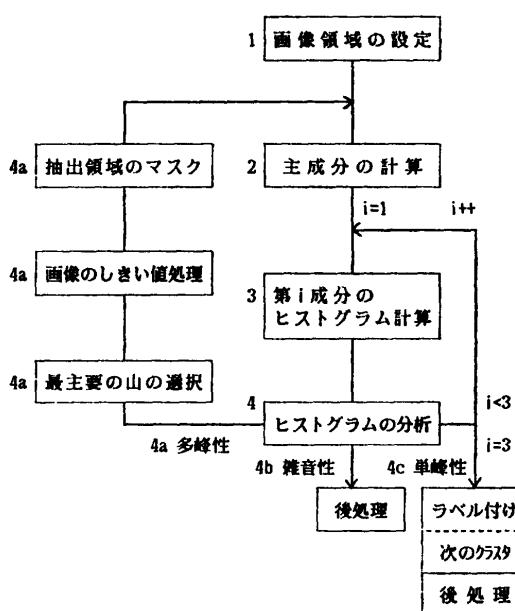


図 5 色クラスタの反復的検出  
Fig. 5 Iterative color cluster detection.

ず、第2と第3成分についても順次ヒストグラム分析することにする。

#### 4.2 色クラスタ検出のアルゴリズム

色クラスタを反復的に自動検出するための過程を図5のフローチャートに示す。各ステップでの手順は以下のとおりである。

(1) まず色ラベルの配列  $img(i, j)$  とマスク配列  $imgm(i, j)$  の内容を初期化する。 $i$  と  $j$  は画像の縦と横の添字である。色ラベル配列はすでに分類した画素に対して、色番号を保持している。新しい色クラスタが抽出されるごとに、色番号を生成し、対応する画素が  $img(i, j)$  上にラベル付けされる。マスク配列は、各画素がクラスタ検出の対象となるデータ集合に属す

るか、あるいはすでに分類済みの画素であるかを決定する。新しいクラスタを検出する際、 $img(i, j)$  上でラベル付けされていない画素を  $imgm(i, j)$  に最初にセットする。

(2) 色空間で色データの主成分を計算する。この計算はマスクされた画像データの領域に対してのみ行う。

(3) 変換式(7)によって色データを主成分軸上に投影し、各色特徴  $c_1', c_2', c_3'$  についてヒストグラムを計算する。

(4) ヒストグラムを分析して大きなピークと谷から主要な山を見出す。まずヒストグラムのランダムな変動を減少させるためにヒストグラムの平滑化を行う。次にいくつかの候補の山を選定し、それぞれについて山の形状を評価する関数を算出する。ヒストグラムの分析法については次節で詳述する。さて、第1成分 ( $i=1$ ) から順にヒストグラム上の山を評価していく。色クラスタの状態を次の3つの場合（多峰性、雑音性、単峰性）のいずれかに分類して処理する。

(4-a) 第1の場合、もしヒストグラムが複数個の山をもつならば、多峰性である。このとき最主要の山を選択する。その山の両サイドの谷の色特徴をしきい値として、画像のしきい値処理を実施する。抽出した部分領域を配列  $imgm(i, j)$  上でマスクする。そしてこれらの領域についてクラスタの検出を続行する。なお、マスクするのは单一の連結領域だけでなく、しきい値処理で抽出したすべての領域が対象となる。

(4-b) 第2の場合、もし第1ヒストグラムが明瞭な山をもたないならば、雑音性とみなす。これはクラスタ検出の反復の終了条件を満たす。なぜならば第1成分が色空間でデータ分布の最大分散の軸と一致しているからである。すなわち、ラベルをもたない残りの画素が少なくなつて色空間でのデータ分布は疎になり、クラスタができるないからである。後処理を実施する。

(4-c) もし第1ヒストグラムがただ1つの山をもつならば、単峰性で、色データは单一のクラスタをなす可能性が高い。しかし第2と第3のヒストグラムも順次解析する。いずれかのヒストグラムが複数個の山をもてば、(a)の多峰性の処理に移る。もし3つのヒストグラムがすべて1つの山しかもたないならば、対象とする色データは1つの色クラスタをなすものとして検出する。抽出した画素を配列  $img(i, j)$  上でラベルづけする。これにより1つの色クラスタの検出が終

了する。もし色ラベルをもたない画素が残されていなければ、後処理を実施する。

以上のアルゴリズムは一見 Ohlander ら<sup>2)</sup>や Ohta<sup>3)</sup>の領域分割アルゴリズムと似て見えるが、2つの点で本質的な違いがある。まず従来の領域分割アルゴリズムでは、(4-a)のようなヒストグラム解析で抽出した画像領域のうちで、1つの連結領域だけをマスクして反復処理を続行していた。一般には、均質な色をもつ物体が、障害物によって分断され、画像上では必ずしも連結していない場合がある。このような場合、従来法では、連結していない領域は異なる色と判断される可能性が大きい。本アルゴリズムは色の分類に主眼を置き、画像上の互いに離れた領域でも、同一の配色があるものとして、抽出したすべての領域を同等に取り扱っている。他の相違点は、固定した色座標系を用いて、分類の効率化を図っていることである。

#### 4.3 ヒストグラムの解析

色クラスタの正確な抽出は、主成分ベクトルに沿って算出したヒストグラム上の山をいかに正確に検出するかに依存する。主要な山を検出するために、山の形状を記述するいくつかのパラメータを定めた。おもなパラメータは①ピークの高さ、②谷の高さ、それらの③色特徴の値（主成分軸上での位置）などである。抽出すべきヒストグラムの山の領域はピークをはさむ両側の谷と谷の区間である。すなわち2つの谷の位置に対応する色特徴の値がいき値となる。山の領域は以下のような直接的な方法で求め、関数にあてはまる方法（例えば、文献 5）、p. 394）は使用しなかった。

##### (1) 山の領域の決定

図6はヒストグラム上の1つの山の例を示している。最も高いピークは  $p_2$  で、これをピークとする山の領域は  $v_1$  から  $v_4$  までわたると考えられる。 $v_1, p_2, v_4$  以外のピークや谷は検出の際、無視され

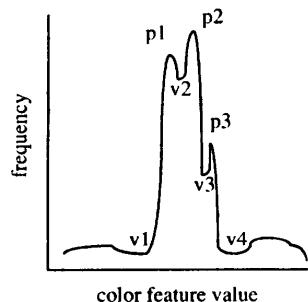


図 6 ヒストグラムの山の形状

Fig. 6 Mountain shape on a histogram.

るべきであるが、一般に局所的な最大値、最小値は正確な山の検出を困難にする。平滑化処理だけでこのような極値を適切に取り除けない。図6で2つの谷  $v_2$  と  $v_3$  は、ピーク  $p_2$  に隣接しているが、明瞭な谷ではない。これらの谷が埋められたら、大きな山の領域  $v_1-p_2-v_4$  が残ることになる。すなわち、谷に注目し、小さな谷だけ取り除けばよい。

そこで小さな谷は2つのタイプに分類できると仮定した。1つは  $p_1-v_2-p_2$  のように、2つの高いピークの間に存在する浅い谷である。他方は  $p_2-v_3-p_3$  のように、1つの高いピークの斜面に存在する小さな谷である。山の小さな凹凸はこれらの組み合わせで表現できるものとし、このような谷を取り除いて比較的大きな山の領域を検出するアルゴリズムを作った。その概要は次のようである。

パラメータ  $v_1, p_1, v_2, p_2, v_3, p_3, v_4$  はピークや谷の高さを表すものとする。さて、もし  $(p_1/v_2) > t$  かつ  $(p_2/v_2) > t$  ならば、 $v_2$  はタイプ1の谷とみなす。 $t$  はいき値のパラメータである。このとき  $p_1$  と  $p_2$  のうちで高い方のピークを残し、他方のピークと谷  $v_2$  を無視する。次に、 $((p_2-v_3)/(p_3-v_3)) > \alpha$  かつ  $((p_3-v_4)/(p_3-v_3)) > \beta$  が成立すれば、 $v_3$  はタイプ2の谷とみなす。このときピーク  $p_2$  と谷  $v_4$  を残し、 $p_3$  と  $v_3$  を無視する。ただしパラメータ  $t, \alpha, \beta$  はおおよそ  $t=1.5, \alpha=10, \beta=10$  に設定した。

##### (2) 山の評価

取り出した山を評価して、小さな山や低い山を捨てて、主要な山のみを選定する。このために使用したパラメータは山のピークの高さ  $p$ 、両側の谷の高さ  $v_1$  と  $v_2$ 、ヒストグラムの平均値  $H_m$ 、山の面積（2つの谷の間のヒストグラム面積） $A_p$  である。山の候補とする条件は、① $(v_1/p) < c_1$  かつ  $(v_2/p) < c_1$ 、② $(p/H_m) > c_2$ 、③ $A_p > c_3$  であり、このうち1つでも満足しなければ、山の候補から除外する。いき値  $c_1 \sim c_3$  は、本論文の実験では  $c_1=0.8, c_2=0.5, c_3=20$  に設定した。

さてヒストグラムにこのような山が1つも存在しない場合、色クラスタは雑音性と判断される。通常、③はこれに対して強力な条件である。次に単峰性の判定には、山の大きさが十分大きいことが必要である。すなわちヒストグラムの全面積（マスクされた全画素数）を  $A_t$  とし、 $(A_p/A_t) > c_4$  の条件を課す。ここで  $c_4=0.97$  のように、 $c_4$  は1に近い値である。もしこ

の条件が満たされなければ、山は1つでも多峰性の処理に移す。最後に、複数個の山があれば、最主要の山を決定するために評価関数を計算する。この評価関数を次のように定義した。

$$f = \frac{A_p}{A_t} \cdot \frac{100}{fwhm}. \quad (8)$$

ここで  $fwhm$  は山の領域の半値幅 (full-width at half-maximum) である。ここでは色特徴の最大値は 100 に基準化した。したがって(8)式右辺で  $(A_p/A_t)$  と  $(100/fwhm)$  はそれぞれ山の面積と山の鋭さを表す相対的な数値を表す。山の形状を評価する関数をこれらの積で定義している。

#### 4.4 後処理

基本分類の後処理部では、(1)色分類されずに残った画素の処理、(2)領域のスムージング、(3)代表色の計算、(4)精度の計算、などを行う。

(1) まず配列  $img(i, j)$  上の各色ラベルについて 8(または 4) 連結性に基づいて領域を決定する。さて、もし色ラベルの付いていない領域が残っていれば、それを隣接したラベル付き領域に強制的に併合する。すなわち、隣接領域との間で平均的な色差を求め、色差が最小となる隣接領域と同じ色ラベルを与えることによって併合する。

(2) 領域のスムージングは色ラベルの付いたすべての分割領域について行う。この処理も一種の領域併合の処理である。もし連結領域の面積(画素数)が一定基準より小さく、かつ隣接領域との色差の最小値が一定基準より小さければ、この領域の色ラベルを最小色差をもつ隣接領域の色ラベルで置き換える。

(3) 各色ラベルの代表色を決定する。このために同じ色ラベルをもつすべての画素について、それらの表色値の平均を求める。いま画像を  $I_1, I_2, \dots, I_K$  の  $K$  種類の色ラベルに分類したと仮定する。またラベル  $I_i (i=1, 2, \dots, K)$  をもつ画素の数を  $n_i$  とする。このときラベル  $I_i$  の代表色  $\mathbf{m}_i$  は次式で与えられる。

$$\mathbf{m}_i = \frac{1}{n_i} \sum_{\mathbf{c} \in I_i} \mathbf{c}. \quad (9)$$

代表色  $\mathbf{m}_i$  は色空間で  $i$  番目のクラスタの重心である。

(4) 分類結果を評価するための目安として、推定精度を表す評価関数を定義する。これまでの処理によって原画像は一様な色領域に分割され、各色領域には代表色が与えられている。したがって、代表色のみを用いて推定した画像と原画像との平均色差を求め

る。評価関数は次式で定義される。

$$J_K = \frac{1}{N} \sum_{i=1}^K \sum_{\mathbf{c} \in I_i} \|\mathbf{c} - \mathbf{m}_i\|. \quad (10)$$

ここで  $N$  は全画素数、記号  $\|\cdot\|$  はベクトルのノルムを表す。関数  $J_K$  は色ラベル数  $K$  とともに変動することに注意すべきで、 $K$  が増大すれば  $J_K$  は減少する傾向にある。

#### 5. 再分類

基本分類では、画像を構成する異なった色の集合を、ヒストグラム分析によるクラスタ検出によって決定した。この分類の特徴は、色空間内のデータ分布の状態を反映して、たとえサイズの異なるクラスタや色の接近したクラスタでも、稠密なクラスタであれば区別して抽出できることである。基本分類では色差や色相差といった知覚の尺度を分類の基準として使用しなかったが、これらは色相互の関係を知るうえで、やはり重要な基準といえる。例えば、色差は色の絶対的な比較に、色相差は陰影を含む画像で物体を識別するのに、それぞれ有用である。

距離に基づく色分類の問題は、数学的には 3 次元ベクトルで記述されたパターンのクラスタリングの問題として扱うことができる(例えは文献 10, 11 参照)。しかし原画像のすべての画素を距離関数でクラスタリングすることは、(1)データが極めて多量であること、および(2)分類結果が距離のいき値に強く依存することから、適用が困難である。ここでは基本分類で抽出した代表色を距離関数で再分類すればよい。クラスタリング・アルゴリズムはすでに多く開発されているが<sup>12)~14)</sup>、クラスタの数をあらかじめ指定したり、制約条件のつけたものが多い。ここでユークリッド距離を使用する単純なものを応用した。基本的な手順は例えは文献 14) (p. 171) で示されている。

いま  $K$  個の代表色の集合  $\{\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_K\}$  を仮定する。色差のいき値を  $T$  とする。まず色空間の中で最初のクラスタ  $A_1$  の中心  $\mathbf{a}_1$  を  $\mathbf{a}_1 = \mathbf{m}_1$  とおく。次に  $\mathbf{m}_2$  について  $\mathbf{m}_2$  から  $\mathbf{a}_1$  への色差を計算し、 $\|\mathbf{a}_1 - \mathbf{m}_2\| > T$  ならば、新たなクラスタ  $A_2$  の中心を  $\mathbf{a}_2 = \mathbf{m}_2$  とおく。さもなくば、 $\mathbf{m}_2$  をクラスタ  $A_1$  に割り当てる。すなわち  $\mathbf{m}_2 \in A_1$  とし、クラスタの中心を  $\mathbf{a}_2 = (\mathbf{m}_1 + \mathbf{m}_2)/2$  で重心に更新する。同様に  $\mathbf{m}_3$  について既存のクラスタ中心との色差を計算する。すべての色差が  $T$  を超えれば、新しいクラスタを生成し、さもなくばその代表色を最も近いクラスタに割り当てる。

る。以下  $m_4, m_5 \dots$  と順次同様な処理を反復する。このアルゴリズムは、初期データに分類結果が依存する可能性があるものの、数少ない代表色の分類には十分利用できる。

また色相差に基づいた分類にも、色差と同じアルゴリズムが適用できる。色相差は本来角度で与えられるが、以下のような変換によってユークリッド距離で近似することができる。いま  $L^*a^*b^*$  色空間で座標系  $(a^*, b^*)$  は色相と彩度の2次元色度平面を表す。例えば、代表色  $m_1$  の色度は  $(a^*, b^*) = (m_{11}, m_{21})$  で表される。このとき色相角は  $\tan^{-1}(m_{21}/m_{11})$ 、また彩度は  $\sqrt{m_{11}^2 + m_{21}^2}$  となる。そこで彩度を 1 に正規化すれば、色度座標が単位円に射影されることになり、色相角が距離として近似できる。この正規化した座標は次の変換式で与えられる。

$$(a', b') = \left( \frac{a^*}{\sqrt{(a^*)^2 + (b^*)^2}}, \frac{b^*}{\sqrt{(a^*)^2 + (b^*)^2}} \right). \quad (11)$$

座標系  $(a', b')$  での 2 点間のユークリッド距離は 2 色の色相差を近似する。

## 6. 実験結果

図 7 は実験に使用したつみ木の写真である。つみ木は厚紙で作ったもので、環境光のほか、屋外用のフラッシュランプで右上方から照明して撮影した。左から黄色の円錐、赤色の円柱、そして青色の四角柱で、照明の仕方で種々の陰影ができる。また背景はエメラルドグリーンである。この画像の特徴は陰影が強いが、ハイライトがほ

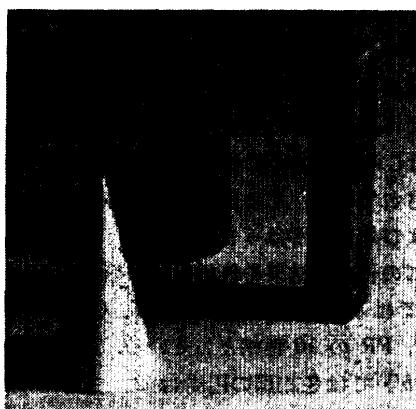


図 7 実験に使用したつみ木の写真  
Fig. 7 Picture of blocks used in an experiment.

表 1 基本色分類の結果  
Table 1 Results of basic color classification.

色番号	色 座 標 ( $a^*$ , $b^*$ , $L^*$ )	マンセル表色値(近似) (色相, 明度, 彩度)				画素数	
1	-10.1	17.5	48.4	1.3GY	4.8	4.0	12142
2	-8.1	20.9	62.9	8.9Y	6.3	4.5	8580
3	-1.6	-7.4	13.7	9.7B	1.4	1.5	1935
4	-4.9	7.0	23.0	2.7GY	2.3	1.7	1923
5	45.0	33.5	41.1	8.2R	4.1	11.2	1780
6	-0.0	15.1	28.9	3.0Y	2.9	3.0	1162
7	2.0	-33.7	46.0	3.9PB	4.6	6.7	1147
8	24.3	17.6	26.6	7.9R	2.7	6.0	976
9	3.4	37.3	42.0	1.6Y	4.2	7.5	946
10	0.5	64.8	81.8	2.9Y	8.2	13.0	593
11	7.2	76.3	75.7	1.5Y	7.6	15.3	574
12	4.9	-25.2	20.6	6.0PB	2.1	5.1	271
13	6.8	60.5	60.6	1.2Y	6.1	12.2	138
14	17.1	34.7	57.1	5.7YR	5.7	7.7	126
15	13.1	32.4	64.8	6.9YR	6.5	7.0	49
16	11.7	28.3	47.9	6.8YR	4.8	6.1	33

表 2 色差  $T=17$  を用いた再分類の結果  
Table 2 Results of reclassification using color difference  $T=17$ .

色番号	色 座 標 ( $a^*$ , $b^*$ , $L^*$ )	マンセル表色値(近似) (色相, 明度, 彩度)				画素数	
1	-9.3	18.9	54.4	0.3GY	5.4	4.2	20722
2	-1.6	-7.4	13.7	9.7B	1.4	1.5	1935
3	-3.0	10.1	25.2	7.7Y	2.5	2.1	3085
4	45.0	33.5	41.1	8.2R	4.1	11.2	1780
5	2.0	-33.7	46.0	3.9PB	4.6	6.7	1147
6	24.3	17.6	26.6	7.9R	2.7	6.0	976
7	3.4	37.0	42.2	1.4Y	4.2	7.4	979
8	3.8	70.4	78.8	2.2Y	7.9	14.1	1167
9	4.9	-25.2	20.6	6.0PB	2.1	5.1	271
10	6.8	60.5	60.6	1.2Y	6.1	12.2	138
11	16.0	34.1	59.2	6.0YR	5.9	7.5	175

表 3 色差による再分類の後、さらに色相差  $T=0.3$  を用いた分類の結果

Table 3 Results of additional classification using hue difference  $T=0.3$  after the reclassification by color difference.

色番号	色 座 標 ( $a^*$ , $b^*$ , $L^*$ )	マンセル表色値(近似) (色相, 明度, 彩度)				画素数	
1	-8.5	17.8	50.6	0.1GY	5.1	3.9	23807
2	0.2	-17.8	25.3	3.1PB	2.5	3.6	3353
3	37.7	27.8	35.9	8.1R	3.6	9.4	2756
4	3.9	55.5	62.0	1.9Y	6.2	11.1	2284
5	16.0	34.1	59.2	6.0YR	5.9	7.5	175

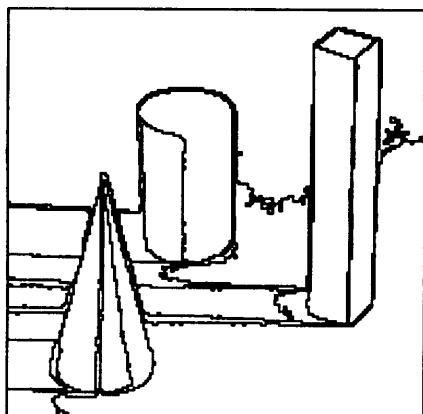


図 8 基本色分類による分割画像  
Fig. 8 Segmented image by basic color classification.

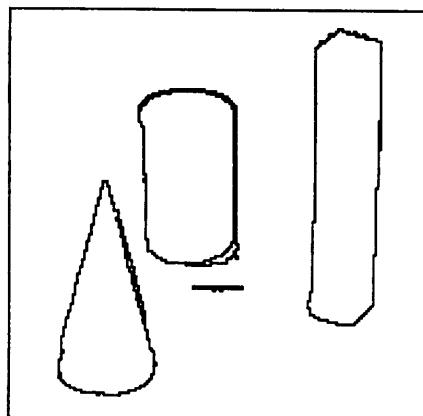


図 10 色相差  $T=0.3$  の追加分類による分割画像  
Fig. 10 Segmented image by additional classification using hue difference  $T=0.3$ .

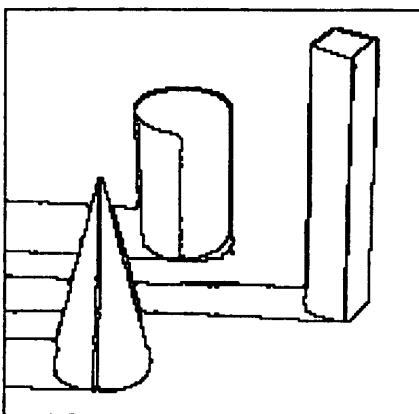


図 9 色差  $T=17$  を用いた再分類による分割画像  
Fig. 9 Segmented image by reclassification using color difference  $T=17$ .

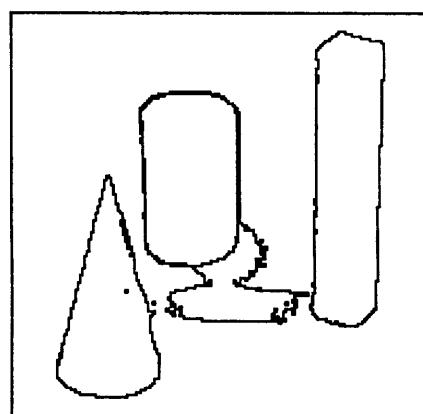


図 11 色相分類による分割画像  
Fig. 11 Segmented image by hue classification.

とんど現れていないことである。

さて写真から  $175 \times 185$  のデジタル画像をドラムスキャナで計測し、CIE- $L^*a^*b^*$  表色系で表色した。画像全体の平均色ベクトル  $\mathbf{m}$  は  $[a^*, b^*, L^*]^t = [-2.6, 17.7, 47.6]^t$  で、第1成分のヒストグラム上に3つの山が観測された。最主要なものは  $f=7.5$  であった。いき値処理とヒストグラム分析を反復し、まず背景色に対応する稠密な色クラスタを抽出した。同様に色クラスタを順次抽出し、16回の繰り返しで基本分類が終了した。表1に基本分類で抽出したクラスタの代表色を示す。各代表色は  $L^*a^*b^*$  座標とともに参考のために近似的なマンセル表色値を算出して3属性でも表示した。評価指標  $J_K$  は  $J_{16}=4.8$  である。図8に一様な色領域に分割した結果を示す。原画像は86の連結領域に分割されている。

次に抽出した代表色を距離に基づいて再分類した。

図8の結果では、一様な背景が2色に分割されていた。この色差は約15であるので、これを融合するために色差  $T=17$  をいき値として再分類した。表2は再分類結果で、色クラスタは11色に再編成された。なお代表色は再編成された各色クラスタの重心で、画像平面上では同じ色番号をもつ画素の平均表色値である。図9はこの再分類による分割画像で、55の連結領域で構成されている。この段階で物体の形状を表す構造線、および影の線がはっきり現れた。

さらにこの再分類結果を色相差で分類した。マンセル表色系では基本色相を R, YR, Y, GY, G, BG, B, PB, P, PR の10色相としている。正規化した座標系  $(a', b')$  では色相環の円周は  $2\pi$  であるから、1つの基本色相は  $2\pi/10$  の距離をしめる。すなわち中心色相から  $\pm\pi/10$  の範囲は同一の基本色相である。そこでこのような基本色相で分類するために色相差

$T=0.3$  をいき値とした。表3はこの結果で、異なる色相をもつ5色にまとめられた。図10は分割画像である。物体の陰影のほとんどすべてが取り除かれ、シルエットが抽出できている。分類された色領域は背景、円錐、円柱、四角柱に対応している。色番号5は物体や影の境界部である。

本手法の有用性を確認するために、同一画像に対して色相のみを用いる処理を実施して結果を比較した。すなわち上の実験の最終結果は色相に基づいて分類された。そこで3次元直交座標系でのヒストグラムではなく、最初から色相環上のヒストグラムのみを用いることによって、分類を簡単化することが考えられる。実際、色相ヒストグラムのみで基本分類した後、 $T=0.3$  による同じ再分類を実施した。この結果を比較のために図11に示す。3つの物体に挟まれた背景の陰の部分は図10のように正しく分類できなかった。一般的に指摘できるように、高彩度の色を色相で分類することは容易であるが、物体の陰のように極低彩度の部分の色味を色相環だけで取り出すことは、かなり不安定な処理といえる。3次元空間でのクラスタ検出は複雑な処理であるが、やはり確実な方法といえる。

## 7. おわりに

本論文では、カラー画像を知覚的に一様な色領域の集合に分割するための色分類法を述べた。このために、計測画像を均等空間で表色し、この空間で色クラスタを順次検出した。色分類の過程は基本分類と再分類からなる。基本分類では1次元ヒストグラムを反復的に使用してクラスタを抽出する。再分類では抽出したクラスタの代表色のみを用いて、距離尺度で分類する。前者の分類結果はおもにクラスタの形状に依存する。そこで逐次検出のアルゴリズムとヒストグラムの山の評価法を示した。これらを用いれば、一般的に色空間で最も稠密なクラスタから、すなわち画像平面上では同色で面積の広い領域から順に抽出される。後者の分類は、代表色のみの分類であるから比較的安定で、処理が高速である。この段階で種々の距離関数を用いて抽出した色と領域の関係を調べることは簡便である。

ここで提案した色分類法のおもな特徴をまとめる。

- (1) 分類過程が2段階で構成されているので、安定で柔軟な分類が可能である。
- (2) 色分類の処理と画像分割の処理が一体となっている。

(3) 均等空間で表色されているので、解析結果は知覚と対応している。

実験では、つみ木の画像に本分類法を適用した。まず強い陰影を含んだカラー画像を構成する基本色を抽出した。また再分類を行うことによって物体の形状がはっきり認識できた。また、色調がより複雑な自然画像にも適用したが、色分類と大まかな領域分割は良好であった。これらより、本手法が一般的なカラー画像の解析に有用であるといえる。

## 参考文献

- 1) Yachida, M. and Tsuji, S.: Application of Color Information to Visual Perception, *Pattern Recogn.*, Vol. 3, pp. 307-323 (1971).
- 2) Ohlander, R., Price, K. and Reddy, D. R.: Picture Segmentation Using a Recursive Region Splitting Method, *Comput. Gr. Image Process.*, Vol. 8, pp. 313-333 (1978).
- 3) Ohta, Y., Kanade, T. and Sakai, T.: Color Information for Region Segmentation, *Comput. Gr. Image Process.*, Vol. 13, pp. 224-241 (1980).
- 4) Nevatia, R.: *Machine Perception*, Prentice-Hall, Englewood Cliffs, NJ (1982).
- 5) Levine, M. D.: *Vision in Man and Machine*, McGraw-Hill, New York (1985).
- 6) Tominaga, S.: A Color Classification Algorithm for Color Images, *Proc. 4th Int. Conf. Pattern Recognition (Lecture Notes in Comp. Sci.)*, Vol. 301, pp. 163-172, Springer-Verlag, New York (1988).
- 7) Klinker, G. J., Shafer, S. A. and Kanade, T.: Image Segmentation and Reflectance Analysis through Color, *SPIE*, Vol. 937, Applications of Artificial Intelligence VI, pp. 229-244 (1988).
- 8) 富永昌治: ドラムスキャナを用いたカラー画像計測のための表色法, 大阪電気通信大学研究論集, Vol. 24, pp. 57-73 (1989).
- 9) 田島謙二, 池田 徹: カラー画像の限定色表示への視覚特性の利用, 情報処理学会グラフィックスと CAD 研究会資料, 38-1 (1989).
- 10) Haralick, R. M. and Kelly, G. L.: Pattern Recognition with Measurement Space and Spatial Clustering for Multiple Image, *Proc. IEEE*, Vol. 57, pp. 654-665 (1969).
- 11) Coleman, G. B. and Andrews, H. C.: Image Segmentation by Clustering, *Proc. IEEE*, Vol. 67, p. 773 (1979).
- 12) Tou, J. T. and Gonzalez, R. C.: *Pattern Recognition Principles*, Addison-Wesley, Reading, MA (1974).
- 13) Duda, R. O. and Hart, P. E.: *Pattern Classi-*

*fication and Scene Analysis*, John Wiley & Sons, New York (1973).

- 14) Pao, Y. H.: *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley, Reading, MA (1989).

(平成2年1月11日受付)  
(平成2年9月11日採録)



富永 昌治 (正会員)

昭和22年生。昭和45年大阪大学

基礎工学部電気工学科卒業。昭和50

年同大学院博士課程修了。工学博

士。電総研大阪支所を経て、昭和51

年大阪電気通信大学講師。昭和61

年教授。昭和62年より1年間スタンフォード大学心理学科客員教授。コンピュータカラービジョン、色彩情報処理、パターン認識、画像・信号処理などの研究に従事。計算視覚や色覚に興味をもつ。電子情報通信学会、計測自動制御学会、テレビジョン学会、日本色彩学会、IEEE、OSA等各会員。