

基于稀疏编码的脑脊液图像快速识别模型

黄文明, 蔡文正*, 邓珍荣

(桂林电子科技大学 计算机科学与工程学院, 广西 桂林 541004)

(*通信作者电子邮箱 cawezh@qq.com)

摘要:考虑到采用传统的图像分割算法很难准确地分割脑脊液(CSF)细胞图像,提出了一种基于稀疏编码的脑脊液图像快速识别模型。该模型首先利用稀疏编码提取图像中的局部特征以及特征描述子,然后将特征描述子转换成线性空间金字塔匹配(SPM)结构,最后将计算结果输入到线性支持向量机(SVM)中进行训练和预测。对脑脊液细胞图像做了异常识别和分类测试,其中异常识别准确率达到 $89.4 \pm 0.9\%$,且对每张 760×570 的图像平均识别时间只需1.3 s,由此可以表明所提出的模型能够有效快速地区分脑脊液细胞是否异常。

关键词:稀疏编码;脑脊液;无监督学习;线性空间金字塔匹配;线性支持向量机

中图分类号:TP391.41 **文献标志码:**A

Fast recognition model for cerebrospinal fluid images based on sparse coding

HUANG Wenming, CAI Wenzheng*, DENG Zhenrong

(School of Computer Science and Engineering, Guilin University of Electronic Technology, Guilin Guangxi 541004, China)

Abstract: Considering the traditional image segmentation algorithm was difficult to segment cerebrospinal fluid cell images accurately, a fast recognition model based on sparse coding for cerebrospinal fluid cell images was presented in this paper. First in this model local features and feature descriptors from the image were extracted by sparse coding. Then the feature descriptors were transformed into linear Spatial Pyramid Matching (SPM) structure. Finally, the calculated result was input into the linear Support Vector Machine (SVM) for training and prediction. In this paper, a test was made for recognizing abnormal cerebrospinal fluid cell images and classification, and the abnormal recognition accuracy rate of the experimental results was up to $89.4 \pm 0.9\%$, and the average recognition time of each 760×570 image is just 1.3 seconds. Therefore, the presented model can effectively and quickly distinguish normal and abnormal cerebrospinal fluid cell images.

Key words: sparse coding; Cerebrospinal Fluid (CSF); unsupervised learning; linear Spatial Pyramid Match (SPM); linear Support Vector Machine (SVM)

0 引言

检测脑脊液(Cerebrospinal Fluid, CSF),在临床上有助于中枢神经系统以及全身相关疾病的诊断。通常CSF正常和异常两类图像的稀疏性差异较大:正常情况下,是一种无色透明液体,仅有淋巴细胞和单核细胞;异常情况下,透明度较低,会有薄膜形成,甚至是凝块或者沉淀物,伴随出现形态变化大、种类繁多的异常细胞^[1]。往往CSF处于异常状态表明被检测者患有某种疾病,因此,利用计算机快速识别CSF图像是否异常对临床的进一步诊断具有较高的应用价值。

图像识别的一种模型可以先利用图像分割算法对单个细胞进行完整的分割,然后提取人工特征,特征提取的准确性取决于是否能够正确地分割出目标,对拓扑结构复杂多变的CSF图像往往是很难做到的。而另一种图像识别模型旨在寻找图像的局部特征,通常只需要将图像分割成一个个小方块(patch),模型的关键就在于如何在这些patch中找到需要的特征与特征描述子。两种图像识别模型如图1所示。

尺度不变特征转换(Scale-Invariant Feature Transform,

SIFT)^[2]就是一种图像局部特征描述子,它具有位置、尺度和旋转不变性,同时对光照、遮挡和噪声具有良好的稳定性,然而SIFT是人工特征,具有一定的局限性^[3]。不同于SIFT,稀疏编码(Sparse Coding, SC)是一个无监督学习算法^[4-6],通过对训练样本进行稀疏编码可以得到一组完备基,以及投影到这组基上的系数,这组系数具有稀疏性和高区分度性。同时,由于空间金字塔匹配(Spatial Pyramid Match, SPM)模型在场景匹配问题中具有良好的效果^[7],同样适用于本文应用。基于这两点,本文提出了一个基于稀疏编码的脑脊液图像快速识别模型,该模型采取稀疏编码算法进行特征提取,然后经过线性SPM计算获得特征描述子,最后输入到线性支持向量机(Support Vector Machine, SVM)中进行分类。实验结果表明该模型能够有效快速区分CSF图像是否异常。




图1 两种图像识别模型

收稿日期:2014-01-13;修回日期:2014-03-07。 基金项目:广西自然科学基金资助项目(2013GXNSFAA019350)。

作者简介:黄文明(1963-),男,江苏苏州人,教授,主要研究方向:网格计算、图形图像处理、软件工程、信息安全;蔡文正(1988-),男,上海人,硕士研究生,主要研究方向:图像识别、机器学习;邓珍荣(1977-),女,广西桂林人,副教授,硕士,主要研究方向:协议安全、软件架构。

1 相关工作

近年来,随着 SIFT 的提出,许多学者投身于对局部特征描述子的研究中,出现了一系列基于 SIFT 的变种算法^[8-10],这些局部特征描述子在实际应用中不断完善^[9]。特征提取是很多模型的基础,特征提取的好坏直接影响了模型的有效性,SIFT 等人工特征提取算法取得了很好的效果,但是人工特征提取算法存在着一定的局限性^[3]。

几乎同时期,利用无监督学习提取特征的算法取得了很大的发展,无监督学习主要模拟人类的学习行为,目前在计算机视觉领域应用比较广泛。1996 年,Olshausen 等^[4]首次指出:自然图像经过稀疏编码后会出现类似于 V1 区简单细胞感受野的反应特性,使得用稀疏编码进行无监督的特征学习得到了充分的理论支持。2007 年,Ng 等^[5]实现了一种高效的稀疏编码优化算法。

随着各种特征描述子与稀疏编码的成熟,便有了许多结合两者的模型提出^[11-13]。2005 年,Lazebnik 等^[7]对场景分类识别问题,考虑了图像特征的空间结构,并修正了金字塔匹配核,首次提出了 SPM 模型。2009 年,Yang 和 Yu 等^[11]发现对 SIFT 进行稀疏编码后,能够采用线性 SPM 核进行快速的分类器训练,并且具有出色的分类准确率。2010 年,Wang 等^[12]提出了一种新的编码策略,称为局部抑制线性编码(Localized-constrained Linear Coding, LLC),LLC 是一种加了局部约束的稀疏编码,它具有局部平滑稀疏特性;而且不像传统稀疏编码需要有复杂的优化过程,LLC 具有解析解,因此在编码过程中速度更快。2013 年,Jiang 等^[13]在编码过程中的基训练上加入了类别信息,使得不同类别图像能够获得不同的基,由此根据这组基所获得的系数更具有区分度。

文献[7, 11-13]中的模型在对 Caltech101、Caltech256 这些通用图像集的测试中都获得了非常好的结果,然而这些模型在提取特征阶段采用的都是 SIFT,忽略了人工特征的局限性^[3]。CSF 正常和异常两类图像具有极大的细胞稀疏性差异,利用稀疏编码的无监督学习同样可以提取特征,并且结合线性 SPM 和线性 SVM 进行分类识别的速度相对更快。

2 本文模型

本文提出了一种快速识别 CSF 图像是否异常的模型,如图 2 所示。




图2 本文模型

训练样本通过稀疏编码学习得到一组过完备基和投影到这组过完备基上的系数。这组过完备基就是局部特征,系数就是局部特征描述子。接着对训练样本的系数进行线性 SPM 计算和线性 SVM 分类器训练,最后便得到了训练好的分类器。测试样本的预测过程与之类似,只是不需要进行过完备基的训练。模型关键在于稀疏编码特征提取与线性 SPM 计算,这一章将着重分析这两个关键点。

2.1 稀疏编码

稀疏编码能够成功模拟哺乳动物视觉皮层 V1 区简单细

胞的感受野^[4],输入数据经过稀疏编码后由少数基向量的加权线性组合来近似表示,数学上用公式描述为:

$$\mathbf{y} \approx \sum_{j=1}^n \mathbf{b}_j s_j \quad (1)$$

式中: $\mathbf{y} \in \mathbf{R}^p$ 表示单个输入向量; $\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_n \in \mathbf{R}^p$ 表示一组 p 维基向量; $s \in \mathbf{R}^n$ 表示单个基向量所对应的系数,这组系数大部分为零,具有稀疏性。基向量是过完备的($n > p$),因此可以捕获输入数据的高层模式。在本文模型中,这组过完备基代表我们要提取的局部特征,系数代表这组局部特征的描述子。过完备基与系数重构原理如图 3 所示。

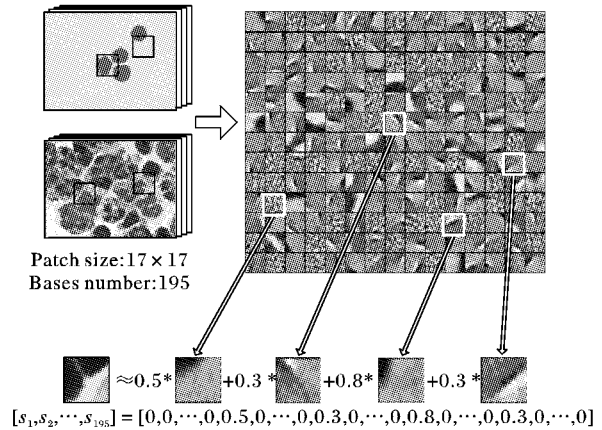


图3 过完备基与系数重构示意图

为了找到式(1)这组基向量和所对应的系数,引出了一个最优化问题,用 $\mathbf{Y} \in \mathbf{R}^{p \times m}$ 表示输入矩阵(每一列表示一个输入向量); $\mathbf{B} \in \mathbf{R}^{p \times n}$ 表示基矩阵(每一列表示一个基向量); $\mathbf{S} \in \mathbf{R}^{n \times m}$ 表示系数矩阵(每一列表示一个系数向量),则得到一个矩阵形式的方程:

$$\min_{\mathbf{B}, \mathbf{S}} \frac{1}{2} \|\mathbf{Y} - \mathbf{BS}\|_F^2 + \beta \sum_{i,j} \varphi(S_{i,j}) \quad (2)$$

$$\text{s. t. } \sum_{i=1}^p B_{i,j}^2 \leq c, \forall j = 1, 2, \dots, n$$

式中:第一项是重构误差;第二项稀疏性惩罚函数 $\varphi(\cdot)$ 可取为 l_1 正则形式的函数,即 $\varphi(S_{i,j}) = \|S_{i,j}\|_1$,便可使得系数 \mathbf{S} 具有稀疏性和鲁棒性^{[6]803}; β 是正常数,来控制稀疏性惩罚项的权重。显然式(2)没有解析解,这里可以采取交替迭代更新法获得最优解^{[6]803-806}。

2.2 线性 SPM

SPM 是一个空间金字塔匹配结构,它通常采用直方图的方法进行特征匹配。假设 \mathbf{S} 是式(2)获得的系数,那么一般图像的直方图表示为:

$$\mathbf{z} = \frac{1}{M} \sum_{m=1}^M \mathbf{S}_m \quad (3)$$

并且该图像的空间金字塔直方图表示 \mathbf{z} 需要计算不同尺度不同分块下的 \mathbf{S} 。假设一个图像二分类问题,一个 SVM 的决策函数为:

$$f(\mathbf{z}) = \sum_{i=1}^n \alpha_i \kappa(\mathbf{z} - \mathbf{z}_i) + b \quad (4)$$

式中: α_i 和 \mathbf{z}_i 是训练集, $\alpha_i \in \{-1, +1\}$ 表示类别标签。测试图像的直方图为 \mathbf{z} ,如果 $f(\mathbf{z}) > 0$,那么该测试图像就属于正样本,否则为负样本。理论上 $\kappa(\cdot, \cdot)$ 可以是任何满足 Mercer 条件的核函数,但实际上,交叉核(intersection kernel)

和卡方核(Chi-square kernel)更适合于直方图表示,然而如果采用这两个非线性核,SVM的训练和预测代价将非常高。文献[11]发现如果对SIFT特征先进行稀疏编码,再采用线性核函数将不会产生大量错误结果,而且能够降低训练和预测的代价。该线性核函数采用max pooling的方法先计算:

$$z_p = \max\{|s_{p1}|, |s_{p2}|, \dots, |s_{pM}|\} \quad (5)$$

式中: z_p 表示 z 的第 p 个元素, s_{pq} 是系数 S 第 p 行第 q 列的元素, M 表示系数向量个数。那么线性 SPM 表示为:

$$\kappa(z_i, z_j) = \sum_{h=0}^2 \sum_{s=1}^{2h} \sum_{t=1}^{2h} (z_i^h(s, t), z_j^h(s, t)) \quad (6)$$

式中, z_i 代表一个图像 I_i , $\langle z_i, z_j \rangle = z_i^T z_j$, $z_i^h(s, t)$ 表示图像 I_i 在 h 尺度下的第 (s, t) 个分块。最终二分类问题的 SVM 决策函数表示为:

$$f(z) = \left(\sum_{i=1}^n \alpha_i z_i \right)^T z + b = w^T + b \quad (7)$$

文献[11]分析认为:1)稀疏编码可以减少量化错误;2)由于自然界图像具有稀疏性,因此稀疏编码更适合于图像数据;3)采用max pooling的方法能使局部特征更加显著和鲁棒。这就是采用线性 SPM 能够获得较好的分类结果原因。本文实验发现对 CSF 正常和异常两类图像,结合线性 SPM,直接采用稀疏编码进行局部特征提取能获得更好的分类结果。

3 模型实现

本文模型采用稀疏编码算法进行特征提取,因此本章首先介绍求解2.1节中式(2)的方法:交替迭代更新法。然后根据本文模型实现过程的三个阶段:无监督特征学习、有监督分类器训练和识别过程,分别给出详细步骤。

3.1 交替迭代更新法

交替迭代更新法^{[6]803-806}求解2.1节中式(2),就能够获得一组过完备基与相对应的系数,分别表示整个训练样本的所有关键局部特征与对局部特征的描述。交替迭代更新法分为两步:通过固定基矩阵求解系数和通过固定系数求解基矩阵,具体可以采用特征符号搜索算法和拉格朗日对偶法^[6]分别求解。

1) 特征符号搜索算法:

首先固定基矩阵 B , 求解相对应的系数 S , 那么2.1节中式(2)便转换成求解 l_1 归一化最小二乘法问题,由此可得到下面方程:

$$\min_x f(x) = \|y - Bx\|_F^2 + \gamma \|x\|_1 \quad (8)$$

式中: γ 为常数。如果能够知道 x 的符号,那么式(8)将转换成标准的无约束二次优化问题,这里采用特征符号搜索算法来获得 x 的最优解。算法主要思想是:通过维护一个存储着非零系数的活动集(active set)及相应的符号 θ_i , 先猜测符号,然后进行求解,最后多次迭代这个过程以判断是否达到最优。经过证明^{[6]804-805},特征符号搜索算法能够在较少迭代的情况下获得最优解。

2) 拉格朗日对偶法:

固定系数矩阵 S , 那么式(2)转换成求解具有二次约束的最小二乘法问题:

$$\min_B \|X - BS\|_F^2$$

$$\text{s. t. } \sum_{i=1}^k B_{i,j}^2 \leq c, \forall j = 1, 2, \dots, n \quad (9)$$

式(9)可以利用拉格朗日对偶法来求解,其拉格朗日形式为:

$$L(B, \lambda) = \text{trace}((X - BS)^T(X - BS)) + \sum_{j=1}^n \lambda_j \left(\sum_{i=1}^k B_{i,j}^2 - c \right) \quad (10)$$

式中 $\lambda_j \geq 0$ 是对偶变量,式(10)最优化基矩阵 B 的推导公式为:

$$D(\lambda) = \min_B L(B, \lambda) = \text{trace}(X^T X - XS^T(SS^T + \text{diag}(\lambda))^{-1}(XS^T)^T - c \cdot \text{diag}(\lambda)) \quad (11)$$

利用共轭梯度法可以优化式(11),得到基 B 的更新形式:

$$B^T = (SS^T + \text{diag}(\lambda))^{-1}(XS^T)^T \quad (12)$$

比起传统的梯度下降法求解有约束的最小二乘问题,拉格朗日对偶法显著地减少了需要优化的变量,因此效率更高^{[6]806}。

3.2 无监督特征学习

本文采用稀疏编码算法进行无监督特征学习,并不对训练样本进行类别标记,对每一个类别取少量相同数量的训练样本,具体步骤如下:

1) 预处理。对训练样本进行预处理,包括:将RGB模式的图像转换为灰度图;将灰度图转换到double类型空间;改变图像尺寸。

2) 获取样本向量。对每个样本,随机抽取相同尺度的patch,形成原样本的向量形式 X_{total} , 它代表整个训练样本,其中每一列表示一个patch,同时记录每一列对应于原图所在位置 G 。

3) 训练基向量。首先初始化一个基向量 B_0 , 其中每一个元素都是 $[-1, 1]$ 的随机double类型值,然后通过交替迭代更新法进行多次迭代,最后获得整个训练样本的过完备基 B 。

4) 训练系数。首先对每一张训练样本进行步骤1)预处理,获得输入向量 X_{one} 和位置 G 。然后采取特征符号搜索算法,固定步骤2)训练得到的过完备基 B , 一次迭代便可获得单张训练样本的系数矩阵 S_{one} , 其中每一列表示一个patch所对应的系数向量。

3.3 有监督分类器训练

以线性 SPM 作为 SVM 的核函数进行分类器训练,因为需要将3.2节中训练得到的系数矩阵进行类别标记,所以这是一个有监督的训练过程。将标记后的系数矩阵输入到SVM中训练分类器。在最后识别过程中,通过这个分类器对测试样本(未标记)进行分类预测。本文有监督分类器训练的具体步骤如下:

1) 特征标记。对系数矩阵 S_{one} 进行类别标记,以区分样本类别。

2) 线性 SPM。对系数矩阵 S_{one} 和对应的位置 G 进行线性 SPM 计算获得 Z_{one} 。

3) 训练分类器。将 Z_{one} 输入到简单线性 SVM 中,训练得到分类器 Classifier。

3.4 识别过程

通过3.3节获得的分类器 Classifier,就可以对未知类别的测

试样本进行分类。本文测试样本识别过程的具体步骤如下:

1) 预处理。样本换成了测试样本,处理过程与3.2节中步骤1)相同。

2) 获取样本向量。样本换成了测试样本,处理过程与3.2节中步骤2)相同。

3) 训练系数。采用3.2节中步骤3)训练得到的过完备基 B ,与3.2节中步骤4)相同,获取每一张测试样本的系数矩阵 S_{one} 。

4) 线性SPM。对系数矩阵 S_{one} 和对应的位置 G 进行线性SPM计算获得 Z_{one} 。

5) 分类器预测:将 Z_{one} 输入到3.3节中步骤3)获得的Classifier中,进行预测,获得预测结果。

4 实验与讨论

本文对临床显微镜下的CSF图像进行了验证,分别比较了三种不同模型对两类CSF图像进行处理的实验结果:

1) SC-SVM模型。简单结合稀疏编码算法和线性SVM。

2) ScSPM模型。由文献[11]提出,同样结合了稀疏编码与SPM的思想,与本文模型最大的不同点在于它提取的是SIFT特征,然后对SIFT特征进行稀疏编码。

3) 本文模型。直接采用稀疏编码进行无监督学习来提取特征,然后经过线性SPM计算,最后用简单线性SVM进行分类器训练与预测。

实验环境:32位Windows7操作系统、主频2.40 GHz四核、内存2.00 GB、Matlab(R2009b)。

4.1 实验结果

对CSF图像随机选择了其中正常细胞图像和异常细胞图像各20张,共40张图片,图片像素大小为统一的 285×380 ,采用 17×17 像素大小的patch,交替迭代更新法迭代5次,获取了大小为195的过完备基,如图3所示。两类样本,如图4所示。




图4 正常与异常CSF图像

本文分别对SC-SVM模型和本文模型进行测试,同时利用ScSPM模型的作者代码,分别获取了这三种模型的测试结果。对CSF图像的398个测试样本,金字塔结构共为三层,分类器预测的平均结果如表1所示。

表1 两类样本预测平均结果

模型	单张识别耗时/s	分类准确率/%
SC-SVM	1.2	83.3 ± 1.2
ScSPM	2.8	89.5 ± 0.7
本文模型	1.3	89.4 ± 0.9

通过对样本进行手工分割,得到四类共702个单目标样本,如图5所示。

同样用三个模型对这四类单目标样本进行测试,结果如表2所示。

去掉单核细胞,对剩余的三类单目标样本进行测试,结果如表3所示。




图5 四类单目标样本

表2 四类样本预测平均结果

模型	单张识别耗时/s	分类准确率/%
SC-SVM	1.0	54.9 ± 1.1
ScSPM	1.3	77.1 ± 0.5
本文模型	1.1	58.1 ± 0.6

表3 三类样本预测平均结果

模型	单张识别耗时/s	分类准确率/%
SC-SVM	1.0	75.2 ± 0.8
ScSPM	1.3	81.3 ± 0.5
本文模型	1.1	77.0 ± 0.7

式(2)中参数 β 控制稀疏性惩罚项的权重,如果 β 越大,那么优化得到的系数越稀疏,优化所需时间越短,但是如果原图像边缘特征不强,也可能导致过完备基训练失败。此外,本文实验发现过完备基训练与系数获取的两个过程中, β 取值不相同可能比取值相同情况下的识别准确率更高。由于CSF图像边缘特征不强,同时为了保证识别速度,经过多次参数调整,本文三组实验在获取过完备基时,均使 $\beta = 0.05$;在获取系数时,均使 $\beta = 0.2$ 。

4.2 讨论

相同参数情况下,表1中的结果表明,对正常和异常两类CSF图像,本文模型在识别准确率方面表现大大优于SC-SVM模型,这充分说明了线性SPM的有效性;同时与ScSPM模型差不多,具有很高的水准。速度方面,本文模型也足够快速,由此可以看出,本文模型对CSF正常和异常两类图像的识别效果最好。

表2中的结果表明,基于稀疏编码特征提取的模型比基于SIFT特征提取的模型在识别准确率方面低了很多。考虑单核细胞和淋巴细胞的形态特征极为相近,舍弃单核细胞,表3中的结果证明了这一点;同时表明对特征差异较大的剩余的三类样本,基于稀疏编码特征提取模型的识别准确率仍然足够高。

5 结语

本文提出了一种快速识别CSF图像是否异常的模型,由于其拓扑结构复杂多变的特点,我们舍弃了传统基于图像分割的特征提取方法。同时由于两类图像稀疏性差异较大,因此直接采取稀疏编码算法进行无监督学习提取特征,然后结合线性SPM和线性SVM进行分类。实验结果表明,该模型识别速度较快,准确率较高,因此在实际临床诊断上具有一定的参考价值。

本文模型对形态特征差异不大的单个目标识别准确率并不高,因此如何改进编码过程,并且利用更多层次的结构进行特征学习,以获取更高区分度的特征是下阶段的主要研究目标。同时稀疏编码算法的相关参数对实验结果影响很大,然

(下转第2049页)

- based on improved LBP[J]. *Opto-Electronic Engineering*, 2012, 39(7): 109–114. (王宪, 张彦, 慕鑫, 等. 基于改进的 LBP 人脸识别算法[J]. *光电工程*, 2012, 39(7): 109–114.)
- [5] ZHAO H, FENG Y. Metric of global texture direction with histogram of local edge probability and Gabor filter[J]. *Optics and Precision Engineering*, 2010, 18(7): 1668–1674. (赵海英, 冯月萍. 应用 Gabor 滤波器和局部边缘概率直方图的全局纹理方向性度量[J]. *光学精密工程*, 2010, 18(7): 1668–1674.)
- [6] GAO J, SUN C, WANG S. (2D)²UFFCA: two-directional two-dimensional unsupervised feature[J]. *Acta Automatica Sinica*, 2012, 38(4): 549–562. (皋军, 孙长银, 王士同. 具有模糊聚类功能的双向二维无监督特征提取方法[J]. *自动化学报*, 2012, 38(4): 549–562.)
- [7] YANG L, YE H. Face Recognition using relative gradient patterns of oriented edge magnitudes[J]. *Highlights of Sciencepaper Online*, 2014, 7(4): 300–305. 2013. (杨利平, 叶洪伟. 人脸识别的相对梯度方向边缘幅值模式[J]. *中国科技论文在线精品论文*, 2014, 7(4): 300–305.)
- [8] COX D, PINTO N. Beyond simple features: A large-scale feature search approach to unconstrained face recognition[C]// *Proceedings of the 2011 IEEE International Conference on Automatic Face and Gesture Recognition and Workshops*. Piscataway: IEEE, 2011: 8–15.
- [9] YANG C, ZHU Y, CHEN G. New classifier ensemble method based on rough set attribute reduction[J]. *Application Research of Computers*, 2012, 29(5): 1648–1650. (杨传振, 朱玉全, 陈耿. 一种基于粗糙集属性约简的多分类器集成方法[J]. *计算机应用研究*, 2012, 29(5): 1648–1650.)
- [10] HUANG R, LANG F, SHI Z. Log-Gabor and 2D semi-supervised discriminant analysis based face image retrieval [J]. *Application Research of Computers*, 2012, 29(1): 393–396. (黄荣兵, 郎方年, 施展. 基于 Log-Gabor 小波和二维半监督判别分析的人脸图像检索[J]. *计算机应用研究*, 2012, 29(1): 393–396.)
- [11] GUILLAUMIN M, VERBEEK J, SCHMID C. Is that you? Metric learning approaches for face identification[C]// *Proceedings of the 2009 IEEE 12th International Conference on Computer Vision*. Piscataway: IEEE, 2009: 498–505.
- [12] GAO Q, XIE D, XU H, *et al.* Supervised feature extraction based on information fusion of local structure and diversity information [J]. *Acta Automatica Sinica*, 2010, 36(8): 1107–1114. (高全学, 谢德燕, 徐辉, 等. 融合局部结构和差异信息的监督特征提取算法[J]. *自动化学报*, 2010, 36(8): 1107–1114.)
- [13] YIN Q, TANG X, SUN J. An associate-predict model for face recognition[C]// *Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE, 2011: 497–504.
- [14] KAN M, SHAN S, XU D, *et al.* Side-information based linear discriminant analysis for face recognition[C]// *Proceedings of the British Machine Vision Conference*. Edinburgh: BMVA Press, 2011: 1–12.
- [15] WOLF L, HASSNER T, MAOZ I. Face recognition in unconstrained videos with matched background similarity[C]// *Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE, 2011: 529–534.

(上接第 2043 页)

而手工调整往往需要多次尝试才能达到理想结果,因此之后也将考虑如何自适应地调整参数,以提高实验效率。

参考文献:

- [1] HE J, KONG F, GUO L. Clinical cerebrospinal fluid cytology diagnosis[M]. Shijiazhuang: Hebei Science and Technology Press, 2007: 16–20. (何俊琪, 孔繁森, 郭力. 临床脑脊液细胞学诊断[M]. 石家庄: 河北科学技术出版社, 2007: 16–20.)
- [2] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. *International Journal of Computer Vision*, 2004, 60(2): 91–110.
- [3] BENGIO Y. Learning deep architectures for AI[M]. Hanover: Now Publishers Inc, 2009.
- [4] OLSHAUSEN B A, FIELD D J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images[J]. *Nature*, 1996, 381(6583): 607–609.
- [5] NG A Y. Feature selection, L1 vs. L2 regularization, and rotational invariance[C]// *Proceedings of the 21st International Conference on Machine Learning*. New York: ACM, 2004: 78.
- [6] LEE H, BATTLE A, RAINA R, *et al.* Efficient sparse coding algorithms[C]// *Advances in Neural Information Processing Systems*. Cambridge: MIT Press, 2006: 801–808.
- [7] LAZEBNIK S, SCHMID C, PONCE J. Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories [C]// *Proceedings of the 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Washington, DC: IEEE Computer Society, 2006, 2: 2169–2178.
- [8] KE Y, SUKTHANKAR R. PCA-SIFT: A more distinctive representation for local image descriptor[C]// *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Washington, DC: IEEE Computer Society, 2004: 506–513.
- [9] MIKOLAJCZYK K, SCHMID C. A performance evaluation of local descriptors[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(10): 1615–1630.
- [10] BAY H, ESS A, TUYTELAARS T, *et al.* Speeded-Up Robust Features (SURF)[J]. *Computer Vision and Image Understanding*, 2008, 110(3): 346–359.
- [11] YANG J C, YU K, GONG Y H, *et al.* Linear spatial pyramid matching using sparse coding for image classification[C]// *Proceedings of the 2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Washington, DC: IEEE Computer Society, 2009: 1794–1801.
- [12] WANG J J, YANG J C, YU K, *et al.* Locality-constrained linear coding for image classification[C]// *Proceedings of the 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Washington, DC: IEEE Computer Society, 2010: 3360–3367.
- [13] JIANG Z L, ZHE L, DAVIS L. Label consistent K-SVD: Learning a discriminative dictionary for recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(11): 2651–2664.
- [14] LI H. Statistical learning methods[M]. Beijing: Tsinghua University Press, 2012. (李航. 统计学习方法[M]. 北京: 清华大学出版社, 2012.)