

基于多特征扩展 pLSA 模型的场景图像分类

江悦 王润生

(湖南长沙国防科技大学电子科学与工程学院 ATR 实验室)

摘要: 场景图像分类近年来受到人们的广泛关注,而基于统计模型的方法更是场景分类中的研究热点。我们提出了一种新的基于多特征融合和扩展 pLSA 模型的场景图像分类框架。对每幅图像首先用多尺度规则分割确定局部基元,然后提取每个局部基元的多分辨率直方图矩特征和 SIFT 特征,最后用扩展的概率生成模型对图像集进行建模,测试。我们的方法不仅能够很好的表示图像的语义特性而且在模型的训练阶段是无监督的。我们针对目前常用的 3 个数据库,做了三组对比实验,均取得了比以前的方法更好的识别结果。

关键词: 多分辨率直方图矩特征; 场景分类; 概率生成模型

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 1003-0530(2010)04-0539-06

Scene classification based on a multi-feature extended pLSA model

JIANG Yue WANG Run-sheng

(ATR National Laboratory, School of Electronic Science and Engineering,
National University of Defense and Technology, Changsha, China)

Abstract: Scene image classification has recently been popular. The classification methods based on statistical models have been the most important methods in scene classification. We propose a new scene image classification framework based on multi-feature and an extended pLSA model. We extract multiresolution histogram moments features and scale invariant feature transform (SIFT) features of patches of images. These patches are extracted on regular segmentations of different scales of every image. Both the features are scale invariant, so they can well describe the characteristic of image patches of different scales. At last, we use extended pLSA to model all training images. Test images are then dealt with a method called fold in. Our methods are not only unsupervised, but also can well represent semantic characteristic of images. We conduct three experiments on three often used image databases. We compare our methods with two previous baseline methods. And our methods get better results than the others.

Key words: multiresolution histogram moments feature; scene classification; probability generative model

1 引言

近年来由于计算机技术和网络技术的飞速发展,产生了大量的图像信息。图像分类和检索越来越受到人们的关注。由于自然图像的场景亮度,目标尺度大小,场景内容等变化多样,对分类的方法提出了很大的挑战。现有的场景图像分类方法大致可分为基于图像特征的方法,基于图像 BOW (Bag of Words) 表示的方法和基于统计模型的方法。在基于图像特征的方法中,包括利用全局特征来表示图像的方法,代表性文献是 Oliva 和 Torralba 提出的 Spatial Envelope 表示[1];利用

局部特征表示来表示图像的方法,代表性文献是 Carson 等人提出的 Blobworld 表示[2];和考虑图像局部块空间位置关系的方法,代表性文献是 Lipson 等人提出的情景构造模型[3]和 Smith 等人提出的组合区域模板[4]。

基于 BOW 表示的方法来源于文本检索和自然语言处理。图像的基于 BOW 的表述[5]有如下处理过程:首先,通过提取图像中局部基元特征并进一步对其进行聚类获得图像视觉词汇表;其次,根据图像中各个视觉词汇出现的统计分布,对出现次数较多的视觉词汇赋予高的权值,对于在整个图像库中出现频率较高

的视觉词汇赋予较小的权值,得到表述图像的加权视觉单词统计直方图,即 Bag of Words 表示;最后,用此 BOW 表示作为图像特征按照某种相似性度量进行检索。BOW 方法由于其简单而得到广泛应用。虽然 BOW 方法能够减小图像的特征维数,但是,简单的图像 BOW 表示不能有效揭示图像集合的类内和类间统计结构信息。基于统计模型的方法源自基于 BOW 方法,不同的是以统计模型代替视觉单词的加权直方图;由于统计模型可以融入图像中存在的结构信息,所以这种表述具有更好的性能。因此,基于统计模型的场景图像分类方法现在越来越受到国内外学者的关注。

Hofmann 等人提出的 pLSA[6]方法则是现在被广泛使用的统计模型。pLSA 是在图像的 BOW 表示的基础上,将图像中的每个视觉词汇看作一个混合模型的采样,这个混合模型的每个分量就是所谓的潜在主题。每个视觉单词都从单个的主题中产生,而不同图像中的不同视觉单词从不同的潜在主题产生。图像的潜在主题可以理解为所包含的抽象目标类别如沙滩,天空,老虎等等。pLSA 通过极大化观测数据和潜在主题变量的对数似然函数得到训练图像的潜在主题分布,而对于测试图像则采用叠入(folding in)[6]方法,固定单词的潜在主题分布来计算测试图像的潜在语义表示。目前的这些基于统计模型的场景图像分类方法基本上都是基于 SIFT 描述子,SIFT 描述子是由 Lowe[7]提出的一种局部图像特征表示。其本质上是计算图像在某个区域的梯度的分块方向直方图。但是 SIFT 的特征维数比较大,Bosch 等人[8]在提取彩色图像特征的时候更是利用了4层的 SIFT 特征,导致总共有 $128 \times 4 \times 3 = 1536$ 维的表示,所以在模型的训练上需要比较大的时间消耗。我们结合以上原因,同时考虑到图像的目标也是有尺度大小的,提出了扩展 pLSA 方法,采用多主题数目联合建模,得到了更稳定和更好的效果。

2 pLSA 模型

pLSA 模型是由 Hofmann[8]提出的一个用于文本检索的概率生成模型。这里我们用图像处理的语言来描述模型。假设有一组训练图像 $\{d_1, \dots, d_M\}$,每个图像均包含若干个局部区域,这些区域被量化为包含 W 个视觉单词[9]的词汇表 $\{w_1, \dots, w_W\}$,因此训练图像的集合就可以由一个单词图像的互共现矩阵来表示,

矩阵的每个元素 $n(d, w)$ 表示单词 w 在图像 d 中出现的次数。假设共有 K 个潜在变量 $\{z_1, \dots, z_K\}$,则每个图像产生的概率都可以看作是条件概率 $P(z_k | d_i)$ 的混合,而这个条件概率被称作因子模型[10](aspect model)。这样的因子模型可以看作是潜在变量产生时视觉词汇出现的概率 $P(w_j | z_k)$ 的组合。因此,这个生成过程可以用下面的联合概率密度函数表示为:

$$P(d_i, w_j) = P(d) \sum_k P(w_j | z_k) P(z_k | d_i) \quad (1)$$

根据极大似然准则,可以通过极大化下面的对数似然函数来进行模型的参数估计:

$$L = \sum_i \sum_j n(d_i, w_j) \log p(d_i, w_j) \quad (2)$$

其中 $n(d_i, w_j)$ 就是图像和视觉单词的互共现矩阵的元素。这样的极大似然解问题一可以通过标准的 EM 算法来估计参数。模型建立后,对于测试图像,则采用叠入操作[6],固定概率 $P(w_j | z_k)$,计算测试图像的潜在主题表示 $P(z_k | d_i)$,来进行相似性度量。

3 局部基元特征提取

近年来计算机视觉领域出现了大量基于局部基元(patch)的方法,所谓局部基元,是指图像中相邻的被看做一个整体单位的局部区域。与处理图像中的单个像素相比,以局部基元为单位进行处理,在计算量,推广性和集成上下文信息上都有着优势。当前的绝大部分文献在提取局部基元的特征时,都采用单一 SIFT 特征[7]。Bosch 更是使用4个支持集的彩色空间 SIFT 特征,针对多个库取得了不错的效果。而我们采取 SIFT 特征和多分辨率直方图矩特征[11]联合表示局部基元特性。关于 SIFT 特征可以参考文献[7],这里主要介绍多分辨率直方图矩特征。该特征已经应用于灰度纹理图像分类并且取得了很好的效果。这里将其扩展到彩色空间并和 SIFT 特征联合使用。基本思想是对一幅图像先进行多尺度分解,然后提取每个尺度下图像的直方图,并计算直方图的 X 和 Y 方向的一至三阶矩特征。最后连接成图像的特征表示。

假设图像区块为 I ,将其用高斯滤波器进行多分辨率分解:

$$I_l = I * G(l) \quad l = 1, \dots, L \quad (3)$$

假设在每个尺度下图像区块的直方图为 $\{h_{i(j)}^l\}_{j=1}^{n_i}$,其中 n_i 表示图像的灰度级数目, $i(j)$ 表示第 j 个柱的灰度值。则可以计算 X 和 Y 方向的矩特征如下:

X 方向:

$$m_{x,1}^l = \sum_{j=1}^{n_l} i(j) p_{h_{i(j)}} = \frac{1}{H} \sum_{j=1}^{n_l} i(j) h_{i(j)} \quad (4)$$

$$m_{x,k}^l = \sum_{j=1}^{n_l} \left| i(j) - m_{x,1}^l \right|^k p_{h_{i(j)}} = \frac{1}{H} \sum_{j=1}^{n_l} \left| i(j) - m_{x,1}^l \right|^k h_{i(j)}, \quad k = 2, 3 \quad (5)$$

Y方向:

$$m_{y,1}^l = \sum_{j=1}^{n_l} h_{i(j)} \frac{1}{n_l} = \frac{1}{n_l} \sum_{j=1}^{n_l} h_{i(j)} \quad (6)$$

$$m_{y,k}^l = \sum_{j=1}^{n_l} \left(\left| h_{i(j)} - m_{y,1}^l \right|^k \frac{1}{n_l} \right) = \frac{1}{n_l} \sum_{j=1}^{n_l} \left| h_{i(j)} - m_{y,1}^l \right|^k, \quad k = 2, 3 \quad (7)$$

可以看出如果直方图经过归一化,则Y方向的一阶矩就正比于图像的大小,所以我们不用其作为特征。将每个级别下所有X方向和Y方向的5个矩特征连接起来得到多分辨率直方图矩特征:

$$MRHM = \{ m_{x,1}^l, m_{x,2}^l, \dots, m_{y,2}^l, \dots, m_{x,1}^l, \dots, m_{y,3}^l \} \quad (8)$$

对于SIFT特征,我们使用 4×4 分块的,8个方向的SIFT描述子,这样的描述子具有的特征维数是128维。则最终我们得到的组合特征MSF(MRHM and SIFT Features)为:

$$MSF = \{ MRHM \text{ weight} * SIFT \} \quad (9)$$

其中weight是尺度权值,因为SIFT特征和MRHM特征的尺度并不相同,需要加一个权值进行调整。如果多分辨率分解的级数是2,则MRHM特征包含 $3 \times 5 = 15$ 特征维数,最终我们得到的组合特征MSF是 $128 + 15 = 143$ 维。

对于彩色图像,我们则针对图像的每个RGB颜色分量 $\{I_R, I_G, I_B\}$,分别计算其多分辨率直方图矩特征,得到彩色多分辨率直方图矩特征 $CMRHM = \{ MRHM_R, MRHM_G, MRHM_B \}$,并将 $CMRHM$ 和SIFT特征联合得到新的组合特征:

$$CMSF = \{ MRHM_R \ MRHM_G \ MRHM_B \ \text{weight} * SIFT \} \quad (10)$$

注意到,我们并不考虑在每个颜色分量计算其SIFT特征,是因为SIFT特征维数太高,计算量大,而且增加这么高的维数并不能显著提高性能。MRHM特征是基于原始图像的灰度值信息提取的,而SIFT特征则是基于原始图像的灰度梯度值信息提取的,这两者的结合能更有效的表示图像特性。

4 扩展的 pLSA 模型

在标准的pLSA模型中,潜在主题数目是人为确定的,Josef[12]等人则采用主题数目和分类类别相同的设置,这样的方法在类别数目较少的时候效果还可以,而当类别数目比较多,则不能取得较好的效果。而Bosch[8]等人则采用在Validation集合上做多次的实验测试以确定最优的潜在主题数目,这样做的问题是验证集合上最优的潜在主题数目未必能较好的推广到测试集合上,我们这里则考虑采用多个潜在主题数目联合的方式。对于特定的潜在主题模型,考虑两个或更多主题数目,分别进行建模。同时考虑到局部基元的提取方式不同,我们提出扩展的pLSA模型(Extended pLSA):

场景图像分类的建模之前需确定图像的局部基元并提取其特征。传统的提取局部基元的方法有两种,一种是先提取图像的感兴趣点,将感兴趣点的邻域作为局部基元。另一种则是Frederic[13]等人提出采用密集的规则网格采样,就是将图像均匀的分割成 $N \times N$ 大小的矩形块,块间隔为 M ,当 $M > N$ 的时候提取的块是重叠的,当 $M < N$ 的时候,提取的块是不重叠的。在实际应用中,多数情况下密集规则采样得到的效果要比稀疏的感兴趣点采样好。但是我们考虑到图像中的视觉特征实际上是有尺度区别的,同样的物体可以有不同的尺度形态,采用单一的尺度进行采样可能会丢失其它尺度下的目标信息,所以我们采用多尺度的密集规则网格提取局部基元。对一幅图像,采用宽度为 $W \times W$ 的矩形局部基元,每个局部基元在水平和垂直方向上的间隔均为 S ,针对 W 取的 m 个不同的值,我们采样 m 次,将得到的所有局部基元集合在一起进行特征提取。

假设有一组训练图像 $\{I_1, \dots, I_M\}$, K 个潜在主题 $\{z_1, \dots, z_K\}$, K 的取值为 $\{K_1, \dots, K_s\}$,测试图像的集合为 $\{J_1, \dots, J_L\}$

模型建立:采用单尺度的局部基元提取方式,假设局部基元的提取方式为块大小为 W ,块间隔为 S ,主题数目为 K_l ,则图像和视觉词汇的互共现概率为: $P(I_i, w_j) = \sum_{k=1}^{K_l} P(z_k) P(I_i | z_k) P(w_j | z_k)$,根据极大似然准则,采用EM算法得到模型参数: $P(w | z) |_{K_l, W, S}$ 和图像的潜在主题分布 $P(z | I) |_{K_l, W, S}$ 。综合所有 K 个主题数目,则得到的训练图像的潜在主题表示为:

$$P(z | I) = [P(z | I) |_{K_1, W, S} \dots P(z | I) |_{K_s, W, S}] \quad (11)$$

模型测试:分别固定图像的潜在主题分布 $\{P(w|z)|_{K_1, w, s}, \dots, P(w|z)|_{K_s, w, s}\}$, 对测试图像集合采用叠入操作[6], 得到测试图像的潜在主题表示:

$$P(z|J) = [P(z|J)|_{K_1, w, s} \cdots P(z|J)|_{K_s, w, s}] \quad (12)$$

为了比较多尺度局部基元提取方式带来的性能提升, 我们对于基于单尺度方式提取局部基元的称为模型 EpLSA1, 对于基于多尺度方式提取局部基元的我们称为模型 EpLSA2。

5 实验及结果

使用上面介绍的扩展 pLSA 模型, 并基于我们的混合特征, 我们和两个基本的算法进行了比较: 1, 是 Oliva 和 Torralba 在文[1]中使用的方法。2, 是 Bosch 在文[8]中使用的方法。

本文使用了3个不同大小和类别的图像库, 分别是: 1#图像库, 来自 COREL 图像库, 包含5个类别: 公共汽车, 猫头鹰, 猫, 飞机, 狮子, 每类均100幅, 共500幅图片。示例图片如图1所示。2#图像库是 OT 图像库[1], 这个图像库包含8个自然场景类别: 高速公路(260幅), 城市(308幅), 高层建筑(256幅), 街道(292幅), 森林(328幅), 海滩(360幅), 山脉(374幅), 乡村开阔地(410幅)一共2688张图片。示例图片如图2所示。3#图像库来自 Caltech-101 图像库, 包含12个类别: 照相机, 加农炮, 鲑鱼, 美元, 手风琴, 桶, 火烈鸟, 渡船, 电吉他, 大象, 斑点狗和飞机, 每个类别图片数目从47到800不等, 一共1441幅图片。示例图片如图3所示。

实验采用的分类器是多类的 SVM 分类器。SVM 是通过一个核函数将低维的特征映射到高维的特征空间中, 然后在此高维特征空间中寻找最大间隔分割超平面和数据进行分类。SVM 本身只支持二元分类问题, 对于多类问题, 我们则采用一对一 (one-against-one) 规则来实现: n 类的分类问题使用 $n(n-1)/2$ 个二元的 SVM 分类器, 将所有类进行两两测试, 测试结果是属于哪个类就给哪个类投一票。得票数最高的类就是最终的标记类。本文使用的 SVM 核函数是径向基函数 (Radial Basic Function 或 RBF) 核函数。

针对这3个图像库, 我们分别做了3组实验:

实验1, 基于1#图像库, 随机选取一半的图像来用作训练, 剩下的图像用作测试。由于这个库图像数目少, 对于训练图像, 我们每个类只取3张图片来提取视觉词汇表, 同时取出50张图片作为验证集合来提取最

优参数。在验证集合上我们得到的视觉词汇表的大小为1500。而对于我们的混合特征 MSF, 其中的 SIFT 特征采用一个支持集的灰度 SIFT 特征。MRHM 特征采用2级分解, 则我们所用的 MSF 特征维数为143, CMSF 特征维数为173。我们的 EPLSA 模型采用的2个主题数目组合: $K_1 = 60; K_2 = 90$ 。我们在进行单尺度采样的时候, 采用 $W = 16, S = 10$; 而对于多尺度采样, 分别取 $W = 64, 32, 16, S = 30, 20, 10$ 。实验结果如表1所示。我们的方法取得了最高的识别率结果, 而且可以看出, 在此图像库上, 基于灰度混合特征 MSF 和单尺度模型的方法已经取得了比基本算法好的结果。

实验2, 基于2#图像库。同样选取一半的图像用作训练, 剩下的图片用于测试。对于训练图像, 从中随机选取50幅左右的图像来建立词汇表, 同时总共取出100幅图像作为验证集合。在验证集合上我们得到的最优词汇表大小是1500。实验所用的特征和多尺度模型设置同实验1。实验结果如表2所示。我们的基于 CMSF 和多尺度模型的方法取得了最好的结果。表2中, 文[8]报道的2#图像库上的结果87.1%是取最佳值, 85.3%是平均值。

实验3, 针对3#图像库, 选取一半的图像用作训练, 剩下的图片用于测试。在每个训练类别中取出5张图片提取词汇表, 验证集合的图片数目也是50个。在验证集合上得到的最优词汇表大小是2000。实验所用的特征和多尺度模型设置同实验1。实验结果如表3所示。可以看出, 无论是单尺度模型, 还是多尺度模型, 均取得了比基本方法好的结果。



图1 示例图片(1#图像库)

表1 实验1的分类结果, 使用1#图像库, 总共5个场景类别

实验方法	正确识别率 (%)
EpLSA1 + MSF	95.2
EpLSA1 + CMSF	96.4
EpLSA2 + MSF	95.6
EpLSA2 + CMSF	97.6
文[8]方法 (CSIFT)	93.6
文[1]方法	90.4



图 2 示例图片(2#图像库)

表 2 实验 2 的分类结果,使用 2#图像库,总共 8 个场景类别

实验方法	正确识别率(%)
EpLSA1 + MSF	82.4
EpLSA1 + CMSF	82.8
EpLSA2 + MSF	84.3
EpLSA2 + CMSF	85.6
文[8]方法 ¹ (CSIFT)	87.1/85.31
文[1]方法	83.9

对于文[8]的方法,我们按照其结论,采用 4 个支持集的彩色 SIFT 特征,每个类选取大约 30 幅图像用来构建视觉词汇表,视觉词汇表的大小设置为 1500。实验结果是对于相同的设置采用 10 次重复实验得到的平均值。综合三组实验的结果,可以看出,我们的基于 CMSF 特征的 EpLSA2 方法取得了最好的结果。对比采用单尺度方式提取局部基元的 EpLSA1 模型,采用多尺度方式的 EpLSA2 模型取得的效果更好。

多尺度方法提取特征的计算量要比单尺度的稍高。我们采用混合特征 MSF 在三个图像库上分别比较了用多尺度和单尺度模型进行分类所用的时间。我们在 CPU 为 AMD Athlon X2 2.9G 的台式机上,用 Matlab 编程进行实验。对于 1#,2#,3#图像库,使用单尺度模型 EpLSA1,参数设置为 $W=16, S=10$ 。平均处理每幅图片的所用时间分别为:2.48 秒,1.94 秒,2.89 秒。采用多尺度方法提取特征,分别取 $W=64, 32, 16, S=30, 20, 10$ 。平均处理每幅图片的所用时间分别为:3.09 秒, 2.52 秒,3.47 秒。由此可见,三层多尺度模型 Eplsa2 其分类时间要比单尺度模型 Eplsa1 大 25%。

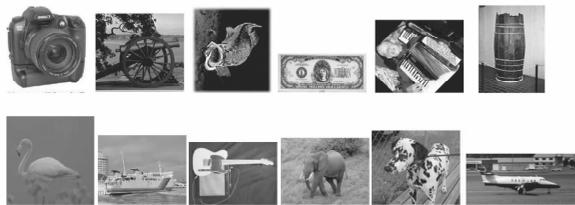


图 3 示例图片(3#图像库)

表 3 实验 3 的分类结果,使用 3#图像库,总共 12 个场景类别

实验方法	正确识别率(%)
EpLSA1 + MSF	78.2
EpLSA1 + CMSF	79.0
EpLSA2 + MSF	79.5
EpLSA2 + CMSF	80.1
文[8]方法(CSIFT)	76.1
文[1]方法	74.7

6 总结

基于以上的实验,我们得出基于多特征融合的扩展潜在主题模型在场景图像分类中有着很重要的意义。图像的内容是多样的,单一的特征只能反映图像的某个方面的特性,而多特征则可以全面的描述图像的内容。图像中的内容也是有尺度大小的,合适的尺度的局部区块能够提取出图像中的关键内容。扩展的潜在主题模型则能够更稳定的对图像库的类别结构和场景信息进行建模,得到更好的分类识别率。我们还注意到,场景图像分类中,图像类别的定义是人为确定的,因此对于类间差别比较小的图像类,就有可能引入人为误差。实验中采用的 2#场景图像库中山脉,乡村开阔地,海滩等类别就存在很难精确辨认类别的图像。而 1#和 3#图像库的目标场景图像类间差别就比较明显,也更能体现出场景分类算法的性能好坏。

在我们的算法中,构建图像库的视觉词汇表中采用的是 kmeans 算法,该算法计算量比较大,所以可以在以后的工作中考虑对聚类 and 量化的技术进行改进,进一步的提高视觉词汇表的表示功能,提高模型的实际应用能力。

参考文献

- [1] O. A and T. A, "Modeling the shape of the scene: a holistic representation of the spatial envelope," International Journal in Computer Vision, vol. 42, pp. 145-175, 2001.
- [2] C. Carson, M. Thomas, S. Belongie, J. M, Hellerstein, and J. Malik, "Blobworld: a system for region-based image indexing and retrieval," in International Conference on Visual Information Systems 1999.
- [3] P. Lipson, E. Grimson, and P. Sinha, "Configuration based scene classification and image indexing," in IEEE Computer Society Conference on Computer Vision and Pat-

¹ 文[8]报道的 2#图像库上的结果 87.1% 是取最好值, 其实验结果的变化范围是 79% 到 87%, 平均值是 85.3%。

- tern Recognition. , Puerto Rico, 1997.
- [4] J. R. Smith and C. Li, "Image classification and querying using composite region templates," *Computer Vision and Image Understanding*, vol. 75, pp. 165-174, 1999.
- [5] J. Sivic and A. Zisserman, "Video Google: A Text Retrieval Approach to Object Matching in Videos," in *Proceedings of the Ninth IEEE International Conference on Computer Vision*, 2003.
- [6] T. Hofmann, "Unsupervised Learning by Probabilistic Latent Semantic Analysis," *Machine Learning*, vol. 42, pp. 177-196, 2001.
- [7] D. G. Lowe, "Distinctive image features from scale-invariant keypoints," *International Journal of Computer Vision*, vol. 60, pp. 91-110, 2004.
- [8] A. Bosch, A. Zisserman, and X. Munoz, "Scene classification using a hybrid generative/discriminative approach," *IEEE Trans Pattern Anal Mach Intell*, vol. 30, pp. 712-727, Apr 2008.
- [9] L. Fei-Fei, R. Fergus, and P. Perona, "A Bayesian hierarchical model for learning natural scene categories," in *CVPR*, Washington D. C. USA, 2005.
- [10] T. Hofmann, J. Puzicha, and M. I. Jordan, "Unsupervised Learning from dyadic data," *Advances in Neural Information Processing Systems*, vol. 11, 1999.
- [11] Y. Jiang, R. Wang, and P. Zhang, "Texture description based on multiresolution moments of image histograms," *Optical Engineering*, vol. 43, pp. 037005(1-7), 2008.

- [12] J. Sivic, B. C. Russell, A. A. Efros, A. Zisserman, and W. T. Freeman, "Discovering Objects and Their Location in Images," in *IEEE International Conference on Computer Vision*, 2005.
- [13] F. Jurie and B. Triggs, "Creating Efficient Codebooks for Visual Recognition," in *IEEE International Conference on Computer Vision*, 2005.

作者简介



江悦(1980-),男(汉族),安徽池州人,分别于2002年和2004年在国防科技大学理学院数学系获得学士和硕士学位。现在是国防科技大学电子科学与工程学院ATR实验室博士研究生。中国计算机学会学生会员。主要研究方向包括图像处理,计算机视觉和模式识别。

E-mail: yue.jiang@163.com



王润生(1941-),男(汉族),江苏扬州人,1964年毕业于哈尔滨军事工程学院电子工程系,现为国防科技大学电子科学与工程学院教授,信号与信息处理博士生导师,中国图像图形学会常务理事,中国电子学会高级会员,享受政府特殊津贴。主要从事图像处理、分析与理解,模式识别和信息融合等方法的科学研究和教学工作。

E-mail : rswang@nudt.edu.cn