

紙カルテに印刷された身体部位図の認識

Recognition of Body Part Diagrams Printed on Paper Medical Records

佐々木 捷人†
Hayato Sasaki大崎 美穂†
Miho Ohsaki川中 普晴‡
Hiroharu Kawanaka片桐 滋†
Shigeru Katagiri

1. はじめに

電子カルテが普及した現在も、紙カルテが必要な場面は多い。紙カルテには、医師が疾患部位等を図示するため、図1のような身体部位図が印刷されている。身体部位図を自動的に認識・タグ付けできれば、紙カルテの管理や活用に役立つと考えられる。本研究では、どの身体部位図が含まれるかの認識を目的とする。過去の研究では、加重方向指数ヒストグラム特徴量と修正2次識別関数分類器の組合せを用いた[1]。その認識性能は比較的高いが、リスク回避に重点を置く医療分野ではより高い認識性能が望まれる。また、従来手法には冗長で設定が難しい処理が含まれている。そこで我々は、一定の成果を得た従来手法を基盤に持ち、処理が簡便で設定が容易な勾配方向ヒストグラム特徴量とマハラノビス距離に基づく分類器の組合せを適用する。そして、実験により提案手法の有効性を検証する。

2. 従来手法

従来手法は、加重方向指数ヒストグラム特徴量 (RWDIH: Revised Weighted Direction Index Histogram) と修正2次識別関数分類器 (MQDF: Modified Quadratic Discriminant Function) を組み合わせていた[1]。WDIH特徴量は漢字やひらがなの認識を目的としており、輪郭線抽出に加えて頑強性確保と計算量低減の処理を含む。模式化された身体部位図は漢字やひらがなに似ているが、医師の描画による塗りつぶし領域がある。RWDIH特徴量は、塗りつぶし領域の影響を減らす処理をWDIH特徴量に加えたものである。MQDFは、マハラノビス距離に基づく分類器[2,3]のうち2次識別境界を持つQDFに、共分散行列の固有値近似を施し、頑強性と低計算量を目指した分類器である。

従来手法の認識性能は98.52%と高いが、頑強性確保と計算量低減の処理は複雑であり設定項目も多い。これらの処理の必要性和設定の方法には検討の余地がある。RWDIH特徴量では、高輝度輪郭線の消失等の情報欠落の恐れがある。MQDFでは、2次識別境界が身体部位図認識に適するとは限らず、固有値近似の必要性や固有ベクトル数の決め方にも疑問がある。また、平均ベクトルの算出が特殊であり(訓練用セット外のデータを使用)、この点も問題である。




図1. 紙カルテ上の身体部位図の一例[1].

† 同志社大学, Doshisha University

‡ 三重大学, Mie University




図2. HOG特徴量の抽出手続き.

3. 提案手法

本研究では、一定の成果を持つ従来手法を基盤にしつつ、処理と設定がより簡易な手法として、勾配方向ヒストグラム特徴量 (HOG: Histograms of Oriented Gradients) とマハラノビス距離に基づく分類器 (MDC: Mahalanobis-Distance-based Classifier) の組合せを提案する。

我々は、RWDIH特徴量に懸念される問題(情報欠落の恐れ、処理の冗長さ、設定の難しさ)を解決し得ると考え、HOG特徴量を選定した。これは、画像の部分領域内の輝度の縦横比から勾配強度と勾配方向を算出し、ヒストグラム化した特徴量である。物体の大きな形状を表現でき、人検出等に用いられる[4]。

HOG特徴量では、画像の各ピクセルの輝度値から勾配強度 m と勾配方向 θ を算出する。画像を部分領域に分割し、各部分領域で θ を9方向に量子化して、方向に対する m のヒストグラムを求める(図2参照)。最後に、 2×2 セルから成るブロックをシフトしながら、ブロックごとに局所的な正規化を行う。この結果を並べたものがHOG特徴量である。

従来手法のMQDFには、2次識別境界というモデルの複雑さが適するののか、共分散行列の固有値近似は必要であるか、固有ベクトル数は適切であるか等の問題があった。そこで我々は、線形から2次までの識別境界を表現でき、固有値近似を含まないMDCが有効であると考えた。

MDCは、クラスの事前分布に多項分布、クラス内の事例の分布にガウス分布を仮定して推定する[2,3]。ベイズの定理を適用し、式(1)に示す各クラスの事後分布を導出する。ここで、 \mathbf{x} は事例のD次元特徴量ベクトル、 C_k はk番目のクラスを表す。 $\Pr(\mathbf{x})$ は事例の確率密度、 $\Pr(\mathbf{x}|C_k)$ はk番目のクラス内の事例の確率密度、 $\Pr(C_k)$ と $\Pr(C_k|\mathbf{x})$ はk番目のクラスの事前確率と事後確率。 μ_k と Σ_k は $\Pr(\mathbf{x}|C_k)$ の平均ベクトルと共分散行列である。事例 \mathbf{x} のクラスは最大の $\Pr(C_k|\mathbf{x})$ を持つ C_k であると判定する。

$$\begin{aligned} \Pr(C_k|\mathbf{x}) &= \Pr(C_k) \Pr(\mathbf{x}|C_k) / \Pr(\mathbf{x}) \\ &= \Pr(C_k) \times \\ &\left\{ \frac{1}{(2\pi)^{D/2}} \frac{1}{|\Sigma_k|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x} - \mu_k)^T \Sigma_k^{-1} (\mathbf{x} - \mu_k)\right) \right\} \\ &/ \Pr(\mathbf{x}) \end{aligned} \quad (1)$$

表1. MQDFとMDC-Q, MDC-L, MDC-L-DCの関係

	MQDF	MDC-Q	MDC-L	MDC-L-DC
共分散行列	クラス間で異なる固有値近似	クラス間で異なる	クラス間で共通	クラス間で共通 同値対角
識別境界	2次	2次	線形	線形. 平均間の垂直二等分

MDCでは、クラス内の共分散行列に仮定を置くことで、異なるモデルの複雑さを実現できる。ここでは便宜上、共分散行列はクラスごとに異なると仮定するMDCをMDC-Q (Quadratic)、クラス間で共通とするものをMDC-L (Linear)、クラス間で共通、かつ、同値の対角行列とするものをMDC-L-DC (Linear with Diagonal Constraints)と呼ぶ。従来手法のMQDFとMDCの共分散行列と識別境界の関係を表1に示す。

4. 評価実験

4.1 目的と条件

提案手法であるHOG特徴量とMDCの組合せの有効性を実験検証した。HOG特徴量に関しては、適切な特徴の表現と次元を得るべく、部分領域の分割数は4×4, 7×7の2種類とした。勾配は9方向、ブロックサイズは2×2、ブロックのシフト幅は1部分領域とした。これらは文献[1,4]を参考に設定した。設定や学習のレンジを揃えるため、特徴量は事例間で正規化して入力した。

MDCに関しては、モデルの適切な複雑さを得るべく、MDC-Q, MDC-L, MDC-L-DCを検討した。比較対象はRWDIH特徴量とMQDFの組合せ、および、WDIH特徴量とMDCの組合せである。WDIH特徴量の部分領域の分割数は、文献[1]より4×4, 7×7の2種類とした。MDCにはハイパーパラメータがないので、データセットを訓練用とテスト用に分割して、5つ抜き交差検定による評価を行った[1]。

紙カルテの様式や使用状況は病院ごとに異なる。そこで、我々は三重大学医学部附属病院で調査を行い、一般的と考えられる身体部位図10種類を選定した(図3参照)。そして、疑似的な身体部位図データセットを次のように作成した。医師の描画を含む身体部位図を参考に、10名の大学生が異なる疾患部位・大きさの描画を行い、1種類の身体部位図につき50パターンの描画結果を求めた。すなわち、10種類×50パターン=500の画像のデータセットを得た。さらに、紙カルテのスキヤン作業で生じるずれを模擬して、-2, -1, 0, +1, +2度の各方向に画像を回転した。そして、10種類×50パターン×5角度=2500枚の画像のデータセットを得た。この2500枚は文献[1]で使用されたものと同じである。




図3. 評価実験で使用した10種類の身体部位図

4.1 目的と条件

回転なし500枚、回転あり2500枚のデータセットで得られた認識率を表2, 3に各々示す。提案したHOG特徴量とMDCの組合せは、多くの条件で100.00%の認識率を達成した。これは従来手法の最も高い認識率である98.52%より高く、提案手法が有効であると確認された。

特徴量に関して、全体的にHOG特徴量はWDIH特徴量よりも認識性能が高い。HOG特徴量には、WDIH特徴量の線損失といった情報欠落が生じなかったと考えられる。また、HOG特徴量の異なる分割数間で比較すると、僅差ではあるが7×7よりも4×4の認識率が高く、今回は4×4が適切と言える。同じ特徴量間で分類器を比較すると、全条件においてMDC-LはMDC-QとMDC-L-DCより認識性能が高く、MDC-Lが適切なモデルの複雑さと言える。以上より、HOG特徴量(4×4分割)とMDC-Lの組合せが最も有効であった。

表2. 回転なし500枚の身体部位図に対する各認識率[%]

	MDC-L-DC	MDC-L	MDC-Q
HOG (4x4)	100.00	100.00	98.40
HOG (7x7)	100.00	100.00	85.20
WDIH (4x4)	95.20	99.00	89.20
WDIH (7x7)	99.20	99.20	81.00

表3. 回転あり2500枚の身体部位図に対する各認識率[%]
下線部の数値は文献[1]から引用。

	MDC-L-DC	MDC-L	MDC-Q	従来手法
HOG (4x4)	100.00	100.00	100.00	-
HOG (7x7)	100.00	100.00	100.00	-
WDIH (4x4)	96.40	100.00	100.00	<u>93.04</u>
WDIH (7x7)	99.28	100.00	99.68	<u>96.72</u>
RWDIH	-	-	-	<u>98.52</u>

5. おわりに

本研究では、紙カルテの管理や知識発見に不可欠である自動タグ付けを目指し、紙カルテに印刷された身体部位図の認識を試みた。従来手法の認識率98.52%に対し、提案手法は100.00%の認識率を持ち、処理の簡便さと設定の容易さも含めて有効であることが示された。今後は、紙カルテからの身体部位図の抽出と、身体部位図上の描画の認識に着手したい。

参考文献

- [1] H. Kajiwara et al., "Modified Weighted Direction Index Histogram Method for Schema Recognition," LNCS, Springer, vol.8746, pp. 63-73, 2014.
- [2] C. M. Bishop, "Pattern Recognition and Machine Learning," Springer, 2006.
- [3] T. Hastie et al., "The Elements of Statistical Learning," Springer, 2009.
- [4] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," IEEE CVPR, pp.886-893, 2005.