科学通报 2013 年 第 58 卷 增刊Ⅱ: 145 ~ 151
论 文 www.scichina.com csb.scichina.com
《中国科学》杂志社
SCIENCE CHINA PRESS

基于稀疏表达的胃部疾病检测

范慧杰[①②], 丛杨[①*], 杨云生[③], 唐延东[①]

① 中国科学院沈阳自动化研究所, 机器人学国家重点实验室, 沈阳 110016;
② 中国科学院大学, 北京 100049;
③ 中国人民解放军总医院, 北京 100853
* 联系人, E-mail: congyang@sia.cn

2013-08-20 收稿, 2013-10-11 接受
国家自然科学基金(61105013, 61375014)和国家科技支撑计划(2012BAI14B03)资助

摘要 提出了一种基于稀疏表达的自动胃病检测算法, 通过训练少量样本就可以进行精确、稳定的病灶检测. 根据实际工作中样本数量(特别是疾病样本)采集有限这一特点, 建立了一个基于小样本的、具有稀疏和低秩特性的大尺度字典选择模型, 实现了用最少的原子来构建超完备字典. 在疾病检测阶段, 设计了一种新的加权稀疏集中度指标(WSCI, weighted sparsity concentration index)判别输入样本是否有效, 然后采用两级判别机制对有效的输入样本进行检测: 首先将输入样本划分为健康或者疾病类别; 然后将病灶看作健康图像中的异常现象, 对判别为健康类别的图像进行再次检测, 以防止漏报现象的出现. 我们将本文算法与现有的胃病检测算法进行比较, 对比结果表明本文算法在检测的精度和算法适用性方面都有较大提高.

关键词
胃病诊断
胶囊内窥镜
稀疏表达
字典选择
异常检测

胃病是损害人体健康的常见疾病之一. 俗话说, 十人九胃, 有人估计中国人胃病发生率达到 85%, 国人相聚, 如果讨论医疗问题, 一半以上的时间可能谈的是某人的胃病. 对于中国农村的医生, 病人中的三分之一是因为胃病方面的症状求诊. 在国外, 美国每年有 24000 人患胃癌, 大约有四百万美国人每年遭受胃溃疡的折磨.

传统的检测胃病的方法是胃镜法, 它利用一条很细的管子, 前端装有内视镜由嘴中伸入受检者的食道、胃、十二指肠, 藉由光源器所发的强光, 经由导光纤维可使光转弯, 让医生从另一端清楚地观察上消化道内各部位的健康状况. 传统胃镜检查带给人的痛苦很大, 近些年出现的无线胶囊内窥镜(WCE, wireless capsule endoscopy)方法只需吞服颗胶囊, 将图像通过无线的方式传回采集设备, 检查过程无痛、无创, 在很大程度上可以减轻病人痛苦. 通过人工途径进行胃病诊断的方法不仅效率低, 而且工作量大, 极易引起医生疲劳过度, 从而可能引起误判或者漏判. 于是在使用这些设备的基础上, 很多基于图像处理的算法迅速发展, 如关键帧提取[1]、出血区域检测[2]、小肠息肉和溃疡检测[3]、肠克隆病[4]、胃癌标记[5]、WCE 彩色视频分割[6]、聚类算法[7]、肠道蠕动评估[8]、基于 WCE 的消化壁三维重建算法[9]等. 这些算法大部分只适用于胶囊内窥镜图像, 由于胶囊在胃中停留的时间较短, 而胃部结构比较复杂, 内窥镜通常不能清楚地捕获完整的内部特征, 使其检测精度低于传统的胃镜方法, 胃镜仍然是不可或缺的检测手段[10].

本文我们旨在通过视觉的方法, 提出一种同时适用于胃镜和内窥镜的胃病检测算法, 实现胃病的自动、精确检测. 其中我们要面对两个关键问题: 图像表达和疾病诊断. 一般来说, 高维特征[11]的表达性更好, 但是通常的统计学习算法所需要的训练样本个数随特征维数呈指数增加, 当样本特征维数较

引用格式: 范慧杰, 丛杨, 杨云生, 等. 基于稀疏表达的胃部疾病检测. 科学通报, 2013, 58(增刊Ⅱ): 145–151
Fan H J, Cong Y, Yang Y S, et al. Sparse representation for gastropathy disease diagnosis (in Chinese). Chin Sci Bull (Chin Ver), 2013, 58(Suppl. II): 145–151, doi: 10.1360/972013-950

大时, 很难收集到足够的样本数. 于是, 我们提出一种基于稀疏表达[12,13]的胃部疾病检测算法, 稀疏表达使图像的能量集中于较少的原子, 来揭示图像的主要特征和内在结构. 为了提高稀疏表达的有效性, 我们设计了一个大尺度字典选择模型. 在疾病诊断方面, 我们首先将它看作一个监督分类问题, 判断测试图像是健康还是疾病, 同时为了防止漏报情况出现, 我们对认定的健康图像进行异常检测, 将疾病看成健康图像中的异常现象[14], 从而进一步提高算法的检测精度. 图 1 给出了本文算法的流程图.

本文算法的创新性主要体现在下述 3 个方面. (1) 设计了一种基于组稀疏(group sparsity)特性和低秩(low rank)特征的大尺度字典选择模型, 一方面去除噪声样本提取出有效样本, 另一方面使构建的字典(基空间)的原子(基)数最小. (2) 在稀疏表达的基础上, 提出一个分级判别机制进行疾病诊断. 首先将疾病诊断问题看作两分类问题, 将待检测图像分到健康或者疾病类别, 然后将病灶区域看成是健康图像中的异常现象, 对判别为健康的图像进行异常检测, 防止漏报情况出现. (3) 为了每次选取有效样本进行分类, 我们设计了一种新的加权稀疏集中度指标(WSCI, weighted sparsity concentration index)判别输入样本是否有效. 该指标充分考虑了字典构建时健康和疾病样本不均衡带来的偏差, 为字典中的基元素引入权值, 从而可以更加准确地选取有效的样本进行分类.

1 方法

我们的算法是基于图像块级别的, 即对于给出的每一幅图像 I, 我们分别从水平和垂直方向上把它分割为若干个子图像块, 然后提取每一块的特征, 分别判断每个块对应的部分是否健康. 在图像表达方面, 将子图像块的色彩和纹理信息相结合作为图像特征. 在判别子图像块检测结果方面, 我们首先将待检测的子图像块划分到健康或者疾病类别, 然后为了防止漏检测出现, 在判定为健康的图像块中进行一次异常检测判别(将病灶看成健康图像的异常行为), 从而设计出一个基于稀疏表达的胃病检测流程, 该过程包括字典选择、分类和异常检测三部分.

1.1 图像表达

无论是在医学图像分析, 还是在一般的计算机视觉领域, 图像特征的表达都是一个非常关键的步骤. 受文献[1~3,9~15]的启发, 我们主要采用色彩[16]和纹理[17]特征来描述图像. 对于彩色特征, 可以采用色彩空间来描述, 如 HSV, RGB 空间等, 也可以用直方图量化法来表达. 对于纹理特征, 我们采用一种改进的、具有多分辨率灰度级和旋转不变特性的选择局部二值模式(LBP, local binary pattern)[16]来表达, 这是由于 LBP 是多数人认可的最有效的描述纹理的方法. 因此, 我们将色彩与纹理特征相结合来描述每个子图像块, 把每个块表示为 $f \in \boldsymbol{R}^d$, 其中 $d=d_c+d_t$ (d_c 和 d_t 分别是彩色特征和纹理直方图表达的维数). 在第 2 节中, 我们分别采用不同特征表达图像特征, 并对比和分析几种表达方式下得到的实验结果.

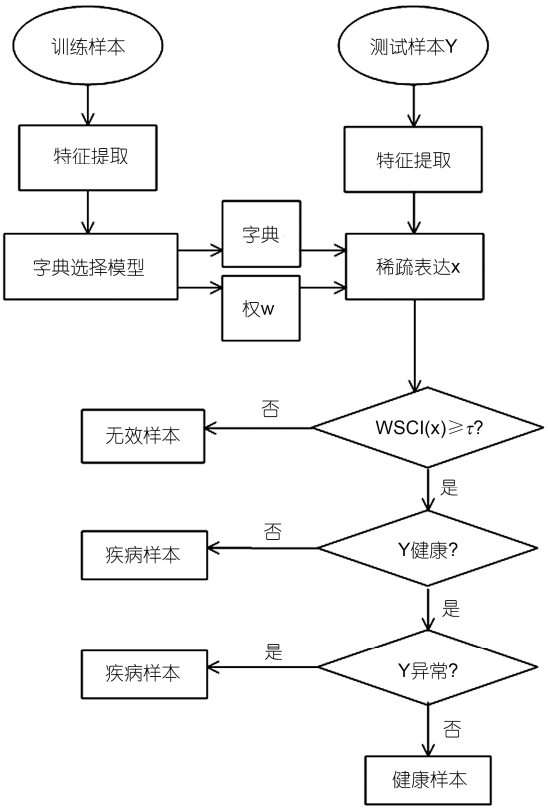


图 1 算法流程图

1.2 基于稀疏一致性的大尺度字典选择

在提取完图像特征之后, 我们需要利用这些特征, 通过训练方法构建超完备字典, 使字典中原子能匹配图像中的色彩、纹理等局部几何结构. 在训练阶段, 我们从内窥镜图像中收集 m 个图像块(这里每个块的大小是 30×30 像素), 分别提取每个图像块的 d 维特征, 构建出一个候选特征池: $\boldsymbol{B}=[b_1,b_2,...,b_m] \in \boldsymbol{R}^{d\times m}$, 其

中列分量 $b_i \in \boldsymbol{R}^{\mathrm{d}}$ 表示第 i 个图像块的特征. 通常情况下, 候选特征池 $\boldsymbol{B}$ 选择得非常大, 其中不仅包含了很多相似或冗余的分量 b_i, 而且还有很多噪声信息. 如果我们让全部的 $\boldsymbol{B}$ 的分量参与稀疏表达和分类, 会导致计算非常耗时, 算法也不稳定. 因此, 我们首先要解决字典选择问题, 也就是如何从 $\boldsymbol{B}$ 中选择出一个最优的子集 $\boldsymbol{B}'=[b_{i_1},b_{i_2},\cdots,b_{i_n}]\in \boldsymbol{R}^{d\times n}$, $i_n \in \{1,\cdots,m\}$, 使这个子集 $\boldsymbol{B}'$满足两个条件: (1) 通过 $\boldsymbol{B}'$可以很好地重建 $\boldsymbol{B}$, (2) $\boldsymbol{B}'$中的元素应该尽可能地少. 简单的解决方法是随机或一致地挑选候选分量来重构字典, 但是重要候选分量遗漏的风险较大. 文献[18]提出采用 $L_{2,1}$ 范数来建立字典选择模型:

$$\min_{D}\left\{\frac{1}{2}\|\boldsymbol{B}-\boldsymbol{B}\boldsymbol{D}\|_2^2+\lambda\|\boldsymbol{D}\|_{2,1}\right\}, \tag{1}$$

其中 $\|\boldsymbol{D}\|_{2,1}:=\sum_{i=1}^{m}\|\boldsymbol{D}_{i.}\|_2$, $\boldsymbol{D}_i$ 表示 $\boldsymbol{D}$ 的第 i 行. (1)式中的第二项为正则项, 作用是使重构出的矩阵尽可能稀疏, 并且最优解通常包含很多零行. 也就是说, 字典 $\boldsymbol{B}'$是通过选择 $\|\boldsymbol{D}_{i.}\|_2\neq 0$ 的分量重构出的.

(1)式中的模型理论上很好, 但是当样本数量巨大时会导致内存过大的问题, 因为 $\boldsymbol{D}$ 需要 m^2 个内存单元进行存储. 在处理大尺度样本问题时, m 的值迅速增加, 没有足够的内存使 $\boldsymbol{D}$ 一次性载入, 就会导致(1)式在应用时失效. 为了解决实际中遇到的大尺度样本问题, 我们对 $\boldsymbol{D}$ 进行矩阵分解为 $\boldsymbol{D}=UV^{\mathrm{T}}$, 其中 $U\in\boldsymbol{R}^{m\times r}$, $V\in\boldsymbol{R}^{m\times r}$ ($r<<m$). 于是, (1)式可以写为

$$\begin{cases}\min\limits_{U,V}\left\{\dfrac{1}{2}\left\|B-BUV^{\mathrm{T}}\right\|_2^2+\lambda\|U\|_{2,1}\right\},\\ \text{subject to: } \|V\|_{\infty,\infty}\leqslant 1.\end{cases} \tag{2}$$

由于 U 趋于 0 时, V 将变为无穷大, 所以我们在求此极小问题时, 对 V 附加约束: $\|V\|_{\infty,\infty}=\max\limits_{i,j}|V_{i,j}|\leqslant 1$. $\boldsymbol{D}$ 的最优解是一个低秩的稀疏矩阵, 它包含很多零行元素, 所以矩阵分解后其内存的占用远小于 m^2.

优化 (2)式是一个非凸优化问题, 它在任意的驻点都能是一个极小解. 我们采用坐标下降法, 交替迭代来优化求解 U 和 V. 即固定 U 优化 V, 然后固定 V 优化 U, 两个过程交替进行.

(ⅰ) 优化 U. 固定 V 的取值, 通过最小化下面子问题可以得到当前 V 下的最优 U:

$$U=\arg\min_{U}\left\{\frac{1}{2}\|\boldsymbol{B}-\boldsymbol{B}UV^{\mathrm{T}}\|_2^2+\lambda\|U\|_{2,1}\right\}. \tag{3}$$

这是一个非光滑的凸优化问题. 令 $p_0(U)=\frac{1}{2}\|\boldsymbol{B}-\boldsymbol{B}UV^{\mathrm{T}}\|_2^2$, 我们采用迭代逼近法求解 U:

$$\begin{aligned}U_{k+1}=\arg\min_{U}\Big\{&p_0(U_k)+\langle\nabla p_0(U_k),U-U_k\rangle\\&+\frac{L}{2}\|U-U_k\|_2^2+\lambda\|U\|_{2,1}\Big\},\end{aligned} \tag{4}$$

其中 L 是 Lipschitz 常数, $\nabla p_0(U_k)=B^{\mathrm{T}}B(U_kV^{\mathrm{T}}-I)V^{\mathrm{T}}$, 文献[19]给出了 U_{k+1} 的封闭解:

$$U_{k+1}=f_{\lambda/L}(U_i-\nabla p_0(U_i)/L), \tag{5}$$

其中函数 $f_\tau(\cdot):\boldsymbol{M}\in\mathbb{R}^{k\times k}\mapsto\boldsymbol{N}\in\mathbb{R}^{k\times k}$,

$$\boldsymbol{N}_{i.}=\begin{cases}0, & \text{if } \|\boldsymbol{M}_{i.}\|\leqslant\tau,\\ \left(1-\tau/\|\boldsymbol{M}_{i.}\|\right)\boldsymbol{M}_{i.}, & \text{else.}\end{cases}$$

(ⅱ) 优化 V. 固定 U 去求解 V 时, 子问题变为

$$\begin{cases}V=\arg\min\limits_{V}\left\{\dfrac{1}{2}\|\boldsymbol{B}-\boldsymbol{B}UV^{\mathrm{T}}\|_2^2\right\},\\ \text{subject to:}\|V\|_{\infty,\infty}\leqslant 1.\end{cases} \tag{6}$$

我们采用“按列坐标下降法”对 V 进行优化求解, 即分别计算 V 中的每一列的值, 优化 V 中的第 i 列 V_i 时, 固定其他列的值. 此时(6)式可写为

$$\begin{cases}V_{.i}=\arg\min\limits_{V_{.i}}\left\{\dfrac{1}{2}\|(\boldsymbol{B}-\sum\limits_{j\neq i}(\boldsymbol{B}U)_{.j}V_{.j}^{\mathrm{T}})-(\boldsymbol{B}U)_{.i}V_{.i}^{\mathrm{T}}\|_2^2\right\},\\ \text{subject to:}\|V_{.i}\|_{\infty}\leqslant 1.\end{cases} \tag{7}$$

令 $\boldsymbol{Z}=\dfrac{\left(\boldsymbol{B}-\sum\limits_{j\neq i}(\boldsymbol{B}U)_{.j}V_{.j}^{\mathrm{T}}\right)^{\mathrm{T}}(\boldsymbol{B}U)_{.i}}{\|(\boldsymbol{B}U)_{.i}\|_2^1}$, 则最优的 $V_{.i}^*$ 可以通过 $V_{.i}^*=\mathrm{sgn}(\boldsymbol{Z})\odot\min(\boldsymbol{Z},1)$ 计算得到, 其中操作符 $\odot$ 运算规则为 $(a\odot b)_i=a_ib_i$.

求得 U 和 V 后, 可以计算 $\boldsymbol{D}=UV^{\mathrm{T}}$, 通过选择 $\|\boldsymbol{D}_{i.}\|_2\neq 0$ 的分量重构出字典 $\boldsymbol{B}'$.

1.3 分类和异常检测

我们分别从健康和患病图像数据集中选取 $\boldsymbol{B}'_P\in\boldsymbol{R}^{d\times n_P}$ 和 $\boldsymbol{B}'_N\in\boldsymbol{R}^{d\times n_N}$ 进行了实验, 在生成超完备字典后, 我们设计一个分级流程进行图像疾病诊断. 首先从有监督分类的角度将待检测样本图片归为健康或者疾病类别, 然后为了防止漏检测现象的出现, 从异常检测的角度对判定为健康的图片进一步判别是否含有疾病.

(ⅰ) 分类. 对给定的待测图像 Y, 首先将其分

割为若干子图像块, 每个块 y 的大小均为 30×30 像素, 我们需要确定 y 是否健康. 我们首先通过(8)式所示的模型进行求解, 计算 y 的最优稀疏表达系数 $\hat{x}$:

$$\hat{x}=\arg\min\|x\|_1,\ s.t.\ \|Ax-y\|_2\leqslant\varepsilon, \tag{8}$$

其中 $A=[B_P',B_N',I]$, ε 是阈值. 在对样本 y 分类之前, 我们首先要基于不同的稀疏系数来确认该样本是否是有效样本, 即它是否是数据库中的某一类. 文献[18]提出采用稀疏集中度指标(SCI, sparsity concentration index)作为判断标准:

$$SCI(x)=\frac{k\cdot\max_i\|\delta_i(x)\|/\|x\|_1-1}{k-1}\in[0,1], \tag{9}$$

其中 k 是字典建立过程中样本类别总数, i=1, 2,…k, $\delta_i(x)$表示 x 中属于第 i 个位置的系数. 将样本 y 的稀疏系数 $\hat{x}$ 带入到(9)式中就得到它的 $SCI(\hat{x})$ 值. 但是在实际应用中, 由于疾病样本很难采集到, $\boldsymbol{B}_P$ 和 $\boldsymbol{B}_N$ 的字典大小很难保持平衡, 从而使 SCI 计算误差较大. 为了克服这个问题, 我们对 SCI 进行了改进, 为每个基元素引入权值, 定义新的判断准则——加权稀疏集中度指标(WSCI):

$$WSCI(x)=\frac{k\cdot\dfrac{\max_i\|\delta_i(Wx)\|}{\|Wx\|_1}-1}{k-1}\in[0,1], \tag{10}$$

其中 W 在字典选择时进行初始化. 显然, 对应的 WSCI 值越大的样本越有效. 这样给定阈值 $\tau\in[0,1]$, 我们认为只有当测试图像 y 的稀疏表达 $\hat{x}$ 满足 $WSCI(\hat{x})\geqslant\tau$ 时才将测试图像 y 视为有效, 否则测试图像 y 无效. 然后我们用最小残差法对测试样本 y 进行分类:

$$C(y)=\arg\min_i\|y-A\delta_i(\hat{x}_i)\|_2. \tag{11}$$

(ii) 异常检测. 由于训练数据不能涵盖实际中的所有情况, 而且在病灶检测中很难容忍漏报(假阴性)情况的出现, 因此, 即使一个有效的样本 y 被分为健康类别, 我们也不能对此确信无疑. 为了提高精准度, 对于任何一个被分为健康类别的样本 y, 我们从异常检测的角度, 将病灶区域看做健康图像中的异常现象, 采用稀疏度重构代价函数(SRC, sparsity reconstruction cost)[18]对 y 做进一步的确认:

$$S_w=\frac{1}{2}\|y-A_Px^*\|_2^2+\lambda_1\|W_Px^*\|_1, \tag{12}$$

其中 $x^*=\arg\min_x\left\{\frac{1}{2}\|y-\phi x\|_2^2+\lambda_1\|W_Px\|_1\right\}$, $A_P=[B_P',I]$, W_P 是权值生成的对角阵. SRC 值较大意味着重构需要较高的成本, 其对应的样本图像是病灶图像(异常现象)的概率较大; 反之 SRC 值越小的样本是病灶图像的可能性越小.

2 实验

2.1 数据库和评估准则

我们首先邀请 30 名健康志愿者和 30 名患有不同胃部疾病的志愿者, 对每位志愿者进行胃镜检测后采集 20~30 张图像建立数据库. 最终获得 1567 幅图片, 其中有 655 幅健康图像和 912 幅疾病图像. 我们邀请了两位在内窥镜手术方面有 5 年以上经验的权威专家使用注解工具对这些图像进行两级标注. 如图 2 所示, 白色区域为划分的病灶区域.

(i) 帧级. 将每幅图像分为健康图像或者病灶图像, 并为病灶图像划分患病类别. 这里主要考虑胃癌、溃疡和胃出血 3 种类别.

(ii) 像素级. 这里需要医生标记出具体的病灶位置和区域.

由于我们的算法处理的是图像块级别, 因此每幅图像沿水平和竖直方向上被均匀分为若干 30×30 像素的图像块. 我们让两位专家随机地选择有代表性的图像块组成训练集(其中包含 3000 个正常的图像块和 3000 个病灶图像块)用于字典学习.

在评估准则方面, 如果一幅健康图像检测出病灶, 就认为是误报, 否则认为准确检测. 对于病灶图像, 将检测结果与像素级的标记图像相比较, 如果检测到的病灶区域能够完全覆盖标注结果, 就认为准确检测, 否则视为假阳性结果.

2.2 实验结果

实验中, 我们选取不同的颜色特征[16]和纹理特征[17], 同时用多种学习算法进行对比. 选取特征时, 在 RGB 彩色空间, 我们分别使用 RG/RGB/标准 RGB/Opponent/Thebf 直方图; 在 HSV 彩色空间, 使用了 H/HV 两种直方图; 也有和纹理相结合的联合混合直方图. 从表 1 的结果可以看出, 采用 Oppo 直方图和 RG 直方图的效果要优于其他单个颜色直方图表达; 联合混合直方图同时包含颜色和纹理信息, 所以优于其他的直方图表达. 在学习算法的比较中, 我们提出的基于稀疏原理(WSCI+SRC)的算法在大部分情况下都优于其他学习算法(如基于线性核或 RBF 核的支

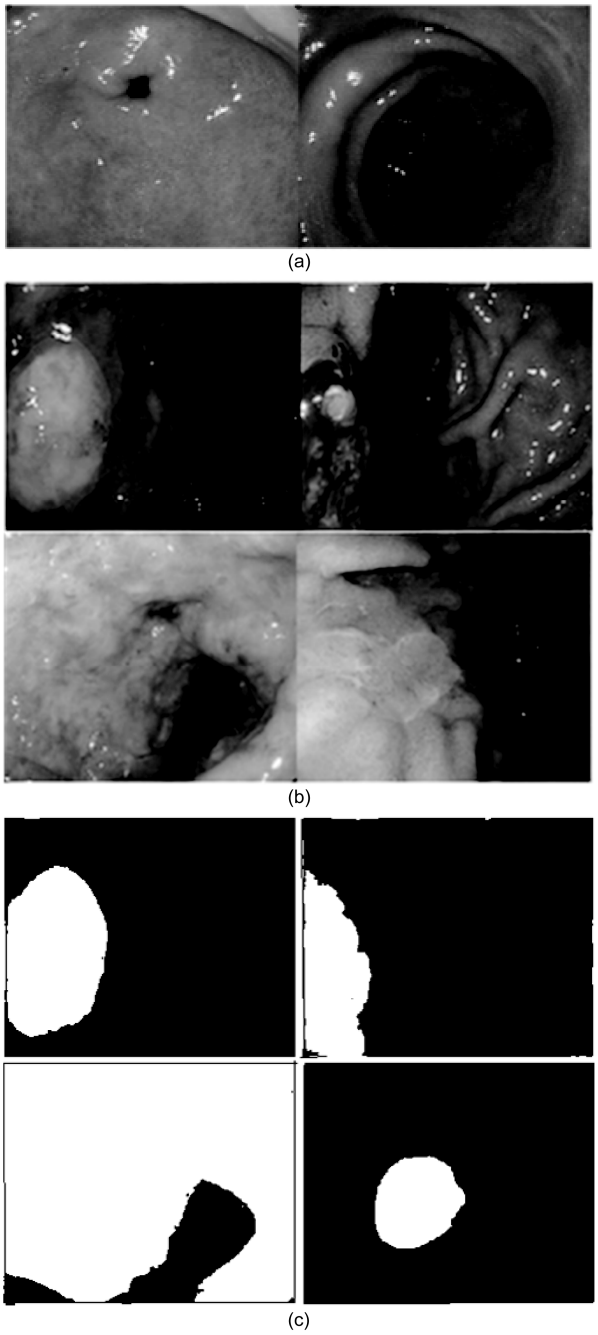


图 2　图像数据库实例

(a) 健康图像; (b) 疾病图像; (c) 对(b)中疾病图像标注后的结果

表 1　多种图像特征表达方法在不同的分类算法下的检测结果

	线性 SVM	RBF SVM	KNN 算法	我们算法
RG-Hist	81.1	82.5	76.1	84.3
RGB-Hist	75.1	86.4	73.2	85.2
标准 RGB-Hist	71.9	81	69.1	80.4
OPPO-Hist	84.3	85.3	80.6	85.9
Thebf-Hist	63.3	72.1	62.1	75.2
HSV H-Hist	74.7	74.9	70.1	77.7
HSV HV-Hist	78.6	79.5	71.2	82.4
LBP I-Hist	80.1	80.0	76.5	83.3
OPPO+LBP-Hist	84.6	86.4	79.8	90.6

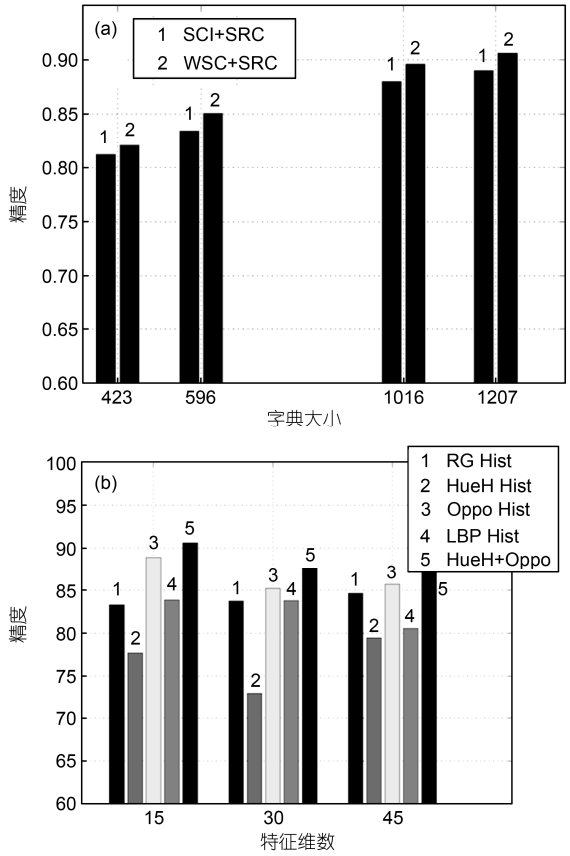


图 3　本文提出的 WSCI+SRC 算法与传统的 SCI+SRC 算法的对比

(a) 检测精度随字典大小的变化; (b) 检测精度随特征维数的变化

持向量机法、K 近邻法等).

图 3(a)给了字典尺寸大小对检测精度的影响, 同时将我们的算法(WSCI+SRC)与传统的 SCI+SRC 算法进行对比. 可以看到, 随着字典尺寸的增加准确性随之提高. 这是由于字典尺寸越大, 分类时得到的信息越多. 事实上, 当字典大小为 423 时, 我们就能得到满意的结果, SVM 要得到这样的准确度需要 2000 多个支持向量. 从而说明, 我们的方法可以用较少的样本得到精确的结果. 图 3(a)的结果还说明, 采用加权稀疏集中度指标(WSCI)的结果要优于使用 SCI 准

则的结果, 这是由于 WSCI 准则考虑了健康和疾病样本所占的权重, 使采用的有效样本更加真实可靠, 从而得到的字典矩阵更准确. 图 3(b)给出了选取不同特征的维数不同时的检测结果对比, 可见特征的维数大小和检测精度之间并没有必然的联系, 只有选取合适的特征维数, 才能得到精确地检测结果.

图 4 给出了我们的方法的部分检测结果, 其中的黑色标记区域为检测到的病灶区域, 可见我们的算法能够准确地检测出胃癌、胃出血、胃溃疡等病灶区域, 对不同的疾病显示出的不同病灶特征都能很精确的检测并标记出来. 基于稀疏表达的分类机制可以有效地将病灶图像识别出来, 对于分类为健康的图像我们进行了更进一步的判别, 因为这些图像中很可能存在病灶区域较小或者病变不是太明显的疾病图像. 这种分级判别机制有效地提高了疾病的识别率, 增加了识别精度.

3 结论

本文提出了一种基于稀疏原理的胃部疾病(如胃癌、溃疡和胃出血等)自动检测算法. 该方法分为特征表达和疾病检测两方面. 在图像特征表达方面, 结合了图像的颜色和纹理特征. 在疾病检测方面, 采用两级判别机制. 首先, 把疾病检测问题看成一个两分类问题(健康与疾病两种类别), 然后对判别为健康的图像进行异常检测(根据健康图像检测病灶区域). 我们的算法在稀疏表达的基础上设计了一个大尺度字典选择模型和加权稀疏浓度指数(WSCI), 建立了一个通用的胃病病灶自动检测系统. 实验结果证明, 我们的方法与传统分类方法(如 SVM)相比, 用较少的训练数据就可以得到较高的精度, 并且具有广泛的适用性.

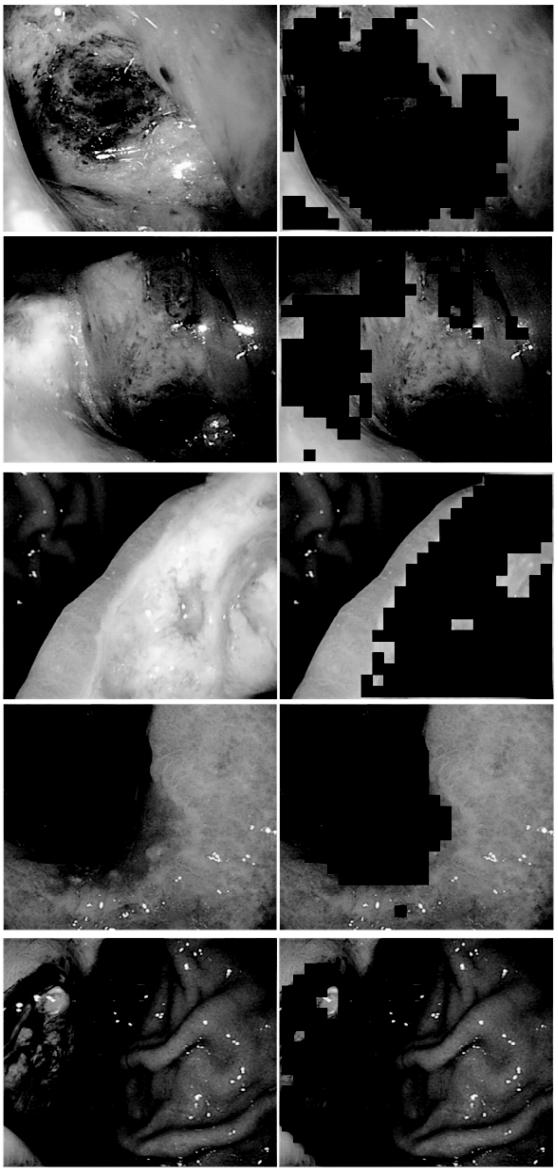


图 4 本文算法的部分检测结果

(a) 原始图像; (b) 相应的检测结果

参考文献

1 Bashar M K, Mori K, Suenaga Y, et al. Detecting informative frames from wireless capsule endoscopic video using color and texture features. In: Medical Image Computing and Computer-Assisted Intervention—MICCAI 2008. Berlin, Heidelberg: Springer, 2008. 603–610

2 Li B, Meng M H. Computer-aided detection of bleeding regions for capsule endoscopy images. IEEE Trans Biomed Eng, 2009, 56: 1032–1039

3 Karargyris A, Bourbakis N. Detection of small bowel polyps and ulcers in wireless capsule endoscopy videos. IEEE Trans Biomed Eng, 2011, 58: 2777–2786

4 Seshamani S, Kumar R, Dassopoulos T, et al. Augmenting capsule endoscopy diagnosis: A similarity learning approach. In: Medical Image Computing and Computer-Assisted Intervention—MICCAI 2010. Berlin, Heidelberg: Springer, 2010. 454–462

5 Li J Z, Zhang Z J, Zhou K W, et al. Investigation on labelling stomach cancer and K562 cell with fluorescence markers. Chin Sci Bull, 1995, 40: 150–153
6 Mackiewicz M, Berens J, Fisher M. Wireless capsule endoscopy color video segmentation. IEEE Trans Med Imaging, 2008, 27: 1769–1781
7 Atasoy S, Mateus D, Lallemand J, et al. Endoscopic video manifolds. In: Medical Image Computing and Computer-Assisted Intervention—MICCAI 2010. Berlin, Heidelberg: Springer, 2010. 437–445
8 Vilarino F, Spyridonos P, DeIorio F, et al. Intestinal motility assessment with video capsule endoscopy: Automatic annotation of phasic intestinal contractions. IEEE Trans Med Imaging, 2010, 29: 246–259
9 Karargyris A, Bourbakis N. Three-dimensional reconstruction of the digestive wall in capsule endoscopy videos using elastic video interpolation. IEEE Trans Med Imaging, 2011, 30: 957–971
10 Liang P, Cong Y, Guan M. A computer-aided lesion diagnose method based on gastroscope image. In: IEEE Conference on Information and Automation (ICIA), 2012. 871–875
11 Zhao S, Yao L, Jin Z, et al. Sparse representation of global features of visual images in human primary visual cortex: Evidence from fMRI. Chin Sci Bull, 2008, 53: 2165–2174
12 Zhang C M, Yin Z K, Chen M X, et al. Signal overcomplete representation and sparse decomposition based on redundant dictionaries. Chin Sci Bull, 2005, 50: 2672–2677
13 张春梅, 尹忠科, 肖明霞. 基于冗余字典的信号超完备表示与稀疏分解. 科学通报, 2005, 51: 628–633
14 Cong Y, Yuan J, Liu J. Abnormal event detection in crowded scenes using sparse representation. Pattern Recog, 2012, 46: 1851–1864
15 Chu X, Poh C K, Li L, et al. Epitomized summarization of wireless capsule endoscopic videos for efficient visualization. In: Medical Image Computing and Computer-Assisted Intervention—MICCAI 2010. Berlin, Heidelberg: Springer, 2010. 522–529
16 Van De Sande K E A, Gevers T, Snoek C G M. Evaluating color descriptors for object and scene recognition. IEEE Trans Pattern Anal Machine Intell, 2010, 32: 1582–1596
17 Ojala T, Pietikainen M, Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. IEEE Trans Pattern Anal Machine Intell, 2002, 24: 971–987
18 Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation. IEEE Trans Pattern Anal Machine Intell, 2009, 31: 210–227
19 Cong Y, Yuan J, Liu J. Sparse reconstruction cost for abnormal event detection. In: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2011. 3449–3456

Sparse representation for gastropathy disease diagnosis

FAN HuiJie[1,2], CONG Yang[1], YANG YunSheng[3] & TANG YanDong[1]

[1] *State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Science, Shenyang 110016, China;*
[2] *University of Chinese Academy of Sciences, Beijing 100049, China;*
[3] *Chinese PLA General Hospital, Beijing 100853, China*

Automatic diagnosis of gastropathy disease plays an important role in supporting the clinician and speeding up the examination process. In this paper, we propose a general algorithm for stomach disease detection using sparse representation, which can get robust result even using a small size of high-dimensional training dataset. First, a noval large scale dictionary selection model based on the low rank property is designed to initialize the meaningful dictionary with minimal size. Then in comparison with the state-of-the-arts, we consider disease diagnosing as both supervised classification issue and one-class classification issue, where a new criterion, weighted sparsity concentration index (WSCI) is designed for outlier detection. Experiments on our dataset and comparisons with state-of-the-arts demonstrate the effectiveness and effciency of our algorithm.

gastropathy disease diagnosis, capsule endoscope, sparse representation, dictionary selection, outlier detection

doi: 10.1360/972013-950