

相関の高い行列のグルーピングによる効率的な行列分解

黒川 貴都^{1,a)} 山内 悠嗣^{1,b)} 安倍 満^{2,c)} 山下 隆義^{1,d)} 藤吉 弘亘^{1,e)}

1. はじめに

近似計算を導入した線形識別器の高速化として、二値ベクトル分解 [1], [2] を多クラス問題に適用した行列分解法 [3] が提案されている。行列分解法は全クラスに対して共通の二値基底行列を用いて分解するため、二値ベクトル分解法と比べ効率が良いというメリットがある。しかし、相関が低い多クラス識別器に対しては多くの基底数が必要となり、計算時間が増加することが報告されている [3]。そこで、本研究では識別器のグルーピングを導入し、より効率的な行列分解と識別演算の高速化法を提案する。

2. 行列分解法 [3]

one-vs.-rest では、クラス数 J 個の二クラス識別器を用いて多クラス識別を実現している。そのため、図 1 に示すようにクラス数の重みベクトル $\mathbf{w} \in \mathbb{R}^D$ が算出され、これら全ての重みベクトル \mathbf{w} と入力特徴ベクトル $\mathbf{x} \in \{-1, 1\}^D$ との内積計算が必要となるため処理時間を要する。この問題に対し、黒川らは図 1(b) に示すように重みベクトルをスタックした重み行列 $\mathbf{W} \in \{\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_J\}$ を基底数 k の二値基底行列 $\mathbf{M} \in \{-1, 1\}^{D \times k}$ とスケール係数行列 $\mathbf{C} \in \mathbb{R}^{k \times J}$ に分解する行列分解法を提案した [3]。重み行列の分解は式 (1) のコスト関数を最小化するように二値基底行列 \mathbf{M} とスケール係数行列 \mathbf{C} を最適化する。

$$\|\mathbf{W} - \mathbf{MC}\|_F^2 \quad (1)$$

二値ベクトル間の内積計算はハミング距離の計算に置き換えることができるため、高速な演算が可能となる。しかし、行列分解では全てのクラスに対して共通の二値基底行列 \mathbf{M} を用いて表現するため、クラス間で相関がない多クラス問題の識別器では多くの基底数が必要となるため、ベクトル分解 [1], [2] に比べ計算時間が増加するという問題がある。




図 1 重み行列 \mathbf{W} の分解

3. 提案手法

本研究では、クラス間の相関が高い識別器群をグルーピングし、各グループに対して行列分解を適用する手法を提案する。これにより、少ない基底数での分解が可能となる。カスケード構造を構築する際の残差行列 \mathbf{R} に対してグルーピングし直すことにより、各段で最適なグループを選択する。

3.1 分解対象行列のグルーピング

本手法では、ベクトル間の距離を基に相関の高い重みベクトルのグルーピングを行う。グルーピングの際はベクトル間の距離を正規化した値を使用する。ベクトル $\mathbf{w}_i (i = 1, 2, \dots, J)$ とベクトル $\mathbf{w}_j (j = 1, 2, \dots, J)$ の距離の正規化を式 (2), (3) に示す。

$$z = \max\{\|\mathbf{w}_a\| \mid a = i, j\} \quad (2)$$

$$ND = -\left(\frac{\|\mathbf{w}_i - \mathbf{w}_j\|}{z} - 1\right) \quad (3)$$

距離 ND は $-1 \sim 1$ の実数であり、 $ND = 1$ であるとき重みベクトル \mathbf{w}_i と \mathbf{w}_j が同じとなり、 $ND = -1$ であるとき重みベクトル \mathbf{w}_i と \mathbf{w}_j は反対の向きのベクトルを表す。グルーピングではしきい値 th^{corre} と ND を使用し $ND > th^{corre}$ であるベクトルを同じグループとする。

3.2 グルーピングを用いたカスケード構造の構築

行列分解は二値基底行列 \mathbf{M} について -1 と 1 の全ての組み合わせを試行するため、基底を 1 つ増やすと分解に必要な時間が 2 倍となる。そのため、基底数が増加すると現実的に分解できない時間が必要となる。そこで、逐次的に行列分解しカスケード構造を構築することで分解に必要な時間を削減するまた、カスケード構造の識別器を構築することで、識別時に近似内積計算の早期棄却ができるため、演算回数の削減が可能となる。カスケード構造の構築は、カスケード 1 で重み行列 \mathbf{W} に対して行列分解を行い、カス

¹ 中部大学 〒 487-0027 愛知県春日井市松本町 1200

² 株式会社センサーアイティラボラトリー 〒 150-0002 東京都渋谷区渋谷二丁目 15 番地 1 号 渋谷クロスタワー 28 階

a) kuro@vision.cs.chubu.ac.jp

b) yuu@vision.cs.chubu.ac.jp

c) manbai@d-itlab.co.jp

d) yamashita@cs.chubu.ac.jp

e) hf@cs.chubu.ac.jp




図 2 処理時間と識別精度の比較

ケード 2 以降では残差行列 \mathbf{R} に対して行列分解を行う。残差行列 \mathbf{R} は、前のカスケードで相関がないベクトルも分解により相関が高くなることもある。そこで、図 3 に示すように残差行列においてもグルーピングし直すことで、各カスケードで最適なグループを選択する。グルーピングと行列分解によるカスケード構造の構築法を Algorithm 1 に示す。

Algorithm 1 相関の高い重みベクトルのグルーピングによるカスケード構造の構築法

Require: \mathbf{W} , k , N , L

$\mathbf{R} \leftarrow \mathbf{W}$

for $n = 1$ to N **do**

残差行列 \mathbf{R} における重みベクトル間の距離を式 (2, 3) より算出 $|ND|$ がしきい値 th^{corre} 以上である重みベクトルをグルーピングし G 個の残差行列 \mathbf{R} を作成

for $g = 1$ to G **do**

残差行列 \mathbf{R}_g を行列分解により $\hat{\mathbf{M}}_n$ と $\hat{\mathbf{C}}_n$ に分解

end for

$\mathbf{R} \leftarrow \mathbf{R} - \hat{\mathbf{M}}_n \hat{\mathbf{C}}_n$

end for

return $\{\hat{\mathbf{M}}\}$, $\{\hat{\mathbf{C}}\}$

Algorithm 1 では、分解時はそれぞれのグループ毎で基底数 k の行列分解を行う。

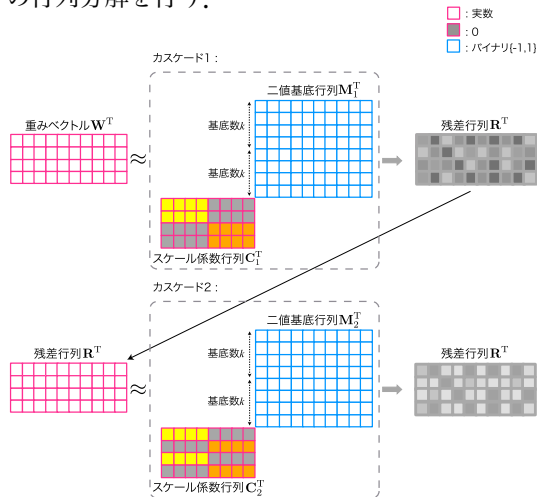


図 3 グルーピングを用いたカスケード構造の構築：スケール係数行列の各要素の色はそれぞれのグループを表す。

4. 評価実験

多クラスにおけるベクトル分解法と提案手法の行列分解法による誤差を比較する。実験に用いる識別器は SVM とし、データセットの画像から抽出した 1,158 次元の B-HOG 特徴量 [4] を使用する。また、識別精度と 1 枚あたりの識別時間を比較する。識別時間の比較では、CPU: Intel Xeon

CPU X7542@2.67GHz, RAM:256GB の PC を用いる。評価実験では、Hare らの分解法と Yamauchi らの分解法を適用した one-vs.-rest による多クラス識別器と比較する。実験に用いるデータセットは形状が類似している 4 クラス (図 4(a)) と 27 クラス (図 4(b)) の標識、形状が類似していない 41 クラス (図 4(c)) の標識を使用する。学習時には各クラスの標識画像 500 枚とネガティブ画像 10000 枚用い、識別時には各クラスの標識画像 500 枚とネガティブ画像 100000 枚用いる。False Positive Rate = 0.01 で True Positive Rate が分解前と比較し ± 0.05 である時の識別時間を図 2 に示す。図 2 より、提案手法は形状が類似している 4 クラス及び 27 クラスの場合、行列分解法と同等な識別時間であるが、形状が類似していない 41 クラスの場合、分解前に比べ約 4.7 倍、行列分解法に比べ約 1.8 倍高速な識別を実現した。




図 4 標識画像

5. おわりに

提案手法は行列分解にグルーピングを導入することで、分解前に比べ約 4.7 倍、行列分解法に比べ約 1.8 倍高速な識別が可能であることを確認した。今後はより多くのクラス分類問題において提案手法を適用させる。

参考文献

- [1] Hare, S. *et al*, "Efficient online structured output learning for keypoint-based object tracking," CVPR, pp. 1894–1901, 2012
- [2] Yamauchi, Y. *et al*, "Asymmetric Feature Representation for Object Recognition in Client Server System," ACCV, 2014
- [3] 黒川貴都等, "行列分解と早期棄却による多クラス物体検出の高速化," CVIM, no. 2, pp. 1–7, 2015
- [4] Yamauchi, Y. *et al*, "Relational HOG Feature with Wild-Card for Object Detection," ICCV, 2011