

カラー画像の色彩分類

富永昌治
大阪電気通信大学工学部

あらまし 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。色分類の過程は基本分類と再分類の2段階からなる。色空間としてマンセルやCIE-L*a*b*表色系のような知覚的に均等する色空間を使用する。このために、まず原画像データを色空間に写像する。色分類は均等色空間でのクラスタの正確な検出に基づいている。基本分類では、ヒストグラム解析によってクラスタが反復的に検出される。ヒストグラムは常に主成分に関して計算され、一様な色に対応する画像の空間領域を決定するために分析される。次に、追加処理として、基本分類で抽出した代表色を色の距離に基づいて再分類する。最後に、本方法の性能を実験で検討する。

Color Classification for Color Images

Shoji Tominaga
Faculty of Engineering, Osaka Electro-Communication University
Neyagawa, Osaka 572

Abstract A color classification method is described for partitioning an image into a set of perceptually uniform color regions. The process of color classification consists of two steps of basic classification and reclassification of colors. A perceptually uniform color space such as the Munsell color system or the CIE-L*a*b* color system is used as the color space. First the original image data are mapped into the uniform color space. The color classification is based on exact detection of clusters in the uniform color space. In the basic classification, we apply a histogram analysis method to recursively detect clusters in the space. Histograms are always computed on the principal components, and analyzed to determine the spatial regions corresponding to a uniform color. Next, as the additional process to the basic process, the extracted representative colors are reclassified based on a color distance. The performance of the method is discussed in an experiment.

1. はじめに

本論文では、カラー画像を知覚的に均等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、これを空間的に分割し、各領域が一つの色で記述されるような新しい画像表現を求めると。その際、空間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、もとの画像で使った色数に比べて当然極めて少ない。このように、原画像の空間的領域を、少数の均等な色領域に分類することは、画像分割や画像表現といったカラー画像解析の基本的問題に有用である^{1)~6)}。

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)。画像平面上の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のクラスタ検出の手段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。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。

さて均等色空間での表色値に基づいて画像の空間領域が分類される。本論文では、まず基本的な分類を行うために、色データのクラスタを逐次検出する方式を用いている。すなわち、色のクラスタを一つずつ色空間より抽出する。その際画像平面の一様な色領域が、色の類似性と同一クラスタに帰属することにより決定される。色空間でのクラスタ検出には反復的なヒストグラム解析の手法を採用している。この手法は画像分割のための伝統的なヒストグラム解析法にも関係している^{3)~5)}。これらのアルゴリズムは1次元ヒストグラムを反復的に解析するものであるから、色空間のクラスタの自動検出は比較的容易に思える。しかし、クラスタ検出の性能がクラスタの配置に依存することや、クラスタを分離して検出できない場合の存在が指摘されてきた。

本論文では、固定した座標系によるヒストグ

ラム解析の代わりに、均等色空間で色分布の主成分を使用してクラスタを検出する。色データの3次元分布の主成分軸が反復過程のすべてにおいて求められ、ヒストグラムがこの軸への投影として算出される。第3章で色分類過程の概要を説明し、第4章で基本分類を展開している。この段階ではクラスタの正確な抽出を目的とし、色知覚の距離や色差といった尺度は陽に用いていない。そこで抽出した色の相互関係を調べるために、第5章で、距離尺度に基づいた再分類の手法を示す。第6章は実験結果で、本方法の性能を検討する。




図1 色クラスタと領域分割

2. 均等色空間への写像

一般に知覚的に均等な色空間への写像は観測したRGB値の非線形変換を伴う。本研究では物体色の表色に色相、明度、彩度の3属性が利用できる色空間を採用した。CIE-L*a*b*表色系を使用する場合について、画像データの写像法の要点を以下にまとめる(詳細は文献7)、8)参照)。

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3刺激値である。ここで L^* はマンセル空間の V に対応する明度を表し、また2次元座標 (a^*, b^*) で色相と彩度の色度平面を表す。 $L^*a^*b^*$ 色空間は距離空間で、色差はユークリッド距離で表される。さて現実 $L^*a^*b^*$ 座標で表色値を得るには、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。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⁶⁾。このため写像は $p = Ts$ と書ける。ただし $p = [X, Y, Z]^T$ 、 $s = [\rho_R, \rho_G, \rho_B]^T$ である。3×3変換行列は色見本の実測データを用いて定める。

画素を雑音と見なして終了する。後処理でこれら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。

以上の基本分類の過程ではヒストグラム解析によってクラスタを検出しており色相互の距離尺度は積極的に使用していない。カラー画像解析には色差や色相差などは重要な知覚測度として知られている。例えば色相差は陰影のあるシーンで物体を同定するのに有用と考えられる。そこで先に抽出した基本色の集合を距離尺度で再分類することによって、色の集合を整理することにする。これには簡単なパターン分類のアルゴリズムを使用する。

3. 色分類過程の概要

色分類過程の概要を図2のフローチャートに示す。分類の過程は、一様な色領域を逐次検出する基本分類の段階と抽出した色を再分類する追加段階に分かれる。

基本分類では、均等色空間におけるクラスタを逐次検出する。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。クラスタ検出は、次章で述べるように、色分布の主成分軸上のヒストグラム解析に基づいている。一度、一つの色クラスタが決定されれば、その色データをもとのデータ集合から取り除く。そしてクラスタ検出を残りの画像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。終了条件には2つの場合が考えられる。一つは、3種類のヒストグラムがすべて単一ピークをもつようになった場合で、色データは一つのクラスタに属するものとして、終了する。他の場合として、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ったと判断できる。そこで、対象




図2 色分類過程の概要

4. 基本分類

4.1 色クラスタの座標変換

色クラスタを検出するための伝統的な方法は、 $\{じ, あ, び\}$ や{色相、明度、彩度}といった色特徴のヒストグラム解析に基づいている³⁾⁻⁵⁾。その検出アルゴリズムの性能は色クラスタの配置に大きく依存する。もしクラスタが比較的球形に近い形で、互いにあまり重なり合っていないならば、固定した色座標系でクラスタの抽出を行うことができる。しかし、もし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 軸に射影するとき、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一次元的なしきい値処理によって区別することができない。そこで色分布の主成分座標を使用することを提案する。

主成分座標は色データベクトルの共分散行列の固有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 m と 3×3 行列 R を、それぞれ直交座標系 (x, y, z) における色ベクトル c の平均値と共分散行列と定義する。

$$m = E[c], \quad R = E[(c - m)(c - m)^t] \quad (4)$$

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。 R の固有値及び対応する固有ベクトルを $\lambda_1, \lambda_2, \lambda_3 (\lambda_1 \geq \lambda_2 \geq \lambda_3)$ と u_1, u_2, 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 c を元の座標系 (x, y, z) から、主成分軸による新しい座標系での色ベクトル 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。

$$c' = U^t(c - m) \quad (5)$$

ただし $U = [u_1, u_2, u_3]$ 、ベクトル 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。

4.2 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抽出するための過程を図3のフローチャートに示す。各ステップ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 $imgw(i, j)$ 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。色クラスタが新しく抽出されるごとに、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。マスク行列は、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。クラスタ検出を繰り返す場合は、配列 $img(i, j)$ 上でラベル付けされていない画素を、色分類を継続させるために最初に配列 $imgw(i, j)$ にセットする。

2. 反復クラスタ検出の各段階で、均等色空間内の色分布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(5)によって色データを主成分軸上に投影し、色特徴 c_1', c_2', c_3' の一つ一つについてヒストグラムを計算する。

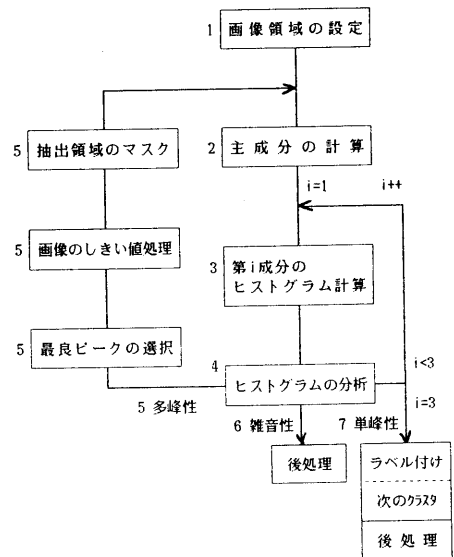


図3 カラークラスタの反復的検出

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少なく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を評価する関数を算出する。この関数は山の形状を数値化したものである。主要な山を決定する評価関数に、については次節で詳述する。さて、第1ヒストグラム($i=1$)から順次、山を評価していく。色分布の形態を次の3つのいずれかに場合に分類して処理する。

5. 第1の場合、もしヒストグラムが多峰性ならば、最主要の山を選択する。色特徴のいき値を、ヒストグラムピークの両サイドの谷の位置から求める。画像のいき値処理を実施し、領域を分割する。抽出した部分領域を配列(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解析を続行する。なお、マスクするのは単一の連結領域だけでなく、いき値処理で抽出したすべての領域が解析の対象となることに注意する。

6. 第2の場合、もし第1ヒストグラムが雑音性で、明瞭な山をもたないならば、色分類過程の終了条件を満たす。すなわち原画像のほとんど全ての画素に色ラベルが与えられて、分類がほぼ完了したとみなせる。このときはラベルをもたない残りの画素が少なくなって色空間での分布は疎になり、クラスタができない。終了手順が実施される。

7. 第3の場合、ヒストグラムが単峰性となる場合である。もし第1ヒストグラムが単峰性ならば、次の第2ヒストグラムを解析する。すべての3つのヒストグラムが単峰性ならば対象とする色データは一つの色クラスタに属するものとして抽出する。抽出した画素を配列(i, j)上でラベルづけする。これにより一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、色分類の終了手順を実施する。

4.3 ヒストグラムの解析

色クラスタの正確な抽出は、色空間で特徴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ピークの高さ、谷の高さ、それらの特徴軸上での位置などである。検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。

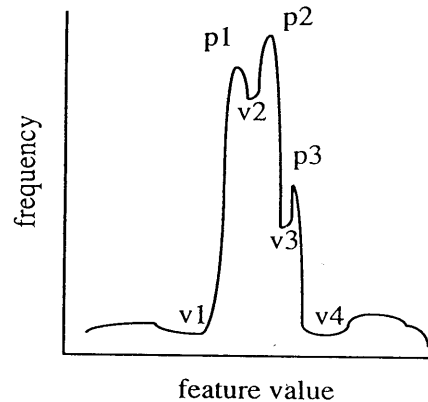


図4 ヒストグラムの山の形状

さて図4はヒストグラム上の一つの山の領域を示している。最も高いピークは $p2$ で、これをピークとする山の領域は $v1$ から $v4$ までわたると考えられる。 $v1$ 、 $p2$ 、 $v4$ 以外のピークや谷は検出の際、無視されるべきであるが、一般に局所的な最大値、最小値は正確な山の検出を複雑にする。このための平滑化は必ずしも適切といえない。図4で2つの谷 $v2$ と $v3$ は、ピーク $p2$ 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 $v1-p2-v4$ が検出できることになる。言い換えれば、区間 $v1-v4$ において谷だけ取り除けばよい。

一般に大きな山に存在する谷は2つのタイプに分類できる。一つは $p1-v2-p2$ のように、2つ高いピークの間が存在する浅い谷である。他方は $p2-v3-p3$ のように、2つの高いピークの斜面に存在する小さな谷である。たいていの大きな山の凹凸はこれらのタイプの組合せで表現できる。そこでこのような谷を取り除くアルゴリズムを作った。

次に検出した山の中から、さらに重要な山の候補を選定し、最後に最主要的の山を決定するために評価関数を計算する。この評価関数は次のように定義される。

$$f = \frac{A_0}{A_t} \cdot \frac{100}{fwhm} \quad (6)$$

ここで A_0 は2つの谷の間のヒストグラム面積、 A_t はヒストグラムの全面積(全画素数)である。また $fwhm$ はピークの半値幅である。ここでは色特徴の最大値は100に基準化した。したがって、評価関数 f は、山の形状を、山の面積(A_0/A_t)と山の鋭さ($100/fwhm$)の組合せで、記述していることになる。

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)領域のスミージング、(3)代表色の計算、(4)精度の計算、などを行う。

(1) まず配列(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。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) 領域のスミージングは色ラベルの付いた全ての分割領域について行う。この処理は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、対象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表色値の平均を求める。

(4) 基本分類の結果を検討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、各領域は代表色を与えられている。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。

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。反面、抽出すべきクラスタの数(色数)をあらかじめ制御したり、色差を考慮することは困難である。基本分類では知覚的な距離尺度を分類の基準として使用しなかったが、均等色空間での距離も有用な基準といえる。

このような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取り扱うことができる。しかし原画像のすべての画素を対象として、距離関数でクラスタリングすることは非常に困難である。そのため本論文では基本分類で抽出した代表色に対して、ユークリッド距離を使用する単純なアルゴリズムを採用した。基本的な手順は例えば文献9)で示されている。いま k 個の代表色の集合 $\{m_1, m_2, \dots, m_k\}$ を仮定しよう。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の中心 α_1 を $\alpha_1 = m_1$ と置く。次に m_2 から α_1 への色差を計算し、これが T を越えるなら、新たなクラスタの中心 α_2 を $\alpha_2 = m_2$ と置く。さもなくば、 m_2 をクラスタ α_1 の領域に割り当てる。同様な仕方で、順次 m_3, m_4, \dots の各代表色をすべてのクラスタ中心との色差を計算して分類する。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。このアルゴリズムはデータ数が多量ならば制約を受けるが、数少ない代表色の分類には簡便である。また同じ手順で色相差に基づいた色分類にも適用できる。

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距離で近似することができる。

$$(x', y') = \left(\frac{x}{\sqrt{x^2 + y^2}}, \frac{y}{\sqrt{x^2 + y^2}} \right) \quad (7)$$

座標系 (x', y') 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。

5. 再分類

6. 実験結果

図5は実験に使用したつみ木の写真である。これらのつみ木は紙で作ったもので、屋光写真用のフラッドランプのもとで撮影した。左から黄色の円錐、赤色の円柱、そして青色の四角柱で、照明の仕方でも種々の陰影ができています。また背景はエメラルドグリーンである。この写真から、175×185のデジタル画像をドラムスキャナで計測し、CIE-L*a*b*表色系に写像した。色クラスタを順次抽出し、16回の繰り返して、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。図6に一樣な色領域に分割された結果を示す。次に抽出された代表色を距離に基づいて再分類した。色差T=17をいき値としてクラスタリング・アルゴリズムを適用した。図7はこの再分類による分割画像で、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。わずかる色に分類された。このときの分割画像を図8に示す。陰影のほとんどすべてが取り除かれ、物体のシルエットだけが検出できている。




図5 実験に使用したつみ木の写真




図6 基本色分類による分割画像




図7 色差 T=17 による再分類結果

表1 基本色分類の結果

| 色番号 | マンセル表色値(近似) (色相、明度、彩度) | 色座標 (L、a、b) | 画素数 |
|-----|---------------------------|--------------------|-------|
| 1 | 1.3GY 4.8 4.0 | 48.38 -10.10 17.54 | 12142 |
| 2 | 8.9Y 6.3 4.5 | 62.92 -8.14 20.86 | 8580 |
| 3 | 9.7B 1.4 1.5 | 13.66 -1.56 -7.37 | 1935 |
| 4 | 2.7GY 2.3 1.7 | 23.01 -4.85 6.99 | 1923 |
| 5 | 8.2R 4.1 11.2 | 41.05 45.03 33.48 | 1780 |
| 6 | 3.0Y 2.9 3.0 | 28.89 -0.03 15.12 | 1162 |
| 7 | 3.9PB 4.6 6.7 | 45.95 1.95 -33.67 | 1147 |
| 8 | 7.9R 2.7 6.0 | 26.60 24.33 17.55 | 976 |
| 9 | 1.6Y 4.2 7.5 | 41.96 3.38 37.34 | 946 |
| 10 | 2.9Y 8.2 13.0 | 81.83 0.45 64.76 | 593 |
| 11 | 1.5Y 7.6 15.3 | 75.66 7.19 76.28 | 574 |
| 12 | 6.0PB 2.1 5.1 | 20.61 4.88 -25.17 | 271 |
| 13 | 1.2Y 6.1 12.2 | 60.59 6.80 60.51 | 138 |
| 14 | 5.7YR 5.7 7.7 | 57.07 17.09 34.71 | 126 |
| 15 | 6.9YR 6.5 7.0 | 64.82 13.07 32.37 | 49 |
| 16 | 6.8YR 4.8 6.1 | 47.86 11.70 28.32 | 33 |




図8 色相差 $T=0.3$ による追加分類結果

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記述した。このためにまず、入力画像を知覚的に均等な色空間に写像した。そしてこの空間で色のクラスタを順次検出した。色分類は基本分類と再分類に分かれていた。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検出する。本論文ではさらに、抽出した代表色を色の距離によって再分類することを提案した。これの動機は、基本分類は色の空間分布のみによって決定されるが、実際の画像解析では色相互の関係や、特定の色特徴による解析も必要とされることがあるためであった。

提案した色分類法が紙でできた物体の抽出・識別に利用できることがわかった。応用として陰影をもつ一般カラー画像に本手法を適用すれば、陰影に影響されない解析が可能である。

提案した色分類法の基本的な特徴を以下にまとめる。

- (1) 色クラスタが常に主成分軸上で解析されている。
- (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) 表色値が知覚的に均等な表色系の値として与えられる。

参考文献

- 1) Nevatia, R.: Machine Perception, Prentice-Hall, Englewood Cliffs, NJ (1982).
- 2) Levine, M.D.: Vision in Man and Machine, McGraw-Hill, New York (1985).
- 3) Ohlander, R., Price, K. and Reddy, D.R.: Picture segmentation using a recursive region splitting method, Computer Graphics and Image Processing, Vol. 8, PP. 313-333 (1978).
- 4) Ohta, Y., Kanade, T. and Sakai, T.: Color information for region segmentation, Computer Graphics and Image Processing, Vol. 13, pp. 224-241 (1980).
- 5) Tominaga, S.: A color classification algorithm for color images, Proc. 4th Int. Conf. Pattern Recognition, J.Kittler(Ed.), Springer-Verlag, New York (1988).
- 6) 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).
- 7) 富永昌治: 測色論に基づいたコンピュータ・カラー・ビジョンのための写像法, 情報処理学会論文誌, Vol. 26, No. 2, pp. 318-328 (1985).
- 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文集, Vol. 24, pp. 57-73 (1989).
- 9) Pao, Y. H.: Adaptive Pattern Recognition and Neural Networks, Addison-Wesley, Reading, MA. (1989).