

編集距離と多次元尺度構成法によるシルエット画像認識

張明明 大町真一郎 阿曾弘具

東北大学大学院工学研究科 〒980-8579 宮城県仙台市青葉区荒巻字青葉6-6-05

E-mail: johnson@aso.ecei.tohoku.ac.jp, {machi, aso}@ecei.tohoku.ac.jp

あらまし シルエット画像をグラフで表現し、グラフマッチングを行うことにより認識する手法を提案する。多様な形状のシルエット画像を高精度に認識するために、カテゴリごとに一枚ではなく複数枚のシルエット画像を用いる。グラフ間の編集距離に多次元尺度構成法を適用することによってグラフをベクトル空間に埋め込み、通常のベクトルを対象とした識別器を適用して認識することを可能とする。多次元尺度構成法では、通常は全データを用いてベクトル空間への埋め込みを行うが、これでは未知データが得られる度に埋め込み操作を行う必要があり、非常に時間がかかる。本論文では、学習データのみから得られた空間に未知データを配置する手法を用いることで高速処理を実現する。

キーワード 中心軸, グラフマッチング, 編集距離, 多次元尺度構成法, シルエット画像, 画像認識

Silhouette Images Recognition by Edit Distance and Multidimensional Scaling

Mingming ZHANG, Shinichiro OMACHI, and Hiroto ASO

Graduate School of Engineering, Tohoku University

Aramaki-aza-Aoba 6-6-05, Aoba-ku, Sendai-shi, Miyagi, 980-8579 Japan

E-mail: johnson@aso.ecei.tohoku.ac.jp, {machi, aso}@ecei.tohoku.ac.jp

Abstract Graph representations are usually used to classify silhouette images based on topological features. A main graph-matching algorithm is the graph edit-distance algorithm that calculates the distance as dissimilarity between two graphs. In generally, by using multidimensional scaling method can embed the graph into a real vector space to get a vector representation of a graph that can be used many vector-based classifiers. However, it is very expensive that to calculate the vector representation of a new graph using multidimensional scaling. In the paper, we present a fast method to classify silhouette images by using multidimensional scaling and edit distance.

Key words Medial Axis, Graph Matching, Edit-Distance, Multidimensional Scaling, Silhouette, Image Recognition

1. はじめに

物体を認識することはコンピュータビジョンの分野において主要な問題である。物体を認識する際に物体の特徴を適切に抽出する必要がある。物体の特徴は色、形状、位置、大きさなど様々である。本論文で扱うシルエット画像は物体の大きさ、形状、構造などの情報を含んでいる。

人間がシルエット画像を見るときそこに物体をうまく認識できることからシルエット画像に含まれている情報を利用して物体の識別が可能であると考えられる。ここでシルエット画像のグラフ表現に注目する。グラフ表現はシルエット画

像の特徴をある程度表しているものと考えられる。たとえば、牛、馬など動物のグラフ表現は類似したトポロジーを持っている。そしてグラフ表現はスケールや回転などに頑健であり、カテゴリ分けに有力な特徴を持つと考えられる。シルエット画像のグラフ表現を求めるためにシルエット画像から中心軸抽出を行い、得られた中心軸をグラフ化することによってシルエット画像のグラフ表現を得ることができる。

グラフを用いて物体を識別する際には一般にグラフマッチングが用いられる。しかし、最適なグラフマッチング問題はNP完全であることが知られている。これに対しグラフマッチングの近似的な解として、二つのマッチングしたいグラフ

に対しいくつかの基本編集操作を適用することによって二つのグラフを一致させる手法がある[3]。一致させるまでの最小編集コストがグラフ間の距離を表すと考え、編集距離と呼ぶ。またグラフマッチング問題を回避し、グラフを連結行列で表して代数的な計算によってグラフを代表するベクトルを求める手法もある[4]。グラフをベクトル空間へ埋め込むことにより様々な識別器を適用できるが、連結行列はノード間の連結性だけを表しているためグラフ表現の利点を失うという問題もある。上記の二つの手法の利点をあわせ持つ手法を提案されている[2]が、求めたベクトルがどのくらい元のグラフを表しているかを評価できないという問題点もある。

本論文ではこれらの手法の利点をまとめ拡張しやすいグラフ編集距離を用いて多次元尺度構成法によりベクトル空間へ埋め込むことによりシルエット画像を認識する手法を提案する。

2. グラフ間の編集距離

本節では二つのシルエット画像の編集距離の計算の手順の概要を述べる。

2.1 中心軸変換

まずシルエット画像のグラフ表現を求めるために、中心軸変換を行う。本論文ではTeleら[1]が提案した中心軸抽出手法を用いた[1]。まず与えられたシルエット画像の輪郭線上の各点に対し順番にラベルを付けていく。ラベルが付いた輪郭線を図1(a)に示す。輪郭線に囲まれた内部の点に対し輪郭線上の最も近い点を探しその点のラベルをその内部点に付ける。そのラベルを濃度値とした画像を変換画像と呼ぶ。変換画像を図1(b)に示す。




図1 (a)ラベルついた輪郭線
(b)変換画像 (c)中心軸

図1(c)に示すように変換画像からエッジ(濃度境界)を抽出することにより中心軸を抽出できる。得られたシルエット画像の中心軸上の点をノードとエッジ上の点を分類することによりグラフ化できる。

2.2 グラフマッチング

得られたシルエット画像のグラフ表現に対しグラフマッチングを行いグラフ間の編集距離を求める。本論文ではKleinの文字列操作を応用したアルゴリズムを用いる[3]。与えられた二つのグラフに対して4種類の基本編集操作を用い一致させるまでの最小編集コストをグラフ間の編集距離として求める。基本編集操作は以下のように定義する。

- 二つのエッジを一致させる操作(match)
- ノード間のエッジを削除する操作(contract)
- 葉を持つエッジを削除する操作(splice)
- 三つのエッジの中葉となるエッジを削除し残った二つのエッジを統合する操作(merge)

これらの基本操作を図2に示す。コストを計算する際にはエッジの重みを設定する必要がある。ここで各エッジの重みをエッジに対応する中心軸の長さとして設定する。




図2 グラフ編集操作

これらの基本操作のコストを以下のように定義する。ただし $w(e)$ はエッジ e の重みを表している。

$$match(e_1, e_2) = |w(e_1) - w(e_2)| \quad (1)$$

$$splice(e) = contract(e) = merge(e) = |w(e)| \quad (2)$$

シルエット画像を識別する従来手法では編集距離をグラフ間の非類似度として識別することが多い。しかし、編集距離は二つの個体から計算したものでありこの二つのグラフに対する依存性が高いため誤識別の可能性が高いと考えられる。一方、高い性能を持つサポートベクトルマシンやニューラルネットワークなどの識別器は非類似度に適用できないため、非類似度を用いグラフをベクトル空間へ埋め込むことにより適用可能とすることを考える。

3. 提案手法

グラフのベクトル空間への埋め込みについて Riesen らは一つ手法を提案している[2]。学習データから何らかの基準で一

つのグラフ集合を選ぶ。与えられたグラフからこの集合のそれぞれのグラフとの編集距離を計算し、得られた編集距離を並べたものをそのグラフを表すベクトルとする。本論文では多次元尺度構成法によりグラフをベクトル空間へ埋め込む。

3.1 多次元尺度構成法

本節では多次元尺度構成法 (Multidimensional Scaling, 略してMDS) の概要を説明する[5]。多次元尺度構成法は観測された対象間の非類似性(距離)が与えられたとき対象を多次元空間内の点として表し、点間の距離と観測された距離が最も良く一致するように点の空間配置を定める方法である。グラフの集合 $G = (g_1, g_2, \dots, g_N)$ と G に属する任意の二つグラフ間の編集距離が与えられたとする。まず任意の三つのグラフ間の距離が三角不等式を満たすように全ての異なるグラフ間の編集距離に定数 α を加算する。

$$d_{ij} = \text{EditDistance}(g_i, g_j) + \alpha \quad (3)$$

距離 d_{ij} を用いて式(4)により対称行列 $\mathbf{B} = (b_{ij})$ を構成する。

$$b_{ij} = \frac{1}{2} \left(\frac{1}{N} \sum_{i=1}^N d_{ij}^2 + \frac{1}{N} \sum_{j=1}^N d_{ij}^2 - \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N d_{ij}^2 - d_{ij}^2 \right) \quad (4)$$

グラフ g_i の空間位置を表すベクトルを \mathbf{x}_i とし、全てのベクトルの平均値 $\bar{\mathbf{x}}$ を原点として、 $d_{ij} = \|\mathbf{x}_i - \mathbf{x}_j\|$ となると想定すると、計算された行列 $\mathbf{B} = (b_{ij})$ は式(5)を満たす。

$$b_{ij} = (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_j - \bar{\mathbf{x}}) \quad (5)$$

行列 \mathbf{B} に対しスペクトル分解を行う。対称行列 \mathbf{B} が非負定符号行列なら、固有値がすべて正であることが分かる。

$$\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_r > 0, \dots, 0 \quad \lambda_{r+1} = \dots = 0 \quad (6)$$

固有ベクトルの行列と固有値から構成した対角行列を用い行列 \mathbf{B} を式(7)のように分解する。

$$\mathbf{B} = \mathbf{Z} \boldsymbol{\lambda} \mathbf{Z}^T \quad (7)$$

そして式(8)のように書き直せば行列 \mathbf{B} を式(9)のように分解できる。

$$\mathbf{A} = \mathbf{Z} \sqrt{\boldsymbol{\lambda}} \quad (8)$$

$$\mathbf{B} = \mathbf{A} \mathbf{A}^T \quad (9)$$

行列 $\mathbf{A}^T = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_N)^T$ の列ベクトルは式(10)を満たす。

$$b_{ij} = \mathbf{a}_i \mathbf{a}_j \quad (10)$$

このように与えられたグラフに対しそれらの空間位置を表す空間ベクトルを求められる。

3.2 ベクトル空間への埋め込み

多次元尺度構成法によって、与えられたグラフ集合の各カテゴリを表すベクトルを求めることができるが、新しいグラフが与えられたときそれをベクトル空間へ埋め込むためにもう一度新しくベクトル空間を構成する必要がある。そのため識別するとき識別器の学習を未知グラフごとに行わなければならない。これは現実的に不可能となる。これを解決するために近似的な手法を考える。まず学習データ $G = (g_1, g_2, \dots, g_N)$ に対する多次元尺度構成法による空間配置 $\mathbf{A}^T = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_N)^T$ を計算する。識別したいグラフ g が与えられたとき学習データとの編集距離を $D = (d_1, d_2, \dots, d_N)$ とする。 g を代表するベクトル \mathbf{x} を求めるために以下の評価関数 J を用いる。

$$J = \frac{1}{2} \sum_{i=1}^N (\|\mathbf{x} - \mathbf{a}_i\| - d_i)^2 \quad (11)$$

評価関数 J が最小となるベクトル \mathbf{x} はグラフ g を代表する空間配置として求められる。評価関数 J のベクトル \mathbf{x} に対する偏微分は式(12)で表される。

$$\frac{\partial J}{\partial \mathbf{x}} = \sum_{i=1}^N (\|\mathbf{x} - \mathbf{a}_i\| - d_i) \frac{(\mathbf{x} - \mathbf{a}_i)}{\|\mathbf{x} - \mathbf{a}_i\|} \quad (12)$$

最急降下法を用い、式(13)の更新式で評価関数 J を最小化するベクトル \mathbf{x} が求められる。

$$\mathbf{x}' = \mathbf{x} - \rho \frac{\partial J}{\partial \mathbf{x}} \quad (13)$$

このように学習グラフの集合を多次元尺度構成法によってベクトル空間に埋め込み、識別器を構築する。未知グラフを最小二乗法で空間位置を定めて識別器により識別することができる。

4. 実験

本手法の有効性を確認するためにkimiaのデータセット[3]を用い実験を行った。このデータセットは全部で18カテゴリ、各カテゴリ12枚のシルエット画像で合計216枚である。すべてのカテゴリに対し6枚を学習データ、6枚をテストデータとする。比較のために同じシルエットのデータセットに対し編集距離を非類似度とする実験とRiesenらが提案した手法による実験も行った。

編集距離を用いた手法では識別するためにまず各カテゴリのプロトタイプを決める。あるカテゴリの学習データにおいてほかのグラフとの編集距離の和が最小となるグラフをこのカテゴリを代表するプロトタイプと決定する。識別する際にプロトタイプを用いて、未知グラフとの編集距離が最も小さいプロトタイプのカテゴリを未知グラフのカテゴリとする。

Riesenらが提案した手法を用いた実験ではまず編集距離の実験において求めた各カテゴリのプロトタイプを用いてグラフの集合を構成する。与えられたグラフとこれらの各グラフとの編集距離を求め、求めた編集距離の組をそのグラフのベクトル表現とする。学習データに対するあるカテゴリのすべてのグラフのベクトルの平均ベクトルをこのカテゴリのプロトタイプとする。識別する際も同様にしてベクトル表現を求め、それと最も近いプロトタイプのカテゴリを識別結果とする。

提案手法ではまず学習データに対して多次元尺度構成法によりそれらを代表するベクトルを求め、各カテゴリの平均ベクトルをプロトタイプとする。識別するとき、未知グラフを表すベクトルを求め、求めたベクトルとユークリッド距離が最小となるプロトタイプのカテゴリを識別結果とする。三つの手法の識別率を表1に示す。

表1. 識別結果

識別手法	編集距離法	Riesen 法	提案手法
正解数/総数	85/108	93/108	101/108
識別率	79%	86%	94%

実験結果から提案手法が従来手法より識別率が高いことが分かる。誤識別したグラフを図3に示す。誤識別したグラフと最も近い学習データの中の10枚のグラフを示している。提案手法が編集距離に基づいて識別する手法であり、正しく編集距離を求めることに依存していることが分かる。従って、識別性能を改善するためには編集距離の計算法を検討する必要がある。

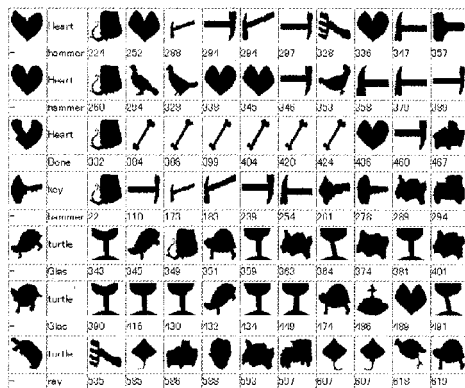


図3 誤識別したグラフ

5. おわりに

本論文ではシルエット画像のカテゴリを識別するために、中心軸からシルエット画像のグラフ表現を求め、グラフ間の編集距離を用いて多次元尺度構成法によりベクトル空間へ埋め込むことで識別器を学習し、最小二乗誤差法で未知グラフを代表するベクトルを求め識別する手法を提案した。

今後の課題としてはまずグラフの編集距離を求める手法を検討し、本論文で用いたデータセットより多いグラフに対する実験をすることを考えている。ニューラルネットワークやサポートベクトルマシンなどより良い識別器を用いて実験を行うことも今後の課題である。

文献

- [1] A. Telea and J. J. van Wijk, "An Augmented Fast Marching Method for Computing Skeletons and Centerlines", IEEE TCVG Symposium on Data Visualisation, 2002, pp. 251–259
- [2] K. Riesen, M. Neuhaus and H. Bunke, "Graph Embedding in Vector Spaces by Means of Prototype Selection", GbRPR 2007, LNCS 4538, pp. 383–393
- [3] T.B. Sebastian, P.N. Klein and B.B. Kimia, "Recognition of shapes by editing their shock graphs", IEEE Trans. on Pattern Analysis and Machine Intelligence 26(5), 550–571 (2004)
- [4] R.C. Wilson, E.R. Hancock and B. Luo, "Pattern vectors from algebraic graph theory", IEEE Trans. on Pattern Analysis and Machine Intelligence Vol. 27, No. 7, pp.1112–1124, 2005
- [5] 齋藤 堯幸, 宿久 洋, "関連性データの解析法——多次元尺度構成法とクラスター分析法", 共立出版, 2006