

複雑さを考慮した絵画自動分類器

Classifying Paintings Utilizing Complexity of Segments

正井宏武^{*1}
Hirotake Masai

櫻井彰人^{*1}
Akito Sakurai

^{*1} 慶應義塾大学大学院理工学研究科
Graduate school of science and engineering, Keio University

It has become popular to search the Internet or local databases for images. Meta information is commonly used in such image searches. It is, though, difficult and costly to annotate images with meta information that may describe their contents, which is also true in searching for paintings. As an important step for the content-based painting searching, we propose a method to classify paintings based on features expressing complexity of segments in them. We evaluated the method on scanned images of some popular paintings.

1. はじめに

近年、ハードディスクの大容量化に伴い、データベース上に莫大な量の画像データが蓄積される様になった。データベースから必要な画像を手に入れる為の検索手法はメタデータ検索と内容検索に大別できる[吉川 2001]。

メタデータ検索とは画像データの内容を注釈したメタデータをもとにした検索である。内容検索とは画像からある特徴を抽出し、抽出した特徴を用いて検索を行う技術である。

メタデータは多くの場合、手動での注釈付けが必要であり、データ量が膨大になる程、注釈付けの手間が膨大なものになる。またメタデータは対象データのある観点から表現したものに過ぎないので、客観性に欠け、メタデータのみでの検索には限界がある。そのため内容検索が必要となる。

この傾向は絵画画像に関しても例外ではなく、内容による絵画画像検索技術やその前段階として絵画画像の自動分類の技術に関する研究が多くなされている[Gunsel et al. 2005] [Jiang et al. 2005] [Lienhart et al. 2002]。

本研究では絵画の自動分類を行うにあたって、人が絵画を見る時に視線が注目する領域が存在することに着目した。人が絵画を見る時の眼球運動の性質は以下の2つがある[ソルソ 1997]。

- ・情報に富んだ領域が注意を集める事。
- ・注意は絵の中心に偏る事。

以上の性質を踏まえ、本研究では、情報に富んだ領域として複雑に描かれている領域の抽出を行い、その領域ごとに特徴を抽出し、それを用いて絵画の自動分類を行う手法を提案する。

2. 領域抽出

2.1 領域抽出について

本研究では特徴抽出の前処理として、画家が複雑に描いた領域を抽出する。まず、Edge Detection and Image Segmentation system (EDISON system)[Christoudias et al. 2002]を用いて全画像を小領域と極小領域に分割した後、小領域ごとに描かれ方の複雑さを表す小領域複雑度を算出した。小領域複雑度を特徴としたスペクトラルクラスタリング[Luxburg 2007] [新納 2007]を行い、小領域を二つの大領域に統合することで、画像全体を複雑

に描かれている領域と複雑に描かれていない領域の二つに分割を行った。

2.2 小領域・極小領域の抽出

本手法の第一段階として、小領域と極小領域を抽出する。小領域・極小領域は全画面をそれぞれ30個程度・150個程度に分割したものである。これらの抽出には Christoudias らが提案した EDISON system [Christoudias et al. 2002]にある Mean Shift Based Image Segmenter を用いる。Mean Shift Based Image Segmenter による領域分割は大きく二つの段階で構成されている。第一段階では色特徴である $L*u*v^*$ 、位置特徴である x, y の合計5属性を特徴として Mean-Shift 法を行う。第二段階では、第一段階で分割された領域のうち、近接している領域同士で $L*u*v^*$ のユークリッド距離が閾値以下の場合に領域統合を行う。

以上の様に、EDISON system を用いて全画面を小領域と極小領域に分割する。

2.3 複雑度の算出

領域 i の複雑に描かれた度合いを表す指標として、複雑度を(1)式で定義する。

$$\rho(i) = \frac{n_i}{r_i} \quad (1)$$

但し、 n_i は領域 i 内の極小領域の数であり、 r_i は領域 i の面積である。すなわち、複雑度とは着目領域内に存在する極小領域数の密度である。

小領域複雑度は(2)式で定義する。

$$\rho_s(i) = \frac{(n_s)_i}{(r_s)_i} \quad (2)$$

但し $(n_s)_i, (r_s)_i$ はそれぞれ小領域 i 内の極小領域数と面積である。

2.4 大領域抽出

小領域をノードとするグラフにスペクトラルクラスタリングを行い、2つの大領域に統合する。エッジは全ノード間に存在し、重み w_{ij} を(3)式で与えた。

$$w_{ij} = \frac{1}{1 - \exp\{|\rho_s(i) - \rho_s(j)| - \overline{dif\rho_s}\}} \quad (3)$$

但し、 $\overline{dif\rho_s}$ は各小領域複雑度の差 $|\rho_s(i) - \rho_s(j)|$ の全小領域における平均である。

上記 w_{ij} を用いて、スペクトラルクラスタリングを行う事で、同程度の複雑度を持つ部分が一つの領域として抽出される。

2.5 複雑度順位

画像全体を同程度の複雑さを持つ2つの大領域に分割したのち、どちらの大領域が複雑に描かれているかを表すために複雑度に従って複雑度順位をつける。

まず、小領域と同様に大領域に関して大領域複雑度を(4)式で与えた。

$$\rho_L(i) = \frac{(n_L)_i}{(r_L)_i} \quad (4)$$

但し $(n_L)_i$, $(r_L)_i$ はそれぞれ大領域 i 内の極小領域数と面積である。次に、大領域複雑度の高い順に複雑度順位をつける。本研究では複雑に描かれた領域と描かれなかった領域の2領域とするので、前者を1位とし、後者を2位とする。

3. 分類

3.1 特徴ベクトル

特徴量として大領域ごとに以下の5属性を二つの領域ごとに取り、合計10属性を特徴量とする。

(1) 図形的特徴

座標分散: 大領域内のピクセルの xy 座標の分散。大領域の広がりを示す

(2) 色彩特徴

色相、彩度、明度、輝度

3.2 分類

分類を行う際には、複雑度順位が同じ領域同士を比べる。分類器としてサポートベクターマシン(SMO)を用いた。

4. 実験

4.1 実験データ

5人の画家が描いた合計97枚のデータセットを二つ用意した。画像データは[大岡 1986]の画像をスキャナーで取り込み全てビットマップデータとし、大きさを360×460(ピクセル)程度に揃えた。データセットの詳細を以下に示す。

・データセット A

Cezanne(16枚), Renoir(20枚), Gogh(22枚), Dali(17枚), Chagall(22枚) 計97枚

・データセット B

Chirico(19枚), Matisse(20枚), Monet(20枚), Gauguin(20枚), Munch(18枚) 計97枚

4.2 実験方法

本研究を評価する、比較対象として Günsel らが提案している輝度ヒストグラムに着目した6個の特徴量による分類手法を用いる。6個の特徴量は以下の通りである[Günsel et al. 2005]。

$$\mu_1 = \frac{\text{number}(\text{dark_pixel})}{\text{number}(\text{all_pixel})} \quad (5)$$

但し、 dark_pixel とは輝度が 64 以下のピクセルである。

$$\mu_2 = \text{Normalize} \left(\sum_{i=1}^r \sum_{j=1}^c \sqrt{(f_{ij})_x^2 + (f_{ij})_y^2} \right) \quad (6)$$

r, c は画像の縦横の長さ(ピクセル)であり $(f_{ij})_x, (f_{ij})_y$ は水平、垂直方向の輝度の勾配である。正規化は面積で割る事で行った。

$$\mu_3 = \text{number}(H(i) > \text{thr}) \quad (7)$$

但し $H(i)$ は輝度値 i での輝度ヒストグラムの値であり、 μ_3 は輝度ヒストグラムのピークの個数を表す。

$$\mu_4 = \arg \max_i H(i) \quad (8)$$

$$\mu_5 = \sum_{i=1}^9 (\text{mean}_i - \text{mean}) \quad (9)$$

全画面を 3×3 の 9 個のブロックに分割する。 mean_i はブロック i 内の輝度平均であり、 mean は全画面の輝度平均である。

$$\mu_6 = \frac{1}{rc} \sum_{i=1}^r \sum_{j=1}^c \left(f_{ij} - \frac{\text{mean}}{\sigma} \right)^3 \quad (10)$$

但し、 f_{ij} は点 (i, j) の輝度値を表す。

$$\sigma = \frac{1}{rc-1} \sqrt{\sum_{i=1}^r \sum_{j=1}^c (f_{ij} - \text{mean})^2} \quad (11)$$

データセット A,B について以下の実験を行った。

(1) 実験1

複雑に描かれている領域の抽出を行わず、Günsel らの6個の特徴量により分類を行う。

(2) 実験2


複雑に描かれている領域を抽出し、Günsel らの特徴量から μ_5 を除いた5個の特徴量を用いて分類を行う。

(3) 実験3


本研究の提案手法により、分類を行う。

4.3 実験結果

領域抽出の一例を図1, 2に示す。黒で示された領域が複雑に描かれたと認識された領域である。



元画像 小領域 大領域
図1 領域抽出結果



元画像 小領域 大領域
図2 領域分割結果

Weka の SMO を用い、10-fold cross-validation test の分類精度(%)を実験結果として表1に示す。

表1 分類精度(%)

	データセット A	データセット B
実験1	29.9	41.2
実験2	42.3	43.3
実験3	56.7	53.6

各実験間で 10-fold cross-validation の結果に対し、対応のある t 検定を行った結果を表2、表3に示す。また、t 検定には Excel を用いた。

表2 データセット A の t 検定

	t 値	p 値	結果
実験1, 実験2	8.55	7.78E-14	1%有意で差有り
実験1, 実験3	15.15	7.86E-28	1%有意で差有り
実験2, 実験3	5.61	8.89E-08	1%有意で差有り

表3 データセット B の t 検定

	t 値	p 値	結果
実験1, 実験2	1.22	0.111758	有意差無し
実験1, 実験3	6.56	1.22E-09	1%有意で差有り
実験2, 実験3	5.013	1.18E-06	1%有意で差有り

5. 考察

5.1 領域抽出結果について

全画像について、複雑な領域が抽出されている事を確認した。例えば、図1では花が、図2では背景が複雑に描かれている領域として抽出されている。

注視する領域の特徴の一つとして中心に偏る事をあげたが、この特徴を用いて実験を行った結果、精度は低くデータセット間で安定しなかった。なお、その実験は以下に行った。

全画面の 10%の面積を持ち、画像の中心を中心とする円を中心円と定義する。複雑に描かれた領域も考慮し、全画面を以下の4つに分割した。

- 複雑に描かれた領域に属し、中心円内に存在する領域
- 複雑に描かれた領域に属し、中心円外に存在する領域
- 複雑に描かれた領域に属さず、中心円内に存在する領域
- 複雑に描かれた領域に属さず、中心円外に存在する領域

以上の4領域からそれぞれ特徴量を抽出し分類を行った。

5.2 分類結果について

実験1の結果から、比較対象の手法ではデータセットによって正答率に大きな差が出ている事が分かる。領域抽出を行った実験2、3はどちらもデータセット間で正答率の差が小さく、提案手法は安定した結果が出せていると言える。

実験1と2で抽出した特徴量は、提案手法では使用する事が出来ない μ_5 の特徴量を除いては同じ特徴量を用いた実験であり、領域抽出による差が出ていると考えられる。本手法に適した特徴量を用いた実験3においては、比較対象である実験1よりデータセット A で 26.8%、データセット B で 12.4%の正答率の増加が見られる。

実験1と実験3ではどちらのデータセットでも有意差が出ている。実験1と実験2ではデータセット A でのみしか有意差が出て

いないが、この違いは実験1の結果にデータセット間での大きな変動が見られる為である。

実験2と実験3でどちらのデータセットでも有意差が出ている事を考えると、複雑な領域を抽出した後に選ぶ特徴量によって結果に差が生じる事を示している。

以上より、複雑な領域の抽出をした後に本手法の特徴量を取ることによって、絵画の自動分類の精度に安定した向上が望めると言える。

参考文献

- [Christoudias et al. 2002] Christopher M. Christoudias, Bogdan Georgescu and Peter Meer: Synergism in Low Level Vision. Proceedings of the 16th International Conference on Pattern Recognition, vol.4, pp.150-155, 2002.
- [Gunsel et al. 2005] Bilge Gunsel, Sanem Sariel and Oguz Icoğlu: Content-Based Access to Art Paintings. Image Possessing, 2005. ICIP 2005, IEEE International Conference on publication Date, vol.2, pp.558-561, 2005
- [Jiang et al. 2006] Shuqiang Jiang, Qingming Huang, Qixiang Ye and Wen Gao: An effective method to detect and categorize digitized traditional Chinese painting. Pattern Recognition Letters, vol.27, pp.734-746, 2006
- [Luxburg 2007] Ulrike von Luxburg: A Tutorial on Spectral Clustering. Statistics and Computing, vol. 17, no. 4, pp. 395-416, 2007
- [Lienhart et al. 2002] Rainer Lienhart and Alexander Hartmann: Classifying Images on the Web Automatically. Journal of Electronic Imaging, vol.11, Issue 4, pp.445-454, 2002
- [大岡 1986] 大岡信, 本江邦夫: アート・ギャラリー 現代世界の美術, 集英社, 1986
- [新納 2007] 新納浩幸: R で学ぶクラスタ解析, オーム社, 2007
- [ソルソ 1997] ロバート・L・ソルソ: 脳は絵をどのように理解するか 絵画の認知科学, 新曜社, 1997
- [吉川 2001] 吉川正俊, 植村俊亮: マルチメディアデータのための索引技術 情報処理, vol.42, no.10, pp.953-957, 2001