

基于异构描述子的新型高斯混合模型图像自动标注方法^{*}

陈利琴 金 聪

(华中师范大学计算机学院 武汉 430079)

摘要: 过去几十年以来,各种图像标注算法相继提出。这些方法要么需要很大的计算量,要么标注效果不理想。论文提出了一种基于异构描述子的新型高斯混合模型图像语义自动标注方法。本文的高斯混合模型是采用异构空间来构建的,不同于其他的高斯混合模型。对于每个标注词,在多个特征空间下分别用高斯模型来描述,形成对应于空间的“标注词分描述子”。由于各个分描述子描述不同标注词的能力有很大差别,因此通过机器学习的方法来融合这些分描述子,形成更加有效的“标注词描述子”,从而提高标注的准确率。论文提出的“标注词描述子”可以有效地建立图像高层语义概念与底层视觉特征之间的对应关系,准确地描述标注词的语义内容,从而提高图像的标注性能。通过在COREL数据集上的测试表明了方法的有效性。

关键词: 异构描述子;高斯模型;标注词描述子;图像语义标注

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Automatic image annotation method based on novel Gauss mixture model with heterogeneous descriptors

Chen Liqin Jin Cong

(School of Computer Science, Central China Normal University, Wuhan 430079, China)

Abstract: Over the past few decades, a variety of image annotation algorithms have been proposed. These methods either require a large amount of computation, or effect of labeling is not satisfactory. In this paper, an automatic image semantic annotation method based on novel Gauss mixture model with heterogeneous descriptors is proposed. The Gauss mixture model is built by the heterogeneous space, which is different from the others'. Specifically, each annotation word was described by the Gauss model at a plurality of feature space respectively, and formed "annotation word sub-descriptor" corresponding to the subspace. Because the ability of each sub-descriptor describing the different words is different, the machine learning method is used to integrate these sub-descriptors to form a more effective "annotation word descriptor" for improving the accuracy of annotation. The proposed "annotation word descriptor" can effectively establish the relations between the image semantic concepts and visual features, and accurately describe the semantic content annotation, thereby improve the performance of image annotation. The experimental results confirm that the proposed method is effectiveness.

Keywords: heterogeneous descriptors; Gaussian mixture model; annotation word descriptor; image annotation

1 引言

图像自动标注的目标是给指定的图像分配标注词,本质上是多标签学习问题,因为一幅图像包含多个对象,所以它与一系列标签相关联^[1]。图像标注通过提取图像的底层视觉特征,建立图像底层视觉特征与高层语义之间的联系,从而实现对图像高层语义的理解^[2]。图像标注的方法大多

采用判别模型和生成模型的方法。判别模型是将图像标注看成是监督分类问题,如文献[3]为每个标签选择有效的特征,然后为每个标签训练一个分类器,利用分类器去判断图像属于哪类;生成模型是构建图像内容与标注词之间的联合分布,利用概率分布来标注图像。如J. Jeon等人^[4]提出的跨媒体相关模型(CMRM)是利用生成模型的方法来进

收稿日期:2015-01

^{*} 基金项目:国家社会科学基金(No. 13BTQ050)、教育部人文社会科学研究规划基金项目(11YJAZH04)

行图像标注。然而判别模型和生成模型容易受到一些因素的影响,造成标注结果不准确。如文献[5]结合生成模型与判别模型的长处,提出一个分层图像标注模型的方法,提高了图像标注的性能。

目前图像标注的研究领域主要集中在如下几方面:1)特征选择^[6]:选取什么样的特征来描述图像。2)分类算法:什么样的分类算法适合图像标注。3)附加信息的利用,比如利用标注词之间的共生关系来提高标注精度等。已有的研究一般都是在同一特征空间下建立标注词与图像内容之间的联系,通过提取不同类型的特征(如颜色、纹理、形状等)构建同一特征空间,进而在该特征空间中进行标注。这样处理的主要缺陷有:1)特征空间的维数往往很高,造成统计或者训练的方法计算量很大,也就是维数灾难问题;2)构建的高维矩阵往往是稀疏的,不利于学习算法的学习。本文是从另外的角度来解释图像不同类型的特征,也就是一幅图像的颜色、纹理、形状等特征意味着一个对象不同角度的描述。对同一个对象,单一特征有不同的描述能力,类似于认知科学中对事物的认知,比如对于熟悉的人,我们可以通过人名、照片、声音、体形等特征单独来识别,各种特征识别的结果融合在一起会增强识别的准确率。同样,一个标注词也可以从不同的角度来描述,比如颜色特征、纹理特征、轮廓特征等等,不同特征的描述有强有弱,如何综合利用这些特征来更好地描述图像是目前一个研究热点。

一般地,对不同对象进行标注的时候有三种方法来处理:1)不同的标注词选择不同的特征,发挥不同特征的优势;2)不同标注词选择相同特征,在同一特征空间下建立标注词与图像特征之间的映射关系;3)通过融合多种特征的方法,利用机器学习来学习每个标注词不同特征的权重,从而融合在一起描述图像。第一种方法的缺陷是需要人为地为每个标注词选择表达能力最强的特征空间,自动化程度不高;第二种方法没能充分利用不同特征对不同对象的描述强弱;第三种方法避免了上述两种方法的缺点,充分利用了不同特征的优势。针对这些我们提出一种基于异构描述子的高斯混合模型的图像自动标注方法,即上述第三种方法。

首先,提取图像的多种特征作为特征子空间,针对每个标注词在这些特征子空间下分别训练一个高斯模型,它表示标注词分描述子。然后,分别为每个标注词分描述子训练一个权重因子,此权重表示特征描述此标注词的重要程度。最后,每个标注词描述子用这三个高斯模型的加权和来描述,称其为高斯混合模型。本文的高斯混合模型不同于图像跟踪^[7]与文献[8-9]中的高斯混合模型,图像跟踪与文献[8-9]中的高斯混合模型是定义在同一个特征空间中,而本文的高斯混合模型表示每一个高斯模型对应不同的特征子空间,混合的加权系数表示该子空间描述标注词的能力。

2 图像块异构描述子

2.1 基本思想

本文是基于区域的特征提取,在各类特征中,颜色特征由于对噪声、尺寸和旋转有较强的鲁棒性而被证明是一种有效的特征^[10],同时,轮廓特征与纹理特征在图像分类中也起到十分重要的作用,所以选择颜色、轮廓、纹理作为图像的底层特征,并将此三个特征作为独立的特征子空间。这里的异构描述子是指颜色描述子、轮廓描述子、纹理描述子,因为颜色特征空间、轮廓特征空间、纹理特征空间是一幅图像的不同侧面描述,所以称它们为异构的,相应的特征向量被称为异构描述子。

2.2 颜色描述子

采用HSV颜色空间的色度矩作为图像颜色特征,分别用每个分量的一阶矩、二阶矩来表达图像的颜色分布。假设 $m \times n \times 3$ 的图像,记它每个分量的第 x 行 y 列的像素是第 $n(x-1)+y$ 个,那么令第 j 个像素的第 i 个颜色分量是 P_{ij} , $N=m \times n$ 是像素的尺寸,则颜色矩定义如下:

$$\text{一阶矩(均值): } \mu_i = \frac{1}{N} \sum_{j=1}^N P_{ij}$$

$$\text{二阶矩(方差): } \sigma_i = \left[\frac{1}{N} \sum_{j=1}^N (P_{ij} - \mu_i)^2 \right]^{\frac{1}{2}}$$

所以图像的颜色特征向量为:

$$\mathbf{F}_{color} = [f_{H1}, f_{S1}, f_{V1}, f_{H2}, f_{S2}, f_{V2}]$$

2.3 轮廓描述子

采用傅里叶描述子来提取图像的轮廓信息。对于 XY 平面上提取的 M 个边界点,其坐标序列表达为 $s(k)=[x(k), y(k), k=0, 1, 2, \dots, M-1]$,将每个坐标用复数来表示为:

$$s(k) = x(k) + jy(k), k = 0, 1, \dots, M-1 \quad (1)$$

利用区域边界的封闭性和周期性,可将二维问题转化成一维问题, $s(k)$ 的傅里叶变换为:

$$f(i) = \frac{1}{N} \sum_{k=0}^{M-1} s(k) \exp(-\frac{j2k\pi i}{N}), i = 0, 1, \dots, M-1 \quad (2)$$

复系数 $f(i)$ 称为傅里叶描述子,傅里叶描述子与形状的尺度、方向和曲线的起始点位置有关。为了识别具有旋转、平移和尺度不变性的形状,需要对傅里叶描述子进行归一化处理^[11]。归一化的傅里叶描述子为:

$$\mathbf{F}_{contour} = \frac{\|f(k)\|}{\|f(1)\|}, k = 0, 1, \dots, M-1 \quad (3)$$

对每个图像的轮廓特征用32个描述子描述,那么轮廓特征是32维的特征向量。

2.4 纹理描述子

采用基于小波变换的纹理描述符作为纹理描述子。利用小波变换将图像进行三级分解,对图像的一个小波变换特征描述符可对应在不同分辨率上沿水平、垂直和对角方向边缘的分布。采用金字塔结构的小波变换,每

一层分解得到 4 个 1/4 大小的子图像,分别是高通滤波图像和水平、垂直、对角线三个分量图像。对各个分解层次上的各个方向的子图像,将对应的分解系数的均值和方差作为小波变换特征描述符,所以纹理特征是 20 维的特征向量表示为:

$$\mathbf{F}_{\text{texture}} = [f_{lm1}, f_{un1}, f_{dm1}, f_{hc1}, f_{xc1}, f_{dc1}, f_{lm2}, f_{un2}, f_{dm2}, f_{hc2}, f_{xc2}, f_{dc2}, f_{lm3}, f_{un3}, f_{dm3}, f_{hc3}, f_{xc3}, f_{dc3}, f_{un3}, f_{ac3}]$$

小波分解的金字塔结构图如图 1 所示。

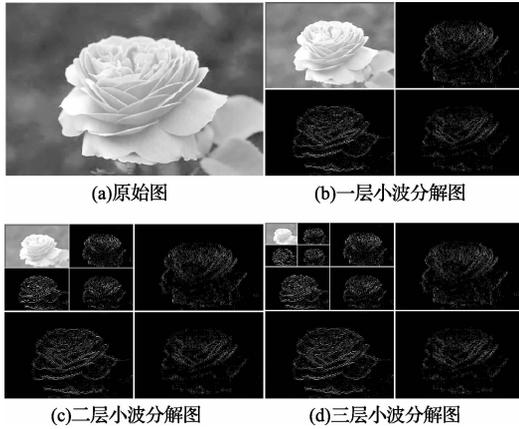


图 1 小波分解金字塔结构图

3 标注词描述子及其学习算法

3.1 标注词描述子及其分描述子的概念

标注词描述子由定义在三个特征空间(即颜色、轮廓、纹理)的特征表示的,可以描述图像的语义信息。由于标注词分描述子是子特征空间的一个区域,而高斯模型具有很多优良的特性,因此标注词分描述子可用一个高斯模型表示。标注词描述子就是三个特征子空间下高斯模型的混合,即异构空间的高斯混合模型。具体地,用三种特征描述子表示图像底层特征时,可用三个高斯模型(G_1^c, G_2^c, G_3^c)表示一个标注词的分描述子,将每种高斯模型附上相应的权重系数($\lambda_1^c, \lambda_2^c, \lambda_3^c$),同时将该标注词附上一个概率阈值(τ^c 表示如果一个图像区域属于该标注词的概率大于该阈值时,才能选择这个标注词作为该图像区域的候选标注词)。按上述方法,每个标注词 $K_c, c = 1, \dots, C$ (C 表示图像数据集中标注词的个数)可用七元组表示为($G_1^c, G_2^c, G_3^c, \lambda_1^c, \lambda_2^c, \lambda_3^c, \tau^c$)。由于高斯模型可用其均值和方差表示,所以标注词描述子可以表示为 $M^c = (\lambda_1^c, \lambda_2^c, \lambda_3^c, \tau^c, \mu_1^c, \mu_2^c, \mu_3^c, \Sigma_1^c, \Sigma_2^c, \Sigma_3^c)$ 。其中,需要学习三个特征空间对应的高斯模型以及三个高斯模型的权重。由于三个特征空间相互独立,所以针对每个标注词,可以单独利用训练集来学习这三个高斯模型,三个高斯模型权重的学习将在 3.4 节中给出。

3.2 标注词分描述子的估计方法

多维高斯分布概率密度函数定义为:

$$f(\mathbf{x}) =$$

$$\frac{1}{|\Sigma|^{1/2} \sqrt{(2\pi)^d}} \exp \left\{ -1/2(\mathbf{x} - \mu)^T \Sigma^{-1} (\mathbf{x} - \mu) \right\} \quad (4)$$

式中: \mathbf{x} 是维数为 d 的样本向量, μ 是模型的期望, Σ 是模型的方差。简单起见,用 θ 表示高斯模型的参数(μ, Σ)。对于这样的单高斯模型,可以通过最大似然估计方法得到模型的两个参数。具体为在图像数据集中,选择用标注词 K_c 来描述图像区域 $R_k (R_k = R_1, R_2, \dots, R_N; N$ 是 K_c 对应的图像区域的个数) 作为训练样本集。对每个训练样本集,生成对应的三个异构的图像块描述子,然后在每个子空间估计高斯模型的参数。最大似然估计量方程为:

$$\Delta_\theta H(\theta) = \Delta_\theta \ln[l(\theta)] = \sum_{k=1}^N \Delta_\theta \ln p(\mathbf{x}_k | \theta) = 0 \quad (5)$$

所得最大似然估计量为:

$$\hat{\mu} = \frac{1}{N} \sum_{k=1}^N \mathbf{x}_k \quad (6)$$

$$\hat{\Sigma} = \frac{1}{N} \sum_{k=1}^N (\mathbf{x}_k - \hat{\mu})(\mathbf{x}_k - \hat{\mu})^T \quad (7)$$

式中: \mathbf{x}_k 表示第 k 个图像区域 d 维特征向量。

3.3 基于标注词描述子的分类方法

一旦建立了第 c 个标注词的描述子 M^c , 针对一幅未标注图像的标注方法如下:

1) 首先对图像进行分割,分割后的区域为 $\{R_1, R_2, \dots, R_k\}$ 。

2) 针对每一个图像区域 R_k , 计算每一个标注词模型的生成概率密度函数:

$$P(R_k | M^c) = \sum_{i=1}^m \lambda_i^c f^{G_i^c}(R_k) \quad (8)$$

式中: $\sum_{i=1}^m \lambda_i^c = 1, G_i^c$ 是第 c 个标注词的第 i 个分描述子。

3) 对任意测试样本是否用该标注词标注的方法是判定下列式子是否成立:

$$P(R_k | M^c) > \tau^c \quad (9)$$

$$\arg \max_{K_j} P(R_k | M^d), d = 1, 2, \dots, D \quad (10)$$

式中: τ^c 是第 c 个标注词的阈值。如果式(9)成立,则意味着该标注词作为图像区域 R_k 的候选标注词;否则就不是。式(10)表明:由式(9)得到多个标注结果 $K_d (d = 1, \dots, D, D$ 是候选标注词的个数) 时,取其中最大值对应的标注词作为最终的标注结果。

3.4 描述子权重学习算法

描述子的权重可以通过经验或者学习获得。神经网络是很常用的一种训练权重的方法,本文采用高斯核函数神经网络,并采用实数编码的遗传算法^[12]求解。对每类标注词选取若干个正样本(用该标注词描述的图像区域集)和负样本(不用该标注词描述的图像区域集)构成训练样本集,然后采用监督学习方法学习描述子的权重。框架见图 2。

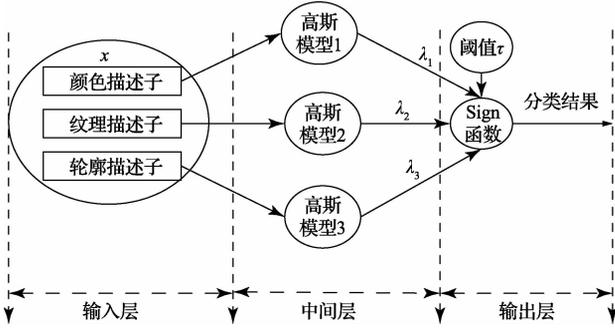


图2 描述子权重学习框图

图2表示的模型类似于前馈神经网络,其中输入层代表一个标注词的训练样本集 $X(X = x_1, x_2, \dots, x_L; L$ 是权重训练样本的大小)。首先提取每个样本 x_l 的特征 $x_l = [x_l^1, x_l^2, x_l^3]^T$ (其中 x_l^1, x_l^2, x_l^3 分别是图像区域的颜色、纹理和轮廓描述子) 作为输入层值。输入层的权重是1,不需要训练。中间层每个节点的函数分别对应于标注词的两个分描述子。输出层的计算公式为:

$$t'_l = \text{sign}(\sum_{i=1}^3 \lambda_i * f^{G_i}(x_l^i) - \tau) \quad (10)$$

式中: t'_l 表示模型输出的分类结果。

由于该模型要求 $\sum_{i=1}^3 \lambda_i = 1$, 而且符号函数不可导,因此不能直接采用梯度算法求解。遗传算法由于不要求求解的函数可导,所以本文选择实数编码的遗传算法求解。具体流程如下:

输入:标注词 K_c 的权重训练集 X 。

3.4.1 初始化:随机生成 N 个个体,记为 Parent,其中每个个体包含四个参数 $(\lambda_1, \lambda_2, \lambda_3, \tau)$, 这四个参数均在 $[0, 1]$

区间生成。然后归一化 $(\lambda_1, \lambda_2, \lambda_3)$, 使其 $\sum_{i=1}^3 \lambda_i = 1$ 且 $\lambda_i \geq 0$ 。

3.4.2 评估初始群体:利用训练集中所有样本计算误差函数:

$$f(x) = \sum_{l=1}^L (\text{sign}(\sum_{i=1}^3 \lambda_i * f^{G_i}(x_l^i) - \tau) - t)^2$$

将它的值作为对个体的评价,其中 t 是训练样本集的正确分类值, $f^{G_i}(x_l^i)$ 是标注词 K_c 的第 i 个分描述子。

3.4.3 循环直到满足停止条件

1) 选取任意 $N/2$ 对个体进行交叉操作,生成新的 $N/2$ 对交叉后的个体,记为 Offspring1。

2) 选取最差的 $N/2$ 个个体进行变异操作,生成新的 $N/2$ 变异后的个体,记为 Offspring2。

3) 评估 Offspring1 + Offspring2 中的每一个个体:利用训练集中所有样本来计算误差函数 $f(x)$ 的值作为对个体的评价。

4) 从 Offspring1 + Offspring2 + Parent 集合中选择适应值最好(这里指误差最小)的 N 个个体组成新的 Parent。

3.4.4 输出 Parent 中误差最小的个体作为训练结果。

上述遗传算法是对传统遗传算法的改进。图3是交叉过程,采用简单交叉的方法。首先随机从父代中选取两个父代个体,然后选择一个交叉位置进行操作,生成两个子代,最后对生成的后代的前三个参数进行归一化处理。

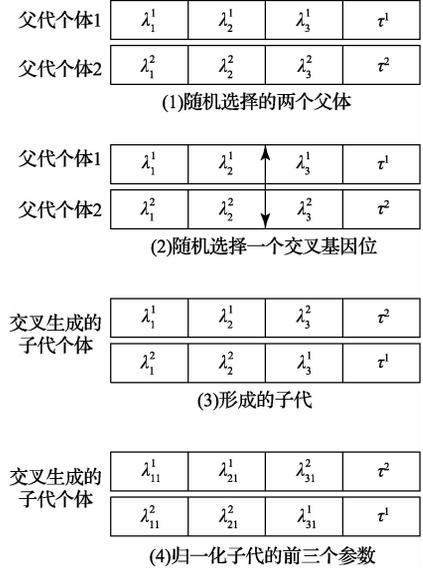


图3 交叉实现的过程

图4是变异过程。变异个体的父代是从父代群体中选择最差的一半个体进行变异。首先从父代中选取一个父代个体,然后随机选取一个变异基因位,进行变异操作,生成的子代个体的变异的基因位用 $[0, 1]$ 随机数来取代,其它基因位的取值和父代一样,最后对生成的后代的前三个参数进行归一化处理。

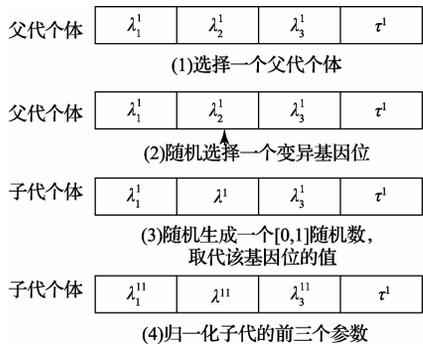


图4 变异实现的过程

3.5 基于异构描述子的图像标注过程

本文提出的基于异构描述子的高斯混合模型的图像标注框架如图5所示。对于一幅测试图像,先进行分割,然后对分割的图像区域计算由每个标注词描述子表示的概率,根据3.3节的方法选择图像区域的标注词,最后将该测试图像所有区域的标注词作为图像的最终标注词。

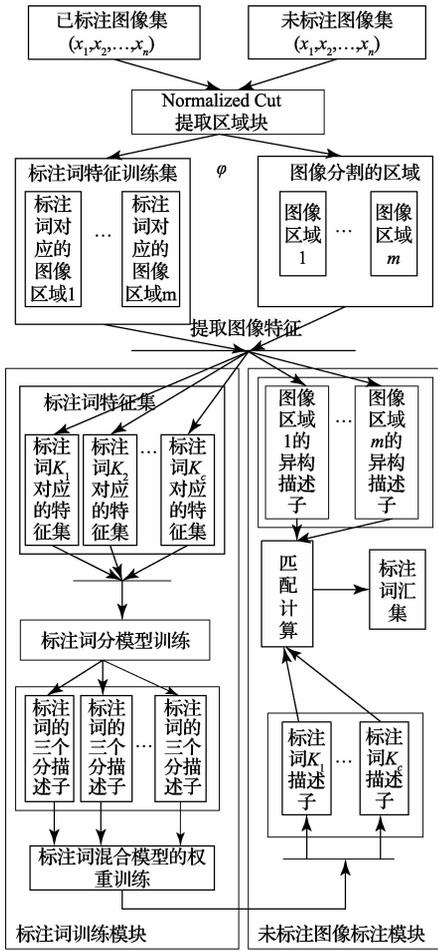


图 5 图像标注的框架

4 实验结果与分析

实验中选择 Corel 图像库的图像。该图像库分为 10 类,每类 100 幅图像,其中 700 幅图像作为训练集,300 幅图像为测试集。首先对已标注图像用 Normalized cut^[13]方法进行分割,然后提取图像区域特征。图像库定义有 22 个标注词,对每个标注词选择分割后相关的图像区域作为图像总的训练数据集。对未标注的图像首先采用同样的方法进行分割,然后运用本文中的方法对图像进行标注,本文中部分图像标注的结果如图 6 所示。

为了衡量图像标注方法的性能,本文采用了图像标注中常用的几种指标,分别为查全率、查准率和 F_1 测度值,它们定义为:

$$Recall = \frac{T_{K_c}}{N_{K_c}}, Precision = \frac{T_{K_w}}{N_{K_w}}$$

$$F_1 = \frac{2 * Recall * Precision}{Recall + Precision}$$

式中: T_{K_c} 是被一个关键词 K_c 标注的图像个数, N_{K_c} 是测试集中被该关键词标注的图像个数, N_{K_w} 是被该关键词正确标注的个数。将所有的测试图像标注好后,计算每个关键词的查全率、查准率、 F_1 测度值、平均查全率、平均查准率、平均 F_1 测度值,并与文献[14]、文献[15]和 CMRM 方法的性能进行比较。取部分标注词 sky, grass, stone, clouds, flower, people, horse, leaf, building 为例子,表 1 是这些标注词的 F_1 测度值比较,表 2 给出文中算法与其他方法平均性能的比较。从两个表中都可以看出,本文提出的方法标注性能较好。

测试图像			
真实标注	elephant, grass, ground, sky, tree	horse, grass	bus, sky, ground
本文标注	elephant, grass, ground, tree	horse, grass	bus, sky, ground

图 6 部分测试图像标注结果

表 1 提出的方法与文献[14]方法的 F_1 测度值比较

关键字	F_1 值	
	文献[14]	本文方法
sky	0.539	0.816
grass	0.414	0.800
stone	0.313	0.577
clouds	0.233	0.456
flower	0.433	0.539
people	0.379	0.760
horse	0.445	0.527
leaf	0.329	0.845
building	0.418	0.457

表 2 不同标注方法的标注性能比较

标注方法	平均查全率	平均查准率	平均 F_1 值
文献[15]	0.43	0.40	0.414
CMRM	0.320	0.360	0.339
本文方法	0.600	0.552	0.575

由上表结果可以看出,本文图像标注的性能比较好,由于对图像进行了分割,分割的结果对标注的结果有一定的影响,比如马容易被分割成多个对象,云由于分割后形状各异,并且与雪的颜色很相近,所以标注的结果不是很

好。但总体上表明本文的方法计算简单、标注高效。

5 结 论

本文提出了一种基于异构描述子的图像标注方法,其基本思想是采用高斯混合模型来描述各个标注词的底层视觉特征。不同于传统高斯混合模型的地方在于:本文认为不同的特征空间是对标注词的不同侧面描述,因而构建了不同描述算子来表示图像,通过加权平均,得到几个模型的描述最终效果,从而提高了标注的效果。在实验验证部分,选择 Corel 图像库中的图像进行验证,实验的效果表明:所提出的算法在平均查全率、平均查准率和平均 F_1 测度值几个方面都优于 CMRM 方法和文献[15]中的方法。

将来的研究重心在于:如何采用增量学习的方法来学习各个标注词的描述子模型,进而实现在线标注。

参考文献

- [1] WANG C H, YAN SH CH, ZHANG L, et al. Multi-label sparse coding for automatic image annotation[C]//CVPR 2009. IEEE Conference on Computer Vision and Pattern Recognition, 2009. IEEE, 2009: 1643-1650.
- [2] CHIANG C C. Interactive tool for image annotation using a semi-supervised and hierarchical approach [J]. Computer Standards & Interfaces, 2013, 35(1): 50-58.
- [3] HU J W, LAM K M. An efficient two-stage framework for image annotation[J]. Pattern Recognition, 2013, 46(3): 936-947.
- [4] JEON J, LAVRENKO V, MANMATHA R. Automatic image annotation and retrieval using cross-media relevance models[C]//Proceedings of the 26th annual international ACM SIGIR conference on Research and development in informaion retrieval. ACM, 2003: 119-126.
- [5] KE X, LI S, CAO D. A two-level model for automatic image annotation[J]. Multimedia Tools and Applications, 2012, 61(1): 195-212.
- [6] LI R, LU J J, ZHANG Y F, et al. Dynamic

Adaboost learning with feature selection based on parallel genetic algorithm for image annotation[J]. Knowledge-Based Systems, 2010, 23(3): 195-201.

- [7] 李红岩,毛征,袁建建,等. 一种基于算法融合的运动目标跟踪算法[J]. 国外电子测量技术, 2013, 32(12): 36-40.
- [8] 陈娜. 基于高斯混合模型的图像自动标注方法[J]. 计算机应用, 2010, 30(11): 986-987.
- [9] 李小红,武敬飞,张国富,等. 结合分水岭和区域合并的彩色图像分割[J]. 电子测量与仪器学报, 2013, 27(3): 247-252.
- [10] 顾晓东,杨诚. 新的颜色相似度衡量方法在图像检索中的应用[J]. 仪器仪表学报, 2014, 35(10): 2286-2292.
- [11] 王振海. 融合傅里叶描述子和尺度不变特征转换特征的商标检索[J]. 计算机应用, 2011, 31(12): 3395-3398.
- [12] YOON Y, KIM Y H. Geometricity of genetic operators for real-coded representation[J]. Applied Mathematics and Computation, 2013, 219(23): 10915-10927.
- [13] SHI J, MALIK J. Normalized cuts and image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8): 888-905.
- [14] 陈祉宏,冯志勇,贾宇. 考虑视觉焦点权重和词相关性的图像标注方法[J]. 计算机应用, 2011, 31(9): 2518-2512.
- [15] 潘嵩,朱红斌. 改进 k-mans 算法在图像标注和检索中的应用[J]. 计算机工程与应用, 2010, 46(4): 183-185.

作者简介

陈丽琴,1989 年出生,在读硕士生,研究方向为数字图像处理。

E-mail: 731135597@qq.com

金聪,1960 年出生,教授,研究方向为数字图像处理、图像水印、图像语义等。

E-mail: jinc26@aliyun.com