

# 基于多特征和改进 SVM 集成的图像分类

付 燕, 鲜艳明

(西安科技大学计算机学院, 西安 710054)

**摘 要:** 现有图像分类方法不能充分利用图像各单一特征之间的优势互补特性, 提取的特征中存在大量冗余信息, 从而导致图像分类精度不高。为此, 提出一种基于多特征和改进支持向量机(SVM)集成的图像分类方法。该方法能提取全面描述图像内容的综合特征, 采用主成分分析对所提取的特征进行变换, 去除冗余信息, 使用支持向量机的集成分类器 RBaggSVM 进行分类。仿真实验结果表明, 与同类图像分类方法相比, 该方法具有更高的图像分类精度和更快的分类速度。

**关键词:** 多特征; 主成分分析; 支持向量机集成; PCA-RBaggSVM 算法; 图像分类

## Image Classification Based on Multi-feature and Improved SVM Ensemble

FU Yan, XIAN Yan-ming

(School of Computer, Xi'an University of Science and Technology, Xi'an 710054, China)

**【Abstract】** Aiming to the problem with poor classification accuracy of present image classification methods because they fail to apply fully complementary advantages between various single features of images and redundant information exists in the extracted features, this paper presents an image classification method based on multi-feature and improved Support Vector Machine(SVM) ensemble algorithm. Comprehensive features describing fully image content are extracted; redundant information is removed by transforming extracted features with Principal Component Analysis(PCA). RBaggSVM classifier is applied for classification. Simulation experimental result shows that this method has higher accuracy and faster speed of image classification than similar methods.

**【Key words】** multi-feature; Principal Component Analysis(PCA); Support Vector Machine(SVM) ensemble; PCA-RBaggSVM algorithm; image classification

DOI: 10.3969/j.issn.1000-3428.2011.21.067

### 1 概述

图像分类在很多领域都是一项关键性的任务, 因此如何利用计算机快速、准确地对图像进行分类判别的技术得到了诸多学者关注, 如文献[1]提出基于直推式支持向量机(Support Vector Machine, SVM)的图像分类算法, 文献[2]提出基于小波变换和支持向量机的图像分类方法等。然而, 文献[1-2]在对图像进行分类时, 均采用单一特征, 可是单一特征只能描述图像的部分属性, 对图像内容描述比较片面, 并且所提取的特征中存在大量的冗余信息, 而冗余信息又极大地损害学习器的泛化能力<sup>[3]</sup>, 因此图像分类精度并不高。

本文提出一种新的图像分类方法, 该方法首先提取图像的综合特征; 然后采用主成分分析(Principal Component Analysis, PCA)对所提取的特征进行变换, 去除特征中的冗余信息, 以 RBaggSVM 算法作为分类器对其进行分类。

### 2 综合特征提取

由于单一特征只能描述图像的部分属性, 对图像内容描述比较片面, 缺少足够的区分信息, 在图像有较大变化(如尺度或方向)的场合通常不能取得较好的分类效果。因此, 本文提出一种综合特征提取方法。

设  $I_k$  表示图像库中第  $k$  幅图像, 向量  $F_{iP_i}^k$  表示  $I_k$  的第  $i$  ( $i=1, 2, \dots, m$ ) 种单一特征,  $P_i$  表示该特征向量所具有的分量个数, 那么  $I_k$  的任意 2 种不同的单一特征向量通过合并所构成的综合特征集合可记为:

$$\left\{ \left[ F_{iP_i}^k, F_{jP_j}^k \right]_{1 \times (P_i + P_j)} \middle| 1 \leq i < j \leq m \right\}$$

该集合具有  $C_m^2$  个元素; 同理,  $I_k$  的任意 3 种不同的单一特征向量通过合并所构成的综合特征集合可记为:

$$\left\{ \left[ F_{iP_i}^k, F_{jP_j}^k, F_{rP_r}^k \right]_{1 \times (P_i + P_j + P_r)} \middle| 1 \leq i < j < r \leq m \right\}$$

该集合具有  $C_m^3$  个元素; 依此类推,  $I_k$  的任意  $n$  ( $n=4, 5, \dots, m$ ) 种不同的单一特征通过合并所构成的综合特征集合可记为:

$$\left\{ \left[ F_{iP_i}^k, F_{jP_j}^k, \dots, F_{sP_s}^k \right]_{1 \times (P_i + P_j + \dots + P_s)} \middle| 1 \leq i < j < \dots < s \leq m \right\}$$

其中,  $i, j, \dots, s$  中共含有  $n$  个不同的子项, 该集合具有  $C_m^n$  个元素。  $I_k$  的所有综合特征集合中共含有  $C_m^2 + C_m^3 + \dots + C_m^m$  个元素, 每个元素都是  $I_k$  的一个综合特征。

### 3 基于多特征和改进 SVM 集成的图像分类

#### 3.1 RBaggSVM 算法

理论界普遍认为在相同的信息量条件下, 多分类器集成的学习方法通常能够获得比单个分类器更好的泛化能力, 因此, 文献[4]在单个 SVM 算法的基础上提出 SVM 集成算法

**作者简介:** 付 燕(1972—), 女, 教授、博士, 主研方向: 图形图像处理, 软件工程; 鲜艳明, 硕士研究生

**收稿日期:** 2011-05-16 **E-mail:** xym2008\_4210@126.com

RBaggSVM。

虽然该算法已具有很好的泛化能力,但是图像数据中通常含有大量的冗余信息,而冗余信息又极大地损害学习器的泛化能力。另外,多特征结合会造成特征维数的上升,而特征维数的上升将导致在采用该算法进行图像分类时,对 SVM 进行训练和测试所占用的时间增长,可是特征维数的多少与分类效果之间并没有必然联系。因此,在采用该算法进行图像分类时,需要对所提取的特征进行降维,去除特征中的冗余信息。

目前,可以用于降维的算法有许多,如 PCA、ICA、LLE 等。文献[5]指出与其他降维算法不同,PCA 在去除图像的二阶相关性时,能使重构的图像与原图像相比具有方差小和峰值信噪比高的特点。

因此,本文提出采用 PCA 进行特征变换,去除特征中的冗余信息,然后将经过 PCA 变换的特征作为 RBaggSVM 的输入进行分类的方法,并将该方法命名为 PCA-RBaggSVM。

### 3.2 PCA-RBaggSVM 算法

PCA-RBaggSVM 算法描述如下:

**输入** 训练集  $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$ ,  $x_i \in X$ ,  $y_i \in \{1, 2, \dots, k\}$ ; 主成分累计贡献率  $\eta$ ; 分类器  $h$ ; 迭代次数为  $N_{\text{iterative}}$ ; 每个 Bag 的大小为  $M$  (一般  $M = l$ ); 惩罚参数  $C$  的范围为  $(C_{\min}, C_{\max})$ ; 核参数  $\gamma$  的范围为  $(\gamma_{\min}, \gamma_{\max})$ ; 差异阈值为  $Div_{\text{threshold}}$ 。

**输出** 多数投票法集成函数  $f(x) = \arg \max(V_i)$ ,  $i = 1, 2, \dots, k$ 。

- (1) 根据  $\eta$  对  $T$  进行 PCA 变化:  $S' \leftarrow T$ ;
- (2)  $\hat{S} \leftarrow$  对  $S'$  进行归一化;
- (3) for  $n = 1, 2, \dots, N_{\text{iterative}}$
- (4)  $\hat{S}_n \leftarrow$  从  $\hat{S}$  中随机重采样  $M$  个样本;
- (5)  $C_n \leftarrow$  随机选择一个惩罚参数  $C$ ;
- (6)  $\gamma_n \leftarrow$  随机选择一个核参数  $\gamma$ ;
- (7) 利用  $\hat{S}_n$  对  $h$  进行学习:  $h_n \leftarrow h(\hat{S}_n)$ ;
- (8) 计算差异  $Div_n$ ;
- (9) if  $(Div_n < Div_{\text{threshold}})$ , 剔除  $h_n$ , 并令  $n = n - 1$ ,
- goto (4);
- (10) 选择  $h_n$  作为成员分类器。

主成分累计贡献率  $\eta$  决定了训练集  $T$  中的样本在经过 PCA 变换后其所具有的主成分数(特征分量数)。迭代次数

$N_{\text{iterative}}$  决定了 PCA-RBaggSVM 算法中成员分类器的个数。

### 4 实验结果与分析

实验所用图像均来自标准 Corel 图像库([http://d.download.csdn.net/download/2248712/zeng\\_1228](http://d.download.csdn.net/download/2248712/zeng_1228) 和 [http://d.download.csdn.net/download/2248733/zeng\\_1228](http://d.download.csdn.net/download/2248733/zeng_1228))和互联网,选择 4 类 24 位的 RGB 图像,每类 100 幅,分别为玫瑰花、建筑物、轿车和恐龙。随机选择每类图像的 70% 作为训练集,剩余的 30% 作为测试集。

测试机器是操作系统为 Windows XP, Core 2.00 GHz CPU, 1 GB 内存的 PC 机,算法采用 VC++ 6.0 工具实现。

目前,有多种方法可以将 SVM 由 2 类扩展到多类,如一对一法(OAO)、一对多法(OAA)和有向无环图(DAG)SVM 等。文献[6]指出一对一法更加适用于实际的工程应用。因此,在实验中采用 OAO 型的 SVM(简称 OAO-SVM)对 4 类图像进行分类。

#### 实验 1

首先分别提取图像的环形颜色直方图(RCH)特征  $[F_{\text{RCH}}]_{1 \times 576}$ 、灰度共生矩阵(GLCM)特征  $[F_{\text{GLCM}}]_{1 \times 8}$ 、小波包变换(WPT)特征  $[F_{\text{WPT}}]_{1 \times 40}$  和边缘方向直方图(EDH)特征  $[F_{\text{EDH}}]_{1 \times 73}$ ; 然后采用单个 OAO-SVM 对 4 类图像进行分类,各类图像在不同的单一特征下的分类准确率和平均准确率如表 1 所示。

表 1 单一特征和单个 OAO-SVM 对 4 类图像的分类结果

特征	惩罚参数 $C$	核参数 $\gamma$	准确率/(%)				平均准确率/(%)
			玫瑰花	建筑物	轿车	恐龙	
$[F_{\text{RCH}}]_{1 \times 576}$	4.0	0.062 500	83.333	66.667	46.667	63.333	65.000
$[F_{\text{GLCM}}]_{1 \times 8}$	524 288.0	0.031 250	83.333	53.333	66.667	60.000	65.833
$[F_{\text{WPT}}]_{1 \times 40}$	2 048.0	0.015 625	46.667	73.333	43.333	66.667	57.500
$[F_{\text{EDH}}]_{1 \times 73}$	1.0	0.250 000	56.667	56.667	56.667	93.333	65.834

从表 1 可以看出,无论使用哪种单一特征对 4 类图像进行分类,其分类的平均准确率都不高。例如,当采用单一特征  $[F_{\text{EDH}}]_{1 \times 73}$  对 4 类图像进行分类时,虽然恐龙图像的分类准确率达到 93.333%,但是,由于其他 3 类图像的分类准确率较低,因此它们的平均准确率并没有超过 66.000%。

#### 实验 2

首先对实验 1 中所提取的 4 种单一特征进行组合,从而得到 11 种综合特征,然后分别以所得到的各种综合特征为输入,采用单个 OAO-SVM 对 4 类图像进行分类,各类图像在不同综合特征下的分类准确率和平均准确率如表 2 所示。

表 2 综合特征和单个 OAO-SVM 对 4 类图像分类的结果

特征	惩罚参数 $C$	核参数 $\gamma$	准确率/(%)				平均准确率/(%)
			玫瑰花	建筑物	轿车	恐龙	
$[F_{\text{RCH}}, F_{\text{GLCM}}]_{1 \times 584}$	2.0	0.062 5	86.667	66.667	46.667	66.667	66.667
$[F_{\text{RCH}}, F_{\text{WPT}}]_{1 \times 616}$	2.0	0.060 0	83.333	70.000	66.667	46.667	66.667
$[F_{\text{RCH}}, F_{\text{EDH}}]_{1 \times 649}$	2.0	0.062 5	86.667	60.000	63.333	73.333	70.833
$[F_{\text{GLCM}}, F_{\text{WPT}}]_{1 \times 48}$	4.0	1.000 0	76.667	66.667	60.000	70.000	68.334
$[F_{\text{GLCM}}, F_{\text{EDH}}]_{1 \times 81}$	4.0	0.250 0	50.000	66.667	70.000	96.667	70.834
$[F_{\text{WPT}}, F_{\text{EDH}}]_{1 \times 113}$	8.0	0.125 0	53.333	60.000	66.667	90.000	67.500
$[F_{\text{RCH}}, F_{\text{GLCM}}, F_{\text{WPT}}]_{1 \times 624}$	1.0	0.100 0	90.000	83.333	56.667	60.000	72.500
$[F_{\text{RCH}}, F_{\text{GLCM}}, F_{\text{EDH}}]_{1 \times 657}$	2.0	0.062 5	93.333	73.333	53.333	73.333	73.333
$[F_{\text{RCH}}, F_{\text{WPT}}, F_{\text{EDH}}]_{1 \times 689}$	2.0	0.058 0	90.000	83.333	60.000	63.333	74.167
$[F_{\text{GLCM}}, F_{\text{WPT}}, F_{\text{EDH}}]_{1 \times 121}$	2.0	0.150 0	53.333	63.333	76.667	93.333	71.667
$[F_{\text{RCH}}, F_{\text{GLCM}}, F_{\text{WPT}}, F_{\text{EDH}}]_{1 \times 697}$	1.0	0.062 5	96.667	53.333	76.667	76.667	75.834

从表 1 与表 2 的对比可以看出,相对于 4 类图像在单一特征下的分类准确率而言,其在绝大多数综合特征下的分类

准确率都有不同程度的提高。并且它们在各种综合特征下分类的平均准确率都高于其在单一特征下的平均准确率,当采

用综合特征 $[F_{RCH}, F_{GLCM}, F_{WPT}, F_{EDH}]_{1 \times 697}$ 进行分类时, 分类的平均准确率是所得到的 11 种综合特征中最高的。这说明图像的各种单一特征之间存在优势互补的特性。

### 实验 3

以 PCA-RBaggSVM 算法为分类器, 采用图像的综合特征 $[F_{RCH}, F_{GLCM}, F_{WPT}, F_{EDH}]_{1 \times 697}$ 对 4 类图像进行分类。随着 PCA 的主成分累计贡献率  $\eta$  取值的变化, 分类的平均准确率如图 1 所示。




图 1 主成分累计贡献率  $\eta$  对平均分类准确率的影响

从图 1 可以看出, 当采用 PCA-RBaggSVM 算法对 4 类图像进行分类时, 随着  $\eta$  的取值从 100% 减小到 94%, 分类

平均准确率逐渐上升; 当  $\eta=94\%$  时, 平均准确率达到最高。当  $\eta$  的取值继续减小时, 平均准确率不再继续上升, 其总的趋势是逐渐下降。

出现这种现象的原因是: 当  $\eta$  的取值从 100% 减小到 94% 时, 综合特征 $[F_{RCH}, F_{GLCM}, F_{WPT}, F_{EDH}]_{1 \times 697}$ 在经 PCA 变换时, 特征中的冗余信息被去除的力度逐渐加大; 当  $\eta=94\%$  时, 综合特征中的冗余信息几乎被去除尽。

然而当  $\eta$  的取值再继续减小时, 综合特征在经 PCA 变换时, 不仅去除了特征中的冗余信息, 也去除了特征中的有效信息。

### 实验 4

分别以 RBaggSVM 和 PCA-RBaggSVM 算法为分类器, 其中, 成员分类器的个数  $N_{\text{iterative}} = 21$ ; 主成分累计贡献率  $\eta = 94\%$ ; 采用图像的综合特征 $[F_{RCH}, F_{GLCM}, F_{WPT}, F_{EDH}]_{1 \times 697}$ 对 4 类图像进行分类。各类图像在 2 种算法下的分类准确率和平均准确率如表 3 所示。可以看出, 建筑物图像和轿车图像在 PCA-RBaggSVM 算法下的分类准确率明显好于其在 RBaggSVM 算法下的分类准确率, 并且 4 类图像在 PCA-RBaggSVM 算法下分类的平均准确率比在 RBaggSVM 算法下高出 7.5 个百分点。由此可知, 对特征进行 PCA 变换, 去除特征中的冗余信息, 可以有效提高图像分类精度。

表 3 2 种算法的图像分类结果比较

分类方法	惩罚参数 $C$		核参数 $\gamma$		准确率 (%)				平均准确率 (%)
	$C_{\min}$	$C_{\max}$	$\gamma_{\min}$	$\gamma_{\max}$	玫瑰花	建筑物	轿车	恐龙	
RBaggSVM	0.100	5.000	0.022 5	0.102 5	70.000	83.333	73.333	86.667	78.333
PCA-RBaggSVM	0.500	2.500	0.150 0	0.350 0	70.000	96.667	93.333	83.333	85.833

算法的训练时间和测试时间如表 4 所示。可以看出, PCA-RBaggSVM 算法的训练和测试时间明显比 RBaggSVM 算法少, 这主要是因为综合特征 $[F_{RCH}, F_{GLCM}, F_{WPT}, F_{EDH}]_{1 \times 697}$ 在经过 PCA 变换后, 特征的维数得到了有效的降低, 特征中的冗余信息被大量去除。

表 4 2 种算法的训练时间与测试时间对比

分类方法	特征维数	训练时间/s	测试时间/s
RBaggSVM	697	11.860	9.610
PCA-RBaggSVM	117	2.331	2.219

## 5 结束语

针对当前图像分类方法未能充分利用图像的各种单一特征之间的优势互补特性和所提取的特征中存在大量的冗余信息, 从而致使图像分类精度不高的问题, 本文提出基于多特征结合和 PCA-RBaggSVM 的图像分类方法。在 4 类图像上进行仿真实验, 结果表明该方法不仅能够有效提高图像分类精度, 而且能够明显提高分类速度。今后将研究 PCA-RBaggSVM 算法中成员分类器的数量对分类精度和速度的影

响, 从而进一步提高该算法的性能。

### 参考文献

- [1] 沈新宇, 许宏丽, 官腾飞. 基于直推式支持向量机的图像分类算法[J]. 计算机应用, 2007, 27(6): 1463-1467.
- [2] 翟俊海, 张素芳, 王熙照. 基于小波变换和支持向量机的图像分类[J]. 河北大学学报: 自然科学版, 2007, 27(3): 317-321.
- [3] Yu Lei, Liu Huan. Efficient Feature Selection via Analysis of Relevance and Redundancy[J]. Journal of Machine Learning Research, 2004, 5: 1205-1224.
- [4] 何灵敏. 支持向量机集成及在遥感分类中的应用[D]. 杭州: 浙江大学, 2006.
- [5] 罗 斌, 顾 伟, 吕皖丽, 等. 基于主分量分析的矢量量化数字水印算法[J]. 计算机工程, 2010, 36(2): 167-169.
- [6] Hsu Chih-Wei, Lin Chih-Jen. A Comparison of Methods for Multi-class Support Vector Machines[J]. IEEE Trans. on Neural Networks, 2002, 13(2): 415-425.
- [7] Perona P, Malik J. Scale Space and Edge Detection Using Anisotropic Diffusion[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12(7): 629-639.
- [8] Rudin L, Osher S, Fatemi E. Nonlinear Total Variation-based Noise Removal Algorithms[J]. Physica D, 1992, 60(1-4): 259-268.
- [9] Osher S, Fedkiw R. Level Set Methods and Dynamic Implicit Surfaces[M]. New York, USA: Springer, 2002: 3-22.
- [4] Chung D H, Sapiro G. On the Level Lines and Geometry of Vector-valued Images[J]. IEEE Signal Processing Letters, 2000, 7(9): 241-243.
- [5] Weickert J. Anisotropic Diffusion in Image Processing[M]. Stuttgart, Germany: Teubner Verlag, 1998.
- [6] 陈 颖, 彭进业, 王大凯, 等. 基于 PDE 的图像去噪和反差增强同步算法[J]. 计算机工程, 2009, 35(23): 224-226.

编辑 陆燕菲

编辑 张 帆

(上接第 195 页)



