

增强的基于灰度共生矩阵的脑肿瘤MRI图像分类

刘大鹏¹, 程 君², 黄 唯², 曹双亮², 杨 茹², 负照强², 冯前进²

1. 解放军第303医院, 广西 南宁 530021; 2. 南方医科大学生物医学工程学院, 广东 广州 510515

【摘要】针对T1加权对比度增强MRI(CE-MRI)脑肿瘤图像的自动分类问题,提出了一种增强的基于灰度共生矩阵(GLCM)的特征表达方法。GLCM是一种常用进行纹理分析的方法,但由于脑部肿瘤图像纹理复杂多变,传统的基于GLCM的二阶统计量特征,如对比度、相关性、能量等,不能很好地区分不同类别的肿瘤,例如使用各向同性的GLCM和4个方向的GLCM(0°、45°、90°、135°)得到的分类正确率只有61.26%和75.16%。本文提出了两个改进措施,极大地提高了分类正确率:(1)直接使用GLCM的元素作为特征表达;(2)对肿瘤区域和肿瘤边界区域分别构造GLCM。在包含3064张图像的数据集上验证了方法的有效性:使用措施(1),分类正确率提高到了82.38%;结合措施(1)和(2),分类正确率提高到了90.7%。结果表明使用改进的基于GLCM的特征表达对于脑部肿瘤图像的分类问题是有效的。

【关键词】T1加权对比度增强MRI;脑肿瘤分类;灰度共生矩阵

【中图分类号】R739.9;TP391

【文献标识码】A

【文章编号】1005-202X(2015)06-0772-05

Improved brain tumor MRI image classification based on gray level co-occurrence matrix

LIU Da-peng¹, CHENG Jun², HUANG Wei², CAO Shuang-liang², YANG Ru², YUN Zhao-qiang², FENG Qian-jin²

1. 303 Hospital of People's Liberation Army, Nanning 530021, China; 2. School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China

Abstract: An improved gray level co-occurrence matrix (GLCM)-based feature representation method is proposed for the automatic classification of brain tumors in T1-weighted contrast-enhanced MRI (CE-MRI) images. GLCM is a popular method for texture analysis. But the texture of brain tumor images is complex and variable, so the traditional second-order statistical texture features based on GLCM, such as contrast, correlation, energy and so on, cannot discriminate different types of brain tumors. The classification accuracy of isotropic GLCM and GLCMs of four directions, 0°, 45°, 90°, 135° were respectively 61.26% and 75.16%. Two improvements, directly taking the element of GLCM as feature representation and constructing GLCMs for tumor region and tumor boundary region respectively, were proposed in this paper to significantly improve the accuracy. A large dataset containing 3064 images was used to validate the efficacy of proposed method. Results showed that the accuracy was improved up to 82.38% by directly taking the element of GLCM as feature representation. Combining the two improvements, the accuracy was improved up to 90.7%. Experimental results suggested that proposed method was feasible and effective in classification of brain tumors.

Key words: T1-weighted contrast-enhanced MRI; brain tumor classification; gray level co-occurrence matrix

前言

目前在医学领域,每天都有大量的数字影像产生,影像科医生凭借自身经验对图像中可能的病变做出分析、诊断。有研究表明让两个影像科医生同

时阅读一组影像资料,能显著地提高癌症的检出率,但这将会极大地增加医生的工作负担^[1]。计算机辅助诊断(CAD)可以充当第二个“阅片医生”,从而在降低医生工作量的情况下,提高疾病的诊断精度,并且能够避免由于医生长时间工作产生疲劳而可能导致的诊断不具有重复性的问题。

我们针对临床上发病率较高的3类脑肿瘤图像(胶质瘤45%、脑膜瘤15%、垂体瘤15%),提出了一种增强的基于灰度共生矩阵(GLCM)的纹理特征表达方法,极大地提高了3类肿瘤的可区分性。纹理分析

【收稿日期】2015-07-29

【基金项目】国家863高技术研究发展计划(2012AA02A616);国家科技支撑计划(2012BA114B02)

【作者简介】刘大鹏(1973-),男,硕士,高级工程师,主要研究方向:计算机图像处理与数据挖掘。E-mail: ldp191@qq.com。

【通信作者】负照强(1982-),男,硕士,主要研究方向:科学计算与可视化。E-mail: 283221079@qq.com。

在图像处理和模式识别领域占有重要的地位。作为一种非正式的定义,图像的纹理可认为是灰度在图像空间的分布模式,这种模式同时具有一定随机性和规律性^[2]。如何定量有效地描述图像的纹理,使其在规律性和随机性之间达到一个平衡是研究的难点。描述灰度和纹理特征常用的方法有一阶统计量^[3]、GLCM^[4-7]、Gabor滤波器^[8]、小波变换^[9]等。

Haralick等^[10]提出了利用GLCM来描述图像的纹理,该方法首先需要定义像素间的相邻关系,然后统计图像空间中相邻像素灰度值的分布,得到GLCM,然后计算定义在GLCM上的若干个统计量作为纹理特征的描述。GLCM由于计算相对高效,能较好地反映灰度的空间分布情况,所以应用非常广泛。Mayerhoefer等^[4]在一次体模研究中发现基于GLCM特征的分类对于MRI采集参数非常好。Alic等^[5]使用GLCM特征来预测18种肢体癌的治疗结果,预测的准确度达到83%。Agner等^[6]和Karahaliou等^[7]利用GLCM特征对乳腺疾病的良恶性进行分类,分类的精度达到约90%。Torheim等^[12]使用GLCM特征对宫颈癌的治疗结果进行预测,预测的精度为75%。

从上述的实验结果可以看出,对于不同的疾病使用GLCM产生的效果差异很大。当不同类别的图像中有大量区别明显的纹理模式时,使用GLCM的统计量来描述纹理特征是有效的。而对于本文数据中的3类脑肿瘤图像而言,其纹理中的随机成分较大,很可能出现的一种情况是不同类别的两张图纹理差异较大,但计算出来的统计量特征却非常接近。因此本文舍弃计算统计量的做法,提出直接用GLCM中的元素作为特征。虽然这样会使得特征向量的维数大大增加,但是通常一幅图像中只有某些灰度模式大量出现,GLCM中存在大量的零元。因而使用主成分分析(Principal Components Analysis, PCA)可以有效的降低维数,从而减轻计算复杂度。

除了上述方法能提高特征的鉴别能力之外,在提取特征时,我们还可以考虑相关的领域知识。在肿瘤的诊断过程中,肿瘤边界区域通常能提供重要的诊断信息。例如脑膜瘤通常与脑壳、灰质、脑脊液毗邻;胶质瘤通常与白质有关联;垂体瘤与蝶窦、内颈动脉和视交叉相邻^[11]。肿瘤边界周围区域的灰度分布与肿瘤的类型密切相关。Yang等^[11]在基于内容的脑肿瘤图像检索中提出利用肿瘤的边缘信息能有效提高检索性能。他们的做法是沿肿瘤边界的法线方向对肿瘤边界区域的灰度进行采样,得到大量的局部描述子,然后利用词袋模型(BoW)获得一个紧凑的特征表达。受到此启发,我们在肿瘤边界区域

单独构造一个GLCM,然后结合整个肿瘤区域的GLCM来形成对一幅图像的特征表达。同时考虑肿瘤区域和肿瘤边界区域的纹理特征,使得特征表达更具有鉴别能力。

1 材料与方法

1.1 材料

使用的数据集是T1加权的CE-MRI脑部图像,包含3类肿瘤图像:胶质瘤、脑膜瘤、垂体瘤。数据集包含来自233个患者的共3064张切片。由于在临床的实际应用中,通常是采集脑部一定数量的切片,并且切片之间有一定的间隔。因此只是对2D的图像提取特征,然后分类。我们选择肿瘤区域较大的切片来构成数据集,每张图像的大小为512×512,像素大小为0.49 mm×0.49 mm,图像中的肿瘤区域由医生手动勾画完成。

1.2 方法

1.2.1 方法概述 方法主要包括两个步骤:(1)基于GLCM的特征提取;(2)使用支持向量机(Support Vector Machine, SVM)进行分类。在(1)阶段,分别针对肿瘤边界区域和肿瘤区域构造GLCM,取两个GLCM的下三角元素拼接起来(或者上三角元素,因为GLCM是对称的),使用PCA降维后得到最终的特征向量。在(2)阶段,我们使用线性SVM,和一对一的多类分类法则,并使用交叉验证来选择SVM的参数。整个算法流程,如图1所示。

1.2.2 灰度共生矩阵 对于一幅大小为 $n \times m$,灰度级为 N (灰度范围为 $[1, N]$)的灰度图像 I ,其非归一化的GLCM中的元素定义为:

$$G_{\Delta x, \Delta y}(i, j) = \sum_{p=1}^n \sum_{q=1}^m \begin{cases} 1, & \text{if } I(p, q) = i \text{ and } I(p + \Delta x, q + \Delta y) = j \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

G 是一个大小为 $N \times N$ 的矩阵, $G_{\Delta x, \Delta y}(i, j)$ 表示像素值分别为 i 和 j 的两个相邻的像素在图像中出现的次数,相邻的关系由 Δx 和 Δy 给出。公式(1)定义的GLCM通常不是对称的。实际应用中,通常使用由步长 d 和角度 θ 定义的对称的GLCM。例如下面定义的步长为 d ,角度 θ 分别为 0° 、 45° 、 90° 、 135° 的GLCM:

$$\begin{aligned} G(d, 0^\circ) &= G_{\Delta x = \pm d, \Delta y = 0}(i, j) \\ G(d, 45^\circ) &= G_{\Delta x = d, \Delta y = -d \text{ or } \Delta x = -d, \Delta y = d}(i, j) \\ G(d, 90^\circ) &= G_{\Delta x = 0, \Delta y = \pm d}(i, j) \\ G(d, 135^\circ) &= G_{\Delta x = -d, \Delta y = d \text{ or } \Delta x = d, \Delta y = -d}(i, j) \end{aligned} \quad (2)$$

容易看出上面定义的4个GLCM具有 180° 旋转不变性,即将图像旋转 180° ,所得GLCM不变。

1.2.3 传统基于GLCM统计量的特征表达 传统的方




图1 脑肿瘤分类流程图

Fig.1 Flowchart of brain tumor classification

法是针对整幅图像或者感兴趣区(ROI)构造一个 GLCM, 然后计算二阶统计量作为特征表达。在计算统计量之前, 需要将 GLCM 归一化, 即将矩阵除以矩阵中所有元素的和, 使得归一化后的矩阵元素和为 1。GLCM 的提出者 Haralick 等^[10]建议了 14 个特征, 但这 14 个特征并不是相互独立的, 因此实际应用中常常只计算其中几个特征, 本文的对比试验中使用了下面 4 个特征: 对比度(Contrast)、相关性(Correlation)、能量(Energy)和同质性(Homogeneity)。

$$\begin{aligned}
 \text{Contrast} &= \sum_{i=1}^N \sum_{j=1}^N (i-j)^2 g_{ij} \\
 \text{Correlation} &= \sum_{i=1}^N \sum_{j=1}^N \frac{(i-m_r)(j-m_c)g_{ij}}{\sigma_r \sigma_c} \\
 \text{Energy} &= \sum_{i=1}^N \sum_{j=1}^N g_{ij}^2 \\
 \text{Homogeneity} &= \sum_{i=1}^N \sum_{j=1}^N \frac{g_{ij}}{1+(i-j)}
 \end{aligned} \quad (3)$$

其中 g_{ij} 表示表示归一化后的 GLCM 中第 i 行第 j 列的元素。我们令

$$g(i) = \sum_{j=1}^N g_{ij}, g(j) = \sum_{i=1}^N g_{ij}$$

则(3)式中的 m_r 、 m_c 、 σ_r 、 σ_c 分别为

$$m_r = \sum_{i=1}^N i g(i)$$

$$m_c = \sum_{j=1}^N j g(j)$$

$$\sigma_r^2 = \sum_{i=1}^N (i-m_r)^2 g(i)$$

$$\sigma_c^2 = \sum_{j=1}^N (j-m_c)^2 g(j)$$

Contrast 衡量的是在整个图像范围内, 某个像素和它相邻像素的对比度, 其取值范围为 $[0, (N-1)2]$, 当图像是常量图时, 对比度为 0。Correlation 度量的是

图像中某个像素与其相邻像素的相关性, 取值为 $[-1, 1]$, 端点值分别对应完全正相关和完全负相关。Energy 又叫做均匀性, 取值为 $[0, 1]$, 对于常量图像, 均匀性为 1。Homogeneity 度量了 GLCM 中元素的分布相对于对角线的靠近程度, 取值为 $[0, 1]$, 当 GLCM 是对角阵时取最大值。

1.2.4 基于 GLCM 的特征表达 通过对肿瘤区域和肿瘤边界区域分别构造 GLCM, 然后直接使用 GLCM 的元素作为特征表达, 使得肿瘤分类精度大大提高。

先对图像的灰度级进行量化, 压缩图像的灰度级。然后对肿瘤区域分别进行膨胀和腐蚀 6 个像素, 膨胀的结果减去腐蚀的结果就得到了肿瘤的边界区域。分别提取肿瘤区域和肿瘤边界区域的 4 个方向的 GLCM, 然后进行平均, 得到两个各向同性的 GLCM。由于 GLCM 是对称的, 故只需要取两个各向同性的 GLCM 的下三角元素(或上三角元素), 然后拼接起来作为特征向量, 再用 PCA 进行降维。由于 GLCM 通常存在较多的零元, 故使用 PCA 能进行有效的降维。例如图像的灰度级为 20, 步长取 4 时, 分类的精度最高, 达到了 90.7%。在 PCA 降维之前, 特征的维度为 420 维, 使用 PCA 降维并且保留 98% 的方差后, 维数为 36 维, 并且仅使用线性的 SVM 就能获得令人满意的精度。

1.2.5 分类 我们使用线性 SVM 和一对一的多类分类法则进行分类。我们先用 min-max 将特征向量的每一维规范化到 0 和 1 之间, 然后对于训练集中, 每两类样本训练得到一个分类器, 本文有 3 类肿瘤, 因此两两组合得到 3 个分类器。对于一个新的测试样本, 每个分类器都有一个分类结果, 然后按照多数投票法则确定最后的分类结果。虽然在大量的文献中, 基于核函数的 SVM 应用广泛, 但我们在实验中发

现,使用本文提出的基于GLCM的特征表达,线性SVM和径向基核函数(RBF)SVM的结果十分接近,这表明本文提出的特征表达使不同类别之间有很强的线性区分性。

2 结果

2.1 参数选择及结果评价

方法涉及到3个参数,即在构造GLCM时需要指定两个参数:量化的灰度级 N 和步长 d ,以及线性SVM中的惩罚因子 C 。给定 N 和 d 后,我们提取4个方向的GLCM。Clausi等^[12]指出不同灰度级的GLCM会对最后的分类结果产生较大的影响。灰度级较多时,GLCM能够描述图像中细致的纹理,但同时也更容易受噪声的影响,而且会显著增大计算量和存储空间。小的步长能够捕获细微的结构;大的步长能够描述粗纹理。为了得到最优的参数组合,我们取 $N=\{10, 20, 40, 80\}$ 、 $d=\{1, 2, 3, 4\}$ 。对于参数 C ,我们使用传统的网格搜索,并在训练集上5折交叉验证选择最优的 C 值,注意 C 的选取并没有涉及到测试集。我们以5折交叉验证的平均分类正确率作为不同方法评价指标,即将整个数据集分成5等份(我们对233个患者近似划分为5等分,从而避免来自同一个患者的图像同时出现在训练集和测试集中),依次取其中1份作为测试集,其余4份作为训练集,然后将5次在测试集上得到的分类正确率取平均值作为最后的结果,并报道每种方法在最优参数组合下的平均分类正确率。

2.2 与基于GLCM统计量特征的比较

Torheim等^[2]在对宫颈癌的分类中使用了1.2.3提到的4个二阶统计量来表达一幅图像。他在文中进行两种比较:一是对4个方向的GLCM分别计算4个统计量,得到16维的特征向量;二是对4个方向的GLCM取平均值,然后再计算统计量,得到4维的特征向量。本文仿照Torheim的实验设计,并结合本文提出的方法,进行了以下4种方法的比较:(1)one Region4:计算肿瘤区域4个方向的GLCM,取平均后再计算4个统计量,得到4维的特征向量;(2)one Region16:计算肿瘤区域4个方向的GLCM,分别计算4个统计量,得到16维的特征向量;(3)one Region Ele:计算肿瘤区域4个方向的GLCM,取平均后,使用矩阵的下三角元素作为特征向量,然后用PCA降维;(4)two Region Ele:分别计算肿瘤区域和肿瘤边界区域4个方向的GLCM,分别取平均后,将得到的两个矩阵的下三角元素拼接起来作为特征向量,然后PCA降维。

4种方法(one Region 4、one Region 16、one Re-

gion Ele、two Region Ele)各自最优的分类正确率分别为61.26%、75.16%、82.38%和90.7%。方法one Region 16比方法one Region 4有显著的提高,说明不同方向的灰度共生关系为区分不同类型的肿瘤提供了重要的线索。方法one Region Ele由于直接使用矩阵元素作为特征,避免了计算统计量时带来的信息损失,因而分类精度比方法one Region 16有较大的提升。对肿瘤区域和肿瘤边界区域的纹理分别考虑则能进一步提升分类精度。

2.3 与BoW模型的比较

近年来,许多研究表明基于图像块的BoW模型在图像分类和基于内容的图像检索领域是一种十分有效的方法^[13-14]。BoW模型可简要地分为4个步骤:首先在数据集中提取大量的局部特征描述子;其次对这些局部特征进行聚类,得到视觉词典;然后使用视觉词典来对一幅图像中的局部特征描述子进行量化;最后统计各个视觉单词出现的频率,得到视觉单词直方图作为该图像的特征表达。Huang等^[13]提出了一种类似空间金字塔对脑肿瘤图像进行区域划分,然后在不同的区域分别应用BoW模型,最后将不同区域得到的特征向量拼接起来的方法。在Huang的基于内容的脑肿瘤图像检索中,就评价指标mAP而言,使用GLCM统计量特征的结果比她提出的方法低40%左右。

我们采取和Huang实验中相同的做法,直接使用图像块作为局部特征描述子,然后使用Kmeans进行聚类。我们将提出的方法与两种基于BoW模型的特征表达进行比较:(1)one Region BoW:仅对肿瘤区域应用BoW模型;(2)two Region BoW:对肿瘤区域和肿瘤边界区域分别应用BoW模型(这里是对两个区域分别生成视觉词典,而不是生成一个视觉词典应用于两个区域)。

在BoW模型中,图像块的大小和聚类中心的数目是两个关键的参数,图像块大小分别取 $\{7, 9, 11, 13\}$,肿瘤边界区域的聚类中心数目固定为100,肿瘤区域聚类中心数目分别取 $\{100, 200, 400, 800\}$ 。我们报道的结果是在最优的参数组合下的结果。另外我们还分别使用了线性的SVM和RBF SVM来比较了不同方法得到的特征的线性区分能力,实验结果如表1所示。从行的方向观察表1,使用线性的SVM进行分类时,本文提出方法分类正确率最高,说明基于GLCM的特征表达比BoW模型得到的特征表达更具线性区分能力。使用RBF SVM进行分类时,两区域的BoW模型分类正确率比本文方法高1.66%。从

列的方向观察表1, 相比于使用RBF SVM, 使用线性SVM时, 两区域的BoW模型的分类正确率大幅下降, 而本文方法保持不变。

表1 与BoW模型的比较 (%)
Tab.1 Compared with BoW model (%)

Classifier	One Region BoW	Two Region BoW	Two Region Ele
Linear SVM	87.01	85.51	90.70
RBF SVM	87.96	92.36	90.70

3 讨论

对于复杂多变、随机性大的纹理, 使用GLCM的统计量来描述纹理特征会导致纹理信息的大量丢失, 从而特征的可区分性降低; 直接使用GLCM的元素作为特征表达能最大限度地保留纹理信息。由于GLCM中存在大量的零元, 使用PCA能有效地降维, 所以不会带来特征向量维数高、计算量大的问题。另外, 在特征提取时通过划分区域的方法引入空间位置信息也能进一步提高分类精度。

本文提出方法的结果略低于目前最先进的基于区域划分的BoW模型。一种可能的解释是图像块的聚类中心代表纹理基元(Texton), 刻画的是多个像素的相邻关系, 而GLCM刻画的是两个像素的关系, 因而基于图像块的BoW模型比GLCM更具表达力, 但这并不表明刻画的像素个数越多越好, 例如当图像块的大小超过 13×13 时, BoW模型的性能反而下降。除了分类准确度, 我们还应当考虑计算复杂度, GLCM的计算非常简单、直接和高效; 而BoW模型首先需要对大量的局部特征描述子进行聚类, 然后要对图像中的局部特征描述子进行矢量量化编码, 因此计算复杂度比较高。而且本文提出的方法只需用线性的SVM就能获得很好的结果, 而BoW模型则需要使用非线性的SVM才能获得较好的结果。

4 结论

针对CE-MRI脑肿瘤图像的自动分类问题, 对传统的基于GLCM统计量的特征表达提出了两点改进: 一是直接使用GLCM元素作为特征; 二是对肿瘤区域和肿瘤边缘区域分别计算GLCM。本文方法的分类准确率比基于各向同性GLCM统计量的分类准确率高出接近30%, 达到了90.7%, 并且接近于目前最流行的BoW模型的92.36%。与BoW模型相比, 本文方法拥有简单、计算效率高、特征表达线性可分的良好特性。

实验中肿瘤区域是由医生手动勾画的, 这在实际应用中不是很方便, 一个可行的方案是结合病灶的自动检测和分割技术来确定肿瘤区域。由于我们特征提取的时候使用了肿瘤的边界区域, 因此我们并不需要精确的分割出肿瘤。下一步的研究任务是将病灶的自动检测和分类相结合, 开发一个全自动的脑肿瘤辅助诊断系统。

致谢: 感谢南方医院和天津医科大学总医院提供实验数据。

参考文献:

- [1] Wernick MN, Yang Y, Brankov JG, et al. Machine learning in medical imaging[J]. IEEE Signal Proc Mag, 2010, 27(4): 25-38.
- [2] Torheim T, Malinen E, Kvaal K, et al. Classification of dynamic contrast enhanced MR images of cervical cancers using texture analysis and support vector machine[J]. IEEE Trans Med Imaging, 2014, 33(8): 1648-1656.
- [3] Mougiakakou SG, Valavanis IK, Nikita A, et al. Differential diagnosis of CT focal liver lesions using texture features, feature selection and ensemble driven classifiers[J]. Artif Intell Med, 2007, 41(1): 25-37.
- [4] Mayerhoefer ME, Szomolanyi P, Jirak D, et al. Effects of MRI acquisition parameter variations and protocol heterogeneity on the results of texture analysis and pattern discrimination: An application-oriented study[J]. Med Phys, 2009, 36(4): 1236-1243.
- [5] Alic L, Vliet MV, Dijke CF, et al. Heterogeneity in DCE-MRI parametric maps: A biomarker for treatment response[J]. Phys Med Biol, 2011, 56(6): 1601-1616.
- [6] Agner SC, Soman S, Libfeld E, et al. Textural kinetics: A novel dynamic contrast-enhanced-MRI feature for breast lesion classification[J]. J Digit Imaging, 2011, 24(3): 446-463.
- [7] Karahaliou A, Vassiou K, Arikidis NS, et al. Assessing heterogeneity of lesion enhancement kinetics in dynamic contrast-enhanced MRI for breast cancer diagnosis[J]. Br J Radiol, 2010, 83(988): 296-306.
- [8] Lee CC, Chen SH, Tsai HM, et al. Discrimination of liver diseases from CT images based on Gabor filters[C]. In the 19th IEEE Symposium on Computer-Based Medical Systems, 2006.
- [9] Arivazhagan S, Ganesan L. Texture classification using wavelet transform[J]. Pattern Recogn Lett, 2003, 24(9): 1513-1521.
- [10] Haralick RM, Shanmuga K, Dinstein I. Texture features for image classification[J]. IEEE Trans Syst Man Cy C, 1973, 23: 610-621.
- [11] Yang W, Feng Q, Yu M, et al. Content-based retrieval of brain tumor in contrast-enhanced MRI images using tumor margin information and learned distance metric[J]. Med Phys, 2012, 39(11): 6929-6943.
- [12] Clausi DA. An analysis of co-occurrence texture statistics as a function of grey level quantization[J]. Can J Remote Sens, 2002, 28(1): 45-62.
- [13] Huang M, Yang W, Wu Y, et al. Retrieval of brain tumors with region-specific bag-of-visual-worlds representations in contrast-enhanced MRI images[J]. Comput Math Methods Med, 2012(4): 479-490.
- [14] Wang J, Bensmail H, Gao X. Joint learning and weighting of visual vocabulary for bag-of-feature based tissue classification[J]. Pattern Recogn, 2013, 46(12): 3249-3255.