

ホームページ配色データベースの構築とその分析 Construction and Analysis of the Homepage Color Scheme Database

富田 隆三[†]
Ryuzo Tomita

木本 晴夫[†]
Haruo Kimoto

1. はじめに

ホームページの内容の意味や重要度を推測するいまでの研究は、HTMLの語句や、リンク情報によって行われてきたが、ホームページを記述するHTML言語では文字情報、文書構造のほかに色情報も含めることができる。この背景色や、文字色、カラー画像などによる色情報は、従来の文書内容推定の研究では切り捨てられていた情報であるが、人間に与える印象や、文章の主題との関連性（たとえば、中日ドラゴンズに関するホームページで、赤が代表色となるのは考えにくい[‡]）などを考えると、文書の色情報を内容推定に用いることで、従来のアルゴリズムを改良することができるとおもわれる。

一方、画像のから得られる色彩などの特徴量を用いた画像検索における先行研究としては、栗田ら[1][2]の画像データベース、福田ら[3]の纖維デザイン画像データベース、また久森ら[4]柳生ら[5]などによるデータベースを使用したユーザー支援の提案などさまざまな研究がある。そのほか、木本[6]は感性語によるデータベースの構築と、その評価法について提案し、また井上ら[7]は、画像から得られるデータをクラスター分析によって選別し、交合密度回帰を使用して感性語と画像特徴量との写像を求めるアルゴリズムを提案し、また鈴木ら[8]はニューラルネットワークによって同様の写像を求める試みについて発表している。

本論文では、ホームページの内容推定に色情報を用いる研究に役立てる目的で、Yahoo! Japan[§]から収集した約20万件のURLかホームページ画像を処理し、その代表色（そのホームページのレンダリング済画像において、目立つ色）をデータベースとして構築した。また、得られたデータに予備的な分析を行った。

2. クラスター分析によるレンダリング済画像からの代表色抽出

画像の出現色を単純にヒストグラムにして、それらの類似度を求ることは可能だが、この方法では1)出現色が増加するにつれて、データ量が増える。2)単純なヒストグラムでは、人が画像から受ける印象をうまく反映できない。たとえば白の背景にごく小さい面積で、彩度の高い色がおかれていた場合、人は白の印象よりもむしろ、その色から得られる印象が強くなる。この場合、単純にヒストグラムの極大値を代表色とすることはできない（画素数が少なくて代表色となる可能性はある）。そこで、本研究では画像において目立つ（他の色と距離が遠い）ことを考慮するようなアルゴリズムとして、クラスター分析を採用した。

[†]名古屋市立大学

[‡]プロ野球チーム中日ドラゴンズのチームカラーは青

[§]Yahoo! Japan: <http://www.yahoo.co.jp>

クラスター分析とは、一般的に多次元（多変量）の変数を持つ異質なデータの集合の中から、似ているものを凝集し、グループ（クラスター）分けを行うためのアルゴリズムの総称を指す、分析方法には主に凝集法（ツリークラスタリング）、K-means法などがある。

本研究では、凝集法によるクラスター分析を画像から得られたヒストグラムに対して適応し代表色を抽出している。凝集アルゴリズムとしてウォード法を次のように改良し、同系色に対する反応を上げることができた。

ウォード法による初期距離計算では単純なユークリッド平方距離と等しい。

$$D(x, y) = \sum_{k=1}^T (x_k - y_k)^2 \quad (1)$$

この式を以下のようにすることで個体数（画素数）が多いクラスターについては同系色でも併合しづらいようにすることにした。

$$D(x, y) = \sum_{k=1}^T (x_k - y_k)^2 + r(m_x + m_y)^2 \quad (2)$$

ここで、 $m_i = 255 \times \frac{\text{クラスター } i \text{ に含まれる画素数}}{\text{全画素数}}$ である。また、ヒストグラムの寄与率を r によって変化させることができる。ヒストグラムの大きいクラスター間の初期距離をあらかじめ大きくとることによって、併合プロセスを同系色であっても生き残りやすくするのがこの距離計算法の狙いである。

以上のようにして得られたクラスター分析の結果として、クラスター間の結合距離が得られる。これは、画像における他のクラスターとの最短距離を示すもので、他のクラスターとどの程度離れているかというものを大まかに表すものであるため、これを画像においてどの程度支配的かを示す指標として用いることができる。

3. 代表色データベース

前章において得られたデータを、リレーショナルデータベースに格納し、簡単なインターフェースを構築した図1。現在、RGBの各範囲を指定してホームページを検索することができる。このようなデータベースをもちいて、将来デザイン支援等に応用することも考えられる。

4. データの自己組織化マップによる分析

自己組織化神経回路網モデル(SOM)[9]は、多次元入力を持つ2次元配列のノードで構成され、以下に述べるような自己組織化によって多次元データを2次元空間にその特徴を反映するように非線形的に射影（マッピング）することができる。




図 1: データベース検索フォーム

入力が n 次元のベクトル $x = [\xi_1, \xi_2, \xi_3, \dots, \xi_n]$ であるとき、マップ上の各ノード i はそれぞれ n 次元のベクトル $m_i = [\mu_1, \mu_2, \mu_3, \dots, \mu_n]$ を持つものとする。このベクトルを参照ベクトルと呼ぶ。参照ベクトルの要素 μ_{ij} は、自己組織化の過程において、少しづつ修正されてゆく。 T を総学習回数とすると、 $T = 0$ のとき、参照ベクトルは乱数である。

まず、入力ベクトル x が与えられたとき、その入力をすべての参照ベクトルと比較し、その距離の最も小さいノードを勝者ノード c とする。つまり c は以下のように選ばれる。

$$c = \operatorname{argmin}_i \{ \|x - m_i\| \} \quad (3)$$

次に、自己組織化のため、勝者ノードの近傍ノードの参照ベクトル以下のようにを入力ベクトルに近づけるよう変更する。

$$m_i(t+1) = m_i(t) + h_{ci}(t)[x(t) - m_i(t)] \quad (4)$$

ここで、 t は学習回数で、 $h_{ci}(t)$ はたとえば以下のように定義される近傍関数である

$$h_{ci}(t) = \alpha(t) \cdot \exp\left(-\frac{\|r_c - r_i\|}{2\rho^2(t)}\right) \quad (5)$$

$\|r_c - r_i\|$ は、勝者ノードと近傍ノードとの距離である。したがって、勝者ノードとの距離が大きくなるにしたがって h_{ci} の値は小さくなり、これは影響がちいさくなることを意味する。また、 α, ρ は、 t とともに単調に減少する関数である。

今回、SOM がホームページ配色と内容とを関連づけることができるかを実証するために、Yahoo! Japan の特定のディレクトリ下（プロ野球チームの選手のディレクトリ）のホームページ 128 のホームページを対象にして SOM による分類を行った。

マップの広さは 12×12 とし、学習回数は 10000 として、ブートストラップにより学習データを再利用している。結果としてえられたノード（例として、青色が優勢な配色）が勝者ノードとなる分類されるホームページと対応するチームは表 1 のように得られた。

結果、ほとんどのチームカラーに青色が使用されているチームを対応づけることができた。大規模に応用する

表 1: 青色が優勢なノードに分類されるチーム

チーム名	チームカラー	ホームページ数
ドラゴンズ	青	2
ヤクルト	青（水色、濃紺）	3
ベイスターズ	青	3
オリックス	青	3
バッファローズ	黒、赤、濃紺	2
ダイエー	黒	2

ためにはまだ分析と改善が必要であるが、アルゴリズムとして SOM は有望であると考えられる。

5.まとめ

20万件の URL からホームページ画像を収集し、それらの画像からウォード法を一部改良したアルゴリズムによって代表色を抽出し、ホームページの配色データベースを構築した。また、それらの配色と内容との関連を調べるアルゴリズムとして SOM を採用し、予備的な実験をおこない、有望であるとの結果を得ることができた。

参考文献

- [1] 栗田多喜夫, 加藤俊一, 福田郁美, 板倉あゆみ: 印象語による絵画データベースの検索, 情報処理学会論文誌, Vol. 33, No. 11, pp. 1373–1383, 1992
- [2] 加藤俊一, 栗田多喜夫: 画像の内容検索 – 電子美術館への応用, 情報処理学会論文誌, Vol. 33, No. 5, pp. 466–477, 1992
- [3] 福田学, 柴田義孝: デザイン画の形状パターンを捉えた感性検索法, 情報処理学会マルチメディア通信と分散処理ワークショップ, pp. 267–274, 1996
- [4] 久森芳彦, 八木康史, 谷内田正彦: 配色調和理論に基づくカラーコーディネイト支援システム, 情処研報, pp. 189–190, 1994
- [5] 柳生智彦, 久森芳彦, 八木康司, 谷内田正彦: 配色支援システムにおける好みの獲得と迷いの解消, 電子情報通信学会論文誌 (A), Vol. J79-A, No. 2, pp. 25–32, 1996. 2
- [6] 木本晴夫: 感性語による画像検索とその精度評価, 情報処理学会論文誌, Vol. 40, No. 3, pp. 886–898, 1999
- [7] 井上光平, 浦浜喜一: 交合密度回帰に基づく感性検索, 電子情報通信学会論文誌 (D-II), Vol. J83-D-II, No. 4, pp. 1192–1194, 2000. 4
- [8] 鈴木健嗣, 橋本周司: ニューラルネットワークを用いた感性情報の数量化, 電子情報通信学会論文誌 (D-II), Vol. J82-D-II, No. 4, pp. 677–684, 1999. 4
- [9] T. Kohonen: *Self-organizing Maps*, Springer, 1997